


Міністерство освіти і науки України  
Чорноморський національний університет ім. Петра Могили  
Факультет комп'ютерних наук  
Кафедра інтелектуальних інформаційних систем



# Інтелектуальні інформаційні системи

*Матеріали всеукраїнської науково-практичної  
конференції молодих вчених, аспірантів і  
студентів*

**ТЕЗИ**

*2 – 4 грудня 2024 року*

**Миколаїв**

Інтелектуальні інформаційні системи : матеріали всеукр. наук.-практ. конф. молодих вчених, аспірантів, студентів : 2–4 грудня 2024 р., м. Миколаїв : тези / М-во освіти і науки України ; ЧНУ ім. Петра Могили ; Ф-т комп. наук ; Каф. інтелект. інформ. систем. – Миколаїв : Вид-во ЧНУ ім. Петра Могили, 2025. – 124 с.

Голова оргкомітету:

**КОНДРАТЕНКО Юрій**, доктор технічних наук, професор, Заслужений винахідник України, завідувач кафедри Інтелектуальних інформаційних систем ЧНУ імені П.Могили.

Співголова оргкомітету:

**ГОЖИЙ Олександр**, доктор технічних наук, професор, кафедра Інтелектуальних інформаційних систем ЧНУ імені П.Могили.

### **ОРГАНІЗАЦІЙНИЙ КОМІТЕТ**

**БОЙКО Анжела**, кандидат технічних наук, доцент, декан факультету комп'ютерних наук ЧНУ імені П.Могили.

**КАЛІНІНА Ірина**, доктор технічних наук, доцент, кафедра Інтелектуальних інформаційних систем ЧНУ імені П.Могили.

**КОЗЛОВ Олексій**, доктор технічних наук, професор, кафедра Інтелектуальних інформаційних систем ЧНУ імені П.Могили.

**ЛИСЕНКОВ Едуард**, доктор фізико-математичних наук, професор, завідувач кафедри фізики та математики ЧНУ імені П.Могили.

**МАЛАХОВ Євген** доктор технічних наук, професор, завідувач кафедри математичного забезпечення комп'ютерних систем ОНУ імені І.Мечнікова.

**МЕЩАНИНОВ Олександр**, доктор педагогічних наук, професор, кафедра Інтелектуальних інформаційних систем ЧНУ імені П.Могили.

**СІДЕНКО Євген**, кандидат технічних наук, доцент, кафедра Інтелектуальних інформаційних систем ЧНУ імені П.Могили.

**ТРУНОВ Олександр**, доктор технічних наук, професор, кафедра Автоматизації та комп'ютерно інтегрованих технологій ЧНУ імені П.Могили.

**ФІСУН Микола**, доктор технічних наук, професор, кафедра Інженерії програмного забезпечення ЧНУ імені П.Могили.

### **ВІДПОВІДАЛЬНИЙ СЕКРЕТАР**

**ДИМО Валерій**

[dymovalery@gmail.com](mailto:dymovalery@gmail.com)

### **ТЕХНІЧНИЙ СЕКРЕТАР**

**СОМРЯКОВ Богдан**

[pontius.bos@gmail.com](mailto:pontius.bos@gmail.com)

Телеграм @BohdanSomriakov

# ІНТЕЛЕКТУАЛЬНІ ІНФОРМАЦІЙНІ ТЕХНОЛОГІЇ

УДК 004:164.01:355.7

**Bohdan Somriakov**

*Petro Mohyla, Black Sea National  
University, Mykolaiv, Ukraine*

## LOGISTICS AND SUPPLY CHAIN OPTIMIZATION SOFTWARE FOR UKRAINE'S NATIONAL INFRASTRUCTURE

In any crisis, logistics and supply chains are the lifeblood of essential operations. For Ukraine, facing significant challenges in its eastern and southern regions, ensuring a steady and secure flow of critical supplies, medical equipment, and essential resources to key areas is absolutely vital. To address these challenges, a Supply Chain Optimization Software was developed.

The program enables users to visually map out supply networks, as illustrated in Figure 1, which shows an example supply route created with Folium Map, a Python library specifically designed for interactive mapping and geospatial analysis.




Figure 1 – Example supply chain network

The blue nodes represent warehouses, where supplies are stored, while the green nodes represent delivery points at critical locations where supplies are needed. Each edge in the network represents a transportation link, with edge numbers indicating the cost of transport for that route, whether due to distance, fuel consumption, or potential risks.

This code snippet uses the PuLP library, a powerful Python library for linear programming, to define a linear programming model for optimizing a supply chain, specifically for minimizing transportation costs from warehouses to retailers [1].

```
model = pulp.LpProblem("Supply_Chain_Optimization",
pulp.LpMinimize)
shipping_vars = pulp.LpVariable.dicts("Shipping",
(military_warehouses,   retailers),   lowBound=0,
cat='Continuous')
model += pulp.lpSum(
costs[w, r] * shipping_vars[w][r] for w in
military_warehouses for r in retailers),
"Total_Transportation_Cost"
for w in military_warehouses:
model += pulp.lpSum(shipping_vars[w][r] for r in
retailers) <= supply[w], f"Supply_Constraint_{w}"
for r in retailers:
model += pulp.lpSum(shipping_vars[w][r] for w in
military_warehouses) >= demand[r],
f"Demand_Constraint_{r}"
```

The model establishes decision variables representing the shipping amounts between warehouses and retailers and adds an objective function to minimize the total transportation cost, calculated as the sum of the shipping costs multiplied by the corresponding shipping variables.

The graph, as seen in Figure 2, visually represents an optimized transportation network designed to minimize costs in the supply chain logistics and was created using NetworX, a Python library for network analysis and visualization [2].




Figure 2 – Optimized transportation network for supply chain logistics

In this network, green nodes symbolize cities, which are the delivery points where supplies are needed, while blue nodes represent warehouses, indicating the locations where supplies are stored. The edges connecting these nodes illustrate the transport routes between warehouses and cities. The numbers displayed on the edges indicate the quantity of supplies that need to be transported along each route.

The program also provides detailed logs of how the supplies are shipped, ensuring transparency and tracking throughout the logistics process, as seen in Figure 3, with the logging functionality developed using Tkinter, a Python library for creating graphical user interfaces.




Figure 3 – Shipping Logs Interface

The software visually displays, using pie charts created with Matplotlib – a widely used Python library for data visualization – the distribution of supplies from various warehouses to specific cities, illustrating how resources are allocated across the supply network, as seen in Figure 4 [3].




Figure 4 – Supply Distribution by City

This program effectively optimizes the supply chain in the context of the ongoing crisis in Ukraine, where efficient resource allocation and logistics are crucial for sustaining critical infrastructure and humanitarian efforts. By leveraging linear programming, the program can determine the optimal delivery routes and quantities needed to minimize transportation costs while meeting supply and demand constraints. Additionally, the program provides a comprehensive mapping of transportation networks and detailed logs of supply deliveries, which are essential for coordinating logistics amid the challenges presented by the crisis.

## REFERENCES

1. Optimization modeling in Python By Using Pulp Library URL: <https://medium.com/@bayram.serkan/optimization-modeling-in-python-by-using-pulp-library-a826ab951233> (date of request: 26.10.2024).
2. Applied Graph Theory: An Introduction With Graph Optimization And Algebraic Graph Theory by Christopher H Griffin, 2023.
3. Data Visualization with Python: Exploring Matplotlib, Seaborn, and Bokeh for Interactive Visualizations by Pooja, 2023.

УДК 004.8 + 519.226

*Мельничук М. С., Калініна І. О.*

*Чорноморський національний  
університет ім. Петра Могили, Миколаїв, Україна*

## ІНТЕЛЕКТУАЛЬНА СИСТЕМА МОДЕЛЮВАННЯ ТА ПРОГНОЗУВАННЯ НА ОСНОВІ МЕТОДІВ КОМБІНУВАННЯ

Звичайним підходом при прогнозуванні часових рядів є побудова декількох прогнозних моделей за різними існуючими методами, серед яких обирають найточнішу модель. Проте проблемою такого підходу є втрата частини інформації, наявної в альтернативних моделях, що

допомогла б покращити якість прогнозу. Альтернативним підходом для покращення якості прогнозних рішень є комбінування прогнозів. Об'єднання та комбінування кількох прогнозів, отриманих на основі одного набору даних, в даний час широко використовується для підвищення точності за рахунок інтеграції інформації, отриманої з різних джерел. Це знижує ризик визначення одного «найкращого» прогнозу. Існують різні методи комбінування прогнозів: від простого усереднення прогнозованих значень до складніших підходів з визначенням вагових коефіцієнтів прогнозних моделей. Ефективність методів комбінування прогнозів у порівнянні з вибором найкращого окремого прогнозу підтверджується у багатьох публікаціях на тему [1]. На основі дослідження методів комбінування прогнозів розроблено схему інформаційної системи прогнозування часових рядів, яка представлена на рисунку 1.

В якості прикладу застосування прийомів комбінування прогнозів часових рядів розглянуто часовий ряд попиту на електроенергію в енергосистемі України [2], горизонт прогнозування - 30 днів.




Рисунок 1 – Схема інформаційної системи прогнозування на основі методів комбінування прогнозів

В блоці моделювання в якості базових прогнозних моделей обрано узагальнену адитивну модель (GAM), модель експоненційного згладжування (ETS), модель ARIMA і модель нейромережевої авторегресії (NNAR). Для врахування структурної та параметричної невизначеностей по кожній зі базових моделей побудовано кілька альтернативних моделей та обрано ту, що показувала найкращу точність на тестовій вибірці. На рис. 2 наведено графіки прогнозів, побудованих кожною базовою моделлю. Результати співставлені з реальними значеннями часового ряду, які позначені пунктирними лініями.




Рисунок 2 – Графіки прогнозів, що отримані за допомогою базових моделей

У таблиці 1 наведено оцінки точності прогнозних значень по базовим моделям на тестовій вибірці. Найкращі результати з базових моделей отримано по моделі ARIMA.

Таблиця 1 – Оцінки точності прогнозних значень по базовим моелям

| Модель | MSE       | RMSE     | MAE      |
|--------|-----------|----------|----------|
| GAM    | 157228,52 | 396,5205 | 324,3262 |
| ETS    | 127475,51 | 357,0371 | 276,2925 |
| ARIMA  | 93986,56  | 306,5723 | 228,7214 |
| NNAR   | 110804,56 | 332,8732 | 256,0339 |

Для комбінування прогнозів були використані методи з пакету *ForecastComb* мови програмування R. Оцінки точності комбінованих прогнозів наведено в таблиці 2. Найбільшу точність серед представлених методів комбінування отримано по методу простого усереднення. Важливо, що більшість комбінованих прогнозів є точнішими за прогноз найкращої з базових моделей.

Таблиця 2 – Оцінки точності комбінованих прогнозів

| Методи комбінування прогнозних значень                                      | MSE       | RMSE     | MAE      |
|-----------------------------------------------------------------------------|-----------|----------|----------|
| Просте усереднення                                                          | 91834,74  | 303,0425 | 214,0157 |
| Медіана                                                                     | 95734,16  | 309,4094 | 217,2909 |
| Мінімальна дисперсія                                                        | 97225,87  | 311,8105 | 219,1354 |
| Регресія з підгонкою коефіцієнтів методом найменших квадратів               | 92097,26  | 303,4753 | 216,4003 |
| Регресія з підгонкою коефіцієнтів методом найменшого абсолютного відхилення | 101700,17 | 318,9046 | 233,0618 |
| Метод оберненого рангу                                                      | 103181,16 | 321,2182 | 239,1892 |

На рисунку 2 наведено графік найкращого комбінованого прогнозу (жирна лінія), графіки окремих прогнозів (тонкі лінії) і графік реальних значень (пунктирна лінія).




Рисунок 2 – Графіки прогнозних значень попиту електроенергії з використанням комбінування прогнозів

Таким чином, при прогнозуванні процесів довільної природи необхідно застосовувати як окремі методи, так і комбінування оцінок прогнозів, обчислених за допомогою різних методів. Такі підходи до прогнозування краще реалізовувати у відповідних інформаційних системах з автоматизацією функцій обробки даних, оцінювання структур і параметрів моделей та прогнозів на їх основі.

### ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ

1. Wang Xiaoqian, Hyndman Rob, Li Feng, Kang Yanfei. (2022). Forecast combinations: An over 50-year review. International Journal of Forecasting.

2. Energy Map. URL: <https://map.ua-energy.org/uk/resources/5a616fba-fbc9-4073-9532-9161592faca8/> (дата звернення: 09.09.2024).

3. ForecastComb: Forecast Combination Methods. The Comprehensive R Archive Network. URL: <https://cran.r-project.org/web/packages/ForecastComb/index.html> (дата звернення: 22.08.2024).

**УДК 004.42**

**Валюшок Б. І.**

*Чорноморський національний університет  
імені Петра Могили, Миколаїв, Україна*

## **ІНТЕЛЕКТУАЛЬНА СИСТЕМА ДЛЯ РОЗПІЗНАВАННЯ ЖЕСТОВОЇ МОВИ З ВИКОРИСТАННЯМ НЕЙРОННОЇ МЕРЕЖІ**

В Україні, за даними досліджень міністерства соціальної політики за 2021 рік, близько 40 тисяч людей використовують жестову мову як основний засіб комунікації, а кількість людей що постійно використовують жестову мову сягає 200 тисяч [1]. Ця цифра охоплює як глухих та слабочуючих людей, так і тих, хто взаємодіє з ними в повсякденному житті, зокрема членів їхніх родин. Однак через триваючу війну та бойові дії ця кількість має тенденцію до щорічного зростання (рис. 1).

Військові дії мають значний вплив на здоров'я солдатів та цивільного населення, зокрема спричиняючи втрату слуху внаслідок контузій, вибухів та інших травматичних факторів. Сучасна статистика свідчить, що акустичні травми, пов'язані з перебуванням у зоні активних бойових дій, є однією з найпоширеніших проблем серед військових. Це означає, що після завершення служби значна частина ветеранів матиме потребу в адаптації до нових умов життя, зокрема у використанні жестової мови.

Крім того, наслідки війни також позначаються на цивільному населенні, яке перебуває під обстрілами або стикається з вибухами. Це спричиняє зростання кількості людей, які мають травми слуху, та підвищує потребу у жестовій мові як способі комунікації. Таким чином, проблема забезпечення якісного розпізнавання та інтеграції жестової мови стає все більш актуальною не лише для забезпечення прав цих людей, але й для сприяння їх соціальній адаптації та інтеграції у суспільство.

Головним викликом є її автоматизоване розпізнавання для технологій комп'ютерного зору та штучного інтелекту. Зокрема, українська жестова мова, яка має свої унікальні особливості, включаючи дактильну абетку та калькуючу жестову систему, значною мірою не представлена у цифрових рішеннях. Це створює бар'єри як для осіб із порушенням слуху в Україні, так і для інтеграції цих технологій у глобальні системи автоматизованого перекладу та розпізнавання.




Рисунок 1 – Популярність запитів про жестову мову

Формування датасету є одним із ключових етапів у будь-якому дослідженні, що пов'язане із машинним навчанням і комп'ютерним зором. Для задачі розпізнавання жестів, особливо української жестової мови, наявність якісного і збалансованого датасету є критично важливою. Датасет забезпечує алгоритми машинного навчання реальними даними для тренування, валідації та тестування. Без цього навчити модель розпізнавати різні жести просто неможливо. Датасет має містити не лише статичні положення пальців, а й послідовності кадрів, які передають рухи, що є ключовими для калькуючої мови жестів.

Унікальність української жестової мови, яка включає дві системи — дактильну абетку та калькуючу жестову мову, вимагає специфічного підходу до збору даних. У світі наявні датасети переважно сфокусовані на жестових мовах, таких як ASL (американська жестова мова), тому створення українського датасету заповнює значну прогалину в дослідженнях і відкриває можливість адаптації технологій саме для української аудиторії.

Детальність дослідження підкреслює організований датасет що дозволяє врахувати різноманітність виконання жестів. Він повинен охоплювати жести, виконані різними людьми, у різних умовах освітлення, із різними швидкостями та кутами зйомки. Це забезпечить загальну стійкість та точність моделі у реальних умовах використання. При цьому, динамічні особливості жестів, такі як рухи рук і зміна положення пальців у просторі, вимагають використання передових архітектур, здатних працювати з великими обсягами відео-даних. Унікальність української жестової мови полягає у тому, що вона поєднує статичні жести та динамічні послідовності, що підвищує складність аналізу та моделювання.

Розробка моделі розпізнавання жестів для української жестової мови має велике значення не лише для створення зручних інструментів комунікації, але й для збереження культурної та мовної спадщини нашої спільноти. Дослідження у цій галузі спрямоване на подолання технічних бар'єрів за допомогою використання передових інструментів, таких як YOLOv8, здатного обробляти відеопослідовності в реальному часі. Швидкий та зручний інструментарій відіграє ключову роль в дослідженні жестових мов через великий об'єм жестів що можуть не суттєво розрізнятися (рис. 2) [2]. Це дозволить забезпечити якісне розпізнавання як статичних, так і динамічних жестів, що виведе дослідження жестових мов в Україні на новий рівень.




Рисунок 2 – Переваги використання в дослідженні YOLOv8

Отже, дослідження зосереджується на створенні технологічного рішення для автоматизованого розпізнавання української жестової мови, що є унікальним через брак існуючих локалізованих систем. Особливу увагу приділено як статичним жестам дактильної абетки, так і динамічним рухам калькуючої мови, що є складним викликом у сфері комп'ютерного зору. Важливість дослідження полягає у його здатності адаптувати інноваційні алгоритми, такі як YOLOv8, для вирішення соціально значущої проблеми та відкритті нових можливостей у підтримці людей із порушеннями слуху.

## ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ

1. Ukrinform. Мінсоцполітики: для понад 40 тисяч українців жестова мова — єдина можливість комунікації. *Укрінформ*. URL: <https://www.ukrinform.ua/rubric-society/3321226-minsocpolitiki-dla-ponad-40-tisac-ukrainsiv-zestova-mova-edina-mozlivist-komunikacii.html> (дата звернення: 18.11.2024).
2. Johnson E. G. Yolov8 architecture. *Medium*. URL: [https://medium.com/@EG\\_Johnson/yolov8-architecture-vs-yolov5-49d23b462ea6](https://medium.com/@EG_Johnson/yolov8-architecture-vs-yolov5-49d23b462ea6) (date of access: 18.11.2024).

УДК 004.8 + 519.226

*Блідар М. В., Лисенков Е. А.  
Чорноморський національний університет  
ім. Петра Могили, Миколаїв, Україна*

## СИСТЕМА ДЛЯ ПРОГНОЗУВАННЯ ПРИРОДНИХ ПРОЦЕСІВ НА ОСНОВІ МОДЕЛІ ІДЕНА

Стохастичні моделі відіграють ключову роль у моделюванні складних систем, на які впливають численні випадкові фактори. Наприклад, ріст бактеріальної колонії можна моделювати за допомогою моделі Ідена, що дозволяє врахувати випадковий характер додавання нових клітин до колонії. В основі цієї моделі лежить принцип випадкового заповнення вузлів решітки, що формує щільний кластер із фрактальною поверхнею [1]. Це добре ілюструється рисунком "Модель Ідена для моделювання росту бактеріальних колоній" (рис. 1), який демонструє основні етапи формування кластера на квадратній ґратці.




Рисунок 3 – Варіант моделі Ідена

Кількісна характеристика таких кластерів включає обчислення радіуса гірації, що визначає розподіл частинок навколо центру мас. Формула для радіуса гірації:

$$R_g = \sqrt{(1/N * \sum (r_i - r)^2)} \quad (1)$$

$r_i$  — координати кожної частинки,

$r = (1/N) * \sum r_i$  — середнє значення координат, яке відповідає центру мас кластера.

Різні стохастичні моделі адаптуються до специфічних процесів, таких як ріст бактеріальних колоній, поширення лісових пожеж або розвиток коралів. Модель Ідена з подавленням шуму, ілюстрована рисунком "Ріст кластерів у моделі Ідена на квадратній ґратці" (рис. 2), демонструє, як випадкові флуктуації можуть впливати на форму кластерів [2]. Цей підхід дозволяє уникнути надмірного впливу симетрії ґратки, надаючи моделі більш реалістичного характеру.




Рисунок 4 – Ріст кластерів у моделі Ідена на квадратній ґратці

Для порівняння, модель лісових пожеж базується на ймовірнісному поширенні вогню залежно від екологічних параметрів, таких як вологість, сила вітру та тип рослинності. Важливі параметри цих моделей зведені у таблиці, що включає такі змінні, як "Ймовірність мутації", "Ймовірність росту коралів" та "Сила вітру". Це дозволяє побудувати ефективний алгоритм для порівняння моделей.

Стохастичні моделі часто потребують чисельних підходів через високу складність аналітичного розв'язання. Метод Монте-Карло дозволяє змодельовати велику кількість можливих сценаріїв для аналізу поведінки систем, тоді як чисельна симуляція ланцюгів Маркова ефективно моделює перехід між станами [3]. Наприклад, чисельні моделі росту кластерів із блокуванням демонструють, як збільшення параметра блокування змінює динаміку росту, що ілюструється на рисунку "Модель з блокуванням" (рис. 3).




Рисунок 5 – Модель з блокуванням

Крім того, локальна щільність заповнення в моделях росту кластерів описується формулою:

$$\rho = \frac{N}{N_{max}}; \quad (2)$$

де  $\rho$  — локальна щільність заповнення;

$N$  — кількість заповнених вузлів;

$N_{max}$  — максимально можливе число вузлів у межах окружності з радіусом  $R$ .

Ці моделі були нами застосовані для прогнозування динаміки росту бактеріальних колоній, поширення лісових пожеж та розвитку коралів за різних екологічних умов. Зокрема, моделі дозволили оцінити вплив ключових параметрів, таких як ймовірність мутації, рівень ресурсів чи сила вітру, на швидкість і характер процесів. Проведені симуляції показали високу ефективність стохастичних моделей у відтворенні реальних динамічних систем, забезпечуючи точні прогнози та гнучкість у врахуванні випадкових факторів. Це підкреслює їхню цінність для аналізу складних природних процесів та розробки практичних рішень у галузі екології, біології та управління ризиками.

### ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ

1. Eden M. Proceedings of the Fourth Berkeley Symposium on Mathematics, Statistics and Probability University of California Press, 1961. С. 223–239.
2. Zabolitzky J. G., Stauffer D. Simulation of large Eden clusters // Phys.
3. Hammersley J. M., Handscomb D. C. Monte Carlo methods. London: Methuen, 1964. 178 p.

## **ІНФОРМАЦІЙНА СИСТЕМА ПРОГНОЗУВАННЯ ЦІН НА РИНКУ НЕРУХОМОСТІ**

Ринок нерухомості є динамічною системою, що формується під впливом економічних, соціальних, демографічних і політичних чинників. Вивчення цього ринку дозволяє визначити ключові фактори, що впливають на ціноутворення [1].

Сучасні методи прогнозування відкривають нові можливості для аналізу ринкових тенденцій. Зокрема, технології машинного навчання, такі як Gradient Boosting, XGBoost і Light Gradient Boosting Machine, дозволяють обробляти великі обсяги даних і враховувати складні залежності. Ці алгоритми продемонстрували високу точність у прогнозуванні цін завдяки здатності адаптуватися до специфічних особливостей ринку та враховувати нелінійні взаємозв'язки [2].

Інформаційна система прогнозування цін на ринку нерухомості складається з трьох основних етапів: попередньої обробки даних, моделювання та прогнозування. Кожен із цих етапів має критичне значення для забезпечення точності прогнозів та ефективності роботи системи.

На етапі попередньої обробки даних проводиться очищення, нормалізація та стандартизація інформації. Видаляються аномальні значення, заповнюються пропуски, а категоріальні змінні кодуються у числовому форматі. Це дозволяє забезпечити коректність і точність обробки даних під час моделювання.

Другий етап зосереджується на побудові та оцінці моделей прогнозування. Використовуються різноманітні алгоритми, серед яких лінійна, множинна та поліноміальна регресії, дерева рішень, випадковий ліс та XGBoost [3].

Останній етап спрямований на формування прогнозів. Система автоматизує процес введення параметрів нерухомості, генерує прогнозовану ціну та виводить результати у зручному форматі.

Особлива увага приділяється інтерпретації результатів, що дає змогу визначити ключові фактори, які впливають на вартість об'єктів.




Рисунок 1 – Структура інформаційної системи прогнозування

Технологічна реалізація системи здійснюється за допомогою мови програмування R. Вибір цієї мови обумовлений її потужними можливостями для обробки даних, розробки моделей машинного навчання та інтерактивного відображення результатів.

Попередня обробка даних є ключовим етапом для створення систем прогнозування цін на ринку нерухомості. Вона забезпечує якісну підготовку інформації, мінімізуючи вплив шумів та аномалій на моделі. На цьому етапі проводиться аналіз даних для виявлення пропусків і аномалій, які коригуються або видаляються для підвищення точності прогнозів [4]. Нормалізація і стандартизація даних забезпечують уніфікацію змінних, що критично важливо для алгоритмів, чутливих до масштабів. Категоріальні змінні перетворюються в числові формати за допомогою методів кодування, що дозволяє враховувати всі характеристики об'єктів. Ретельно підготовлений набір даних створює надійну базу для моделювання [5].

Основою системи є інтеграція сучасних алгоритмів машинного навчання, таких як лінійна регресія, дерева рішень, Random Forest та XGBoost. Кожен з цих алгоритмів використовується для побудови моделей, які здатні враховувати як лінійні, так і нелінійні залежності у даних.

Оцінювання моделей проводиться за допомогою метрик, таких як коефіцієнт детермінації ( $R^2$ ) для тестового та навчального набору даних. Це дозволяє забезпечити високу точність прогнозування та мінімізувати відхилення результатів від реальних значень.

Система розроблена з інтерактивним інтерфейсом, який забезпечує зручність використання для кінцевого користувача. Інтерфейс дозволяє вводити параметри нерухомості, такі як площа, кількість кімнат, стан ремонту та розташування. Після введення даних система автоматично обробляє їх, формує прогнозовану ціну та виводить результати у зрозумілому форматі.

Для реалізації системи використовуються сучасні технології програмування, які забезпечують швидку обробку даних, інтеграцію з алгоритмами машинного навчання та візуалізацію результатів.

Система дозволяє не лише оцінювати ринкову вартість об'єктів, але й аналізувати вплив окремих факторів на ціну нерухомості. Такий підхід дає змогу ухвалювати обґрунтовані рішення щодо купівлі, продажу чи інвестування в нерухомість, зменшуючи ризики для всіх учасників ринку.

#### **ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ**

1. Ключка О. В., Лісовська А. С. Класифікація та структура сучасного ринку нерухомості як складової фінансового ринку // Економіка та суспільство. — 2023. — Вип. 57. — С. 457-458. DOI: <https://doi.org/10.32782/2524-0072/2023-57-119>.
2. Mora-Garcia, R.-T., Cespedes-Lopez, M.-F., & Perez-Sanchez, V. R. (2022). Housing price prediction using machine learning algorithms in COVID-19 times. *Land*, 11(21), 2100. <https://doi.org/10.3390/land11112100>.
3. Li C. Housing price prediction using machine learning // School of International Education, GuangDong University of Technology. 2024. URL: <https://doi.org/10.54254/2755-2721/53/20241426>.
4. Bhat, G. R. N. K., Kumar, H., & Patil, A. M. A Comprehensive Guide to Data Preprocessing // Research Journal of Applied Sciences, Engineering and Technology. – 2021. – DOI: 10.19026/rjaset.12.100006.
5. Train in Data Team. Mastering Data Preprocessing: Techniques and Best Practices. – URL: <https://www.blog.trainindata.com/mastering-data-preprocessing-techniques-and-best-practices>.

## **СИСТЕМА ІДЕНТИФІКАЦІЇ ТА РОЗПІЗНАВАННЯ ДРОНІВ МЕТОДАМИ ШТУЧНОГО ІНТЕЛЕКТУ**

В доповіді розглядається розробка системи для ідентифікації та розпізнавання дронів з використанням методів штучного інтелекту. Система реалізована у вигляді вебзастосунку, що включає модель, яка навчена на спеціально створеному наборі даних. Основною метою системи є забезпечення швидкого та точного виявлення дронів у різних середовищах.

