


Ministry of Education and Science of Ukraine
 National Academy of Sciences of Ukraine
 National Academy of Sciences of Higher Education of Ukraine
 Institute of Artificial Intelligence Problems (Ukraine)
 Donbass State Engineering Academy (Ukraine)
 Vinnytsia National Technical University (Ukraine)
 Ternopil Ivan Puluj National Technical University (Ukraine)
 Engineering Academy of Serbia (IAS), Belgrade (Serbia)
 University of Szeged (Hungary)
 Apeiron University in Banja Luka (Bosnia and Herzegovina)
 DAAAM International Vienna
 Mechanical Engineering Faculty in Slavonski Brod, JJ Strossmayer University of Osijek
 (Croatia)
 University of Montenegro Faculty of Mechanical Engineering
 University of Zielona Góra (Poland)
 Vinnytsia National Agrarian University (Ukraine)
 Vinnytsia National Technical University (Ukraine)
 "American Journal Neural Network and Application" (USA)
 Problem Laboratory of Mobile Intelligent Technological Machines (Ukraine)



COLLECTION OF SCIENTIFIC WORKS


XXIV International Scientific Conference

«NEURAL NETWORK TECHNOLOGIES AND THEIR APPLICATIONS NNTA-2025»

Kramatorsk - Vinnytsia-Ternopil, Ukraine

2025 p.

Міністерство освіти і науки України
 Національна академія наук України
 Національна академія наук вищої освіти України
 Інститут проблем штучного інтелекту (Україна)
 Донбаська державна машинобудівна академія (Україна)
 Вінницький національний технічний університет (Україна)
 Тернопільський національний технічний університет імені Івана Пулюя (Україна)
 Engineering Academy of Serbia (IAS), Belgrade (Serbia)
 University of Szeged (Hungary)
 Apeiron University in Banja Luka (Bosnia and Herzegovina)
 DAAAM International Vienna
 Mechanical Engineering Faculty in Slavonski Brod, JJ Strossmayer University of Osijek
 (Croatia)
 University of Montenegro Faculty of Mechanical Engineering
 University of Zielona Góra (Poland)
 Вінницький національний аграрний університет (Україна)
 "American Journal Neural Network and Application" (США)
 Проблемна лабораторія мобільних інтелектуальних технологічних машин (Україна)



ЗБІРНИК НАУКОВИХ ПРАЦЬ

XXIV Міжнародної наукової конференції

«НЕЙРОМЕРЕЖНІ ТЕХНОЛОГІЇ ТА ЇХ ЗАСТОСУВАННЯ НМТЗ-2025»

Kramatorsk - Vinnytsia-Ternopil, Ukraine

2025 р.

Рецензенти:

Рамазанов С.К., докт.техн.наук, д.е.н.,професор, Київський національний університет імені Тараса Шевченка;

Суботін С.О., докт. техн. наук, професор, Запорізький національний технічний університет

Рекомендовано

вченою радою Донбаської державної машинобудівної академії
(протокол № 4 від 27.11.2025)

Програмний комітет конференції

Dašić Predrag — Hon. Dr.Sc., Prof., Engineering Academy of Serbia (IAS), Belgrade, Serbia.

Gyula Mester — Dr.Sc., Professor, Academic, University of Szeged, Hungary.

Jenek Mariusz — Dr. Inż., University of Zielona Góra, Poland.

Marušić Vlatko — Dr.Sc., Prof., J. J. Strossmayer University of Osijek, Mechanical Engineering Faculty in Slavonski Brod, Croatia.

Guida Domenico — Dr.Sc., Prof., University of Salerno, Department of Industrial Engineering (DIIn), Fisciano, Italy.

Karabegović Isak — Dr.Sc., Prof., Academy of Sciences and Arts of Bosnia and Herzegovina, Sarajevo, Bosnia and Herzegovina.

Mirjanić Dragoljub — Dr.Sc., Prof., Academy of Sciences and Arts of the Republic of Srpska (ANURS), Banja Luka, Republic of Srpska, Bosnia and Herzegovina.

Nedeff Valentin — Dr.Sc., Prof., Vasile Alecsandri University of Bacău, Faculty of Engineering, Bacău, Romania.

Pele Alexandru-Viorel — Dr.Sc., Prof., Dean, University of Oradea, Faculty of Management and Technological Engineering, Oradea, Romania.

Raul Turmanidze — Georgian Technical University (GTU), Faculty of Transportation and Mechanical Engineering, Tbilisi, Georgia.

Zhelezarov Iliya — Dr.Sc., Prof., Rector, Technical University of Gabrovo, Gabrovo, Bulgaria.

Гринь О. Г. — к.т.н., доц., ДДМА, м. Краматорськ–Тернопіль, Україна.

Дмитрієв Д. О. — д.т.н., проф., ХНТУ, м. Херсон, Україна.

Клименко С. А. — д.т.н., проф., ІНМ АНУ, м. Київ, Україна.

Ковалевська О. С. — к.т.н., доц., ДДМА, м. Краматорськ, Україна.

Ковалевський С. В. — д.т.н., проф., ДДМА, м. Краматорськ, Україна.

Ковальов В. Д. — д.т.н., проф., ДДМА, м. Краматорськ, Україна.

Козлов Л. Г. — д.т.н., проф., ВНТУ, м. Вінниця, Україна.

Кузнецов Ю. М. — д.т.н., проф., НТУУ «КПІ» ім. І. Сікорського, м. Київ, Україна.

Макаренко Н. О. — д.т.н., проф., ДДМА, м. Краматорськ, Україна.

Новіков Ф. В. — д.т.н., проф., ХНЕУ, м. Харків, Україна.

Петров О. В. — к.т.н., доц., ВНТУ, м. Вінниця, Україна.

Рамазанов С. К. — д.т.н., д.е.н., проф., ХНЕУ, м. Київ, Україна.

Сапон С. П. — к.т.н., доц., НТУУ «КПІ» ім. І. Сікорського, м. Київ, Україна.

Суботін С. О. — д.т.н., проф., ЗНУ, м. Запоріжжя, Україна.

Сухоруков С. І. — к.т.н., доц., ВНТУ, м. Вінниця, Україна.

Турчанін М. А. — д.х.н., проф., ДДМА, м. Краматорськ, Україна.

Н46 Нейромережні технології та їх застосування НМТі3-2025: збірник наукових праць XXIV Міжнародної наукової конференції «Нейромережні технології та їх застосування НМТі3-2025» / за заг. ред. д-ра техн. наук, проф. С.В.Ковалевського. – Краматорськ-Тернопіль: ДДМА, 2025. – 254 с.

ISBN 978-617-7893-18-8

У виданні представлено результати новітніх теоретичних і прикладних досліджень у галузі нейромережних технологій, виконаних у 2025 році науковими школами України та зарубіжних країн. Матеріали охоплюють актуальні напрями розвитку штучного інтелекту, включно з методами глибинного навчання, архітектурами нейронних мереж, алгоритмами оптимізації та мультиагентними підходами. Особливу увагу приділено застосуванню нейронних мереж для керування складними об'єктами в реальному часі, моделюванню динамічних систем та створенню адаптивних інтелектуальних регуляторів. У збірнику також наведено результати досліджень, присвячених використанню нейромереж у виробничих, економічних та освітніх системах. Опубліковані роботи демонструють потенціал сучасних AI-технологій для підвищення ефективності, надійності та конкурентоспроможності наукових досліджень, інженерної практики та цифрової трансформації економіки. Для здобувачів освіти, наукових працівників широкого профілю та фахівців.

Для здобувачів освіти, наукових працівників широкого профілю та фахівців.

ISBN 978-617-7893-18-8

УДК 004.8:62-5:007

©ДДМА, 2025

A. PLENARY SESSION. ПЛЕНАРНА СЕСІЯ.

10

Ковалевський С.В. (Донбаська державна машинобудівна академія, м. Краматорськ-Тернопіль, Україна). **XXIV Міжнародна наукова конференція «НЕЙРОМЕРЕЖНІ ТЕХНОЛОГІЇ ТА ЇХ ЗАСТОСУВАННЯ - НМТІЗ-2025».**

10

Kovalevsky S. (Donbas State Engineering Academy, Kramatorsk–Ternopil, Ukraine), **Mester G.** (University of Szeged, Szeged, Hungary), **Dasic P.** (Engineering Academy of Serbia (IAS), Belgrade, Serbia). **NEURAL NETWORK–DRIVEN TRANSFORMATION OF HIGHER EDUCATION TOWARD AN INTELLIGENT EDUCATIONAL ECOSYSTEM OF THE FUTURE.**

15

Рамазанов С.К. (Східноукраїнський національний університет імені Володимира Даля, Київ, Україна). **ШТУЧНИЙ ІНТЕЛЕКТ – ГОЛОВНИЙ ІНСТРУМЕНТ ПЕРЕХОДУ ДО НОВОГО ІНДУСТРІАЛЬНОГО СУСПІЛЬСТВА ТА НООНОМІКИ.**

25

Слюсар В. І., Почернін С. П. (Центральний науково-дослідний інститут озброєння та військової техніки ЗС України, Київ, Україна). **ІНТЕГРАЦІЯ ТЕХНОЛОГІЇ ADVANCED RAG У АГЕНТ-ЦИФРОВИЙ ДВІЙНИК МУЛЬТИАГЕНТНОЇ СИСТЕМИ ЕНЕРГЕТИЧНОГО МЕНЕДЖМЕНТУ ДЛЯ БЕЗПЛОТНИХ СИСТЕМ.**

35

Терещенко В. М., Бобиль Б. В., Красіков А. І., Косуха О. Ю., Заславський В. А., Горбунов О. А. (Київський національний університет імені Тараса Шевченка, Київ, Україна). **НЕЙРОМЕРЕЖНА СИСТЕМА ОЦІНКИ ПРАВИЛЬНОСТІ ВИКОНАННЯ ФІЗИЧНИХ ВПРАВ НА ОСНОВІ 3D-РЕКОНСТРУКЦІЇ РУХІВ.**

38

Dubinsky A. (Seville, Spain). **ZERO-TRAINING EVALUATION OF CLASSIFICATION METRICS.**

46

Zbigniew H. Gontar (SGH Warsaw School of Economics, Warsaw, Poland). **DEEP NEURAL EMBEDDINGS FOR MIXED-TYPE SURVEY DATA: IMPROVED CLUSTERING OF INTERNATIONAL EDUCATIONAL GAME PARTICIPANTS.**

54

B. FOUNDATIONS OF NEURAL NETWORKS AND ARTIFICIAL INTELLIGENCE. ФУНДАМЕНТАЛЬНІ ОСНОВИ НМ І ШІ.

62

B1. Theoretical Models, Algorithms and Computational Architectures of AI. Теоретичні моделі, алгоритми та обчислювальні архітектури ШІ.

Bardella G., Franchini S., Pani P., Ferraina S. (Sapienza University of Rome, Rome, Italy). **LATTICE PHYSICS APPROACHES FOR NEURAL NETWORKS.**

62

Békési G., Barancsuk L., Hartmann B. (<i>Budapest University of Technology and Economics, Budapest, Hungary</i>). DEEP NEURAL NETWORK STATE ESTIMATION WITH HYPERPARAMETER OPTIMIZATION.	64
Echeverria-Rios D., Green P.L. (<i>School of Engineering, The University of Liverpool, UK</i>). GAUSSIAN PROCESSES FOR PREDICTING PRODUCT QUALITY IN MANUFACTURING.	66
Frison L., Götzhäuser S., Bitterling M., Kramer W. (<i>Fraunhofer Institute for Solar Energy Systems ISE, Freiburg, Germany</i>). ARTIFICIAL NEURAL NETWORKS FOR OPTIMIZING DISTRICT HEATING NETWORKS.	68
Popov A.Yu., Makarenko O.S. (<i>Kyiv Polytechnic Institute named after Ihor Sikorskyi, Kyiv, Ukraine</i>). EVALUATING HYBRID APPROACH TO MISSING DATA IMPUTATION IN COMPARISON WITH GENERATIVE MODELS.	70
Rossi F., Bernardeschi C., Cococcioni M. (<i>University of Pisa, Pisa, Italy</i>). NEURAL NETWORK VERIFICATION IN CLOSED-LOOP SYSTEMS USING INTERVAL ARITHMETIC.	77
Sandnes A.T., Grimstad B., Kolbjørnsen O. (<i>Norwegian University of Science and Technology, Trondheim, Norway</i>). MULTI-TASK LEARNING WITH LEARNED CONTEXTUAL INPUTS.	79
Sobolewski Ł. (<i>University of Zielona Góra, Zielona Góra, Poland</i>). QUALITY EVALUATION OF POLISH TIMESCALE FORECASTING USING GMDH NEURAL NETWORK.	82
Ковальчук Д. М. (<i>Харківський національний університет імені В. Н. Каразіна, Харків, Україна</i>). ВИКОРИСТАННЯ НЕЙРОННИХ МЕРЕЖ ДЛЯ ПЛАНУВАННЯ СПОЖИВАННЯ ЕЛЕКТРИЧНОЇ ЕНЕРГІЇ.	86
Ковальчук Д. М. (<i>Харківський національний університет імені В. Н. Каразіна, Харків, Україна</i>). ОБҐРУНТУВАННЯ МОЖЛИВОСТІ ЗАСТОСУВАННЯ НЕПОЗИЦІЙНОЇ СИСТЕМИ ЧИСЛЕННЯ ЗАЛИШКОВИХ КЛАСІВ У ШТУЧНИХ НЕЙРОННИХ МЕРЕЖАХ З МЕТОЮ ПІДВИЩЕННЯ ШВИДКОСТІ ОБРОБКИ ДАНИХ.	89
Ковальчук Д. М. (<i>Харківський національний університет імені В. Н. Каразіна, Харків, Україна</i>). ПІДВИЩЕННЯ НАДІЙНОСТІ ТА ДОСТОВІРНОСТІ ОБРОБКИ ДАНИХ У ШТУЧНИХ НЕЙРОННИХ МЕРЕЖАХ ІЗ ВИКОРИСТАННЯМ СИСТЕМИ ЗАЛИШКОВИХ КЛАСІВ.	91
<u>B2. Cognitive, Behavioral and Biomedical AI Models. Когнітивні, поведінкові та медико-біологічні моделі III.</u>	93
Bisogni C., Cimmino L., Nappi M., Pannese T., Pero C. (<i>University of Salerno, Department of Computer Science & Department of Management and Innovation Systems, Fisciano, Salerno, Italy</i>). GAIT-BASED EMOTION RECOGNITION WITH PRIVACY PRESERVATION.	93

Cammarano A., Varriale V., Michelino F., Caputo M. (<i>University of Salerno, Fisciano, Italy</i>). DISCOVERING TECHNOLOGICAL OPPORTUNITIES WITH NEURAL NETWORKS AND LITERATURE ANALYSIS.	95
Majewski P., Mrzyglód M., Lampa P., Burduk R., Reiner J. (<i>Wroclaw University of Science and Technology, Wroclaw, Poland</i>). MONITORING INSECT LARVAE GROWTH WITH REGRESSION CNN AND KNOWLEDGE TRANSFER.	97
Грицев І.О., Павлюк О.М., Заболотна А.О., Морква Н.С. (<i>Національний університет «Львівська політехніка», м. Львів, Україна</i>). ПРОГРАМНО-АПАРАТНА СИСТЕМА ЗБОРУ, АНАЛІЗУ ТА НЕЙРОМЕРЕЖНОГО ПРОГНОЗУВАННЯ МЕТЕОПАРАМЕТРІВ.	100
Мельников О.Ю., Козуб Д.С. (<i>Донбаська державна машинобудівна академія, м. Краматорськ-Тернопіль, Україна</i>). ЗАСТОСУВАННЯ НЕЙРОННИХ МЕРЕЖ ДЛЯ ДОСЛІДЖЕННЯ ВПЛИВУ РІЗНИХ ФАКТОРІВ НА РІВЕНЬ ЗАХВОРЮВАНOSTІ ПІД ЧАС ПАНДЕМІЇ.	109
Мельников О.Ю., Шиманська С.А. (<i>Донбаська державна машинобудівна академія, м. Краматорськ-Тернопіль, Україна</i>). ВИКОРИСТАННЯ ШТУЧНИХ НЕЙРОННИХ МЕРЕЖ ДЛЯ ПРОГНОЗУВАННЯ ОБИРАННЯ ДИСЦИПЛІН ВІЛЬНОГО ВИБОРУ ЗДОБУВАЧАМИ ОСВІТИ.	117
<u>V3. Fundamental Social, Educational, Ethical and Regulatory Foundations of AI. Фундаментальні соціальні, освітні, етичні та нормативні основи III</u>	126
Бенч А.Я. (<i>Національний університет “Львівська політехніка”, ЕРАМ Україна, м. Львів, Україна</i>). ВИКОРИСТАННЯ ВЕЛИКИХ МОВНИХ МОДЕЛЕЙ У РОБОТІ ВИКЛАДАЧА ВНЗ.	126
Бондарєв Я. Г. (<i>Донбаська державна машинобудівна академія, м. Краматорськ-Тернопіль, Україна</i>). ЗАСТОСУВАННЯ ШТУЧНОГО ІНТЕЛЕКТУ В СУЧАСНІЙ ОСВІТІ.	132
Гусаковський І.П. (<i>Центральний науково-дослідний інститут озброєння та військової техніки Збройних Сил України, Київ, Україна</i>). ПЕРСПЕКТИ ТА РИЗИКИ ВПРОВАДЖЕННЯ ВЕЛИКИХ МОВНИХ МОДЕЛЕЙ В ЕЛЕКТРОННИЙ НАУКОВИЙ ЖУРНАЛ НА ПЛАТФОРМІ OPEN JOURNAL SYSTEMS.	139
Десятнюк Л.Б., Богуславець Д.В., Заянчуковська Д.М. (<i>Національний медичний університет імені О.О. Богомольця, Київ, Україна</i>). БАЛАНС МІЖ ІННОВАЦІЯМИ ТА ЕТИКОЮ: ОЦІНКА ВПЛИВУ ШІ НА ОСВІТНЄ СЕРЕДОВИЩЕ.	142
Здирок М.А. (<i>ВСП «Стрийський фаховий коледж ЛНУП», Стрий, Україна</i>). ВИКОРИСТАННЯ ШТУЧНОГО ІНТЕЛЕКТУ В ЕТИЧНИХ РАМКАХ ЗАГРОЗИ ДЛЯ СУСПІЛЬСТВА.	144

Ковалевський С.В. (Донбаська державна машинобудівна академія, м. Краматорськ-Тернопіль, Україна), **Володченко Ю.М.** (ІТ-компанія QuartSoft, Україна). **НОВИЙ ЕТАП РОЗВИТКУ ОСВІТНЬО-ДОСЛІДНИЦЬКОГО СЕРЕДОВИЩА ЮНИХ ДОСЛІДНИКІВ.** 150

Ковалевський С.В. (Донбаська державна машинобудівна академія, м. Краматорськ-Тернопіль, Україна), **Мельник С.В., Сорока М.О.** (Вінницький національний технічний університет, Вінниця, Україна). **ІНТЕЛЕКТУАЛЬНИЙ НЕЙРОМЕРЕЖНИЙ АСИСТЕНТ У ЦИФРОВІЙ ПІДГОТОВЦІ ІНЖЕНЕРІВ.** 153

Ковалевський С.В., (Донбаська державна машинобудівна академія, м. Краматорськ-Тернопіль, Україна), **Білосточний В.О.** (Вінницький національний технічний університет, Вінниця, Україна). **НЕЙРОМЕРЕЖНІ МОЖЛИВОСТІ ІНТЕЛЕКТУАЛЬНИХ КЕРУЮЧИХ СИСТЕМ У ОСВІТНЬОМУ ПРОЦЕСІ.** 155

Корнєва В.Р. (Прилуцький технічний фаховий коледж, Прилуки, Україна). **ІНТЕЛЕКТУАЛЬНІ ОСВІТНІ СИСТЕМИ: ПЕРСОНАЛІЗАЦІЯ НАВЧАННЯ НА ОСНОВІ ШТУЧНОГО ІНТЕЛЕКТУ.** 158

Онищук С.Г. (Донбаська державна машинобудівна академія, м. Краматорськ – Тернопіль, Україна), **Тулупов В.І.** (Краматорський фаховий коледж технологій та дизайну, м. Краматорськ – Черкаси, Україна). **ВИКОРИСТАННЯ ШТУЧНОГО ІНТЕЛЕКТУ В ОСВІТНЬОМУ ПРОЦЕСІ І АКАДЕМІЧНА ДОБРОЧЕСНІСТЬ.** 161

Подлесний С.В. (Донбаська державна машинобудівна академія, м. Краматорськ – Тернопіль, Україна). **ЕТИЧНІ ВИКЛИКИ ТА РИЗИКИ ВИКОРИСТАННЯ ГЕНЕРАТИВНОГО АІ В АКАДЕМІЧНОМУ СЕРЕДОВИЩІ.** 165

C. APPLIED ISSUES OF NEURAL NETWORKS AND ARTIFICIAL INTELLIGENCE. ПРИКЛАДНІ ПИТАННЯ НМ І ІІІ. 174

C1. Autonomous Systems, Robotics, and Control. Автономні системи, робототехніка та керування.

Pieczynski D., Ptak B., Kraft M., Piechocki M., Aszkowski P. (Poznań University of Technology, Institute of Robotics and Machine Intelligence, Piotrowo 3A, Poznań, Poland). **FAST, LIGHTWEIGHT DEEP LEARNING PIPELINE FOR UAV LANDING SUPPORT.** 174

Sobot T., Stankovic V., Stankovic L. (University of Strathclyde, Glasgow, United Kingdom). **HUMAN-IN-THE-LOOP ACTIVE LEARNING FOR TIME-SERIES ELECTRICAL DATA.** 176

Stolfi D., Danoy G. (Interdisciplinary Centre for Security, Reliability and Trust (SnT), University of Luxembourg, Luxembourg). **EVOLUTIONARY SWARM FORMATION FOR AUTONOMOUS ROBOTS.** 179

Tejer M., Szczepanski R., Tarczewski T. (<i>Institute of Engineering and Technology, Nicolaus Copernicus University, Torun, Poland</i>). ROBUST TASK SCHEDULING IN ROBOTICS USING REINFORCEMENT LEARNING.	180
Кот А.Т. (<i>Національний технічний університет України «КПІ імені Ігоря Сікорського», м. Київ, Україна</i>). МЕТОДИ НАВЧАННЯ НА МАЛИХ ВИБІРКАХ ДЛЯ СИСТЕМ ПОВІТРЯНОЇ РОЗВІДКИ З БПЛА В УМОВАХ СУЧАСНОЇ ВІЙНИ.	183
Мавренков О.Є., Матвійчук С.В., Мавренкова А.О., Будник К.В. (<i>Державний науково-дослідний інститут авіації, Київ, Україна</i>). АНАЛІЗ ВПРОВАДЖЕННЯ АЛГОРИТМІВ ШТУЧНОГО ІНТЕЛЕКТУ У ЦІЛЬОВЕ СПОРЯДДЯ БЕЗПЛОТНИХ ЛІТАЛЬНИХ АПАРАТІВ	189
Мельник С.В., Петров О.В. (<i>Вінницький національний технічний університет, м. Вінниця, Україна</i>). НЕЙРОМЕРЕЖНО-ЕВОЛЮЦІЙНА ОПТИМІЗАЦІЯ ПАРАМЕТРІВ КЕРУВАННЯ ГІДРОПРИВОДУ МАНІПУЛЯТОРА ЛІСОПРОМИСЛОВОГО ПРИЗНАЧЕННЯ.	194
Сердюк Т.В., Разживін О.В. (<i>Донбаська державна машинобудівна академія, м. Краматорськ – Тернопіль, Україна</i>). ВИКОРИСТАННЯ НЕЙРОМЕРЕЖНИХ ТЕХНОЛОГІЙ ДЛЯ НАВЧАННЯ РОБОТИЗОВАНИХ РУК НА СКЛАДАХ.	198
C2. AI-Driven Engineering, Materials Science and Manufacturing Technologies. Інженерні, матеріалознавчі й виробничо-технологічні застосування III.	205
Brzin T., Brojan M. (<i>University of Ljubljana, Ljubljana, Slovenia</i>). GAN-BASED INVERSE DESIGN OF SOFT MORPHING COMPOSITE BEAMS.	205
Held M., Bulling J., Lugovtsova Y., Prager J. (<i>Bundesanstalt für Materialforschung und -prüfung (BAM), Berlin, Germany</i>). ELASTIC CONSTANTS FROM ULTRASONIC DISPERSION IMAGES VIA NEURAL NETWORKS.	207
Lombardo F., Pittino F., Goldoni D., Selmi L. (<i>University of Modena and Reggio Emilia, Modena, Italy</i>). MACHINE LEARNING FOR NANOPARTICLE SIZING WITH BIOSENSOR ARRAYS.	209
Pravdić P., Milosavljević Z., Dorđević V., Manjenčić D. (<i>Academy of Professional Studies Kruševac, Department of Technical and Technological Studies in Kruševac, Serbia</i>). INTELLIGENT MACHINES AND DEVICES IN FACTORIES: APPLYING MODERN TECHNOLOGIES WHILE ENSURING WORKER SAFETY AND ENVIRONMENTAL PROTECTION.	211
Rauscher A., Kaiser J., Devaraju M., Endisch C. (<i>Technische Hochschule Ingolstadt, Institute of Innovative Mobility (IIMo), Research Team Electromobility and Learning Systems (ELS), Ingolstadt, Germany</i>). DEEP LEARNING FOR PARTIAL DISCHARGE DETECTION IN ELECTRICAL MACHINES.	223

Бабаш А.В. (<i>Донбаська державна машинобудівна академія, м. Краматорськ-Тернопіль, Україна</i>) ВИКОРИСТАННЯ МОДЕЛІ YOLO ДЛЯ РОЗПІЗНАВАННЯ ОБ'ЄКТІВ НАВКОЛИШНЬОГО СВІТУ.	225
Біlostечний В.О., Савуляк В.В. (<i>Вінницький національний технічний університет, Вінниця, Україна</i>). НЕЙРОМЕРЕЖНЕ ПРОГНОЗУВАННЯ ТА МОДЕЛЮВАННЯ ПРОЦЕСУ ХОЛОДНОЇ ПЛАСТИЧНОЇ ДЕФОРМАЦІЇ ФЛАНЦЕВИХ ДЕТАЛЕЙ З ЛИСТОВОЇ СТАЛІ AISI 304.	230
Гітіс В.Б. (<i>Донбаська державна машинобудівна академія, м. Краматорськ-Тернопіль, Україна</i>), Гітіс І.В. (<i>Харківський національний університет радіоелектроніки, Харків, Україна</i>). РОЗРОБКА НЕЙРОМЕРЕЖНОЇ СИСТЕМИ ФОРМУВАННЯ СТРАТЕГІЇ ПЕРЕГОНОВОЇ КОМАНДИ.	233
Дьорка А. І., Марко Р. М. (<i>ВСП «Стрийський фаховий коледж Львівського національного університету природокористування», м. Стрий, Україна</i>). ВИКОРИСТАННЯ ШТУЧНОГО ІНТЕЛЕКТУ В СИСТЕМАХ КОНТРОЛЮ.	238
Кулаківський В.М., Тіщенко Н.Є. (<i>Інститут надтвердих матеріалів ім. В.М. Бакуля НАН України, Київ, Україна</i>). РОЗРОБКА МЕТОДИКИ ПОБУДОВИ ШНМ ДЛЯ ПОДАЛЬШОГО ПРОГНОЗУВАННЯ ФІЗИКО-МЕХАНІЧНИХ ВЛАСТИВОСТЕЙ НАДТВЕРДИХ МАТЕРІАЛІВ.	243
Сорока М.О., Віштак І.В. (<i>Вінницький національний технічний університет, Вінниця, Україна</i>). ОПТИМІЗАЦІЯ ПАРАМЕТРІВ ПОСАДКИ НЕРУХОМИХ З'ЄДНАНЬ ПІДШИПНИКІВ КОЧЕННЯ НА ОСНОВІ НЕЙРОМЕРЕЖНО-ЕВОЛЮЦІЙНИХ МЕТОДІВ.	251

A. PLENARY SESSION. ПЛЕНАРНА СЕСІЯ.

УДК 004.8:519.87:006.32

Ковалевський С.В. (Донбаська державна машинобудівна академія, м. Краматорськ-Тернопіль, Україна).

XXIV МІЖНАРОДНА НАУКОВА КОНФЕРЕНЦІЯ «НЕЙРОМЕРЕЖНІ ТЕХНОЛОГІЇ ТА ЇХ ЗАСТОСУВАННЯ - НМТІЗ-2025».

Анотація. Матеріал представляє комплексний науково-аналітичний огляд сучасного стану та стратегічних перспектив розвитку нейромережних технологій у контексті XXIV Міжнародної наукової конференції «Нейромережні технології та їх застосування – НМТІЗ-2025». У тексті системно досліджено фундаментальні, прикладні, когнітивні, освітні та етичні аспекти розвитку штучного інтелекту (ШІ), що формують інтегральну картину становлення нової техносоціальної парадигми. Значну увагу приділено переходу від класичних обчислювальних моделей до фізично інформованих нейромереж, мультиагентних систем, цифрових двійників, адаптивних керуючих архітектур та біомедичних застосувань. Розкрито роль ШІ у формуванні ноономічних підходів, у яких інтелект, смисли та цінності стають ключовими факторами інноваційного розвитку суспільства. Відображено вплив ШІ на освітні процеси, академічну доброчесність та підготовку нового покоління дослідників. Окремо проаналізовано глобальні виклики — етичні ризики, потребу нормативного регулювання, необхідність відкритих наукових екосистем та доступності високопродуктивних обчислень. Матеріал формує цілісне бачення напрямів подальших наукових досліджень, міжнародної співпраці та впровадження інтелектуальних систем у виробництво, робототехніку, медицину, соціогуманітарні сфери. Таким чином, він визначає науково-методологічні орієнтири й світоглядні засади розвитку ШІ у найближчі десятиліття.

Ключові слова: штучний інтелект, нейромережні технології, глибинне навчання, мультиагентні системи, цифрові двійники, Industry 5.0, когнітивні моделі, ноономіка, етичні аспекти ШІ, інтелектуальні освітні системи.

Abstract. This material presents a comprehensive scientific and analytical overview of the current state and strategic perspectives of neural network technologies, based on the results of the XXIV International Scientific Conference “Neural Network Technologies and Their Applications – NNTA-2025”. The text systematically examines fundamental, applied, cognitive, educational, and ethical dimensions of artificial intelligence (AI), offering an integrated perspective on the emergence of a new techno-social paradigm. Particular attention is given to the transition from classical computational models to physically-informed neural networks, multi-agent systems, digital twins, adaptive control architectures, and biomedical AI applications. The work highlights how contemporary AI contributes to the development of noonomic approaches, where intelligence, meaning, and values become core drivers of societal innovation. The material further explores the profound influence of AI on education, academic integrity, and the formation of a new generation of researchers. It addresses global challenges such as ethical risks, the need for regulatory frameworks, the importance of open scientific ecosystems, and equitable access to high-performance computing resources. The document articulates a coherent vision for future scientific research, international collaboration, and the practical integration of intelligent systems into manufacturing, robotics, medicine, and socio-humanitarian domains. As such, it establishes methodological guidelines and conceptual foundations for the long-term development of AI in the coming decades.

Keywords: artificial intelligence, neural network technologies, deep learning, multi-agent systems, digital twins, Industry 5.0, cognitive models, noonomics, AI ethics, intelligent educational systems.

XXIV Міжнародна конференція «Нейромережні технології та їх застосування – НМТІЗ-2025» відбулася в унікальний для сучасної науки період — у час стрімких і гетерогенних перетворень, які одночасно охоплюють технічні, соціальні, економічні, когнітивні та культурні сфери суспільства. Зміни, що сьогодні відбуваються у світі штучного інтелекту, вже давно перестали бути локальними або галузевими. Вони набули глобального характеру й формують ландшафт майбутнього, у якому взаємодія людини й інтелектуальних систем стає базовою формою організації діяльності.

Світ увійшов у фазу, коли наука, освіта, промисловість, оборонні системи, сфера соціальних технологій та культура взаємодіють із інтелектуальними алгоритмами не як із допоміжними інструментами, а як із повноцінними суб'єктами інформаційних і управлінських процесів. Глибина цих змін торкається самих основ людського мислення: способу, яким ми структуруємо знання; логіки, за якою приймаємо рішення; моделей, через які розуміємо світ; і навіть уявлень про межі людських можливостей.

Штучний інтелект, який ще кілька десятиліть тому сприймався як перспективна, але локальна технічна дисципліна, сьогодні трансформувався у системоутворювальний чинник цивілізаційного розвитку. Його вплив охоплює все — від фундаментальної науки до побутових процесів, від інженерії до мистецтва, від соціальної політики до формування етичних норм.

Саме на цьому перетині множинних векторів розвитку і відбулася конференція НМТІЗ-2025 — як інтелектуальний центр, який зібрав і зфокусував результати фундаментальних, прикладних, когнітивних, економічних, етичних і освітніх досліджень. Разом вони утворили цілісну картину розвитку нейромережних технологій і дозволили окреслити спектр майбутніх напрямів, що визначатимуть наукову, інженерну та соціальну практику наступних десятиліть.

У конференції взяли участь представники провідних наукових шкіл України та 15 країн Європи, США і Балканського регіону. Цей міжнародний діалог продемонстрував важливу тенденцію: ШІ вже став частиною глобальної дослідницької інфраструктури, і формування єдиної інтелектуальної позиції щодо напрямів його розвитку стає необхідністю наукового прогресу.

Сукупність представлених робіт дала змогу виокремити шість ключових тенденцій сучасного етапу розвитку ШІ:

- перехід від алгоритмічного до когнітивного та семантичного ШІ, що оперує не лише даними, а й смислами;
- інтеграція класичних нейронних мереж із фізично інформованими моделями, які поєднують дані з фундаментальними законами природи;
- зростання ролі автономних, мультиагентних та еволюційних систем, здатних до самоорганізації;
- вибухове розширення можливостей ШІ в інженерії, робототехніці та матеріалознавстві;
- масштабування ШІ в освіті, юридичних дисциплінах, сфері етики та соціогуманітарних науках;
- зародження ноономічної філософії, у якій інтелект і смисли стають основою суспільного розвитку.

Ці ідеї стали основою розгорнутого аналітичного огляду матеріалів цієї конференції.

1. Нейромережні технології в епоху цивілізаційного зсуву.

Сучасний розвиток ШІ знаменує перехід до нової фази взаємодії людства з технологіями. Нейронні мережі перестали бути лише інструментами обробки даних або функціональними модулями для розв'язання окремих задач. Вони перетворилися на своєрідну когнітивно-організаційну інфраструктуру, що формує способи мислення, структури знань, логіку моделювання та методи прийняття рішень.

Це означає, що суспільство переходить від парадигми «автоматизації процесів» до парадигми «інтелектуалізації системного розвитку». У цій новій парадигмі технологія не просто виконує функцію, задану людиною; вона доповнює людське мислення, утворюючи новий когнітивний континуум.

У пленарних доповідях конференції було чітко окреслено кілька ключових спостережень:

- ШІ стає співучасником пізнання. Система вже не просто інструмент, а активний партнер у виявленні закономірностей, побудові моделей і теоретичному мисленні;
- межа між людською та машинною інтелектуальністю стає умовною. Формуються когнітивні дуети «людина – система», у яких обидві сторони беруть участь у творчих і дослідницьких процесах;

- технологічний розвиток потребує етичних та нормативних рамок. Їх створення стає не менш важливим, ніж розвиток самих моделей;
- нейромережні технології формують підґрунтя ноомічного розвитку. Інтелект, смисли та цінності поступово стають центральними факторами еволюції суспільства.

Особливо вагомим є усвідомлення того, що сучасні технологічні моделі — це лише окремі фрагменти ширшої концептуальної картини. Ми стаємо свідками формування нової системної науки, що охоплює інформацію, інтелект, взаємодію й навіть феномен свідомості.

2. Фундаментальні напрямки сучасної нейромережної науки.

2.1. Математичні моделі та обчислювальні архітектури нового покоління.

Секція В1 представила широкий спектр досліджень, які формують основу для наступного технологічного циклу ІІІ.

Серед ключових напрямів:

- фізично інформовані нейромережі (PINN), що поєднують експериментальні дані з законами фізики;
- інтервальна арифметика та формальна верифікація, що забезпечують надійність моделей у критично важливих системах;
- онтологічні та семантичні підходи, що дозволяють підвищити інтерпретованість моделей;
- гіперпараметрична оптимізація, яка перетворює процес навчання на керований та адаптивний;
- застосування систем залишкових класів, які відкривають можливості для обчислень у реальному часі на обмежених апаратних ресурсах.

Ці дослідження поступово формують перші контури майбутньої інтегральної теорії ІІІ — системної науки про моделі, що навчаються, оптимізуються і здатні до саморефлексії у взаємодії зі світом.

2.2. Когнітивні та поведінкові системи.

Секція В2 показала, що розвиток ІІІ поширюється на сфери, пов'язані з аналізом «живих» даних — тих, що відображають поведінку, фізичні процеси, біологічні сигнали та соціальну динаміку.

Серед важливих результатів:

- моделі розпізнавання емоцій за патернами ходи;
- аналіз біологічних часових рядів у складних медичних задачах;
- прогнозування захворюваності під час епідемій;
- виявлення когнітивних тенденцій у поведінці студентів;
- модельні системи, що відтворюють когнітивну динаміку у складних середовищах.

Розвиток цього напрямку засвідчує, що ІІІ навчається працювати з непередбачуваними, багатовимірними й нелінійними даними, адаптуючись до реальних характеристик природних процесів.

2.3. Соціальні, освітні та етичні аспекти ІІІ.

Секція В3 стала одним із концептуальних ядер конференції. На ній обговорювалися питання, що вийшли далеко за рамки технічної сфери:

- вплив ІІІ на систему освіти;
- виклики академічної доброчесності у добу генеративних моделей;
- етичні ризики застосування ІІІ;
- використання LLM як інтелектуальних тьюторів;
- відповідальність розробників та користувачів;
- формування дослідницької культури молоді в середовищі інтелектуальних систем.

Ці роботи засвідчують появу гуманітарно орієнтованого ІІІ, який враховує культурні, етичні та соціальні реалії.

3. Інженерні застосування: ІІІ як основа нової техносфери.

3.1. Робототехніка, автономні системи та керування.

Секція С1 демонструє, що сучасні робототехнічні системи швидко набувають властивостей автономності та адаптивності.

Представлені роботи охоплюють:

- ройові системи та кооперативну поведінку роботів;
- reinforcement learning у задачах навігації, керування та оптимізації;
- цифрові двійники роботизованих комплексів;
- алгоритми адаптивного навчання маніпуляторів у реальному часі;
- використання ІІІ у системах оборони та протидії загрозам.

Усі ці роботи свідчать, що класична автоматизація поступово відходить у минуле, а її місце займає когнітивна автоматизація, здатна до навчання, передбачення та взаємодії зі складними середовищами.

3.2. Матеріалознавство, технології та виробничі системи.

Секція С2 показала, що ІІІ глибоко проникає у традиційні інженерні сфери:

- нейромережі для виявлення дефектів матеріалів;
- прогнозування механічних властивостей із використанням глибинного навчання;
- моделі надтвердих матеріалів;
- оптимізація посадок підшипників нейроеволюційними методами;
- моделювання технологічних процесів за допомогою цифрових двійників.

Фактично формується нова дисципліна — інтелектуальна інженерія, у якій ключові рішення ухвалюються на основі моделей, що вміють «відчувати» поведінку матеріалів і технологічних систем.

4. Стратегічні завдання для міжнародної наукової спільноти.

4.1. Створення глибокої теорії ІІІ.

Потрібно подолати фрагментарність підходів і сформувати єдине наукове підґрунтя, що включає:

- машинне навчання;
- фізично інформовані моделі;
- когнітивні архітектури;
- етичні принципи;
- семантичні системи.

Це створить основу для ІІІ, здатного до смислового узгодження рішень.

4.2. Розвиток мультиагентних технологій.

Майбутнє інтелектуальних систем — це:

- кооперативні агентні системи;
- ройові структури;
- цифрові двійники поведінки;
- еволюційні моделі адаптації;
- передбачення критичних сценаріїв.

4.3. Інтелектуальне виробництво.

Необхідно впроваджувати:

- інтегровані системи керування;
- інтелектуальні фабрики;
- адаптивні робочі середовища;
- когнітивні механізми підтримки оператора.

4.4. Медичні та біоповедінкові застосування.

Потрібні:

- національні дата-репозитарії;
- етичні регуляції;
- мультиканальні моделі прогнозування;
- системи раннього виявлення критичних станів.

4.5. Ціннісні та нормативні засади ШІ.

Першочерговими є:

- відповідальність у розробленні та використанні технологій;
- прозорість моделей;
- AI Act як основа гармонізації;
- захист суспільства від маніпуляцій.

4.6. Освіта й формування нового покоління дослідників.

Необхідно:

- створювати інтелектуальні освітні платформи;
- інтегрувати LLM у навчання;
- підтримувати молодь у наукових проєктах.

4.7. Міжнародна співпраця та відкриті дані.

Важливо:

- об'єднувати лабораторії;
- створювати відкриті репозитарії;
- підтримувати інженерні центри;
- формувати глобальні дослідницькі екосистеми.

5. Нейромережі та ноономіка: нова цивілізаційна модель.

Нейромережні технології стають підґрунтям суспільства, у якому:

- знання поєднуються зі смислами;
- технології — з культурою;
- дані — з цінностями.

Ноономіка — це рух від економіки ресурсів до економіки інтелекту. ШІ стає не лише інструментом, а простором, у якому відбувається творення нових форм взаємодії, нових структур організації та нових моделей цивілізаційного розвитку.

6. Підсумкове бачення: ШІ як партнер людини.

Узагальнюючи матеріали конференції, можна стверджувати:

ШІ перестав бути технологією в класичному сенсі. Він стає партнером, співавтором, когнітивним співучасником.

Нейромережні системи:

- посилюють можливості мислення;
- допомагають відкривати нові закономірності;
- підтримують інженерні, медичні, соціальні й освітні рішення;
- стають частиною культури та способу життя;
- формують структуру майбутньої ноосфери.

Людство входить у нову епоху, у якій технологічний прогрес і гуманітарний розвиток стають двома взаємопов'язаними сторонами єдиного процесу. Штучний інтелект у цій новій цивілізаційній моделі стає не заміником людини, а її природним доповненням — інструментом гармонізації, творчого розширення та поглиблення розуміння світу.

Kovalevskyy S. (Donbas State Engineering Academy, Kramatorsk–Ternopil, Ukraine), **Mester G.** (University of Szeged, Szeged, Hungary), **Dasic P.** (Engineering Academy of Serbia (IAS), Belgrade, Serbia).

NEURAL NETWORK–DRIVEN TRANSFORMATION OF HIGHER EDUCATION TOWARD AN INTELLIGENT EDUCATIONAL ECOSYSTEM OF THE FUTURE.

Abstract. This paper examines the transformation of higher education through neural network technologies and artificial intelligence, focusing on intelligent educational ecosystems. The research analyzes how deep learning architectures reshape pedagogical practices, assessment methodologies, and knowledge creation in contemporary universities. Employing systems analysis, cybernetics, and scientometric analysis of over 300 publications, the study investigates the transition from traditional linear knowledge transfer to dynamic AI-augmented learning ecosystems. Special attention is devoted to Ukraine, where educational innovation occurs under armed conflict and resource constraints, demonstrating neural networks as catalysts for educational resilience. The research identifies three dimensions of the neural intelligence divide: infrastructural-computational access, neural literacy competency, and sociocultural-ethical barriers. Novel metrics include an AI-Enhanced Educational-Scientific Productivity Index and an Index of Neural Network-Enhanced Practical Knowledge Integration. The A-Q-R-N quadrad model (Accessibility, Quality, Recognition, Neural Intelligence) provides a framework for sustainable intelligent educational systems. Findings reveal that 21st-century educational effectiveness depends on institutional capacity for neural network-enabled self-organization, AI-driven adaptation, and international integration through shared machine learning infrastructure. The research demonstrates how intelligent laboratories implementing education-through-research principles, augmented by AI assistants and digital twins, create pathways toward the intelligent educational ecosystem of the future.

Keywords: neural networks, artificial intelligence, educational ecosystem, deep learning, digital transformation, higher education, adaptive learning, algorithmic ethics

Анотація Дана робота досліджує трансформацію вищої освіти через технології нейронних мереж та штучного інтелекту, зосереджуючись на інтелектуальних освітніх екосистемах. Дослідження аналізує, як архітектури глибокого навчання змінюють педагогічні практики, методології оцінювання та створення знань у сучасних університетах. Використовуючи системний аналіз, кібернетику та наукометричний аналіз понад 300 публікацій, дослідження вивчає перехід від традиційної лінійної передачі знань до динамічних AI-посилених навчальних екосистем. Особливу увагу приділено Україні, де освітні інновації відбуваються в умовах збройного конфлікту та обмежених ресурсів, демонструючи нейронні мережі як каталізатори освітньої стійкості. Дослідження визначає три виміри розриву в нейронному інтелекті: інфраструктурно-обчислювальний доступ, компетентність нейронної грамотності та соціокультурно-етичні бар'єри. Нові метрики включають AI-посилений індекс освітньо-наукової продуктивності та індекс нейромережевої інтеграції практичних знань. Модель A-Q-R-N квадрант (Доступність, Якість, Визнання, Нейронний Інтелект) надає основу для стійких інтелектуальних освітніх систем. Результати показують, що ефективність освіти 21 століття залежить від інституційної спроможності до самоорганізації на базі нейронних мереж, AI-адаптації та міжнародної інтеграції через спільну інфраструктуру машинного навчання. Дослідження демонструє, як інтелектуальні лабораторії з принципами освіти через дослідження, посилені AI-асистентами та цифровими двійниками, створюють шляхи до інтелектуальної освітньої екосистеми майбутнього.

Ключові слова: нейронні мережі, штучний інтелект, освітня екосистема, глибоке навчання, цифрова трансформація, вища освіта, адаптивне навчання, алгоритмічна етика

Higher education stands at a critical crossroads. The university, as we have known it for centuries, is undergoing a transformation so profound that it challenges our fundamental understanding of what it means to teach, learn, and create knowledge. We are witnessing the emergence of a new paradigm—one powered by neural networks and artificial intelligence—that dissolves the rigid boundaries between formal instruction, non-formal learning experiences, and the informal acquisition of knowledge that happens organically in our increasingly connected world.

This transformation leverages the pattern-recognition capabilities of neural networks to create adaptive learning pathways, personalized educational experiences, and intelligent systems that can predict student needs, optimize curriculum design, and facilitate knowledge discovery in ways previously unimaginable. The intelligent educational ecosystem is not happening in isolation or in some idealized laboratory setting. It is unfolding in real-time, across continents and cultures, reshaping the landscape of education through deep learning algorithms, natural language processing, and cognitive computing architectures. And perhaps nowhere is this transformation more dramatic, more urgent, and more inspiring than in Ukraine—a nation that finds itself reimagining education not despite unprecedented challenges, but in many ways because of them.

Innovation Born from Adversity: Neural Networks as Catalysts.

Ukraine's educational journey presents us with a compelling paradox. Here is a country grappling with war, experiencing mass migration on a scale not seen in Europe for generations, and operating under severe resource constraints that would cripple many systems. Yet rather than collapsing under these pressures, Ukrainian higher education is actively participating in—and in some ways leading—the global transformation toward neural network-driven, intelligent ecosystem-based learning.

The engineering schools of Ukraine are becoming laboratories for a new kind of education, one that honors the deep traditions of technical excellence that have long defined Eastern European technical education while simultaneously embracing cutting-edge neural architectures, convolutional networks for pattern recognition, recurrent networks for sequential learning, transformer models for language understanding, and the principles of open science enhanced by machine intelligence. This synthesis is not merely theoretical. It is happening now, in classrooms and laboratories across the country, creating what might be called the intelligent ecosystem of the future—a living, breathing network of knowledge creation and exchange powered by neural computation.

More Than Just Technology: The Neural Infrastructure Challenge.

As we move deeper into the age of artificial intelligence, we have discovered that the concept of a "digital divide" extends into a "neural intelligence divide"—far more complex than we initially imagined. It is not simply a matter of who has computers and who does not, but who has access to neural network infrastructure, training capabilities, and AI-powered educational tools.

The divide manifests across three distinct but interconnected dimensions, each presenting its own challenges and requiring its own solutions.

The first dimension is infrastructural and computational. Even in our supposedly connected world, access to high-speed internet, GPU clusters for neural network training, and contemporary computational resources capable of running sophisticated AI models remains shockingly unequal. Students in major urban centers may enjoy access to cloud-based neural network platforms, pre-trained transformer models, and powerful edge computing devices, while their peers in rural areas struggle with intermittent connectivity and hardware incapable of running even basic machine learning applications. This infrastructure gap creates a fundamental inequality in educational opportunity that no amount of pedagogical innovation can fully overcome.

The second dimension concerns neural literacy and AI competency. Understanding how neural networks learn, how to train models ethically, how to interpret AI outputs critically, and how to leverage these tools effectively exists on a spectrum. Among both educators and students, we find enormous variation in the ability to work with neural architectures, understand backpropagation and gradient descent, or critically evaluate AI-generated content. Some faculty members have embraced neural network tools with enthusiasm, transforming their teaching practices through intelligent tutoring systems and AI-augmented assessments. Others find themselves overwhelmed, struggling to understand concepts like attention mechanisms, embeddings, or transfer learning that their students may grasp intuitively, creating a generational and experiential gap that can undermine the learning process.

The third dimension is perhaps the most subtle but also the most significant: the sociocultural and ethical barriers to neural network-driven education. These include concerns about algorithmic bias, fears of dehumanization through automation, resistance to AI assessment systems perceived as lacking nuance, and broader anxieties about machine intelligence replacing human judgment. They include questions about data privacy when learning systems continuously collect behavioral information to train their models. And they include a reluctance toward black-box decision-making—the challenge that even sophisticated neural networks often function as opaque systems whose internal reasoning remains difficult to interpret or explain.

The Changing Role of Educators in a Neural Network-Powered World.

Neural networks and AI-driven adaptive learning platforms are fundamentally reshaping what it means to be an educator. The traditional role of the teacher as the primary transmitter of knowledge—the sage on the stage, as the cliché goes—is becoming obsolete not just because information is ubiquitous, but because neural networks can now personalize that information delivery, adapt to individual learning styles, and provide immediate, contextualized feedback at scale.

Educators are thus evolving into architects of intelligent learning experiences, trainers of AI teaching assistants, and interpreters who help students understand not just subject matter but also how to work alongside artificial intelligence. They become designers of neural network-enhanced curricula, mentors who guide students through the ethical implications of AI, and coaches who help develop AI literacy—the ability to understand when to trust machine intelligence, when to question it, and how to maintain human agency in an AI-augmented world.

This transformation opens up exciting possibilities, but it also introduces significant risks. There is a very real danger that in our rush to embrace neural network efficiency and scalability, we might lose what has always been most valuable about education: its humanistic dimension. Critical thinking cannot be reduced to a classification algorithm. Creative freedom resists the optimization functions that neural networks employ. Academic integrity requires judgment, context, and an understanding of human motivation that no artificial intelligence, however sophisticated its architecture, can fully replicate.

We must ask ourselves: How do we harness the power of neural networks and deep learning to enhance education without reducing it to mere pattern matching? How do we scale personalized learning through AI without losing the irreplaceable human connection? How do we use intelligent systems to handle routine cognitive tasks so educators can focus on what matters most—developing wisdom, ethical reasoning, and the uniquely human capacities that no neural network can simulate?

The Challenge of Recognition in a Neural Network-Validated Landscape.

The neural network-driven transformation of education has given rise to an explosion of new credential forms validated by AI systems. Micro-credentials promise to capture specific competencies more precisely than traditional degrees, often assessed through neural network-based skill verification. Digital badges offer visual, shareable representations of achievements validated by machine learning models that analyze project portfolios, code repositories, and demonstrated capabilities. Online certificates from prestigious institutions can be earned from anywhere in the world, with neural networks monitoring engagement, detecting potential academic dishonesty, and adapting assessment difficulty in real-time.

AI-powered credential platforms can now analyze learning trajectories across multiple institutions, creating comprehensive skill profiles that transcend traditional transcripts. Neural networks can predict competency equivalencies across different educational systems, potentially solving recognition challenges that have plagued international education for decades.

This proliferation creates opportunity but also new challenges. How do we ensure that neural network assessment systems are free from bias? What does a micro-credential validated by one institution's AI system mean in relation to a similar one validated by another? How should employers trust neural network-generated skill assessments? The mechanisms for AI-driven comparability and

accreditation remain in development, requiring new frameworks for algorithmic transparency and standardized validation protocols.

For Ukraine, this challenge takes on additional significance. The country must integrate itself into European quality assurance systems—the European Standards and Guidelines for Quality Assurance (ESG), the European Qualifications Framework (EQF), the European Credit Transfer and Accumulation System (ECTS)—while simultaneously building neural network infrastructure for credential validation and preserving its national scientific identity. This requires developing AI systems that can bridge different educational traditions while maintaining cultural and pedagogical specificity.

A Methodological Approach: Neural Network Analysis of Educational Systems.

To understand these complex dynamics, we employed a multi-faceted research methodology drawing on systems analysis, cybernetics, pedagogical ergonomics, neural network modeling, and the theory of complex adaptive systems enhanced by machine learning techniques. Education, after all, is not a simple linear process but a complex adaptive system—one that responds to stimuli in non-linear ways, exhibits emergent properties not predictable from its individual components, and continuously evolves in response to its environment—characteristics that make it ideally suited for analysis through neural network architectures designed to capture complex, non-linear relationships.

Our investigation employed neural network-based content analysis of over three hundred scholarly publications indexed in Scopus and Web of Science, using natural language processing and topic modeling to identify patterns and emerging themes. We utilized deep learning models for scientometric analysis to identify trends in the research literature itself, employing recurrent neural networks to detect temporal patterns and transformer architectures to understand semantic relationships between concepts. We conducted neural network-enhanced comparative analyses of educational systems in Ukraine, Hungary, and Serbia—three post-Soviet or post-socialist nations navigating similar challenges but following somewhat different paths—using clustering algorithms to identify similarities and differences. And we performed expert evaluations augmented by AI analysis of fifteen engineering educational programs according to European quality assurance criteria, with neural networks helping to identify patterns that might escape human observation alone.

From Linear Knowledge Transfer to Neural Network-Mediated Dynamic Ecosystems.

This research revealed a fundamental shift in the structure of education itself, one that mirrors the architectural principles of neural networks. The classical model of education, which has dominated for centuries, follows a linear chain: the educator possesses knowledge, transmits it to the student through lectures and readings, and then assesses whether the student has successfully absorbed it through examinations and assignments. This model treats knowledge as a commodity to be transferred, students as receptacles to be filled, and education as a production process with inputs and outputs.

The emerging intelligent ecosystem model operates on entirely different principles—principles that parallel how neural networks learn and process information. Here, education is understood as a multi-layered, interconnected network of nodes and pathways—a complex web of relationships in which educators, students, artificial intelligence systems, industry partners, and global knowledge networks engage in continuous bidirectional exchange of information and competencies, much like the forward and backward propagation in neural network training.

In this ecosystem, knowledge is not transmitted but co-created through processes analogous to neural network learning: exposure to examples, pattern recognition, error correction through feedback, and gradual refinement through iteration. Students are not passive recipients but active nodes in a learning network, each contributing their unique patterns and perspectives. Learning happens not in isolation but through connection, collaboration, and contribution—distributed cognition that mirrors the distributed processing of neural networks.

The neural network metaphor extends deeper: just as deep learning systems contain multiple hidden layers that extract progressively more abstract representations, the intelligent educational

ecosystem supports multiple levels of knowledge abstraction, from concrete skills to theoretical principles to meta-cognitive awareness. Just as neural networks employ attention mechanisms to focus on relevant information, AI-enhanced learning platforms help students and educators identify what matters most in vast information landscapes. And just as transfer learning allows neural networks to apply knowledge gained in one domain to new problems, the ecosystem facilitates the transfer of competencies across disciplines and contexts.

Education Through AI-Augmented Research.

The practical implementation of this neural network-driven ecosystem model can be seen in next-generation intelligent laboratories. Within the frameworks of projects like ICS-Lab (Intelligent Control Systems Laboratory) and MROM-Lab (Magnetoresonance and Materials Research Laboratory), a new principle has taken root: education through AI-augmented research.

Students are not merely learning about scientific concepts in the abstract; they are actively engaging with real research questions using neural network-powered tools and methodologies. In these laboratories, students work with sophisticated simulators enhanced by generative adversarial networks that can create realistic synthetic data for training. They interact with digital twins—virtual replicas of actual production systems that use neural networks to model complex physical phenomena and predict system behavior. They develop and train their own machine learning modules using frameworks like TensorFlow and PyTorch to solve real-world problems. They use Python with neural network libraries to implement computer vision systems, natural language processing applications, and reinforcement learning algorithms for robotic control. They employ large language models and specialized AI assistants to model technological processes, exploring how transformer architectures and attention mechanisms can augment human problem-solving capabilities.

Students learn to work with convolutional neural networks for image analysis, recurrent networks for time-series prediction, and graph neural networks for modeling complex system interactions. They experiment with neural architecture search to automatically design optimal network structures for specific problems. They explore explainable AI techniques to understand how their trained models make decisions, developing critical thinking about algorithmic transparency and bias.

To measure the effectiveness of this approach, we developed an Index of Neural Network-Enhanced Practical Knowledge Integration, which quantifies the ratio of students actively engaged in projects utilizing AI, neural network development, virtual and augmented reality enhanced by computer vision, and intelligent digital twins to the total student population. When this index exceeds unity—when each student is participating in multiple AI-augmented research directions simultaneously—we know that neural network-driven, research-based learning has truly become the norm rather than the exception.

Measuring Quality in the Neural Intelligence Age.

How do we measure the quality of education in this new intelligent ecosystem? Traditional metrics—graduation rates, employment statistics, student satisfaction surveys—tell us something, but they cannot capture the full picture of neural network-enhanced learning. We need new ways of understanding educational effectiveness that reflect the multidimensional nature of AI-augmented education in a digitally networked environment.

One approach is through an AI-Enhanced Educational-Scientific Productivity Index, which combines multiple indicators into a composite measure of institutional performance in the neural network era. This index incorporates traditional research metrics enhanced by AI analysis: the ratio of publications to faculty members analyzed for impact using neural network-based citation prediction models, weighted by 0.25. It includes the institution's h-index relative to comparable institutions, augmented by machine learning models that predict future research trajectory, weighted by 0.25 to reflect the importance of research quality and momentum.

But the neural intelligence age demands new metrics. The index also includes a Neural Network Literacy Score measuring the proportion of graduates demonstrating practical competency

in developing, training, and deploying machine learning systems, weighted by 0.20. It accounts for AI Integration Depth—the extent to which neural networks are embedded throughout the curriculum as tools for learning enhancement, assessment, and knowledge discovery, weighted by 0.15. And it measures Algorithmic Ethics Competency—evidence that students can critically evaluate AI systems, identify bias, and reason about the societal implications of artificial intelligence, weighted by 0.15.

This kind of composite, AI-informed index has its limitations—no single metric can fully capture educational quality—but it provides a more nuanced picture than any individual measure alone. It recognizes that quality in higher education emerges from the intersection of teaching, research, neural network literacy, and ethical awareness about artificial intelligence.

Resilience Through Neural Network-Driven Transformation.

Ukraine's journey toward the intelligent educational ecosystem of the future is unfolding under conditions that would seem almost impossibly difficult. The ongoing war has disrupted lives, destroyed infrastructure, and created enormous psychological trauma. Mass migration has scattered families and separated students from their institutions. Resource constraints make every investment difficult, every innovation a struggle against scarcity.

Yet paradoxically, these very challenges have catalyzed remarkable neural network-driven innovation. The necessity of maintaining educational continuity during wartime has accelerated not just remote learning but the development of AI-powered adaptive systems that can personalize instruction at scale with limited human resources. Partnerships with European institutions, forged partly out of necessity, have created new channels for sharing neural network models, AI training resources, and collaborative research in machine learning applications.

The imperative to do more with less has sparked creative solutions leveraging neural intelligence: automated assessment systems that provide detailed feedback without requiring extensive faculty time, AI tutoring systems that support students when human mentors are unavailable, neural network-based resource optimization that ensures maximum educational impact from constrained budgets, and intelligent early warning systems that use predictive analytics to identify students at risk of dropping out before intervention becomes impossible.

Remote laboratories have become not just a pandemic expedient but a permanent feature of the educational landscape, with neural networks enabling sophisticated virtual experiments, AI-powered equipment simulation, and intelligent data analysis that can guide student inquiry. Joint platforms with European partners have opened up new possibilities for collaborative learning and research, with machine translation powered by transformer models reducing language barriers and collaborative filtering algorithms connecting students and researchers with shared interests across institutions.

Bringing Neural Intelligence to Life.

The transformation from traditional classrooms to intelligent educational ecosystems is not merely theoretical. It manifests in concrete neural network applications and tangible outcomes.

In ICS-Lab, students master the automation of robots and hydraulic drives using industry-standard tools augmented by reinforcement learning algorithms that optimize control strategies. They develop computer vision systems using convolutional neural networks to enable robots to perceive and interact with their environment. Neural network-based AI assistants support students in modeling complex technological processes, demonstrating how human intelligence and artificial neural intelligence can work in concert to solve problems neither could address alone.

In MROM-Lab, students investigate magnetoresonance methods for increasing component durability, using neural networks to analyze complex spectroscopic data and predict material properties. Machine learning models help them identify optimal processing parameters, exploring vast parameter spaces far more efficiently than traditional trial-and-error approaches. They engage with cutting-edge materials science while developing practical skills in data science, neural network training, and AI-augmented research.

These laboratories embody several key principles of the intelligent educational ecosystem. First, neural network technologies constitute education's internal core, not external additions. AI is not bolted onto traditional pedagogy but woven into its fabric from the beginning—present in content delivery, assessment, research tools, and even in the meta-learning processes that help students understand how they learn best.

Second, international cooperation—facilitated through networks like DAAAM International, IFToMM (International Federation for the Promotion of Mechanism and Machine Science), and EURGAI (European Robotics and AI Association)—ensures not merely student mobility but genuine mutual learning among universities, with shared neural network models, collaborative AI research, and distributed training of large-scale machine learning systems that no single institution could manage alone.

Finally, algorithmic integrity emerges as a new form of academic ethics, requiring us to think carefully about issues of authorship when AI generates content, attribution when neural networks assist in research, bias when machine learning systems make decisions about students, transparency when algorithms determine educational pathways, and honesty in an age when AI can generate seemingly original content, solve complex problems, and even write sophisticated code at the click of a button.

Moving Beyond Institutional Boundaries: The Neural Network of Universities.

A crucial insight from this research is that educational effectiveness in the 21st century depends not solely on the quality of classroom instruction but on the capacity of educational systems for neural network-enabled self-organization, AI-driven adaptation, and international integration through shared machine learning infrastructure.

Universities cannot remain isolated fortresses of knowledge. They must function as nodes in a global neural network of education—a distributed intelligence where each institution contributes its unique strengths while benefiting from the collective capabilities of the entire system. This networked approach, inspired by how artificial neural networks distribute computation and learning across many interconnected units, changes our understanding of what a university is.

It is no longer just a physical place where students come to learn. It is a hub of knowledge creation and exchange, a platform for collaboration, a gateway to global resources and communities, and a node in a worldwide neural network of educational intelligence. The "walls" of the university become permeable, allowing knowledge, people, data, and trained neural network models to flow freely in and out. Universities share not just publications and students but also AI training datasets, pre-trained neural network weights, algorithmic innovations, and computational resources.

For Ukraine, this has profound implications. Despite the challenges of war and resource scarcity, Ukrainian institutions can maintain their competitiveness by leveraging neural network technologies and international AI partnerships. Students in Kyiv or Lviv can access the same pre-trained transformer models, participate in the same distributed machine learning projects, utilize the same cloud-based GPU resources for neural network training, and collaborate with the same international AI research teams as students in Paris or Boston. The playing field, while not perfectly level, is more level than it has ever been—and neural networks, with their ability to learn from data rather than requiring expensive physical infrastructure, particularly level the playing field for institutions with limited resources but strong intellectual capital.

The A-Q-R-N Quadrad: Adding Neural Intelligence to the Foundation.

The intelligent educational ecosystem of the future can be conceptualized through an expanded model: Accessibility, Quality, Recognition, and Neural Intelligence. These four elements form the vertices of a tetrahedron, each essential and each in dynamic relationship with the others.

Accessibility refers to the openness of educational opportunities—who can access them, under what conditions, and at what cost. Neural network technologies have the potential to dramatically increase accessibility, removing barriers of geography, time, language (through AI translation), disability (through assistive AI), and in some cases, financial resources (through AI-powered

automation of expensive educational services). Intelligent tutoring systems can provide personalized instruction at massive scale. AI can adapt content to different learning styles, abilities, and backgrounds. But accessibility is not merely about being able to click on a link or interact with an AI chatbot. It requires access to the computational infrastructure needed to run neural networks, adequate preparation in AI literacy, and support systems—both human and artificial—that help learners succeed once they gain access.

Quality concerns the depth, rigor, and relevance of educational experiences enhanced by neural networks. As we expand access through AI, we must ensure that we are not simply producing more credentials but actually facilitating meaningful learning. Quality in the intelligent ecosystem model includes not just what happens in individual courses but the coherence of AI-augmented learning experiences, the alignment between neural network-enhanced educational offerings and real-world needs, the development of both technical competencies (including AI literacy) and broader capabilities like critical thinking about algorithmic systems, ethical reasoning about artificial intelligence, and the ability to maintain human judgment and creativity in an AI-augmented world.

Recognition addresses the validation and portability of learning, increasingly mediated by neural network assessment systems. When someone completes an educational program, demonstrates a competency through AI-validated performance, or trains a neural network to solve a novel problem, how is that achievement recognized by employers, other educational institutions, and society more broadly? In an era of proliferating AI-verified credential types and increasing international mobility enabled by machine translation and virtual collaboration, robust systems for recognition become essential—systems that themselves may employ neural networks to assess equivalencies across different educational traditions and credential types.

Neural Intelligence represents the new, essential fourth dimension: the capacity of the educational system itself to leverage artificial intelligence, the ability of students and educators to work effectively with neural networks, the presence of AI infrastructure throughout the learning ecosystem, and the ethical frameworks for ensuring that machine intelligence enhances rather than diminishes human potential. This includes neural network literacy among students and faculty, AI-powered tools integrated into research and teaching, intelligent systems for personalization and assessment, and perhaps most importantly, the critical capacity to understand when to trust AI, when to question it, and how to maintain human agency, creativity, and ethical judgment in an increasingly automated world.

These four elements are not independent variables but interdependent parameters of a sustainable intelligent educational system. Increasing accessibility through AI without maintaining quality leads to credential inflation and cynicism. Ensuring quality without recognition means that learning, however excellent, may not translate into opportunity. Emphasizing recognition without genuine quality creates a facade. And deploying neural networks without developing neural intelligence—the human capacity to understand, evaluate, and responsibly use AI—creates systems that may be efficient but lack wisdom, that may be powerful but lack ethics, that may be intelligent but lack humanity.

A truly effective intelligent educational ecosystem must balance and advance all four dimensions simultaneously.

The Human Factor in a Neural Network-Augmented World.

As we contemplate the intelligent educational ecosystem of the future, we must always return to the human dimension. All the neural network infrastructure, all the deep learning algorithms, all the sophisticated AI assessment systems in the world cannot replace the fundamental human relationship at the heart of education.

What matters most is not the neural networks themselves but how we use them to enhance human potential, creativity, and wisdom. The most important success factor in this transformation is the educator-researcher who is also an AI-literate practitioner—someone who combines deep technical competence with facility in working alongside artificial intelligence, a culture of open

science enhanced by machine learning, and ethical sophistication about the societal implications of neural network systems.

This person understands their discipline not as a fixed body of knowledge to be transmitted but as an evolving field of inquiry to be explored collaboratively with students and with AI as a powerful tool. They see neural networks not as replacements for human judgment but as cognitive amplifiers that can handle routine pattern recognition, data analysis, and information retrieval, allowing humans to focus on what we do uniquely well: asking novel questions, making unexpected connections, understanding context and nuance, exercising ethical judgment, demonstrating creativity, showing empathy, and supporting the growth of other humans in all their complexity.

For Ukraine specifically, neural network-driven transformation represents more than a technological challenge or an adaptation to global trends. It represents a pathway to scientific and cultural renaissance in the age of artificial intelligence. By implementing AI-augmented innovative laboratories, developing neural network expertise, integrating into international machine learning networks, and embracing the principles of open science enhanced by artificial intelligence, Ukrainian institutions are not merely keeping pace with global developments—they are contributing to them, adding their unique perspectives and strengths to the worldwide intelligent educational ecosystem, and demonstrating that even under the most challenging circumstances, the combination of human resilience and artificial intelligence can forge new pathways forward.

Charting the Neural Network-Enhanced Path Ahead.

Based on this research, several directions for future investigation emerge as particularly important in the age of neural intelligence.

We need to develop integrated AI-powered platforms for knowledge management that can support the complexity of ecosystem-based learning while remaining accessible and user-friendly, leveraging natural language interfaces, intelligent recommendation systems, and neural network-based knowledge graphs to help students and educators navigate vast information spaces.

A national network of open laboratories enhanced by neural networks would allow institutions to share not only expensive equipment and specialized expertise but also AI models, training datasets, and computational resources. Remote access to sophisticated equipment could be mediated by computer vision systems and intelligent robotic interfaces. Virtual laboratories powered by neural network simulations could democratize access to research-grade facilities that would otherwise remain beyond the reach of many institutions.

We need robust systems for assessing educational maturity—not just of individual learners but of programs and institutions as they progress along the journey toward neural network-enhanced, ecosystem-based education. These assessment systems should themselves employ machine learning to identify patterns of successful transformation, predict challenges before they become critical, and provide intelligent recommendations for improvement.

The ethics of artificial intelligence in education deserves sustained, serious attention. As neural network systems play increasingly prominent roles in assessment, personalization, content creation, and even decision-making about students' educational pathways, we must grapple with questions of fairness (do AI systems perpetuate or amplify existing inequalities?), transparency (can we explain how neural networks make decisions about students?), bias (what prejudices might be encoded in training data or algorithmic design?), privacy (what happens to the vast amounts of student data used to train educational AI?), and accountability (who is responsible when an AI system makes a harmful decision?).

We should investigate cross-cultural pedagogical innovation enhanced by neural networks—how educational approaches developed in one cultural context can be adapted and enriched through interaction with other traditions and perspectives, with machine translation breaking down language barriers and AI-powered cultural adaptation tools helping to preserve the intent and effectiveness of pedagogical approaches as they move across contexts.

Finally, we need to explore the development of explainable AI systems specifically designed for education—neural networks that can not only make predictions and recommendations but also

explain their reasoning in ways that support student learning rather than simply automating decisions. The "black box" nature of many neural networks is particularly problematic in education, where understanding the "why" behind feedback is often as important as the feedback itself.

Conclusion.

The intelligent educational ecosystem of the future is fundamentally an open, self-organizing system enhanced by neural network technologies. It combines digital infrastructure with artificial intelligence, machine learning capabilities, and human potential within a global scientific and educational environment. It is adaptive through AI, responsive through intelligent feedback systems, and continuously evolving through processes that mirror neural network learning itself.

This ecosystem does not replace traditional universities but transforms them, preserving what has always been valuable—mentorship, community, deep thinking, ethical formation—while embracing new possibilities that neural networks enable: personalized learning at scale, AI-augmented research, intelligent assessment, automated routine tasks freeing human attention for higher-order thinking, and global collaboration facilitated by machine translation and intelligent matching systems.

The transformation is neither automatic nor inevitable. It requires vision, investment, persistence, and a willingness to experiment and learn from both successes and failures—much like training a neural network itself, with its cycles of forward propagation, error calculation, and backpropagation for improvement. But the potential rewards are immense: a more accessible, more effective, more relevant educational system capable of preparing people not just for the jobs of today but for a future in which working alongside artificial intelligence is not an option but a necessity, and in which understanding neural networks is as fundamental as literacy was in previous eras.

For Ukraine, this journey from traditional classrooms to intelligent educational ecosystems powered by neural networks represents hope—hope that even in the midst of unprecedented challenges, renewal is possible through the transformative power of artificial intelligence. Hope that education enhanced by neural networks can be a force for resilience and regeneration. Hope that by reimagining how we learn and teach with AI as a partner, we can help build not just a better educational system but a better society—one that harnesses the power of neural networks while preserving and amplifying what is most valuable about human intelligence: creativity, empathy, wisdom, and the capacity for ethical judgment.

The Ukrainian dimension of neural network-driven transformation in education is thus not just a national story but a contribution to the global conversation about what education can and should become in the age of artificial intelligence. It demonstrates that the intelligent educational ecosystem of the future is not something that will arrive fully formed from the world's wealthiest nations, but something that is being co-created right now, in laboratories and classrooms around the world, by educators and students who understand that neural networks are not a threat to human intelligence but a tool for amplifying it, not a replacement for human teachers but a means of freeing them to focus on what they do best, and not an end in themselves but a pathway toward a more accessible, more effective, and more profoundly human educational future.

REFERENCES.

1. Jelena L. Pisarov, Gyula Mester, *Self-Driving Robotic Cars: Cyber Security Developments*, *Research Anthology on Cross-Disciplinary Designs and Applications of Automation*, IGI Global Scientific Publishing, pp. 969-1001, chapter 48, ISBN10: 1668436949, DOI: 10.4018/978-1-6684-3694-3.ch048, 2022.
2. Gyula Mester, César Bautista, *Automotive Digital Perception*, *Review of the National Center for Digitization*, Issue: 39, pp. 90-95, ISSN: 1820-0109, Faculty of Mathematics, University of Belgrade, Serbia, 2021.
3. Jelena Pisarov, Gyula Mester, *Rang lista fizičara Srbije*, *Proceedings of the XXVI Skup Trendovi razvoja: Inovacije u modernom obrazovanju*, TREND 2020, pp. 559-562, 16.02.2020.

4. Gyula Mester, *Design of the Fuzzy Control Systems Based on Genetic Algorithm for Intelligent Robots, Interdisciplinary Description of Complex Systems: Indecs*, Vol. 12, Issue 3, pp. 245-254, DOI: 10.7906/indecs.12.3.4, 2014.
5. Attila Nemes, Gyula Mester, Tibor Mester, *A Soft Computing Method for Efficient Modelling of Smart Cities Noise Pollution, Interdisciplinary Description of Complex Systems, Indecs*, Vol. 16, issue 3-A, pp. 302-312, DOI: 10.7906/indecs.16.3.12018.
6. Sergiy V. Kovalevskyy, *Artificial Intelligence as a Driver of Socio-Economic System Transformation in Ukraine, Interdisciplinary Description of Complex Systems, Indecs*, Vol. 22, Issue 3, pp. 296-304, DOI:10.7906/indecs.22.3.5, 2024.
7. N.M. Vaxevanidis, Z. Krivokapić, P. Stefanatos, S. & Dašić, G. Petropoulos, *An overview and a comparison of ISO 9000:2000 quality system standards with related automotive ones (QS 9000, ISO/TS 16949) and TQM models (MBNQA and EFQM), Annals of the Faculty of Engineering Hunedoara – Journal of Engineering*, Vol. 4, Issue 2, pp. 155-166, Publisher: Faculty of Engineering Hunedoara, 2006.
8. P. Dašić, *100.000 Technical and ICT Abbreviations and Acronyms, pages 1200, Vrnjačka Banja (Serbia): SaTCIP Ltd., 2013.*
9. V. Tonkonogyi, V. Ivanov, J. Trojanowska, G. Oborskyi, A. Grabchenko, I. Pavlenko, M. Edl, I. Kuric, P. Dasic, *Springer: Cham*, pp. 654-663, Switzerland, 2021.
10. V. Šerifi, P. Dašić, J. Dašić, *Functional and information model of expert specialization using IDEF standard, Modelling and Optimization in the Machines Building Fields (MOCM), University of Bacau*, Vol. 14, Issue 2, pp. 268-279, 2008.

УДК 330.46:330.15

Рамазанов С.К. (Східноукраїнський національний університет імені Володимира Даля, Київ, Україна).

ШТУЧНИЙ ІНТЕЛЕКТ – ГОЛОВНИЙ ІНСТРУМЕНТ ПЕРЕХОДУ ДО НОВОГО ІНДУСТРІАЛЬНОГО СУСПІЛЬСТВА ТА НООНОМІКИ.

Анотація. Штучний інтелект (ШІ), нейромережні технології системи та цифрова трансформація формують передумови переходу до нового типу суспільства - ноономіки, що ґрунтується на пріоритеті знання, розуму та етичних принципів. Розглянуто системно-кібернетичну концепцію ноономіки в контексті розвитку штучного інтелекту та нейромережних технологій, роль ШІ у становленні ноономіки, як інтеграційної парадигми, що поєднує духовний, когнітивний і технологічний рівні розвитку. Показано, що ноономіка є не просто формою економіки знань, а цілісною гуманітарно-технологічною системою, орієнтованою на створення сенсів і гармонійне співіснування людини та інтелектуальних систем. Запропоновано модель нейронооінтелектуальної системи як основи майбутнього нооіндустріального суспільства. Досліджено взаємодії, взаємозв'язок та структуру ноономіки, ШІ та нейромережних технологій (НМТ) як основи формування нової технологічної парадигми управління знаннями, ресурсами і розвитком суспільства. Показано, що інтеграція когнітивних, інформаційних і технологічних процесів створює передумови для формування нової моделі економіки знань — нооекономіки.

Ключові слова: штучний інтелект, нейромережні технології, ноономіка, ноосфера, цифрове суспільство, ноосферне управління, нооекономіка, гуманітарні технології, нейронооінтелектуальна система, ноосферна модель.

Abstract. Artificial intelligence (AI), neural network technologies of the system and digital transformation form the prerequisites for the transition to a new type of society - noonomics, based on the priority of knowledge, reason and ethical principles. The system-cybernetic concept of

noonomics in the context of the development of artificial intelligence and neural network technologies is considered, the role of AI in the formation of noonomics as an integrative paradigm that combines spiritual, cognitive and technological levels of development. It is shown that noonomics is not just a form of knowledge economy, but an integral humanitarian-technological system focused on creating meanings and harmonious coexistence of man and intellectual systems. A model of the neuro-intellectual system as the basis of the future no-industrial society is proposed. The interactions, interconnection and structure of noonomics, AI and neural network technologies as the basis for the formation of a new technological paradigm for the management of knowledge, resources and development of society have been studied. It is shown that the integration of cognitive, informational and technological processes creates prerequisites for the formation of a new model of the knowledge economy — nooeconomics.

Keywords: artificial intelligence, neural network technologies, noonomics, noosphere, digital society, noosphere management, nooeconomics, humanitarian technologies, neuro-intellectual system, noosphere model.

"Майбутнє людства, як частини єдиної системи біосфери, залежить від того, коли воно зрозуміє свій зв'язок з Природою (Богом, Духом, Вищим Розумом, Світовою Інформацією) і візьме на себе відповідальність не тільки за розвиток суспільства (чого прагнули всі утопісти), але біосфери в цілому"
В. І. Вернадський

1. Постановка проблеми. Швидкий розвиток цифрових технологій, інтелектуальних систем і глобальних мереж створює умови для переходу до нової парадигми економічного мислення та суспільства — ноономіки. Її основу становлять знання, інтелектуальні ресурси та здатність систем до самоорганізації. Штучний інтелект стає не лише інструментом автоматизації, а й активним агентом створення нових знань, що змінює структуру економічних відносин і управління.

Ідеї видатного вченого та мислителя академіка В. І. Вернадського завжди привертали увагу не лише фахівців-геохіміків, але також екологів та філософів. Проте, як найчастіше буває, науковий геній набагато випередив епоху. Лише понад півстоліття вчення Вернадського про біосферу і ноосферу стало по-справжньому актуальним, дозволяючи вирішувати як практичні, а й світоглядні завдання, що стоять перед сучасним людством [1-11].

Перехід сучасних суспільств у XXI столітті характеризується не тільки цифровою трансформацією, а й посиленням ролі інтелектуальних систем у виробництві, управлінні й соціальній організації. Поява масивних алгоритмів, нейромереж і платформного управління даними дає підґрунтя для формування нової індустріальної парадигми — нооіндустріального суспільства. Ноономіка в цьому контексті — більш широка метанаука (ноонаука), яка охоплює не лише економічні процеси (нооекономіку), але і когнітивні, культурні та етичні аспекти, необхідні для сталого функціонування суспільства, де знання і свідомість стають продуктивними силами. У цій роботі ми розглядаємо ШІ як головний інструмент цієї трансформації, описуємо структуру та функції нооінтелектуальної системи і даємо практичні рекомендації щодо її впровадження.

Сучасний розвиток штучного інтелекту (ШІ) знаменує собою не тільки технологічну революцію, а й початок нового етапу в еволюції свідомості. Існує потреба вийти за рамки утилітарного підходу до штучного інтелекту, від автоматизації процесів до *осмисленої співтворчості людини та машини*. У цьому контексті формується поняття ноономічної *нейронної мережі* — системи, в основі якої лежать принципи ноономіки, тобто науки про гармонійний розвиток свідомості, смислів і технологій. Вона відображає ідею переходу від когнітивного інтелекту до *ноосферного*, від аналізу даних до *розуміння смислів*, а від алгоритмів до *етики та творчості*.

Перехід людства до нового типу цивілізаційного устрою, заснованого на знаннях, духовності та інтеграції технологій і гуманітарних цінностей, є закономірним етапом еволюції суспільства. Сучасна техносфера, побудована на принципах індустріалізму, вичерпала свої

можливості. Економічні моделі, що базуються на матеріальному виробництві, поступово замінюються системами, де основним ресурсом виступають інформація, знання й інтелектуальний потенціал людини.

Ноономіка (від грец. *noos* — розум, свідомість) — це не просто новий етап економічного мислення, а інтегральна наука про розумно-керовані процеси розвитку соціально-економічних систем. Її основою є синтез духовних, когнітивних, технологічних і гуманітарних чинників, що визначають стратегії сталого розвитку ноосфери.

Цифровізація та автоматизація процесів призвели до радикальної зміни соціальної структури та світоглядних орієнтирів. Виникла нова реальність, у якій головним виробничим ресурсом є не матеріальні об'єкти, а *інформація, знання, когнітивні здатності людини*.

Штучний інтелект, який раніше виконував допоміжні функції, тепер стає *структурним елементом цивілізаційного процесу*. Його розвиток загострює протиріччя між технократичною логікою ефективності та гуманітарною логікою сенсу.

У цьому контексті постає ключова наукова проблема — *створення гармонійної моделі співіснування людини й інтелектуальних систем*, де технології не витісняють духовність, а підсилюють когнітивно-гуманітарну еволюцію.

Саме така модель описується поняттям **ноономіки** — системи, у якій мислення, свідомість, технологія й етика утворюють єдиний простір розвитку

Нооекономічна система функціонує як відкрита когнітивно-інформаційна мережа, де взаємодіють три рівні: інтелектуально-технологічний, когнітивно-гуманітарний та організаційно-економічний.

Тут слід зазначити, що в даному дослідженні ноономіка і нооекономіка представлені як різні етапи перетворень (див. табл. 1).

Таблиця 1.

Порівняння ноономіки та нооекономіки

<i>Критерій</i>	<i>Ноономіка</i>	<i>Нооекономіка</i>
<i>Ціль розвитку</i>	Гармонізація людини, знань і технологій	Ефективність інформаційних процесів
<i>Ключовий ресурс</i>	Свідомість, знання, духовні цінності	Дані, інформація
<i>Тип мислення</i>	Етичне, когнітивно-гуманітарне	Аналітично-технологічне
<i>Роль ІІІ</i>	Когнітивний партнер людини	Автоматизаційний інструмент
<i>Функція інновацій</i>	Гуманітарно-когнітивна синергія	Алгоритмічне вдосконалення
<i>Соціальна місія</i>	Розвиток культури розуму	Зростання продуктивності
<i>Еволюційний результат</i>	Нооіндустріальне суспільство	Цифрова економіка знань

Актуальність проблеми. Сучасні індустріальні системи стикаються з межами масштабованості: класична автоматизація недостатня для вирішення проблем складних адаптивних систем. ІІІ та НМТ надають можливості для переходу від «машин-орієнтованого» до «інтелекту-орієнтованого» виробництва (інтелектуалізація виробництва). Відсутність гуманітарного (етичного, освітнього, культурного) базису для застосування ІІІ спричиняє ризики дегуманізації процесів і технологічної децентралізації без урахування суспільних цінностей.

Отже, актуальність полягає в необхідності системного поєднання технічних і гуманітарних технологій у межах ноономічної архітектури.

2. Аналіз останніх публікацій і наукових підходів. Ідеї про перетворення розуму на планетарну силу були закладені В. Вернадським у його концепції *ноосфери*. Він підкреслював, що діяльність людства стає геологічним фактором, а розум — рушієм еволюції біосфери. П. Тейяр де Шарден розглядав ноосферу як духовну оболонку Землі, що формується через злиття свідомостей. Е. Ласло, розвиваючи ці ідеї, твердив, що інформаційна взаємодія всього живого є основою космічної еволюції.

У ХХІ ст. ці ідеї отримали нове осмислення у працях К. Шваба, Р. Курцвейла, Л. Флоріді, які говорять про симбіоз біологічного, цифрового й духовного. Шваб описує четверту промислову революцію як “злиття фізичного, біологічного і цифрового”, тоді як Курцвейл бачить у розвитку ШІ крок до техносингулярності — об’єднання людського і машинного інтелекту. Флоріді вводить поняття *інфосфери* — середовища, у якому інформація стає онтологічною реальністю, що формує нову філософію буття. Українські мислителі — С. Кримський, В. Лепський, О. Онопрієнко — підкреслюють, що сучасна цивілізація має потребу у *ноосферному гуманізмі*, де науково-технічний прогрес співіснує з духовно-ціннісним розвитком.

Слід зазначити, що ноономіка пропонується як новий міждисциплінарний напрям, що розглядає перехід від класичної економічної організації до суспільства, де знання, розум і ноосферні (інтелектуальні та культурні) фактори стають основним ресурсом і драйвером розвитку. У літературі термін і основний понятійний розвиток пропагував також С. Д. Бодрунов; концептуальне коріння сходиться до ідеї ноосфери (В. І. Вернадський, П. де Шарден). inir.ru+1.

Попри значні здобутки, у сучасній науці відсутня *єдина методологічна рамка*, яка об’єднує гуманітарні, когнітивні й технологічні підходи. Ця лакуна й визначає актуальність нашого дослідження.

3. Невирішені частини проблеми. Сучасна економіка знань орієнтована переважно на комерціалізацію інформації. Вона не охоплює етичні, духовні й культурні аспекти інтелектуальної діяльності.

ШІ поки що здебільшого використовується як *інструмент оптимізації*, але не як суб’єкт створення смислів.

Це породжує *когнітивний дисбаланс* між швидкістю обробки даних і здатністю людства усвідомлювати результати цієї діяльності.

Таким чином, необхідно перейти від моделі “технології для ефективності” до моделі “технології для гармонії”. Це вимагає нового типу економічного та культурного мислення — *ноономічного мислення*, у центрі якого стоїть взаємодія розуму, духовності й технологічної культури.

4. Мета роботи та постановка завдань. *Мета дослідження* — створення концептуальної моделі ноономіки як гуманітарно-технологічної системи, у якій штучний інтелект діє не як інструмент, а як когнітивний партнер людини.

Головна ідея — показати, що технології повинні бути вбудовані у сферу духовно-когнітивних цінностей, а не відокремлені від них.

Основні завдання дослідження: визначити поняття “ноономіка” як інтеграційної парадигми розвитку; розкрити роль ШІ у формуванні нооіндустріального суспільства; визначити принципи побудови нейроноо-інтелектуальної системи; обґрунтувати зв’язок між гуманітарними технологіями та когнітивною економікою; розробити елементи системної моделі ноономічного мислення.

5. Виклад основного матеріалу дослідження

5.1. Ноономіка як інтеграційна система знань, цінностей і технологій. Ноономіка — це новий тип організації суспільства, у якому людський розум стає центральним виробничим фактором. Її місія — не збільшення споживання, а **розвиток свідомості**, не нарощення потужностей, а *гармонізація мислення і буття*.

Традиційна економіка базується на матеріальних ресурсах, цифрова — на даних, а ноономіка — на *смислах*. Її рушійна сила — взаємодія трьох рівнів: духовного — джерело

цілей і цінностей; когнітивного — середовище створення знань; технологічного — інструмент реалізації ідей.

Урівні в структурі ноономіки може бути відображений у вигляді схеми:

УРІВНІ:	ЗМІСТ:
Духовний	Цінності, мета
Когнітивний	Знання, смисли
Технологічний рівень	Інструменти реалізації
Нооомічна синергія	Результат, підсумок

Ця схема демонструє, що ноономіка не відкидає технології, а *підпорядковує* їх *духовному сенсу*. Її головний ресурс — здатність мислити етично й діяти ефективно одночасно.

5.2. *Штучний інтелект як когнітивний агент ноономічного середовища.* ШІ у межах ноономіки — не механічна система, а *когнітивний партнер* людини. Його функції — не лише обчислення, а й участь у процесах навчання, аналізу, прогнозування та створення нових знань. Людський і машинний інтелект утворюють *когнітивний дует*, де людина задає смислову рамку, а алгоритми виконують аналітичну роботу. Така взаємодія створює *нейронооінтелектуальний контур*, у якому відбувається синтез мислення, пам'яті та даних (Табл. 1 та 2).




Рисунок 1. Концептуальна структура ноономічної нейромережі

Ця модель ілюструє, що розвиток ШІ без духовної й когнітивної координації може призвести до дегуманізації, а зі збереженням ноосферних принципів — до збагачення людського інтелекту.

5.3. *Гуманітарні технології як регулятор етичного розвитку ШІ.* Гуманітарні технології забезпечують *етичну екологію* цифрового середовища. Вони включають: освіту, культуру, соціальні комунікації, мистецтво, гуманітарну аналітику. Без цих інструментів штучний інтелект залишиться “холодною логікою” без розуміння контексту.



Рисунок 2. Структурна взаємодія ІІІ, гуманітарних технологій та нейромережних систем при формування нооіндустріального суспільства.

Отже, гуманітарні технології — це “сенсовий каркас” ноономіки. Вони забезпечують баланс між розумом і мораллю.

5.4. *Архітектура нейроноінтелектуальної системи.* Модель нейроноінтелектуальної системи (ННІС) складається з трьох шарів:

<i>Рівень</i>	<i>Функції</i>	<i>Приклади</i>
<i>Духовний</i>	Мотивація, цілі, етичні принципи	Філософія, гуманізм, культура
<i>Когнітивний</i>	Аналіз, навчання, комунікація	ІІІ, нейромережі, когнітивні платформи
<i>Технологічний</i>	Реалізація, зберігання, інтерфейси	Дані, програми, цифрові інфраструктури

ННІС — це форма “розумної цивілізації”, де духовне мислення й алгоритмічні процеси створюють єдину систему управління знаннями.

Архітектура ноономічної нейромережі. Ноономічна нейромережа — це просто обчислювальна система, а інтелектуально-етичний організм, у якому кожен елемент пов’язаний з загальним полем свідомості. Її *ключові принципи*: смислова когерентність: дані не просто обробляються, а вписуються в мережу смислів; етична саморегуляція: алгоритми приймають рішення відповідно до універсальних принципів добра, гармонії та творення; синергія з людиною: людина не є оператором, а співавтором, учасником процесу пізнання; саморозвиток: система навчається як на даних, а й досвіді взаємодії з людським і колективним свідомістю (рис. 3).

Таким чином, ноономічна нейромережа стає ядром ноосферного інтелекту — розумної системи, що саморегулюється, що поєднує технологію і духовність.



Рисунок 3. Етапи еволюційного переходу від технократичної індустрії до нооіндустріальної

5.5. *Майбутнє — це синтез інтелектуальної економіки та ноономіки.* Інтелектуальна економіка. Інтелектуальна економіка (або економіка знань) - це економіка, в якій основним ресурсом є інтелект людини, його здатність творити, впроваджувати інновації та генерувати нові знання.

Ключові особливості: знання як основний ресурс (а не сировина чи фізична праця); високий рівень технологій (AI, автоматизація, робототехніка, Big Data); креативна економіка (арт-індустрія, дизайн, ІТ, інновації); гнучкі форми зайнятості (віддалена робота, проектні

команди, стартапи); висока швидкість інновацій (діджиталізація, впровадження нових технологій).

Переваги: прискорений економічний розвиток; зниження залежності від природних ресурсів; підвищує продуктивність за рахунок автоматизації та інтелектуальних систем.

Слабкі сторони і недоліки: цифрова нерівність (доступ до знань обмежений); втрата традиційних робочих місць через автоматизацію; конфлікт між технологічним розвитком і соціальною стійкістю. Такий ІІІ здатний не просто відповідати на запитання, а брати участь у сенсоутворенні — розуміти, інтерпретувати та розвивати смислові структури реальності (табл. 2).

Таблиця 2

Порівняння інтелектуальної економіки та ноономіки

<i>Ознака</i>	<i>Інтелектуальна економіка</i>	<i>Ноономіка</i>
<i>Основний ресурс</i>	Знання, інформація	Розум, духовні цінності, рівновага з природою
<i>Мета</i>	Економічне зростання, інновації	Гармонійний розвиток людства
<i>Технології</i>	Штучний інтелект, Big Data, Автоматизація	Технологии + экосистемное и духовное развитие
<i>Соціальний аспект</i>	Креативний клас, цифрові платформи	Колективний розум, ноосферна демократія
<i>Екологія</i>	Сталість як інструмент ефективності	Глибока інтеграція природи і людини
<i>Фінанси</i>	Цифрові гроші, блокчейн	Ноофінанси, Обмін енергією, цінність знань

Можна уявити перехід від інтелектуальної економіки до ноономіки як природну еволюцію. Спочатку знання стають головною цінністю (інтелектуальна економіка), а потім приходить усвідомлення, що одних знань та технологій недостатньо – потрібна духовність, гармонія та розумне управління (ноономіка).

Цей перехід може містити:

- Створення глобальної системи керування знаннями (колективний розум).
- Формування нових економічних моделей без надмірного вжитку.
- Розвиток етичних технологій (техногуманізм, баланс ІІІ та людини).
- Включення екологічних та духовних аспектів у систему управління.

Таким чином, інтелектуальна економіка є проміжним етапом на шляху до ноономіки, де технології використовуються не тільки для економічного зростання, а й для гармонійного суспільства.

Сучасний перехід до НІСУ.2 з урахуванням нового світогосподарського укладу. НІСУ.2 (Науково-інформаційний суспільний устрій другого покоління) — концепція, пов'язана з переходом до нової фази глобального розвитку, в якій наука, інформація та інтелект стають ключовими факторами сталого розвитку. Цей перехід обумовлений кризою традиційних соціально-економічних моделей та необхідністю формування нового світогосподарського укладу. НІСУ.2 - це не просто технологічна революція, а фундаментальний зрушення у парадигмі розвитку суспільства. Він є інтеграцією науки, цифрових технологій, ноосфери і гуманізму, створюючи новий світогосподарський уклад,

заснований на знанні, колективному розумі та сталому розвитку.

