

НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ «ОДЕСЬКА ПОЛІТЕХНІКА»
МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ

*Кваліфікаційна наукова
праця на правах рукопису*

КОШУТІНА ДАР'Я ВАЛЕРІЇВНА

УДК 004.93

ДИСЕРТАЦІЯ

**МЕТОДИ ОБРОБКИ ТА АНАЛІЗУ ГЕТЕРОГЕННИХ ДАНИХ НА ОСНОВІ
ВЕЙВЛЕТ-ПЕРЕТВОРЕННЯ**

Спеціальність: 122 Комп'ютерні науки

Галузь знань: 12 Інформаційні технології

Подається на здобуття наукового ступеня доктора філософії

Дисертація містить результати власних досліджень. Використання ідей, результатів і текстів інших авторів мають посилання на відповідне джерело.

_____ Д.В. Кошутіна

Науковий керівник:

Щербакова Галина Юріївна, доктор технічних наук, професор

АНОТАЦІЯ

Кошутіна Д.В. Методи та моделі обробки і аналізу гетерогенних даних на основі вейвлет-перетворення. – Кваліфікаційна наукова праця на правах рукопису.

Дисертація на здобуття наукового ступеня доктора філософії за спеціальністю 122 – Комп'ютерні науки. – Національний університет «Одеська політехніка», МОН України, Одеса, 2026.

У **вступі** показана актуальність вирішення задач обробки та аналізу гетерогенних даних (ГД) на основі вейвлет-перетворення (ВП). Показана недосконалість існуючих методів обробки і аналізу даних на основі ВП в умовах потреби підвищення швидкодії та/або зниження ресурсоемності. Визначено об'єкт, предмет, задачі та методи дослідження; наведено наукову новизну та практичне значення отриманих результатів; висвітлено особистий внесок здобувача.

В **першому розділі** дисертаційної роботи проведений аналіз сучасних методів обробки та аналізу ГД, отриманих на основі малих серій вимірів. Проведено класифікацію ГД та розглянуті обмеження щодо їх вимірювання у дрібносерійному виробництві електроніки та при медичному діагностуванні в телемедицині.

Показано, що основою фільтрації, сегментації, ідентифікації, кластеризації для обробки та аналізу малих наборів ГД є оптимізація з ВП. Визначено, що ці методи не володіють для вказаних прикладних задач необхідною швидкістю та/або ресурсоемністю.

Сформульовано актуальну науково-прикладну задачу – удосконалення методів обробки та аналізу з ВП малих наборів вимірів ГД, що дозволять підвищити швидкість при достатньому рівні достовірності рішень та знизити вимоги до ресурсоемності в умовах апріорної невизначеності.

Для вирішення поставленої задачі удосконалено концептуальну модель оптимізації з ВП для обробки та аналізу сигналів з багатьма екстремумами, особливістю якої є проведення запропонованого в роботі кількісного ентропійно-інформаційного аналізу (ЕІА) для обґрунтованого вибору виду ВП та його

масштабу. Ця модель є основою для удосконалення методів оптимізації, кластеризації та класифікації на основі вейвлет аналізу ГД.

За результатами проведеного аналізу сформульовано мету та завдання досліджень.

В **другому розділі** дисертаційної роботи запропоновано удосконалені методи оптимізації, кластеризації та нейромережевої класифікації з ВП.

Методи оптимізації з ВП застосовують для обробки та аналізу ГД, коли цільова функція мультимодальна чи має негладку, зашумлену поверхню. Відомі методи з ВП для оцінки напрямку руху до екстремуму використовують замість градієнту його наближене значення, обчислене на основі обробки з ВФ Хаара та гіперболічної ВФ (ГВФ).

В методі на основі методу центрів, в якому на етапі обробки з ВФ Хаара визначаються обмеження другого роду, похибка визначення екстремуму знижується шляхом обробки з ГВФ. Це вимагає багато обчислень цільової функції (звернень до «оракулу»), що обмежує швидкодію. Для її підвищення запропоновано удосконалити цей метод оптимізації шляхом скорочення кількості етапів обробки з ГВФ. Для тестування цього методу в порівнянні з базовим використано функцію де Іонга 1. При співвідношенні сигнал/шум по амплітуді до 6,4 (завада розподілена за нормальним законом з нульовим середнім і СКВ від 0 до 100) зростання швидкодії склало від 1,7 до 2,8 разів. Число звернень до оракулу знизилось від 25% до 32% (в залежності від співвідношення сигнал/шум).

Таким чином, сформульовано **перший пункт наукової новизни**:

– *удосконалено* метод оптимізації на основі методу центрів з визначенням обмежень другого роду з ВП Хаара, що за рахунок скорочення кількості етапів обробки з ГВФ та скороченню кількості обчислень цільової функції (звернень до оракулу) дозволило підвищити швидкодію.

На основі удосконаленого методу оптимізації з обмеженнями другого роду на основі ВП та методу центрів запропоновано удосконалення методу кластеризації з ВП. Для дослідження його швидкодії сформовано набір даних з двох груп (кластерів) у двовимірному просторі ознак. При кластеризації порівняно з базовим

методом з урахуванням обмежень другого роду виграш в часі склав більше 1,18 разів.

Запропоновано удосконалити кластеризацію з ВП в умовах дрейфу центру кластеру за лінійною траєкторією за рахунок скорочення кількості етапів обробки з ГВФ. Цей метод кластеризації з ВФ при дрейфі центру кластера по лінійній траєкторії дозволяє оцінювати координати центру кластера швидше від 1,2 до 1,3 разів у порівнянні з базовим методом при відношенні сигнал/завада від 30. При відношенні сигнал/завада більшому, ніж 10, відносна погрішність удосконаленого методу *кластеризації* при дрейфі центру кластера по лінійній траєкторії складала менше 7 % і вища в середньому в 1,2 рази, ніж у базовому методі.

Ці результати дозволяють рекомендувати удосконалені методи для кластеризації ГД при потребі досягнення швидкодії та скорочення обчислень цільової функції.

Таким чином, сформульовано **другий пункт наукової новизни:**

– *удосконалено* методи кластеризації за дисперсійною ознакою та з дрейфом центру кластера по лінійній траєкторії, особливістю яких є врахування обмежень у вигляді нерівностей та визначення належності образу до відповідного кластеру з допомогою ВФ, що завдяки скороченню кількості обчислень цільової функції (звернень до оракулу) дозволило підвищити швидкодію обчислень.

Для підвищення точності класифікації мережі Колмогорова-Арнольда в ній у KAN-шарі були використані ВФ. Ця модель отримала назву MLP-KAN-WT (Multilayer Perceptron with Kolmogorov-Arnold Layer and Wavelet Transform). За рахунок використання ентропійно-інформаційного аналізу удосконаленої концептуальної моделі обробки з ВП сигналів з багатьма екстремумами для фільтрації вихідних даних обрано ВФ Добеші (db4).

Тестування цієї мережі з використанням для фільтрації ВФ Добеші (db4), а для шару активації KAN ВФ Хаара дозволило досягти зростання швидкодії обчислень в 2.5-3 рази при точності (Accuracy) 98.45%, для класів аритмій: Precision – 0.99, Recall – 0.98.

Таким чином, сформульовано **третій пункт наукової новизни:**

– *удосконалено* метод нейромережевої класифікації ГД на базі архітектури KAN шляхом застосування у вхідному шарі вейвлет функцій, що дозволило підвищити точність ідентифікації станів об'єктів у зашумленому середовищі при мінімізації кількості налаштовуваних параметрів та зростання швидкодії обчислень.

В **третьому розділі** дисертаційної роботи розроблені та досліджені методи аналізу ГД з ВП для аналізу ЕКГ.

