

УДК 004.8:519.7

МЕТОДИ ОБРОБКИ ВЕЛИКИХ ДАНИХ І ПРОГНОЗУВАННЯ ТИМЧАСОВИХ РЯДІВ ЗА ДОПОМОГОЮ НЕЙРОННИХ МЕРЕЖ

Клименко О. В.¹, Сухомлинова О. В.², Кравченко В. В.²

¹*TEAM International*

²*Військовий інститут телекомунікацій та інформатизації імені Героїв Крут*

Анотація: У статті детально розглянуто особливості функціонування нейронних мереж у контексті їх застосування для обробки великих обсягів даних і прогнозування тимчасових рядів, приділяючи особливу увагу механізмам накопичення інтелектуального капіталу. Встановлено, що ключовою характеристикою таких нейронних мереж є їхня здатність до адаптивного налаштування вагових коефіцієнтів і взаємозв'язків між нейронами, що досягається завдяки використанню принципів самоорганізації. У статті проведено аналіз моделей нейронних мереж, зокрема мережі Хопфілда та Хеммінга, які орієнтовані на збереження еталонних зразків за рахунок попередньої ініціалізації, але демонструють обмежену гнучкість у змінюваних середовищах. Доведено, що мережі, архітектура яких побудована на основі принципу мінімізації відстані Хеммінга, ефективно виконують завдання класифікації двійкових вхідних даних та ідентифікації зразків із найменшою відстанню до поданого сигналу. Разом з тим, зазначено, що обмеження в обчислювальних ресурсах та відсутність зворотного зв'язку з базою знань можуть спричинити певну нестабільність у роботі таких мереж. У статті запропоновано метод оптимізації структури нейронних мереж, що передбачає заміну окремих шарів на матриці вагових коефіцієнтів, що дає змогу знизити обчислювальну складність без втрати точності отримуваних результатів. Оцінено ефективність нейронних мереж у контексті аналізу великих масивів тимчасових рядів, зокрема у випадках, коли дані характеризуються високою динамічністю та складними нелінійними залежностями. У статті розроблено рекомендації для створення нейронних мереж із покращеними показниками стабільності та пластичності, які здатні зберігати сформовані знання навіть у випадках впливу зовнішніх сигналів. Описано підхід, згідно з яким процес обробки інформації базується на активації короткочасної пам'яті, функціонуванні системи уваги та використанні довготривалих зв'язків, що сприяє точнішій ідентифікації класів даних.

Ключові слова: обробка великих даних, прогнозування тимчасових рядів, нейронні мережі, машинне навчання, аналіз даних, активаційні функції.

METHODS OF PROCESSING BIG DATA AND FORECASTING TIME SERIES USING NEURAL NETWORKS

O. Klymenko¹, O. Sukhomlynova², V. Kravchenko²

¹*TEAM International*

²*Kruty Heroes Military Institute of Telecommunications and Information Technology*

Abstract: The article examines in detail the features of the functioning of neural networks in the context of their application for processing large amounts of data and forecasting time series, paying special attention to the mechanisms of accumulation of intellectual capital. It is established that the key characteristic of such neural networks is their ability to adaptively adjust weight coefficients and interconnections between neurons, which is achieved through the use of self-organization principles. The article analyzes neural network models, in particular Hopfield and Hamming networks, which are focused on preserving reference samples through preliminary initialization, but demonstrate limited flexibility in changing environments. It is proven that networks, the architecture of which is built on the principle of minimizing the Hamming distance, effectively perform the tasks of classifying binary



input data and identifying samples with the smallest distance to the given signal. At the same time, it is noted that limitations in computing resources and the lack of feedback with the knowledge base can cause a certain instability in the operation of such networks. The article proposes a method for optimizing the structure of neural networks, which involves replacing individual layers with matrices of weight coefficients, which makes it possible to reduce the computational complexity without losing the accuracy of the obtained results. The effectiveness of neural networks is assessed in the context of analyzing large arrays of time series, in particular in cases where the data are characterized by high dynamics and complex nonlinear dependencies. The article develops recommendations for creating neural networks with improved stability and plasticity indicators, which are able to preserve the formed knowledge even in cases of influence of external signals. An approach is described according to which the information processing process is based on the activation of short-term memory, the functioning of the attention system and the use of long-term connections, which contributes to a more accurate identification of data classes.

Keywords: big data processing, time series forecasting, neural networks, machine learning, data analysis, activation functions.

