



О. В. Золотухін<sup>1</sup>, М. С. Кудрявцева<sup>2</sup>, Є. Ю. Єремєєв<sup>3</sup>

<sup>1</sup>ХНУРЕ, м. Харків, Україна, oleg.zolotukhin@nure.ua,  
ORCID iD: 0000-0002-0152-7600

<sup>2</sup>ХНУРЕ, м. Харків, Україна, maryna.kudryavtseva@nure.ua,  
ORCID iD: 0000-0003-0524-5528

<sup>3</sup>ХНУРЕ, м. Харків, Україна, yevhenii.yeremieiev@nure.ua,  
ORCID iD: 0009-0000-9752-1774

## СТОХАСТИЧНА ІНІЦІАЛІЗАЦІЯ НЕЙРОННИХ МЕРЕЖ НА ОСНОВІ АНАЛІЗУ БІОЛОГІЧНИХ СИСТЕМ

Штучні нейронні мережі, як правило, ініціалізуються за допомогою математично визначених методів, які не враховують структурного та функціонального різноманіття біологічних систем. Хоча традиційні підходи забезпечують стабільність навчання, вони ігнорують природні механізми формування синаптичних зв'язків. У цьому дослідженні запропоновано біологічно натхненний підхід до ініціалізації вагових коефіцієнтів, заснований на стохастичних закономірностях, виявлених в емпіричних траєкторіях руху, зафіксованих у контрольованому біологічному середовищі. Дані проходять попередню обробку, що включає згладжування, нормалізацію та масштабування, для генерації вагових значень, які надалі використовуються для ініціалізації нейронної мережі. Ефективність запропонованого методу оцінюється у порівнянні зі стандартними стратегіями ініціалізації на основі трьох тестових наборів даних: MNIST, Fashion-MNIST і Gas Sensor Array Drift. Експериментальні результати демонструють, що біологічно натхненний підхід забезпечує порівнянну ефективність за всіма оціночними критеріями, включаючи точність на тестовій і валідаційній вибірках, кількість епох до збіжності, чутливість за класами та макроусереднений показник F1-метрики. У ряді випадків метод сприяв швидшій збіжності без зниження якості класифікації. Попри те, що запропонована стратегія не завжди перевершує стандартні методи, вона вводить структуровану стохастичність у процес навчання, спираючись на біологічні принципи, та формує перспективне підґрунтя для подальших досліджень у сфері складніших архітектур і біологічно натхнених моделей навчання.

**ШТУЧНІ НЕЙРОННІ МЕРЕЖІ, ІНІЦІАЛІЗАЦІЯ ВАГОВИХ КОЕФІЦІЄНТІВ, СТОХАСТИЧНЕ ЗРОСТАННЯ, МАШИННЕ НАВЧАННЯ, БЕГГІНГ, СТЕКІНГ, АНСАМБЛЕВЕ НАВЧАННЯ, ШВИДКІСТЬ ЗБІЖНОСТІ, ЕФЕКТИВНІСТЬ НАВЧАННЯ, ТОЧНІСТЬ КЛАСИФІКАЦІЇ**

**O. V. Zolotukhin, M. S. Kudryavtseva, Y. Y. Yeremieiev. Stochastic initialization for neural networks based on the analysis of biological systems.** Artificial neural networks are typically initialized using mathematically defined methods that do not account for the structural and functional diversity of biological systems. While traditional approaches ensure training stability, they overlook natural mechanisms of synaptic connection formation. This study proposes a biologically inspired approach to weight initialization based on stochastic patterns identified in empirical movement trajectories recorded in a controlled biological environment. The data undergo preprocessing, including smoothing, normalization, and scaling, to generate weight values subsequently used for neural network initialization. The effectiveness of the proposed method is evaluated against standard initialization strategies using three benchmark datasets: MNIST, Fashion-MNIST, and the Gas Sensor Array Drift dataset. Experimental results demonstrate that the biologically inspired approach achieves comparable performance across all evaluation criteria, including test and validation accuracy, the number of epochs required for convergence, class-wise sensitivity, and the macro-averaged F1-score. In several cases, the method facilitates faster convergence without compromising classification accuracy. Although the proposed strategy does not consistently outperform conventional methods, it introduces structured stochasticity into the training process based on biological principles and provides a promising foundation for further research into more complex architectures and biologically inspired learning models.

**ARTIFICIAL NEURAL NETWORKS, WEIGHT INITIALIZATION, STOCHASTIC GROWTH, MACHINE LEARNING, BAGGING, STACKING, ENSEMBLE LEARNING, CONVERGENCE SPEED, TRAINING PERFORMANCE, CLASSIFICATION ACCURACY**

### Вступ

Ефективність навчання штучних нейронних мереж значною мірою залежить від того, як обрано початкові значення вагових коефіцієнтів. Саме початкова ініціалізація визначає характер поширення градієнтів, впливає на збіжність алгоритму та формує загальну динаміку перебігу навчання. Чутливість до початкових значень ваг може зумовити зникнення або вибухове зростання градієнтів, що ускладнює процес оптимізації та знижує здатність моделі до

узагальнення. У відповідь на ці виклики було розроблено низку стратегій ініціалізації, орієнтованих на збереження стабільного поширення сигналу між шарами та ефективне функціонування нейромережі [1].

Традиційні підходи до ініціалізації зазвичай ґрунтуються на заздалегідь заданих математичних розподілах, а також на емпіричних припущеннях щодо глибини мережі та властивостей функцій активації. Хоча такі стратегії значно покращують стабільність і швидкість навчання, вони практично не враховують

принципи, притаманні біологічним нейронним системам [2]. Зокрема, у стратегіях ініціалізації штучних нейронних мереж часто ігноруються просторові закономірності, природна розрідженість і стохастичні механізми зростання, притаманні формуванню синаптичних зв'язків у біологічних нейронних системах.

На відміну від цього, розвиток нейронних структур у біологічних системах відбувається через механізми зростання, що поєднують випадкові процеси та впливи зовнішнього середовища. Синаптичні з'єднання виникають у результаті аксонального росту та просторово спрямованого формування мереж, що призводить до розріджених і функціонально адаптивних схем з'єднань [3]. Такі біологічні особливості можуть слугувати основою для переосмислення принципів ініціалізації ваг у штучних мережах, замінюючи суто формальні підходи на більш природні, з елементами структурного різноманіття та стохастичної організації.

Останні дослідження демонструють, що біологічно натхненні моделі здатні підвищити ефективність нейронних обчислень, зокрема за рахунок відтворення природних механізмів пластичності та навчання [4]. Такі підходи не лише сприяють зростанню продуктивності, а й покращують інтерпретованість і надійність моделей, оскільки ґрунтуються на нейробіологічних закономірностях.