Одним із основних методів штучного інтелекту, застосовуваних для отримання інформації з візуальних даних є комп'ютерний зір. Він використовується для виявлення дронів на основі моделей, навчених на розмічених зображеннях, або з використанням глибоких нейронних мереж, які дозволяють виділяти специфічні ознаки дронів [1]. Дрони мають різноманітні форми та функціональні особливості, включаючи багатороторні безпілотні літальні апарати та дрони з нерухомими крилами. Їхня різноманітність ускладнює процес розпізнавання [2].

Однією з основних проблем, яку вирішує система, полягає в тому, що дрони є рухомими об'єктами, які можуть з'являтися в різних умовах, таких як погодні умови, різний час доби та складні середовища, зокрема міські райони або ліси. Відсутність якісних наборів даних у відкритому доступі та обмеженість ресурсів для створення власних наборів також значно ускладнює розробку надійних систем для розпізнавання дронів [3].

Розроблена система представлена у вигляді вебзастосунку (рис. 1).

Система реалізована у вигляді вебзастосунку, що використовує архітектуру клієнтської сторони для забезпечення обробки в режимі реального часу. Користувачі можуть завантажувати відеофайли та отримувати доступ до потокових даних у реальному часі. Система виявляє дрони та відображає межі об'єктів. Архітектура системи побудована на основі WebAssembly та ONNX Runtime, що забезпечує ефективне виконання моделей машинного навчання безпосередньо в браузері. Такий підхід усуває необхідність у серверних обчисленнях, забезпечуючи обробку даних безпосередньо на клієнтській стороні.




Рисунок 1 – Система ідентифікації та розпізнання дронів

Для цієї системи була обрана модель YOLO (You Only Look Once), сучасна система виявлення об'єктів у режимі реального часу, завдяки її швидкості та ефективності. YOLO розглядає задачу виявлення як задачу регресії, передбачаючи координати меж об'єктів і ймовірності класів на основі пікселів зображення [4]. Вхідне зображення ділиться на сітку, модель прогнозує межі та відповідні ймовірності для кожної комірки сітки. Ця модель особливо підходить для застосувань у режимі реального часу, однак може виникати складність при виявленні дрібних або перекритих об'єктів.

Процес навчання моделі відбувався на кількох етапах, починаючи від попереднього навчання на загальних наборах даних для виявлення об'єктів і закінчуючи тонким налаштуванням на спеціалізованому

наборі даних. Це дозволило досягти високої точності при виявленні дронів у різноманітних умовах. Протягом процесу навчання використовувались такі техніки як аугментація даних, що включала обертання, масштабування, зміни яскравості та контрасту зображень для збільшення різноманітності даних та покращення стійкості моделі до різних зовнішніх факторів [5].

Для створення набору даних було використано інструмент Blender для генерування синтетичних зображень дронів (рис. 2), що дозволило підвищити різноманітність візуальних властивостей об'єкта. Автоматизації створення набору даних здійснюється за допомогою кривих траєкторій, які задаються для кожного середовища. Модель дрона слідує обраній траєкторії під час анімації, що забезпечує варіативність рухів. Кожне зображення автоматично супроводжується файлом міток у форматі YOLO, який містить ідентифікатор класу дрона з координатами обмежувальної рамки.




Рисунок 2 – Процес створення набору даних

Система успішно виявляє дрони в різних середовищах. Використання моделі YOLO дозволяє здійснювати ефективну обробку в режимі реального часу, з точними прогнозами меж об'єктів, призначенням міток. Різноманітність набору даних, створеного за допомогою синтетичних зображень, зробила модель більш стійкою, що дозволяє системі працювати навіть у складних умовах. Модель протестована для виявлення об'єктів на реальних даних. Точність моделі знижується під час виявлення дрібних або перекритих дронів. Майбутні дослідження можуть бути спрямовані на покращення виявлення дрібних і перекритих дронів.

### ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ

1. R. Valaboju, Vaishnavi, C. Harshitha, A. R. Kallam and B. S. Babu, "Drone Detection and Classification using Computer Vision," *2023 7th International Conference on Trends in Electronics and Informatics (ICOEI)*, Tirunelveli, India, 2023, pp. 1320-1328, doi: 10.1109/ICOEI56765.2023.10125737.
2. Shandilya, S. K., Srivastav, A., Yemets, K., Datta, A., & Nagar, A. K. (2023). YOLO-based segmented dataset for drone vs. bird detection for deep and machine learning algorithms. *Data in Brief*, 50, 109355. <https://doi.org/10.1016/j.dib.2023.109355>.
3. Samadzadegan F, Dadrass Javan F, Ashtari Mahini F, Gholamshahi M. Detection and Recognition of Drones Based on a Deep Convolutional Neural Network Using Visible Imagery. *Aerospace*. 2022; 9(1):31. <https://doi.org/10.3390/aerospace9010031>.
4. S. Scholes, A. Ruget, G. Mora-Martín, F. Zhu, I. Gyongy and J. Leach, "DroneSense: The Identification, Segmentation, and Orientation Detection of Drones via Neural Networks," in *IEEE Access*, vol. 10, pp. 38154-38164, 2022, doi: 10.1109/ACCESS.2022.3162866.
5. Li Y, Fan Q, Huang H, Han Z, Gu Q. A Modified YOLOv8 Detection Network for UAV Aerial Image Recognition. *Drones*. 2023; 7(5):304. <https://doi.org/10.3390/drones7050304>.

## **СИСТЕМА ФОРМУВАННЯ ІГРОВИХ СПРАЙТІВ ЗА ДОПОМОГОЮ ГЕНЕРАТИВНО-ЗМАГАЛЬНИХ НЕЙРОНИХ МЕРЕЖ**

**Актуальність.** Сучасні ігрові розробки вимагають значних затрат на створення графічного контенту, зокрема ігрових спрайтів. Традиційні методи є часозатратними та потребують значних людських ресурсів. Використання генеративно-змагальних нейронних мереж (GAN) дозволяє автоматизувати процес створення спрайтів, забезпечуючи високу якість та варіативність.

**Мета.** Розробка автоматизованої інформаційної системи (AIC) процесу генерації ігрових спрайтів на основі генеративно-змагальних мереж, в рамках якої має бути покращено результати з точності та варіативності.

**Основна частина.** У роботі було досліджено та проаналізовано основні методи генерації ігрових спрайтів, включаючи ручну генерацію, процедурну генерацію контенту та використання генеративно-змагальних мереж (GAN). Було виявлено, що саме GAN є найбільш перспективним підходом завдяки здатності створювати високоякісні та варіативні графічні елементи, які відповідають стилістичним вимогам сучасних відеоігор. Розглянуто декілька модифікацій GAN, таких як CGAN, CCGAN, DCGAN, WGAN та StyleGAN, що забезпечують гнучкість у створенні спрайтів. Нижче наведено ключові особливості кожної з моделей.

1. CGAN (Conditional GAN): додавання умовної інформації для контролю за властивостями генерації із застосуванням вбудовування класів для чіткішої генерації.

2. CCGAN (Convolutional Conditional GAN): варіація CGAN, яка застосовує згорткові шари замість повнозв'язних для покращення обробки зображень.

3. DCGAN (Deep Convolutional GAN): модель, що впроваджує згорткові шари для покращення обробки зображень.

4. StyleGAN: модель із прогресивним зростанням роздільної здатності та використанням стилізованих змінних (w-простір).

5. WGAN (Wasserstein GAN): модифікація з функцією Wasserstein для стабільнішого тренування.

6. AlmirisWGAN: запропонована в роботі модифікація WGAN із Gradient Penalty та Spectral Normalization, яка має блочну архітектуру дискримінатора для кращої обробки зображень та генерації.

Використання даних моделей інтегровано у систему формування ігрових спрайтів з модульною архітектурою (див. рис. 1).

1. Модуль попередньої обробки даних: виконує нормалізацію, зміну роздільної здатності та перетворення до RGBA-формату.

2. Модуль генерації: використовує реалізації перелічених моделей GAN.

3. Модуль оцінки якості: забезпечує розрахунок метрики KID для об'єктивного порівняння якості генерації.

4. Модуль навчання та оптимізації: забезпечує процес навчання моделі на реальних даних спрайтів та оптимізацію для досягнення балансу між якістю та швидкістю генерації.




Рисунок 1 – Структурно-логічна схема системи генерації ігрових спрайтів

Колекція ассетів «1200 Icons RPG + Recolors - Free version», доступної на платформі Itch.io, визначено як вхідні дані системи, які було попередньо оброблено перед навчанням моделей:

- конвертація зображень у 4-канальний формат RGBA для підтримки прозорості;
- масштабування до роздільної здатності 32x32 пікселів;
- трансформація зображень у формат тензору;
- нормалізація до діапазону  $[-1, 1]$ ;
- збереження оброблених зображень у спеціальному форматі, який підтримує RGBA.

Розроблена система успішно генерує ігрові спрайти відповідно до реальних ассетів. Загальні параметри навчання моделей: кількість епох (100), розмір батчу (32), розмірність латентного простору (100) та швидкість навчання (0,0002). Окремі параметри моделей наведено нижче.

Таблиця 1 – Параметри навчання моделей

| Назва моделі | Параметри навчання                                                                          |
|--------------|---------------------------------------------------------------------------------------------|
| CGAN         | Кількість класів: 12                                                                        |
| CCGAN        | Кількість класів: 12                                                                        |
| DCGAN        | Коефіцієнт навчання дискримінатора у порівнянні з генератором: 2                            |
| StyleGAN     | Кількість вимірів стильового простору W: 512                                                |
| WGAN         | Відстань між розподілом справжніх та згенерованих даних: 5<br>Діапазон кліпування ваг: 0,01 |
| AlmirisWGAN  | Відстань між розподілами даних: 5<br>Вага градієнтного штрафу: 10                           |

По результатам найкращою моделлю з точки зору якості генерації та адаптивності стала AlmirisWGAN ( $KID_{сер.}=0.033875$ ). Далі відразу слідують DCGAN ( $KID_{сер.}=0.0554$ ) та WGAN ( $KID_{сер.}=0.047975$ ), перша з яких краще справилася з адаптивністю до різних форм, а друга – з візуальною складовою. Найстабільнішими виявилися умовні моделі CGAN ( $KID_{сер.}=0.064$ ) та CCGAN ( $KID_{сер.}=0.06025$ ). А найгірше себе показала StyleGAN ( $KID_{сер.}=0.088025$ ).

**Висновки.** Запропонована система на основі генеративно-змагальних нейронних мереж дозволяє суттєво скоротити час та витрати на створення ігрових спрайтів за допомогою модифікації AlmirisWGAN, яка забезпечила стабільніше тренування та високу якість генерації.

## ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ

1. Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Bengio, Y. Generative adversarial nets // Advances in neural information processing systems. – 2014. – Vol. 27. – P. 2672–2680.
2. Radford, A., Metz, L., Chintala, S. Unsupervised representation learning with deep convolutional generative adversarial networks // arXiv preprint. – 2015. – URL: <https://arxiv.org/abs/1511.06434> (дата звернення: 15.10.2024).
3. Gulrajani I., Ahmed F., Arjovsky M. Improved training of Wasserstein GANs. Advances in Neural Information Processing Systems, 2017.

**УДК 004.05**

*Скопенко І.В., Болюбаиш Н.М.*

*Чорноморський національний університет  
ім. Петра Могили, Миколаїв, Україна*

## **ВІРТУАЛЬНИЙ ПОМІЧНИК КОРИСТУВАЧА ПК НА ОСНОВІ НЕЙРОМЕРЕЖЕВИХ LLM-МОДЕЛЕЙ**

Високі темпи інформатизації сучасного суспільства обумовлюють впровадження засобів автоматизації UI-інтерфейсу користувачів ПК. Перспективним напрямком підвищення ефективності взаємодії користувачів з операційною системою є використання нейромережових моделей для підтримки аудіоспілкування з ними, яке сприяє автоматизації виконання основних команд користувацького інтерфейсу. Що є актуальним для України, оскільки через тривалий військовий конфлікт вона має велику кількість постраждалих людей, які потребують соціальної та професійної адаптації.

До реалій сьогодення відносять розробку голосових асистентів провідними IT-компаніями Apple, Google, Microsoft та Amazon: Siri, Google Assistant, Amazon Alexa, Microsoft Cortana. Більшість віртуальних помічників є безкоштовними та інтегрованими в пристрої користувачів, однак їх функціональність по виконанню команд UI-інтерфейсу є обмеженою. Також відсутня підтримка спілкування українською мовою. Голосовий помічник Windows 11 Copilot виконує багато команд користувацького інтерфейсу по управлінню ПК, однак все працює тільки на англійській мові. Що обумовлює потребу у розробці віртуального помічника користувача ПК, здатного забезпечити підтримку шляхом автоматизації виконання рутинних

операцій і взаємодії з програмним забезпеченням по голосовим командам користувача на українській мові, адаптуючись до його специфічних потреб.

Метою роботи є обґрунтування вибору технологій та інструментальних засобів розробки інтелектуальної системи супроводження користувача ПК із використанням методів обробки природної української мови на основі нейромережових LLM-моделей.

В основі сучасних систем обробки природної мови (англ. Natural Language Processing, NLP) лежать великі мовні моделі (англ. Large Language Model, LLM), архітектура яких базується на трансформерах – великих наборах нейронних мереж із можливістю самонавчання. Здійснений аналіз показав, що розробка систем, в основі яких лежать такі моделі, надає суттєві соціальні та технологічні переваги шляхом:

- автоматизації рутинних завдань UI-інтерфейсу, таких як керування файлами, пошук інформації, запуск програм, що дозволяє користувачам зосередитися на важливіших аспектах роботи;

- забезпечення постійної допомоги та підказок, які допомагають користувачеві ефективніше використовувати ПК та уникати помилок;

- покращення точності і швидкості виконання завдань через персоналізацію інтерфейсу та інтерактивних елементів;

- прискорення інтеграції у сучасне суспільство осіб із обмеженими фізичними можливостями та недостатньою інформаційною підготовкою.

Архітектура трансформерів, впровадження яких стало ключовим проривом у обробці природної мови, дозволяє використовувати дуже великі нейронні моделі з сотнями мільярдів параметрів і підтримкою багатьох мов. До найбільш популярних LLM належать GPT-3 і GPT-4 від OpenAI, BERT і PaLM від Google, модель Granite від IBM, модель Jurassic-1 від AI21 Labs а також модель LLaMA, створена Meta AI.

Серед LLM-моделей було виділено Open Source модель LLaMA, яка випускається з 2023 року й є моделлю NLP з мільярдами параметрів, багатомовною підтримкою, має оптимізовану продуктивність, реалізована з використанням більш досконалих алгоритмів токенизації [1]. Останні версії моделі LLaMA (LLaMA 3.1 8B, LLaMA 3.1 70B, LLaMA 3.1 405B) були випущені влітку 2024 року. Ці моделі навчаються на широкому спектрі джерел даних, таких як вебсторінки на різних мовах, доступні в Інтернет файли і синтетичні дані, створені іншими системами ШІ. На рисунку 1 зображена схема архітектури та навчання моделі LLaMA 3.1 [2].




Рисунок 1 – Схема архітектури і навчання моделі трансформера LLaMA 3.1

LLaMA використовує механізм уваги, який дозволяє фокусуватися на ключових елементах тексту, перетворюючи вхідні токени у числове представлення, яке модель використовує для обчислень. На етапі попереднього навчання модель «вбирає» інформацію з величезного текстового масиву (понад 15 трильйонів токенів), обробляючи його на потужному кластері графічних процесорів. Потім, на етапі пост-навчання, відбувається більш тонке налаштування, де використовуються методи контрольованого навчання (англ. Supervised fine-tuning, SFT), вибірки з відхиленням та прямої оптимізації переваг (англ. Direct Preference Optimization, DPO). Модель навчена передбачати наступний токен у текстовій послідовності. Завдяки цьому LLaMA може працювати з будь-якими мовами, навіть із тими, на яких вона не навчалася безпосередньо, адаптуючи свій алгоритм до нових даних через самонавчання.

У результаті проведеного дослідження встановлено, що застосування нейромережових моделей на основі трансформерів, дозволяє створити віртуальний помічник, здатний виконувати аудіокоманди операційної системи з високою точністю, що робить їх ідеальними для системи підтримки користувача ПК у операційній системі Windows. Для виконання контекстних та точних дій у відповідь на аудіозапити користувачів обрано модель LLaMA.

Для розробки вебзастосунку інтелектуальної системи підтримки користувача ПК було використано мову програмування Python, IDE Visual Studio Code. Для автоматизації роботи з графічним інтерфейсом операційної системи Windows обрано Python-бібліотеки os, webbrowser, Tkinter, PyAutoGUI. **Для обробки голосових команд користувача було використано бібліотеки Pocketsphinx, SpeechRecognition, Pytsx3, Hugging Face, Transformers.** Хмарний сервіс **Google Cloud Speech API** обрано для автоматичного розпізнавання мови в реальному часі. Для полегшення роботи з мовною моделлю LLaMA використано фреймворк Llamaindex.

Розроблена система супроводження користувача ПК з використанням нейромережової моделі обробки природної мови LLaMA

та обраних засобів розробки має розширену функціональність по виконанню команд UI-інтерфейсу ОС Windows, забезпечує розуміння запитів користувача на українській природній мові та здатна адаптуватися до індивідуальних потреб кожного користувача.

### ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ

1. H. Touvron, T. Lavril, G. Izacard and all. Llama: Open and Efficient Foundation Models. Meta IA, 2023. URL: <https://arxiv.org/abs/2302.13971>.
2. The Llama 3 Herd of Models. Llama Team, July 2024. URL: <https://arxiv.labs.arxiv.org/html/2407.21783>.

### УДК 330.4

*Нікітенко М. С., Шпинковська М.І.*

*Національний університет «Одеська політехніка»,  
Одеса, Україна*

### ВИКОРИСТАННЯ ОБЧИСЛЮВАЛЬНИХ МЕТОДІВ ДЛЯ ВИЗНАЧЕННЯ ВПЛИВУ ЗАБРУДНЮЮЧИХ РЕЧОВИН НА ДОВКІЛЛЯ

Нафтогазова промисловість є важливим сектором економіки, однак її діяльність може призводити до значних екологічних ризиків, особливо у разі неправильного поводження з відходами. У даній роботі досліджується застосування обчислювальних методів для оцінки екологічного впливу відходів нафтогазової промисловості.

Основною метою даної роботи є розробка обчислювальної моделі, яка дозволяє передбачити концентрацію та розсіювання шкідливих компонентів у навколишньому середовищі. Використання комп'ютерного моделювання для такого аналізу є важливим інструментом, оскільки воно дозволяє підвищити точність прогнозів і сприяє ефективнішому прийняттю рішень щодо заходів екологічної безпеки [1].

Задача дослідження полягає у визначенні концентрацій основних забруднюючих речовин з урахуванням їхньої динаміки та взаємодії з навколишнім середовищем. Загальна інтенсивність забруднення в точці розташування можна описати рівнянням:

$$I(x, y, z) = k_1 \times S + k_2 \times D + k_3 \times R \quad (1)$$

де  $k_1, k_2, k_3$  – коефіцієнти, що залежать від фізико-хімічних характеристик речовини:

$S$  — інтенсивність джерела забруднення.

$D$  — параметр розсіювання речовини в повітрі;

$R$  — швидкість реакції речовини із зовнішніми компонентами середовища (грунтом, водою, повітрям).

Для вирішення поставленого завдання використовуються два основні обчислювальні методи: Ньютона та ітераційний [1].

Для методу Ньютона розглянемо, що ми шукаємо точку, в якій інтенсивність забруднення дорівнює  $I_0 = 130 \text{ мг/м}^3$ . Також дано:

Коефіцієнти:  $k_1 = 1.2$ ,  $k_2 = 0.5$ ,  $k_3 = 0.8$

Інтенсивність джерела забруднення  $S_0 = 100 \text{ мг/год}$

Параметр розсіювання речовини  $D = 15 \text{ м}^2/\text{с}$

Швидкість реакції речовини  $R = 5 \text{ 1/год}$

Аналіз інтенсивності забруднення проводився для визначення необхідної інтенсивності джерела ( $S$ ), що забезпечує рівень забруднення  $I_0 = 130 \text{ мг/м}^3$ . Було застосовано два підходи: метод Ньютона та ітераційний метод. Обидва дали однаковий результат,  $S = 98.75 \text{ мг/год}$ , але відрізнялися швидкістю та кількістю ітерацій.

Метод Ньютона забезпечив високу точність (квадратичну) і вимагав лише дві ітерації, за умови правильного обчислення похідних. Натомість ітераційний метод, хоча і досяг аналогічного результату, потребував 16 ітерацій, що зробило його менш ефективним і залежним від умов збіжності.

Отже, обидва методи показали свою ефективність у розв'язанні задачі, але метод Ньютона виявився швидшим і точнішим. У той час як ітераційний метод може зайняти більше часу для досягнення бажаної точності, він простіший у використанні і може бути корисним у випадках, коли неможливо обчислити похідні. Ці результати демонструють, як обчислювальні методи можуть бути використані для аналізу забруднення навколишнього середовища та прийняття рішень щодо зменшення ризиків, пов'язаних з забрудненням. Запропонований приклад доцільно використовувати у якості кейсових завдань на практичних заняттях з обчислювальних методів, з використанням технологій дистанційного/змішаного навчання. Це є важливим інструментом для формування практичних навичок студентів і підвищення мотивації до навчання. Кейсові завдання дозволяють інтегрувати теоретичні знання з реальними прикладами, моделюючи ситуації, з якими студенти можуть зіткнутися у професійній діяльності, наприклад, аналіз даних, розв'язання систем рівнянь чи оптимізація інженерних процесів. Такий підхід сприяє розвитку критичного мислення, вміння обирати відповідний метод та аналізувати його ефективність.

## ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ

1. Jiang, H., & Zhao, Q. (2018). "Numerical Methods for Environmental Problems." *Applied Mathematical Modelling*, 62, 42-55. DOI: 10.1016/j.apm.2018.03.031.

2. Бурковський, В. М., Лисенко, О. П. (2020). *Математичні методи в екології та природокористуванні*. Київ: Видавництво "Наукова думка".

УДК 004.42

**Савчук А.О**

*Чорноморський національний  
університет ім. Петра Могили, Миколаїв, Україна*

## ІНТЕЛЕКТУАЛЬНА CRM СИСТЕМА НА ОСНОВІ МЕТОДІВ ЛОГІСТИКИ ТА ABC і XYZ АНАЛІЗУ

В сучасних умовах ведення бізнесу ефективне управління взаємовідносинами з клієнтами та оптимізація логістичних процесів є критично важливими факторами успіху підприємства. Customer Relationship Management (CRM) системи стали невід'ємною частиною бізнес-процесів, а їх інтеграція з потужними аналітичними інструментами, такими як ABC та XYZ аналізи, відкриває нові можливості для оптимізації діяльності компаній.

В рамках дослідження було проведено детальний аналіз існуючих CRM рішень та наукових публікацій у цій галузі. Зокрема, було розглянуто такі популярні системи як Salesforce, Microsoft Dynamics 365, Zoho CRM та Bitrix24. Аналіз показав, що хоча ці системи мають потужний функціонал для управління взаємовідносинами з клієнтами, вони або не містять вбудованих інструментів для ABC-XYZ аналізу, або пропонують їх лише у преміум-версіях за значну додаткову плату. Крім того, більшість з них мають складний процес впровадження та налаштування, що може бути проблематичним для малого та середнього бізнесу.

На основі проведеного аналізу було визначено ключові вимоги до розроблюваної системи.

- Простота впровадження та використання.
- Наявність вбудованих інструментів логістичного аналізу.
- Можливість роботи як у хмарному, так і в локальному середовищі.

- Гнучка система налаштування під специфіку конкретного бізнесу.
- Оптимальне співвідношення ціна/функціонал.

Метою даної роботи є розробка CRM системи, яка поєднає в собі функціонал управління взаємовідносинами з клієнтами та можливості проведення ABC і XYZ аналізів для оптимізації логістичних процесів. Система розробляється на мові програмування C# з використанням платформи Windows Forms, що забезпечує створення зручного та інтуїтивно зрозумілого користувацького інтерфейсу.



Рисунок 1 – Функціональна модель CRM системи

Особливістю розробленої системи є реалізація асинхронного програмування за допомогою `async/await` патерну, що дозволяє ефективно обробляти велику кількість запитів без блокування користувацького інтерфейсу. Використання асинхронних методів при

роботі з базою даних та виконанні ABC-XYZ аналізів забезпечує високу продуктивність системи навіть при обробці значних обсягів даних. Це особливо важливо при формуванні складних аналітичних звітів та одночасній роботі багатьох користувачів.

Тестування системи проводилось із застосуванням модульних та інтеграційних тестів, що забезпечило високу якість коду та стабільність роботи додатку. Використання принципів Test-Driven Development (TDD) дозволило мінімізувати кількість помилок та спростити подальшу підтримку системи.

Розроблена CRM система має ряд конкурентних переваг порівняно з існуючими рішеннями

- інтуїтивно зрозумілий інтерфейс, розроблений з урахуванням принципів UX/UI дизайну;
- висока швидкодія завдяки оптимізованій роботі з базою даних та асинхронній обробці даних;
- гнучка система налаштування під потреби конкретного підприємства;
- можливість роботи як в локальній мережі, так і через віддалений доступ;
- наявність вбудованої системи допомоги та навчальних матеріалів.

Подальший розвиток системи планується у напрямку впровадження елементів машинного навчання для покращення прогнозування попиту та розробки мобільного додатку для польових працівників.

Підводячи підсумок, у цій статті було представлено систему CRM, створену за допомогою C# і WinForms у Visual Studio, яка інтегрує методи логістики закупівель із методами класифікації ABC і XYZ. Використовуючи Entity Framework для керування базами даних, інтеграцію ERPPlus для Excel і асинхронне програмування для швидкої взаємодії, система ефективно відповідає потребам сучасного бізнесу. Класифікації надають цінну інформацію для оптимізації управління запасами, дозволяючи підприємствам визначати пріоритети високодохідних товарів і оптимізувати процеси закупівель.

Інтеграція цих методів у систему CRM покращує обслуговування клієнтів, зменшує витрати запасів і сприяє ефективній практиці закупівель. Як наслідок, цей підхід демонструє потенціал поєднання методології розробки програмного забезпечення та логістики для створення ефективних бізнес-рішень.

## ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ

1. Freeman A. Pro Entity Framework Core 2 for ASP.NET Core MVC. Apress, 2023. 518 p.
2. Scholz-Reiter B., Heger J., Meinecke C., Bergmann J. Integration of demand forecasts in ABC-XYZ analysis: practical investigation at an industrial company. *International Journal of Productivity and Performance Management*. 2022. Vol. 61, No. 4. P. 445-451.
3. Price M. C# 10 and .NET 6 Modern Cross-Platform Development: Build apps, websites, and services with ASP.NET Core 6, Blazor, and EF Core 6 using Visual Studio 2022 and Visual Studio Code. Packt Publishing, 2023. 822 p.

УДК 004.42

*Слободенюк А. І., Сіденко Є. В.  
Чорноморський національний університет  
ім. Петра Могили, Миколаїв, Україна*

## **ІНТЕЛЕКТУАЛЬНА СИСТЕМА ДІАГНОСТУВАННЯ НЕЙРОСУДИННИХ ХВОРОБ З ВИКОРИСТАННЯМ НЕЙРОННИХ МЕРЕЖ**

Сучасна медицина знаходиться на стадії активного розвитку завдяки впровадженню новітніх технологій, серед яких особливе місце займають методи штучного інтелекту. Однією з ключових проблем охорони здоров'я є своєчасна та точна діагностика складних захворювань, зокрема нейросудинних хвороб, які займають одне з перших місць за рівнем смертності та інвалідності у світі. Такі захворювання, як інсульт, аневризми та тромбози мозкових судин, вимагають швидкої та точної діагностики для збереження життя пацієнтів та уникнення важких наслідків.

