

Серденко Т.В.,

к. ф.-м. н., доцент кафедри системного аналізу та кібербезпеки,
Київський національний економічний університет імені Вадима
Гетьмана

Левчук О.М.,

к. т. н., завідувач кафедри інформаційних управляючих систем та
технологій, Ужгородський національний університет

Serdenko T.V.,

Candidate of Physical and Mathematical Sciences,
Associate Professor of the Department of System Analysis and
Cybersecurity,
Kyiv National Economic University named after Vadym Hetman

Levchuk O.M.,

Candidate of Technical Sciences,
Head of the Department of Information Control Systems and Technologies,
Uzhhorod National University

ВЕЙВЛЕТ-АНАЛІЗ ЯК ІНСТРУМЕНТ ПІДВИЩЕННЯ ЕФЕКТИВНОСТІ МОДЕЛЕЙ ШТУЧНОГО ІНТЕЛЕКТУ

WAVELET ANALYSIS AS A TOOL FOR IMPROVING THE EFFICIENCY OF ARTIFICIAL INTELLIGENCE MODELS

Анотація. У статті представлено комплексний огляд вейвлет-аналізу як ефективного математичного інструменту для покращення продуктивності моделей штучного інтелекту (ШІ). Матеріали статті мають науково-методологічний та оглядовий характер і спрямовані на систематизацію сучасних підходів до застосування вейвлет-перетворень в інтелектуальному аналізі даних. Сучасні системи ШІ працюють з великими обсягами складних і часто нестационарних даних, включаючи часові ряди, сигнали та зображення, що вимагає передових методів попередньої обробки та вилучення ознак. Традиційні підходи, такі як спектральний аналіз на основі Фур'є, обмежені у своїй здатності фіксувати локальні характеристики сигнали як у часовій, так і в частотній областях. У цьому контексті вейвлет-перетворення забезпечує потужну альтернативу, дозволяючи проводити багатомасштабний аналіз та одночасну локалізацію ознак даних. У статті розглядаються теоретичні основи вейвлет-аналізу, включаючи неперервні та дискретні вейвлет-перетворення, а також багатороздільний аналіз. Особлива увага приділяється здатності вейвлет-методів розкладати сигнали на компоненти різних частотних діапазонів, що дозволяє ідентифікувати як глобальні тенденції, так і локальні коливання. Ця властивість робить вейвлет-аналіз особливо корисним для обробки зашумлених, нелінійних та нестационарних даних. Дослідження зосереджене на інтеграції вейвлет-методів у сучасні технології штучного інтелекту. Зокрема, аналізується використання вейвлет-перетворень для попередньої обробки даних, зменшення шуму, вилучення ознак та зменшення розмірності. У статті також розглядаються

новітні підходи, які безпосередньо включають вейвлет-операції в архітектурі машинного та глибокого навчання, включаючи згорткові нейронні мережі (CNN), рекурентні нейронні мережі (RNN) та моделі на основі трансформаторів. Такі гібридні підходи демонструють покращення стійкості, кращі можливості узагальнення та вищу точність прогнозування. Особлива увага приділяється застосуванню вейвлет-аналізу в моделюванні часових рядів, зокрема в економічній та фінансовій сферах, де дані демонструють багатомасштабну поведінку та складну динаміку. Декомпозиція на основі вейвлетів дозволяє точніше моделювати та прогнозувати, ізольовуючи шаблони на різних часових масштабах. Результати дослідження підтверджують, що вейвлет-аналіз є потужним та універсальним інструментом для підвищення ефективності моделей штучного інтелекту. Поєднання багатомасштабної обробки сигналів та інтелектуальних алгоритмів відкриває нові перспективи для розробки передових методів аналізу даних. Майбутні напрямки досліджень включають розробку адаптивних нейронних архітектур на основі вейвлетів та застосування вейвлет-методів у великих даних та системах штучного інтелекту реального часу.

Ключові слова: вейвлет-аналіз; штучний інтелект; машинне навчання; глибоке навчання; часові ряди; вилучення ознак; обробка сигналів; багатороздільний аналіз.

