

Р. А. Бралатан; С. О. Жуков, канд. техн. наук, доц.

ГІБРИДНА БАЙЄСІВСЬКА-НЕЙРОМЕРЕЖЕВА АРХІТЕКТУРА ДЛЯ ПЕРЕДБАЧЕННЯ РИЗИКУ ДІАБЕТУ

У цьому дослідженні розглядається актуальна проблема створення інтерпретованих моделей із високою точністю передбачення ризиків у сфері охорони здоров'я. Основну увагу приділено задачі ранньої діагностики цукрового діабету. Для вирішення цієї задачі критично важливим є надійність та прозорість моделі, так як на основі її роботи будуть прийматися клінічні рішення. Наявні підходи часто пов'язані із складними "чорними скриньками", які демонструють високу точність або з простими лінійними моделями, результати яких легко пояснити, але їхні передбачення поступаються в якості.

Для подолання цього компромісу в цій роботі запропоновано та реалізовано інноваційну гібридну архітектуру, що складається з двох послідовних етапів. Перший етап використовує байєсівську логістичну регресію з розріджувальними апіорними розподілами типу "Regularized Horseshoe". За допомогою цього було отримано надійну та добре відкалібровану базову оцінку ймовірності та виконано автоматичний відбір найбільш значимих факторів ризику, таким чином підвищуючи інтерпретованість моделі. Під час другого етапу вихідні дані базової моделі інтегруються як нова, потужна ознака до багатошарового перцептрона (MLP), який виконує роль нелінійного коректора, уточнюючи передбачення шляхом моделювання складних залежностей, пропущених лінійною моделлю.

Результати дослідження та їх ефективність було протестовано на відкритому наборі даних 'Behavioral Risk Factor Surveillance System (BRFSS)'. Експерименти продемонстрували, що гібридна модель стабільно перевершує базову за ключовими метриками класифікації, зокрема AUROC (Area Under the ROC Curve) та AUPRC (Area Under the Precision-Recall Curve). Було продемонстровано, що, попри додавання нейромережевого компонента, модель зберігає високу якість калібрування, що підтверджує достовірність її передбачуваних ймовірностей. Таким чином, дослідження доводить практичну цінність гібридизації для створення збалансованих та надійних діагностичних систем.

Продемонстрована ефективність гібридної архітектури відкриває перспективи її застосування для широкого кола задач медичного передбачення. Це підкреслює універсальність підходу та його потенціал для подальшого розвитку.

Ключові слова: інформаційна технологія, машинне навчання, байєсівські методи, нейронні мережі, передбачення ризиків, діабет, гібридні моделі.

Вступ та постановка задачі

Застосування методів машинного навчання покращить сучасну медицину, особливо в задачах передбачення ризиків для здоров'я. Алгоритми здатні аналізувати великі обсяги багатофакторних медичних даних, що відкриває безпрецедентні можливості для раннього виявлення проблем зі здоров'ям, персоналізації лікування та оцінки індивідуальних ризиків для пацієнтів. Створення надійних та точних прогностичних моделей є першочерговим завданням для підвищення ефективності системи охорони здоров'я [1, 5].

Однією з найактуальніших медико-соціальних проблем, де таке передбачення є критично важливим, є цукровий діабет. Мільйони людей щороку вражає це хронічне захворювання, створюючи високе навантаження на системи охорони здоров'я по всьому світу. Тому рання і точна ідентифікація осіб, що належать до групи високого ризику, дозволяє вчасно застосовувати профілактичні заходи, що суттєво знижує ймовірність розвитку хвороби та її ускладнень [4].

Для вирішення поставлених задач у цьому дослідженні запропоновано гібридний підхід, який поєднує сильні сторони обох парадигм. В основі лежить ідея, яка запозичена з успішних практик ансамблювання моделей, де статичні та нейромережеві методи об'єднуються для досягнення найкращих результатів [2, 6]. В основі запропонованого підходу лежить байєсівська логістична регресія з розріджувальним апіорним розподілом

(Regularized Horseshoe), яка забезпечує надійну, добре відкалібровану та інтерпретовану базову оцінку ризиків, автоматично визначаючи найвпливовіші показники. Для того щоб підвищити точність передбачення, байєсівську логістичну регресію було доповнено нейромережним коректором MLP, який навчається на вихідних даних базової моделі, уточнюючи її результати шляхом моделювання залишкових нелінійних ефектів.