У цьому дослідженні розглядається метод стохастичної ініціалізації штучних нейронних мереж, що базується на даних, отриманих із біологічних систем. Запропонований підхід базується на концепції формування зв'язків у процесі росту та моделює стохастичні закономірності їх розвитку для генерації початкових вагових коефіцієнтів. На відміну від класичних повнозв'язних архітектур, такий метод забезпечує формування розрідженої, структуровано впорядкованої початкової конфігурації, що може сприяти покращенню навчальної динаміки й обчислювальної ефективності.

Об'єктом дослідження є процес ініціалізації вагових коефіцієнтів у штучних нейронних мережах із використанням біологічно натхненого підходу, заснованого на стохастичних закономірностях, виявлених у реальних траєкторіях руху біологічних систем. Предметом дослідження є метод ініціалізації, побудований на моделі стохастичного зростання, що відтворює ключові механізми формування синаптичних зв'язків у біологічних нейронних структурах. У роботі проаналізовано теоретичні основи, реалізовано алгоритм методу та проведено його оцінювання щодо впливу на динаміку навчання й ефективність моделей у порівнянні зі стандартними підходами.

## 1. Постановка проблеми

Попри суттєвий прогрес у методах навчання штучних нейронних мереж, проблема ефективної та

біологічно обґрунтованої ініціалізації вагових коефіцієнтів залишається відкритою. Сучасні стратегії ініціалізації здебільшого базуються на математичних моделях, розроблених для забезпечення статистичної стабільності активацій і градієнтів між шарами мережі. Вони демонструють високу ефективність у запобіганні градієнтній нестабільності та покращенні динаміки навчання, проте спираються на абстрактні ймовірнісні припущення і не враховують ані структурних, ані функціональних особливостей біологічних систем.

Натомість нейронні зв'язки в біологічних мережах не формуються з використанням рівномірних або симетричних розподілів. Вони виникають у результаті стохастичних, просторово обмежених процесів, зумовлених локальними взаємодіями, динамікою розвитку та адаптивною реакцією на зовнішнє середовище. Формування синаптичних зв'язків у біологічних системах визначається такими принципами, як розрідженість, локальність та пластичність, що спричиняє появу різноманітних і неоднорідних закономірностей зв'язків, які зазвичай не відтворюються в штучних моделях. Дані нейронауки свідчать про те, що така варіативність відіграє ключову роль у підвищенні ефективності навчання, забезпеченні різноманіття сигналів та адаптивності системи загалом.

Однак у більшості штучних нейронних мереж біологічно обґрунтована варіативність майже не враховується під час ініціалізації. Існуючі методи зазвичай розглядають цей процес як суто математичну процедуру, відокремлену від емпіричних біологічних даних. Як наслідок, моделі втрачають потенційні переваги структурованої природної випадковості, серед яких – покращена динаміка навчання, краща здатність до узагальнення та вища стійкість до зміни даних або зовнішніх умов.

Центральною проблемою, що розглядається у цьому дослідженні, є відсутність практичного та відтворюваного методу впровадження біологічно обґрунтованої варіативності в процес ініціалізації ваг штучних нейронних мереж. Хоча ідеї біологічного натхнення широко визнаються в машинному навчанні, більшість підходів не використовує реальні біологічні процеси як структуроване джерело для формування початкових розподілів ваг.

Метою дослідження є розв'язання актуального питання, пов'язаного з відсутністю біологічно обґрунтованих методів ініціалізації, шляхом використання патернів руху, виявлених на основі аналізу біологічних систем. Перетворюючи природні траєкторії руху на структуровані вагові коефіцієнти, запропонована методика має на меті підвищити стабільність навчання, забезпечити ефективну збіжність і з'ясувати, чи може біологічна варіативність позитивно впливати на продуктивність нейронної мережі. Такий підхід

особливо актуальний для задач, пов'язаних із нерівномірним розподілом вхідних даних, динамічними середовищами або сферами, у яких перевагу мають моделі з біологічною інтерпретованістю. У ширшому контексті запропонований підхід сприяє подоланню концептуального розриву між моделями навчання штучних нейронних мереж і принципами, характерними для біологічних нейронних систем.

## 2. Огляд літератури

Ініціалізація ваг залишається важливою складовою навчання штучних нейронних мереж, особливо у глибоких архітектурах, де вибір початкових значень може суттєво впливати на стабільність градієнтів і загальну динаміку оптимізації. Важливим кроком у цьому напрямі стало запровадження ініціалізації Ксав'єра (Xavier initialization), цей підхід полягає в масштабуванні вагових коефіцієнтів відповідно до кількості нейронів у вхідному та вихідному шарах, що дозволяє зберігати дисперсію активацій і градієнтів стабільною як під час прямого поширення сигналу, так і на етапі зворотного поширення помилки [2]. Ініціалізація Ксав'єра продемонструвала ефективність у прискоренні збіжності та забезпеченні стабільного навчання, особливо у випадку використання симетричних активаційних функцій, таких як гіперболічний тангенс.

Одним з альтернативних широко вживаних підходів є ортогональна ініціалізація (orthogonal initialization), яка зберігає норму вхідного сигналу та виявилася ефективною для стабілізації градієнтного потоку між шарами. Цей метод, окрім математичної обґрунтованості, викликає інтерес і з біологічної точки зору, оскільки орієнтовані схеми з'єднань розглядаються як потенційний механізм стабільного передавання сигналу в біологічних системах [5].

Останніми роками з'явилися альтернативні стратегії, які прагнуть запровадити структуровану випадковість у процес ініціалізації. Зокрема, методи ініціалізації на основі хаотичних відображень (chaos-based initialization) використовують детерміновані хаотичні функції для генерації різноманітних вагових коефіцієнтів, порушуючи симетрію на початкових етапах навчання та сприяючи зростанню репрезентативного різноманіття. Такі підходи демонструють покращену збіжність і вищу точність класифікації, особливо в умовах неопуклої оптимізації, де початкова ініціалізація суттєво впливає на траєкторію навчання [6].

На відміну від штучних моделей, які здебільшого ґрунтуються на абстрактних математичних розподілах, біологічні системи формуються через стохастичні, проте функціонально структуровані процеси росту. У таких системах синаптичні зв'язки виникають завдяки просторовій організації, локальній конкуренції та адаптивним механізмам, залежним від активності.