Abstract. The article presents a comprehensive review of wavelet analysis as an effective mathematical tool for improving the performance of artificial intelligence (AI) models. The materials of the paper are of a scientific-methodological and review nature and are aimed at systematizing modern approaches to the application of wavelet transforms in intelligent data analysis. Modern AI systems operate on large volumes of complex and often non-stationary data, including time series, signals, and images, which require advanced methods for preprocessing and feature extraction. Traditional approaches, such as Fourier-based spectral analysis, are limited in their ability to capture local characteristics of signals in both time and frequency domains. In this context, wavelet transform provides a powerful alternative by enabling multiscale analysis and simultaneous localization of data features. The theoretical foundations of wavelet analysis, including continuous and discrete wavelet transforms, as well as multiresolution analysis, are examined in the paper. Particular attention is given to the ability of wavelet methods to decompose signals into components of different frequency ranges, which allows for the identification of both global trends and local fluctuations. This property makes wavelet analysis especially useful for handling noisy, nonlinear, and non-stationary data. The study focuses on the integration of wavelet-based techniques into modern artificial intelligence technologies. Specifically, the use of wavelet transforms for data preprocessing, noise reduction, feature extraction, and dimensionality reduction is analyzed. The paper also reviews recent approaches that incorporate wavelet operations directly into machine learning and deep learning architectures, including convolutional neural networks (CNNs), recurrent neural networks (RNNs), and transformer-based models. Such hybrid approaches demonstrate improved robustness, better generalization capabilities, and higher prediction accuracy. Special attention is paid to the application of wavelet analysis in time series modeling, particularly in economic and financial domains, where data exhibit multiscale behavior and complex dynamics. Wavelet-based decomposition enables more accurate modeling and forecasting by isolating patterns at different temporal scales. The results of the study confirm that wavelet analysis is a powerful and versatile tool for enhancing the efficiency of AI models. The combination of multiscale signal processing and intelligent algorithms opens new perspectives for the development of advanced data analysis methods. Future research directions include the development of adaptive wavelet-based

neural architectures and the application of wavelet techniques in big data and real-time AI systems.

Keywords: *wavelet analysis; artificial intelligence; machine learning; deep learning; time series; feature extraction; signal processing; multiresolution analysis.*

Постановка проблеми. Сучасний розвиток технологій штучного інтелекту супроводжується стрімким зростанням обсягів даних, що характеризуються складною структурою, нестаціонарністю та наявністю шумових компонентів. Такі дані широко використовуються у задачах економічного аналізу, фінансового прогнозування, обробки сигналів і зображень, а також у біомедичних і технічних системах. Особливістю сучасних інформаційних потоків є їх багатовимірність, нелінійність і наявність прихованих закономірностей, що ускладнює процес їх аналізу та інтерпретації. У зв'язку з цим підвищується роль методів, здатних ефективно працювати з даними, які змінюються у часі та містять неоднорідні компоненти.

Ефективність моделей штучного інтелекту значною мірою залежить від якості попередньої обробки даних та формування інформативних ознак, які відображають суттєві характеристики досліджуваних процесів. Недостатньо якісне представлення даних може призводити до зниження точності моделей, втрати важливої інформації та зростання впливу шумів. Тому одним із ключових завдань сучасних досліджень у галузі штучного інтелекту є розроблення ефективних методів аналізу даних, які забезпечують виділення релевантних ознак і підвищення стійкості моделей до зовнішніх впливів.

Традиційні методи аналізу, зокрема перетворення Фур'є, мають обмеження при дослідженні нестаціонарних процесів, оскільки вони забезпечують лише глобальне представлення сигналу у частотній області та не дозволяють визначити часову локалізацію окремих його компонентів. Це суттєво обмежує їх використання у задачах, де важливо враховувати зміну характеристик сигналу в часі. У зв'язку з цим виникає необхідність застосування більш гнучких методів аналізу, здатних враховувати як часову, так і частотну структуру даних.

Одним із таких методів є вейвлет-аналіз, який забезпечує можливість багатомасштабного представлення сигналів і дозволяє досліджувати їх локальні особливості на різних рівнях деталізації. Вейвлет-перетворення дозволяє одночасно аналізувати сигнал у часовій і частотній областях, що робить його ефективним інструментом для роботи з нестаціонарними даними. Завдяки цьому він

знаходить широке застосування у задачах обробки сигналів, аналізу часових рядів та інтелектуального аналізу даних.