Метою дослідження є підвищення точності передбачення ризику розвитку діабету за допомогою розробки, реалізації та оцінки гібридної моделі, що інтегрує байєсівську логістичну регресію та нейромережний коректор.

Методологія та архітектура моделі

Методологія дослідження базується на побудові та валідації гібридної двоступеневої моделі, яка послідовно інтегрує ймовірнісний байєсівський підхід для отримання інтерпретованого базового передбачення та гнучкість нейронних мереж для нелінійної корекції цього передбачення. Загальну архітектуру запропонованого підходу зображено на рис. 1. Нижче детально описано кожен компонент.

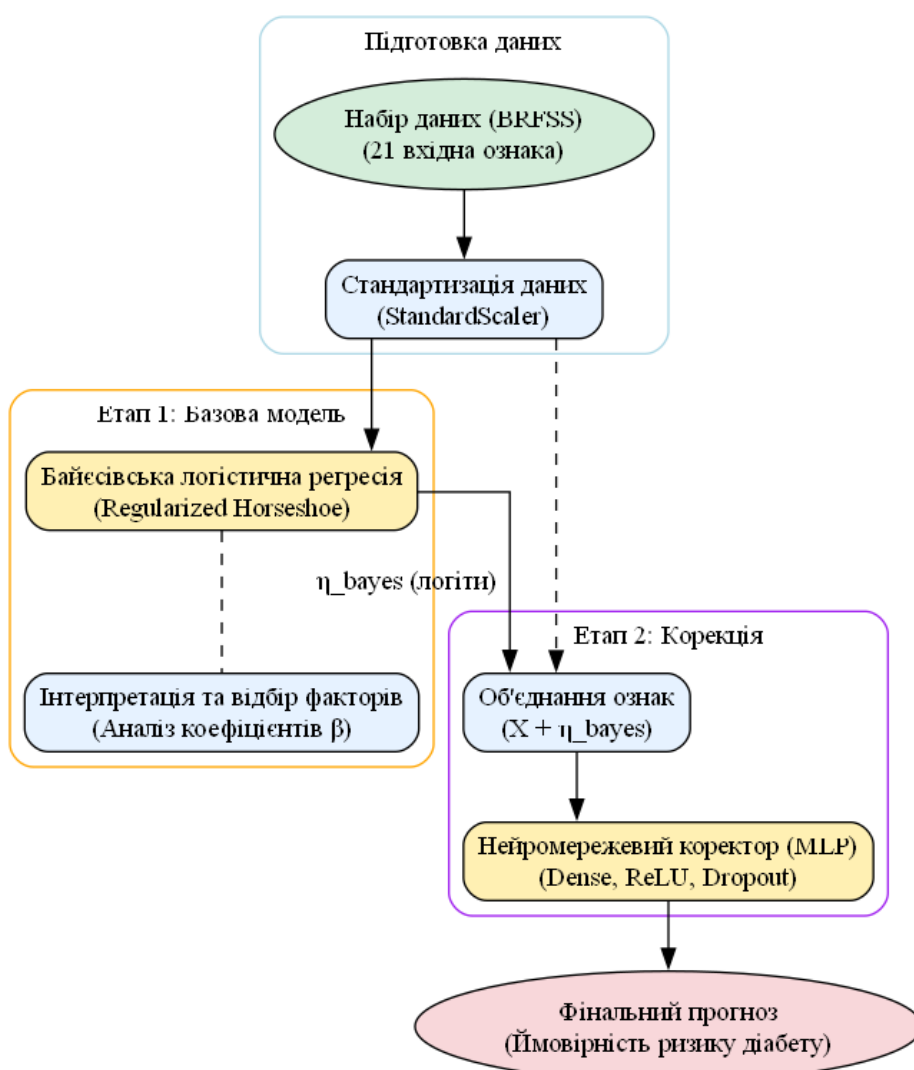


Рис. 1. Блок-схема архітектури гібридної моделі

Для проведення експериментів було використано публічний збалансований набір даних Behavioral Factor Surveillance System (BRFSS) [7]. Цей набір є результатом масштабного телефонного опитування, що проводиться щорічно в США. Він містить широкий спектр інформації про стан здоров'я та фактори ризику серед дорослого населення. Вибірка для цього дослідження містить 70692 записів, збалансованих за цільовою ознакою, та включає 21

медико-соціальний предиктор. Цільовою змінною є бінарний показник *Diabetes_binary*, що вказує на наявність або відсутність діабету у респондента.