1 ВСТУП

У сучасних умовах стрімкого розвитку інформаційних технологій та цифрової трансформації, обробка великих обсягів даних стає критично важливою для прийняття обґрунтованих управлінських рішень у різних сферах діяльності, зокрема в економіці, фінансах, медицині, енергетиці, та інших галузях. Великі дані містять характерний потенціал для аналізу складних систем, прогнозування змін та оптимізації процесів. Однак традиційні методи обробки даних часто виявляються недостатньо ефективними через високий рівень складності, динамічності та багатовимірності цих даних. Провідне значення набувають дослідження методів прогнозування часових рядів, оскільки аналіз трендів, циклічності та інших характеристик є основою для побудови прогнозів у різних сферах, таких як фінансовий ринок, енергетика, кліматологія тощо. І відповідно в обґрунтованому контексті нейронні мережі демонструють свою ефективність завдяки здатності виявляти нелінійні залежності, адаптуватися до динамічних змін і працювати з великими масивами даних. Незважаючи на прогрес у дослідженні методів машинного навчання та нейронних мереж, існують виклики, пов'язані з оптимізацією архітектури нейронних мереж, мінімізацією помилок прогнозування, а також забезпеченням високої швидкості обробки даних за умов обмежених ресурсів.

2 АНАЛІЗ ЛІТЕРАТУРНИХ ДАНИХ ТА ПОСТАНОВКА ПРОБЛЕМИ

У ряді сучасних наукових робіт висвітлюється питання стосовно потенціалу нейронних мереж для вирішення задач, що вимагають аналізу великих обсягів даних із високою динамічністю та складними нелінійними залежностями. У роботах Дзямучич М., Шматковська Т., Борисюк О. [1], Шакір А., Стегеманн Д., Волк М., Джамоус Н., Туровські К. [13] детально розглянуто базові методи обробки великих даних і алгоритми машинного навчання, що лежать в основі нейронних мереж. Автори вказують на здатність штучних нейронних мереж виявляти приховані закономірності у великих наборах даних, що є ключовим для прогнозування тимчасових рядів. У подальших дослідженнях Інкін О., Погорелов О. [7] акцентовано увагу на застосуванні рекурентних нейронних мереж і довготривалої короткочасної пам'яті для прогнозування тимчасових рядів, таких як фінансові показники, погодні умови та енергетичні витрати.

У сучасних дослідженнях Чжан Л., Ван Р., Ліз., Лі Дж. [16] розглянуто питання оптимізації архітектури нейронних мереж для підвищення їхньої точності та ефективності при роботі з великими даними. Крім того, дослідження Хевамаладж Х., Бергмейр К., Бандара К. [5], Тілаб А. [12] акцентують увагу на використанні згорткових нейронних мереж (CNN) для комбінованого аналізу часових рядів і просторових даних, що дозволяє досягати високої точності прогнозування. Автори зазначають, що якісна підготовка даних значно впливає на точність прогнозування тимчасових рядів. У статті від Чжан М., Чень Й. [15], висвітлено проблему масштабування обчислювальних ресурсів для навчання нейронних мереж у задачах великих даних. Запропоновані рішення включають використання розподілених обчислень, хмарних платформ та оптимізованих алгоритмів, що дозволяють знизити витрати часу та ресурсів.

Ми можемо констатувати, що огляд сучасної бази дослідження свідчить про провідну роль нейронних мереж у задачах обробки великих даних і прогнозування тимчасових рядів, однак питання оптимізації архітектури, зниження обчислювальної складності та адаптації до змінюваних середовищ залишаються актуальними й потребують подальшого дослідження.

3 ЦІЛЬ ТА ЗАДАЧІ ДОСЛІДЖЕННЯ

Метою статті визначено розробку ефективних інструментів обробки великих даних і прогнозування тимчасових рядів, заснованих на нейронних мережах. Завдання дослідження: а) дослідити особливості функціонування моделей нейронних мереж, таких як мережі Хопфілда та Хеммінга, для аналізу великих даних і прогнозування тимчасових рядів; б) обґрунтувати доцільність удосконалення моделей нейронних мереж шляхом розробки нових архітектур, які дозволяють забезпечити баланс між стабільністю і пластичністю в процесі роботи з великими масивами даних; в) запропонувати алгоритм інтеграції механізмів довготривалої пам'яті та зворотного зв'язку для підвищення гнучкості нейронних мереж у задачах прогнозування тимчасових рядів.

4 РЕЗУЛЬТАТИ ДОСЛІДЖЕННЯ

Процес навчання нейронної мережі, який ґрунтується на принципі накопичення і прогнозування, передбачає використання вибірки, що складається з численних пар вхідних і вихідних векторів, які тісно пов'язані між собою. Важливою особливістю алгоритму такого типу є механізм самоорганізації, за допомогою якого здійснюється адаптація вагових коефіцієнтів і зв'язків між нейронами. Однак існують специфічні моделі нейронних мереж, у яких концепцію накопичення інтелектуального капіталу не можна розглядати як просте додавання навичок або досвіду. У подібних мережах вагові коефіцієнти синапсів обчислюються лише один раз на початковому етапі налаштування, ґрунтуючись на характеристиках даних, що обробляються. Після цього процес накопичення даних мережі зводиться виключно до початкового розрахунку. Такі нейронні мережі, як-от мережа Хопфілда та мережа Хеммінга, зберігають зразки ще до подачі реальних даних на їхній вхід і не мають здатності до адаптації або зміни своїх параметрів після цього етапу.