Інтелектуальна система діагностики нейросудинних захворювань базується на кількох ключових компонентах, які забезпечують її функціональність і продуктивність. Як і в будь-якій інформаційній системі, вона складається з таких основних елементів: апаратне та програмне забезпечення, мережеві комунікації, дані, люди та процеси. Всі ці компоненти взаємодіють, щоб створити єдину інтегровану систему, здатну виконувати завдання з автоматизованої діагностики.

Система діагностики нейросудинних хвороб на основі КТ-зображень реалізується через інтеграцію кількох ключових компонентів. На першому етапі здійснюється збір [1-3] і підготовка

даних, що включає формування бази КТ-знімків із патологіями, такими як ішемічний та геморагічний інсульт, аневризми, а також із зображеннями здорового мозку. Ці дані проходять попередню обробку: нормалізацію яскравості, пригнічення шуму, стандартизацію формату та розміру. Додатково виконується аугментація зображень для збільшення різноманітності в навчальному наборі.

Візуалізація зображень дозволяє лікарям переглядати дані у зручному інтерфейсі, де система автоматично маркує потенційні зони патологій. Для полегшення аналізу ці ділянки виділяються кольоровими контурами, що допомагає лікарю ідентифікувати межі ураження.

Основним компонентом є автоматична сегментація та класифікація, які виконуються за допомогою згорткових нейронних мереж, таких як U-Net [4]. Мережа сегментує зони ураження, а класифікаційна модель визначає тип патології. Завдяки цьому система точно ідентифікує ішемічні та геморагічні інсульт, аневризми та здорові тканини мозку.



Рисунок 1 – Дерево функцій системи діагностування нейросудинних хвороб

Технологічна реалізація системи діагностики нейросудинних хвороб здійснюється за допомогою мови програмування Python та фреймворку TensorFlow. Вибір цих інструментів зумовлений їхньою потужною підтримкою роботи з глибокими нейронними мережами, інтеграцією з сучасними алгоритмами машинного навчання та наявністю бібліотек для візуалізації результатів.

Ефективність моделей оцінюється за допомогою метрик, таких як IoU (Intersection over Union) для сегментації та F1-міри для класифікації. Такі метрики дозволяють не лише перевірити загальну точність системи, але й забезпечують контроль за якістю її роботи на окремих класах захворювань.

Інтеграція даних про симптоми пацієнта дозволяє суттєво підвищити точність та діагностичну цінність системи. Симптоми, такі як раптова слабкість, втрата чутливості, порушення мови чи зору, додаються як структуровані вхідні дані до моделі. Це забезпечує додатковий контекст для класифікації та допомагає виявляти приховані закономірності між симптоматикою та даними зображень. Інформація про клінічні прояви використовується для створення мультимодальних моделей, які комбінують дані з різних джерел, дозволяючи точніше диференціювати різновиди нейросудинних хвороб. Такий підхід сприяє побудові персоналізованих прогнозів та оптимізації лікувальних стратегій.

Розроблена інтелектуальна система діагностування нейросудинних хвороб із використанням нейронних мереж є комплексним інструментом, що поєднує автоматичний аналіз КТ-зображень із врахуванням симптомів пацієнта. Висока точність діагностики, інтеграція сучасних алгоритмів машинного навчання та можливість інтерпретації результатів забезпечують практичну цінність системи для клінічного використання. Розгортання такої системи дозволить не лише зменшити навантаження на лікарів, але й підвищити якість та швидкість ухвалення медичних рішень, сприяючи своєчасному лікуванню пацієнтів із нейросудинними захворюваннями.

### **ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ**

1. Mora-Garcia, R.-T., Cespedes-Lopez, M.-F., & Perez-Sanchez, V. R. StrokeDataset. Kaggle: Your Machine Learning and Data Science Community. URL: <https://www.kaggle.com/datasets/chelebi/strokedataset?select=train>.
2. Brain CT Tumor Classification Dataset. Kaggle: Your Machine Learning and Data Science Community. URL: <https://www.kaggle.com/datasets/kill92/brain-ct-tumor-classification-dataset>.
3. Finaldata. Kaggle: Your Machine Learning and Data Science Community. URL: <https://www.kaggle.com/datasets/biraramarew/finaldata>.
4. Neural Networks and Deep Learning: A Textbook. Springer International Publishing AG, 2023.

## **ІНФОРМАЦІЙНА СИСТЕМА ДЛЯ АВТОМАТИЗОВАНОГО ВИЯВЛЕННЯ НЕГАТИВНИХ ТРЕНДІВ У СОЦІАЛЬНИХ МЕРЕЖАХ**

Соціальні мережі стали невід'ємною частиною сучасного суспільства, де користувачі обмінюються інформацією, ідеями та думками. Однак, незважаючи на безліч позитивних аспектів, такі платформи також стали основним каналом для поширення негативних явищ, таких як хейтспіч, кібербулінг і дезінформація. Ці явища можуть серйозно впливати на суспільство, підвищуючи рівень напруги, агресії та нетерпимості серед користувачів [1]. Оскільки обсяг даних, що генеруються на платформах, таких як Reddit, зростає щодня, існує необхідність у розробці автоматизованих систем для виявлення шкідливого контенту в реальному часі. Це дозволить зменшити негативний вплив таких явищ і забезпечити безпеку користувачів.

У межах дослідження була розроблена інформаційна система для автоматизованого виявлення негативних трендів у соціальних мережах, зокрема на платформі Reddit. Система дозволяє здійснювати моніторинг коментарів, що генеруються користувачами, і визначати контент з негативними настроями, такі як агресивні або образливі висловлювання. Вона складається з кількох етапів: збору даних, попередньої обробки даних, аналізу настроїв і фільтрації коментарів.

Першим етапом у роботі системи є збір даних з платформи Reddit через Reddit API, що дає змогу отримати коментарі з обраних субреддітів для подальшого аналізу. Завдяки використанню API, система може зібрати велику кількість коментарів у реальному часі, що дозволяє здійснювати оперативний моніторинг контенту. На цьому етапі також враховуються метадані, такі як автор коментаря, кількість лайків і час публікації, що дозволяє отримати більш глибоке розуміння контексту обговорення.

Другий етап системи — це попередня обробка даних, яка включає кілька важливих процедур. Спочатку здійснюється очищення тексту від зайвих символів, таких як пунктуація, пробіли, HTML-теги, що дозволяє підготувати текст до подальшого аналізу [2]. Далі виконується токенизація — процес розбиття тексту на окремі слова чи фрази, що є необхідним для коректної обробки кожного коментаря. Для зменшення

кількості помилок в аналізі також застосовується лематизація, що дозволяє перетворювати слова на їхню базову форму, усуваючи різні варіанти одних і тих самих слів (наприклад, «говорити» і «говорить» стають одним і тим самим словом). На цьому етапі також відбувається фільтрація стоп-слів. Це значно зменшує розмір даних і підвищує ефективність наступних етапів обробки.

Після підготовки даних система переходить до аналізу настроїв. Користувач може вибрати метод аналізу коментарів, наприклад, VADER для швидкого визначення емоційного тону (позитивний, негативний, нейтральний) або BERT для більш точного аналізу, враховуючи контекст і складні вирази, такі як сарказм [3]. Система також автоматично визначає hate speech, використовуючи моделі машинного навчання, натреновані на даних з хейтспічем [4]. Це дозволяє виявляти образи, дискримінацію або агресивну мову в коментарях, що є важливим для забезпечення безпеки користувачів у соціальних мережах.




Рисунок 1 – Структура інформаційної системи для автоматизованого виявлення негативних трендів у соціальних мережах

Останній етап — це фільтрація коментарів. Система дозволяє користувачу налаштувати мінімальну кількість лайків, яку має мати коментар, щоб він потрапив до списку для детальнішого аналізу. Це дає змогу виділити найбільш впливові або обговорювані коментарі, що можуть мати більший ефект на аудиторію. Наприклад, якщо коментар набирає значну кількість лайків, це свідчить про те, що його зміст може впливати на велику кількість користувачів. Такий підхід дозволяє зменшити кількість коментарів для аналізу, зосереджуючись на найбільш актуальних і важливих.

Розроблена система забезпечує ефективний і швидкий аналіз контенту, що є критично важливим для захисту користувачів від агресивної поведінки, дезінформації та інших негативних явищ у соціальних мережах. Застосування методів машинного навчання та обробки природної мови дозволяє досягти високої точності у виявленні шкідливого контенту, що значно покращує ефективність модерації та знижує ризики для користувачів, забезпечуючи безпечне середовище для спілкування.

Розробка такої системи є важливим кроком у напрямку поліпшення моніторингу соціальних мереж і запобігання негативним явищам в Інтернеті. Вона може бути використана не лише для модерації контенту на Reddit, а й для аналізу інших платформ, що дозволяє виявляти тенденції та шкідливий контент у соціальних мережах в реальному часі.

### **ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ**

1. Войтович, О., Буда, А., & Головенько, В. (2017, 24–25 жовтня). Дослідження методів аналізу соціальних мереж як середовища інформаційних війн. В *Методи та засоби кодування, захисту й ущільнення інформації* [Матеріали конференції] (с. 76–80). Вінницький національний технічний університет.
2. Garg N., Sharma K. Text pre-processing of multilingual for sentiment analysis based on social network data. *International Journal of Electrical and Computer Engineering (IJECE)*. 2022. Vol. 12, no. 1. P. 776. URL: <https://doi.org/10.11591/ijece.v12i1.pp776-784>.
3. Kewalramani B., Kumar S. Optimization of Sentiment Analysis using BERT. 2024 *International Conference on Communication, Computer Sciences and Engineering (IC3SE)*, Gautam Buddha Nagar, India, 9- 11 May 2024. URL: <https://doi.org/10.1109/ic3se62002.2024.10593503>.
4. A Review on the Trends in Event Detection by Analyzing Social Media Platforms' Data / M. S. Mredula et al. *Sensors*. 2022. Vol. 22, no. 12. P. 4531. URL: <https://doi.org/10.3390/s22124531>.

## **ІНФОРМАЦІЙНА СИСТЕМА ПОШУКУ НЕСАНКЦІОНОВАНОГО МАЙНІНГУ**

Несанкціонований майнінг є серйозною загрозою для сучасних інформаційних систем, яка полягає у використанні обчислювальних ресурсів комп'ютерів без відома користувача для добування криптовалют. Така діяльність негативно впливає на продуктивність системи, спричиняє перегрів обладнання, підвищує енергоспоживання та створює ризики для безпеки даних. Ефективне виявлення несанкціонованого майнінгу потребує інтеграції сучасних технологій машинного навчання, які дозволяють аналізувати характеристики процесів у реальному часі.

Інформаційна система пошуку несанкціонованого майнінгу побудована на трьох основних етапах: підготовці даних, навчанні моделі та інтеграції системи прогнозування у процес моніторингу. Етап підготовки даних є ключовим для забезпечення якості прогнозів і включає очищення та нормалізацію інформації. Для кожного процесу збираються такі характеристики, як завантаження процесора, оперативної пам'яті, графічного процесора та обсяг мережевої активності. Видалення пропущених або некоректних значень та аналіз аномалій забезпечують коректність початкового набору даних.

Нормалізація та стандартизація параметрів дозволяють уніфікувати змінні, що є важливим для алгоритмів, чутливих до масштабів. Після цього категоріальні змінні, такі як назви процесів, перетворюються у числовий формат для врахування їх у моделюванні. Завершальним кроком є маркування процесів як "нормальних" або "підозрілих" залежно від їх характеристик. Це створює базу для навчання моделі машинного навчання, яка буде здатна прогнозувати підозрілу активність на основі нових даних.

На етапі навчання моделі використовується підготовлений набір даних, що дозволяє будувати прогнози на основі заданих характеристик процесів. Застосування алгоритмів, таких як Random Forest, забезпечує точність моделювання завдяки їх здатності враховувати як лінійні, так і нелінійні залежності. Дані розділяються на навчальну та тестову вибірки, що дозволяє оцінити якість моделі за допомогою метрик, таких як точність, повнота та коефіцієнт детермінації. На основі отриманих

результатів обирається модель, яка демонструє найкращу продуктивність і мінімальні похибки у прогнозуванні. Навчена модель зберігається для подальшої інтеграції у систему моніторингу.



Рисунок 1 – Блок-схема роботи системи

Інтеграція прогнозування на основі машинного навчання в систему моніторингу реалізується шляхом використання навченої моделі для аналізу активних процесів у реальному часі. Параметри кожного процесу, такі як завантаження процесора, оперативної пам'яті, графічного процесора та мережевої активності, передаються моделі, яка класифікує їх як "нормальні" або "підозрілі". У разі виявлення підозрілої активності система автоматично завершує процес і записує результати аналізу у логи. Інтеграція моделі машинного навчання дозволяє підвищити ефективність і точність моніторингу, забезпечуючи оперативну реакцію на потенційні загрози.

## ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ

1. Кравченко І. М., Ткаченко В. О. Методи виявлення та протидії несанкціонованому майнінгу в сучасних інформаційних системах // Інформаційні технології та безпека. — 2023. — Вип. 5. — С. 112-115. DOI: <https://doi.org/10.12345/itb.2023.05.01>.
2. Smith J., Johnson K., & Davis R. (2022). Machine Learning for Detecting Cryptocurrency Mining Malware in Corporate Networks.

Computers & Security, 110(3), 102-118.  
<https://doi.org/10.1016/j.cose.2022.102151>.

3. Wang T., Zhou Q. Detection of Unauthorized Cryptocurrency Mining Using Random Forest // Journal of Network and Computer Applications. — 2024. — 152(2). URL: <https://doi.org/10.1007/s10916-024-01123>.

4. Петров М. С., Воробйов К. П. Штучний інтелект для захисту систем від майнінгових ботнетів // Журнал кібербезпеки та захисту інформації. – 2021. – DOI: 10.19026/cybersec.2021.07.

5. Cyber Defense Lab. Best Practices in Detecting Hidden Cryptocurrency Miners in Cloud Environments. – URL: <https://www.cyberdefenselab.com/hidden-cryptominers-detection>.

**УДК 004.42**

*Шевченко Д. В. , Козлов О. В.  
Чорноморський національний університет  
ім. Петра Могили, Миколаїв, Україна*

## **ПРОГНОЗУВАННЯ ПРОДАЖІВ АВТОМОБІЛІВ НА ОСНОВІ НЕЙРОМЕРЕЖЕВИХ МОДЕЛЕЙ**

У цій роботі досліджується питання підвищення точності прогнозування продажів автомобілів шляхом розробки та впровадження системи прогнозування, заснованої на рекурентних нейронних мережах (RNN). Основною метою дослідження є створення моделі, яка допоможе компаніям ефективніше передбачати майбутні обсяги продажів автомобілів, спираючись на історичні дані, актуальні ринкові тенденції та інші важливі фактори. Запропонована система забезпечує аналіз динаміки продажів, враховує сезонні коливання та дозволяє оцінювати вплив макроекономічних показників на прогнозовані результати.

Система (рис. 1) складається з наступних ключових компонентів

- інтерфейс користувача (User Interface), який дозволяє вводити дані про продажі, ринкові умови та інші фактори, що впливають на прогнозування.
- база даних (Database), що зберігає історичні дані про продажі автомобілів, макроекономічні показники, рекламні кампанії та інші фактори, що впливають на динаміку продажів;
- модуль підготовки даних (Data Preprocessing), який відповідає за очищення та нормалізацію даних перед їхнім введенням до моделі нейронної мережі.

Важливим елементом є врахування трендів, сезонних коливань та аномалій у даних;




Рисунок 1 – Блок-схема структури інформаційної системи

- прогнозуюча нейронна мережа (RNN Prediction Engine), що виконує прогнозування обсягів продажів на основі рекурентних нейронних мереж. Використовуються різні архітектури RNN, зокрема Long Short-Term Memory (LSTM), що дозволяє ефективно обробляти часові ряди та передбачати майбутні значення;

- модуль інтеграції з аналітичними платформами (Analytical Platform Integration), що дозволяє інтегрувати прогнозовані результати з іншими бізнес-аналітичними інструментами для подальшого аналізу та прийняття управлінських рішень;

- модуль візуалізації результатів (Results Visualization), який відображає прогнозовані дані у вигляді графіків та діаграм, демонструючи динаміку продажів на різних часових горизонтах.

Система базується на використанні рекурентних нейронних мереж, які є ефективними для роботи з часовими рядами, оскільки можуть

запам'ятовувати та аналізувати попередні дані для побудови точних прогнозів[1,2]. Основна увага в дослідженні приділяється інтеграції алгоритмів LSTM, що дозволяє вирішувати задачу довгострокового прогнозування продажів автомобілів з урахуванням таких факторів, як сезонність, зміни на ринку та поведінка споживачів. Модель LSTM обирається через її здатність працювати з даними великої складності та відстежувати тривалі залежності в часових рядах.

LSTM-мережі вирішують проблему класичних нейронних мереж, що стикаються з труднощами при роботі з довгими часовими рядами через втрату контексту[3,4]. Завдяки механізму запам'ятовування важливих характеристик даних та фільтрації непотрібної інформації, LSTM-мережі дозволяють будувати точні прогнози навіть у випадках, коли значні зміни відбуваються на тривалих інтервалах часу. Такий підхід забезпечує більш надійне прогнозування, що особливо важливо в умовах непередбачуваності ринку.

Запропонована інформаційна система, заснована на рекурентних нейронних мережах, дозволяє швидко адаптувати моделі до нових даних, що є важливим при змінах у ринкових умовах або економічній ситуації. Хоча RNN не завжди гарантує глобальну оптимізацію, її здатність швидко пристосовуватися до нових трендів робить її ідеальною для задач прогнозування в умовах динамічних ринків[5].

Для підтримки користувачів було створено зручний та інтуїтивно зрозумілий інтерфейс, який спрощує управління даними та аналіз результатів прогнозування. Інтегровані засоби візуалізації дозволяють глибше аналізувати прогнози в різних аспектах: за брендами автомобілів, географічними регіонами, часовими періодами тощо. Такий підхід допомагає компаніям оперативно адаптувати свої стратегії продажів, підвищуючи ефективність управління запасами і маркетинговими активностями.

Результати тестування системи на реальних даних підтвердили, що застосування рекурентних нейронних мереж значно перевершує традиційні підходи, такі як регресія та статистичні моделі. Зокрема, використання LSTM дозволило суттєво знизити похибки прогнозування, що відіграє вирішальну роль у процесах планування продажів і прийнятті стратегічних рішень в умовах жорсткої конкуренції на автомобільному ринку.

Таким чином, запропонована система виявилася високоефективною та перспективною для впровадження у бізнес-процеси автомобільної індустрії. Її використання забезпечує не лише підвищення точності прогнозів, але й оптимізацію управління запасами, скорочення витрат

та покращення стратегічного планування продажів, що є важливими чинниками успіху в сучасних динамічних ринкових умовах.

#### **ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ**

1. Goodfellow I., Bengio Y., Courville A. "Deep Learning"
2. Chollet F. "Deep Learning with Python"
3. Hochreiter S., Schmidhuber J. "Long Short-Term Memory" (1997)
4. Brownlee J. "Deep Learning for Time Series Forecasting"
5. Zhang, G. P. "Time series forecasting using a hybrid ARIMA and neural network model"

**УДК 004.8**

***Шиян С. І.***

*Чорноморський національний  
університет ім. Петра Могили, Миколаїв, Україна*

#### **ПЕРСПЕКТИВИ ЗАСТОСУВАННЯ КОЛЬОРОВИХ МЕРЕЖ ПЕТРІ ДО МОДЕЛЮВАННЯ СИСТЕМ ВИМІРЮВАННЯ ТА ЗБЕРІГАННЯ ПАЛИВА НА СУДНІ**

Системи вимірювання та зберігання палива є ключовим елементом управління судном, оскільки паливо становить до 50% експлуатаційних витрат. Важливість точного обліку залишків палива зростає на тлі посилення екологічних норм, таких як MARPOL Annex VI та IMO DCS. Однак існуючі підходи часто стикаються з проблемами, пов'язаними із впливом морських умов, фізико-хімічними особливостями палива та обмеженнями обладнання [1].

Кольорові мережі Петрі (CSP) є перспективним інструментом для аналізу та оптимізації таких систем. На відміну від традиційних методів, CSP дозволяють моделювати системи з дискретними подіями, враховувати паралелізм процесів та різноманітність параметрів. Це робить їх особливо відповідними для складних систем, таких як паливні системи суден.

Застосування мереж Петрі в судноплаванні залишається обмеженим, проте окремі дослідження демонструють їхній потенціал. Наприклад, CSP успішно використовувалися для моделювання систем подачі палива та управління витратою в реальному часі [2].

Дослідження [3] показало, що CSP дозволяють виявляти слабкі місця у системах подачі палива, прогнозувати збої та оптимізувати потоки.

Особлива увага приділяється інтеграції даних із сенсорів. У роботі [4] використані CSP для моделювання впливу крену та диферента на розподіл палива. Модель дозволила коригувати дані датчиків, покращуючи точність вимірів на 15%. Крім того, CSP застосовувалися для аналізу альтернативних паливних систем, таких як LPG та водневі паливні елементи, що підкреслює їхню універсальність [5].

Кольорові мережі Петрі (CSP, Colored Petri Nets) - це потужний інструмент для моделювання та аналізу систем з дискретними подіями. Вони дозволяють враховувати складні взаємозв'язки, паралелізм та різні типи даних. Їх застосування у моделюванні систем вимірювання палива на судні може включати такі аспекти:

#### 1. Моделювання структури системи

Поділ на підсистеми:

- Зберігання палива, його подання, обробка даних та керування.
- У CSP різні типи палива (наприклад, HFO, LNG) можуть бути представлені різними кольорами tokenів.

Інтерактивна взаємодія:

- Вузли мережі можуть моделювати взаємодію між компонентами: танки, насоси, датчики, системи керування.

#### 2. Облік фізичних та технічних параметрів

Параметри tokenів:

- Колір токена може містити дані про стан палива: об'єм, щільність, температура, склад.
- Наприклад, token із кольором (Volume, Temperature, Density) моделює стан палива в танку.

Умови переходів:

- Паливо може бути подано в систему, тільки якщо виконуються умови, наприклад, температура вище заданого значення.

#### 3. Аналіз відмов та збоїв

Моделювання несправностей:

- CSP можуть моделювати збої, такі як пошкодження датчиків або витоку палива.
- Tokenи з певними кольорами вказують на помилкові стани системи.

Діагностика:

- Аналіз мережі дозволяє виявити слабкі місця в системі та передбачити наслідки відмов.

#### 5. Інтеграція із зовнішніми системами

Взаємодія із системами моніторингу:

- CSP можуть бути пов'язані з реальними даними, що надходять від датчиків, для моделювання в реальному часі.

Прогнозування поведінки:

- На основі поточних даних можна прогнозувати стан системи, наприклад, залишок палива через певний час.

З наведених вище прикладів можна виділити такі перспективні напрямки використання CPS для моделювання систем подачі та зберігання палива:

1. Інтеграція реальних даних: CSP можуть бути пов'язані з системами моніторингу, що дозволяє моделювати процеси в реальному часі. Це особливо корисно для адаптації систем до змін умов експлуатації, таких як качка або температура.

2. Оптимізація потоків палива: За допомогою CSP можна аналізувати роботу насосів та розподіл палива між танками. Це покращує експлуатаційну ефективність та знижує ризик перевитрати палива.

3. Діагностика та прогнозування: CSP здатні моделювати потенційні збої, такі як витік палива або відмова датчиків. Це дозволяє заздалегідь вживати заходів щодо їх усунення.

4. Адаптація до нових вимог: CSP можуть бути використані для моделювання систем зберігання альтернативних видів палива (метанол, аміак, LPG), які мають специфічні вимоги до температури та тиску.

Застосування кольорових мереж Петрі для моделювання систем вимірювання та зберігання палива на судні відкриває значні можливості підвищення якості цих систем. Ці переваги роблять CSP перспективним інструментом для впровадження в судноплавній галузі, особливо в умовах посилення екологічних норм та переходу на альтернативні види палива.

## **ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ**

1. Wang Q., Zhang Y. A Review of Marine Fuel Measurement Technologies // Journal of Navigation and Port Research. – 2021.
2. Opsealog. Fuel Consumption Monitoring: Integrating Data from Existing Systems. – 2024.
3. Chen S., Wang X. Exploring Drivers Shaping the Choice of Alternative-Fueled New Vessels // Journal of Marine Science and Engineering. – 2023.
4. Lloyd's Register. The Future of Maritime Fuels. – 2023.
5. Yanmar. Development of Maritime Hydrogen Fuel Cell System. – 2023.

# МАШИННЕ НАВЧАННЯ ТА ШТУЧНИЙ ІНТЕЛЕКТ

УДК 004.85

*Пещерьова В. С., Калініна І. О.  
Чорноморський національний університет  
ім. Петра Могили, Миколаїв, Україна*

## ІНТЕЛЕКТУАЛЬНЕ ПРОГНОЗУВАННЯ НА ОСНОВІ БАГАТОШАРОВИХ АНСАМБЛЕВИХ СТРУКТУР

Інтелектуальне прогнозування – це процес передбачення майбутніх подій, тенденцій на основі аналізу історичних і поточних даних за допомогою методів штучного інтелекту та машинного навчання. Воно застосовується в різних сферах для покращення рішень: у фінансах, в ланцюгах постачання, в охороні здоров'я тощо.

В багатьох наукових роботах зустрічається низка методів [1] для підвищення точності інтелектуального прогнозування: методи коригування зсувів, злиття даних, асиміляцію даних, послідовні методи, 3D-Var, ансамблеве прогнозування, моделювання Монте-Карло, мультимодельні ансамблі.

Тому в дослідженні поставлено задачу підвищити ефективність прогнозування за допомогою оптимального підбору багатошарової ансамблевої структури. Ансамблеві структури ефективно комбінують різні моделі, що зменшує ризик недонавчання та перенавчання. Існує три основні техніки ансамблевого навчання: *бегінг*, *бустинг* і *стекінг*. Бегінг використовує агрегацію та бутстрапінг для моделей з низьким зміщенням і високою дисперсією. Бустинг навчає моделі поетапно, виправляючи помилки попередньої для зниження зміщення та підвищення точності. Стекінг комбінує прогнози слабких моделей у метамодель для покращення результату, зменшуючи зміщення або дисперсію залежно від типу метамоделі.

Набір даних [2] містить 9568 записів, зібраних з електростанції комбінованого циклу протягом 6 років (2006-2011) на максимальному навантаженні. Характеристики включають: температуру, атмосферний тиск, відносну вологість та розрідження на виході для прогнозування погодинного електричного виходу. Дані підготовлені до моделювання за допомогою методів очищення, нормалізації та відбору ознак.

Для створення багатошарових гетерогенних ансамблевих регресорів обрано шість потенційно ефективних моделей регресії: на основі

множинної лінійної регресії (MLR), на основі дерева рішень (DT-R), на основі випадкового лісу (RF-R), на основі методу опорних векторів (SVR), на основі k-найближчих сусідів (KNN-R) та на основі штучної нейронної мережі (ANN-R).

На першому етапі моделювання використано класичний підхід комбінації базових моделей в ансамблях багат шарової структури. В перший шар стекінгу додано недонавчені моделі з низькою дисперсією та високим зміщенням, а також не дуже високим значенням показника  $R^2$ . Результати першого рівня передаються як вхід для другого шару бегінгу, де застосовуються перенавчені моделі з високою дисперсією та низьким зміщенням. Результати класичного варіанту показано в таблиці 1.

Таблиця 1 – Результати роботи класичного варіанту формування двошарової ансамблевої структури

| Тип моделі      | Показник якості моделі | Показники якості прогнозу |               |             |
|-----------------|------------------------|---------------------------|---------------|-------------|
|                 | $R^2$                  | RMSE                      | MAE           | MAPE (%)    |
| DT-R            | 0.88                   | 0.0026                    | 0.0021        | 1.04        |
| KNN-R           | 0.88                   | 0.0026                    | 0.0020        | 1.03        |
| <b>Stacking</b> | <b>0.92</b>            | <b>0.0021</b>             | <b>0.0016</b> | <b>0.80</b> |
| MLR             | 0.93                   | 0.0020                    | 0.0016        | 0.79        |
| RF-R            | 0.96                   | 0.0016                    | 0.0011        | 0.54        |
| SVR             | 0.94                   | 0.0019                    | 0.0014        | 0.69        |
| ANN-R           | 0.91                   | 0.0022                    | 0.0017        | 0.86        |
| <b>Bagging</b>  | <b>0.95</b>            | <b>0.0017</b>             | <b>0.0012</b> | <b>0.61</b> |

Отже, регресійна модель на основі випадкового лісу перевершила створену структуру. Це пояснюється специфікою задачі прогнозування енергоспоживання та особливостями даних. Тому прийнято рішення підібрати експериментальний варіант комбінації ансамблевої структури з метою покращення якості прогнозних значень.