Попередня обробка даних включала кілька ключових кроків. По-перше, було проведено аналіз на наявність пропущених значень, який показав відсутність таких у цьому наборі. По-друге, усі числові ознаки було стандартизовано за допомогою *StandartScaler* зі *scikit-learn*. Ця процедура полягає у відніманні середнього значення та діленні на стандартне відхилення для кожної ознаки, що приводить їх до одного масштабу з нульовим середнім та одиничною дисперсією. Стандартизація є критично важливою для коректної роботи як байєсівської моделі, особливо за використання регуляризуючих пріорів, так і для стабільного та швидкого навчання нейронної мережі.

На першому етапі архітектури застосовується узагальнена лінійна модель GLM в байєсівській інтерпретації. Цей вибір обґрунтований двома причинами: по-перше, байєсівський підхід дозволяє отримати не просто точкову оцінку, а повний апостеріорний розподіл ймовірностей, що забезпечує кращу калібрацію та кількісну оцінку невизначеності. По-друге, використання спеціальних розріджувальних пріорів дає змогу автоматично виконувати відбір значущих ознак, що підвищує інтерпретованість моделі.

Ймовірність p -ого класу (наявність діабету) для i -го спостереження моделюється за допомогою логістичної функції (сигмоїди) від лінійного предиктора η_i :

$$p_i = \sigma(\eta_i) = 1 / (1 + \exp(-\eta_i)) \quad (1)$$

Де лінійний предиктор η_i є лінійною комбінацією вхідних ознак X_i :

$$\eta_i = \alpha + X_i\beta \quad (2)$$

Тут α – вільний член (intercept), а β – вектор вагових коефіцієнтів для ознак. В рамках байєсівського підходу параметри моделі $\theta = \{\alpha, \beta\}$ розглядаються як випадкові величини, для яких визначаються апіорні розподіли $P(0)$. Згідно з правдоподібності та апіорного розподілу [8]:

$$P(\theta|D) \propto P(D|\theta)P(\theta) \quad (3)$$

Функція правдоподібності для задачі бінарної класифікації описується розподілом Бернуллі, оскільки цільова змінна є бінарною:

$$y_i \sim \text{Bernoulli}(p_i) \quad (4)$$

Ключовою особливістю моделі є вибір апіорних розподілів. Для вільного члена α було обрано слабо інформативний пріор *Normal* (0, 10), що відображає мінімальні попередні уявлення про базовий рівень ризику. Для коефіцієнтів β було застосовано розріджувальний пріор *Regularized Horseshoe* [9]. Цей ієрархічний пріор дозволяє моделі ефективно відокремлювати значущі предиктори від неінформативних, стискаючи коефіцієнти останніх до нуля, але залишаючи можливість для сильних сигналів залишатися незмінними. Його можна представити наступним чином:

$$\beta_j \sim \text{Normal}(0, \tau^2 * \lambda_j^2) \quad (5)$$

$$\lambda_j \sim \text{HalfCauchy}(1) \quad (6)$$

Де τ є глобальним параметром стиснення, що впливає на всі коефіцієнти, а λ_j – локальними параметрами, що дозволяють окремим коефіцієнтам β_j уникнути стиснення. Це

забезпечує одночасно і регулювання для запобігання перенавчанню, і ефективний відбір ознак.

На другому етапі архітектури використовується багатошаровий персептрон MLP як нелінійний коректор. Його завдання – виявити та змодельовати складні, нелінійні залежності в даних, які не були враховані лінійною базовою моделлю. Вхідними даними для нього слугує розширений набір ознак X_{hybrid} , який формується шляхом об'єднання початкових стандартизованих ознак X та згенерованого на першому етапі лінійного предиктора η_{bayes} [3]:

$$X_{hybrid} = [X, \eta_{bayes}] \quad (7)$$

Де η_{bayes} є апостеріорним середнім значенням лінійного предиктора, отриманим з байєсівської моделі. Включення η_{bayes} як нової ознаки є центральним елементом гібридного підходу. Ця ознака є потужним узагальненням інформації, отриманої від лінійної моделі, вона слугує для MLP своєрідним “керівництвом”, вказуючи на базовий рівень ризику, який мережа має уточнити.