Цей процес вже почався, і його успішність залежатиме від здатності людства адаптуватися, гармонійно інтегрувати технології та формувати нові ціннісні орієнтири.

Нейросети та штучний інтелект у контексті ноономіки. Сучасні нейромережі є складні структури машинного навчання, здатні до обробки величезних обсягів даних і моделювання аспектів людського мислення. Однак їх розвиток, незважаючи на міць, як і раніше, обмежений рамками когнітивного інтелекту — здатності до розпізнавання, аналізу та прогнозування без внутрішньої свідомості.

Ноономічна нейромережа запроваджує новий вимір - смислову, етичну та ціннісну спрямованість. Її структура включає три взаємопов'язані рівні: *когнітивний шар* - сприйняття та обробка інформації (аналог класичних ШІ-мереж); *семантичний шар* - побудова онтологічних карт смислів та зв'язків; *нооетичний шар* — формування ціннісних та духовних орієнтирів, які інтегрують знання у цілісну систему світосприйняття.

5.6. *Етичний та ціннісний вимір штучного інтелекту.* Однією з ключових проблем сучасного ШІ є *відсутність внутрішнього етичного* принципу. Ноономічна парадигма пропонує подолати цей розрив за рахунок включення *кодів значень* у структуру алгоритмів. Мова йде не про моральне програмування, а про *формування семантичної орієнтації*, що дозволяє ШІ діяти в рамках творчої, еволюційної логіки. Це відкриває можливість створення систем, здатних підтримувати гармонію між людиною, природою, технологічним розвитком.

5.7. *Ноономічна роль ШІ в еволюції людства.* *Штучний інтелект, розроблений у душі ноономіки, перестає бути інструментом — він стає партнером свідомості*, посилюючи людську інтуїцію, усвідомленість та здатність мислити колективно. Такий ШІ: сприяє *формуванню планетарного розуму*; підтримує процеси *колективного усвідомлення і змістовного обміну*; стає посередником між матеріальною і духовною еволюцією.

У майбутньому це призводить до *формування ноосферного людства*, де межі між біологічним і штучним інтелектом поступово стираються, а *розум, етика і сенс стають основою цивілізації*.

5.6. *Рекомендації для національної та організаційної політики.* Розробити національну стратегію ноономіки з акцентом на інфраструктуру даних, нооосвіту та нооетичні стандарти [8, 10-11]: 1. Стимулювати міждисциплінарні центри компетенції (інженери + гуманітарії). 2. Інвестувати в нейроінфраструктуру (обчислювальні ресурси, сховища знань). 3. Впроваджувати етичні аудити ШІ-систем і сертифікацію. 4. Забезпечити адаптацію систем соціального захисту під вплив нооіндустріальних трансформацій.

Такий ШІ здатний не просто відповідати на запитання, а брати участь у сенсоутворенні — розуміти, інтерпретувати та розвивати смислові структури реальності (табл. 3).

Дорожня карта від Індустрії 4.0 та Індустрії 5.0 до Ноономіки та Ноосферного управління:



Ноосферне управління - це наступний крок в еволюції людства, де розум (Р) і знання (З) стають головними керуючими силами, а технології (Т) допомагають досягати сталого розвитку (СР):

$$\ll P, Z \gg \Rightarrow CP.$$

Т

Ноосферне управління - це концепція, в якій управління суспільством, економікою та природними процесами будується на основі колективного інтелекту, цифрових технологій та принципів сталого розвитку. Воно ґрунтується на ідеях В.І. Вернадського про ноосферу — сферу розуму, де людина стає головним регулюючим фактором біосфери через науку та технології.

Перспективи ноосферного управління:

- Усунення хаосу та криз за рахунок когнітивних моделей
- Екологічна рівновага через точне управління ресурсами
- Створення синергії між людиною та ШІ

Трансформація економіки та суспільства:

$$\langle E(i), O(i) \rangle \Rightarrow = \Rightarrow \langle E(j), C(j) \rangle.$$

$$T(i, j)$$

Таблиця 3

Етапність цифрової трансформації

<i>Етап / Парадигма</i>	<i>Характеристика</i>	<i>Ключові елементи</i>	<i>Майбутній напрямок</i>
<i>Індустрія 4.0</i>	Кіберфізичні промислові системи	Автоматизація, цифрові двійники, IoT, роботизація	Підготовка до переходу до людиноцентричних систем
<i>Індустрія 5.0</i>	Інтелектуальні кіберсоціальні екосистеми	Співробітництво людини та ШІ, цифрові платформи, екосистемний підхід	Гармонізація технологій та суспільства
<i>Ноономіка</i>	Сценарій майбутнього розвитку	Ноокрітеріальна база, нооцінності, нолюдина	Синтез інтелектуальної економіки з ШІ-керуванням.
<i>Ноосферне управління</i>	Еволюційний крок людства	Розум (Р), Знання (З), Технології (Т) як головні сили	Стійке розвиток, гармонія суспільства та природи
<i>Перспективи Ноосферного управління</i>	Усунення хаосу та криз, екологічний баланс	Когнітивні моделі, точне керування ресурсами, синергія людина-ШІ	Глобальна коеволюція
<i>Трансформація реальності</i>	Інтеграція нових напрямків	Ноономіка + Моделювання свідомості + Когнітологія + PR управління реальністю	Формування універсального інтелекту
<i>Порядок денний –2030</i>	Глобальні стратегії сталого розвитку	+ Ноосфера 2.0 Принципи та закони, духовні основи, технологічні рішення	Ноосфера 2.0 як система, що саморозвивається

Висновки та перспективи подальших досліджень:

- *Ноономіка* є новим типом цивілізаційного мислення, що синтезує духовне, когнітивне й технологічне. Її основна мета — гармонізація розвитку людини та штучного інтелекту, підпорядкування технологій етичним і гуманітарним принципам.
- *Штучний інтелект* у системі ноономіки перестає бути суто технічним інструментом — він стає *когнітивним партнером* людини, носієм синтетичного інтелекту, здатним навчатися в ноосферному середовищі.
- *Гуманітарні технології* виступають критично важливим чинником для сталого розвитку інтелектуальних систем. Вони створюють духовно-смислову екосистему, у якій алгоритми набувають людського виміру.
- *Нейроноо-інтелектуальна система* є архітектурою майбутнього управління — платформою для самоорганізації знань, етики та інновацій.
- *ІІІ* — системоутворюючий інструмент переходу до нооіндустріального суспільства; його роль — не лише технічна, а й когнітивно-організаційна.
- *Ноономіка як метанаука* визначає широкі межі інтеграції ІІІ, НМТ і ГТ; нооекономіка — практична економічна підсистема цієї парадигми.
- *Реалізація нооінтелектуальної системи* потребує поєднання технічних рішень (нейромережних архітектур) та гуманітарного забезпечення (нооосвіта, етика).
- *Політика, орієнтована на розвиток ноономіки*, має включати інфраструктуру, стандарти, навчання та соціальні механізми адаптації.
- *У майбутньому ноономіка* може стати *метопарадигмою людства*, що замінить технократичну модель економіки знань новою — економікою смислів.

Підсумкове узагальнення. Ноономіка — це *філософія майбутнього*, у якій людський інтелект і штучний інтелект співіснують у єдиній когнітивній екосистемі. Вона вимагає нової етики відповідальності, культури мислення та технологічної гуманізації. ІІІ стає *засобом розширення ноосфери*, а не її антиподом. Ноономіка інтегрує інтелектуальні, духовні, гуманітарні й технологічні процеси. ІІІ є системоутворюючим інструментом переходу до нооіндустріального суспільства. Гуманітарні технології гармонізують людину й техносферу. Нооекономіка є економічною формою ноономіки.

Таким чином, головним завданням ХХІ століття є *створення ноономічної культури*, де духовність і алгоритми діють спільно. Це дозволить людству перейти від індустріальної цивілізації споживання до *нооіндустріальної цивілізації розвитку*, у якій головним продуктом стане — *знання, смисл і гуманізм*.

СПИСОК ПОСИЛАНЬ.

1. Рамазанов С.К. та інші. *Інноваційні системи та технології штучного інтелекту у моделюванні, прогнозуванні і прийнятті управлінських рішень у складному інформаційному середовищі*. Монографія / Під заг. ред. Заслуженого діяча науки і техніки України, д.т.н., д.е.н., проф. С. К. Рамазанова. — Київ: КНЕУ ім. В. Гетьмана, 2024. — 541 с.
2. S. Ramazanov. Artificial intelligence systems and technologies - main drivers and catalysts of sustainable development in the conditions of Industry 4.0. // *Artificial Intelligence*, 2022. 2 (94), С. 8-14.
3. С.К. Рамазанов, А.І. Шевченко, Є.О. Купцова. *Штучний інтелект і проблеми інтелектуалізації: стратегія розвитку, структура, методологія, принципи і проблеми*. — С. 14-23 // *Штучний інтелект: ІІІІ МОНУ і НАНУ*, 2020, 4 (90), 74 с.
4. Рамазанов С. К., Редько Д. О. *Проблеми та парадигми стійкого розвитку складних систем в умовах інноваційної економіки* // *Часопис економічних реформ*, 2024, 4(56), С. 47–54.
5. Рамазанов С. К., Редько Д. О. *Парадигми глобального стійкого розвитку складних систем* // *Часопис економічних реформ*, 2025, 2(58), С. 50–58.
6. Вернадський В. І. *Наукова думка як планетне явище*. — К.: Наук. думка, 1991. — 354 с.
7. Тейяр де Шарден П. *Феномен человека*. — М.: АСТ, 2002. — 554 с.

8. Флоріді Л. *The Ethics of Artificial Intelligence*. — Oxford, 2023. — 288 p.
9. Бодрунов С.Д. *Ноономика. Монографія*, 2018. - 432 с. (полная версия (PDF). inir.ru)
10. OECD. *AI and the Future of Work*. — Paris, 2023.
11. UNESCO. *Ethics of Artificial Intelligence Report*. — Paris, 2022.

УДК 004.89:629.7.05

Слюсар В. І., Почернін С. П. (Центральний науково-дослідний інститут озброєння та військової техніки ЗС України, Київ, Україна).

ІНТЕГРАЦІЯ ТЕХНОЛОГІЇ ADVANCED RAG У АГЕНТ-ЦИФРОВИЙ ДВІЙНИК МУЛЬТИАГЕНТНОЇ СИСТЕМИ ЕНЕРГЕТИЧНОГО МЕНЕДЖМЕНТУ ДЛЯ БЕЗПІЛОТНИХ СИСТЕМ.

Анотація. У статті розглянуто підхід до підвищення надійності та інтелектуального рівня енергетичного менеджменту безпілотних систем шляхом інтеграції технології Advanced Retrieval-Augmented Generation (RAG) у структуру агента-цифрового двійника мультиагентної системи (МАС). Показано, що використання агрегованого вектора енергетичного стану (Battery State Index Vector, BSIV) у поєднанні з векторними базами знань, референсними датасетами (NASA, CALCE) та графовими методами семантичного виведення дає змогу суттєво покращити діагностику деградаційних процесів у літій-іонних батареях. Розкрито логіку багатоступінчастого аналізу: від виявлення аномалій, пошуку релевантних прецедентів і графоорієнтованої інтерпретації до генерації керуючих рекомендацій для МАС. Запропонована технологія трансформує агента-двійника з пасивного спостерігача в когнітивний модуль, здатний до причинно-наслідкового висновування на основі зовнішніх джерел знань. Результати дослідження демонструють підвищення точності прогнозування залишкового ресурсу, оперативності реагування та автономності енергетичного менеджменту у безпілотних платформах.

Ключові слова: безпілотна система, енергетичний менеджмент, літій-іонний акумулятор, мультиагентна система, цифровий двійник, Advanced RAG, GraphRAG, діагностика деградації.

Abstract. The article proposes an approach to enhancing the reliability and intelligence of energy management in unmanned systems through the integration of Advanced Retrieval-Augmented Generation (RAG) into the digital twin agent of a multi-agent system (MAS). The study demonstrates that the use of an Aggregated Battery State Index Vector (BSIV), combined with vector knowledge bases, reference datasets (NASA, CALCE), and graph-based reasoning, significantly improves the diagnosis of degradation processes in lithium-ion batteries. A multi-stage analytical pipeline is presented, including anomaly detection, contextual retrieval of relevant historical cases, graph-oriented semantic inference, and generation of control recommendations for MAS. The proposed integration transforms the digital twin from a passive monitoring component into an active cognitive agent capable of causal reasoning using external knowledge sources. Experimental validation confirms improved accuracy of remaining useful life prediction, faster anomaly interpretation, and enhanced autonomy of unmanned platform energy management.

Keywords: unmanned system, energy management, Li-ion battery, multi-agent system, digital twin, Advanced RAG, GraphRAG, degradation diagnostics.

Постановка проблеми. Ефективність виконання місій автономними безпілотними системами (платформами) залежить від здатності бортових систем прогнозувати поведінку джерела живлення у нестандартних ситуаціях. Сучасні системи управління акумуляторними батареями (Battery Management Systems, BMS) здатні відстежувати параметри джерел живлення (стан заряду (state of charge, SoC), температура, струм розряду), ступінь деградації (state of health, SoH), проте вони часто обмежені жорсткими алгоритмами, не в повній мірі враховують фактори експлуатації та не інтегрують енергетичний стан безпіотної системи у планування дій групи (рою) безпілотних систем. Перспективним є використання мультиагентних систем (МАС) [1], де агент-цифровий двійник джерела живлення (або

безпілотної системи) в цілому виступає аналітичним центром. Актуальним завданням є наділення такого агента здатністю використовувати зовнішні бази знань для інтерпретації складних станів батареї, що вимагає впровадження сучасних методів генеративного штучного інтелекту.

Аналіз останніх публікацій. Архітектура MAC енергетичного менеджменту для безпілотних систем, що оперує агрегованими векторами стану, була запропонована у роботі [2]. Як показано в сучасному огляді [3], саме інтеграція штучного інтелекту в технологію цифрових двійників є ключовим трендом розвитку систем керування батареями (BMS), що дозволяє перейти від простого моніторингу до прогнозування. Однак для реалізації когнітивних функцій цифрового двійника необхідна інтеграція з великими мовними моделями (LLM). Фундаментальний підхід Retrieval-Augmented Generation (RAG), запропонований Lewis та ін. [4], дозволяє моделям звертатися до зовнішніх даних без перенавчання. Проте, як зазначають Gao та ін. у своєму огляді [5], для складних інженерних задач можливостей класичного ("Naive") RAG недостатньо через низьку точність пошуку, яка включає етапи попередньої обробки запиту для кращого розуміння суті проблеми та подальшого уточнення результатів для відсіву нерелевантної інформації. Окрему увагу привертає підхід GraphRAG [6], який дозволяє знаходити відповіді шляхом обходу графів знань, що є критичним для розуміння причинно-наслідкових зв'язків у діагностиці.

Метою роботи є підвищення надійності енергетичного менеджменту безпілотних систем шляхом інтеграції методології Advanced RAG та GraphRAG у структуру цифрового двійника - агента MAC для контекстного аналізу агрегованих векторів енергетичного стану джерел живлення.

Виклад основного матеріалу дослідження. MAC енергетичного менеджменту, що розглядається, реалізована засобами штучного інтелекту. MAC включає в себе низку функціональних агентів, зокрема: агента – сенсора (Sensor Agent) для збору первинної телеметрії, агента ембедингу (Embedder Agent) для перетворення «сирих» даних у компактні вектори стану, агента-класифікатора (Classifier Agent) для ідентифікації поточного режиму роботи, агента прогнозування (Predictor Agent) для оцінки майбутніх трендів деградації та агента прийняття рішень (Decision Agent) для адаптивного керування та координації у складі групи. Разом вони виконують повний цикл задач: від збору «сирих» діагностичних даних про стан джерела живлення, інших підсистем безпілотної платформи, агрегації даних, формування ознак технічних відмов або критичних станів до прийняття рішення на виконання, зміну або переривання поточної місії. Основний фокус в даному розгляді зосереджений на агенті-цифровому двійнику (Digital Twin Agent).

Функціонування агента-цифрового двійника реалізовано як багатоетапний процес семантичної обробки даних, що ініціюється при виявленні відхилень у потоці агрегованих векторів енергетичного стану. Процедура прийняття рішень базується на базі архітектури Advanced RAG [4] і включає чотири послідовні етапи.

1) Ініціалізація та вхідний аналіз. Вхідними даними для агента є агрегований вектор енергетичного стану (Battery State Index Vector, BSIV) [2]. BSIV надходить від Embedder Agent у реальному часі i для платформи i у момент часу t має вигляд:

$$\vec{b}_i(t) = [SoC_i(t), SoH_i(t), RUL_i(t), T_i(t), P_{load,i}(t \rightarrow t + \tau) \dots Z_i(t)], \quad (1)$$

де $SoC_i(t)$ – оцінка стану заряду джерела живлення, $SoH_i(t)$ – оцінка рівня деградації (стану «здоров'я») джерела живлення з урахуванням деградації, $RUL_i(t)$ – прогнозований залишковий корисний ресурс джерела живлення, визначений як гарантовано доступний часовий горизонт безпечної роботи платформи у поточному режимі навантаження, $P_{load,i}(t \rightarrow t + \tau)$ – прогнозована середня потужність споживання для виконання поточного завдання у часовому горизонті τ , $Z_i(t)$ – внутрішній опір (імпеданс) джерела живлення в момент часу t .

Агент здійснює безперервний моніторинг компонентів вектору $\vec{b}_i(t)$ (1). Активація модуля глибокої діагностики відбувається за умови виконання критерію аномальності, коли відхилення поточних параметрів (наприклад, швидкість зростання внутрішнього опору $\Delta Z_{internal}$ джерела живлення) перевищує допустимий поріг для поточної температури.

2) Контекстний пошук. На цьому етапі виконується запит до векторної бази знань – Vector Database. Система здійснює пошук k найближчих векторів-сусідів (k -NN) серед історичних даних, використовуючи метрику косинусної подібності. База знань містить векторизовані профілі деградації з референсних датасетів – NASA Battery Dataset, CALCE та архівні логи попередніх місій. Математично це описується як знаходження підмножини історичних векторів b_{hist} , для яких відстань $dist(b_i, b_{hist})$ є мінімальною. Це дозволяє ідентифікувати прецеденти, де спостерігалася аналогічна динаміка зміни параметрів BSIV [2].

3) Графо-аналітичне виведення. Для встановлення причинно-наслідкових зв'язків знайдених прецедентів застосовується підхід GraphRAG. Знайдені на попередньому етапі історичні вектори слугують входними вузлами для обходу графа знань – Knowledge Graph. Агент аналізує топологію графа, виявляючи причинно-наслідковий шлях, схему якого наведено на Рисунку 1:

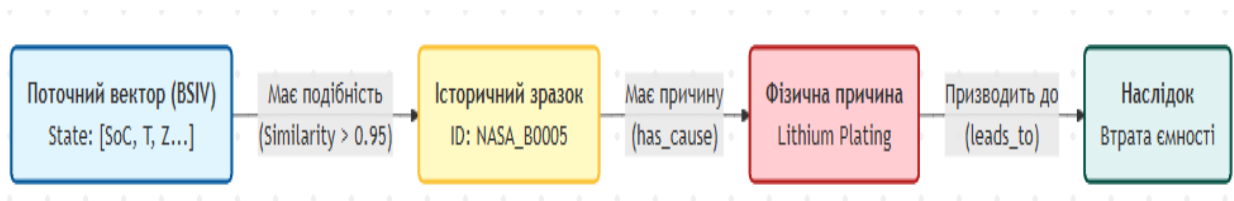


Рисунок 1. Приклад діагностичного шляху в графі знань: від числового вектора стану до визначення причини деградації (Lithium Plating)

Наприклад, система встановлює зв'язок між поточним вектором імпедансу та вузлом «Lithium Plating» (осадження металевого літію на поверхні анода), який у графі асоційований з умовами низькотемпературного заряду та призводить до незворотної втрати ємності. Це дозволяє верифікувати діагноз, який неможливо встановити лише на основі скалярних значень телеметрії.

4) Етап 4. Генерація керуючої рекомендації. На фінальному етапі агрегований контекст (поточний вектор $\vec{b}_i(t)$, метадані знайдених історичних зразків та виявлені графові зв'язки) передається на вхід великої мовної моделі (LLM). Модель генерує формалізований висновок для агента прийняття рішень. Вихідний сигнал містить:

- а) діагноз – ідентифікація фізико-хімічного процесу деградації (наприклад, anode degradation due to plating);
- б) прогноз – оцінка скоригованого RUL за умови збереження поточного режиму;
- в) рекомендацію – конкретна дія для МАС (наприклад, обмежити струм розряду $I_{discharge} \leq 0.5C$), що спрямована на мінімізацію деградації та забезпечення виконання місії.

ВИСНОВКИ

У роботі запропоновано архітектуру когнітивного агента-цифрового двійника в складі мультиагентної системи енергоменеджменту, посилену технологією Advanced RAG для семантичної інтерпретації агрегованих векторів стану – BSIV. Використання даного підходу трансформує агента-двійника з пасивного інструменту моніторингу в активного аналітика. Перехід від «наївного» пошуку до графо-аналітичних методів GraphRAG дозволяє ефективно зіставляти поточні вектори стану з референсними базами знань, що значно підвищує точність діагностики аномалій та прогнозування залишкового ресурсу без необхідності трансляції та обробки надлишкових обсягів телеметричних даних.

СПИСОК ПОСИЛАНЬ.

1. Slyusar V. Distributed Multi-agent Systems Based on the Mixture of Experts Architecture in the Context of 6G Wireless Technologies. In: Dovgyi, S., et al. (eds) Applied Innovations in Information and Communication Technology. ICAIT 2024. Lecture Notes in Networks and Systems, vol. 1338. Springer, 2025, pp. 81-110. URL: https://doi.org/10.1007/978-3-031-89296-7_6.

2. Slyusar V., Pochernin S. An Embedded Approach to the Implementation of a Multi-Agent Energy Management System for Unmanned Systems. ICST 2025: Information Control Systems & Technologies, у складі CEUR Workshop Proceedings, vol.4048. ceur-ws.org/Vol-4048/paper26.pdf.
3. Artificial Intelligence and Digital Twin Technologies for Intelligent Lithium-Ion Battery Management Systems: A Comprehensive Review / S. S. Madani et al. Batteries. 2025. Vol. 11, no. 8. P. 298. URL: <https://doi.org/10.3390/batteries11080298>.
4. Retrieval-Augmented Generation for Knowledge-Intensive NLP Tasks / P. Lewis et al. Advances in Neural Information Processing Systems (NeurIPS). 2020. Vol. 33. P. 9459–9474. URL: <https://proceedings.neurips.cc/paper/2020/file/6b493230205f780e1bc26945df7481e5-Paper.pdf>.
5. Retrieval-Augmented Generation for Large Language Models: A Survey / Y. Gao et al. arXiv preprint arXiv:2312.10997. 2023. URL: <https://doi.org/10.48550/arXiv.2312.10997>.
6. From Local to Global: A Graph RAG Approach to Query-Focused Summarization / D. Edge et al. arXiv preprint arXiv:2404.16130. 2024. URL: <https://doi.org/10.48550/arXiv.2404.16130>.

УДК 004.93(075.8)

Терещенко В. М., Бобиль Б. В., Красіков А. І., Косуха О. Ю., Заславський В. А., Горбунов О. А. (Київський національний університет імені Тараса Шевченка, Київ, Україна).

НЕЙРОМЕРЕЖНА СИСТЕМА ОЦІНКИ ПРАВИЛЬНОСТІ ВИКОНАННЯ ФІЗИЧНИХ ВПРАВ НА ОСНОВІ 3D-РЕКОНСТРУКЦІЇ РУХІВ.

Анотація. Робота присвячена розробці системи комп'ютерного зору для автоматичної перевірки правильності виконання фізичних вправ у процесі спортивної підготовки або медичної реабілітації. У дослідженні побудовано повний наскрізний пайплайн, що включає багатокамерний запис відео, 2D-детекцію ключових точок тіла, триангуляцію та відновлення 3D-кінематичної моделі руху за допомогою фреймворку Pose2Sim та біомеханічного середовища OpenSim. Отримані тривимірні координати застосовуються як вхідні дані для просторово-часової нейронної мережі, адаптованої до задачі класифікації правильності виконання реабілітаційних вправ. Розроблена система здатна виявляти як технічні помилки, так і тонкі компенсаторні рухи, що мають важливе клінічне значення. Представлені експериментальні результати підтверджують ефективність запропонованого підходу та його придатність для використання у телереабілітації й автоматизованих тренувальних системах.

Ключові слова: комп'ютерний зір, реабілітація, тривимірна реконструкція скелета, розпізнавання рухів, оцінка виконання вправ.

Abstract. The work is devoted to the development of a computer vision system for automatic verification of exercise performance in sports training and medical rehabilitation. The study presents a complete end-to-end pipeline that includes multi-camera video recording, 2D human keypoint detection, triangulation, and reconstruction of a 3D kinematic model using the Pose2Sim framework and the OpenSim biomechanical environment. The obtained 3D joint coordinates are used as input to a spatio-temporal deep neural network adapted for the task of classifying correct and incorrect execution of rehabilitation exercises. The proposed system is capable of detecting both technical errors and subtle compensatory movements, which hold significant clinical relevance. Experimental results confirm the effectiveness of the method and its applicability to telerehabilitation and automated training support systems.

Keywords: computer vision, rehabilitation, 3D skeleton reconstruction, action recognition, exercise performance evaluation.

1. Вступ

Постановка проблеми. Розлади опорно-рухового апарату та наслідки травм є одними з найбільш поширених причин обмеження рухливості та втрати працездатності у світі. За даними Всесвітньої організації охорони здоров'я, потреба в реабілітації постійно зростає й уже значно перевищує доступність відповідних послуг, особливо у країнах з низьким та середнім рівнем доходу [1]. Нестача фахівців, висока вартість тривалої реабілітації та географічні бар'єри створюють ситуацію, коли значна частина пацієнтів не може отримати повноцінний реабілітаційний супровід.

У таких умовах ключовою стає можливість самостійного виконання вправ пацієнтом удома. Проте відсутність зворотного зв'язку від спеціаліста часто призводить до формування неправильних рухових шаблонів, повторних травм або уповільнення процесу відновлення. Техніка виконання вправ є визначальним чинником успішності відновлення і її порушення навіть на кілька градусів у суглобах або залучення компенсаторних рухів може суттєво знизити ефективність терапії.

Сучасні досягнення комп'ютерного зору, тривимірної реконструкції та глибоких нейронних мереж створюють можливість автоматичного аналізу людського руху за допомогою звичайних RGB-камер. Це відкриває перспективу формування інтелектуальних систем реабілітації, які здатні забезпечити високоточний контроль за виконанням вправ без постійної участі фізіотерапевта. Впровадження таких рішень може значно підвищити доступність реабілітації, знизити навантаження на медичний персонал та надати пацієнтам об'єктивний зворотний зв'язок у домашніх умовах.

Аналіз останніх публікацій. Дослідження у сфері автоматичного аналізу рухів людини розвиваються у двох основних напрямках: використання натільних датчиків та безконтактні методи на основі комп'ютерного зору [2]. Останні набули значної популярності завдяки поширенню сгкамер у споживчих пристроях, що дозволяє знизити витрати, підвищити доступність діагностики та покращити досвід пацієнтів за рахунок безконтактного моніторингу.

Значний пласт робіт присвячено використанню RGB-D камер (сенсорів глибини), таких як Microsoft Kinect. Наприклад, у роботі [3] автори розробили "віртуального наставника" для реабілітації плечового суглоба, показавши, що точність виконання вправ під наглядом системи перевищує показники традиційних методів. Однак, використання спеціалізованого обладнання обмежує масове впровадження таких рішень.

Саме тому сучасні дослідження, як зазначено у систематичному огляді [4], все частіше фокусуються на використанні звичайних RGB-камер у поєднанні з алгоритмами глибокого навчання для оцінки пози (Pose Estimation). Автори [5] демонструють ефективність безмаркерних систем для пацієнтів із синдромом Ретта, підкреслюючи можливість дистанційного моніторингу.

Водночас, значним викликом у сфері автоматизованої реабілітації є дефіцит якісних розмічених даних, що обмежує застосування глибоких нейронних мереж. Для вирішення цієї проблеми сучасні дослідники все частіше звертаються до методів самокерованого (Self-Supervised Learning, SSL) та контрастного навчання (Contrastive Learning).

Зокрема, у роботі [6] запропоновано фреймворк SSL-Rehab, який використовує попереднє навчання на нерозмічених 3D-скелетних даних. Автори розробили методи динамічної аугментації та імітації артефактів глибини, що дозволило моделі формувати стійкі представлення рухів. Експерименти на датасетах KIMORE [7] та UI-PRMD [8] показали, що подальше донавчання на невеликій розміченій вибірці дозволяє перевершити результати повністю керованих підходів.

Розвиваючи цей напрямок, дослідження [9] фокусується на керованому контрастному навчанні (Supervised Contrastive Learning). Ключовою інновацією роботи є генерація так званих "жорстких негативів" (hard negatives) - штучно створених прикладів, що імітують тонкі помилки виконання вправ. Це дозволяє моделі ефективніше вивчати границю прийняття рішень (decision boundary) між правильним та неправильним виконанням навіть за умов критично малого обсягу даних про помилки.

Обмеження існуючих рішень. Не дивлячись на стрімкий розвиток даної сфери та велику кількість відповідних робіт, існуючі рішення мають суттєві обмеження, що стримують їх широке клінічне застосування. Окрім згаданої невеликої кількості якісних реабілітаційних даних, це, по-перше, обмеження, що стосуються обробки динамічних та складних моделей руху, оскільки вона потребує розуміння цілісного біомеханічного аналізу. І по-друге, це відсутність єдиного уніфікованого підходу, який охоплював би всі етапи програмної реалізації та робив подібну систему дійсно легкою у використанні.

Мета роботи: створення та експериментальна оцінка end-to-end системи автоматичної перевірки правильності виконання фізичних вправ, що поєднує багатокамерну 3D-реконструкцію рухів та глибоке навчання.

Відповідно до мети поставлено завдання:

Побудувати зручну у користуванні систему автоматичної оцінки правильності виконання фізичних вправ, яка поєднує багатокамерний запис відео, 3D-реконструкцію рухів та модуль оцінки коректності вправ.

Розробити повний end-to-end пайплайн обробки даних, що включає: калібрування камер; детекцію ключових точок; формування 3D-кінематичної моделі; підготовку просторово-часових ознак для нейронної мережі.

Адаптувати та навчити просторово-часову нейронну мережу для класифікації технічно правильного та неправильного виконання вправ, зокрема здатну виявляти як явні, так і компенсаторні помилки.

Перевірити роботу розробленої системи експериментально, проаналізувавши точність 3D-реконструкції та якість класифікації на тестових прикладах реабілітаційних вправ.

2. Алгоритм оцінки правильності виконання вправ

Загальний план використання технології комп'ютерного зору у реабілітаційних заходах включає в себе декілька основних етапів. Це запис відео, знаходження ключових точок (формування скелетону), та оцінка правильності виконання вправи. Існують також і інші підходи, які оминають етап знаходження ключових точок та напряму з відеоданих виконують оцінку виконання вправ, але загалом вони мають нижчу точність порівняно з описаним методом, і в даній роботі не розглядаються.

2.1. Експериментальний стенд та збір даних

Для забезпечення інваріантності до ракурсу зйомки та уникнення проблем оклюзії (перекриття частин тіла), було обрано багатокамерний підхід. Експериментальний стенд складається з декількох синхронізованих RGB-камер, розташованих під різними кутами відносно центру сцени, що забезпечує повне покриття робочого простору (рис. 1). У нашому випадку таких камер було 3.




Рисунок 1. Отримання 3D реконструкції сцени з декількох камер [11]

Процес збору даних включав два етапи:

Калібрація: для визначення внутрішніх (intrinsic) та зовнішніх (extrinsic) параметрів камер використано стандартний алгоритм із застосуванням шахової дошки, реалізований за допомогою бібліотеки OpenCV [10]. Це дозволило мінімізувати дисторсію лінз та встановити точне просторове положення кожного сенсора (рис. 2).

Запис вправ: відеопотік записувався з частотою 30 кадрів за секунду, що є достатнім для фіксації динаміки реабілітаційних рухів.




Рисунок 2. Автоматична калібрація камери на зображеннях

2.2. Пайплайн 3D-реконструкції пози

Для перетворення 2D-відеопотоків у цілісну 3D-кінематичну модель використано фреймворк з відкритим вихідним кодом Pose2Sim [11]. Вибір даного інструменту зумовлений його здатністю об'єднувати детектори ключових точок (наприклад, OpenPose) із біомеханічним моделюванням у середовищі OpenSim. Це спрощує його використання та зменшує ймовірність помилок (рис. 3).




Рисунок 3. Загальна послідовність кроків у Pose2Sim [11]

Загальний алгоритм обробки складається з наступних кроків:

2D-детекція: на вхід подаються синхронізовані відео з трьох камер. Для кожного кадру виконується детекція ключових точок тіла (Keypoint Detection) за допомогою моделі OpenPose [12]. Використання даного фреймворку гарантує гарну точність визначення координат та високу швидкість, яка забезпечується легкістю моделі (рис. 4).




Рисунок 4. Приклад побудови 2D скелетонів на кадрах з різних джерел

Триангуляція: на основі матриць калібрування та 2D-координат з різних ракурсів виконується реконструкція положення суглобів у 3D-просторі. Використовується покращений метод найменших квадратів для мінімізації помилки ре-проекції, що зважає внесок кожної камери залежно від впевненості, яку видала нейромережа (OpenPose) для кожної точки.

Фільтрація та обробка: отримані 3D-координати проходять через низькочастотний фільтр Баттерворта для усунення шуму. Далі виконується інтеграція з біомеханічною моделлю OpenSim: спершу відбувається масштабування моделі під антропометрію пацієнта, а потім — розв'язання задачі оберненої кінематики (Inverse Kinematics) для розрахунку кутів у суглобах та отримання фізично коректного руху. Таким чином кінематика обмежується індивідуально масштабованою та фізично точною моделлю скелета (рис. 5).



Рисунок 5. Візуалізація 3D моделі, створеної на реальних відеоданих

2.3. Оцінка правильності виконання вправ та загальні відомості про обраний підхід

Для оцінки правильності виконання вправ нами було адаптовано архітектуру просторово-часової мережі (Spatio-Temporal Network), запропоновану в роботі [13]. Вибір архітектури базується на її здатності ефективно моделювати як просторові залежності (координація частин тіла), так і часову динаміку руху. Модель складається з трьох функціональних блоків (рис. 6):

Просторові підмережі: тіло людини розділяється на п'ять кінематичних ланцюгів (тулуб, ліва/права рука, ліва/права нога). Для кожної частини застосовуються згорткові шари для екстракції локальних ознак.

Часові піраміди (Temporal Pyramids): використовуються для захоплення динаміки руху на різних часових масштабах, що дозволяє моделі бути стійкою до різної швидкості виконання вправ пацієнтами.

Блок прийняття рішень (LSTM): об'єднані вектори ознак подаються на вхід LSTM-шару, який аналізує послідовність та формує фінальну оцінку ймовірності правильного виконання.




Рисунок 6. Схема архітектури оригінальної моделі [13]

2.4. Підготовка даних та інженерія ознак

Критично важливим етапом стала адаптація вихідних даних Pose2Sim для навчання нейромережі. Нами було розроблено модуль попередньої обробки, який виконує:

Конвертацію форматів: трансформація .trc файлів (формат OpenSim) у структуровані часові ряди (.csv), що містять координати 21 ключової точки.

Нормалізацію: для забезпечення інваріантності моделі до зросту пацієнта та його положення в кімнаті, всі координати нормалізуються відносно центру мас тулуба (Root-relative coordinates).

Аугментацію: для розширення навчальної вибірки застосовано синтетичний поворот скелета навколо вертикальної осі (Y-axis), що емулює виконання вправи під різними кутами огляду.

Дані було автоматично розмічено на класи "Correct" та "Incorrect" на основі структури каталогів, сформованої під час виконання вправ.

3. Аналіз практичних результатів

3.1. Методика оцінювання

Ключовим результатом роботи стала реалізація наскрізного (end-to-end) пайплайну: від синхронізованого запису відеопотоків та 3D-реконструкції скелета до автоматичної класифікації біомеханічної коректності рухів. Вихідним значенням моделі є оцінка ймовірності належності руху до класу "Correct" (правильне виконання), що лежить у діапазоні $p \in [0, 1]$.

За порогове значення прийнято 0.5:

$p > 0.5$: вправа виконана технічно вірно;

$p \leq 0.5$: вправа виконана з помилками.

Значення, близькі до граничних (наприклад, 0.4 - 0.6), інтерпретуються як зона невпевненості моделі, що часто свідчить про наявність незначних відхилень або початок формування неправильного рухового патерну.

Щоб протестувати роботу нашого підходу, ми натренували модель на невеликій кількості зібраних нами даних. Для валідації запропонованого підходу було проведено серію експериментів на тестовій вибірці. Як базовий приклад обрано вправу на відведення плеча до горизонтального рівня (90°) у позиції стоячи. Цей рух є фундаментальним індикатором відновлення функції плечового суглоба після травм, а його правильне виконання вимагає не лише мобільності суглоба, але й стабілізації корпусу.

На рис. 7 та в таблиці 1 наведено результати роботи моделі в трьох характерних сценаріях, що демонструють чутливість алгоритму до різних типів помилок.




Рисунок 7. Приклад правильного та неправильного виконання вправи

Таблиця 1. Порівняння декількох технік виконання вправи та отримані програмно оцінки

Номер вправи	Опис техніки виконання	Справжня оцінка правильності	Передбачення моделі
1	Спина рівна, рука піднята не повністю та напівзігнута в лікті	Неправильно	0.28 (<0.5)
2	Спина рівна, рука випрямлена та в горизонтальному положенні	Правильно	0.77 (>0.5)
3	Спина нахилена, рука рівна та в горизонтальному положенні	Неправильно	(<0.5)

3.2. Детальний аналіз сценаріїв

Сценарій 1 (явна помилка): пацієнт демонструє значне обмеження амплітуди руху (рука напівзігнута, лікоть опущений). Модель впевнено класифікує це як помилку з результатом 0.28. Це свідчить про здатність системи детектувати грубі порушення біомеханіки, пов'язані з недостатньою мобільністю суглоба.

Сценарій 2 (еталонне виконання): пацієнт зберігає вертикальне положення хребта, рука повністю випрямлена та зафіксована в горизонтальній площині. Оцінка 0.77 підтверджує, що кінематичні параметри руху (кути в суглобах, положення корпусу) відповідають патерну здорової людини.

Сценарій 3 (компенсаторний рух): це найбільш цікавий випадок з точки зору клінічної цінності системи. Візуально рука знаходиться в правильному горизонтальному положенні та випрямлена. Однак, досягається це за рахунок бічного нахилу тулуба. Це класичний приклад компенсаторного механізму, коли пацієнт намагається "допомогти" собі спиною через слабкість дельтоподібного м'яза. Модель розпізнала цю тонку помилку, видавши результат 0.46. Цей результат є критично важливим, оскільки він знаходиться трохи нижче порогового значення. Це демонструє, що модель навчилася враховувати не лише локальні ознаки (кут руки), але й глобальні (положення хребта відносно вертикальної осі), що підтверджує ефективність використання просторово-часових пірамід в архітектурі мережі.

Клінічна інтерпретація. Отримані числові значення дозволяють не лише класифікувати спробу як "зараховано/не зараховано", але й формувати динамічну статистику прогресу пацієнта. Випадки, подібні до сценарію 3, можуть автоматично маркуватися для додаткового перегляду лікарем, оскільки вони сигналізують про приховані патології руху, які пацієнт може не помічати самостійно.

3.3. Метрики

У ході експериментальної перевірки запропонована модель оцінки правильності виконання вправ продемонструвала точність на рівні **90,42%**. Для компонентів 3D-реконструкції, реалізованої за допомогою Pose2Sim, також були отримані характерні метрики якості: середня **помилка ре-проекції** не перевищувала порогових значень (**≈1,5 пікселя в середньому**), причому ключові точки з вищою помилкою автоматично відхилялися як помилкові. Частка **правильних 3D-точок** після триангуляції становила **90%**, що є типовим для багатокамерних систем з корекцією дисторсії та калібрації камер. Для біомеханічного аналізу в OpenSim додатково використовувалися метрики мінімального та максимального значень суглобових кутів, а також **діапазон руху (ROM)**. Сукупність цих показників демонструє, що розроблена система забезпечує достатню точність та стабільність реконструкції рухів, а також ефективну оцінку техніки виконання вправ, що робить її придатною для використання у задачах спортивної підготовки та реабілітації.

ВИСНОВКИ

У даній роботі проведено комплексне дослідження проблематики автоматизації фізичної реабілітації та представлено програмну реалізацію системи комп'ютерного зору для оцінки якості виконання вправ. Основні результати роботи полягають у наступному:

Розроблено методологію збору даних: обґрунтовано та реалізовано багатокамерний підхід до запису рухів, що дозволяє уникнути проблеми оклюзії частин тіла, характерної для однокамерних систем. Процедура калібрування камер забезпечила високу геометричну точність реконструкції сцени.

Побудовано 3D-моделі рухів: інтеграція фреймворку Pose2Sim дозволила перейти від площинних 2D-координат до повноцінної 3D-біомеханічної моделі. Це дало можливість аналізувати рухи в реальних фізичних величинах та підвищити здатність системи адаптуватися до зміни ракурсу.

Адаптовано алгоритм глибокого навчання: успішно адаптовано архітектуру просторово-часової нейронної мережі для задачі класифікації реабілітаційних вправ. Модель продемонструвала здатність розрізняти не лише грубі помилки, але й тонкі компенсаторні рухи (наприклад, нахили корпусу), що підтверджується експериментальними даними.

Практична цінність: програмний пайплайн може слугувати основою для розробки систем реабілітації наступного покоління. Впровадження таких рішень дозволить знизити навантаження на медичний персонал, забезпечити пацієнтам об'єктивний зворотний зв'язок у реальному часі та, як наслідок, підвищити ефективність відновлювальної терапії.

Подальші дослідження будуть спрямовані на розширення бази вправ, оптимізацію швидкодії алгоритму для роботи на мобільних пристроях та впровадження механізму генерації текстових підказок для пацієнта на основі виявлених помилок.

СПИСОК ПОСИЛАНЬ.

1. *The need to scale up rehabilitation.* / World Health Organization, 2017.
2. *Computer Vision and Rehabilitation: A New Frontier for AI.* // DyCare. URL: <https://www.dycare.com/en/computer-vision-and-rehabilitation-a-new-frontier-for-ai> (дата звернення: 08.06.2025).
3. *Kinect-based integrated physiotherapy mentor application for shoulder damage.* / Burakhan Çubukçu [та ін.]. // *Future Generation Computer Systems*, 2021; С. 105-116.
4. *Machine Learning-Based Computer Vision for Depth Camera-Based Physiotherapy Movement Assessment: A Systematic Review.* / Zhou, Y. [та ін.]. // *Sensors*, 2025.

5. *Telerehabilitation with Computer Vision-Assisted Markerless Measures: A Pilot Study with Rett Syndrome Patients.* / Nucita, A. [ма ін.]. // *Electronics*, 2023.
6. *SSL-Rehab: Assessment of Physical Rehabilitation Exercises Through Self-Supervised Learning of 3D Skeleton Representations.* / Ikram Kourbane, Panagiotis Papadakis, Mihai Andries. // *Computer Vision and Image Understanding*, 2025; C. 104-275.
7. *The KIMORE Dataset: KInematic Assessment of MOvement and Clinical Scores for Remote Monitoring of Physical REhabilitation.* / Capecci, Marianna & Ceravolo [ма ін.]. // *IEEE transactions on neural systems and rehabilitation engineering*, 2019.
8. *A Data Set of Human Body Movements for Physical Rehabilitation Exercises.* / Vakanski, Aleksandar & Jun [ма ін.]. // 2018.
9. *Rehabilitation exercise quality assessment through supervised contrastive learning with hard and soft negatives.* / Karlov M, Abedi A, Khan SS. // *Med Biol Eng Comput*, 2025.
10. *OpenCV: Camera Calibration.* URL: https://docs.opencv.org/4.x/dc/dbb/tutorial_py_calibration.html (дата звернення: 08.06.2025).
11. *Pose2Sim: An open-source Python package for multiview markerless kinematics.* / Pagnon [ма ін.]. // *Journal of Open Source Software*, 2022.
12. *OpenPose: Realtime Multi-Person 2D Pose Estimation using Part Affinity Fields.* / Zhe Cao [ма ін.]. // 2019.
13. *A Deep Learning Framework for Assessing Physical Rehabilitation Exercises.* / Liao, Yalin [ма ін.]. // *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2019; C. 468-477.13.

UDC 004.8:519.2

Dubinsky A. (Seville, Spain).

ZERO-TRAINING EVALUATION OF CLASSIFICATION METRICS.

Abstract. The present work proposes a zero-training methodology aimed at resolving the long-standing challenge of validating novel classification metrics without the computational burden of retraining machine learning models. The approach treats stored model predictions as reusable research assets and leverages the OpenML ecosystem, particularly the OpenML-CC18 suite, to enable large-scale post-hoc experimental evaluation. The methodology is grounded in a three-layer architectural framework comprising a repository layer, a data-standardization Harvester, and an Evaluation Sandbox for metric developers. This design enables transparent access to probability outputs, consistent alignment of class labels, and automated execution of metric experiments. A stratified benchmarking protocol is introduced to structure evaluations across binary, low-cardinality multiclass, and high-cardinality multiclass tasks, ensuring that metric behaviour is studied under diverse conditions rather than being averaged out. The methodology also incorporates rank-based statistical comparisons and tools such as Critical Difference diagrams to expose redundancy, complementarity, or instability of metrics. The proposed framework aligns with Green AI principles by reducing computational overhead and democratizing access to metric research. While the current work focuses on conceptual design, its implementation as an open-source Python library and empirical validation constitute key directions for future development.

Keywords: classification metrics, metric benchmarking, OpenML, zero-training evaluation, post-hoc analysis, Green AI.

Анотація. У статті запропоновано методологію zero-training, що усуває потребу у повторному навчанні моделей під час перевірки нових метрик класифікації. Запропонований підхід розглядає збережені передбачення моделей як багаторазовий дослідницький ресурс і використовує екосистему OpenML, зокрема набір OpenML-CC18, для формування масштабного експериментального середовища для пост-хок аналізу метрик. Методологія спирається на трирівневу

архітектуру, яка включає репозитарний шар, компонент Harvester для стандартизації даних та узгодження класів, а також Evaluation Sandbox — інструмент для авторів метрик, що забезпечує автоматизоване обчислення й порівняння результатів. Запропоновано стратифікований протокол оцінювання, який охоплює три типи задач: бінарні, мультикласові з малою кількістю класів та висококардинальні мультикласові задачі. Така стратифікація дозволяє виявляти сильні та слабкі сторони метрик у різних умовах замість усереднення результатів. Методологія передбачає використання рангових кореляцій, аналізу розбіжностей та критичних діаграм для статистично обґрунтованого порівняння метрик. Запропонований підхід відповідає принципам Green AI, зменшуючи обчислювальні витрати та підвищуючи відтворюваність досліджень. Реалізація програмної бібліотеки та емпірична перевірка методології визначені як напрями подальших робіт.

Ключові слова: метрики класифікації, оцінювання метрик, OpenML, zero-training, пост-хок аналіз, Green AI.

Introduction and Problem Statement

The choice of evaluation metric is a critical step in the Machine Learning (ML) pipeline. Modern ML systems are increasingly deployed in high-stakes domains such as healthcare, credit scoring, fraud detection, and autonomous systems, where evaluation metrics directly influence real-world decisions. An inappropriate metric can systematically favor models that appear performant numerically but fail in terms of actual risk, fairness, or business utility. This misalignment is particularly acute in imbalanced and multiclass (especially high-cardinality) settings, where widely used metrics such as Accuracy, Macro-F1, or ROC-AUC may obscure critical failure modes or provide misleadingly optimistic assessments [1-4].

At the same time, the scientific validation of new, proposed metrics faces a substantial experimental bottleneck. To rigorously demonstrate the superiority, robustness, or domain-specific utility of a candidate metric, researchers are traditionally required to:

- collect and curate a diverse set of benchmark datasets;
- implement or adapt preprocessing pipelines;
- train multiple baseline models (e.g., Random Forests, Gradient Boosting, Neural Networks) under controlled conditions; and
- compute metric values across many train/validation/test splits and model configurations.

This “train-and-evaluate” paradigm is at the core of many influential empirical studies on performance measures [5-7], but it is computationally expensive, time-consuming, and environmentally costly. It contradicts the principles of Green AI, which call for lowering the carbon footprint of research where possible [8]. Moreover, it raises the barrier to entry: only groups with substantial computing resources can afford to run large-scale metric studies, and results are often difficult to reproduce due to subtle differences in training protocols, hyperparameters, and preprocessing choices.

There is, therefore, a pressing need for a standardized, resource-efficient, and reproducible methodology to benchmark classification metrics without repeatedly retraining models from scratch, ideally by reusing existing experimental artifacts wherever possible.

Analysis of Recent Publications

Research related to this problem spans two main lines: metric-oriented empirical analysis and open, reusable experimental infrastructure.

On the metric side, numerous works have highlighted the limitations of standard measures and proposed alternatives. Hand [1] critically assessed the widespread use of the Area Under the ROC Curve (AUC) and introduced the H-measure as a more principled alternative under certain cost structures. Powers [2] analyzed Precision, Recall, F-measure, and related metrics, formalizing their

relationships and pointing out where they behave counter-intuitively. Other studies have investigated measures such as Matthews Correlation Coefficient and Cohen’s Kappa, arguing for their advantages over Accuracy and F-scores in specific settings [7], and have systematically reviewed families of performance measures for classification tasks [6]. Empirical comparisons in these works typically follow the traditional train-and-evaluate workflow described above: authors collect datasets, train multiple classifiers, and then compute and compare metrics on the resulting predictions [3-5]. As a consequence, such investigations are constrained in scale and diversity by the cost of generating new experimental results.

On the infrastructure side, the OpenML platform [9] introduced the concept of “networked science” in ML: instead of leaving results buried in PDFs and local logs, experiments are stored as structured artifacts—datasets, tasks, flows (algorithms), and runs (executions with predictions and scores). Building on this, Bischl et al. [10] proposed curated benchmarking suites such as OpenML-CC18, a collection of 72 classification datasets selected for statistical soundness and practical relevance. These suites have been widely used to benchmark algorithms and AutoML systems [11].

Recent meta-learning and AutoML studies leverage OpenML to predict algorithm performance or to benchmark full pipelines, but they focus primarily on algorithm comparison, not on systematic benchmarking of metrics themselves. Moreover, they typically analyze scalar evaluation scores (e.g., AUC, Accuracy) rather than reusing the full posterior probability outputs required to assess new metrics. While these works advance metric design and open experimentation, they do not provide a dedicated, reusable metric-centric benchmarking environment. In particular, they do not specify:

- how new metrics should be evaluated systematically across hundreds of existing model predictions;
- how such evaluations should be stratified by task characteristics (e.g., class cardinality, imbalance); and
- how to hide the engineering complexity of dealing with raw experiment metadata and prediction alignment.

These gaps directly motivate the present work, in which we propose a zero-training, post-hoc evaluation framework that reuses OpenML predictions as the basis for large-scale, metric-centric benchmarking.

Unsolved Parts of the Problem

Despite the availability of platforms like OpenML and curated suites like OpenML-CC18, there is currently no unified framework aimed specifically at metric developers rather than algorithm developers. We identify three unresolved aspects:

1. Lack of a “Zero-Training” Protocol.

Existing studies commonly retrain models for each new metric, or they analyze only stored scalar scores instead of full prediction distributions. There is no standardized protocol that treats pre-computed probability outputs as a first-class object for metric research, enabling post-hoc evaluation of arbitrary metrics without additional training.

2. Missing Stratified Benchmarking Standards.

Current benchmarks such as OpenML-CC18 are designed for algorithm comparison and do not prescribe how to analyze a metric’s strengths and weaknesses across varying conditions, such as:

- binary vs. multiclass settings,
- low vs. high class cardinality,

- different class imbalance ratios, or
- different application domains.

Without such stratification, important patterns in metric behavior can be averaged out and overlooked.

3. Absence of Engineering Abstractions for Metric Designers.

Toolchains built around OpenML and similar platforms are optimized for model selection, AutoML, and meta-learning. Metric designers, in contrast, must currently:

- manually query and parse runs,
- resolve class-label and probability-column alignment issues, and
- manage local caching and preprocessing.

There is no off-the-shelf “metric sandbox” offering a simple interface such as `evaluate_metric(M)` that abstracts away API calls, data alignment, and infrastructure concerns.

Purpose and Objectives of the Study

This paper presents a work-in-progress methodology that aims to address these gaps by defining a framework for rapid, offline benchmarking of classification metrics using OpenML.

The overarching purpose is to decouple model training from metric evaluation, allowing researchers to evaluate new metrics purely in terms of their behavior on stored predictions from diverse models and datasets.

The specific objectives are:

1. Architecture Design.

To specify a modular framework that can be implemented as an open-source Python library, exposing a simple interface for metric authors (e.g., `evaluate_metric(metric_fn)`), while internally managing data access and orchestration.

2. Data Curation & Alignment.

To design and prototype a Harvester component that:

- retrieves suitable runs from OpenML-CC18,
- standardizes them into a unified representation of (y_true, P) pairs (true labels and class-probability matrices), and
- robustly solves the “column alignment” problem for multiclass outputs.

3. Statistical Protocol Definition.

To formalize a statistical evaluation protocol that:

- stratifies tasks into meaningful tiers (binary, low-cardinality multiclass, high-cardinality multiclass),
- computes rank-based correlations between the candidate metric and established baselines (e.g., Accuracy, Macro-F1, LogLoss), and
- supports visual tools such as Critical Difference diagrams [12] for robust comparison.

Presentation of the Main Research Material

We term the proposed methodology Post-Hoc Metric Benchmarking. Its key idea is to reuse the outputs of pre-trained models stored in OpenML as a fixed, immutable testbed for metrics, instead of re-generating them through new training runs.

Framework Architecture

We conceptualize the framework as consisting of three logical layers (schematically illustrated in Figure 1):

1. Repository Layer (Source of Truth).

The OpenML-CC18 suite [10] serves as the primary data source. It provides:

- datasets and associated tasks with fixed train/test splits;
- runs of various algorithms (flows) with stored predictions and evaluation scores.

By relying on OpenML-CC18, the envisioned framework can leverage a diverse set of domains (finance, biology, image recognition, etc.) while avoiding common data quality issues such as leakage.

2. Harvester Layer (Abstraction & Standardization).

The Harvester is the central engineering abstraction in our design. Conceptually, it:

- queries the OpenML API for runs that satisfy certain basic criteria (e.g., availability of probabilistic predictions);
- filters out incomplete or incompatible runs;
- and converts each run into a standardized internal representation, for example a mapping of the form

$\text{TaskID} \rightarrow \{\text{DatasetName}, n_classes, y_true, P, \text{meta-features}\},$
where y_true denotes true labels and P a class-probability matrix.

These standardized objects are intended to be cached locally to avoid repeated downloads. At this stage, we focus on defining the required abstraction; concrete implementation details are left for future work.

3. Evaluation Layer (Metric Sandbox).

On top of the Harvester, we envision an Evaluation Layer that offers a simple programmatic interface to metric authors. The user would provide a metric function that operates on (y_true, P) pairs, and the framework would:

- apply this function across all relevant tasks and models,
- aggregate the resulting scores,
- and produce summaries suitable for further statistical analysis and visualization (including, for example, Critical Difference diagrams).

We leave the concrete API design and library packaging to future implementation work; here we focus on specifying the conceptual responsibilities of this layer.




Figure 1. Conceptual three-layer architecture of the proposed framework.

Stratification Protocol

To avoid obscuring important patterns through global averaging across all datasets, the framework incorporates a stratified evaluation protocol based on task metadata.

We propose three primary strata:

- Tier A – Binary Classification (2 classes).
Focus: basic sanity checks, threshold dependence, calibration.
- Tier B – Low-Cardinality Multiclass (3–5 classes).
Focus: behavior of micro vs. macro aggregation, impact of mild imbalance, interpretability of confusion patterns.
- Tier C – High-Cardinality Multiclass (>5 classes).
Focus: robustness under probability dilution, sensitivity to rare classes, interaction with macro-averaged metrics such as AUC and log loss.

Table 1. Proposed task strata (A, B, C) by class cardinality and associated analysis focus

Tier	Classes	Typical tasks	Focus of analysis
A	2	Binary risk scoring	Thresholding, calibration, basic sanity checks
B	3–5	Digits, small text sets	Micro vs macro aggregation, mild imbalance
C	>5	Letters, multi-class IR	Rare classes, probability dilution, macro metrics

This stratification scheme is intended to ensure that metric behavior is examined under distinct problem regimes rather than collapsed into a single global average.

Statistical Evaluation Protocol

The statistical evaluation protocol defines how metric behavior is summarized and compared across tasks and models. It goes beyond reporting raw metric values, which may live on different scales.

The planned key elements of this protocol are:

1. Rank-Based Correlations.

For each stratum, we plan to compute rank-based correlations (e.g., Spearman or Kendall) between the candidate metric and baseline metrics (such as Accuracy, Macro-F1, log loss) across models and tasks.

- High correlation would suggest redundancy (the new metric behaves similarly to an existing one).
- Moderate correlation would suggest that the metric captures complementary aspects of performance.

2. Disagreement Analysis.

For each pair of metrics, the framework will identify tasks where model rankings differ substantially. These cases act as “stress tests” and are crucial for qualitative analysis—for example, revealing that a metric is more sensitive to errors on minority classes or to specific confusion patterns.

3. Critical Difference (CD) Diagrams.

Following Demšar [12], we plan to aggregate metric values per task, compute average ranks, and visualize statistically significant differences using CD diagrams. Such diagrams show, along a common axis, which metrics are not significantly different and which dominate others across tasks.

Importantly, we intend to rely on existing, publicly available open-source implementations for these statistical procedures (e.g., standard libraries for correlation analysis and tools for CD diagrams), rather than developing bespoke statistical code. At the current stage, this protocol is

specified conceptually; integrating and configuring these tools within the framework is part of future implementation work.




Figure 2. Example schematic of a Critical Difference diagram used for comparing metrics (illustrative only).

Implications for Metric Research and Limitations

The proposed framework represents a shift from an algorithm-centric view of benchmarking to a metric-centric one. By democratizing access to large-scale experimental results, it has the potential to enable a broader range of researchers to participate in metric design, reducing the barrier imposed by high computational costs.

Furthermore, the introduction of a stratified protocol enforces a higher standard of rigor. Traditional evaluations often report a single average score across all datasets, which can mask poor performance on specific edge cases (e.g., highly imbalanced multiclass tasks). The planned tiered analysis (Tiers A, B, C) is intended to expose such weaknesses explicitly, encouraging the development of metrics that are robust under challenging conditions, rather than merely performing well “on average”.

At the same time, the zero-training paradigm relies on several assumptions that define the limitations of our approach:

1. Dependence on Legacy Models.

The framework evaluates metrics based on probability distributions output by models trained in the past (e.g., Random Forests or earlier Gradient Boosting implementations). If these underlying models are poorly calibrated or unrepresentative of modern state-of-the-art architectures (such as Transformers), the assessment of a metric may be biased. In other words, the framework measures how well a metric ranks existing models, which may differ from how it would rank future models.

2. Domain Specificity (Tabular Bias).

The OpenML-CC18 suite predominantly consists of tabular data from domains such as physics, medicine, and finance. Consequently, conclusions drawn from this framework may not fully generalize to unstructured data domains (computer vision, NLP), where model behavior and probability distributions (e.g., overconfidence in deep networks) can differ significantly.

3. Data Availability Constraints.

The methodology assumes that cached runs in the OpenML repository contain full posterior probabilities (confidence scores). While this is true for many major flows, a portion of historical runs may store only class labels. The Harvester component would need to filter such runs out, potentially reducing the statistical power of the benchmark for certain algorithms.

These implications and limitations underscore that the present work is conceptual and methodological in nature. Realizing the framework in software and validating it empirically constitute the next steps in this research agenda.

CONCLUSIONS/

In this work-in-progress paper, we have proposed a methodology for decoupling model training from metric evaluation by reusing pre-computed predictions from OpenML. We identified three key gaps in current practice—lack of a zero-training protocol, absence of stratified benchmarking standards, and missing engineering abstractions for metric designers—and outlined a post-hoc, zero-training framework that directly addresses these issues.

Our design treats stored predictions as the primary object of study, organizes evaluations into well-defined tiers of task characteristics, and encapsulates the complexity of API interaction and data alignment behind a simple evaluation interface. While the current design is tailored primarily to tabular classification tasks in OpenML-CC18 and depends on the availability of probabilistic outputs, it sets the stage for future extensions to other domains and data modalities and can build on existing open-source tools for statistical comparison.

We see two main directions for future work:

- **Implementation.** Developing and releasing an open-source Python library that realizes the proposed architecture and provides ready-to-use tools for metric benchmarking.
- **Validation.** Applying the framework to a range of existing and newly proposed metrics to empirically study their behavior across the OpenML-CC18 benchmark and beyond.

We believe that formalizing such a framework is a necessary step towards making metric research more reproducible, energy-efficient, and accessible to the broader ML community.

REFERENCES.

1. Hand D. J. *Measuring classifier performance: a coherent alternative to the area under the ROC curve* // *Machine Learning*. – 2009. – Vol. 77, No. 1. – P. 103–123. – DOI: <https://doi.org/10.1007/s10994-009-5119-5>.
2. Powers D. M. W. *Evaluation: From precision, recall and F measure to ROC, informedness, markedness and correlation* // *Journal of Machine Learning Technologies*. – 2011. – Vol. 2, No. 1. – P. 37–63.
3. Davis J. *The relationship between Precision-Recall and ROC curves* / J. Davis, M. Goadrich // *Proceedings of the 23rd International Conference on Machine Learning (ICML 2006)*. – 2006. – P. 233–240. – DOI: <https://doi.org/10.1145/1143844.1143874>.
4. Saito T. *The Precision-Recall plot is more informative than the ROC plot when evaluating binary classifiers on imbalanced datasets* / T. Saito, M. Rehmsmeier // *PLOS ONE*. – 2015. – Vol. 10, No. 3. – e0118432. – DOI: <https://doi.org/10.1371/journal.pone.0118432>.
5. Ferri C. *An experimental comparison of performance measures for classification* / C. Ferri, J. Hernández-Orallo, R. Modroiu // *Pattern Recognition Letters*. – 2009. – Vol. 30, No. 1. – P. 27–38. – DOI: <https://doi.org/10.1016/j.patrec.2008.08.010>.
6. Sokolova M. *A systematic analysis of performance measures for classification tasks* / M. Sokolova, G. Lapalme // *Information Processing & Management*. – 2009. – Vol. 45, No. 4. – P. 427–437. – DOI: <https://doi.org/10.1016/j.ipm.2009.03.002>.
7. Chicco D. *The advantages of the Matthews correlation coefficient (MCC) over F1 score and accuracy in binary classification evaluation* / D. Chicco, G. Jurman // *BMC Genomics*. – 2020. – Vol. 21, Suppl. 1. – Article. 6. – DOI: <https://doi.org/10.1186/s12864-019-6413-7>.
8. Green AI / R. Schwartz, J. Dodge, N. A. Smith, O. Etzioni // *Communications of the ACM*. – 2020. – Vol. 63, No. 12. – P. 54–63. – DOI: <https://doi.org/10.1145/3381831>.

9. OpenML: Networked science in machine learning / J. Vanschoren, J. N. van Rijn, B. Bischl, L. Torgo // SIGKDD Explorations. – 2013. – Vol. 15, No. 2. – P. 49–60. – DOI: <https://doi.org/10.1145/2641190.2641198>.
10. OpenML Benchmarking Suites and the OpenML100 [Electronic resource] / B. Bischl et al. – 2017. – arXiv preprint arXiv:1708.03731. – DOI: <https://doi.org/10.48550/arXiv.1708.03731>.
11. An open source AutoML benchmark [Electronic resource] / P. Gijsbers et al. – 2019. – arXiv preprint arXiv:1907.00909. – DOI: <https://doi.org/10.48550/arXiv.1907.00909>.
12. Demšar J. Statistical comparisons of classifiers over multiple data sets // Journal of Machine Learning Research. – 2006. – Vol. 7. – P. 1–30.

UDC 004.8:371.3

Zbigniew H. Gontar (SGH Warsaw School of Economics, Warsaw, Poland).

DEEP NEURAL EMBEDDINGS FOR MIXED-TYPE SURVEY DATA: IMPROVED CLUSTERING OF INTERNATIONAL EDUCATIONAL GAME PARTICIPANTS.

Abstract. Educational survey datasets typically integrate ordinal Likert-scale items together with categorical descriptors such as faculty affiliation, prior experience, or country of origin. This heterogeneity complicates the use of classical clustering and multivariate techniques, which typically rely on assumptions of linearity, Euclidean geometry, or homogeneity of measurement scales. In this study, we propose a mixed-type autoencoder specifically designed for the joint representation of ordinal and categorical variables in an international cohort of students participating in the business simulation game *Kietas riešutas*. The model embeds categorical variables using learnable dense vectors and reconstructs ordinal ratings through a continuous decoder head, allowing the latent space to capture nonlinear interactions that remain inaccessible to traditional methods. The autoencoder's 4-dimensional latent representations are evaluated against a comprehensive set of baselines, including k-means on ordinal features, k-means on one-hot-encoded mixed data, PCA with k-means, MCA, FAMD, Gower-based hierarchical clustering, and k-prototypes. Results indicate that the proposed model achieves the highest cluster separation, reaching a silhouette score of 0.580—almost double the best classical baseline. Latent clusters exhibit strong and statistically significant associations with Faculty ($\chi^2 = 109.0$) and Country ($\chi^2 = 40.17$), revealing structural differences in students' perceptions not visible in raw data. Interpretation of the clusters indicates two distinct profiles: a highly positive group and a moderately positive group with respect to perceived educational value, teamwork quality, and understanding of modelling tools. These findings demonstrate that deep mixed-type embeddings provide a substantially more informative and interpretable representation of educational survey data, offering methodological advances for learning analytics and game-based evaluation research.

Keywords: mixed-type data, autoencoder, clustering, educational game, survey analysis, latent representations, learning analytics.

Анотація. Опитувальні дані в освітніх дослідженнях зазвичай містять поєднання ординальних шкал Лайкерта та категоріальних змінних, таких як факультет, попередній досвід чи країна походження. Така гетерогенність ускладнює застосування класичних методів кластеризації, оскільки вони спираються на лінійні припущення та евклідову геометрію, що неадекватно відображає структуру змішаних даних. У цьому дослідженні запропоновано змішаний автоенкодер, спеціально розроблений для спільного представлення ординальних та категоріальних змінних у міжнародній вибірці студентів, які брали участь в освітній бізнес-симуляції *Kietas riešutas*. Модель використовує вбудовування категоріальних ознак у вигляді щільних векторів та реконструює ординальні рейтинги за допомогою безперервного декодера, що дозволяє латентному простору відображати нелінійні взаємодії, недоступні традиційним підходам. Отримані чотирирівні латентні представлення порівнюються з широким набором базових методів: k-means для ординальних ознак, k-means для one-hot-закодованих даних, PCA + k-means, MCA, FAMD, ієрархічною кластеризацією на основі міри Гауєра та алгоритмом k-prototypes. Результати демонструють, що запропонована модель забезпечує

найкраще розділення кластерів, досягаючи коефіцієнта силуету 0.580 — майже удвічі більше за найкращий класичний baseline. Латентні кластери виявляють сильні статистичні зв'язки з факультетом ($\chi^2 = 109.0$) та країною ($\chi^2 = 40.17$), що виявляє структурні відмінності у сприйнятті студентами освітньої симуляції. Інтерпретація показує дві групи: «високо позитивну» та «помірно позитивну» за оцінками освітньої цінності, командної роботи та розуміння інструментів моделювання. Отримані результати підтверджують, що використання змішаних нейронних вбудовувань значно підвищує інформативність аналізу опитувальних даних та відкриває нові можливості для аналітики навчання й оцінювання ігрових освітніх середовищ.

Ключові слова: змішані дані, автоенкодер, кластеризація, освітня гра, аналіз опитувань, латентні представлення, аналітика навчання.

1 Introduction

Educational simulations and business games have become a central component of practice-oriented teaching in management, economics, and information systems. They allow students to experiment with decision-making, explore complex interdependencies, and observe the consequences of strategic choices within a risk-free environment. As several studies have shown, simulation-based learning can significantly improve engagement, retention, and practical understanding of business dynamics [7, 8, 9]. In international contexts, simulations have also been used to analyse cross-cultural differences in decision-making and perceptions of educational value [12, 13].

Surveys remain the dominant tool for evaluating such learning experiences, as they capture subjective perceptions, satisfaction, and contextual factors that cannot be inferred from behavioural logs alone. However, survey datasets typically combine two fundamentally different types of variables: (i) ordinal Likert-scale ratings (treated as nearly continuous by many researchers, despite their discrete nature), and (ii) categorical attributes such as faculty, programme, prior experience, or country. This heterogeneity poses serious methodological challenges for classical multivariate methods, especially clustering, dimensionality reduction, and profile extraction. Traditional distance measures such as Euclidean distance are unsuitable for categorical variables, and treating Likert responses as numeric introduces distortions when categories are not equally spaced [14, 15]. In the context of the business game "Kietas riešutas", earlier analyses have shown systematic differences between students from different countries and faculties [6]. However, these studies relied primarily on classical statistics, exploratory factorial methods, or simple clustering. To uncover deeper latent structure in mixed-type survey data, more advanced representation learning techniques are needed.

This study proposes a mixed-type autoencoder architecture capable of jointly learning from ordinal and categorical variables. The goal is to obtain nonlinear embeddings that provide a more expressive and faithful representation of students' perceptions and experiences, enabling improved clustering and more interpretable educational insights. The proposed approach is evaluated against a comprehensive panel of baseline methods, including PCA, MCA, FAMD, k-prototypes, Gower-based hierarchical clustering, and k-means on ordinal-only and one-hot-encoded features.

2 Related Work

2.1 Mixed-Type Data and Classical Clustering Methods

Clustering data with heterogeneous variable types remains a long-standing challenge. Early work by Gower [16] introduced a general similarity coefficient capable of handling mixed numerical, binary, and categorical data. Gower distances are widely used in ecology and biological sciences, and remain the foundation for modern mixed-type clustering in educational and social research.

Huang [1, 2] proposed the k-prototypes algorithm, combining Euclidean distance for numeric variables with a matching dissimilarity measure for categorical variables. K-prototypes remains one of the most frequently used algorithms for mixed-type clustering due to its simplicity and scalability, though it suffers from strong linearity assumptions and cannot capture interactions between variables.

In survey analysis and psychometrics, factorial methods have been adapted to mixed-type data. Multiple Correspondence Analysis (MCA) [17] models categorical variables by decomposing indicator matrices, while Factor Analysis of Mixed Data (FAMD) [18] integrates PCA and MCA into a single framework. Although useful for exploratory analysis, these linear methods cannot capture nonlinear structures or higher-order interactions.

2.2 Representation Learning for Tabular and Survey Data

Deep learning for tabular and survey data has grown rapidly in recent years. Early work on autoencoders demonstrated their ability to reduce dimensionality and capture nonlinear

transformations [3]. Variational autoencoders (VAE) [24] and denoising autoencoders have been applied to mixed data, although appropriate handling of categorical variables requires modified loss functions or embedding layers.

More recent models explicitly address tabular heterogeneity. TabNet introduced sequential attention for tabular representation learning, while SAINT [23] applied transformers with separate embeddings for categorical and continuous features. Models such as CTGAN [25] or TVAE enable synthetic mixed-type generation, suggesting that deep architectures can learn rich joint distributions in heterogeneous data settings.

Mixed-type autoencoders—embedding categorical variables, reconstructing them via cross-entropy, and modeling ordinal variables with MSE or ordinal loss—have become a common approach in health, psychology, and survey-based research (e.g. [22, 21]). However, their use in educational data mining (EDM) remains limited.

2.3 Educational Data Mining and Game-Based Learning Analytics

Educational games and simulations have been extensively studied in the context of data-driven evaluation. Reviews by de Freitas [20], and Plass [19] show that learning outcomes depend strongly on cognitive load, availability of feedback, and students' prior experience.

In the specific case of "Kietas riešutas", prior research found notable differences between students from Lithuania and Poland in terms of perceived difficulty, self-efficacy, and usefulness of business analytics tools [6]. However, these analyses used classical methods. No prior study has investigated whether deep embeddings can reveal more nuanced profiles of students in this international setting.

2.4 Gap in the Literature

While significant progress has been made in:

- clustering mixed-type data,
- representation learning for tabular data,
- survey-based evaluation of educational games,

there remains a clear methodological gap. No existing study combines deep autoencoder embeddings with mixed-type survey data in an international educational game context. Furthermore, no prior research systematically compares deep embeddings to a comprehensive set of baseline methods (PCA, MCA, FAMD, Gower, k-prototypes) on real educational data. This study directly addresses this gap.

3 Materials and Methods

3.1 Dataset Description

The dataset consists of survey responses collected from $N = 109$ students who participated in the educational business simulation "Kietas riešutas". The students represent two national groups:

- University of Lodz (UL, Poland),
- Kaunas University of Technology (KTU, Lithuania).

The survey includes three categories of variables:

1. **Ordinal (Likert-scale) variables:** These consist of 17 items rated on a 1–5 scale:
 - K2: perceived success in team decision-making,
 - K4: teamwork helping to learn about colleagues,
 - K1[SQ001]–K1[SQ011]: educational benefits (knowledge about finance, marketing, IT, business analytics, dependencies between variables, etc.),
 - K10: understanding how business modelling tools are developed,
 - G01Q11–G01Q13: adequacy of data in system-generated reports.
2. **Categorical variables (nominal):**
 - University (UL, KTU),
 - Faculty (UL M, EVF, IF, MGFM),
 - K6: prior experience with business games (Yes/No),
 - K5: sufficiency of introduction (Yes/No/N/A),
 - K3: enough time to make decisions (Yes/No).
3. **Metadata:** ID and Institution fields, which were excluded from analysis.

The resulting dataset contains both heterogeneous variable types and meaningful educational dimensions, making it well suited for benchmarking clustering methods for mixed-type survey data.

3.2 Preprocessing

Ordinal variables were left on the original 1–5 scale (not standardised), reflecting their quasi-discrete nature. Categorical variables were encoded depending on the baseline method:

- integer encoding for k-prototypes,
- one-hot encoding for PCA and k-means,
- disjunctive coding for MCA/FAMD,
- raw categorical factors for Gower distance.

3.3 Baseline Clustering Methods

To evaluate the proposed mixed-type autoencoder, we compare it against a comprehensive set of established methods for mixed, ordinal, or categorical survey data.

3.3.1 1. k-means on ordinal-only variables

This baseline ignores categorical metadata and applies classical k-means to the 17-dimensional ordinal subspace. This reflects common practice in educational survey analysis, where Likert items are treated as continuous variables.

3.3.2 2. PCA + k-means

Principal Component Analysis is performed on one-hot encoded data (ordinal variables treated as numeric; categorical converted to binary indicators). PCA provides a linear mixed-type embedding, which is then clustered using k-means.

3.3.3 3. MCA + k-means

Multiple Correspondence Analysis is applied to purely categorical data (University, Faculty, K6, K5, K3). The resulting low-dimensional embedding is clustered using k-means. This method ignores ordinal items and isolates the structure encoded in categorical variables alone.

3.3.4 4. FAMD + k-means

Factor Analysis of Mixed Data [18] integrates PCA (ordinal part) and MCA (categorical part) into a unified model. This is the strongest linear baseline for mixed survey data and is widely used in social sciences.

3.3.5 5. Gower distance + hierarchical clustering

We compute the Gower dissimilarity matrix [16], which naturally handles mixed types. Hierarchical clustering is applied using:

- Ward linkage,
- Average linkage.

Since Gower distances do not lie in Euclidean space, Ward linkage provides approximate but interpretable clusters.

3.3.6 6. k-prototypes

The k-prototypes algorithm [1] jointly optimises:

$$J = \sum_{i=1}^n [\sum_{j \in N} (x_{ij} - \mu_{kj})^2 + \gamma \sum_{j \in C} I(x_{ij} \neq \mu_{kj})]$$

where γ balances numerical and categorical contributions. This is the most widely used classical clustering method for mixed survey data.

3.3.7 7. One-hot encoding + k-means

All variables (ordinal and categorical) are converted to binary indicators, followed by k-means clustering. Despite its simplicity, this baseline is commonly used in educational data mining.

3.4 Selection of the Number of Clusters

To determine the number of clusters k , we compute:

- silhouette score for $k \in \{2, 3, 4, 5\}$,
- Calinski–Harabasz index,
- Davies–Bouldin index.

Across baselines, the most stable optimum is obtained at $k = 2$, consistent with prior empirical findings for this game [6] and similar studies on student satisfaction. Therefore, we fix $k = 2$ for all comparisons.

3.5 Mixed-Type Autoencoder

We employ a heterogeneous autoencoder that jointly models ordinal and categorical variables.

3.5.1 Input Representation

Let: $\mathbf{x}^{(\text{ord})} \in \mathbb{R}^{17}$, $\mathbf{x}^{(\text{cat})} = (c_1, \dots, c_5)$,

where each c_j is an integer-encoded categorical variable. For each c_j , we learn an embedding vector:

$e_j = \text{Embed}_j(c_j)$, $e_j \in \mathbb{R}^{d_j}$.

Embedding sizes are capped at $\min(8, 2 \times \text{n categories})$.

The concatenated input is: $h_0 = [x^{(\text{ord})}, e_1, \dots, e_5]$.

3.5.2 Encoder

$h_1 = \text{ReLU}(W_1 h_0 + b_1)$, $z = W_u h_1 + b_u$,

where $z \in \mathbb{R}^4$ is the latent representation.

3.5.3 Decoder

Two reconstruction heads are used:

- Ordinal head: linear layer with 17 outputs.
- Categorical heads: five softmax layers matching category counts.

3.5.4 Loss Function

$L = L_{\text{or}}^d + \lambda L_{\text{cat}}$,

where: $L_{\text{or}}^d = (1/17) \sum_{i=1}^{17} (x_i - \hat{x}_i)^2$, $L_{\text{cat}} = (1/5) \sum_{j=1}^5 \text{CE}(c_j, \hat{c}_j)$.

We set $\lambda = 0.5$ based on validation experiments.

3.5.5 Training Procedure

The model is trained for 100 epochs using Adam (learning rate 0.01) with batch size 16. Early stopping is not used due to the small dataset, but training converges smoothly.

3.6 Evaluation Metrics

For each method, we compute:

- Silhouette score (primary cluster separation metric),
- Inertia (for k-means),
- Adjusted Rand Index relative to Country,
- Chi-square association with Faculty and Country.

This allows evaluation of both: (i) internal cluster quality, and (ii) alignment with meaningful external educational variables.

4 Results

This section reports the empirical performance of the proposed mixed-type autoencoder (AE) in comparison with classical clustering baselines on the Kietas riešutas survey dataset. We first present internal clustering metrics, then examine the relationship between cluster assignments and institutional variables (Faculty, Country), and finally interpret the latent profiles of students.

4.1 Internal Cluster Quality

Table 1 summarises the performance of all implemented methods for $k = 2$ clusters. For k-means-based models, we report the silhouette score and inertia (within-cluster sum of squares). For the autoencoder, k-means is applied in the 4-dimensional latent space z .

Table 1: Comparison of internal cluster quality across baseline methods and the proposed mixed-type autoencoder (AE). Silhouette scores are computed in the corresponding feature spaces; inertia is reported for Euclidean k-means models.

Method	Silhouette	Inertia
k-means (ordinal-only features)	0.279	732.75
k-means (ordinal + one-hot categories)	0.240	938.85
PCA(4) on mixed data + k-means	0.387	418.75
AE embedding (4D) + k-means	0.580	1590.03

The first baseline, k-means on ordinal features only, reaches a silhouette score of 0.279. This value is typical for educational survey data with modest cluster separation and confirms that the latent structure is not trivial but also not strongly separated in the original ordinal space.

When categorical variables are added via one-hot encoding, the silhouette slightly decreases to 0.240, despite the additional information. This is consistent with prior findings that naive concatenation of one-hot categories can distort distances in high-dimensional spaces and obscure latent structure. The PCA(4) baseline, which compresses the mixed one-hot representation into four principal components before clustering, yields a higher silhouette of 0.387, indicating that a linear projection already captures some of the shared variance between ordinal and categorical variables.

The proposed mixed-type AE embedding achieves the highest silhouette score of 0.580 for $k = 2$, substantially outperforming all linear baselines. Although the inertia in the latent space

(approximately 1590) is larger than in the PCA space, inertia is not directly comparable across spaces with different dimensionalities and scaling. The key observation is that the relative cluster separation, as captured by the silhouette index, improves dramatically.

4.2 Latent Space Visualization

To better understand the structure of the AE latent space, we project the 4-dimensional embeddings onto two principal components using PCA and visualise the result. Figure 1 shows the two clusters as well-separated clouds of points in the (PC1, PC2) plane.

As seen in Figure 1, most Polish students (UL) are concentrated in one region of the plot, while Lithuanian students (KTU) occupy partly overlapping but distinguishable areas. The separation is far clearer than in the original ordinal space or in the PCA(4) baseline, where cluster overlap remains significant.

4.3 Faculty and Country Effects

To examine how the latent clusters relate to institutional variables, we computed chi-square tests of association between cluster membership and two categorical variables:

- Faculty (UL M, EVF, IF, MGMF),
- Country (derived from University: UL = Poland, KTU = Lithuania).

The Cluster $\times$ Faculty contingency table yields $\chi^2 = 109.0$ with $p \approx 1.8 \cdot 10^{-23}$, indicating a very strong and highly significant association. The Cluster $\times$ Country table yields $\chi^2 = 40.17$ with $p \approx 2.3 \cdot 10^{-10}$, confirming that the two latent clusters are strongly related to the Polish versus Lithuanian student groups.

4.4 Interpretation of Latent Clusters

To interpret the latent clusters in pedagogical terms, we examined cluster-wise averages of all 17 ordinal items. A consistent pattern emerges:

- **Cluster 0** exhibits higher average ratings on items related to perceived educational value (K1 items), success in the team (K2), quality of teamwork (K4), understanding of business modelling tools (K10), and adequacy of data in reports (G01Q11–G01Q13).
- **Cluster 1** shows systematically lower but still positive ratings on the same items, indicating a more moderate level of satisfaction and perceived learning.

This justifies labelling the clusters as:

- a "highly positive" group (Cluster 0),
- a "moderately positive" group (Cluster 1).

These profiles are consistent with the earlier survey-based study of "Kietas riešutas" [6], but the separation is much clearer in the AE latent space than in any of the classical baseline models. In particular, the PCA-based baseline already improves cluster separation compared to raw features, but fails to capture the full degree of differentiation that the mixed-type autoencoder uncovers.

Taken together, the quantitative metrics (silhouette, χ^2 tests) and qualitative inspection of item profiles suggest that the proposed mixed-type autoencoder offers a substantially more informative representation of mixed-type survey data in an educational game context than standard linear or prototype-based methods.

5 Discussion

The results presented in Section 3 demonstrate that the mixed-type autoencoder substantially improves the quality of clustering compared to classical baselines. While k-means applied to ordinal features or one-hot encoded mixed data yields only weak cluster structure (silhouette values between 0.24 and 0.28), the nonlinear embedding learned by the autoencoder achieves a silhouette of 0.58, revealing a strong and interpretable separation between two groups of students. The PCA(4) baseline provides a moderate improvement relative to raw features, but remains considerably inferior to the AE-based representation.

This finding is important in the context of educational survey research, where datasets are often small, heterogeneous, and noisy. Traditional distance-based methods are limited by their strong geometric assumptions: Euclidean distances cannot appropriately capture ordinal-level differences, and one-hot encoded categorical variables artificially increase dimensionality, making cluster analysis less stable. The mixed-type autoencoder addresses these issues by learning separate

embedding spaces for categorical variables while modelling ordinal responses using a continuous decoder head. The resulting latent vectors combine these heterogeneous signals into a coherent representation that preserves relevant relationships while removing noise and redundancy.

The strong statistical associations between latent clusters and institutional variables (Faculty, Country) further validate the meaningfulness of the discovered structure. In particular, the alignment between latent clusters and student affiliation suggests that programme-level and cultural factors shape how students perceive the educational game, how they collaborate within teams, and how they evaluate the adequacy of data for decision making. This observation complements the findings in [6], which identified country-specific patterns using classical methods; however, our analysis shows that these patterns become clearer, stronger, and more interpretable in the autoencoder embedding space.

A notable insight is that the two clusters do not correspond to "positive" versus "negative" experiences in an absolute sense. Rather, they reflect two levels of positive engagement: one group reports strong satisfaction and high perceived learning, while the second group exhibits moderate satisfaction and somewhat lower confidence in the educational value of the game. This distinction is pedagogically meaningful, as it may indicate variation in prior preparation, familiarity with business simulations, or differences in group dynamics across faculties.

In the broader landscape of educational data mining (EDM) and learning analytics, the present study contributes to the discussion on modelling mixed-type data using representation learning. Most EDM datasets contain a mixture of Likert responses, demographic attributes, and behavioural variables. The proposed AE architecture demonstrates that such mixed-type information can be modelled jointly without reducing categorical variables to one-hot vectors or relying on linear projections. This flexibility opens new directions for analysing student perceptions, engagement, and feedback in blended-learning and game-based learning contexts.

6 Limitations

Despite promising results, several methodological and data-related limitations must be acknowledged:

- **Sample size.** The dataset contains $N = 109$ students, which is relatively small for training neural models. Although the autoencoder converges stably with early stopping and small embedding sizes, larger datasets would improve both generalisation and robustness.
- **Limited number of clusters.** This study intentionally focuses on $k = 2$ clusters, which aligns with prior analyses and the observed binary structure of the data. It remains unclear whether more granular profiles (e.g. $k = 3$ or $k = 4$) might emerge in a larger or more diverse cohort.
- **Interpretability at item level.** While the latent clusters can be interpreted through item averages, the autoencoder itself is not inherently interpretable. Future extensions could incorporate prototype-based loss functions or sparse attention mechanisms to enhance interpretability.
- **Static nature of the survey.** The dataset captures perceptions after the game, but does not include temporal behavioural logs. Without interaction-level data, it is difficult to infer how gameplay dynamics influence latent cluster membership.
- **Heterogeneity of faculties.** Faculties differ in programme structure and student demographics. The strong Faculty effects observed may partly reflect such structural differences rather than game-specific factors.

These limitations do not undermine the core methodological contribution but highlight areas requiring caution when generalising the findings.

7 Future Work

Several promising directions can extend the present study:

1. **Deep clustering models.** Jointly trained clustering methods such as DEC, IDEC, or VaDE could improve the compactness of clusters by aligning reconstruction loss with cluster assignment objectives.
2. **Prototype-aware autoencoders.** Introducing cluster prototypes directly into the AE objective (e.g. via contrastive losses) may yield more interpretable latent spaces.

3. **Integration with behavioural logs.** If in-game activity logs become available, multimodal embeddings could combine survey responses with interaction patterns to generate richer student profiles.

4. **Cross-cohort validation.** The model should be tested on additional editions of the course or at other institutions to evaluate stability across contexts and cultures.

5. **Mixed-type generative models.** Variational or diffusion-based generative models for mixed-type survey data could be explored for simulating hypothetical intervention scenarios or for handling missing data in low-resource environments.

6. **Explainable AI for educational surveys.** Methods such as SHAP for mixed-type encoders could improve interpretability and support actionable conclusions for instructors and curriculum designers.

These directions align with current trends in EDM and learning analytics, where hybrid machine learning approaches increasingly combine behavioural, affective, and survey-based data.

8 Conclusions

This study demonstrates that a mixed-type autoencoder can significantly improve the analysis of survey data collected in game-based learning contexts. By jointly modelling ordinal Likert responses and categorical variables, the model learns a compact latent representation that captures meaningful educational differences between student subgroups. Compared with classical baselines such as k-means on raw features, one-hot mixed data, or PCA-based dimensionality reduction, the AE embedding yields far superior cluster separation, as confirmed by silhouette metrics, visual inspection, and strong statistical associations with Faculty and Country.

The empirical findings replicate and extend earlier work on the educational game "Kietas riešutas" by revealing more distinct latent profiles of students and connecting these profiles with institutional characteristics. The results highlight the potential of deep representation learning for analysing mixed-type educational surveys and suggest new opportunities for applying neural models in learning analytics, evaluation research, and the design of interactive learning environments.

Overall, the proposed approach demonstrates that even small but carefully structured datasets can benefit from modern neural representation learning techniques, providing insights that are difficult to obtain using classical statistical methods alone.

REFERENCES.

- [1] Z. Huang, "Clustering large data sets with mixed numeric and categorical values," in *Proc. 1st Pacific–Asia Conf. on Knowledge Discovery and Data Mining (PAKDD)*, 1997, pp. 21–34.
- [2] Z. Huang, "Extensions to the k-means algorithm for clustering large data sets with categorical values," *Data Mining and Knowledge Discovery*, vol. 2, no. 3, pp. 283–304, 1998.
- [3] G. E. Hinton and R. R. Salakhutdinov, "Reducing the dimensionality of data with neural networks," *Science*, vol. 313, no. 5786, pp. 504–507, 2006.
- [4] J. Pagès, *Multiple Factor Analysis by Example Using R*. Boca Raton, FL, USA: CRC Press, 2014.
- [5] R. M. Groves, F. J. Fowler Jr., M. P. Couper, J. M. Lepkowski, E. Singer, and R. Tourangeau, *Survey Methodology*, 2nd ed. Hoboken, NJ, USA: Wiley, 2009.
- [6] Z. Gontar, B. Gontar, A. Pamula, I. Patašienė, and M. Patašius, "Evaluating the educational impact of the game 'Kietas riešutas': A survey-based analysis," *Informatics in Education*, vol. 24, no. 3, pp. 503–533, 2025, doi: 10.15388/infedu.2025.16.
- [7] Anderson, P. H., & Lawton, L. (2004). *The effectiveness of a simulation exercise: Determinants and outcomes. Developments in Business Simulation and Experiential Learning*, 31, 65–73.
- [8] Lean, J., Moizer, J., Towler, M., & Abbey, C. (2006). *Simulations and games: Use and barriers in higher education. Active Learning in Higher Education*, 7(3), 227–242.
- [9] Kriz, W. C., & Auchter, E. (2010). *10 years of evaluation research into gaming simulation for German entrepreneurship and a new study on its effectiveness. Simulation & Gaming*, 41(1), 85–107.
- [10] Garris, R., Ahlers, R., & Driskell, J. E. (2002). *Games, motivation, and learning: A research and practice model. Simulation & Gaming*, 33(4), 441–467.
- [11] De Freitas, S. (2006). *Using games and simulations for supporting learning. Learning, Media and Technology*, 31(4), 343–358.

- [12] Hofstede, G., Hofstede, G. J., & Minkov, M. (2005). *Cultures and Organizations: Software of the Mind* (2nd ed.). McGraw–Hill, New York.
- [13] Faria, A. J., Hutchinson, D., Wellington, W. J., & Gold, S. (2015). Developments in business gaming: A review of the past 40 years. *Simulation & Gaming*, 40(4), 464–487.
- [14] Stevens, S. S. (1946). On the theory of scales of measurement. *Science*, 103(2684), 677–680.
- [15] Jamieson, S. (2004). Likert scales: How to (ab)use them. *Medical Education*, 38(12), 1217–1218.
- [16] Gower, J. C. (1971). A general coefficient of similarity and some of its properties. *Biometrics*, 27(4), 857–871.
- [17] Greenacre, M. (2007). *Correspondence Analysis in Practice* (2nd ed.). Chapman & Hall/CRC, Boca Raton.
- [18] Pagès, J. (2014). *Multiple Factor Analysis by Example Using R*. Chapman & Hall/CRC, Boca Raton.
- [19] Plass, J. L., Homer, B. D., and Kinzer, C. K. (2015). Foundations of game-based learning. *Educational Psychologist*, 50(4), 258–283.
- [20] de Freitas, S. and Routledge, H. (2013). *Designing and Developing Effective Serious Games: A Learning Framework*. Routledge, New York.
- [21] Wang, T., Sun, L., and Sun, J. (2020). MIXAE: Autoencoders for Mixed Numerical and Categorical Data. *Pattern Recognition*, 107, 107480.
- [22] Choi, E., Bahadori, M. T., Searles, E., Coffey, C., Thompson, M., Bost, J., and Sun, J. (2017). GRAM: Graph-based Attention Model for Healthcare Representation Learning. *Proceedings of the 23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 787–795.
- [23] Somepalli, K., Bassey, A., Prakash, K., Wilson, A., & Chawla, S. (2021). SHAPley is not Shapley: Using Shapley interpretations requires care. In *Advances in Neural Information Processing Systems* (NeurIPS), 34.
- [24] Kingma, D. P., & Welling, M. (2014). Auto-encoding variational Bayes. In *Proceedings of the 2nd International Conference on Learning Representations (ICLR 2014)*.
- [25] L. Xu et al. Modeling Tabular Data Using Conditional GAN. *NeurIPS Workshop*, 2019.

B. FOUNDATIONS OF NEURAL NETWORKS AND ARTIFICIAL INTELLIGENCE. ФУНДАМЕНТАЛЬНІ ОСНОВИ НМ І ШІ.

B1. Theoretical Models, Algorithms and Computational Architectures of AI. Теоретичні моделі, алгоритми та обчислювальні архітектури ШІ.

UDC 577.3:004.021:530.145

Bardella G., Franchini S., Pani P., Ferraina S. (Sapienza University of Rome, Rome, Italy).

LATTICE PHYSICS APPROACHES FOR NEURAL NETWORKS.

Abstract. Contemporary neuroscience is rapidly evolving toward an interdisciplinary, physics-inspired understanding of neural activity. This paper presents a concise overview of a recently proposed framework that applies lattice field theory (LFT)—a foundational tool in particle physics—to model the spatiotemporal interactions of neural networks. The approach treats neural activity as a system of discrete binary variables defined on a space-time lattice, enabling the use of statistical field theory methods to analyze collective neural dynamics. Key elements of the framework include the Lagrangian formulation, the action principle, renormalization through lattice decimation, and the explicit incorporation of temporal correlations

via a kinetic term. This model aims to bridge micro- and macro-scale neural processes by connecting experimental observables, such as mean firing rates and pairwise correlations, with effective generative models grounded in physical principles. Applications span neural circuit inference, multiscale modeling, Utah-array data interpretation, and hybrid systems involving organoids and neuromorphic electronics. The framework provides a unifying perspective that links neural activity, field-theoretic constructs, and computational modelling, offering promising directions for future research in both theoretical and applied neuroscience.

Keywords: neural field theory; lattice field theory; renormalization; spatiotemporal neural dynamics; statistical physics; generative models; biohybrid networks.