З огляду на це, особливої актуальності набуває дослідження можливостей використання вейвлет-перетворень у технологіях штучного інтелекту, зокрема у контексті підвищення ефективності моделей машинного навчання та глибоких нейронних мереж. Інтеграція вейвлет-аналізу у сучасні алгоритми штучного інтелекту відкриває нові перспективи для підвищення якості обробки даних, покращення процесу виділення ознак і забезпечення більш точного моделювання складних динамічних процесів.

Аналіз останніх досліджень і публікацій. Теоретичні основи вейвлет-аналізу були сформовані у фундаментальних працях I. Daubechies та S. Mallat, які заклали математичний апарат багатомасштабного аналізу сигналів і визначили основні принципи побудови вейвлет-базисів [2; 9]. У цих роботах було показано, що вейвлет-перетворення забезпечує локалізацію сигналу як у часовій, так і у частотній областях, що є принциповою перевагою порівняно з класичними методами спектрального аналізу. Подальший розвиток цих ідей привів до формування концепції багатомасштабного аналізу, яка стала основою для сучасних методів обробки сигналів і даних.

Значний внесок у розвиток методів аналізу часових рядів за допомогою вейвлет-перетворень зроблено у працях Percival і Walden, а також Nason, де розглянуто статистичні властивості вейвлет-коефіцієнтів і продемонстровано їх ефективність у задачах аналізу нестационарних процесів [10; 11]. Зокрема, показано, що вейвлет-методи дозволяють виділяти структурні компоненти сигналу на різних часових масштабах, що є важливим для аналізу складних динамічних систем.

У сфері економіки та фінансів вейвлет-аналіз активно застосовується для дослідження багатомасштабної динаміки економічних процесів. У роботах Gençay, Selçuk та Whitcher показано, що використання вейвлет-перетворень дозволяє виявляти залежності між економічними показниками на різних часових інтервалах, що сприяє більш точному моделюванню та прогнозуванню [5]. Це особливо актуально для аналізу фінансових ринків, де дані характеризуються високою волатильністю та складною структурою.

Сучасний етап розвитку досліджень характеризується активною інтеграцією вейвлет-аналізу у технології штучного інтелекту. Зокрема, у роботі Bruna та Mallat запропоновано scattering transform, який поєднує ідеї вейвлет-аналізу та згорткових нейронних мереж і дозволяє отримувати інваріантні до зсувів представ-

лення даних [1]. Цей підхід став одним із перших прикладів глибокої інтеграції вейвлетних методів у сучасні архітектури машинного навчання.

Подальший розвиток цього напрямку представлений у роботах, присвячених використанню вейвлет-перетворень у згорткових нейронних мережах. У дослідженні Li та співавт. запропоновано архітектуру WaveCNet, яка поєднує дискретне вейвлет-перетворення зі згортковими операціями, що дозволяє зменшити ефект аліасингу та підвищити стійкість моделей до шумів [7]. Аналогічні підходи розглядаються у роботах Fujieda та співавт., де вейвлет-перетворення використовується для покращення процесу виділення ознак у нейронних мережах [4].

Окрему увагу слід приділити дослідженням, присвяченим використанню вейвлетних методів у процедурах downsampling та pooling. У роботі Wang та співавт. запропоновано метод learnable wavelet pooling, який дозволяє інтегрувати вейвлет-перетворення безпосередньо у структуру нейронної мережі [12]. Подальший розвиток цієї ідеї представлено у роботі Wolter і Garcke, де запропоновано адаптивні методи вейвлет-пулінгу, що забезпечують покращення якості узагальнення інформації [13].

Важливим напрямом сучасних досліджень є використання вейвлет-аналізу для задач обробки зображень і сигналів. У роботі Liu та співавт. розглядається використання вейвлетних мереж для де-нойзингу зображень, що дозволяє досягти високої якості відновлення сигналів [8]. Подібні результати отримано у дослідженні Frusque і Fink, де показано ефективність вейвлет-пакетного перетворення у задачах очищення часових рядів від шумів [3].