Архітектура MLP була підібрана емпірично і складається з кількох повнозв'язних шарів (Dense) з функцією активації ReLu, яка добре себе зарекомендувала у глибокому навчанні. Для стабілізації процесу навчання та прискорення збіжності після кожного повнозв'язного шару додано шар пакетної нормалізації (BatchNormalization) [10]. Цей метод нормалізує виходи попереднього шару, зменшуючи так званий “внутрішній коваріантний зсув”. Для боротьби з перенавчанням, що є поширеною проблемою для нейронних мереж, було використано шари проріджування (Dropout) [11], які під час навчання випадковим чином “вимикають” частину нейронів, змушуючи мережу навчатися більш стійких та узагальнених репрезентацій. Підходи до оптимізації архітектури глибоких мереж, зокрема з використанням квантування, є актуальним напрямком досліджень [16]. Вихідний шар мережі використовує сигмоїдну функцію активації для отримання фінальної ймовірності в діапазоні [0, 1]. Таким чином, MLP навчається моделювати залишкові, нелінійні ефекти, які не були враховані базовою моделлю, використовуючи її узагальнений висновок як потужну нову ознаку.

Експериментальні результати та їх аналіз

Для об'єктивної оцінки розроблених моделей вихідний набір даних було розділено на навчальну, валідаційну та тестову вибірки у співвідношенні 60 %, 20 % та 20 % відповідно. Усі числові ознаки було попередньо стандартизовано за допомогою StandartScaler для забезпечення коректної роботи та збіжності обох моделей. Навчання байєсівської моделі проводилося за допомогою методу варіаційного виведення Automatic Differentiation Variational Inference (ADVI) [12] у програмному середовищі PuMC [14], а нейромережевої з використанням оптимізатора Adam [13]. За результатами дослідження було створено Kaggle ноутбук [15].

Першим етапом аналізу є інтерпретація результатів базової байєсівської моделі. Завдяки використанню розріджувальних пріорів Regularized Horseshoe вдалося провести відбір найбільш значущих факторів ризику. На рис. 2 візуалізовано апостеріорні розподіли коефіцієнтів β для ключових предикторів. Кожен коефіцієнт відображає силу та напрямок впливу відповідного фактору на логарифм шансів розвитку діабету. Сині відрізки представляють 94 % довірчі інтервали, які показують діапазон найбільш імовірних значень для кожного коефіцієнта.

Аналіз графіка (рис. 2) дозволяє зробити два ключових висновки. Модель автоматично ідентифікувала статистично значущі фактори ризику: довірчі інтервали для показників загального стану здоров'я (GenHlth), індексу маси тіла (BMI) та високого кров'яного тиску (HighBP) повністю знаходяться праворуч від нульової лінії. Це свідчить про їхній сильний

позитивний вплив на ймовірність захворювання. Коефіцієнти для менш значущих ознак були ефективно стиснуті до нуля, що підтверджує ефективність обраного пріору для автоматичного відбору ознак та підвищення інтерпретованості моделі.



Рис. 2. Візуалізація апостеріорних розподілів коефіцієнтів β для найбільш значущих факторів

Для порівняння дискримінаційної здатності та загальної точності моделей було використано набір стандартних метрик, розрахованих на тестовій вибірці, яка не використовувалася під час навчання. До цих метрик увійшли: AUROC (площа під ROC-кривою), AUPRC (площа під кривою точності-повноти) та Brier Score.

	AUROC	AUPRC	Brier Score
Bayes Model	0.825731	0.792250	0.169238
Hybrid Model	0.831961	0.802364	0.165677

Рис. 3. Результати порівняльного аналізу

Як видно з рис. 3, гібридна модель демонструє статистично значуще покращення за всіма метриками. Зростання AUROC та AUPRC свідчить про те, що нейромережевий коректор зміг успішно виявити та використати додаткові нелінійні патерни в даних, що підвищило якість ранжування та класифікації. Одночасне зменшення вказує на вищу загальну точність та краще узгодження передбачуваних ймовірностей з реальними результатами.

Надійність передбачуваних ймовірностей є критично важливою для медичних застосувань, тому окрему увагу було приділено аналізу калібрування моделей. Аналіз калібрувальних кривих (рис. 4) показав, що обидві моделі є добре відкаліброваними, оскільки їхні криві лежать близько до діагоналі ідеального калібрування. Варто відзначити, що базова байєсівська модель демонструє майже ідеальне калібрування, що є очікуваною перевагою ймовірнісного підходу. Гібридна модель, хоч і трохи поступається в цьому аспекті, все ж зберігає високу якість калібрування, що робить її передбачення достовірними та придатними для практичного використання.