Дослідження в галузі нейронауки свідчать, що ці процеси формують розріджені, модульні та високоадаптивні мережі, що, своєю чергою, дає підстави вважати, що біологічно натхненні методи (bio-inspired initialization) ініціалізації здатні суттєво покращити характеристики штучних нейронних моделей [7].

Одним із таких підходів є ініціалізація на основі флуктуацій (fluctuation-based initialization), яка імітує природні коливання, зумовлені синаптичним шумом і балансом збуджувальної та гальмівної активності. Цей метод відображає біологічні механізми шумової модуляції, що забезпечують адаптивність нейронних систем. Ініціалізація з флуктуаційною варіативністю асоціюється з покращеною збіжністю та підвищеною здатністю моделі до навчання узагальнених уявлень [8].

Окрім біологічно натхнених схем, активну увагу дослідників привертають оптимізаційно-орієнтовані методи ініціалізації. Зокрема, було запропоновано застосування еволюційних алгоритмів та евристик, натхнених природними процесами, для налаштування початкового розподілу ваг ще до початку навчання. Ці підходи забезпечують гнучкість і адаптивність, використовують стохастичні варіації для пошуку ефективних параметрів, і особливо добре працюють у задачах регресії та підкріплювального навчання [9].

Архітектурні рішення в нейромережевому проектуванні також включають елементи біологічного моделювання – такі як синаптичний шум і стохастична активація. Прикладом є нейросемплінгова машина, яка інтегрує мультиплікативний синаптичний шум у ініціалізацію та обчислення, реалізуючи ймовірнісне навчання, наближене до біологічного [10].

Теоретичні основи навчання нейронних мереж підкреслюють важливість узгодження стратегій ініціалізації з особливостями оптимізаційного процесу. Ефективність зворотного поширення помилки залежить не лише від властивостей градієнтного потоку, а й від масштабу та розподілу початкових вагових коефіцієнтів. Неузгоджена ініціалізація може уповільнити збіжність або спрямувати модель до субоптимальних рішень. Відтак, структуровано побудована схема ініціалізації залишається ключовим чинником для досягнення стабільного та ефективного навчання [11].

Дослідження в галузі моделювання складних систем підтверджують вирішальну роль ініціалізації у формуванні поведінки моделі. При виконанні аналітичних або прогностичних завдань у структурованих середовищах початкові параметри здатні довгостроково впливати на поведінку моделі, динаміку збіжності та рівень інтерпретованості результатів. Інтелектуальний аналіз таких систем показує, що початкові структурні умови часто визначають успішність подальших етапів навчання [12]. Разом із цим, семантичне моделювання предметних галузей

акцентує увагу на необхідності логічно вивіреного, формалізованого представлення знань, що, своєю чергою, сприяє точнішій ініціалізації параметрів завдяки чіткому визначенню структури та залежностей у моделі даних [13].

Сучасні дослідження, орієнтовані на біологічно правдоподібну динаміку навчання, доповнюють це розуміння через запровадження диференційованих навчальних правил, що базуються на нейрофізіологічних спостереженнях. Наприклад, у стохастичних нейронних мережах досліджуються правила навчання, засновані на кореляції активності із затримкою, які відтворюють механізми хеббівської пластичності та синаптичної адаптації, залежної від часу спайкування. Такі підходи демонструють значущість впровадження біологічних принципів у алгоритми навчання та процеси ініціалізації [14].

Ще одним перспективним напрямом є ініціалізація на основі інтервалів, де окремим нейронам або шарам призначаються специфічні діапазони початкових значень. Це сприяє контрольованому внесенню варіативності, порушенню симетрії та покращенню збіжності, особливо в нейронних мережах прямого поширення сигналу [15].

У прикладних сферах значення оптимальної ініціалізації ще більше зростає, зокрема, в комп'ютерному зорі, обробці природної мови та аналізі біомедичних сигналів. У глибоких згорткових мережах початковий розподіл ваг суттєво впливає на якість навчання, особливо у випадках обмеженої кількості навчальних прикладів. У медичній візуалізації та дистанційному зондуванні метод ініціалізації визначає чутливість і надійність виявлення структур, що робить його критично важливим етапом побудови моделей [16].

Моделі адаптивної поведінки в інтелектуальних системах також підтверджують користь структурованої випадковості під час ініціалізації. Така варіативність забезпечує чутливість до контексту та дозволяє агентам змінювати стратегії відповідно до змінних зовнішніх умов [17]. Аналогічні принципи застосовуються в нейромережах, де стохастична ініціалізація сприяє різноманітності поведінки та підвищує ефективність у динамічних і непередбачуваних середовищах. Подібні закономірності виявлено і в дослідженнях прогнозування для систем Інтернету речей, де початкові сигнальні параметри суттєво впливають на точність передбачення екологічних показників у «розумних» будинках [18].

Окрім біологічно обґрунтованих патернів і евристичних методів, значну роль відіграє й попередня обробка даних, орієнтована на прикладні потреби. Так, у біомедичних системах, наприклад, при аналізі ринноманометричних сигналів, згорткові нейронні мережі використовуються для автоматичної ідентифікації та виправлення аномалій, що дозволяє

підвищити якість даних ще до етапу навчання [19]. У тривимірному аналізі ефективною виявилася нечітка фільтрація хмар точок на основі F-перетворення, що забезпечує збереження геометричної структури даних і підвищення точності сигналу, що також важливо для ініціалізації мереж, що працюють з просторовими вхідними даними [20].

Підсумовуючи, слід зазначити, що ініціалізація є не просто підготовчим етапом, а фундаментальним компонентом, який визначає якість і ефективність усього процесу навчання. Попри досягнутий прогрес, більшість сучасних методів залишаються в межах абстрактних математичних моделей і не враховують природну варіативність, характерну для біологічних систем. Запропонований підхід спрямований на подолання цього обмеження шляхом використання траєкторій природного руху для генерації початкових ваг.

### 3. Матеріали та методи

Запропонований метод ініціалізації вагових коефіцієнтів у штучних нейронних мережах ґрунтується на використанні траєкторій руху, отриманих із біологічних систем. Дані про переміщення були зібрані шляхом відеоспостереження за біологічними зразками у контрольованому водному середовищі. Запис здійснювався за допомогою стаціонарної камери, розміщеної над експериментальним об'єктом, з роздільною здатністю 1080p та частотою 30 кадрів на секунду.

Відстеження руху біологічних зразків виконувалося покадрово з використанням алгоритмів виявлення контурів на основі бібліотеки OpenCV. У результаті було сформовано послідовність двовимірних координат  $(x_t, y_t)$ , що відповідають положенню об'єкта на кожному часовому кроці  $t$ .