Сучасні дослідження також демонструють перспективність використання вейвлет-аналізу у поєднанні з новітніми архітектурами штучного інтелекту. Зокрема, у роботі Korkmaz і Tekalp показано, що використання вейвлетних функцій втрат у трансформерних моделях дозволяє підвищити якість реконструкції зображень [6]. Це свідчить про можливість використання вейвлетних методів не лише на етапі попередньої обробки даних, але й у процесі навчання моделей.

Окрім цього, перспективним напрямом є використання вейвлетних підходів у графових нейронних мережах. У роботі Zheng та співавт. показано, що застосування фреймлетів дозволяє покращити якість представлення графових структур і підвищити ефективність моделей [15].

Узагальнення сучасних досліджень представлено у роботі Wu та співавт., де проведено систематичний огляд підходів до

інтеграції вейвлет-аналізу у глибокі нейронні мережі [14]. Автори підкреслюють, що поєднання вейвлетних методів із сучасними алгоритмами машинного навчання є перспективним напрямом, який дозволяє підвищити ефективність моделей та розширити можливості аналізу даних.

Таким чином, аналіз сучасних наукових публікацій свідчить про активний розвиток досліджень у напрямі інтеграції вейвлет-аналізу у технології штучного інтелекту. Вейвлет-перетворення розглядається як ефективний інструмент формування ознак, зменшення шуму та підвищення якості моделей, що підтверджує його значний потенціал для подальших досліджень і практичних застосувань.

Виділення невирішених раніше частин проблеми. Незважаючи на значну кількість досліджень, питання систематизації підходів до використання вейвлет-аналізу у технологіях штучного інтелекту залишається недостатньо розробленим. Більшість наукових праць присвячена окремим прикладним аспектам, тоді як комплексний аналіз ролі вейвлет-перетворень у формуванні ознак та інтеграції у моделі машинного навчання потребує подальшого дослідження. Це зумовлює необхідність узагальнення сучасних підходів і визначення перспективних напрямів розвитку.

Основною метою статті є узагальнення сучасних підходів до застосування вейвлет-аналізу у технологіях штучного інтелекту, аналіз можливостей його використання для підвищення ефективності моделей машинного навчання та визначення перспектив подальшого розвитку цього напрямку досліджень.

Виклад основного матеріалу. Сучасні системи штучного інтелекту функціонують у середовищі, де дані характеризуються високою складністю, багатовимірністю, нестаціонарністю та наявністю шумових компонентів. Такі властивості даних створюють суттєві труднощі для побудови ефективних моделей машинного навчання, оскільки класичні методи аналізу часто не здатні адекватно відобразити їхню структуру. У цьому контексті особливого значення набувають методи багатомасштабного аналізу, серед яких вейвлет-аналіз займає провідне місце [9].

Вейвлет-аналіз базується на представленні сигналу у вигляді лінійної комбінації базисних функцій, що отримуються шляхом масштабування та зсуву материнського вейвлета. Такий підхід дозволяє здійснювати локалізований аналіз сигналу як у часовій, так і у частотній областях, що є принциповою перевагою порівняно з класичними методами спектрального аналізу, такими як перетворення Фур'є [2].

Безперервне вейвлет-перетворення сигналу $x(t)$ визначається інтегральним співвідношенням

$$W(a, b) = \frac{1}{\sqrt{|a|}} \int_{-\infty}^{\infty} x(t) \psi^* \left(\frac{t-b}{a} \right) dt,$$

де a – параметр масштабу, b – параметр зсуву, $\psi(t)$ – материнський вейвлет. Нормуючий множник $\frac{1}{\sqrt{|a|}}$ забезпечує збереження енергії сигналу при зміні масштабу. Це перетворення дозволяє аналізувати сигнал у широкому діапазоні частот та виявляти локальні особливості його структури.

Інверсне вейвлет-перетворення має вигляд

$$x(t) = \frac{1}{C_\psi} \int_0^\infty \int_{-\infty}^\infty W(a, b) \psi_{a,b}(t) \frac{dad b}{a^2},$$

де C_ψ — константа допустимості вейвлета, яка визначається як

$$C_\psi = \int_0^\infty \frac{|\hat{\psi}(\omega)|^2}{\omega} d\omega < \infty.$$

Ця умова забезпечує можливість відновлення сигналу за його вейвлет-коефіцієнтами.