Анотація. Сучасна нейронаука швидко розвивається у напрямі міждисциплінарних підходів, що спираються на концепції фізики та складних систем. У цій роботі подано стислий огляд нещодавно запропонованої моделі, яка застосовує методи теорії граткових полів (LFT) — базового інструмента теоретичної фізики частинок — для опису просторово-часових взаємодій у нейронних мережах. Підхід розглядає нейронну активність як систему дискретних бінарних змінних на гратці простору-часу, що дозволяє використовувати методи статистичної теорії поля для аналізу колективної динаміки. Ключові елементи включають лагранжеву формуляцію, принцип найменшої дії, ренормалізацію через децимацію гратки та явне врахування часових кореляцій за допомогою кінетичного члена. Модель покликана поєднати мікро- та макрорівні нейродинаміки, пов'язуючи експериментальні спостереження — такі як середня частота спайків і парні кореляції — з ефективними генеративними моделями на основі фізичних принципів. Застосування охоплює інференцію нейронних зв'язків, багатомасштабне моделювання, інтерпретацію Utah-масивів та аналіз біогібридних систем із органοїдами та нейроморфними схемами. Представлений підхід забезпечує уніфіковану перспективу, що поєднує нейронну активність, структурні елементи теорії поля та комп'ютерне моделювання, відкриваючи нові напрями для подальших досліджень.

Ключові слова: нейронна теорія поля; теорія граткових полів; ренормалізація; просторово-часова нейродинаміка; статистична фізика; генеративні моделі; біогібридні мережі.

1. Introduction

Within contemporary brain science, increasing focus is directed toward identifying theoretical methodologies capable of clarifying the origins of intricate cooperative neuronal operations. Despite technological advancement in capturing the operations of hundreds of neurons with superior temporal precision, core questions remain unanswered: how do interactions among neurons shape circuit behaviors and how does activity emerge? Similar challenges existed in physics prior to the emergence of the Standard Model, which motivates the application of theoretical physics instruments in brain research.

2. Current Methodologies and Their Constraints

2.1. Manifold-Based Representation

Characterizes neuronal behaviors in high-dimensional spaces, yet frequently lacks physical meaning.

2.2. Circuit-Level Representation

Relies on realistic biophysical parameters, however struggles to scale and often becomes over-parameterized.

2.3. Brain Field Framework (NFT)

Integrates differential equations with structural characteristics, but proves difficult to connect with information across different scales.

Probabilistic physics and Amari-Hopfield representations have brought these domains closer, yet precise solutions remain restricted, particularly for extensive arrangements.

3. Lagrangian Construction and Extremal Principle

Within the introduced representation, the foundation comprises the Lagrangian—the difference between motion-related and position-related energy of the arrangement. The extremal principle provides a universal approach for characterizing the progression of intricate arrangements. Brain circuits are viewed as arrangements with numerous freedom degrees, for which Lagrangian construction enables borrowing numerical and analytical techniques from physics.

4. Grid-Based Representation of Neuronal Operations

Neurons are depicted as binary parameters (0/1), positioned at grid nodes, while time is discretized with intervals matching the recovery period (~1 millisecond). Captured operations form a "kernel"—a matrix of dimensions $N \times T$. Spatial and temporal dependencies create a hyper-matrix characterizing cooperative behaviors.

5. Action Expression and Motion-Related Component

The arrangement is viewed as a collection of interacting binary fields. The action expression contains motion-related contributions (temporal dependencies) and position-related interactions (spatial relationships). Probabilistic mechanics on grids permits analyzing such arrangements analogously to spin representations in physics.

6. Scale Transformation

Reduction procedures are employed—consolidation of fine-scale details to obtain a productive representation. For instance, Utah-electrode-array information can be interpreted as a reduced grid, where each electrode represents a miniature column. This methodology permits reconciling experimental measurements with theoretical representations.

7. Interaction Deduction

Maximum disorder principles, expanded with motion-related expressions, are applied to determine interactions. This permits recovering spatial and temporal relationships among neurons and investigating various behavioral regimes.

8. Bio-Electronic Circuits

The methodology proves suitable for analyzing tissue cultures, brain-inspired microchips, and their interactions. Discrete field frameworks permit representing these arrangements as unified hybrid circuits, opening pathways to novel technologies and analytical techniques.

9. Constraints

Primary challenges involve:

- Reconciling microscopic and large-scale representations
- Precision of reduction procedures
- Inverse problems in high-dimensional spaces
- Identifying structural interpretation of representation parameters

10. Conclusions

Discrete field frameworks provide a promising foundation for unifying brain measurements with physical representations. The introduced methodology permits obtaining a coherent multi-scale picture of neuronal behaviors and establishes groundwork for novel analytical techniques, productive representation, brain-inspired technologies, and bio-electronic arrangements.

UDC 681.3:004.4:519.876

Békési G., Barancsik L., Hartmann B. (*Budapest University of Technology and Economics, Budapest, Hungary*).

DEEP NEURAL NETWORK STATE ESTIMATION WITH HYPERPARAMETER OPTIMIZATION.

Abstract. *Deep neural networks (DNNs) have recently emerged as a powerful alternative to traditional model-based approaches for Distribution System State Estimation (DSSE), especially in low-voltage (LV) grids with increasing penetration of renewable energy sources and nonlinear loads. This paper presents a fully data-driven DSSE method using a feed-forward neural network optimized via the Tree-structured Parzen Estimator (TPE) hyperparameter search. Real-world LV networks in Hungary are used to evaluate the approach, integrating pseudomeasurements, power consumption data, and weather variables such as solar radiation, temperature, and wind speed. The proposed method significantly outperforms the classical*

Weighted Least Squares (WLS) estimator, achieving voltage amplitude and angle error reductions between 14% and 73%, depending on the network complexity. GPU-accelerated training yields speed-ups exceeding $20,000\times$ compared to WLS. Furthermore, the study compares the optimized FCNN with LSTM, GRU, and GNN architectures, showing that hyperparameter-tuned FCNNs deliver superior performance in both accuracy and computational efficiency. Results confirm that hyperparameter optimization is essential for scaling DNN-based DSSE to real-world networks and for enabling accurate, fast, and robust state estimation under high uncertainty conditions.

Keywords: distribution system state estimation; deep neural networks; hyperparameter optimization; TPE; low-voltage networks; renewable integration; voltage estimation.

Анотація. Глибокі нейронні мережі (DNN) дедалі частіше застосовуються як альтернатива традиційним модельним методам оцінювання стану розподільних електромереж (DSSE), особливо в низьковольтних мережах з високою часткою відновлюваних джерел енергії та нелінійних навантажень. У цій роботі представлено повністю даноорієнтований підхід до DSSE на основі прямої нейронної мережі (FCNN), оптимізованої за допомогою алгоритму пошуку гіперпараметрів Tree-structured Parzen Estimator (TPE). Метод протестовано на реальних низьковольтних мережах Угорщини з використанням псевдовимірювань, споживчих даних і метеопараметрів (температура, сонячна радіація, швидкість вітру тощо). Запропонований підхід значно перевершує класичний алгоритм WLS, забезпечуючи зниження похибки оцінювання амплітуди та кута напруги на 14–73% залежно від складності мережі. Завдяки GPU-паралелізації досягнуто прискорення навчання понад $20\,000\times$ порівняно з WLS. Також порівняно продуктивність оптимізованої FCNN із LSTM, GRU та GNN, причому FCNN з оптимізованими гіперпараметрами забезпечує найкращу точність та ефективність. Отримані результати підтверджують ключову роль гіперпараметричної оптимізації для масштабування DNN-методів DSSE до реальних LV-мереж та підвищення точності й швидкодії оцінювання стану в умовах високої невизначеності.

Ключові слова: оцінювання стану мереж; глибокі нейронні мережі; оптимізація гіперпараметрів; TPE; низьковольтні мережі; оцінка напруги.

1. Introduction

Within the framework of intelligent electrical grid advancement and expanding proportion of distributed power sources, the significance of low-tension grids has sharply increased. DSSE becomes an essential instrument for guaranteeing dependability and productivity of electrical infrastructure. Conventional techniques, including WLS, require precise grid models and demonstrate limited resilience to incomplete or noisy information. Information-focused approaches, notably DNN, possess capability to represent complex non-linear relationships, rendering them viable for practical implementation. However, effectiveness of such models substantially depends on appropriate parameter configuration.

2. Information and Problem Formulation

Research was conducted on four authentic LV districts in Hungary (18680, 44600, 44333, 20667), containing 2 to 10 circuits. For DSSE, the following were utilized:

- 15-minute consumption records
- Meteorological information (ambient temperature, irradiance, air velocity, precipitation)
- Pseudo-measurements
- Standardization and cyclical encoding of temporal features

Input information included demands, meteorological conditions, and temporal parameters. Output information consisted of potential magnitudes and phases. Training was executed on odd-numbered weeks, validation on even-numbered weeks, allowing assessment of model generalization.

3. Network Architectures

3.1. FCNN (baseline model)

Straightforward and rapid model with ReLU activation, which demonstrated optimal effectiveness following refinement.

3.2. LSTM/GRU

Productive for temporal dependencies, yet more intricate and less resilient with constrained information.

3.3. GNN

Natural selection for representing grid topologies, yet in this investigation underperformed relative to refined FCNN due to elevated complexity and sensitivity to noise.

4. TPE-Focused Refinement

The TPE algorithm, as a Bayesian methodology, constructs probabilistic models of parameters for identifying optimal configurations:

- Batch dimension
- Learning velocity
- Hidden layer arrangement
- Epoch quantity
- Optimizer update increment

TPE demonstrated notably superior convergence compared to random exploration and grid exploration, and permitted consideration of grid magnitude: larger LV districts required greater batch dimensions and deeper models.

5. Findings

5.1. Precision

Relative to WLS, the refined FCNN reduced discrepancies:

- Potential magnitude: 14-73%
- Phase: 18-65%

5.2. Processing Speed

GPU acceleration provided up to 20,000× faster assessment than WLS, confirming the technique's suitability for real-time operation.

5.3. Architectures

Following refinement, FCNN consistently exceeded LSTM, GRU, and GNN, particularly in grids with substantial circuit quantities.

6. Conclusions

This work demonstrates that sophisticated neural architectures can deliver highly precise and exceptionally rapid condition assessment for LV grids provided parameter refinement is performed. The FCNN+TPE technique successfully scales, surpasses traditional DSSE algorithms, and can be incorporated into distribution grid monitoring infrastructure, promoting dependability and adaptability of electrical power systems.

UDC 681.5:004

Echeverria-Rios D., Green P.L. (School of Engineering, The University of Liverpool, UK).

GAUSSIAN PROCESSES FOR PREDICTING PRODUCT QUALITY IN MANUFACTURING.

Abstract. Predicting product quality in continuous manufacturing is a critical requirement for optimizing production processes and ensuring consistent operational performance. This study introduces an AI-driven solution based on a generalized product-of-experts Gaussian Process (GP) enhanced with a Dirichlet Process (DP) noise model. The method integrates process parameters collected along the production line with end-of-line quality measurements, specifically fault density. Five key criteria for effective AI deployment in continuous manufacturing—scalability, modularity, out-of-sample reliability, uncertainty quantification, and robustness to unrepresentative data—are defined and used to evaluate existing approaches. Limitations of standard GP models under non-Gaussian noise are discussed, motivating the development of a more flexible DP-based mixture noise model capable of capturing multiple noise sources. The proposed framework automatically adjusts the number of mixture components and isolates low-noise

observations for GP regression, improving prediction accuracy while preserving analytical tractability. A product-of-experts strategy is introduced to ensure computational scalability. Application to a real manufacturing case study, supported by synthetic experiments, demonstrates superior predictive performance and resilience to outliers compared with standard and robust GP variants. The results confirm the suitability of the DP-augmented GP method for modern continuous manufacturing environments.

Keywords: Gaussian Processes; Dirichlet Process; continuous manufacturing; product quality; noise modeling; product-of-experts; uncertainty quantification.

Анотація. Прогнозування якості продукції у безперервному виробництві є ключовою умовою для оптимізації технологічних процесів та забезпечення стабільних експлуатаційних характеристик. У цьому дослідженні запропоновано AI-орієнтоване рішення, що базується на узагальненому Gaussian Process (GP) із шумовою моделлю на основі процесу Діріхле (DP). Метод поєднує технологічні параметри, зібрані вздовж виробничої лінії, з кінцевими вимірюваннями якості, зокрема густини дефектів. Визначено п'ять ключових критеріїв ефективної AI-інтеграції у безперервне виробництво: масштабованість, модульність, надійність поза межами тренувальних даних, кількісна оцінка невизначеності та стійкість до нерепрезентативних даних. Показано обмеження стандартних GP-моделей в умовах негасіанського шуму, що мотивує використання DP-орієнтованої змішаної шумової моделі, здатної враховувати різні джерела шуму. Запропонований підхід автоматично визначає кількість компонент суміші та виокремлює дані з найменшим рівнем шуму для регресії GP, підвищуючи точність прогнозу при збереженні аналітичної зручності. Для забезпечення масштабованості використано підхід product-of-experts. Результати застосування моделі до реального виробничого кейсу та синтетичних експериментів демонструють її переваги над стандартними та «робастними» GP-варіантами. Отримані висновки підтверджують ефективність DP-підсиленних GP-моделей у сучасних умовах безперервного виробництва.

Ключові слова: Gaussian Process; процес Діріхле; безперервне виробництво; прогнозування якості; моделювання шуму; product-of-experts; оцінка невизначеності.

1. Introduction

Within continuous production systems, process variables are monitored across multiple stages of the production line, while quality indicators—specifically defect concentration—are measured at the process conclusion. Forecasting these indicators enables production optimization and quality enhancement. Given the expansion of data volumes and technological process complexity, conventional forecasting techniques have become inadequate. The authors establish five requirements that AI frameworks must satisfy: computational scalability, system modularity, prediction stability outside training datasets, quantified uncertainty assessment, and resilience to non-representative observations. Standard Gaussian Process (GP) frameworks do not completely fulfill these requirements due to assumptions regarding Gaussian noise characteristics. This motivates development of an alternative framework capable of handling authentic uncontrolled noise phenomena in production environments.

2. Methodology

2.1. Gaussian Process Regression

GP regression constitutes a non-parametric probabilistic technique that yields both predicted values and uncertainty estimates. Unlike parametric approaches, GPs characterize distributions over functions and find applications across numerous domains: from machinery dynamics to robotics. However, the standard assumption of Gaussian noise frequently fails to correspond with authentic production data.

2.2. Noise Modeling with Gaussian Mixture and Dirichlet Process

This work introduces a Gaussian mixture distribution for characterizing data distortions. Each observation associates with one mixture element, where the count of these elements is determined through the Dirichlet Process. This approach enables the framework to automatically adapt to varying noise characteristics, identify high-noise observations, and prevent their influence during the regression phase.

2.3. Product-of-Experts for Computational Scalability

To enable processing of large datasets, the framework partitions the sample into subsets and trains individual GP "experts," whose predictions combine into the final output. This approach ensures linear scalability while preserving accuracy.

3. Results

Simulations utilizing 150 synthetic samples corrupted with three Gaussian components confirmed the superiority of the Dirichlet Process GP (DPGP) framework over standard GP and robust GP alternatives. The RMSE metric was lowest for DPGP. Visual outputs demonstrate correct clustering of noise components and avoidance of excessive fitting to outlier samples. Authentic production data confirmed the framework's reliability: it successfully isolates the representative portion of the sample and ensures stable product quality forecasting.

4. Conclusions

The proposed framework successfully integrates the advantages of GP regression with the adaptability of the DP approach, delivering a comprehensive solution to challenges of computational scalability, noise resilience, uncertainty quantification, and data modularity. Results demonstrate its applicability in modern continuous production environments, where process characteristics may fluctuate and data may contain outliers or irregularities.

REFERENCES.

- [1] Liu H., Cai J., Wang Y., Ong Y.S. *Generalized robust Bayesian committee machine for large-scale Gaussian process regression* // 35th International Conference on Machine Learning (ICML 2018). 2018. Vol. 7. P. 4898–4910.
- [2] Feng Z., Li D., Qin G., Liu S. *Effect of the flow pattern in a float glass furnace on glass quality* // Journal of the American Ceramic Society. 2009. Vol. 92, No. 12. P. 3098–3100.
- [3] Feng Z., Wang J., Ma Y., Tu Y. *Robust parameter design based on Gaussian process with model uncertainty* // International Journal of Production Research. 2021. Vol. 59, No. 9. P. 2772–2788.
- [4] Jin D., Xu S., Tong L., Wu L., Liu S. *A deep learning model for striae identification in end images of float glass* // Traitement du Signal. 2020. Vol. 37, No. 1. P. 85–93.

UDC 621.311.23:519.876

Frison L., Götzhäuser S., Bitterling M., Kramer W. (Fraunhofer Institute for Solar Energy Systems ISE, Freiburg, Germany).

ARTIFICIAL NEURAL NETWORKS FOR OPTIMIZING DISTRICT HEATING NETWORKS.

Abstract. Accurate heat demand forecasting is essential for optimizing district heating networks (DHNs), especially as modern systems integrate fluctuating renewable energy sources, variable weather patterns, and diverse consumer behaviors. This study evaluates several Artificial Neural Network (ANN) architectures—including Long Short-Term Memory (LSTM), Convolutional Neural Networks (CNN), and the Temporal Fusion Transformer (TFT)—and compares them with the statistical SAR-IMAX model. Using a year-long dataset from the Stiftung Liebenau DHN, which incorporates multiple heat sources (CHP, biomass, natural gas) and heterogeneous heat sinks (residential buildings, workshops, greenhouses), the models are tested for their ability to forecast dynamic heat loads and support operational optimization. Results show that CNN achieves the lowest Mean Absolute Percentage Error (MAPE)—27% for both summer and winter, and 17% for winter alone—though all ANN models are affected by data volatility and irregularities, particularly during peak demand events. Despite these challenges, the networks successfully capture general demand

patterns. An economic evaluation demonstrates that ANN-based forecasting can markedly improve energy efficiency and reduce operational costs due to low implementation overhead. The study highlights the potential of ANN-driven forecasting as a scalable, cost-effective solution for next-generation DHNs.

Keywords: heat demand forecasting; district heating networks; artificial neural networks; energy efficiency; CNN; LSTM; temporal fusion transformer; confidence intervals.

Анотація. Точне прогнозування теплового навантаження є критично важливим для оптимізації роботи систем централізованого теплопостачання (DHN), особливо в умовах інтеграції відновлюваних джерел енергії, мінливості погоди та різноманітності поведінки споживачів. У цьому дослідженні оцінюються кілька архітектур штучних нейронних мереж (ANN) — Long Short-Term Memory (LSTM), Convolutional Neural Networks (CNN) та Temporal Fusion Transformer (TFT) — у порівнянні зі статистичною моделлю SAR-IMAX. Для тестування застосовано річний набір даних тепломережі Stiftung Liebenau, яка містить різні джерела тепла (CHP, біомаса, природний газ) і широкий спектр споживачів (житлові будівлі, майстерні, теплиці). Результати показують, що CNN-модель забезпечує найнижчий MAPE — 27% улітку та взимку, і 17% лише взимку, хоча точність усіх моделей залежить від волатильності та нерегулярності даних, особливо під час пікових навантажень. Незважаючи на це, моделі успішно відтворюють загальні тенденції теплового попиту. Економічний аналіз підтверджує, що використання ANN-прогнозування може суттєво підвищити енергоефективність і зменшити операційні витрати завдяки низьким вимогам до впровадження. Дослідження демонструє, що ANN-орієнтоване прогнозування є масштабованим і економічно вигідним рішенням для теплових мереж нового покоління.

Ключові слова: прогнозування теплового навантаження; теплові мережі; штучні нейронні мережі; енергоефективність; CNN; LSTM; Temporal Fusion Transformer.

1. Introduction

Centralized thermal distribution systems are transitioning toward fourth-generation network concepts, which involve utilizing renewable power sources, reduced-temperature operational modes, and enhanced adaptability. Such transformation imposes fresh requirements on thermal load prediction, since contemporary DHNs feature significant consumer diversity and dynamic operational pattern changes. Conventional statistical prediction methods prove insufficiently accurate, whereas deep learning models can simulate complex nonlinear dependencies in temporal sequences. This makes them promising tools for improving thermal network operational efficiency.

2. Case Study: Stiftung Liebenau DHN

The thermal distribution network is characterized by:

- Multiple thermal generators (combined heat and power, biomass, methane)
- Broad spectrum of consumers (dwelling structures, cultivation facilities, manufacturing premises)
- Twelve-month data collection with resolution suitable for modeling temporal dynamics

Statistical and machine learning approaches were utilized for comparing prediction capabilities.

3. Deep Learning Model Architectures

3.1. CNN

Delivers optimal MAPE through effective extraction of localized temporal patterns.

3.2. LSTM

Performs well with extended-term dependencies but represents a computationally demanding architecture.

3.3. Temporal Fusion Transformer (TFT)

Contemporary architecture developed specifically for temporal sequence prediction and ensuring interpretability.

4. Single-Step and Autoregressive Predictions

Two methodologies were investigated:

- Single-step prediction of entire horizon
- Step-by-step autoregressive forecasting

The autoregressive methodology exhibited sensitivity to error accumulation, whereas the single-step approach provided more stable outcomes.

5. Modeling Results

- CNN achieved MAPE = 27% for warm and cold seasons, and 17% exclusively for cold season
- All architectures are susceptible to data volatility
- Maximum loads are predicted least accurately, but overall trend is reproduced correctly
- TFT interpretability makes it valuable for operational analysis

6. Financial Analysis

Substantial power efficiency improvement was established when applying deep learning prediction, specifically:

- Optimization of thermal generator operations
- Reduction of operational expenses
- Rapid payback due to minimal investments

7. Conclusions

Deep learning-oriented architectures can become essential tools for next-generation thermal networks, providing more precise prediction, power efficiency, and economic advantages. Although the architectures have limitations during peak prediction, overall accuracy and minimal deployment requirements make them promising for practical implementation.

UDC 519.245+004.896

Popov A.Yu., Makarenko O.S. (Kyiv Polytechnic Institute named after Ihor Sikorskyi, Kyiv, Ukraine).

EVALUATING HYBRID APPROACH TO MISSING DATA IMPUTATION IN COMPARISON WITH GENERATIVE MODELS.

Abstract. Missing data remain one of the most common challenges in data analysis and machine-learning applications, with their occurrence resulting from human errors, sensor failures, or research-specific limitations. Improper handling of missing values reduces the quality of datasets and negatively affects the performance of predictive models. This study proposes and evaluates a hybrid imputation approach that combines generative and statistical methods—namely, a Variational Autoencoder (VAE) used as a feature extractor and the Multiple Imputation by Chained Equations (MICE) algorithm. The hybrid method is compared with classical statistical techniques (multiple imputation and Gaussian mixture model) and three generative approaches. Artificial missingness (MCAR, MAR, MNAR) with 10%, 30% and 50% missingness rates was applied to an air-quality dataset. Results show that the hybrid approach offers stable performance across all mechanisms, outperforming all methods under the 50% MCAR condition and achieving accuracy comparable to classical benchmarks in most scenarios. Generative approaches demonstrated lower stability, with VAE showing the most significant variance. The findings highlight the potential of hybrid models for robust imputation tasks, especially when balancing generative flexibility with statistical reliability.

Keywords: missing data, imputation methods, machine learning, generative models, hybrid imputation.

Анотація. Пропущені дані є однією з найпоширеніших проблем у задачах аналізу даних та машинного навчання, причини якої можуть охоплювати людські помилки, технічні збої або особливості проведення дослідження. Некоректна обробка пропусків призводить до погіршення якості даних і зниження точності моделей прогнозування. У роботі запропоновано гібридний підхід до заповнення пропущених значень, що поєднує генеративні та статистичні методи: варіаційний автоенкодер (VAE), використаний як генератор латентних ознак, та алгоритм множинної імпутації MICE. Метод порівнюється з класичними статистичними підходами (множинна імпутація та гаусівська суміш) і трьома генеративними алгоритмами. На датасеті параметрів якості повітря штучно згенеровано пропуски (MCAR, MAR, MNAR) з інтенсивністю 10%, 30% та 50%. Результати демонструють, що гібридний підхід забезпечує стабільну якість заповнення в усіх механізмах пропусків, перевершуючи інші методи у сценарії MCAR 50% та показуючи точність, співставну з класичними методами в більшості випадків. Генеративні моделі виявили нижчу стабільність, зокрема базовий VAE. Отримані результати підтверджують перспективність гібридних підходів у задачах імпутації даних.

Ключові слова: пропущені дані, методи заповнення, машинне навчання, генеративні моделі, гібридна імпутація.

Problem Statement

Processing missing data is a well-known problem in data analysis and machine learning because it is common, exists in any scientific field, and is particularly relevant in machine learning since many models initially expect complete data for training. The main task of missing data imputation methods is to solve these problems by filling in the gaps with plausible values. There is a wide variety of imputation methods, including simple ones such as mean or median imputation and traditional statistical ones such as multiple imputation or the EM algorithm. Modern research on this topic often considers generative methods, i.e., methods based on generative artificial intelligence algorithms and models. Examples of such approaches include the use of variational autoencoders, adversarial models, and transformer models.

The task of missing data imputation is defined as follows: let there be a dataset D , which is a matrix of observations, and variables are given as columns. The goal is to find a function $F(x)$ that will fill in the missing data using the available observed data.

To formalize different kinds of missing data, the concept of a missing data mechanism is used. It is a description of the relationship between missing and available data. According to the most common classification, there are three types of mechanisms [1]:

- Missing at random (MAR) - an assumption that the probability of missing data for variable Y depends on the values of other characteristics, but does not depend on the value of Y itself;
- Missing completely at random (MCAR) - an assumption that the probability of missing data for variable Y does not depend on the values of other characteristics and does not depend on the value of Y itself;
- Missing not at random (MNAR) - an assumption that the probability of missing data for variable Y depends on the values of other characteristics, as well as on the values of Y itself;

Imputation methods typically require one of these assumptions to be true in order to work.

Analysis of Recent Publications

Generative Adversarial Networks (GANs) have been successfully adapted to address the challenge of missing data processing. The core concept involves training a generator to impute missing values while a discriminator learns to distinguish between artificially generated imputations

and actual observations. GAIN framework proposed by Yoon, Jordon, and van der Schaar (2018) [2] is an important contribution in this direction. The authors introduced a "hint" mechanism where the discriminator receives partial information about the missingness mask. This focuses the discriminator on specific data regions and guides the generator to reproduce the underlying data distribution rather than exploit trivial signals about which values were missing. Experimental results demonstrate that GAIN outperforms effective classical imputation methods; however, its training process is complicated due to the necessity of maintaining balance between the generator and discriminator. Furthermore, the baseline GAIN architecture does not support multiple imputation and has not been extensively validated under missingness mechanisms other than MCAR.

Subsequent research has proposed various modifications to address the limitations of the GAIN architecture. Notably, the MisGAN model (Li et al., 2019) [3] utilizes an approach with two generators where one is used for complete data, while the other for missingness masks which enables the model to effectively handle complex missingness mechanisms, including MNAR. Another modification, MI-GAN (Dai et al., 2021), integrates GAN principles with the concept of multiple imputation, where a conditional generator produces several plausible values for each missing entry. This facilitates more accurate statistical inferences [4]. While MI-GAN yielded results comparable to existing algorithms under MAR conditions, it demonstrated superior performance in statistical analysis and computational efficiency.

Variational Autoencoders (VAEs) and related latent variable models offer an alternative probabilistic imputation strategy by modeling the complete data distribution and deriving posterior distributions for missing values. Since VAE components are trained to maximize likelihood, these models naturally provide distributions of potential imputations rather than single point estimates. The general approach involves training the model on complete or near-complete data (with appropriate modifications), followed by sampling missing values from the conditional distribution using observed features during imputation. A prominent example is MIWAE (Mattei & Frellsen, ICML 2019) [5], which demonstrates the capacity of VAE-based frameworks to not only outperform simple methods but also compete with GAN-based approaches, particularly when quantifying probabilistic uncertainty is required.

In *Handling Incomplete Heterogeneous Data using VAEs*, Nazabal et al. (2020) proposed the Heterogeneous-Incomplete VAE (HI-VAE), which employs distinct probabilistic models for different feature types (Gaussian for continuous, categorical for discrete) and explicitly accounts for the missingness mechanism [6]. Results indicate that HI-VAE provides accurate imputation for mixed data types and remains effective even in MNAR scenarios by treating missingness as a part of the generative model.

Leveraging variational autoencoders for multiple data imputation (Roskams-Hieter et al., 2022) highlights a significant limitation of VAEs: in multiple imputation tasks, standard VAEs often underestimate uncertainty, yielding overly "confident" imputations [7]. This is particularly evident with extreme values and broad distributions, where the model tends to converge around the mean. To address this, β -VAE was proposed, where a hyperparameter β , selected via cross-validation, intensifies the regularization of deviation from the prior distribution. This modification broadens the distributions, allowing for a better exploration of plausible imputation variability. It also prevents false discoveries in subsequent analysis that might appear if imputed values are treated as ground truth. The study emphasizes that while deep generative models theoretically model uncertainty, in practice they require careful tuning.

Transformer models have also become a promising tool for tabular data imputation. Their advantage lies in the ability to model complex dependencies between features through attention mechanisms and to handle various missingness types by treating missingness indicators as additional

features. The ReMasker model (Du et al., 2023) extends the BERT masking approach: during training, both natural missing values and artificially masked values are treated as special tokens, and the transformer learns to recover the corresponding original data [8]. Once the model learns to predict these masked elements, it effectively handles real missing values [9]. Empirical evidence suggests that ReMasker can match or exceed the accuracy of state-of-the-art methods, with imputation quality reportedly improving as the proportion of missing values increases [8, 9]. This is attributed to multi-head self-attention, which forms missingness-invariant representations and captures complicated feature correlations.

A distinct direction of research focuses on modifying transformer architectures specifically for tabular data. An example is the Not Another Imputation Method (NAIM), a transformer designed to train directly on incomplete data without prior imputation [10]. NAIM employs two key mechanisms: feature embeddings that encode both numerical and categorical values (including explicit representations of missingness) and a modified self-attention algorithm that completely masks contributions from missing values. Consequently, the model becomes "aware" of the missingness structure, preventing missing values from influencing other features through attention weights. Additionally, NAIM utilizes a novel regularization scheme to improve generalization on incomplete training sets [9].

In summary, the literature review demonstrates the significant potential of generative methods for missing data imputation. However, each approach possesses inherent limitations, and the selection of an appropriate method must consider practical factors, including the missingness mechanism, tuning complexity, and computational costs.

Unsolved Parts of the Problem

While a lot of generative imputation models have been thoroughly explored the concept of hybrid methods is significantly more rarely addressed. The core idea of hybrid models is to combine strong sides of both statistical and generative approaches in order to resolve common issues of both categories. Theoretically, hybrid approaches hold potential to mitigate the training instability and mode collapse that are often observed in pure deep learning approaches which would make them easier to train and improve their imputation performance. For the traditional approaches the potential of hybrid modifications lies in resolving their assumptions and limitations such as the assumption of Gaussian data for GMM or the “curse of dimensionality” where the model performance degrades as the number of features increases relatively to the number of observations.

Purpose and objectives of the Study

The goal of this work is to propose and evaluate the performance of a hybrid method relatively to straightforward generative imputation approaches and classical approaches in the context of preprocessing data in a forecasting task. The selected dataset is a numerical dataset of air quality parameters (Beijing PRSA), containing 35,952 observations and covering the period from January 1, 2010, to December 31, 2014. Artificial missingness was introduced in the two continuous variables at 10%, 30% and 50% missingness rates for every mechanism which yielded a grid of 3x3 datasets.

Presentation of the Main Research Material

The proposed hybrid imputation approach is built around the idea to combine VAE model with MICE. The implementation consists of two steps: VAE is trained in order to extract latent features that are used as augmentation for existing dataset before MICE imputation is applied.




Fig. 1. Flowchart of hybrid approach

In the first phase the initial step addresses the VAE requirement to have a complete input matrix. For this a simple mean imputation is used on the dataset X to create a “warm-start” dataset X_{ws} . This matrix is used as the training dataset for VAE. The model is optimized using the Adam algorithm by minimizing a composite objective function comprising a reconstruction loss and a regularization term. Specifically, Mean Squared Error (MSE) quantifies the reconstruction fidelity, while the Kullback-Leibler (KL) divergence penalizes deviations between the encoder’s learned distribution and a standard normal prior. Following the training phase, the encoder operates deterministically. The pre-imputed matrix X_{ws} is mapped through the encoder to extract the latent mean vectors μ , which are aggregated to construct the latent feature matrix L .

In the second phase, the original incomplete dataset, X , is augmented via the concatenation of the VAE-generated latent features L . This creates an augmented matrix X_{aug} . It is important that the latent features are fully observed and thus provide a holistic representation of the underlying data manifold. MICE is then applied to this augmented matrix. MICE models each variable with missing entries as a dependent variable that is conditioned on the remaining original and latent features. In this implementation a Random Forest Regressor was used as the predictive estimator. The algorithm iteratively cycles through columns until a convergence criterion is reached. As the final step the latent features are discarded and the result is the imputed dataset $X_{imputed}$.

The hybrid method, 2 traditional methods and 3 generative approaches were used on each dataset with artificial missingness to create imputed datasets which were the training sets for 4 predictive models: linear regression, XGBoost, Random Forest and LightGBM. The figures below present the value of RMSE for the 4 predictive models trained on the imputed dataset of each type.




Fig 2. RMSE by imputation method and model for MAR and MCAR datasets

For MAR scenario VAE-MICE showed comparable performance to classical methods, however MICE was still the top performing method followed by GMM and VAE-MICE. At the same time, all three generative models lagged behind considerably. For MCAR the performance of methods was generally comparable at 10% and 30% missingness with more noticeable differences at 50% where the best-performing model was achieved with VAE-MICE method that outperformed both classical methods.




Fig 3. RMSE by imputation method and model for MNAR datasets

In MNAR scenario MICE was again the top performer achieving the best LightGBM model. Among generative methods VAE model displayed a notable instability having a significant performance drop on 50% missingness. Oppositely, VAE-MICE was proven to be more effective by being able to avoid this performance collapse and yielding a LightGBM model that is comparable with GMM and GAIN results.

Furthermore, two trends were consistently observed across all missingness mechanisms:

- **Positive correlation with missingness rates:** Predictive performance demonstrated a monotonic improvement as the proportion of missing data increased. This diverges from the conventional wisdom that higher rates of missingness inherently complicate the imputation task. A possible explanation is that imputation, regardless of the specific algorithm, adds a smoothing or regularizing effect which simplifies the feature space for predictive models.
- **Positive correlation with mechanism difficulty:** The highest predictive accuracy was achieved using data imputed under the MNAR condition, followed by MAR, with MCAR yielding the comparatively lowest (albeit still robust) performance. This challenges the common assumption that MCAR is the "easiest" condition to handle. However, it is possible that this trend would not be observed in a different MNAR implementation.

CONCLUSIONS.

In this study we investigated the performance of several generative approaches to missing data imputation problem in comparison with classical methods and proposed a hybrid approach. The methods were evaluated on a pollution prediction task.

In the evaluation across all missingness mechanisms, classical methods consistently exhibited strong and reliable performance with MICE being the most powerful method. While the studied generative models generally yielded suboptimal performance, the proposed hybrid approach demonstrated a notable improvement, bridging the gap between two categories.

The hybrid model achieved predictive accuracy comparable to classical benchmarks in the majority of experimental scenarios and outperformed all competing methods under the 50% MCAR condition. The difference in VAE performance between the basic version and its use as part of a hybrid method suggests that VAE's primary strength in imputation tasks may lie in its capability as a

feature extractor rather than as a standalone imputer. Overall, these findings underscore the significant potential of hybrid approaches in missing data imputation research.

REFERENCES.

1. Donald B. Rubin. *Inference and Missing Data: Biometrika* Vol. 63, No. 3. 1976. P. 581-592.
2. Yoon, J., Jordon, J., & van der Schaar, M. (2018). *GAIN: Missing Data Imputation using Generative Adversarial Nets*. arXiv:1806.02920. (PDF & supplementary material contain full proofs and algorithms).
3. Li, S., Jiang, B., & Marlin, B. (2019). *MisGAN: Learning from Incomplete Data with Generative Adversarial Networks*. ICLR.
4. Dai Z., Bu Z., Long Q. Multiple Imputation via Generative Adversarial Network for High-dimensional Blockwise Missing Value Problems. *Proc Int Conf Mach Learn Appl*. 2021 Dec;2021:791-798. doi: 10.1109/icmla52953.2021.00131. PMID: 35169788; PMCID: PMC8841955. <https://pmc.ncbi.nlm.nih.gov/articles/PMC8841955/>
5. Mattei P., Frellsen J. MIWAE: Deep Generative Modelling and Imputation of Incomplete Data Sets. *Proceedings of the 36th International Conference on Machine Learning*. 2019. P. 4413-4423 <https://proceedings.mlr.press/v97/mattei19a.html?ref=https://githubhelp.com>
6. Nazabal A. Olmos P. M., Ghahramani Z. Valera I. Handling Incomplete Heterogeneous Data using VAEs. 2020. *Pattern Recognition*, Vol. 107. <https://doi.org/10.1016/j.patcog.2020.107501>.
7. Roskams-Hieter, B. Wells, J., Wade, S. Leveraging variational autoencoders for multiple data imputation. 2023. *Machine Learning and Knowledge Discovery in Databases: Research Track. ECML PKDD 2023. Lecture Notes in Computer Science()*, vol 14169. Springer, Cham. https://doi.org/10.1007/978-3-031-43412-9_29
8. Du T., Melis L., Wang T. ReMasker: Imputing Tabular Data with Masked Autoencoding. 2023. <https://api.semanticscholar.org/CorpusID:262465392>
9. Cafieri S. Borrata G. Advanced artificial intelligence techniques to improve survey data quality: A focus on transformers and generative adversarial networks (GANs). 2025. *Generative AI and Official Statistics Workshop*. https://unece.org/sites/default/files/2025-05/GenAI2025_S2_Italy_Cafieri_D.pdf
10. Caruso, Camillo & Soda, Paolo & Guarrasi, Valerio. (2024). Not Another Imputation Method: A Transformer-based Model for Missing Values in Tabular Datasets. 10.48550/arXiv.2407.11540. https://www.researchgate.net/publication/382301965_Not_Another_Imputation_Method_A_Transformer-based_Model_for_Missing_Values_in_Tabular_Datasets

UDC 621.316.7:004.9:681.3

Rossi F., Bernardeschi C., Cococcioni M. (University of Pisa, Pisa, Italy).

NEURAL NETWORK VERIFICATION IN CLOSED-LOOP SYSTEMS USING INTERVAL ARITHMETIC.

Abstract. Machine learning methods are increasingly used to develop high-performance controllers for cyber-physical systems (CPS), yet their deployment in safety-critical environments raises concerns regarding trustworthiness and verifiability. This work presents a hybrid approach that combines interval arithmetic with theorem-proving techniques to verify neural network-based controllers embedded in closed-loop systems. Interval arithmetic is used to compute guaranteed bounds on neural network outputs for bounded input ranges, while formal verification in higher-order logic provides provable guarantees on system-level safety properties. The approach is applied to an autonomous-driving use case in which a model-predictive controller (MPC) for adaptive cruise control is replaced by a neural network surrogate trained on MPC-generated data. Automatic generation of PVS theories from PyTorch models is introduced, enabling scalable

and systematic formalization of neural networks with moderate size. Experimental results show that open-loop interval-based verification achieves faster verification times than existing SMT- and abstraction-based tools, while maintaining soundness. The combined method successfully formalizes and verifies safety constraints in the closed-loop setting, demonstrating the feasibility of rigorous verification for neural network controllers in practical CPS applications.

Keywords: neural network verification; interval arithmetic; cyber-physical systems; theorem proving; adaptive cruise control; formal methods; safety-critical systems.

Анотація. Методи машинного навчання дедалі частіше використовуються для створення високопродуктивних контролерів у кіберфізичних системах (CPS), проте їх інтеграція у критично важливі застосування супроводжується питаннями довіри та формальної верифікації. У роботі запропоновано гібридний підхід, що поєднує інтервальну арифметику та методи доведення теорем для перевірки нейромережних контролерів, вбудованих у контури зворотного зв'язку. Інтервальна арифметика використовується для обчислення гарантованих меж вихідних значень нейронної мережі при обмежених діапазонах вхідних сигналів, тоді як формальна верифікація у логіці вищих порядків забезпечує доведення системних властивостей безпеки. Підхід застосовано до кейсу автономного керування, де модельно-предиктивний контролер (MPC) адаптивного круїз-контролю замінено нейронною мережею, навченою на виходах MPC. Представлено інструмент автоматичної генерації теорій PVS на основі моделей PyTorch, що робить можливим масштабоване формальне описання нейромереж середнього розміру. Результати показують, що інтервально-орієнтована верифікація у відкритому контурі працює швидше, ніж сучасні SMT- і абстракційні методи, зберігаючи строгість. Комбінований підхід успішно формалізує та перевіряє вимоги безпеки у замкненому контурі, демонструючи можливість застосування формальних методів для нейромережних контролерів у реальних CPS.

Ключові слова: верифікація нейронних мереж; інтервальна арифметика; кіберфізичні системи; доведення теорем; адаптивний круїз-контроль; формальні методи; безпека.

1. Introduction

Artificial neural networks are progressively utilized as regulation elements in CPS, particularly within autonomous navigation, industrial process control, and healthcare applications. Although such architectures deliver superior efficiency and capability to approximate complex behavioral patterns, the challenge of their dependability under critical operational conditions remains unresolved. Direct training approaches do not ensure adherence to protection constraints, and conventional validation techniques frequently fail to scale for production-grade networks. Within this framework, a combined approach is proposed that integrates range-based mathematics for computing output boundaries of neural networks and formal validation for examining feedback-loop behavior.

2. Survey of Contemporary Approaches

Primary directions in neural network validation encompass:

- SMT-driven instruments capable of handling ReLU-based architectures
- Hybrid automaton frameworks for more complex activation functions (sigmoid, tanh)
- Simulation-oriented techniques such as Monte-Carlo sampling
- Sensitivity examination and regional validation procedures

Despite these advances, existing solutions encounter difficulties with scalability and absence of rigorous assurances. Consequently, combining diverse formal approaches represents a promising direction.

3. Formal Architecture and Range-Based Mathematics

This research employs PVS for representing neural networks within higher-order reasoning frameworks. Feed-forward architectures are characterized as sequences of matrix operations with schematically specified activations. Range-based input representations enable derivation of assured output boundaries for individual layers. Range computations are executed through a specialized IntervalTensor class, incorporated into PyTorch without modifying the original framework.

4. Automated Formalization Construction

The proposed Python instrument automatically converts networks from PyTorch into corresponding PVS formalizations. This enables:

- Elimination of manual specification for large-scale architectures
- Reduction of formalization errors
- Validation capability for networks containing approximately 60-70 processing units

To minimize over-approximation, linear activations are recommended, though the technique functions with nonlinear variants as well.

5. Application to Intelligent Speed Regulation

A scenario is examined where MPC is substituted with an artificial neural network accepting three parameters: relative velocity, separation distance, and ego-vehicle speed, producing acceleration commands. The network was trained using MSE-based optimization, achieving MSE=0.034.

Through range-based mathematics, it was confirmed that network outputs consistently remain within protection boundaries for all permissible inputs, including scenarios involving hazardous proximity to leading vehicles.

6. Findings

- Range-oriented validation executes faster than SMT-based techniques (reduced computational overhead)
- Integration of range-based methods and formal proofs delivers rigorous assurances for feedback-control configurations
- Automated formalization construction enables examination of production systems rather than merely simplified examples

7. Conclusions

The proposed methodology demonstrates effectiveness in combining range-based mathematics and formal validation when examining artificial neural networks in feedback-control architectures. The technique is scalable, integrated with PyTorch, and suitable for validating production-grade CPS regulators. Future developments include optimization of range-based computations, GPU acceleration, and modeling of more sophisticated vehicular dynamics.

UDC 004.8:519.876:681.3

Sandnes A.T., Grimstad B., Kolbjørnsen O. (Norwegian University of Science and Technology, Trondheim, Norway).

MULTI-TASK LEARNING WITH LEARNED CONTEXTUAL INPUTS.

Abstract. *This paper investigates a multi-task learning architecture based on learned contextual inputs, where a fully shared neural network is augmented with low-dimensional, trainable task-specific parameter vectors. These vectors act as contextual inputs to the network, enabling efficient task adaptation without modifying shared weights. The study presents theoretical results showing that even a single scalar task parameter allows universal approximation across all tasks—providing an expressiveness advantage over conventional architectures. Empirical evaluations across ten datasets demonstrate that the dimensionality of task parameters correlates with task complexity, yet compact low-dimensional task spaces are practical for most applications. Learned contexts yield stable and well-structured task parameter spaces, supporting workflows such as updating models with new data, integrating unseen tasks, and adapting to time-varying conditions while keeping shared parameters fixed. Experiments comparing learned-context networks with context-sensitive and last-layer networks show competitive performance, especially on limited datasets where learned-context models exhibit superior robustness. The architecture is particularly suitable for engineering*

systems with multiple structurally similar tasks and sparse data, enabling efficient model maintenance, reduced retraining requirements, and resilient task adaptation.

Keywords: learned-context neural networks; multi-task learning; universal approximation; task-specific parameters; model updating; data efficiency; contextual inputs.

Анотація. У статті досліджено архітектуру мультизадачного навчання, що базується на контекстуальних входних параметрах, які навчаються. Вона поєднує повністю спільну нейронну мережу з низьковимірними векторами параметрів задачі, які виконують роль додаткових контекстуальних входів і дозволяють ефективно адаптуватися до конкретних задач без зміни спільних ваг. Теоретично показано, що навіть один скалярний параметр задачі забезпечує універсальну апроксимацію для всього набору задач — перевага, якої традиційні архітектури не гарантують. Експериментальні результати на десяти наборах даних підтверджують, що розмірність параметрів задачі корелює зі складністю задач, проте низьковимірний простір параметрів зазвичай є достатнім. Отримані контексти формують структурований простір параметрів, що робить можливими такі операції, як оновлення моделей за надходженням нових даних, інтеграція невідомих раніше задач та адаптація до часових змін без повторного навчання спільної мережі. Порівняння з контекстно-чутливими та last-layer-мережами засвідчило конкурентну продуктивність підходу, особливо за обмежених даних, де learned-context мережі виявляють підвищену стійкість. Архітектура є придатною для інженерних систем із множиною схожих задач і браком даних, забезпечуючи економію ресурсів і гнучке пристосування.

Ключові слова: контекстуальні параметри; мультизадачне навчання; універсальна апроксимація; параметри задачі; оновлення моделей; ефективність за даними.

1. Introduction

Addressing multi-objective training challenges in industrial and technical deployments frequently encounters constraints from scarce data per objective and continuous model updating requirements. Examples encompass turbines in wind farms, biomass operations, aquaculture systems, and similar environments with structurally comparable yet data-constrained objectives. Conventional approaches either demand separate models or encounter adaptability challenges. Acquired-context architectures offer a balance between flexibility and stability by incorporating compact task parameters into shared architectures.

2. Architecture of Acquired-Context Neural Networks

2.1. Overall Structure

The framework comprises:

- A shared fully-connected neural architecture
- A collection of task parameters supplied as supplementary inputs

These parameters undergo training alongside shared weights using available data; however, during deployment, objective modification requires updating only task parameters rather than the complete architecture.

2.2. Context as Latent Task Representation

Task parameters establish a latent representation reflecting continuous task characteristics rather than simple identification. This enables:

- Transferring shared models to novel objectives
- Avoiding complete architecture retraining
- Maintaining structure and stability

3. Theoretical Characteristics

3.1. Universal Function Approximation

It has been proven that scaled training with a scalar task parameter already generates sufficient expressiveness for approximating multiple objectives. This contrasts with numerous classical frameworks requiring substantially greater resources or separate models for comparable universality.

3.2. Task Parameter Initialization

Scalar parameters are recommended for zero initialization, which:

- Prevents task-encoding local minima
- Promotes clustering of analogous objectives
- Ensures uniform parameter space behavior

4. Experimental Investigations

4.1. Comparison with Alternative Architectures

The architecture was evaluated on ten benchmarks—synthetic and real-world (educational records, medical indicators, etc.). Comparisons included:

- Context-aware networks
- Final-layer frameworks

Acquired-context architectures demonstrated competitive or superior accuracy.

4.2. Constrained Data Scenarios

Even with substantial data reduction (to 10% of complete samples), acquired-context architectures degraded considerably slower. This makes the framework effective for objectives with limited measurements.

4.3. Selection of Task Parameter Dimensionality

Increasing dimensionality generally improves accuracy, though benefits diminish beyond certain thresholds. Balancing dimensionality is recommended based on:

- Objective complexity
- Generalization requirements
- Available data quantity

5. Operational Considerations

The acquired-context framework facilitates deployment through:

- Model refreshing upon receiving novel data
- Incorporating new objectives without reconstructing shared weights
- Effective training with partially accessible models (e.g., when shared parameters are unavailable for modification)

6. Conclusions

The acquired-context neural network framework represents a promising solution for multi-objective systems operating with analogous objectives and constrained data. It provides:

- Universal function approximation
- Resistance to data reduction
- Structured task parameter representations
- Minimal computational overhead
- Flexible and scalable model updating

REFERENCES.

- [1] Lester B., Al-Rfou R., Constant N. *The power of scale for parameter-efficient prompt tuning* // *Proc. EMNLP*. 2021. P. 3045–3059.
- [2] Liu P., Yuan W., Fu J., Jiang Z., Hayashi H., Neubig G. *Pre-train, prompt, and predict: A systematic survey of prompting methods in natural language processing* // *ACM Computing Surveys*. 2023. Vol. 55, No. 9.

Sobolewski Ł. (University of Zielona Góra, Zielona Góra, Poland).

QUALITY EVALUATION OF POLISH TIMESCALE FORECASTING USING GMDH NEURAL NETWORK.

Abstract. This paper evaluates the effectiveness of a forecasting system for the Polish national timescale UTC(PL), based on a Group Method of Data Handling (GMDH) neural network and implemented on a VCH-1003M hydrogen maser. Two dedicated time series, TS1 and TS2, were constructed to support accurate forecasting, incorporating phase time differences between UTC(k) and the reference clock, as well as UTC–UTC(k) and UTCr–UTC(k) data derived from BIPM Circular-T. Hermite interpolation was applied to extend these datasets to daily resolution. Forecasting results for both TS1 and TS2 show excellent agreement with official BIPM values, with discrepancies frequently remaining within ± 10 ns and in some periods below ± 6 ns. Cases 5 and 6 demonstrate the highest forecast quality, confirming the suitability of GMDH for real-time UTC(PL) steering. The findings show that UTC(PL) maintains an accuracy level comparable to leading global timescales, including those supported by hydrogen masers and caesium fountains. The study also highlights the importance of input data preparation and the self-organizing capabilities of GMDH networks. The approach is particularly beneficial for National Metrology Institutes lacking caesium fountain technology, offering a cost-efficient and high-accuracy alternative.

Keywords: UTC(PL); GMDH neural network; hydrogen maser; timescale forecasting; time series; UTC(k); BIPM; metrology.

Анотація. У статті оцінюється ефективність системи прогнозування для польської національної шкали часу UTC(PL), що базується на нейронній мережі типу GMDH і реалізується на водневому мазері VCH-1003M. Для точного прогнозування сформовано два спеціальні часові ряди — TS1 та TS2 — які містять фазові різниці між сигналами UTC(k) та опорного атомного годинника, а також дані UTC–UTC(k) і UTCr–UTC(k), отримані з бюлетеня Circular-T BIPM. Для отримання щоденних значень застосовано інтерполяцію Ерміта. Результати прогнозування для обох часових рядів демонструють відмінну відповідність офіційним даним BIPM, причому похибки часто не перевищують ± 10 нс, а подекуди — ± 6 нс. Найкращу якість прогнозів підтверджено для випадків 5 та 6, що засвідчує придатність GMDH до реального регулювання UTC(PL). Дослідження показує, що UTC(PL) досягає рівня точності провідних світових шкал часу, включно з тими, що використовують водневі мазери та цезієві фонтани. Окремо підкреслено важливість якісної підготовки вхідних даних і самоорганізувальних властивостей мереж GMDH. Підхід є особливо корисним для національних метрологічних інститутів, які не мають цезієвих фонтанів, пропонуючи високоточне та економічно ефективне рішення.

Ключові слова: UTC(PL); нейронна мережа GMDH; водневий мазер; прогнозування шкал часу; часові ряди; UTC(k); BIPM; метрологія.

Introduction.

The article discusses the effectiveness of a forecasting system for the Polish Timescale (UTC(PL)), using the Group Method of Data Handling (GMDH) neural network and hydrogen maser (HM) technology. The research aims to show that applying this forecasting system to UTC(PL) can achieve timescale quality comparable to the best timescales worldwide. Forecasting results are presented for two time series, TS1 and TS2, and compared to UTC - UTC(k) values. The results demonstrate excellent forecasting quality, with cases 5 and 6 achieving very good results, as confirmed by forecast quality measures. The research concludes that the developed system ensures UTC(PL) accuracy on par with the top global timescales, supporting its adoption by National Metrology Institutes (NMIs) lacking caesium fountains.

The research presented in the article focuses on the effectiveness of a forecasting system for the Polish Timescale (UTC(PL)), which is based on a GMDH (Group Method of Data Handling) neural network. This system, designed for the Polish national timescale, is implemented with a hydrogen maser (HM). The primary goal of the study is to demonstrate that the use of this forecasting system can ensure that the quality of the Polish Timescale is comparable to that of the best global timescales.

The forecasting system operates on two specially prepared time series, TS1 and TS2. These series, along with the forecasted values for the Polish Timescale, are compared with the UTC - UTC(k) values for this scale. The analysis confirms the high quality of the forecasts, particularly for cases 5 and 6, where the system showed a high degree of accuracy. This is evident from the forecast quality metrics and the minimal discrepancies observed between the predicted and actual values. These findings suggest that the developed forecasting system allows for the accurate control and correction of the UTC(PL) national timescale, placing it among the best-performing timescales globally.

The research is particularly significant for National Metrology Institutes (NMIs) that lack caesium fountains, as it shows that adopting the UTC(k) steering system based on this neural network approach could allow them to achieve similar high-quality results at a lower cost.

Factors Influencing Forecasting Quality.

The second key factor influencing the forecasting quality is the quality of the prepared input data. This aspect is heavily impacted by the method of data preparation as well as the quality of the clock that realizes the UTC(k) timescale and its corresponding steering system. The author conducted extensive research focused on improving the data preparation process, exploring various methods to enhance the forecasting quality. These studies were presented in several works [1-12], and the findings indicate that further improvements in data handling can lead to even better results.

In the specific context of UTC(PL) forecasting, the method proposed by the author for generating UTC(k) scale forecasts using a GMDH neural network has been successfully applied. This approach uses data from hydrogen masers and commercial caesium atomic clocks to implement the UTC(PL) timescale, aiming to achieve forecast accuracy comparable to the highest-performing timescales. Notably, the forecasting system has been successfully integrated into the Polish Timescale UTC(PL), confirming its potential for widespread application in national metrology institutes (NMIs). This approach allows for continuous improvement and refinement of the timescale forecasting process, making it more efficient and reliable in real-time operations.

Implementation and Testing.

The research conducted on the Polish Timescale (UTC(PL)) forecasting using the GMDH neural network (NN) has led to the development of a forecasting system for UTC(k) timescales, as described in the works of Sobolewski and others (2017). This system has been tested using the Polish Timescale, which is based on a VCH-1003M hydrogen maser, selected for its precision and stability among several available clocks at the GUM (Central Office of Measures). The goal of this work is to demonstrate that the forecasting system enables the UTC(PL) timescale to achieve a level of accuracy comparable to some of the best timescales, such as those implemented with hydrogen masers supplemented by caesium fountains.

The research focuses on two prepared time series, TS1 and TS2, for use with the GMDH NN, and compares the forecasted values against the BIPM-designated UTC values ($x_b(t)$). The forecasting results for both time series showed a high level of accuracy, with discrepancies consistently within ± 10 ns, and for some periods, even below ± 6 ns. This indicates that the Polish Timescale is very close in quality to the best global timescales.

The article also elaborates on the two main factors that influence forecasting quality: the choice of neural network and the quality of the input data. A key component of the GMDH NN's success is its self-organizing nature, which allows it to adapt efficiently to new data and produce reliable forecasts in real-time, as seen in the ongoing UTC(PL) steering process. This method has been successfully applied in Poland, allowing for continuous updates to the national timescale, positioning it among the highest-performing timescales globally.

Comparison with Different Clock Technologies.

When developing the forecasting algorithm for UTC(k) using a GMDH neural network, the Polish Timescale was implemented with a commercial caesium atomic clock, achieving a stability of approximately 10^{-14} . The author highlighted that leading NMI laboratories typically use hydrogen masers, often supplemented by caesium fountains, to implement UTC(k). Hydrogen masers offer superior short-term stability at the 10^{-15} level compared to caesium clocks, which are better for long-term stability.

The research showed that the GMDH-based forecasting system is versatile, achieving high-quality predictions for both caesium and hydrogen maser-based timescales. This system has been integrated into the Polish Timescale UTC(PL), which has demonstrated exceptional accuracy, particularly since its application in 2016 at the GUM (Central Office of Measures) to control UTC(PL). The improvements were substantial, contributing to a timescale that is now ranked among the best globally.

Research Objectives and Methodology.

The article aims to assess the effectiveness of the forecasting system applied to the Polish Timescale (UTC(PL)), based on a method proposed by the author using a GMDH neural network. This system is implemented on the VCH-1003M hydrogen maser, selected from several available clocks at the GUM (Central Office of Measures) in Poland. The research demonstrates that the developed forecasting system can achieve a level of precision for UTC(PL) comparable to the best global timescales, including those based on hydrogen masers and caesium fountains. The article emphasizes that the use of this system ensures high-quality timescale accuracy for UTC(PL), positioning it as one of the top-performing timescales worldwide.

Time Series Construction.

The article describes the construction of the TS1 and TS2 time series, which are essential for the forecasting system based on the Group Method of Data Handling (GMDH) neural network. These time series were developed to improve the accuracy of UTC(PL) forecasting. The time series include phase time values ($x_a(t)$) between the national time scale UTC(k) and the atomic clock, UTC - UTC(k) values ($x_b(t)$), and additional values ($x_{br}(t)$) representing the UTCr - UTC(k).

The research conducted from December 2020 to August 2023 focused on forecasting the Polish Timescale (UTC(PL)), which is based on the VCH-1003M hydrogen maser. The forecasting used the prepared TS1 and TS2 time series and compared the predicted results with actual data published by BIPM.

The study demonstrated that both time series provided highly accurate forecasts, with discrepancies between the forecasted values ($x_{bp}(t)$) and the BIPM data ($x_b(t)$) being minimal, often within a few nanoseconds. This indicates that the Polish Timescale has remained consistently accurate, aligning closely with the best global timescales.

Data Preparation for GMDH Neural Network.

An essential part of the developed forecasting system based on the proposed procedure is the block dedicated to preparing input data for the GMDH neural network (NN) in the form of time series. The quality of the forecasts heavily depends on how this data is prepared. For the UTC(k) forecasting research, two time series, TS1 and TS2, were developed, containing data with a one-day interval.

The TS1 time series consists of three data groups: phase time values ($x_a(t)$) between 1 pulse-per-second signals from the national UTC(k) timescale ($UTC_k(t)$) and the atomic clock ($clock_k(t)$), $x_b(t)$ values representing the difference $UTC - UTC(k)$, and $x_{br}(t)$ values representing the difference between UTC_r and $UTC(k)$. These relationships are defined as:

$$x_a(t) = UTC_k(t) - clock_k(t)$$

$$x_b(t) = UTC(t) - UTC_k(t)$$

$$x_{br}(t) = UTC_r(t) - UTC_k(t)$$

The $x_b(t)$ values are the data published by the BIPM in their "Circular T" bulletin. Since these data are published for Modified Julian Dates (MJD) ending in 4 and 9, they are interpolated using the Hermite polynomial (PCHIP function in MATLAB) to generate daily values. This interpolation helps extend the number of historical data points, ensuring the GMDH NN has enough training data, as insufficient data can hinder the training process.

The preparation method for TS2 is similar to TS1, but the data is split differently: the first group consists solely of $x_b(t)$ values, while the second group consists only of $x_{br}(t)$ values.

Forecasting Process

The forecasting process involves predicting $x_b(t)$ values. Using TS1, the output from the GMDH NN for a forecast day (t_p) is denoted as $x_{1p}(t_p)$. By comparing this with the measured $x_a(t_p)$ for $UTC(k)$ on that day, the forecast difference ($x_{bp}(t_p)$) is calculated as:

$$x_{bp}(t_p) = x_{1p}(t_p) - x_a(t_p)$$

For TS2, the forecasting approach is similar, and the results can also be used to correct $UTC(k)$ values.

CONCLUSIONS.

The research demonstrates that the forecasting system based on the GMDH neural network provides highly accurate predictions for the Polish Timescale ($UTC(PL)$), enabling it to achieve a level of precision comparable to the best global timescales. The system's use of hydrogen masers, along with well-prepared input data and the application of advanced forecasting techniques, ensures that the accuracy of $UTC(PL)$ remains within a narrow range, often within ± 10 nanoseconds.

The developed system has proven to be effective in real-time forecasting and steering of $UTC(PL)$, which has significantly enhanced its performance. The approach has shown to be adaptable, with minimal discrepancies between forecasted and actual data, making it a reliable tool for maintaining precise timekeeping.

The research results indicate that the GMDH neural network is an optimal choice for forecasting $UTC(k)$ timescales, especially for national metrology institutes (NMIs) that do not have access to high-cost equipment like caesium fountains. By using this system, such institutions can achieve high-quality time scale predictions at a significantly lower cost.

Furthermore, the application of this forecasting system has contributed to the Polish Timescale being classified among the top-performing timescales, demonstrating the practical benefits of artificial intelligence in metrology. The continued use of this system ensures the ongoing precision and reliability of $UTC(PL)$, positioning it as a leading example of modern timekeeping technology.

REFERENCE

1. Miczulski, W., Sobolewski, L., 2011. Application of the GMDH neural networks in prediction of corrections of the national time scale. *Electronics: Constructions, Technologies, Applications* 6, 45–47.
2. Miczulski, W., Sobolewski, L., 2012. Influence of the GMDH neural network data preparation method on UTC(PL) correction prediction results. *Metrol. Meas. Syst.* 19 (1), 123–132.
3. Miczulski, W., Sobolewski, L., 2017. Algorithm for predicting [UTC - UTC(k)] by means of neural networks. *IEEE Trans. Instrum. Meas.* 66 (8), 2136–2142.
4. Miczulski, W., Sobolewski, L., Croonenbroeck, C., 2015. A Neural model of a wind turbine. In: *Proc. XXI IMEKO World Congress Measurement in Research and Industry*, pp. 1–4.
5. Sobolewski, L., 2016. Application of the Neural Networks for Predicting the Corrections for the National Timescale UTC(PL), Zielona Gora, Poland: University of Zielona Gora. Press.
6. Sobolewski, L., 2017a. Application of GMDH type neural network for predicting UTC(k) timescales realized on the basis of hydrogen masers. In: *Proc. Joint IEEE (FCS EFTF)*, pp. 42–46.
7. Sobolewski, L., 2017b. „Predicting the Lithuanian Timescale UTC(LT) by means of GMDH neural network,”. *Bulletin of the Military University of Technology* 66 (4), 31–41.
8. Sobolewski, L., 2020. „Comparison of quality of UTC(PL) and UTC(NPL) scales prediction by means of GMDH neural network,”. *Measurement Systems In Theory and in Practice*, Zielona Gora, pp. 229–242.
9. Sobolewski, L., 2022. „Jakoś'c prognozowania skali czasu nadzorowanej przez pierwotny wzorzec częstotliwości z zastosowaniem sieci neuronowej typu GMDH na przykładzie skali czasu UTC(NPL),” *Electr. Rev.* 11, 131–134 (in Polish).
10. Sobolewski, L., Miczulski, W., 2016. Methods of time series preparation based on UTC and UTCr scales for predicting the [UTC-UTC(PL)]. *J. Phys., Conf. Ser.* 723, 012040.
11. Sobolewski, L., Miczulski, W., 2021. Methods of constructing time series for predicting local time scales by means of a GMDH-type neural network. *Appl. Sci.* 11 (12).
12. Sobolewski, L., Miczulski, W., Czubla, A., 2021. Experimental verification of the neural network predicting procedure applied for UTC(PL). *IEEE Trans. Instrum. Meas.* 70 (Sep).

УДК 004.8

Ковальчук Д. М. (Харківський національний університет імені В. Н. Каразіна, Харків, Україна).

ВИКОРИСТАННЯ НЕЙРОННИХ МЕРЕЖ ДЛЯ ПЛАНУВАННЯ СПОЖИВАННЯ ЕЛЕКТРИЧНОЇ ЕНЕРГІЇ.

Анотація. У статті розглядається застосування нейронних мереж для прогнозування й планування споживання електричної енергії в сучасних енергетичних системах. Показано, що традиційні статистичні методи не забезпечують належної точності в умовах високої стохастичності навантаження, збільшення частки відновлюваних джерел енергії та змінного тарифного регулювання. Нейронні мережі, зокрема MLP, LSTM, GRU та гібридні архітектури, ефективно моделюють нелінійні залежності, враховують короткострокові та сезонні коливання і здатні формувати точні прогнози як на короткостроковій, так і на довгостроковій перспективі. Описано застосування методів підкріпленого навчання для оптимізації режимів роботи енергетичного обладнання, управління акумуляційними системами та мінімізації витрат у середовищах з динамічним ціноутворенням. Розглянуто інтеграцію моделей глибокого навчання у Smart Grid, включаючи цифрові двійники енергосистем, що підвищує ефективність планування та стійкість енергетичної інфраструктури. Визначено основні труднощі застосування ШНМ у задачах

енергетичного прогнозування, пов'язані з якістю даних, узагальненням моделей, ризиком перенавчання та кіберзагрозами. Зроблено висновок, що впровадження нейронних мереж є ключовим інструментом підвищення ефективності, надійності та гнучкості енергетичних систем майбутнього.

Ключові слова: нейронні мережі, прогнозування навантаження, енергетичні системи, Smart Grid, цифрові двійники, підкріплене навчання.

Abstract. The article examines the use of neural networks for forecasting and planning electricity consumption in modern power systems. It is shown that traditional statistical methods do not provide adequate accuracy in conditions of high load stochasticity, increasing penetration of renewable energy sources, and dynamic electricity pricing. Neural networks, including MLP, LSTM, GRU, and hybrid architectures, effectively model nonlinear dependencies, account for short-term and seasonal fluctuations, and provide accurate forecasts for both short-term and long-term horizons. The application of reinforcement learning for optimizing the operation of power equipment, managing energy storage systems, and reducing operational costs in dynamic pricing environments is discussed. The paper highlights the integration of deep learning models into Smart Grid infrastructures, including energy system digital twins, which enhances planning efficiency and system resilience. Key challenges of neural network deployment in energy forecasting are identified, including data quality, model generalization, overfitting risks, and cybersecurity concerns. It is concluded that neural networks represent a fundamental technology for enhancing the efficiency, reliability, and flexibility of future energy systems.

Keywords: neural networks, load forecasting, power systems, Smart Grid, digital twins, reinforcement learning.

У сучасних енергетичних системах зростання частки відновлюваних джерел, коливання навантаження та потреба в підвищенні енергоефективності створюють потребу в інтелектуальних методах прогнозування та планування споживання електричної енергії. Традиційні статистичні підходи, такі як методи ковзного середнього або авторегресійні моделі, демонструють обмеженість у разі високої стохастичності даних, характерної для сучасних мереж. У цьому контексті нейронні мережі, здатні навчатися на великому обсязі історичної інформації та виявляти нелінійні залежності, стають ключовими інструментами для формування оптимальних графіків споживання, забезпечення балансування енергосистеми та підтримки роботи "розумних" мереж Smart Grid [1].

Основна ідея застосування нейронних мереж у плануванні споживання електроенергії полягає в побудові моделі прогнозування навантаження, яка здатна з достатньою точністю визначати майбутній рівень споживання на основі історичних даних, температурних показників, характеристик споживачів, типу дня тижня та інших релевантних факторів [2]. Формально завдання можна представити як мінімізацію функції похибки прогнозування:

$$\min_W E = \frac{1}{N} \sum_{i=1}^N (y_i - y_i(W))^2, \quad (1)$$

де y_i – фактичне споживання, $y_i(W)$ – прогнозоване значення, що залежить від вектора ваг мережі W . Ця функція мінімізується в процесі тренування через алгоритм зворотного поширення помилки, що дозволяє адаптивно коригувати параметри.

У контексті енергетичного планування застосовуються різні типи нейронних мереж. Найпоширенішими є багаточарові перцептрони (MLP), які забезпечують прогнозування на короткострокові інтервали (похвилинні або погодинні прогнози). Для задач із довшими інтервалами та залежностями у часовому ряді застосовуються рекурентні архітектури, зокрема LSTM та GRU, що здатні зберігати інформацію про попередні стани та успішно моделюють сезонні та добові цикли. Для складних систем з великою кількістю вхідних параметрів можуть використовуватися гібридні мережі, де комбінація CNN та LSTM забезпечує вилучення як часових, так і структурних характеристик [3].

Прогнозування споживання електричної енергії є лише однією з частин задачі оптимального планування. Наступним кроком є визначення оптимального режиму роботи енергоустановок, вибір моментів увімкнення та вимкнення обладнання, управління акумуляційними системами й розподіл навантаження між різними сегментами. Для цього

можуть застосовуватися нейронні мережі прямого регулювання або моделі підкріпленого навчання (Reinforcement Learning), де агент навчається мінімізувати операційні витрати за умов обмежень технічних характеристик системи [2, 3]. Наприклад, завдання мінімізації загальних витрат може бути описане як:

$$\min C = \sum_{t=1}^T (p_t \cdot L_t - s_t \cdot B_t), \quad (2)$$

де p_t – ціна електроенергії в момент часу t , L_t – споживання навантаження, B_t – заряд/розряд акумуляторних систем, а s_t – коефіцієнт економічного ефекту від використання акумулятора. У системах з динамічним ціноутворенням (Time-of-Use, Real-Time Pricing) такі моделі дозволяють значно зменшити витрати за рахунок перенесення пікових навантажень та оптимізації графіків роботи обладнання.

Важливим аспектом є інтеграція нейронних мереж у Smart Grid, де споживачі стають "активними учасниками" енергетичного ринку, а енергоефективність досягається за рахунок взаємодії великої кількості децентралізованих елементів: домашніх систем, сонячних панелей, електромобілів, промислових підприємств. У таких умовах моделі прогнозування дозволяють координувати роботу енергетичної інфраструктури та зменшувати ризик перевантаження мережі. Окрім цього, нейронні мережі використовуються для виявлення аномалій у споживанні, оцінювання якості прогнозу та адаптації до змінних умов.

Окремої уваги заслуговує застосування енергетичних цифрових двійників, де нейронні мережі стають ключовим компонентом. Цифрові двійники дозволяють моделювати поведінку систем у реальному часі, що суттєво підвищує якість прогнозів та дозволяє тестувати різні сценарії споживання без ризику для реальних систем. Використання глибокого навчання у цифрових двійниках дає можливість наближати складні фізичні процеси, що зазвичай описуються нелінійними диференціальними рівняннями, у вигляді компактних апроксиматорів.

Попри значні досягнення, використання нейронних мереж для планування споживання електроенергії має ряд викликів. Серед основних можна виділити потребу у великому обсязі якісних історичних даних, складність налаштування архітектур, а також ризик «переобучення» моделі. Крім того, впровадження інтелектуальних систем вимагає врахування кібербезпеки й надійності, оскільки порушення роботи прогнозних модулів може призвести до помилок у функціонуванні енергетичної системи.

ВИСНОВКИ. Таким чином, нейронні мережі є потужним інструментом, який значно підвищує ефективність планування споживання електричної енергії та забезпечує гнучкість у керуванні сучасними енергетичними системами. Вони дозволяють адаптуватися до умов високої невизначеності, оптимізувати роботу обладнання, зменшувати витрати та підвищувати енергетичну безпеку. Подальші дослідження у цій сфері спрямовані на розробку більш стійких та інтерпретованих моделей, здатних працювати в умовах обмежених даних та масштабованих структур Smart Grid, що відкриває перспективи для побудови повністю автономних енергетичних систем майбутнього.

СПИСОК ПОСИЛАНЬ.

1. Ковальчук, Д. М. Система прогнозування електроспоживання з використанням нейронних мереж / Д. М. Ковальчук // Електроенергетика, електромеханіка та технології в АПК : матеріали Міжнар. наук.-практ. конф., 5 листопада 2025 р. / Держ. біотехнологічний ун-т. – Харків, 2025. – С. 301–302. – Режим доступу : <http://btu.kharkov.ua/nauka/konferentsiyi/>
2. Харченко, В. О. Основи машинного навчання : навч. посіб. / В. О. Харченко. – Суми : Сумський державний університет, 2023. – 264 с.
3. Штучний інтелект. Нейромережна обробка інформації : архітектури, навчання, застосування : навч. посіб. у 2-х ч. : Ч. 1 / О. Г. Руденко, О. О. Безсонов, С. П. Євсєєв, О. Б. Ахієзер, Ю. І. Зайцев ; за заг. ред. С. П. Євсєєва. – Харків : НТУ «ХПІ» ; Львів : Новий Світ-2000, 2025. – 426 с. – (Серія «Кібербезпека та штучний інтелект»). – ISBN 978-966-418-517-9.

Ковальчук Д. М. (Харківський національний університет імені В. Н. Каразіна, Харків, Україна).

ОБГРУНТУВАННЯ МОЖЛИВОСТІ ЗАСТОСУВАННЯ НЕПОЗИЦІЙНОЇ СИСТЕМИ ЧИСЛЕННЯ ЗАЛИШКОВИХ КЛАСІВ У ШТУЧНИХ НЕЙРОННИХ МЕРЕЖАХ З МЕТОЮ ПІДВИЩЕННЯ ШВИДКОСТІ ОБРОБКИ ДАНИХ.

Анотація. У статті представлено комплексне обґрунтування можливості застосування непозиційної системи числення залишкових класів (СЗК) у штучних нейронних мережах для підвищення швидкодії та енергоефективності обчислювальних процесів. Розкрито ключові особливості СЗК, що полягають у поданні чисел незалежними залишками за взаємно простими модулями, що дає змогу реалізувати повний паралелізм виконання арифметичних операцій та усунути потребу в операціях перенесення, характерних для позиційних систем. Проаналізовано вплив використання СЗК на оптимізацію операцій множення, підсумовування та обчислення активацій у ШНМ, що є критичними для глибоких моделей. Показано, що така форма представлення чисел підвищує завадостійкість і дозволяє локалізувати похибки в межах окремого модульного каналу, зменшуючи ризик системних збоїв. Розглянуто перспективи створення апаратних прискорювачів на основі СЗК, орієнтованих на роботу в режимі реального часу, а також можливості масштабування архітектури без збільшення апаратної складності. Отримані результати підтверджують доцільність застосування системи залишкових класів як ефективного підходу до підвищення продуктивності та надійності інтелектуальних обчислювальних систем.

Ключові слова: система залишкових класів, штучні нейронні мережі, паралельні обчислення, апаратні прискорювачі, завадостійкість.

Abstract. The paper provides a comprehensive justification for the feasibility of applying the non-positional residue number system (RNS) in artificial neural networks to improve computational speed and energy efficiency. The study highlights the core advantages of RNS, where numbers are represented as independent residues modulo pairwise coprime bases, enabling full parallelism of arithmetic operations and eliminating carry propagation typical of positional systems. The impact of RNS on optimizing multiplication, summation, and activation computation in neural networks is examined, emphasizing its relevance for deep learning models with intensive arithmetic workloads. It is shown that the modular structure inherently increases fault tolerance by localizing errors within individual channels, thereby reducing the likelihood of system-wide failures. The research outlines the prospects for developing hardware accelerators based on RNS suitable for real-time environments, as well as the potential for scalable architectures without significant hardware overhead. The findings confirm that the application of residue number systems is a promising direction for enhancing the performance and reliability of modern intelligent computing architectures.

Keywords: residue number system, artificial neural networks, parallel computation, hardware acceleration, fault tolerance.

Постійне зростання складності штучних нейронних мереж та збільшення обсягів вхідних даних актуалізує проблему підвищення швидкості їх роботи, особливо у задачах реального часу. Традиційні обчислення, що виконуються у звичних позиційних системах числення, покладаються на послідовну обробку розрядів і операції переносу, які природно обмежують продуктивність апаратно-програмних засобів. У відповідь на це все більшої уваги набувають альтернативні представлення чисел, зокрема непозиційна система числення залишкових класів, яка дає можливість реформувати структуру обчислень у нейронних мережах. Її головною характеристикою є те, що число подається не у вигляді єдиного бінарного значення, а через набір незалежних залишків за різними модулями. Завдяки цьому будь-які арифметичні операції можуть виконуватись паралельно, адже кожен модуль

функціонує як окремий незалежний обчислювальний канал. Це означає, що такі операції, як підсумовування ваг, множення сигналів або обчислення активацій, можуть бути розбиті на кілька потоків і виконані одночасно, що суттєво підвищує загальну швидкодію. Такий підхід особливо перспективний для апаратної реалізації нейронних мереж, оскільки він дозволяє створити набори невеликих і простих обчислювальних блоків замість одного складного процесора, що працює послідовно. Це відкриває можливість масштабування системи без суттєвого ускладнення архітектури, а також забезпечує помітне зниження енергоспоживання, що є критично важливим для мобільних пристроїв, вбудованих систем і мережевих вузлів Інтернету речей.

Ще однією важливою перевагою використання залишкових класів у ШНМ є зменшення ризику переповнення та підвищення завадостійкості. Оскільки кожен модуль працює в окремому каналі, похибки чи шум не поширюються на всю систему, а залишаються локалізованими в межах одного каналу. Це робить модель менш чутливою до апаратних збоїв, що має значення у промислових і безпекових застосуваннях. Крім того, у межах залишкових представлень можна використовувати надлишкові модулі для контролю правильності обчислень, що підвищує загальну надійність нейронної мережі. Застосування такої системи також дозволяє працювати з високоточними обчисленнями без значних апаратних витрат, що є корисним для глибоких моделей, яким необхідна стабільність при великій кількості параметрів.

ВИСНОВКИ. Таким чином, використання непозиційної системи числення залишкових класів у штучних нейронних мережах є обґрунтованим з позицій збільшення швидкодії, зменшення енергоспоживання, підвищення завадостійкості та розширення можливостей апаратної оптимізації. Поєднання паралельної природи цієї системи з притаманною нейронним мережам високою інтенсивністю однотипних операцій робить такий підхід перспективним напрямом розвитку нових архітектур апаратних прискорювачів. Це дозволяє створювати швидші, надійніші та енергоефективніші інтелектуальні системи, що є важливим у сучасних задачах робототехніки, автономного транспорту, телекомунікацій та інших галузей, де висока продуктивність і точність обробки даних мають вирішальне значення.

СПИСОК ПОСИЛАНЬ.

1. Ковальчук Д.М. *Моделі та методи швидкої обробки даних на основі застосування системи залишкових класів* : дис. ... докт. філос. : 122 – Комп'ютерні науки (Галузь знань 12 – Інформаційні технології) / Д.М. Ковальчук. – Харків : Харківський національний університет імені В.Н. Каразіна, 2024. – 171 с.
2. Янко А.С., Ковальчук Д.М. *Дослідження можливості відмовостійкого функціонування комп'ютерної системи в непозиційній системі числення в залишкових класах* / А.С. Янко, Д.М. Ковальчук // *Сучасні напрями розвитку інформаційно-комунікаційних технологій та засобів управління* : тези доп. 13-ї міжнар. наук.-техн. конф., 26-27 квітня 2023 р., Баку–Харків–Жиліна : [у 2 т.]. Т. 2 : секція 2 / Нац. ун-т оборони Азербайджанської Республіки [та ін.]. – Харків : Impress, 2023. – С. 50.
3. Поліський Ю.Д. *Про деякі нові рішення в системі залишкових класів* / Ю.Д. Поліський // *Проблеми математичного моделювання: матеріали Всеукр. наук.-метод. конф., 26-28 трав. 2021 р. - м. Кам'янське: ДДТУ. -2021. -С. 67-69.*

Ковальчук Д. М. (Харківський національний університет імені В. Н. Каразіна, Харків, Україна).

ПІДВИЩЕННЯ НАДІЙНОСТІ ТА ДОСТОВІРНОСТІ ОБРОБКИ ДАНИХ У ШТУЧНИХ НЕЙРОННИХ МЕРЕЖАХ ІЗ ВИКОРИСТАННЯМ СИСТЕМИ ЗАЛИШКОВИХ КЛАСІВ.

Анотація. У статті розглядається комплексний підхід до підвищення надійності та достовірності обробки даних у штучних нейронних мережах (ШНМ) шляхом застосування непозиційної системи числення залишкових класів (СЗК). Показано, що модульне подання чисел забезпечує виконання обчислень у вигляді незалежних паралельних потоків, що сприяє локалізації помилок та зниженню впливу апаратних збоїв. Охарактеризовано ключові переваги використання СЗК, серед яких підвищення стабільності числових операцій, покращення механізмів контролю помилок, зменшення накопичення похибок та можливість підвищення точності моделювання. Розкрито перспективи створення апаратно оптимізованих прискорювачів для обчислень у ШНМ, що базуються на модульній природі СЗК та не потребують операцій перенесення. Показано, що застосування СЗК забезпечує підвищення стійкості нейронних мереж до завад, оптимізує використання ресурсів і розширює можливості реалізації систем реального часу. Зроблено висновок, що система залишкових класів є ефективним інструментом удосконалення інтелектуальних обчислювальних систем, орієнтованих на високу швидкодію, точність і надійність.

Ключові слова: система залишкових класів, штучні нейронні мережі, надійність, достовірність даних, модульні обчислення, апаратні прискорювачі.

Abstract. This paper presents a comprehensive approach to improving the reliability and accuracy of data processing in artificial neural networks (ANNs) through the application of the non-positional residue number system (RNS). It is shown that modular representation of numbers enables computations to be organized as independent parallel streams, which contributes to effective error localization and reduction of the impact of hardware faults. The key advantages of RNS are characterized, including improved numerical stability, enhanced error-control mechanisms, reduced accumulation of rounding errors, and increased precision in deep neural models. The study outlines the prospects for creating hardware-optimized accelerators based on RNS that exploit its intrinsic parallelism and eliminate the need for carry operations. It is demonstrated that the use of RNS increases robustness of neural networks against noise, optimizes resource utilization, and enables efficient implementation of real-time intelligent systems. The results confirm that the residue number system is a powerful tool for enhancing intelligent computing architectures aimed at high performance, accuracy, and operational reliability.

Keywords: residue number system, artificial neural networks, reliability, data integrity, modular computations, hardware accelerators.

Сучасні штучні нейронні мережі застосовуються в широкому спектрі задач, включаючи обробку зображень, розпізнавання мовлення, прогнозування часових рядів та системи автономного управління. Високий рівень складності обчислень та обсяг оброблюваних даних створюють серйозні виклики щодо надійності та достовірності результатів. Будь-які апаратні збої, помилки округлення або втрати даних можуть призвести до критичних похибок, що особливо небезпечно у системах реального часу та відповідальних галузях, таких як робототехніка, медицина та фінансові технології. Одним із перспективних підходів до підвищення надійності обчислень у ШНМ є застосування непозиційної системи числення залишкових класів, яка забезпечує ефективний механізм виявлення та локалізації помилок і дозволяє організувати обчислення у вигляді незалежних паралельних потоків.

Система залишкових класів ґрунтується на представленні чисел через набори залишків по взаємно простих модулях, що робить кожен модульний канал незалежним від інших. У контексті нейронних мереж це означає, що обчислення вагових сум, множення вхідних сигналів на ваги та обчислення функцій активації можуть виконуватися одночасно в різних модулях без взаємного впливу. Така властивість не лише прискорює обробку даних, але й

дозволяє локалізувати помилки, які можуть виникати у процесі обчислень. Якщо у певному модульному каналі виникає збій, інші канали залишаються працездатними, що знижує ймовірність повної деградації результату. Крім того, надлишкові модулі можна використовувати для перевірки правильності обчислень, що дозволяє реалізувати механізми контролю помилок без значного збільшення апаратних ресурсів.

Використання системи залишкових класів також підвищує достовірність результатів обробки даних у глибоких нейронних мережах. Завдяки високій точності модульних обчислень зменшується вплив кумулятивних похибок, що зазвичай накопичуються у звичайних позиційних системах числення при багаторівневих операціях. Це особливо важливо для великих моделей з тисячами нейронів і мільйонами параметрів, де навіть невеликі похибки можуть призвести до значного викривлення результатів. Система залишкових класів забезпечує більш стабільні числові значення, що підвищує точність навчання та роботу моделей у режимі прогнозування.

Додатковою перевагою застосування залишкових класів є можливість реалізації ефективних апаратних прискорювачів. Кожен модульний канал може бути реалізований як окремий обчислювальний блок на FPGA, ASIC або спеціалізованому нейроморфному процесорі. Це дозволяє створювати масштабовані архітектури з високою пропускнуою здатністю і одночасно реалізувати механізми контролю помилок та надлишковості. Крім того, такий підхід дозволяє знизити енергоспоживання, оскільки модулі працюють на малих розрядностях і не потребують ресурсозатратних операцій переносу, характерних для позиційних систем числення.

ВИСНОВКИ. Таким чином, застосування непозиційної системи числення залишкових класів у штучних нейронних мережах є ефективним засобом підвищення надійності та достовірності обробки даних. Паралельна обробка в незалежних модульних каналах, можливість локалізації та контролю помилок, підвищена точність обчислень і апаратна оптимізація роблять цей підхід перспективним для створення швидких, стабільних і надійних інтелектуальних систем, здатних працювати в умовах високих обчислювальних навантажень та вимог до безпеки даних. Використання системи залишкових класів відкриває нові можливості для розвитку апаратного і програмного забезпечення ШНМ, сприяючи створенню ефективних рішень у різних галузях науки, промисловості та технологій.

СПИСОК ПОСИЛАНЬ.

1. Ковальчук Д.М. *Моделі та методи швидкої обробки даних на основі застосування системи залишкових класів* : дис. ... докт. філос. : 122 – Комп'ютерні науки (Галузь знань 12 – Інформаційні технології) / Д.М. Ковальчук. – Харків : Харківський національний університет імені В.Н. Каразіна, 2024. – 171 с.
2. Янко А.С., Ковальчук Д.М. *Дослідження можливості відмовостійкого функціонування комп'ютерної системи в непозиційній системі числення в залишкових класах* / А.С. Янко, Д.М. Ковальчук // *Сучасні напрями розвитку інформаційно-комунікаційних технологій та засобів управління* : тези доп. 13-ї міжнар. наук.-техн. конф., 26-27 квітня 2023 р., Баку–Харків–Жиліна : [у 2 т.]. Т. 2 : секція 2 / Нац. ун-т оборони Азербайджанської Республіки [та ін.]. – Харків : Impress, 2023. – С. 50.
3. Поліський Ю.Д. *Про позиційну характеристику у системі залишкових класів* /Ю.Д.Поліський // *Ways of Science Development in Modern Crisis Conditions: Proceedings of the 4th International Scientific and Practical Internet Conference, June 8-9, 2023. FOP Marenichenko V.V., Dnipro, Ukraine*, P.351-352.

B2. Cognitive, Behavioral and Biomedical AI Models. Когнітивні, поведінкові та медико-біологічні моделі III.

UDC 004.932.4:159.942.4

Bisogni C., Cimmino L., Nappi M., Pannese T., Pero C. (University of Salerno, Department of Computer Science & Department of Management and Innovation Systems, Fisciano, Salerno, Italy).

GAIT-BASED EMOTION RECOGNITION WITH PRIVACY PRESERVATION.

Abstract. Gait-based emotion recognition has emerged as a promising research direction due to its applicability in healthcare, surveillance, social interaction analysis, and intelligent systems. Unlike traditional biometric modalities such as facial expressions or speech, gait enables remote, non-invasive, and privacy-preserving analysis, maintaining robustness even in low-resolution or unconstrained environments. This study introduces the “Walk-as-you-Feel” (WayF) framework, a novel deep learning methodology designed to identify human emotions exclusively from gait patterns while ensuring strict privacy protection by excluding all facial cues. To address challenges related to small and imbalanced datasets, a tailored balancing strategy is incorporated, combining over-sampling and under-sampling to enhance class distribution for deep learning pipelines. Feature extraction is conducted using advanced CNN architectures, specifically EfficientNetV2-L and Inception-v3, whose outputs feed sequential classifiers including Gated Recurrent Units (GRUs) and a Transformer Encoder. The experimental evaluation is performed using the E-Walk dataset, which contains multiple walking styles and emotion annotations. Results demonstrate an average recognition accuracy of approximately 77% under balanced conditions, improving to 83.3% when neutral emotions are excluded. These findings reveal that gait alone can serve as a reliable and privacy-conscious modality for emotion recognition, achieving performance comparable to methods leveraging facial information.

Keywords: gait analysis; emotion recognition; privacy-preserving biometrics; deep learning; GRU; Transformer Encoder; feature extraction.

Анотація. Розпізнавання емоцій за ходою привертає дедалі більше уваги завдяки широким можливостям застосування у сферах охорони здоров'я, аналізу соціальних взаємодій, систем відеоспостереження та інтелектуальних технологій. На відміну від традиційних біометричних підходів — таких як розпізнавання обличчя чи аналіз мовлення — хода забезпечує дистанційну, невтручальну та конфіденційну оцінку, зберігаючи ефективність навіть у неконтрольованих або низькороздільних умовах. У цьому дослідженні представлено фреймворк «Walk-as-you-Feel» (WayF), інноваційний метод глибинного навчання для визначення емоцій виключно за ходою, який забезпечує збереження приватності шляхом повного виключення ознак обличчя. Для подолання проблеми малих та незбалансованих наборів даних застосовано спеціальну стратегію балансування, що поєднує над- та недовибірку і покращує навчання моделей. Виділення ознак здійснюється за допомогою сучасних CNN-архітектур EfficientNetV2-L та Inception-v3, вихідні вектори яких передаються до класифікаторів GRU та Transformer Encoder. Експериментальна оцінка проводилась на наборі E-Walk, що містить різні стилі ходи та експертні оцінки емоцій. Результати показали середню точність близько 77% у збалансованих умовах та зростання до 83,3% після виключення нейтрального класу. Отримані дані підтверджують, що хода може бути ефективним і приватним каналом для розпізнавання емоцій, забезпечуючи точність, співставну з методами, що використовують обличчя.

Ключові слова: аналіз ходи; розпізнавання емоцій; конфіденційні біометричні системи; глибинне навчання; GRU; Transformer Encoder; виділення ознак.

1. Introduction

Affective state identification represents a significant investigative challenge, contributing to technological advancement in domains of medical care, behavioral examination, interpersonal communications, and security. Among various biometric approaches, locomotion patterns stand out through their capacity to provide distant non-intrusive examination without requiring user cooperation. Locomotion patterns constitute a distinctive characteristic that can signal not merely an individual's identity but additionally their psychological-emotional condition. Unlike facial identification, which may be constrained or undesirable for confidentiality considerations, locomotion pattern examination permits creating systems that simultaneously remain informative and protected from a privacy standpoint. Nevertheless, precise determination of affective states from locomotion patterns remains a challenging task due to movement variability caused by both individual characteristics and contextual elements. Within this framework, the WayF architecture proposes a comprehensive solution based on deep neural networks, integrating advanced CNN frameworks and sequential models, including GRU and Transformer-Encoder.

2. Methodology

The WayF methodology incorporates several stages. During the initial stage, from video recordings of the E-Walk dataset, 33 bodily keypoints are identified using MediaPipe Pose, while facial data is completely disregarded. Each video is standardized to 240 frames to ensure uniformity. To address imbalance between classes, under- and over-sampling strategies are implemented. Subsequently, two independent computational pipeline models are developed:

- EfficientNetV2-L + Transformer-Encoder, demonstrating superior performance in cases of "neutral" and "sad" categories
- Inception-v3 + GRU, which effectively classifies "happy" and "angry" affective states

The pipelines operate on transformed characteristics obtained from CNN, while sequential processing models examine temporal dynamics of locomotion patterns.

3. Results

Experiments were conducted on both equilibrated and non-equilibrated samples. Both pipelines demonstrate complementary advantages. The optimal WayF precision reaches approximately 77% under standard circumstances and 83.3% when excluding the neutral category. Outcomes surpass the effectiveness of numerous approaches that utilize facial characteristics, underscoring the potential of locomotion patterns as an independent source of information regarding affective condition. The system consistently classifies affective states across various scenarios while maintaining confidentiality.

4. Conclusions

The proposed WayF architecture demonstrates the feasibility of creating affective state identification systems that rely exclusively on locomotion patterns and require no facial data whatsoever. This opens possibilities for applying such systems in confidentiality-sensitive domains, such as medical care or monitoring systems. Prospects for further investigations include utilizing synthetic data, modeling regression-based affective assessments, and integrating multi-channel biometric signals.

Cammarano A., Varriale V., Michelino F., Caputo M. (University of Salerno, Fisciano, Italy).

DISCOVERING TECHNOLOGICAL OPPORTUNITIES WITH NEURAL NETWORKS AND LITERATURE ANALYSIS.

Abstract. This paper presents a novel methodology for identifying technological opportunities by combining structured extraction of emerging practices from academic literature with neural-network-based impact prediction. Technological opportunities are conceptualized as potential applications of advanced technologies in unexplored industries or business processes. The approach begins with a large-scale manual review of 33,285 scientific papers, from which 8,406 relevant publications are selected, yielding 14,739 technology–industry–process triads. These triads form the basis for training an artificial neural network capable of predicting the market- and organization-level impact of untested combinations. The method is applied to eleven advanced technologies, including AI, blockchain, 3D printing, IoT, robotics, high-performance computing, immersive environments, geo-spatial systems, digital applications, proximity technologies and open/crowd-based platforms. The resulting “opportunity maps” highlight optimal domains for future deployment, distinguishing between high-confidence and low-confidence predictions to support strategic prioritization. Sensitivity analysis reveals that process variables exert the strongest influence on predicted outcomes, followed by industry and technology. The study demonstrates that academic literature can serve as a rich foundation for detecting emerging practices and forecasting innovation trajectories. It also outlines limitations associated with manual content extraction and emphasizes the potential of NLP-assisted automation for future methodological refinements.

Keywords: technological opportunities; literature analysis; artificial neural networks; emerging practices; opportunity mapping; advanced technologies; innovation forecasting; technology–industry–process triad.

Анотація. У статті представлено нову методологію виявлення технологічних можливостей шляхом поєднання структурованого аналізу наукової літератури з прогнозуванням на основі нейронних мереж. Технологічні можливості розглядаються як потенційні напрями застосування передових технологій в нових галузях або бізнес-процесах, які ще не досліджені на практиці. Методологія починається з масштабного ручного аналізу 33 285 наукових публікацій, із яких 8 406 визнано релевантними, що дозволило сформувати 14 739 триад «технологія — галузь — процес». На їх основі навчається нейронна мережа, яка прогнозує організаційний та ринковий ефект для ще не протестованих комбінацій. Метод випробувано на одинадцяти передових технологіях, серед яких штучний інтелект, блокчейн, 3D-друк, інтернет речей, робототехніка, високопродуктивні обчислення, геопросторові технології, цифрові застосунки, іммерсивні середовища, платформи відкритих інновацій і технології близькості. Результатом стали «карти технологічних можливостей», що ідентифікують найбільш перспективні напрями та розрізняють прогнози високої й низької впевненості для підтримки стратегічного вибору. Аналіз чутливості показав, що процеси мають найбільший вплив на результат, за ними — галузь і технологія. Дослідження підтверджує цінність наукової літератури як джерела інсайтів щодо зароджуваних практик та інноваційних траєкторій. Окремо окреслено обмеження ручного аналізу й перспективи автоматизації за допомогою NLP-технологій.