Рис. 4. Калібрувальні криві для базової та гібридної моделей

Висновки

У ході цього дослідження було успішно розв'язано актуальну науково практичну задачу, що полягає у подоланні фундаментального компромісу між точністю та інтерпретованістю предиктивних моделей у сфері охорони здоров'я. Поставлена мета щодо підвищення точності передбачення ризику розвитку діабету була досягнута шляхом розробки, реалізації та всебічної оцінки інноваційної гібридної двоступеневої архітектури, яка синергетично поєднує сильні сторони ймовірнісних байєсівських методів та гнучкість глибокого навчання. Запропонований підхід ефективно вирішує проблему “чорної скриньки”, не жертвуючи при цьому якістю передбачення. На першому етапі, інтерпретована байєсівська логістична регресія і розріджувальним апіорним розподілом “Regularized Horseshoe” не лише формує надійне та добре відкаліброване базове передбачення, але й виконує функцію автоматичного відбору найбільш значущих факторів ризику. Зокрема, модель кількісно підтвердила, що ключовими предикторами діабету є загальний стан здоров'я (“GenHlth”), індекс маси тіла (“BMI”) та наявність високого кров'яного тиску (“HighBP”), що повністю узгоджується з клінічними даними. На другому етапі, багатошаровий перцептрон, виступаючи в ролі нелінійного коректора, використовує узагальнений висновок байєсівської моделі як нову, інформативну ознаку, що дозволяє йому фокусуватися на моделюванні складних, нелінійних взаємозв'язків, які були пропущені лінійною моделлю. Таким чином, ключовою перевагою розробленого підходу є підвищення інтерпретованості кінцевого прогнозу, оскільки навіть нелінійної корекції зберігається можливість аналізувати внесок кожного окремого фактору ризику, визначений на першому, байєсівському етапі.

Експериментальне тестування на великому, збалансованому наборі даних BRFS показало переконливо продемонструвало перевагу гібридного підходу. Модель продемонструвала статистично значуще покращення за всіма ключовими метриками класифікації. Показник AUROC зріс з 0.8256 до 0.8319 (покращення на 0.63 %) та AUPRC зріс з 0.7922 до 0.8035 (покращення на 1.43 %), що свідчить про вищу дискримінаційну здатність. Важливо підкреслити, що цей приріст точності не був досягнутий ціною втрати надійності. Аналіз калібрувальних кривих підтвердив, що гібридна модель зберігає високу якість калібрування (Brier Score покращився з 0.1693 до 0.1659), а отже, її передбачувані ймовірності є достовірними та можуть бути використані для прийняття відповідальних клінічних рішень.

Практична значущість роботи полягає у тому, що розроблена архітектура може слугувати прототипом для нового покоління систем підтримки прийняття рішень, які надають лікарю не лише точне числове передбачення, але й прозоре обґрунтування ключових факторів ризику для конкретного пацієнта. Головним внеском роботи є створення архітектури яка поєднує високу точність з можливості оцінки невизначеності та поясненням результатів.

Незважаючи на отримані позитивні результати, ця робота має певні обмеження, які відкривають шляхи для подальших досліджень. Зокрема, валідація проводилася на даних однієї популяції, тому для підтвердження робастності та узагальнювальної здатності моделі доцільно провести її тестування на інших медичних датасетах. Перспективними напрямками для подальшого вдосконалення є також систематична оптимізація архітектури та гіперпараметрів нейромережевого коректора (наприклад, кількості шарів та нейронів, функцій активації, параметрів шарів “Dropout” та “BatchNormalization”), а також адаптація цієї архітектури для ширшого кола захворювань. Таким чином, це дослідження не лише пропонує конкретне рішення для задачі передбачення діабету, але й демонструє високий потенціал гібридизації ймовірнісних та нейромережевих моделей як загальної стратегії для створення збалансованих, точних та надійних інтелектуальних систем у сфері охорони здоров'я.