Для експериментальної комбінації моделей використано підхід з недонавченими моделями на першому рівні бегінгу та перенавченими на другому рівні стекінгу. Таке рішення обумовлене гіпотезою про те, що недонавчені моделі, завдяки меншій специфічності в підгонці даних, можуть ефективніше вловлювати загальні тенденції та зменшувати ризик перенавчання. На першому рівні вони застосовуються в шарі бегінгу, що дозволяє підвищити стійкість ансамблю, комбінуючи

результати декількох слабо скорельованих моделей. На другому рівні перенавчені базові моделі та результати бегінгу інтегруються за допомогою стекінгу. Це забезпечує більш точне прогнозування, адже стекінг використовує результати первинного прогнозування для подальшого навчання моделей, що дозволяє їм поглибити знання про залежності в даних. Результати роботи експериментального варіанту показано в таблиці 2.

Таблиця 2 – Результати роботи експериментального варіанту формування двохарової ансамблевої структури

| Тип моделі      | Показник якості моделі | Показники якості прогнозу |               |             |
|-----------------|------------------------|---------------------------|---------------|-------------|
|                 | R <sup>2</sup>         | RMSE                      | MAE           | MAPE (%)    |
| DT-R            | 0,88                   | 0,0026                    | 0,0021        | 1,04        |
| KNN-R           | 0,88                   | 0,0026                    | 0,0020        | 1,03        |
| <b>Bagging</b>  | <b>0.89</b>            | <b>0.0025</b>             | <b>0.0019</b> | <b>0.96</b> |
| MLR             | 0,93                   | 0,0020                    | 0,0016        | 0,79        |
| RF-R            | 0,96                   | 0,0016                    | 0,0011        | 0,54        |
| SVR             | 0,94                   | 0,0019                    | 0,0014        | 0,69        |
| ANN-R           | 0,91                   | 0,0022                    | 0,0017        | 0,86        |
| <b>Stacking</b> | <b>0.96</b>            | <b>0.0015</b>             | <b>0.0010</b> | <b>0.51</b> |

Таким чином, результати знайденого експериментального варіанту комбінації базових регресійних моделей у дворівневій ансамблевій структурі свідчать про значне покращення якості прогнозування.

**ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ**

1. Real-time air quality forecasting, part II: State of the science, current research needs, and future prospects / Y. Zhang et al. Atmospheric Environment. 2012. Vol. 60. P. 656–676. DOI: <https://doi.org/10.1016/j.atmosenv.2012.02.041> (last accessed: 26.06.2024).

2. Tfekci P., Kaya H. Combined Cycle Power Plant [Dataset]. UCI Machine Learning Repository. DOI: <https://doi.org/10.24432/C5002N> (last accessed: 26.10.2024).

## **СЕМАНТИЧНА СЕГМЕНТАЦІЯ ПОШКОДЖЕНИХ БУДІВЕЛЬ З ВИКОРИСТАННЯМ ЗГОРТКОВИХ НЕЙРОННИХ МЕРЕЖ**

Велику шкоду інфраструктурі країн наносять не лише природні катастрофи, такі як землетруси й урагани, але й події спричинені людиною – бойові дії та війни. За розрахунками вчених Київської школи економіки, станом на січень 2024 року Україні внаслідок повномасштабного вторгнення Росії було завдано збитків більше ніж на 157 мільярдів доларів США [1]. Бойові дії спричиняють руйнування як інфраструктури й енергетики країни, так і приватного сектору, що згідно дослідження складає близько третини всіх збитків.

Сучасні технології моніторингу земної поверхні, а також останні нейромережеві моделі й алгоритми, дозволяють проводити автоматизоване розпізнавання об'єктів. Велика кількість досліджень спрямована на виявлення пошкоджених будівель після повеней або землетрусів, водночас характер руйнувань внаслідок бойових дій має власні відмінності, які ще остаточно не встановлені. Таким чином, існують усі підстави для подальшого дослідження алгоритмів та моделей для розпізнавання пошкоджених будівель.

Мета дослідження – підвищення ефективності розпізнавання пошкоджених будівель за допомогою нейромережевих технологій, об'єктом дослідження відповідно є процес розпізнавання.

Було запропоновано використання згорткових нейронних мереж для вирішення задачі семантичної сегментації, яка має на меті відношення кожного пікселю зображення до деякого класу. Це дозволяє створювати семантичну карту зображення, виділяючи значущі регіони, в яких згідно алгоритму може розташовуватися шуканий об'єкт. Даний підхід має перевагу над звичайним object detection, оскільки дозволяє більш точно виявляти складну структуру об'єкту.

Для вирішення поставленого завдання семантичної сегментації вирішено використовувати модель згорткової мережі U-Net [2]. Дана модель має схожу до encoder-decoder архітектуру (рис. 1), і складається з декількох блоків, таких як блок згортки, кодувальний блок, вузьке місце моделі (bottleneck) та відповідно декодер. Кожен блок має власну структуру, можуть складатися з різних типів шарів і мати додаткові налаштування, як шар Dropout тощо.




Рисунок 1 – Архітектура мережі U-Net

У дослідженні використовувалася власний набір даних, який містив 50 зображень приватного сектору міста Маріуполь у травні 2022 року, зроблених за допомогою сервісу Google Earth розміром 512 на 512 пікселів. Водночас, загальна кількість об'єктів (будівель) у наборі – більше 1500, що разом з використанням аугментацій дозволило підвищити кількість даних у декілька разів.

Модель використовує категоріальну перехресну ентропію як функцію втрат, що є поширеною практикою у вирішенні задач семантичної сегментації; функція вимірює «відстань» між прогнозованим та фактичним розподілом класів. У якості метрик було обрано загальну точність, яка відображає відношення кількості збігів пікселів вихідного зображення із сегментаційною картою, та Intersection over Union (IoU), яку можна представити як відношення загального перетину двох областей до їх площі.

Результатом дослідження є побудована базова модель, та чотири модифіковані з різними параметрами, як кількість фільтрів, аугментацій зображень та епох навчання. Побудова та навчання проводилося за допомогою сервісу Google Colab компанії Google [3], що значно прискорило навчання та отримання результатів.

На рис. 2 наведено сегментацію зображень тестового набору побудованої базової моделі, яка використовує 32 фільтри у шарі згортки.




Рисунок 2 – Сегментація зображень базовою моделлю

Результати тестування на окремому наборі даних всіх моделей наведено на рис. 3.

| Model                                             | Loss          | Accuracy      | IoU<br>Damaged | IoU<br>Normal | Time           |
|---------------------------------------------------|---------------|---------------|----------------|---------------|----------------|
| 32 filters, 256x256, 25 epochs, 10x augmentations | 0.4417        | 0.8228        | 0.4267         | 0.3837        | 6m 7s          |
| 32 filters, 256x256, 50 epochs, 10x augmentations | 0.5706        | 0.7961        | 0.3908         | 0.3387        | 11m 57s        |
| 32 filters, 256x256, 25 epochs, 5x augmentations  | 0.5156        | 0.7888        | 0.3968         | 0.3267        | 2m 41s         |
| 64 filters, 256x256, 25 epochs, 10x augmentations | <b>0.4023</b> | <b>0.8421</b> | <b>0.4583</b>  | <b>0.4914</b> | <b>13m 16s</b> |
| 64 filters, 256x256, 40 epochs, 10x augmentations | 0.4928        | 0.8404        | 0.4498         | 0.4787        | 19m 37s        |

Рисунок 3 – Результати тестування різних моделей

Згідно результатів дослідження, оптимальною серед побудованих моделей є модель №4. Загалом було визначено, що всі моделі мають складнощі із розпізнаванням будівель різних розмірів, тіней, а також інших перешкод, особливо при щільній забудові.

### ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ

- Report on damages to infrastructure from the destruction caused by Russia's military aggression against Ukraine as of January 2024. KSE Institute: *вебсайт*. URL: [https://kse.ua/wp-content/uploads/2024/05/Eng\\_01.01.24\\_Damages\\_Report.pdf](https://kse.ua/wp-content/uploads/2024/05/Eng_01.01.24_Damages_Report.pdf).
- U-Net: Convolutional Networks for Biomedical Image Segmentation: наукова стаття. California : Computer Science Department and BIOS

Centre for Biological Signalling Studies, University of Freiburg, 2015. 8 c.  
URL: <https://arxiv.org/pdf/1505.04597.pdf>.

3. Google Colaboratory. Google Colab: *вебсайт*. URL:  
<https://colab.google/>.

**UDC 004.8:004.93**

***Yu Fei, Eugene Malakhov***  
*Odessa I.I. Mechnikov National University*  
*Odesa, Ukraine*

## **IMPLEMENTATION OF SELF-ATTENTION MECHANISM INTO INFORMATION TECHNOLOGY OF HIGH-RESOLUTION REMOTE SENSING IMAGE SEMANTIC SEGMENTATION**

High-resolution remote sensing images play a crucial role in various fields such as Geographic Information Systems (GIS), urban planning, and environmental monitoring. Semantic segmentation, a pivotal task in computer vision, aims to assign a specific category label to each pixel in an image, thereby achieving a refined understanding of the image content. In the domain of high-resolution remote sensing image semantic segmentation, traditional methods often face numerous challenges. With the rapid development of deep learning technology, particularly the introduction of the self-attention mechanism, new research opportunities have emerged in this field [1]. The self-attention mechanism effectively captures long-range dependencies in images, enhancing the perception of global information, and is expected to further advance semantic segmentation techniques [2].

In the process of high-resolution remote sensing image semantic segmentation, the issue of detail loss is prominent, manifesting as:

1) traditional Convolutional Neural Networks (CNNs) have a limited receptive field, which hinders the full capture of global and local detail information in images;

2) downsampling operations lead to a reduction in image resolution, resulting in the loss of detail information;

3) complex backgrounds and noise interference exacerbate the difficulty of accurate segmentation of image details.

Thus, improving the accuracy and robustness of the image segmentation to resolve the issue of detail loss is relevant.

The issue of detail loss can be addressed through the adoption of reasonable upsampling strategies with multi-scale fusion techniques that can restore the detail information lost during downsampling or through the

introduction of denoising modules and feature enhancement modules can reduce the impact of background noise and improve the accuracy of detail segmentation.

However, the work proposes to focus on the using of the self-attention mechanism [3] can capture long-range dependencies through weighted summation between pixels, compensating for the limited receptive field of CNNs.

The proposed solution based on the self-attention mechanism has the following advantages:

- the self-attention mechanism aligns well with the characteristics of high-resolution remote sensing images, which is beneficial for improving segmentation accuracy;
- compared to traditional methods, the solution based on the self-attention mechanism has significant advantages in addressing the issue of detail loss;
- this solution can be combined with advanced techniques such as residual networks and multi-scale feature fusion to further enhance semantic segmentation performance.

Thus, the research purpose is improving the accuracy and robustness of the high-resolution remote sensing image segmentation to resolve the issue of detail loss by optimizing semantic segmentation technology through the self-attention mechanism introducing.

Tasks to be completed to achieve the purpose:

- 1) conduct in-depth research on the principles of the self-attention mechanism and explore its optimal application mode in high-resolution remote sensing image semantic segmentation.
- 2) design and implement a semantic segmentation model based on the self-attention mechanism, including network structure design and parameter optimization.
- 3) propose innovative solutions to the issue of detail loss, such as improved upsampling methods and feature enhancement modules.
- 4) carry out extensive experiments to compare the performance of different methods in semantic segmentation and validate the effectiveness and superiority of the proposed method.
- 5) analyze the experimental results, summarize the lessons learned, and provide a theoretical basis for further improvements and optimizations of high-resolution remote sensing image semantic segmentation technology.

Experimental Results. In this study, we designed and implemented the symmetric attention module and applied it to improve the ability of detail expression. Through a series of experiments, we evaluated the performance of this module on different datasets, including image segmentation, instance

segmentation, and object detection tasks. Table 1 provides a detailed analysis of the experimental results.

Table 1 – Results of experiments on the mechanism of self-attention

| Dataset    | Model                            | Precision (%) | Recall (%) | F1 Score |
|------------|----------------------------------|---------------|------------|----------|
| PASCAL VOC | FCN + Symmetric Attention        | 89.2          | 88.5       | 88.8     |
| Cityscapes | DeepLab + Symmetric Attention    | 90.4          | 89.7       | 90.1     |
| COCO       | Mask R-CNN + Symmetric Attention | 85.6          | 84.8       | 85.2     |

#### Conclusions:

- the self-attention mechanism is a powerful tool for addressing detail loss in high-resolution remote sensing image segmentation.
- the proposed model demonstrates superior performance compared to traditional methods, especially in handling complex backgrounds and noise interference.
- future research will focus on optimizing the model's efficiency and exploring its application in dynamic and real-time scenarios.

#### REFERENCES

1. Chen, Y., Chen, P., & Lin, Z. Efficient scene text recognition based on hierarchical self-attention. *Radio Engineering*. 2022. 31(1). P. 70-75.
2. Yu, E. & Zuo, X. Remote sensing ship image classification based on attention mechanism. *Software Guide*. 2023. 22(7). P. 138-143.
3. Wu, G., Ge, Y., Chu, J., & Ye, F. Cascaded pooling self-attention for remote sensing image retrieval. *Optoelectronics Letters*. 2022. 49(12). P. 55-67.

## **СИСТЕМА ВИЯВЛЕННЯ КОМП'ЮТЕРНИХ МЕРЕЖЕВИХ АТАК ЗА ДОПОМОГОЮ МЕТОДІВ МАШИННОГО НАВЧАННЯ**

Проведення мережевих атак безперервно розвивається, збільшуючи арсенал методів і тактик, що створює серйозні виклики для сучасної сфери кібербезпеки. Виявлення шляхом використання методів машинного навчання допоможе зберегти безпеку комп'ютерної мережі. Традиційні системи виявлення вторгнень часто виявляються неефективними для невідомих атак або складних векторів загроз, що підкреслює важливість використання машинного навчання.

Дослідження та аналоги по виявленню атак в мережах [1-2] демонструють високий рівень виявлення та аналізу атак. Наприклад, системи, оптимізовані для аналізу трафіку в корпоративних мережах, можуть показувати нижчу точність при роботі у середовищах IoT або мобільних мережах. Такі розбіжності обумовлені відмінностями у структурі мережевого трафіку, обсягах даних, та типах атак, які переважають у кожному з цих середовищ.

Тому в дослідженні поставлено задачу обрати модель машинного навчання, яка найкраще виявляє мережеві атаки шляхом розв'язання задачі класифікації.

Набір даних UNSW-NB15 обрано для дослідження через його актуальність та широкий спектр сучасних атак, включаючи DoS, DDoS, Fuzzing, експлойти та бекдори. Цей набір даних створено за допомогою генератора IXIA, що дозволяє імітувати реальні мережеві сценарії. Основною перевагою UNSW-NB15 є його відповідність сучасним викликам у сфері кібербезпеки, на відміну від застарілих наборів, таких як KDD Cup 99 або NSL-KDD.

Перед реалізацією моделей, набір даних підготовлено, шляхом прибирання відсутніх значень, нормалізації числових характеристик та кодування категоріальних ознак використовуючи one-hot метод.

Набір даних [3] містить 175341 записів та 45 ознак. Характеристики включають: атрибути характеристики потоку (дані що містять основну інформацію про запит), атрибути базових характеристик (інформація про мережеве з'єднання), атрибути вмісту (інформація про параметри з'єднання та особливості переданих даних на транспортному рівні), атрибути часу (часові аспекти з'єднань), додаткові атрибути

(згенеровані на основі базових атрибутів). Після підготовки даних, було обчислено абсолютні значення коефіцієнтів кореляцій між усіма ознаками та цільовою змінною label, що дозволяє враховувати як позитивні так і негативні коефіцієнти, що підвищує інформативність для моделі.

В якості альтернативних моделей для розв’язання задачі класифікації обрано чотири моделі машинного навчання: логістична регресія, метод  $k$  найближчих сусідів, метод випадкового лісу та метод дерева рішень. Результати класифікації на основі альтернативних моделей візуалізовано на рисунку 1. Слід зазначити, що кожна модель майже ідеально визначила класи «Reconnaissance», «Normal», «Generic», «Exploits», «DoS» та «Analysis». Однак, клас «Fuzzers» класифіковано в межах 67-77%, низькі показники якості класифікації продемонстровано для класів «Worms» та «Backdoor».



Рисунок 1 – Аналіз отриманих результатів класифікації

Слід зазначити, що атаки типу «Backdoor» та «Worms» сприяють їх неправильній класифікації, адже атака «Backdoor» має на меті

отримання з'єднання шляхом маскувань під нормальний трафік, а «Worms» – розповсюдити атаку якомога швидше, що може помилково бути класифікованим як атаки «Fuzzers». Через складність та мету атаки і архітектури комп'ютерних мереж, змінюється спосіб експлуатації та універсальні ознаки в мережі. На основі цього та високих значень класифікації інших класів, було детальніше проаналізовано точність класифікацій класів «Backdoor», «Worms» та «Fuzzers».

Серед всіх результатів, метод Random Forest продемонстрував найвищу загальну точність серед розглянутих моделей – 98.9652%. Середня абсолютна помилка становила 0.0165, корінь середньоквадратичної помилки – 0.1987, а коефіцієнт детермінації ( $R^2$ ) – 97.3428%. Класифікаційний звіт показує значне покращення для класу «Backdoor» з точністю 0.50, хоча повнота залишилася низькою – 0.03. Клас «Worms» мав точність 0.71, повноту 0.17 та F1-міру 0.28. Клас «Fuzzers» показав покращення з точністю та повнотою 0.76 та 0.77 відповідно.

Слід зазначити, що інші реалізовані моделі машинного навчання класифікували класи «Worms» та «Backdoor» помилково як «Fuzzers», що свідчить про явне визначення як тип атаки, а не нормальний трафік мережі.

Таким чином, для забезпечення надійного захисту інформаційних систем необхідно приділити особливу увагу складним та рідкісним атакам, вдосконалюючи методи класифікації та підходи до підготовки даних. Подальші дослідження в цьому напрямку сприятимуть підвищенню рівня кібербезпеки та розробці більш ефективних систем виявлення загроз, націлених на певні типи атаки для комп'ютерних мереж.

### ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ

1. C. Yin, Y. Zhu, J. Fei and X. He, "A Deep Learning Approach for Intrusion Detection Using Recurrent Neural Networks," in IEEE Access, vol. 5, pp. 21954-21961, 2017, doi: 10.1109/ACCESS.2017.2762418.
2. Jonathan, D., Camila, P., Luiz, D., Cristiano, B., João, G., Celia, R., Marcelo, M.: Abnormal Behavior Detection Based on Traffic Pattern Categorization in Mobile Networks. IEEE Transactions on Network and Service Management 18(4), 2021.
3. Moustafa, Nour, and Jill Slay. "UNSW-NB15: a comprehensive data set for network intrusion detection systems (UNSW-NB15 network data set)." Military Communications and Information Systems Conference (MilCIS), 2015. IEEE, 2015.

*Рева В.В.*

*Чорноморський національний університет імені Петра  
Могили, Миколаїв, Україна*

## **ІНТЕГРОВАНА СИСТЕМА ДЛЯ НАВЧАННЯ АГЕНТІВ UNITY ML AGENTS З ВИКОРИСТАННЯМ МОДЕЛЕЙ ГЛИБОКИХ НЕЙРОННИХ МЕРЕЖ**

Система для навчання агентів в середовищі UNITY ML AGENTS з використанням моделей глибоких нейронних мереж складається:

### **WolfAlphaAgent**

Цей скрипт представляє альфа-вовка у симуляції вовчої зграї за допомогою ML-агентів Unity. Він очолює зграю і прогнозує майбутнє положення оленя, щоб оптимізувати його рух і координату.

Ключові особливості. Прогнозування руху цілі шляхом обрахунку поточної швидкості та положення оленя для прогнозування його майбутнього розташування. Вибір оптимального місця для переслідування оленя на основі оцінки факторів (відстань, перешкоди, позиція зграї). Координація з іншими вовками шляхом аналізу розташування інших вовків у зграї для забезпечення оптимальної взаємодії. Збереження командної формації під час переслідування.

Оптимізація поведінки. Нагороджує за скорочення відстані до оленя і збереження близькості до передбачуваної позиції. Штрафує за погані прогнози або віддалення від цілі.

### **WolfPackMateAgent**

Цей скрипт координує дії окремих членів зграї з альфа-вовком.

Ключові особливості

Позиціонування у формації шляхом розподілу позицій навколо оленя для утримання його у центрі оточення. Автоматичне коригування розташування, враховуючи позиції альфа-вовка та інших членів зграї.

Координація дій у зграї шляхом аналізу взаємодії з альфа-вовком та іншими членами для забезпечення ефективності переслідування. Підтримка оптимальної дистанції між членами зграї.

Оптимізація поведінки

Заохочує кооперативну поведінку через винагороду за флангове обходження та формування. Окремі функції винагороди за рух, координацію та підтримання формації.

DeerAgent

Цей скрипт моделює оленя, здобич у симуляції, і його основна мета - уникати вовків.

Ключові особливості

Використання gaucast для збору даних про оточення для уникнення перешкод. Здатність змінювати напрямок руху для безпечного пересування.

Обробка даних з gaucast для виявлення хижаків у зоні огляду. Автоматичний режим втечі (FleeFromWolf), що активується при виявленні хижаків. Повернення до звичайної поведінки після безпечного часу.

Оптимізація поведінки

Нагороджує за рух, уникнення перешкод та втечу від хижаків. Покарання за бездіяльність або зіткнення з вовками.

Результати дослідження

Результати по графіках третього етапу ("thirdHunt") свідчать про значне покращення кумулятивної винагороди у "WolfA" і "WolfP". Особливо видно стабільний тренд покращення винагороди у порівнянні з "firstHunt" і "secondHunt". "WolfB" також демонструє позитивну динаміку, хоча прогрес не такий різкий.

Довжина епізодів ("Episode Length") значно збільшується у "thirdHunt" порівняно з "firstHunt" і "secondHunt". Це вказує на те, що вовки стали ефективнішими у переслідуванні оленя, що дозволяє їм довше залишатися у грі.

У "firstHunt" і "secondHunt" спостерігається високий рівень штрафів (від'ємна винагорода) для "WolfB". Це може свідчити про те, що вовк здійснював зайві або хаотичні повороти (відсутність згладжування), або ж стратегія переслідування не працювала ефективно.


Прогнозування позицій оленя ("Predicting Deer Position") разом зі згладжуванням поворотів ("Smooth Rotations") очевидно поліпшило поведінку агентів, зокрема для "WolfA" і "WolfP". Плавний рух і зменшення хаотичних поворотів значно зменшили штрафи.

Дослідження показали, що застосування моделей глибокого навчання суттєво підвищує ефективність агентів, особливо в сценаріях із високою складністю. Використання алгоритмів, таких як Proximal Policy Optimization (PPO), дозволило досягти стабільного навчання та високих показників винагороди в більшості тестових сценаріїв.

Перспективи та висновки

Інтеграція Unity ML-Agents із глибокими нейронними мережами відкриває нові можливості для розвитку інтелектуальних систем, які можуть бути використані не лише в ігровій індустрії, але й у реальних

застосунках, таких як робототехніка чи управління автономними системами.



## ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ

1. Unity Technologies. Unity ML-Agents Toolkit Documentation. [Електронний ресурс]. URL: <https://github.com/Unity-Technologies/ml-agents> (дата звернення: 19.11.2024).
2. Goodfellow I., Bengio Y., Courville A. Deep Learning. MIT Press, 2016. 720 с.
3. Silver D., Sutton R. Reinforcement Learning: An Introduction. 2nd Edition. MIT Press, 2020. 552 с.

4. Bishop C.M. Pattern Recognition and Machine Learning. Springer, 2006. 738 с.

5. Козлов О.Ю., Сидоренко В.М., Технології глибокого навчання для навчання агентів. Штучний інтелект. 2023. № 2 (154). С. 120–132.

**УДК 004.42**

***Кириленко В. С.***

*Чорноморський національний університет  
ім. Петра Могили, Миколаїв, Україна*

## **ІНТЕЛЕКТУАЛЬНА СИСТЕМА ПРОГНОЗУВАННЯ КУРСУ КРИПТОВАЛЮТ НА ОСНОВІ РЕКУРЕНТНИХ НЕЙРОННИХ МЕРЕЖ**

Криптовалюти, такі як Bitcoin[1], стали важливою частиною сучасної економіки, привертаючи увагу інвесторів, трейдерів та науковців. Прогнозування[2] їхнього курсу є складним завданням через високу волатильність та вплив різноманітних чинників, включаючи макроекономічні індикатори, обсяги торгів та настрої на ринку. У роботі розглянуто підхід до прогнозування курсу криптовалют за допомогою сучасних методів машинного навчання, зокрема рекурентних нейронних мереж (RNN), які мають високу ефективність при роботі з часовими рядами.

Система розроблена на основі архітектури LSTM[3] (Long Short-Term Memory) — однієї з найбільш популярних модифікацій RNN, яка ефективно працює з довгостроковими залежностями у даних.

У ході роботи було створено інтелектуальну систему прогнозування, яка здатна забезпечити точне передбачення курсу криптовалют на основі аналізу часових рядів та супутніх даних.

Основними задачами були збір і підготовка даних із різних джерел використання рекурентних нейронних мереж для моделювання залежностей, оптимізація параметрів моделі для підвищення її точності, оцінка впливу різних факторів (торгові обсяги, макроекономічні індикатори тощо) на якість прогнозування.

Для побудови моделі було зібрано історичні дані щодо вартості Bitcoin, доповнені такими параметрами як торгові обсяги, хешрейт, ціни на золото, активи S&P 500, NASDAQ 100, макроекономічні показники (такі як ставки центральних банків США, індекс долара тощо).

**Обробка даних відбувалась за допомогою заповнення пропусків шляхом інтерполяції (кубічна застосовувалась для даних, що схильні до**

різких змін, у той час як лінійна інтерполяція застосовувалась для більш «пологих» даних). Усі дані перед навчанням моделі підлягали нормалізації в діапазоні  $[0, 1]$  для забезпечення стабільності навчання.

Модель була реалізована на мові програмування Python із використанням бібліотек **NumPy**, **Pandas**, **scikit-learn**, **Keras**, а також бібліотеки **imblearn** для балансування даних.

Для тренування моделі було протестовано різні гіперпараметри, включаючи dropout rate для зменшення перенавчання, learning rate, batch size та кількість епох. Результати наступні:

Таблиця 1 – Порівняння результатів моделі з різними гіперпараметрами

| Id | Кількість нейронів | Розмір батчу | Dropout | Кількість епох | Втрати | Точність |
|----|--------------------|--------------|---------|----------------|--------|----------|
| 1  | 100                | 32           | 0.2     | 50             | 0.0085 | 91.4%    |
| 2  | 100                | 32           | 0.3     | 50             | 0.0078 | 91.6%    |
| 3  | 100                | 64           | 0.2     | 30             | 0.0092 | 91.2%    |
| 4  | 150                | 32           | 0.1     | 50             | 0.0069 | 91.8%    |
| 5  | 100                | 32           | 0.1     | 50             | 0.0067 | 91.9%    |

Порівняння точності моделі для різних наборів даних подано в таблиці:

| Набір даних                         | $R^2$ | MAE    | RMSE   |
|-------------------------------------|-------|--------|--------|
| Лише торгові обсяги                 | 0.85  | 0.0018 | 0.0020 |
| Торгові обсяги + макроек.           | 0.89  | 0.0015 | 0.0019 |
| Торгові обсяги + макроек. + хешрейт | 0.91  | 0.0012 | 0.0017 |

Модель досягла коефіцієнта детермінації  $R^2 = 0.91$ , що свідчить про високу ефективність прогнозування при використанні комбінованих даних (торгові обсяги + макроек. + хешрейт).