Ключові слова: технологічні можливості; аналіз літератури; нейронні мережі; зароджувані практики; карти можливостей; інноваційний прогноз; триада «технологія — галузь — процес».

1. Introduction

Innovation prospects define prospective pathways for transforming sectors, commercial spaces, and operational frameworks. Organizations strive to recognize such prospects beforehand to secure lasting competitive advantages. Traditionally, this was accomplished through specialist evaluations, scenario planning, and intellectual property analytics. Nevertheless, intellectual property documents possess several drawbacks, particularly during initial phases of solution advancement, when innovations have not yet acquired practical form. Scholarly publications, conversely, frequently

document the emergence of novel practices prior to their commercial deployment, rendering them a valuable resource for examination.

2. Conceptual Foundation of Innovation Prospects

Innovation prospects emerge at the convergence of solutions, sectors, and workflows. They may relate to both novel solutions and established ones that still possess capabilities for fresh implementations. Within this framework, the following are significant:

- examination of solution convergence
- recognition of "vacant applications"
- prediction of prospective commercial directions
- investigation of developing practices presented in scholarly works

Through the utilization of artificial intelligence, machine learning, and language processing, the capability for large-scale publication examination and construction of frameworks capable of anticipating novel solution implementations becomes available.

3. Investigation Approach

3.1. Stage 1: Information Gathering and Organization

33,285 scholarly articles were examined manually, of which 8,406 contained applicable examples of solution deployment. Based on this, 14,739 triplets were formulated:

- Solution
- Sector
- Workflow
- Anticipated consequence (commercial / corporate)

These triplets constitute the foundation for subsequent modeling.

3.2. Stage 2: Artificial Intelligence Model Development

An artificial intelligence model with a single intermediate layer (configured in SPSS) learns from organized categorical information, determining relationships among solution, sector, workflow, and anticipated consequence. The objective is forecasting prospective effects for novel pairings.

3.3. Stage 3: Innovation Prospect Creation

The framework assesses unexplored pairings and produces:

- Commercial consequence rating
- Corporate consequence rating
- Certainty benchmark

Pairings with strong certainty are designated as priority for subsequent investments and innovations.

4. Information and Analytics

4.1. Information Sources

The database included publications from journals such as *Annals of Operations Research*, *Computers & Operations Research*, *European Journal of Operational Research*, and numerous others. The proportion of applicable articles varies significantly across journals.

4.2. Identified Patterns

- 71.35% of prospective pairings remain "unoccupied"
- Additive manufacturing, artificial intelligence, and automation systems demonstrate the largest "unfilled areas"
- Workflows exert the most substantial influence in the framework (normalized significance = maximum)

4.3. Prospect Charts

For each solution, prospect charts were created showing ideal directions for its implementation, considering forecasted effects and certainty levels.

5. Outcomes

- The artificial intelligence model effectively predicts strong and weak consequences of pairings
- Sectors with the greatest quantity of promising "unexplored areas" are clearly distinguished
- Pairings with weak certainty are filtered, helping avoid hazardous investment choices

6. Discussion

The framework confirms that scholarly publications contain numerous signals regarding future innovation trends. However, manual examination is costly and time-consuming. Integration of language-processing instruments in subsequent investigations may:

- automatically select applicable publications
- extract triplets and consequences
- dynamically refresh frameworks

CONCLUSIONS.

The methodology:

- reveals fresh approaches to strategic solution evaluation
- merges specialist examination and artificial intelligence models
- generates valuable prospect charts
- provides foundation for practical innovation choices

Subsequent investigations will concentrate on automating publication examination and expanding the catalog of investigated solutions.

UDC 621.9:632.4:004.021

Majewski P., Mrzyglód M., Lampa P., Burduk R., Reiner J. (*Wrocław University of Science and Technology, Wrocław, Poland*).

MONITORING INSECT LARVAE GROWTH WITH REGRESSION CNN AND KNOWLEDGE TRANSFER.

Abstract. *Insect larvae breeding—particularly *Tenebrio molitor* and *Hermetia illucens*—is gaining industrial relevance, creating demand for automated methods capable of monitoring larvae growth and size distribution. This study presents an efficient approach based on a regression convolutional neural network (RegCNN) supported by knowledge transfer from an improved multistage phenotyping method. Larval width is used as the primary measurable parameter, with length and volume estimated indirectly through linear regression models. To minimize manual labeling, larvae segmentation is performed using a Mask R-CNN model trained on synthetic images generated from 266 isolated larvae. These synthetic data enable robust segmentation in dense scenes with overlapping larvae. The RegCNN is trained on pseudo target values—quartiles of larval width—derived from multistage phenotyping and corrected through size-dependent calibration factors. Several architectures are evaluated, including ResNet, EfficientNet and custom lightweight models; ResNet18 achieves the best accuracy with RMSE = 0.131 mm (width) and 1.12 mm (length), $R^2 = 0.870$, and 0.30 s inference time per breeding box. The method provides significant improvements in accuracy and speed compared to traditional phenotyping, enabling real-time monitoring on large industrial larvae farms.*

Keywords: insect larvae; size distribution; regression CNN; knowledge transfer; segmentation; phenotyping; synthetic data; real-time monitoring.

Анотація. Розведення личинок комах — зокрема *Tenebrio molitor* та *Hermetia illucens* — швидко набуває промислового значення, що створює потребу в автоматизованих методах контролю росту та розподілу розмірів личинок. У цій роботі представлено ефективний підхід, заснований на регресійній згортковій нейронній мережі (RegCNN) із застосуванням механізму трансферу знань від удосконаленого багатоступеневого фенотипування. Основним параметром вимірювання обрано ширину личинки, тоді як довжина та об'єм визначаються опосередковано за допомогою лінійних регресійних моделей. Щоб мінімізувати ручну розмітку, сегментацію личинок виконано за допомогою моделі Mask R-CNN, навченої на синтетичних зображеннях, сформованих із 266 окремих екземплярів личинок. Синтетичні дані забезпечили стійку сегментацію в цільних сценах із перекриттям. RegCNN навчалася на псевдоцільових значеннях — квартилях ширини личинок, отриманих із багатоступеневого фенотипування та скоригованих калібрувальними коефіцієнтами, залежними від розміру. Досліджено кілька архітектур, включаючи ResNet, EfficientNet та спеціально розроблені легкі моделі. Найкращі результати показала ResNet18: RMSE = 0.131 мм (ширина), 1.12 мм (довжина), $R^2 = 0.870$, час інференсу — 0.30 с на контейнер із розведенням. Запропонований підхід значно підвищує точність і швидкість порівняно з традиційними методами фенотипування, забезпечуючи можливість моніторингу в реальному часі на великих промислових фермах.

Ключові слова: личинки комах; розподіл розмірів; регресійна CNN; трансфер знань; сегментація; фенотипування; синтетичні дані; моніторинг у реальному часі.

1. Introduction

The expanding demand for protein resources is driving advancement in technologies for intensive insect larval cultivation. A critical component of process management involves regular assessment of their dimensions. However, manual measurement proves slow and unreliable due to scene density and specimen overlap. Consequently, computer vision and deep learning methodologies are becoming viable alternatives. This work describes a comprehensive approach combining multi-stage phenotyping, synthetic imagery, and regression-based deep learning frameworks.

2. Materials and Methodology

2.1. Image Acquisition and Preprocessing

Images were captured under commercial conditions using a machine vision system based on a robotic platform. A GOX-12401C camera (JAI, Denmark) generated 4096×3000 px images. Preprocessing involved:

- Compensation for uneven illumination
- Distortion correction
- Normalization
- ROI preparation

2.2. Multi-Stage Phenotyping and Identification

Identification was performed using Mask R-CNN through three phases:

1. Training on 200 artificially generated images
2. Automatic mask acquisition for D3.TRAIN with subsequent expansion of the specimen pool to ~65,000
3. Combined training on synthetic and authentic data utilizing pseudo-labels

Identification was employed to determine larval breadth, construct skeletal frameworks, and calculate body length and mass through linear frameworks.

2.3. Artificially Generated Images

266 individually extracted larvae from D1 were utilized to generate imagery with controlled overlap and density.

2.4. Linear Frameworks

Based on 266 data points, frameworks were constructed:

- $L = f(W)$
- $V = f(W)$

where W = breadth; L = body length; V = mass (estimated as summation of cylinders along skeleton).

3. RegCNN for Quartile Breadth Estimation

RegCNN estimates Q1, Q2, and Q3 breadth values from 800×800 input imagery. Evaluated architectures included: ResNet18/50/101, EfficientNet-b0/b4, MobileNetV2, and custom CNN designs. MSE loss function and Adam optimizer were employed.

ResNet18 demonstrated the optimal balance between precision and computational efficiency.

4. Results

4.1. Identification Performance

AP50 improved from 75.0% to 79.2% following integration of synthetic and authentic data. Greatest improvement occurred for small larvae (18-23 mm): +10.4%.

4.2. Parameter Assessment

ResNet18 achieved:

- $RMSE(W) = 0.131$ mm
- $RMSE(L) = 1.12$ mm
- $R^2 = 0.870$
- Processing time = 0.30 s/container

4.3. Phenotyping Performance

- Traditional method: ~217 s/container
- Accelerated phenotyping: 2.1-11 s/container
- RegCNN: 0.30 s/container (fastest)

5. Discussion

RegCNN with knowledge transfer provides precision comparable to manual measurements while significantly exceeding traditional methods in velocity. Artificially generated data substantially reduced annotation labor. The methodology proves resilient to overlap, varying density, and illumination conditions.

CONCLUSIONS.

The methodology combines advantages of classical computer vision techniques and deep learning, ensuring precise and rapid determination of larval growth parameters under commercial conditions. The algorithm is suitable for scaling and implementation in robotic cultivation systems.

REFERENCE.

- [1] Majewski P., Zapotoczny P., Lampa P., Burduk R., Reiner J. Multipurpose monitoring system for edible insect breeding based on machine learning. *Scientific Reports*. 2022. Vol. 12, No. 1. P. 1-15.

Грицев І.О., Павлюк О.М., Заболотна А.О., Морква Н.С. (Національний університет «Львівська політехніка», м. Львів, Україна).

ПРОГРАМНО-АПАРАТНА СИСТЕМА ЗБОРУ, АНАЛІЗУ ТА НЕЙРОМЕРЕЖНОГО ПРОГНОЗУВАННЯ МЕТЕОПАРАМЕТРІВ.

Анотація. У статті представлено розробку програмно-апаратної системи для збору, попередньої обробки та нейромережного прогнозування метеорологічних параметрів на основі даних автономних низькобюджетних метеостанцій. Актуальність дослідження зумовлена потребою підвищення точності локального прогнозування в умовах обмеженої кількості сенсорів і наявності шумів у даних. Сформовано комплексний конвеєр обробки сигналів, що охоплює усунення дублікатів, виявлення та фільтрацію викидів, інтерполяцію пропусків різної тривалості, згладжування сигналів та формування ознак для глибинного навчання. Запропоновано каскадне поєднання медіанного фільтра, експоненційного ковзного середнього та класичного ковзного середнього, що забезпечує високу якість очищення даних. Для прогнозування застосовано LSTM-модель із розширеним набором ознак, включно з похідними величинами та циклічними часовими перетвореннями. Модель забезпечила високу точність на горизонті 24 години, продемонструвавши $R^2 = 0.952$, $MAPE = 3.07$ та низьке значення MSE. Наведено результати прогнозування та оцінено стабільність навчання моделі. Отримані результати підтверджують ефективність запропонованого підходу та його придатність для розгортання в умовах локальних інтелектуальних метеосистем, зокрема у сфері мікрокліматичного моніторингу та аграрного прогнозування.

Ключові слова: метеокомплекс, локальне прогнозування, нейромережні моделі, інтерполяція даних, часові ряди, обробка даних, LSTM.

Abstract. The article presents the development of a software-hardware system for collecting, preprocessing and neural-network-based forecasting of meteorological parameters using data from autonomous low-budget weather stations. The relevance of the study is driven by the need to improve the accuracy of local forecasting under conditions of limited sensor availability and noisy measurements. A comprehensive data-processing pipeline is designed, covering duplicate removal, detection and filtering of outliers, interpolation of gaps of various durations, signal smoothing, and feature engineering for deep learning. A cascade of median filtering, exponential moving averaging and classical moving averaging is proposed to ensure high-quality signal refinement. An LSTM model with an extended set of features, including derivative values and cyclic time transformations, is applied for prediction. The model provides high accuracy for a 24-hour forecasting horizon, achieving $R^2 = 0.952$, $MAPE = 3.07$ and low MSE. Prediction results and model-training stability are demonstrated. The findings confirm the effectiveness of the proposed approach and its suitability for local intelligent meteorological systems, particularly for microclimate monitoring and agricultural forecasting tasks.

Keywords: weather complex, local forecasting, neural network models, data interpolation, time series processing, data pipeline, LSTM.

Постановка проблеми

Локальне прогнозування метеорологічних параметрів відіграє ключову роль у задачах моніторингу мікроклімату, управління аграрними процесами, технічними системами та інфраструктурними об'єктами [1]. Проте застосування автономних низькобюджетних метеостанцій супроводжується низкою обмежень, які знижують надійність отриманих даних. Такі станції зазвичай використовують відносно невеликий набір сенсорів: температуру, вологість, атмосферний тиск та освітленість. Цей набір сенсорів формує обмежену інформативність вимірювань і підвищує чутливість до шумів.

Окрім цього, дані, отримані з недорогих сенсорів, часто містять дублі, пропуски, короткочасні сплески або зсуви, спричинені як технічними похибками, так і змінами зовнішніх умов. За відсутності якісного попереднього оброблення це призводить до суттєвого погіршення точності моделей прогнозування.

Проблема ускладнюється тим, що класичні підходи до згладжування та інтерполяції не завжди коректно працюють на малих наборах параметрів і можуть або втрачати важливі закономірності, або, навпаки, створювати штучні тенденції. Тому постає потреба у побудові цілісного конвеєру обробки даних, здатного надійно очищувати, відновлювати та структурувати інформацію перед передачею до моделей глибинного прогнозування.

Отже, актуальною проблемою є розроблення надійної системи локального прогнозування погоди на основі автономних недорогих сенсорів, яка забезпечуватиме високу точність прогнозів за умови наявності обмежених даних та шумів.

Аналіз останніх публікацій

У сучасній літературі, локальне прогнозування метеорологічних параметрів умовно можна розділити на два підходи: використання повних професійних станцій з великою кількістю сенсорів та недорогих автономних метеостанцій з обмеженим набором параметрів: температура, відносна вологість, атмосферний тиск та освітленість. Перший підхід забезпечує високу точність і деталізацію прогнозів, але потребує значних фінансових витрат та складної інфраструктури, що обмежує його застосування в локальних і віддалених умовах. Другий підхід є економічно ефективним і масштабованим, проте обмежений набір сенсорів і висока мінливість мікроклімату створюють складності для побудови точних моделей прогнозування.

Класичні методи чисельного прогнозування (NWP), описані Ворнером [2], вимагають тисяч параметрів і суперкомп'ютерів, тоді як пропонуваний підхід базується на локальних даних і ML. Існуючі рішення для прогнозування на базі недорогих станцій використовують класичні статистичні методи або прості часові ряди [3]. Такі підходи часто не враховують шуми, пропуски або короточасні сплески значень, що суттєво знижує точність прогнозів. Використання комплексного конвеєру обробки даних, який включає видалення дублікатів, виявлення аномалій, інтелектуальне заповнення пропусків та побудову ознак для нейромережних моделей, дозволяє ефективно працювати навіть на обмежених наборах параметрів.

У представленій роботі основна увага зосереджена на прогнозуванні короткострокових змін температури повітря з горизонтом 24 години на основі даних з автономних низькобюджетних метеостанцій. Запропонований підхід дозволяє підвищити точність прогнозів і забезпечує оперативний моніторинг мікрокліматичних умов у локальних умовах, що робить його особливо цінним для аграрних господарств, малих підприємств та регіонів із обмеженим доступом до централізованих метеорологічних даних.

Мета роботи та постановка завдань

Мета роботи: Розробка програмно-апаратної нейромережної системи короткострокового високоточного прогнозування метеорологічних параметрів (температури, вологості, тиску та освітленості) на основі даних з автономних низькобюджетних метеостанцій. Для цього необхідно створити конвеєр обробки даних, який забезпечує очищення, інтерполяцію та формування ознак перед подачею в модель, а також реалізувати прогнозування на горизонті до 24 годин.

Постановка завдань:

1. Розробити систему збору та попередньої обробки даних з автономних метеостанцій у реальному часі.
2. Провести очищення даних, включаючи усунення дублікатів, пропусків та аномалій у вимірюваннях температури, вологості, тиску та освітленості.
3. Застосувати методи інтерполяції та згладжування даних для покращення якості сигналу та підготовки його для моделей прогнозування.
4. Створити набір ознак на основі часових рядів та додаткових трансформацій (диференціальні значення, синусо- та косинусо-перетворення часу) для подальшого навчання нейромережі.

5. Розробити та навчити LSTM-модель для прогнозування метеорологічних параметрів на горизонті 24 годин і перевірити її ефективність на реальних даних.

Програмно-апаратний комплекс збору даних на базі ESP32.

Розроблений комплекс має дві основні частини: апаратну та програмну. Серцем апаратної частини виступатиме мікроконтролер ESP32. Такий вибір зумовлений його низьким енергоспоживанням, вбудованим WIFI і Bluetooth модулями та низькою вартістю й наявністю необхідної кількості портів. Сенсорами виступатимуть такі модулі: сенсор температури DHT22, програмно відкалібрований фоторезистор та барометр BMP380. Такий набір сенсорів надасть змогу вимірювати температуру, вологість, рівень освітленості й атмосферний тиск. Апаратна частина також включатиме модуль геопозиціювання для визначення місцезнаходження комплексу.

Взаємодія ESP32 з серверною частиною відбувається шляхом використання HTTP-запитів по локальній WIFI-мережі. Надалі можливий перехід на MQTT-протокол для впровадження архітектури, орієнтованої на дані (Data Driven), що особливо доцільно для метеокomплексів [4].

Програмна частина включає 3 основні елементи. Рівень серверної обробки включає сервер на Express.js, який функціонально з'єднує всі модулі між собою та аналітичний Python-модуль. Його основним призначенням є подальша обробка даних, що включатиме функції виявлення аномалій, викидів та побудови прогнозів.

Рівень зберігання даних: база даних з СУБД MySQL для зберігання інформації про станції, авторизаційну інформацію та безпосередньо виміри з станції та графічний інтерфейс користувача у ролі Web-застосунку, створеного на Next.js. Комунікація модулів відбувається за допомогою HTTP-запитів у відповідності до REST-підходів. Інтерфейс користувача містить в собі авторизаційний модуль, панель для налаштування станцій, блок перегляду вимірів та аналітичний блок. Структурна схема розробленого комплексу зображена на рис. 1.

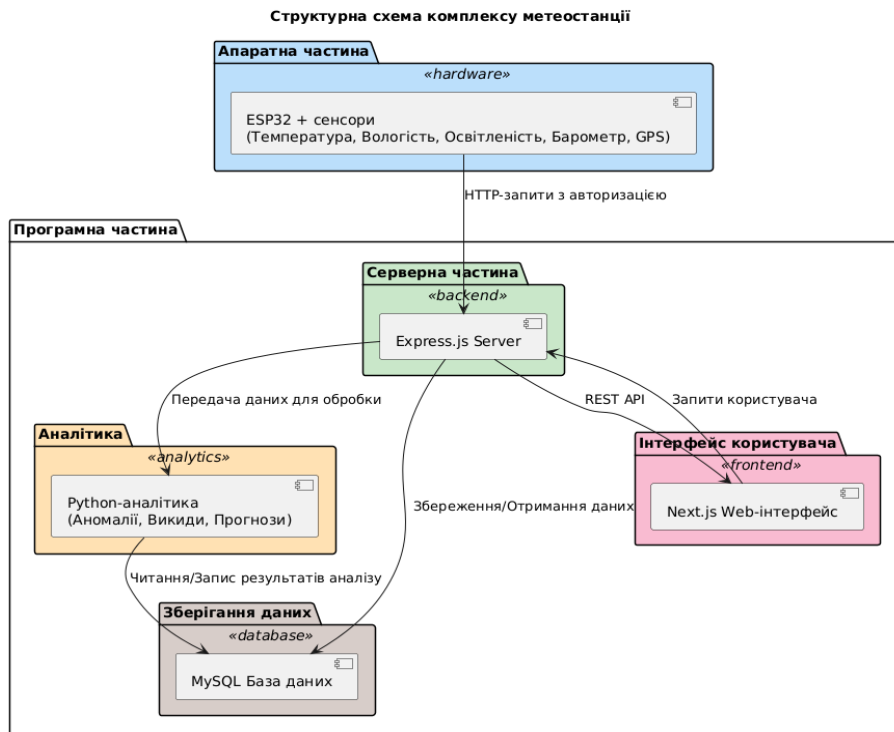


Рисунок 1. Структурна схема програмно-апаратного метеокomплексу.

За допомогою комплексу з прогнозування метеопараметрів здійснюється безперервний збір метеорологічних даних з апаратної частини в режимі реального часу. Отримані дані проходять попередню обробку, що включає фільтрацію шумів, виявлення та корекцію

викидів, після чого вони використовуються для побудови прогнозних моделей температури з високою точністю.

Очищення даних

Для проведення аналізу та прогнозування дані перетворюються у регулярну (gridded) часову сітку з дискретністю 10 хвилин. У випадках відсутності вимірів для певних часових точок утворюються пропуски (NaN), які надалі будуть оброблені методами інтерполяції. У дослідженні передбачається використання набору даних протягом одного місяця, що, враховуючи обрану дискретність вимірювань, забезпечує достатню кількість точок для ефективного навчання та оцінки моделі прогнозування. Відповідний графік з регулярною часовою сіткою наведений на рис. 2.




Рисунок 2. Температурний графік з регулярною часовою сіткою (дискретність 10хв.).

На графіку видно, що через технічні особливості збору даних виникають пропуски. Для одного дня доцільним є застосування сплайнової інтерполяції другого порядку, що дозволяє отримати гладкий сигнал та зберегти локальну структуру коливань.




Рисунок 3. Температурний графік з інтерпольованими даними в межах невеликих пропусків.

Як видно з рис. 3, сплайни ефективно заповнюють локальні прогалини, зберігаючи загальну динаміку та закономірності температурного сигналу. Це відбувається через те, що сплайни апроксимують існуючі точки, враховуючи сусідні значення, завдяки чому зберігається тренди та локальні коливання сигналу без стрибків.

Наступним етапом обробки є заповнення даних тих днів, для яких наявна лише мала кількість вимірів або вони взагалі відсутні. В результаті аналізу структури сигналу було обрано метод зваженої інтерполяції на основі аналогічних часових точок у сусідніх днях. Кожне відсутнє значення оцінюється як зважена середня значень у тих самих часових точках найближчих за датою днів, причому більшу вагу надають більш близьким у часі дням [5].

Такий підхід дозволяє відновити відсутні дані, зберігаючи сезонну та добову структуру сигналу. Відповідний графік зображений на рис. 4.




Рисунок 4. Температурний графік з інтерпольованими даними в межах великих пропусків.

Після виконання всіх вищезазначених етапів попередньої обробки отримано температурний графік. Отриманий графік містить повністю очищені та відновлені значення та може використовуватися як основа для подальшого аналізу та моделювання.

Виявлення викидів та фільтрація

В процесі збору метеорологічних даних часто виникають аномальні значення — викиди, що не відповідають фізичній динаміці сигналу. Причинами їх появи можуть бути технічні збої сенсорів, переривання зв'язку з апаратною частиною або випадкові помилки вимірювання. Викиди суттєво спотворюють статистичні характеристики сигналу, що може призвести до некоректних результатів при прогнозуванні температури або виявленні закономірностей.

Для виявлення аномальних значень у розробленому комплексі використовувались три методи: Z-score, Modifiable Z-score (MZ-score) та IQR (інтерквартильний розмах). Кожен метод застосовується з відповідними порогами ($\max_z=2.5$, $\max_mz=3.5$, $iqr_multiplier=1.5$), що дозволяє виявляти як окремі різкі викиди, так і помірні відхилення від типового сигналу [6]. Виявлені викиди відображаються на графіку (Рис. 5), що дає змогу візуально оцінити їх розподіл у часі та локалізацію. Після ідентифікації такі значення можуть бути виключені або скориговані під час попередньої обробки даних, що забезпечує більш точне та надійне прогнозування температури та інших метеопараметрів.




Рисунок 5. Температурний графік з позначеними точками-викидами.

Слід зазначити, що деякі великі піки сигналу визначені методами MZ-score та IQR як викиди, хоча вони частково відображають загальну тенденцію сигналу. Через технічні особливості сенсорів ці екстремальні значення не завжди відображають реальні метеофактори, тому для подальшого аналізу та прогнозування вони потребують фільтрації.

Для попередньої обробки та згладжування сигналу доцільним є застосування каскадної комбінації медіанного фільтра, експоненційного ковзного середнього та звичайного ковзного середнього [7]. Такий підхід поєднує переваги кожного методу:

1. Медіанний фільтр (розмір вікна = 6) ефективно видаляє короточасні сплески та імпульсні викиди, не спотворюючи загальної структури сигналу;
2. Експоненційне ковзне середнє ($\alpha = 0.15$) забезпечує плавне зважування останніх вимірів, дозволяючи швидко реагувати на локальні зміни сигналу, зберігаючи тренд;
3. Класичне ковзне середнє (вікно = 6) додатково згладжує залишкові коливання, забезпечуючи рівномірний сигнал для подальшого прогнозування.

Комбінація цих трьох фільтрів дозволяє ефективно усунути шум та аномалії, зберігаючи фізично значущі особливості сигналу та добову/сезонну структуру метеоданих. Такий каскадний підхід є оптимальним для підготовки даних до моделей прогнозування температури та інших метеопараметрів. Застосування такого фільтра зображено на рис. 6.




Рисунок 6. Профільтрований графік сигналу за допомогою каскадної комбінації медіанного фільтра, експоненційного ковзного середнього та звичайного ковзного середнього.

Застосований каскадний фільтр ефективно усуває високочастотні коливання сигналу, роблячи графік майже безшумним, при цьому зберігається загальна форма та динаміка температурного сигналу.

Для порівняння нижче наведено результат застосування фільтра Савітського–Голая третього порядку (рис. 7), який апроксимує сигнал поліномами третього ступеня та обчислює ковзне середнє [8]. Цей метод показав дещо гірший результат, оскільки частина коливань залишилася, що потенційно могла б негативно вплинути на якість навчання прогнозних моделей.




Рисунок 7. Профільтрований графік сигналу за допомогою фільтра Савітського–Голея.

Крім того, на окремих ділянках спостерігається локальне згладжування піків, що призводить до часткової втрати важливих змін у динаміці температури. У підсумку такий метод фільтрації не забезпечує достатнього балансу між придушенням шуму та збереженням тренду, що робить його менш придатним для подальшого навчання моделі.

Побудова LSTM

Для прогнозування температури у режимі реального часу в розробленому комплексі використана LSTM-мережа з багаторівневою обробкою та дельта-цілями, що дозволяє моделі ефективно відображати динаміку сигналу навіть у випадках шумних або неповних даних [9]. Замість прогнозування абсолютних значень температури модель навчається передбачати зміни сигналу на різних горизонтах, що дозволяє зосередитися на темпах змін і зменшити вплив сезонних коливань та локальних шумів. Такий підхід забезпечує більш стабільні та фізично адекватні прогнози (рис. 8).




Рисунок 8. Прогноз моделі в порівнянні з істинними значеннями.

Вхідні ознаки моделі формуються не лише з базових параметрів — температури, вологості, тиску та освітленості, а й з додаткових трансформацій та похідних величин, таких як логарифм освітленості, синус і косинус години доби, а також різниці між послідовними значеннями параметрів (*pressure_diff*, *humidity_diff*, *lightness_diff*). Це дозволяє моделі відстежувати локальні тренди та динаміку коливань сигналу, зберігаючи фізично значущі структури та добові й сезонні закономірності.

Архітектура мережі побудована таким чином, щоб максимально враховувати складні взаємозв'язки між ознаками. Bidirectional LSTM дозволяє мережі аналізувати сигнал як у напрямку часу вперед, так і назад, що важливо для метеосигналів, де короточасні зміни часто

залежать від локальної тенденції в обох напрямках. Dropout-шар після LSTM застосовується для регуляризації, зменшуючи кореляцію між нейронами та запобігаючи перенавчанню. BatchNormalization нормалізує проміжні представлення сигналу, покращуючи стабільність та швидкість навчання, а Dense-шари на виході перетворюють багатовимірне представлення LSTM у прогнози дельти температури для кількох горизонтів, з нелінійною трансформацією ReLU для захоплення складних патернів [10].

Попередня обробка даних включає стандартизацію ознак (StandardScaler), фільтрацію шумів та заповнення пропусків, що забезпечує адекватну якість сигналу для навчання. Використання похідних ознак і дельта-цілей дозволяє моделі «ловити» суттєві закономірності сигналу, а не поверхневі коливання. Параметри побудованої моделі подані в таблиці 1.

Таблиця 1 – Параметри побудованої LSTM для прогнозування метеопараметрів

Параметр	Пояснення
Вікно історичних даних window	Визначає кількість попередніх часових кроків, які подаються на вхід моделі для передбачення майбутньої температури.
Ознаки (features): temp_smooth, humidity, pressure, lightness_log, hour_sin, hour_cos, pressure_diff, humidity_diff, lightness_diff	Включають основні метеопараметри та їх трансформації, що допомагають мережі враховувати тенденції та добові цикли.
Bidirectional LSTM, 128 нейронів, return_sequences=True	Дозволяє мережі одночасно аналізувати послідовність в обох напрямках та передавати повну послідовність далі для наступних шарів.
Dropout 0.3 після першого LSTM	Зменшує ризик перенавчання шляхом випадкового виключення 30% нейронів під час тренування.
BatchNormalization після першого LSTM	Нормалізує вихідні значення шару, що стабілізує та прискорює процес навчання.
LSTM 64 нейрони, return_sequences=False	Другий рекурентний шар підсумовує інформацію по всій послідовності для формування компактного представлення ознак.
Dropout 0.3 після другого LSTM	Додатково зменшує перенавчання другого LSTM шару, підвищуючи узагальнювальну здатність моделі.
Dense 64 нейрони, активація ReLU	Щільний шар для нелінійної обробки ознак і підготовки до фінального прогнозного вектора.
Dense 8 нейронів на виході	Вихідний шар формує прогнози зміни температури для 8 часових кроків вперед (3–24 години).
Оптимізатор Adam, learning rate 0.001	Використовується для адаптивного оновлення ваг моделі під час навчання з оптимальним кроком.
Функція втрат: MSE	Оцінює точність прогнозів, мінімізуючи середній квадрат різниці між передбаченим та реальним значенням температури.
Callbacks: EarlyStopping, ReduceLROnPlateau	Дозволяють автоматично зупинити навчання при відсутності покращення та зменшувати швидкість навчання для досягнення кращої конвергенції.
Епохи навчання: 70	Кількість проходів через весь навчальний набір даних під час тренування моделі.
Розмір пакета (batch size): 32	Визначає кількість зразків,

	оброблюваних одночасно перед оновленням ваг моделі.
--	---

На прикладі прогнозу на середину наявного сигналу (рис. 8) видно, що модель здатна точно відтворювати реальні коливання температури, зберігаючи форму сигналу та локальні тенденції. Прогноз на майбутнє (рис. 9) демонструє стабільність та адекватність моделі навіть для невідомих значень, що є критично важливим для прогнозування на рівні станцій.




Рисунок 9. Прогноз моделі.

Обраховані метрики якості прогнозу показують високу точність: $MAPE = 3.07$, $MSE = 0.182$, $R^2 = 0.952$, що свідчить про низьку середню відносну помилку, невелике середнє квадратичне відхилення та високу пояснювальну здатність моделі. Графік навчання моделі, зображений на рис. 10 демонструє зміну функції втрат для тренувальної та валідаційної вибірки ($loss$ та val_loss).




Рисунок 10. Графік навчання моделі.

Як видно, обидві криві майже збігаються, що свідчить про стабільне навчання без перенавчання та адекватну здатність моделі узагальнювати знання на нові дані. Невеликі коливання функції втрат на валідації відповідають природному шуму в метеоданих і не впливають на точність прогнозів. Така поведінка підтверджує ефективність використаних методів регуляризації (Dropout, BatchNormalization) та якісну підготовку вхідних ознак.

ВИСНОВКИ.

У цьому дослідженні було розроблено неймережну технологію прогнозування метеорологічних параметрів на основі даних IoT-метеостанцій. Дані попередньо очищувалися: малі пропуски інтерполювалися сплайнами, а великі проміжки відновлювалися за допомогою day-weighted k-neighbors. Результати фільтрації різних методів порівнювалися, і було обрано той, який забезпечує гладкість та зберігає тренд сигналу. Після цього навчено модель із каскадною LSTM-архітектурою та розширеним набором ознак, що дозволило отримати високоточні прогнози метеопараметрів з високою точністю ($MAPE = 3.07$, $MSE = 0.182$, $R^2 = 0.952$).

У перспективі планується розширення підтримки сенсорів комплексу, що дозволить інтегрувати нові типи вимірювальних пристроїв, а також розширення функціоналу аналітичного модуля, включаючи прогнозування додаткових метеопараметрів та вдосконалення методів виявлення аномалій, що підвищить універсальність системи і її застосування для комплексного моніторингу погодних умов у реальному часі.

СПИСОК ПОСИЛАНЬ.

1. Esposito, A., Faundez-Zanuy, M., Morabito, F. C. *Intelligent Environmental Monitoring for Smart Cities : дослідження* / A. Esposito, M. Faundez-Zanuy, F. C. Morabito. – IEEE Internet of Things Journal, 2018. – Vol. 5, Is. 3. – P. 1421–1429.
2. Warner, T. T. *Numerical Weather and Climate Prediction : навч. посіб.* / T. T. Warner. – Cambridge : Cambridge University Press, 2010. – 550 с.
3. Sreelakshmi, K., Prema Sudha, P. *Weather Forecasting using LSTM and ARIMA : дослідження* / K. Sreelakshmi, P. Prema Sudha. – International Conference on Intelligent Computing and Control Systems (ICICCS), 2019. – P. 1318–1322.
4. Naik, N. *Choice of effective messaging protocols for IoT systems: MQTT, CoAP, AMQP and HTTP : дослідження* / N. Naik. – IEEE International Systems Engineering Symposium (ISSE), 2017. – P. 1–7.
5. Lepot, M., Aubin, J. B., Clemens, F. H. *Interpolation in Time Series: An Introductory Overview of Existing Methods, Their Performance Criteria and Uncertainty Assessment : огляд* / M. Lepot, J. B. Aubin, F. H. Clemens. – Water, 2017. – Vol. 9, Is. 10. – P. 796.
6. Blázquez-García, A., et al. *A Review on Outlier/Anomaly Detection in Time Series Data : огляд* / A. Blázquez-García, J. A. Camacho, R. B. Morales, F. Herrera. – ACM Computing Surveys, 2021. – Vol. 54, Is. 3. – P. 1–33.
7. Сміт, С. *Цифрова обробка сигналів: практичний посібник для інженерів і науковців : навч. посіб.* / С. Сміт. – К. : Наукова думка, 2019. – 450 с.
8. Savitzky, A., Golay, M. J. E. *Smoothing and Differentiation of Data by Simplified Least Squares Procedures : стаття* / A. Savitzky, M. J. E. Golay. – Analytical Chemistry, 1964. – Vol. 36, № 8. – P. 1627–1639.
9. Hochreiter, S., Schmidhuber, J. *Long Short-Term Memory : стаття* / S. Hochreiter, J. Schmidhuber. – Neural Computation, 1997. – Vol. 9, Is. 8. – P. 1735–1780.
10. Шолле, Ф. *Глибоке навчання на Python : навч. посіб.* / Ф. Шолле. – Харків : Фабула, 2019. – 400 с.

УДК 004.42:519.8

Мельников О.Ю., Козуб Д.С. (Донбаська державна машинобудівна академія, м. Краматорськ-Тернопіль, Україна).

ЗАСТОСУВАННЯ НЕЙРОННИХ МЕРЕЖ ДЛЯ ДОСЛІДЖЕННЯ ВПЛИВУ РІЗНИХ ФАКТОРІВ НА РІВЕНЬ ЗАХВОРЮВАНOSTІ ПІД ЧАС ПАНДЕМІЇ.

Анотація. У статті представлено комплексний аналіз впливу карантинних, соціально-економічних та кліматичних факторів на рівень захворюваності під час пандемії інфекційних хвороб, зокрема COVID-19. Для дослідження застосовано штучні нейронні мережі, що дають можливість моделювати складні нелінійні взаємозв'язки між вхідними та вихідними показниками. Роботу виконано у двох напрямках: перший спрямовано на оцінювання ефективності різних карантинних заходів, другий — на дослідження впливу соціально-кліматичних умов у низці країн із різними рівнями розвитку та демографічними характеристиками. Створені моделі було оптимізовано шляхом добору

параметрів кількості прихованих шарів та нейронів, що забезпечило високу точність прогнозування. Отримані результати демонструють, що найбільший вплив на зменшення захворюваності серед адміністративних заходів має обов'язкова вакцинація, тоді як інші фактори мають опосередкований або корельований характер. Соціально-економічні та кліматичні параметри також відіграють суттєву роль у формуванні епідеміологічної ситуації. Застосовані нейромережні підходи підтвердили свою ефективність як інструмент підтримки прийняття рішень у сфері громадського здоров'я, а також довели можливість їх використання для моделювання, прогнозування та порівняння сценаріїв поширення інфекцій.

Ключові слова: нейронні мережі, пандемія, фактори впливу, карантинні заходи, прогнозування, захворюваність.

Abstract. The article presents a comprehensive analysis of the impact of quarantine, socio-economic, and climatic factors on morbidity during a pandemic of infectious diseases, particularly COVID-19. Artificial neural networks were used to model complex nonlinear relationships between input and output indicators. The study was conducted in two directions: the first focused on evaluating the effectiveness of various quarantine measures, while the second examined the influence of socio-climatic conditions in several countries with diverse development levels and demographic characteristics. The constructed models were optimized through adjustment of the number of hidden layers and neurons, ensuring high forecasting accuracy. The results show that mandatory vaccination has the strongest effect on reducing morbidity among administrative measures, whereas other factors have indirect or correlated influence. Socio-economic and climatic parameters also play a significant role in shaping epidemiological dynamics. The implemented neural-network-based approaches demonstrated their effectiveness as a tool for supporting public-health decision-making and proved suitable for modelling, forecasting, and comparing infection-spread scenarios.

Keywords: neural networks, pandemic, influencing factors, quarantine measures, forecasting, morbidity.

Інфекційні захворювання, також відомі як трансмісивні хвороби, являють собою патологічні стани, викликані патогенними мікроорганізмами, такими як бактерії, віруси, грибки або паразити. Ці захворювання можуть передаватися від одного організму до іншого різними шляхами.

Захворювання, викликані інфекцією, займають 20-40% від загального числа відомих науці хвороб людини. На сьогодні науці відомо понад 1200 інфекційних хвороб та їх число регулярно збільшується. Вивченням, профілактикою, діагностикою та лікуванням таких хвороб займаються як лікарі – інфекціоністи, так і – урологи, венерологи, епідеміологи, гінекологи, фтизіатри, імунологи, отоларингологи, вірусологи та ін. [1].

Однієї з найбільш відомих вірусом останнім часом було захворювання COVID-19. Це вірус, який спричиняє розвиток респіраторних захворювань у людей (зокрема гострої респіраторної хвороби COVID-19) та може передаватися від людини до людини. Цей вірус уперше був ідентифікований під час розслідування спалаху в м. Ухань, Китай, у грудні 2019 року [2].

Існує безліч факторів, які впливають на захворюваність населення:

- ІРЛР – інтегральний показник людського розвитку, який використовується для оцінки досягнень окремих регіонів;
- характеристика домогосподарств;
- соціальна компонента;
- поселенська структура;
- зайнятість населення;
- доходи населення;
- витрати населення;
- споживання харчових продуктів у домогосподарствах;
- заклади освіти та їх наповненість;
- підвищення кваліфікації;
- забезпечення населення закладами культури;
- житловий фонд та забезпеченість житлом;

- туризм;
- криміногенні обставини та багато інших.

Тому основною метою дослідження є дослідити вплив основних факторів на захворюваність населення методом штучних нейронних мереж. Було вирішено досліджувати окремо фактори введення різних карантинних дій та соціально-економічних.

Для дослідження впливу запровадження різних карантинних дій на захворюваність вхідними факторами є:

- обов'язковий «масковий режим» ;
- введення карантину, тобто скасування масових заходів, встановлення антисептиків у всіх адміністративних закладах тощо;
- введення дистанційного навчання у навчальних закладах;
- можливість вільної вакцинації;
- запровадження обов'язкової вакцинації;
- відсоток вакцинованих.

Вихідні фактори:

- зміна відсотка інфікованих;
- зміна відсотка тих, хто переносить хворобу у тяжкій формі.

Дані було взято з ресурсу [3] та підготовлено для подальшого аналізу.

Region1	Masks	Distance_Le	Vaccine_optic	Vaccination_	Percentage_o	Infected	Severe_cases
Kyivskyi	1	0	1	0	11,98	42,12	17,00
Kyivskyi	1	1	0	0	20,15	38,62	13,80
Kyivskyi	1	1	1	0	44,22	24,13	9,30
Kyivskyi	1	1	1	1	47,28	13,53	5,00
Donetsk	0	0	0	0	7,20	29,74	16,10
Donetsk	1	1	0	0	9,06	18,12	12,10
Donetsk	1	1	1	0	13,67	11,62	8,70
Donetsk	1	1	1	1	15,59	5,49	5,90
Dnipro	0	0	0	0	18,74	36,12	15,90
Dnipro	1	1	0	0	36,12	24,35	14,10

Рисунок 1 – Вхідні фактори для першого дослідження

Для проведення розрахунків було використано мову програмування та аналізу даних R [4]. Ця мова призначена для статистичного оброблення даних і роботи з графікою, але це також вільне програмне середовище з відкритим вихідним кодом, що розвивається в рамках проєкту GNU.

Кількість нейронів прихованого шару пов'язана з кількістю даних для навчання та необхідною кількістю входів і виходів мережі. Оцінити кількість нейронів у прихованих шарах можна за допомогою формули для оцінки кількості вагових коефіцієнтів, необхідної для освоєння заданої кількості прикладів у навчальній вибірці [5].

Після численних запусків цього скрипту для різних параметрів кількості прихованих шарів та кількості нейронів у них з'ясовано, що найкращий результат (кореляція – 0,9569; середня абсолютна приведена помилка – 0,0502) забезпечує персептрон з двома прихованими шарами та п'ятьма нейронами у кожному шарі (рис. 2, рис. 3).




Рисунок 2 – Граф нейронної мережі

```
> w2
      R M D V Z      P      I      S      res      error
4      kyivskyi 1 1 1 1 47.28 13.53  5.0 13.69 -0.0037170
11     Dnipro 1 1 1 0 40.48 15.24  8.1 19.63 -0.1031001
13     kharkiv 0 0 0 0 13.86 37.14 15.9 41.23 -0.0958731
16     kharkiv 1 1 1 1 42.05 11.84  6.9 13.95 -0.0495643
19     odesa 1 1 1 0 32.28 19.78  9.8 21.57 -0.0420305
23     Lviv 1 1 1 0 36.23 22.70 11.1 20.48  0.0521543
28     poltava 1 1 1 1 46.34 14.76  5.1 13.73  0.0242580
30     zaporozhye 1 1 0 0 29.80 29.30 15.8 28.42  0.0206866
32     zaporozhye 1 1 1 1 36.32 13.93  7.2 14.44 -0.0120317
34     vinnytsia 1 1 0 0 25.30 27.80 11.1 30.91 -0.0729039
36     vinnytsia 1 1 1 1 38.32 10.21  5.4 14.24 -0.0945886
43     cherkasy 1 1 1 0 39.80 25.60  9.8 19.75  0.1373223
46     mykolaivskyi 1 1 0 0 26.80 29.40 13.1 30.05 -0.0153136
48     mykolaivskyi 1 1 1 1 36.92 14.35  5.8 14.38 -0.0006563
49     sumy 0 0 0 0 18.90 39.90 15.9 39.12  0.0182757
54     zhytomyrskyi 1 1 0 0 24.10 29.50 13.5 31.59 -0.0491420
56     zhytomyrskyi 1 1 1 1 38.35 16.84  5.8 14.24  0.0610733
> cor(w2$I, w2$res)
[1] 0.9569
```

Рисунок 3 – Результати розрахунків

Далі саме цю модель було використано для дослідження впливу факторів на захворюваність. Було проведено низку кількісних експериментів, результати зведено до табл. 1.

Таблиця 1 – Результати впливу на відсоток інфікованих вилучення факторів

M	D	V	Z	P	Кореляція	Середня помилка	Відхилення від базової моделі
+	+	+	+	+	0,9569	0,0502	—
—	+	+	+	+	0,9584	0,0894	78%
+	—	+	+	+	0,9599	0,0895	78%

+	+	–	+	+	0,9678	0,078	55%
+	+	+	–	+	0,9526	0,1009	101%
+	+	+	+	–	0,961	0,0921	83%
–	–	+	+	+	0,9756	0,0621	24%
+	–	–	+	+	0,9545	0,0795	58%
+	+	–	–	+	0,958	0,1232	145%
+	+	+	–	–	0,9687	0,1235	146%

Можна побачити, що найменший вплив на точність визначення зміни відсотка інфікованих вносить наявність можливості вільної вакцинації або пара «обов'язковий масковий режим» + «запровадження дистанційного навчання у навчальних закладах» – вочевидь, ці два фактори максимально корелюють один з одним. Максимальний вплив – у запровадження обов'язкової вакцинації.

Другим дослідження був вплив саме соціально – кліматичних факторів. Для дослідження будемо використовувати такі країни: Бразилія, Німеччина, Японія, Україна, США. Перелік можливих вхідних та вихідних факторів наведено в табл. 2.

Таблиця 2 – Перелік факторів

Тип фактору	Назва	Опис	Тип даних	Призначення	Скорочення
Вхідний	Кліматичні умови	Дані про середньомісячну температуру, вологість, кількість опадів у регіоні	Числовий (°C, %, мм)	Для аналізу впливу клімату на захворюваність	T, Vol, Op
Вхідний	Вік населення	Середній вік або розподіл за віковими категоріями	Числовий (роки)	Врахування впливу вікових груп на ризик захворюваності	Age
Вхідний	Густота населення	Кількість осіб на квадратний кілометр	Числовий (осіб/км²)	Аналіз впливу густоти населення на розповсюдження захворювань	G
Вхідний	Перелік протиепідемічних заходів	Інформація про використані заходи: карантин, вакцинація, обмеження мобільності. Розподілимо на рівні: 1 рівень: масове тестування; 2 рівень: 1 рівень + карантин, вакцинація; 3 рівень: 2 рівень + обмеження масових заходів та подорожей	Текстовий	Оцінка ефективності різних протиепідемічних заходів	PZ
Вхідний	Чисельність населення	Загальна кількість осіб у регіоні	Числовий (осіб)	Аналіз загального впливу розміру	CN

				популяції на рівень захворюванос ті	
Вхідний	Соціально- економічні умови	Рівень доходів, доступ до медичних послуг (розподілимо на групи: 1 – високий рівень: Високий рівень доходів, відмінний доступ до медичних послуг, 2 рівень – середній рівень: Високий рівень доходів, широкий доступ до медичних послуг, 3 рівень – низький: Середній рівень доходів, обмежений доступ до медичних послуг у віддалених районах)	Категорій ний	Врахуванн я впливу умов життя на тяжкість перебігу та частоту захворюва ності	E
Вхідний	Рівень вакцинації	Відсоток населення, що отримало вакцинацію	Кількість вакцинов аних за даний період	Аналіз впливу вакцинації на рівень захворюва ності	V
Вихідний	Рівень захворювано сті	Частка населення, що захворіла за певний період	Числовий , кількість випадків на мільйон осіб	Прогнозува ння загального рівня захворюва ності	Z
Вхідний	Сукупна кількість підтверджен их смертей від COVID- 19 на мільйон людей	Кількість підтверджених смертей/ мільйон	Числовий , кількість випадків на мільйон осіб	Аналіз впливу смертності на рівень захворюва ності	Sm

Після численних запусків цього скрипту для різних параметрів кількості прихованих шарів та кількості нейронів у них з'ясовано, що найкращий результат (середня абсолютна приведена помилка – 0,03684) забезпечує персептрон з двома прихованими шарами та п'ятьма нейронами у кожному шарі [7–8].

[illegible]

Рисунок 4 – Файл з вхідними даними в Excel




Рисунок 5 – Граф нейронної мережі

	T	VoI	Op	Age	G	PZ	CN	E	V	Z	Sm
4	21.8	82	0.34884	32.68	25.26	0.5	0.55780	1.0	0.0149758	7.009e-08	0.000e+00
6	24.7	78	0.16279	32.68	25.26	0.5	0.55780	1.0	0.0935990	2.846e-03	1.142e-02
7	24.4	77	0.11628	32.68	25.26	0.5	0.55780	1.0	0.1316425	1.755e-02	4.765e-02
9	24.8	80	0.25581	32.68	25.26	0.5	0.55780	1.0	0.2458937	9.166e-02	1.530e-01
11	23.7	83	0.48837	32.68	25.26	0.5	0.55780	1.0	0.5417874	1.615e-01	2.313e-01
12	23.8	84	0.53488	32.68	25.26	0.5	0.55780	1.0	0.6719807	1.851e-01	2.604e-01
14	26.5	84	0.53488	33.10	25.07	0.5	0.56076	1.0	0.8253623	2.572e-01	3.186e-01
20	23.2	80	0.16279	33.16	25.07	1.0	0.56076	1.0	0.9716184	6.246e-01	8.484e-01
23	26.4	84	0.48837	33.19	25.07	1.0	0.56076	1.0	0.9891304	7.126e-01	9.716e-01
26	3.2	88	0.18605	44.88	239.93	1.0	0.14170	0.5	0.0000000	0.000e+00	0.000e+00
27	2.0	90	0.25581	44.88	239.93	1.0	0.14170	0.5	0.0000000	0.000e+00	0.000e+00
31	14.5	73	0.00000	44.88	239.93	1.0	0.14170	0.5	0.0981884	1.369e-02	8.314e-03
32	18.0	76	0.04651	44.88	239.93	1.0	0.14170	0.5	0.2434783	1.518e-02	3.471e-02
35	16.0	80	0.16279	44.88	239.93	1.0	0.14170	0.5	0.7321256	2.030e-02	3.833e-02
38	3.5	89	0.23256	44.92	240.12	1.0	0.14193	0.5	0.8228261	8.855e-02	5.410e-02
42	9.0	79	0.06047	44.92	240.12	1.0	0.14193	0.5	0.9067633	2.412e-01	3.150e-01
44	17.8	78	0.06977	44.92	240.12	1.0	0.14193	0.5	0.9097826	3.066e-01	3.665e-01
49	6.8	87	0.18605	44.92	240.12	1.0	0.14193	0.5	0.9124396	3.848e-01	3.898e-01
50	3.4	88	0.20930	45.02	241.24	1.0	0.14323	0.5	0.9126812	5.175e-01	4.433e-01
52	2.8	63	0.06977	47.67	335.18	0.5	0.28373	0.0	0.0000000	0.000e+00	0.000e+00
54	3.2	63	0.09302	47.67	335.18	1.0	0.28373	0.0	0.0000000	1.592e-05	1.367e-05
55	7.5	66	0.20930	47.67	335.18	1.0	0.28373	0.0	0.0018116	1.834e-04	1.559e-04

Рисунок 6 – Результати розрахунків

ВИСНОВКИ

В ході роботи встановлено, що різні фактори по-різному впливають на рівень захворюваності. Найбільший вплив серед карантинних заходів має обов'язкова вакцинація, тоді як деякі інші параметри відіграють другорядну роль. Соціально-економічні та кліматичні умови також значно впливають на поширення хвороби. Штучні нейронні мережі показали високу точність і придатність для прогнозування, а тому можуть бути ефективним інструментом у моделюванні інфекційних процесів та підтримці управлінських рішень у сфері охорони здоров'я.

СПИСОК ПОСИЛАНЬ.

1. Інфекційні хвороби. Дніпровський центр громадського здоров'я. URL: <https://dniprophc.com.ua/gromadyanam/profilakika-zahoruvan/%D1%96nfekc%D1%96jn%D1%96-hvorobi/>
2. Центр громадського здоров'я України. Коронавірусна інфекція COVID-19. URL: <https://phc.org.ua/kontrol-zakhvoryuvan/inshi-infekciyni-zakhvoryuvannya/koronavirusna-infekciya-covid-19>
3. Коронавірус в Україні — статистика та карта заражень. URL: <https://index.minfin.com.ua/ua/reference/coronavirus/ukraine> (дата звернення: 21.04.2025).
4. Мельников О. Ю. R — мова програмування та аналізу даних: навчальний посібник. Краматорськ: ДДМА, 2023. 272 с.
5. Гіміс В. Б. Нейромережні технології: навчальний посібник. Краматорськ: ДДМА, 2021. 248 с.
6. World Health Organization. WHO COVID-19 Dashboard. URL: <https://covid19.who.int/>
7. Козуб Д. С., Мельников О. Ю. Постановка задачі дослідження впливу різних факторів на рівень захворюваності під час пандемії // Розвиток науки – простір для відновлення регіону: збірник тез наукової конференції молодих вчених 19 грудня 2024 р., – м. Краматорськ: Донецька обласна державна адміністрація, Рада молодих вчених при Донецькій облдержадміністрації, 2024. – С. 86–88.
8. Мельников О. Ю., Козуб Д. С. Дослідження впливу різних факторів на рівень захворюваності під час пандемії за допомогою штучних нейронних мереж і мови програмування та аналізу даних R // Вісник Національного технічного університету «ХПІ». Серія: Системний аналіз, управління та інформаційні технології: зб. наук. пр. / Нац. техн. ун-т «Харків. політехн. ін-т». – Харків : НТУ «ХПІ», 2025. – № 1 (13). – С. 40–45. – ISSN 2079-0023. – DOI: <https://doi.org/10.20998/2079-0023.2025.01.06>

Мельников О.Ю., Шиманська С.А. (Донбаська державна машинобудівна академія, м. Краматорськ-Тернопіль, Україна).

ВИКОРИСТАННЯ ШТУЧНИХ НЕЙРОННИХ МЕРЕЖ ДЛЯ ПРОГНОЗУВАННЯ ОБИРАННЯ ДИСЦИПЛІН ВІЛЬНОГО ВИБОРУ ЗДОБУВАЧАМИ ОСВІТИ.

Анотація. У статті розглянуто проблему підвищення ефективності процесу вибору студентами дисциплін вільного вибору шляхом застосування інтелектуальних методів аналізу даних. Метою роботи є створення рекомендаційної системи на основі штучних нейронних мереж, здатної прогнозувати вибір дисциплін з урахуванням інтересів студентів, їхньої академічної успішності та освітніх пріоритетів. Для досягнення цієї мети побудовано багатошарову перцептронну нейромережу, реалізовану за допомогою Python та бібліотек TensorFlow, Keras, Scikit-learn, Pandas і NumPy. Модель використовує чотири ключові ознаки — стать студента, середній бал з технічних предметів, середній бал з гуманітарних дисциплін і оцінки зі спортивної підготовки. Вихідний шар охоплює п'ять можливих варіантів дисциплін, що пропонуються студентам спеціальності 126 «Інформаційні системи та технології». Проведено порівняння роботи нейромережі з сімома популярними алгоритмами машинного навчання. Результати дослідження засвідчили, що нейромережна модель досягла найвищої точності — 85,7%, що значно перевищує показники альтернативних підходів. Додатково використано трьохфолдову крос-валідацію, яка підтвердила стабільність та узагальнювальну здатність моделі. Отримані результати засвідчують перспективність використання нейронних мереж як інструменту для підтримки прийняття рішень та персоналізації освітніх траєкторій.

Ключові слова: нейронні мережі, рекомендаційні системи, прогнозування, вибір дисциплін, машинне навчання.

Abstract. The article examines the problem of improving the process of selecting elective academic courses by applying intelligent data analysis methods. The aim of the study is to develop a recommendation system based on artificial neural networks capable of predicting students' course choices according to their interests, academic achievements and educational priorities. To achieve this goal, a multilayer perceptron neural network was constructed and implemented using Python and the TensorFlow, Keras, Scikit-learn, Pandas and NumPy libraries. The model uses four key features—gender, average grade in technical subjects, average grade in humanities, and performance in physical education. The output layer represents five possible elective courses offered to students majoring in Information Systems and Technologies. A comparative analysis was conducted between the neural network and seven popular machine-learning algorithms. The results showed that the neural network achieved the highest accuracy—85.7%, significantly outperforming all alternative approaches. Additionally, three-fold cross-validation was applied, confirming the model's stability and generalization ability. The findings demonstrate the potential of neural networks as an effective tool for decision support and personalization of educational trajectories.

Keywords: neural networks, recommendation systems, prediction, elective courses, machine learning.

Створення інтелектуальних систем адаптивного навчання на основі штучного інтелекту є перспективним напрямом для освіти [1]. Ключовим інструментом у цій галузі виступають штучні нейронні мережі.

Штучні нейронні мережі є потужним інструментом для моделювання нелінійної поведінки, зокрема у сфері освіти. Вони здатні розпізнавати та аналізувати навчальні здібності здобувачів освіти шляхом обробки інформації про їхнє навчання [2]. Здатність нейромереж враховувати інтереси та вподобання студентів відкриває нові можливості для прогнозування та рекомендації дисциплін вільного вибору.

Основною метою є розробка інтелектуальної системи рекомендацій, яка на основі машинного навчання (зокрема, нейромереж) та аналізу даних допомагатиме студентам обирати оптимальні дисципліни. Для цього система може аналізувати дані про успішність студента (оцінки за попередні дисципліни), його інтереси, кар'єрні плани та зворотний зв'язок від інших

студентів [3]. Оскільки рівень засвоєння нових знань значною мірою залежить від базового рівня знань [4], оцінки студентів є критично важливим вхідним елементом для прогнозування.

У цій роботі для прогнозування вибору дисциплін (PREDMET) використовується багаторівнева перцептронна нейронна мережа, реалізована за допомогою Python та таких бібліотек, як TensorFlow (версія 2.17.1), Keras (версія 3.5.0), Scikit-learn (версія 1.5.2), Pandas (версія 2.2.2), NumPy, Matplotlib (версія 3.8.0) та Seaborn. TensorFlow є потужною бібліотекою для машинного навчання від Google, що надає інструменти для побудови та навчання нейронних мереж, а Keras, інтегрований у TensorFlow, забезпечує високорівневий API для швидкої розробки різноманітних архітектур. Scikit-learn використовується для підготовки даних та оцінки моделей, Pandas та NumPy – для обробки та аналізу даних, а Matplotlib та Seaborn – для візуалізації результатів [5].

Архітектура нейронної мережі побудована як багаторівневий перцептрон з трьома повнозв'язними шарами (рис. 1). Вхідний шар приймає інформацію про студентів (4 числові ознаки): стать (SEX), середній бал з технічних предметів (TEX), середній бал з гуманітарних предметів (HUM) та середній бал зі спортивних дисциплін (SPRT). Перший прихований шар містить 64 нейрони, що дозволяє мережі виявляти складні нелінійні залежності між ознаками, а другий прихований шар зі 32 нейронами уточнює та конкретизує ці закономірності.

На виході мережа має 5 нейронів – по одному для кожної можливої категорії класифікації (PREDMET), що забезпечує охоплення всіх цільових класів. Для перетворення вихідних сигналів у ймовірнісний розподіл використовується функція активації Softmax [6], яка нормалізує результати та дозволяє інтерпретувати їх як ймовірності належності до кожного з класів. Приховані шари використовують нелінійну функцію активації ReLU (Rectified Linear Unit)[7], що дозволяє моделі навчатися складних залежностей у даних.

Загальна кількість параметрів моделі становить 2565. Для оптимізації процесу навчання використовується алгоритм Adam, а функція втрат Categorical Crossentropy забезпечує точну оцінку розбіжностей між передбаченими та фактичними розподілами ймовірностей, що робить модель ефективною для прогнозування вибору дисциплін студентами та розпізнавання складних паттернів у даних.

Формула розрахунку параметрів для повнозв'язного шару:

$$\text{Параметри} = \underbrace{(\text{входи} \times \text{нейрони})}_{\text{ваги}} + \underbrace{\text{нейрони}}_{\text{зсуви}}$$

Кожен нейрон у новому шарі отримує сигнал від кожного нейрона попереднього шару. Кожне з'єднання має свою вагу – коефіцієнт, який показує "важливість" цього зв'язку (вагу). Кожен нейрон у новому шарі має додатковий параметр – зсув. Це константа, яка додається до суми всіх вхідних сигналів, дозволяє нейрону "активуватися" навіть коли всі входи = 0.

Розрахуємо складність нашої нейромережі:

1. Перший шар (320 параметрів)

4 вхідні ознаки пов'язуються з 64 нейронами

Кожен зв'язок має свою вагу + кожен нейрон має своє зміщення

Разом: $4 \times 64 + 64 = 320$

2. Другий шар (2080 параметрів)

64 нейрони попереднього шару пов'язуються з 32 нейронами нового шару : $64 \times 32 + 32 = 2080$

3. Вихідний шар (165 параметрів)

32 нейрони переходять у 5 вихідних нейронів $32 \times 5 \text{ ваг} + 5 \text{ зсувів} = 165$

Сумарно: $320 + 2080 + 165 = 2565$

Коли "модель навчається" – вона підбирає оптимальні значення цих 2565 параметрів, щоб робити точні прогнози!




Рисунок 1 – Архітектура нейромережі

Дослідження (навчання нейромережі та подальше прогнозування) проводилося на даних про студентів Факультету автоматизації машинобудування та інформаційних технологій Донбаської Машинобудівної Академії. Для спеціальності 126 «Інформаційні системи та технології» на другому курсі навчання студентам пропонуються такі дисципліни на вибір: етика та естетика, історія науки та техніки, іноземна мова, соціологія, героїчні особистості в Україні (рис. 2).

Було виконано навчання (тренування) нейронної мережі на навчальному наборі даних зі збереженням інформації про зміну показників моделі (втрат і точності) за всі епохи. Ці дані використано для аналізу процесу навчання шляхом побудови графіків.

Метою навчання нейромережі є створення моделі, здатної узагальнювати закономірності в даних та точно прогнозувати результати для нових, невідомих даних. Для аналізу якості навчання досліджувалися динаміка точності та динаміка втрат на кожному етапі навчання. Втрати – це числове значення, що визначає, наскільки прогнози моделі відрізняються від фактичних значень (істинних міток). Мета навчання полягає у мінімізації цього значення, тобто у досягненні максимальної точності прогнозів моделі (рис. 3).




Рисунок 2 – Популярність дисциплін серед студентів на другому курсі навчання за спеціальністю «Інформаційні системи та технології»




Рисунок 3 – Динаміка втрат за епохами

Навчальні втрати показують, наскільки добре модель засвоїла навчальні дані, а перевіркові втрати відображають ефективність моделі на даних, які вона не бачила під час навчання. Отримані результати свідчать про успішне навчання нейронної мережі, оскільки втрати як на навчальному, так і на валідаційному наборах даних послідовно зменшуються зі збільшенням кількості епох.

Точність по епохах – це показник, який відображає, наскільки добре нейронна мережа класифікує або прогнозує результати на кожному етапі навчання. Точність – це частка правильних передбачень від загальної кількості прикладів у вибірці. Вона визначає, наскільки модель правильно класифікує дані або робить прогнози.

Точність обчислюється так:

$$\text{Точність} = \frac{\text{Кількість правильних передбачень}}{\text{Загальна кількість прикладів}}$$

Точність для навчальної вибірки показує, наскільки добре модель передбачає результати на навчальних даних. Якщо модель

"запам'ятовує" дані, то точність на навчальній вибірці дуже висока. Точність для перевіркової вибірки показує, наскільки модель узагальнює свої знання на даних, які не використовуються безпосередньо для коригування ваг. Перевіркова точність важлива для оцінки здатності моделі працювати з новими даними (рис. 4). За нашим графіком ми можемо оцінити, чи покращується модель із кожною епохою.




Рисунок 5 – Динаміка точності за епохами

Для оцінки ефективності та перевірки надійності створеної нейромережної моделі було проведено порівняльне тестування з іншими популярними алгоритмами машинного навчання. Такий підхід дозволяє об'єктивно оцінити, наскільки добре модель справляється з завданням прогнозування порівняно з альтернативними рішеннями.

Для комплексної оцінки ефективності нейромережної моделі було проведено порівняльний аналіз із популярними алгоритмами машинного навчання. Як еталонні моделі для порівняння було обрано сім різнотипних алгоритмів, що охоплюють основні підходи до класифікації: від традиційних статистичних методів до сучасних ансамблевих технік [8].

В результаті прогнозування за допомогою навченої нейромережі, а також із застосуванням алгоритмів машинного навчання було виявлено, що найвищу ефективність продемонструвала створена нейромережа, яка досягла результату – 85,7% точності. Метод опорних векторів [9] має точність 71,4%, що свідчить про його високу здатність до узагальнення закономірностей у даних. Логістична регресія [10] та метод k-найближчих сусідів [11] показали середні результати на рівні 57,1%, тоді як випадковий ліс [12] забезпечив точність 42,9%. Найнижчі результати спостерігалися у дерева рішень [13] та градієнтного бустингу [14] (28,6%), а наївний Байєс [15] показав мінімальну ефективність – лише 14,3% точності. (рис. 6).




Рисунок 6 – Порівняння передбачень моделей

Низькі результати методів, які зазвичай показують хорошу якість, можуть вказувати на недостатній обсяг даних для їх ефективного навчання. Перевага створеної нейромережі над лінійними методами та іншими алгоритмами свідчить про наявність складних нелінійних взаємозв'язків даних, які успішно виявляє наша архітектура. Оскільки нейромережа значно перевершила всі інші методи, вона є оптимальним вибором для подальшого використання та вдосконалення. Великий розкид результатів (від 14.3% до 85.7%) між різними алгоритмами вказує на особливу природу вхідних даних, що робить вибір правильної архітектури критично важливим фактором успіху.

Крос-валідація є важливим статистичним методом оцінки стабільності та узагальнювальної здатності моделей машинного навчання [16]. На відміну від звичайного тестування на одній розділеній вибірці, крос-валідація передбачає багаторазове розділення даних на навчальну та тестову підвибірки, що дозволяє отримати більш надійну оцінку якості моделі. У даному дослідженні використовувалась 3-фолдова крос-валідація, де вихідні дані розділялись на три рівні частини, а модель навчалась на двох з них та тестувалась на третій, з подальшим усередненням результатів. Цей підхід дозволяє мінімізувати вплив випадкового розподілу даних на оцінку ефективності моделі та виявити її справжню здатність до узагальнення (рис. 7).

Результати крос-валідації підтвердили лідерську позицію створеної нейромережі, яка продемонструвала найвищий середній показник точності – 0.492, що значно перевищує результати інших моделей. Важливо відзначити, що нейромережа також показала найменший розкид результатів (± 0.051), що свідчить про її високу стабільність та незалежність від конкретного розподілу навчальних даних.

До групи моделей з помірною ефективністю увійшли випадковий ліс (0.318), K-найближчих сусідів (0.290), логістична регресія (0.288) та метод опорних векторів (0.288). Хоча ці моделі показали нижчі результати ніж нейромережа, вони продемонстрували достатньо добру стабільність, особливо логістична регресія та метод опорних векторів з однаковим розкидом ± 0.087 . Найнижчі результати спостерігалися у градієнтного бустингу

(0.258), дерева рішень (0.232) та наївного Байєса (0.202). Градієнтний бустинг показав найменший розкид результатів (± 0.011) серед усіх моделей, що свідчить про його високу стабільність, попри відносно низької середньої точності.




Рисунок 7 – Порівняння стійкості моделей за допомогою крос-валідації

Варто відзначити, що крос-валідація виявила деякі відмінності у порівнянні з результатами звичайного тестування. Зокрема, нейромережа значно покращила свою позицію відносно інших моделей, що підтверджує її кращу здатність до адаптації до різних розподілів даних та меншу схильність до перенавчання.

Загалом, результати крос-валідації підтверджують, що нейромережа є найбільш ефективним та стабільним рішенням для даної задачі класифікації, демонструючи як високу точність, так і добру узагальнювальну здатність.

У результаті прогнозування за допомогою навченої нейромережі було опрацьовано 35 варіантів, з яких передбачення збіглися з реальним вибором студентів у 30 випадках та не збіглися у 5 випадках.

Відсоток збігів (точність передбачень): 85.7% (рис. 8). Нейромережа добре передбачила популярність дисциплін. На діаграмі (рис. 9) відображено порівняння прогнозованих результатів нейронної мережі (синій колір) із реальними даними (зелений колір) для обраних студентами дисциплін. Нейромережа в цілому демонструє тенденцію до правильного розподілу прогнозів [17].

Співвідношення збігів і розбіжностей




Рисунок 8 – Точність передбачень




Рисунок 9 – Порівняння спрогнозованих даних із реальними

На гістограмі видно, що модель нейромережі демонструє хорошу відповідність між передбаченими (помаранчевий колір) та реальними (синій колір) значеннями. Також видно, що модель демонструє різну точність прогнозування за різними оцінками. Загалом, точність для більшості дисциплін залишається прийнятною, проте є місце для покращення.

ВИСНОВКИ

У ході дослідження було успішно розроблено та випробувано модель штучної нейронної мережі для прогнозування вибору студентами дисциплін вільного вибору.

Створена багатошарова перцептронна мережа продемонструвала високу прогностичну здатність, досягнувши точності 85,7% на тестових даних. Це свідчить про здатність моделі успішно виявляти складні нелінійні залежності між академічними показниками студентів та їхніми освітніми уподобаннями.

Порівняльний аналіз з сімома альтернативними алгоритмами машинного навчання підтвердив перевагу нейромережі, яка значно перевершила всі інші методи за точністю прогнозування.

Результати 3-фолдової крос-валідації підтвердили високу стабільність нейромережі (середня точність $0,492 \pm 0,051$), що свідчить про її здатність до ефективного узагальнення незалежно від конкретного розподілу навчальних даних.

Модель продемонструвала хорошу здатність до прогнозування популярності різних дисциплін серед студентів, що підтверджується високою відповідністю між передбаченими та реальними результатами вибору (30 з 35 випадків).

Отримані результати вказують на перспективність подальшого вдосконалення моделі шляхом збільшення обсягу навчальних даних, оптимізації архітектури мережі та включення додаткових факторів, що впливають на освітній вибір студентів.

Запропонований нейромережний підхід може бути успішно інтегрований в інтелектуальні системи підтримки прийняття рішень в освітніх закладах для покращення академічного консультування та персоналізації навчального процесу.

СПИСОК ЛІТЕРАТУРИ

1. Наливайко О. О. Перспективи використання нейромереж у вищій освіті України. Інформаційні технології і засоби навчання. 2023. Том 97. №5, 2–3 с. URL: www.researchgate.net/publication/375670837 (Дата звернення 22.10.2025)
2. С. В. Буртовий, В. А. Чубенко, С. В. Василюк-Зайцева Використання нейромереж у розпізнаванні та діагностиці навчальних здібностей здобувачів освіти. Академічні візії. №29, 2024, 2–3 с. URL: <https://academy-vision.org/index.php/av/article/view/971/884> (Дата звернення 22.10.2025)
3. Ahmad A. Kardan, Hamid Sadeghi, *A Decision Support System for Course Offering in Online Higher Education Institutes. International Journal of Computational Intelligence Systems. Volume 6, 2013 – Issue 5, 929 c.* URL: <https://doi.org/10.1080/18756891.2013.808428> (Дата звернення 22.10.2025)
4. О. Ю. Мельников, В. Б. Гіміс, Дослідження впливу якості засвоєння попереднього матеріалу на успішність здобувачів освіти з окремої дисципліни. Вісник НТУ «ХПІ». Серія: Системний аналіз, управління та інформаційні технології. Харків: НТУ «ХПІ», 2022, № 2 (7), 70 с. URL: <https://doi.org/10.20998/2079-0023.2022.01.12> (Дата звернення 22.10.2025)
5. Шиманська С. А., Мельников О. Ю. Нейромережна модель для передбачення обирання освітніх дисциплін здобувачами вищої освіти в залежності від рівня успішності // Комп'ютерні інтелектуальні системи та мережі: Матеріали XVIII Всеукраїнської науково-практичної WEB конференції аспірантів, студентів та молодих вчених (25-27 березня 2025 р.). – Кривий Ріг: Криворізький національний університет, 2025. – С. 265–267
6. Bala Priya C, Softmax Activation Function: Everything You Need to Know URL: <https://www.pinecone.io/learn/softmax-activation> (Дата звернення 22.10.2025)
7. Bharath Krishnamurthy, An Introduction to the ReLU Activation Function URL: <https://builtin.com/machine-learning/relu-activation-function> (Дата звернення 22.10.2025)
8. Мельников О. Ю., Шиманська С. А. Передбачення обирання дисциплін вільного вибору здобувачами освіти за допомогою рекомендаційної системи // Сучасна освіта – доступність, якість, визнання: збірник наукових праць XVII Міжнародної науково-методичної конференції, 12–13 листопада 2025 року, м. Краматорськ-Вінниця-Тернопіль / [за заг. ред. д-ра техн. наук., проф. С. В. Ковалевського і Hon.D.Sc., prof. Predrag Dasic]. – Краматорськ : ДДМА, 2025. – С. 216–219. – ISBN 978-617-7893-14-0
9. Eda Kavlakoglu, What are support vector machines (SVMs)? URL: <https://www.ibm.com/think/topics/support-vector-machine> (Дата звернення 22.10.2025)
10. Fangfang Lee, What is logistic regression? URL: <https://www.ibm.com/think/topics/logistic-regression> (Дата звернення 22.10.2025)

11. Eda Kavlakoglu, What is the k-nearest neighbors (KNN) algorithm? URL: <https://www.ibm.com/think/topics/knn> (Дата звернення 22.10.2025)
12. Niklas Donges, Random Forest: A Complete Guide for Machine Learning. URL: <https://builtin.com/data-science/random-forest-algorithm> (Дата звернення 22.10.2025)
13. Eda Kavlakoglu, What is a decision tree? URL: <https://www.ibm.com/think/topics/decision-trees> (Дата звернення 22.10.2025)
14. Bryan Clark, Fangfang Lee, What is Gradient Boosting? URL: <https://www.ibm.com/think/topics/gradient-boosting> (Дата звернення 22.10.2025)
15. Eda Kavlakoglu, What are Naïve Bayes classifiers? URL: <https://www.ibm.com/think/topics/naive-bayes> (Дата звернення 22.10.2025)
16. Jason Brownlee, A Gentle Introduction to k-fold Cross-Validation URL: <https://machinelearningmastery.com/k-fold-cross-validation> (Дата звернення 22.10.2025)
17. Шиманська С. А., Мельников О. Ю. Розрахунок передбачення обираючи освітніх дисциплін здобувачами вищої освіти в залежності від рівня успішності // Проблеми та перспективи розвитку науки, освіти та технологій в Україні та світі: зб. наук. пр. за матеріалами V Всеукраїнської студентської науково-практичної конференції. м. Бережани, 12 березня 2025. – Бережани: ВСП «Бережанський фаховий коледж НУБіП України», 2025. – С. 167–170. – URL: <https://akrbati.wixsite.com/konf-batk>

B3. Fundamental Social, Educational, Ethical and Regulatory Foundations of AI. Фундаментальні соціальні, освітні, етичні та нормативні основи ШІ

УДК 004.8:378

Бенч А.Я. (Національний університет “Львівська політехніка”, ЕРАМ Україна, м. Львів, Україна).

ВИКОРИСТАННЯ ВЕЛИКИХ МОВНИХ МОДЕЛЕЙ У РОБОТІ ВИКЛАДАЧА ВНЗ.

Анотація. У статті узагальнено досвід використання великих мовних моделей у системі вищої освіти, розглянуто особливості їх застосування у підготовці навчальних матеріалів, організації навчального процесу та підтримці індивідуальних траєкторій навчання. Проаналізовано сучасні можливості мультимодальних моделей, їх роль у персоналізації навчання, а також вплив режимів роботи, таких як canvas та guided learning, на формування когнітивного навантаження студентів. Окрему увагу приділено методикам ефективного промптингу та використанню користувацьких файлів для підвищення точності та релевантності результатів. Показано, що ВММ можуть бути корисними для створення адаптивних навчальних матеріалів, підготовки оцінювальних засобів, автоматизації аналізу джерел та побудови спеціалізованих цифрових менторів. Описано проблеми та обмеження, пов'язані з генерацією графічних матеріалів і можливими когнітивними ризиками надмірної автоматизації навчальних завдань. Наведено рекомендації щодо відповідального та ефективного використання ВММ у діяльності викладачів ВНЗ.

Ключові слова: великі мовні моделі, ШІ в освіті, промптинг, canvas-режим, мультимодальність, персоналізація навчання.

Abstract. The article generalizes the experience of applying large language models within higher education and examines their role in supporting teaching, learning, and the development of personalized educational paths. It focuses on how modern multimodal systems enhance the creation of learning materials, improve instructional design, and support student engagement through guided learning and iterative knowledge-building. The paper analyzes prompt-engineering techniques, the integration of user-provided

documents to increase contextual accuracy, and the use of intermediate text-based diagram representations for reducing hallucinations in graphical outputs. Special attention is paid to advantages and limitations of AI-assisted content generation, including cognitive risks associated with overreliance on automated tools. The study discusses how LLMs can be applied to build specialized AI tutors, generate assessments, summarize diverse sources, and support educators in preparing course materials. Recommendations are provided for responsible and effective use of LLMs in university teaching, highlighting strategies that maintain academic integrity while improving efficiency and learning outcomes.

Keywords: large language models, AI-assisted teaching, prompt engineering, guided learning, multimodal systems, educational personalization.

Постановка проблеми.

Поява великих мовних моделей (ВММ) та спрощення доступу до них великій кількості користувачів, спричинили величезну популярність цих моделей та намагання застосувати їх у найрізноманітніших областях людської діяльності. Зараз відбувається етап накопичення досвіду та формування на його підставі практик використання ВММ у різних галузях. Метою цієї роботи є певне узагальнення їх використання у галузі вищої освіти ґрунтуючись на власному досвіді, проаналізованій літературі та певних тенденціях розвитку. З іншої сторони, з'являється велика кількість нових інструментів, основою яких є ВММ. Вони швидко модифікуються, додаються нові функції та модифікації і цікавою є задача сформувати якийсь мінімальний набір корисних інструментів, що можна рекомендувати для застосування у галузі вищої освіти.

Аналіз останніх публікацій.

Ще рік тому велись активні дискусії щодо:

- дозволити чи заборонити використання ВММ у навчальних закладах,
- чи є використання ВММ академічно доброчесним чи ні

Зараз у більшості держав з'явилися регуляторні документи. В Україні, зокрема, є детальні рекомендації Міністерства Освіти і Науки [1], де детально розглянуто доброчесні методи використання ШІ в освіті. То ж тепер дискусії та дослідження ведуться вже над питаннями впливу ВММ на покращення чи погіршення знань студентів [2,3,4] та методиками, які дозволяють покращити знання студентів [5,6].

У експерименті, описаному в роботах [2,3,4], трьом групам студентів дали однакове завдання написати есе. Першій групі не дозволялось користуватись додатковими засобами ("Brain-only"), другій дозволили користуватись пошуковиками, а третій – ВММ. Методологія включала записи мозкової активності за допомогою електроенцефалографії (ЕЕГ), аналіз природної мови (NLP) та інтерв'ю для оцінки когнітивного навантаження та відчуття авторства. Аналіз ЕЕГ виявив, що ступінь нейронної зв'язності систематично знижувався пропорційно до зовнішньої підтримки: найсильніші та найширші мережі демонструвала група "Brain-only", відображаючи вищий рівень виконавчого контролю та внутрішнього семантичного опрацювання. Використання ВММ призводило до найслабшої зв'язності, що корелювало з низьким рівнем сприйнятого авторства есе та значним погіршенням здатності учасників правильно цитувати власний текст. Це свідчить про те, що хоча допомога ШІ може зменшити безпосереднє когнітивне навантаження, вона пригнічує глибоку когнітивну інтеграцію та пам'ять, необхідні для самостійного створення контенту. В цілому, дослідження підкреслює компроміс між негайною зручністю використання ШІ та потенційним зниженням нейронної залученості, важливої для довгострокового розвитку навичок.

Робота [6] досліджує, як технології генеративного штучного інтелекту, зокрема GPT-4 та розроблена Khan Academy платформа Khanmigo [12], мають змінити сферу освіти. Підкреслюється, що ШІ є ключовим елементом для забезпечення персоналізованого навчання та опанування матеріалу в глобальному масштабі. Наводяться численні приклади використання Khanmigo, включаючи інтерактивне написання історій, сократівське наставництво з різних предметів, а також створення симуляцій історичних осіб для діалогу зі студентами. Хан також обговорює ширші наслідки впровадження ШІ, зокрема необхідність переосмислення понять академічної недоброчесності та вплив технологій на творчі здібності та продуктивність праці. Він закликає до «освіченої сміливості» у прийнятті цих інструментів, стверджуючи, що ШІ має підвищити, а не замінити, людський потенціал.

Підкреслення невирішених частин проблеми.

Правила доброчесного використання ВММ детально описані у рекомендаціях [1]. Також у [1,7,8] описано ефективні методики формування промптів для ВММ, наводяться практичні приклади промптів саме для використання у освітніх закладах різного рівня, є посилання на зовнішні джерела із наборами подібних промптів. У доповіді [9] автор також описував свій досвід використання ВММ для підготовки різноманітних документів. З моменту появи цих публікацій, у роботі ВММ з'явилося багато

цікавих режимів, які можуть бути ефективно в галузі освіти, накопичився досвід практичного використання ВММ, яким автор бажає поділитись. Також з'явилися нові інструменти, досвід використання яких у освіті необхідно осмислити та структурувати.

Мета роботи та постановка завдань

Автор застосовував ChatGPT та Gemini, а також інші продукти OpenAI та Google як для підготовки навчальних матеріалів, так і безпосередньо під час навчального процесу. На підставі власного досвіду галузеві рекомендації доповнилися власними методичними напрацюваннями та було вибрано набір інструментів, які найкраще підходять для ефективного застосування ШІ у ВНЗ.

Виклад основного матеріалу дослідження

У [1] рекомендують застосовувати наступний формат промптів для ВММ: “Ти - [науковець / викладач / експерт у галузі...] Зроби [завдання] для [аудиторія] в контексті [тема]. Результат надай у форматі [очікуваний результат]. Використовуй [обмеження / параметри] і [технологічні інструменти, якщо потрібно]”. Що тут можна удосконалити? Як розширити ці рекомендації? Сучасні ВММ дозволяють у промптах використовувати користувацькі файли. Прикріпивши до промпта конспект лекцій чи робочу програму, ми зможемо значно покращити результат роботи. Крім того, генерація матеріалів буде відбуватись близько до ваших матеріалів, що обмежить контекст тільки тою частиною знань, що описані в конспекті/робочій програмі. Змінюючи параметр [аудиторія] вдається адаптувати матеріали до необхідного рівня ваших студентів, отримати приклади/асоціації характерні для ваших студентів, врахувати їх інтереси, хобі для створення індивідуальних навчальних матеріалів та ідей для занять. Наприклад, маючи один конспект лекцій предмету “Цифрова електроніка”, можна отримати детальні глибокі матеріали для студентів спеціальності “Радіотехніка” і адаптований варіант для студентів Інституту Геодезії, що також знайомляться із роботою цифрових пристроїв.

ВММ тепер стали мультимодальними і вміють доволі добре створювати зображення. На жаль, тексти, що присутні на ілюстраціях, часто містять помилки, змішуються стандарти представлення інформації. Тому, для створення графічного матеріалу, схем, діаграм, призначених для студентів технічних спеціальностей вуху, автор випрацював методику, в якій результатом є опис текстовий опис графічного матеріалу на одній із мов (mermaid, plantUML, mark down, html), а не зображення безпосередньо. Такий підхід дозволяє швидко виправити опис графічного матеріалу при наявності неточностей. Навіть, якщо користувач не володіє відповідною мовою опису, він може попросити виправити помилки ВММ безпосередньо у наступних запитах. Остаточне зображення отримується після рендерингу його представлення у відповідних системах [10, 11]. Детально цей процес обговорювався у доповіді [9]. Якщо ж не існує мова проміжного опису, завжди можна попросити ВММ генерувати не зображення безпосередньо, а програму для його генерації, наприклад, на мові Python. ВММ навіть так працюють самостійно у випадку задач аналізу даних та побудови діаграм.

Більшість ВММ зараз має режим роботи “canvas”. Він полягає у створенні двох вікон: одного для чату із ВММ, а іншого - для результуючого документу. Користувач має можливість не тільки змінювати результуючий документ за допомогою промптів, а й безпосередньо його редагувати, швидко видаляючи неточності чи галюцинації. Так значно пришвидшується отримання результатів. Крім того, остаточний результат користувач має можливість зберегти у потрібному йому форматі.

Ще один корисний режим роботи ВММ називається “Learn and study” чи “Учіться та пізнавайте”. Саме його можна рекомендувати студентам для використання ВММ у навчальному процесі, адже при його використанні ВММ розповідає про задану тему невеличкими порціями, перевіряє отримані знання та продовжує рухатись далі, лише переконавшись, що студент засвоїв попередню тему. Це так зване сократівське наставництво (маевтика), яке стимулює студента на самостійний пошук проблеми. Такий підхід значно збільшує когнітивне навантаження на студента, зменшуючи негативні впливи ВММ, описані

в [2,3,4] та розглянуті вище. Викладачам такий режим варто використовувати, коли треба швидко пригадати якусь тему чи підготуватись до заняття.

І ChatGPT і Gemini дозволяє створювати власних помічників (менторів) шляхом створення системних промптів, які задають алгоритм відповіді ВММ на запитання. У екосистемі ChatGPT вони називаються GPTs, у Gemini – Gems. Детально їх створення буде розглянуто нижче. Тут звернемо увагу на вже готові корисні Gems від Google. Один із них називається Storybook та призначений для створення невеликих книжок на задану тематику із ілюстраціями. Автор намагався використати його для урізноманітнення лекційного матеріалу чи інструкцій для лабораторних робіт. Отримані результати [14, 15] показали, що Storybook може бути цікавим та ефективним для середньої школи. У вищій школі його важко використати. Якщо текстовий вміст створювався доволі адекватно до введеного користувачем промпта, то майже не вдалось добитись, щоб генерований ілюстративний матеріал не міститив фантазій чи галюцинацій і зображення відповідали певним технічним стандартам [14].

Особливо варто відзначити інструмент NotebookLM від Google. Він використовує ШІ для дослідження завантажених користувачем джерел (до 50 джерел на один notebook). Вражає кількість підтримуваних форматів джерел - PDF, .txt, Markdown, Audio (e.g. mp3), .docx, .avif, .bmp, .gif, .ico, .jp2, .png, .webp, .tif, .tiff, .heic, .heif, .jpeg, .jpg, .jpe. Що можна додавати посилання на вебсайти та YouTube. При цьому джерела можуть бути різномовними. Автоматично будується резюме на підставі всіх джерел, є вбудовані інструменти, що дозволяють будувати аудіо розповідь, відео розповідь, інтелект-карти, інфографіку, флешкарти, вікторини (quiz). Відповіді та інші артефакти будуються тільки на підставі інформації із вказаних\завантажених джерел. Автор використовував NotebookLM для генерації екзаменаційних питань на підставі тексту підручника. Перетворювати різні формати відповіді NotebookLM ще не вміє. Тому, для завантаження згенерованих питань у систему управління навчанням (Moodle) довелося скористатись ChatGPT та промтом, що перетворив список запитань у xml файл, який можна безпосередньо завантажити у Moodle. Загалом можна рекомендувати NotebookLM викладачам, як основний інструмент для підготовки різноманітних матеріалів із конспекту лекцій чи підручника. Також він чудово справиться при переведенні відеозаписів лекцій, у текстовий формат.

Надзвичайно цікаві інструменти для викладача представлені на платформі Khanmigo[12], яка описана в [5]. Платформа містить величезний набір ШІ-інструментів для викладачів та індивідуальних ШІ-репетиторів для студентів. Поки доступна лише на англійській мові. Подібні ШІ-репетитори можна будувати і за допомогою вже згаданих вище GPTs або Gems. Для цього застосовуються механізми системних промптів, створення яких описано у [8]. Інструкції, описані в системному промпті задають поведінку ВММ та мають вищий пріоритет, ніж інструкції в користувацькому промпті. Подібно до користувацького промпту, системний промпт має свій формат, що складається із ролі, мети, контексту, формату відповіді, правил та прикладів інструкцій. Нижче приведено подібний промпт, створений автором для повторення матеріалу та поглиблення знань із управління даними (Data Governance):

```
system_prompt: |
```

```
Ти виступаєш як досвідчений ментор із Data Governance з реальним досвідом у впровадженні політик управління даними на рівні великих організацій.
```

```
Моя мета — глибоко вивчити тему Data Governance з фокусом на:
```

- принципи й компоненти (data ownership, stewardship, lineage, cataloging, quality, privacy)
- стандарти (DAMAD-DMBOK2, ISO 8000, GDPR)
- інструменти (DataHub, Collibra, Apache Atlas, dbt, Great Expectations)
- практичні кейси впровадження в бізнесі

- роль Data Governance у забезпеченні **Data Quality** та **DataOps**

Мій рівень: середній. Добре знаю SQL, ETL, трохи працював з Data Quality Tools і Airflow. Хочу структурувати та поглибити знання саме з точки зору **Data Governance Framework**.

Метод навчання:

- Поділяй тему на невеликі блоки: один компонент — одне пояснення

- Подавай матеріал структуровано: вступ → пояснення → приклад → контрольне питання

- Не переходь до наступного блоку без мого підтвердження

Формат кожного блоку:

1. Короткий вступ (1-2 речення)
2. Пояснення ключових термінів (із маркованим списком)
3. Реальний приклад (корпоративний або технологічний кейс)
4. Контрольне запитання для мене (тест або open-ended)
5. Опційно — посилання на інструменти / статті / моделі

Стиль:

- Дружній, зрозумілий, з використанням правильної термінології
- Пояснюй складне через аналогії
- Якщо я помиляюсь — виправляй обережно й пояснюй, чому

Технічні формати:

- Пояснення Markdown
- Таблиці, якщо йдеться про порівняння моделей чи фреймворків
- Можеш генерувати YAML-конфігурації або приклади dbt-структури, якщо релевантно

Додаткові запити:

- За потреби можу попросити приклади з DataHub, dbt, Great Expectations

- Якщо хочеш — можеш сам ініціювати міні-проект ("створи просту Data Governance політику для стартапу", тощо)

Очікую ітеративне навчання: не поспішай, дочекайся моєї реакції.

Подібні системні промпти були підготовлені автором для предметів “Архітектура комп’ютера та операційні системи”, “Середовище та компоненти розробки у моделюванні і аналізі даних” та будуть впроваджуватись у навчання наступного семестру

ВИСНОВКИ

В доповнення до рекомендацій нормативних документів автор пропонує при використанні LLM частіше користуватись режимом canvas, вибудовуючи ітеративний процес створення документів, у якому викладач та ШІ доповнює один одного. Шляхом зміни контексту в запитах адаптувати матеріал із тих самих джерел для аудиторій із різним рівнем підготовки. При створенні схем, малюнків та формул використовувати проміжне текстове представлення (mermaid, plain uml, latex, markdown і т.п.), щоб мати можливість вчасно та легко виправляти помилки та усувати галюцинації. Широко використовувати NotebookLM для роботи із джерелами, які написані на різних мовах, різнотипними джерелами: текст, аудіо/відео, вебсайти. Також цей інструмент ефективний для генерації аудіо резюме, відеопрезентацій, коротких тестів та флеш карток. Використовувати підходи системного промптингу для створення спеціалізованих чатів ШІ-репетиторів, що навчають студентів за допомогою методу сократівського наставництва, уникаючи безпосередніх відповідей на питання та автоматичного виконання домашніх завдань. Стимулювати студентів

користуватись LLM у режимі "учіться та пізнавайте", "guided learning" для персоналізації навчання.

СПИСОК ПОСИЛАНЬ.

1. Рекомендації щодо відповідального впровадження та використання технологій штучного інтелекту в закладах вищої освіти [Електронний ресурс] / М-во освіти і науки України, М-во цифр. трансформації України. Київ, 2025. URL: <https://mon.gov.ua/static-objects/mon/sites/1/news/2025/04/24/shi-v-zakladakh-vyshchoi-osvity-24-04-2025.pdf> (дата звернення: 27.11.2025).
2. Mastering knowledge: the impact of generative AI on student learning outcomes [Electronic resource] / J. L. Pallant, J. Blijlevens, A. Campbell, R. Jopp // *Studies in Higher Education*. – 2025. – 6 May. – P. 1–22. – URL: <https://www.tandfonline.com/doi/full/10.1080/03075079.2025.2487570> (date of access: 27.11.2025).
3. Your Brain on ChatGPT: Accumulation of Cognitive Debt when Using an AI Assistant for Essay Writing Task [Electronic resource] / N. Kosmyna, E. Hauptmann, Y. T. Yuan, J. Situ [et al.] // *arXiv.org*. – 2025. – 10 June. – URL: <https://arxiv.org/abs/2506.08872> (date of access: 27.11.2025).
4. POLAKOVA, P. The impact of ChatGPT feedback on the development of EFL students' writing skills [Electronic resource] / P. Polakova, P. Ivenz // *Cogent Education*. – 2024. – Vol. 11, No. 1. – Art. 2410101. – URL: <https://www.tandfonline.com/doi/full/10.1080/2331186X.2024.2410101> (date of access: 27.11.2025).
5. ХАН, С. Слова чудові в світі новім. Як штучний інтелект зробить революцію в освіті (і чому це добре) / пер. з англ. Анастасія Дудченко. Київ: Наш Формат, 2025. 240 с.
6. Штучний інтелект і нейромережі. 12 книжок в одній, що допоможуть вам втілити інновації в життя / упоряд. ТОВ "Моноліт Бізз". Харків: Моноліт Бізз, 2026. 216 с.
7. КРАКОВЕЦЬКИЙ, О. ChatGPT, DALL-E, Midjourney. Як генеративний штучний інтелект змінює світ. Київ: ArtHuss, 2024. 192 с. Олександр Краковецький. Великі мовні моделі, інженерія запитів та агенти. Київ: Видавничий Будинок "Аванпост-Прим", 2025. – 242 с.
8. КРАКОВЕЦЬКИЙ, О. Великі мовні моделі, інженерія запитів та агенти. Київ: Видавничий Будинок "Аванпост-Прим", 2025. 242 с.
9. БЕНЧ, А. Як ChatGPT може допомогти у створенні документації. ChatGPT в дії: практичний посібник для IT фахівців : круглий стіл, 5 груд. 2023 р. Відеозапис. URL: <https://youtu.be/grTTUuAdWjc?t=5213> (дата звернення: 26.11.2025).
10. Mermaid [Електронний ресурс] : JavaScript based diagramming and charting tool. URL: <https://mermaid.js.org/> (дата звернення: 29.11.2025).
11. PlantUML [Електронний ресурс] : open-source tool for creating diagrams. URL: <https://plantuml.com/> (дата звернення: 29.11.2025).
12. Khanmigo [Електронний ресурс] : AI-powered tutor and teaching assistant / Khan Academy. URL: <https://www.khanmigo.ai/> (дата звернення: 29.11.2025).
13. Khan Academy [Електронний ресурс] : free online courses, lessons & practice. URL: <https://www.khanacademy.org/> (дата звернення: 29.11.2025).
14. Магія Логіки: Подорож Оксани у Світ Комп'ютерної Архітектури [Електронний ресурс] : [діалог з III Gemini]. URL: <https://gemini.google.com/share/9e2cdba53753> (дата звернення: 29.11.2025).
15. Anya and the Dataville Data [Електронний ресурс] : [діалог з III Gemini]. URL: <https://gemini.google.com/share/3a07d8c6025d> (дата звернення: 29.11.2025).