У роботі удосконалено метод пошуку екстремумів мультіекстремальних нестационарних сигналів з ВП Хаара, з виконанням наступних етапів.

Етап 1. Попередня обробка вихідного сигналу з використанням фільтрації, з ВП, форма і рівень обробки якого обраний на основі запропонованого ентропійно-інформаційного критерію.

Етап 2. Визначення просторових координат екстремумів (пиків) шляхом пошуку координат екстремумів періодичних сигналів з ВФ Хаара.

Етап 3. Визначення довжини інтервалів між екстремумами при необхідності оцінки статистичних характеристик сигналів та/або екстремумів типу «мінімум», класифікації та прийняття діагностичного рішення.

Проведений аналіз підтвердив ефективність ЕІК для обґрунтованого вибору масштабу вейвлет-розкладання для попередньої обробки при виявленні комплексів QRS в сигналах ЕКГ. Максимальні значення ЕІК послідовно зустрічаються в межах масштабів d3-d5, що відповідає частотному спектру комплексів QRS. Метод дозволив скоротити об'єм даних для подальшої ідентифікації та досягти зниження рівня шуму сигналу ЕКГ, що дозволило підвищити швидкість пошуку характерних точок ЕКГ.

В **четвертому розділі** дисертаційної роботи розроблені та досліджені методи аналізу ГД з ВП для електронних виробів та систем тривимірного комп'ютерного зору.

На основі удосконаленого методу кластеризації з урахуванням обмежень проведено відбір резисторів по параметрах надійності для апаратури відповідального призначення. Розраховані інтенсивності відмов склали $\lambda_1 =$

$0,35 \times 10^{-5} \text{ год}^{-1}$ – за відсутності кластеризації, $\lambda_2 = 0,19 \times 10^{-5} \text{ год}^{-1}$ – для резисторів першого і $\lambda_3 = 0,19 \times 10^{-4} \text{ год}^{-1}$ для резисторів другого кластера. Розраховані з допомогою DN -розподілу значення середнього часу роботи до відмови склали відповідно 4,8 років за відсутності розділу на кластери, 7,5 років – для резисторів першого кластеру і порядку 2 років резисторів другого кластеру. Таким чином, швидкодія процедури кластеризації з урахуванням обмежень під час відбору резисторів була підвищена в середньому на 7-9 %.

На основі удосконаленого методу кластеризації з обмеженнями була також удосконалена інформаційна технологія оцінки параметрів електронних компонентів. В результаті вдосконалення зазначеного підходу з урахуванням запропонованого методу кластеризації з ВФ з обмеженнями швидкодія процедур було підвищено загалом на 7-9 %.

На основі запропонованого у другому розділі методу оптимізації проведено оцінку діспарантності стерео-зображень для систем тривимірного комп'ютерного зору. Для побудови карти глибин стереозображення запропоновано проводити наближену оцінку глибини розташування об'єктів, яка враховує результати виділення ділянок схожої інтенсивності або контурів об'єктів на зображеннях, або точок найбільшої кривизни контурного опису. Тобто особливістю оцінки глибини розташування об'єктів є виділення контурів об'єктів з ВФ і обчислення мінімуму функції помилки суміщення зображень розробленим методом оптимізації. Запропонований вище метод можна рекомендувати для систем тривимірного комп'ютерного зору, що працюють в умовах обмеженості обчислювальних та енергетичних ресурсів.

Розроблені в роботі методи та інструментальні засоби отримали впровадження у діяльності ТОВ НВО «Діскрет» та знайшли відображення у навчальному процесі Національного університету «Одеська політехніка».

Ключові слова: гетерогенні дані, вейвлет-перетворення, оптимізація, нейронні мережі KAN, адаптивна кластеризація, діагностика, комп'ютерний зір, інформаційні технології

Список опублікованих праць за темою дисертації

Наукові праці, в яких опубліковані основні наукові результати дисертації:

1. Shcherbakova G., Koshutina D. Development of a criterion for selecting the level of wavelet decomposition for QRS detection in electrocardiogram signals using energy and entropy. *Proceedings of Odessa Polytechnic University*. 2025. No. 1(71). P. 157–166. DOI: 10.15276/opu.1.71.2025.18. Видання включено до переліку наукових фахових видань України, категорія «Б».

2. Антощук С. Г., Щербакова Г. Ю., Кошутіна Д. В. Оцінка параметрів компонентів електроніки при відборі їх для апаратури відповідального призначення на основі кластеризації з вейвлет-обробкою та врахуванням обмежень. *Наукові праці Вінницького національного технічного університету*. 2025. Вип. 3. DOI: 10.31649/2307-5376-2025-3-27-36. Видання включено до переліку наукових фахових видань України, категорія «Б».

3. Shcherbakova G. Y., Koshutina D. V. Improving the performance of clustering with wavelet function by using inequality constraints. *Herald of Advanced Information Technology*. 2025. Vol. 8, No. 3. P. 277–287. DOI: 10.15276/hait.08.2025.17. Видання включено до переліку наукових фахових видань України, категорія «Б» та проіндексовано в Scopus (Q4).

4. Koshutina D. V. KAN-Type Neural Network Model for ECG Signal Analysis and Classification. *Proceedings of Odessa Polytechnic University*. 2025. No. № 2(72). P. 163-174. DOI: 10.15276/opu.2.72.2025.17. Видання включено до переліку наукових фахових видань України, категорія «Б».

Наукові праці, які засвідчують апробацію матеріалів дисертації:

5. Shcherbakova G., Antoshchuk S., Koshutina D., Sakhno K. Adaptive clustering for distribution parameter estimation in technical diagnostics. *12th International Conference on Applied Innovations in IT (ICAIIIT)*, Köthen, Germany, March 7, 2024. Vol. 12, No. 1. P. 123–127. DOI: 10.25673/115650. Видання проіндексовано у базі даних Scopus.

6. Antoshchuk S., Shcherbakova G., Kondratyev S., Koshutina D., Usov O. Wavelet transform based optimization method for three-dimensional computer vision. *Proceedings of the 12th International Conference «Information Control Systems & Technologies» (ICST 2024)*, Odesa, Ukraine, September 23–25, 2024. P. 471–482. Видання проіндексовано у базі даних Scopus.

7. Антощук С. Г., Щербакова Г. Ю., Кондратьєв С. Б., Кошутіна Д. В. Наближений метод оцінки глибини об'єктів на основі вейвлет-перетворення. *Х Міжнародна науково-практична конференція «Інформатика. Культура. Техніка»*, Одеса, Україна, 26–27 вересня 2024 р. Том 1, № 1. С. 197–201.

8. Кошутіна Д. В., Сахно К. О., Щербакова Г. Ю. Використання вейвлет-перетворення при аналізі електрокардіограм. *Тези доповідей XXXIII Міжнародної науково-практичної конференції MicroCAD-2025*, Харків, 14–17 травня 2025 р. С. 765–766. DOI: 10.5281/zenodo.15520692.

9. Кошутіна Д. В., Щербакова Г. Ю. Автоматизований вибір рівня вейвлет-розкладу на основі енергії та ентропії для виявлення QRS-комплексів ЕКГ. *Матеріали XV Міжнародної наукової конференції «Modern Information Technology – 2025»*, Одеса, 15–16 травня 2025 р. С. 21–23. DOI: 10.5281/zenodo.15521809.

10. Koshutina D., Shcherbakova G., Antoshchuk S., Glava M. Improving the performance of wavelet transform optimization using inequality constraints. *The 13th IEEE International Conference on Intelligent Data Acquisition and Advanced Computing Systems: Technology and Applications (ICIDACS 2025)*, Gliwice, Poland, September 4–6, 2025. DOI: 10.1109/IDAACS68557.2025.11322357.