Для кількісної оцінки інтенсивності руху розраховувалося переміщення між сусідніми кадрами за допомогою евклідової відстані:

$$d_t = \sqrt{(x_t - x_{t-1})^2 + (y_t - y_{t-1})^2}, \quad (1)$$

де  $d_t$  – величина переміщення на часовому кроці  $t$ ,  $x_t$  та  $y_t$  – координати об'єкта у поточному кадрі, а  $x_{t-1}$  та  $y_{t-1}$  – координати об'єкта у попередньому кадрі.

Для зменшення високочастотного шуму та пригнічення короткочасних флуктуацій було застосовано двоетапну процедуру згладжування сигналу. На першому етапі використовувався фільтр ковзного середнього з розміром вікна п'ять кадрів. На другому етапі використовувався фільтр Гауса зі стандартним відхиленням  $\sigma = 1$ . Обрані параметри були підібрані з метою досягнення оптимального балансу між ефективним усуненням шуму та збереженням природної варіативності у траєкторіях руху біологічних об'єктів.

Після згладжування сигнал переміщення було нормалізовано за допомогою Z-нормалізації, яка обчислюється за формулою:

$$z_t = \frac{d_t - \mu}{\sigma}, \quad (2)$$

де  $z_t$  – нормалізоване значення переміщення на часовому кроці  $t$ ,  $\mu$  – середнє значення всіх вимірних переміщень, а  $\sigma$  – стандартне відхилення. Така трансформація забезпечує нульове середнє значення та одиничну дисперсію нормалізованого сигналу, що запобігає впливу екстремальних значень на процес ініціалізації.

Для адаптації нормалізованих значень до задачі ініціалізації ваг у нейронній мережі, а також з метою забезпечення стабільної дисперсії активацій, виконувалося масштабування за формулою:

$$w_{scaled} = z_t \times \frac{1}{\sqrt{n_{in} + n_{out}}}, \quad (3)$$

де  $w_{scaled}$  – остаточне масштабоване значення ваги,  $n_{in}$  – кількість нейронів на вході шару, а  $n_{out}$  – кількість нейронів на виході. Масштабування здійснювалося з урахуванням структури шару для підтримання стабільного розповсюдження сигналу та уникнення перенасичення або згасання активацій.

Отриманий одномірний масив вагових коефіцієнтів було перетворено у двовимірну матрицю ваг шляхом позиційного відображення, яке відповідало топології з'єднань між нейронами:

$$w_{i,j} = w_{scaled} [i \times n_{out} + j], \quad (4)$$

де  $w_{i,j}$  – вага з'єднання між вхідним нейроном  $i$  та вихідним нейроном  $j$ . Ця процедура виконується у рядковому порядку, що забезпечує відповідність структури матриці типовим реалізаціям нейронних мереж.

Для інтеграції запропонованого методу ініціалізації у нейромереву архітектуру було визначено модель, що складається з вхідного шару, одного прихованого шару та вихідного шару. Ілюстративна конфігурація містила 100 вхідних нейронів, 64 нейрони у прихованому шарі та 10 нейронів на виході, що відповідали категоріям класифікації. Сформована матриця ваг була використана для ініціалізації з'єднань між вхідним і прихованим шарами. Ваги інших шарів були ініціалізовані стандартними методами з метою збереження сумісності та забезпечення можливості порівняльного аналізу.

Функції активації, застосовані в нейронній мережі, були підібрані з метою запровадження нелінійності, забезпечення ефективного перетворення сигналу та підтримки стабільного поширення градієнтів. У прихованому шарі використовувалася функція активації ReLU, яка визначається за формулою:

$$f(x) = \max(0, x), \quad (5)$$

де  $x$  – вхідне значення нейрона. Вибір ReLU зумовлений її обчислювальною ефективністю, здатністю

сприяти формуванню розріджених активацій та стійкістю до проблеми зникнення градієнтів.

У вихідному шарі застосовувалася сигмоїдна функція активації, яка відображає вихідні значення у проміжок  $[0,1]$ , що дозволяє інтерпретувати результати як ймовірності у задачах класифікації. Вона визначається наступним чином:

$$f(x) = \frac{1}{1 + e^{-x}}, \quad (6)$$

де  $e^{-x}$  – експонента від від'ємного значення вхідного сигналу.

Описана методологія ґрунтується на аналізі біологічних систем і забезпечує статистично коректну ініціалізацію штучних нейронних мереж. Інтеграція природної варіативності в процес генерації початкових параметрів сприяє підвищенню структурного різноманіття мережі та відкриває нові перспективи для розробки біологічно натхненних рішень у сфері машинного навчання. Ефективність запропонованого підходу розглядається в наступному розділі, присвяченому експериментальній оцінці.

#### 4. Експерименти

Експериментальна перевірка запропонованого методу була проведена із застосуванням повнозв'язної нейронної мережі прямого поширення, реалізованої у середовищі PyTorch. Метою експериментів було аналізування динаміки навчання та якісних характеристик моделі під час використання біологічно натхненного методу ініціалізації в порівнянні з іншими відомими підходами. Дослідження здійснювалося в контрольованих і відтворюваних умовах, що дозволяло ізолювати вплив саме ініціалізації на результати навчання та оцінити доцільність включення стохастичних патернів, характерних для біологічних систем, у процес навчання штучної нейронної мережі.

Навчання моделей проводилося з використанням алгоритму оптимізації Adam, який поєднує переваги адаптивного регулювання швидкості навчання та імпульсного прискорення. Швидкість навчання було встановлено на рівні 0.001 як компроміс між швидкою збіжністю та стабільністю, тоді як розмір міні-вибірки, що становив 64, забезпечував ефективне оновлення ваг без надмірного обчислювального навантаження. Кожен сеанс навчання складався з 30 епох, що надавало моделі достатньо часу для стабілізації та досягнення високої точності класифікації. Функцією втрат обрано CrossEntropyLoss, яка є стандартом для багатокласової класифікації й дозволяє безпосередньо інтерпретувати точність моделі у ймовірнісних термінах. Для запобігання перенавчанню та покращення здатності до узагальнення після кожного прихованого шару було додано шари випадкового вимикання із ймовірністю 0.25.

Усі архітектурні, навчальні та оптимізаційні параметри залишалися незмінними протягом

експериментів; варіювався лише метод ініціалізації ваг. Запропонований біологічно натхненний підхід було порівняно з такими стратегіями, як ініціалізація Ксав'єра, ортогональна ініціалізація, ініціалізація на основі хаотичних відображень та ініціалізація на основі флуктуацій. Щоб забезпечити об'єктивність порівняння, кожна конфігурація тренувалася з однаковими випадковими початковими значеннями у стабільному обчислювальному середовищі. Це гарантувало, що всі відмінності в результатах навчання були зумовлені виключно обраним методом ініціалізації.