У практичних застосуваннях використовується дискретне вейвлет-перетворення, яке реалізується через фільтрування сигналу. На кожному рівні декомпозиції сигнал розкладається на дві складові:

$$A_j(k) = \sum_n x(n)h(2k-n), D_j(k) = \sum_n x(n)g(2k-n),$$

де $A_j(k)$ — апроксимаційні коефіцієнти, $D_j(k)$ — деталізуючі коефіцієнти [11].

Багаторівнева декомпозиція сигналу здійснюється рекурсивно, що дозволяє отримати представлення сигналу у вигляді

$$x(t) = A_J(t) + \sum_{j=1}^J D_j(t),$$

де J — кількість рівнів декомпозиції.

Це представлення лежить в основі багатомасштабного аналізу, який дозволяє досліджувати сигнал на різних рівнях деталізації. Важливим аспектом є те, що кожен рівень відповідає певному частотному діапазону, що дозволяє виділяти як низькочастотні тренди, так і високочастотні коливання.

У контексті штучного інтелекту багатомасштабний аналіз відіграє ключову роль у формуванні ознак. Зокрема, вейвлет-коефіцієнти можуть використовуватися як вхідні параметри для моделей машинного навчання, що дозволяє підвищити їхню точність та стійкість до шумів [8].

Важливим напрямом розвитку є використання енергетичних характеристик сигналу у вейвлет-області. Енергія сигналу на рівні j визначається як

$$E_j = \sum_k |D_j(k)|^2,$$

що дозволяє оцінювати вклад різних частотних компонентів у загальну структуру сигналу. Такі характеристики широко використовуються у задачах класифікації та діагностики.

Окрему увагу слід приділити вейвлет-пакетному перетворенню, яке є узагальненням дискретного вейвлет-перетворення. На відміну від класичного підходу, де декомпозиція застосовується лише до апроксимаційної складової, у вейвлет-пакетному перетворенні розкладаються як апроксимаційні, так і деталізуючі компоненти. Це дозволяє отримати більш гнучке представлення сигналу:

$$\begin{aligned} W_{j+1}^{2n}(k) &= \sum_m h(m - 2k) W_j^n(m), W_{j+1}^{2n+1}(k) = \\ &= \sum_m g(m - 2k) W_j^n(m). \end{aligned}$$

Таке представлення дозволяє більш точно адаптуватися до структури даних і широко використовується у задачах машинного навчання.

У сучасних системах штучного інтелекту вейвлет-аналіз використовується на різних етапах обробки даних. На етапі попередньої обробки він дозволяє виконувати фільтрацію сигналів і зменшення шуму. Це є важливим для підвищення якості навчання моделей, оскільки шум може суттєво впливати на результати прогнозування [3].

На етапі формування ознак вейвлет-аналіз дозволяє отримати багатовимірне представлення даних, що включає інформацію про їхню структуру на різних масштабах. Це особливо важливо для задач класифікації, де необхідно враховувати як глобальні, так і локальні характеристики сигналу.

Інтеграція вейвлет-перетворень у нейронні мережі є одним із найбільш перспективних напрямів сучасних досліджень. Зокрема, у згорткових нейронних мережах вейвлет-перетворення може використовуватися як альтернатива операціям pooling. Це дозволяє зменшити втрати інформації та покращити якість представлення ознак [7].

У роботах Wolter і Garcke запропоновано адаптивні методи вейвлет-пулінгу, які дозволяють динамічно змінювати параметри перетворення залежно від структури даних [13]. Це забезпечує більш ефективне узагальнення інформації та підвищує точність моделей.

Важливим напрямом є також використання вейвлет-аналізу у трансформерних архітектурах. Сучасні дослідження показують, що використання вейвлетних представлень дозволяє покращити обробку довгих часових залежностей і підвищити ефективність моделей [6].

У задачах аналізу часових рядів вейвлет-аналіз дозволяє розкладати сигнал на компоненти різних масштабів, що відповідають різним часовим інтервалам. Це дозволяє окремо аналізувати довгострокові тренди, середньострокові коливання та короткочасні флуктуації [5].