11. Кошутіна Д. В., Щербакова Г. Ю. Визначення інтенсивності відмов при відбракуванні виробів електронної техніки за допомогою завадостійкої кластеризації. *Proceedings of the 13th International Conference Information Control Systems & Technologies (ICST 2025)*, Odesa, Ukraine, September 24–26, 2025. P. 137–140.

12. Щербакова Г. Ю., Кошутіна Д. В., Сахно К. О. Оцінка параметрів надійності компонентів електроніки при відбракуванні за допомогою кластеризації з вейвлет-перетворенням. *Матеріали XI Міжнародної науково-практичної*

конференції «Інформатика. Культура. Техніка», Одеса, 16–17 жовтня 2025 р. DOI: 10.15276/ict.02.2025.02.

13. Світлана Антошук, Галина Щербакова, Сергій Кондратьєв, Дар'я Кошутіна, Олександр Усов. Метод оптимізації на основі вейвлет-перетворення для наближених методів оцінки глибини. *Інформаційні управляючі системи та технології (ІУСТ-Одеса-2024)*, м. Одеса, 23–25 вересня 2024 р. С. 123–127.

14. Shcherbakova G., Antoshchuk S., Koshutina D., Sakhno K., Kondratiev S. Adaptive Clustering for Distribution Parameter Estimation in Technical Diagnostics. *Applied Innovations in Information and Communication Technology. ICAIIT 2024. Lecture Notes in Networks and Systems*, Vol. 1338. Springer, Cham, 2025. P. 379–392. DOI: 10.1007/978-3-031-89296-7_19. (Scopus).

15. Кошутіна Д. В., Щербакова Г. Ю., Антошук С. Г. Удосконалення пошуку параметрів електрокардіограм за допомогою оптимізації на основі вейвлет-функції. *Колективна монографія «Information Control Systems and Intelligent Technologies. Achievements and Applications»*. Lviv–Torun: Liha-Pres, 2025. С. 383–401. DOI: 10.36059/978-966-397-538-2.

ABSTRACT

Koshutina D.V. Methods and models for processing and analyzing heterogeneous data based on wavelet transform. – Qualification scientific work in the form of manuscript.

Thesis for the PhD degree in specialty 122 Computer science. – Odessa Polytechnic National University, Ministry of Education and Science of Ukraine, Odesa, 2026.

The introduction establishes the relevance of processing and analyzing heterogeneous data (HD) using wavelet transforms (WT). It addresses the limitations of existing WT-based methods, specifically the need for enhanced computational speed and reduced resource intensity. The study defines the research object, subject, objectives, and methodology; presents the scientific novelty and practical significance of the results; and outlines the author's personal contributions.

The first chapter of the dissertation analyzes modern methods for processing and analyzing HD obtained from small measurement series. A classification of HD is provided, and the limitations of their measurement in small-batch electronics production and medical diagnostics in telemedicine are considered.

It is shown that optimization with WT is the basis for filtering, segmentation, identification, and clustering for processing and analyzing small sets of HD. It is determined that these methods do not possess the necessary speed and/or resource intensity for the specified applied tasks.

A relevant scientific and applied task is formulated: the improvement of methods for processing and analyzing small sets of HD measurements with WT, which will allow for increased speed with a sufficient level of decision reliability and reduced resource intensity requirements under conditions of a priori uncertainty.

To solve the stated problem, the conceptual model of optimization with WT for processing and analyzing signals with many extremes is improved. Its feature is the conduct of the quantitative entropy-information analysis (EIA) proposed in the work for the justified choice of the type of WT and its scale. This model is the basis for improving optimization, clustering, and classification methods based on wavelet analysis of HD.

Based on the results of the analysis, the goal and objectives of the research are formulated.

The second chapter of the dissertation proposes improved methods for optimization, clustering, and neural network classification with WT.

WT-optimization methods are used for processing and analyzing HD when the objective function is multimodal or has a non-smooth, noisy surface. Known methods with WT use an approximate value instead of a gradient, calculated based on processing with Haar wavelet functions (WF) and hyperbolic wavelet functions (HWF), to estimate the direction toward the extremum.

In the method based on the Method of Centers, in which second-order constraints are determined at the Haar WF processing stage, the error in determining the extremum is reduced by processing with HWF. This requires many calculations of the objective function ("oracle calls"), which limits speed. To increase it, it is proposed to improve this optimization method by reducing the number of HWF processing stages. To test this method in comparison with the baseline, the De Jong function 1 was used. At a signal-to-noise ratio in amplitude up to 6.4 (noise distributed according to the normal law with zero mean and RMS from 0 to 100), the increase in speed ranged from 1.7 to 2.8 times. The number of oracle calls decreased from 25% to 32% (depending on the signal-to-noise ratio).

Thus, **the first point of scientific novelty** is formulated:

- the optimization method based on the Method of Centers with the determination of second-order constraints with Haar WT *has been improved*, which, by reducing the number of HWF processing stages and reducing the number of objective function calculations (oracle calls), allowed for an increase in speed.

Based on the improved optimization method with second-order constraints using WT and the Method of Centers, an improvement of the WT-clustering method is proposed. To study its speed, a data set of two groups (clusters) in a two-dimensional feature space was formed. During clustering, compared to the baseline method taking into account second-order constraints, the time gain was more than 1.18 times.

It is proposed to improve WT-clustering under conditions of linear cluster center drift by reducing the number of HWF processing stages. This method of clustering with WF during linear cluster center drift allows for estimating the coordinates of the cluster center 1.2 to 1.3 times faster compared to the baseline method at a signal-to-interference ratio from 30. At a signal-to-interference ratio greater than 10, the relative error of the improved clustering method was less than 7% and is on average 1.2 times better than in the baseline method.

These results allow recommending the improved methods for HD clustering when there is a need to achieve speed and reduce objective function calculations.

Thus, **the second point of scientific novelty** is formulated:

– clustering methods based on variance characteristics and with linear cluster center drift *have been improved*, the feature of which is the consideration of constraints in the form of inequalities and the determination of pattern membership to the corresponding cluster using WF, which, due to the reduction in the number of objective function calculations (oracle calls), allowed for an increase in computational speed.

To increase the classification accuracy of the Kolmogorov-Arnold network, WFs were used in its KAN layer. This model was named MLP-KAN-WT (Multilayer Perceptron with Kolmogorov-Arnold Layer and Wavelet Transform). Due to the use of entropy-information analysis of the improved conceptual model of processing signals with many extremes with WT, the Daubechies wavelet (db4) was chosen for filtering the output data.

Testing this network using the Daubechies wavelet (db4) for filtering and the Haar WF for the KAN activation layer allowed for a 2.5-3 times increase in computational speed with an Accuracy of 98.45%, and for arrhythmia classes: Precision – 0.99, Recall – 0.98.

Thus, **the third point of scientific novelty** is formulated:

– the neural network classification method of HD based on the KAN architecture *has been improved* by using wavelet functions in the input layer, which allowed for an increase in the identification accuracy of object states in a noisy environment while minimizing the number of tunable parameters and increasing computational speed.

The third chapter of the dissertation develops and investigates methods for analyzing HD with WT for ECG analysis.

The work improves the method for searching for extremes of multi-extremal non-stationary signals with Haar WT, performing the following stages.

Stage 1. Preprocessing the output signal using filtering with WT, the form and level of processing of which is chosen based on the proposed entropy-information criterion.

Stage 2. Determining the spatial coordinates of extremes (peaks) by searching for the coordinates of extremes of periodic signals with Haar WF.