Для експериментальної перевірки використано три тестові набори даних, що відрізняються типами вхідної інформації та складністю. Набір MNIST [21], що містить 70 000 зображень рукописних цифр у відтінках сірого, слугував для оцінки ефективності моделі у задачах візуальної класифікації зі структурованими та чітко розділеними класами. Цей набір використовувався як базовий для аналізу збіжності та ефективності навчання в умовах спрощеного середовища. Другим був набір Fashion-MNIST [22], який має ту саму структуру, але представляє складніше завдання класифікації одягу, де візуальна подібність між класами значно вища, що ускладнює навчання та вимагає кращого розпізнавання тонких відмінностей. Третім набором був Gas Sensor Array Drift [23], який складається з часових рядів, отриманих від газових сенсорів протягом кількох місяців. Через старіння сенсорів і зміну середовища вхідні розподіли піддаються поступовому дрейфу, що робить цей набір особливо цінним для перевірки стійкості моделей до нестабільності даних і концептуального дрейфу.

Поєднання статичних зображень і динамічних часових рядів формує різноманітне середовище тестування, що дозволяє оцінити як здатність моделі до короткотривалого розпізнавання шаблонів, так і до довгострокової адаптації. Така експериментальна конструкція забезпечує глибокий аналіз впливу стратегії ініціалізації за різних рівнів складності та стаціонарності даних.

Кожну конфігурацію експерименту було повторено п'ять разів для врахування стохастичної природи навчального процесу та зменшення варіації результатів. Усі показники усереднювались для отримання стабільних і статистично достовірних висновків. Для оцінювання ефективності використовувався набір ключових метрик, що відображають різні аспекти якості моделі. Точність на тестовій вибірці характеризувала загальну продуктивність моделі на нових даних, тоді як точність на валідаційній вибірці відображала її здатність до узагальнення під час навчання. Кількість епох до збіжності, визначена як момент досягнення 95% точності на навчальному наборі, використовувалася для оцінки ефективності початкової ініціалізації. Чутливість за класами дозволяла проаналізувати здатність моделі виявляти приклади

кожної окремої категорії, а макроусереднений показник F1-метрики, що є гармонічним середнім між точністю та повнотою по класах, слугував інтегральним критерієм збалансованості класифікації, особливо в умовах нерівномірного розподілу даних.

Усі експерименти були проведені в однаковому апаратному середовищі із використанням стандартних програмних бібліотек, щоб уникнути впливу сторонніх факторів, пов'язаних із конфігурацією обладнання чи програмного забезпечення. Експериментальний протокол було розроблено з урахуванням повної відтворюваності та можливості безпосереднього порівняння результатів з майбутніми дослідженнями, що базуватимуться на подібних стратегіях ініціалізації.

Ця розширена експериментальна структура дозволяє не лише оцінити безпосередню ефективність біологічно натхненого методу ініціалізації, а й закласти підґрунтя для його інтеграції в ширші машинно-навчальні процеси.

## 5. Результати

У цьому розділі подано результати експериментів, які відображають ефективність кожного методу ініціалізації ваг за різними критеріями оцінювання. Аналіз охоплює такі показники: точність на тестовій вибірці, точність на валідаційній вибірці, кількість епох до збіжності, чутливість за класами та макроусереднений показник F1-метрики для трьох різних наборів даних. Це дозволяє здійснити комплексне порівняння стратегій ініціалізації з урахуванням точності класифікації та динаміки навчання в умовах різноманітних інформаційних доменів.

Огляд точності на тестовій вибірці демонструє, наскільки ефективно кожна модель навчалася на відповідній вибірці даних. Усі методи досягли високої точності на наборі даних MNIST, тоді як на складніших наборах даних Fashion-MNIST та Gas Sensor Drift спостерігалася дещо більша варіативність результатів. Біологічно натхненна ініціалізація показала стабільну ефективність, зіставну з іншими методами ініціалізації на всіх розглянутих наборах даних. Результати продемонстровано в табл. 1.

Таблиця 1

Точність на тестовій вибірці (%)

Метод ініціалізації	MNIST	Fashion-MNIST	Gas Sensor Drift
Xavier	99.2	94.8	91.4
Orthogonal	99.1	95.0	91.7
Chaos-Based	99.0	94.4	90.5
Fluctuation-Driven	98.9	94.6	90.9
Bio-Inspired	99.2	94.9	91.6

Точність на валідаційній вибірці відображає здатність моделі узагальнювати знання на нові дані, які

не використовувалися під час навчання. Цей показник є критично важливим для оцінки реальної працездатності моделі за межами тренувального середовища. Отримані результати свідчать про те, що всі методи зберігали високу здатність до узагальнення з незначними відмінностями між ними, що свідчить про їхню надійність. Біологічно натхненна ініціалізація демонструвала стабільну ефективність, результати якої були близькими до показників ініціалізації Ксав'єра та ортогональної ініціалізації. Це вказує на те, що використання стохастичної ініціалізації на основі аналізу біологічних систем не лише не знижує здатність моделі до узагальнення, а навпаки – може сприяти зменшенню перенавчання завдяки введенню початкової структурної неоднорідності. Така властивість є особливо важливою у випадках, коли навчальна вибірка обмежена або містить внутрішній шум, що робить стабільне узагальнення пріоритетом. Результати продемонстровано в табл. 2.

Таблиця 2

## Точність на валідаційній вибірці (%)

Метод ініціалізації	MNIST	Fashion-MNIST	Gas Sensor Drift
Xavier	97.8	89.9	88.3
Orthogonal	97.7	90.1	88.6
Chaos-Based	97.6	89.5	87.7
Fluctuation-Driven	97.5	89.7	88.0
Bio-Inspired	97.7	90.1	88.5

Швидкість збіжності визначається кількістю епох, необхідних для досягнення 95% точності на навчальній вибірці, що є важливим критерієм ефективності початкової ініціалізації. Менша кількість епох свідчить про здатність моделі швидше входити в режим стабільного навчання з мінімальними обчислювальними витратами. Біологічно натхненна ініціалізація, відповідно до експериментальних результатів, у більшості випадків забезпечувала таку ж або меншу кількість епох до збіжності порівняно з іншими методами, особливо на наборах MNIST і Fashion-MNIST. Така динаміка може бути зумовлена тим, що стохастичні вагові розподіли, сформовані на основі біологічних траєкторій, сприяють формуванню початкової конфігурації з вищою чутливістю до градієнтів, що зменшує ризик затримки на плато помилок і пришвидшує оптимізацію. Результати подано в табл. 3.