Окрім цього, вейвлет-аналіз використовується для зменшення розмірності даних. Відбір найбільш інформативних коефіцієнтів дозволяє зменшити обсяг даних без втрати суттєвої інформації, що є важливим для задач обробки великих даних.

Сучасні дослідження також демонструють перспективність використання вейвлет-методів у графових нейронних мережах, де вони дозволяють ефективно враховувати структуру графових даних [15].

Таким чином, вейвлет-аналіз є універсальним інструментом обробки даних, який поєднує математичну строгість та практичну ефективність. Його інтеграція у технології штучного інтелекту відкриває нові можливості для підвищення ефективності моделей, покращення якості аналізу даних та створення більш точних систем прогнозування.

Висновки та перспективи подальших досліджень. У статті здійснено узагальнення сучасних підходів до використання вейвлет-аналізу у технологіях штучного інтелекту. Показано, що

вейвлет-перетворення є ефективним інструментом багатомасштабного аналізу сигналів і часових рядів, який дозволяє підвищити якість попередньої обробки даних та ефективність моделей машинного навчання.

Встановлено, що інтеграція вейвлет-перетворень у структуру нейронних мереж сприяє покращенню процесу виділення ознак, зменшенню впливу шумів і підвищенню точності прогнозування. Використання багатомасштабного аналізу дозволяє більш повно враховувати структуру даних і забезпечує підвищення стійкості моделей штучного інтелекту.

Перспективи подальших досліджень пов'язані з розробленням адаптивних вейвлетних моделей, інтеграцією вейвлет-перетворень у сучасні архітектури глибокого навчання, а також застосуванням цих методів у задачах аналізу великих даних та економічного прогнозування.

Бібліографічні посилання

1. Bruna J., Mallat S. Invariant scattering convolution networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2013. Vol. 35, No. 8. P. 1872–1886.
2. Daubechies I. *Ten lectures on wavelets*. Philadelphia : SIAM, 1992. 357 p.
3. Frusque G., Fink O. Robust time series denoising with learnable wavelet packet transform. *Advanced Engineering Informatics*. 2024. Vol. 62. Article 102656.
4. Fujieda S., Takayama K., Hachisuka T. Wavelet convolutional neural networks. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops*. 2020. P. 58–67.
5. Gençay R., Selçuk F., Whitcher B. *An introduction to wavelets and other filtering methods in finance and economics*. San Diego : Academic Press, 2001. 359 p.
6. Korkmaz C., Tekalp A. M. Training transformer models by wavelet losses improves quantitative and visual performance in single image super-resolution. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops*. 2024.
7. Li Q., Shen L., Guo S., Lai Z. WaveCNet: Wavelet integrated CNNs to suppress aliasing effect for noise-robust image classification. *IEEE Transactions on Image Processing*. 2021. Vol. 30. P. 7074–7089.
8. Liu W., Yan Q., Zhao Y. Densely self-guided wavelet network for image denoising. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops*. 2020.
9. Mallat S. *A wavelet tour of signal processing: the sparse way*. 3rd ed. Burlington : Academic Press, 2009. 832 p.

10. Nason G. P. Wavelet methods in statistics with R. New York : Springer, 2008. 272 p.
11. Percival D. B., Walden A. T. Wavelet methods for time series analysis. Cambridge : Cambridge University Press, 2000. 594 p.
12. Wang B.-S., Hsieh J.-W., Chang M.-C., Chen P.-Y., Ke L., Lyu S. Learnable discrete wavelet pooling for convolutional networks. Proceedings of the British Machine Vision Conference. 2021.
13. Wolter M., Garcke J. Adaptive wavelet pooling for convolutional neural networks. Proceedings of the 24th International Conference on Artificial Intelligence and Statistics. 2021. Vol. 130. P. 1936–1944.
14. Wu J. et al. Wavelet-integrated deep neural networks: a systematic review of applications and architectures. Neurocomputing. 2025.
15. Zheng X., Zhou B., Gao J., Wang Y., He Y., Jin Y., Li Y. How framelets enhance graph neural networks. Proceedings of the 38th International Conference on Machine Learning. 2021. Vol. 139. P. 12761–12771.