Stage 3. Determining the length of intervals between extremes when it is necessary to estimate the statistical characteristics of signals and/or extremes of the "minimum" type, classification, and making a diagnostic decision.

The conducted analysis confirmed the effectiveness of the EIC for the justified choice of the wavelet decomposition scale for preprocessing during the detection of QRS complexes in ECG signals. Maximum EIC values consistently occur within scales d3-d5, which corresponds to the frequency spectrum of QRS complexes. The method allowed for a reduction in the data volume for further identification and achieved a reduction in the noise level of the ECG signal, which allowed for an increase in the speed of searching for characteristic ECG points.

The fourth chapter of the dissertation develops and investigates methods for analyzing HD with WT for electronic products and 3D computer vision systems.

Based on the improved clustering method with constraints, resistors were selected by reliability parameters for critical applications. The calculated failure rates were: $\lambda_1 = 0,35 \times 10^{-5}$ without clustering, $\lambda_2 = 0,19 \times 10^{-5}$ for the first cluster, and $\lambda_3 = 0,19 \times 10^{-4}$ for the second cluster. Using the DN-distribution, the calculated mean time to failure (MTTF) was 4.8 years without clustering, 7.5 years for the first cluster, and about 2 years for the second cluster. Thus, the speed of the clustering procedure during resistor selection was increased by an average of 7-9%.

Based on the improved clustering method with constraints, the information technology for evaluating the parameters of electronic components was also improved. As a result of the improvement of this approach, taking into account the proposed method

of clustering with WF with constraints, the speed of the procedures was increased by 7-9% overall.

Based on the optimization method proposed in the second chapter, the disparity of stereo images for 3D computer vision systems was estimated. To build a depth map of a stereo image, it is proposed to perform an approximate estimation of the depth of the objects, which takes into account the results of highlighting areas of similar intensity or contours of objects in the images, or points of the greatest curvature of the contour description. That is, the feature of estimating the depth of objects is the extraction of object contours with WF and the calculation of the minimum of the image matching error function by the developed optimization method. The method proposed above can be recommended for 3D computer vision systems operating under conditions of limited computational and energy resources.

The methods and instrumental tools developed in the work were implemented in the activities of «DISKRET» LLC and found reflection in the educational process of the Odessa Polytechnic National University.

Keywords: heterogeneous data, wavelet transform, optimization, KAN neural networks, adaptive clustering, diagnostics, computer vision, information technologies.

List of publications of the applicant on the topic of the dissertation

Scientific works in which the main scientific results of the dissertation are published:

1. Shcherbakova G., Koshutina D. Development of a criterion for selecting the level of wavelet decomposition for QRS detection in electrocardiogram signals using energy and entropy. Proceedings of Odessa Polytechnic University. 2025. No. 1(71). P. 157–166. DOI: 10.15276/opu.1.71.2025.18. The publication is included in the list of specialized scientific editions of Ukraine, category "B".

2. Antoshchuk S., Shcherbakova G., Koshutina D. Estimation of electronic component parameters during selection for critical applications based on clustering with

wavelet processing and constraints. Scientific Works of Vinnytsia National Technical University. 2025. Iss. 3. DOI: 10.31649/2307-5376-2025-3-27-36. The publication is included in the list of specialized scientific editions of Ukraine, category "B".

3. Shcherbakova G. Y., Koshutina D. V. Improving the performance of clustering with wavelet function by using inequality constraints. Herald of Advanced Information Technology. 2025. Vol. 8, No. 3. P. 277–287. DOI: 10.15276/hait.08.2025.17. The publication is included in the list of specialized scientific editions of Ukraine, category "B" and indexed in Scopus (Q4).

4. Koshutina D. V. KAN-Type Neural Network Model for ECG Signal Analysis and Classification. Proceedings of Odessa Polytechnic University. 2025. No. № 2(72). P. 163-174. DOI: \10.15276/opu.2.72.2025.17. The publication is included in the list of specialized scientific editions of Ukraine, category "B".

Scientific papers certifying the approbation of the dissertation materials:

5. Shcherbakova G., Antoshchuk S., Koshutina D., Sakhno K. Adaptive clustering for distribution parameter estimation in technical diagnostics. 12th International Conference on Applied Innovations in IT (ICAIIIT), Köthen, Germany, March 7, 2024. Vol. 12, No. 1. P. 123–127. DOI: 10.25673/115650. The publication is indexed in the Scopus database.

6. Antoshchuk S., Shcherbakova G., Kondratyev S., Koshutina D., Usov O. Wavelet transform based optimization method for three-dimensional computer vision. Proceedings of the 12th International Conference «Information Control Systems & Technologies» (ICST 2024), Odesa, Ukraine, September 23–25, 2024. P. 471–482. The publication is indexed in the Scopus database.

7. Antoshchuk S., Shcherbakova G., Kondratyev S., Koshutina D. Approximate method for estimating object depth based on wavelet transform. X International Scientific and Practical Conference «Informatics. Culture. Technology», Odesa, Ukraine, September 26–27, 2024. Vol. 1, No. 1. P. 197–201.

8. Koshutina D., Sakhno K., Shcherbakova G. Use of wavelet transform in the analysis of electrocardiograms. Abstracts of the XXXIII International Scientific and Practical Conference MicroCAD-2025, Kharkiv, May 14–17, 2025. P. 765–766. DOI: 10.5281/zenodo.15520692.

9. Koshutina D., Shcherbakova G. Automated selection of wavelet decomposition level based on energy and entropy for ECG QRS complex detection. Materials of the XV International Scientific Conference «Modern Information Technology – 2025», Odesa, May 15–16, 2025. P. 21–23. DOI: 10.5281/zenodo.15521809.

10. Koshutina D., Shcherbakova G., Antoshchuk S., Glava M. Improving the performance of wavelet transform optimization using inequality constraints. The 13th IEEE International Conference on Intelligent Data Acquisition and Advanced Computing Systems: Technology and Applications (IDAACS 2025), Gliwice, Poland, September 4–6, 2025. DOI: 10.1109/IDAACS68557.2025.11322357.

11. Koshutina D., Shcherbakova G. Determination of failure rates in electronic product screening using noise-resistant clustering. Proceedings of the 13th International Conference Information Control Systems & Technologies (ICST 2025), Odesa, Ukraine, September 24–26, 2025. P. 137–140.

12. Shcherbakova G., Koshutina D., Sakhno K. Estimation of reliability parameters of electronic components during screening using clustering with wavelet transform. Materials of the XI International Scientific and Practical Conference «Informatics. Culture. Technology», Odesa, October 16–17, 2025. DOI: 10.15276/ict.02.2025.02.

13. Antoshchuk S., Shcherbakova G., Kondratyev S., Koshutina D., Usov O. Optimization method based on wavelet transform for approximate depth estimation methods. Information Control Systems and Technologies (ICST-Odesa-2024), Odesa, September 23–25, 2024. P. 123–127.

14. Shcherbakova G., Antoshchuk S., Koshutina D., Sakhno K., Kondratyev S. Adaptive Clustering for Distribution Parameter Estimation in Technical Diagnostics. Applied Innovations in Information and Communication Technology. ICAIIT 2024. Lecture Notes in Networks and Systems, Vol. 1338. Springer, Cham, 2025. P. 379–392. DOI: 10.1007/978-3-031-89296-7_19. (Scopus).

15. Koshutina D., Shcherbakova G., Antoshchuk S. Improving the search for electrocardiogram parameters using wavelet-function-based optimization. Collective monograph «Information Control Systems and Intelligent Technologies. Achievements and Applications». Lviv-Torun: Liha-Pres, 2025. P. 383–401. DOI: 10.36059/978-966-397-538-2.