Таблиця 3

## Кількість епох до збіжності

Метод ініціалізації	MNIST	Fashion-MNIST	Gas Sensor Drift
Xavier	13	17	21
Orthogonal	14	16	20
Chaos-Based	15	18	23
Fluctuation-Driven	16	17	22
Bio-Inspired	14	16	21

Показник чутливості за класами характеризує здатність моделі коректно виявляти об'єкти, що належать до кожного окремого класу, і є важливим критерієм оцінювання якості класифікації в умовах нерівномірного розподілу класів або присутності класів із низькою частотою появи. Аналіз отриманих результатів свідчить про те, що біологічно натхненна ініціалізація забезпечила стабільну ефективність моделі у розрізі класів. За рівнем чутливості вона не поступалася класичним методам ініціалізації і не спричиняла зниження надійності класифікації на жодному з досліджуваних класів. Таким чином, можна зробити висновок про її здатність підтримувати баланс якості розпізнавання в межах усіх класів, що є критично важливим для задач, де помилка в окремому класі має високу вагу. Результати продемонстровано в табл. 4.

Таблиця 4

## Чутливість за класами

Метод ініціалізації	MNIST	Fashion-MNIST	Gas Sensor Drift
Xavier	0.980	0.891	0.873
Orthogonal	0.978	0.894	0.875
Chaos-Based	0.976	0.885	0.865
Fluctuation-Driven	0.975	0.888	0.870
Bio-Inspired	0.979	0.892	0.874

Більш узагальнене уявлення про якість класифікації дає макроусереднений показник F1-метрики. Цей показник поєднує точність і чутливість, забезпечуючи збалансовану оцінку ефективності моделі по всіх класах. Він є особливо інформативним у випадках дисбалансу класів або різної складності їх розпізнавання. Біологічно натхненна ініціалізація знову продемонструвала порівнювані результати, підтвердивши свою надійність у різних задачах та здатність зберігати стабільну якість класифікації без упередженості до окремих категорій. Результати продемонстровано в табл. 5.

Таблиця 5

## Макроусереднений показник F1-метрики

Метод ініціалізації	MNIST	Fashion-MNIST	Gas Sensor Drift
Xavier	0.978	0.889	0.871
Orthogonal	0.977	0.892	0.874
Chaos-Based	0.976	0.884	0.864
Fluctuation-Driven	0.975	0.887	0.868
Bio-Inspired	0.977	0.890	0.873

Отримані результати підтверджують, що біологічно натхненна ініціалізація демонструє стабільну ефективність за всіма метриками та на всіх наборах

даних. У низці випадків цей підхід сприяв швидшому навчанню без зниження точності класифікації, що свідчить про його потенціал як повноцінної альтернативи традиційним стратегіям ініціалізації.

## 6. Обговорення

Результати експериментів дозволяють глибше зрозуміти практичну поведінку біологічно натхненого методу ініціалізації у порівнянні з усталеними підходами. У межах усіх наборів даних і за всіма критеріями оцінювання запропонований підхід продемонстрував ефективність, не нижчу за показники загальноновизнаних методів ініціалізації. Така стабільність свідчить про те, що впровадження варіативності, отриманої з біологічних систем, не має негативного впливу на процес навчання моделі або якість класифікації. Це свідчить про те, що структурована випадковість, сформована на основі аналізу біологічних систем, може слугувати ефективною основою для ініціалізації нейронних мереж.

Щодо точності на навчальній та валідаційній вибірках, запропонований метод забезпечив результати, практично ідентичні тим, що були досягнуті за допомогою інших стратегій ініціалізації. Це вказує на те, що стохастичні патерни, отримані на основі аналізу біологічних систем, є цілком достатніми для підтримки стабільного процесу навчання та ефективного узагальнення. Хоча самі дані були отримані з емпіричних спостережень, процес ініціалізації на їх основі виявився сумісним із статистичною динамікою навчання в штучних системах. Це підтверджує гіпотезу про те, що варіативність, запозичена з біологічних систем, може функціонально передаватися у моделі штучних нейронних мереж без втрати ефективності навчання.

Одним із найпомітніших спостережень стала швидкість збіжності. Біологічно натхненна ініціалізація в багатьох випадках потребувала меншої кількості епох для досягнення порогу точності в 95%, зокрема на задачах MNIST і Fashion-MNIST. Хоча різниця не була значною, вона може свідчити про те, що такий розподіл початкових ваг створює більш сприятливі умови для швидкого входження моделі в ефективний навчальний режим. Згладжені криві збіжності, зафіксовані в окремих експериментах, також вказують на те, що природна варіативність, закладена у ініціалізацію, може допомагати уникати плато помилок на ранніх етапах навчання.

Метод також продемонстрував стабільну поведінку за показниками чутливості по класах та макроусередненим значенням F1-метрики, що підтверджує його відсутність упередженості до окремих класів і надійність навіть за умов дисбалансу даних. Такі результати мають особливу практичну цінність для реальних застосувань, де важливо забезпечити рівномірну якість

класифікації для всіх категорій. У прикладних задачах віддається перевага моделям, що забезпечують узгоджену продуктивність на різномірних вхідних даних без домінування окремих класів, тоді як запропонований метод задовольняє цю вимогу.

Ще одним важливим аспектом є потенційна стійкість методу до зсувів розподілу даних та навчання в нестабільних середовищах. Оскільки біологічні траєкторії руху, що використовуються для генерації ваг, містять у собі структуровану стохастичність та часову динаміку, така ініціалізація може виявитися більш придатною для задач, у яких розподіл вхідних даних змінюється з часом. Хоча ця гіпотеза не перевірялася безпосередньо у межах даного дослідження, вона становить перспективний напрям подальших робіт.

У теоретичному контексті запропонований метод розглядається як внесок у розвиток напрямку машинного навчання, що орієнтується на біологічні принципи. На відміну від більшості традиційних стратегій ініціалізації, які ґрунтуються на формальних положеннях оптимізаційної теорії, запропонований підхід використовує стохастичні закономірності, виявлені в поведінці біологічних систем. Отримані вагові коефіцієнти відображають характерні властивості природних нейронних структур – зокрема, розрідженість з'єднань, присутність шуму та просторову варіативність. Попри те, що навчання штучної нейронної мережі реалізується у вигляді формального алгоритму, впровадження біологічно обґрунтованої структури ще на етапі ініціалізації дозволяє частково відтворити функціональні особливості природних нейронних систем.