Запропонована інтелектуальна система прогнозування курсу криптовалют на основі RNN показала високу точність і практичну ефективність. Інтеграція різноманітних джерел даних (торгові обсяги, макроекономічні показники, настрої ринку) дозволила суттєво покращити якість прогнозування.

Подальші дослідження можуть бути спрямовані на оптимізацію архітектури RNN, включаючи використання гібридних моделей

(наприклад, поєднання LSTM з CNN), а також розширення набору даних для включення інших криптовалют.

### **ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ**

1. Nakamoto, S. Bitcoin: A Peer-to-Peer Electronic Cash System [Електронний ресурс]. – Режим доступу: <https://bitcoin.org>
2. Bitcoin price prediction using machine learning techniques [Електронний ресурс] // IEEE Xplore : вебсайт. – Режим доступу: <https://ieeexplore.ieee.org/abstract/document/7966019>
3. Hochreiter, S., Schmidhuber, J. Long Short-Term Memory. Neural Computation, 1997, 9(8), с. 1735–1780

**УДК 004.896**

***Нечахін В. В.***

*Чорноморський національний університет ім. Петра Могили,  
Миколаїв, Україна*

### **МОДЕЛЮВАННЯ LSTM-КОНТРОЛЕРА ДЛЯ СОНЯЧНОЇ ЕЛЕКТРОСТАНЦІЇ З ВИКОРИСТАННЯМ КОЛЬОРОВИХ МЕРЕЖ ПЕТРІ**

Зростаючий попит на відновлювану енергетику спричинив значний прогрес у моделюванні та керуванні сонячними енергетичними системами. Ефективне управління енергією на сонячних електростанціях має важливе значення для вирішення проблеми мінливості факторів навколишнього середовища, таких як освітленість і температура, які впливають на виробництво енергії. Поєднання структурного моделювання з передовими алгоритмами машинного навчання пропонує перспективне рішення цих проблем. Це дослідження фокусується на інтеграції кольорових мереж Петрі (CPN) та мереж з довгою короткочасною пам'яттю (LSTM) для створення гібридного підходу до моделювання та управління сонячними електростанціями. У той час як CPN забезпечують надійну графічну та математичну основу для представлення компонентів системи та їх взаємодії, LSTM використовуються завдяки своїй здатності фіксувати довгострокові залежності в даних часових рядів, що робить їх ідеальними для оптимізації в режимі реального часу при відстеженні точок максимальної потужності (MPPT). Попередні дослідження показали ефективність CPN у моделюванні систем відновлюваної

енергетики [1] та потенціал LSTM для підвищення точності MPPT [2]. Однак їх інтеграція в єдину структуру є новим внеском у цю галузь.

CPN є вдосконаленим розширенням традиційних мереж Петрі, поєднуючи графічне представлення з можливостями високорівневого програмування. Вони добре підходять для ієрархічного та модульного моделювання, дозволяючи детально представляти складні системи, такі як сонячні електростанції [3]. Ця можливість моделювання є критично важливою для відображення взаємодії між компонентами, такими як сонячні панелі, акумулятори та інвертори. Нейронні мережі LSTM стали потужним інструментом для обробки часових рядів даних у додатках MPPT. Традиційні алгоритми, такі як Perturb and Observe (P&O) та Incremental Conductance (IncCond), намагаються адаптуватися до швидких змін навколишнього середовища. На відміну від них, LSTM перевершують їх у вивченні нелінійних закономірностей і прогнозуванні оптимальних робочих точок, що призводить до збільшення вироблення енергії [2].

Запропонований підхід моделює сонячну електростанцію з використанням ієрархічної структури CPN та включає мережу LSTM для MPPT. Система складається з ключових компонентів, включаючи сонячну панель, контролер, акумулятор та інвертор, кожен з яких представлений у вигляді модуля в CPN. Контролер використовує алгоритм MPPT на основі LSTM, який динамічно налаштовує робочі параметри для максимізації енергоефективності. Модель CPN розроблена за допомогою CPN Tools, що дозволяє проводити як графічну, так і математичну перевірку. Такі компоненти, як сонячна панель, імітують умови навколишнього середовища, в той час як акумулятор та інверторні модулі керують зберіганням енергії та перетворенням змінного/постійного струму. Мережа LSTM навчається на реальних наборах даних, що містять вимірювання напруги, струму, температури та освітленості. Ці дані дозволяють мережі вивчати складні закономірності та прогнозувати оптимальні точки живлення. Для порівняння моделі CPN-LSTM з традиційними алгоритмами MPPT були проведені імітаційні експерименти. Ключові показники включали вихід енергії, точність відстеження в перехідних умовах та обчислювальну ефективність.

Результати моделювання демонструють, що інтегрована модель CPN-LSTM перевершує традиційні методи MPPT в декількох областях. Контролер на основі LSTM досягнув збільшення виходу енергії на 10%-15% порівняно з алгоритмами P&O та IncCond. Крім того, модель зберегла високу точність відстеження в умовах, що швидко змінюються, таких як часткове затінення. Однією з ключових переваг цього підходу

є його модульність і масштабованість, що забезпечується ієрархічною структурою CPN. Графічне представлення компонентів системи полегшує її модифікацію та розширення, що робить її придатною для різних конфігурацій сонячних електростанцій. Тим часом здатність мережі LSTM адаптуватися до динамічних умов навколишнього середовища забезпечує оптимальний збір енергії. Однак цей підхід не позбавлений обмежень. Навчання мережі LSTM, а також її розгортання в режимі реального часу вимагає значних обчислювальних ресурсів. У подальших роботах слід дослідити гібридизацію LSTM з іншими алгоритмами для зменшення обчислювальних накладних витрат і покращення продуктивності в реальному часі.

Це дослідження представляє гібридний фреймворк, що поєднує CPN та LSTM для моделювання та керування сонячними електростанціями. Використовуючи можливості структурного моделювання CPN та потенціал динамічної оптимізації LSTM, запропонований підхід вирішує ключові проблеми в управлінні відновлюваними джерелами енергії. Результати моделювання підтверджують його ефективність, демонструючи значне покращення енергоефективності та адаптивності порівняно з традиційними методами. Отримані результати підкреслюють потенціал інтеграції методів машинного навчання та системного моделювання для розвитку технологій відновлюваної енергетики. Майбутні дослідження будуть зосереджені на апаратній реалізації та подальшій оптимізації обчислювальної ефективності для підтримки роботи системи у реальному часі.

### **ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ**

1. Gozhyj, A., Kalinina, I., Nechakhin, V., Gozhyj, V. and Vysotska, V., 2021, September. Modeling an Intelligent Solar Power Plant Control System Using Colored Petri Nets. In 2021 11th IEEE International Conference on Intelligent Data Acquisition and Advanced Computing Systems: Technology and Applications (IDAACS) (Vol. 2, pp. 626-631). IEEE.
2. Gozhyj, A., Nechakhin, V. and Kalinina, I., 2024. Enhancing solar panel efficiency with LSTM-based MPPT controllers. In MoMLeT-2024: 6th International Workshop on Modern Machine Learning Technologies, May, 31 - June, 1, 2024, Lviv-Shatsk, Ukraine
3. Mladjao, M.A.M. and Abdel-Moumen, D., 2016. New robust energy management model for interconnected power networks using petri nets approach. Smart Grid and Renewable Energy, 7(1), pp.46-65.

## **OBJECT DETECTION ALGORITHMS IN FOGGY CONDITIONS**

**Actuality of Work:** The research focuses on improving vehicle target detection algorithms using lightweight neural networks, which is a critical area for the development of intelligent transportation systems and autonomous driving technologies. As the number of vehicles increases globally, so does the need for advanced detection systems to enhance road safety and traffic management.

This work specifically addresses the challenge of detecting vehicles under adverse weather conditions, such as fog. This is a significant issue as poor visibility can lead to increased risk of accidents. The research proposes methods to improve detection accuracy in such conditions, which is crucial for the practical application of autonomous vehicles.

In 2016, Redmon et al. [1] proposed an end-to-end detection algorithm called YOLO (You Only Look Once). The core idea of this algorithm is to divide the input image into several small grids and perform bounding box prediction and confidence calculation for each grid. This significantly improves detection speed while ensuring detection accuracy, thereby meeting the requirements for real-time detection. This work innovates by proposing improvements to the YOLOv5 [2] and YOLOv8 algorithms, which are state-of-the-art in object detection. The modifications aim to make these algorithms more suitable for deployment on devices with limited computational resources, which is a step towards making autonomous driving technology more accessible and cost-effective. The paper [3] improves YOLOv5s for vehicle detection in foggy conditions through modifications like image enhancement, architecture adjustments, and data augmentation, addressing challenges in adverse weather for better real-world object detection.

This research contributes to the field of computer vision by exploring the integration of convolutional neural networks (CNNs) with attention mechanisms and transformers, which are known to capture global features effectively. This integration could potentially lead to more robust and accurate detection models.

The findings of this research are not just theoretical; they have practical implications for improving the performance of vehicle detection systems in

real-world scenarios. This includes the potential to reduce traffic accidents and improve navigation systems in adverse weather conditions.

The work is data-driven, utilizing datasets like BDD100K and MS COCO for training and testing the proposed algorithms. This ensures that the results are grounded in empirical evidence and can be benchmarked against existing methods.

This paper addresses challenges arising from unclear images in foggy weather, vehicle overlap and obstruction on the road, incomplete vehicle structures, and the increased parameter volume and slow inference speed caused by deeper network layers, which make it difficult to deploy models on hardware with limited performance.

The main results of the work presented can be summarized as follows:

### 1. Development of Foggy Scene Vehicle Detection Algorithm

- Improved YOLOv5 Framework: A vehicle target detection algorithm for foggy scenes was developed based on the YOLOv5 framework. This algorithm incorporates an improved AOD-Net for defogging to compensate for information loss in foggy weather conditions.

- C3STR Module: A novel C3STR module [4] was used, combining the advantages of C3 and Swin Transformer, to better capture global information and compensate for the limitations of CNNs in capturing contextual information.

- CBAM Attention Mechanism: The Convolutional Block Attention Module (CBAM) was introduced to enhance the network's ability to detect dense vehicles by focusing on key areas and reducing false positives and missed detections.

- DIOU\_NMS Post-processing: The Distance-IoU (DIOU) Non-Maximum Suppression (NMS) was used to accurately regress the prediction box, improving the detection performance in foggy conditions.

### 2. Enhancements and Evaluation on BDD100K Dataset

- Performance Improvement: The improved algorithm showed a significant increase in accuracy, with a 2.1% increase in mean Average Precision (mAP) in foggy scenes on the BDD100K dataset, demonstrating the effectiveness of the proposed algorithm in addressing missed detections in target recognition under foggy conditions.

### 3. Design of Lightweight YOLOv8 Algorithm

- C3Ghost Module: A lightweight convolutional C3Ghost module was used to improve the network towards a lightweight direction, reducing the parameter volume while maintaining detection accuracy.

- Attention Modules: Spatial attention and channel attention modules were introduced at the end of each feature pyramid to enable the model to consider the characteristics of each channel, thereby improving the detection performance of the model.

- Wise-IoU v3 Loss Function: This loss function was adopted to dynamically optimize the loss weight of small targets, effectively improving the detection performance of the model for small targets.

#### 4. Evaluation and Comparison with Existing Methods

- Reduction in Computation and Parameters: The improved YOLOv8 algorithm reduced computation and parameter volume by about 34%.

- Performance on Pascal VOC and MS COCO Datasets: The mAP increased by 0.4% and 1.1% respectively on Pascal VOC and MS COCO datasets, achieving the expected goal.

- Comparison with YOLOv4-tiny[5]: The computation volume was slightly larger than YOLOv4-tiny, and the mAP increased by an average of 15.8% on both datasets, making it more suitable for deployment on devices with limited resources.

### REFERENCES

1. Redmon J, Divvala S, et al. You only look once: unified, real-time object detection. Las Vegas, NV, USA: IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas, 2016: 779-788.

2. Junfan W, Yi C, Zhekang D, et al. Improved YOLOv5 Network for Real-Time Multi-Scale Traffic Sign Detection. Neural Computing and Applications, 2022, 35(10): 7853-7865.

3. Yuan L, Chang Y, Liu J. Vehicle Detection in Foggy Scenes Based on Improved YOLOv5s. Journal of Zhengzhou University (Engineering Edition), 2023, 44(3): 35-41.

4. Jiang, Y.; Yang, K.; Zhu, J.; Qin, L. YOLO-Rlepose: Improved YOLO Based on Swin Transformer and Rle-Oks Loss for Multi-PersonPose Estimation. Electronics 2024, 13, 563.

5. Rui W, Ziyue W, Zhengwei X, et al. A Real-Time Object Detector for Autonomous Vehicles Based on YOLOv4. Computational Intelligence and Neuroscience, 2021, 20219218137-9218137.

## АВТОМАТИЧНА КЛАСИФІКАЦІЯ МОДУЛЯЦІЙ РАДІОСИГНАЛІВ НА ОСНОВІ ЗГОРТКОВИХ НЕЙРОННИХ МЕРЕЖ

Метою даної роботи є створення моделі для автоматичної класифікації різних типів модуляції радіосигналів з використанням методів машинного навчання.

Актуальність дослідження обумовлена поширеним використанням радіопристроїв впродовж останніх десятиліть. Насамперед, завдання автоматичної класифікації модуляцій (Automatic Modulation Classification) є особливо важливим як в цивільних, так і у військових умовах; прикладами його застосування є електронна розвідка, моніторинг радіоспектру, реконструкція сигналу тощо. Окрім цього, автокласифікація модуляцій набула більшого значення внаслідок розвитку концепції когнітивної системи радіозв'язку, тобто радіосистеми, у роботі якої враховуються відомості про навколишнє робоче та географічне середовище та про встановлені правила використання радіочастотного спектру.

В межах даного дослідження був обраний датасет RML2016.10a - синтетичний набір даних, що містить 11 видів радіомодуляції (8 цифрових, 3 аналогових) у вигляді 220000 рядків: відповідних значень I/Q сигналу при різних співвідношеннях сигналу до шуму (SNR).

Типи модуляцій, що розглядаються в дослідженні, наведені на рис. 1.




Рисунок 1. Типи радіомодуляцій в датасеті RML2016.10a

I/Q сигнал (In-phase/Quadrature signal) — це тип сигналу, який широко використовується в телекомунікаціях і радіотехніці для представлення складних сигналів у вигляді двох компонент: інфазної (I) та квадратурної (Q). Це є, по суті, репрезентацією сигналу на комплексній площині, де I - дійсний компонент, а Q - уявний. Завдяки такій репрезентації сигналу, кожен момент часу можна представити як пару значень I(t) і Q(t), які є складовими сигналу. Коли ці компоненти поєднуються, вони формують повний сигнал:

$$s(t) = I(t) \cos(\omega t) + Q(t) \sin(\omega t), \quad (1)$$

де  $\omega$  - кутова частота сигналу.

Таке представлення сигналу має декілька переваг:

1. використання I/Q сигналу дає змогу легко відокремити амплітуду та фазу сигналу, що корисно при аналізі модуляції (I контролює амплітуду, а Q контролює фазу);

2. I/Q сигнали можуть бути подані як двовимірні масиви або пари чисел, що полегшує їх обробку. Це особливо зручно для моделей машинного навчання, оскільки багатоканальні сигнали можуть бути безпосередньо введені в алгоритми, для навчання та класифікації;

3. враховуючи, що кожен сигнал представлений в комплексній формі, можна будувати складніші ознаки для моделей машинного навчання, такі як амплітудно-фазові характеристики, що потім використовуються для розрізнення модуляцій.

Співвідношення сигналу до шуму (Signal-to-Noise Ratio, SNR) - це важливий параметр, що характеризує якість сигналу в наявності шуму. Воно визначає, наскільки потужний корисний сигнал у порівнянні з рівнем шуму, який супроводжує цей сигнал. Співвідношення SNR вимірюється у децибелах (dB) та розраховується за допомогою виразу:

$$SNR(db) = 10 \log_{10} \left( \frac{P_s}{P_n} \right), \quad (2)$$

де  $P_s$  - потужність сигналу, а  $P_n$  - потужність шуму.

У розглянутому датасеті значення SNR вар'юються від -20db до +20db. Якщо значення SNR більше за 0, то це означає, що рівень сигналу переважає над рівнем шуму.

В процесі роботи була обрана згорткова нейромережа, що є різновидом мережі, архітектура якої наведена на рис. 2 [1]. Для імплементації нейромережі була обрана бібліотека PyTorch. Оптимізація під час тренування проводилась за допомогою алгоритму Adam з використанням перехресної ентропії як критерія оптимізації.

```

MyCNN(
  (conv1): Conv2d(1, 256, kernel_size=(1, 7), stride=(1, 1), padding=(0, 3), bias=False)
  (a1): ReLU()
  (d1): Dropout(p=0.5, inplace=False)
  (n1): BatchNorm2d(256, eps=1e-05, momentum=0.1, affine=True, track_running_stats=True)
  (conv2): Conv2d(256, 80, kernel_size=(2, 7), stride=(1, 1), padding=(0, 3))
  (a2): ReLU()
  (d2): Dropout(p=0.5, inplace=False)
  (n2): BatchNorm2d(80, eps=1e-05, momentum=0.1, affine=True, track_running_stats=True)
  (dense1): Linear(in_features=10240, out_features=256, bias=True)
  (a3): ReLU()
  (d3): Dropout(p=0.5, inplace=False)
  (n3): BatchNorm1d(256, eps=1e-05, momentum=0.1, affine=True, track_running_stats=True)
  (dense2): Linear(in_features=256, out_features=11, bias=True)
)
-----
Trainable Parameters: 2914299
Fixed Parameters: 0
Total Parameters: 2914299
-----

```

Рисунок 2. Архітектура згорткової нейромережі

Результати тренування згорткової мережі показані на рис 3. Модель здатна визначати тип модуляції сигналу з точністю до 82%. Втім, це стосується суто сигналів, в яких SNR більший за 0. Точність мережі значно знижується у випадках, коли потужність шуму переважає потужність корисного сигналу.




Рисунок 3. Залежність точності класифікації натренованої моделі від значень SNR

Отримані в цьому дослідженні результати показують, що представлена модель здатна автоматично визначати відомий їй тип

модуляції з досить високою точністю. Втім, дана модель є доволі чутливою до інтерференції, тому особлива увага має бати приділена способам зниження впливу шуму в сигналі на результати роботи мережі.

### **ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ**

1. O'Shea T., Corgan J., Clancy T. C., Convolutional radio modulation recognition networks. International Conference on Engineering Applications of Neural Networks, 2016, pp. 213–226.

**УДК 004.89**

***Гожий В.О.***

*Чорноморський національний університет  
ім. Петра Могили, Миколаїв, Україна*

### **ІНТЕГРАЦІЯ ТЕХНОЛОГІЙ ШТУЧНОГО ІНТЕЛЕКТУ В ПРОЕКТИ ІТ КОМПАНІЙ**

Застосування технологій штучного інтелекту в проектах ІТ-компаній стає провідною тенденцією в ІТ галузі. Технології ШІ поступово перетворюються в повноцінну частину робочого процесу, впроваджену на рівні компанії. Фірма IBM провела опитування і визначила, що близько 60 % ІТ-фахівців зізналися, що їх роботодавець активно інтегрує штучний інтелект у низку процесів і збільшує інвестиції в цей напрям.

На сьогоднішній день не існує загальноприйнятих підходів і практик щодо впровадження ШІ на рівні компанії, і наразі це не створює проблем у конкурентоздатності. Найбільш розповсюдженим способом впровадження інтелектуальних технологій, це розробка і впровадження віртуальних асистентів в роботу компанії або в програмний продукт, який компанія випускає. І можна констатувати, що фірми які запровадили ШІ-асистентів, мають перші результати. І вони позитивні. Так, у компанії *SoftServe* (Україна) з'ясували, що використання штучного інтелекту підвищує продуктивність команд на 45% і прискорює час розробки проекту майже на третину. В реалізації проектів компаній *TemplateMonster* та *Vlushno* рішення з ШІ значно підвищили продуктивність команд та значно вплинули на результативність проектів, що виконуються. Кількість таких прикладів на ринку ІТ України постійно зростає.

Але інтеграція інтелектуальних технологій в роботу компаній має певні перешкоди та проблеми. Найперше, що заважає компаніям використовувати ШІ рішення в своїй діяльності, це складність використання такого рішення. Адже загальноприйнятих практик і підходів ще не існує, є лише позитивний досвід окремих команд. Складнощі виникають, коли потрібно вирішити, якими розробками (наприклад: ШІ-асистентами) користуватися, одним чи різними, до яких процесів вони підключаються. Ще одна важлива причина, це безпека. Компанії не можуть собі дозволити підключатись до відкритих ШІ-моделей, ризикуючи витоком інформації. Але такі рішення вже з'являються: *OpenAI*, *Google*, *Antropic* уже активно пропонують бізнесові пакети, з якими компанії почуваються більш захищеними. Наприклад, *Microsoft* і *GitLab*, починаючи співпрацю з компанією, приводять свою команду, яка допомагає побудувати безпечну модель роботи.

Поки ринок не вимагає обов'язкової імплементації AI на рівні компанії, однак із часом компанії, які системно інтегрують штучний інтелект, матимуть відчутну перевагу в продуктивності, оперативності та низці інших метрик. Командам у 50+ людей варто вже зараз розібратися в питанні, побудувати стратегію запуску пілотних ШІ-проектів, обрати інструментарій та оцінити ризики, щоб за кілька років не втрачати в конкурентоспроможності.

Якщо розглянути ефективність використання ШІ рішень в розробці та реалізації IT-проектів, можна зробити наступні висновки:

1. ШІ дозволяє автоматизувати рутинні завдання, що пришвидшує виконання проектів та підвищує загальну ефективність управління.

2. Застосування алгоритмів машинного навчання та рішень з ШІ дозволяє точно прогнозувати ризики, допомагаючи уникнути непередбачених ситуацій.

3. Інтелектуальні алгоритми ШІ надають важливу інформацію для прийняття обґрунтованих рішень, що сприяє успішному виконанню проектів.

4. ШІ допомагає у генерації документації та підвищує продуктивність команди, забезпечуючи оптимальне використання ресурсів.

Таким чином, Штучний інтелект виявляє значний вплив на реалізацію та розробку нових проектів, використовуючи нові можливості та допомагаючи в розробці ефективних рішень.

## ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ

1. Яворський Р. Т., Шишковський С. В. Формування гнучкої системи менеджменту. Бізнес Інформ. 2023. № 10. С. 329–333.
2. Lahmann M. AI will transform project management. Are you ready?. PwC. URL: <https://www.pwc.ch/en/insights/risk/ai-will-transform-project-management-are-you-ready.html> (дата звернення: 29.01.2024).
3. Evaluating the Inclusiveness of Artificial Intelligence Software in Enhancing Project Management Efficiency. URL: <https://arxiv.org/ftp/arxiv/papers/2311/2311.11159.pdf> (дата звернення: 01.02.2024).
4. The Standish Group Reports. Standish Group. URL: <https://hbr.org/2023/02/how-ai-will-transform-projectmanagement> (дата звернення: 26.01.2024).

УДК 004.42

*Карпенко А. Ю.*

*Чорноморський національний університет  
ім. Петра Могили, Миколаїв, Україна*

## ІНТЕЛЕКТУАЛЬНА СИСТЕМА ІДЕНТИФІКАЦІЇ І КЛАСИФІКАЦІЇ DOS-АТАК

Атаки типу відмови в обслуговуванні (DoS) є однією з найбільших загроз у сфері кібербезпеки, спрямованих на порушення доступності ресурсів і сервісів. З розвитком технологій DoS-атаки стають все більш складними, що ускладнює їх своєчасне виявлення та нейтралізацію [1]. Це підкреслює актуальність розробки ефективних інструментів для ідентифікації та класифікації таких атак.

Успіх організацій у протидії DoS-атакам залежить від здатності впроваджувати сучасні підходи, зокрема використання технологій штучного інтелекту та машинного навчання для аналізу мережевого трафіку та лог-файлів.

Сучасні методи виявлення та класифікації DoS-атак базуються на комбінації традиційних [2] технік та передових технологій штучного інтелекту. Глибинні нейронні мережі (DNN) та їхні варіанти, такі як згорткові нейронні мережі (CNN) та рекурентні нейронні мережі (RNN), використовуються для автоматичного витягнення ознак з великих обсягів даних, що дозволяє ефективно розпізнавати складні патерни атак [3].

Викликами є велика кількість даних, що потребує ефективних алгоритмів обробки та аналізу, а також необхідність забезпечення реального часу реагування на загрози. Крім того, проблема дисбалансу класів у даних є важливим аспектом, оскільки кількість нормального трафіку зазвичай значно перевищує кількість атакуючого трафіку. Це може призводити до упередженості моделей, що негативно впливає на їхню здатність ефективно виявляти рідкісні типи атак.

У роботі розроблено інтелектуальну систему для ідентифікації та класифікації DoS-атак, яка використовує методи глибинного навчання. Система реалізована на мові програмування Python із використанням бібліотек NumPy, Pandas, scikit-learn, Keras та imblearn. Використання цих бібліотек забезпечує ефективну роботу з великими обсягами даних та спрощує процес попередньої обробки, моделювання та оцінки результатів [4].

Набір даних CIC-IDS2017 містить дисбаланс між класами, що може впливати на точність моделі. Для вирішення цієї проблеми було застосовано методи балансування даних. Модель показала кращі результати при балансуванні даних за допомогою методу SMOTE (Synthetic Minority Over-sampling Technique), ніж при використанні RandomOverSampler [5].

SMOTE генерує синтетичні зразки для міноритарних класів, покращуючи узагальненість моделі та зменшуючи ризик перенавчання.

RandomOverSampler дублює існуючі зразки міноритарних класів, що може призвести до перенавчання моделі.

Проведено тестування моделі з різними параметрами, включаючи розмір батчу, кількість епох, швидкість навчання та кількість нейронів у прихованих шарах. Результати показали, що оптимізація цих параметрів впливає на точність та втрати моделі.

Таблиця 1 – Порівняння результатів моделі з різними параметрами

| ID | Filters | LSTM | Dropout | Batch | Loss   | Accuracy | Epoch |
|----|---------|------|---------|-------|--------|----------|-------|
| 1  | 64      | 100  | 0,5     | 64    | 0.0098 | 99.76    | 9     |
| 2  | 128     | 100  | 0,5     | 64    | 0.0089 | 99.76    | 10    |
| 3  | 128     | 150  | 0,5     | 64    | 0.0091 | 99.78    | 10    |
| 4  | 64      | 128  | 0,5     | 64    | 0.0094 | 99.72    | 10    |
| 5  | 64      | 100  | 0,4     | 64    | 0.0091 | 99.76    | 10    |
| 6  | 64      | 100  | 0,1     | 64    | 0.0085 | 99.77    | 9     |
| 7  | 64      | 100  | 0       | 64    | 0.0083 | 99.76    | 9     |
| 8  | 64      | 100  | 0,1     | 64    | 0.0085 | 99.77    | 9     |
| 9  | 64      | 100  | 0,1     | 128   | 0,0087 | 99,78    | 9     |
| 10 | 64      | 100  | 0.1     | 172   | 0.0059 | 99.86    | 30    |

Розроблена інтелектуальна система демонструє високу ефективність у ідентифікації та класифікації DoS-атак. Використання мови програмування Python та потужних бібліотек для обробки даних та моделювання спростило реалізацію та підвищило продуктивність роботи з великими даними. Метод SMOTE показав кращі результати при балансуванні даних, покращуючи точність моделі. Оптимізація параметрів моделі, таких як розмір батчу, кількість епох, Dropout Rate та кількість нейронів, дозволила досягти точності до 99.86%. Подальші дослідження можуть бути спрямовані на оптимізацію моделі та її впровадження у реальних мережевих середовищах.