ЗМІСТ

Вступ.....	20
1 Аналіз методів обробки та аналізу гетерогенних даних із застосуванням вейвлет-перетворення.....	25
1.1 Характеристика гетерогенних даних	25
1.1.1 Проблеми обробки ГД в електроніці	30
1.1.2 Проблеми обробки ГД в медицині	31
1.2 Загальна схема обробки та аналізу гетерогенних даних.....	32
1.2.1 Попередня обробка за допомогою вейвлет-перетворення	34
1.2.2 Сегментація за допомогою вейвлет-перетворення.....	38
1.2.3 Оптимізація за допомогою вейвлет-перетворення.....	45
1.2.4 Оптимізація з ВП в умовах дрейфу екстремуму за лінійною траєкторією	58
1.2.5 Кластеризація за допомогою вейвлет-перетворення.....	60
1.2.6 Кластеризація з ВП в умовах дрейфу центру кластеру за лінійною траєкторією	61
1.2.7 Класифікація з ВФ в задачах нейромережових.....	64
1.3 Удосконалення концептуальної моделі обробки та аналізу гетерогенних даних.....	67
1.4 Висновки до першого розділу.....	70
2 Методи аналізу гетерогенних даних з використанням вейвлет-перетворення ...	72
2.1 Методи оптимізації з вейвлет-перетворенням	72
2.1.1 Метод оптимізації з обмеженнями у вигляді нерівностей	72
2.1.2 Оптимізація нестационарних мультимодальних сигналів.....	77
2.2 Кластеризація на основі оптимізації з обмеженнями.....	79
2.3 Кластеризація в умовах дрейфу центру кластеру за лінійною траєкторією .	86
2.4 Нейронні мережі Колмогорова-Арнольда на основі удосконаленої концептуальної моделі.....	89
2.5 Висновки до другого розділу	104
3 Дослідження методів аналізу електрокардіограм з вейвлет-перетворенням.....	106

3.1 Вибір типу і рівня вейвлет-перетворення на основі критерія співвідношення ентропії та енергії сигналу	106
3.2 Ідентифікація ознак на базі пошуку оптимумів нестационарних мультимодальних сигналів.....	110
3.3 Реалізація вейвлет-шару в структурі мережі Колмогорова Арнольда для виділення локальних ознак ЕКГ-сигналів	118
3.4 Висновки до третього розділу.....	126
4 Дослідження методів з вейвлет-перетворенням для відбору компонентів електроніки і оцінки діспарантності зображень	128
4.1 Модель передбачення параметрів електронних компонентів	128
4.2 Оцінка показників надійності електронних компонентів на основі адаптивної кластеризації	130
4.3 Інформаційна технологія оцінки параметрів електронних компонентів	135
4.4 Оцінка діспарантності стерео-зображень на основі пошуку екстремумів з вейвлет-функцією Хаара	138
4.5 Висновки до четвертого розділу.....	144
Загальні висновки.....	146
Список використаних джерел	150
Додаток А Акти впровадження результатів дисертаційного дослідження.....	167
Додаток Б Довідки про впровадження результатів дисертаційної роботи у навчальному процесі Національного Університету «Одеська Політехніка» ...	168
Додаток В Фрагменти вихідного коду програмних інструментальних засобів ...	170
Додаток Г Список публікацій здобувача	172
Додаток Д Відомості про апробацію результатів дисертаційної роботи	173

ВСТУП

Актуальність теми. Ефективність автоматизації прийняття рішень у багатьох галузях сучасного життя багато в чому визначається ефективністю обробки та аналізу інформації, прискоренням процесів одержання даних про об'єкт, поліпшенням форми їхньої подання. Серед багатьох видів інформації досить важлива й значна роль належить гетерогенним часовим або просторовим сигналам даних (ГД), які використовуються при автоматизації прийняття рішень в технічній діагностиці, в робототехніці, в медицині та ін. Для обробки сигналів та аналізу ГД, особливо в умовах завад та апіорної невизначеності, виникає необхідність у методах, здатних забезпечити ефективний та точний аналіз як у часовій або просторовій, так і в частотній областях. Аналіз літературних джерел довів, що найбільш ефективними для таких задач є методи, що ґрунтуються на вейвлет-перетворенні. Але незважаючи на чисельні дослідження, присвячені їх розробкам для вирішення різних завдань, що пов'язані з аналізом ГД, таких як оптимізація, фільтрація, класифікація, кластеризація тощо, використання методів на основі вейвлет-перетворення на практиці, обмежується показниками їх швидкодії та ресурсоємності. Це призводить до протиріччя між затребуваністю методів на основі вейвлет-перетворення завдяки високій ефективності у визначенні часових або просторових характеристик ГД та забезпеченню необхідної роздільної здатності, з одного боку, та обмеженнями використання, що пов'язані з показниками обчислення (швидкодія та ресурсоємність тощо), з другого.

Це протиріччя може бути усунене за рахунок вирішення актуальної та важливої науково-прикладної задачі, яка полягає в удосконаленні методів обробки та аналізу ГД різної фізичної природи на основі вейвлет-перетворення, що дозволить при достатній достовірності в умовах апіорної невизначеності підвищити їх швидкодію та/або знизити ресурсоємність.

Зв'язок роботи з науковими програмами, планами, темами. Дисертаційну роботу виконано у відповідності до пріоритетних тематичних напрямів наукових досліджень і науково-технічних розробок на період до 31 грудня року, наступного

після припинення або скасування воєнного стану в Україні (Постанова Кабінету Міністрів України від 30.04.2024 р. № 476), згідно пп. 1.2.1.1, 1.2.1.4, 1.2.4.6 і 1.2.1.7 «Основних наукових напрямів та найважливіших проблем фундаментальних досліджень у галузі природничих, технічних, суспільних і гуманітарних наук Національної академії наук України на 2019–2023 роки» (постанова Президії НАН України від 30.01.2019 р. № 30) та також у відповідності до планів науково-дослідних робіт Національного університету «Одеська політехніка» при виконанні держбюджетних тем: НДР роботи № 719-61/161 – «Інтелектуальна підтримка прийняття рішень при проєктуванні кісткових замінників для лікування воєнних травм» (номер держ. реєстрації 0124U000388) та НДР № 1938 (Договор МОН № СШ / 05 – 2024) Інтелектуальна система визначення стану довкілля у реальному часі на базі БПЛА (номер держ. реєстрації 0124U004854). Дисертант приймав участь у виконанні вказаних тем як співвиконавець (акт впровадження від 25.12.2025 р.) (Додаток Б).

Метою дослідження є удосконалення методів обробки та аналізу ГД на основі вейвлет- перетворення, що дозволить при достатній достовірності в умовах апріорної невизначеності підвищити їх швидкодію та/або знизити ресурсоемність.

Для досягнення мети дослідження необхідно вирішити такі завдання:

- провести аналіз основних проблем, обмежень та викликів, які виникають задачах обробки та аналізу гетерогенних даних;
- удосконалити метод оптимізації на основі вейвлет- перетворення шляхом обчислення обмежень;
- удосконалити методи кластеризації за дисперсійною ознакою та з дрейфом центру кластеру по лінійній траєкторії, в якому належність образу до кластеру розраховується на основі обчислення обмежень;
- удосконалити метод нейромережевої класифікації ГД на базі архітектури KAN шляхом застосування у вхідному шарі вейвлет функцій, що дозволило підвищити точність ідентифікації станів об'єктів у зашумленому середовищі при мінімізації кількості налаштовуваних параметрів та зростання швидкодії обчислень.