Мережі цього типу мають обмежений спектр можливостей, адже, незважаючи на можливість використовувати апріорні знання, вони не здатні адаптуватися до нових даних, оскільки позбавлені зворотного зв'язку з інтелектуальним базисом. Мережі Хопфілда та Хеммінга, завдяки своїй структурі добре вписуються в концепції організації спільної діяльності. Мережа Хопфілда, зокрема, складається з єдиного шару нейронів, кількість яких одночасно відповідає кількості входів і виходів. Усі нейрони пов'язані між собою через синапси, що дозволяє кожному з них отримувати сигнали через вхідний синапс і передавати їх далі через аксони (рис. 1.). Ці мережі, незважаючи на свої обмеження, займають важливе місце у дослідженні та розробці моделей для вирішення специфічних завдань, пов'язаних із аналізом великих даних і прогнозуванням тимчасових рядів [2].

Завдання, яке вирішується нейронною мережею в межах її функціонування як «моделі обробки великих даних і прогнозування тимчасових рядів», зазвичай формулюється таким чином: існує набір двійкових сигналів, що можуть бути представлені у вигляді зображень, оцифрованих звукових записів або інших даних, які характеризують певні об'єкти чи процеси, і які вважаються еталонними зразками [3, 8]. Основною метою мережі є здатність на основі неповного або спотвореного вхідного сигналу, поданого на її вхід, ідентифікувати відповідний еталонний зразок, якщо він присутній у пам'яті, або визначити, що вхідний сигнал не відповідає жодному із збережених зразків.




Рис. 1. Форматне структурування нейронної мережі Хопфілда для обробки великих даних і прогнозування тимчасових рядів

У загальному випадку будь-який сигнал, незалежно від його природи, може бути представлений у вигляді вектора, що відображає його основні характеристики та структуру. Для великих даних, таких як часові ряди, цей підхід дозволяє обробляти інформацію в компактній формі, забезпечуючи можливість її ефективного аналізу та використання для прогнозування. Нейронні мережі, які реалізують такі завдання, особливо актуальні у контексті обробки великих обсягів даних, де традиційні методи не завжди здатні справлятися з високою динамічністю та нелінійністю процесів. Це відкриває перспективи їх застосування для аналізу та прогнозування тимчасових рядів у сферах фінансів, медицини, енергетики та інших галузях, де точність і швидкість обробки інформації мають вирішальне значення [10].

Кожен елемент вхідного вектора x_i може мати значення або «+1», або «-1», що дозволяє описувати характеристики даних у чіткій двійковій формі. Вектор, який представляє i -й зразок, позначається як X_k , де його компоненти x_{ik} належать множині $k=0, \dots, m-1$, а m визначає загальну кількість зразків. У процесі роботи нейронна мережа, розпізнаючи або «згадуючи» конкретний зразок на основі поданих на вхід даних, формує на своїх виходах результат у вигляді точного відтворення цього зразка, тобто $Y=X_k$, де Y є вектором вихідних значень мережі.

$$X = \{ x_i : i = 0, \dots, n-1 \}, \tag{1}$$

n – кількість нейронів в мережі і розмірність вхідних і вихідних формуючих векторів.

Такий підхід має особливе значення в задачах обробки великих даних, коли необхідно працювати з великим масивом тимчасових рядів. Завдяки можливості точного визначення та відтворення характерних зразків, нейронні мережі забезпечують не лише класифікацію, але й прогнозування складних нелінійних залежностей. Вказана властивість є особливо корисною у випадках, коли необхідно виділити ключові тренди з великих масивів даних, таких як фінансові показники, метеорологічні спостереження або медичні дослідження, і використовувати їх для точного прогнозування майбутніх змін тимчасових рядів [4].

$$Y = \{ y_i : i = 0, \dots, n-1 \}. \quad (2)$$

Якщо вихідний вектор не збігається з жодним із зразкових, то мережа фактично не здатна розпізнати вхідний сигнал і створює результат, який не відповідає жодному із закладених шаблонів. Наприклад, якщо вхідні сигнали є графічними зображеннями, то дані, відтворені мережею на виході, можуть виглядати як чітке відображення одного із зразкових зображень (у разі успішного розпізнавання) або ж як неточна імпровізація, яка не має конкретного сенсу (у разі невдачі).