Крім того, запропонований підхід може слугувати основою для створення гібридних архітектур, які поєднують стохастичну біологічну ініціалізацію з іншими елементами біологічного наслідування, зокрема регуляризацією типу випадкового вимикання, правилами навчання, керованим шумом, або обчисленням, що ґрунтується на подіях. Така багаторівнева інтеграція біологічних компонентів потенційно дозволяє підвищити як ефективність моделей, так і рівень їх інтерпретованості.

Хоча біологічно натхненна ініціалізація не продемонструвала істотного перевищення показників традиційних методів, вона підтвердила свою стабільність, відтворюваність та практичну придатність. Найважливішим її внеском є новий погляд на те, як біологічні джерела випадковості можуть бути інтегровані у процес навчання без шкоди для якості моделі. Цінність цього підходу полягає не стільки в перевершенні існуючих технік на окремих тестових наборах, скільки в розширенні концептуального інструментарію для побудови нейронних систем з вищим рівнем структурної реалістичності та функціонального різноманіття.

З огляду на це, метод біологічно натхненної ініціалізації може бути особливо корисним для адаптивних або онлайн-навчальних сценаріїв, де початкові умови повинні швидко налаштуватися під динамічні потоки даних. У таких задачах класичні фіксовані методи ініціалізації можуть виявитися неефективними або надто інертними до змін, тоді як ініціалізація на основі біологічних патернів відкриває можливість для створення систем з підвищеною гнучкістю та контекстною чутливістю. Подальше дослідження таких властивостей могло б розширити сферу застосування запропонованого підходу на задачі адаптивного контролю, безперервного навчання та роботи з потоковими даними.

### Висновки

У представленому дослідженні запропоновано новий біологічно натхнений метод ініціалізації вагових коефіцієнтів штучних нейронних мереж, який базується на аналізі стохастичних закономірностей, виявлених у траєкторіях руху біологічних об'єктів у контрольованому середовищі. Такий підхід реалізує концепцію перенесення природної варіативності до математичних моделей, спрямовану на подолання обмежень, властивих традиційним стратегіям ініціалізації, що базуються виключно на абстрактних статистичних розподілах.

Результати експериментів підтверджують, що запропонований підхід забезпечує ефективність, сумірну з ustalеними методами, такими як ініціалізація Ксав'єра, ортогональна ініціалізація, ініціалізація на основі хаотичних відображень та ініціалізація на основі флуктуацій, за всіма ключовими метриками: точністю класифікації на тестовій і валідаційній вибірках, кількістю епох до збіжності, чутливістю за класами та макроусередненою F1-метрикою. Стабільність запропонованого методу, відсутність деградації навчання й неупередженість до окремих класів свідчать про його надійність, незалежно від природи вхідних даних чи особливостей предметної області.

Особливо примітним є те, що біологічно натхненна ініціалізація в окремих випадках сприяла швидшому досягненню бажаного рівня точності, демонструючи потенціал до покращення динаміки навчання. Враховуючи, що початковий розподіл ваг значною мірою впливає на траєкторію оптимізації у багатовимірному просторі параметрів, можна припустити, що природна структурована варіативність забезпечує сприятливіші умови для ефективного навчання, зменшуючи ймовірність застрягання в локальних мінімумах.

Ще одним важливим внеском є можливість поєднання даного методу з іншими біологічно натхненими компонентами: шумовими регуляризаторами, стохастичними правилами навчання,

моделями спайкової активності або подієво орієнтованими обчисленнями. Біологічна сумісність стохастичної ініціалізації закладає основу для створення мультикомпонентних архітектур, які відтворюють не лише функціональні, а й структурні аспекти роботи природної нервової системи.

Наукове значення дослідження полягає не лише у підтвердженні працездатності методу, але й у демонстрації концептуальної життєздатності підходу, що ґрунтується на емпіричних біологічних процесах як джерелі ініціалізації. Це означає, що у майбутньому вагові конфігурації можуть не просто оптимізуватися за допомогою стохастичних функцій, а формуватися на основі природно отриманих динамічних сигналів, адаптованих до конкретного типу задачі або середовища.

Практична цінність підходу підтверджується його сумісністю з існуючими архітектурами, простотою інтеграції в типові фреймворки та відсутністю потреби в модифікації основних елементів навчального процесу. Це дозволяє впроваджувати метод у широке коло застосувань без ризику втрати продуктивності. Зокрема, він є перспективним у тих контекстах, де моделі працюють з динамічними, нестабільними або біологічно релевантними даними – наприклад, у біомедичних системах, робототехніці, когнітивному моделюванні та обробці сенсорних потоків у реальному часі.

Водночас результати дослідження відкривають кілька перспективних напрямів подальших наукових робіт. По-перше, доцільно розширити метод для використання в складніших нейромережевих архітектурах: глибоких згорткових мережах, рекурентних моделях і трансформерах. Це дозволить оцінити, чи зберігається перевага запропонованої стохастичної ініціалізації в умовах значної глибини або часової залежності сигналів. По-друге, варто дослідити адаптивні стратегії побудови вагових розподілів, у яких ініціалізація буде динамічно коригуватися залежно від типу даних, початкового розміру вибірки або змінних зовнішніх умов. По-третє, перспективним є вивчення впливу різних джерел біологічного руху – не лише лінійних траєкторій у просторі, а й багатовимірних патернів активності, зокрема нейрофізіологічних сигналів.

Крім того, важливо дослідити вплив даної ініціалізації на інтерпретованість і надійність моделей у критично важливих додатках, таких як медицина або автономні системи, де неконтрольована варіативність може призвести до небажаних наслідків. У цьому контексті можливим є інтегрування біологічно натхненого методу з механізмами пояснення рішень, що дозволить не лише покращити ефективність, а й підвищити довіру до моделей у чутливих доменах.

Підсумовуючи, варто зазначити, що запропонована стратегія стохастичної ініціалізації, розроблена

на основі аналізу біологічних систем, формує основу для подальшого розвитку адаптивних, стійких та структурно оптимізованих систем штучного інтелекту. Її застосування не лише забезпечує конкурентоспроможну продуктивність у розв'язанні стандартних задач класифікації, а й створює передумови для побудови моделей навчання з високим рівнем гнучкості, інтерпретованості та здатності до адаптації.