– розробити інструментальні засоби, що реалізують запропоновані рішення та провести експериментальні дослідження, апробацію і впровадження отриманих теоретичних результатів.

Об’єкт дослідження є процеси обробки та аналізу гетерогенних даних.

Предмет дослідження є моделі та методи обробки та аналізу гетерогенних даних на основі вейвлет перетворення.

Методи дослідження. Для вирішення поставлених задач використано теорію розпізнавання образів, методи комп’ютерного зору, машинного навчання та математичний апарат статистичного та імітаційного моделювання. Застосовано теорію рішення оптимізаційних задач для удосконалення моделей та методів вейвлет обробки та аналізу гетерогенних даних.

Наукова новизна отриманих результатів. Основний науковий результат полягає у розв’язанні важливої науково-практичної задачі удосконалення моделей та методів обробки та аналізу гетерогенних даних на основі вейвлет перетворення в інформаційних системах різного прикладного призначення.

У рамках виконаних досліджень отримано такі наукові результати:

– удосконалено метод оптимізації на основі методу центрів з визначенням обмежень другого роду з ВП Хаара, що за рахунок скорочення кількості етапів обробки з ГВФ та скороченню кількості обчислень цільової функції (звернень до оракулу) дозволило підвищити швидкодію;

– удосконалено методи кластеризації за дисперсійною ознакою та з дрейфом центру кластера по лінійній траєкторії, особливістю яких є врахування обмежень у вигляді нерівностей та визначення належності образу до відповідного кластеру з допомогою ВФ, що завдяки скороченню кількості обчислень цільової функції (звернень до оракулу) дозволило підвищити швидкодію обчислень;

– удосконалено метод нейромережевої класифікації ГД на базі архітектури KAN шляхом застосування у вхідному шарі вейвлет функцій, що дозволило підвищити точність ідентифікації станів об’єктів у зашумленому середовищі при мінімізації кількості налаштовуваних параметрів та зростання швидкодії обчислень.

Практичне значення одержаних результатів. Розроблені в дисертаційній роботі методи та моделі обробки гетерогенних даних із використанням адаптивної вейвлет–декомпозиції, обмежень–нерівностей другого порядку та нейромережових архітектур KAN були використані для підвищення обчислювальної ефективності, швидкодії та завадостійкості процесів аналізу інформації у складних системах.

Розроблене програмне забезпечення швидкої обробки та аналізу гетерогенних даних дозволяє адаптувати запропоновані рішення до різних задач комп’ютерних наук, зокрема для автоматизованої технічної діагностики, 3D–реконструкції сцен у системах технічного зору та оперативного моніторингу динамічних сигналів.

Особистий внесок здобувача. Основні наукові положення, висновки і рекомендації, що містяться в дисертації та виносяться на захист, отримано здобувачем особисто в період з 2020 по 2025 рік.

У статті [1] внесок здобувача полягає в проведенні аналітичного дослідження та розробці критерію вибору оптимального рівня вейвлет-розкладу для детектування QRS-комплексів на основі показників енергії та ентропії.

У статті [2] здобувачем проаналізовано варіанти підвищення надійності електронних компонентів та запропоновано підхід до їх відбору на основі кластеризації з вейвлет-обробкою.

У статті [3] автором проведено дослідження ефективності методів кластеризації із застосуванням вейвлет-функцій та розроблено алгоритм врахування обмежень-нерівностей для підвищення швидкодії.

У статті [4] здобувачем запропоновано та програмно реалізовано метод нейромережової класифікації ЕКГ-сигналів на базі архітектури KAN (Kolmogorov-Arnold Network) з використанням вейвлет-функцій у вхідному шарі.

У роботах [5, 14] автором розроблено адаптивну процедуру кластеризації для оцінки параметрів розподілу гетерогенних даних у задачах технічної діагностики.

У роботах [6, 7, 13] внесок здобувача полягає в розробці методу оптимізації на основі вейвлет-перетворення для систем тривимірного комп’ютерного зору з метою наближеної оцінки глибини об’єктів.

У роботах [8, 9] досліджено можливості використання вейвлет-перетворення для багатоетапного аналізу електрокардіограм, зокрема автоматизації вибору параметрів розкладу для ідентифікації характерних точок в умовах зашумленості.

У роботах [10, 15] здобувачем удосконалено математичний апарат вейвлет-оптимізації шляхом застосування методів центрів та розширено сферу їх застосування для аналізу параметрів медичних сигналів.

У роботах [11, 12] автором розроблено методику визначення інтенсивності відмов та параметрів надійності компонентів електроніки на основі завадостійкої кластеризації з використанням вейвлет-аналізу.

Апробація результатів дисертації. Основні положення і практичні результати дисертаційної роботи доповідалися та одержали схвалення на таких конференціях:

- міжнародна конференція «International Conference on Applied Innovations in IT 2024 (ICAIT 2024)» (м. Кетен, Німеччина, 2024 рік);

- X Міжнародної науково-практичної конференції Інформатика. Культура. Техніка. 2024 25–27 вересня 2024 р. м. Одеса (Україна);

- XII Міжнародна науково-практична конференція «Інформаційні управляючі системи та технології (ІУСТ - Одеса - 2024)» (м. Одеса, 2024 рік);

- міжнародна конференція «The 13th IEEE International Conference on Intelligent Data Acquisition and Advanced Computing Systems: Technology and Applications» (м. Глівіце, Польща, 2025 рік).

Публікації. Основні результати дисертаційної роботи викладено в 15 публікаціях з них: 4 статті у наукових фахових виданнях України категорії «Б», 11 публікацій у працях і матеріалах міжнародних наукових конференцій (матеріали чотирьох з яких проіндексовано у наукометричній базі Scopus), та монографіях. 1 стаття надрукована без співавторів.

Структура і обсяг роботи. Дисертація складається з вступу, чотирьох розділів, висновків, списку використаних джерел і додатків. Повний обсяг дисертації складає 174 сторінок, в тому числі: 130 сторінки основного тексту, 30 рисунки і 10 таблиць, список використаних джерел зі 162 найменувань і 5 додатків.

1 АНАЛІЗ МЕТОДІВ ОБРОБКИ ТА АНАЛІЗУ ГЕТЕРОГЕННИХ ДАНИХ ІЗ ЗАСТОСУВАННЯМ ВЕЙВЛЕТ-ПЕРЕТВОРЕННЯ

1.1 Характеристика гетерогенних даних

Ефективність автоматизації прийняття рішень багато в чому визначається ефективністю обробки та аналізу даних про об'єкт, поліпшенням форми їхнього подання. Значна частина даних при цьому належить гетерогенним часовим або просторовим сигналам даних (ГД), які використовуються при автоматизації прийняття рішень в технічній діагностиці, в робототехніці, в медицині та ін. В прикладних задачах такі дані мають бути представлені в цифровій формі, придатній для подальшої алгоритмічної обробки.

Цифрову форму дані отримують після реєстрації первинними перетворювачами або сенсорними мережами в межах складних технічних чи біологічних систем. В процесі такої обробки дані піддаються дискретизації за часом та квантуванню за рівнем, в результаті чого перетворюються на послідовність цифрових відліків [1, 2] і групуються у масиви даних різної розмірності [3]:

- одновимірні сигнали (1D): Аудіозаписи, електрокардіограми (ЕКГ), електроенцефалограми (ЕЕГ), сейсмічні коливання, фінансові часові ряди;
- двовимірні дані (2D): цифрові зображення, медичні знімки (МРТ, рентген), супутникові карти;
- тривимірні дані (3D); послідовності кадрів зображень, об'ємні медичні сканування, комп'ютерна томографія.