На етапі ініціалізації нейронної мережі налаштування вагових коефіцієнтів синапсів здійснюється за певними алгоритмами, які забезпечують початкове формування структури мережі, що формує мережі ефективно працювати з великими масивами даних і адаптуватися до завдань прогнозування тимчасових рядів. Такий підхід особливо важливий для задач, де точність і здатність мережі до розпізнавання складних патернів у великих обсягах даних є вирішальними, наприклад, у фінансовому аналізі, прогнозуванні погодних умов чи оцінці поведінки споживачів у маркетингу

$$w_{ij} = \begin{cases} \sum_{k=0}^{m-1} x_i^k x_j^k, & i \neq j, \\ 0, & i = j. \end{cases} \quad (3)$$

У моделі під індексами i та j розуміють відповідно індекси пресинаптичного та постсинаптичного нейронів, які беруть участь у передачі сигналу. Значення x_i^k , відповідають i -му та j -му елементам вектора, що описує k -й зразок даних, який використовується в процесі обробки. Такий підхід дозволяє детально моделювати зв'язки між нейронами та їхню взаємодію в процесі навчання нейронної мережі, що є важливим у задачах прогнозування тимчасових рядів. Використання таких структурних елементів у контексті великих даних дає змогу мережі адаптуватися до складних патернів і виявляти взаємозв'язки між різними елементами даних, забезпечуючи ефективність аналізу та прогнозування [13].

Процес функціонування нейронної мережі відбувається за таким алгоритмом (де через p позначається номер ітерації), коли на вхід нейронної мережі подається невідомий сигнал, який потребує обробки та аналізу і сам сигнал вводиться шляхом безпосереднього встановлення відповідних значень аксонів, що представляють початкові вхідні дані для обчислень у мережі [10]. Запропонований підхід є ключовим для задач обробки великих даних, зокрема у випадках, коли необхідно аналізувати часові ряди. Вхідний сигнал може містити велику кількість інформації, що характеризує складні процеси, і правильна ініціалізація даних є основою для подальшої роботи мережі з виявлення закономірностей і побудови прогнозів

$$y_i(0) = x_i, i = 0, \dots, n-1. \quad (4)$$

Таким чином, позначення вхідних синапсів на схемі нейронної мережі носить умовний характер і слугує лише для спрощення візуального уявлення процесу. Нуль у дужках праворуч від y_i вказує на те, що це початковий, або нульовий, етап ітеративного циклу функціонування мережі. На наступному етапі виконується розрахунок нового стану кожного нейрона в мережі, що дозволяє оновлювати їхні значення відповідно до алгоритмів навчання та взаємодії між шарами. Цей процес є фундаментальним для роботи нейронних мереж у задачах обробки великих даних і прогнозування тимчасових рядів, адже саме через поступове оновлення станів нейронів мережа здатна моделювати складні закономірності, які приховані у великих обсягах інформації [12]. Такий підхід дозволяє забезпечити точність аналізу та адаптивність до динамічних змін даних

$$s_j(p+1) = \sum_{i=0}^{n-1} w_{ij} \times y_i(p) \quad j = 0, \dots, n-1, \quad (5)$$

і нові значення аксонів в мережі

$$y_i(p+1) = f[s_j(p+1)], \quad (6)$$

де f – активаційна функція у вигляді стрибка, наведена на рис. 1.

На наступному етапі перевіряється, чи змінилися вихідні значення аксонів порівняно з попередньою ітерацією. Якщо зміни відбулися, алгоритм повертається до другого пункту для подальшого оновлення станів нейронів. Якщо ж вихідні значення стабілізувалися, процес завершується, а сформований вихідний вектор вважається зразком, який найкраще відповідає вхідним даним.

Як зазначалося раніше, інколи нейронна мережа може не впоратися із завданням розпізнавання, видаючи на виході образ, який не має відповідника серед запам'ятованих зразків. Це обмеження пов'язане з ємністю мережі, яка для мережі Хопфілда обмежується кількістю зразків mmm , що не повинна перевищувати приблизно $0,15 - n$, де n – кількість нейронів. Крім того, якщо два зразки, наприклад, A і B , мають значну схожість, мережа може створювати перехресні асоціації. У такому випадку подання на вхід мережі вектора A може призводити до формування на виході вектора B , і навпаки [5].

Коли завдання не вимагає явного формування повного образу, а достатньо лише визначити ідентифікаційний номер зразка, для реалізації асоціативної пам'яті ефективно використовується мережа Хеммінга. Ця модель у порівнянні з мережею Хопфілда потребує менших обчислювальних ресурсів і пам'яті, що пояснюється її простою структурою. Мережа Хеммінга складається з двох шарів нейронів. У кожному шарі є mmm нейронів, де mmm відповідає кількості зразків (рис. 2.). Нейрони першого шару мають по n синапсів, що підключені до входів мережі, які утворюють так званий фіктивний нульовий шар. Нейрони другого шару пов'язані між собою інгібіторними, тобто негативними зворотними, синапсами, що обмежують взаємний вплив. Крім того, кожен нейрон має позитивний зворотний зв'язок через єдиний синапс, з'єднаний із власним аксоном [14].