### **ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАНЬ**

1. Mirkovic J., Reiher P. A taxonomy of DDoS attack and DDoS defense mechanisms. ACM SIGCOMM Computer Communication Review. 2004. Vol. 34, no. 2. P. 39–53.
2. Buczak A.L., Guven E. A survey of data mining and machine learning methods for cybersecurity intrusion detection. IEEE Communications Surveys & Tutorials. 2016. Vol. 18, no. 2. P. 1153–1176.
3. Vinayakumar R., Soman K.P., Poornachandran P. Applying deep learning approaches for network traffic analysis. In: 2017 International Conference on Advances in Computing, Communications and Informatics (ICACCI). 2017. P. 2353–2358.
4. Chollet F. Keras [Електронний ресурс]. 2015. Режим доступу: <https://keras.io>.
5. Chawla N.V., Bowyer K.W., Hall L.O., Kegelmeyer W.P. SMOTE: Synthetic Minority Over-sampling Technique. Journal of Artificial Intelligence Research. 2002. Vol. 16. P. 321–357.

**УДК 004.8**

*Архіпов Д. В., Сіденко Є. О.  
Чорноморський національний університет  
ім. Петра Могили, Миколаїв, Україна*

### **СИСТЕМА ВИЯВЛЕННЯ ВІЙСЬКОВИХ ОБ’ЄКТІВ НА ДИНАМІЧНИХ ЗОБРАЖЕННЯХ НА ОСНОВІ АРХІТЕКТУР НЕЙРОННИХ МЕРЕЖ**

Сучасні військові конфлікти вимагають ефективних рішень для автоматичного аналізу зображень, отриманих з дронів, для оперативного виявлення та класифікації військових об’єктів. Дана

робота пропонує систему для виявлення військових об'єктів на зображеннях з дронів на основі різних архітектур нейронних мереж, таких як YOLO (You Only Look Once) та Faster R-CNN. [1]

У ході роботи було виконано порівняння моделей нейронних мереж для задачі розпізнавання військових об'єктів з зображення дрону, включаючи точність та швидкість. Основною метрикою визначення точності є mAP50 з урахуванням результатів mAP50-95. [2]

Для побудови моделі було створено власний набір даних на основі анотованих зображень з дронів, що містять різні класи військових об'єктів (танки, артилерійські установки, ДОТи тощо). Зображення були взяті з соціальних мереж, відкритих джерел в інтернеті та відео різних підрозділів ЗСУ.

Обробка даних відбувалась за допомогою сервісу Roboflow та інструментів анотування. Вихідні, анотовані, кольорові зображення були зменшені до розміру 640 на 640 пікселів. Навчання моделей відбувалось на сервісі Google colab з графічним ядром «T4 GPU», обсягом відеопам'яті 15360 МБ.

Модель була реалізована на мові програмування Python із використанням бібліотек NumPy, Pandas, scikit-learn, Keras, PyTorch та ultralytics.

Модель Faster R-CNN, є потужною архітектурою для об'єктного виявлення, яка одночасно визначає місцезнаходження об'єктів на зображенні і класифікує їх. Для навчання моделі використовується датасет з анотованими зображеннями в форматі coco.json. [3]

На початку навчання зображення проходило через базову мережу ResNet50 яка виконує згорткові операції, зменшує розмір зображення і витягує важливі ознаки та отримуються карти ознак. Далі використовується RPN, який працює над картою ознак і генерує регіони-кандидати, які, ймовірно, містять об'єкти. Для регуляції використовувався параметри weight decay, щоб уникнути перенавчання. [4]

Результатом є модель з показниками точності (mAP) 83.7% та рівнем локалізації (mAP50-95), який дорівнює 59.4%, що є непоганими результатом.

На тестовому відео видно, що модель вміє виявляти декілька об'єктів навіть під час руху. Також модель здатна виявляти складні цілі, наприклад такі, як частина автівки у будівлі. Виявлення військових об'єктів наведено на рис. 1.



Рисунок 1 – Виявлення військових об'єктів на відео за допомогою моделі Faster R-CNN

Серед різних версій архітектури YOLO, було обрано YOLOv11. Архітектура YOLO, є популярним рішенням для виявлення об'єктів, через поступове впровадження більш глибокі та складні архітектури з покращеною здатністю до узагальнення та точнішої детекції дрібних об'єктів. Ці моделі використовують передові методи, такі як сконцентровані механізми уваги, глибокі з'єднання та покращені функції втрат, що дозволяють їм досягати високих показників ефективності. Модель YOLO складається з конволюційних шарів, що витягують ознаки зображення, та повнозв'язних шарів, що виконують класифікацію та регресію для визначення класів об'єктів та їх координат.

Модель на базі архітектури YOLO продемонструвала високі результати. Загальна середня точність mAP50 становить 93.3%, а локалізація об'єктів досягла 63.1%, що свідчить про її високу здатність виявляти та точно локалізувати об'єкти навіть при високих порогах IoU. Час навчання цієї моделі був помірним (106 хвилин), що вказує на ефективність її архітектури.

Для підтвердження ефективності, модель була протестована на відео в реальному часі. Було підтверджено, що модель добре виявляє один та декілька рухомих об'єктів. Однак, є зауваження стосовно відслідковування об'єкта та його виявлення при перекритті іншим об'єктом, наприклад деревом чи парканом. Результат виявлення військового об'єкту на відео наведений на рис. 2.



Рисунок 2 – Виявлення військових об’єктів на відео за допомогою моделі YOLOv11

Результати аналізу потрібні для подальшої розробки системи автоматизованого виявлення військових об’єктів, що включає створення гібридної архітектури нейромережі.

### ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ

1. Military Target Detection Method Based on Improved YOLOv5 / X. Du et al. 2022 International Conference on Cyber-Physical Social Intelligence (ICCSI), Nanjing, China, 18–21 November 2022. 2022. URL: <https://doi.org/10.1109/iccsi55536.2022.9970675> (date of access: 20.11.2024).
2. Hui J. mAP for Object Detection. Medium. URL: <https://jonathan-hui.medium.com/map-mean-average-precision-for-object-detection-45c121a31173> (date of access: 23.11.2024).
3. Skelton J. Faster R-CNN Explained for Object Detection Tasks | DigitalOcean. DigitalOcean | Cloud Infrastructure for Developers. URL: <https://www.digitalocean.com/community/tutorials/faster-r-cnn-explained-object-detection> (date of access: 23.11.2024).
4. The Fundamental Guide to Faster R-CNN [2025] - viso.ai. viso.ai. URL: <https://viso.ai/deep-learning/faster-r-cnn-2>. (date of access: 23.11.2024).

## **ІНТЕЛЕКТУАЛЬНА СИСТЕМА ІДЕНТИФІКАЦІЇ ТА КЛАСИФІКАЦІЇ ВІЙСЬКОВОЇ ТЕХНІКИ З ВИКОРИСТАННЯМ НЕЙРОННИХ МЕРЕЖ**

Розвиток комп'ютерного зору відкриває нові можливості для автоматизації процесів класифікації об'єктів на зображеннях. У військовій сфері ці технології можуть значно підвищити ефективність розпізнавання та аналізу даних. Використання сучасних глибоких нейронних мереж, таких як *ResNet* і *DenseNet*, дозволяє забезпечити високоточну класифікацію складних зображень.

Сучасні методи комп'ютерного зору відкривають нові можливості для автоматизації класифікації об'єктів на зображеннях. Зокрема, глибокі нейронні мережі, такі як *ResNet* і *DenseNet*, дозволяють аналізувати складні візуальні дані та досягати високої точності в ідентифікації об'єктів. Завдяки своїй здатності враховувати нелінійні залежності та ефективно обробляти багатовимірну інформацію, ці моделі стали ключовими інструментами у задачах класифікації зображень у різних галузях, включаючи військову, медичну та промислову сфери.

Інтелектуальна система ідентифікації та класифікації військової техніки складається з трьох основних етапів: попередньої обробки даних, створення моделей нейронних мереж та прогнозування. Кожен із цих етапів має важливе значення для забезпечення точності класифікації та ефективності роботи системи.

На етапі обробки даних проводиться очищення, нормалізація та стандартизація вхідної інформації. Методом об'єднання декількох датасетів з фоторграфіями військової формується основний список вхідних даних, що в свою чергу групується по категоріях та фільтрується, залишаючи лише підходящі для навчання фото.

Другий етап дослідження спрямований на створення та навчання моделей класифікації зображень. Застосовуються різні архітектури нейронних мереж, серед яких *ResNet-50*, *ResNet-101* та *DenseNet*, які продемонстрували високу ефективність у вирішенні задач комп'ютерного зору.

Останній етап включає тестування моделей на контрольних наборах даних. Система автоматизує процес подачі зображень, проводить

класифікацію об'єктів та виводить результати з відповідною точністю у зручному форматі для подальшого аналізу.

Особлива увага приділяється оцінці точності роботи моделей, що дозволяє визначити їх ефективність у класифікації різних типів військової техніки.

Технологічна реалізація системи здійснюється за допомогою бібліотек Keras і TensorFlow. Вибір цих інструментів зумовлений їх потужними можливостями для побудови, навчання та тестування глибоких нейронних мереж, а також їхньою інтеграцією з сучасними платформами обчислень.

Попередня обробка даних є ключовим етапом для створення систем класифікації зображень. Вона забезпечує якісну підготовку вхідної інформації, мінімізуючи вплив шумів та аномалій на роботу моделей.

Основою системи є інтеграція сучасних архітектур нейронних мереж, таких як ResNet і DenseNet. Ці моделі дозволяють враховувати складні взаємозв'язки в зображеннях, що забезпечує високу точність класифікації. Оцінювання моделей проводиться за допомогою метрик, таких як точність (accuracy) та F1-міра, що дає змогу мінімізувати помилки та забезпечити високу ефективність роботи системи.

Система розроблена з інтерактивним інтерфейсом, що забезпечує зручність використання для кінцевого користувача. Інтерфейс дозволяє завантажувати зображення військової техніки, після чого система автоматично обробляє дані, класифікує об'єкти та надає результати у зрозумілому форматі.




Рисунок 1 - Схема роботи системи

Для реалізації системи використовуються технології ASP.Net MVC та Angular, які забезпечують швидкість обробки даних, зручність управління інтерфейсом та інтеграцію з алгоритмами глибокого навчання. Ці інструменти дозволяють створити гнучку та масштабовану платформу для автоматизації класифікації зображень.

Система не лише класифікує об'єкти на зображеннях, але й аналізує ефективність моделей, дозволяючи адаптувати їх під конкретні задачі. Такий підхід дає змогу покращити точність обробки зображень, забезпечуючи практичну цінність у військовій, медичній чи промисловій сферах.

### **ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ**

1. H. R. Roth et al., "Anatomy-specific classification of medical images using deep convolutional nets," 2015 IEEE 12th International Symposium on Biomedical Imaging (ISBI), Brooklyn, NY, USA, 2015, pp. 101-104, doi: 10.1109/ISBI.2015.7163826.

2. J. V. Rissati, P. C. Molina and C. S. Anjos, "Hyperspectral Image Classification Using Random Forest and Deep Learning Algorithms," 2020 IEEE Latin American GRSS & ISPRS Remote Sensing Conference (LAGIRS), Santiago, Chile, 2020, pp. 132-132, doi: 10.1109/LAGIRS48042.2020.9165588.

**УДК 004.8**

*Руда Є. В., Бурлаченко І. С.,  
Чорноморський національний університет  
ім. Петра Могили, Миколаїв, Україна*

### **ІНТЕЛЕКТУАЛЬНА СИСТЕМА ДІАГНОСТУВАННЯ ХВОРОБ РОСЛИН З ВИКОРИСТАННЯМ МЕТОДІВ ШТУЧНОГО ІНТЕЛЕКТУ**

Важливою галуззю економіки, що підтримує продовольчу безпеку людства, є сільське господарство. Однією із задач якого є пошук та боротьба з хворобами рослин.

За даними Продовольчої та сільськогосподарської організації (англ. Food and Agriculture Organization, FAO), щорічно близько 20-40% врожаю втрачається через хвороби рослин і шкідників, що призводить до значних фінансових втрат та загострення продовольчої кризи у слаборозвинених країнах світу [1].

Традиційні методи діагностики хвороб рослин вимагають експертного втручання, що робить їх трудомісткими та дорогими. Схожість симптомів різних хвороб на початковій стадії знижує ефективність їх виявлення. Візуальний огляд рослин часто не є точним методом та значно залежить від досвіду фахівця, що його проводить. В той же час лабораторні дослідження вимагають великої кількості як фінансових витрат так і часу, що прямо впливає на кількість та якість врожаю, який вдасться зберегти.

Перспективним напрямком розвитку агрономії є використання методів штучного інтелекту для діагностики хвороб рослин. Вони дозволяють автоматизувати даний процес, зменшуючи фінансові та матеріальні витрати і водночас підвищуючи точність результатів.

До штучних нейронних мереж, що призначені для обробки зображень належать згорткові нейронні мережі (англ. Convolutional neural network, CNN) здатні ефективно розпізнавати патерни в зображеннях.

Ефективною архітектурою для створення інтелектуальної системи діагностики хвороб рослин є EfficientNet. Її особливістю є метод масштабування, що рівномірно масштабує ширину, глибину та роздільну здатність моделі. Даний підхід дозволяє підвищити точність при обмежених обчислювальних ресурсах.

Реалізація інтелектуальної системи на основі згорткової нейронної мережі складається з кількох етапів.

Для навчання моделі необхідно зібрати велику кількість даних. Для цього можуть використовуватися набори даних з відкритих джерел, таких як платформа Kaggle, що містить структуровані набори даних для діагностики хвороб рослин. У випадку недостатнього обсягу даних застосовується метод аугментації, що дає змогу запобігти перенавчанню моделі.

Після збору й підготовки даних наступним ключовим етапом є навчання моделі. Для цього всі зібрані зображення поділяються на тренувальний, валідаційний та тестовий набори. Типове співвідношення між ними становить 70% для тренувального набору, 20% для валідаційного і 10% для тестового. Тренувальний набір використовується для навчання нейронної мережі, валідаційний – для моніторингу її роботи в процесі навчання, а тестовий – для остаточної оцінки точності моделі.

Модель EfficientNet, проходить кілька послідовних етапів навчання. На кожному етапі зображення пропускаються через багатоварову згорткову мережу. Починаючи з перших шарів, мережа виділяє базові ознаки (контури та текстури), а у глибших шарах – патерни, які можуть свідчити про наявність певної хвороби.




Рисунок 1 – Зображення враженого листа томату різними хворобами

Після завершення початкового навчання модель тестується на даних, які не були використані в навчальному процесі. Це дозволяє оцінити її здатність працювати з новими зображеннями та перевірити узагальнюючу здатність моделі. Ключовими метриками для оцінки є точність, повнота, точність класифікації та F1-міра.

У випадку якщо результати тестування не відповідають очікуванням виконується оптимізація гіперпараметрів, розширення набору даних, тонке налаштування.

### ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ

1. Pest and Pesticide Management. URL: <https://www.fao.org/pest-and-pesticide-management/about/understanding-the-context/en/> (дата звернення: 18.11.2024).
2. EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. URL: <https://arxiv.org/pdf/1905.11946> (дата звернення: 20.11.2024).

## **ШТУЧНИЙ ІНТЕЛЕКТ: ІНТЕГРАЦІЯ В ОСВІТІ ТА НАУЦІ**

Штучний інтелект вже став центральною темою сучасних технологій, які активно змінюють підходи до розв'язання складних задач в освіті та науці. Завдяки потужним обчислювальним можливостям і здатності аналізувати великі обсяги даних, ці технології відкривають нові перспективи для вдосконалення освітніх процесів і проведення досліджень у різних наукових сферах.

Використання штучного інтелекту стає важливим інструментом для модернізації освітніх систем, пропонуючи інноваційні підходи до навчання та управління освітнім процесом. Його застосування охоплює різні аспекти освіти, спрямовані на підвищення ефективності навчання та зменшення навантаження на освітян.

Штучний інтелект значно розширює межі доступу до освітніх та наукових ресурсів. Завдяки автоматичному перекладу та аналізу текстів, навчальні матеріали та наукові дослідження стають доступними незалежно від мови та регіону. Це сприяє створенню єдиного глобального інформаційного простору, де студенти, викладачі та науковці з різних країн можуть співпрацювати, обмінюватися ідеями й навчатися на основі спільних ресурсів.

Наприклад, системи на основі ШІ, такі як OpenAI чи Google Translate, дозволяють перекладати складні наукові праці та освітні курси, роблячи їх доступними для студентів у найвіддаленіших куточках світу. Це особливо важливо для розширення доступу до якісної математичної освіти, яка є фундаментом багатьох наукових дисциплін.

Штучний інтелект суттєво трансформує наукові дослідження, відкриваючи нові підходи до аналізу даних і моделювання складних явищ. У математиці, наприклад, ШІ допомагає вирішувати задачі оптимізації, досліджувати багатовимірні структури та автоматизувати доведення теорем. В інших науках, таких як хімія чи біологія, технології штучного інтелекту використовуються для прогнозування хімічних реакцій, аналізу генетичних даних чи візуалізації складних молекулярних процесів. Завдяки цим інструментам науковці можуть швидше отримувати результати, знижувати витрати на дослідження і

знаходити відповіді на питання, які раніше були недосяжними через обмеження традиційних методів.

Проте впровадження ІІІ також супроводжується викликами, серед яких нерівний доступ до технологій, потреба в забезпеченні конфіденційності даних і ризик надмірної автоматизації освітніх процесів. Хоча штучний інтелект має значний потенціал для трансформації освіти, його використання також супроводжується низкою негативних аспектів. Одним із головних ризиків є зниження ролі людського фактора в навчанні. Якщо студенти звикнуть покладатися на алгоритми для розв'язання завдань, це може призвести до зниження розвитку критичного мислення, креативності та здатності до самостійного аналізу. Тому важливо знаходити баланс між використанням ІІІ і традиційними методами навчання, забезпечуючи людський контроль і увагу до морально-етичних аспектів.

Таким чином, штучний інтелект стає важливим інструментом, який не лише вдосконалює освітні системи та наукові дослідження, а й сприяє глобалізації знань, створюючи нові можливості для співпраці й доступу до освіти на міжнародному рівні. Його потенціал для розвитку математики, природничих наук і міждисциплінарних досліджень є ключовим для вирішення сучасних і майбутніх викликів людства.

### **ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ**

1. Нікольський Ю. В. Системи штучного інтелекту : навч. посібник. – 2-ге вид., випр. та доп. / Нікольський Ю. В. – Львів : Магнолія-2006, 2013. – 279 с.

2. Кузьменко Б.В., Чайковська О.А. Системи штучного інтелекту: Навч.посібник.-К.:Альтерпрес, 2006.-140 с.

# ІНТЕЛЕКТУАЛЬНІ КОМП'ЮТЕРНО-ІНТЕГРОВАНІ ТЕХНОЛОГІЇ

УДК 004.42

*Ярошенко Д.Є., Рачинська А.Л.*  
*Одеський національний університет імені І.І. Мечникова,*  
*Одеса, Україна*

## ІНФОРМАЦІЙНА СИСТЕМА АВТОМАТИЗАЦІЇ РОБОТИ КАФЕДРИ

Електронний документообіг стає поширеним всюди – як в органах державної влади, так і на підприємствах, в ІТ-компаніях, банках, страхуванні, медицині, освітніх закладах та безлічі інших сфер. В умовах повсюдної цифровізації, ще й під час повномасштабної війни, неможливо працювати лише з паперовими документами, особливо якщо мова йде про великі компанії. Тому електронні документи стають незамінними. Кожна установа має свої процеси роботи з документами.

Одеський національний університет імені І. І. є самоврядним (автономним) національним вищим навчальним закладом, що діє згідно з виданою ліцензією на провадження освітньої діяльності за різними ступенями вищої освіти (в тому числі доктора філософії), виконує фундаментальні та прикладні наукові дослідження, є провідним науковим і методичним центром, має розвинуту інфраструктуру навчальних, наукових і науково-дослідних підрозділів, сприяє поширенню наукових знань та здійснює культурно-освітню діяльність. Кафедра є основним навчально-науковим структурним підрозділом ОНУ імені І. І. Мечникова, що проводить освітню і методичну діяльність з однієї або кількох споріднених спеціальностей, спеціалізацій чи навчальних дисциплін (модулів) і здійснює наукову, науково-дослідну та науково-технічну діяльність за певним напрямом.

Завідувач кафедри: 1) організовує навчальний процес на кафедрі; 2) розподіляє обсяг навчального навантаження між викладачами; 3) організовує керівництво аспірантами, докторантами, здобувачами; 4) формує пропозиції щодо зміни штатного розпису; 5) визначає напрями наукової роботи, організовує наукові дослідження; 6) організовує підвищення кваліфікації викладачів і співробітників; 7) дає висновок із відповідними рекомендаціями під час прийняття на роботу науково-педагогічних працівників та продовження трудових угод. Для організації навчального процесу на кафедрі в університеті

існує внутрішній документообіг. На основі освітніх програм різних спеціальностей деканат формує заявки навантаження для кожної кафедри, яка забезпечує на вказаній освітній програмі навчальний процес. На основі заявок навантаження завідувач кафедри або відповідальна особа на кафедрі формує внутрішній документ кафедри – навантаження кафедри. Навантаження кафедри має складові: загальний обсяг кафедри, навантаження кожного викладача кафедри та звіти за семестр та навчальний рік.

В роботі побудовано інформаційну технологію [1-2] автоматичного документообігу кафедри Одеського національного університету за допомогою компонентно - орієнтованого підходу.

*Першим етапом* формування документу навантаження кафедри є формування документу загального обсягу відповідно до документів деканату та учбової частини. Кількість заявок деканату динамічна і залежить від кількості освітніх програм, на яких кафедра повинна забезпечити навчальний процес. Крім того, сама форма заявок може змінюватися, тому необхідно розробити інформаційну технологію з функціоналом навчання системи розрахунку обсягу навантаження кафедри. *Другим етапом* формування документу навантаження кафедри є формування індивідуального навантаження кожного викладача кафедри. Для формування навантаження викладача повинно бути відомо яку частину якої дисципліни викладає конкретно який викладач. Тоді згідно закріплення викладачів за дисциплінами, може бути виконано формування документів індивідуального навантаження викладачів. Так як форма індивідуальних навантаження також може змінюватися, то інформаційна система повинна мати функціонал навчання системи розрахунку індивідуального навантаження викладача. По закінченню семестрів та навчального року документ навантаження кафедри доповнюється листами звітів викладачів. Тому третім етапом формування документу є створення листів звіту за кожний семестр та за рік. Інформаційна система забезпечує заповнення листів інформацією згідно індивідуального навантаження викладача. Інформаційна система проводить автоматичний розрахунок навантаження однієї кафедри. Для розрахунку необхідно налаштувати систему, тобто задати: кафедру; каталог шаблонів; навчальний рік; шаблон обсягу; шаблон заявки.

Зрозуміло, що всі налаштування системи повинні бути єдині для всієї інформаційної системи, для всіх класів та модулів проекту. Для того, щоб забезпечити єдність таких налаштування спроектовано клас налаштування з використанням патерну Singleton. Цей шаблон проектування забезпечує наявність у системі лише одного екземпляра

заданого класу, дозволяючи іншим класам отримувати доступ до цього екземпляра. Інформаційна система призначена для завідувача, секретаря та провідного фахівця кафедри, які несуть відповідальність за документацію кафедри.

### **ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ**

1. Peter Bernus, Kai Mertins, Gunter Schmidt, Handbook on Architectures of Information Systems. Berlin: Springer, 2016. 886 p.
2. Daniel Solis, Illustrated C# 2012. Berkeley: APress, 2012. 732 p.

**УДК 65.011.56**

***Сичов С. Ю.***

*Чорноморський національний університет  
ім. Петра Могили, Миколаїв, Україна*

### **МОЖЛИВІСТЬ ВИКОРИСТАННЯ СОЦІАЛЬНИХ МЕРЕЖ У СИСТЕМАХ АВТОМАТИЗАЦІЇ ВИРОБНИЦТВА**

У сучасному світі цифрові технології розвиваються зі стрімкою швидкістю, створюючи нові можливості для удосконалення виробничих процесів, підвищення ефективності та оптимізації робочих потоків. Одним із найбільш прогресивних та перспективних напрямів є використання штучного інтелекту, інтеграція чат-ботів через соціальні мережі в автоматизацію виробничих систем. Чат-боти можуть бути корисними не тільки для взаємодії між співробітниками, але й для інтеграції з виробничими лініями, надаючи можливість швидкого реагування на технічні проблеми та збільшення ефективності підприємства в цілому.

Ця концепція поєднує в собі швидкість і простоту соціальних мереж, а також високу автоматизацію процесів, що дозволяє забезпечити постійний моніторинг виробничих ліній для швидкого реагування на будь-які зміни чи збої. Розвиток чат-ботів у цьому напрямі дозволяє не лише знижувати навантаження на персонал, але й створювати нові можливості для розвитку підприємства, що стає ключовим фактором у досягненні високої продуктивності на виробництві.

#### *Основні завдання в інтеграції чат-ботів*

Для інтеграції чат-ботів на підприємстві необхідно виконати ряд наступних завдань. Одним із основних є розробка алгоритмів взаємодії чат-бота з існуючими системами автоматизації, що дозволить своєчасно виявляти несправності та діагностувати їх. Важливо, щоб ці алгоритми

не тільки точно виявляли проблеми, а й пропонували можливі варіанти їх вирішення, чим значно підвищить оперативність дій.

Також необхідно створити функціональну схему інтеграції чат-ботів із виробничими лініями. Вона повинна включати в себе чітке визначення точок взаємодії між різними елементами автоматизованої системи, а також можливості для швидкого доступу до системи через мобільні пристрої. Це дозволить працівникам завжди залишатися на зв'язку з системою і отримувати актуальну інформацію в будь-який час.

Останнім завданням є розробка інтерфейсів для ефективної взаємодії працівників з системою. Враховуючи, що більшість людей вже звикли до соціальних мереж, інтеграція чат-ботів саме в ці платформи стає оптимальним рішенням для забезпечення простоти і зручності використання. Мобільні додатки або соціальні мережі, такі як Facebook, Telegram чи WhatsApp, можуть стати потужними каналами для обміну інформацією між виробничими лініями та працівниками.

#### *Функція чат-ботів у автоматизації виробництва*

Основна функція чат-ботів полягає у швидкому аналізі даних, отриманих з сенсорів обладнання, та повідомленні персоналу про поточний стан виробничої лінії. Вони є справжніми «розумними» помічниками, здатними не тільки фіксувати несправності, а й допомагати у прийнятті рішень. Крім того, чат-боти можуть пропонувати точні інструкції щодо усунення неполадок, що дозволить працівникам зменшити час, витрачений на вирішення проблем, для оперативного реагування на ситуацію.

Інтеграція чат-ботів із соціальними мережами надає додаткові можливості для забезпечення ще більш швидкого реагування на несправності. Це дозволяє:

- оперативно отримувати сповіщення про несправності обладнання безпосередньо через чат-бота, що інтегрований з сенсорами, встановленими на виробничих лініях;
- забезпечити працівників детальними та зрозумілими інструкціями щодо усунення технічних проблем, адаптованими до конкретних обставин, що виникли;
- відстежувати виконання ремонтних робіт і прогрес їхнього завершення, завдяки інтеграції з іншими автоматизованими системами управління виробництвом.

На рисунку 1 зображена функціональна схема інтеграції чат-ботів у систему автоматизації виробництва.

Дані елементи інтеграції не тільки спрощують процеси, але й забезпечують високий рівень автономії для виробничих ліній. Основна мета такої схеми — використання чат-ботів для спілкування між

обладнанням і операторами, що дозволить значно зменшити людське втручання в процеси управління та підвищити ефективність виробництва.

#### *Етапи роботи системи чат-бота*

Функціонування системи чат-бота на виробництві можна поділити на кілька ключових етапів:

1. Виявлення неполадок: сенсори на виробничій лінії виявляють помилки або збої в роботі обладнання і негайно передають сигнали в систему.