Серед таких даних можуть бути як гомогенні так і гетерогенні масиви. Гомогенні масиви даних описують єдину фізичну величину та мають ідентичну аналітичну природу – наприклад, часовий ряд відліків напруги або звукового тиску [4, 5]. Властивість гомогенності дозволяє ефективно застосовувати лінійну фільтрацію та спектральний аналіз, оскільки припускається, що статистичні

характеристики даних залишаються стабільними на інтервалі спостереження, а внутрішня структура масиву є лінійною та передбачуваною [6].

Проте ускладнення об'єктів дослідження та розвиток систем моніторингу з багатьма сенсорами призвели до виникнення якісно нових типів інформаційних структур – гетерогенних даних (ГД).

Гетерогенні дані – (часто) багатовимірні, інтегрують у собі компоненти різної фізичної природи, форматів представлення, масштабів та часо-частотних характеристик локалізації [7, 8]. На відміну від ізоморфних гомогенних рядів, такі дані відображають синергію мультимодальних процесів, де в одному масиві можуть бути поєднані швидкі динамічні сигнали, статичні параметри стану системи та контекстні метадані. З точки зору морфології, внутрішня організація гетерогенних даних характеризується високим ступенем нелінійності та ієрархічності. У межах даного дослідження гетерогенний масив даних X розглядається як багатокомпонентна структура, що може бути формалізована як об'єднання декількох інформаційних підпросторів [9, 10]:

$$X = \{S, I, P, M\}, \quad (1.1)$$

де кожен елемент відображає тип даних з власною топологією та метрикою:

S – часові ряди та динамічні сигнали;

I – цифрові зображення та матричні структури;

P – параметричні вектори стану;

M – контекстні метадані.

Часові ряди та динамічні сигнали S представлені як одновимірні послідовності цифрових відліків $s(n\Delta t)$, що описують зміну фізичного процесу у часі. Прикладом таких даних є ЕКГ-сигнали [11]. Математично вони описуються як функції у просторі Гільберта $L^2(\mathbb{R})$, що передбачає скінченність енергії сигналу:

$$\int_{-\infty}^{\infty} |s(t)|^2 dt < \infty \quad (1.2)$$

Властивості простору Гільберта, зокрема наявність скалярного добутку та повнота метрики, створюють математичний фундамент для декомпозиції сигналу за ортогональними базисами. Це дозволяє використовувати апарат вейвлет-перетворення для виявлення локальних аномалій на фоні нестаціонарного дрейфу ізолінії, оскільки будь-який складний сигнал із цього простору може бути представлений як сума масштабованих та зміщених вейвлет-функцій.

На відміну від лінійних сигналів, цифрові зображення та матричні структури I формуються як двовимірні масиви $I(x, y)$, що відображають просторовий розподіл інтенсивності або інших фізичних параметрів [12]. Гетерогенність у даному випадку проявляється через поєднання текстурних ознак, контурів об'єктів та специфічних просторових завад, що вимагає переходу до двовимірних операторів трансформації.

Параметричні вектори стану P складаються з наборів дискретних значень $\{p_1, p_2, \dots, p_k\}$, що описують стаціонарні характеристики об'єкта, такі як температура, тиск або параметри режиму. Оскільки ці величини мають різну розмірність та діапазони значень, виникає потреба у проведенні процедур нормалізації перед етапом сумісного аналізу.

Контекстні метадані M включають логічні та структурні змінні, що визначають умови реєстрації інформації та описують системні зв'язки між компонентами (рівняння (1.1)).

Важливою характеристикою такого об'єднання є мультимодальність, яка обумовлює виникнення латентних зв'язків між компонентами різної фізичної природи [13]. Наприклад, нестаціонарний сплеск у підпросторі сигналів S може бути корельований із градієнтною зміною у підпросторі зображень I . Математична оцінка таких зв'язків реалізується через обчислення взаємної інформації між компонентами або шляхом аналізу кореляційної залежності у спільному багатовимірному просторі ознак. Таким чином, ГД можуть бути складною ієрархічною системою, де інформаційна цінність масиву міститься у синергії його різнорідних компонентів.

Важливою рисою ГД є масштабна неоднорідність [14]. У межах одного масиву одночасно співіснують ознаки, що потребують різної роздільної здатності для аналізу. Якщо для опису загального тренду часового ряду достатньо низькочастотного представлення, то для ідентифікації короткочасних імпульсних викидів необхідна висока часова локалізація. Класичні методи, засновані на фіксованому вікні аналізу, не здатні забезпечити адекватне відображення такої структури, що призводить до виникнення конфлікту між необхідною деталізацією та обчислювальною складністю.

Різноманіття форм ГД та їхня мультимодальна природа ускладнюють їх обробку, створюючи умови, за яких традиційні методи втрачають свою ефективність.

Ефект апріорної невизначеності. На початковому етапі формування гетерогенного масиву дослідник часто стикається з відсутністю вичерпної інформації про математичну модель корисного сигналу або точну структуру завад [15]. У гомогенних системах цільові параметри зазвичай відомі заздалегідь (наприклад, гармоніка певної частоти), тоді як у гетерогенних структурах корисний сигнал може змінювати свою форму та амплітуду випадковим чином. Це обумовлює необхідність розробки адаптивних методів ідентифікації ознак [16].

Фактор нестаціонарності та багатомасштабності. Гетерогенні структури відрізняються динамічною зміною енергетичної щільності та основних статистичних моментів (математичного очікування, дисперсії) у часі або просторі [17]. В таких умовах спектральний склад сигналу S або текстурні особливості зображення I не є константами, а перетворення Фур'є виявляється малоефективним через ефект інтегрального усереднення інформації на вікні аналізу. Це призводить до «розмиття» спектра та нівелювання критично важливих локальних особливостей – імпульсних сплесків або перехідних процесів, які у медицині (наприклад, швидкі зміни в ЕКГ) або технічній діагностиці є найбільш інформативними, оскільки сигналізують про зміну стану системи та/або процесу, що досліджується [18, 19].

Інформаційна та обчислювальна складність. Поєднання зазначених характеристик формує головний технологічний бар'єр. Специфіка ГД полягає в тому, що вони потребують одночасно високої роздільної здатності у різних доменах: для зображень це потреба ідентифікувати як дрібні деталі (високі частоти), так і загальний фон (низькі частоти) [20]. Спроба підвищити точність локалізації ознак у гетерогенному середовищі за допомогою стандартних алгоритмів неминує призводити до експоненціального зростання кількості обчислювальних операцій.

Часова десинхронізація та топологічна неоднорідність. Суттєвим викликом є невідповідність метричних просторів, у яких існують кількісні параметри P та структурні метадані M , що створює бар'єр для їхнього узгодження в межах єдиного простору ознак [21]. Додатково ситуація ускладнюється різницею у частотах дискретизації підпросторів, що призводить до виникнення ефекту часового дрейфу. Така десинхронізація робить неможливим використання універсальних лінійних фільтрів для аналізу мультимодальних потоків, оскільки порушується когерентність сигналів у часовій області [22, 23].

Ускладнює обробку ГД також специфічний характер шуму в них. Гетерогенні масиви містять не лише адитивні, а й мультиплікативні шуми та нестаціонарні артефакти, параметри яких динамічно змінюються [24]. Наприклад, у підпросторі динамічних сигналів S (таких, як ЕКГ) це проявляється у вигляді дрейфу ізолінії та м'язових артефактів, що потребує фільтрації без спотворення форми екстремумів (піків). У двовимірних масивах I шум супроводжується різкою зміною локальних властивостей на межах об'єктів та фону [25].

Концептуальна модель утворення ГД наведена на рис.1.1.