Рис. 2. Форматне структурування нейронної мережі Хеммінга для обробки великих даних і прогнозування тимчасових рядів

Завдяки своїй простоті та ефективності, мережа Хеммінга демонструє значний потенціал для роботи із задачами прогнозування часових рядів, де точне розпізнавання та класифікація є критично важливими для обробки великих обсягів даних.

Принцип роботи мережі Хеммінга полягає в обчисленні відстані Хеммінга між тестованим вхідним сигналом і кожним із зразкових образів, що зберігаються в пам'яті мережі. Відстань Хеммінга визначається як кількість розрядів (бітів), які відрізняються між двома бінарними векторами. Завдання мережі полягає у визначенні зразка, для якого ця відстань є мінімальною. У результаті цього процесу активується єдиний вихідний нейрон, що відповідає зразку з найменшою відстанню Хеммінга до поданого вхідного сигналу [6].

На етапі ініціалізації мережі відбувається налаштування вагових коефіцієнтів нейронів першого шару та порогових значень активаційної функції. Ці параметри визначаються згідно зі спеціальними алгоритмами, які забезпечують коректність і точність роботи мережі в процесі обробки даних. Такий підхід є надзвичайно ефективним для задач аналізу великих обсягів даних, особливо в контексті прогнозування тимчасових рядів. Мережа здатна швидко ідентифікувати ключові закономірності у вхідних даних, визначаючи найбільш релевантні зразки для подальшого аналізу, що робить її важливим інструментом для побудови моделей прогнозування в умовах складних і динамічних систем:

$$w_{ik} = \frac{x_i^k}{2} \quad i = 0, \dots, n-1, \quad k = 0, \dots, m-1, \quad (7)$$

де x_i^k – i -й елемент k -го зразка.

Вагові коефіцієнти інгібіторних (гальмівних) синапсів у другому шарі мережі Хеммінга задаються як деяке значення $0 < e < 1/m$, де m – кількість зразків. Водночас кожен нейрон у цьому шарі має позитивний синапс, пов'язаний із власним аксоном, який отримує вагу «+1».

Процес функціонування нейронної мережі Хеммінга відбувається за наступним алгоритмом: на вхід мережі подається невідомий вектор $X = \{x_i: i = 0, \dots, n-1\}$, де n – кількість компонент вектора. На основі цього вхідного сигналу виконуються обчислення станів нейронів першого шару, які представляють собою проміжні результати для подальшої обробки. У позначеннях індекси в дужках вказують на номер шару, до якого належать нейрони. Наведений алгоритм є основою роботи мережі Хеммінга, яка демонструє високу ефективність в обробці великих обсягів даних. Застосування цієї моделі особливо актуальне для задач прогнозування тимчасових рядів, адже вона дозволяє швидко ідентифікувати та класифікувати вхідні сигнали, забезпечуючи високу точність і швидкість обчислень, що є критичними у сучасних умовах аналізу даних.

$$s_j(p+1) = \sum_{i=0}^{n-1} w_{ij} y_i(p), \quad j = 0, \dots, n-1. \quad (8)$$

Після завершення розрахунків станів нейронів першого шару отримані значення використовуються для ініціалізації аксонів другого шару [9]. Цей процес забезпечує передачу обробленої інформації на наступний етап роботи мережі, що є важливим кроком у формуванні остаточних результатів.

Такий механізм передачі даних між шарами нейронної мережі дозволяє адаптуватися до специфіки вхідної інформації та забезпечувати точність обробки великих обсягів даних, особливо у випадках прогнозування тимчасових рядів. Завдяки

цьому мережа здатна моделювати складні залежності та виявляти ключові закономірності, які є основою для прийняття рішень або формування прогнозів.

$$y_j^{(2)} = y_j^{(1)}, j = 0, \dots, m-1. \quad (9)$$

2. Визначаються нові стани очікуваних нейронів другого шару

$$s_j^{(2)}(p+1) = y_j(p) - \varepsilon \sum_{k=0}^{m-1} y_k^{(2)}, k \neq j; o = 0, \dots, m-1, \quad (10)$$

і показники відповідних аксонів

$$y_j^{(2)}(p+1) = f[s_j^{(2)}(p+1)], j = 0, \dots, m-1. \quad (11)$$

Активаційна функція f у даній моделі має форму порогу, як показано на рис. 2., причому значення порогу F повинно бути достатньо великим, щоб уникнути насичення для будь-яких можливих значень аргументу. На наступному етапі алгоритму перевіряється, чи змінилися вихідні значення нейронів другого шару у порівнянні з попередньою ітерацією. Якщо зміни відбулися, алгоритм повертається до другого кроку для оновлення станів мережі. В іншому випадку процес завершується.