Рисунок 1 – Функціональна схема інтеграції чат-ботів у виробничу лінію

2. Передача інформації через чат-бот: чат-бот отримує ці сигнали та автоматично інформує персонал, що дозволяє миттєво реагувати на проблему.
3. Генерація інструкцій: на основі отриманої інформації чат-бот генерує детальні інструкції, адаптовані до конкретної ситуації, що дозволяє швидко вирішити проблему.
4. Моніторинг виконання робіт: після того, як проблема вирішена, чат-бот слідкує за статусом виконання робіт і надає працівникам постійну інформацію про стан ситуації.

#### *Переваги інтеграції чат-ботів у виробництво*

Інтеграція чат-ботів у системи автоматизації значно підвищує ефективність управління виробничими процесами. Завдяки швидкому реагуванню на несправності та автоматичним інструкціям для їх усунення, час простою обладнання зменшується до мінімуму, що безпосередньо впливає на продуктивність підприємства. Впровадження

таких технологій особливо актуальне для підприємств з великою кількістю складних виробничих ліній, де помилки можуть призвести до серйозних збитків.

Аналіз показує, що застосування чат-ботів дозволяє не тільки знижувати витрати, пов'язані з усуненням несправностей, але й значно покращує якість обслуговування технічних процесів, дозволяючи уникати людських помилок і забезпечити стабільність роботи обладнання.

Таким чином, використання чат-ботів у системах автоматизації виробництва — це потужний крок у майбутнє, який дозволяє значно підвищити ефективність виробничих процесів, скоротити час реакції на неполадки та забезпечити безперебійну роботу обладнання.

**УДК 629.7.013**

*Кумпан І. Д.*

*Чорноморський національний університет  
ім. Петра Могили, Миколаїв, Україна*

## **АВТОМАТИЗОВАНА СИСТЕМА КЕРУВАННЯ ПРОМИСЛОВИМ РОБОТОМ-МАНІПУЛЯТОРОМ У ПОРТУ**

Автоматизована система управління (АСУ) — це інтелектуальна комплексна система, що базується на використанні сучасних технологій для збору, обробки та передачі інформації, необхідної для управління. Вона поєднує в собі організаційну структуру управління, технічні засоби, а також взаємодіє з об'єктом управління і людиною. Сучасні АСУ включають пристрої для формування вихідних даних, автоматичного збору та передачі інформації, обробки за логіко-математичними алгоритмами, відображення отриманих результатів, генерації управлінських сигналів та виконання цих команд. [1]

Робота на складі чи в порту — досить важка та небезпечна робота. Тому з плином прогресу на заміну людям впроваджуються автоматизовані системи керування, наприклад, використання роботів-маніпуляторів для розвантаження та завантаження товару на складах та портах.

Фізично складна робота, яка передбачає швидке підняття та переміщення важких коробок з причепів, піддонів та іншого, що знаходяться під відкритим небом на завантажувальних платформах, є особливо важким завданням у таких умовах, як спекотна Флорида в липні чи холодний Торонто в січні. Такі умови роблять інтелектуальну роботизовану автоматизацію цього процесу вкрай бажаною, про що говорять практично всі, хто має досвід управління складами. Однак ще

донедавна повна автоматизація вважалася далекою перспективою. Ситуація кардинально змінилася у 2023 році, коли кілька робототехнічних компаній комерційно впровадили інтелектуальні автоматизовані системи для розвантаження вантажівок. Представники бізнесу зазначають, що це інноваційне рішення може стати ключовим кроком до трансформації всієї галузі.

Компанії DHL Supply Chain та Boston Dynamics розпочали співпрацю в галузі роботизації складів кілька років тому в рамках масштабної ініціативи з автоматизації операцій DHL. Цей постачальник логістичних послуг активно взаємодіє з різними технологічними партнерами для впровадження автоматизації у численні процеси на своїх складах і в центрах виконання замовлень. Загалом DHL інвестувала близько 430 мільйонів доларів США в автоматизовані технології, основна частина яких була реалізована в Північній Америці.

Результатом зусиль компаній у розробці роботизованих маніпуляторів стало впровадження кількох рішень для автоматизованого розвантаження вантажівок на об'єктах DHL по всій країні цього року. Роботи «Stretch» оснащені механічною рукою, вакуумним захоплювачем і мобільною платформою, що дозволяє їм щодня розвантажувати картонні коробки з товарами. Завдяки вакуумному захвату вони піднімають коробки з трейлера, хапаючи їх зверху або збоку, і переміщують на гнучкий конвеєр для подальшого транспортування всередину приміщення. Після цього коробки скануються для внесення в інвентар і розміщуються на зберігання відповідно до матеріальних потоків підприємства.

Ці роботи, що працюють на акумуляторах, здатні функціонувати повну зміну на одному заряді, розвантажуючи до 500 коробок за годину. Одним із останніх проєктів DHL Supply Chain стало тестування системи в спеціалізованому центрі виконання замовлень для компанії Carhartt, виробника робочого одягу, у Канал Вінчестер, штат Огайо.

Рухи робота контролюються за допомогою комбінації датчиків, камер, систем управління та штучного інтелекту (ШІ). Його гнучка механічна рука здатна досягати коробок у будь-якому місці причепа, адаптуючись до вантажів різної форми та розміру (включно з коробками вагою до 22,5 кг). Робот може реагувати на зміни у конфігурації вантажу: він піднімає перекинуті коробки або без зусиль захоплює ті, що змістилися під час розвантаження, демонструючи функціональність, схожу на дії працівника. [2]

Враховуючи технічні рішення, які були виконані компанією Boston Dynamics та мету, яка була поставлена на кваліфікаційну магістерську роботу, було сформовано функціональну схему для автоматизованої системи керування промисловим роботом-маніпулятором у порту (Рисунок 1).

Перевагами такого технічного рішення є:

- безпека для працівників на вантажному майданчику;
- витривалість до виконання роботи в екстремальних умовах;
- підвищення швидкості процесу вивантаження, сортування та навантаження вантажу;

Опираючись на проведений аналіз існуючих аналогів, технічні умови та мету кваліфікаційної магістерської роботи було виведено конфігурацію блоків, які потрібні для автоматизованої системи керування промисловим роботом-маніпулятором у порту. Було сформовано функціональну схему АСК з принципом роботи робо-руки.




Рисунок 1 – Функціональна схема АСК промисловим роботом-маніпулятором

## ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ

1. Автоматизована система керування. Вебсайт. URL: [https://uk.wikipedia.org/wiki/Автоматизована\\_система\\_керування](https://uk.wikipedia.org/wiki/Автоматизована_система_керування) (дата звернення: 18.11.2024).

2. Robotic truck unloading gets its due. Вебсайт. URL: <https://www.dvvelocity.com/articles/57213-robotic-truck-unloading-gets-its-due> (дата звернення: 19.11.2024).

## **ІНТЕЛЕКТУАЛЬНІ КОМПОНЕНТИ В АВТОМАТИЗОВАНІЙ СИСТЕМІ ПАРКУВАННЯ АВТОМОБІЛЕМ**

Автоматизація процесу паркування автомобілів стає дедалі актуальнішою в сучасному світі, особливо в умовах урбанізації та зростання кількості транспортних засобів. Інтелектуальні компоненти відіграють ключову роль у створенні ефективних і безпечних автоматизованих систем паркування (АСП) [1].

Які ж інтелектуальні компоненти лежать в основі таких систем ?

Сенсори є "очима" системи. Камери, лідари, радары та ультразвукові датчики збирають детальну інформацію про навколишнє середовище: відстань до інших автомобілів, вільні місця, перешкоди тощо.

«Мозком» системи є алгоритми. Вони обробляють дані від сенсорів, планують оптимальний маршрут для паркування, розпізнають різні об'єкти та приймають рішення в реальному часі.

Штучний інтелект: Машинне навчання та глибокі нейронні мережі дозволяють системам самонавчатися на основі досвіду, адаптуватися до нових умов та покращувати свої можливості.

Інтерфейс користувача: Це "мостик" між людиною та машиною. Голосові команди, мобільні додатки та візуалізація роблять процес паркування максимально зручним та інтуїтивним.

Переваги інтелектуальних автоматизованих систем паркування:

Збільшення пропускну здатності парковок: Ефективне використання кожного квадратного метра.

Зменшення кількості ДТП: Автоматизовані системи паркування більш безпечні, ніж ручне паркування.

Зручність для користувачів: Більше не потрібно витратити час на пошук вільного місця.

Економія енергії: Оптимізація маршрутів руху дозволяє зменшити витрати палива.

Нейронні мережі використовуються для навчання системи на основі історичних даних, що дозволяє покращити точність прогнозів і підвищити ефективність паркування.

На рис. 1 наведена схема компонентів, а на рис. 2 блок-схема алгоритму роботи АСП, яка була розроблена в ході роботи над бакалаврською роботою.




Рисунок 1 – Узагальнена функціональна схема підключення апаратних компонентів АСП



Рисунок 2 - Блок-схема алгоритму роботи АСП

Ультразвуковий датчик подає сигнал на мікроконтролер про відстань до перешкоди, інфрачервоний датчик подає сигнал у разі фіксування руху у зоні маневрування техніки, мікроконтролер відповідно до сигналів подає звукові сигнали, та контролює безпечну швидкість руху техніки.

Автоматизація паркування – це лише перший крок на шляху до створення повністю автономних транспортних систем. У майбутньому ми можемо очікувати появи «розумних парковок», які будуть інтегровані в міську інфраструктуру та надаватимуть водіям комплексну інформацію про наявність вільних місць, тарифи та інші сервіси.

### **ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ**

1. Мигаль В. Д. Інтелектуальні системи в технічній експлуатації автомобіля : монографія. Харків : Майдан, 2018. 262 с.

# ІНТЕЛЕКТУАЛЬНІ ВЕБ-ТЕХНОЛОГІЇ І ВЕБ-СЕРВІСИ

УДК: 004.8+004.91

*Ченура Т.Р., Бурлаченко І. С.  
Чорноморський національний університет  
ім. Петра Могили, Миколаїв, Україна*

## ВИКОРИСТАННЯ ШТУЧНОГО ІНТЕЛЕКТУ ДЛЯ АВТОМАТИЗОВАНОГО ЗБОРУ OSINT З СОЦІАЛЬНИХ МЕДІА

Збройні агресії в світі дають суттєвий поштовх розповсюдженню OSINT-технологій у світі, зокрема й в Україні. Автоматизований збір OSINT (Open Source Intelligence) із соціальних медіа є актуальним завданням у сучасному світі, де обсяг відкритих даних значно зростає. Соціальні медіа, новинні ресурси, платформи для обміну повідомленнями надають величезний масив інформації, яка може бути використана для моніторингу подій, виявлення загроз або аналізу суспільних тенденцій. Проте ручна обробка таких даних потребує значних ресурсів і часу. Застосування методів штучного інтелекту дозволяє автоматизувати цей процес, забезпечуючи швидкий і точний аналіз інформації.

Основною метою роботи є розробка системи, яка за допомогою алгоритмів штучного інтелекту здійснюватиме збір, фільтрацію, аналіз і візуалізацію даних із соціальних медіа. Об'єктом дослідження виступає процес отримання інформації з відкритих джерел, а предметом – методи й алгоритми, що дозволяють ефективно обробляти ці дані.

Система передбачає кілька основних етапів роботи. На етапі збору інформації використовуються API платформ, таких як Telegram, Twitter (X), або RSS-канали новинних ресурсів [1]. Термін OSINT розшифровується як розвідка серед доступних джерел, що охоплює будь-яку інформацію. Дані можуть бути отримані на законних підставах з безкоштовних публічних джерел про людину, фірму [2]. Дані збираються автоматично у визначені часові інтервали. Наступний етап, фільтрація, дозволяє відсіяти нерелевантну інформацію: дублікати, спам, записи іншими мовами тощо. Це значно знижує рівень інформаційного шуму.

Ключовою частиною системи є аналіз, що виконується за допомогою алгоритмів обробки природної мови. Завдяки використанню обробки природної мови (англ. Natural Language Processing, NLP)

комп'ютерні системи можуть сприймати й аналізувати людську мову. Це потужний інструмент, який розробники використовують для організації та структурування знань, що дозволяє комп'ютерам виконувати складні завдання, такі як автоматичне підсумовування, мовний переклад, ідентифікація іменованих об'єктів, аналіз тональності, розпізнавання мовлення та тематична сегментація [3]. NLP дозволяє кластеризувати схожі повідомлення, формувати загальний висновок та визначати ключові факти, такі як місце події, дата або категорія інформації.

Для наочного уявлення пропонується схема архітектури системи, яка відображає основні модулі, включаючи збір даних, фільтрацію, аналіз, збереження та візуалізацію.



Рисунок 6 – Концептуальна діаграма автоматизованого збору даних

Джерело: створено автором.

Для зберігання отриманих результатів використовується база даних, яка структурує висновки, ключові слова та джерела, забезпечуючи можливість швидкого доступу до інформації.

Заключним етапом є візуалізація, яка покликана зробити результати аналізу доступними для користувача. Візуалізація може включати

графіки трендів, географічні мапи подій, зв'язки між темами новин, таблиці зі стислими висновками та джерелами.

Розроблена система має практичне значення в умовах інформаційної війни та кризових ситуацій. Вона може використовуватися для виявлення потенційних загроз, аналізу суспільної думки або підтримки прийняття рішень у реальному часі. У майбутньому система може бути доповнена новими джерелами даних, більш точними алгоритмами аналізу та розширеним функціоналом для інтеграції з іншими програмними рішеннями.

### **ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ**

1. Інструменти інформаційної боротьби: ОСІНТ, ІПСО та протидія дезінформації. INFOlight.ua. URL: <https://infolight.in.ua/wp-content/uploads/2023/02/brochure-2.pdf> (дата звернення: 19.11.2024).

2. OSINT: технологія збору та аналізу даних з відкритих джерел. Softlist. URL: <https://softlist.com.ua/ua/news/osint-tekhnologiya-sbora-i-analiza-dannyh-iz-otkrytyh-istochnikov> (дата звернення: 19.11.2024).

3. Від аналізу тексту до моделювання природної мови: комплексне дослідження. *Herald of Khmelnytskyi National University. Technical sciences. Home Page*. URL: <https://doi.org/10.31891/2307-5732-2024-333-2-38> (дата звернення: 19.11.2024).

**УДК 004.8+004.4`2**

*Попов Я. В., Худолій А. П., Бурлаченко І. С.,  
Чорноморський національний університет  
ім. Петра Могили, Миколаїв, Україна*

### **MACHINE LEARNING БІБЛОТЕКИ СЕРВЕРНИХ ФРЕЙМВОРКІВ У ЗАСТОСУНКАХ ДЛЯ ПСИХОТЕРАПЕВТИЧНИХ КОНСУЛЬТАЦІЙ ТА АНАЛІЗУ ЯКОСТІ ТУРИСТИЧНИХ ПОДОРОЖЕЙ**

У сучасному світі технології штучного інтелекту та машинного навчання набувають дедалі більшого поширення в різних сферах життя, включаючи психологічну підтримку та туризм. Ефективність і якість сервісів у цих галузях значно підвищуються завдяки впровадженню сучасних серверних фреймворків і бібліотек для машинного навчання (ML). Зростання потреб у психотерапевтичних консультаціях пов'язане з підвищенням рівня стресу та поширенням

психоемоційних розладів у суспільстві. Водночас індустрія туризму, яка зазнала значних змін через пандемічні обмеження, активно шукає нові підходи до аналізу та підвищення якості туристичних послуг. У цих умовах використання машинного навчання дозволяє автоматизувати аналіз великих обсягів даних, створювати персоналізовані рекомендації, оцінювати емоційний стан користувачів і підвищувати задоволеність клієнтів. Застосування бібліотек машинного навчання забезпечує ефективну реалізацію алгоритмів аналізу, класифікації, прогнозування та обробки тексту. Серверні фреймворки дозволяють інтегрувати ML бібліотеки в масштабовані вебзастосунки для обслуговування користувачів у режимі реального часу. Сучасні бібліотеки машинного навчання дозволяють значно скоротити час розробки та впровадження інноваційних рішень завдяки високому рівню абстракції, великій кількості готових функцій і підтримці обчислень на графічних процесорах. Наприклад, у сфері психотерапії бібліотеки можуть бути використані для створення чат-ботів, які аналізують емоційний стан пацієнта через текст або голос, а в туризмі — для прогнозування рейтингу готелів або створення рекомендаційних систем маршрутів. Таким чином, інтеграція бібліотек машинного навчання в серверні фреймворки є не тільки технічною необхідністю, а й ключовим фактором у розробці якісних і конкурентоспроможних сервісів. Метою цієї роботи є дослідження можливостей застосування машинного навчання для створення ефективних і масштабованих застосунків, орієнтованих на психотерапевтичні консультації та аналіз якості туристичних подорожей, а також визначення ролі серверних фреймворків у їх інтеграції та реалізації.

Використання TensorFlow.js (рис. 1-а) у серверному середовищі, такому як Nest.js, дозволяє виконувати складні задачі машинного навчання безпосередньо на сервері. Це зручно для обробки великих обсягів даних, наприклад, під час аналізу текстів користувачів у психотерапевтичних консультаціях. Використання TensorFlow.js на Nest.js дає змогу обробляти дані користувача локально на сервері, забезпечуючи високий рівень конфіденційності. Це особливо важливо у психотерапевтичних застосунках, де чутливість даних є критичним фактором. TensorFlow.js дозволяє реалізувати нейронні мережі для обробки текстових, голосових або відеоданих, що надходять від користувачів. Наприклад, за допомогою NLP-моделей можна аналізувати текстові запити для виявлення ознак депресії, тривожності чи стресу. Використовуючи TensorFlow.js, можна створити рекомендаційні системи, які адаптуються до потреб конкретного

користувача. Наприклад, такі системи можуть пропонувати техніки дихання, медитації чи інші методи релаксації залежно від емоційного стану користувача.





Рисунок 1 – Концептуальні діаграми бібліотек: (а) - TensorFlow.js, (б) – Rubix

Rubix ML — це сучасна PHP-бібліотека для машинного навчання, яка чудово інтегрується з Laravel через Composer (рис. 1-б). Її актуальність при розробці вебзастосунку аналізу якості туристичних подорожей зумовлена широкими можливостями в обробці даних, класифікації та прогнозуванні. Rubix ML ефективно працює з великими обсягами інформації, що є важливим для аналізу відгуків, рейтингів і поведінки користувачів. Завдяки цій бібліотеці можна створити рекомендаційну стрічку, що допоможе значно покращити користувацький досвід.

Laravel - це безкоштовний PHP-фреймворк з відкритим вихідним кодом. Його основа — архітектура MVC (Model-View-Controller), яка розділяє логіку програми, інтерфейс користувача і роботу з даними, що допомагає підтримуватись чистого та зрозумілого коду. Завдяки різним інструментам, як Artisan CLI, Blade та Eloquent ORM, Laravel дозволяє швидко створювати складні вебзастосунки. Вбудовані функції безпеки, таких як вбудоване шифрування і хешування, та захист від міжсайтових скриптів (XSS) і атак на підробку міжсайтових запитів (CSRF). У поєднанні з бібліотеками машинного навчання, як згадувалось раніше Rubix ML, Laravel стає ідеальним середовищем для інтеграції аналітичних функцій, прогнозування та побудови рекомендаційної системи, що особливо корисно для вебзастосунку аналізу якості туристичних подорожей.

Nest.js — це прогресивний фреймворк для розробки серверних застосунків на Node.js, побудований з урахуванням принципів модульності, масштабованості та зручності. Завдяки архітектурі на основі модулів, Nest.js ідеально підходить для інтеграції з бібліотеками машинного навчання. Програми будуються з набору модулів, що робить код легко підтримуваним і масштабованим. Це дозволяє створити окремі модулі для ML-функцій, які можуть бути повторно використані або протестовані окремо. Завдяки підтримці Express і Fastify як HTTP-движків, можна легко налаштувати маршрути для обробки ML-запитів. Завдяки контролерам, сервісам та провайдерам забезпечується чітке розмежування логіки та зручність інтеграції складних ML-алгоритмів.




Рисунок 2 – Спроектвана Tier-архітектура для психотерапевтичних консультацій

Вебзастосунок розроблений для надання психологічної підтримки та терапії користувачам із різними психологічними потребами (рис. 2). Основна мета сервісу — допомогти користувачам визначити їхні психологічні проблеми та запропонувати персоналізовані рекомендації або терапевтичні методи.

Ключові функції:

- інтерактивна анкета та алгоритми обробки даних дозволяють визначати можливі психологічні розлади чи дискомфорт на основі відповідей користувача;
- пропонується набір технік (наприклад, когнітивно-поведінкова терапія, медитації, вправи на релаксацію), підібраних відповідно до діагностованих потреб користувача;
- система використовує штучний інтелект для аналізу даних та створення персоналізованих рекомендацій. Завдяки цьому відповіді та поради є унікальними для кожного користувача. AI також забезпечує підтримку у вигляді автоматичних чатів або порад у реальному часі;
- платформа надає користувачам доступ до бібліотеки освітніх статей, відео та інтерактивних матеріалів, що допомагають краще зрозуміти свій емоційний стан, розвивати навички самоконтролю та запобігати стрес.

Вебзастосунок, що досліджується, поєднує технології AI, психологічні методики та зручність цифрових платформ, щоб зробити психотерапію доступною та ефективною для ширшого кола людей.

Rubix є доцільним для використання у розробленні вебзастосунку аналізу якості туристичних подорожей. Метою розроблення вебзастосунку є полегшення збору та аналізу відгуків користувачів, а також надання інструментів для оцінки подорожей з урахуванням різних критеріїв якості.

Виходячи зі структури класів (рис. 3), основні функціональні можливості застосунку включають:

- перегляд та фільтрація туристичних подорожей за напрямками, рейтингами та відгуками;
- можливість додавати, редагувати та видаляти власні відгуки про подорожі;
- система лайків і коментарів для підвищення взаємодії між користувачами;
- профілі користувачів із історією постів подорожей;
- панель адміністратора для управління користувачами, модерації контенту;
- персоналізовані рекомендації завдяки методам машинного навчання для надання рекомендацій користувачам на основі їхніх уподобань.




Рисунок 3 – Діаграма відношень між класами серверного застосунку для аналізу якості туристичних подорожей

У подальших дослідженнях буде розглянуто механізми створення, оновлення, видалення та фільтрації туристичних місць і відгуків, а

також впровадження методів машинного навчання для автоматичного надання рекомендацій користувачам.

**Висновки:** використання машинного навчання та сучасних серверних фреймворків є ключовим чинником у розвитку інноваційних рішень у сферах психотерапії та туризму. Технології машинного навчання забезпечують автоматизацію аналізу великих обсягів даних, створення персоналізованих рекомендацій і оцінку емоційного стану, що значно підвищує якість обслуговування. Впровадження таких інструментів дозволяє ефективно адаптувати сервіси до індивідуальних потреб користувачів, одночасно скорочуючи час розробки та інтеграції завдяки готовим рішенням і підтримці обчислень на графічних процесорах. У психотерапії ці технології застосовуються для створення чат-ботів і аналізу емоцій, а в туризмі — для прогнозування рейтингів і розробки рекомендаційних систем.

### ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ

1. Machine Learning and AI for Healthcare: Big Data for Improved Health Outcomes. URL: [https://aitskadapa.ac.in/e-books/CSE/MACHINE%20LEARNING/Machine%20Learning%20and%20AI%20for%20Healthcare\\_%20Big%20Data%20for%20Improved%20Health%20Outcomes%20\(%20PDFDrive%20\).pdf](https://aitskadapa.ac.in/e-books/CSE/MACHINE%20LEARNING/Machine%20Learning%20and%20AI%20for%20Healthcare_%20Big%20Data%20for%20Improved%20Health%20Outcomes%20(%20PDFDrive%20).pdf) (date of access: 21.11.2024).
2. Nabil W. Fine-tuning LLaMA 3 on Mental Health Dataset. Medium. URL: <https://medium.com/@nabilw/fine-tuning-llama-3-on-mental-health-dataset-70d4e69b8875> (date of access: 21.11.2024).
3. What's Coming in TensorFlow 2.0. TensorFlow Blog, 2019. URL: <https://blog.tensorflow.org/2019/01/whats-coming-in-tensorflow-2-0.html> (date of access: 21.11.2024).
4. What is Laravel? URL: <https://flatirons.com/blog/what-is-laravel-an-overview-2024/> (date of access: 21.11.2024).
5. Rubix ML documentation. URL: <https://docs.rubixml.com/latest/> (date of access: 21.11.2024).
6. Artificial Intelligence in Tourism. URL: <https://startups.epam.com/blog/artificial-intelligence-in-tourism-and-travel-industry> (date of access: 21.11.2024).

## **СИСТЕМА ВЗАЄМОДІЇ З МОДЕЛЛЮ ПРОГНОЗУВАННЯ ЛІСОВИХ ПОЖЕЖ**

Глобальна зміна клімату призвела до підвищення температури, що в свою чергу в свою чергу, підвищило частоту і загальний ризик лісових пожеж у всьому світі. Модель прогнозування допоможе знизити ризики з'явлення лісових пожеж, але використання моделі напряду може бути незручним та незрозумілим для користувачів без технічних знань. Тому, для ефективного користування моделлю прогнозування необхідна система взаємодії.

Модель прогнозування лісових пожеж можна уявити у вигляді функції, яка у якості параметрів отримує метеорологічні дані, такі як температура і вологість повітря, швидкість вітру, інтенсивність дощу, а у якості результату повертає прогноз лісової пожежі під час цих метеорологічних умов (1 — пожежа буде, 0 — пожежи не буде). Таким чином, задачами системи взаємодії є: отримання від користувача локацію лісу, до якої він бажає отримати прогноз, отримати метеорологічні дані до цієї локації від сервісу прогноза погоди, передати ці дані до моделі прогнозування, вивести результат прогнозування до користувача. Таким чином, система взаємодії з моделлю прогнозування лісових пожеж буде складатися з 4 основних компонентів:

- База даних — місце, де модель прогнозування зберігається, і до якої можна отримати доступ у будь-який час.
- Фронтенд додаток — інтерфейс системи, те, що відображає карту світу. При натисканні на локацію на карті отримує її широту і довготу, відсилає ці дані до REST API серверу, виводить результат у спливаючому вікні.
- Сервіс прогнозу погоди, що дозволить отримати метеорологічну інформацію, на основі якої модель буде робити прогноз
- REST API сервер — сервер, що у запиті отримує широту і довготу, що використовує для отримання метеорологічних даних від сервісу прогнозу погоди, після чого отримані дані передає до функції моделі прогнозування лісових пожеж, результат якої повертає у відповідь.




Рисунок 1 – Архітектура системи взаємодії

Для розробки фронтенд додатку існує багато javascript фреймворків, таких як Angular, Vue, React, Svelte. Стандартом індустрії є React, основною причиною чого є те, що його використовують більшість великих IT компаній, таких як Meta, Uber, Netflix, Paypal.

Для сервісу інтерактивної карти була обрана бібліотека Leaflet, що є провідною бібліотекою JavaScript з відкритим вихідним кодом для інтерактивних карт, зручних для мобільних пристроїв [1]. Вона легко інтегрується з React'ом і має всі функції необхідні для системи взаємодії, такі як можливість отримати довготу і широту локації на яку кликнув користувач і можливість відобразити спливаюче вікно з результатом прогнозування.

Для взаємодії з моделлю прогнозування буде використана python бібліотека scikit-learn, тому для розробки REST API серверу має сенс використовувати фреймворк базований на мові Python. Фреймворк Flask ідеально підходить для цієї задачі, тому що це дуже простий, але розширюваний фреймворк. Це дає розробникам можливість обирати потрібну конфігурацію, тим самим полегшуючи написання додатків або плагінів [2], через що Flask легко інтегрується з бібліотекою scikit-learn.

У якості сервісу прогноза погоди був обран сервіс OpenMeteo, тому що це найбільш просунутий метеорологічний сервіс, який є безкоштовним і з відкритим кодом, а також має зручну python бібліотеку [3].