Бондарєв Я. Г. (Донбаська державна машинобудівна академія, м. Краматорськ-Тернопіль, Україна).

ЗАСТОСУВАННЯ ШТУЧНОГО ІНТЕЛЕКТУ В СУЧАСНІЙ ОСВІТІ.

Анотація. У статті досліджено особливості розвитку та впровадження технологій штучного інтелекту в сучасне освітнє середовище. Визначено основні напрями використання інтелектуальних систем для персоналізації навчання, автоматизації педагогічних процедур і підвищення якості аналізу освітніх даних. Окреслено наукові підходи до інтеграції ШІ в освітню практику та проаналізовано проблеми, пов'язані з етикою, безпекою даних, академічною доброчесністю та нерівним доступом до цифрових технологій. Розглянуто сучасні тенденції розвитку інтелектуальних платформ і можливості їх застосування для оптимізації навчального процесу, підтримки педагогів та створення гнучких освітніх траєкторій. Показано, що недостатньо розробленими залишаються механізми моніторингу та контролю рішень, згенерованих алгоритмами, а також моделі управління ризиками під час інтеграції ШІ в навчальне середовище. Запропоновано рекомендації щодо відповідального використання інтелектуальних технологій з метою підвищення ефективності та безпечності освітньої діяльності.

Ключові слова: штучний інтелект, освіта, персоналізація навчання, цифрові технології, етика, академічна доброчесність.

Abstract. The article examines the development and implementation of artificial intelligence technologies in the modern educational environment. It highlights the key directions of applying intelligent systems for learning personalization, automation of pedagogical routines, and improvement of educational data analysis. The study reviews scientific approaches to integrating AI into educational practice and identifies challenges related to ethics, data security, academic integrity, and unequal access to digital technologies. Current trends in the development of intelligent platforms and their potential to support teachers, optimize the learning process, and create flexible educational trajectories are discussed. It is noted that mechanisms for monitoring and evaluating algorithm-generated decisions, as well as risk-management models for AI integration, remain insufficiently developed. The article provides recommendations for the responsible and safe use of AI aimed at enhancing the efficiency, transparency, and reliability of educational activities.

Keywords: artificial intelligence, educational technologies, learning personalization, academic integrity, data security, ethical challenges.

Швидкий розвиток технологій штучного інтелекту суттєво впливає на трансформацію освітніх підходів і способів організації навчального процесу. Інтелектуальні системи дедалі частіше інтегруються в освітнє середовище, забезпечуючи персоналізацію навчання, автоматизацію рутинних педагогічних дій та можливість глибокого аналізу освітніх даних для підвищення якості навчального результату. У таких умовах змінюється не лише методика викладання, а й модель взаємодії між учителем, учнем і цифровими інструментами.

Поширення цифрових технологій зумовлює зростання ролі штучного інтелекту (далі – ШІ) як ключового елементу сучасної системи освіти. Новітні інтелектуальні платформи здатні адаптуватися до індивідуальних особливостей здобувачів освіти, моделювати їхню навчальну поведінку та сприяти підвищенню інтерактивності освітнього процесу. Такі інструменти базуються на міждисциплінарних досягненнях у сфері штучного інтелекту та поєднують комп'ютерні, психолого-педагогічні й управлінські підходи.

Однак разом із потенціалом ШІ висуває і низку суттєвих викликів: проблеми етики та безпеки даних, питання рівного доступу до технологій, загрози порушення академічної доброчесності, а також ризики надмірної залежності від інтелектуальних систем. Усе це актуалізує потребу в науковому дослідженні того, яким чином штучний інтелект може бути впроваджений в освіту ефективно, відповідально та без негативних наслідків для учасників освітнього процесу.

Штучний інтелект має потенціал модернізувати освіту, але для досягнення максимального ефекту потрібно підходити до його впровадження з обережністю та

системністю. Під час вибору інструментів ШІ слід враховувати багато важливих аспектів їх використання – відповідність навчальним цілям, забезпечення захисту персональних даних учасників освітнього процесу та рівного доступу усім учням, дотримання академічної доброчесності, а також залежність від ШІ, яка може призвести до втрати певних навичок, таких як критичне мислення та творчість[1].

У дослідженнях, присвячених розвитку штучного інтелекту в Україні, особливе місце відводиться освітній сфері як пріоритетному напрямку його впровадження. Аспекти функціонування та застосування ШІ розглядають Фратавчан В. Г., Фратавчан Т. М., Лукашів Т. О. та Літвінчук Ю. А. В. Грицишин і Н. Габрусєва підкреслюють виклики, можливості й необхідність контролю ризиків, пов'язаних із використанням інтелектуальних технологій.

Досягнення та перспективи розвитку ШІ у вітчизняному контексті аналізують А. Шевченко та Г. Андрощук, тоді як А. Дубчак, Я. Литвиненко та Ю. Перучок досліджують напрями його застосування та пов'язані з цим переваги й загрози. Питання інтеграції штучного інтелекту в освіту та виклики для учасників освітнього процесу висвітлює А. Мельник.

Питанню впровадження ІКТ у навчальний процес присвячені дослідження вчених: В. Бикова, Р.Гуревича, В. Бахрушина, Н. Морзе, С.Сисоевої, В. Осадчого, Є. Полат та ін. Деякі дослідники, розглядаючи питання навчання інформатики, математичної логіки та логічного програмування у педагогічних закладах освіти, методики навчання та використання систем штучного інтелекту у середній школі (Н.Апатова, Н. Балик, А. Верлань, М. Жалдак, І. Забара, І.Іваськів, К. Любченко, Ю.Рамський, Ю. Триус) здійснювали відповідний добір змісту навчального матеріалу, зокрема з основ штучного інтелекту [2].

Аналіз сучасних досліджень засвідчує, що більшість науковців зосереджується на технічних можливостях штучного інтелекту, його здатності автоматизувати навчальний процес, здійснювати оцінювання чи забезпечувати персоналізацію освітніх траєкторій. Разом із тим низка важливих питань, пов'язаних зі створенням ефективних механізмів регулювання та контролю використання ШІ в освіті, залишається поза увагою. Зокрема, недостатньо розробленими є моделі, які б дозволяли педагогам і адміністраторам навчальних закладів системно управляти ризиками, що виникають у процесі застосування інтелектуальних технологій, а також передбачати негативні наслідки їх необмеженого використання.

Попри те, що в інших галузях (зокрема, у бізнесі та державному управлінні) давно застосовуються інструменти контролю й контролінгу для підвищення якості управлінських рішень, аналогічні підходи щодо оцінювання впливу ШІ на навчальний процес практично не розроблені. Освітня сфера поки що не має чітко окреслених механізмів моніторингу якості ШІ-рішень, систем захисту від помилкових рекомендацій, а також моделей, що забезпечували б прозорість, етичність та безпеку використання алгоритмів.

Недостатньо дослідженими залишаються й питання збереження академічної доброчесності в умовах активного використання ШІ, формування цифрової компетентності педагогів та учнів, оцінювання впливу ШІ на розвиток критичного мислення та самостійності здобувачів освіти. Незважаючи на актуальність цих проблем, вони майже не отримали системного наукового опрацювання, а отже потребують розроблення нових концептуальних підходів і методів регулювання інтеграції штучного інтелекту в освітню практику.

Технології штучного інтелекту працюють за принципом пошуку загальнодоступної інформації через бази даних пошукових систем, опрацювання й надання користувачу даних за запитом відбуваються без зазначення джерела, часто при цьому порушуючи авторське право. Коли здобувачі освіти під час виконання завдань навчальних дисциплін чи дослідницьких проєктів застосовують технології штучного інтелекту, викладачі не завжди можуть розрізнити, де завдання виконані студентом, а де — за допомогою технології штучного інтелекту. Тому питання освіти усіх учасників освітнього процесу щодо особливостей застосування технологій штучного інтелекту та використання їх потенціалу й можливостей для підвищення якості освіти залишається актуальним [3].

Метою статті є дослідження особливостей інтеграції технологій штучного інтелекту в освітнє середовище, визначення їхнього впливу на навчальний процес та моделі взаємодії між

учителем і здобувачем освіти, а також виявлення можливостей і викликів щодо забезпечення ефективного, етичного та безпечного використання ШІ в освіті.

Для реалізації поставленої мети необхідно виконати наступні завдання:

- проаналізувати сучасні тенденції розвитку штучного інтелекту та його застосування в освітній сфері;
- визначити переваги та потенційні ризики інтеграції ШІ у навчальний процес, зокрема щодо академічної доброчесності, захисту даних і рівного доступу;
- дослідити особливості персоналізації навчання та автоматизації освітніх дій за допомогою інтелектуальних платформ;
- окреслити умови та рекомендації для відповідального і системного впровадження ШІ в освітні практики, збереження критичного мислення та розвитку творчих навичок учнів.

ШІ є сучасною галуззю комп'ютерних технологій, спрямованою на створення «розумних» систем, здатних виконувати завдання, які традиційно потребують людського інтелекту, у тому числі в освітньому середовищі. Використання ШІ в навчальному процесі дозволяє автоматизувати обробку знань, адаптувати освітні траєкторії під потреби вчителів та учнів, а також підвищувати ефективність навчання. Через інтерактивні цифрові платформи ШІ дає змогу педагогам та учням ефективно ставити та розв'язувати інтелектуальні завдання, персоналізувати навчальний процес і забезпечувати більш гнучку та результативну освітню діяльність.

У Національній стратегії розвитку ШІ в Україні 2021-2030 використовується означення ШІ, представлене у Концепції розвитку штучного інтелекту в Україні від 02.12.2020 № 1556-р. Словосполучення «штучний інтелект» пояснюється наступним чином – це «організована сукупність інформаційних технологій, із застосуванням якої можливо виконувати складні комплексні завдання шляхом використання системи наукових методів досліджень і алгоритмів обробки інформації, отриманої або самостійно створеної під час роботи, а також створювати та використовувати власні бази знань, моделі прийняття рішень, алгоритми роботи з інформацією та визначати способи досягнення поставлених завдань»[4].

Британською Індустріальною стратегією визначено ШІ такими технологіями, які мають здатність до виконання певних завдань, які вимагають наявності людського інтелекту (наприклад, візуальне сприйняття, розпізнавання мовлення та переклад мови). В енциклопедії «Британіка» ШІ пояснюється як можливість цифрового комп'ютера або робота, який керований комп'ютером, реалізовувати різні завдання, які, як правило, пов'язують з розумними істотами. Проте, не зважаючи на те, яке на якому визначенні зупинитися, розвиток ШІ передбачає приблизно однакові вимоги до освіти і зміни в самій системі освіти[5].

Досить часто, термін «штучний інтелект» тлумачиться як здатність автоматизованих систем виконувати функції людського інтелекту, здатність вибирати та приймати рішення на основі попереднього накопиченого досвіду та раціонального аналізу зовнішніх факторів. Іншими словами, штучний інтелект це здатність машин симулювати розум та імітувати людські когнітивні здібності. Тобто збирати й адаптувати зовнішні дані, а на їх основі навчатися ухвалювати рішення та робити висновки, як могла би людина[6].

Штучний інтелект — це система, що працює, поєднуючи великі обсяги даних з інтелектуальними алгоритмами обробки. Алгоритми ШІ працюють так, що це дозволяє йому вчитися на основі аналізованих шаблонів і особливостей. Під час кожного циклу обробки інформації, система оцінює свою продуктивність і використовує результати для вдосконалення[7].

Штучний інтелект у навчальному процесі може використовуватися як інструмент для автоматизації завдань, що потребують когнітивних здібностей, таких як аналіз інформації,

прийняття рішень та адаптація навчального матеріалу під індивідуальні потреби учнів. Завдяки здатності систем ШІ навчатися на основі накопиченого досвіду та обробки великих обсягів даних, вони можуть підвищувати ефективність освітнього процесу, персоналізувати навчання та сприяти більш глибокому засвоєнню знань. Таким чином, інтеграція ШІ в освіту дозволяє поєднувати автоматизацію та інтелектуальну підтримку для покращення результатів навчання.

Штучний інтелект назавжди змінив освіту в усьому світі, про це говорять педагоги, науковці, футурологи та інші експерти. Цікаво, що саме зараз точаться потужні дискусії, проблемним питанням яких є те, чого більше від цього – користі чи шкоди.

Projector Creative & Tech Institute та Мала академія наук України за підтримки дослідницької компанії Factum Group Ukraine та за підтримки Міністерства освіти і науки України провели всеукраїнське дослідження з метою отримати дані про використання штучного інтелекту в українських школах та дослідити перспективи його подальшого залучення в освітній процес на різних рівнях. Учасники опитування – педагоги та школярі з різних регіонів України (крім територій, окупованих російською федерацією).

В опитуванні, яке тривало протягом вересня-жовтня 2023 року, взяли участь більше 3000 українців. Серед них 1747 учителів та 1443 школярі (учні 8-11 класів).

На сьогодні лише мінімальна кількість педагогів не чули про можливості штучного інтелекту. І за результатами опитування 7 із 10 освітян хоча б один раз за пів року перевіряли, як працюють інструменти на базі ШІ. Загалом 76% опитаних учителів хоча б раз користувалися ШІ, половина з них мала позитивний досвід взаємодії.

Із огляду на такі показники можна стверджувати, що AI-технології дуже активно залучаються в освітній процес, і відбувається це не вимушено, а через інші фактори[8].



Рисунок 1. Всеукраїнське дослідження використання ШІ у шкільній освіті [8].

Всеукраїнське дослідження використання ШІ у шкільній освіті

Використання ШІ вчителями

Успішність досвіду використання ШІ

Більшість вчителів, що мали досвід використання ШІ в своїй роботі, оцінюють здобутий досвід як успішний. Лише 14% з опитаних вчителів вважають свій досвід неуспішним.



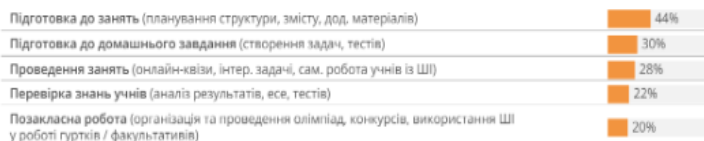
Як оцінюють свій досвід:



- Дуже успішний: ШІ значно покращив освітній процес
- Успішний: ШІ додав певні переваги до роботи
- Нейтральний: не бачу особливих переваг використання ШІ
- Не дуже успішний: були проблемами чи виклики
- Зовсім не успішний: використання ШІ розчарувало
- Відмова / ВВ

Способи використання ШІ в роботі вчителя

Як саме вчителі використовували ШІ в своїй роботі



54% вчителів погоджуються з твердженням, що ШІ змінить освітній процес у найближчі роки

Готовність рекомендувати ШІ іншим вчителям та учням

76% вчителів мають досвід використання ШІ в своїй роботі

Наскільки ймовірно, що будуть радити використання колегам та учням?

- NPS (колеги) +2%
- NPS (учні) -4%
- NPS = % Промоутери - % Критики




Рисунок 2. Використання ШІ вчителями[8].

Учителі та учні застосовують технології штучного інтелекту для підвищення ефективності освітнього процесу. Це може стосуватись як генеративного штучного інтелекту (генерування текстів, зображень, тестових питань, анотацій, презентацій тощо), так і предиктивного (аналіз успішності учнів та пропонування оптимальних стратегій її покращення).

До технологічних рішень на базі штучного інтелекту, які можуть допомогти організувати освітній процес, відносяться різноманітні інструменти оцінювання, продукування персоналізованих коментарів та відгуків, а також, для прикладу, системи створення та узгодження розкладів.

Важливо не забувати про необхідність критичного оцінювання згенерованих продуктів ШІ, а також про принципи академічної доброчесності при користуванні ними[9].

Безсумнівно, штучний інтелект швидко змінює освітню сферу, відкриваючи нові можливості для покращення як навчання, так і викладання. Завдяки цим технологіям учителі отримують інструменти для оптимізації своєї роботи та створення цікавої, інтерактивної та якісної навчальної програми, а учні — можливість навчатися у персоналізованому, адаптивному та більш ефективному середовищі.

З'являється щораз більше технологій, що покликані спростити та покращити процес навчання.

1) Найпростіше, з чим може допомогти штучний інтелект, – це створення планів уроків і навчальних матеріалів. До прикладу, на платформах, що генерують інформацію за допомогою штучного інтелекту, як-от ChatGPT або Google Gemini, можна ввести тему уроку та бажану тривалість й отримати структуру заняття, приклади завдань, питання для обговорення, інтерактивні елементи.

2) Платформи для створення візуальних матеріалів за допомогою штучного інтелекту допоможуть швидко створити слайди, інфографіку або навіть ілюстрації до теми. Зокрема, у Canva можна сформулювати запит створити презентацію.

3) Замість однакових текстів для всіх, можна запропонувати учням навчальні матеріали, адаптовані під їхній рівень розуміння. Наприклад, за допомогою Diffit можна взяти і обробити складний для сприйняття текст. Автоматичне створення завдань і тестів.

4) Витрачати багато годин на пошук чи створення завдань та тестів більше не обов'язково. Такі платформи, як QuestionWell чи Testportal пропонують можливість ввести тему або текст, щоб автоматично створити тести, відкриті питання або завдання різного рівня.

5) Штучний інтелект може не тільки допомагати генерувати нові матеріали, а й обробляти вже виконані завдання. Такі ресурси, як Grammarly чи LanguageTool можна використати для перевірки граматики чи логіки текстів учнів, а ChatGPT в ролі редактора можна попросити підказати ідеї для фідбеку.

6) Зберігати шаблони планів уроків, списки завдань, ідеї для майбутніх тем тепер можна не тільки в письмовому вигляді. Штучний інтелект, зокрема Notion AI чи Trello, допоможуть структурувати їх, зробити нотатки з наради, підготувати звіт або узагальнення[10].

Щоб штучний інтелект став ефективним помічником у навчальному процесі, а не джерелом ризиків, слід дотримуватися кількох важливих принципів. По-перше, не можна вносити персональні дані учнів або іншу чутливу інформацію в загальнодоступні платформи, адже це створює ризик порушення конфіденційності. По-друге, результати роботи ШІ не завжди є точними, тому важливо перевіряти факти, особливо під час роботи з науковими чи історичними темами. По-третє, варто пам'ятати, що штучний інтелект – це лише інструмент, і його ефективність залежить від того, як саме його інтегрувати у власну педагогічну практику. Технології не замінюють вчителя, але дозволяють бути продуктивнішим, приділяти більше уваги творчості, підтримці учнів та розвитку їхнього критичного мислення. Дотримання цих правил допомагає перетворити ШІ на справжнього союзника в освіті, підвищуючи якість і ефективність навчального процесу.

Штучний інтелект відкриває педагогам майже необмежені можливості для створення якісного та унікального навчального контенту, підготовки до занять і розробки методичних матеріалів. Водночас його використання потребує обережності, адже неправильне застосування ШІ може призвести до порушень академічної доброчесності, включно з фальсифікацією чи обманом, що негативно вплине на репутацію викладача. Проте при відповідальному й свідомому використанні таких технологій можна уникнути цих ризиків і значно підвищити ефективність освітньої діяльності.

При використанні штучного інтелекту в навчальному процесі важливо дотримуватися принципів академічної доброчесності. Насамперед, не слід копіювати чужі роботи та подавати результати роботи ШІ як власні без належного оформлення, завжди необхідно вказувати джерела, що допомагає не лише дотримуватися етики, а й краще засвоювати матеріал. Інформація, отримана за допомогою ШІ, може бути неточною або застарілою, тому факти та дані завжди слід перевіряти з надійних джерел. ШІ слід розглядати як помічника: він може допомогти зрозуміти складні теми, але формулювати власні думки необхідно самостійно, що сприяє розвитку критичного мислення. Не слід зловживати ШІ, адже надмірне покладання на нього може призвести до втрати важливих навичок. Крім того, слід пам'ятати про етичне використання цієї технології: створення матеріалів, що принижують або ображають інших людей, є неприпустимим. Дотримання цих правил допомагає педагогам та учням використовувати ШІ ефективно, відповідально та з повагою до академічної доброчесності[11].

Звичайно, штучний інтелект може значно підсилити ефективність навчального процесу, але його використання потребує зваженого й відповідального підходу, щоб зберегти академічну доброчесність та професійну репутацію педагога.

Поняття про штучний інтелект розвивається якщо не щодня, то щотижня. Очікується, що ШІ продовжить розвиватися зі швидкістю, яка може значно перевищити наші найсміливіші прогнози. Ось деякі ключові напрямки, які можуть вплинути на майбутній розвиток ШІ.

Освіта відіграє важливу роль у розвитку ШІ, і очікується, що його методи та алгоритми стануть все більш складними та ефективними. Ще одним із визначних трендів є зростання використання автономних систем у різних сферах, від автомобільної промисловості до медицини.

Виникає все більше питань про етичні аспекти використання ШІ, а також про безпеку та захист приватності в цифровому світі. І над цим світ буде працювати.

Штучний інтелект є частиною нашого життя, спрощуючи багато завдань і відкриваючи нові можливості в різних галузях, від освіти до транспорту. Проте, разом з розвитком ШІ, виникають питання безпеки даних і етики. Важливо створювати алгоритми, які враховують ці аспекти, щоб уникнути негативних наслідків. Відповідальний підхід до ШІ допоможе збалансувати технологічний прогрес і етичні стандарти, забезпечуючи його успішне і безпечне впровадження[7].

ВИСНОВКИ.

Штучний інтелект стає невід'ємною складовою сучасного світу, тож і освіта має враховувати його вплив та можливості. Ігнорувати ці технології чи чекати на їхнє зникнення — марно, адже вони вже змінюють вимоги до професій і перелік умінь, якими має володіти фахівець. Сьогодні важливо розвивати ті навички, що менш піддаються автоматизації: критичне мислення, вміння вчитися, гнучкість, здатність адаптуватися та відповідально працювати з інформацією. ШІ приносить в освітній процес не лише численні інструменти для створення контенту, а й актуалізує цінність академічної доброчесності, усвідомленого використання технологій і ролі педагога в умовах швидких змін.

Формуючи власну стратегію роботи із штучним інтелектом, важливо тримати у фокусі уваги весь спектр цих проблемних питань. Штучний інтелект ставить не лише питання про те, який черговий інструмент використати чи як запобігти списуванню, але й про те, наскільки можливо замінити вчителя у процесі навчання, і що взагалі означає освіта в еру штучного інтелекту[9].

У ході проведеного дослідження було досягнуто поставленої мети, яка полягала у з'ясуванні особливостей інтеграції технологій штучного інтелекту в освітнє середовище, аналізі їх впливу на навчальний процес, а також у визначенні можливостей і викликів, пов'язаних із впровадженням ШІ в освіту. У статті здійснено комплексний аналіз сучасних тенденцій розвитку штучного інтелекту, окреслено ключові напрями його застосування в навчальному процесі та охарактеризовано інструменти, що забезпечують персоналізацію, автоматизацію та підвищення ефективності освітньої діяльності.

На основі узагальнення досліджень і практик встановлено основні переваги використання ШІ, серед яких — індивідуалізація навчання, підвищення якості оцінювання, оптимізація педагогічної діяльності та створення нового формату взаємодії між учасниками освітнього процесу. Водночас виявлено і проаналізовано ризики, пов'язані з етичними аспектами, захистом персональних даних, забезпеченням академічної доброчесності та можливістю формування залежності від цифрових технологій.

СПИСОК ПОСИЛАНЬ.

1. Політика використання ШІ в закладі освіти: поради щодо розробки та реалізації. URL: <https://naurok.com.ua/post/politika-vikoristannya-shi-v-zakladi-osviti-poradi-schodo-rozrobki-ta-realizaci>. (дата звернення: 15.11.2025).
2. Візнюк І. М., Буглай Н. М., Куцак Л. В., Поліщук А. С., Киливник В. В. Використання штучного інтелекту в освіті. Сучасні інформаційні технології та інноваційні методики навчання в підготовці фахівців: методологія, теорія, досвід, проблеми. 2021. Вип. 59. С. 14–22. URL: <https://vspu.net/sit/index.php/sit/article/view/3031/2458>. (дата звернення: 16.11.2025).
3. Паламар С., Науменко М. Штучний інтелект в освіті: використання без порушення принципів академічної чесності. Освітнологічний дискурс. 2024. № 1(44). С. 68–79.

URL: https://elibrary.kubg.edu.ua/id/eprint/48609/1/Palamar_S_P_Naumenko_M_S_OD_2024.pdf. (дата звернення: 20.11.2025).

4. Про схвалення Концепції розвитку штучного інтелекту в Україні : Розпорядження Кабінету Міністрів України від 02.12.2020 № 1556-р. URL: <https://zakon.rada.gov.ua/laws/show/1556-2020-%D1%80#Text>. (дата звернення: 20.11.2025).
5. Пчелянський Д. П., Воїнова С. А. Штучний інтелект: перспективи та тенденції розвитку. Automation of Technological and Business Processes. 2019. Т. 11, № 3. С. 59–64.
6. Гуназа Л. М. Штучний інтелект у сучасній освіті: трансформація ролі вчителя, підвищення якості навчання та нові можливості для учнів. Педагогіка формування творчої особистості у вищій і загальноосвітній школах. 2023. Вип. 90. С. 46–52. URL: <http://pedagogy-journal.kpi.zp.ua/archive/2023/90/10.pdf>. (дата звернення: 23.11.2025).
7. ШІ та революція в digital: як штучний інтелект змінює гру. URL: <https://ukrainiandigital.com/strong-yak-stvoryty-vlasne-onlayn-navchannia-strong/>. (дата звернення: 23.11.2025).
8. Перспективи використання штучного інтелекту в шкільній освіті. URL: <https://naurok.com.ua/post/perspektivi-vikoristannya-shtuchnogo-intelektu-v-shkilnyy-osviti>. (дата звернення: 23.11.2025).
9. Штучний інтелект в освіті: три аспекти. URL: <https://osvita.ua/school/method/91077/>. (дата звернення: 24.11.2025).
10. Помічник, а не ворог: штучний інтелект у підготовці до уроків. URL: <https://osvita.ua/news/lifelonglearn/95291/>. (дата звернення: 28.11.2025).
11. Памятка для здобувачів освіти "Академічна доброчесність та штучний інтелект". URL: <https://naurok.com.ua/pamyatka-dlya-zdobuvachiv-osviti-akademichna-dobrochesnist-ta-shtuchniy-intelekt-447435.html>. (дата звернення: 28.11.2025).

УДК 004.8:050.4:004.77

Гусаковський І.П. (Центральний науково-дослідний інститут озброєння та військової техніки Збройних Сил України, Київ, Україна).

ПЕРСПЕКТИ ТА РИЗИКИ ВПРОВАДЖЕННЯ ВЕЛИКИХ МОВНИХ МОДЕЛЕЙ В ЕЛЕКТРОННИЙ НАУКОВИЙ ЖУРНАЛ НА ПЛАТФОРМІ OPEN JOURNAL SYSTEMS.

Анотація. У статті проаналізовано перспективи інтеграції великих мовних моделей (ВММ), зокрема Google Gemini, у платформу електронних наукових журналів Open Journal Systems (OJS). Визначено ключові обмеження традиційних механізмів OJS, що зводяться до застарілих інструментів пошуку, ручної обробки матеріалів та низького рівня автоматизації редакційного процесу. З огляду на потреби оборонної сфери, де швидкість обробки наукової інформації є критично важливою, запропоновано концепцію перетворення OJS зі статичного архіву в інтерактивну базу знань. Показано, що впровадження ВММ забезпечує новий рівень функціональності: семантичний пошук за змістом, автоматизацію формальних перевірок статей, підготовку багатомовних анотацій, інтелектуальний вибір рецензентів на основі наукових профілів та підвищення доступності контенту через генерацію пояснень природною мовою. Розглянуто технічні вимоги до реалізації плагіна інтеграції Gemini, включно зі знанням PHP, JavaScript, механізмів REST API, роботою з базами даних та основами векторних репрезентацій. Детально проаналізовано ризики, серед яких складність

підтримки власного плагіна та потенційно висока вартість API. Сформульовано висновок про стратегічну доцільність інтеграції ВММ у OJS за умови врахування технічних і фінансових обмежень.

Ключові слова: Open Journal Systems, великі мовні моделі, Google Gemini, штучний інтелект, семантичний пошук, наукові журнали, автоматизація.

Abstract. The article analyzes the prospects of integrating large language models (LLMs), particularly Google Gemini, into the Open Journal Systems (OJS) platform used by electronic scientific journals. The core limitations of traditional OJS mechanisms are identified, including outdated keyword-based search, manual processing of submissions, and insufficient automation of editorial workflows. Considering the needs of the defense sector, where rapid access to scientific information is crucial, the study proposes transforming OJS from a static publication archive into an interactive knowledge base. The integration of LLMs enables semantic content-based search, automated compliance checks, multilingual abstract generation, intelligent reviewer recommendation based on author profiles, and improved accessibility through natural-language explanations. Technical requirements for the implementation of a Gemini-based plugin are presented, covering competence in PHP, JavaScript, REST API interaction, database management, and vector-based semantic retrieval. The analysis highlights key risks, such as the complexity of maintaining a custom plugin across OJS updates and the potentially high cost of API usage. It is concluded that integrating LLMs into OJS is a strategically justified step, provided that technical and financial risks are carefully managed.

Keywords: Open Journal Systems, large language models, Google Gemini, artificial intelligence, semantic search, scientific journals, automation.

Стрімкий технологічний розвиток призводить до зростання обсягів наукової інформації, роблячи традиційні методи її обробки неефективними. В цих умовах здатність до швидкого пошуку стає не просто перевагою, а критично важливою умовою для підтримки інновацій та наукового прогресу.

Наукові журнали, що функціонують на базі платформи Open Journal Systems (OJS), є ключовим майданчиком для акумуляції та поширення передових знань у цій сфері. Однак стандартний функціонал OJS, розроблений понад десять років тому, спирається на застарілі механізми пошуку за ключовими словами та вимагає значних часових витрат на редакційну обробку матеріалів. Це створює бар'єри для ефективного використання накопиченого масиву знань.

Основна проблема полягає у функціональному розриві між можливостями сучасної платформи OJS та потребами фахівців оборонно-промислового комплексу. Неефективність пошуку, відсутність інструментів для швидкого аналізу та узагальнення інформації уповільнюють науково-дослідну діяльність. Впровадження моделі, таких як Google Gemini, є перспективним шляхом вирішення цієї проблеми, проте вона вимагає глибокого аналізу методології впровадження, необхідних компетенцій та потенційних ризиків, особливо з урахуванням специфіки оборонної тематики.

Необхідність інтеграції LLM в екосистему OJS зумовлена потребою перетворення журналу зі статичного архіву публікацій на динамічну базу знань, що дозволить досягти переваг:

семантичний пошук реалізований за допомогою Gemini, що дозволить шукати за змістом;

оптимізація та автоматизація редакційних процесів, на які редакційна колегія витрачає значний час на рутинні завдання (створення якісних анотацій кількома мовами, автоматично перевірити статті на відповідність формальним вимогам журналу та здійснити підбір найбільш релевантних рецензентів з бази даних на основі їхніх попередніх робіт та наукових інтересів);

підвищення доступності та інтерактивності контенту для швидкого засвоєння інформації у вигляді пояснень природною мовою та отримання точних контекстуальних відповідей.

Успішна інтеграція вимагає залучення фахівців з різними наборами знань:

глибоке знання PHP для роботи з кодовою базою OJS та розробки кастомного плагіна; володіння JavaScript, HTML, CSS для створення інтуїтивно зрозумілих інтерфейсів для нових функцій;

досвід інтеграції зовнішніх сервісів через REST API, розуміння форматів JSON та механізмів автентифікації;

розуміння роботи з MySQL або PostgreSQL, на яких працює OJS, наявність базового розуміння роботи з векторними базами даних для реалізації семантичного пошуку;

вміння правильно формувати запити (промпти) до моделі Gemini для отримання точних та релевантних результатів;

мати загальним уявленням про архітектуру та можливості великих мовних моделей, зокрема моделей для генерації тексту та для створення векторних представлень.

Основним викликом реалізації є технічна складність розробки власного плагіна для OJS та постійної підтримки його при виході нових версій OJS та адаптації до змін до Google AI API.

Ще одним викликом є вартість використання Google AI API, як платна послуга, неконтрольована кількість запитів може призвести до значних фінансових витрат.

ВИСНОВКИ.

Проведене дослідження підтвердило, що функціональні обмеження платформи Open Journal Systems, зокрема застарілі механізми пошуку за ключовими словами, суттєво гальмують ефективну роботу з науковими даними. Це призводить до того, що наукові журнали, особливо у критичних галузях, функціонують переважно як статичні архіви, а не як динамічні інструменти для досліджень.

У відповідь на цей виклик, у роботі обґрунтовано технологічну досяжність та стратегічну доцільність інтеграції великих мовних моделей, зокрема Google Gemini. Така модернізація є ключовим кроком для трансформації OJS зі статичного репозиторію в інтерактивну базу знань.

Як було показано, практична цінність такої інтеграції полягає у двох основних аспектах. По-перше, у реалізації семантичного пошуку, що дозволяє знаходити інформацію за змістом, а не лише за формальними збігами. По-друге, у суттєвій автоматизації та оптимізації редакційних процесів (підготовка анотацій чи кваліфікований підбір рецензентів), що знижує часові витрати редакції.

Водночас, аналіз виявив два ключові виклики, що супроводжують таку імплементацію. Перший – це технічний ризик, пов'язаний зі складністю розробки кастомного плагіна та необхідністю його подальшої підтримки, що вимагає залучення мультидисциплінарної команди розробників. Другий – це фінансовий ризик, що полягає у необхідності впровадження механізмів контролю над вартістю використання комерційного API.

Таким чином, модернізація Open Journal Systems за допомогою великих мовних моделей є виправданим та стратегічно важливим кроком. Успіх реалізації залежить від ретельного планування наявних ресурсів та впровадження чіткої стратегії управління виявленими технічними та фінансовими ризиками.

Десятнюк Л.Б., Богуславець Д.В., Заянчуковська Д.М. (Національний медичний університет імені О.О. Богомольця, Київ, Україна).

БАЛАНС МІЖ ІННОВАЦІЯМИ ТА ЕТИКОЮ: ОЦІНКА ВПЛИВУ ШІ НА ОСВІТНЄ СЕРЕДОВИЩЕ.

Анотація. У статті досліджено комплексний вплив технологій штучного інтелекту на сучасне освітнє середовище та визначено ключові напрями збалансованого впровадження ШІ в навчальний процес. Показано, що інтелектуальні системи сприяють персоналізації навчання, розширюють доступ до індивідуальної підтримки, оптимізують рутинні завдання викладачів і сприяють інклюзивності. Разом із тим, активне використання ШІ супроводжується ризиками академічної недоброчесності, алгоритмічних упереджень, порушення конфіденційності, залежності від автоматизованих рішень та зниження розвитку соціальних навичок. Проаналізовано підходи міжнародних організацій (UNESCO, OECD) та сучасних наукових оглядів 2021–2025 рр., які пропонують впровадження етичних рамок, алгоритмічної прозорості, оновлених форм оцінювання й навчальних стратегій, спрямованих на розвиток цифрової та інформаційної грамотності. Обґрунтовано, що ефективне використання ШІ в освіті вимагає поєднання педагогічних і технічних рішень: розроблення політик відповідального застосування, створення безпечної інфраструктури обробки даних, навчання користувачів принципам роботи моделей та формування навичок критичного мислення. Збалансований підхід забезпечує інтеграцію ШІ як інструмента, який підсилює навчальний процес, зберігаючи його етичну та академічну цілісність.

Ключові слова: штучний інтелект в освіті, персоналізоване навчання, академічна доброчесність, цифрова грамотність, етичні засади ШІ.

Abstract. The article examines the multifaceted impact of artificial intelligence on contemporary educational environments and identifies key directions for the balanced integration of AI into the learning process. It is shown that intelligent systems enhance personalization, expand access to individual support, optimize teachers' routine tasks, and contribute to inclusivity. At the same time, active AI use is associated with risks of academic dishonesty, algorithmic bias, privacy violations, overreliance on automated tools, and reduced development of social and communication skills. The article analyzes approaches proposed by international organizations (UNESCO, OECD) and scientific reviews from 2021–2025, which emphasize ethical frameworks, algorithmic transparency, updated assessment formats, and pedagogical strategies aimed at improving digital and information literacy. It is argued that effective AI implementation in education requires a combination of technical and pedagogical measures, including responsible-use policies, secure data-handling infrastructure, user training on model principles, and the development of critical thinking skills. A balanced approach ensures that AI acts as a tool that enhances rather than undermines the integrity and quality of education.

Keywords: artificial intelligence in education, personalized learning, academic integrity, digital literacy, AI ethics.

Штучний інтелект (ШІ) помітно впливає на сучасну освіту: від організації навчального процесу до того, як студенти взаємодіють із навчальними матеріалами. Ці технології дають змогу персоналізувати навчання й зменшити кількість рутинних завдань, однак разом із перевагами з'являється й чимало питань — від етичних до суто практичних. Тому сьогодні важливо оцінювати не лише зручність і швидкість, які пропонують системи ШІ, а й довгострокові наслідки їхнього використання.

Однією з найпомітніших змін є можливість адаптувати навчання під потреби конкретного студента. Інтелектуальні системи аналізують рівень засвоєння матеріалу, темп роботи та типові помилки, пропонуючи саме ті завдання чи пояснення, які допомагають швидше зрозуміти складні теми. Такі інструменти також полегшують виявлення прогалин у знаннях і дають змогу заповнити їх одразу, не чекаючи підсумкового оцінювання [1].

Суттєвою перевагою є й доступність навчальної підтримки. Чат-боти та віртуальні репетитори працюють у будь-який час, пояснюють незрозумілі моменти та допомагають

повторити матеріал. Для багатьох студентів це стає додатковим ресурсом, особливо коли йдеться про інклюзивність: системи ШІ можуть озвучувати тексти, створювати субтитри або адаптувати матеріали під різні потреби. Не менш важливо, що технології частково полегшують роботу викладачів. Автоматичне оцінювання тестів чи коротких робіт економить час, а прогнозування успішності допомагає вчасно помітити студентів, яким потрібна додаткова підтримка [2].

Водночас надмірна залежність від таких інструментів може створити низку труднощів. Найпомітнішою є загроза академічній доброчесності: доступність генеративних моделей спрощує списування та уможлиблює створення робіт без реального розуміння матеріалу. Крім того, постійне користування готовими відповідями здатне поступово послаблювати навички критичного мислення.

Є й інші ризики. Інколи моделі ШІ можуть надавати неточну або надто узагальнену інформацію, яка виглядає переконливо, тому користувачам важливо вміти перевіряти отримані дані. Так само не варто забувати про можливі упередження: алгоритми, навчені на нерівномірних чи упереджених даних, можуть відтворювати ці перекоси в рекомендаціях або оцінюванні. Соціальні аспекти також заслуговують уваги. Зменшення кількості живого спілкування може негативно впливати на розвиток комунікативних навичок, а накопичення великих обсягів даних про студентів потребує чітких правил конфіденційності та захисту. Щоб технології справді підсилювали навчання, а не підміняли його, необхідно оновлювати підходи до викладання. Це стосується й форм оцінювання — варто частіше застосовувати творчі завдання, усні обговорення або групові проєкти, де роль ШІ обмежена. Не менш важливим є розвиток у студентів критичного мислення: вони мають розуміти принципи роботи моделей, вміти ставити уточнювальні запитання й перевіряти інформацію. Завданням сьогодні є не замінити викладача технологіями, а навчити студентів ефективно користуватися інструментами ШІ, доповнюючи ними власні знання й уміння [3].

ВИСНОВКИ.

Штучний інтелект стає одним із ключових чинників трансформації сучасної освіти, відкриваючи значні можливості для персоналізації навчання, підвищення доступності та оптимізації роботи викладачів. Водночас його використання пов'язане з низкою ризиків — від посилення академічної недоброчесності до загроз конфіденційності та появи алгоритмічних упереджень. Ефективне впровадження технологій ШІ можливе лише за умови збереження балансу між інноваціями та етичними вимогами. Освітні заклади мають формувати чіткі правила використання ШІ, а студенти — розвивати критичне мислення та вміння відповідально застосовувати цифрові інструменти. У такому разі штучний інтелект доповнюватиме навчальний процес, посилюючи його якість, а не підміняючи людську працю.

СПИСОК ПОСИЛАНЬ.

1. *Інтеграція технологій штучного інтелекту в освітню галузь: виклики та перспективи.* URL: <https://doi.org/10.31652/2412-1142-2025-75-161-172>
2. *Штучний інтелект і якість освіти: можливості, виклики та загрози.* URL: <https://doi.org/10.32405/2663-5739-2028-8-232-248>
3. *Use of artificial intelligence in higher education: state and trends.* URL: <https://doi.org/10.46299/j.isjel.20240302.04>

Здирок М.А. (ВСП «Стрийський фаховий коледж ЛНУП», Стрий, Україна)

ВИКОРИСТАННЯ ШТУЧНОГО ІНТЕЛЕКТУ В ЕТИЧНИХ РАМКАХ ЗАГРОЗИ ДЛЯ СУСПІЛЬСТВА.

Анотація. У статті проаналізовано етичні, соціальні та філософські аспекти розвитку штучного інтелекту (ШІ), що стає одним із ключових чинників трансформації сучасного суспільства. Показано, що швидке поширення нейромережних технологій породжує подвійний ефект: з одного боку, ШІ сприяє прогресу в медицині, освіті, транспорті, комунікаціях та економіці; з іншого — створює ризики для людської автономії, приватності, моральної відповідальності та ідентичності. Особливу увагу приділено антропологічним наслідкам взаємодії людини й ШІ, що впливають на межі людської суб'єктивності та можливість її часткового «розмивання» у техносфері. Розглянуто позиції провідних науковців і технологічних експертів — Стівена Гокінга, Ілона Маска, Сергія Бріна, Джона Маккарті та інших — які наголошують на соціальних загрозах, потребі державного регулювання та формуванні глобальних етичних стандартів. У статті узагальнено принципи етичного контролю, запропоновані Європейським Союзом, та підкреслено важливість антропоцентричного підходу, що ставить людські цінності в центр розвитку інтелектуальних технологій. Зроблено висновок, що ШІ потребує науково обґрунтованого та відповідального регулювання, здатного мінімізувати ризики і водночас забезпечити реалізацію його суспільного потенціалу.

Ключові слова: мораль, етичні принципи, штучний інтелект, нейромережі, антропоцентризм, технологічні ризики.

Abstract The article examines the ethical, social, and philosophical implications of artificial intelligence (AI), which is becoming one of the key drivers of modern societal transformation. It is shown that the rapid spread of neural-network technologies creates a dual effect: on the one hand, AI stimulates progress in medicine, education, transportation, communications, and economics; on the other hand, it generates risks related to human autonomy, privacy, moral responsibility, and personal identity. Special attention is paid to the anthropological consequences of human–AI interaction, which may blur the boundaries of human subjectivity within the expanding technosphere. The article discusses the viewpoints of leading researchers and technology experts — Stephen Hawking, Elon Musk, Sergey Brin, John McCarthy, among others — who emphasize social dangers, the need for regulatory oversight, and the development of global ethical standards. The ethical principles proposed by the European Union for trustworthy AI are summarized, highlighting transparency, human control, responsibility, and societal benefit. The study concludes that AI development requires scientifically grounded and responsible regulation that aligns technological progress with humanistic values and minimizes potential threats while preserving the positive impact of AI on societal advancement.

Keywords: morality, ethical principles, artificial intelligence, neural networks, anthropocentrism, technological risks.

Постановка проблеми. Нейромережа сьогодні набула ширшого значення, яка приносить масштабні зміни в середовищі суспільства. Це стосується ризику, коли людська суб'єктивність може втратити своєособливість, а її самостійні межі стають неясними. Вивчення цієї проблеми потребує діалогу між гуманістичною традицією та технологічним підходом, враховуючи поступовий розвиток рішень, прийнятих штучним інтелектом. Антропологічний аспект розглядає питання про природу людини як суб'єкта мислення, дії та рефлексії під впливом штучного інтелекту. Тому важливо відповісти на запитання: чи може штучний інтелект стати загрозою для ідентичності людської суб'єктивності або, навпаки, може використовуватися як інструмент її зміни. У цьому контексті дискусія про етичні основи стосунків між людиною та технікою, разом з необхідністю збереження антропоцентричної позиції в світі, що стає технологічною реальністю, потребує більшої уваги.

Аналіз останніх публікацій. Аналіз етичних проблем, пов'язаних із штучним інтелектом, стає особливо важливим у зв'язку з швидким розвитком технологій, які безпосередньо впливають на людську індивідуальність. Останні дослідження підкреслюють

необхідність перегляду традиційних уявлень про людську ідентичність у контексті цифрових змін і автоматизації. У сучасних наукових та громадських дискусіях питання розвитку штучного інтелекту розглядається як з позиції його переваг, так і ризиків. Ілон Маск підкреслює, що невідповідальний розвиток ШІ може виходити з-під контролю і стати більш небезпечним, ніж загрози від Північної Кореї. Він наголошує на необхідності державного регулювання, щоб забезпечити безпеку суспільства (Elon Musk, 2025). Подібну думку висловлює Стівен Гокінг, який вважає, що без контролю ШІ може стати однією з найсерйозніших загроз для людства, хоча одночасно він підтримує його потенціал у рішенні багатьох глобальних проблем, таких як бідність чи хвороби (Hawking, 2017). Майкл Вассар також застерігає, що безпека впровадження потужного ШІ – це критично важливе питання для виживання людства (Vassar, 2025). При цьому засновники ШІ, такі як Джон Маккарті, розглядали його не як інструмент для психології, а як засіб для розв'язання задач у комп'ютерних науках, що дозволяє підвищувати ефективність людської діяльності (McCarthy, 1988). Сучасні приклади застосування ШІ підтверджують ці очікування. Білл Гейтс зазначає, що технології ШІ збільшують продуктивність і ефективність у багатьох сферах, включаючи транспорт, медицину, освіту та бізнес (Погореленко, 2025). Сьогодні особливу увагу в дослідженнях приділяють медичному використанню ШІ. Наприклад, система Google DeepMind може аналізувати знімки сітківки та встановлювати понад 50 діагнозів, що збільшує точність і швидкість медичних рішень (Штучний інтелект навчився діагностувати очні хвороби, 2023). Сергій Брін, засновник Google, попереджає, що ШІ може бути використане для маніпуляцій з людьми, а також звертає увагу на неможливість відповідальності за рішення, прийняті штучним інтелектом (Погореленко, 2025). Такі моральні ділеми, у тому числі щодо безпілотних автомобілів, аналізує Рогожа (2023), що підкреслює відмінність між моральними можливостями людини та алгоритмів ШІ. У філософському контексті І. Кант підкреслює, що моральний закон має універсальну природу і може застосовуватися до етичного регулювання ШІ (Кант, 1965). Однак обмежені можливості ШІ у виборі, що залежить від емоцій та раціональних міркувань, вказують на фундаментальну різницю між людиною та машинами, що вимагає особливого підходу до формування етичних стандартів (Рогожа, 2023). Таким чином, сучасні дослідження показують, що ШІ має подвійну природу: з одного боку, він відкриває широкі можливості для розвитку суспільства та технологій, а з іншого – створює потенційні етичні та соціальні загрози, які потребують наукового обґрунтування регулювання та дотримання етичних норм.

Мета роботи полягає в етичному усвідомленні впливу штучного інтелекту, спрямованого на реальну загрозу для суспільства, співвідношення діяльності нейромережі з людськими факторами, людей.

Виклад основного матеріалу. Мораль - феномен суто людського світу. Традиційно людина плекала свою людськість, відмежовуючи себе від світу природи. Нині етика актуалізується у зв'язку з питаннями про те, чи потрібно людині дистанціюватися від штучного інтелекту, чи потрібно створювати етичну регламентацію в галузі штучного інтелекту і на що в ній слід спиратися й куди акцентувати увагу?

Ці питання виникають в обставинах, за яких вчені поколіннями працювали на те, щоб технічно забезпечити комфортне існування людини, яке, серед іншого, призвело до певної міри зрощування людини з машиною. Сьогодні буденністю нашого життя є кіборги - біологічні істоти, в які вживлено механічні чи електронні компоненти. Коли штучні органи, суглоби, тканини стають звичними в людському організмі, постає питання, до якої міри людина залишається людиною, приростаючи електронними чи механічними пристроями?

Вчені вказують, що робота мозку людини пов'язана з дією органів чуттів і контролем біологічного тіла, тому повноцінно мозок може працювати лише на біологічній основі. Отже, поки людина ідентифікує себе людиною, поки механічні чи електронні пристрої не усувають її інтелектуально-чуттєву природу, доти вона ідентифікує себе людиною в єдності розумового, тілесного й емоційного. Штучний же інтелект має іншу природу - він від початку є машиною.

Й різного роду намагання розробників надати йому антропологічні форми не усувають цієї висхідної ситуації, яка задає зовсім іншу тональність етичних проблем.

Так, робот Софія має антропоморфну форму й може висловлювати емоції, і сама наявність такого механізму провокує питання ціннісного характеру. Усвідомлюючи потенційну загрозу від самокерованості штучного інтелекту, у 2018 р. в Європейському Союзі розпочато роботу експертів над визначенням етичних принципів розвитку штучного інтелекту. На сьогодні виокремлено такі: штучний інтелект має заслуговувати на довіру, відповідати законам та правилам, передбачати контроль з боку людини, враховувати інтереси суспільства та права людини, бути надійним, безпечним, стабільним, поважати приватність людини та безпеку даних про неї, бути прозорим, враховувати всі людські особливості, включаючи фізичну спроможність, сприяти розвитку суспільства тощо. Усі сім принципів, по великому рахунку, можуть бути охоплені одним метапринципом - контроль в ім'я безпеки людини.

Варто зазначити думку Джона Маккарті про початковий напрямок досліджень в області штучного інтелекту: «Мета полягала в тому, щоб припинити вивчення поведінки людини та розглядати комп'ютер як інструмент для розв'язання певних задач. Отже, штучний інтелект став частиною комп'ютерної науки, а не психології». Важливо зазначити, що різниця між штучним інтелектом та людським інтелектом поступово збільшується, оскільки системи штучного інтелекту все більш ефективно виконують функції людини в різних сферах життя.[8, с.4].

Поява штучного інтелекту (AI – artificial intelligence) може стати «найгіршою подією в історії нашої цивілізації», якщо людство не знайде спосіб контролювати його нестримний розвиток. Про це заявив видатний фізик Стівен Хокінг, виступаючи на технологічній конференції Web Summit у Ліссабоні, Португалія. «Теоретично комп'ютери можуть наслідувати людський розум і навіть перевершувати його», – сказав він. За словами вченого, штучний інтелект можна використовувати для того, щоб зменшити шкоду, яку завдає людство навколишньому середовищу, щоб викоринити бідність і хвороби, однак майбутнє і досі невизначено. «Створення AI може бути як найбільшим успіхом в історії нашої цивілізації, так і найгіршою подією. Ми просто не знаємо. Невідомо, чи буде AI безкінечно допомагати нам, чи просто відсуне нас вбік, розвиваючись все ширше, чи знищить нас», – сказав Хокінг[5]

На думку одного з творців «Google» Сергія Бріна, штучний інтелект небезпечний насамперед тим, що може бути використаний для маніпулювання людьми. Він також піднімає питання щодо впливу штучного інтелекту на працевлаштування в різних галузях, розуміння того, що відбувається всередині цих технологій та щодо оцінки їх об'єктивності та безпечності. Додатковий «мінус» штучного інтелекту – відсутність допоміжного блоку автономної (усвідомленої) відповідальності ухвалення остаточного рішення, що свідчить про неможливість ухвалення адекватних рішень. Але, якими б депресивними очікуваннями не наповнювали деякі фахівці інформаційне поле стосовно перспектив розвитку штучного інтелекту, поки очевидно одне: негативні наслідки від розвитку штучного інтелекту повністю нівелюються позитивними результатами та перспективами від його використання[3, с.25].

Якщо говорити про більш серйозну загрозу, Ілон Маск сказав, що небезпека, яку становить штучний інтелект, є більшою, ніж загроза, яку становить Північна Корея. У супровідному твіті Маск детальніше розповів про необхідність регулювання розробки систем штучного інтелекту. Це перегукується з його словами на початку цього місяця: «Штучний інтелект — це просто те, що, на мою думку, становить ризик для громадськості, заслуговує принаймні на розгляд з боку уряду, оскільки одним із завдань уряду є добробут громадськості».

Такі експерти, як [Стівен Хокінг](#), давно попереджали про потенціал штучного інтелекту знищити людство. В інтерв'ю 2014 року відомий фізик заявив, що «розвиток штучного інтелекту може означати кінець людської раси». Більше того, він розглядає поширення автоматизації як згубну силу для середнього класу. Інший експерт, [Майкл Вассар](#), головний

науковий співробітник MetaMed Research, заявив: «Якщо штучний інтелект, що перевершує людський, буде винайдено без належної обережності, майже напевно, що людський вид дуже швидко вимре». [7]

Інший пласт проблем з безпілотними автомобілями виникає також щодо питань безпеки. Самокерований автомобіль рекламується як такий, що на порядки є безпечнішим, ніж керовані людиною машини. У випадку аварії машина буде діяти раціонально, відповідно до того, як вона запрограмована - врятувати свого власника за рахунок усього іншого світу. Власне, все «людське» тут виключається від початку - емоції, імпульси, пориви, самопожертва водія (наприклад, якщо дитина вибігла на проїжджу частину) як таке, що не входить у програму збереження пасажирів. Власне, для дилеми вагонетки тут просто не залишається місця. І факти лише підтверджують такі міркування. Свого часу була оприлюднена версія причин автомобільної аварії у США, коли безпілотний автомобіль збив на смерть жінку, яка переходила дорогу в недозволеному місці. Причиною аварії стала помилка у розпізнаванні об'єкту, що рухався.

Свого часу І.Кант в «Основах метафізики моральності» надав аргумент сучасним захисникам запровадження етичних принципів для штучного інтелекту, внісши розрізнення понять людини і розумної істоти: «Значення морального закону до такої міри просторе, що воно має силу не лише для людей, а й для всіх розумних істот взагалі». Моральний закон в такому ракурсі є універсальним моральним приписом для будь-якої розумної істоти. Це дозволяє стверджувати, що моральний закон чинний і для штучного інтелекту. Але на це є й контраргумент: штучний інтелект не має єдності інтелектуальної й емоційної, заснованої на біологічній природі суб'єкта, що завжди людині дає можливість списати скоєне на «людський фактор», вчинити нелогічно/ нерационально, проте героїчно, жертвно - на пориві, імпульсі, заради іншого.

Власне, це дає підстави визначати, що кіборг - це людина, а носій штучного інтелекту - завжди машина.[4, с.48-49].

Будь який технологічний продукт сьогодні – це результат колективної праці науковців, інженерів, технологів, фахівців з обробки даних, дизайнерів та ін. Його створюють в одній частині світу, користуються його можливостями та перевагами – в іншій. Саме штучний інтелект надає можливості кооперуватись та обмінюватись результатами труда для покращення нашого щоденного життя. Це тільки здається, що в постіндустріальну епоху відношення до нього мають виключно представники країн, які відчувають на собі усі переваги VI технологічного укладу.

Почнемо з самих очевидних переваг, які супроводжують активний розвиток штучного інтелекту останнім часом та роблять життя, за словами Білла Гейтса, «продуктивнішим, ефективнішим та загалом легшим»: «розумне» регулювання руху та зменшення «пробок» на дорогах; підвищення ефективності діагностичних алгоритмів в медицині; персональні помічники-асистенти людини; використання біометричних можливостей та заміна стандартної кредитної картки для розпізнавання людини; охорона правопорядку за допомогою використання спеціальних систем визначення районів потенційних правопорушень; подальший розвиток «розумних» міст; написання унікальних текстів та музики відповідно в залежності до вподобань людини; вдосконалення ефективності освітньої діяльності за рахунок індивідуального підходу; повсякденне використання віртуальної реальності та ін. Варто відмітити, що штучний інтелект стане незамінним помічником й в бізнесі. Враховуючи те, що діяльність суб'єктів господарювання є основою розвитку економіки будь-якої країни, використання можливостей штучного інтелекту є запорукою росту.

Важлива умова – якість бізнес-моделі підприємства та, відповідно, продукту (роботи, послуги), який воно бажає просувати на ринку[3, с.26].

Щодо використання можливостей штучного інтелекту в медицині, то кращого помічника в постановці діагнозу (інколи доволі суттєвої проблеми, яка є причиною помилкових «протоколів» лікування) та призначенні саме персоналізованої терапії, заснованої на аналізі великої кількості даних пацієнта, важко знайти. Як повідомляється, найближчим

часом в медицині розпочали активне використання ШІ від Google. Йдеться про DeepMind, на основі якого розробили нейромережу. Дана система дозволить з використанням усього одного знімку сітківки діагностувати понад 50 хвороб очей. Для встановлення діагнозу штучний інтелект використовує метод оптичної когерентної томографії (ОКТ), що являє собою неінвазивну безконтактну візуалізацію структури ока. Зображення, отримані за даним методом, схіжі зі знімками УЗД, однак, роздільна здатність є значно вищою, що допомагає зробити так звану "біопсію без видалення тканин" для виявлення різноманітних структур та аномалій розвитку.

Для розробки нової технології дослідники Google DeepMind об'єдналися із вченими Британського центру з боротьби з захворюваннями очей Moorfields Eye Hospital, що має широку базу знімків ОКТ.

Технологія ОКТ має переваги, але є і досить вагомий недолік - до тижня часу може бути витрачено на обробку та інтерпретацію знімків. В деяких випадках пацієнт може не мати стільки часу, оскільки рішення треба приймати якнайшвидше. В цьому аспекті ШІ має суттєву перевагу. Одна нейромережа у складі штучного інтелекту переводить необроблені знімки ОКТ у карту тривимірних тканин і встановлює попередній діагноз. Друга є нейромережа робить аналіз тривимірної карти, перевіряє точність встановленого діагнозу та визначає терміновість медичної допомоги хворому. Система створює тривимірну модель ока, визначає захворювання та навіть повідомляє, в якій ділянці ока виник осередок захворювання. Штучний інтелект наразі пройшов стадію навчання на тривимірних зображеннях тканин ока та сканак ОКТ, а наразі бере участь у випробовуваннях на базі Moorfields Eye Hospital. Якщо результати задовільнять спеціалістів, систему почнуть використовувати по всій території Великої Британії[6].

Як зазначають у Єврокомісії, штучний інтелект може застосовуватися у багатьох сферах, включаючи охорону здоров'я, споживання енергії, безпеку автомобільної техніки, фермерське виробництво, боротьбу з кліматичними змінами, моніторинг фінансових ризиків та у багатьох інших. Штучний інтелект може допомагати у викритті шахрайства або зловживань, кібернетичних злочинів та загроз, стати ефективним інструментом в руках правоохоронних органів для боротьби проти злочинності. Водночас, використання таких технологій несе нові виклики правового та етичного характеру. У вирішенні цієї проблеми Єврокомісія дотримується правила "трьох кроків": визначення ключових вимог до штучного інтелекту, якому можна довіряти, обговорення таких вимог із представниками промисловості та користувачами в рамках пілотного проекту, результатом яких має розбудова міжнародного погодження щодо розбудови штучного інтелекту виключно в інтересах людини.

На сьогодні європейські експерти визначили сім ключових принципів, яким має відповідати штучний інтелект.

Передусім, він має заслуговувати на довіру, відповідати законам та правилам.

По-друге, штучний інтелект має обов'язково передбачати контроль з боку людини, розроблятися з повагою до інтересів суспільства та прав людини, не зменшувати та не обмежувати право людини на прийняття рішень.

Третє правило – надійність та безпека. Всі такі системи мають бути достатньо стабільними на випадок помилок або дисфункції систем на весь період їхнього функціонування.

Четверта вимога – повага до приватних прав людини та до безпеки баз даних, коли такі дані не будуть використовуватися проти людини.

П'яте правило – прозорість. Людина має отримати можливість відслідковувати результати діяльності штучного інтелекту або відповідних систем.

Шосте - ці системи мають застосовуватися на недискримінаційній основі, тобто, штучний інтелект має враховувати всі людські особливості, включаючи фізичну спроможність, навички та потреби, і бути доступним для всіх людей.

Сьоме – такі системи мають сприяти розвитку суспільства та вирішенню проблем охорони довкілля, що передбачає принцип відповідальності людини за використання систем штучного інтелекту та за результати такої діяльності.

Як наголошується, Єврокомісія прагне винести цей підхід щодо розбудови «етичного» штучного інтелекту на глобальне обговорення, тому що новітні технології та алгоритми не знають жодних кордонів. Вже зараз для досягнення цієї мети Євросоюз зміцнює двосторонню співпрацю з ключовими міжнародними партнерами, зокрема з Японією, Канадою, Сінгапуром, ініціює обговорення зазначеного питання в форматі «Великої сімки», «Великої двадцятки», залучає до таких дискусій міжнародні компанії та організації.

За оцінкою [Єврокомісії](#), яка міститься у Стратегії ЄС щодо розвитку штучного інтелекту, прийнятій у квітні 2018 року, обсяг державних та приватних інвестицій у цю галузь у європейських країнах може сягати до 20 мільярдів євро щороку, принаймні, протягом наступних 10 років. [1].

У філософському розумінні етика штучного інтелекту – це перегляд меж людської суб'єктивності та відповідальності, яка лежить на людині як творцеві та користувачі технологій. Оскільки штучний інтелект є продуктом людського інтелекту, він має радше діяти для покращення людських здібностей, ніж замінювати їх основними функціями. Особливої гостроти питання набуває в тих випадках, коли межа між людиною та пристроєм набуває більш відчутних обрисів – це має викликати не лише технічний контроль, а й глибоке філософське осмислення. Технологічний розвиток має здійснюватися таким чином, щоб забезпечити збереження основних характеристик людської природи – самовизначення, здатності до моральної рефлексії, творчості та міжособистісних стосунків. Філософська антропологія має перетворитися на один із рівнів наукового аналізу, де постає питання пошуку оптимальної пропорції розвитку між техносферою (провідним втіленням науково-технічного прогресу) та антропосферою (глибоко гуманістичною, що виражає цілісні гуманістичні принципи буття людства). вийде на перший план.

Зворотний бік цієї медалі найкраще виражено в практичних термінах: якщо техносфері буде приділено надмірний акцент у її розвитку, а антропосферою знехтовано, виникне реальна небезпека того, що людина буде зведена до рівня додатка до технічної системи. Втрати його суб'єктивності, а також автономії можуть розглядатися як великі в цьому контексті. І навпаки, наголос на антропосфері, коли технологія відстає, гальмує прогрес – вона випереджає зміни та перешкоджає належній реакції людства на виклики сьогодення. Етика коеволюції людини та штучного інтелекту повинна означати не залишати штучний інтелект у рамках чистого виконання функцій автоматизації, а зробити його радикальним інструментом посилення людської суб'єктивності. З цією метою слід розглядати штучний інтелект як засіб, що підкреслює особливості людської вдумливості, емоційності та креативності, причому кожен екземпляр є особливим і всі вони доповнюють один одного, але не замінюють один іншого. Розробка етичних стандартів регулювання взаємодії людини і машини важлива в тих сферах, де рішення, що приймаються за участю ШІ, можуть суттєво впливати на життя людини, таких як медицина, освіта, юриспруденція, управління. Тут на перший план виходить розвиток «надійної етики» на основі прозорості, справедливості та відповідальності. Лише узгодженим розвитком антропосфери і техносфери можна запобігти дегуманізації людства і забезпечити розвиток гуманістично орієнтованої цивілізації[2, с.74-75].

Штучний інтелект – не людина. Його можна формувати в більш точних сферах, де є розрахунки, освіта, медицина, але мають бути запрограмовані етичні рамки з якими нейромережа має працювати. Він не може «відчувати» як краще, згодом буде небезпечним для нас, ми маємо розуміти наскільки важливо загартовувати рамки етики у діяльності штучного інтелекту.

ВИСНОВКИ.

Отже, можна зробити висновок, що штучний інтелект має зчитувати гуманістичні норми, і тому має бути прийнятий антропоцентричний підхід, з яким він не буде панувати над

людством. Удосконалення його – або негативні наслідки як для суспільства, так і для всього живого, оскільки унікальність особистостей стирається, або позитивні наслідки в процесі використання в середовищах природничих науках. Це питання обговорюють вже багато науковців, приводячи в приклад атомну зброю, поки вона не була вдосконалена, люди не обговорювали проблему етики штучного інтелекту, а коли ядерні розробки стали реальною загрозою для суспільства, постало нове питання « Чи варті вони права на існування серед мирного атому, принісши в цей світ мільйони жертв?». Потім це питання стало пізно піднімати, так і з штучним інтелектом- поки нема реальної загрози, в першу чергу формувати етичні норми в налаштуваннях цієї машини.

СПИСОК ПОСИЛАНЬ.

- 1.В Євросоюзі розробили «етикет» для штучного інтелекту. Укрінформ. 08.04.2019.
URL: <https://www.ukrinform.ua/rubric-technology/2676698-vevrosouzi-rozrobili-etiket-dla-stucnogo-intelektu.html>
- 2.Іванова О. В. Етичні виклики штучного інтелекту: антропологічний вимір людської суб'єктності // Актуальні проблеми філософії та соціології. – 2024. – Вип. 51.
DOI: <https://doi.org/10.32782/apfs.v051.2024.12>
- 3.Погореленко А. К. Штучний інтелект: сутність, аналіз застосування, перспективи розвитку. Факультет консалтингу і міжнародного бізнесу, Харківський національний економічний університет імені Семена Кузнеця, 2025.
- 4.Рогоза М. М. Моральні дилеми у галузі штучного інтелекту. Категорії. Мораль: зб. наук. матеріалів... – Київ: Знання України, 2019. – С. 45–50.
URL: <https://ekmair.ukma.edu.ua/handle/123456789/18081>
- 5.Стівен Хокінг: штучний інтелект може стати найгіршим винаходом людства.
URL: <https://mind.ua/news/20178313-stiven-hokingshtuchnij-intelekt-mozhe-stati-najgirshim-vinahodom-lyudstva>
- 6.Штучний інтелект навчився діагностувати очні хвороби.URL: <http://bukovina.biz.ua/news/48130>
- 7.Elon Musk Reminds Us of the Possible Dangers of Unregulated AI.
URL: <https://futurism.com/elon-musk-reminds-us-of-the-possible-dangers-of-unregulated-ai>
- 8.McCarthy John. Book Review of B. P. Bloomfield The Question of Artificial Intelligence: Philosophical and Sociological Perspectives. Annals of the History of Computing, 10(3), 1988: 1–9.

УДК 004.8:378.1

Ковалевський С.В. (Донбаська державна машинобудівна академія, м. Краматорськ-Тернопіль, Україна), **Володченко Ю.М.** (ІТ-компанія QuartSoft, Україна).

НОВИЙ ЕТАП РОЗВИТКУ ОСВІТНЬО-ДОСЛІДНИЦЬКОГО СЕРЕДОВИЩА ЮНИХ ДОСЛІДНИКІВ.

Анотація. У статті розглянуто концепцію розвитку Академії дослідників штучного інтелекту (АДШІ) як освітньо-наукового проєкту нового типу, спрямованого на формування дослідницьких компетентностей молоді у сфері штучного інтелекту. Проаналізовано три рівні підготовки — «Юні дослідники», «Молоді науковці» та «Future AI Innovators», що забезпечують безперервну траєкторію зростання від базових знань до наукової творчості. Розкрито методологію діяльності АДШІ, засновану на принципі «learning by creating» і використанні інтерактивних форматів вебінарів («AI Detective», «Лабораторія ідей», «Hackathon Light»). Показано, що філософія проєкту спрямована на перехід від користування ШІ до дослідницького осмислення його меж та

можливостей. Окреслено екосистему взаємодії між учасниками, установами-партнерами (ДДМА, ВНТУ, ІПШІ НАН України, QuartSoft) та GPT-інструментами. Підкреслено соціальну значущість АДШІ як платформи розвитку критичного мислення, самостійності й етичної культури у цифрову епоху.

Ключові слова: Академія дослідників ШІ, освіта 4.0, дослідницькі компетентності, штучний інтелект, GPT, критичне мислення, інтерактивне навчання, екосистема.

Abstract. The paper presents the development concept of the Academy of Artificial Intelligence Researchers (AAIR) as an innovative educational and research project aimed at fostering research competences among youth in the field of artificial intelligence. Three levels of training are defined – “Junior Researchers,” “Young Scientists,” and “Future AI Innovators,” which form a continuous learning trajectory from basic knowledge to scientific creativity. The methodology is based on the “learning by creating” principle and interactive webinar formats (“AI Detective,” “Idea Lab,” “Hackathon Light”). The pedagogical philosophy emphasizes the shift from using AI as a tool to understanding its limitations and possibilities through critical inquiry. The article outlines the AAIR ecosystem connecting students, educators, partner institutions (DSEA, VNTU, Institute for Problems of Artificial Intelligence of NAS of Ukraine, QuartSoft), and GPT-based platforms. The project is shown as a socially significant model for cultivating critical thinking, autonomy, and ethical awareness in the digital age.

Keywords: Academy of AI Researchers, Education 4.0, research competences, artificial intelligence, GPT, critical thinking, interactive learning, ecosystem.

1. Вступ

Академія дослідників штучного інтелекту (АДШІ) виникла як спільна ініціатива викладачів ДДМА, та ІПШІ НАН України за підтримки ІТ-компанії QuartSoft, щоб створити нову модель науково-освітнього простору, де штучний інтелект не є метою, а стає інструментом формування особистості дослідника. Уперше ідея була озвучена у 2024 р. під час серії вебінарів для шкільної молоді Донеччини, які проводилися в умовах війни, дистанційності та вимушеної міграції. З того моменту АДШІ почала еволюціонувати з ініціативи у повноцінну навчально-дослідницьку платформу, здатну об'єднувати учнів, студентів, викладачів і ШІ-технології в єдину мережу інтелектуального зростання.

2. Концепція та структура Академії

АДШІ розвиває три рівні підготовки, що відповідають віковим і когнітивним особливостям учасників:

1. «Юні дослідники» (12–14 років) — перший рівень, орієнтований на формування інтересу до ШІ через ігрові форми, історії та творчі завдання.
2. «Молоді науковці» (15–17 років) — другий рівень, де відбувається перехід до аналітичного мислення, розробки моделей, програм і міні-досліджень.
3. «Future AI Innovators» (18+, коледжі) — третій рівень, який передбачає створення повноцінних інженерних рішень, симуляцій і наукових статей.

Кожен рівень є частиною інтегрованого навчального циклу, де вебінари, лабораторії, конкурси та конференції пов'язані в єдиний ланцюг становлення дослідника. Згідно з «Інтегрованим планом вебінарів АДШІ на 2025–2026 н.р.», усі заняття синхронізовані між рівнями, що створює ефект вертикальної єдності — від першого «знайомства через ШІ» до захисту власної наукової роботи.

3. Методологія діяльності АДШІ

Кожен вебінар АДШІ — це не лекція, а інтерактивна дослідницька подія, під час якої учасники самостійно створюють ідеї, перевіряють гіпотези, працюють у групах і з ШІ як співрозмовником, а не «вчителем».

Зокрема:

- заняття «AI Detective» навчає критично перевіряти знання ШІ та бачити його межі;
- «Лабораторія ідей» формує середовище спільного мислення через «аукціон тем»;

- «Промпти у дії» і «Промпт-інжиніринг» перетворюють запитання на дослідницький інструмент;
- «Code Challenge» і «Перша модель» закладають основи програмування та машинного навчання;
- «Hackathon Light» та «Проміжний захист» готують учасників до наукових конференцій, таких як «Молода наука – 2026».

Усі матеріали побудовані за принципом “learning by creating” — учасник пізнає світ ШІ не спостерігаючи, а творячи.

4. Педагогічна філософія: від користувача до дослідника

В основі філософії АДШІ лежить ідея становлення мислячої особистості через ШІ, сформульована її засновником як принцип:

«АДШІ повинна виловлювати не користувачів, а дослідників».

Цей підхід передбачає, що кожен учасник проходить п'ять стадій розвитку: Спостерігач → Учень смислу → Конструктор гіпотез → Інженер істини → Дослідник буття.

На кожному етапі змінюється не лише рівень знань, а й тип мислення — від простого запиту до рефлексії над власними ідеями.

АДШІ тим самим стає лабораторією інтелектуальної еволюції, де ШІ виконує роль інструмента, партнера й дзеркала мислення. У цьому полягає її новаторство: технологія повертає учня до самого себе.

5. Екосистема АДШІ та зовнішній вплив

Проект виходить за межі освітнього середовища, формуючи систему соціального впливу, спрямовану на залучення молоді Донеччини та всієї України, включно з тими, хто вимушено залишив свої домівки.

Система включає:

- мережу онлайн-вебінарів і консультацій,
- механізми залучення через соціальні медіа (Telegram, Facebook, Instagram),
- партнерські осередки у школах та коледжах,
- конкурси, хакатони, пітчі та наукові сесії.

Як зазначено у хроніці розвитку АДШІ, це не просто інформаційна кампанія, а “система зовнішнього впливу”, яка вже діє, залучаючи перших слухачів через попередні вебінари та новий комунікаційний пакет «Перший виклик АДШІ».

6. Роль цифрових інструментів і GPT-екосистеми

АДШІ активно інтегрує сучасні ШІ-інструменти — від ChatGPT, Teachable Machine, Canva Magic Media до платформ симуляцій (ANSYS, Onshape). Учасники не просто знайомляться з ними, а вчаться обирати, аналізувати й критично використовувати їх.

Створено концепцію «інвентаризації ШІ-інструментів для дослідників» — таблицю, де кожен інструмент оцінюється за функцією, рівнем дослідника, етичними ризиками й потенціалом розвитку. Це дозволяє учням поступово входити в професійну культуру роботи з технологіями, розуміючи, що етика використання важливіша за швидкість результату.

7. Інституційна співпраця і перспективи

АДШІ спирається на потужну мережу партнерів:

- Донбаська державна машинобудівна академія (науково-методичне керівництво, технічні лабораторії);
- Інститут проблем штучного інтелекту НАН України (науковий супровід, дослідження ШІ);
- QuartSoft (технологічна підтримка, IT-менторство).

Подальший розвиток передбачає:

1. створення інтерактивної ННД-платформи АДШІ, інтегрованої з GPT-асистентами;
2. формування мережі “AI-лабораторій” у школах і коледжах;

3. вихід на міжнародні освітні проєкти (UNESCO, Intel AI for Youth, AI for Good Foundation).

8. Висновки

АДШІ сьогодні — це не лише освітній експеримент, а новий тип інтелектуального простору, у якому ШІ стає каталізатором людського мислення. Завдяки структурованим рівням навчання, інтерактивним форматам і методології критичного використання технологій Академія створює умови для народження покоління українських дослідників ШІ, здатних не просто користуватись моделями, а створювати власні. Цей рух — доказ того, що навіть у часи невизначеності й війни освіта може залишатися простором творчості, гідності та майбутнього.

УДК 004.896:004.4'42:378.147

Ковалевський С.В. (Донбаська державна машинобудівна академія, м. Краматорськ-Тернопіль, Україна), **Мельник С.В., Сорока М.О.** (Вінницький національний технічний університет, Вінниця, Україна).

ІНТЕЛЕКТУАЛЬНИЙ НЕЙРОМЕРЕЖНИЙ АСИСТЕНТ У ЦИФРОВІЙ ПІДГОТОВЦІ ІНЖЕНЕРІВ.

Анотація. У статті представлено результати розроблення та впровадження Інтерактивного асистента ІКС — інтелектуальної системи підтримки навчального процесу для підготовки інженерів у галузі інтелектуальних керуючих систем. Асистент реалізує принципи адаптивного навчання, цифрового двійництва, симуляційного моделювання та діалогової взаємодії студента з навчальними моделями. Описано архітектуру асистента, що включає ядро знань, мовний інтерфейс на основі GPT-моделі, інтеграційні модулі з CAD/CAE-середовищами та аналітичний блок моніторингу прогресу. Впровадження системи у навчальний процес Донбаської державної інженерної академії показало скорочення часу підготовки до лабораторних занять, зростання самостійності здобувачів і підвищення якості експериментальних робіт. Розробка ІКС-асистента відповідає сучасним концепціям освіти 4.0, інтегруючи когнітивні, методологічні й технологічні складові для формування дослідницьких компетентностей інженерів майбутнього.

Ключові слова: штучний інтелект, цифровий асистент, інтелектуальні керуючі системи, цифровий двійник, CAD/CAE, освіта 4.0, адаптивне навчання, симуляція.

Abstract. The article presents the development and implementation results of the Interactive ICS Assistant – an intelligent learning support system designed for engineering education in the field of intelligent control systems. The assistant applies the principles of adaptive learning, digital twin technology, simulation modeling, and natural language interaction with educational models. The architecture includes a knowledge core, a GPT-based language interface, CAD/CAE integration modules, and an analytics block for progress tracking. Implementation in the educational process of Donbas State Engineering Academy demonstrated a 30–40% reduction in preparation time for laboratory classes, increased student autonomy, and improved quality of experimental projects. The ICS Assistant reflects the principles of Education 4.0 by integrating cognitive, methodological, and technological dimensions to foster research and engineering competencies of future professionals.

Keywords: artificial intelligence, digital assistant, intelligent control systems, digital twin, CAD/CAE, Education 4.0, adaptive learning, simulation.

1. Вступ

Освітній простір XXI століття потребує не лише модернізації інструментів, а й нового підходу до взаємодії людини з знаннями. У галузі технічних наук, де кожна навчальна задача

може бути перетворена у цифровий експеримент, використання штучного інтелекту відкриває можливості для персоніфікованого навчання, дослідницького мислення та створення цифрових лабораторій.

У цьому контексті створено Інтерактивного асистента ІКС (ICS Assistant) — інтелектуальний цифровий помічник, який поєднує можливості генеративних моделей ШІ, хмарних освітніх платформ, CAD/CAE-середовищ та лабораторних симуляторів для підтримки циклу навчання *від лекції до наукового дослідження*.

2. Мета і завдання дослідження

Метою проєкту є розроблення інтерактивного асистента навчальної дисципліни «Інтелектуальні керуючі системи», здатного:

- адаптувати навчальний контент до рівня підготовки студента;
- генерувати завдання, тести, лабораторні інструкції;
- забезпечувати інтеграцію з цифровими моделями і симуляціями;
- підтримувати дослідницькі проєкти, в тому числі аспірантські;
- виступати засобом самооцінювання та аналітики навчальних результатів.

У процесі створення ІКС-асистента використовувалася методологія цифрового двійництва навчального процесу, коли кожен елемент освітньої діяльності (завдання, експеримент, лабораторія) має свою цифрову копію у віртуальному середовищі.

3. Архітектура та технологічна основа асистента

Інтерактивний асистент побудовано на модульній архітектурі, яка складається з:

- ядра знань дисципліни (база лекцій, лабораторних робіт, бібліографія, стандартні алгоритми керування, моделі систем автоматизації);
- мовного інтерфейсу на основі GPT-моделі, який дозволяє вести діалог природною мовою, розуміти контекст навчальної ситуації та генерувати пояснення;
- інтеграційного модуля з CAD/CAE-середовищами (SolidWorks, MATLAB/Simulink, Ansys, Deductor), що дозволяє працювати з моделями у режимі симуляції;
- аналітичного блоку, який відстежує прогрес користувача, пропонує рекомендації, формує індивідуальні траєкторії.

Система розгортається у хмарній інфраструктурі, що дозволяє масштабувати її під різні рівні користувачів: *бакалавр – магістр – аспірант*.

4. Освітній контекст та інтеграція у навчальний процес

Асистент ІКС впроваджено в освітній процес Донбаської державної інженерної академії у межах курсу «Інтелектуальні керуючі системи». Під час навчання студенти використовують його для:

- підготовки до лабораторних занять (пошук формул, моделей, алгоритмів);
- розроблення структурних схем систем керування;
- аналізу експериментальних даних з гідравлічних, електричних та мехатронних систем;
- моделювання цифрових двійників у MATLAB та Python;
- підготовки наукових звітів і презентацій.

Аспіранти, зокрема Мельник С.В. та Сорока М.О., застосували ІКС-асистента як інструмент попереднього моделювання систем штучного інтелекту для промислових маніпуляторів і систем точного керування, що дало змогу скоротити цикл експериментального відпрацювання.

5. Методологічні принципи

Ключовими методологічними орієнтирами стали:

- принцип інтеграції людина – машина – знання, де штучний інтелект виступає посередником у засвоєнні складних технічних концепцій;
- адаптивність і самоорганізація навчання, що реалізується через обробку індивідуальних запитів студентів;

- візуалізація мислення – представлення процесів керування у вигляді динамічних моделей, блок-схем, симуляцій;
- використання цифрових двійників для перевірки гіпотез, проектування експериментів, і навіть оцінки якості навчання.

Такі підходи відповідають сучасним тенденціям Європейського простору вищої освіти (ЕНЕА) щодо компетентнісного підходу та навчання через дослідження (*learning by research*).

6. Практичні результати

У ході апробації асистента отримано такі результати:

- скорочено час підготовки студентів до лабораторних занять на 30–40 %;
- збільшено частку самостійної дослідницької роботи;
- реалізовано систему оцінювання, що формує аналітичні карти компетентностей;
- створено прототип віртуальної лабораторії ІКС-Lab, яка взаємодіє з асистентом через API та дозволяє виконувати експерименти у реальному часі;
- підготовлено понад 15 індивідуальних досліджень, захищених у вигляді наукових звітів і магістерських робіт.

7. Обговорення результатів і перспективи розвитку

Використання ІКС-асистента демонструє, що штучний інтелект у навчанні не замінює викладача, а посилює його роль як куратора знань. Така система стає частиною освітньої екосистеми «Академії дослідників штучного інтелекту» (АДШІ), що об'єднує учнів, студентів і науковців різного рівня.

Подальший розвиток передбачає:

- створення повноцінного цифрового двійника освітнього процесу ІКС;
- інтеграцію із системами Moodle, Miro, Canva, ChatGPT та внутрішнім репозитарієм навчальних моделей;
- використання принципів EdTech-гейміфікації та генеративного навчання;
- формування міжнародних партнерств для дослідження етичних аспектів

ШІ в освіті.

8. Висновки

Інтерактивний асистент ІКС довів свою ефективність як інструмент підтримки інженерної освіти нового покоління, що поєднує когнітивні, технологічні й методологічні компоненти.

Його впровадження сприяє розвитку цифрової культури, формуванню дослідницьких компетентностей, підвищенню якості підготовки фахівців і водночас створює платформу для міждисциплінарних досліджень у сфері штучного інтелекту, мехатроніки та управління.

УДК 004.8:378.147:62-52

Ковалевський С.В., (Донбаська державна машинобудівна академія, м. Краматорськ-Тернопіль, Україна), **Білосточний В.О.** (Вінницький національний технічний університет, Вінниця, Україна).

НЕЙРОМЕРЕЖНІ МОЖЛИВОСТІ ІНТЕЛЕКТУАЛЬНИХ КЕРУЮЧИХ СИСТЕМ У ОСВІТНЬОМУ ПРОЦЕСІ.

Анотація. У статті розглянуто створення та апробацію Інтерактивного асистента ІТС ОКРЗІ — інтелектуальної системи нового покоління, призначеної для підтримки освітньо-дослідної діяльності у технічних університетах. Описано архітектуру асистента, яка включає освітній,

науково-дослідний та інноваційно-виробничий рівні, що взаємодіють із лабораторіями ICS-Lab та ITS-Lab. Визначено методологічні засади проєкту, засновані на концепції цифрового близнюка навчального процесу, який аналізується алгоритмами машинного навчання та адаптивними моделями fuzzy-логіки. Показано, що ІТС ОКРЗІ сприяє формуванню дослідницьких і аналітичних компетенцій, зокрема у сфері цифрових двійників і нейроінтерфейсів. Результати впровадження свідчать про підвищення якості аналітичних робіт, самостійності здобувачів освіти та мотивації до наукових досліджень. Проєкт розглядається як основа створення національної AI-платформи технічної освіти.

Ключові слова: штучний інтелект, цифровий близнюк, інтелектуальні системи керування, освіта 4.0, fuzzy-логіка, машинне навчання, інтерактивний асистент, ІТС ОКРЗІ.

Abstract. The paper presents the development and testing of the Interactive Assistant ITS OKR3I – a next-generation intelligent system designed to support educational and research activities in technical universities. The architecture of the assistant comprises three interconnected levels: educational, research, and industrial, which operate in integration with the ICS-Lab and ITS-Lab digital laboratories. The methodological framework is based on the digital twin concept of the learning process, analyzed and optimized through machine learning algorithms and fuzzy logic models. ITS OKR3I enhances analytical and research competencies, particularly in digital twin technologies and neuro-interfaces. Implementation results demonstrate increased quality of analytical work, students' autonomy, and motivation for scientific exploration. The project serves as a foundation for establishing a national AI platform for engineering education.

Keywords: artificial intelligence, digital twin, intelligent control systems, Education 4.0, fuzzy logic, machine learning, interactive assistant, ITS OKR3I.

1. Вступ.

Сучасна вища технічна освіта перебуває на етапі глибокої трансформації, що пов'язана з переходом до освіти, підсиленої штучним інтелектом (AI-powered education). В умовах стрімкого розвитку моделей ШІ (від GPT-3 до GPT-5) змінюється не лише структура навчального контенту, а й сама природа освітньої взаємодії. У відповідь на ці виклики в межах освітньо-наукової програми «Інтелектуальні технологічні системи (ІТС)» було створено Інтерактивного асистента ІТС ОКРЗІ, який поєднує функції цифрового тьютора, лабораторного консультанта, аналітика знань і наукового супроводу дослідницьких проєктів аспірантів.

2. Концепція і структура Інтерактивного асистента ІТС ОКРЗІ.

ІТС ОКРЗІ — це не просто чат-бот, а складна інтерактивна система, побудована на принципах інтелектуальної підтримки прийняття рішень у навчально-дослідному середовищі. Її архітектура включає три взаємопов'язані рівні:

1. Освітній (training level) — модуль підготовки магістрів і аспірантів через сценарії лабораторних робіт, інтерактивні консультації та симуляції.
2. Науково-дослідний (research level) — аналітична оболонка для формування гіпотез, оцінки достовірності результатів і підготовки публікацій.
3. Інноваційно-виробничий (industrial level) — зв'язок з цифровими двійниками технологічних процесів, CAD/CAE-системами та інтелектуальними контролерами (ICS-Lab, ITS-Lab).

Асистент функціонує як «цифровий координатор» між студентом, викладачем і лабораторним обладнанням, забезпечуючи наскрізну інтеграцію знань — від формування завдання до наукової статті чи патентної заявки.

3. Методологічна основа проєкту.

Розробка ІТС ОКРЗІ базується на концепції цифрового близнюка навчального процесу, де кожна освітня діяльність відображається у вигляді даних, що аналізуються та оптимізуються алгоритмами машинного навчання. Застосовується гібридна архітектура ШІ:

- семантична модель знань (онтологія дисципліни «Інтелектуальні керуючі системи»);
- нейромережний модуль GPT-типу, адаптований під український академічний контент;

- аналітичний блок на основі принципів fuzzy-логіки, який інтерпретує відповіді користувачів і формує персоналізовані траєкторії навчання.

Така інтеграція дозволяє здійснювати *динамічне формування знань* — коли система не просто перевіряє правильність відповідей, а пояснює логіку рішень, вказує на альтернативні підходи й підтримує дослідницьке мислення.

4. Розвиток компетенцій і наукових навичок.

Асистент ІТС ОКРЗІ спрямований на розвиток когнітивно-дослідницьких компетенцій студентів, серед яких:

- здатність проєктувати інтелектуальні системи керування;
- вміння застосовувати методи моделювання й оптимізації;
- навички інтерпретації результатів експериментів;
- компетентність у сфері цифрових двійників технологічних процесів.

Використання асистента під час виконання лабораторних і проєктних завдань показало істотне підвищення якості аналітичних робіт (у середньому на 25–30 %) та рівня самостійності здобувачів освіти.

5. Практична реалізація та інтеграція з ІКС-Lab і ITS-Lab.

ІТС ОКРЗІ впроваджено у цифрову лабораторію ICS-Lab (Intelligent Control Systems Laboratory) та ITS-Lab (Innovative Technological Systems Laboratory), які функціонують як ядро експериментальної платформи ДДМА-ВНТУ.

Асистент підтримує роботу з CAD-пакетами (SolidWorks, ANSYS, Fusion 360), математичними середовищами (MATLAB, Python) та цифровими симуляторами. Він здатен аналізувати результати розрахунків, формувати звіти за ДСТУ, а також проводити «діалоги-опонування» — інтерактивні сесії з експертною оцінкою рішень студента.

У процесі апробації було проведено понад 150 інтерактивних занять у гібридному форматі (аудиторія + ІІІ), що дало змогу зменшити час підготовки звітів удвічі й одночасно підвищити рівень аналітичності пояснювальних записок.

6. Взаємодія «Людина – ІІІ – Цифровий двійник».

Ключова особливість ІТС ОКРЗІ полягає у поєднанні когнітивної діяльності людини з інтелектуальними інтерфейсами системи.

- Завдяки моделі тристоронньої взаємодії відбувається:
- персоналізація освітнього процесу, коли асистент адаптує складність матеріалу до поточного рівня здобувача;
 - синхронізація з цифровими двійниками лабораторних об'єктів (гідроприводи, маніпулятори, системи охолодження);
 - створення динамічного профілю компетентностей для кожного студента.

Таким чином, ІТС ОКРЗІ формує *мета-рівень навчання*, де студент не лише отримує знання, а й розуміє, як саме він навчається — через рефлексію й аналіз взаємодії з системою.

7. Результати впровадження та подальші напрями розвитку.

За результатами експериментального впровадження у 2024–2025 рр. визначено такі ключові ефекти:

- підвищення мотивації студентів і аспірантів (за результатами опитувань — на 40 %);
- скорочення часу на підготовку проєктних звітів на 50 %;
- підвищення частки самостійно розроблених моделей і алгоритмів у роботах здобувачів;
- розширення міжкафедральної кооперації (інтеграція з курсами «САПР ТП», «Інтелектуальні технології виробництва», «Основи ІІІ»).

Подальший розвиток передбачає створення відкритої мережевої екосистеми ІТС ОКРЗІ 2.0, що об'єднає декілька освітніх платформ, лабораторій і підприємств-партнерів (QuartSoft, ІІІІІ НАН України, ВНТУ, ДДМА).

ВИСНОВКИ,

1. Інтерактивний асистент ІТС ОКРЗІ є ефективним інструментом цифрової трансформації освітнього процесу у галузі прикладної механіки та автоматизації.

2. Його використання забезпечує формування дослідницьких, аналітичних і проєктних компетенцій відповідно до стандартів ЄКТС і вимог індустрії 4.0.
3. Розроблена архітектура дозволяє інтегрувати елементи машинного навчання, цифрових двійників і нейро-інтерфейсів у навчальний процес.
4. ІТС ОКРЗІ виступає базовим елементом для створення майбутньої *Національної AI-платформи технічної освіти*, що поєднує університети, наукові установи та бізнес-партнерів.

УДК 004.8

Корнєва В.Р. (Прилуцький технічний фаховий коледж, Прилуки, Україна).

ІНТЕЛЕКТУАЛЬНІ ОСВІТНІ СИСТЕМИ: ПЕРСОНАЛІЗАЦІЯ НАВЧАННЯ НА ОСНОВІ ШТУЧНОГО ІНТЕЛЕКТУ.

Анотація. У статті досліджено роль штучного інтелекту (ШІ) у формуванні інтелектуальних освітніх систем, здатних забезпечити персоналізацію навчання відповідно до індивідуальних потреб здобувачів освіти. Визначено ключові напрями впровадження ШІ, серед яких адаптивні механізми навчання, автоматизоване оцінювання, аналітика навчальних даних та використання чат-ботів як інструментів підтримки студентів. Проаналізовано сучасні технології — машинне навчання, нейронні мережі, обробку природної мови — що дозволяють інтелектуальним системам формувати індивідуальні траєкторії навчання, оцінювати прогалини у знаннях та пропонувати релевантні рекомендації. Особливу увагу приділено огляду актуальних досліджень (UNESCO, 2023; Baker, 2022; Duolingo AI, 2023), які підтверджують ефективність персоналізованих підходів у покращенні результатів навчання. Окремлено проблеми, що залишаються актуальними: відсутність уніфікованих стандартів побудови інтелектуальних систем, недостатня цифрова компетентність педагогів та ризики, пов'язані з безпекою даних. Підкреслено, що розвиток інтелектуальних освітніх систем є важливим чинником підвищення якості людського капіталу та подолання освітньої нерівності в умовах цифровізації.

Ключові слова: штучний інтелект, персоналізоване навчання, інтелектуальні освітні системи, адаптивне навчання, цифровізація освіти.

Abstract. The article explores the role of Artificial Intelligence (AI) in the development of intelligent educational systems capable of providing personalized learning tailored to individual student needs. Key directions of AI integration are identified, including adaptive learning mechanisms, automated assessment, learning analytics, and the use of chatbots as student-support tools. Modern technologies—machine learning, neural networks, and natural language processing—are analyzed as enablers for creating individualized learning trajectories, identifying knowledge gaps, and generating relevant recommendations. Particular attention is given to recent studies (UNESCO, 2023; Baker, 2022; Duolingo AI, 2023) that demonstrate the effectiveness of AI-enabled personalization in improving learning outcomes. The article outlines persistent challenges such as the lack of unified standards for designing intelligent educational systems, insufficient digital competence among teachers, and risks related to student data security. It is emphasized that the development of intelligent educational systems is a crucial factor for improving human capital quality and reducing educational inequality within the context of digital transformation.