#### Список літератури:

- [1] Dai, K., Barati Farimani, A., Webster-Wood, V.: Bio-inspired stochastic growth and initialization for artificial neural networks. In: Proceedings of the 17th International Conference on Artificial Intelligence Applications and Innovations (IAAI), pp. 88–100. Springer, Cham (2019). [https://doi.org/10.1007/978-3-030-24741-6\\_8](https://doi.org/10.1007/978-3-030-24741-6_8)
- [2] Glorot, X., Bengio, Y.: Understanding the difficulty of training deep feedforward neural networks. In: Proceedings of the Thirteenth International Conference on Artificial Intelligence and Statistics (AISTATS), pp. 249–256. PMLR, Sardinia (2010). <https://proceedings.mlr.press/v9/glorot10a/glorot10a.pdf>
- [3] Goodfellow, I., Bengio, Y., Courville, A.: Deep Learning. MIT Press, Cambridge (2016).
- [4] Squadrani, L., Curti, N., Giampieri, E., Remondini, D., Blais, B., Castellani, G.: Effectiveness of biologically inspired neural network models in learning and patterns memorization. Entropy 24(5), 682 (2022). <https://doi.org/10.3390/e24050682>
- [5] Manchev, N., Spratling, M.: On the biological plausibility of orthogonal initialization for solving gradient instability in deep neural networks. In: Proceedings of the 2022 International Symposium on Computational and Business Intelligence (ISCMI), pp. 47–55. IEEE, Shanghai (2022). <https://doi.org/10.1109/ISCMI56532.2022.10068489>
- [6] Masood, S., Doja, M.N., Chandra, P.: Chaos-based network initialization approach for feedforward artificial neural networks. J. Comput. Theor. Nanosci. 17(4), 418–424 (2020). <https://doi.org/10.1166/jctn.2020.8684>
- [7] Pircher, T., Schlücker, E., Pircher, B., Feigenspan, A.: The structure dilemma in biological and artificial neural networks. Sci. Rep. 11, 5621 (2021). <https://doi.org/10.1038/s41598-021-84813-6>
- [8] Rossbroich, J., Gygax, J., Zenke, F.: Fluctuation-driven initialization for spiking neural network training. Neuroinform. Comput. Eng. 2, 044016 (2022). <https://doi.org/10.1088/2634-4386/ac97bb>
- [9] Demidova, L.A., Gorchakov, A.V.: Biology-inspired optimization algorithms applied to intelligent input weights selection of an extreme learning machine in regression problems. AIP Conf. Proc. 2700(1), 030003 (2023). <https://doi.org/10.1063/5.0124917>
- [10] Dutta, S., Detorakis, G., Khanna, A., Grisafe, B., Neftci, E., Datta, S.: Neural sampling machine with stochastic synapse allows brain-like learning and inference. Nat. Commun. 13, 2571 (2022). <https://doi.org/10.1038/s41467-022-30305-8>
- [11] LeCun, Y., Bottou, L., Orr, G.B., Müller, K.-R.: Efficient backprop. In: Orr, G.B., Müller, K.-R. (eds.) Neural Networks: Tricks of the Trade, pp. 9–50. Springer, Berlin (2000). [https://doi.org/10.1007/3-540-49430-8\\_2](https://doi.org/10.1007/3-540-49430-8_2)
- [12] Filatov, V., Yerokhin, A., Zolotukhin, O., Kudryavtseva, M.: Methods of intellectual analysis of processes in medical information systems. Inf. Extr. Process. 48(124), 92–98 (2020). <https://doi.org/10.15407/vidbir2020.48.092>
- [13] Filatov, V., Semenets, V., Zolotukhin, O.: Synthesis of semantic model of subject area at integration of relational databases. In: Proceedings of the IEEE 8th International Conference on Advanced Optoelectronics and Lasers (CAOL), pp. 598–601. IEEE, Sozopol (2019). <https://doi.org/10.1109/CAOL46282.2019.9019532>
- [14] Saglietti, L., Gerace, F., Ingrosso, A., Baldassi, C., Zecchina, R.: From statistical inference to a differential learning rule for stochastic neural networks. Interface Focus 8, 20180033 (2018). <https://doi.org/10.1098/rsfs.2018.0033>
- [15] Sodhi, S., Chandra, P.: Interval-based weight initialization method for sigmoidal feedforward artificial neural networks. AASRI Procedia 6, 19–25 (2014). <https://doi.org/10.1016/j.aasri.2014.05.004>
- [16] Zangana, H., Mohammed, A., Mustafa Alfaqi, F.: Advances and applications of convolutional neural networks in image analysis: A comprehensive review. J. Intell. Comput. Syst. 3(1), 16–29 (2024). <https://doi.org/10.58602/jics.v3i1.30>
- [17] Zolotukhin, O., Filatov, V., Yerokhin, A., Lanovyy, O., Kudryavtseva, M., Semenets, V.: An approach to the selection of behavior patterns autonomous intelligent mobile systems. In: Proceedings of the IEEE International Conference on Problems of Infocommunications Science and Technology (PIC S&T), pp. 349–352. IEEE, Kyiv (2021). <https://doi.org/10.1109/PICST54195.2021.9772110>
- [18] Zolotukhin, O., Filatov, V., Yerokhin, A., Kudryavtseva, M.: The methods for the prediction of climate control indicators in the Internet of Things systems. CEUR Workshop Proc. (2021). <https://doi.org/10.5281/zenodo.14526027>
- [19] Yerokhin, A., Nechyporenko, A., Babii, A., Turuta, O.: A new intelligence-based approach for rhinomanometric data processing. In: 2016 IEEE 36th International Conference on Electronics and Nanotechnology (ELNANO), pp. 198–201. IEEE, Kyiv (2016). <https://doi.org/10.1109/ELNANO.2016.7493047>
- [20] Yerokhin, A., Semenets, V., Nechyporenko, A., Turuta, O., Babii, A.: F-transform 3D point cloud filtering algorithm. In: 2018 IEEE Second International Conference on Data Stream Mining & Processing (DSMP), pp. 524–527. IEEE, Lviv (2018). <https://doi.org/10.1109/DSMP.2018.8478581>
- [21] LeCun, Y., Bottou, L., Bengio, Y., Haffner, P.: Gradient-based learning applied to document recognition. Proc. IEEE 86(11), 2278–2324 (1998). <https://doi.org/10.1109/5.726791>
- [22] Xiao, H., Rasul, K., Vollgraf, R.: Fashion-MNIST: A novel image dataset for benchmarking machine learning algorithms. arXiv:1708.07747 (2017). <https://doi.org/10.48550/arXiv.1708.07747>
- [23] Vergara, A., Vembu, S., Ayhan, T., Ryan, M.A., Homer, M.L., Huerta, R.: Chemical gas sensor drift compensation using classifier ensembles. Sens. Actuators B Chem. 166–167, 320–329 (2012). <https://doi.org/10.1016/j.snb.2012.01.074>