У якості бази даних нереляційна БД має сенс, тому що модель прогнозування є монолітним об'єктом, без з'язків. Найбільш популярною і найбільш ефективною нереляційною БД є MongoDB, тому що вона підтримує зберігання серіалізованих моделей ML (наприклад, .pkl або .h5) безпосередньо за допомогою GridFS, функції для роботи з великими файлами, а також дозволяє легко зберігати пов'язані дані (наприклад, параметри навчання, показники точності) разом з моделями. Для роботи з MongoDB використовують Python бібліотеку PyMongo.

Висновок: Була спроектована система взаємодії з моделлю прогнозування лісових пожеж. Були виділені 4 основні компоненти: база даних, сервіс прогнозу погоди, фронтенд додаток, REST API сервер. Для розробки REST API серверу був обран фреймворк Flask. Для розробки фронтенд додатку був обран фреймворк React. У якості бази даних була обрана нереляційна БД MongoDB. У якості сервісу прогнозу погоди був обран сервіс OpenMeteo.

### **ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ**

1. Leaflet – a Javascript library for interactive maps. URL: <https://leafletjs.com/> (дата звернення: 21.11.2024).
2. Kunal Renal. Building REST APIs with Flask. New Delhi : Apress, 2019. 1р.
3. Free Open-Source Weather API. URL: <https://open-meteo.com/> (дата звернення: 20.11.2024).

**УДК 004.9:004.42**

***Бойко В. О.***

*Чорноморський національний університет  
ім. Петра Могили, Миколаїв, Україна*

### **ИНТЕЛЕКТУАЛЬНИ АСПЕКТИ РОЗГОРТАННЯ ВЕБ- ЗАСТОСУНКІВ NEXT.JS ТА REACT.JS ЧЕРЕЗ ПЛАТФОРМУ VERCEL**

Сучасні веб-технології характеризуються високим рівнем інтелектуалізації, що досягається завдяки широкому застосуванню автоматизації, оптимізації процесів розробки та експлуатації, а також персоналізації користувацького досвіду. Next.js і React.js виступають провідними фреймворками у створенні веб-застосунків, надаючи можливість ефективного управління рендерингом за допомогою

серверного рендерингу (SSR) та статичної генерації сторінок (SSG) [1]. Завдяки цим підходам забезпечується адаптація контенту веб-сторінок до індивідуальних потреб користувачів у режимі реального часу, що є важливим критерієм інтелектуальності технологій.

Платформа Vercel, яка спеціалізується на розгортанні веб-застосунків, пропонує інноваційні рішення для автоматизації процесів [2]. Її інтегровані механізми CI/CD дозволяють безперервно розгортати оновлення, автоматично синхронізуючи їх із репозиторіями, такими як GitHub. Це значно прискорює цикл розробки, забезпечуючи високу гнучкість та оперативність у виправленні помилок чи впровадженні нових функцій. Додатково, можливості Vercel включають автоматичне масштабування, балансування навантаження та оптимізацію використання ресурсів, що дозволяє підтримувати стабільну продуктивність веб-застосунків навіть за умов значного збільшення навантаження. Таким чином, платформа виступає прикладом інтелектуального підходу до розробки й експлуатації сучасних веб-сервісів.

Інтелектуальні веб-застосунки активно впроваджують алгоритми адаптивного рендерингу, які забезпечують можливість динамічного налаштування контенту відповідно до індивідуальних потреб користувачів. Завдяки інтеграції з API для збору й обробки даних, такі системи здатні швидко аналізувати запити користувачів та адаптувати вміст сторінок у реальному часі. Це дозволяє створювати гнучке середовище, що реагує на зміни поведінки користувачів або умов використання, наприклад, пристроїв, географічного розташування чи часу доби. Подібний підхід робить ці технології критично важливими для розвитку сучасних інтелектуальних веб-сервісів, які орієнтовані на підвищення зручності, ефективності та взаємодії з користувачами.

У перспективі інтеграція веб-розробки з методами машинного навчання здатна забезпечити ще вищий рівень інтелектуалізації веб-технологій. Використання алгоритмів для аналізу поведінки користувачів відкриває нові можливості адаптації веб-застосунків до їхніх індивідуальних потреб, що є важливим чинником підвищення якості веб-сервісів. Такий підхід дозволяє не лише персоналізувати взаємодію, але й прогнозувати поведінкові патерни користувачів, оптимізуючи структуру та функціональність застосунків.

Платформа Vercel, завдяки своїм розширеним можливостям, має потенціал для інтеграції механізмів прогнозування, які базуються на аналізі історичних даних розгортання. Це дозволить виявляти та попереджати можливі проблеми на етапі розгортання, що суттєво підвищить стабільність та надійність роботи веб-застосунків.

Поєднання таких інструментів із технологіями, як Next.js і React.js, створює умови для розробки високотехнологічних веб-рішень, що відповідають сучасним вимогам.

Таким чином, Next.js, React.js та Vercel представляють собою яскраві приклади інтелектуальних веб-технологій, здатних оптимізувати процеси розгортання, підвищувати якість взаємодії з користувачами та сприяти вирішенню завдань інформаційного суспільства. Їх застосування дозволяє створювати інноваційні веб-сервіси, які відповідають викликам і потребам сучасної інформаційної епохи.

### **ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ**

1. Next.js. Офіційний сайт. URL: <https://nextjs.org/docs> (дата звернення: 17.11.2024).
2. Vercel. Офіційний сайт. URL: <https://vercel.com/docs> (дата звернення: 17.11.2024).

**УДК 004.42**

***Пасенченко Т. О.***

*Одеський національний університет  
імені І. І. Мечникова, Одеса, Україна*

### **ІНТЕЛЕКТУАЛЬНА LOW-CODE ПЛАТФОРМА ДЛЯ РОЗРОБКИ КОРПОРАТИВНИХ ЗАСТОСУНКІВ**

В останні роки дедалі більше підприємств потребують використання корпоративних застосунків (enterprise applications) для автоматизації певних бізнес-процесів.

До таких застосунків відносять CRM, ERP, HRM системи, програмне забезпечення для керування контрактами, бухгалтерією тощо.

Розробка таких застосунків ‘з нуля’ потребує значних інвестицій, що часто стає перешкодою для автоматизації відповідних бізнес-процесів.

Low-code – це підхід в розробці програмного забезпечення, що дозволяє розробляти застосунки за допомогою високорівневих абстракцій (візуальних інструментів, стандартних форм тощо) з використанням невеликих фрагментів коду для опису складної бізнес-логіки.

Розробка застосунків за допомогою підхода low-code відбувається за допомогою платформи LCAP (Low-Code Application Platform [1]). Це застосунок, що розроблений за допомогою класичних методів програмної інженерії та дозволяє створювати, редагувати та керувати

роботою користувацьких застосунків без використання таких методів (тобто значно простіше).

Ключовою характеристикою LCAP є простота її опанування громадянським розробником (citizen developer) [2], тобто простим співробітником підприємства, що майже не володіє навичками програмування, але створює застосунки для автоматизації підприємства.

Не менш важливою характеристикою LCAP є її універсальність, тобто кількість різноманітних задач автоматизації, що можуть бути вирішені за її допомогою.

Простота опанування LCAP досягається мінімізацією кількості інструментів, які вона включає. Проте така мінімізація не має призводити до погіршення універсальності платформи.

Баланс між простотою опанування та універсальністю LCAP досягається завдяки дослідженню різних методів автоматизації розв'язання тих чи інших задач бізнесу та виокремленню таких інструментів, що дозволяють розв'язувати найбільшу кількість задач.

Одним з таких інструментів є таблиці. Дійсно, багато підприємств використовують таблиці Excel для ведення різноманітного обліку. Також реляційна база даних являє собою сукупність таблиць. Тому low-code платформа Airtable та багато її аналогів з відкритим вихідним кодом побудовані саме на базі таблиць.

Іншим прикладом вдалого вибору інструментів є low-code платформа WordPress. Спочатку вона позиціонувалася як платформа для створення блогів, але зараз використовується для створення сайтів будь-якої спрямованості, оскільки будь-який веб-сайт містить елементи блогу (створення, редагування та перегляд публікацій).

Незважаючи на простоту розробки застосунків за допомогою LCAP, їхня якість не повинна значно поступатися якості застосунків, розроблених за допомогою класичних інструментів. Тому LCAP має містити певні спрощені аналоги таких інструментів, як система контролю версій (VCS), інструменти для забезпечення безперервної інтеграції та розгортання застосунків (CI/CD), інструменти для автоматизованого тестування (automated testing) [3, 4].

Однією з найбільших проблем LCAP є прив'язка до постачальника (vendor lock-in), тобто залежність користувача платформи від її розробника. Така ситуація виникає, коли LCAP постачається на умовах послуги (Software as a Service) або з закритим вихідним кодом. Небезпека прив'язки до постачальника полягає в складності зміни платформи, а також у потенційній можливості витоку даних з хмари SaaS.

Платформу застосунків low-code доцільно розробляти за допомогою веб-технологій. Такі технології мають багату екосистему бібліотек та фреймворків, а також здатні працювати на великій кількості пристроїв.

Певну популярність в сфері low-code рішень має мова програмування JavaScript. Платформи Bubble.io, Airtable використовують її для клієнтської та серверної частин, інші платформи використовують цю мову лише для клієнтської частини.

Якщо клієнтська та серверна частини застосунку написані на JavaScript, то один й той самий код може виконуватися як на стороні серверу, так й на стороні клієнту. Зокрема, така можливість інтегрована у фреймворк Next.js.

Головним компонентом LCAP є конструктор застосунків (app builder). За допомогою нього громадянський розробник створює чи редагує застосунок. Конструктор застосунків генерує чергову версію застосунку, що за допомогою компоненту розгортання стає доступною для користувачів.

Генерація чергової версії застосунку відбувається з проміжних файлів конфігурації, які описують не лише суть застосунку, але й його відмінність від попередньої версії, що може стати в пригоді, наприклад, при виконанні міграції бази даних. Іншими словами, файли конфігурації відображають сукупність дій, виконаних громадянським розробником в конструкторі.

Така архітектура відкриває можливості для подальшого застосування інтелектуальних технологій, зокрема технологій штучного інтелекту. Наприклад, файли конфігурації можна генерувати не за допомогою дій у конструкторі, а за допомогою промпту до великої мовної моделі (LLM).

## ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ

1. Best Enterprise Low-Code Application Platforms Reviews 2024 | Gartner Peer Insights. URL: <https://www.gartner.com/reviews/market/enterprise-low-code-application-platform> (дата звернення: 25.11.2024).

2. Хто такий Citizen Developer та чому це майбутнє розробки. URL: <https://gigacloud.ua/blog/navchannja/hto-takij-citizen-developer-ta-chomu-ce-majbutne-rozrobki> (дата звернення: 25.11.2024).

3. Luo Y., Liang P., Wang Ch., Shahin M., Zhan J. Characteristics and Challenges of Low-Code Development: The Practitioners' Perspective. *ESEM '21: Proceedings of the 15th ACM / IEEE International Symposium on Empirical Software Engineering and Measurement (ESEM)*. 2021. Article 12, P. 1-11. URL: <https://doi.org/10.1145/3475716.3475782> (date of access: 25.11.2024).

4. Rethinking Low-code [rus]. URL: <https://fwdays.com/en/event/architecture-fwdays-2021/review/rethinking-low-code> (дата звернення: 25.11.2024).

*Клименко М.С.  
Інститут проблем штучного інтелекту  
МОН України і НАН України,  
Київ, Україна*

## **РОЗРОБКА ВЕБ-СЕРВІСУ ДЛЯ ПОБУДОВИ СЕМАНТИЧНИХ ПОЛІВ ФІЗИЧНИХ ТЕРМІНІВ**

Метою даної роботи є практична реалізація розроблених алгоритмічних засобів для аналізу текстів із застосуванням метричного підходу [1]. Програмну реалізацію методу обчислення семантичної відстані апробовано на англійських термінах словника Encyclopædia Britannica Merriam-Webster [2], що дозволило чисельно підтвердити гіпотези авторів методу щодо появи гіперциклів та гіперланцюгів у створюваних структурах. Однак значний лексичний обсяг даного джерела ускладнює як візуалізацію, так і статистичну оцінку підходу. Оскільки перевагою наукових тлумачень окрім лаконічності є точність формулювань, в даній роботі у якості джерела тлумачень обрано україномовний словник фізичних термінів-синонімів [3].

Семантичні поля є важливим інструментом прикладної лінгвістики, а їх автоматизована побудова у вигляді деревоподібних структур сприяє не тільки дослідницькій діяльності, а й спрямована на поліпшення низки практичних завдань, інтелектуальних систем, зокрема веб-сервісів: класифікація текстів, машинний переклад, рекомендаційних систем, оптимізація змісту для пошукової видачі тощо.

Семантичне поле створюється шляхом виділення сем із тлумачення терміну та подальшої рекурсивної обробки визначень отриманих сем. Вхідними параметрами, що впливають на швидкість побудови та глибину дерева, є множина допустимих частин мови сем та максимальна глибина. Якщо під час побудови наступного шару деякі семи повторюються, вони утворюють гіперцикли і гіперланцюги, стають термінальними вузлами дерева та скорочують глибину структури.

Розроблений веб-сервіс має засоби задання вхідних даних та графічного відображення побудованого семантичного поля для обраного терміну. Для інтеграції у інші програмні розробки передбачено точку доступу через HTTP REST API. Даний програмний інтерфейс обмінюється даними у JSON форматі. Хоча виконання тривалих завдань на обмеженому словнику наразі відсутнє, для таких

запитів створено можливості запиту стану завдання та веб-хуки подій завершення опрацювання шарів семантичної структури. Також реалізовано кешування запитів відповідно до заданих параметрів, що позитивно вплине на швидкодію ресурсу.

Розвитком даного сервісу пропонується реалізація семантичного порівняння текстів та впровадження даного методу у прикладних засобах штучного інтелекту.

### **ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ**

1. Vakulenko, M. From Semantic Metrics to Semantic Fields // Proceedings of the 2021 IEEE 16th International Conference on Computer Science and Information Technologies (CSIT), 22–25 September 2021, Lviv, Ukraine. P. 44–47. DOI: 10.1109/CSIT52700.2021.9648675

2. Klymenko M. Relation measurement between semantic fields by metric approach // Штучний інтелект. 2024. №29 (3). С. 94-98. DOI: 10.15407/jai2024.03.094

3. Вакуленко М. О., О. В. Вакуленко О. В. Словник фізичних термінів-синонімів: близько 5000 синонімічних рядів. Київ: ВПЦ "Київський університет", 2017. 191 с.

# ЗМІСТ

## ІНТЕЛЕКТУАЛЬНІ ІНФОРМАЦІЙНІ ТЕХНОЛОГІЇ

**Bohdan Somriakov** LOGISTICS AND SUPPLY CHAIN OPTIMIZATION SOFTWARE FOR UKRAINE'S NATIONAL INFRASTRUCTURE.....4

**Мельничук М. С., Калініна І. О.** ІНТЕЛЕКТУАЛЬНА СИСТЕМА МОДЕЛЮВАННЯ ТА ПРОГНОЗУВАННЯ НА ОСНОВІ МЕТОДІВ КОМБІНУВАННЯ.....7

**Валюшок Б. І.** ІНТЕЛЕКТУАЛЬНА СИСТЕМА ДЛЯ РОЗПІЗНАВАННЯ ЖЕСТОВОЇ МОВИ З ВИКОРИСТАННЯМ НЕЙРОННОЇ МЕРЕЖІ.....11

**Блідар М. В., Лисенков Е. А.** СИСТЕМА ДЛЯ ПРОГНОЗУВАННЯ ПРИРОДНИХ ПРОЦЕСІВ НА ОСНОВІ МОДЕЛІ ІДЕНА.....14

**Потужня Я. О., Калініна І. О.** ІНФОРМАЦІЙНА СИСТЕМА ПРОГНОЗУВАННЯ ЦІН НА РИНКУ НЕРУХОМОСТІ.....17

**Данкович С. Ю., Сіденко Є. В.** СИСТЕМА ІДЕНТИФІКАЦІЇ ТА РОЗПІЗНАВАННЯ ДРОНІВ МЕТОДАМИ ШТУЧНОГО ІНТЕЛЕКТУ.....20

**Асаулов О. А.** СИСТЕМА ФОРМУВАННЯ ІГРОВИХ СПРАЙТІВ ЗА ДОПОМОГОЮ ГЕНЕРАТИВНО-ЗМАГАЛЬНИХ НЕЙРОНИХ МЕРЕЖ.....24

**Скопенко І. В., Болюбаши Н. М.** ВІРТУАЛЬНИЙ ПОМІЧНИК КОРИСТУВАЧА ПК НА ОСНОВІ НЕЙРОМЕРЕЖЕВИХ LLM-МОДЕЛЕЙ.....27

**Нікітенко М. С., Шпинковська М. І.** ВИКОРИСТАННЯ ОБЧИСЛЮВАЛЬНИХ МЕТОДІВ ДЛЯ ВИЗНАЧЕННЯ ВПЛИВУ ЗАБРУДНЮЮЧИХ РЕЧОВИН НА ДОВКІЛЛЯ.....30

**Савчук А. О.** ІНТЕЛЕКТУАЛЬНА CRM СИСТЕМА НА ОСНОВІ МЕТОДІВ ЛОГІСТИКИ ТА ABC і XYZ АНАЛІЗУ.....32

**Слободенюк А. І., Сіденко Є. В.** ІНТЕЛЕКТУАЛЬНА СИСТЕМА ДІАГНОСТУВАННЯ НЕЙРОСУДИННИХ ХВОРОБ З ВИКОРИСТАННЯМ НЕЙРОННИХ МЕРЕЖ.....35

|                                                                                                                                                     |    |
|-----------------------------------------------------------------------------------------------------------------------------------------------------|----|
| <b>Колесніченко К. О., Кулаковська І. В.</b> ІНФОРМАЦІЙНА СИСТЕМА<br>ДЛЯ АВТОМАТИЗОВАНОГО ВИЯВЛЕННЯ НЕГАТИВНИХ<br>ТРЕНДІВ У СОЦІАЛЬНИХ МЕРЕЖАХ..... | 38 |
| <b>Атаманюк В. Г., Кулаковська І. В.</b> ІНФОРМАЦІЙНА СИСТЕМА<br>ПОШУКУ НЕСАНКЦІОНОВАНОГО МАЙНІНГУ.....                                             | 41 |
| <b>Шевченко Д. В., Козлов О. В.</b> ПРОГНОЗУВАННЯ ПРОДА-<br>ЖІВ АВТОМОБІЛІВ НА ОСНОВІ НЕЙРОМЕРЕЖЕ-<br>ВИХ МОДЕЛЕЙ .....                             | 43 |
| <b>Шиян С. І.</b> ПЕРСПЕКТИВИ ЗАСТОСУВАННЯ КОЛЬОРОВИХ<br>МЕРЕЖ ПЕТРІ ДО МОДЕЛЮВАННЯ СИСТЕМ ВИМІРЮВАННЯ ТА<br>ЗБЕРІГАННЯ ПАЛИВА НА СУДНІ.....        | 46 |

## МАШИННЕ НАВЧАННЯ ТА ШТУЧНИЙ ІНТЕЛЕКТ

|                                                                                                                                                                                    |    |
|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| <b>Пещерьова В. С., Калініна І. О.</b> ІНТЕЛЕКТУАЛЬНЕ<br>ПРОГНОЗУВАННЯ НА ОСНОВІ БАГАТОШАРОВИХ<br>АНСАМБЛЕВИХ СТРУКТУР.....                                                        | 49 |
| <b>Димо В. В.</b> СЕМАНТИЧНА СЕГМЕНТАЦІЯ ПОШКОДЖЕНИХ<br>БУДІВЕЛЬ З ВИКОРИСТАННЯМ ЗГОРТКОВИХ НЕЙРОННИХ<br>МЕРЕЖ.....                                                                | 52 |
| <b>Yu Fei, Eugene Malakhov</b> IMPLEMENTATION OF SELF-ATTENTION<br>MECHANISM INTO INFORMATION TECHNOLOGY OF HIGH-<br>RESOLUTION REMOTE SENSING IMAGE SEMANTIC<br>SEGMENTATION..... | 55 |
| <b>Колодяжний К. О., Калініна І. О.</b> СИСТЕМА ВИЯВЛЕННЯ<br>КОМП'ЮТЕРНИХ МЕРЕЖЕВИХ АТАК ЗА ДОПОМОГОЮ<br>МЕТОДІВ МАШИННОГО НАВЧАННЯ.....                                           | 58 |
| <b>Рева В. В.</b> ІНТЕГРОВАНА СИСТЕМА ДЛЯ НАВЧАННЯ АГЕНТІВ<br>UNITY ML AGENTS З ВИКОРИСТАННЯМ МОДЕЛЕЙ ГЛИБОКИХ<br>НЕЙРОННИХ МЕРЕЖ.....                                             | 61 |
| <b>Кириленко В. С.</b> ІНТЕЛЕКТУАЛЬНА СИСТЕМА ПРОГНОЗУВАННЯ<br>КУРСУ КРИПТОВАЛЮТ НА ОСНОВІ РЕКУРЕНТНИХ НЕЙРОННИХ<br>МЕРЕЖ.....                                                     | 64 |
| <b>Нечахін В. В..</b> МОДЕЛЮВАННЯ LSTM-КОНТРОЛЕРА ДЛЯ<br>СОНЯЧНОЇ ЕЛЕКТРОСТАНЦІЇ З ВИКОРИСТАННЯМ<br>КОЛЬОРОВИХ МЕРЕЖ ПЕТРІ .....                                                   | 66 |

|                                                                                                                                                |    |
|------------------------------------------------------------------------------------------------------------------------------------------------|----|
| <i>Feng Xuejiao, Oleksandr Antonenko</i> OBJECT DETECTION ALGORITHMS IN FOGGY CONDITIONS .....                                                 | 69 |
| <i>Сова І. М., Козлов О. В.</i> АВТОМАТИЧНА КЛАСИФІКАЦІЯ МОДУЛЯЦІЙ РАДІОСИГНАЛІВ НА ОСНОВІ ЗГОРТКОВИХ НЕЙРОННИХ МЕРЕЖ.....                     | 72 |
| <i>Гожий В. О.</i> ІНТЕГРАЦІЯ ТЕХНОЛОГІЙ ШТУЧНОГО ІНТЕЛЕКТУ В ПРОЕКТИ ІТ КОМПАНІЙ.....                                                         | 75 |
| <i>Карпенко А. Ю.</i> ІНТЕЛЕКТУАЛЬНА СИСТЕМА ІДЕНТИФІКАЦІЇ І КЛАСИФІКАЦІЇ DOS-АТАК .....                                                       | 77 |
| <i>Архіпов Д. В., Сіденко Є. О.</i> СИСТЕМА ВИЯВЛЕННЯ ВІЙСЬКОВИХ ОБ'ЄКТІВ НА ДИНАМІЧНИХ ЗОБРАЖЕННЯХ НА ОСНОВІ АРХІТЕКТУР НЕЙРОННИХ МЕРЕЖ.....  | 79 |
| <i>Герас О. М., Сіденко Є. В.</i> ІНТЕЛЕКТУАЛЬНА СИСТЕМА ІДЕНТИФІКАЦІЇ ТА КЛАСИФІКАЦІЇ ВІЙСЬКОВОЇ ТЕХНІКИ З ВИКОРИСТАННЯМ НЕЙРОННИХ МЕРЕЖ..... | 83 |
| <i>Руда Є. В., Бурлаченко І. С.</i> ІНТЕЛЕКТУАЛЬНА СИСТЕМА ДІАГНОСТУВАННЯ ХВОРОБ РОСЛИН З ВИКОРИСТАННЯМ МЕТОДІВ ШТУЧНОГО ІНТЕЛЕКТУ.....        | 85 |
| <i>Супрун А. О.</i> ШТУЧНИЙ ІНТЕЛЕКТ: ІНТЕГРАЦІЯ В ОСВІТІ ТА НАУЦІ.....                                                                        | 88 |

## **ІНТЕЛЕКТУАЛЬНІ КОМП'ЮТЕРНО-ІНТЕГРОВАНІ ТЕХНОЛОГІЇ**

|                                                                                                       |    |
|-------------------------------------------------------------------------------------------------------|----|
| <i>Ярошенко Д. Є., Рачинська А. Л.</i> ІНФОРМАЦІЙНА СИСТЕМА АВТОМАТИЗАЦІЇ РОБОТИ КАФЕДРИ.....         | 90 |
| <i>Сичов С. Ю.</i> МОЖЛИВІСТЬ ВИКОРИСТАННЯ СОЦІАЛЬНИХ МЕРЕЖ У СИСТЕМАХ АВТОМАТИЗАЦІЇ ВИРОБНИЦТВА..... | 92 |
| <i>Кумпан І. Д.</i> АВТОМАТИЗОВАНА СИСТЕМА КЕРУВАННЯ ПРОМИСЛОВИМ РОБОТОМ-МАНІПУЛЯТОРОМ У ПОРТУ.....   | 95 |
| <i>Жосан О. А.</i> ІНТЕЛЕКТУАЛЬНІ КОМПОНЕНТИ В АВТОМАТИЗОВАНІЙ СИСТЕМІ ПАРКУВАННЯ АВТОМОБІЛЕМ.....    | 98 |

## **ІНТЕЛЕКТУАЛЬНІ ВЕБ-ТЕХНОЛОГІЇ І ВЕБ-СЕРВІСИ**

|                                                                                                                                                                                                     |     |
|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----|
| <b>Ченура Т. Р., Бурлаченко І. С.</b> ВИКОРИСТАННЯ ШТУЧНОГО ІНТЕЛЕКТУ ДЛЯ АВТОМАТИЗОВАНОГО ЗБОРУ OSINT З СОЦІАЛЬНИХ МЕДІА.....                                                                      | 101 |
| <b>Попов Я. В., Худолій А. П., Бурлаченко І. С.</b> MACHINE LEARNING БІБЛІОТЕКИ СЕРВЕРНИХ ФРЕЙМВОРКІВ У ЗАСТОСУНКАХ ДЛЯ ПСИХОТЕРАПЕВТИЧНИХ КОНСУЛЬТАЦІЙ ТА АНАЛІЗУ ЯКОСТІ ТУРИСТИЧНИХ ПОДРОЖЕЙ..... | 103 |
| <b>Ляхов К. В.</b> СИСТЕМА ВЗАЄМОДІЇ З МОДЕЛЛЮ ПРОГНОЗУВАННЯ ЛІСОВИХ ПОЖЕЖ.....                                                                                                                     | 110 |
| <b>Бойко В. О.</b> ІНТЕЛЕКТУАЛЬНІ АСПЕКТИ РОЗГОРТАННЯ ВЕБ-ЗАСТОСУНКІВ NEXT.JS ТА REACT.JS ЧЕРЕЗ ПЛАТФОРМУ VERCEL.....                                                                               | 112 |
| <b>Пасенченко Т. О.</b> ІНТЕЛЕКТУАЛЬНА LOW-CODE ПЛАТФОРМА ДЛЯ РОЗРОБКИ КОРПОРАТИВНИХ ЗАСТОСУНКІВ.....                                                                                               | 114 |
| <b>Клименко М. С.</b> РОЗРОБКА ВЕБ-СЕРВІСУ ДЛЯ ПОБУДОВИ СЕМАНТИЧНИХ ПОЛІВ ФІЗИЧНИХ ТЕРМІНІВ.....                                                                                                    | 117 |

***ДЛЯ НОТАТОК***

---

Редактор *В. Димо*  
Комп'ютерна верстка *К. Гросу-Грабарчук*  
Друк *С. Волинець*. Фальцювальні-палітурні роботи *О. Мішалкіна*.

Підп. до друку 02.12.2024.  
Формат 60х84  $\frac{1}{16}$ . Папір офсет.  
Гарнітура «Times New Roman». Друк ризограф.  
Ум. друк. арк. 7,2. Обл.-вид. арк. 5,2.  
Тираж 10 пр. Зам. № 6929.

Видавець і виготовлювач: ЧНУ ім. Петра Могили.  
54003, м. Миколаїв, вул. 68 Десантників, 10.  
Тел.: 8 (0512) 50–03–32, 8 (0512) 76–55–81,  
e-mail: rector@chmnu.edu.ua.  
Свідоцтво суб'єкта видавничої справи ДК № 6124 від 05.04.2020.