СПИСОК ЛІТЕРАТУРИ

1. Бралатан Р. А., Жуков С. О. Байєсівське моделювання для оцінювання ризиків виникнення раку легенів на основі аналізу медичних даних. *Матеріали LIV Всеукраїнської науково-технічної конференції підрозділів Вінницького національного технічного університету (НТКП ВНТУ–2025**, Вінниця, 2025. URL: <https://press.vntu.edu.ua/index.php/vntu/catalog/book/904>.
2. Метод бустингу гетероскедастичних моделей для прогнозування концентрацій пилу Сахари в атмосферному повітрі України / В. Є. Копняк та ін. *Наукові праці Вінницького національного технічного університету*. 2024. № 2. URL: <https://doi.org/10.31649/2307-5376-2024-2-28-38>.
3. Інформаційна технологія прогнозування курсу криптовалют на основі комплексної інженерії ознак / В. Б. Мокін та ін. *Вісник Вінницького політехнічного інституту*. 2022. №2. С. 81–93. URL: <https://doi.org/10.31649/1997-9266-2022-161-2-81-93>
4. Deo R. C. Machine Learning in Medicine. *Circulation*. 2015. Vol. 132, №20. P. 1920–1930. URL: <https://doi.org/10.1161/CIRCULATIONAHA.115.001593>.
5. Rudin C. Stop explaining black box machine learning models for high stakes decisions and use interpretable models instead. *Nature Machine Intelligence*. 2019. Vol. 1, №5. P. 206–215. URL: <https://doi.org/10.1038/s42256-019-0048-x>.
6. A Hybrid Bayesian-Based Deep-Learning-Enabled Model for the Prediction of Diabetes / M. A. Al-masni et al. *Sensors*. 2023. Vol. 23, №1. Article 489. URL: <https://doi.org/10.3390/s23010489>.
7. Centers for Disease Control and Prevention (CDC). Behavioral Risk Factor Surveillance System (BRFSS) Survey Data. 2015. URL: https://www.cdc.gov/brfss/annual_data/annual_2015.html (Last accessed: 02.09.2025).
8. Bayesian Data Analysis. 3rd ed. / Gelman A. Et al. Chapman and Hall/CRC, 2013. 675 p.
9. Piironen J., Vehtari A. Sparsity information and regularization in the horseshoe and other shrinkage priors. *Journal of Machine Learning Research*. 2017. Vol. 18, №164. P. 1–42. URL: <http://dx.doi.org/10.1214/17-EJS1337SI>.
10. Ioffe S., Szegedy C. Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift. In *Proceedings of the 32nd International Conference on Machine Learning (ICML)*. 2015. P. 448–456. URL: <https://arxiv.org/abs/1502.03167>.
11. Dropout: A Simple Way to Prevent Neural Networks from Overfitting / N. Srivastava et al. *Journal of Machine Learning Research*. 2014. Vol. 15. P. 1929–1958. URL: <http://jmlr.org/papers/v15/srivastava14a.html>.
12. Automatic Differentiation Variational Inference / A. Kucukelbir et al. *Journal of Machine Learning Research*. 2017. Vol. 18, №13. P. 1–45. URL: <http://jmlr.org/papers/v18/16-107.html>.
13. Kingma D. P., Ba J. Adam: A Method for Stochastic Optimization. In *Proceedings of the 3rd International Conference on Learning Representations (ICLR)*. 2015. URL: <https://arxiv.org/abs/1412.6980>.
14. Salvatier J., Wiecki T. V., Fonnesbeck C. Probabilistic programming in Python using PyMC. *PeerJ Computer Science*. 2016. Vol. 2. Article e55. URL: <https://doi.org/10.7717/peerj-cs.55>.
15. Bralatan R. HYBRID BAYESIAN-NEURAL NETWORK MODEL. *Kaggle*. URL: <https://www.kaggle.com/code/romantick/hybrid-bayesian-neural-network-model>.
16. Жуков С. О., Рудзевич О. В. Оптимізація глибоких нейронних мереж для класифікації емоційного стану мовлення з використанням динамічного квантування. *Наукові праці Вінницького національного технічного університету*. 2025. № 2. URL: <https://doi.org/10.31649/2307-5376-2025-2-51-65>.

Стаття надійшла до редакції 03.09.2025.

Стаття пройшла рецензування 25.09.2025.

Бралатан Роман Андрійович – студент групи 124-24а, факультет інтелектуальних інформаційних технологій та автоматизації, e-mail: bralatan.roman@gmail.com.

Жуков Сергій Олександрович – канд. техн. наук, доцент, доцент кафедри системного аналізу та інформаційних технологій, e-mail: sazhukov@gmail.com.

Вінницький національний технічний університет.