5 ОБГОВОРЕННЯ РЕЗУЛЬТАТІВ ДОСЛІДЖЕННЯ

З аналізу алгоритму видно, що роль першого шару носить умовний характер: значення вагових коефіцієнтів використовуються лише на першому кроці, після чого мережа більше до них не звертається. Це дозволяє замінити перший шар матрицею вагових коефіцієнтів без шкоди для функціональності. У реальних умовах, коли вхідні дані змінюються динамічно і мережа, ймовірно, ніколи не отримає однаковий вектор двічі, може виникнути ситуація, за якої ваги мережі постійно змінюються, не досягаючи стабільності. У таких випадках мережа втрачає здатність накопичувати інтелектуальний капітал або знання, що робить її роботу менш ефективною. Додатково існують приклади мереж, в яких навіть чотири циклічно подані вектори можуть викликати безперервні зміни ваг, що призводить до процесу, який не сходиться. Ця тимчасова нестабільність стала однією з ключових причин розробки альтернативних конфігурацій нейронних мереж, здатних забезпечувати стабільність у навчанні.

З метою розв'язання проблеми балансу між стабільністю та пластичністю, зв'язки, що йдуть зверху вниз, відіграють вирішальну роль. Вони дозволяють фокусувати увагу мережі та запобігати деградації пам'яті під впливом сторонніх сигналів. Процес обробки інформації починається з моменту, коли сенсорний вхід активує короткочасну пам'ять, систему уваги та орієнтації. Вхідний сигнал представлений у вигляді патерну активності в першому шарі короткочасної пам'яті. Поки цей патерн залишається подібним до вхідного, система орієнтації залишається неактивною через баланс між стимулюючим сигналом і гальмівними впливами короткочасної пам'яті.

Зв'язки, які йдуть від нижніх шарів до верхніх і зберігають довготривалу пам'ять у вигляді вагових коефіцієнтів, впливають на елементи другого шару. Ці елементи кодують класи, а їхня активація відбувається, коли патерн короткочасної пам'яті в першому шарі найбільшою мірою відповідає характеристикам класу, записаним у довготривалій пам'яті. Таким чином, мережа здатна ефективно класифікувати дані та забезпечувати високоточне прогнозування на основі великого обсягу тимчасових рядів.

6 ВИСНОВКИ

У ході дослідження було детально вивчено функціонування нейронних мереж, зокрема таких моделей, як мережа Хопфілда та мережа Хеммінга, які і відзначаються здатністю зберігати еталонні зразки шляхом попередньої ініціалізації, проте мають обмеження в адаптації до змінюваних умов через відсутність механізму зворотного зв'язку з базою знань. Оцінено, що використання принципу мінімізації відстані Хеммінга є ефективним для ідентифікації зразків, найбільш подібних до вхідного сигналу, особливо у двійкових даних. Разом із тим виявлено, що при високій подібності між зразками можливе виникнення перехресних асоціацій, що потребує додаткової оптимізації архітектури мережі для усунення таких явищ.

Обґрунтовано доцільність впровадження структурних змін у нейронних мережах, які дозволяють досягти балансу між їхньою стабільністю та пластичністю. Зокрема, було запропоновано замінити окремі шари мережі матрицями вагових коефіцієнтів, що забезпечує зниження обчислювальних витрат та підвищення ефективності без втрати точності отриманих результатів. Розроблено рекомендації для створення нейронних мереж із покращеною стабільністю, які зберігають накопичені знання та захищають пам'ять від зовнішніх впливів, що сприяє ефективності їх використання в умовах змінюваних середовищ. Запропоновано підхід до обробки інформації, який базується на активації короткочасної пам'яті, інтеграції системи уваги та використанні довготривалих зв'язків, що підвищує точність ідентифікації класів даних у задачах прогнозування тимчасових рядів і сприяє вдосконаленню моделей для аналізу великих обсягів інформації.

7 ЕТИЧНІ ДЕКЛАРАЦІЇ

Автори не мають будь-яких фінансових чи нефінансових інтересів щодо матеріалів, представлених у цій статті, які слід розкривати.