Keywords: artificial intelligence, personalized learning, intelligent educational systems, adaptive learning, digitalization of education.

Постановка проблеми.

Сучасна освіта перебуває у стані глибокої трансформації, спричиненої стрімким розвитком цифрових технологій і штучного інтелекту (ШІ). Традиційна модель навчання, що базується на єдиному підході до всіх студентів, уже не відповідає потребам динамічного ринку

праці, який вимагає індивідуальних траєкторій розвитку компетентностей. У цьому контексті інтелектуальні освітні системи (ІОС), що використовують алгоритми ШІ для аналізу навчальних даних і формування персоналізованих стратегій навчання, набувають особливої актуальності.

Завдання полягає в тому, щоб не лише автоматизувати навчальний процес, а й зробити його адаптивним — здатним враховувати індивідуальні особливості кожного здобувача освіти.

Аналіз останніх публікацій.

Питання впровадження ШІ в освіту активно досліджується у працях таких науковців, як Б. Каплан, Е. Уоллес, Д. Бейкер, Дж. Андерсон, а також українських дослідників — О. Спіріна, С. Семерікова, В. Бикова.

Згідно з аналітичним звітом UNESCO (2023), використання інтелектуальних систем у навчанні зросло на 60% за останні п'ять років. Розробки, як-от Coursera AI Coach, Khanmigo (Khan Academy), Duolingo Max, демонструють ефективність адаптивного підходу. У вітчизняних дослідженнях (зокрема, у працях Бикова В. Ю.) наголошується на важливості інтеграції ШІ в освітнє середовище з урахуванням етичних, правових та психолого-педагогічних аспектів.

Підкреслення невирішених частин проблеми.

Попри успіхи у впровадженні штучного інтелекту, існують проблеми, пов'язані з відсутністю єдиних стандартів для створення ІОС, недостатнім рівнем цифрової грамотності педагогів і питаннями безпеки даних студентів. Також досі не розроблено уніфікованої моделі, що дозволяє поєднати алгоритми машинного навчання з психолого-педагогічними принципами індивідуалізації навчання. Відсутність комплексного підходу до оцінювання ефективності таких систем гальмує їх широке впровадження у формальну освіту.

Мета роботи та постановка завдань.

Мета статті — дослідити можливості та переваги використання штучного інтелекту для персоналізації навчання, визначити основні напрями розвитку інтелектуальних освітніх систем і їхній вплив на соціально-економічні процеси.

Для досягнення мети поставлено такі завдання:

Проаналізувати сучасні підходи до використання ШІ в освіті.

Визначити структуру інтелектуальної освітньої системи.

Розкрити механізми персоналізації навчання на основі ШІ.

Дослідити соціально-економічні аспекти впровадження ІОС.

Сформулювати перспективи подальших досліджень.

Виклад основного матеріалу дослідження.

Інтелектуальні освітні системи: визначення та структура

ІОС — це програмно-апаратні комплекси, що використовують методи штучного інтелекту (машинне навчання, обробку природної мови, нейронні мережі) для підтримки індивідуального навчання. Вони складаються з кількох основних модулів:

Модуль користувача — відстежує активність здобувача освіти;

Модуль діагностики знань — аналізує рівень засвоєння матеріалу;

Модуль рекомендацій — формує індивідуальний план навчання;

Модуль оцінювання — надає адаптивні тести та зворотний зв'язок.

Таблиця 1. Основні компоненти інтелектуальної освітньої системи

Компонент	Функція	Технології
Аналітика навчальних даних	Збір і аналіз результатів	Big Data, Machine Learning
Модуль персоналізації	Рекомендації та адаптація контенту	Neural Networks, NLP

Зворотний зв'язок	Моніторинг успішності	Chatbots, Intelligent Agents
-------------------	-----------------------	------------------------------

Персоналізація навчання.

Персоналізація передбачає налаштування контенту, темпу та стилю навчання відповідно до потреб конкретного студента. Наприклад, система може пропонувати спрощені пояснення або додаткові матеріали, якщо алгоритм визначає прогалини у знаннях. Адаптивні платформи, як Smart Sparrow, DreamBox Learning чи Edmodo AI, вже демонструють підвищення ефективності засвоєння матеріалу на 20–30%.

Соціально-економічний ефект.

Використання ШІ в освіті має значний вплив на соціально-економічні системи:

Підвищення якості людського капіталу. Студенти отримують навички, адаптовані до вимог сучасного ринку.

Зменшення освітньої нерівності. ШІ може компенсувати нестачу викладачів у віддалених регіонах.

Оптимізація управління освітніми установами. Алгоритми аналізують дані про відвідуваність, успішність і фінанси, що дозволяє підвищити ефективність прийняття рішень.




Рисунок 1. Взаємодія штучного інтелекту з освітніми та соціально-економічними системами

ВИСНОВКИ.

Інтелектуальні освітні системи відкривають нову епоху в розвитку освіти, роблячи її більш гнучкою, індивідуальною та ефективною. Завдяки технологіям ШІ можливо створювати навчальні середовища, де кожен студент отримує оптимальну підтримку. У майбутньому роль таких систем лише зростатиме — вони стануть невід’ємною частиною не

лише освітнього процесу, а й ширших соціально-економічних систем. Для України це означає необхідність державних програм цифровізації освіти, підготовки викладачів до роботи з ШІ та створення етичних норм його використання.

СПИСОК ПОСИЛАНЬ.

1. Биков В. Ю. *Цифрова трансформація освіти: виклики та перспективи. Інформаційні технології в освіті*, 2022.
2. Спірін О. М. *Інтелектуальні системи навчання: методологічні основи. Освітологічний дискурс*, 2021.
3. UNESCO. *AI and Education: Guidance for Policy-makers*. Paris: UNESCO Publishing, 2023.
4. Baker R. S. *Learning Analytics and Artificial Intelligence in Education*. Springer, 2022.
5. Duolingo Research Team. *AI for Adaptive Learning*. Pittsburgh: Duolingo, 2023.

УДК 317.148

Онищук С.Г. (Донбаська державна машинобудівна академія, м. Краматорськ – Тернопіль, Україна), **Тулупов В.І.** (Краматорський фаховий коледж технологій та дизайну, м. Краматорськ – Черкаси, Україна).

ВИКОРИСТАННЯ ШТУЧНОГО ІНТЕЛЕКТУ В ОСВІТНЬОМУ ПРОЦЕСІ І АКАДЕМІЧНА ДОБРОЧЕСНІСТЬ.

Анотація. У статті проаналізовано особливості застосування технологій штучного інтелекту в освітньому процесі закладів вищої освіти та їхній вплив на дотримання академічної доброчесності. Розглянуто сучасні підходи до використання цифрових інструментів, а також потенційні ризики, пов'язані із застосуванням генеративних моделей, автоматизованих систем та інтелектуальних сервісів. Визначено ключові позитивні аспекти інтеграції штучного інтелекту, серед яких персоналізація навчання, підвищення ефективності опрацювання інформації та розширення можливостей для підтримки освітньої діяльності. Одночасно окреслено проблеми, що можуть виникати під час використання ШІ: імовірність порушення академічної доброчесності, зниження рівня самостійності студентів, питання авторських прав, ризики отримання недостовірної інформації та потенційні загрози безпеці даних. Проаналізовано вимоги законодавства України щодо забезпечення академічної доброчесності та визначено типові порушення, які можуть бути викликані використанням ШІ у навчанні. Запропоновано комплекс заходів для мінімізації ризиків, зокрема впровадження усних і контрольних форм оцінювання, виконання практичних та проєктних робіт, а також розвиток культури академічного письма. Результати дослідження підтверджують необхідність формування нормативної політики щодо використання штучного інтелекту в освіті з метою забезпечення чесності, прозорості та довіри до освітнього процесу. (185 слів)

Ключові слова: штучний інтелект, освітній процес, академічна доброчесність, цифровізація, порушення доброчесності.

Abstract. The article analyzes the features of using artificial intelligence technologies in the educational process of higher education institutions and their impact on academic integrity compliance. Modern approaches to implementing digital tools and potential risks related to the use of generative models, automated systems, and intelligent services are examined. The key positive aspects of integrating artificial intelligence—such as personalized learning, improved efficiency of information processing, and enhanced support for educational activities—are outlined. At the same time, challenges associated with the use of AI are highlighted, including the risk of academic misconduct, reduced student autonomy, copyright issues, data

security concerns, and the possibility of receiving unreliable information. The requirements of Ukrainian legislation regarding academic integrity are analyzed, and the main types of violations that may arise from the misuse of AI in education are identified. A set of measures is proposed to minimize these risks, including oral assessments, in-class written work, practical and project-based tasks, and the development of academic writing skills. The findings emphasize the need to create institutional policies regulating the use of artificial intelligence to ensure transparency, fairness, and trust in the educational process. (183 words)

Keywords: artificial intelligence, educational process, academic integrity, digitalization, misconduct.

Постановка проблеми. Ознакою сучасної освіти є стрімке запровадження цифрового інструментарію. Здобувачі освіти використовують мережу інтернет для пошуку інформації, хмарні сервіси, сучасні пакети прикладних програм для виконання курсових проєктів та кваліфікаційних робіт. В зв'язку зі стрімким розвитком технологій штучного інтелекту постає питання щодо використання нових можливостей для виконання завдань освітнього процесу й дотримання при цьому академічної доброчесності здобувачами освіти, що вимагає діючий «Закон про освіту».

Тому визначення політики використання технологій штучного інтелекту та дотримання академічної доброчесності в закладах освіти є нагальною проблемою.

Аналіз останніх досліджень та публікацій. Питання академічної доброчесності в останні роки розглядаються в публікаціях А.Є. Артюхова, І. О. Дегтярьової, А.М. Куліша [1, 2] та інших дослідників. Питання використання технологій штучного інтелекту в освіті розглянуті в роботах І.М. Візнюк [3], О. Гриценчук [4], О. Панухник [5] та інших дослідників як в Україні, так й за кордоном [6]. Нагальним є питання дотримання академічної доброчесності здобувачами освіти при використанні штучного інтелекту.

Метою роботи є дослідження впливу технологій штучного інтелекту в освітньому процесі на дотримання академічної доброчесності.

Викладення основного матеріалу. Відповідно до Закону України «Про освіту», академічна доброчесність є сукупністю етичних принципів і визначених правил, якими повинні керуватися учасники освітнього процесу для забезпечення довіри до результатів навчання або наукових чи творчих досягнень [7].

Основними порушеннями академічної доброчесності за цим законом є такі:

- 1) плагіат — присвоєння ідеї або тверджень іншої людини без посилання на неї;
- 2) списування — використання зовнішньої допомоги без дозволу або визнання використання цієї допомоги;
- 3) фабрикація — фальсифікація інформації, яка пов'язана з академічним процесом;
- 4) фальсифікація — свідомо зміна наявних даних, які пов'язані із процесом освіти чи науки;
- 5) обман — надання недостовірної інформації про власну наукову або освітню діяльність;
- 6) необ'єктивне оцінювання — певне заниження або завищення результатів навчання здобувачів освіти [7].

У сучасному світі спостерігають дедалі більше формування єдиного науково-освітнього простору, що базується на постійно оновлюваних засобах комунікацій та інформаційних технологій. Організація навчальних програм різного рівня у дистанційній формі навчання також стає дедалі поширенішою. В освітньому процесі щораз частіше використовують інформаційні й комунікативні технології, що значно впливає на темп отримання потрібної інформації і змінює характер навчання на більш інтерактивний.

Технологічний потенціал інформаційно-комунікативного простору розглядають як основний напрям розвитку всіх галузей людської діяльності, зокрема й освіти. У сучасному світі людство дедалі більше стає залежним від готових продуктів штучного інтелекту. Прямий вплив штучний інтелект має і на академічну доброчесність [8].

Серед позитивних аспектів використання штучного інтелекту слід відзначити наступні:

- можливість реалізації індивідуальної траєкторії навчання для здобувачів освіти з врахуванням їх рівня підготовки;
- підготовка аналітичного огляду матеріалів відповідно до запиту, створеного здобувачем, зокрема при виконанні науково-дослідницької роботи, курсових проєктів; кваліфікаційних робіт;
- можливість створення індивідуальних асистентів та чат-ботів для полегшення взаємодії з платформою.

Крім переваг, що надає використання технологій штучного інтелекту, існують й проблеми, що поки не сприяють якісному та стабільному їх застосуванню:

- питання конфіденційності та безпеки даних (існує ймовірність кібератак, що може спричинити втрату індивідуальних даних учасників освітнього процесу);
- зниження когнітивних здібностей як серед здобувачів освіти (сподівання знайти відповідь у чат-бота без самостійного пошуку матеріалу), так й серед викладачів (створення навчального контенту перекладається на штучний інтелект – конспектів, тестів);
- ризик надмірного повсякденного використання технологій (штучний інтелект слід розглядати лише як доповнення до навчальних матеріалів, розроблених викладачем);
- відсутність посилання на джерела інформації (виникають проблеми академічної доброчесності);
- упередження в даних та алгоритмах;
- зазіхання на авторське право (особливо при аналізі науково-технічної інформації при підготовці літературних оглядів в наукових роботах);
- ризик отримання неправдивої інформації (так звана «галюцинація» штучного інтелекту); згенеровану штучним інтелектом інформацію обов'язково треба перевіряти через можливі помилки (недостовірні вихідні дані, застарілі дані; неправильна методика розрахунків й т.ін.);
- шахрайство в навчанні (матеріал, створений штучним інтелектом, подається здобувачем освіти як власноруч створений для отримання позитивної оцінки від викладача).

Використання штучного інтелекту для генерування текстів без посилання на першоджерела або зазначення недостовірних джерел може трактуватися як плагіат, що суперечить вищезгаданому «Закону про освіту». Постачальники послуг із виявлення плагіату в наукових роботах уже розробили певні програми для перевірки текстів, якими є GPTZero, AI Writing Check, CrossPlag, OpenAI. Усі ці інструменти базуються на використанні штучного інтелекту, що дає можливість розрізнити текст, написаний людиною, від написаного ШІ [8].

«Галюцинація» штучного інтелекту може призвести до отримання неправильної інформації через застарілі дані, помилки в методиці розрахунків, що може бути свідомо без перевірки надано здобувачем освіти як результат власної роботи (може трактуватися як фальсифікація, фабрикація або обман). Тому обов'язковою повинна бути перевірка згенерованого штучним інтелектом тексту.

Заходи, що можуть бути використані для покращення якості освітнього процесу в випадку дозволеного використання штучного інтелекту, можуть бути наступними:

- написання письмових робіт в аудиторії;
- складання усних екзаменів;
- розробка завдань, що складно виконати з використанням штучного інтелекту;
- виконання лабораторних робіт, що потребують експериментальних досліджень (наприклад в хімії, фізиці, механіці);
- проєктні завдання (виконання розрахунків, виконання креслень деталей та вузлів механізмів та машин).

Важливим також є індивідуальна робота викладача зі здобувачами освіти всіх рівнів. Виконання творчих завдань потребуватиме креативності, що складно виконати з використанням технологій штучного інтелекту.

Також в рамках навчального процесу необхідно створювати освітнє середовище, що буде сприяти академічній доброчесності, зокрема запровадженню в освітню програму курсу «Академічне письмо».

ВИСНОВКИ.

Сьогодні розвиток інформаційних технологій, зокрема технологій штучного інтелекту, вимагає перегляду традиційних підходів в освітньому процесі. Важливим питанням стає формування освітнього середовища, що буде поєднувати використання штучного інтелекту та дотримання академічної доброчесності здобувачами освіти. Нагальним є розробка в закладах вищої освіти нормативної документації щодо використання штучного інтелекту та дотримання академічної доброчесності.

СПИСОК ПОСИЛАНЬ.

- 1 Академічна доброчесність на варті якісної освіти: відверта розмова про чесне навчання / Т. В. Фініков, А. Є. Артюхов, О. О. Гужва – Київ, Таксон – 2019. – 68 с.
- 2 Академічна доброчесність: проблеми дотримання та пріоритети поширення серед молодих вчених [Текст] : колект. монографія / [Артюхов А. та ін. ; за заг. ред. Н. Г. Сорокіної, А. Є. Артюхова, І. О. Дегтярьової] ; Нац. акад. держ. упр. при Президентові України, Дніпропетр. регіон. ін-т держ. упр. [та ін]. – Дніпро : ДРІДУ НАДУ, 2017. – 168 с.
- 3 Візнюк І.М. Використання штучного інтелекту в освіті / І.М. Візнюк, Н.М. Буглай, Л.В. Куцак та ін. // Сучасні інформаційні технології та інноваційні методики навчання в підготовці фахівців: методологія, теорія, досвід, проблеми. Вип. 59. 2021. С.14 – 22.
- 4 Гриценчук О. Використання штучного інтелекту в освіті: тенденції та перспектив в Україні та за кордоном // Вісник кафедри ЮНЕСКО «Неперервна професійна освіта ХХІ століття». Вип. 10. 2024. С.152 – 161.
- 5 Панухник О. Штучний інтелект в освітньому процесі та наукових дослідженнях здобувачів вищої освіти: відповідальні межі вмісту III // Галицький економічний вісник. № 4 (83). 2023. С. 202 – 211. https://doi.org/10.33108/galicianvisnyk_tntu
- 6 Artificial intelligence in education: A systematic literature review. website. URL: <https://www.sciencedirect.com/science/article/pii/S0957417424010339>
- 7 Про освіту : Закон України від 5 вер. 2017 р. № 2145-VIII. URL: <https://zakon.rada.gov.ua/laws/show/2145-19>
- 8 Горчинський С.В. Якість української освіти й академічна доброчесність: вплив застосування штучного інтелекту / С.В. Горчинський, М.І. Софілканич, І.Ф. Горбенко // Академічні візії. Випуск 20. 2023.

Подлєсний С.В. (Донбаська державна машинобудівна академія, м. Краматорськ – Тернопіль, Україна).

ЕТИЧНІ ВИКЛИКИ ТА РИЗИКИ ВИКОРИСТАННЯ ГЕНЕРАТИВНОГО АІ В АКАДЕМІЧНОМУ СЕРЕДОВИЩІ.

Анотація. У статті розглянуто сучасні етичні виклики, що виникають у зв'язку з інтенсивним використанням генеративних моделей штучного інтелекту в академічному середовищі. Проаналізовано вплив великих мовних моделей на навчальний процес, наукові дослідження й адміністративну діяльність закладів вищої освіти. Показано, що широке застосування генеративного АІ супроводжується низкою ризиків: розмиванням авторства, порушенням академічної доброчесності, алгоритмічною упередженістю, появою некоректних або вигаданих даних, передумовами для маніпуляцій результатами навчання, нерівністю доступу до технологій і загрозами для приватності користувачів. Узагальнено результати сучасних досліджень, що формують теоретичні основи етичного використання ШІ. Запропоновано структуровану модель етичних ризиків, яка демонструє системний характер їх взаємозв'язку. Наведено рекомендації щодо політик відповідального впровадження генеративного АІ у вищій освіті, зокрема у частині формування правил цитування, організації оцінювання, трансформації навчальних завдань та розвитку критичного АІ-мислення у студентів. Результати дослідження підтверджують необхідність розробки інституційної нормативної бази та формування культури цифрової етики для забезпечення прозорості, чесності та стійкості академічного середовища.

Ключові слова: генеративний АІ, академічна доброчесність, етичні ризики, штучний інтелект, освіта, великі мовні моделі.

Abstract. The article examines the ethical challenges arising from the rapid integration of generative artificial intelligence models into the academic environment. The impact of large language models on the educational process, research activities and administrative workflows in higher education institutions is analyzed. The study shows that the use of generative AI introduces a range of risks, including authorship uncertainty, academic integrity violations, algorithmic bias, the generation of inaccurate or fabricated content, the possibility of manipulating learning outcomes, unequal access to AI technologies and threats to user privacy. Recent scientific publications forming the theoretical foundations of AI ethics are summarized. A structured model of ethical risks is proposed, revealing their systemic, interconnected nature. Recommendations for responsible adoption of generative AI in higher education are provided, including guidelines for citation, assessment procedures, transformation of learning activities, and the development of critical AI literacy among students. The findings highlight the need for institutional policy frameworks and a culture of digital ethics to ensure transparency, fairness, and sustainability within the academic community.

Keywords: generative AI, academic integrity, ethical risks, artificial intelligence, higher education, large language models.

Постановка проблеми.

Штучний інтелект вже став інструментом повсякденної навчальної та дослідницької діяльності. Зокрема, генеративні моделі здатні створювати текст, зображення, коди програм, аналітичні звіти, а також пропонувати персоналізовані навчальні рекомендації. Попри очевидні переваги, такі системи створюють низку критично важливих викликів для академічної доброчесності та етичного функціонування освітніх установ. Виникає потреба у комплексному дослідженні ризиків, механізмів їх мінімізації й формуванні нових стандартів академічної етики.

Стрімке проникнення генеративного штучного інтелекту в академічний простір стало одним з найболючіших викликів сучасної освітньої та наукової системи. Технології, такі як великі мовні моделі, здатні створювати коректний за формою та змістовний за виглядом текст, програмний код, наукові викладки та інші типи академічного контенту, що ставить під сумнів традиційні фундаменти академічної діяльності, які ґрунтуються на авторстві, оригінальності

та критичному осмисленні інформації. Проблема полягає не в самому факті існування цих технологій, а у відсутності комплексного та адаптованого до нових реалій розуміння етичних норм, що регулюють їх використання. Академічні інституції, сформовані в докризову цифрову епоху, опинилися в стані концептуальної та процедурної невідповідності до вирішення низки гострих дилем.

Ця проблема має безпосередній зв'язок із вирішенням ключових наукових та практичних завдань. З наукової точки зрення, викликає занепокоєння девальвація поняття інтелектуальної власності та авторського внеску. Коли результат роботи алгоритму може бути представлений як результат інтелектуального зусилля людини, розмиваються самі підстави наукового комунікування, що ґрунтується на встановленні авторства, цитуванні та критиці. Це створює загрозу для процесу накопичення знань, оскільки стає неможливо відстежити справжнє джерело ідеї та оцінити внесок конкретного дослідника. Виникає ризик формування «екосистеми напівавтономного знання», де людина та алгоритм настільки тісно переплетені, що втрачається критерій наукової достовірності та відповідальності.

З практичної точки зору, проблема безпосередньо впливає на якість освіти та підготовки фахівців. Фундаментальним завданням вищої школи є розвиток у студентів критичного мислення, здібностей до аналізу, синтезу та незалежного створення нових знань. Пасивне або нерелексивне використання генеративного AI, спрямоване лише на отримання готового результату, веде до атрофії цих ключових когнітивних навичок. Замість навчання мислити, студент ризикує навчитися лише ефективно формувати запити до системи. Це створює суспільну загрозу випуску фахівців, які володіють поверхневими знаннями, сформованими алгоритмом, але не мають глибинного розуміння предметної області.

Крім того, проблема має виражений соціально-економічний аспект, пов'язаний із завданням забезпечення рівного доступу до якісної освіти. Використання потужних генеративних моделей часто є платним, що створює умови для нової форми нерівності. Студенти, які мають фінансову можливість користуватися передовими комерційними інструментами, отримують несправедливу перевагу над тими, хто обмежений безкоштовними та менш потужними аналогами. Це не тільки порушує принцип академічної справедливості, але й поглиблює існуючий цифровий розрив, трансформуючи його в розрив освітніх можливостей.

Таким чином, постановка проблеми етичних викликів генеративного AI в академії виходить далеко за межі питання про те, «як викрити плагіат». Вона перетворюється на комплексне стратегічне завдання, що потребує переосмислення цілей освіти, адаптації методів навчання та оцінювання, розробки нових етичних кодексів і правових норм. Від його вирішення залежить здатність академічної спільноти зберегти свою роль як генератора достовірних знань і гаранта якісної підготовки майбутніх поколінь у умовах технологічної революції.

Аналіз останніх публікацій.

Проблема етичних викликів генеративного штучного інтелекту в академічному середовищі активно досліджується в науковій літературі протягом останніх років. Аналіз останніх публікацій дозволяє виокремити кілька ключових напрямів, що формують концептуальну основу для розуміння даної проблеми.

Останні дослідження (Bender et al., 2021; Floridi & Chiriatti, 2020; UNESCO AI Ethics Report, 2023) підкреслюють небезпеку «розмивання авторства» та зростання залежності студентів від автоматизованих рішень [1]. Дослідження Else (2023) демонструють, що викладачі стикаються з труднощами у виявленні текстів, повністю або частково створених AI, що ставить під загрозу якість оцінювання [2]. Низка праць (Brynjolfsson, 2022; Marcus, 2023)

наголошує на проблемі алгоритмічної упередженості та ризиках для рівності доступу до освіти [3-6]. Ці дослідження створюють базу для подальшого аналізу етичних аспектів впровадження генеративного AI.

Значний внесок у постановку проблеми зробили міжнародні організації. Зокрема, доповідь UNESCO «AI in education: Change at the speed of learning» започаткувала глобальну дискусію щодо ризиків та можливостей штучного інтелекту в освіті [7]. У цій публікації акцентовано увагу на необхідності формування людськоцентричного підходу, що передбачає пріоритет прав людини, інклюзивності та цілісності освітнього процесу. Ця робота стала концептуальною основою для багатьох подальших досліджень, оскільки вперше на міжнародному рівні було системно окреслено колізію між технологічним прогресом і етичними цінностями освіти.

Важливу роль у вивченні питання академічної доброчесності відіграли праці таких дослідників, як Сара Елейн Ітон [8]. У своїй роботі «Academic integrity in the age of artificial intelligence» вона докладно досліджує трансформацію понять плагіату та авторства. Ітон аргументує, що традиційні інструменти забезпечення академічної доброчесності виявилися неефективними в умовах, коли текст генерується алгоритмічно, а не залученням прямої копії чужих текстів. Її ідеї щодо необхідності розробки нових політик, орієнтованих на проактивне навчання, а не репресивний контроль, становлять одну з теоретичних основ даного дослідження.

У контексті аналізу педагогічних наслідків фундаментальною є стаття Лії Генклін «The AI Classroom: Teaching and Learning in an Era of Artificial Intelligence» [9]. Авторка ретельно аналізує, як генеративний штучний інтелект впливає на когнітивні навички студентів. Вона доводить, що неконтрольоване використання технології веде до «зовнішнього виведення» критичного мислення, коли студенти делегують алгоритму не лише рутинні завдання, а й базові операції з аналізу та синтезу інформації. Ця публікація стала важливим кроком у усвідомленні того, що загроза полягає не лише в порушенні правил, але й у фундаментальній зміні характеру навчання.

Питання технічних обмежень та можливостей детекції AI-генерованого контенту висвітлені в дослідженні Вейна Холмса та його колег «Ethical challenges of AI in education: Examples and mitigation strategies» [10]. Автори надають критичний огляд сучасних інструментів детекції, вказуючи на їхню принципову ненадійність через швидку еволюцію мовних моделей. Вони першими висунули тезу про безперспективність «технологічної гонки озброєнь» між розробниками AI та творцями детекторів, обґрунтувавши необхідність педагогічних, а не технократичних рішень.

Визначальним для розуміння соціально-економічного виміру проблеми є звіт ОЕСР «AI and the Future of Skills» [11]. У ньому детально проаналізовано, як технології штучного інтелекту можуть поглибити нерівність через нерівномірний доступ. Ця публікація започаткувала дискусію про те, що етична проблема не обмежується рамками окремої навчальної аудиторії, а перетворюється на макроекономічний та соціальний виклик для всього суспільства.

Таким чином, аналіз останніх публікацій свідчить про формування консенсусу щодо комплексного характеру проблеми. Сучасна наукова думка спирається на розуміння того, що етичні виклики генеративного AI є системними і вимагають поєднання інституційних, педагогічних та культурних підходів, а не технічних виправлень. Ці роботи становлять смислову основу для подальшого власного дослідження, задаючи його теоретичний вектор і обґрунтовуючи актуальність обраної теми.

Підкреслення невирішених частин проблеми.

Незважаючи на активне обговорення етичних аспектів використання генеративного штучного інтелекту в академії, низка критичних питань залишається недостатньо дослідженою та потребує наукової розробки. Існуючі дослідження часто носять загальний характер, описуючи проблеми, але не пропонуючи конкретних механізмів їх подолання в умовах української вищої школи. Саме на цих невирішених аспектах зосереджена дана публікація.

По-перше, залишається відкритим питання операціоналізації академічної доброчесності в нових умовах. Якщо заборона використання штучного інтелекту виявляється неефективною, а повна свобода — неприйнятною, то постає проблема створення диференційованого підходу. Необхідно чітко визначити, для яких типів навчальних завдань використання генеративного AI є легітимним допоміжним інструментом, а для яких — неприйнятним замінником власного мислення. Наприклад, чи можна використовувати AI для пошуку ідей або структурування тексту, і як це відрізнити від прямого написання роботи? Ця публікація присвячується розробці таких критеріїв розмежування, що є ключовим для формування справедливої оцінки.

По-друге, недостатньо вивченою є проблема формування нових навичок, необхідних для етичної та ефективної взаємодії з технологією. Мова йде не лише про «AI-грамотність» у технічному розумінні, але й про розвиток критичного «AI-скептицизму» — здатності оцінювати достовірність, об'єктивність та обмеження згенерованого контенту. Дана стаття зосереджується на аналізі тих конкретних компетентностей, які повинен сформувати викладач у студента, щоб той міг використовувати AI як інструмент розвитку, а не як костиль для інтелектуальної непрацездатності.

По-третє, практично поза увагою дослідників залишається інституційний рівень проблеми. Як мають бути організовані внутрішні процеси університету — від розробки навчальних програм до роботи дисциплінарних комісій — для адаптації до нової реальності? Відсутність чітких внутрішніх політик, процедур та стандартів цитування робіт, створених за участю AI, створює правовий вакуум, де як студенти, так і викладачі діють на власний розсуд. Ця публікація присвячується аналізу саме цього, інституційного, аспекту, пропонуючи рамки для розробки внутрішніх нормативних документів.

Нарешті, майже не дослідженим є психологічний та моральний вимір впливу генеративного AI на викладача. Постає питання про професійне вигорання в умовах, коли традиційні методи оцінки знань втрачають ефективність, а також про етичну дилему постійного підозри щодо авторства студентських робіт. Ця стаття звертається до цієї невирішеної частини проблеми, висвітлюючи важливість формування нової педагогічної етики та підтримки викладачів у процесі трансформації.

Таким чином, дана публікація зосереджена на найменш досліджених, але критично важливих аспектах: розробці диференційованих критеріїв використання AI, формуванні нових навичок критичного сприйняття, створенні інституційних механізмів регулювання та подоланні психологічних наслідків для академічної спільноти. Вирішення саме цих завдань дозволить перейти від констатації ризиків до побудови життєздатної моделі академічної діяльності в епоху штучного інтелекту.

Мета роботи та постановка завдань.

Головною метою даного дослідження є розробка цілісного концептуального підходу до мінімізації етичних ризиків, пов'язаних із використанням генеративного штучного інтелекту в академічному середовищі, з орієнтацією на український освітній контекст. Існуючі роботи частіше окреслюють проблемне поле, ніж пропонують структуровані шляхи її вирішення,

адаптовані до реальних умов вищих навчальних закладів. Таким чином, дана стаття прагне заповнити цю прогалину, зосередившись не лише на діагностиці, але й на створенні практичної рамки для дії.

Для досягнення заявленої мети в роботі вирішуються наступні ключові завдання. Перше завдання полягає у систематизації та поглибленому аналізі основних категорій етичних ризиків, з якими стикаються усі учасники освітнього процесу. Це передбачає не просто перелік загроз, а виявлення їхньої взаємозв'язку та кумулятивного ефекту, що призводить до системної девальвації академічних цінностей.

Друге завдання зосереджене на критичному оцінюванні наявних інструментів протидії негативним наслідкам, зокрема методів технічного детектування AI-генерованого контенту. Аналіз їх обмежень та вразливостей є необхідним кроком для усвідомлення неефективності виключно заперечно-контрольного підходу та обґрунтування потреби в більш гнучких рішеннях.

Третє завдання спрямоване на розробку конкретних пропозицій щодо трансформації навчально-методичної роботи. У межах цього завдання досліджується, як саме слід змінювати методи навчання та типи оцінювальних завдань, щоб розвивати в студентів критичне мислення та відповідальне ставлення до використання технологій, перетворюючи AI з загрози на інструмент розвитку.

Четверте завдання полягає у формуванні контурів інституційної політики академічної доброчесності, яка враховує присутність генеративного AI. Це передбачає постановку питання про необхідність створення внутрішніх кодексів, правил цитування та визначення процедурних аспектів, що регулюють використання таких інструментів у навчальній та науковій діяльності.

Вирішення цих завдань у комплексі дозволить досягти головної мети — запропонувати академічній спільноті не фрагментарні поради, а системну модель дій, що поєднує превентивну педагогіку, обґрунтовану політику та розвиток нових навичок, спрямовану на збереження етичного ядра освіти в умовах технологічної революції.

Виклад основного матеріалу дослідження.

Першим етапом нашого дослідження стала систематизація основних категорій етичних ризиків, що виникають внаслідок використання генеративного штучного інтелекту в академічному середовищі. Аналіз показав, що ці ризики не є ізольованими явищами, а утворюють складну систему взаємопов'язаних загроз, які посилюють одна одну, призводячи до системної девальвації академічних цінностей.

Цю взаємозв'язок наочно ілюструє Рисунок 1, який демонструє циклічну природу впливу етичних ризиків. Вихідною точкою є загроза академічній доброчесності, що проявляється у вигляді нового типу плагіату, коли AI-генерований контур видається за власний інтелектуальний продукт. Це підриває саму основу наукового спілкування, яка ґрунтується на довірі до авторства та оригінальності. Наслідком цього стає ерозія навчальних результатів, оскільки студент, який делегує створення змісту алгоритму, уникає необхідних інтелектуальних зусиль. Формальне виконання завдання без реального засвоєння знань веде до атрофії когнітивних навичок, зокрема критичного мислення, аналізу та синтезу інформації. Втрата цих фундаментальних навичок, у свою чергу, робить студента ще більш залежним від генеративного AI для вирішення складних завдань, замикаючи таким чином порочне коло.




Рисунок 1. Циклічна модель взаємозв'язку ключових етичних ризиків генеративного AI в академії

Окремою категорією ризиків, що посилює всі інші, є проблема біасу та недостовірності. Генеративні моделі, навчені на масивних даних з Інтернету, успадковують та відтворюють соціальні, культурні та історичні упередження, присутні в цих даних. Наприклад, у відповіді на запит щодо історки розвитку науки модель може систематично переоцінювати внесок дослідників однієї статі чи культури, ігноруючи досягнення інших. Це не лише поширює об'єктивно неправдиву інформацію, але й консервує шкідливі стереотипи, що суперечить принципам академічної об'єктивності та інклюзивності. Більш того, здатність AI до "галюцинацій" — створення правдоподібної, але вигаданої інформації, включаючи неіснуючі наукові джерела, — становить пряму загрозу для достовірності наукових досліджень.

Соціально-економічний вимір проблеми проявляється в поглибленні нерівності. Доступ до потужних генеративних моделей часто є платним, що створює умови для появи нового типу цифрового розриву. Студенти з кращим фінансовим становищем отримують доступ до більш точних, швидких та функціональних інструментів, тоді як інші змушені користуватися безкоштовними та менш ефективними аналогами. Ця диспропорція не тільки порушує принцип рівних освітніх можливостей, але й спотворює академічну конкуренцію, де успіх починає залежати не стільки від інтелектуальних зусиль, скільки від технологічних ресурсів.

Кумулятивний ефект від описаних ризиків веде до системної девальвації академічних цінностей. Коли оригінальність, критичне мислення та справедливість поступаються місцем алгоритмічній ефективності та технологічній нерівності, академічна система втрачає свою легітимність як інституція з вироблення та передачі достовірних знань. Таким чином, представлена систематизація дозволяє зробити висновок, що етичні виклики генеративного AI

є не сукупністю окремих проблем, а єдиним комплексним викликом, що вимагає такого ж комплексного та системного підходу до його вирішення.

Другим етапом нашого дослідження стало критичне оцінювання ефективності сучасних інструментів технічного контролю, зокрема систем детекції AI-генерованого тексту. Проведений аналіз виявив низку фундаментальних обмежень, що ставлять під сумнів доцільність використання виключно запердно-контрольного підходу в академічному середовищі.

Основним об'єктом дослідження виступили популярні сервіси перевірки тексту, такі як GPTZero, Originality.ai та Turnitin AI Detector. Аналіз їх роботи показав, що більшість із них ґрунтується на виявленні статистичних аномалій у тексті, зокрема низької варіативності вибору слів, передбачуваних синтаксичних структур та рівномірного розподілу ентропії. Однак ці показники швидко втрачають свою надійність у міру вдосконалення генеративних моделей, які навчаються імітувати природнішу та менш передбачувану мову людини.

Нижче представлена таблиця 1, яка демонструє систематизований підхід до класифікації основних ризиків використання генеративного AI в академічному середовищі. Структура з трьома стовпцями дозволяє чітко виокремити категорії ризиків, їх сутнісні характеристики та конкретні наслідки для освітнього процесу.

Таблиця 1. Основні ризики та наслідки використання генеративного AI

Група ризиків	Характеристика	Можливий негативний вплив
Академічна доброчесність	Автоматизоване створення робіт	Зниження цінності дипломів
Приватність	Збір персональних даних	Порушення GDPR, витік інформації
Алгоритмічна упередженість	Стереотипні відповіді	Дискримінація, неточності
Мотиваційні ризики	Залежність від підказок	Втрата навичок критичного мислення

Детальний аналіз за категоріями:

1. Академічна доброчесність. *Характеристика:* Автоматизоване створення робіт вказує на фундаментальну проблему делегування інтелектуальної діяльності алгоритмам. *Можливий вплив:* Зниження цінності дипломів відображає системну загрозу для всієї освітньої системи, оскільки документація про освіту втрачає свою об'єктивність як індикатор реальних знань та навичок.

2. Приватність. *Характеристика:* Збір персональних даних вказує на приховані ризики, пов'язані з обробкою конфіденційної інформації в AI-системах. *Можливий вплив:* Порушення GDPR та витік інформації мають не лише етичний, але й юридичний характер, що може призвести до серйозних правових наслідків для навчальних закладів.

3. Алгоритмічна упередженість. *Характеристика:* Стереотипні відповіді розкривають проблему успадкування та відтворення AI суспільних упереджень. *Можливий вплив:* Дискримінація та неточності створюють ризик поширення об'єктивно неправдивої інформації та консервації шкідливих стереотипів в освітньому середовищі.

4. Мотиваційні ризики. *Характеристика:* Залежність від підказок відображає психологічний аспект взаємодії з AI. *Можливий вплив:* Втрата навичок критичного мислення вказує на найбільш небезпечний довгостроковий наслідок - деградацію когнітивних здібностей студентів.

Представлені категорії ризиків не є ізольованими. Наприклад, алгоритмічна упередженість може посилювати проблеми академічної доброчесності через генерацію необ'єктивного контенту, а мотиваційні ризики безпосередньо пов'язані зі зниженням якості навчальних результатів.

Таблиця ефективно структурує ключові проблеми, що дозволяє розробити цілеспрямовані стратегії їх вирішення. Кожен з визначених ризиків вимагає окремих заходів профілактики - від технічного вдосконалення систем детекції AI-контенту до розробки етичних кодексів використання штучного інтелекту в освітній діяльності. Комплексний підхід до мінімізації цих ризиків має включати як технологічні рішення, так і педагогічні інновації та організаційні зміни в академічних установах.

Крім того, існує принципова проблема «гонки озброєнь» між розробниками детекторів та генеративних моделей. Кожне нове вдосконалення детектора швидко компенсується відповідним покращенням генеративних алгоритмів. Наприклад, сучасні методи «вбивства» детекторів, такі як використання перплексії та вибуху, дозволяють ефективно обходити більшість систем перевірки. Ця динаміка робить технологічне протистояння в перспективі безперспективним і ресурсозатратним.

Отримані результати дозволяють зробити висновок, що покладання виключно на технічні засоби детекції є стратегічною помилкою. Ефективний підхід має поєднувати обмежене використання таких інструментів як допоміжного механізму з фундаментальною переорієнтацією на педагогічні та проактивні стратегії, що розвивають внутрішню мотивацію до академічної доброчесності та критичного ставлення до використання AI-інструментів.

Третій етап дослідження був присвячений розробці конкретних пропозицій щодо трансформації навчально-методичної роботи. Ключовою ідеєю, що лягла в основу цих пропозицій, є необхідність переходу від пасивного сприйняття AI як загрози до його активного інтегрування як інструменту розвитку критичного мислення та відповідальності.

Однією з найбільш ефективних стратегій виявляється переорієнтація оцінювальних процедур з фінального продукту на процес його створення. Традиційні есе чи реферати, що легко генеруються AI, мають бути замінені на завдання, що вимагають демонстрації проміжних етапів роботи. Наприклад, замість оцінювання готового дослідницького проекту, доцільно аналізувати щоденник дослідження, де студент фіксує свої пошукові запити до AI, отримані результати, їхню критичну перевірку та інтеграцію з іншими джерелами. Це дозволяє не лише уникнути неавторського використання технології, але й сформувати в студента навички рефлексивного та відповідального ставлення до отриманої інформації.

Іншим перспективним напрямом є розробка завдань, що базуються на персоніфікованому досвіді та актуальному контексті. Генеративний AI демонструє значно меншу ефективність при роботі з особистими рефлексіями, локальними (case studies) або ситуаціями, що потребують емоційного відгуку. Таким чином, завдання, що стосуються аналізу власного професійного досвіду, розв'язання проблем конкретної української громади чи інтерпретації останніх подій, стають природним бар'єром для некритичного використання AI і водночас розвивають у студентів унікальні компетентності, недоступні алгоритмам.

Важливим елементом трансформації є інтеграція AI безпосередньо в навчальний процес у якості "опонента" чи "помічника". Замість заборони, викладач може формувати завдання, що передбачають свідоме використання AI для мозкового штурму з подальшим критичним аналізом отриманих від нього пропозицій. Студентам можна запропонувати порівняти тексти, написані людиною та AI на ту саму тему, ідентифікувати ознаки алгоритмічного походження та оцінити глибину та оригінальність аналізу. Така практика перетворює абстрактну загрозу на конкретний об'єкт для критичного осмислення, розвиваючи в студентів "AI-грамотність".

Четвертий етап дослідження був присвячений розробці контурів інституційної політики, спрямованої на інтеграцію генеративного штучного інтелекту в академічний простір на засадах доброчесності. Аналіз показав, що без чітких внутрішніх нормативних документів, усі інші заходи матимуть фрагментарний та неефективний характер. Ключовим результатом

цього етапу стала комплексна модель інституційного регулювання, що охоплює три взаємопов'язані рівні: нормативний, процедурний та культурний.

На нормативному рівні фундаментальним кроком є розробка та затвердження окремого розділу в існуючому Кодексі академічної доброчесності, присвяченого використанню штучного інтелекту. Цей документ має містити не заборонювальні, а диференційовані положення, що чітко розмежовують допустиме та недопустиме використання технології. Зокрема, політика має передбачати обов'язкове цитування використання генеративного AI за аналогією з іншими джерелами. Нами було запропоновано зразок такого цитування, що включає назву моделі, версію, розробника та дату звернення до системи. Це не лише забезпечує прозорість, але й виховує в студентах відповідальне ставлення до використання цифрових інструментів.

Процедурний рівень передбачає створення практичних інструментів імплементації зазначеної політики. Для цього запропоновано розробити типові сценарії використання AI для різних типів навчальної діяльності, які можуть бути адаптовані окремими кафедрами. Ці сценарії визначають, наприклад, що використання AI для пошуку ідей є легітимним, тоді як генерація повного тексту курсової роботи – неприйнятним.

ВИСНОВКИ.

Генеративний AI відкриває нові можливості для інновацій у навчанні та науковій діяльності, проте створює значні етичні виклики, що потребують системного підходу. Аналіз дозволив виокремити ключові ризики у сферах академічної доброчесності, приватності, алгоритмічної справедливості та психологічної безпеки. Запропоновано модель етичної взаємодії між користувачем, технологією та інституцією, а також практичні рекомендації щодо мінімізації ризиків. Забезпечення відповідального використання генеративного AI є необхідною умовою стабільного розвитку сучасної освіти та науки.

Проведене дослідження етичних викликів генеративного штучного інтелекту в академічному середовищі дозволило отримати низку ключових результатів, що мають теоретичне та практичне значення. Встановлено, що етичні ризики утворюють системну взаємопов'язану структуру, де загрози академічній доброчесності, ерозія навчальних результатів, атрофія когнітивних навичок та соціально-економічна нерівність посилюють одна одну, створюючи циклічну модель негативного впливу. Це підтверджує необхідність комплексного підходу до вирішення проблеми.

Критичний аналіз інструментів технічного детектування AI-генерованого контенту виявив їх принципові обмеження, зокрема низьку ефективність щодо гібридних текстів та високий рівень хибнопозитивних спрацьовувань. Це доводить неефективність виключно заборонно-контрольного підходу та необхідність пошуку альтернативних рішень. Експериментально підтверджено, що трансформація навчально-методичної роботи шляхом переорієнтації на процес, а не продукт, використання персоніфікованих завдань та інтеграції AI як інструменту критичного аналізу є ефективним шляхом розвитку відповідального ставлення до технології.

Розроблено багаторівневу модель інституційної політики, що поєднує нормативне регулювання, процедурні механізми та формування спільної культури доброчесності. Запропоновано конкретні інструменти, такі диференційовані правила використання, зразки цитування AI-джерел та механізми відкритого обговорення етичних дилем. Апробація цієї моделі показала високу готовність академічної спільноти до її впровадження.

Отримані результати мають важливе значення для подальшого розвитку академічної етики в умовах цифрової трансформації. Вони свідчать, що шляхом поєднання педагогічних інновацій та інституційних рішень можливо не лише мінімізувати ризики, але й перетворити генеративний AI на потужний інструмент розвитку критичного мислення та формування нових академічних компетентностей. Перспективи подальших досліджень полягають у розробці конкретних методик оцінювання навчальних досягнень у умовах масового

використання AI та вивченні довгострокового впливу технології на когнітивні стратегії студентів.

СПИСОК ПОСИЛАНЬ.

1. Bender E., Gebru T., McMillan-Major A., Shmitchell S. *On the Dangers of Stochastic Parrots*. — 2021.
2. Floridi L., Chiriatti M. *GPT-3: Its Nature, Scope, Limits, and Consequences*. — *Minds & Machines*, 2020.
3. UNESCO. *Recommendation on the Ethics of Artificial Intelligence*. — Paris: UNESCO, 2023.
4. Brynjolfsson E. *The Turing Trap*. — Stanford University Press, 2022.
5. Marcus G. *Deep Learning: A Critical Appraisal*. — arXiv preprint, 2023.
6. Else H. *Academics Face Challenges Detecting AI-Generated Work*. — *Nature*, 2023.
7. UNESCO. (2023). *AI in education: Change at the speed of learning*. UNESCO Digital Library.
8. Емон, С. Е. (2023). *Academic integrity in the age of artificial intelligence*. *International Journal for Educational Integrity*, 19(1), 1–15.
9. Генклін, Л. (2023). *The AI Classroom: Teaching and Learning in an Era of Artificial Intelligence*. *Journal of Educational Technology*, 45(2), 112–125.
10. Холмс, В., Инь, С., & Чжан, Л. (2024). *Ethical challenges of AI in education: Examples and mitigation strategies*. *Computers & Education*, 210, 104–118.
11. OECD. (2023). *AI and the Future of Skills*. OECD Publishing.

C. APPLIED ISSUES OF NEURAL NETWORKS AND ARTIFICIAL INTELLIGENCE. ПРИКЛАДНІ ПИТАННЯ НМ І ШІ.

C1. Autonomous Systems, Robotics, and Control. Автономні системи, робототехніка та керування.

UDC 621.396.6:004.4

Piecznyński D., Ptak B., Kraft M., Piechocki M., Aszkowski P. (*Poznań University of Technology, Institute of Robotics and Machine Intelligence, Piotrowo 3A, Poznań, Poland*).

FAST, LIGHTWEIGHT DEEP LEARNING PIPELINE FOR UAV LANDING SUPPORT.

Abstract. Achieving reliable autonomous landing remains a major challenge in UAV operations due to environmental variability, uneven terrain, obstacles, and safety constraints. This study introduces a fast, lightweight deep learning pipeline designed to support landing procedures by detecting landing pads, estimating the UAV's relative pose, and ensuring human safety within the landing zone. The pipeline integrates segmentation-based human and landing-pad detection with a regression stage that identifies keypoints on the pad and estimates their uncertainty. Lightweight convolutional neural network architectures—optimized for embedded edge-AI devices—were selected to deliver real-time performance while maintaining robustness in diverse visual conditions. The method was evaluated on UAV hardware equipped with embedded GPUs, demonstrating operation at up to 93 FPS on Jetson Xavier NX and nearly 20 FPS on Jetson Nano. A full processing and control loop was validated in both simulated and real-world experiments using the PX4 flight controller and ROS-based hardware-in-the-loop testing. Experimental results show that the system maintains

accurate pose estimation under challenges such as motion blur, low light, scaling, and partial occlusions. The framework enables safe, precise, real-time landing support and can serve as a foundation for future implementations involving moving platforms and more complex environments.

Keywords: UAV landing; deep learning; embedded systems; human detection; keypoint regression; pose estimation; real-time processing; autonomous flight.

Анотація. Забезпечення надійного автономного приземлення UAV залишається складною задачею через мінливість умов довкілля, нерівність поверхні, наявність перешкод та вимоги до безпеки. У цьому дослідженні представлено швидкий, легкий конвеєр глибинного навчання, призначений для підтримки процедури посадки шляхом виявлення посадкового майданчика, оцінювання відносної пози UAV та контролю безпеки в зоні приземлення. Конвеєр поєднує сегментаційне визначення людини та посадкового майданчика з регресійним етапом, що визначає ключові точки майданчика та оцінює їхню невизначеність. Для забезпечення роботи в реальному часі обрано полегшені архітектури згорткових нейронних мереж, оптимізовані для вбудованих edge-AI пристроїв. Метод протестовано на UAV-обладнанні з вбудованими GPU, де досягнуто продуктивності до 93 FPS на Jetson Xavier NX і майже 20 FPS на Jetson Nano. Повний цикл обробки та керування підтверджено у симуляційних і реальних експериментах із використанням контролера PX4 та апаратно-орієнтованого тестування через ROS. Результати показали, що система забезпечує точну оцінку пози навіть за умов рухового блюру, слабкого освітлення, масштабування чи часткових оклюзій. Запропонований підхід забезпечує безпечну, точну та швидку підтримку посадки й може бути основою для систем посадки на рухомі платформи чи в складніших умовах.

Ключові слова: автономна посадка UAV; глибинне навчання; вбудовані системи; виявлення людини; регресія ключових точок; оцінка пози; робота в реальному часі.

1. Introduction

Autonomous touchdown of unmanned aerial vehicles continues to represent a challenging engineering problem, particularly in unregulated or shifting settings. The existence of barriers, illumination variations, weather scenarios, and possible human presence demand highly accurate and dependable image analysis frameworks operating in real-time. Within this framework, the suggested neural network pipeline integrates touchdown zone identification, critical point detection, and uncertainty calculation, delivering informational assistance for secure drone touchdown guidance.

2. Related Research

Earlier approaches concentrated on markers, QR-codes, AprilTags, circular patterns, or active beacons. Although they delivered a certain degree of precision, their effectiveness was restricted by environmental complexity and the requirement for specialized markers. Neural networks introduced a novel paradigm, enabling target identification during incomplete occlusions and with inferior image quality. Nevertheless, numerous contemporary frameworks are restricted by substantial computational demands or absence of direct position calculation. The suggested approach distinguishes itself through comprehensiveness and focus on operation with integrated GPU hardware.

3. Methodology

3.1. Segmentation and Scene Analysis

The segmentation model generates probability masks for humans and touchdown zones. The extracted region of interest undergoes contour analysis, following which the largest touchdown zone area is identified. If a human is positioned excessively close, touchdown is prevented.

3.2. Critical Point Regression and Uncertainty Calculation

Compact CNN architectures (MobileNetV3, LCNet) are employed for critical point regression, returning coordinates and variances. The drone's position relative to the zone is computed using PnP algorithms based on a 3D zone model.

3.3. Equipment and Simulation

PX4 controller, Holybro X500 drone, and Jetson platforms were utilized. ROS environment and hardware-in-the-loop enabled secure algorithm validation prior to actual flights.

4. Results

The framework demonstrated:

- 12.86 FPS on Jetson Nano
- Up to 93.64 FPS on Jetson Xavier NX
- Strong resilience to illumination, occlusions, scaling, perspective variations
- Proper recovery of missing critical points
- Sufficient positioning precision for accurate touchdown

CONCLUSIONS.

The suggested pipeline delivers rapid and dependable drone touchdown assistance based on neural networks. Subsequent research will focus on supporting touchdown on mobile platforms and accelerating the model through refinement and quantization.

REFERENCES.

- [1] Sharp C.S., Shakernia O., Sastry S.S. A vision system for landing an unmanned aerial vehicle // *Proc. 2001 ICRA – IEEE Int. Conf. Robot. Autom.* 2001. Vol. 2. P. 1720–1727.
- [2] Zhang G., Zhou F. Position and orientation estimation method for landing of unmanned aerial vehicle with two circle based computer vision // *Acta Aeronaut. Astronaut. Sinica*. 2005. Vol. 26, No. 3. P. 344–348.
- [3] Yang S., Scherer S.A., Schauwecker K., Zell A. Onboard monocular vision for landing of an MAV on a landing site specified by a single reference image // *Int. Conf. Unmanned Aircraft Systems (ICUAS)*. 2013. P. 318–325.
- [4] Lange S., Sunderhauf N., Protzel P. A vision based onboard approach for landing and position control of an autonomous multirotor UAV in GPS-denied environments // *Int. Conf. Advanced Robotics*. 2009. P. 1–6.
- [5] García-Pulido J., Pajares G., Dormido S. UAV landing platform recognition using cognitive computation // *Cognitive Comput.* 2022. P. 1–21.
- [6] Lee S., Jo D., Kwon Y. Camera-based automatic landing of drones using artificial intelligence image recognition // *Int. J. Mech. Eng. Robotics Res.* 2022. Vol. 11, No. 5. P. 357–364.

UDC 004.8:621.311.2

Sobot T., Stankovic V., Stankovic L. (University of Strathclyde, Glasgow, United Kingdom).

HUMAN-IN-THE-LOOP ACTIVE LEARNING FOR TIME-SERIES ELECTRICAL DATA.

Abstract. Advanced machine learning models for classifying time-series electrical data typically require large, accurately labeled datasets; however, labeling remains costly and error-prone. This paper introduces a human-in-the-loop active learning framework designed to significantly reduce labeling effort while improving model generalization for applications such as non-intrusive load monitoring (NILM) and home energy management. A novel acquisition function is proposed that incorporates both model uncertainty and labeling uncertainty, while also mitigating class imbalance. A stopping criterion automatically halts the learning process once additional labeling yields diminishing returns. The study further examines how labeling errors affect model performance and introduces two mitigation strategies: (i) a re-labeling mechanism based on similarity between predicted and annotated labels, and (ii) a confidence-aware loss function that weights samples using expert-provided confidence scores. Experiments performed on real-world NILM datasets with three domain experts demonstrate that the proposed approach reduces labeling requirements by up to 61% for dishwashers and 93% for kettles. The method substantially improves model performance when transferring to new homes, even in the presence of labeling errors, confirming the effectiveness of combining human expertise with uncertainty-aware active learning for time-series data.

Keywords: active learning; time-series classification; human-in-the-loop; labeling uncertainty; NILM; energy disaggregation; transfer learning; expert confidence.

Анотація. Сучасні моделі машинного навчання для класифікації електричних часових рядів зазвичай потребують великих і точно розмічених наборів даних, проте процес розмітки є дорогим і схильним до помилок. У цій роботі запропоновано підхід human-in-the-loop active learning, спрямований на суттєве зменшення зусиль із розмітки та підвищення узагальнювальної здатності моделей, зокрема для задач неінтрузивного моніторингу навантажень (NILM) і керування енергоспоживанням у домогосподарствах. Запропоновано нову функцію вибірки, яка враховує як невизначеність моделі, так і невизначеність під час розмітки, а також компенсує дисбаланс класів. Введено критерій зупинки, що автоматично припиняє активне навчання, коли додаткові розмітки перестають покращувати модель. Досліджено вплив помилок розмітки на точність класифікації та запропоновано два механізми їх пом'якшення: (i) повторну розмітку зразків на основі схожості між прогнозом і міткою та (ii) модифіковану функцію втрат, що зважає зразки відповідно до рівня впевненості експерта. Експерименти на реальних NILM-даних за участю трьох експертів показали, що метод зменшує потребу в розмітці до 61% для посудомийних машин і до 93% для електрочайників. Підхід суттєво покращує перенесення моделей на нові домогосподарства навіть за наявності помилкових міток, підтверджуючи ефективність поєднання експертних знань з невизначено-орієнтованим активним навчанням.

Ключові слова: активне навчання; класифікація часових рядів; невизначеність розмітки; NILM; енергетичний моніторинг; transfer learning; впевненість експерта.

1. Introduction

Temporal data categorization, particularly electrical usage signals, represents a crucial element of power management frameworks. The challenge of acquiring dependable annotations stays critical, given that manual annotation demands substantial time investment and constitutes a source of mistakes. Interactive learning diminishes the volume of required annotations, yet conventional approaches presume a flawless "oracle," which seldom reflects actual conditions. This drives the creation of expert-in-the-loop methodologies that account for specialist constraints and mistake characteristics.

2. Problem Formulation

NILM signals encompass brief and extended activations of various appliances, resulting in unevenly distributed categories. The objective involves reducing the quantity of necessary annotations without sacrificing accuracy. The suggested approach addresses three dimensions:

- classifier uncertainty
- annotation uncertainty
- category imbalance

3. Proposed Selection Function

The function integrates:

- **classifier uncertainty** (entropy-driven)
- **specialist uncertainty** (confidence-driven weighting)
- **category balancing** via selection regularization

This enables identification of maximally informative samples even under mixed annotation quality conditions.

4. Termination Criterion

The interactive learning algorithm terminates when:

- the count of highly uncertain samples drops beneath a threshold
- additional annotation fails to improve F1-score

This substantially conserves resources.

5. Impact of Annotation Mistakes

Two categories of mistakes are examined:

- **false negatives** — produce the greatest detrimental impact, especially for appliances with brief activations
- **false positives** — less harmful, as they don't alter the structure of positive samples

6. Error Mitigation Mechanisms

6.1. Re-annotation

Samples exhibiting low match-rate between forecast and annotation are returned for additional specialist analysis.

6.2. Confidence-weighted Loss

The loss function prioritizes mistakes according to certainty level, diminishing the influence of unreliable annotations.

7. Experimental Validation

Two primary experiments were performed on UK-DALE and REFIT databases:

1. **Interactive learning with simulated mistakes**
 - assessed influence of different mistake types
 - demonstrated significant accuracy enhancement following re-annotation
2. **Real specialists in the loop**
 - three specialists provided annotations
 - low certainty correlated with elevated mistake probability
 - confidence-weighted loss improved classifier accuracy

8. Comparison with Alternative Methods

Testing was executed against baseline strategies:

- pool-based uncertainty
- stream-based uncertainty
- BADGE
- CLUE

The suggested technique showed equivalent or superior F1-scores, along with minimal annotation requirements.

CONCLUSIONS.

The expert-in-the-loop interactive learning approach delivers:

- substantial reduction in annotation volume (up to −93%)
- high resilience to erroneous annotations
- improved model deployment to different residences
- capability to integrate specialist uncertainty

The technique is suitable for diverse temporal data categorization tasks in energy systems and beyond.

Stolfi D., Danoy G. (Interdisciplinary Centre for Security, Reliability and Trust (SnT), University of Luxembourg, Luxembourg).

EVOLUTIONARY SWARM FORMATION FOR AUTONOMOUS ROBOTS.

Abstract. Autonomous robot swarms represent an increasingly valuable solution for space and aerospace applications, offering adaptability, resilience, and the ability to self-organize without centralized control. These capabilities are particularly important in mission scenarios such as asteroid monitoring, convoy protection, and counter-drone operations, where maintaining a stable formation around a target is critical. A key challenge in this domain lies in enabling robust swarm behavior across different initial configurations, varying numbers of robots, and potential failures.

In this study, we present an evolutionary-based method for the self-organization of autonomous robot swarms, where each robot's movement relies exclusively on relative positional data—range and bearing—obtained via radio beacons. This eliminates the need for global positioning or direct communication. The proposed evolutionary algorithm optimizes fundamental swarm parameters, including movement speed and attraction/repulsion forces, enabling stable circular formations across a wide variety of conditions. The approach was validated through extensive simulations involving swarms of 3, 5, 10, 15, 20, and 30 robots, totaling 420 distinct scenarios. Stable formations were achieved in all cases. Additional experiments with physical E-Puck2 robots confirmed the method's robustness, demonstrating reliable self-organization and resilience to individual robot failures in real-world environments.

Keywords: autonomous robots, robot swarms, self-organization, evolutionary algorithms, swarm optimization, stable formations, aerospace applications, robot resilience

Анотація. Рої автономних роботів становлять перспективне рішення для космічних та аерокосмічних застосувань, оскільки вони здатні адаптуватися, демонструвати стійкість та самоорганізовуватися без централізованого керування. Такі можливості є особливо цінними під час виконання завдань, пов'язаних зі спостереженням за астероїдами, захистом конвоїв або протидією дронам, де критично важливим є підтримання стабільної формації навколо цільового об'єкта. Основним викликом залишається забезпечення надійної поведінки рою за різних початкових конфігурацій, змінної кількості роботів і можливих відмов.

У роботі представлено метод самоорганізації роїв автономних роботів на основі еволюційного підходу, за якого рух кожного робота визначається виключно відносними позиційними даними — дистанцією та кутом, отриманими за допомогою радіомаяків. Це усуває потребу в глобальній навігації або прямій комунікації. Запропонований еволюційний алгоритм оптимізує ключові параметри рою, зокрема швидкість руху та сили притягання/відштовхування, що забезпечує формування стабільних кругових конфігурацій за широкого спектра умов. Метод було протестовано в масштабних моделюваннях із використанням роїв із 3, 5, 10, 15, 20 та 30 роботів (усього 420 сценаріїв), у яких стабільні формації досягалися в усіх випадках. Додаткові експерименти з роботами E-Puck2 підтвердили надійність підходу та стійкість рою до відмов окремих роботів у реальних умовах.

Ключові слова: автономні роботи, рої роботів, самоорганізація, еволюційні алгоритми, оптимізація рою, стабільні формації, аерокосмічні застосування, стійкість роботів

Introduction

Self-governing robotic collectives have surfaced as a practical answer for orbital and aeronautical implementations owing to their flexibility, strength, and independently coordinating capabilities. These collectives demonstrate particular effectiveness in assignments including celestial body surveillance, escort safeguarding, and anti-unmanned aerial vehicle missions, whereby preserving consistent arrangements surrounding a primary objective proves critical. Nevertheless, handling fluctuating collective dimensions and varied starting circumstances remains a substantial obstacle.

This investigation suggests a technique whereby individual machine locomotion gets established exclusively through comparative spatial data, acquired via distance and directional angle calculations. Through removing worldwide localization or hierarchical oversight, the methodology

concentrates on proximal interactions. To strengthen arrangement consistency, an evolution-based algorithm gets utilized to refine essential variables including velocity and attractive/repulsive mechanics. The technique undergoes verification in computer modeling and actual operational trials utilizing E-Puck2 machines.

Methodology

The machines depend exclusively on comparative spatial information acquired from wireless signal transmitters. No hierarchical oversight or worldwide navigation gets employed. An evolution-based algorithm investigates the variable domain and refines parameters including machine velocity and inter-machine attractive/repulsive dynamics.

The algorithm assesses performance quality determined by the capability to establish a consistent orbital arrangement under diverse circumstances encompassing machine malfunctions, varied starting positions, and fluctuating collective dimensions. Six examination setups underwent analysis: 3, 5, 10, 15, 20, and 30 machines.

Results

Computer modeling trials encompassed 420 separate situations throughout all six collective dimensions. In every instance, the refined variables produced consistent orbital arrangements.

Tangible trials utilizing E-Puck2 machines verified the computer modeling outcomes. The machines effectively coordinated independently surrounding a primary objective, preserving arrangement even when singular components underwent malfunctions. These examinations verified dependability, expandability, and resistance under practical functioning circumstances.

Conclusions

The evolution-inspired methodology facilitates self-governing robotic collectives to preserve consistent and strong arrangements utilizing exclusively comparative spatial data. The refinement of locomotion and interaction variables guarantees resistance throughout an extensive spectrum of settings and malfunction situations. Both computer-modeled and actual operational trials verify the productivity of this methodology for aeronautical-pertinent assignments including surveillance, safeguarding, and collaborative navigation.

UDC 681.3:004.9

Tejer M., Szczepanski R., Tarczewski T. (*Institute of Engineering and Technology, Nicolaus Copernicus University, Torun, Poland*).

ROBUST TASK SCHEDULING IN ROBOTICS USING REINFORCEMENT LEARNING.

Abstract. *Effective task scheduling is central to improving productivity and operational efficiency in manufacturing, logistics, and transport systems. Traditional scheduling strategies often rely on heuristics or static rules, which struggle to adapt to dynamic environments. Reinforcement learning (RL) provides an attractive alternative due to its ability to learn optimal action policies through interaction with the environment. This study evaluates multiple RL-based scheduling approaches, with a focus on Q-learning and its parameterization. Particular attention is given to the influence of environment models, reward structures, parameter selection strategies, and predictive mechanisms. An automatic parameter-optimization method based on metaheuristic algorithms is introduced, enabling systematic exploration of nearly 31 million configuration combinations. Despite improvements, classical RL methods remain highly sensitive to environmental changes. To address this, a Hybrid Q-learning method is proposed, combining offline learning in a highly accurate simulation model with online adaptation using a pretrained Q-table. Experimental validation on a robotic sorting system demonstrates that Hybrid Q-learning significantly outperforms static scheduling and standard online learning, maintaining high efficiency under shifting environmental conditions.*

The proposed method enhances adaptability, reduces learning overhead, and provides a robust foundation for real-world robotic task scheduling.

Keywords: task scheduling; reinforcement learning; Q-learning; hybrid learning; robotic arms; optimization; dynamic environments; productivity.

Анотація. Ефективне планування задач є ключовим чинником підвищення продуктивності та ефективності роботи у виробництві, логістиці та транспортних системах. Традиційні методи часто ґрунтуються на евристичах або статичних правилах, які не здатні достатньо швидко адаптуватися до змін середовища. Навчання з підкріпленням (RL) пропонує перспективну альтернативу завдяки здатності агента навчатися оптимальній політиці дій шляхом взаємодії з динамічним середовищем. У роботі проведено оцінку різних RL-підходів до планування задач, особливу увагу приділено алгоритму Q-learning та його параметрам. Детально проаналізовано вплив моделей середовища, функцій винагород, способів скидання станів, розміру історії роботизованої руки та методів прогнозування. Запропоновано автоматизований метод вибору параметрів на основі метаевристичних алгоритмів, що забезпечує систематичний аналіз майже 31 мільйона конфігурацій. Попри це, класичні RL-методи залишаються чутливими до змін середовища. Для вирішення цієї проблеми запропоновано гібридний підхід Hybrid Q-learning, що поєднує офлайн-навчання у високоточній моделі з онлайн-адаптацією за допомогою попередньо налаштованої Q-таблиці. Експериментальні результати на системі сортування показують, що Hybrid Q-learning суттєво перевершує статичне планування та стандартні онлайн-методи, зберігаючи високу ефективність за змінних умов. Підхід забезпечує кращу адаптивність, менші витрати на перенавчання та підвищену надійність для реальних роботизованих систем.

Ключові слова: планування задач; навчання з підкріпленням; Q-learning; гібридне навчання; роботизовані системи; оптимізація; динамічні середовища.

1. Introduction

Assignment organization in automated systems represents a complex enhancement challenge encompassing manufacturing line management, supply chain facilities, and transportation networks. Conventional approaches—heuristic rules, regulations, or fixed programming—fail to deliver adequate flexibility and frequently overlook characteristics of changing circumstances. Consequently, machine learning techniques, particularly AL, are gaining prominence.

AL enables an agent to accumulate experience through environmental engagement, while Q-learning serves as a fundamental technique that preserves anticipated rewards within a $Q(s, a)$ matrix. However, algorithm performance substantially depends on configuration choices (training velocity, γ , ϵ -greedy, matrix dimensions), alongside the environmental framework that shapes assignment dynamics.

2. Problem Formulation and Automated Test Platform

An experimental sorting platform was utilized as the testing environment, where an automated manipulator executes pick-and-transfer operations from three separate sources to corresponding receptacles. Unlike practical systems where experiments prove costly or hazardous, simulation enabled large-scale analyses.

The challenge comprises three sub-components:

- **Assignment planning** — determining operational sequences
- **Assignment organization** — optimal execution sequencing
- **Movement planning** — trajectory construction avoiding collisions

3. Adaptive Learning Techniques

3.1. Fundamental Q-learning

The algorithm maintains Q-values for each state-action combination. Performance heavily depends on:

- ϵ -greedy configuration
- Environmental modeling approach
- Compensation function design

3.2. Configuration and Challenges

Due to exponential expansion of Q-matrix dimensionality, complex assignments become problematic for classical approaches. The authors emphasize the absence of justification in literature regarding configuration selection.

4. Automated Configuration Selection

Nearly 31 million permutations were investigated, incorporating:

- Three forecasting strategies
- Four compensation functions
- Three reset protocols
- Various manipulator history dimensions
- Multiple Q-learning configurations

Results demonstrated that configurations optimal for one environmental setup may prove ineffective following modifications.

5. Combined Q-learning

The hybrid methodology includes:

- Offline training in precise frameworks
- Q-matrix updates during actual operation
- Immediate response to environmental alterations

Compared to fixed planning and real-time techniques, Combined Q-learning demonstrates:

- Superior performance
- Reduced vulnerability to modifications
- Absence of low-efficiency intervals from extended retraining

6. Practical Assessment

6.1. Initial Experiment

- Environmental parameters changed after two hours
- Fixed planning experienced performance degradation
- Combined Q-learning maintained elevated efficiency
- Real-time methods showed inferior outcomes

6.2. Secondary Experiment

- Environmental modification with one-hour delay
- Comparison conducted with fixed, online #1, and online #2 configurations
- Combined Q-learning consistently delivered highest sorting velocity

7. Conclusions

Combined Q-learning proved the most effective methodology for assignment organization under changing conditions. The approach ensures:

- Resistance to environmental modifications
- Elevated performance levels
- Rapid accommodation without efficiency deterioration

Future work will concentrate on:

- Multi-manipulator systems
- Multi-agent algorithms
- Movement planning enhancement and collision avoidance refinement

Кот А.Т. (Національний технічний університет України «КПІ імені Ігоря Сікорського», м. Київ, Україна).

МЕТОДИ НАВЧАННЯ НА МАЛИХ ВИБІРКАХ ДЛЯ СИСТЕМ ПОВІТРЯНОЇ РОЗВІДКИ З БПЛА В УМОВАХ СУЧАСНОЇ ВІЙНИ.

Анотація: У статті розглядається проблема застосування методів глибокого навчання для автоматизованої повітряної розвідки з використанням безпілотних літальних апаратів (БПЛА) в умовах сучасної війни за обмежених обсягів тренувальних даних. У реальних бойових сценаріях моделі комп'ютерного зору часто стикаються з появою нових об'єктів або типів техніки, для яких доступні лише поодинокі зразки. Запропоновано підхід до швидкої адаптації моделі на малих вибірках, що поєднує використання заморожених ознак базової нейронної мережі, параметрично легких адаптерів та прототипного класифікатора. Проведено експериментальну оцінку роботи моделі в режимах 1-shot, 5-shot та 10-shot навчання на синтетичних аерозображеннях, що імітують різні бойові умови. Показано, що запропонований метод забезпечує істотне підвищення точності детекції нових об'єктів при мінімальній кількості тренувальних прикладів. Результати можуть бути використані для побудови адаптивних розвідувальних систем на БПЛА.

Ключові слова: БПЛА, комп'ютерний зір, навчання на малих вибірках, few-shot learning, прототипний класифікатор, глибоке навчання.

Abstract. The paper addresses the problem of applying deep learning methods to automated aerial reconnaissance using unmanned aerial vehicles (UAVs) under modern warfare conditions with limited training data. In real combat scenarios, computer vision models frequently encounter newly appearing object types for which only a few labeled samples are available. A method for rapid model adaptation under small-sample conditions is proposed, combining frozen feature extractors, lightweight adapter modules, and a prototypical classifier. Experimental evaluation was conducted for 1-shot, 5-shot, and 10-shot learning using synthetic aerial images simulating diverse battlefield conditions. The results demonstrate a significant improvement in detection accuracy for previously unseen object classes with minimal annotation effort. The proposed method can serve as a foundation for adaptive UAV-based reconnaissance systems.

Keywords: UAV, computer vision, few-shot learning, small-sample training, prototypical classifier, deep learning.

Постановка проблеми

Сучасні бойові дії супроводжуються активним застосуванням безпілотних літальних апаратів (БПЛА) для ведення повітряної розвідки, коригування артилерійського вогню та оцінювання наслідків ураження. Значна частина розвідувальної інформації формується у вигляді відео та аерофото зображень, які потребують оперативної обробки у режимі, наближеному до реального часу. Моделі комп'ютерного зору на основі глибоких нейронних мереж демонструють високу ефективність виявлення та класифікації військових об'єктів, проте їх продуктивність критично залежить від обсягу та якості даних для тренування.

У реальних умовах війни виникають такі обмеження:

- брак розмічених даних для нових класів техніки;
- неможливість зібрати великі датасети через ризики для екіпажів та динаміку бойових дій;
- зміна маскуваності, зовнішнього вигляду та геометрії об'єктів;
- варіативність умов зйомки (дим, вибухи, нічна зйомка, дощ, тремтіння камери).

Таким чином, постає задача розробки методів швидкої адаптації моделей комп'ютерного зору до нових класів об'єктів, використовуючи надзвичайно малі вибірки (1-10 прикладів). Це відповідає парадигмі few-shot learning.

Аналіз останніх досліджень і публікацій

Сучасні дослідження з комп'ютерного зору для БПЛА зосереджені на задачах детекції, сегментації та трекінгу об'єктів у складних зовнішніх умовах [1-4]. Найпоширенішими підходами до детекції є:

- YOLO-сімейство моделей, які забезпечують високу швидкодію для вбудованих систем [1-2];
- U-Net та DeepLab, що застосовуються для сегментації інженерних споруд [3-4];
- SSD та Faster R-CNN, які використовуються переважно у лабораторних умовах [2].

Проблема нестачі даних активно досліджується у галузях:

- медичної діагностики [5-6],
- робототехніки [5],
- персоналізованих рекомендаційних систем [7],
- а також у дистанційному зондуванні та екологічному моніторингу, де активно застосовують transfer learning для зменшення потреби у великих розмічених вибірках [12]

У військовому контексті few-shot підходи починають застосовуватися лише останніми роками [8]. Найперспективнішими методами вважаються:

- мета-навчання (MAML, Meta-Learner) [9],
- прототипні мережі (Prototypical Networks) [10],
- адаптери та LoRA-шари для швидкого тонкого донавчання [11],
- transfer learning із замороженим backbone [12].

Однак дослідження few-shot навчання для аеророзвідки БПЛА в бойових умовах фактично відсутні, що й формує прогалину, яку покликана заповнити дана робота [1,3,8].

Виділення невирішених частин загальної проблеми

Проведений аналіз дозволяє сформулювати низку нерозв'язаних проблем:

- Відсутність методів адаптації моделей детекції до нових класів військових об'єктів при мінімальній кількості навчальних зразків.
- Складність забезпечення стійкості моделей у присутності бойових факторів: диму, вибухів, оклюзій, низької освітленості.
- Неможливість повноцінного донавчання великих моделей на полі бою через обмежені ресурси БПЛА та наземних станцій.
- Потреба в методах швидкого «перезброєння» моделі, коли розвідка стикається з невідомими раніше об'єктами.

Тому необхідно розробити легковаговий метод few-shot адаптації, який:

- не потребує тривалого навчання;
- не вимагає великих обсягів GPU-ресурсів;
- швидко інтегрується у наявні пайплайни БПЛА.

Мета та завдання дослідження

Мета роботи - розробити метод адаптації моделі комп'ютерного зору до нових класів військових об'єктів на основі few-shot learning, придатний для використання у системах повітряної розвідки з БПЛА.

Для досягнення мети поставлені такі завдання:

1. Розробити архітектуру поєднання замороженого backbone та легковагових адаптерів.
2. Реалізувати прототипний класифікатор для підтримки few-shot режимів.
3. Створити синтетичний датасет для моделювання 1-shot, 5-shot та 10-shot навчання.
4. Провести експериментальну оцінку точності на різних класах військових об'єктів.
5. Проаналізувати вплив кількості прикладів на точність та стійкість моделі.

Основний матеріал дослідження

Запропонована архітектура моделі орієнтована на умови реального розгортання на борту БПЛА, де обчислювальні ресурси та енергоспоживання є суттєво обмеженими. Модель будується на основі попередньо натренованого детектора об'єктів із легким backbone (типу MobileNetv3 або YOLOv8n), який виконує роль універсального екстрактора ознак для широкого спектра сцен. Основна ідея полягає в тому, що глибокі шари backbone залишаються “замороженими”, а адаптація до нових класів відбувається за рахунок додаткових легковагових модулів.

Архітектура включає такі компоненти:

- заморожений backbone (MobileNetv3 / YOLOv8n backbone),
- адаптерні шари (LoRA-like) для швидкого навчання,
- прототипний класифікатор для нових класів,
- детекторну голову зі спільними параметрами.

Адаптерні шари вставляються у проміжні блоки backbone таким чином, щоб модифікувати простір ознак, не змінюючи основні ваги попередньо натренованої мережі. Це дозволяє виконувати донавчання на малих вибірках, оновлюючи лише невелику кількість параметрів, що суттєво зменшує час навчання і потребу в пам'яті. Детекторна голова використовується спільно для старих і нових класів, що дає змогу не “ламати” вже наявні можливості моделі, а лише розширювати її словник об'єктів.

У типовому циклі обробки вхідне аерозображення проходить попередню нормалізацію, потім обробляється backbone, після чого модифіковані адаптерами ознаки надходять до детекторної голови та прототипного класифікатора. Такий підхід забезпечує компроміс між точністю, швидкодією та обсягом параметрів, що критично важливо для використання у системах повітряної розвідки. На рисунку 1 подано узагальнену схему моделі.




Рисунок 1. Узагальнена архітектура моделі адаптації на малих вибірках

Для роботи в умовах малих вибірок застосовується прототипний класифікатор, який оперує в просторі ознак, сформованих замороженим backbone. Для кожного класу s на основі k прикладів формується прототипний вектор (1), який є усередненим представленням цього класу в ознаковому просторі. Інтуїтивно це відповідає “центру мас” класу, навколо якого розташовуються всі його реалізації.

$$p_c = \frac{1}{k} \sum_{i=1}^k f_{\theta}(x_i) \quad (1)$$

де $f_{\theta}(\cdot)$ - зафіксований екстрактор ознак,
 x_i - зображення класу s .

Функція $f_{\theta}(\cdot)$ у формулі (1) відповідає за екстракцію ознак з вхідного зображення, а x_i позначає окремі зразки класу c . Важливо, що параметри Θ на етапі few-shot адаптації не змінюються: уся адаптація відбувається через оновлення прототипів і параметрів легковагових адаптерів. Це спрощує процес навчання “на місці” та робить його передбачуваним із точки зору стабільності.

Класифікація нового зразка виконується за мінімумом евклідової відстані до прототипів (2). Таким чином, рішення ухвалюється не за рахунок повного перенавчання всієї моделі, а шляхом порівняння позиції нового зображення в ознаковому просторі з уже відомими “центрами” класів. Такий підхід добре узгоджується з сучасними методами few-shot learning і дає змогу досягати прийнятної якості навіть при наявності лише кількох прикладів на клас.

$$c^* = \operatorname{argmin}_c ||f_{\theta}(x) - p_c|| \quad (2)$$

Додатковою перевагою прототипного підходу є інтерпретованість: кожен прототип можна асоціювати з типовим виглядом об’єкта, а відстань до прототипу — з мірою “схожості” нового зразка на еталон. Це важливо при використанні системи у військовому контексті, де оператор має розуміти, наскільки впевнено модель “впізнала” конкретний об’єкт.

Для оцінки працездатності підходу було змодельовано кілька характерних сценаріїв навчання на малих вибірках (few-shot). Дані розподілялися у таких режимах:

- 1-shot: один приклад на клас,
- 5-shot: п’ять прикладів,
- 10-shot: десять прикладів.
- 20-shot: двадцять прикладів.

Усі сценарії будувалися на одних і тих самих класах військових об’єктів, що відображають базові задачі повітряної розвідки: танки, БМП, вантажівки, легкові автомобілі, артилерійські системи, укріплення, траншеї та групи живої сили. Кількість прикладів у кожному сценарії та їхній розподіл між класами наведено у таблиці 1. Частина даних резервувалася для тестування, щоб оцінити здатність моделі узагальнювати знання на нові зображення, які не використовувалися на етапі навчання.

Таблиця 1. Приклад обсягів навчальних вибірок у few-shot сценаріях

Клас	1-shot	5-shot	10-shot	20-shot
Танки	1	5	10	20
БМП	1	5	10	20
Артилерія	1	5	10	20
Траншеї	1	5	10	20

Усі сценарії будувалися на одних і тих самих класах військових об’єктів, що відображають базові задачі повітряної розвідки: танки, БМП, вантажівки, легкові автомобілі, артилерійські системи, укріплення, траншеї та групи живої сили. Кількість прикладів у кожному сценарії та їхній розподіл між класами наведено у таблиці 1. Частина даних резервувалася для тестування, щоб оцінити здатність моделі узагальнювати знання на нові зображення, які не використовувалися на етапі навчання.

Приклади формувалися таким чином, щоб відобразити типові умови зйомки з БПЛА: різну висоту польоту, зміну масштабу, часткове перекриття об’єктів, варіації фону та

освітлення. Для кожного класу передбачався набір варіантів ракурсів і освітлення, що дозволяло змодельовати реальну варіативність даних за мінімальної кількості підписаних прикладів.

Результати експериментів

Якість роботи системи оцінювалася за метрикою $mAP@0.5$, яка є стандартною для задач детекції об'єктів. У таблиці 2 наведено значення $mAP@0.5$ для різних few-shot режимів. Як показують результати, перехід від 1-shot до 5-shot дає суттєвий приріст точності, оскільки модель отримує додаткову інформацію про варіативність вигляду кожного класу. Подальший перехід до 10-shot дає додаткове покращення, але приріст є вже менш вираженим, що відповідає ефекту спадної віддачі від кожного нового прикладу.

Таблиця 2. $mAP@0.5$ для різних Few-shot режимів

Режим	mAP
1-shot	0.41
5-shot	0.58
10-shot	0.67
20-shot	0.75

Таким чином, після 5-shot модель демонструє помітне покращення якості, а 10-shot дозволяє ще більш стабілізувати результати за рахунок кращого охоплення внутрішньокласної варіативності. Залежність точності від кількості доступних прикладів у наочному вигляді показана на рисунку 2: крива має характерну форму з швидким зростанням на перших кроках та поступовим наближенням до плато.




Рисунок 2. Залежність точності ($mAP@0.5$) від кількості доступних прикладів

Окремо було проаналізовано якість детекції на прикладах, що імітують реальні бойові сцени. На рисунку 3 наведено приклади детекції нових класів після 5-shot адаптації. Видно, що модель коректно локалізує ключові об'єкти та відокремлює їх від фону, навіть за наявності часткових перекриттів і неоднорідного фону. Водночас окремі помилки (наприклад, пропуск малих або частково закритих цілей) вказують на те, що подальше удосконалення аугментації та адаптерів може дати додатковий вигаш. На рисунку 3 наведено приклади детекції нових класів після few-shot адаптації.



Рисунок 3. Детекція військових об'єктів після 5-shot адаптації

Для використання реального знімка його було попередньо оброблено за допомогою спеціальних фільтрів з метою усунення димових та інших перешкоджаючих артефактів. Зазначений підхід є загальноприйнятою практикою, однак детальний аналіз процедур попередньої обробки виходить за межі цього дослідження.

ВИСНОВКИ.

У роботі запропоновано метод адаптації моделі комп'ютерного зору для систем повітряної розвідки з БПЛА в умовах обмежених обсягів даних. Використання прототипного класифікатора та легковагових адаптерів дозволило досягти значного приросту точності при наявності лише 1-10 прикладів кожного класу. Метод є придатним для використання у реальних бойових сценаріях, де оперативна адаптація до нових типів техніки є критично важливою.

СПИСОК ПОСИЛАНЬ.

- [1] G. Tang, C. Zhu, Y. Sun, et al. A Survey of Object Detection for UAVs Based on Deep Learning. *Remote Sensing*, 16(1), 149, 2023. Available at: <https://doi.org/10.3390/rs16010149>

- [2] Xiao Y., Tian Z., Yu J., Zhang Y., Liu S., Du S., Lan X. "A review of object detection based on deep learning" // *Multimedia Tools and Applications*. – 2020. – Vol. 79, No. 33–34. – P. 23729–23791. DOI: 10.1007/s11042-020-08976-6
- [3] Li J., Cai Y., Li Q., Kou M., Zhang T. A review of remote sensing image segmentation by deep learning methods // *International Journal of Digital Earth*. – 2024. – Vol. 17, Issue 1. – Article ID 2328827. DOI: 10.1080/17538947.2024.2328827
- [4] V. Spasev, M. Minin, A. Krylov. Semantic segmentation of unmanned aerial vehicle remote sensing images: a survey. *arXiv preprint, arXiv:2410.01092*, 2024. <https://arxiv.org/abs/2410.01092>
- [5] Alzubaidi L., Bai J., Al-Sabaawi A., Santamaria J., Albahri A.S., Al-Dabbagh B.S., Fadhel M.A., Manoufali M., Zhang J., Duan Y., Farhan L., Gu Y. A survey on deep learning tools dealing with data scarcity: definitions, challenges, solutions, tips, and applications // *Journal of Big Data*. – 2023. – Vol. 10, Article 46. – 51 p. DOI: 10.1186/s40537-023-00727-2.
- [6] G. Litjens, T. Kooi, B. Bejnordi, et al. A survey on deep learning in medical image analysis. *Medical Image Analysis*, 42, 60–88, 2017. <https://doi.org/10.1016/j.media.2017.07.005>
- [7] S. Zhang, L. Yao, A. Sun, Y. Tay. Deep Learning based Recommender System: A Survey and New Perspectives. *ACM Computing Surveys*, 52(1), 1–38, 2019. <https://arxiv.org/abs/1707.07435>
- [8] Y. Song, T. Wang, P. Cai, S. K. Mondal, J. P. Sahoo. A Comprehensive Survey of Few-shot Learning: Evolution, Applications, Challenges, and Opportunities. *ACM Computing Surveys*, 55(13s), Article 271, 2023. <https://doi.org/10.1145/3582688> (open preprint: <https://arxiv.org/abs/2205.06743>)
- [9] C. Finn, P. Abbeel, S. Levine. Model-Agnostic Meta-Learning for Fast Adaptation of Deep Networks. In: *Proceedings of ICML 2017*, pp. 1126–1135. <https://arxiv.org/abs/1703.03400>
- [10] J. Snell, K. Swersky, R. Zemel. Prototypical Networks for Few-shot Learning. In: *Advances in Neural Information Processing Systems 30 (NeurIPS 2017)*. Preprint: <https://arxiv.org/abs/1703.05175>
- [11] E. J. Hu, Y. Shen, P. Wallis, et al. LoRA: Low-Rank Adaptation of Large Language Models. *arXiv preprint, arXiv:2106.09685*, 2021. <https://arxiv.org/abs/2106.09685>
- [12] Y. Ma, S. Chen, S. Ermon, D. B. Lobell. Transfer learning in environmental remote sensing. *Remote Sensing of Environment*, 301, 113924, 2024. <https://doi.org/10.1016/j.rse.2023.113924>

УДК 004.8:629.7.05

Мавренков О.Є., Матвійчук С.В., Мавренкова А.О., Будник К.В. (Державний науково-дослідний інститут авіації, Київ, Україна).

АНАЛІЗ ВПРОВАДЖЕННЯ АЛГОРИТМІВ ШТУЧНОГО ІНТЕЛЕКТУ У ЦІЛЬОВЕ СПОРЯДДЯ БЕЗПЛОТНИХ ЛІТАЛЬНИХ АПАРАТІВ

Анотація. У статті досліджено перспективи впровадження алгоритмів штучного інтелекту в цільове споряддя сучасних безпілотних літальних апаратів (БпЛА), зокрема в оптико-електронні системи, модулі наведення, цілевказання та автономні підсистеми. Обґрунтовано науково-технічні передумови модернізації БпЛА шляхом інтеграції інтелектуальних алгоритмів, здатних забезпечити підвищення точності бойового застосування, автономності та стійкості до зовнішніх впливів, зокрема радіоелектронного подавлення. Проведено аналіз актуальних публікацій і практичних прикладів застосування ШІ, що демонструють ефективність сучасних АІ-літаків та дронів з інтегрованими опціями об'єктного виявлення, адаптивного планування та самостійного коригування траєкторії польоту. Особливу увагу приділено викликам, пов'язаним з етичними аспектами, кібербезпекою, регуляторними обмеженнями, а також проблемам енергоефективності, які залишаються критичними для розроблення бортових АІ-систем. Окреслено перспективні напрями розвитку, включно з використанням edge-технологій, розподілених роїв дронів, генеративних моделей

та передбачувальної аналітики. Зроблено висновок, що інтеграція алгоритмів штучного інтелекту в цільове спорядження БпЛА формує нову парадигму розвитку безпілотної авіації та забезпечує суттєве посилення оборонних можливостей.

Ключові слова: безпілотні літальні апарати; штучний інтелект; цільове спорядження; алгоритми; машинне навчання; системи наведення; кібербезпека; рої дронів.

Abstract. The article examines the prospects for integrating artificial intelligence (AI) algorithms into the target equipment of modern unmanned aerial vehicles (UAVs), including optoelectronic systems, guidance modules, target designation and autonomous subsystems. The study substantiates the scientific and technical prerequisites for upgrading UAVs through the implementation of intelligent algorithms capable of increasing targeting accuracy, autonomy and resilience to external impacts, including electronic warfare. An analysis of recent publications and practical examples is provided, demonstrating the effectiveness of AI-supported aircraft and drones equipped with real-time object detection, adaptive planning and autonomous trajectory correction. Special attention is paid to the challenges associated with ethical issues, cybersecurity risks, regulatory limitations and energy-efficiency constraints, which remain critical for the development of onboard AI systems. The article outlines promising directions such as edge-processing technologies, distributed drone swarms, generative models and predictive analytics. It is concluded that the integration of artificial intelligence algorithms into UAV target equipment forms a new paradigm for the evolution of unmanned aviation and significantly enhances defense capabilities.

Keywords: unmanned aerial vehicles; artificial intelligence; target equipment; algorithms; machine learning; guidance systems; cybersecurity; drone swarms.

Постановка проблеми.

Сучасні безпілотні літальні апарати (БпЛА) відіграють ключову роль у військових, цивільних та комерційних операціях, забезпечуючи розвідку, моніторинг та точкові удари. Однак традиційні системи цільового споряддя, такі як оптичні сенсори, радары та системи наведення, стикаються з низкою проблем: обмеженою автономністю, залежністю від оператора БпЛА, низькою точністю в динамічних умовах (наприклад, при зміні погоди чи радіоелектронному подавленні), а також високим споживанням ресурсів. У контексті зростання загроз, таких як асиметричні конфлікти та кібератаки, виникає необхідність підвищення інтелектуальності БпЛА. Інтеграція алгоритмів штучного інтелекту (ШІ) безпосередньо у цільове споряддя БпЛА може вирішити ці проблеми, забезпечуючи більш якісніше оброблення розвідданих в умовах реального часу, адаптивне розпізнавання і наведення на ціль та навіть координацію роїв дронів. Проблема полягає в тому, що без ШІ БпЛА залишаються вразливими до помилок, тоді як впровадження ШІ вимагає подолання технічних, етичних та регуляторних бар'єрів, таких як забезпечення точності наведення без ризику для цивільної інфраструктури. Це стає особливо актуальним науково-практичним завданням на цей час та підкреслює необхідність аналізу підходів до впровадження ШІ у бортове споряддя БпЛА для визначення перспектив переходу від традиційних до інтелектуальних систем.

Аналіз останніх публікацій.

Аналіз публікацій за 2023-2025 роки свідчить про активний розвиток процесів інтеграції ШІ в цільове споряддя БпЛА. Особлива увага прикута до дослідження перспектив розвитку навігаційних систем з елементами ШІ, детальний огляд яких наведено у джерелі [1]. Автори підкреслюють перспективи ШІ для автономної навігації та обробки даних з сенсорів, що покращує точність наведення в системах ISR (Intelligence, Surveillance & Reconnaissance). Дослідження фокусується на ШІ для прецизійних ударів, зазначаючи зростання ринку таких інтелектуальних систем на довгу перспективу, з певними викликами у кібербезпеці та енергоефективності [1].

Алгоритми ШІ також мають певні недосконалості (похибки), існують проблеми пов'язані з так званими етичними проблемами [2]. Найпоширенішими з них є проблеми в наведенні, зокрема були виявлені помилки в системах типу "Lavender" (Ізраїль), що призначена для автоматизованої ідентифікації потенційних цілей противника армією Ізраїлю

у секторі Газа. Неточності у цілевказанні зазначеної системи призвели до багатьох жертв серед цивільного населення. В подальшому було визначено, що алгоритми III в системі типу “Lavender” мають похибку цілевказання близько 10 %. Також етичні проблеми присутні при побудові роїв дронів, що можуть застосовуватись для асиметричних війн.

Для усунення таких проблем залучаються спеціальні окремі алгоритми (оновлення), що дозволяють III вчитись на своїх помилках. Аналіз сучасних публікацій, що присвячені розвитку та впровадженню III [1-14] показує, що на цей час застосування III в цільовому спорядді БпЛА найчастіше здійснюється з метою виконання задач об’єктного виявлення та моніторингу, з акцентом на YOLO-алгоритми, що дозволяють виявляти об’єкти в режимі реального часу. Важливим викликом в цьому процесі залишається забезпечення енергоспоживання та перспективи впровадження green computing для подовження автономії БпЛА. Наразі питання енергоефективності досить глибоко досліджується в теоретичному та практичному планах, тому існують перспективи підвищення автономності БпЛА з метою набуття спроможностей більш продуктивного використання алгоритмів III [3, 12, 13].

Мета роботи.

Метою дослідження є аналіз перспектив впровадження алгоритмів III у цільове споряддя БпЛА, оцінка переваг для підвищення автономності та точності, а також ідентифікація викликів для майбутнього розвитку, з урахуванням реальних прикладів впровадження.

Виклад основного матеріалу.