Література

1. Дзямулич М. І., Шматковська Т. О., Борисюк О. В. Великі дані та їх роль у формуванні цифрової економіки. Галицький економічний вісник. 2021. №70(3). С. 16-21.
2. Коротун Н. В. Сучасна модель інформаційного аналітика в умовах розвитку BigData в Україні. Інформаційні технології і системи в документознавчій сфері. 2024. С. 52-54.
3. Македон В. В., Маковецька А. О. Інформаційне забезпечення економічної безпеки підприємств в умовах ринкової нестабільності. Міжнародний науковий журнал "Інтернаука". Серія: "Економічні науки". 2023. №12. URL: <https://www.inter-nauka.com/issues/economic2023/12/9477>. <https://doi.org/10.25313/2520-2294-2023-12-9477>.
4. Усата О. Ю., Іванов Д. Є. Великі дані та основи роботи з ними. Актуальні питання сучасної інформатики. 2024. №11. С. 57-59.
5. Hewamalage H., Bergmeir C., Bandara K. Recurrent Neural Networks for Time Series Forecasting: Current Status and Future Directions. *International Journal of Forecasting*. 2020. No 36(3). pp. 388–427. <https://doi.org/10.1016/j.ijforecast.2020.06.008>.
6. Huang Q., Zhou Z., Yang K., Lin G., Yi Z., Wang Y. LeRet: Language-Empowered Retentive Network for Time Series Forecasting. *Proceedings of the Thirty-Third International Joint Conference on Artificial Intelligence*. 2024. pp. 4165–4173. <https://doi.org/10.24963/ijcai.2024/460>.
7. Inkin O.A., Pohorielov O.V. EEG simulation using deep neural networks. *System Technologies*. 2024. No 3. pp. 57–68. <https://doi.org/10.34185/1562-9945-3-152-2024-06>.
8. Makedon V., Budko O., Salyga K., Myachin V., Fisunen N. Improving Strategic Planning and Ensuring the Development of Enterprises Based on Relational Strategies. *Theoretical And Practical Research In Economic Fields*. 2024. No 15(4). pp. 798-811. doi:10.14505/tpref.v15.4(32).02.

9. McAfee A., Brynjolfsson E. *Machine, Platform, Crowd: Harnessing Our Digital Future*. New York: W.W. Norton & Company, 2017. 340 p.
10. Pajak K., Omelyanenko V., Makedon V., Shevchenko V., Ovcharenko I. Raising the level of financial security of the enterprise based on the basic risks differentiation. *Journal of Security and Sustainability Issues*. 2020. No 10(1). pp. 115-130. [https://doi.org/10.9770/jssi.2020.10.1\(9\)](https://doi.org/10.9770/jssi.2020.10.1(9)).
11. Shelukhin M., Kupriichuk V., Kyrylko N., Makedon V., Chupryna N. Entrepreneurship Education with the Use of a Cloud-Oriented Educational Environment. *International Journal of Entrepreneurship*. 2021. Volume 25. Issue 6. URL: <https://www.abacademies.org/articles/entrepreneurship-education-with-the-use-of-a-cloudoriented-educational-environment-11980.html>.
12. Tealab A. Time Series Forecasting using Artificial Neural Networks Methodologies: A Systematic Review. *Future Computing and Informatics Journal*. 2018. No 3. pp. 10–20. <https://doi.org/10.1016/j.fcij.2018.10.003>.
13. Shakir A., Staegemann D., Volk M., Jamous N., Turowski K. Towards a concept for building a big data architecture with microservices. *Business Information Systems*. 2021. pp. 83–94.
14. Valenzuela O., Rojas F., Herrera L. J., Pomares H., Rojas I. New Advances and Methodologies in the Field of Time Series and Forecasting ITISE-2024. *Engineering Proceedings*. 2024. Vol. 68(1). p. 67. <https://doi.org/10.3390/engproc2024068067>.
15. Zhang M., Chen Y. Link prediction based on graph neural networks. *Advances in Neural Information Processing Systems*. 32nd Conference on Neural Information Processing Systems (NeurIPS 2018). Montréal, Canada, 2018.
16. Zhang L., Wang R., Li Z., Li J., Ge Y., Wa S., Huang S., Lv C. Time-Series Neural Network: A High-Accuracy Time-Series Forecasting Method Based on Kernel Filter and Time Attention. *Information*. 2023. Vol. 14(9). pp. 500. <https://doi.org/10.3390/info14090500>.