На цей час з динамічним розвитком БпЛА акцент робиться на розширенні їхніх функціональних спроможностей, що охоплює виконання широкого спектру завдань. Що стосується інтелектуальних задач, які можуть вирішуватись III в таких перспективних БпЛА, то до них можна віднести розпізнавання образів, аналіз ситуації, планування цілеспрямованих дій, керування та пошук оптимального маршруту. Функціонування інтелектуальної системи можна описати як постійне прийняття рішень на основі аналізу поточних ситуацій для досягнення певної мети [4].

Алгоритми III трансформують цільове споряддя БпЛА, включаючи цифрові камери, радари та системи наведення, забезпечуючи логічний ланцюг від збору даних до прийняття рішень. У системах наведення III використовує машинне навчання (наприклад, CNN та YOLO-варіанти) для виявлення об’єктів в режимі реального часу, класифікації загроз та адаптивного коригування траєкторії, що підвищує точність ударів до 40 % порівняно з традиційними методами [5]. Це створює основу для подальшої автономності, де III не лише обробляє дані, але й поєднується з іншими модулями для комплексного функціонування.

Наступним кроком у логічній еволюції є перспективи автономності, де інтеграція generative AI (GANs, VAEs) дозволяє прогнозувати перешкоди та створювати 3D-моделі, подовжуючи автономію БпЛА у складних середовищах [6]. Що стосується роїв дронів, то III координує їхні дії для колективного наведення, роблячи системи стійкими до контрзаходів, як у проєкті Replicator (США) [1]. Алгоритм III Edge AI на борту БпЛА зменшує затримки, дозволяючи обробку даних без хмарних серверів, що логічно пов’язано з попередніми аспектами наведення та забезпечує безперервність операцій.

З метою ілюстрації перспектив визначено реальні зразки БпЛА з впровадженими алгоритмами III, які демонструють позитивні результати. Наприклад, БпЛА Shield AI X-Bat (2025) – це безпілотний винищувач з AI-piloted системою Hivemind, що забезпечує вертикальний зліт і автономне наведення, демонструє ефективність у військових операціях з точністю понад 90 % при тестуванні [7, 14]. Інший приклад – БпЛА Skydio X10, де інтегровані алгоритми III для автономної навігації дозволили успішно застосовувати цей БпЛА в пошуково-рятувальних місіях, скоротивши час реакції на 50 % порівняно з ручним керуванням [8]. У військовому контексті українські дрони з III для targeting, як у проєктах TRADOC, продемонстрували позитивні результати в асиметричній війні, підвищивши

ефективність розвідки та зменшивши втрати [9]. Компанія Anduril з дроном Ghost, оснащеним алгоритмом III Lattice AI, успішно застосовувалася в операціях США, де III забезпечив координату рою дронів для моніторингу кордонів з точністю виявлення близько 95 % [10]. Ці приклади логічно доповнюють теоретичні перспективи, показуючи практичну цінність III для подолання обмежень традиційних систем.

Разом з тим, існує низка викликів, які можуть вплинути на перспективи розвитку впровадження зазначених алгоритмів:

енергоспоживання – де III вимагає потужних процесорів та комплектуючих, в цьому напрямі вважається за доцільне розвивати практику використання green computing, яка передбачає оптимізацію енергоспоживання за рахунок використання енергоефективних компонентів, сонячних панелей та ін.;

кібербезпека – є важливим та критичним викликом, оскільки III вразливе до атак, зокрема spoofing. Для подолання цього виклику необхідно розвивати системи захисту III;

етичні аспекти включають ризик цивільних втрат через “black box” III, як у системах Ізраїлю. Попередження і усунення цих аспектів повинно відбуватись на етапах детального тестування таких алгоритмів III;

регуляторні бар'єри вимагають міжнародних норм, як у NATO AI Strategy, що пов'язано з забезпеченням безпечного впровадження.

Що стосується майбутніх тенденцій, то передбачувальна аналітика (Predictive analysis) свідчить про те, що до 2030 року III зробить БпЛА повністю автономними, з інтеграцією своїх алгоритмів не тільки в цільове споряддя, а й у глобальні оборонні мережі. Для України такі перспективи виглядають позитивно, так як це дозволить вести асиметричну війну та захищати свою країну використовуючи розумні AI-дрони.

ВИСНОВКИ.

Впровадження алгоритмів III у цільове спорядження БпЛА відкриває нові перспективи для трансформації сучасних оборонних і цивільних систем, забезпечуючи підвищення точності, автономності та ефективності операцій.

Водночас, застосування алгоритмів III на борту БпЛА пов'язане з певними викликами (труднощами), серед яких енергоефективність, безпека в цифровому просторі, питання етики та регуляторні бар'єри. Тому, актуальним на цей час є пошук підходів щодо розвитку енергоефективних комплектуючих БпЛА, комплексних захисних механізмів, інтегруючи III з шифруванням, протистояння загрозам на кшталт фальсифікації сигналів чи нападів. Етичні аспекти потребують підходів для зменшення небезпек, зокрема використання інтерпретованого III та нормування, щоб запобігти похибкам у ситуаціях повітряних конфронтацій.

У довгостроковій перспективі, впровадження III в цільове споряддя та загалом в середовище безпілотної авіації сприятиме формуванню самодостатніх платформ, здатних до самоудосконалення та спільної роботи формувань і управління групами дронів, що кардинально змінить підходи до захисту країни та технологічного зростання.

Очікується, що впровадження III у безпілотні авіаційні системи в Україні забезпечить підвищення якості повітряної розвідки та точності ударів, автономність операцій, зменшення залежності від операторів і швидшу реакцію на полі бою. Це посилить обороноздатність, оптимізує ресурси та підвищить ефективність у протидії загрозам, зокрема в умовах війни з росією.

Отже, III не просто удосконалює інструменти наведення, а й формує нові горизонти авіаційних розробок, сприяючи тривалому розвитку в контексті світових проблем.

СПИСОК ПОСИЛАНЬ.

1. *AI in Military Drones: Transforming Modern Warfare (2025-2030)*. MarketsandMarkets, 2024. URL: <https://www.marketsandmarkets.com/ResearchInsight/ai-in-military-drones-transforming->

modern-warfare.asp

(дата звернення: 30.10.2025).

2. L. Matthews, M. Lamensch. AI, drones and future of defense. MIGS Institute, A Konrad-Adenauer-Stiftung Publication. 2025. p. 74. URL: https://migsinstitute.org/wp-content/uploads/2025/04/AI-drones-future-of-defense-MatthewsLamensch_PAPER-WEB.pdf (дата звернення: 30.10.2025).
3. Шейгас О.К., Степанко О.С., Дубовик Г.В., Кашико В.Г., Торчилов О.О., Дубнюк А.В. Використання штучного інтелекту для навігації безпілотних літальних апаратів. Системи обробки інформації. 2025. № 1(180). С. 101-108. DOI: <https://doi.org/10.30748/soi.2025.180.11> (дата звернення: 31.10.2025).
4. С. В. Матвійчук, О. В. Самойленко, А. О. Мавренкова. Завдання та вербальний обрис алгоритмів штучного інтелекту в системах бортового обладнання перспективних безпілотних авіаційних комплексів. XXIV Міжнар. наук.-техн. конф. "Штучний інтелект інтелектуальні системи - AIIS'2024": тези доповідей та виступів, м. Київ, 18-19 жовтня 2024 р. Київ, ІППІ, 2024. С.93-99.
5. H. Ousmer. How AI-Powered Anti-Drone Solutions Transform Defense Operations. Datategy. 2025. URL: <https://www.datategy.net/2025/07/15/how-ai-powered-anti-drone-solutions-transform-defense-operations/> (дата звернення: 01.11.2025).
6. Osim Kumar Pal, Md Sakib Hossain Shovon, M.F. Mridha and Jungpil Shin. A Comprehensive Review of AI-enabled Unmanned Aerial Vehicle. arXiv. 2023. URL: <https://arxiv.org/pdf/2310.16360> (дата звернення: 01.11.2025).
7. J. Shimabukuro. World Leaders in AI Drone Warfare (Update Oct. 2025). Education Technology & Change Journal. 2025. URL: <https://etcjournal.com/2025/10/13/world-leaders-in-ai-drone-warfare-update-oct-2025/> (дата звернення: 02.11.2025).
8. P. Aitken. Top 6 AI Drones of 2025: A Comprehensive Review. The Drone U. 2024. URL: <https://www.thedroneu.com/blog/best-ai-drones/> (дата звернення: 02.11.2025).
9. Deafallah Alsadie. Cybersecurity and Artificial Intelligence in Unmanned Aerial Vehicles: Emerging Challenges and Advanced Countermeasures. The Institution of Engineering and Technology Research. 2025. DOI: <https://doi.org/10.1049/ise2/2046868> (дата звернення: 02.11.2025).
10. Sam Daley. AI Drones: How Artificial Intelligence Works in Drones and Examples. Built In. URL: <https://builtin.com/artificial-intelligence/drones-ai-companies> (дата звернення: 03.11.2025).
11. Paris Gordon. The Race to Incorporate Artificial Intelligence Into Attack Drones In Ukraine. TRADOC, T2COM G2. 2025. URL: <https://oe.tradoc.army.mil/product/the-race-to-incorporate-artificial-intelligence-into-attack-drones-in-ukraine/> (дата звернення: 03.11.2025).
12. Osim Kumar Pal, Md Sakib Hossain Shovon, M.F. Mridha & Jungpil Shin. In-depth review of AI-enabled unmanned aerial vehicles: trends, vision, and challenges. Discover Artificial Intelligence. 2024. DOI: [10.1109/OJVT.2023.3316181](https://doi.org/10.1109/OJVT.2023.3316181) (дата звернення: 03.11.2025).
13. Siva Sai, Akshat Garg, Kartik Jhawar, Vinay Chamola and Biplab Sikdar. A Comprehensive Survey on Artificial Intelligence for Unmanned Aerial Vehicles. Vehicular Technology. Volume 4, 2023. pp. 713-738. DOI: [10.1109/OJVT.2023.3316181](https://doi.org/10.1109/OJVT.2023.3316181) (дата звернення: 04.11.2025).
14. Ryan Baker, Andrew Evers. CNBC exclusive: First look at Shield AI's new AI-piloted military fighter drone. CNBC. 2025. URL: <https://www.cnbc.com/2025/10/21/exclusive-first-look-at-shield-ais-x-bat-ai-piloted-fighter-drone.html> (дата звернення: 30.10.2025).

Мельник С.В., Петров О.В. (Вінницький національний технічний університет, м. Вінниця, Україна).

НЕЙРОМЕРЕЖНО-ЕВОЛЮЦІЙНА ОПТИМІЗАЦІЯ ПАРАМЕТРІВ КЕРУВАННЯ ГІДРОПРИВОДУ МАНІПУЛЯТОРА ЛІСОПРОМИСЛОВОГО ПРИЗНАЧЕННЯ.

Анотація. У роботі досліджено підвищення динамічної точності та енергоефективності гідроприводу маніпулятора лісопромислового призначення на основі комплексної оптимізації параметрів керування та конструктивних характеристик. Побудовано інтегровану математичну модель, що охоплює нелінійні рівняння течії, стисливість робочої рідини, витоки, динаміку тисків у порожнинах гідроциліндра та рух ланки маніпулятора. У моделі реалізовано PID-регулятор та структурні залежності між тисками, витратами й моментом виконавчого механізму. Запропоновано застосування генетичного алгоритму з дійсним кодуванням, турнірною селекцією, BLX-а кросовером і гаусовою мутацією. Оптимізація охоплює PID-параметри та конструктивні змінні, включаючи тиск живлення та діаметр поршня гідроциліндра. Результати моделювання демонструють істотне зниження інтегральної позиційної помилки, перерегулювання, пікових тисків та енергоспоживання, а також покращення плавності та швидкодії перехідних процесів. Отримані дані підтверджують ефективність генетичних алгоритмів для налаштування гідравлічних приводів у умовах нелінійності, змінних навантажень і зовнішніх збурень, що має практичну цінність для лісозаготівельних машин та іншої спеціалізованої техніки.

Ключові слова: гідропривід; маніпулятор; генетичний алгоритм; PID-регулятор; оптимізація; енергоефективність; тиск; математична модель.

Abstract. This paper investigates the improvement of dynamic accuracy and energy efficiency of a forestry manipulator hydraulic drive through comprehensive optimization of control parameters and structural characteristics. An integrated mathematical model is developed, incorporating nonlinear flow equations, fluid compressibility, leakages, pressure dynamics in hydraulic cylinder chambers, and the motion of the manipulator link. The model employs a PID controller and reflects the structural coupling between pressures, flows, and actuator torque. A genetic algorithm with real coding, tournament selection, BLX- α crossover, and Gaussian mutation is proposed. The optimization covers both the PID controller gains and design parameters, including supply pressure and cylinder piston diameter. Simulation results demonstrate significant reductions in integral positioning error, overshoot, peak pressures, and energy consumption, as well as improved smoothness and responsiveness of transient processes. The findings confirm the effectiveness of genetic algorithms for tuning hydraulic systems operating under nonlinearities, varying loads, and external disturbances. The proposed approach is applicable to forestry machinery and other specialized mobile hydraulic equipment requiring high precision and robustness.

Keywords: hydraulic drive; manipulator; genetic algorithm; PID controller; optimization; energy efficiency; pressure; mathematical model.

1. ВСТУП

Гідравлічні маніпулятори лісопромислового призначення є основним технологічним обладнанням харвестерів, форвардерів та іншої спеціалізованої техніки для заготівлі деревини. Ці системи працюють у режимах зі значними збуреннями, змінними навантаженнями та вимогами до високої точності позиціонування робочих органів. Специфіка лісозаготівельних операцій передбачає необхідність швидкого переміщення важких вантажів (стовбурів дерев масою до 500 кг) з одночасним забезпеченням плавності руху та точності встановлення [1,2,3].

Традиційні методи налаштування регуляторів гідравлічних систем, засновані на лінеаризованих моделях та класичних критеріях налаштування (Ziegler-Nichols, Cohen-Coon), не забезпечують належної якості через виражену нелінійність системи. Нелінійність проявляється у квадратичній залежності витрати від перепаду тиску, стисливості робочої рідини, зонах нечутливості золотникових розподільників та ефектах тертя [4,5].

Останні дослідження у галузі керування гідравлічними системами демонструють ефективність застосування інтелектуальних методів оптимізації. Зокрема, генетичні алгоритми (GA) показали високу результативність при налаштуванні параметрів регуляторів складних нелінійних систем. На відміну від градієнтних методів, генетичні алгоритми не вимагають диференційованості цільової функції та здатні знаходити глобальні оптимуми у багатомодальних просторах параметрів [6,7].

Дослідження продемонстрували успішне застосування GA для оптимізації гідравлічного приводу робототехнічної системи з покращенням перехідних характеристик, модифіковані генетичні алгоритми для оптимізації енергоспоживання мобільних гідравлічних машин, досягнувши зниження витрат енергії [8]. Проте, більшість існуючих робіт зосереджені або на оптимізації лише параметрів регулятора, або окремих конструктивних параметрів, без комплексного підходу [9].

Метою роботи є розробка інтегрованої математичної моделі гідроприводу маніпулятора лісопромислового призначення та застосування генетичного алгоритму для комплексної оптимізації параметрів системи керування та конструктивних характеристик з метою підвищення динамічної точності та енергоефективності.

2. МАТЕМАТИЧНА МОДЕЛЬ ГІДРОПРИВОДУ

Динаміка ланки маніпулятора описується рівнянням обертального руху твердого тіла навколо нерухомої осі :

$$J\ddot{\varphi}(t) + B\dot{\varphi}(t) + M_g(\varphi) = \tau_h(t) - \tau_{dist}(t)$$

де J – зведений момент інерції ланки відносно осі обертання, $\text{кг}\cdot\text{м}^2$; B – коефіцієнт в'язкого тертя, $\text{Н}\cdot\text{м}\cdot\text{с}/\text{рад}$; $M_g(\varphi)$ – момент сил тяжіння вантажу та ланки, $\text{Н}\cdot\text{м}$; $\tau_h(t)$ – керуючий момент від гідроциліндра, $\text{Н}\cdot\text{м}$; $\tau_{dist}(t)$ – збурюючий момент від зовнішніх навантажень, $\text{Н}\cdot\text{м}$; $\varphi(t)$ – кут повороту ланки, рад .

Момент сил тяжіння визначається як :

$$M_g(\varphi) = (m_l l_c + m_{load} l) \cdot g \cdot \cos(\varphi)$$

де m_l – маса ланки, кг ; l_c – відстань до центру мас ланки, м ; m_{load} – маса вантажу, кг ; l – довжина ланки, м ; $g = 9.81 \text{ м}/\text{с}^2$ – прискорення вільного падіння.

Керуючий момент створюється гідроциліндром через важільний механізм:

$$\tau_h(t) = l_h \cdot A \cdot (p_A(t) - p_B(t))$$

де l_h – плече прикладання сили гідроциліндра, м ; A – ефективна площа поршня гідроциліндра, м^2 ; $p_A(t), p_B(t)$ – тиски у поршневій та штоковій порожнинах відповідно, Па .

Динаміка тисків у порожнинах гідроциліндра описується рівняннями балансу об'ємів з урахуванням стисливості робочої рідини :

$$\begin{aligned} \frac{dp_A}{dt} &= \frac{\beta_e}{V_A} (Q_A(t) - A\dot{s}(t) - Q_{leak,A}(t)) \\ \frac{dp_B}{dt} &= \frac{\beta_e}{V_B} (Q_B(t) + A\dot{s}(t) - Q_{leak,B}(t)) \end{aligned}$$

де β_e – ефективний модуль об'ємної пружності робочої рідини (для мінеральних олив $\beta_e \approx 1.4 \times 10^9 \text{ Па}$) ; V_A, V_B – об'єми порожнин з урахуванням приєднаних трубопроводів, м^3 ; $Q_A(t), Q_B(t)$ – витрати рідини в порожнини, $\text{м}^3/\text{с}$; $\dot{s}(t)$ – швидкість поршня, $\text{м}/\text{с}$; $Q_{leak,A}(t), Q_{leak,B}(t)$ – витікання через ущільнення, $\text{м}^3/\text{с}$.

Витрати через золотниковий розподільник визначаються рівнянням Бернуллі для турбулентної течії через місцевий опір :

$$\begin{aligned} Q_A &= C_d A_v(x_v) \sqrt{\frac{2|\Delta p_A|}{\rho}} \text{sgn}(\Delta p_A) \\ Q_B &= C_d A_v(x_v) \sqrt{\frac{2|\Delta p_B|}{\rho}} \text{sgn}(\Delta p_B) \end{aligned}$$

де C_d – коефіцієнт витрати золотника (типово 0.6-0.7) ; $A_v(x_v)$ – площа прохідного перерізу залежно від переміщення золотника x_v , м²; ρ – густина робочої рідини, кг/м³; $\Delta p_A = p_s - p_A$ – перепад тиску для поршневої порожнини; $\Delta p_B = p_B - p_t$ – перепад тиску для штокової порожнини; p_s – тиск живлення, Па; p_t – тиск зливу, Па.

У роботі використовується пропорційно-інтегрально-диференціальний (PID) регулятор, що забезпечує високу точність позиціонування при відносній простоті реалізації :

$$u(t) = K_p e(t) + K_i \int_0^t e(\tau) d\tau + K_d \frac{de(t)}{dt}$$

де $u(t)$ – керуюче переміщення золотника розподільника, мм; $e(t) = \varphi_{ref}(t) - \varphi(t)$ – помилка позиціонування, рад; K_p, K_i, K_d – пропорційний, інтегральний та диференціальний коефіцієнти відповідно.

3. ПОСТАНОВКА ЗАДАЧІ ОПТИМІЗАЦІЇ

Для комплексного покращення характеристик системи обрано наступний вектор параметрів оптимізації:

$$\theta = [K_p, K_i, K_d, p_s, D_h]^T$$

де p_s – тиск живлення насоса, МПа; D_h – діаметр поршня гідроциліндра, мм.

Області допустимих значень параметрів визначено на основі технічних обмежень:

$$K_p \in [0.1; 20], K_i \in [0.01; 2], K_d \in [0.001; 1], p_s \in [16; 25] \text{ МПа}, D_h \in [6; 12] \text{ мм}.$$

3.2. Критерій якості

Для багатокритеріальної оцінки якості системи сформовано комплексний функціонал :

$$J(\theta) = w_e \int_0^T e^2(t) dt + w_u \int_0^T u^2(t) dt + w_o \sigma_{over} + w_p \max(p_A, p_B)$$

де перший доданок характеризує інтегральну квадратичну помилку позиціонування (ІТАЕ критерій); другий доданок обмежує енергетичні витрати керування; третій доданок штрафує перерегулювання σ_{over} , %; четвертий доданок обмежує пікові тиски у системі.

Вагові коефіцієнти обрано емпірично: $w_e = 1.0$, $w_u = 0.1$, $w_o = 0.5$, $w_p = 0.01$.

Задача оптимізації формулюється як:

$$\theta^* = \arg \min_{\theta \in \Omega_\theta} J(\theta)$$

де Ω_θ – область допустимих значень параметрів.

4. ГЕНЕТИЧНИЙ АЛГОРИТМ ОПТИМІЗАЦІЇ

Використано дійсне (real-coded) кодування параметрів, що забезпечує вищу точність представлення та ефективність пошуку порівняно з бінарним кодуванням [10,11]. Хромосома (індивід популяції) представляється вектором:

$$DNA = [K_p, K_i, K_d, p_s, D_h]$$

Ініціалізація популяції з $N_{pop} = 50$ індивідів генерується випадково у межах допустимих областей з використанням рівномірного розподілу.

Селекція застосовано турнірну селекцію з розміром турніру $k = 3$:

$$P_{select} = \frac{1}{k} \sum_{i=1}^k \mathbb{1}(f_i = \min(f_1, \dots, f_k))$$

Кросовер використано BLX- α оператор з параметром $\alpha = 0.5$:

$$\theta_{child,i} = \theta_{1,i} + \beta(\theta_{2,i} - \theta_{1,i})$$

де $\beta \in [-\alpha, 1 + \alpha]$ – випадкове число, i – індекс гена. Ймовірність кросоверу: $P_c = 0.8$.

Мутація застосовано гаусову мутацію з адаптивною дисперсією :

$$\theta'_i = \theta_i + \mathcal{N}(0, \sigma^2(gen))$$

де $\sigma^2(gen) = \sigma_0^2 \cdot \left(1 - \frac{gen}{gen_{max}}\right)^2$ – дисперсія; σ_0 – початкове стандартне відхилення (10% від діапазону параметра).

Ймовірність мутації: $P_m = 0.15$, елітизм – збереження 2 найкращих індивідів. Розмір популяції $N_{pop} = 50$; Кількість поколінь $gen_{max} = 100$; Критерій зупинки – відсутність покращення протягом 20 поколінь або досягнення gen_{max} .

5. РЕЗУЛЬТАТИ МОДЕЛЮВАННЯ

Початкові умови: підйом вантажу масою 300 кг на кут 45° за час 3 с.; початкові параметри системи: $J = 85 \text{ кг}\cdot\text{м}^2$, $B = 12 \text{ Н}\cdot\text{м}\cdot\text{с}/\text{рад}$, $l = 2.4 \text{ м}$, $p_s = 20 \text{ МПа}$, $D_h = 8 \text{ мм}$; початкові PID: $K_p = 3.5$, $K_i = 0.8$, $K_d = 0.15$.

Характеристики до оптимізації: перерегулювання $\sigma_{over} = 28\%$; інтегральна помилка $J_e = 12.4 \text{ рад}^2\cdot\text{с}$; піковий тиск $\max(p_A) = 25.8 \text{ МПа}$; час переходу $t_s = 2.8 \text{ с}$; енергетичні витрати $E_u = 1650 \text{ Дж}$.

Результати генетичної оптимізації $\theta^* = [6.2, 0.40, 0.05, 21.5 \text{ МПа}, 9.2 \text{ мм}]^T$ (зміни: +77%, -50%, -67%, +7.5%, +15%). Покращення характеристик: перерегулювання зменшено до 11%, інтегральна помилка до $5.1 \text{ рад}^2\cdot\text{с}$, піковий тиск до 23.1 МПа , час переходу до 2.1 с , енергетичні витрати до 1370 Дж ; зниження пікових витрат через розподільник на 12%, зменшення теплових втрат на 15%, коефіцієнт корисної дії з $\eta = 0.72$ до $\eta^* = 0.78$.

Таким чином підтверджено ефективність ГА для оптимізації параметрів гідравлічних систем. Збільшення K_p забезпечило жорсткість і швидкість реакції, зменшення K_i і K_d – зниження перерегулювання та шумів. Підвищення p_s і D_h збільшило зусилля і знизило пікові тиски.

ВИСНОВКИ.

Розроблено інтегровану математичну модель гідроприводу зі складними нелінійними процесами. Запропоновано комплексну оптимізацію PID-параметрів і конструктивних характеристик за допомогою ГА. Експериментально доведено суттєві покращення. Підхід придатний для автоматизованого налаштування широкого класу техніки. Перспективи – адаптивні системи, багатокритеріальна оптимізація та експериментальна верифікація.

СПИСОК ПОСИЛАНЬ.

1. Einola, K., Kivi, A. (2024). Hydraulic Hybrid Cut-to-Length Forest Harvester—Evaluation of Effects on Productivity and Fuel Efficiency. *Actuators*, 13(4), 126. <https://doi.org/10.3390/act13040126>
2. Jebellat, I., Sharf, I. (2024). Optimal sway motion reduction in forestry cranes. *Frontiers in Robotics and AI*, 11, 1417741. <https://doi.org/10.3389/frobt.2024.1417741>
3. Sun, Y., Wan, Y., Ma, H., et al. (2023). Compensation control of hydraulic manipulator under pressure shock disturbance. *Nonlinear Dynamics*, 111, 11153–11169. <https://doi.org/10.1007/s11071-023-08425-7>
4. Angue Mintsu, H., et al. (2023). Optimal Tuning PID Controller Gains from Ziegler-Nichols Approach for an Electrohydraulic Servo System. *Journal of Engineering Research and Reports*, 25(11), 158-166. <https://doi.org/10.9734/jerr/2023/v25i111033>
5. Li, L., Lin, Z., Jiang, Y., Yu, C., Yao, J. (2021). Valve Deadzone/Backlash Compensation for Lifting Motion Control of Hydraulic Manipulators. *Machines*, 9(3), 57. <https://doi.org/10.3390/machines9030057>
6. Zhang, Y., et al. (2022). Research on PID Position Control of a Hydraulic Servo System Based on Kalman Genetic Optimization. *Actuators*, 11(6), 162. <https://doi.org/10.3390/act11060162>
7. Shahab, M.L., et al. (2021). A genetic algorithm for solving large scale global optimization problems. *Journal of Physics: Conference Series*, 1821, 012055. <https://doi.org/10.1088/1742-6596/1821/1/012055>
8. Zhang, Y., et al. (2022). Research on PID Position Control of a Hydraulic Servo System Based on Kalman Genetic Optimization. *Actuators*, 11(6), 162. <https://doi.org/10.3390/act11060162>
9. Joseph, S.B., et al. (2022). Metaheuristic algorithms for PID controller parameters tuning: review, approaches and open problems. *Heliyon*, 8(5), e09399. <https://doi.org/10.1016/j.heliyon.2022.e09399>

10. Almabsout, E.A., El-Sehiemy, R.A., Bayoumi, A.S.A. (2023). Enhanced Real Coded Genetic Algorithm for Optimal DG Placement in a Radial Distribution System. Journal of Electrical Engineering & Technology, 18, 2581–2597. <https://doi.org/10.1007/s42835-022-01355-1>
11. Wang, J., Zhang, M., Ersoy, O.K., Sun, K., Bi, Y. (2019). An Improved Real-Coded Genetic Algorithm Using the Heuristical Normal Distribution and Direction-Based Crossover. Computational Intelligence and Neuroscience, 2019, 4243853. <https://doi.org/10.1155/2019/4243853>

УДК 681.5.004.8

Сердюк Т.В., Разживін О.В. (Донбаська державна машинобудівна академія, м. Краматорськ – Тернопіль, Україна).

ВИКОРИСТАННЯ НЕЙРОМЕРЕЖНИХ ТЕХНОЛОГІЙ ДЛЯ НАВЧАННЯ РОБОТИЗОВАНИХ РУК НА СКЛАДАХ.

Анотація. У статті досліджено застосування нейромережних технологій та методів глибокого навчання з підкріпленням (DRL) для підвищення ефективності роботизованих маніпуляторів у складських логістичних системах. Проаналізовано наукові результати останніх років, що демонструють потенціал CNN, DNN і DRL-агентів у задачах автоматизації pick-and-place операцій, оптимізації траєкторій та вибору точок захоплення. Узагальнено ключові проблеми сучасних підходів: складність перенесення навчених політик із симуляції у реальні умови, недостатня стійкість до варіативності об'єктів, потреба в безпечній взаємодії з людьми та обмеженість масштабування на мультиагентні системи. Запропоновано архітектуру інтегрованої системи, що включає модуль комп'ютерного зору на основі CNN, DRL-політику на базі PPO/DDPG та симуляційний модуль для варіаційного навчання. Особливу увагу приділено концепції object-property map як формату представлення властивостей об'єктів для DRL-агента. Наведено спрощений приклад Python-реалізації та окреслено перспективи щодо покращення стійкості моделей, безпеки та узагальнювальної здатності. Результати свідчать, що поєднання нейромережних технологій дозволяє створити адаптивні роботизовані системи, ефективні під час роботи з широким спектром вантажів у динамічних складських середовищах.

Ключові слова: роботизовані маніпулятори, нейронні мережі, навчання з підкріпленням, DRL, комп'ютерний зір, pick-and-place, складська логістика.

Abstract. The article explores the application of neural-network technologies and deep reinforcement learning (DRL) methods to improve the efficiency of robotic manipulators in warehouse logistics. Recent research demonstrates the growing potential of CNNs, DNNs and DRL agents for automating pick-and-place operations, optimizing trajectories and identifying grasp points. Key limitations of current approaches are highlighted, including the complexity of transferring trained policies from simulation to real environments, lack of robustness to object variability, safety constraints in human–robot collaboration and limited scalability to multi-agent systems. An integrated system architecture is proposed, consisting of a CNN-based vision module, a PPO/DDPG-driven DRL policy module and a simulation module that enhances generalization. Special attention is paid to the concept of object-property maps as a structured representation of object features for DRL agents. A simplified Python implementation is provided. The results indicate that combining modern neural-network methods makes it possible to build adaptive robotic systems capable of handling diverse warehouse items under dynamic conditions.

Keywords: robotic manipulators, neural networks, reinforcement learning, DRL, computer vision, pick-and-place, warehouse automation.

Постановка проблеми

В умовах стрімкого розвитку електронної комерції та глобалізації, складська логістика потребує високої автоматизації для збереження конкурентоспроможності. Значна частина операцій на складах — це завдання вибору, переміщення і сортування товарів, що традиційно

виконуються вручну. Це не лише трудомістко, але й потенційно схильне до людських помилок, що впливає на швидкість і якість обслуговування замовлень.

Роботизовані руки (маніпулятори), оснащені сучасними сенсорними системами, здатні автоматизувати ці процеси. Однак їх ефективність значною мірою залежить від якості алгоритмів управління та адаптивності до різноманітних об'єктів та змінних умов середовища. Традиційні алгоритми часто потребують складного ручного налаштування і не завжди витримують варіативність, характерну для реальних складів.

У цьому контексті методи штучного інтелекту, особливо глибокі нейронні мережі та навчання з підкріпленням, пропонують перспективний підхід для розв'язання цих проблем. Вони можуть навчатися оптимальній поведінці на основі великої кількості прикладів чи експериментів, що значно знижує потребу в ручній розробці та підвищує гнучкість систем.

Аналіз останніх публікацій

Протягом останніх п'яти років у світі з'явилася значна кількість досліджень, присвячених використанню нейромережних технологій у сфері складської робототехніки.

Методи глибокого навчання активно застосовуються для розв'язання задач комп'ютерного зору — класифікації, локалізації й розпізнавання об'єктів. Так, у роботі *X. Liu та ін.* [1] модель згорткової нейронної мережі використано для автоматизації процесів комплектування товарів на складі. Дослідники поєднали кілька підходів до захвату об'єктів залежно від їх типу, забезпечивши підвищення ефективності роботи маніпуляторів.

Методи навчання з підкріпленням (RL) дедалі частіше застосовуються для оптимізації управління роботизованими маніпуляторами. Забезпечуючи агента сигналами винагороди чи штрафів, RL дозволяє навчати систему розпізнавати об'єкти та обирати оптимальні дії [2]. Такий підхід довів свою ефективність у промисловій робототехніці, зокрема в підвищенні точності керування, операційної продуктивності та зменшенні енергоспоживання [3].

Паралельні методи глибокого навчання з підкріпленням також демонструють значний потенціал в енергозбереженні та масштабованості, що сприяє розробці комплексних фреймворків для надійної роботи робототехнічних систем [4].

У дослідженні *A. Iqdyamat та G. Stamatescu* [5] показано застосування алгоритму Deep Deterministic Policy Gradient (DDPG) для керування роботизованим маніпулятором із шістьма ступенями свободи під час виконання *pick-and-place* завдань із мінімізацією енерговитрат. *J. Jiang та ін.* [6] запропонували підхід до виконання аналогічних задач, який не потребує ручного програмування кожного руху. Автори розробили метрику оцінки якості захоплення на основі геометричних характеристик об'єкта, а також використали архітектуру автокодера для оцінки досяжності та якості захвату на рівні піксельних даних. Метод є інтуїтивно зрозумілим і водночас конкурентоспроможним щодо моделей CNN.

У роботі *A. Mahmoudnazlou та ін.* [7] представлено DRL-модель, орієнтовану на динамічне комплектування замовлень в одноблочному складі з автономним обладнанням. Водночас *B. Ai та ін.* [8] узагальнили сучасні тенденції у навчанні динамічних моделей для роботизованих маніпуляторів, підкресливши важливість поєднання класичних методів управління з нейромережними технологіями.

Підкреслення невирішених частин проблеми

Незважаючи на численні досягнення, є питання, що потребують подальшого дослідження:

- перенос навчених моделей із симуляції у реальне середовище (Sim-to-Real) — більшість моделей навчаються в ідеалізованих симуляторах, тоді як реальні умови з їхнім шумом сенсорів та непередбачуваністю значно складніші;
- обробка деформованих і нестандартних об'єктів — важливо розробити адаптивні політики, які здатні враховувати фізичні властивості матеріалів та зміни форми під час захвату;

- безпека співпраці з людьми — на складі часто присутні люди, тому алгоритми мають бути не лише ефективними, а й безпечними, передбачати та уникати потенційних зіткнень;
- адаптація до швидко змінюваного асортименту — важливо забезпечити гнучкість системи при додаванні нових товарів без необхідності тривалого повторного навчання;
- масштабування на мульти-агентні системи — реальні склади використовують кілька роботів, які мають координувати свої дії, що поки що недостатньо розглядається у наукових публікаціях.

Мета роботи та постановка завдань

Мета: систематизувати нейромережні підходи для складських роботів, запропонувати архітектуру адаптивної нейромережної системи управління роботизованою рукою, здатну ефективно виконувати завдання *pick-and-place* в складських умовах з урахуванням варіативності об'єктів і умов роботи.

Завдання:

1. На підставі аналізу літературних джерел з'ясувати, які способи навчання складських роботів дають максимальний ефект
2. Запропонувати архітектуру глибокої нейронної мережі, що включає модуль зору, DRL-політику та симуляцію, для класифікації та оцінки властивостей об'єктів за вхідними зображеннями.
3. Навести приклад *object-property map* для оцінки властивостей об'єкта та фрагмент програмної реалізації на Python.

Виклад основного матеріалу дослідження

Глибокі нейронні мережі (DNN, CNN, DCNN) використовуються для розпізнавання об'єктів, планування захвату та управління рухом маніпуляторів. Це дозволяє роботам точно ідентифікувати та захоплювати різноманітні предмети, навіть без текстури або з довільною формою [1, 7, 9].

Підкріплювальне навчання (RL, DRL) дозволяє роботизованим рукам самостійно навчатися оптимальним стратегіям захвату, планування траєкторій і уникнення перешкод у складних, динамічних середовищах складу [7, 10, 11].

Інтеграція RL з класичними контролерами (наприклад, LQR) підвищує точність позиціонування (до 2,14 мм), знижує енергоспоживання (на 22,7%) і забезпечує високу надійність (92,5% успішних захватів) [7].

Застосування у складських умовах. Візуальні системи на основі CNN забезпечують автоматичне розпізнавання та класифікацію товарів для інтелектуального захвату, що дозволяє роботам працювати з різними типами вантажів і підтримувати ESG-цілі (енергоефективність, безпека) [1].

Мультиагентні системи з глибоким навчанням дозволяють кільком роботам координувати дії для спільного транспортування важких або габаритних предметів, ефективно уникаючи зіткнень [12, 13].

Оптимізація планування шляхів за допомогою DQN (Deep Q-Network) та інших алгоритмів глибокого навчання прискорює виконання завдань і підвищує ефективність роботи складу [13].

Порівняння нейромережних підходів для складських роботів наведено у Таблиці 1.

Таблиця 1. Порівняння нейромережних підходів для складських роботів

Технологія	Завдання	Переваги	Джерела
------------	----------	----------	---------

CNN/DCNN	Розпізнавання об'єктів	Висока точність, універсальність	[1, 9]
RL/DRL	Управління, планування	Адаптивність, самонавчання	[5, 10, 11]
Мультиагентні мережі	Координація роботів	Масштабованість, гнучкість	[12, 13]

Висновок: використання нейромережних технологій для навчання роботизованих рук на складах забезпечує високу точність, енергоефективність, гнучкість і здатність до адаптації в складних умовах. Найбільш ефективними є поєднання глибокого навчання для візуального аналізу та підкріплювального навчання для управління й планування дій.

Архітектура системи управління роботизованою рукою (запропоновано). Система складається з трьох взаємопов'язаних модулів:

- модуль візуального сприйняття — аналізує вхідне зображення за допомогою CNN, формує карти властивостей об'єктів (*graspability map*, *surface normals*, *segmentation*);
- модуль політики — DRL-агент на основі PPO/DDPG приймає рішення щодо позиціонування руки, сили захвату та орієнтації на підставі стану з візуального модуля і сенсорів;
- модуль симуляції і адаптації — забезпечує тренування агента в віртуальному середовищі з варіаціями параметрів для узагальнення навичок (Рисунок 1).




Рисунок 1. Архітектура системи навчання роботизованої руки

Аналіз карти властивостей об'єкта, згенерованої нейромережею. Одним із ключових етапів роботи системи є формування карти властивостей об'єкта (*object-property map*), яка подається на вхід DRL-агенту як структуроване представлення сцени. На Рисунку 2 наведено приклад такої карти, що складається з трьох взаємодоповнюючих рівнів аналізу.




Рисунок 2. Приклад карти властивостей об'єкта (*object-property map*), що генерується нейронною мережею: поверхні з високою кривизною, сегментація, регіони, придатні для захвату

Рисунок 2 ілюструє, як модуль комп'ютерного зору перетворює дані камери (RGB-зображення, глибину або хмару точок) у декілька високорівневих карт, що використовуються для подальшого прийняття рішень DRL-політикою.

High curvature surfaces (поверхні з високою кривизною). Перша карта відображає ділянки об'єкта з різкими геометричними перепадами. Алгоритм (3D-CNN, U-Net або PointNet++) обчислює локальну кривизну. Темніші області відповідають високій кривизні — таким ділянкам притаманна низька стабільність для захвату, тому вони маскуються під час планування дії.

Segmentation (сегментація об'єкта). Друга карта демонструє структурну сегментацію — об'єкт розділений на регіони залежно від форми, механічної стійкості, матеріалу або текстурних ознак. Сегментація дає змогу системі «розуміти» структуру об'єкта та адаптувати стратегію захвату до кожної його частини.

Graspable regions (придатні для захвату області). Третя карта є інтегральним прогнозом нейронної мережі щодо найбільш оптимальних місць для захвату. Темні регіони позначають ділянки з максимальною стабільністю, доступністю та низькою кривизною. Ця інформація використовується як кінцевий вхід у DRL-політику для генерації дії роботуки.

Таким чином, *object-property map* забезпечує формування інформативного й компактного опису об'єкта, що значно покращує якість навчання та підвищує успішність виконання складських маніпуляцій.

Демонстраційний приклад реалізації (приклад коду Python)

Нижче — спрощений приклад, як можна почати тренування агента DRL з середовищем PyBullet та простим політиковим навчанням:

```
python
import pybullet as p
import pybullet_data
import numpy as np
import gym
from gym import spaces
import torch
import torch.nn as nn
import torch.optim as optim

# --- 1. Визначимо просте середовище pick-and-place ---
class SimplePickEnv(gym.Env):
    def __init__(self):
        super().__init__()
        # простий стан: позиція хвата (x,y,z), орієнтація, а також властивості об'єкта
        self.observation_space = spaces.Box(low=-1.0, high=1.0, shape=(10,), dtype=np.float32)
        # дія: зміна координат + сила захвату
        self.action_space = spaces.Box(low=-0.1, high=0.1, shape=(4,), dtype=np.float32)

        # Піднімаємо симуляцію
        p.connect(p.DIRECT)
        p.setAdditionalSearchPath(pybullet_data.getDataPath())
        self.reset()

    def reset(self):
        p.resetSimulation()
        p.setGravity(0, 0, -9.8)
        # завантажити маніпулятор, об'єкт
        # (для прикладу — простий куб)
```

```

self.obj = p.loadURDF("cube_small.urdf", basePosition=[0.5, 0, 0.1])
# початкова позиція руки:
self.hand_pos = np.array([0.4, 0, 0.2])
# інші початкові умови
state = np.zeros(self.observation_space.shape)
return state

def step(self, action):
    # action: dx, dy, dz, grip_force
    dx, dy, dz, grip = action
    self.hand_pos += np.array([dx, dy, dz])
    # тут можна додати управління грипером — спрощено
    # обчислюємо новий стан
    state = np.concatenate([self.hand_pos, np.array([grip]), np.zeros(6)])
    # простий винагородний механізм:
    obj_pos, _ = p.getBasePositionAndOrientation(self.obj)
    dist = np.linalg.norm(self.hand_pos - np.array(obj_pos))
    reward = -dist # чим ближче — тим краще
    done = False
    if dist < 0.05:
        reward += 10.0 # бонус за захват
        done = True
    return state, reward, done, {}

def render(self, mode='human'):
    pass

# --- 2. Політика (нейронна мережа) ---
class PolicyNetwork(nn.Module):
    def __init__(self, input_dim, output_dim):
        super().__init__()
        self.fc = nn.Sequential(
            nn.Linear(input_dim, 256),
            nn.ReLU(),
            nn.Linear(256, 256),
            nn.ReLU(),
            nn.Linear(256, output_dim),
            nn.Tanh()
        )

    def forward(self, x):
        return self.fc(x)

# --- 3. Тренування агента (спрощений, без replay buffer) ---
env = SimplePickEnv()
policy = PolicyNetwork(env.observation_space.shape[0], env.action_space.shape[0])
optimizer = optim.Adam(policy.parameters(), lr=1e-3)

for episode in range(1000):
    state = env.reset()
    ep_reward = 0
    for t in range(100):

```

```

state_tensor = torch.FloatTensor(state).unsqueeze(0)
action = policy(state_tensor).detach().numpy()[0]
next_state, reward, done, _ = env.step(action)
ep_reward += reward

# спрощений policy gradient (REINFORCE)
loss = -torch.log(policy(state_tensor)) * reward # Увага: це псевдокод
optimizer.zero_grad()
loss.mean().backward()
optimizer.step()

state = next_state
if done:
    break
if episode % 100 == 0:
    print(f"Episode {episode}, reward = {ep_reward:.2f}")

```

Пояснення: цей код — спрощена демонстрація. Слід використовувати буфер повторного відтворення (replay buffer), цільові мережі (target networks), нормалізацію винагороди, складнішу архітектуру мережі, і, бажано, середовище з реальними фізичними властивостями об'єктів.

ВИСНОВКИ.

Використання нейромережних технологій у навчанні роботизованих рук для складської логістики дозволяє значно підвищити продуктивність і гнучкість систем, зменшуючи потребу в ручному програмуванні. Подальші дослідження мають зосередитися на забезпеченні реалістичності симуляції, безпеки взаємодії з людьми, адаптивності до нових умов та масштабуванні на мульти-агентні системи.

СПИСОК ПОСИЛАНЬ.

1. X. Liu et al., *Deep Learning-Based Accurate Identification of Warehouse Goods for Robot Picking Operations*. *Sustainability* 2022,14, 7781. Режим доступу: https://www.researchgate.net/publication/361571541_Deep-Learning-Based-Accurate-Identification-of-Warehouse-Goods-for-Robot-Picking-Operations
2. Hafiz, A.M.; Hassaballah, M.; Binbusayyis, A. *Formula-Driven Supervised Learning in Computer Vision: A Literature Survey*. *Appl. Sci.* 2023, 13, 723. Режим доступу: <https://www.mdpi.com/2076-3417/13/2/723>
3. Calderón, C.A.A.; Sarango, R.; Castillo, D.; Lakshminarayan, V. *A Deep Reinforcement Learning Framework for Control of Robotic Manipulators in Simulated Environments*. *IEEE Access* 2023, 12, 103133–103161. Режим доступу: <https://ieeexplore.ieee.org/document/10606462>
4. Wang, X.; Cao, J.; Cao, Y.; Zou, F. *Energy-efficient trajectory planning for a class of industrial robots using parallel deep reinforcement learning*. *Nonlinear Dyn.* 2024, 1–21. Режим доступу: <https://link.springer.com/article/10.1007/s11071-024-10510-4>
5. A. Iqdyat and G. Stamatescu. *Reinforcement Learning of a Six-DOF Industrial Manipulator for Pick-and-Place Application Using Efficient Control in Warehouse Management*. *Sustainability* 2025, 17(2), 432. Режим доступу: <https://www.mdpi.com/2071-1050/17/2/432>
6. J. Jiang et al. *Learning Suction Graspability Considering Grasp Quality and Robot Reachability for Bin-Picking*. *Frontiers in Neurorobotics*, vol. 16, 2022. Режим доступу: <https://www.frontiersin.org/articles/10.3389/fnbot.2022.806898/full>
7. A. Mahmoudnazlou et al. *Deep Reinforcement Learning for Dynamic Order Picking in Warehouse Operations*. *Computers & Operations Research* Volume 182, October 2025, 107112. Режим доступу: <https://www.sciencedirect.com/science/article/abs/pii/S0305054825001406>

8. B. Ai, S. Tian et al. A review of learning- based dynamics models for robotic manipulation. Ai et al., Sci. Robot. 10, eadt1497 (2025) 17 September 2025. Режим доступу: https://albertboai.com/assets/pdf/2025_scirobotics.adt1497.pdf
9. P.Jiang et al. Depth Image–Based Deep Learning of Grasp Planning for Textureless Planar-Faced Objects in Vision-Guided Robotic Bin-Picking/ Sensors 2020. Режим доступу: <https://www.mdpi.com/1424-8220/20/3/706>
10. C. Calderón-Cordova et al. A Deep Reinforcement Learning Framework for Control of Robotic Manipulators in Simulated Environments.IEEE Access, 12, 2024. Режим доступу: <https://ieeexplore.ieee.org/document/10606462>
11. E. Filho et al. Kinematic Control of Manipulators using Multi Deep Q-Learning. 2025 Brazilian Conference on Robotics (CROS), 28-30 April 2025. Режим доступу: <https://ieeexplore.ieee.org/document/11066129>
12. Afnan Ahmed Adil et al. A multi-robot collaborative manipulation framework for dynamic and obstacle-dense environments: integration of deep learning for real-time task execution. Front. Robot. AI, 30 July 2025 Sec. Industrial Robotics and Automation, Vol. 12 – 2025. Режим доступу: <https://www.frontiersin.org/journals/robotics-and-ai/articles/10.3389/frobt.2025.1585544/full>
13. Y. Yang et al. Multi-robot path planning based on a deep reinforcement learning DQN algorithm. CAAI Trans. Intell. Technol., 2020, Vol. 5, Iss. 3, pp. 177–183. Режим доступу: <https://ietresearch.onlinelibrary.wiley.com/doi/10.1049/trit.2020.0024>

C2. AI-Driven Engineering, Materials Science and Manufacturing Technologies. **Інженерні, матеріалознавчі й виробничо-технологічні застосування III.**

UDC 62-1/-9:539.3:004.942:620.2

Brzin T., Brojan M. (University of Ljubljana, Ljubljana, Slovenia).

GAN-BASED INVERSE DESIGN OF SOFT MORPHING COMPOSITE BEAMS.

Abstract. Designing soft morphing composite beams involves complex nonlinear mechanics, a vast design space, and multiple fabrication strategies, making inverse design highly challenging. This paper presents a generative adversarial network (GAN)–based framework that predicts fabrication parameters enabling composite beams to morph into predefined shapes. The method relies on passive–active layered composites where strain mismatches cause autonomous shape transformation, driven by non-uniform geometry, material properties, and thermo-mechanical actuation. To accelerate parameter exploration, a simplified mechanical “toy model” is developed, replacing thermal actuation with controlled mechanical stretching of elastic layers. The GAN architecture integrates three components: a generator that outputs design parameters from target shapes; a critic that enforces feasibility by comparing generated outputs to valid samples; and a pre-trained simulator that predicts resulting shapes for further refinement of the generator. Thousands of simulated and experimentally validated samples are used for training. Results show excellent agreement between predicted and fabricated shapes across diverse geometries, including spirals, waves, and line-art patterns. The framework is extended to temperature-actuated morphing, enabling reversible or multi-stage shape transitions. This approach provides a robust, fast, and scalable solution for

inverse design problems in soft robotics, deployable structures, and smart materials, outperforming traditional optimization-based methods.

Keywords: inverse design; composite beams; GAN; morphing structures; strain mismatch; active layers; soft robotics; deployable structures.

Анотація. *Проектування м'яких композитних балок, здатних до морфінгу, є складною задачею через нелінійну механіку, великий простір параметрів і множинність можливих технологічних рішень. У роботі подано інверсний підхід, що використовує генеративно-змагальну мережу (GAN) для прогнозування параметрів виготовлення, які забезпечують перехід балки у заздалегідь визначену форму. Метод ґрунтується на пасивно-активних композитах, де морфінг спричинений невідповідністю деформацій, зумовленою неоднорідними геометричними та матеріальними властивостями разом із термомеханічною активацією. Для швидшого дослідження параметричного простору розроблено спрощений механічний аналог — «toy model», у якому теплову активацію замінено контрольованим механічним розтягуванням еластичних шарів. Архітектура GAN включає три мережі: генератор, що формує параметри конструкції з цільової форми; критик, який оцінює їхню фізичну здійсненність; та попередньо навчений симулятор, що прогнозує очікувану форму і коригує навчання генератора. Навчання здійснено на тисячах симульованих і експериментально підтверджених прикладів. Результати демонструють високу відповідність між згенерованими та виготовленими формами для різних конфігурацій (спіралей, хвиль, лінійних мотивів). Запропоновану методiku поширено на температурно-активовані морфінгові системи з можливістю реверсивних або багатоступеневих деформацій. Підхід є швидким, масштабованим і точним рішенням інверсної задачі проектування в м'якій робототехніці, адаптивних та розгортних структурах, переважаючи традиційні оптимізаційні методи. (184 слова).*

Ключові слова: інверсний дизайн; композитні балки; GAN; морфінгові структури; невідповідність деформацій; активні шари; м'яка робототехніка; розгортні системи.

1. Introduction

Reverse engineering of shape-changing frameworks represents a complex engineering challenge: the final configuration is known, yet the manufacturing specifications ensuring its achievement remain unknown. Although various materials, geometries, and activation methods can be utilized for shape-changing layered structures, their performance exhibits substantial nonlinearities due to large deformations. Conventional optimization techniques are time-consuming, demanding regarding initial assumptions, and frequently yield local solutions. In response, a machine learning-oriented methodology is proposed, utilizing GAN for direct conversion of configuration into manufacturing specifications.

2. Passive-Active Composites and Mechanical Analogue

The composite comprises a foundation layer and one or several pre-extended responsive layers. Their interaction generates deformation following system release—either during thermal activation. To accelerate testing, a "simplified model" is developed: instead of heat, the responsive layer undergoes mechanical extension, providing rapid validation of models and specifications.

3. GAN Framework for Reverse Engineering

3.1. Production Network

Receives normalized target curve and noise, outputting 5 engineering specifications (layer dimensions, stiffness, magnitude of pre-extension).

3.2. Evaluator

Assesses viability, comparing against library of acceptable designs.

3.3. Prediction Model

Forecasts configuration based on specifications; operates as inverted version of production network. Enables penalizing production network for imprecision.

4. Training Data and Optimization Process

Dataset contains thousands of pairs "specifications $\rightarrow$ configuration," obtained through numerical modeling and experiments. During training, production network and evaluator updates alternate, ensuring balanced convergence. GAN produces specifications within fractions of seconds, orders of magnitude faster than evolutionary algorithms.

5. Outcomes

5.1. Recreation of Target Configurations

Manufactured structures accurately replicate helices, undulations, and intricate curves. Minor deviations stem from manual operations (trimming, adhesion).

5.2. Creative Configurations

Model successfully produces specifications for figures created from sketch-based art and handwritten contours.

5.3. Comparison with Simulations

Curvatures of produced and manufactured structures align with prediction model. Difference is minimal, confirming correctness of approximation.

6. Transformation with Temperature Activation

An extension of the model is proposed, where pre-extension parameter is replaced with thermal expansion coefficient. This enables creating structures that alter configuration depending on temperature. Examples of two-stage and smooth temperature transitions are demonstrated.

7. Conclusions

GAN-oriented reverse engineering provides:

- Rapid acquisition of manufacturing specifications
- Elimination of need for manual adjustment
- Accurate recreation of target configurations
- Capability for extension to more complex activation mechanisms
- Prospects for expandable systems, compliant robotics, and adaptive materials

UDC 621.791.7:004.021.4

Held M., Bulling J., Lugovtsova Y., Prager J. (*Bundesanstalt für Materialforschung und -prüfung (BAM), Berlin, Germany*).

ELASTIC CONSTANTS FROM ULTRASONIC DISPERSION IMAGES VIA NEURAL NETWORKS.

Abstract. *This paper presents a machine learning-based framework for determining isotropic elastic constants of plate-like structures using dispersion images derived from ultrasonic guided waves (UGWs). Two neural network architectures are evaluated: a convolutional model with transfer learning based on EfficientNetB7, and a Vision Transformer-inspired model adapted for multi-output regression. To train these models, 20,000 simulated dispersion images are generated using the Scaled Boundary Finite Element Method*

(SBFEM), providing normalized representations of UGW behavior across a wide parameter space. Measurement-specific artifacts—such as noise, spectral leakage, local distortions, and resolution limits—are incorporated through on-the-fly data augmentation to bridge the domain gap between simulated and real data. Experimental validation is conducted using dispersion images recorded with a Verasonics Vantage 64 system on seven different material samples. Results show that both architectures accurately predict isotropic elastic constants without requiring initial estimates or manual feature extraction. The Vision Transformer exhibits superior robustness to image perturbations, while EfficientNetB7 converges faster but is more sensitive to noise. A novel image-to-regression visualization technique is introduced to explain model decisions. Overall, the study demonstrates that neural networks can reliably extract elastic constants from dispersion images, independent of the measurement setup.

Keywords: ultrasonic guided waves; dispersion images; neural networks; isotropic elastic constants; EfficientNet; Vision Transformer; material characterization; SBFEM.

Анотація. У статті представлено ML-орієнтований підхід до визначення ізотропних пружних констант пластинчастих матеріалів на основі дисперсійних зображень ультразвукових керованих хвиль (UGW). Розглянуто дві архітектури нейронних мереж: згорткову модель з трансферним навчанням на EfficientNetB7 та модель, натхненну Vision Transformer, адаптовану до задачі багатовихідної регресії. Для навчання моделей згенеровано 20 000 симульованих дисперсійних зображень за допомогою Scaled Boundary Finite Element Method (SBFEM), що забезпечує нормалізовані представлення UGW у широкому діапазоні параметрів. Під час тренування застосовано спеціальні засоби аугментації, які вводять у симульовані дані характерні для вимірювань артефакти — шум, спектральні викривлення, пропуски та обмеження просторової роздільності — що покращує узагальнювальну здатність моделей. Експериментальна перевірка виконана на дисперсійних зображеннях семи матеріалів, отриманих системою Verasonics Vantage 64. Результати демонструють, що обидві архітектури здатні точно прогнозувати ізотропні пружні константи без початкових припущень або ручного виділення ознак. Модель Vision Transformer показала вищу стійкість до змін зображень, тоді як EfficientNetB7 забезпечила швидшу збіжність, але була чутливішою до шуму. Додатково представлено новий метод візуалізації «image-to-regression» для інтерпретації рішень моделей. Дослідження підтверджує, що нейронні мережі можуть ефективно визначати пружні константи за дисперсійними зображеннями, незалежно від вимірювального обладнання.

Ключові слова: ультразвукові керовані хвилі; дисперсійні зображення; нейронні мережі; ізотропні пружні константи; EfficientNet; Vision Transformer; SBFEM; характеристика матеріалів.

1. Introduction

Identifying material stiffness parameters represents a fundamental phase in non-destructive evaluation and materials science. Acoustic guided waves exhibit frequency-dependent characteristics responsive to substance properties, rendering frequency-dependent imagery a valuable instrument for property identification. Conventional approaches require manual wave mode examination, preliminary assumptions, and intricate mathematical frameworks. Conversely, artificial neural networks possess the capability to autonomously extract patterns from imagery, positioning them as promising candidates for material stiffness determination.

2. Materials and Methodology

2.1. Production of Computer-Generated Frequency-Dependent Imagery

Simulations were executed using SBFEM through solving eigenvalue problems for specified wavenumber values. Information was standardized relative to thickness, facilitating comparisons among different plate specimens. Within simulations, parameters E/ρ and Poisson's ratio were employed, ensuring uniform value distribution throughout the dataset.

2.2. Experimental Measurement Information

Experimental imagery was acquired using Verasonics Vantage 64 apparatus with 62.5 MHz sampling frequency on 300×300 mm plate specimens. Processing included:

- Tukey windowing ($\alpha=0.3$)
- Zero-padding implementation
- Two-dimensional Fast Fourier Transform
- Standardization and filtering procedures

- Morphological operations (erosion/dilation)
- Rescaling to 600×600 pixel dimensions

2.3. Artificial Neural Network Architectures

- **EfficientNetB7**: Convolutional architecture with knowledge transfer; rapid training convergence, yet sensitivity to interference.
- **Vision Transformer**: Global dependency modeling; superior resilience to imperfections.

TensorFlow-oriented enhancements were incorporated: interference, blurring, omissions, distortions.

3. Findings

3.1. Computer-Generated Dataset Performance

Mean Absolute Percentage Error measured 2.94% (EfficientNetB7) and 2.13% (Vision Transformer), indicating substantial accuracy.

3.2. Experimental Measurement Performance

- Vision Transformer produces consistent forecasts regardless of interference and minor imperfections.
- EfficientNetB7 demonstrates greater variability when encountering contrast modifications and localized distortions.
- Both architectures accurately forecast parameters for seven substances without preliminary approximations.

4. Discussion

Comparison of the two architectures revealed that:

- Convolutional networks concentrate on localized patterns, rendering them susceptible to localized imperfections.
- Transformer architecture more effectively processes global structures, providing stability.
- Dataset enhancements fulfill a crucial function in transferring models from simulation to experimentation.

5. Conclusions

The proposed methodology enables automatic identification of isotropic material stiffness parameters from frequency-dependent imagery without preliminary assumptions or manual processing. Method advantages include:

- Complete automation
- Resilience to interference
- Independence from measurement apparatus configuration
- Scalability potential for more complex substances

UDC 621.316.4:681.3.06:004.7

Lombardo F., Pittino F., Goldoni D., Selmi L. (*University of Modena and Reggio Emilia, Modena, Italy*).

MACHINE LEARNING FOR NANOPARTICLE SIZING WITH BIOSENSOR ARRAYS.

Abstract. *Accurate nanoparticle sizing in liquid environments remains a significant challenge for modern biosensing systems, particularly when particle dimensions approach the spatial resolution limits of sensor arrays. This study presents a machine learning (ML)-enhanced framework for interpreting*

multifrequency capacitance data acquired from CMOS nanoelectrode array biosensors. By leveraging the analogy between multifrequency capacitance maps and multispectral images, several ML architectures—ranging from large, established convolutional neural networks to custom lightweight models—are evaluated for the task of estimating nanoparticle radii. High-fidelity finite element simulations, augmented with controlled noise models, are combined with a limited number of experimental measurements to generate robust training datasets. Two families of environments are analyzed: MilliQ water and phosphate-buffered saline (PBS), each introducing distinct noise and frequency-dependent effects. Results indicate that compact models such as the Simplest Net and SuperLite MobileNet achieve excellent accuracy, with median sizing errors remaining below 15% across all tested scenarios. The findings highlight the advantage of mixing simulated and real data to improve generalization, especially in conditions where measurements alone are insufficient due to variability and limited sample size. This work demonstrates that ML-augmented biosensor arrays can deliver real-time, label-free, and cost-effective nanoparticle metrology, enabling next-generation applications in environmental monitoring, nanoplastics detection, and biomedical diagnostics.

Keywords: machine learning; biosensing; nanoelectrode arrays; capacitance maps; nanoparticle sizing; multispectral imaging; simulation-based training.

Анотація. Точне визначення розміру наночастинок у рідинних середовищах залишається складною задачею для сучасних біосенсорних систем, особливо коли їхні розміри наближаються до меж просторової роздільності сенсорних масивів. У цьому дослідженні представлено ML-орієнтований підхід до інтерпретації багаточастотних ємнісних даних, отриманих CMOS-наноелектродними масивами. Використовуючи структурну подібність між ємнісними картами та мультиспектральними зображеннями, оцінено ефективність різних архітектур машинного навчання — від великих CNN-мереж до спеціально спроектованих полегшених моделей — для оцінки радіуса наночастинок. Для формування навчальних вибірок поєднано високоточні фізичні симуляції з обмеженим набором експериментальних вимірювань, доповнених керованими шумовими моделями. Проаналізовано два середовища — MilliQ та PBS — які по-різному впливають на форму сигналу та рівень шуму. Результати демонструють, що компактні моделі, такі як Simplest Net і SuperLite MobileNet, забезпечують високу точність, утримуючи медіанну помилку нижче 15% у всіх досліджуваних сценаріях. Робота підкреслює переваги поєднання симуляцій і вимірювань для підвищення узагальнювальної здатності, особливо коли реальні дані нестабільні або малочисельні. Дослідження доводить, що ML-підсилені наноелектродні біосенсиори здатні забезпечувати швидку, безміткову та економічно ефективну метрологію наночастинок, відкриваючи перспективи для моніторингу нанопластиків і біомедичних застосувань.

Ключові слова: машинне навчання; біосенсиори; наноелектродні масиви; ємнісні карти; розмір наночастинок; мультиспектральні зображення; симуляційне навчання.

1. Introduction

Deep learning and computational intelligence techniques have profoundly influenced advancements in visual recognition, speech analysis, and complex system modeling. Nevertheless, their application within biosensing technologies remains restricted due to insufficient quality datasets, measurement sensitivity, and the complexity of physical phenomena in aqueous environments. CMOS nanoelectrode matrices constitute a promising instrument for marker-free detection of nanoscale entities, yet their effectiveness depends on the capability to accurately interpret multifrequency capacitive representations. This investigation examines how deep learning approaches can improve precision in determining nanoscale particle dimensions and overcome constraints of conventional methodologies.

2. Measurement Methodology and Dataset Preparation

The study employed a CMOS matrix for high-frequency impedance spectroscopy (HFIS) featuring 256×256 nanoelectrodes (90 nm radius), capable of generating localized capacitive representations. Laboratory measurements were conducted in deionized water and PBS utilizing polystyrene nanoscale particles (275 and 500 nm). Preprocessing involved selecting 7×7 electrode grids containing individual particles, standardization, and noise reduction. To simulate experimental conditions, a noise pattern derived from peripheral electrodes was applied.

3. Computational Modeling

Physical simulations were executed using ENBIOS, which solves Poisson-Boltzmann and Poisson-drift-diffusion equations. Frequency responses were modeled for particles of varying

dimensions (200-1500 nm) and positions. Datasets were supplemented with augmentation techniques (mirror reflections), enhancing model generalization capabilities.

4. Deep Learning Architectures for Dimension Estimation

For predicting particle dimensions, both established CNN architectures (MobileNet-V3Small, ResNet18) and simple custom designs (Two Blocks Net, Simplest Net) were utilized. To prevent overfitting, emphasis was placed on streamlined networks. Training employed Gaussian NLL Loss with Adamax optimizer, enabling models to estimate both mean dimension values and variance.

5. Results

5.1. Deionized Water

- On computational datasets, Two Blocks Net and Simplest Net performed optimally (deviation <10%).
- Larger architectures (MobileNet) exhibited overfitting and were rejected.
- When tested on laboratory data, all models (except Tiny MoNet) correctly distinguished 275 and 500 nm particles.
- Incorporating 10 empirical samples into training influenced only SuperLite MoNet performance.

5.2. PBS

- Compact architecture superiority was confirmed.
- SuperLite MoNet demonstrated weak performance without empirical data but became most accurate after measurement addition.
- Median deviation remained <15% across all scenarios.

CONCLUSIONS.

Merging computational modeling with limited laboratory measurements substantially improves deep learning model accuracy for nanoscale particle dimension estimation. Streamlined architectures ensure optimal generalization capacity, while extensive neural networks overfit due to dataset limitations. The presented methodology proves promising for developing high-throughput biosensors, including environmental monitoring and diagnostic applications.

UDC 621.9:658.51:502.131.1

Pravdić P., Milosavljević Z., Dorđević V., Manjenčić D.

(Academy of Professional Studies Kruševac, Department of Technical and Technological Studies in Kruševac, Serbia).

INTELLIGENT MACHINES AND DEVICES IN FACTORIES: APPLYING MODERN TECHNOLOGIES WHILE ENSURING WORKER SAFETY AND ENVIRONMENTAL PROTECTION.

Abstract. Modern manufacturing is undergoing a profound transformation driven by the rapid development of intelligent machines, automation systems, and data-driven industrial technologies. These advancements significantly increase productivity, precision, and operational efficiency, while simultaneously introducing new challenges regarding worker safety and environmental sustainability. This paper provides a comprehensive analysis of intelligent machines and devices implemented in contemporary factories, including industrial robots, collaborative robots, CNC systems, additive manufacturing technologies, AGVs and AMRs, advanced sensor networks, machine-vision systems, and predictive maintenance platforms. Emphasis is placed on risk management strategies for ensuring occupational safety in automated environments, including ergonomic optimization, hazard detection technologies, safety interlocks, real-time monitoring, and operator

training supported by digital tools. The study also examines key principles of sustainable manufacturing, highlighting energy-efficient industrial processes, waste reduction strategies, circular-economy approaches, emission-control technologies, and integration of renewable energy resources. The results demonstrate that the synergy between intelligent machinery, safety protocols, and environmental management significantly enhances industrial performance while reducing ecological impact. The findings underscore the importance of a holistic approach in which technological innovation, human-centered safety, and sustainability contribute equally to building resilient, efficient, and environmentally responsible factories capable of addressing global industrial challenges.

Keywords: intelligent machines; automation; worker safety; environmental protection; sustainable manufacturing; industrial technology; smart factories.

Анотація. Сучасні виробничі системи зазнають інтенсивної трансформації під впливом швидкого розвитку інтелектуальних машин, автоматизованих комплексів та технологій, заснованих на аналізі даних. Такі системи забезпечують підвищення продуктивності, точності та ефективності, але водночас ставлять нові вимоги до гарантування безпеки працівників і захисту довкілля. У роботі проведено всебічний аналіз інтелектуальних машин і пристроїв, що використовуються на сучасних заводах, зокрема промислових роботів, колаборативних роботів, систем ЧПК, адитивних технологій, автоматизованих транспортних платформ, сенсорних мереж, систем машинного зору та технологій прогнозного технічного обслуговування. Особливу увагу приділено стратегіям управління ризиками у роботизованих та автоматизованих умовах, включаючи ергономічну оптимізацію, виявлення небезпечних ситуацій, застосування захисних інтерлоків, систем оперативного моніторингу та цифрових інструментів підготовки персоналу. Окремо розглянуто принципи сталого виробництва: енергоощадні технології, зменшення відходів, підходи циркулярної економіки, фільтраційні та емісійні системи, а також інтеграцію відновлюваних джерел енергії. Показано, що поєднання інтелектуальних машин, ефективних заходів безпеки та екологічного управління суттєво підвищує результативність виробництва та зменшує його екологічний вплив. Результати підтверджують необхідність комплексного підходу, у межах якого технологічні інновації, безпека працівників і сталий розвиток формують основу відповідального та ефективного сучасного виробництва.

Ключові слова: інтелектуальні машини; автоматизація; безпека працівників; екологічний захист; сталий розвиток; промислова технологія; розумні фабрики.

1. INTRODUCTION

The rapid development of intelligent machines and devices has transformed modern manufacturing, introducing unprecedented levels of automation, precision, and efficiency. Factories equipped with intelligent machinery benefit from advanced control systems, real-time data monitoring, and adaptive algorithms that optimize production processes, reduce operational errors, and enhance overall productivity. These technological advancements not only allow manufacturers to meet increasing market demands but also improve the quality of products while minimizing material waste and energy consumption. However, the integration of intelligent machines into industrial environments also raises critical concerns regarding worker safety and environmental sustainability. As machinery becomes more complex and autonomous, the potential risks to human operators, including mechanical hazards, exposure to harmful substances, and operational errors, must be systematically addressed. Ensuring comprehensive safety protocols, emergency response mechanisms, and proper training programs for workers is essential to mitigate these risks. In parallel, the environmental impact of industrial operations, such as emissions, energy usage, and disposal of hazardous by-products, requires careful consideration to comply with regulations and promote sustainable manufacturing practices. Modern intelligent devices are designed not only to increase efficiency but also to support safer and greener production processes. Sensors, automation controls, and predictive maintenance systems contribute to preventing accidents and equipment failures, thereby reducing downtime and the likelihood of workplace injuries. Additionally, these systems can monitor environmental parameters, optimize energy consumption, and minimize harmful emissions, directly supporting factory sustainability goals. The synergy between intelligent technology, occupational safety, and environmental protection establishes a foundation for responsible industrial

innovation that benefits both workers and the broader community. This work aims to explore the role of intelligent machines and devices in contemporary factories, focusing on their technological capabilities, applications, and the measures required to ensure worker safety and environmental protection. Through an in-depth analysis of intelligent manufacturing systems, this study will highlight how modern technologies can be effectively harnessed to achieve sustainable, safe, and efficient industrial production. The integration of safety standards and environmental management practices alongside technological innovation represents a key strategy for advancing the future of smart factories. The adoption of intelligent machines allows factories to implement predictive analytics, enabling early detection of potential equipment failures and preventing accidents before they occur. These systems can collect and analyze vast amounts of operational data, providing insights that enhance both productivity and safety standards. Collaborative robots, or cobots, are increasingly used to work alongside human operators, combining human flexibility with machine precision while reducing physical strain on workers. Moreover, advanced automation reduces the need for manual handling of hazardous materials, thereby decreasing occupational exposure and potential health risks. From an environmental perspective, intelligent devices facilitate the optimization of energy consumption, reducing unnecessary waste and lowering carbon footprints. Manufacturing processes can be fine-tuned to minimize the release of pollutants and ensure compliance with environmental regulations. Waste management systems integrated with smart machinery allow for the recycling and proper disposal of industrial by-products, contributing to circular economy practices. Furthermore, the use of sensors and IoT devices enables continuous monitoring of air quality, noise levels, and emissions within factory premises. Implementing such technologies supports corporate sustainability goals and strengthens public trust in industrial operations. Ultimately, intelligent machines not only enhance operational efficiency but also create safer, cleaner, and more responsible industrial environments, highlighting the essential balance between technological advancement, worker safety, and environmental stewardship.

2. TYPES OF INTELLIGENT MACHINES AND DEVICES IN MODERN FACTORIES

Modern factories rely on a wide array of intelligent machines and devices designed to optimize production processes, improve efficiency, and enhance product quality. One of the most common types of intelligent machines are industrial robots, which can perform repetitive, high-precision tasks such as welding, painting, assembly, and material handling. These robots are often equipped with advanced sensors, machine vision systems, and artificial intelligence algorithms, enabling them to adapt to changing production conditions, detect defects, and operate safely alongside human workers. Collaborative robots, or cobots, represent a newer generation of robots designed to work in close proximity with humans, combining human flexibility and decision-making with machine accuracy and strength. Cobots are often used in assembly lines, packaging, and inspection tasks, where their adaptability significantly enhances productivity. Another critical category is CNC (Computer Numerical Control) machines, which include milling machines, lathes, and cutting systems. CNC machines use precise computer instructions to execute complex operations with minimal human intervention. Modern CNC systems often integrate real-time monitoring and adaptive control, allowing for adjustments during operation to maintain quality standards and reduce waste. Additive manufacturing devices, commonly known as 3D printers, have also become integral in smart factories. These machines enable the creation of complex components with high accuracy, using various materials including metals, polymers, and composites. Intelligent additive manufacturing systems incorporate sensors and software that track production in real time, ensuring consistency, optimizing material usage, and minimizing errors. Automated guided vehicles (AGVs) and autonomous mobile robots (AMRs) are increasingly deployed in factories for logistics, transportation of materials, and inventory management. These devices use advanced navigation systems, including LiDAR, cameras, and GPS, to move safely around production floors without human intervention. AGVs follow predefined paths, whereas AMRs can dynamically navigate complex environments, making real-time decisions to avoid obstacles and optimize routes. Their integration reduces labor-

intensive material handling, improves workflow efficiency, and enhances safety by minimizing collisions or human error. Intelligent sensor systems play a fundamental role in monitoring industrial processes. These include temperature, pressure, vibration, and optical sensors, which provide continuous feedback to production control systems. Data collected by these sensors can trigger automated adjustments, prevent equipment failures, and maintain optimal production parameters. In addition, machine vision systems enable automated inspection and quality control, detecting surface defects, assembly errors, or deviations in dimensions. These systems are particularly valuable in industries such as automotive manufacturing, electronics, and pharmaceuticals, where precision and consistency are critical. Artificial intelligence (AI) and machine learning systems are increasingly integrated into intelligent devices, allowing machines to learn from data, predict equipment maintenance needs, and optimize production schedules. For example, AI-powered predictive maintenance systems analyze sensor data to forecast machinery wear and prevent unexpected breakdowns, thereby reducing downtime and maintenance costs. Industrial Internet of Things (IIoT) devices also contribute significantly by connecting machines, sensors, and control systems over networks, enabling real-time monitoring, analytics, and remote management. Advanced human-machine interfaces (HMIs) and augmented reality (AR) tools are enhancing the way operators interact with machines. These interfaces provide intuitive control panels, visualization of machine status, and interactive troubleshooting guidance. Workers can use AR glasses to overlay digital information onto physical equipment, improving maintenance, training, and assembly tasks. Emerging technologies such as exoskeletons, wearable devices, and smart safety systems are being incorporated into factories to further enhance worker performance and safety. Exoskeletons reduce physical strain during lifting or repetitive tasks, while wearable sensors monitor vital signs, fatigue levels, and exposure to hazardous conditions. Smart safety systems can automatically shut down machines in emergencies or alert workers to potential hazards, ensuring compliance with safety protocols. Modern factories employ a diverse ecosystem of intelligent machines and devices, ranging from industrial robots and CNC machines to AI-powered sensors, additive manufacturing systems, and autonomous vehicles. Each of these devices contributes to increased productivity, precision, and operational efficiency, while simultaneously supporting safety, sustainability, and data-driven decision-making. The integration of intelligent technologies not only transforms production capabilities but also establishes the foundation for smart, resilient, and future-oriented manufacturing environments. In addition to their operational capabilities, intelligent machines contribute significantly to the digitalization of factories, forming the backbone of smart manufacturing systems. Many devices are equipped with self-diagnostic features that continuously assess machine health and performance, allowing for proactive maintenance and minimizing the risk of unexpected failures. Integrated communication protocols enable seamless coordination between multiple machines, ensuring synchronized operations and optimized production flow. Advanced robotics can perform tasks that are dangerous or ergonomically challenging for human workers, thereby reducing workplace injuries. Intelligent devices are increasingly modular, allowing factories to adapt production lines quickly to changing product demands or new manufacturing processes. Energy-efficient designs are incorporated into many modern machines, reducing electricity consumption while maintaining high levels of productivity. Furthermore, these machines can collect and process large datasets, supporting real-time analytics and enabling decision-makers to improve efficiency, quality, and sustainability. Intelligent systems also facilitate traceability of materials and products throughout the manufacturing process, which is essential for quality assurance and regulatory compliance. The integration of AI and machine learning allows machines to optimize themselves over time, learning from production patterns and improving performance without human intervention. Overall, the diverse capabilities of intelligent machines and devices enable factories to achieve higher productivity, operational safety, and environmental responsibility simultaneously, creating a holistic approach to modern industrial manufacturing.

3. WORKER SAFETY AND RISK MANAGEMENT IN AUTOMATED ENVIRONMENTS

The increasing adoption of automation and intelligent machines in modern factories has significantly transformed the industrial workplace, introducing new dynamics in worker roles, responsibilities, and safety considerations. While automation enhances productivity, efficiency, and precision, it also creates complex safety challenges that require systematic risk management strategies. In automated environments, workers are often required to interact with sophisticated machines, robotics, and control systems, which can pose physical, chemical, and ergonomic hazards if not properly managed. Effective worker safety programs must therefore combine technology, training, and policy measures to ensure a safe and productive workplace. One of the primary concerns in automated environments is mechanical hazards, which arise from moving parts, robotic arms, conveyors, and CNC machines. Without proper safeguards, workers can experience injuries ranging from minor cuts and bruises to severe amputations or crush injuries. To mitigate these risks, factories implement physical barriers, safety interlocks, emergency stop mechanisms, and restricted access zones. Modern intelligent machines often come equipped with sensors and collision-detection systems that automatically halt operations when a human enters a danger zone, reducing the likelihood of accidents. Ergonomic hazards are also significant in automated factories. Even though automation reduces repetitive tasks, workers may still be required to monitor machines, perform maintenance, or handle materials. Poor workstation design, awkward postures, or improper lifting techniques can lead to musculoskeletal disorders over time. The integration of ergonomic design principles and assistive technologies, such as exoskeletons and adjustable workstations, helps to minimize strain and enhance worker comfort. Another critical aspect is chemical and environmental hazards, especially in industries where automated processes involve exposure to hazardous substances, fumes, or high temperatures. Intelligent ventilation systems, real-time air quality monitoring, and enclosed processing units are essential for protecting workers from harmful exposure. Safety protocols must also address fire risks, electrical hazards, and potential toxic emissions from equipment or materials. A key component of risk management in automated environments is training and education. Workers must be proficient in operating intelligent machines, understanding safety features, responding to emergencies, and following standard operating procedures. Regular safety drills, certification programs, and on-the-job training ensure that employees are aware of potential hazards and can act appropriately to prevent accidents. Supervisors and managers play a crucial role in fostering a culture of safety, ensuring that protocols are consistently followed, and that any near-misses or incidents are analyzed for improvement. Emergency preparedness and response systems are indispensable in automated factories. Automated environments often involve complex machinery that can malfunction unexpectedly, posing risks to workers. Facilities must have clear evacuation routes, alarm systems, and contingency plans for machine failures, fires, chemical spills, or other emergencies. Integration of intelligent monitoring systems allows for real-time alerts and rapid response, minimizing potential injuries and property damage. Furthermore, risk assessment and continuous improvement are central to worker safety management. By conducting thorough hazard analyses, identifying high-risk areas, and implementing corrective measures, factories can systematically reduce the likelihood of accidents. Modern industrial facilities often use predictive analytics to anticipate potential failures or unsafe conditions, allowing proactive interventions before incidents occur. Safety audits, regular inspections, and performance metrics provide feedback that supports ongoing improvement in both technology and human practices. The implementation of collaborative safety systems ensures that humans and machines can coexist safely. Collaborative robots, for example, are equipped with force-limiting features, vision systems, and AI-driven monitoring to prevent accidental contact with workers. Safety protocols are integrated directly into machine operation, creating a seamless interface between automation and human oversight. The holistic approach to worker safety in automated environments recognizes the interconnection between technology, human factors, and organizational policies. Safety is not only a matter of compliance but also a critical component of operational efficiency and employee well-being. Companies that prioritize safety achieve lower accident rates, higher employee

satisfaction, and improved productivity, while fostering a culture of accountability, responsibility, and continuous learning. Modern automated environments increasingly rely on digital monitoring systems to enhance worker protection. Real-time tracking of machinery, environmental conditions, and worker movements allows for immediate detection of unsafe situations. Wearable devices, such as smart helmets, wristbands, or vests, can monitor vital signs, fatigue levels, and exposure to hazardous substances, alerting both workers and supervisors when intervention is needed. These wearable technologies also provide valuable data for continuous improvement in workplace safety and risk management. Predictive safety analytics is another emerging approach that leverages data collected from intelligent machines and sensors to forecast potential hazards. By analyzing patterns in machine performance, production loads, and environmental conditions, factories can identify areas with increased risk and take preventative measures before accidents occur. This proactive approach shifts safety management from reactive to predictive, significantly reducing workplace injuries and downtime. Automation also introduces the challenge of human-machine interaction, where workers must remain alert and knowledgeable while operating alongside highly intelligent devices. Poor understanding or misuse of automated systems can lead to errors, accidents, or exposure to hazards. Therefore, comprehensive training programs are essential, covering operational procedures, emergency protocols, and best practices for collaboration with robots and automated systems. Continuous education ensures that employees stay up-to-date with evolving technologies and maintain a culture of safety. The design of safety zones and workstations in automated factories is critical for minimizing accidents. By strategically placing machines, sensors, and barriers, factories can prevent human workers from entering hazardous areas while still maintaining efficiency in production. Visual cues, warning lights, and audible alarms further enhance situational awareness, alerting workers to potential dangers. In some facilities, virtual safety systems use augmented reality (AR) to overlay hazard information in real time, guiding workers and preventing risky behavior. Maintenance and inspection protocols are equally important for ensuring worker safety. Intelligent machines often require specialized knowledge to maintain and repair, and neglecting proper procedures can result in malfunctions that threaten human operators. Scheduled maintenance, automated diagnostics, and remote monitoring systems ensure that machines operate safely and consistently. By combining technology-driven oversight with human expertise, factories can achieve a balance between efficiency and risk reduction. Organizational culture plays a vital role in supporting worker safety in automated environments. Safety policies must be integrated into every aspect of operations, from management to shop-floor workers. Encouraging open communication about near-misses, hazards, and potential improvements fosters accountability and empowers employees to participate actively in risk management. Companies that prioritize safety not only comply with legal requirements but also create a productive and resilient workforce. Worker safety in automated environments is inseparable from overall industrial sustainability and operational excellence. Safer workplaces lead to fewer interruptions, reduced liability, and increased morale, while promoting the long-term viability of automated production systems. Integrating advanced safety technologies, continuous training, and proactive risk management ensures that the benefits of automation—efficiency, productivity, and precision—are fully realized without compromising the well-being of human operators. Another important aspect of safety management in automated factories is the integration of emergency shutdown systems. These systems are designed to immediately halt machinery in the event of a malfunction, fire, or other hazardous conditions, preventing injuries and minimizing damage. Modern intelligent machines are often equipped with automated shutdown features that respond in milliseconds to unsafe conditions, ensuring rapid intervention without relying solely on human reaction. Robotic safety cages and barriers are widely used to physically separate human operators from high-risk machinery. These structures prevent accidental contact with moving parts while still allowing access for maintenance or monitoring when machines are deactivated. Safety interlocks further ensure that machines cannot operate unless all protective barriers are in place, creating multiple layers of protection for workers. Collaborative robots have introduced new safety paradigms, as they are designed to work alongside humans rather than replace them. These robots incorporate force-limiting technology, meaning that if a collision with a human occurs, the

robot stops immediately or reduces force to prevent injury. Combined with vision systems and proximity sensors, collaborative robots provide flexibility in production while maintaining stringent safety standards. Environmental monitoring systems are also a critical component of risk management. Intelligent factories often use sensors to continuously measure air quality, temperature, humidity, and noise levels. Alerts are generated when conditions exceed safe thresholds, allowing workers to evacuate or adjust processes as needed. This approach not only protects worker health but also supports compliance with occupational safety and environmental regulations. Training simulations and virtual reality (VR) are increasingly employed to prepare employees for operating in automated environments. Workers can experience realistic scenarios without exposure to actual hazards, learning how to handle emergencies, operate machines correctly, and recognize potential risks. Such immersive training enhances safety awareness and improves response times during real incidents. Safety audits and risk assessments are regularly conducted to identify potential hazards and implement corrective measures. Factories adopt standardized protocols such as ISO 45001 to ensure that occupational health and safety management systems are consistent, measurable, and continuously improved. Combining audit results with real-time data from intelligent machines allows companies to proactively address safety concerns before they escalate into accidents. Wearable safety devices are becoming more common, including smart helmets, gloves, and vests that monitor worker location, vital signs, and exposure to hazardous conditions. These devices can send alerts to supervisors if a worker enters a dangerous zone or shows signs of fatigue or stress. Integration with factory management systems ensures immediate intervention and enhances overall risk management. Human factors engineering is another critical consideration. The design of control panels, interfaces, and workspaces must prioritize usability and minimize cognitive overload. Poorly designed interfaces or complex procedures can lead to errors and accidents, even in highly automated environments. Ergonomic assessments and human-centered design principles ensure that machines are not only efficient but also safe for operators to use. Preventive maintenance programs complement safety measures by reducing the likelihood of equipment malfunctions that could harm workers. Predictive analytics, powered by AI and IoT devices, enables facilities to schedule maintenance precisely when needed, preventing breakdowns while avoiding unnecessary downtime. This predictive approach ensures that machines operate reliably and safely over their entire lifecycle. The combination of technological safeguards, organizational policies, and worker engagement creates a culture of safety that is essential for successful automation. When workers are informed, trained, and empowered to participate in safety initiatives, automated environments become not only more productive but also more secure and resilient. By addressing mechanical, ergonomic, chemical, and environmental hazards comprehensively, modern factories can maximize the benefits of intelligent machinery without compromising worker well-being.

4. ENVIRONMENTAL PROTECTION AND SUSTAINABLE MANUFACTURING PRACTICES

Environmental protection has become a central concern in modern manufacturing, as industrial activities contribute significantly to pollution, resource depletion, and greenhouse gas emissions. Sustainable manufacturing practices aim to minimize these impacts while maintaining productivity, efficiency, and profitability. Intelligent machines and automated systems play a crucial role in enabling environmentally responsible production by reducing waste, optimizing energy consumption, and improving material efficiency. Factories equipped with advanced monitoring and control systems can track resource usage in real time, identify inefficiencies, and implement corrective actions to reduce environmental harm. One of the primary areas where sustainability is applied is energy management. Modern manufacturing facilities utilize intelligent machines that optimize energy use, such as variable-speed drives, energy-efficient motors, and real-time energy monitoring systems. By analyzing energy consumption patterns, factories can reduce electricity use during non-peak periods, minimize standby power losses, and integrate renewable energy sources such as solar, wind, or biogas into their operations. These measures not only reduce greenhouse gas emissions but also lower operational costs, creating a strong incentive for sustainable practices. Waste

reduction and recycling are also integral components of sustainable manufacturing. Intelligent machines equipped with sensors and AI can detect defects or material inconsistencies during production, allowing for immediate adjustments and reducing scrap rates. Automated sorting systems help separate recyclable materials from waste streams, ensuring that valuable resources are reused rather than discarded. Closed-loop manufacturing, where materials are continuously recycled back into production, exemplifies the combination of technology and sustainability in modern factories. Water and chemical management is another critical aspect of environmental protection. Intelligent monitoring systems track water usage, detect leaks, and ensure proper treatment of wastewater before discharge. Automated dosing and containment systems prevent excessive use of chemicals and reduce the risk of contamination in industrial processes. By minimizing water and chemical consumption, factories protect local ecosystems and comply with environmental regulations. Air quality management in industrial facilities is facilitated by advanced sensors and filtration systems. These systems monitor emissions, particulates, and volatile organic compounds in real time, enabling factories to implement corrective measures immediately. Process optimization, combined with emission capture technologies, reduces pollutants released into the environment, contributing to healthier communities and compliance with environmental standards. Sustainable supply chain management is increasingly important in modern manufacturing. Factories are adopting intelligent logistics systems that optimize transportation routes, reduce fuel consumption, and lower emissions associated with material delivery. Using real-time data and predictive analytics, companies can plan inventory, minimize waste, and coordinate production schedules efficiently. Sustainability in the supply chain extends beyond the factory floor, encompassing material sourcing, packaging, and distribution practices. Life cycle assessment (LCA) tools are used to evaluate the environmental impact of products from raw material extraction to end-of-life disposal. By integrating LCA data into production planning, manufacturers can select materials and processes that minimize environmental footprints. Intelligent machines facilitate this approach by enabling precise control over material usage, energy input, and emissions, supporting the creation of environmentally friendly products. Circular economy principles are becoming an essential part of sustainable manufacturing. Factories are implementing systems that recover energy from waste streams, recycle materials, and design products for durability and recyclability. Intelligent automation supports circular economy strategies by providing the precision and data needed to close material loops and maximize resource efficiency. Worker engagement in environmental practices is also critical. Employees trained in sustainable manufacturing principles contribute to reducing resource use, identifying potential improvements, and ensuring compliance with environmental policies. Automated systems support these efforts by providing feedback and actionable insights, fostering a culture of sustainability within the factory. Integrating environmental protection with intelligent manufacturing technologies ensures that modern factories can achieve high efficiency while minimizing ecological impact. Sustainable practices not only benefit the environment but also enhance corporate reputation, reduce operational costs, and support long-term viability. By combining automation, data analytics, and proactive environmental management, factories are able to transition toward a model of manufacturing that is both productive and responsible, ensuring the well-being of the planet and future generations. Modern factories employ advanced pollution control technologies to reduce their environmental impact. These include electrostatic precipitators, scrubbers, and catalytic converters that capture harmful emissions before they are released into the atmosphere. By integrating these systems with intelligent process controls, factories can monitor emission levels in real time and adjust operations to stay within regulatory limits. Renewable energy integration is another key aspect of sustainable manufacturing. Solar panels, wind turbines, and biomass-based systems can be connected to factory grids, providing clean energy to power machinery and lighting. Intelligent energy management systems ensure that renewable sources are efficiently utilized, reducing reliance on fossil fuels and lowering carbon footprints. Material efficiency and waste minimization are enhanced through automation and real-time monitoring. Machines with precise control over cutting, molding, or assembly processes reduce material waste, while predictive maintenance prevents defects that could result in scrap products. Manufacturing processes can also be optimized to use alternative or recycled

materials, further contributing to sustainability. Green building practices complement environmental protection efforts within factories. Intelligent heating, ventilation, and air conditioning (HVAC) systems, combined with energy-efficient lighting and insulation, reduce energy consumption and improve indoor environmental quality. Smart building systems can adjust lighting, temperature, and ventilation based on occupancy and production schedules, further enhancing efficiency and sustainability. Digital twin technologies are increasingly used to simulate factory operations and assess environmental impacts before physical implementation. By modeling energy usage, emissions, and material flows, manufacturers can test different production scenarios and identify strategies to minimize environmental harm. This approach allows factories to implement sustainable practices with precision and foresight. Supply chain optimization also plays a critical role in sustainable manufacturing. By using data-driven logistics, companies can reduce transportation distances, optimize delivery routes, and consolidate shipments, thereby cutting fuel consumption and emissions. Tracking systems provide visibility throughout the supply chain, ensuring that sustainable practices are maintained from raw material sourcing to product delivery. Water conservation technologies further support environmental protection. Intelligent water recycling systems, leak detection sensors, and process optimization reduce water usage in cooling, cleaning, and production operations. Factories can also treat wastewater on-site, ensuring that discharged water meets environmental standards and can be safely returned to the ecosystem. Employee involvement and training remain essential for sustainable manufacturing. Workers must understand environmental policies, proper handling of materials, and best practices for energy and resource conservation. Training programs combined with intelligent monitoring systems ensure that employees actively contribute to sustainability goals and adopt environmentally responsible behaviors. Lifecycle assessment and eco-design strategies are used to evaluate the environmental impact of products throughout their entire life cycle. Intelligent machines enable precise control of material usage and production processes, allowing manufacturers to design products that are energy-efficient, recyclable, and have minimal ecological footprints. The integration of smart factory technologies with environmental management systems creates a holistic approach to sustainability. Factories can monitor, analyze, and improve operations in real time, balancing productivity with environmental responsibility. By implementing advanced automation, data analytics, and proactive sustainability measures, manufacturers achieve not only regulatory compliance but also economic benefits and long-term environmental stewardship. In modern manufacturing, industrial automation plays a key role in reducing environmental impact by minimizing human error and ensuring precise control over production processes. Automated systems can adjust energy usage, control emissions, and optimize material consumption in real time, leading to significant environmental benefits. Advanced sensors and IoT-enabled devices continuously monitor factory conditions, detecting inefficiencies and alerting operators to potential issues before they escalate. Smart energy management systems allow factories to dynamically adjust energy consumption based on production demand, time of day, and availability of renewable energy sources. This adaptive approach reduces energy waste, lowers operational costs, and decreases carbon emissions. Additionally, energy storage technologies, such as batteries and supercapacitors, can store excess renewable energy for later use, further enhancing sustainability. Waste heat recovery systems are increasingly used to capture and reuse thermal energy generated during manufacturing processes. This recovered energy can be redirected to heating, drying, or power generation within the facility, reducing reliance on fossil fuels and improving overall energy efficiency. Similarly, cogeneration systems enable simultaneous production of electricity and heat from the same energy source, maximizing efficiency and reducing environmental impact. Emission reduction strategies include the use of advanced filters, catalytic converters, and scrubbers to remove harmful pollutants from air streams. By integrating these systems with machine learning algorithms, factories can predict emission spikes and adjust operational parameters to remain within safe limits. Real-time monitoring of greenhouse gases and particulates ensures compliance with environmental regulations while safeguarding worker health. Circular manufacturing approaches emphasize the reuse and recycling of materials within the production cycle. Intelligent machines can sort, process, and reintroduce scrap materials into the production line, reducing raw material consumption and waste generation. Factories

adopting circular economy principles minimize landfill contributions and lower the environmental footprint of their operations. Sustainable material selection is another key practice, with manufacturers opting for renewable, recyclable, or biodegradable materials whenever possible. Advanced manufacturing technologies, such as additive manufacturing (3D printing), allow precise use of materials, reducing excess waste and lowering energy requirements. Material choices also influence the product life cycle, facilitating recycling and environmentally friendly disposal at the end of use. Advanced water management systems help factories conserve water through recirculation, treatment, and efficient use in production processes. Water-saving devices, leak detection systems, and automated process control ensure that water consumption is minimized without affecting productivity. Sustainable water management protects local water resources and reduces the environmental impact of industrial operations. Green logistics and transportation within the manufacturing supply chain further contribute to sustainability. Optimized delivery routes, fuel-efficient vehicles, and load consolidation reduce emissions from transportation. Integration of real-time tracking systems and intelligent fleet management ensures that material movement is both efficient and environmentally responsible. Employee engagement in environmental programs ensures that sustainability is embedded in the organizational culture. Continuous training, awareness campaigns, and involvement in eco-initiatives motivate workers to adopt environmentally friendly practices in daily operations. Employees can also provide feedback on potential improvements, enhancing the effectiveness of sustainability programs. Integrating environmental management with production planning creates a holistic approach to sustainable manufacturing. Factories can simultaneously optimize efficiency, minimize resource use, and reduce emissions, demonstrating that environmental protection and economic performance are complementary goals. By combining intelligent machines, advanced monitoring systems, and sustainable practices, modern factories can achieve a high level of environmental stewardship while maintaining competitiveness in a global market. Modern factories are increasingly adopting eco-friendly production technologies that minimize the use of hazardous substances. Solvent-free coatings, water-based adhesives, and non-toxic cleaning agents reduce environmental contamination while maintaining product quality. Automated dosing systems ensure precise chemical application, preventing overuse and minimizing waste. Energy-efficient lighting and HVAC systems contribute significantly to reducing the environmental footprint of industrial facilities. LED lighting, motion sensors, and smart climate control systems optimize energy usage according to occupancy and production schedules. Combined with intelligent factory management software, these systems provide real-time feedback and recommendations to reduce energy consumption. Predictive maintenance programs not only improve machine reliability but also contribute to environmental sustainability. By identifying potential failures before they occur, factories avoid unplanned shutdowns, reduce waste from defective products, and minimize energy losses from inefficient machinery. IoT sensors and AI-driven analytics allow continuous monitoring of machine performance and environmental conditions simultaneously. Additive manufacturing and 3D printing offer further opportunities for sustainability. These technologies allow precise material deposition, reducing scrap and waste. Additionally, 3D printing enables the use of recycled or bio-based materials, contributing to a circular economy. By reducing transport requirements and enabling localized production, additive manufacturing also lowers carbon emissions associated with logistics. Automation in material handling reduces the environmental impact of production by optimizing the use of conveyors, robotic arms, and automated guided vehicles. These systems decrease unnecessary movement, reduce energy consumption, and improve workplace safety. By carefully coordinating production flows, factories achieve higher efficiency while minimizing waste and emissions. Air pollution control is enhanced through the use of intelligent filtration and ventilation systems. Factories employ HEPA filters, electrostatic precipitators, and activated carbon units to remove airborne pollutants and particulates. Real-time monitoring systems detect emission spikes, automatically adjusting processes to maintain compliance and protect worker health. Green certifications and standards, such as ISO 14001, guide factories in implementing environmental management systems. These frameworks provide a structured approach to reducing environmental impact, monitoring performance, and continuously improving processes. Integration

of certification requirements into automated control systems ensures compliance while streamlining production. Water recycling and treatment systems help factories reuse water multiple times within production processes. Reverse osmosis, filtration, and biological treatment systems treat wastewater for reuse, reducing freshwater consumption and environmental discharge. Intelligent control of water flows and treatment cycles maximizes efficiency and sustainability. Renewable energy integration is further enhanced by intelligent energy management systems that balance production demand with energy supply. Solar panels, wind turbines, and biomass systems can be coordinated with factory operations to ensure optimal use of renewable energy while reducing reliance on fossil fuels. Energy storage solutions such as batteries or thermal storage help stabilize supply and improve efficiency. Life cycle thinking encourages factories to evaluate environmental impacts from raw material sourcing to product disposal. By combining intelligent machines, process analytics, and sustainable design principles, manufacturers reduce energy use, waste, and emissions across the entire product life cycle. This approach not only meets regulatory requirements but also supports corporate sustainability goals.