References

1. Dziamulich, M. I., Shmatkovska, T. O., Borysiuk, O. V. (2021). Velyki dani ta yikh rol u formuvanni tsyfrovoy ekonomiky [Big data and their role in the formation of the digital economy]. *Halytskyi ekonomichnyi visnyk*, 70(3), 16–21.
2. Korotun, N. V. (2024). Suchasna model informatsiynoho analityka v umovakh rozvytku BigData v Ukraini [Modern model of an information analyst in the context of BigData development in Ukraine]. *Informatsiini tekhnolohii i systemy v dokumentoznavchii sferi*, 2024, 52–54.
3. Makedon, V. V., Makovetska, A. O. (2023). Informatsiine zabezpechennia ekonomichnoi bezpeky pidpriemstv v umovakh rynkovoi nestabilnosti [Information support for economic security of enterprises under market instability]. *Mizhnarodnyi naukovi zhurnal "Internauka"*. Seriya: "Ekonomichni nauky", 12. URL: <https://www.inter-nauka.com/issues/economic2023/12/9477>. DOI: <https://doi.org/10.25313/2520-2294-2023-12-9477>. [in Ukrainian].
4. Usata, O. Yu., Ivanov, D. Ye. (2024). Velyki dani ta osnovy roboty z nymy [Big data and basics of working with them]. *Aktualni pytannia suchasnoi informatyky*, 11, 57–59.
5. Hewamalage, H., Bergmeir, C., & Bandara, K. (2020). Recurrent Neural Networks for Time Series Forecasting: Current Status and Future Directions. *International Journal of Forecasting*, 36(3), 388-427. <https://doi.org/10.1016/j.ijforecast.2020.06.008>.
6. Huang, Q., Zhou, Z., Yang, K., Lin, G., Yi, Z., & Wang, Y. (2024). LeRet: Language-Empowered Retentive Network for Time Series Forecasting. *Proceedings of the Thirty-Third International Joint Conference on Artificial Intelligence*, 4165–4173. <https://doi.org/10.24963/ijcai.2024/460>.
7. Inkin O.A., & Pohorielov O.V., (2024). EEG simulation using deep neural networks. *System technologies*. 3. 57-68. 10.34185/1562-9945-3-152-2024-06.
8. Makedon, V., Budko, O., Salyga, K., Myachin, V., & Fisunenko, N. (2024). Improving Strategic Planning and Ensuring the Development of Enterprises Based on Relational Strategies. *Theoretical And Practical Research In Economic Fields*, 15(4), 798-811. doi:10.14505/tpref.v15.4(32).02
9. McAfee, A., & Brynjolfsson, E. (2017) *Machine, Platform, Crowd: Harnessing Our Digital Future*. New York: W.W. Norton & Company.

10. Pajak, K., Omelyanenko, V., Makedon, V., Shevchenko, V., Ovcharenko, I. (2020). "Raising the level of financial security of the enterprise based on the basic risks differentiation", Journal of Security and Sustainability Issues, №10 (1), 115-130. [https://doi.org/10.9770/jssi.2020.10.1\(9\)](https://doi.org/10.9770/jssi.2020.10.1(9)).
11. Shakir, A., Staegemann, D., Volk, M., Jamous, N., Turowski, K. (2021). "Towards a concept for building a big data architecture with microservices", Business Information Systems, pp. 83–94.
12. Shelukhin, M., Kupriichuk, V., Kyrylko, N., Makedon, V., Chupryna, N. (2021). Entrepreneurship Education with the Use of a Cloud-Oriented Educational Environment. International Journal of Entrepreneurship. Volume 25, Issue 6. URL: <https://www.abacademies.org/articles/entrepreneurship-education-with-the-use-of-a-cloudoriented-educational-environment-11980.html>.
13. Tealab, Ahmed. (2018). Time Series Forecasting using Artificial Neural Networks Methodologies: A Systematic Review. Future Computing and Informatics Journal. 3. 10.1016/j.fcij.2018.10.003.
14. Valenzuela, O., Rojas, F., Herrera, L. J., Pomares, H., & Rojas, I. (2024). New Advances and Methodologies in the Field of Time Series and Forecasting ITISE-2024. Engineering Proceedings, 68(1), 67. <https://doi.org/10.3390/engproc2024068067>.
15. Zhang, M. and Chen, Y. (2018). Link prediction based on graph neural networks. Advances in Neural Information Processing Systems. 32nd Conference on Neural Information Processing Systems (NeurIPS 2018), Montréal, Canada.
16. Zhang, L., Wang, R., Li, Z., Li, J., Ge, Y., Wa, S., Huang, S., & Lv, C. (2023). Time-Series Neural Network: A High-Accuracy Time-Series Forecasting Method Based on Kernel Filter and Time Attention. Information, 14(9), 500. <https://doi.org/10.3390/info14090500>

Клименко Олександр Вікторович

TEAM International,
старший розробник програмного забезпечення,
US, Lake Mary, 1145 TownPark Avenue, Suite 2201
alexanderklmn@gmail.com
ORCID:0009-0000-5924-3697

Сухомлинова Олена Валеріївна

Військовий інститут телекомунікацій та інформатизації імені Героїв Крут,
старший викладач,
вул. Князів Острозьких, 45/1, м. Київ, Україна, 01011
osukhomlynova@gmail.com
ORCID:0000-0001-7592-7255

Кравченко Вікторія Валеріївна

Військовий інститут телекомунікацій та інформатизації імені Героїв Крут,
викладач,
вул. Князів Острозьких, 45/1, м. Київ, Україна, 01011
elzkravchenko@ukr.net
ORCID:0000-0003-0399-7013

Для посилань:

Клименко О. В., Сухомлинова О. В., Кравченко В. В. Методи обробки великих даних і прогнозування тимчасових рядів за допомогою нейронних мереж. Механіка та математичні методи, 2025. Т. VII. №. 1. С. 103–114.

For references:

O. Klymenko, O. Sukhomlynova, V. Kravchenko. (2025). Methods of processing big data and forecasting time series using neural networks . Mechanics and Mathematical Methods. VII (1). 103–114.