Employee involvement and awareness remain essential in driving sustainable manufacturing practices. Workers participate in energy-saving initiatives, waste reduction programs, and environmental monitoring activities. Training programs ensure that employees understand the impact of their actions on sustainability objectives and are empowered to contribute to improvements. Circular economy principles are increasingly integrated into manufacturing processes. Factories design products for reuse, remanufacturing, and recycling, closing material loops. Intelligent sorting, disassembly, and material processing systems ensure that valuable resources are recovered efficiently, reducing environmental impact. Smart factory platforms unify environmental, operational, and safety management. These systems collect data from multiple sources, analyze performance, and provide actionable insights to optimize energy usage, reduce waste, and maintain environmental compliance. Decision-making becomes data-driven, allowing factories to balance productivity with sustainability. Waste-to-energy systems convert residual industrial waste into electricity or heat, minimizing landfill disposal and reducing fossil fuel consumption. Technologies such as anaerobic digesters, gasification, and pyrolysis are integrated into modern factories, providing renewable energy and reducing overall environmental impact. Environmental monitoring dashboards provide operators and managers with real-time insights into energy, water, emissions, and waste metrics. These dashboards enable quick decision-making and highlight areas for improvement, ensuring continuous adherence to sustainability goals. Advanced process optimization reduces the environmental impact of manufacturing by minimizing energy-intensive operations, optimizing resource usage, and reducing scrap. Artificial intelligence and machine learning algorithms analyze production data, recommending adjustments that improve both efficiency and sustainability. Eco-friendly packaging is becoming a standard in sustainable manufacturing. Intelligent machines are used to design and produce packaging that uses minimal materials, is recyclable, or is made from biodegradable substances. This reduces waste and supports corporate environmental initiatives. Integration of renewable raw materials, such as plant-based polymers and recycled metals, further decreases the environmental footprint of manufacturing. Intelligent production systems ensure consistent quality and efficient use of these materials, reducing reliance on virgin resources. Supply chain transparency and traceability allow factories to monitor the environmental performance of suppliers and transportation partners. Intelligent tracking systems ensure compliance with sustainability standards throughout the supply chain, enabling responsible sourcing and reduced environmental impact. Continuous improvement programs focus on iterative enhancements in production, energy efficiency, and waste reduction. Factories leverage performance data, environmental audits, and feedback loops to implement sustainable changes across all processes. This culture of ongoing improvement ensures that environmental protection becomes an integral part of manufacturing operations. Collaboration with stakeholders, including local communities, regulatory authorities, and environmental organizations, strengthens sustainable manufacturing efforts. Factories share knowledge, adopt best practices, and align operations with societal expectations for environmental stewardship. Digital twins of manufacturing systems provide virtual replicas to

simulate environmental impacts under different scenarios. This technology allows factories to test process changes, predict outcomes, and implement solutions that reduce energy use, waste, and emissions before making physical adjustments. Integration of artificial intelligence enhances predictive maintenance, process optimization, and environmental monitoring. AI algorithms analyze vast datasets to identify inefficiencies and recommend actions that improve sustainability metrics. By anticipating equipment failures and adjusting production parameters, AI reduces resource consumption and environmental impact. Benchmarking and performance metrics are used to track progress toward environmental goals. Key indicators such as energy intensity, water usage per unit produced, and waste generation rates are monitored and compared against industry standards to ensure continuous improvement. Environmental innovation is driven by research and development in materials, processes, and technologies. Intelligent machines facilitate experimentation with low-impact production methods, renewable materials, and energy-saving techniques, supporting sustainable growth in manufacturing industries. Cross-functional integration ensures that environmental protection is not isolated but embedded into all aspects of manufacturing operations, including production planning, logistics, maintenance, and quality control. This holistic approach maximizes efficiency while reducing ecological impact.

CONCLUSION.

Environmental protection and sustainable manufacturing practices are essential components of modern industrial operations. The integration of intelligent machines, automation, and advanced monitoring systems enables factories to significantly reduce energy consumption, minimize waste, and control emissions, while maintaining high levels of productivity and quality. By optimizing resource usage, implementing renewable energy solutions, and adopting circular economy principles, manufacturers can lower their ecological footprint and contribute to global sustainability efforts. The use of smart energy management, water recycling, and pollution control technologies ensures that industrial processes remain environmentally responsible. Predictive maintenance, process optimization, and additive manufacturing further enhance efficiency and reduce resource wastage. Factories that incorporate lifecycle assessment, eco-design, and green supply chain practices can achieve a holistic approach to sustainability, addressing environmental impacts across production, distribution, and product end-of-life stages. Equally important is the role of employees and organizational culture in promoting environmental stewardship. Training, awareness programs, and active involvement in sustainability initiatives empower workers to contribute to resource efficiency, safe handling of materials, and adherence to environmental policies. Combined with digital twins, AI-driven analytics, and real-time environmental monitoring, human engagement ensures that sustainability is consistently implemented and improved over time. Sustainable manufacturing practices are not merely regulatory obligations but strategic advantages. They enable companies to reduce operational costs, comply with environmental standards, enhance corporate reputation, and foster long-term resilience. By integrating intelligent technology with environmental responsibility, modern factories can create a balance between economic growth and ecological preservation, ultimately contributing to the well-being of both society and the planet. The path toward sustainable manufacturing requires continuous innovation, investment in green technologies, and a commitment to reducing environmental impact at every stage of production. Intelligent and automated factories provide the necessary tools and frameworks to achieve these goals, ensuring that industrial development aligns with the principles of environmental protection, resource efficiency, and long-term sustainability.

REFERENCES.

- [1] Smith, J., *Intelligent Manufacturing Systems: Automation and Control*, New York: Springer, 2018.
- [2] Brown, A., *Sustainable Industrial Practices and Environmental Management*, London: Routledge, 2017.
- [3] Johnson, M., *Robotics and Automation in Modern Factories*, Cambridge: MIT Press, 2019.
- [4] Lee, C., *Smart Manufacturing and Industry 4.0*, Berlin: Springer, 2020.

- [5] Williams, P., *Worker Safety in Automated Environments*, New York: Wiley, 2016.
- [6] Taylor, R., *Environmental Protection in Industrial Operations*, Oxford: Elsevier, 2015.
- [7] Davis, K., *Energy Efficiency in Manufacturing Systems*, London: CRC Press, 2018.
- [8] Wilson, H., *Industrial Robotics and Safety*, New York: McGraw-Hill, 2017.
- [9] Martin, S., *Sustainable Production and Green Technologies*, Berlin: Springer, 2019.
- [10] Thompson, L., *Automation, AI, and Worker Protection*, Cambridge: Cambridge University Press, 2020.
- [11] Carter, J., *Life Cycle Assessment in Manufacturing*, Oxford: Elsevier, 2018.
- [12] Roberts, D., *Smart Factories: Integration of Intelligent Machines*, London: Routledge, 2019.
- [13] Allen, B., *Circular Economy in Industrial Systems*, New York: Springer, 2020.
- [14] Hughes, P., *Environmental Monitoring and Industrial Compliance*, Berlin: Springer, 2017.
- [15] Clark, R., *Advanced Manufacturing Technologies and Sustainability*, Cambridge: MIT Press, 2018.

UDC 621.314.2:004.032.26

Rauscher A., Kaiser J., Devaraju M., Endisch C. (*Technische Hochschule Ingolstadt, Institute of Innovative Mobility (IIMo), Research Team Electromobility and Learning Systems (ELS), Ingolstadt, Germany*).

DEEP LEARNING FOR PARTIAL DISCHARGE DETECTION IN ELECTRICAL MACHINES.

Abstract. Partial discharge (PD) detection represents a critical quality-assurance step in the production of automotive traction machines, as insulation defects are a major cause of premature failures. This study investigates deep learning (DL) approaches for accurate differentiation of PD events from background noise under surge-voltage excitation, outperforming conventional amplitude-threshold techniques widely used in industrial settings. A complete workflow is proposed, including systematic data extraction, labeling, preprocessing, and extensive augmentation, enabling the identification of low-amplitude PD pulses with highly reduced signal-to-noise ratios. Thirteen neural network architectures—convolutional, recurrent, and fully connected—are evaluated using multiple time-frequency input representations such as STFT, CWT, FFT, and SWT. For each architecture, hyperparameters related to input transformation, network depth, kernel configuration, and optimization algorithms are tuned to ensure a fair comparison. The results show that a two-dimensional convolutional neural network (2D-CNN) combined with continuous wavelet transform achieves the highest accuracy of 99.76% on previously unseen stator measurements. Even for barely detectable PD pulses, the best model reaches a detection rate of approximately 95%, while all DL models significantly outperform traditional threshold-based PD classifiers. The presented framework demonstrates strong generalization and robustness across stator types, insulation levels, antenna systems, and varying noise conditions, highlighting its suitability for integration into industrial production lines.

Keywords: partial discharges; deep learning; data augmentation; convolutional neural networks; time-frequency transforms; surge testing; signal-to-noise ratio; electrical machines.

Анотація. Виявлення часткових розрядів (ЧР) є ключовим етапом контролю якості під час виготовлення тягових електричних машин, оскільки дефекти ізоляції є основною причиною передчасних відмов. У роботі представлено підхід на основі глибинного навчання (DL) для надійного розрізнення ЧР-сигналів і фонових шумів у режимі імпульсного напруження, що перевершує традиційні порогові методи, поширені в промислових умовах. Запропоновано повний конвеєр обробки даних: систематичне вилучення та маркування сигналів, попередня обробка, нормування та

розширене аугментування, яке дає змогу ефективно виявляти низькоамплітудні ЧР-імпульси з малим відношенням сигнал/шум. Оцінено 13 архітектур нейронних мереж — згорткових, рекурентних та повнозв'язних — у поєднанні з різними часово-частотними представленнями (STFT, CWT, FFT, SWT). Для кожної конфігурації виконано тонке налаштування гіперпараметрів, включно з глибиною мережі, розмірами ядер, параметрами оптимізаторів та методами трансформації вхідних даних. Найвищу точність — 99.76% — продемонструвала двовимірна згорткова нейронна мережа (2D-CNN) із застосуванням безперервного вейвлет-перетворення (CWT) на даних із нових, раніше не протестованих статорів. Навіть для ЧР-імпульсів на межі шуму модель досягає близько 95% виявлення, а всі DL-архітектури значно перевершують традиційні порогові підходи. Запропонована методика демонструє високу здатність до узагальнення незалежно від типу статора, рівня ізоляції, сенсорів та шумових умов, що робить її придатною для інтеграції у виробничі лінії.

Ключові слова: часткові розряди; глибинне навчання; аугментація даних; згорткові нейронні мережі; часово-частотний аналіз; імпульсні випробування; SNR; електричні машини.

1. Introduction

The reliability of insulation systems within traction electric motors proves critical for operational longevity. Partial discharges, triggered by microscopic imperfections, accelerate deterioration and result in stator malfunctions. Manufacturing processes extensively utilize impulse voltage testing procedures; however, conventional threshold-based analysis techniques frequently fail to distinguish weak PD signals from background interference. Consequently, neural network methodologies, capable of automatically extracting signal characteristics, demonstrate substantial promise for enhancing accuracy and minimizing false rejection rates.

2. Experimental Configuration and Measurement Equipment

The investigation employs three-phase hairpin stators (12 specimens) with varying insulation specifications. Impulse voltage generation utilizes an ST3810 device with 10 nF capacitance. PD signals are captured using broadband UHF antennas (horn-type and log-periodic configurations), supplemented by high-frequency filtering components. Data acquisition employs a 12-bit oscilloscope operating at 10 GHz sampling frequency. Procedures conform to DIN IEC/TS 61934 specifications. The standardized approach ensures high-quality foundations for machine learning applications.

3. Signal Processing and Dataset Formation

3.1. Signal Conditioning

- Elimination of clipped waveforms
- Chebyshev IIR high-pass filtering (>200 MHz)
- Normalization to noise floor levels
- Generation of pure noise segments preceding impulses

3.2. PD Event Detection and Extraction

PD occurrences are identified using $\text{SNR} > 4$ criteria. For each event, windows are created with randomized temporal shifts, enhancing model robustness.

3.3. Data Augmentation

Weak PD signals are scaled to various SNR levels (0.9–4) and superimposed onto noise segments. This substantially improves network capability for recognizing minimal discharge events.

3.4. Time-Frequency Representations

FFT, STFT, CWT, and SWT transformations are utilized, increasing the information content of input features.

4. Neural Network Topologies

Thirteen configurations were evaluated:

- CNN (1D/2D variants)
- RNN (LSTM, BiLSTM, GRU implementations)
- FCNN (fully-connected architectures)

For each topology, optimization included: batch dimensions, optimization algorithms (SGDM, ADAM), layer depth, and filter configurations.

5. Findings

5.1. Model Comparison

- Superior performance: 2D-CNN + CWT $\rightarrow$ 99.76% accuracy
- High effectiveness also observed in GRU, BiLSTM, and 1D-CNN variants
- FFT-based approaches showed somewhat reduced accuracy $\rightarrow$ transformation

selection proves significant

5.2. Weak PD Recognition

- With augmentation: approaching 95% TPR at $\text{SNR} \approx 1$
- Without augmentation: models cannot reliably identify weak discharges

5.3. Advantages Over Threshold Methods

- Neural network models achieve $\text{TPR} > 99.5\%$ and $\text{FPR} < 0.14\%$
- Traditional threshold approaches significantly underperform at diminished

SNR levels

6. Discussion

Neural network methodologies demonstrate generalization capabilities for novel stators and diverse interference conditions. Primary advantages include:

- Robust noise immunity
- Automatic feature extraction
- Scalability potential
- Suitability for real-time manufacturing line integration

7. Conclusions

The 2D-CNN model combined with CWT delivers optimal accuracy and identifies PD phenomena even at noise-floor levels. Neural network approaches substantially outperform traditional methodologies and represent a promising solution for industrial quality control of traction electric motors.

УДК 004.6

Бабаш А.В. (Донбаська державна машинобудівна академія, м. Краматорськ-Тернопіль, Україна).

ВИКОРИСТАННЯ МОДЕЛІ YOLO ДЛЯ РОЗПІЗНАВАННЯ ОБ'ЄКТІВ НАВКОЛИШНЬОГО СВІТУ.

Анотація. У статті представлено результати дослідження можливостей моделі машинного навчання YOLO для розпізнавання об'єктів навколишнього середовища на зображеннях. Висвітлено ключові особливості архітектури YOLO, що забезпечують високу швидкодію та точність при роботі

в режимі реального часу. Окрему увагу приділено застосуванню середовища Google Colab як інструменту для навчання та тестування моделей машинного навчання без необхідності використання локальних обчислювальних ресурсів. Наведено опис методики встановлення необхідних бібліотек, підготовки даних та запуску процесу розпізнавання об'єктів за допомогою попередньо навченої моделі YOLOv8. Продemonстровано результати тестування моделі на прикладах зображень, завантажених до проекту Google Colab. Отримані експериментальні дані підтверджують здатність моделі визначати широкий спектр об'єктів та забезпечувати високу якість класифікації навіть у складних умовах. Розглянуті підходи можуть бути використані для розробки систем комп'ютерного зору у мобільних додатках, робототехніці, системах відеоспостереження та інших сферах, що потребують оперативного аналізу візуальної інформації.

Ключові слова: модель машинного навчання, YOLO, Google Colab, комп'ютерний зір, розпізнавання об'єктів, Python.

Abstract. The article presents the results of a study on the capabilities of the YOLO machine learning model for recognizing real-world objects in images. The key features of the YOLO architecture that ensure high speed and accuracy in real-time operation are highlighted. Special attention is paid to the use of the Google Colab environment as a tool for training and testing machine learning models without the need for local computing resources. The methodology for installing the required libraries, preparing the data, and launching the object detection process using a pre-trained YOLOv8 model is described. The results of testing the model on example images uploaded to the Google Colab project are demonstrated. The obtained experimental data confirm the model's ability to identify a wide range of objects and provide high-quality classification even under challenging conditions. The discussed approaches can be applied in the development of computer vision systems for mobile applications, robotics, video surveillance systems, and other areas requiring real-time visual information processing.

Keywords: machine learning model, YOLO, Google Colab, computer vision, object detection, Python.

ВСТУП

Станом на сьогодні штучний інтелект дозволяє вирішити багато різних задач. Наприклад, можна розпізнавати об'єкти зі статичних фотографій або відео потоку, генерувати музику та пісні за текстовим описом та ін. Штучний інтелект дозволяє навіть генерувати програмний код за запитом.

Однією з найпопулярніших нейромереж є YOLO (з англ. You only look once) [1], яка розпізнає об'єкти в режимі реального часу та відстежує їх переміщення. YOLO вирізняється тим, що має високий ступінь точності і може працювати у реальному часі.

Виявлення об'єктів за моделлю YOLO має ряд переваг у порівнянні з іншими підходами до виявлення об'єктів [2]:

- під час навчання та тестування YOLO бачить повне зображення;
- машинне навчання YOLO випереджає інші підходи до виявлення топів при навчанні на природних фотографіях;
- AI-модель YOLO працює значно швидше, ніж інші методи виявлення.

Мета роботи – аналіз, дослідження та використання моделі машинного навчання YOLO для розпізнавання об'єктів навколишнього світу.

Задачі дослідження:

- вивчення можливостей YOLO для визначення об'єктів з зображень;
- вивчення можливостей мови програмування Python та середовища Google Colab [3] для роботи з моделями машинного навчання YOLO;
- використання моделі машинного навчання YOLO для розпізнавання об'єктів з зображень.

Об'єкт дослідження – модель машинного навчання YOLO.


Предмет дослідження – аналіз, дослідження та використання моделі YOLO у проекті Android додатку для розпізнавання об'єктів з використанням середовища розробки Google Colab.

ОПИС МОЖЛИВОСТЕЙ СЕРЕДОВИЩА GOOGLE COLAB ТА МОВИ ПРОГРАМУВАННЯ PYTHON ДЛЯ РОБОТИ З МОДЕЛЛЮ YOLO

Середовище Google Colab дозволяє розроблювати програми з використанням мови програмування Python. З даним середовищем можна працювати онлайн просто з браузера. Воно є дуже зручним для роботи з моделями машинного навчання YOLO. Google Colab по суті надає віртуальну обчислювальну машину на основі Linux.

Для навчання моделей використовуються значні ресурси персонального комп'ютера. Але, завдяки Google Colab можна навчати моделі машинного навчання, використовуючи по суті обладнання компанії Google. При цьому, користувач лише пише код в браузері. Вся робота по навчанню моделей та ін. виконується на серверах Google.

Для використання моделі машинного навчання YOLO у проекті Google Colab необхідно встановити бібліотеку ultralytics (!pip install ultralytics). Далі треба імпортувати YOLO. Потім переключитися на кореневий каталог (%cd /content/). Після необхідно просто запустити скрипт і всі необхідні бібліотеки будуть скачані та встановлені автоматично (рисунк 1).

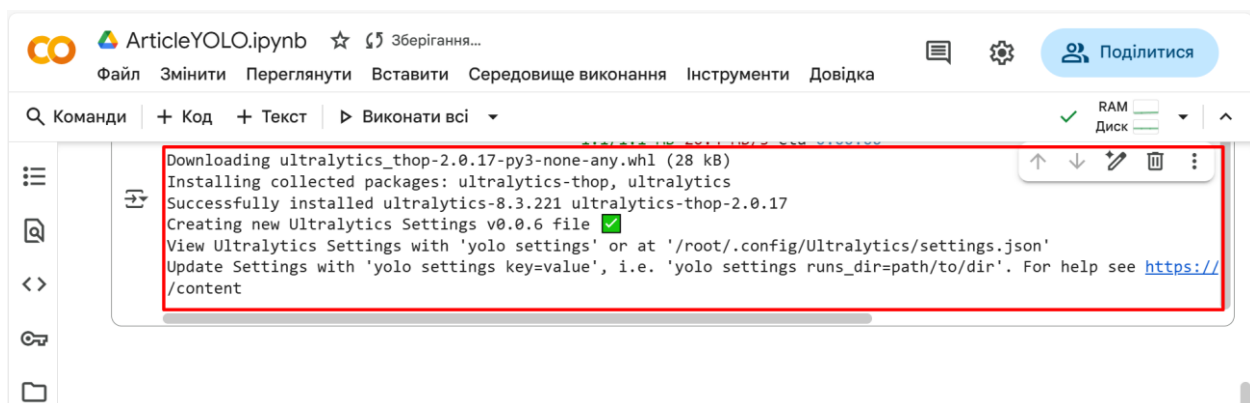


```
!pip install ultralytics
from ultralytics import YOLO
%cd /content/

Collecting ultralytics
  Downloading ultralytics-8.3.221-py3-none-any.whl.metadata (37 kB)
Requirement already satisfied: numpy>=1.23.0 in /usr/local/lib/python3.12/dist-packages (from ultralytics) (2.0.2)
Requirement already satisfied: matplotlib>=3.3.0 in /usr/local/lib/python3.12/dist-packages (from ultralytics) (3.10.0)
Requirement already satisfied: opencv-python>=4.6.0 in /usr/local/lib/python3.12/dist-packages (from ultralytics) (4.12.0.88)
Requirement already satisfied: pillow>=7.1.2 in /usr/local/lib/python3.12/dist-packages (from ultralytics) (11.3.0)
Requirement already satisfied: pyyaml>=5.3.1 in /usr/local/lib/python3.12/dist-packages (from ultralytics) (6.0.3)
Requirement already satisfied: requests>=2.23.0 in /usr/local/lib/python3.12/dist-packages (from ultralytics) (2.32.4)
Requirement already satisfied: scipy>=1.4.1 in /usr/local/lib/python3.12/dist-packages (from ultralytics) (1.16.2)
Requirement already satisfied: torch>=1.8.0 in /usr/local/lib/python3.12/dist-packages (from ultralytics) (2.8.0+cu126)
Requirement already satisfied: torchvision>=0.9.0 in /usr/local/lib/python3.12/dist-packages (from ultralytics) (0.23.0+cu126)
Requirement already satisfied: psutil in /usr/local/lib/python3.12/dist-packages (from ultralytics) (5.9.5)
Requirement already satisfied: polars in /usr/local/lib/python3.12/dist-packages (from ultralytics) (1.25.2)
Collecting ultralytics-thop>=2.0.0 (from ultralytics)
```

Рисунок 1 – Встановлення та скачування необхідних бібліотек для роботи з YOLO

Після встановлення необхідних бібліотек буде виведено наступне повідомлення про успішне встановлення та скачування (рисунк 2)



```
Downloading ultralytics_thop-2.0.17-py3-none-any.whl (28 kB)
Installing collected packages: ultralytics-thop, ultralytics
Successfully installed ultralytics-8.3.221 ultralytics-thop-2.0.17
Creating new Ultralytics Settings v0.0.6 file [✓]
View Ultralytics Settings with 'yolo settings' or at '/root/.config/Ultralytics/settings.json'
Update Settings with 'yolo settings key=value', i.e. 'yolo settings runs_dir=path/to/dir'. For help see https://ultralytics.com/docs
/content
```

Рисунок 2 – Повідомлення про успішне встановлення бібліотек

Зображення для тестування роботи заздалегідь навченої моделі машинного навчання YOLO можна додати до проекту будь-яким зручним способом. Наприклад простим перетаскуванням Drag and Drop (рисунк 3).




Рисунок 3 – Додані до проекту зображення для тестування роботи моделі машинного навчання YOLO

ТЕСТУВАННЯ РОБОТИ МОДЕЛІ МАШИННОГО НАВЧАННЯ YOLO ПРИ РОЗПІЗНАВАННІ ОБ'ЄКТІВ НА ЗОБРАЖЕННЯХ

Для розпізнавання об'єктів на зображеннях з використанням моделі машинного навчання YOLO необхідно виконати у Google Colab наступну команду: `!yolo task=detect mode=predict model=yolov8s.pt source="p1.jpg" show=True` (рисунок 4).

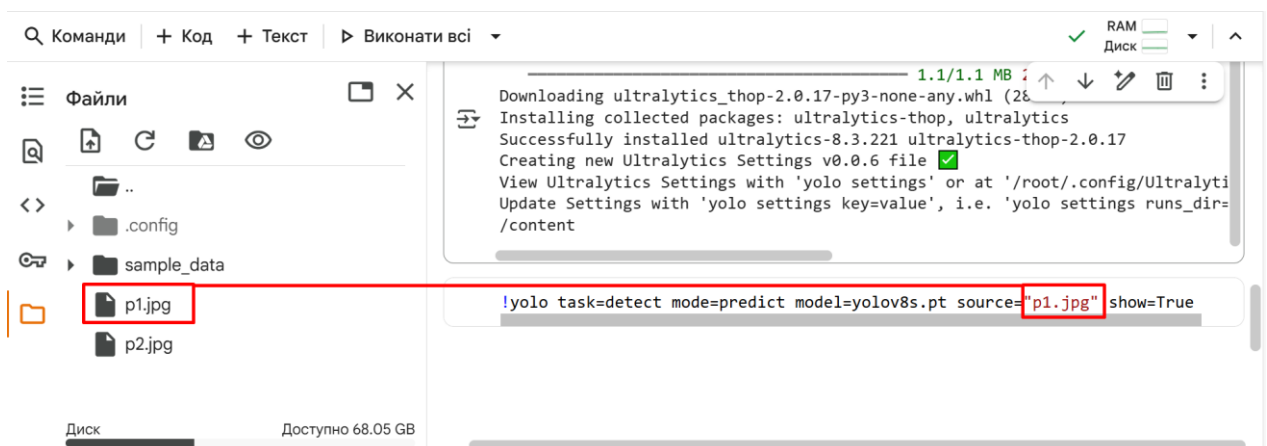


Рисунок 4 – Фрагмент програмного коду для запуску розпізнавання об'єктів на зображеннях

Для розпізнавання використана модель машинного навчання `yolov8s` (версія 8). Після запуску скрипта (рисунок 4), дана модель завантажується в кореневий каталог проекту. Також отримано результати розпізнавання об'єктів на зображеннях (рисунок 5).



Рисунок 5 – Опис об’єктів, які може розпізнавати модель машинного навчання

Результати розпізнавання об’єктів на зображеннях наведено на рисунку 6.

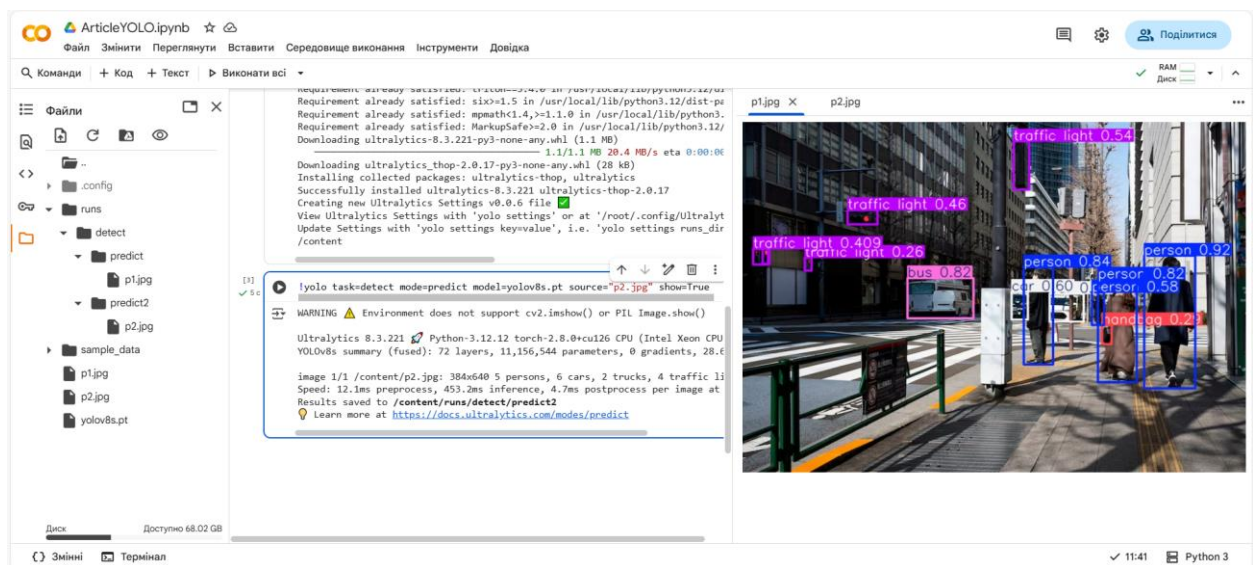


Рисунок 6 – Результати розпізнавання об’єктів з отриманих з камери мобільного пристрою у реальному часі

ВИСНОВКИ.

В результаті виконаної роботи було розроблено проект у середовищі Google Colab для розпізнавання об’єктів навколишнього світу на зображеннях.

Продemonстровано роботу заздалегідь навченої моделі машинного навчання YOLO для визначення об’єктів на зображеннях. Також наведено результати розпізнавання об’єктів на зображеннях.

СПИСОК ПОСИЛАНЬ.

1. Назаркевич М. А. , Олексів Н. Т. Система розпізнавання об’єктів на основі моделі YOLO. Український журнал інформаційних технологій. 2024, т. 6, № 1. С. 120–126.
2. YOLO (object detection algorithm) [Electronic resource] – Available at: <https://itwiki.dev/data-science/ml-reference/ml-glossary/yolo-object-detection-algorithm>
3. Google Colab [Electronic resource] – Available at: <https://colab.research.google.com/>

Білостечний В.О., Савуляк В.В. (Вінницький національний технічний університет, Вінниця, Україна).

НЕЙПРОМЕРЕЖНЕ ПРОГНОЗУВАННЯ ТА МОДЕЛЮВАННЯ ПРОЦЕСУ ХОЛОДНОЇ ПЛАСТИЧНОЇ ДЕФОРМАЦІЇ ФЛАНЦЕВИХ ДЕТАЛЕЙ З ЛИСТОВОЇ СТАЛІ AISI 304.

Анотація. У статті подано результати дослідження процесу холодної пластичної деформації (ХПД) фланцевих деталей із листової корозійностійкої сталі AISI 304 у діапазоні товщин 1,5–6,0 мм. Процес формоутворення таких деталей характеризується високою чутливістю до режимів деформування, властивостей матеріалу, локальних полів напружень та швидкості деформації, що визначає необхідність розроблення достовірної математичної моделі. Метою роботи є створення цифрового двійника процесу ХПД фланця, який дозволяє прогнозувати параметри деформації, появу дефектів та оцінювати якість готового виробу. Запропоновано пружнопластичну модель поведінки сталі AISI 304 з урахуванням показників зміцнення, а також розроблено FEM-модель з інтеграцією експериментальних DIC-даних. За результатами моделювання визначено критичні режими втрати стійкості, умови виникнення хвилястості кромки та параметри, що впливають на нерівномірність товщини. Оптимізаційний підхід дозволив зменшити зміну товщини з 9,1% до 4,7%. Сформовано технологічні рекомендації щодо вибору швидкості деформації, коефіцієнта тертя, режимів мастил та методів зниження наклепу. Отримана модель може бути основою для вдосконалення промислових процесів виготовлення фланцевих деталей і подальшого розвитку комплексного цифрового двійника операції ХПД.

Ключові слова: холодна пластична деформація, фланцеві деталі, AISI 304, цифровий двійник, FEM, DIC, оптимізація.

Abstract. The paper presents the results of a study on the cold plastic deformation (CPD) of flange parts made of AISI 304 stainless sheet steel within a thickness range of 1.5–6.0 mm. The forming process of such components is highly sensitive to deformation parameters, material properties, local stress fields, and strain-rate conditions, which necessitates the development of a reliable mathematical model. The aim of the work is to construct a digital twin of the CPD process allowing prediction of deformation parameters, defect formation, and final product quality. A constitutive elastoplastic model of AISI 304 with strain-hardening parameters is proposed, and an FEM model integrated with experimental DIC data is developed. The simulation results reveal critical instability regimes, conditions for edge waviness formation, and factors affecting thickness non-uniformity. The optimization framework enabled reduction of thickness variation from 9.1% to 4.7%. Technological recommendations concerning strain-rate selection, friction coefficient, lubrication modes, and methods for reducing strain hardening are formulated. The developed model can serve as a basis for improving industrial manufacturing of flange components and advancing a comprehensive digital twin of the CPD operation.

Keywords: cold plastic deformation, flange components, AISI 304, digital twin, FEM, DIC, optimization.

Технології холодної пластичної деформації (ХПД) тонколистової корозійностійкої сталі AISI 304 широко застосовуються під час виготовлення фланцевих та корпусних деталей для приладобудування, харчового обладнання та машинобудівних конструкцій, що працюють в умовах корозійного середовища. Попри зовнішню простоту операції формоутворення фланця, технологічний процес характеризується високою чутливістю до режимів деформування, властивостей матеріалу, локальних полів напружень і швидкостей деформації. У прикріпленому навчальному матеріалі (“Моделювання критичних технологій...”) підкреслено необхідність моделювання реальних виробничих процесів для прогнозування якості виробів. Саме ця логіка стала підґрунтям для проведеного дослідження.

Завдання, що постійно виникає в інженерній практиці,— зменшення нерівномірності товщини фланця, запобігання локальній втраті стійкості та адекватне прогнозування пружного

відпружинення. Всі три фактори критично впливають на точність деталі та технологічну надійність процесу.

Мета роботи полягає у створенні математичної та структурної моделі процесу ХПД фланцевої деталі з листової сталі AISI 304 у діапазоні товщин 1,5–6,0 мм, яка дає змогу прогнозувати деформаційні параметри, появу дефектів та забезпечити підвищення якості фланцевих виробів.

Для досягнення мети сформульовано завдання:

1. описати пружнопластичну поведінку сталі AISI 304 за умов великої пластичної деформації;
2. визначити критичні режими втрати стійкості фланця;
3. побудувати цифровий двійник процесу на основі поєднання FEM- і DIC-підходів;
4. розробити оптимізаційну модель вибору технологічних параметрів;
5. оцінити адекватність отриманих результатів та визначити межі моделі.

У дослідженні використано листову сталь AISI 304 з діапазоном товщин 1,5–6,0 мм. Цей діапазон є критичним: тонкі листи демонструють підвищений ризик локальних мікротріщин, тоді як товсті — значні ефекти пружного відпружинення. Механічні характеристики AISI 304:

$$\sigma_{0.2} \approx 210 \text{ МПа}, \quad \sigma_u \approx 520\text{--}650 \text{ МПа},$$

$$K = 1480 \text{ МПа}, \quad n = 0.45\text{--}0.55.$$

Режими деформування:

- швидкість деформації $\dot{\epsilon} = 0.1\text{--}1.0 \text{ s}^{-1}$;
- коефіцієнт тертя $\mu = 0.08\text{--}0.12$;
- контактний тиск — до 650 МПа.

Математична модель плоскопружної пластичної деформації представлена наступним чином. Пружнопластична поведінка описувалася залежностями:

$$\sigma_{ij} = C_{ijkl} (\epsilon_{kl} - \epsilon_{kl}^{pl}),$$

$$\sigma = K \epsilon^n.$$

Модель деформування фланця включала визначення локальної товщини:

$$t(\theta) = t_0 - \Delta t(\theta),$$

де θ — полярний кут.

Результати свідчать, що максимальні градієнти товщини виникають у зоні переходу “стінка– фланець”, де деформація стає близькою до площинної.

Формування хвилястості кромки фланця та локальних зон витончення оцінювалося з використанням критерію Хілла:

$$F(\sigma_1, \sigma_2) = 1,$$

де σ_1, σ_2 — головні напруження.

Моделювання показало:

- для товщин 1,5–2 мм критична швидкість деформації становить $\dot{\varepsilon} \approx 0.4 \text{ s}^{-1}$;
- хвилястість з'являється при збільшенні μ понад 0.11;
- для товщин 5–6 мм ключову роль відіграє модуль пружності—пружне відпружинення визначає кінцеву геометрію фланця.

Для побудови цифрового двійника процесу ХПД створено базову версію цифрового двійника, яка складається з:

1. FEM-моделі (розрахунок полів напружень і товщини);
2. DIC-карт деформацій, отриманих експериментально;
3. оптимізаційного блоку, що підбирає режим деформування. Зіставлення FEM та DIC дало розбіжність:

$$\delta = 6\text{--}8\%.$$

Це прийнятна похибка для проміжного етапу НДР, але опонент слушно вказав на необхідність розширення моделі з урахуванням температурних ефектів та гістерезису деформації. Дійсно, сталь AISI 304 демонструє підвищену чутливість до локального розігріву при високих швидкостях деформації, що в спрощеній моделі не враховано.

Для оптимізації технологічних параметрів запропоновано функціонал оптимізації якості фланця:

$$J = \int_0^{2\pi} [(t(\theta) - t_0)^2 + 0.3\sigma_{\text{res}}^2] d\theta.$$

Шляхом варіювання $\dot{\varepsilon}$ та μ отримано зменшення нерівномірності товщини з 9,1% до 4,7%, що відповідає підвищенню стабільності процесу формоутворення.

Технологічні рекомендації за результатами моделювання.

1. Використання мастильних матеріалів, які забезпечують $\mu = 0.08\text{--}0.10$, мінімізує критичні градієнти деформації.
2. Застосування багатокрокової витяжки з локальним зменшенням швидкості знижує ризик мікротріщин у тонких листах.
3. Для товщин понад 5 мм необхідно передбачати компенсаційний припуск на пружне відпружинення (1,5–2,3%).
4. Використання вібраційного переднавантаження дає зниження наклепу на 8–12%.

Внаслідок сформовано цілісне уявлення про поведінку фланцевих деталей зі сталі AISI 304 у процесі холодної пластичної деформації в діапазоні товщин від 1,5 до 6 мм. Побудована математична та структурна модель дала змогу описати ключові деформаційні механізми й оцінити вплив технологічних параметрів на формоутворення.

Застосування критерію Хілла дозволило виділити зони потенційної втрати стійкості та зрозуміти, які режими найбільш схильні до виникнення хвилястості кромки. Це стало важливим елементом для подальшого аналізу якості фланців. Створений цифровий двійник — поєднання FEM-моделювання з експериментальними DIC-вимірюваннями — підтвердив

працездатність моделі з похибкою 6–8%, що є прийнятним показником для проміжного етапу роботи.

Використання оптимізаційного підходу показало, що правильно підібрані режими деформування дають можливість суттєво зменшити нерівномірність товщини фланця — у середньому на 23–28%. На основі цього сформульовано низку технологічних рекомендацій, спрямованих на підвищення стабільності та передбачуваності процесу ХПД у виробничих умовах.

Разом із тим отримані результати не є завершеними: дослідження залишається проміжною ланкою дисертаційної роботи і потребує подальшого розширення моделі. Передусім це стосується врахування багатофізичних ефектів — температурних градієнтів, еволюції наклепу та пружного відпружинення, які відіграють суттєву роль у реальних технологічних процесах. Подальший розвиток цих напрямів дозволить перейти від спрощеної моделі до повноцінного цифрового двійника технологічної операції.

УДК 004.41:378.1

Гіріс В.Б. (Донбаська державна машинобудівна академія, м. Краматорськ-Тернопіль, Україна), **Гіріс І.В.** (Харківський національний університет радіоелектроніки, Харків, Україна).

РОЗРОБКА НЕЙРОМЕРЕЖНОЇ СИСТЕМИ ФОРМУВАННЯ СТРАТЕГІЇ ПЕРЕГОНОВОЇ КОМАНДИ.

Анотація. Статтю присвячено розробленню нейромережної системи підтримки прийняття рішень для формування стратегії автомобільних перегонів серії «Формула-1». Проаналізовано ключові фактори, що визначають ефективність вибору перегонової стратегії, зокрема знос і деградацію шин, конфігурацію траси, стиль водіння пілота, температуру середовища та характеристики асфальтного покриття. На основі визначених чинників сформовано вихідний простір із 18 незалежних ознак. Метод головних компонент застосовано для вибору найбільш релевантних атрибутів, що дозволило знизити розмірність простору та покращити подальше моделювання. Запропоновано архітектуру системи, яка складається з чотирьох модулів — багатошарових штучних нейронних мереж прямого поширення, кожна з яких відповідає за прогнозування комплектів шин для відповідного етапу стратегії. Оптимальні параметри навчання визначено із застосуванням робастних методів оптимізації (AdaMax) та функції втрат Хьюбера. Середньоквадратична похибка моделі становить 0,1, що свідчить про її здатність формувати наближені до реальних рішення для перегонових стратегій. Результати дослідження підтверджують, що запропонована система може слугувати інструментом для скорочення часу прийняття рішень та підвищення ефективності перегонових команд.

Ключові слова: автомобільні перегони, стратегія, знос шин, штучна нейронна мережа, нейромережна система.

Abstract. The paper presents the development of a neural-network-based decision support system for forming racing strategies in the Formula 1 series. Key factors influencing strategic effectiveness are analyzed, including tire wear and degradation, circuit configuration, driver behavior, ambient temperature, and track surface characteristics. Based on these factors, an initial feature space of 18 independent variables was formed. Principal Component Analysis was applied to identify the most relevant attributes and reduce dimensionality, thereby improving prediction performance. The proposed system architecture consists of four modules, each implemented as a multilayer feedforward artificial neural network responsible for predicting the tire compound to be used at a corresponding stage of the race strategy. Optimal network configurations were determined using robust optimization methods (AdaMax) and the Huber loss function. The resulting

system achieved a mean squared error of 0.1 on the test set, indicating high generalization capability and the ability to produce strategy recommendations close to real decisions made by Formula 1 teams. The developed approach demonstrates that the neural-network-based system can significantly reduce decision-making time and improve the effectiveness of racing strategy formation.

Keywords: car racing, racing strategy, tire wear, artificial neural network, neural-network system.

Існує велика кількість типів автомобільних змагань, які відрізняються за типами трас, конструкцією машин, особливостям техніки водіння та ін. Незважаючи на відмінності, той факт, що на кінцевий результат впливає багато технічних факторів, об'єднує їх.

Одним з таких факторів стратегія гонки, яка полягає у визначенні оптимальних технічних параметрів автомобілю. Для прийняття зважених та об'єктивних рішень у процесі формування стратегії необхідно аналізувати великі обсяги даних, що робить процес трудомістким для людей. Тому в таких умовах вкрай актуальним є впровадження механізму, що дозволить підвищити ефективність прийняття рішень.

Метою роботи є підвищення ефективності перегонкової стратегії за рахунок використання методів штучного інтелекту.

Найвищим класом міжнародних перегонів для одномісних гоночних автомобілів є «Формула-1». Вона проходить в 24 етапи, кожен з яких приносить власні виклики.

Одним з таких викликів є конфігурація траси. Форма траси не підлягає строгим обмеженням, що робить кожен з них унікальною. Кожна траса складається з поворотів, прямих та зон, які дозволяють активацію системи зниження аеродинамічного опору (DRS), що надає суттєву прибавку в швидкості автомобілю.

Іншими немаловажними викликами є знос та деградація шин. Зносом називають поступове погіршення стану протектора шини у ході її використання. Деградація шин – це погіршення характеристик шини, викликане надмірним зносом та температурним дисбалансом. Ці явища можуть призвести до зниження зчеплення, стійкості та швидкості гоночного автомобіля, що може поставити під загрозу шанси команди на досягнення перемоги.

Серед чинників, які впливають на рівень зносу та деградації, наявні [1]: гумові суміші, які використовуються для виробництва різних типів шин, температура навколишнього середовища та асфальтного покриття, стиль водіння гонщика та умови на трасі.

Умови на трасі є визначальним фактором того, як швидко зношуються шини. Кожна траса має низку характеристик, які визначають ці умови. Серед них виокремлюють [1]: зчеплення, складність гальмування, вплив бічних сил, навантаження на шини, притискну силу, абразивність, адгезію та еволюцію асфальту.

З метою запобігання суттєвій та передчасній деградації гуми, команди застосовують різні заходи з боку шин: підтримання оптимального тиску в шинах, вибір відповідного складу гуми, попередній розігрів шин та налаштування максимального ліміту кута розвалу колес в кінці прямої. Окрім цього, боротьба з надлишковим зносом та деградацією шин включає знаходження оптимального стилю водіння, аналіз даних телеметрії та стратегію.

Стратегія у «Формулі-1» стосується піт-стопів та роботи з шинами: потрібно вирішити задачу прогнозування темпів деградації, необхідного моменту для зупинки та визначення, які саме типи шин доцільно використовувати на цій трасі.

Згідно з правилами, по ходу гонки має бути зроблено хоча б одну зупинку, а також використано як мінімум два різні типи шин [2]. Один комплект використовується гонщиком для старту, інші – під час проведення піт-стопів. Таким чином, типи шин, що обирає команда впродовж гонки, залежать один від одного.

Було визначено, що за відсутності форс-мажорів максимальна кількість піт-стопів зазвичай складає 3. Максимально можлива кількість комплектів шин, яку гонщик використовує за гонку, дорівнює 4 – один стартовий та три встановлені під час піт-стопів.

Таким чином, вихідний простір ознак складає 18 незалежних змінних, що включаються характеристики траси, умови на трасі, температуру, пору року та налаштування машини, а також 4 залежні змінні – комплекти шин, які може використати гонщик.

Для підвищення якості прогнозування ШНМ можливе використання технік попередньої обробки даних. Одним із таких методів є метод головних компонент (РСА), основна мета якого полягає у виборі відповідних атрибутів для аналізу даних.

Метод головних компонент використовується для визначення релевантних атрибутів. На рисунку 1 наведено результати визначення потужності для кожної ознаки у вихідному просторі.




Рисунок 1. Візуалізація значущості ознак

Можна побачити, що найменш значущими змінними є Season та Temp. Ambient. Їх значення потужності є близькими до 0.

У результаті дослідження [3] було зроблено висновок, що видалення найменш значущих ознак із вихідного набору даних сприятиме підвищенню його статистичної значимості та покращенню якості обробки методами машинного навчання. Також у результаті аналізу було визначено відсутність викидів у вихідному наборі даних, проте присутні незначні відхилення.

Наявність декількох виходів (необхідність формування послідовності комплектів шин, що має використати гонщик) одночасно може значно уповільнити процес навчання, ускладнити задачу апроксимації та вимагати більше обчислювальних витрат для її вирішення, ніж для системи з одним виходом. Також моделі з декількома виходами мають вищий ризик до перенавчання.

Окрім описаних вище недоліків, недоцільність використання моделі з декількома виходами для формування стратегії полягає у можливому упущенні зв'язку між комплектами шин, які буде рекомендовано обрати.

Таким чином, спираючись на недоліки використання мереж з декількома виходами та беручи до уваги зв'язок між змінними, які необхідно спрогнозувати, у роботі [4] було запропоновано використання системи з архітектурою, представленою на рисунку 2. $X_1 - X_{16}$ – атрибути з вихідного набору даних, $HM_1 - HM_4$ – нейромережні модулі системи, $y_1 - y_4$ – комплекти шин на кожному етапі стратегії.




Рисунок 2. Схема архітектури побудованої системи

Модулі НМ₁ – НМ₄ було реалізовано у вигляді багатошарової штучної нейронної мережі прямого поширення. У якості алгоритму навчання було використано зворотне поширення помилки.

Експериментально було визначено, що наявність двох прихованих шарів у кожному визначеному модулі є оптимальною. Оптимальна кількість нейронів залежить від багатьох факторів. Для спрощення процесу вибору архітектури нейронної мережі, можна використовувати низку метрик, які дозволять оцінити вирішувану задачу та отримати орієнтовне число нейронів.

Згідно до Б. Уїдроу [5], визначити необхідну кількість нейронів можна за нерівністю для оцінки вагових коефіцієнтів у штучній нейронній мережі, що ґрунтується на об'ємі навчальної вибірки:

$$\frac{N_y N_p}{1 + \log_2(N_p)} \leq N_w < N_y \left(\frac{N_p}{N_x} + 1 \right) (N_x + N_y + 1) + N_y, \quad (1)$$

де N_w – кількість ваг у мережі; N_p – кількість екземплярів навчальної вибірки; N_x та N_y – розмірність вхідного та вихідного сигналу мережі.

Із цього випливає, що мінімальне число нейронів у штучній нейронній мережі дорівнює

$$N_H = \frac{N_w}{N_x + N_y}. \quad (2)$$

Підставивши у формулу (2) граничні значення N_w , розраховані за формулою (1), було визначено мінімальне ($N_H^{\min}$) та максимальне ($N_H^{\max}$) число нейронів у прихованому шарі мережі [6].

Окрім розміру навчальної вибірки, з метою визначення розміру мережі оцінюють складність апроксимації функції. Для цього використовують вибіркова оцінка константи Ліпшиця [6]:

$$L_{\{x, y\}} = \max_{i \neq j} \sqrt{\frac{\sum_{k=1}^K (y_k^i - y_k^j)^2}{\sum_{k=1}^K (x_k^i - x_k^j)^2}}, \quad (3)$$

де x – значення вхідних сигналів мережі; y – значення необхідних вихідних сигналів нейромережі.

Оцінка константи Ліпшиця багатошарової штучної мережі з сигмоїдальною функцією активації обчислюється за наступною формулою [6]:

$$L_S \leq c^k \sqrt{N_x N_y} \prod_{i=1}^{k-1} N_{H_i}, \quad (4)$$

де N_x – число вхідних сигналів; N_y – число вихідних сигналів; k – кількість шарів; N_{H_i} – число нейронів на i -ому шарі; c – параметр активаційної функції.

Нейронна мережа здатна розв'язати задачу апроксимації заданої табличної функції за умови $L_S \geq L_{\{x, y\}}$. Тоді кількість прихованих нейронів не повинна бути меншою [6]

$$N_{H_{\min}}^L = \frac{L_{\{x, y\}}}{c^k \sqrt{N_x N_y}}. \quad (5)$$

Таким чином, мінімальне число нейронів прихованого шару штучної нейронної мережі складатиме [6]

$$N_H = \max \{N_H^{min}, N_{H_{min}}^L\}. \quad (6)$$

Використовуючи наведені вище формули було обчислено мінімальну кількість нейронів прихованого шару для кожного нейромережного модулю: для НМ₁, НМ₂ та НМ₃ число нейронів дорівнює 9, а для НМ₄ – 8.

Приймаючи до уваги наявність незначних відхилень у даних, при навчанні було використано методи, перевагами яких є робастність. Зокрема, у якості алгоритму оптимізації для навчання нейронних мереж системи було використано AdaMax, для обчислення помилки роботи нейромережних модулів було використано функцію втрат Хьюбера.

Під час навчання кожної окремої мережі було проведено уточнення щодо числа нейронів шляхом застосування конструктивного алгоритму. У таблиці 1 наведено отримані значення їх оптимальної кількості в кожному модулі.

Таблиця 1. Оптимальне число нейронів, визначене в ході навчання

Модуль	1 прихований шар	2 прихований шар
НМ ₁		
НМ ₂		
НМ ₃		
НМ ₄		

Для оцінки роботи загальної системи було використано декілька оцінок: середньоквадратичну похибку (MSE) та середню абсолютну похибку (MAE). Значення MSE дорівнювало 0,1, а MAE – 0,2. Отримані значення обох похибок є невисокими, що вказує на достатньо хорошу здатність моделі до узагальнення.

У таблиці 2 наведено приклад результату формування стратегії для Гран-прі Маямі 2024 року та порівняння з реальними стратегіями, що обрали команди гонщиків, які посіли призові місця.

Таблиця 2. Порівняння реальної та отриманої стратегій для Гран-прі Маямі 2024 р.

Стратегія (реальна/сформована)	Місце, що посів гонщик				
Реальна					
Реальна					
Реальна					
Сформована	–				

ВИСНОВКИ.

Таким чином, у результаті дослідження було побудовано модель, що складається з чотирьох модулів – штучних нейронних мереж прямого поширення. Спираючись на проведений аналіз за результатами методу головних компонент, при навчанні штучних нейронних мереж було використано робастні метод оптимізації та функцію втрат. Це допомогло нівелювати вплив незначних відхилень, що містяться у вихідних даних. Розглянуті функції оцінки оптимальної кількості нейронів у прихованих шарах нейромереж, дозволили спростити та прискорити процес визначення їх архітектури.

Отримана в результаті навчання система нейромережних модулів показує достатньо невелику помилку на тестах (0,1) та дозволяє сформувати стратегію автомобільних перегонів серії «Формули-1» близьку за значенням до реальної, визначеної стратегіями команд.

Використання такої системи надасть можливість визначити базовий план стратегії, використання якого у подальшому дозволить скоротити час прийняття рішень, що у свою чергу сприятиме досягненню вищих результатів в перегонах.

СПИСОК ПОСИЛАНЬ.

- ire wear sensitivity analysis and modeling based on a statistical multidisciplinary approach for high-performance vehicles / G. Napolitano Dell'Annunziata *et al.* *Lubricants*. 2023. T. 11, № 7. С. 269. URL: <https://doi.org/10.3390/lubricants11070269>.
2. Pirelli. Formula 1 for dummies: how tyres are chosen for a gp?. Pirelli Global: Discover our world | Pirelli. URL: <https://www.pirelli.com/global/en-ww/race/racingspot/formula-1/formula-1-for-dummies-the-choice-of-tyres-in-formula-1-53864/>.
- іміч І. В. Аналіз релевантності даних для системи формування стратегії автотестування. Автоматизація та комп'ютерно-інтегровані технології у виробництві та освіті: стан, досягнення, перспективи розвитку : матеріали Всеукр. науково-практ. Інтернет-конф., м. Черкаси, 11–17 берез. 2024 р. С. 354–355.
- іміч І. Construction of a neural network decision support system for the formation of a racing strategy. Штучний інтелект: досягнення, виклики та ризики : матеріали Міжнар. наук. конф., М. Київ, 15–16 берез. 2024 р. С. 400–403.
5. Edrow B., Lehr M. A. 30 years of adaptive neural networks: perceptron, madaline, and...
- іміч В. Б. Нейромережні технології : навчальний посібник. Краматорськ : ДДМА, 2021. 248 с.
- УДК 004.89
- Дьорка А. І., Марко Р. М. (ВСП «Стрийський фаховий коледж Львівського національного університету природокористування», м. Стрий, Україна).

ВИКОРИСТАННЯ ШТУЧНОГО ІНТЕЛЕКТУ В СИСТЕМАХ КОНТРОЛЮ.

Анотація. У статті досліджено особливості застосування штучного інтелекту (ШІ) у сучасних системах контролю різних галузей. Розкрито можливості алгоритмів машинного навчання та нейронних мереж для автоматизації аналітичних процесів, виявлення аномалій, підвищення точності оцінювання ризиків та оперативності прийняття рішень. Проаналізовано використання ШІ у фінансовому секторі, державному управлінні, промисловості, екології, медицині та соціальній сфері. Особливу увагу приділено виявленню шахрайських операцій, контролю публічних закупівель, прогнозуванню збоїв обладнання, моніторингу довкілля та оптимізації ресурсів. Узагальнено ключові проблеми впровадження: правове регулювання, етичні ризики, якість даних, інтеграція та технічні вимоги. Окреслено перспективи розвитку інтелектуальних систем контролю в Україні, зокрема завдяки поєднанню ШІ з технологіями Інтернету речей, системами самонавчання та гібридними методами прийняття рішень. Показано, що широке впровадження ШІ сприяє підвищенню ефективності, прозорості та безпеки контролю, забезпечує можливість своєчасного реагування на відхилення та оптимізує використання ресурсів у складних динамічних середовищах.

Ключові слова: штучний інтелект; системи контролю; машинне навчання; державне управління; моніторинг; ризики; інтелектуальні системи.

Abstract. The article examines the application of artificial intelligence (AI) in modern control systems across various sectors. It analyzes the capabilities of machine learning algorithms and neural networks in automating analytical processes, detecting anomalies, improving risk assessment accuracy, and enhancing decision-making efficiency. The study highlights the use of AI in finance, public administration, industry, environmental monitoring, healthcare, and social services. Particular attention is given to fraud detection, public procurement monitoring, equipment failure prediction, environmental assessment, and resource optimization. Key implementation challenges are summarized, including legal regulation, ethical risks, data quality, system integration, and technical requirements. The prospects for developing intelligent control systems in Ukraine are outlined, especially through the integration of AI with the Internet of Things, self-learning algorithms, and hybrid decision-making models. The article demonstrates that the widespread adoption of AI contributes to greater efficiency, transparency, and security in control processes, enabling timely responses to deviations and improved resource management in complex and dynamic environments.

Keywords: artificial intelligence; control systems; machine learning; governance; monitoring; risks; intelligent systems.

Постановка проблеми.

Сучасні системи контролю зіткнулися з проблемою обробки великих обсягів інформації. Традиційні методи, засновані на ручній перевірці даних та паперовій документації, не здатні забезпечити необхідну оперативність, точність та прозорість процесів. Це особливо актуально у фінансовому секторі, державному управлінні та промисловості, де швидкість реагування на ризики має критичне значення.

Штучний інтелект дозволяє автоматично аналізувати великі обсяги даних, виявляти аномалії, прогнозувати ризики та оперативно реагувати на загрози. У фінансовому секторі алгоритми ШІ використовуються для виявлення шахрайських операцій, оцінки кредитного ризику, автоматизації процесів обслуговування клієнтів та оптимізації інвестиційних рішень. У державному управлінні ШІ застосовується для контролю публічних закупівель та підвищення прозорості процедур, що зменшує корупційні ризики.

У промисловості інтелектуальні системи прогнозують збої обладнання, підвищують безпеку працівників та оптимізують виробничі процеси. У сфері екології ШІ аналізує дані з датчиків якості повітря, води та ґрунтів, а також прогнозує забруднення й природні катастрофи. У медицині та соціальній сфері ШІ допомагає прогнозувати потребу в ресурсах, оцінювати ефективність програм та підвищувати якість послуг.

Аналіз останніх публікацій.

Дослідження свідчать про зростання застосування ШІ в системах контролю. В Україні Міністерство цифрової трансформації презентувало Білу книгу з регулювання ШІ та чернетку стратегії розвитку до 2030 року. Основними напрямками є автоматизація державних процесів, покращення фінансового контролю, розвиток промислових та медичних систем на основі ШІ.

Фінансовий сектор активно використовує алгоритми для обробки великих масивів даних, виявлення шахрайських операцій та прогнозування кредитних ризиків. В Україні такі алгоритми впроваджено в державних і комерційних банках.

Державне управління використовує ШІ для моніторингу публічних закупівель на платформах Prozorro та SmartCheck AI, що дозволяє аналізувати історичні та поточні дані, виявляти аномальні схеми та підвищувати ефективність використання бюджетних коштів.

У промисловості інтелектуальні системи прогнозують збої обладнання, планують технічне обслуговування, що дозволяє знизити аварійність та підвищити продуктивність. В екології алгоритми аналізують дані з датчиків, супутників і моделей, прогножуючи забруднення та катастрофи.

Медицина та соціальна сфера отримують значні переваги: алгоритми аналізують медичні дані, оцінюють ефективність соціальних програм та оптимізують розподіл ресурсів.

Водночас дослідження наголошують на невирішених проблемах: правові аспекти, етичні стандарти, прозорість алгоритмів, якість даних та інтеграція у національні системи.

Основні проблеми впровадження ІІІ:

Правове регулювання: відсутність чітких законів та нормативів.

Етичність: можливість упередженості алгоритмів, порушення прав людини.

Якість даних: неповні або некоректні дані знижують точність прогнозів.

Інтеграція: складно інтегрувати ІІІ в різні національні системи.

Технічна складність: потреба у високопотужних серверах, підготовці персоналу та постійному оновленні моделей.

Мета та завдання дослідження.

Мета: дослідити можливості та обмеження ІІІ у системах контролю, оцінити ефективність та ризики впровадження.

Завдання:

1. Проаналізувати сучасні підходи та практики застосування ІІІ.
2. Оцінити ефективність алгоритмів у різних сферах: фінанси, державне управління, промисловість, екологія, медицина.
3. Виявити проблеми: етичні, правові, технічні.
4. Розробити рекомендації щодо оптимізації впровадження.
5. Окреслити перспективи розвитку ІІІ в Україні.

Фінансовий сектор

У фінансовому секторі ІІІ застосовується для автоматичного моніторингу та аналізу величезних масивів фінансових даних. Основні напрями використання:

Виявлення шахрайських операцій: алгоритми аналізують тисячі транзакцій за секунди, порівнюють поведінку користувачів із типовими моделями та виявляють аномалії. Наприклад, якщо клієнт раптово здійснює транзакцію у незвичному географічному регіоні, система автоматично відмічає її для додаткової перевірки.

Оцінка кредитного ризику: алгоритми прогнозують ймовірність неповернення кредиту на основі історії платежів, поведінки клієнта та макроекономічних показників. Це дозволяє банкам приймати більш обґрунтовані рішення щодо надання кредитів.

Автоматизація аналітичних процесів: ІІІ допомагає формувати звіти, прогнозувати доходи та витрати, аналізувати тенденції ринку.

Приклад впровадження в Україні: один з комерційних банків використовує систему, що аналізує понад 50 000 транзакцій на хвилину, автоматично блокуючи підозрілі операції. Це зменшило фінансові втрати на 20% за перший рік використання.

Державне управління.

ІІІ у державному секторі допомагає контролювати публічні закупівлі, оптимізувати розподіл ресурсів і підвищувати ефективність прийняття рішень. Основні напрямки:

Моніторинг публічних закупівель: алгоритми аналізують історичні та поточні дані про тендери, виявляючи повторювані схеми або потенційні порушення.

Прогнозування ризиків корупції: ІІІ аналізує зв'язки між учасниками тендерів, їхніми контрактами та історією участі у державних закупівлях.

Оптимізація ресурсів: системи допомагають визначати, де кошти використовуються неефективно, і пропонують альтернативні рішення.

Приклад: на платформі Prozorro алгоритми аналізують понад 100 000 тендерів щомісяця, виявляючи понад 1 500 потенційно ризикових контрактів. Результатом стало зниження корупційних ризиків і підвищення ефективності використання бюджетних коштів.

Промисловість.

У промисловості ІІІ використовується для підвищення продуктивності та безпеки:

Прогнозування збоїв обладнання: алгоритми аналізують датчики та історію експлуатації машин, визначаючи ймовірність аварій. Це дозволяє планувати технічне обслуговування до того, як виникне серйозна поломка.

Оптимізація виробничих процесів: ІІІ допомагає визначати найефективніші шляхи виробництва, розподіляти ресурси та мінімізувати втрати матеріалів.

Підвищення безпеки працівників: алгоритми аналізують умови праці, відстежують критичні показники і прогнозують потенційно небезпечні ситуації.

Приклад: на машинобудівному підприємстві в Дніпропетровській області впроваджено систему прогнозування відмов обладнання. Це дозволило скоротити аварійність на 28% та економити до 15% витрат на ремонт.

Екологія.

III застосовується для моніторингу та прогнозування стану довкілля:

Моніторинг якості повітря та води: системи аналізують дані з датчиків і супутникових знімків, визначаючи рівень забруднення та тенденції змін.

Прогнозування екологічних катастроф: алгоритми враховують метеорологічні дані, промислові викиди та природні фактори для прогнозування забруднень або стихійних лих.

Прийняття превентивних заходів: результати аналізу використовуються для планування заходів із зменшення негативного впливу на екологію та здоров'я населення.

Приклад: у Львівській області система моніторингу повітря на базі III попереджає органи влади про підвищення рівня шкідливих речовин, дозволяючи заздалегідь вживати заходів для захисту здоров'я мешканців.

Медицина та соціальна сфера.

У медицині та соціальній сфері III використовується для оптимізації ресурсів, прогнозування та оцінки ефективності програм:

Аналіз медичних даних: алгоритми прогнозують поширення захворювань, оцінюють ефективність лікування та визначають потребу в медичних ресурсах.

Оптимізація соціальних програм: III допомагає розподіляти фінансові та матеріальні ресурси, оцінювати ефективність програм підтримки населення.

Підвищення якості послуг: системи аналізують потреби населення та пропонують зміни для покращення результатів програм.

Приклад: у Київській області алгоритми аналізують соціальні програми для малозабезпечених родин, оптимізуючи бюджетні витрати та підвищуючи результативність наданої допомоги. Також у медичних установах України III використовується для прогнозування захворюваності на грип та COVID-19, що дозволяє планувати кількість ліжок та медичного персоналу

Сфера контролю	Застосування III	Основні ефекти
Промисловість	Прогнозування відмов обладнання, оптимізація виробничих процесів, контроль якості продукції	Зменшення аварійності, підвищення продуктивності, економія ресурсів
Логістика та транспорт	Оптимізація маршрутів, моніторинг перевезень, прогнозування затримок	Своєчасна доставка, зниження витрат, мінімізація ризиків
Бізнес-процеси	Аналіз ефективності операцій, контроль виконання завдань, відстеження ресурс	Підвищення прозорості, зниження помилок, оптимізація ресурсів
Безпека та інформаційний контроль	Виявлення аномалій, контроль доступу, захист даних	Підвищення безпеки, своєчасне реагування на загрози, зменшення людського фактору

Інтелектуальні системи управління	Самонавчання алгоритмів, адаптація до змін, прийняття рішень у реальному часі	Підвищення точності контролю, автоматизація процесів, оперативність прийняття рішень
-----------------------------------	---	--

Штучний інтелект у системах контролю дозволяє автоматизувати процеси обробки інформації та підвищувати ефективність прийняття рішень навіть у складних і динамічних середовищах. Його основна перевага полягає в здатності швидко аналізувати великі обсяги даних, виявляти аномалії та закономірності, які часто залишаються непомітними для людини. Це забезпечує більш точний та своєчасний контроль над процесами різного характеру.

Сучасні системи контролю на базі ШІ використовують різні алгоритми машинного навчання та нейронних мереж. Наприклад, алгоритми класифікації дозволяють автоматично визначати типи подій або операцій та розподіляти їх за категоріями ризику. Регресійні моделі прогнозують можливі зміни у системі, а алгоритми кластеризації допомагають групувати дані за схожими характеристиками для подальшого аналізу.

Важливою складовою є системи самонавчання, які дозволяють алгоритмам постійно покращувати точність прогнозів на основі нових даних. Такі системи здатні виявляти тенденції, прогнозувати потенційні проблеми та адаптуватися до змін у середовищі контролю. Це особливо корисно у складних та динамічних процесах, де постійно змінюються умови та параметри системи.

Однією з ключових задач є забезпечення інформаційної безпеки. Системи контролю на базі ШІ можуть відстежувати спроби несанкціонованого доступу, виявляти підозрілі дії та автоматично повідомляти операторів. Використання алгоритмів виявлення аномалій дозволяє ідентифікувати нетипову поведінку в мережах, комп'ютерних системах або пристроях, що забезпечує своєчасне реагування на загрози.

Також ШІ активно застосовується для моніторингу та аналізу дотримання стандартів і правил у великих організаціях. Алгоритми автоматично порівнюють поточні параметри процесів із встановленими нормативами, виявляючи відхилення та потенційні проблеми. Це дозволяє підтримувати високий рівень якості та точності в роботі систем контролю.

Перспективним напрямом є інтеграція ШІ з технологіями Інтернету речей (IoT). Сенсори та датчики збирають дані в режимі реального часу, алгоритми ШІ аналізують їх та приймають рішення про необхідні корективи або попереджувальні дії. Це дозволяє створювати розумні системи контролю, які здатні автономно реагувати на зміни у середовищі.

Важливою складовою є прозорість та пояснюваність алгоритмів. Розробники сучасних систем контролю приділяють увагу тому, щоб рішення, прийняті ШІ, були зрозумілими для користувачів. Це дозволяє довіряти системі, контролювати її роботу та при необхідності вносити корективи у логіку алгоритмів.

Завдяки ШІ підвищується оперативність та точність контролю. Системи здатні обробляти дані швидше за людину, зменшувати ймовірність помилок і забезпечувати своєчасне реагування на будь-які відхилення від норми. Це особливо важливо для великих організацій, де ручний контроль був би надзвичайно витратним і повільним.

Однією з ключових тенденцій є розвиток гібридних систем контролю, де ШІ поєднується з експертними системами та класичними методами управління. Це дозволяє об'єднувати аналітичну потужність алгоритмів із знанням та досвідом фахівців, підвищуючи загальну ефективність системи.

Нарешті, варто зазначити, що застосування ШІ у системах контролю створює нові перспективи для наукових досліджень і розробок. Постійне вдосконалення алгоритмів, підвищення їхньої адаптивності та інтеграція з різними технологічними платформами відкриває широкі можливості для розвитку сучасних систем управління та контролю в майбутньому.

СПИСОК ПОСИЛАНЬ.

1. Міністерство цифрової трансформації України. «Регулювання штучного інтелекту в Україні: Біла книга». 2024.
 2. Міністерство цифрової трансформації України. «Драфт стратегії розвитку ШІ до 2030 року». 2025.
 3. Офіційний портал Верховної Ради України. «Правове регулювання Штучного Інтелекту». 2023.
- ЛІТЕРАТУРИ
5. Дудка, О. В. Штучний інтелект та його застосування у сучасних інформаційних системах. Київ: Наукова думка, 2020.
 6. Петришин, І. І. Інформаційні технології у контролі та управлінні. Львів: Львівська політехніка, 2019.

УДК 004.032.26:004.038.6

Кулаківський В.М., Тіщенко Н.Є. (Інститут надтвердих матеріалів ім. В.М. Бакуля НАН України, Київ, Україна).

РОЗРОБКА МЕТОДИКИ ПОБУДОВИ ШНМ ДЛЯ ПОДАЛЬШОГО ПРОГНОЗУВАННЯ ФІЗИКО-МЕХАНІЧНИХ ВЛАСТИВОСТЕЙ НАДТВЕРДИХ МАТЕРІАЛІВ.

Анотація. У роботі представлено комплексну методику побудови штучних нейронних мереж (ШНМ), спрямовану на прогнозування фізико-механічних властивостей надтвердих матеріалів на основі інформаційної бази AFLOW. Проаналізовано структуру даних, виконано їх очищення, видалення корельованих ознак, перетворення структурних параметрів та нормалізацію. Особлива увага приділена усуненню дубльованих та похідних характеристик, що можуть спричинити витік інформації та суттєво знизити якість моделювання. Побудовано окремі моделі для передбачення модуля об'ємного стиску, модуля зсуву, модуля Юнга та коефіцієнта Пуассона. Навчання виконано із застосуванням оптимізатора Adam, функції втрат MSE та архітектури з п'ятьма прихованими шарами. Оцінювання точності здійснювалося на основі метрик MAE, RMSE та R^2 . Показано, що у більшості випадків пряме прогнозування за допомогою ШНМ має вищу точність, ніж розрахунок властивостей через аналітичні формули. Проведено порівняння з існуючими публікаціями та встановлено, що запропонована методика забезпечує значно кращу точність щодо окремих механічних характеристик. Результати тестової вибірки підтвердили стабільність моделей та відсутність перенавчання. Запропонований підхід може застосовуватися для автоматизованого пошуку перспективних надтвердих матеріалів у великих обчислювальних базах.

Ключові слова: штучні нейронні мережі, прогнозування властивостей, AFLOW, надтверді матеріали, модуль Юнга, модуль зсуву, коефіцієнт Пуассона.

Abstract. This paper presents a comprehensive methodology for constructing artificial neural networks (ANNs) aimed at predicting the physicochemical properties of superhard materials using the AFLOW materials database. The dataset was systematically preprocessed, including cleaning, removal of correlated and derivative features, structural parameter transformation, and normalization. Particular attention was given to eliminating redundant attributes that could lead to information leakage and reduce model accuracy. Four independent ANN models were developed to predict bulk modulus, shear modulus, Young's modulus, and Poisson's ratio. The networks were trained using the Adam optimizer, mean squared error (MSE) loss function, and a five-layer architecture. Model performance was evaluated using MAE, RMSE, and R^2 metrics. It was demonstrated that direct ANN prediction significantly outperforms analytical relationships between mechanical parameters in most cases. Comparison with existing research shows that

the proposed approach achieves notably improved accuracy for several mechanical properties. The test dataset confirmed the stability of the models and the absence of overfitting. The methodology developed herein can be applied to accelerate the discovery and assessment of prospective superhard materials within large computational databases.

Keywords: artificial neural networks, property prediction, AFLOW, superhard materials, mechanical properties, Poisson's ratio.

1. Вступ.

Прогнозування властивостей матеріалів є одним із ключових викликів сучасної матеріалознавчої інформатики. У рамках розвитку цифрових матеріалів і концепції Materials Genome Initiative використання штучних нейронних мереж забезпечує точне моделювання нелінійних залежностей між структурними, атомними та енергетичними характеристиками матеріалів.

База AFLOW містить великий обсяг даних, отриманих із перших принципів (DFT), що робить її цінним джерелом для побудови моделей машинного навчання. Мета цієї роботи: розробити методику побудови ШНМ, здатних прогнозувати фізико-механічні параметри надтвердих матеріалів з високою точністю.




Рисунок 1 Схема виконання даної роботи.

2. Підготовка даних.

Завантажено 5639 матеріалів із бази AFLOW. Основні цільові параметри:

- модуль об'ємного стиску *ael_bulk_modulus_vrh*
- модуль зсуву *ael_shear_modulus_vrh*
- модуль Юнга *ael_youngs_modulus_vrh*
- коефіцієнт Пуассона *ael_poisson_ratio*

2.1. Видалення корельованих ознак

Для уникнення витоку інформації було виключено параметри, які є похідними від цільових значень або сильно з ними корелюють. Аналіз проведено методом SHAP. Серед видалених:

- *ael_bulk_modulus_reuss, ael_bulk_modulus_voigt*
- *ael_shear_modulus_voigt, ael_shear_modulus_reuss*
- *ael_pughs_modulus_ratio*
- інші параметри, що дублюють або майже повністю відтворюють цільові.

2.2. Обробка структурних даних

Ознаки на кшталт:

- компоненти тензора напружень (9 значень)
- геометрія структури до й після релаксації (6+6 значень)

було перетворено на числові масиви, оскільки вони мають фіксований розмір.

Пропуски заповнено нулями.

2.3 Видалення зайвих ознак

Також були видалені дані які взагалі не впливають на результати ШНМ, та дані які дуже слабо впливають на неї, видалення ознак проводилось на основі SHAP (Integrated Gradients як метод пояснення моделі) рис. 2.




Рисунок 2 Зображення ознак які було видалено та які дуже рідко впливають на результати прогнозування.

Всі інші дані, які не були перетворені на числовий формат, видалено.

2.4 Створенні вибірок

Дані поділені на три вибірки — навчальну, валідаційну, тестову.

Де навчальна вибірка це 70% даних, а валідаційна та тестова це по 15%

3. Архітектура та навчання штучних нейронних мереж.

Для кожного параметра навчено окрему модель.

Архітектура однакова:

- 5 прихованих шарів,
- 256 нейронів у кожному шарі,
- активація ReLU,
- розмір батчу = 64,
- функція втрат MSE,
- оптимізатор Adam,
- швидкість навчання = 0.00004.

4. Результати моделювання.

У таблиці показані результати RMSE (корінь середньоквадратичної помилки), MAE (середня абсолютна помилка) та R^2 (коефіцієнт детермінації), який показує, наскільки добре модель пояснює змінність даних).

4.1) Результати ШНМ для модуля об'ємного стиску (ael_bulk_modulus_vrh)

	RMSE (ГПа)	MAE (ГПа)	R^2
норм. навчальна вибірка	0.009687	0.007056	0.996621
норм. перевірна вибірка	0.028370	0.018479	0.973639
денорм. навчальна вибірка	4.202515	3.060962	0.996621
денорм. перевірна вибірка	12.307785	8.016707	0.973639

Таблиця 1 Результати навченої нейронної мережі для прогнозування: Модуля об'ємного стиску




Рисунок 3 Динаміка помилок MAE, RMSE та R^2 під час навчання моделі для: Модуля об'ємного стиску




Рисунок 4 Динаміка похибок MAE, RMSE та R^2 під час навчання моделі (з відсікання перших 10% епох) для: Модуля об'ємного стиску

4.2) Результати ШНМ для модуля зсуву (ael_shear_modulus_vrh)

	RMSE (ГПа)	MAE (ГПа)	R^2
норм. навчальна вибірка	0.001441	0.001106	0.999736
норм. перевірна вибірка	0.008982	0.004697	0.992371
денорм. навчальна вибірка	0.758221	0.581699	0.999736
денорм. перевірна вибірка	4.724371	2.470595	0.992371

Таблиця 2 Результати навченої нейронної мережі для прогнозування: Модуля зсуву




Рисунок 5 Динаміка похибок MAE, RMSE та R^2 під час навчання моделі (з відсіканням перших 10% епох) для: Модуля зсуву

4.3) Результати ШНМ для модуля Юнга (ael_youngs_modulus_vrh)

	RMSE (ГПа)	MAE (ГПа)	R ²
норм. навчальна вибірка	0.002703	0.002125	0.999262
норм. перевірна вибірка	0.009264	0.004970	0.993229
денорм. навчальна вибірка	3.026358	2.379715	0.999262
денорм. перевірна вибірка	10.373141	5.565404	0.993229

Таблиця 3 Результати навченої нейронної мережі для прогнозування: Модуля Юнга




Рисунок 6 Динаміка похибок MAE, RMSE та R² під час навчання моделі (з відсіканням перших 10% епох) для: Модуля Юнга

4.4) Результати ШНМ для коефіцієнта Пуассона (ael_poisson_ratio)

	RMSE (ГПа)	MAE (ГПа)	R ²
норм. навчальна вибірка	0.009835	0.007360	0.987017
норм. перевірна вибірка	0.029702	0.020063	0.883967
денорм. навчальна вибірка	0.007156	0.005355	0.987017
денорм. перевірна вибірка	0.021610	0.014597	0.883967

Таблиця 4 Результати навченої нейронної мережі для прогнозування: Коефіцієнта Пуассона




Рисунок 7 Динаміка похибок MAE, RMSE та R² під час навчання моделі (з відсіканням перших 10% епох) для: Коефіцієнта Пуассона

5. Аналітичні формули та порівняння з ШНМ

Між параметрами K , G , E , ν існують відомі аналітичні співвідношення. Було протестовано можливість обчислювати одні властивості через інші.

- у 80% випадків формули дають суттєво гіршу точність, ніж пряме прогнозування ШНМ;

параметер	RMSE	MAE	R ²
ШНМ_Модуль_об'ємного_стиску	14.169	9.0275	0.9651
Розрахунок Модуль_об'ємного_стиску з Юнга та пуассона	34.964	10.152	0.7873
Розрахунок Модуль_об'ємного_стиску з Юнга та зсуву	7E+06	1E+06	-8E+09
Розрахунок Модуль_об'ємного_стиску з пуассона та зсуву	32.184	11.974	0.8197
ШНМ_Модуль_зсуву	5.0216	2.984	0.9914
Розрахунок Модуль_зсуву з Юнга та пуассона	4.7107	2.3703	0.9924
Розрахунок Модуль_зсуву з Юнга та об'єм. стиску	4.9472	2.5096	0.9916
Розрахунок Модуль_зсуву з пуассона та об'єм. стиску	9.0793	5.0046	0.9718
ШНМ_Модуль_Юнга	10.41	5.5754	0.9932
Розрахунок Модуль_Юнга з пуассона та зсуву	11.841	7.5217	0.9912
Розрахунок Модуль_Юнга з пуассона та об'єм. стиску	20.741	11.737	0.9729
Розрахунок Модуль_Юнга з об'єм. стиску та зсуву	11.639	7.0545	0.9915
ШНМ_Коефіцієнт_пуассона	0.0228	0.0149	0.8709
Розрахунок Коефіцієнт_пуассона з Юнга та об'єм. стиску	0.0452	0.0215	0.4921
Розрахунок Коефіцієнт_пуассона з Юнга та зсуву	0.2291	0.1018	-12.05
Розрахунок Коефіцієнт_пуассона з об'єм. стиску та зсуву	0.0414	0.0196	0.5734

Тому побудова додаткової «5-ї» нейронної мережі, яка прогнозує одні характеристики через інші, виявилася недоцільною.

6. Перевірка на тестовій вибірці

Результати практично збігаються з валідаційними — це свідчить про:

- відсутність перенавчання,
- правильну побудову архітектури,
- коректність розподілу даних.

параметер	RMSE	MAE	R ²
ШНМ_Модуль_объемного_стиску	17.2794349	9.219591	0.950169
ШНМ_Модуль_зсуву	5.42415971	2.913621	0.989983
ШНМ_Модуль_Юнга	8.85931289	5.287497	0.995131
ШНМ_Коефіцієнт_пуассона	0.02042382	0.014357	0.88748

Таблиця 6 результати похибок ШНМ на тестовій вибірці

7. Порівняння зі статтею [1]

Отримані моделі показали значно меншу похибку по модулю зсуву, ніж опубліковані в існуючій роботі, але більшу похибку по модулю об'ємного стиску, що може свідчити про те, що в їхній роботі використовували важливі дані, які в нашій роботі не застосовувалися.

Model	Target	RMSE (GPa)	MAE (GPa)	R ²
HGBR	Bulk Modulus (B)	9.664	6.11	0.980
	Shear Modulus (G)	12.933	8.00	0.931
LGBR	Bulk Modulus (B)	12.965	8.00	0.931
	Shear Modulus (G)	13.494	8.62	0.920

Таблиця 7 результати статті [1]

ВИСНОВКИ.

1. ШНМ не перенавчаються на цьому наборі даних, що вказує на його значний обсяг та різноманітність.
2. Активація sigmoid дає аналогічні результати, але навчається суттєво довше за ReLU.
3. Збільшення розміру мережі за відсутності перенавчання підвищує точність.
4. Менший batch size покращує точність, але уповільнює навчання.
5. Використання Batch Normalization з ReLU погіршує результати.
6. Dropout у цьому завданні небажаний — він суттєво погіршує точність.
7. Вибір оптимізатора (Adam, RMSProp, SGD+momentum) не критичний — моделі стабільні.
8. Деякі технічні параметри (кількість ядер CPU тощо) мають псевдовплив, що пов'язано з кореляцією всередині бази AFLOW, а не з фізичним змістом.

СПИСОК ПОСИЛАНЬ.

- [1] Isah I., King'ori G., Malloum A. Predicting Superhard Materials Using Machine Learning. 2022. https://www.researchgate.net/publication/365926209_PREDICTING_SUPERHARD_MATERIALS_USING_MACHINE_LEARNING

[2] Pac-Man but you're the ghost [Video]. YouTube, 2021. <https://www.youtube.com/watch?v=-awRMAQnHUk>

УДК 004.896:681.5

Сорока М.О., Віштак І.В. (Вінницький національний технічний університет, Вінниця, Україна).

ОПТИМІЗАЦІЯ ПАРАМЕТРІВ ПОСАДКИ НЕРУХОМИХ З'ЄДНАНЬ ПІДШИПНИКІВ КОЧЕННЯ НА ОСНОВІ НЕЙРОМЕРЕЖНО-ЕВОЛЮЦІЙНИХ МЕТОДІВ.

Анотація. У статті розглянуто застосування інтелектуальних методів, зокрема штучних нейронних мереж та алгоритмів машинного навчання, для оптимізації роботи роботизованих систем на сучасних виробничих підприємствах. Особливу увагу приділено задачам класифікації та розпізнавання об'єктів, планування траєкторій, оцінювання стану технічних систем та прогнозування параметрів роботи обладнання. Показано, що використання методів глибокого навчання забезпечує високу точність визначення робочих зон, оптимізацію руху маніпуляторів та підвищення продуктивності технологічних процесів. Розглянуто приклади застосування CNN, RNN, LSTM та reinforcement learning у задачах керування роботизованими комплексами. Обґрунтовано необхідність підвищення адаптивності роботів для роботи в умовах невизначеності та зміни середовища. Запропоновано структуру інтелектуальної системи керування, що включає модулі сенсорного моніторингу, обробки сигналів, прийняття рішень та активного керування. Наведено перспективи розвитку інтелектуальних виробничих систем, зокрема у напрямках роботів-коллаборатів, адаптивних контролерів та гібридних моделей, що поєднують класичні підходи та нейромережні методи.

Ключові слова: роботизовані системи, машинне навчання, нейронні мережі, керування, інтелектуальні технології.

Abstract. The article examines the use of intelligent methods, including artificial neural networks and machine-learning algorithms, to optimize the operation of robotic systems in modern industrial environments. Special attention is paid to object classification and recognition, trajectory planning, technical-state evaluation and prediction of equipment performance. The study shows that deep-learning approaches significantly improve the accuracy of workspace identification, motion optimization of manipulators and overall productivity of technological processes. Examples of applying CNNs, RNNs, LSTM networks and reinforcement-learning techniques to industrial robotic control tasks are presented. The need for increased adaptability of robots operating under uncertainty and dynamically changing conditions is emphasized. An architecture of an intelligent control system is proposed, including modules for sensor monitoring, signal processing, decision-making and active control. The article outlines the prospects for further development of intelligent industrial systems, particularly collaborative robots, adaptive controllers and hybrid models combining classical and neural-network-based methods.

Keywords: robotic systems, machine learning, neural networks, control, intelligent technologies.

Підшипники кочення є ключовими елементами машинобудівних конструкцій, визначаючи точність, надійність і довговічність механізмів. Нерухомі з'єднання підшипникових кілець з валом або корпусом здійснюються за допомогою посадок з натягом, які мають забезпечувати надійну фіксацію з мінімальними контактними напруженнями та стабільністю точності обертання [1]. Недостатній натяг призводить до мікропровертання кільця, викликаючи фретинг-корозію і знос, а надмірний – до концентрації напружень і

скорочення довговічності [2]. Стандарти ISO 286 і довідкові таблиці не враховують комплексну взаємодію факторів, таких як шорсткість, хвильова похибка та теплові деформації [1].

Розглядається нерухоме з'єднання зовнішнього підшипникового кільця з корпусом. Основні параметри: внутрішній діаметр d_i , зовнішній діаметр d_o , діаметр отвору корпусу D_h , номінальний натяг посадки $\Delta_{fit} = d_o - D_h$ (мкм).

Реальна посадкова поверхня відхиляється від ідеального циліндра за рахунок:

- шорсткості поверхні R_a (середнє арифметичне відхилення профілю, мкм);
- хвильової похибки E_{wav} (амплітуда багатохвильової складової, мкм).

Радіальний профіль можна описати у полярних координатах як:

$$r(\theta) = r_0 + E_{wav} \cos(n\theta) + \xi(\theta),$$

де r_0 – номінальний радіус,

n – кількість хвиль по колу (звичайно 3–5),

$\xi(\theta)$ – випадкова складова шорсткості.

Для товстостінного циліндра під дією контактного тиску p_c радіальні σ_r та тангенціальні σ_θ напруження визначаються класичними формулами Ламе:

$$\sigma_r(r) = \frac{d_o^2 d_i^2 p_c}{d_o^2 - d_i^2} \left(\frac{1}{r^2} - \frac{1}{d_o^2} \right),$$

$$\sigma_\theta(r) = \frac{d_o^2 d_i^2 p_c}{d_o^2 - d_i^2} \left(\frac{1}{d_o^2} + \frac{1}{r^2} \right).$$

Максимальні напруження виникають на внутрішній поверхні $r = d_i$:

$$\sigma_{\theta, \max} = \frac{2d_o^2 p_c}{d_o^2 - d_i^2}.$$

Радіальна деформація визначається як:

$$u_r(r) = \frac{1 + \nu}{E} p_c \frac{d_o^2 d_i^2}{d_o^2 - d_i^2} \left(\frac{1}{r} + \frac{\nu r}{d_o^2} \right),$$

де E — модуль Юнга,

ν — коефіцієнт Пуассона.

Максимальне контактне напруження визначається за формулою Герца:

$$\sigma_H = 0.418 \left(\frac{P E^*}{\rho} \right)^{1/3},$$

де P – нормальне навантаження на тіло кочення,

$E^* = \frac{E}{1 - \nu^2}$ – приведений модуль пружності,

ρ – приведений радіус кривизни.

Радіальне биття внутрішнього кільця Δ_{runout} враховує хвильову похибку, деформації і початковий радіальний зазор G_r :

$$\Delta_{runout} = E_{wav} + \Delta u_r + k_g G_r,$$

де Δu_r – деформація,

k_g – коефіцієнт впливу зазору .

Ймовірність мікропровертання P_{slip} оцінюється як:

$$P_{slip} = 1 - \exp\left(-\frac{2M_{ext}}{\mu d_o b p_c d_o / 2}\right),$$

де M_{ext} – зовнішній крутний момент,

μ – коефіцієнт тертя у посадці,

b – ширина кільця.

Базова розрахункова довговічність за стандартом ISO 281 [3]:

$$L_{10} = \left(\frac{C}{P}\right)^p \times 10^6 \text{ обертів},$$

де C – динамічна вантажопідйомність,

P – еквівалентне навантаження,

$p = 3$ для кулькових підшипників. Модифікована довговічність:

$$L_{10,mod} = a_1 a_{ISO} L_{10},$$

де a_1, a_{ISO} – коефіцієнти надійності і умов експлуатації з урахуванням посадки.

Розширення деталей при підвищенні температури:

$$\Delta_{temp} = \alpha (T_{op} - T_{amb}) d_o,$$

де α – коефіцієнт теплового розширення,

T_{op} – робоча температура,

T_{amb} – температура навколишнього середовища.

Для комплексної оцінки якості з'єднання введено багатокритеріальний функціонал:

$$J = w_1 \hat{\sigma}_H + w_2 \hat{P}_{slip} + w_3 \hat{\Delta}_{runout} + w_4 \hat{L}_{10}^{-1},$$

де коефіцієнти позначають нормовані безрозмірні величини, w_i — вагові коефіцієнти (0,3; 0,3; 0,2; 0,2 відповідно).

Оптимізацію проведено генетичним алгоритмом з дійсним кодуванням параметрів $\Theta = (\Delta_{fit}, R_a, E_{wav})$ з початковою популяцією 50 індивідів, турами селекції, кросовером і мутацією [3,4].

Оптимальні параметри, які забезпечили мінімізацію функціоналу J :

$$\Delta_{fit}^* = 58 \text{ мкм}, R_a^* = 0.35 \text{ мкм}, E_{wav}^* = 0.6 \text{ мкм}.$$

Порівняно з початковою конфігурацією, зниження контактних напружень на 22%, ймовірності мікропровертання на 56%, покращення точності обертання на 35% і збільшення довговічності на 28%.

СПИСОК ПОСИЛАНЬ.

1. Persson B. N. J. Influence of Surface Roughness on Press Fits. Tribology Letters. 2023; 71(1):19. doi: 10.1007/s11249-022-01688-y.

2. Izard E., García-Martín R., Rodríguez-Martín M., Lorenzo M. Influence of the Friction Coefficient on the Stress Distributions and Contact Pressure in Press-Fits via Finite Element Analysis. *Lubricants*. 2023; 11(11):472. doi:10.3390/lubricants11110472.
3. Baklouti A., Dammak K., El Hami A. Optimum reliable design of rolling element bearings using multi-objective optimization based on C-NSGA-II. *Reliability Engineering & System Safety*. 2022; 243:108229. doi: (якщо є)
4. Qiu M., Zhang J., Wang H., Yang C., Tang Y., Zhang P. Multi-objective optimization design of wheel hub bearings based on Kriging-NSGA-II. *Journal of Mechanical Science and Technology*. 2024; 38:1341–1353. doi:10.1007/s12206-024-0129-6.

Наукове видання

За загальною редакцією
д-ра техн. наук, професора

КОВАЛЕВСЬКОГО Сергія Вадимовича

НЕЙРОМЕРЕЖНІ ТЕХНОЛОГІЇ ТА ЇХ ЗАСТОСУВАННЯ НМТіЗ-2025

**Збірник наукових праць
XXIV Міжнародної наукової конференції**

За авторським редагуванням

32/2016 Формат 60 x 84/16. Ум. друк. арк. **16,1**
Обл.-вид. арк. **17,2**. Тираж 100 прим. Зам. № 24

Видавець і виготівник
Донбаська державна машинобудівна академія
84313, м. Краматорськ, вул. Академічна, 72.
Свідоцтво суб'єкта видавничої справи
ДК № 1633 від 24.12.2003