Рисунок 1.1 – Концептуальна модель утворення гетерогенного інформаційного об'єкта X

1.1.1 Проблеми обробки ГД в електроніці

Метою обробки гетерогенних даних в електроніці є оцінка параметрів електронних компонентів для визначення серед них якісних і ненадійних і подальшого використання при збиранні апаратури. Особливо це важливо для вибору компонентів апаратури відповідального призначення (систем безпеки автомобілів, блоків орієнтації летальних апаратів та іншого).

В сучасному виробництві апаратури задіяно велике число підприємств, які виробляють малі і середні партії виробів з номенклатурою, яка швидко оновлюється. Оскільки для такого виробництва важливе оперативне виконання замовлень, воно потребує скорочення часу на вимірювання параметрів ЕК. Така оперативність супроводжується або зниженням якості виробів через скорочення числа операцій вимірювання, або зростанням вартості виробів. Вартість виробів може зростати через проведення великого обсягу вимірювань, оскільки для забезпечення достовірності при обробці даних з застосуванням існуючих методів необхідні дані про великі партії виробів.

Для забезпечення оперативності краще проводити обробку даних про малі партії виробів. Але при прийнятті рішень по малим наборам даних через випадкові

помилки в результатах вимірів збільшується апіорна невизначеність і знижується достовірність, яка оцінюється в роботі по критерію середнього ризику.

Часто при відборі більш надійних компонентів для апаратури відповідального призначення потрібно враховувати можливі зміни параметрів виробів з часом. При виробництві виробів швидко змінюваної номенклатури це обумовлює необхідність оперативної адаптації параметрів методів обробки до зміни параметрів виробів з метою забезпечення потрібної достовірності.

Проведений аналіз довів, що в умовах виробництва малих партій виробів знижуються необхідний обсяг апіорних досліджень. Через це зростає апіорна невизначеність даних та знижується ефективність діагностування (в роботі оцінюється як достовірність).

Зниження апіорної невизначеності шляхом збільшення обсягу партій виробів приводить до зростання ресурсомісткості та зниження оперативності при оновленні номенклатури виробів. Тобто виникає протиріччя між ефективністю та оперативністю процедур відбору якісних виробів при зміні їх номенклатури.

В рамках данної роботи це протиріччя може бути вирішене за рахунок удосконалення методів та інформаційних технологій, котрі дозволять при достатній достовірності в умовах невизначеності через малі набори даних вимірів з (ймовірно) високим рівнем шумів в даних, забезпечити потрібний рівень швидкодії та/або знизити кількість обчислень цільової функції (звернень до «оракулу») а відповідно до ресурсоемності вирішення цих задач.

1.1.2 Проблеми обробки ГД в медицині

Сучасний рівень обробки даних наприклад, в телемедицині, часто потребує проведення оперативного аналізу нестационарних періодичних сигналів.

Прикладом таких сигналів можуть бути електрокардіограми (ЕКГ). Своєчасна та точна діагностика серцевих порушень залишається одним з ключових викликів сучасної медицини. Електрокардіографія є одним із найбільш інформативних методів діагностики, що дозволяє виявляти аритмії, ішемічні стани

та інші функціональні порушення роботи серця. Одним із центральних елементів аналізу ЕКГ є детектування QRS-комплексів – швидких високочастотних складових сигналу, що відповідають за деполяризацію шлуночків серця. Саме коректне та автоматизоване виявлення цих піків є критично важливим етапом для подальшого аналізу серцевого ритму, побудови частотних характеристик або виявлення патологій.

При цьому часто вимірювання ЕКГ не дозволяє позбутися шумів. Ці шуми виникають при реєстрації сигналів і при передаванні сигналів по лініям зв'язку. Через високу варіабельність серцевого ритму навіть у одного і того ж пацієнта, часто отримати великі набори даних складно. Ускладнює вирішення цієї задачі і те, що методи обробки медичних даних мають володіти не тільки стійкістю до завад (шуму) в даних, але й необхідною для аналізу швидкістю і достовірністю.

В рамках данної роботи це протиріччя може бути вирішене за рахунок удосконалення методів та інформаційних технологій, котрі дозволять при достатній достовірності і завадостійкості, забезпечити потрібний рівень швидкодії та ресурсоемності вирішення цих задач.

1.2 Загальна схема обробки та аналізу гетерогенних даних

Загальна схема обробки та аналізу гетерогенних даних (рис. 1.2) – це послідовність етапів перетворення цих даних у корисну інформацію, яка передбачає реєстрацію, попередню обробку (наприклад, фільтрацію), перетворення та аналіз у просторовій та/або в частотній області, сегментацію, виділення ознак, аналіз та прийняття рішень. На значній кількості вказаних етапів сучасні дослідження передбачають значні вигоди від використання вейвлет-перетворення [26].



Рисунок 1.2 – Загальна схема обробки та аналізу гетерогенних даних

Загальна схема обробки та аналізу ГД складається з наступних етапів.

Етап 1. Формування та реєстрація (Acquisition). Передбачає перетворення фізичного явища (світла, звуку, тиску) в електричний сигнал. При вимірюванні сигналів датчик фіксує їх зміни в часі, при фіксації зображень матриця камери фіксує фотони світла. На цьому етапі проводиться дискретизація (перетворення безперервного сигналу в набір чисел) та квантування (визначення точності значень).

Етап 2. Попередня обробка (Pre-processing). Мета її – "очистити" дані від шуму та спотворень, внесених через технічні особливості системи формування. На цьому етапі проводиться фільтрація шуму; корекція (вирівнювання яскравості, балансу білого або компенсація спотворень (для ЕКГ), виділення області інтересу (видалення не потрібних для аналізу фрагментів сигналу).

Етап 3. Перетворення та аналіз у просторовій та/або в частотній області (Transformation). Наприклад, Фур'є-перетворення дозволяє побачити, з яких частот складається сигнал, вейвлет-перетворення (ВП) – дозволяє отримати просторово-частотні характеристики сигналів та зображень (табл.1.1).

Етап 4. Сегментація та ідентифікація (виділення ознак (Feature Extraction)). Дозволяє отримати структурні елементи сигналів та зображень. На цьому етапі здійснюється виявлення контурів, форм, текстур для розпізнавання об'єктів на зображеннях, виявлення піків або періодів сигналів.

Етап 5. Аналіз та прийняття рішень (Analysis & Decision). На цьому етапі може бути виконана кластеризація даних («навчання без вчителя», наприклад, коли нема розміченої експертами вибірки даних), прийняття рішень на основі класифікації (при медичній, технічній діагностиці).

Етап 6. Вивід або Візуалізація (Output). Зворотне перетворення цифрових даних у зручний для людини або іншої системи вигляд (відображення на екрані, відтворення через динаміки або запис у базу даних).

Таблиця 1.1 – Порівняння засобів обробки і аналізу ГД

Характеристика	Обробка сигналів (1D)	Обробка зображень (2D)
Змінна	Час (t)	Координати (x, y)
Типовий шум	Завада від мережі живлення, білий шум	"Сіль і перець", розмиття через рух камери
Основний інструмент	Цифрова фільтрація, вейвлет-фільтрація	Нейронні мережі (CNN, KAN, вейвлет- KAN)
Результат	Чистий сигнал, графік, спектр	Чітке зображення, маска об'єкта

Важливою є особливість сучасних підходів до аналізу ГД: На поточний період межа між етапами 4 та 5 майже зникла завдяки глибинному навчанню (Deep Learning). Нейронні мережі часто виконують виділення ознак та прийняття рішень одночасно в межах однієї архітектури.

Фундаментальний зсув у методології стався наприкінці 1980–х років із виникненням теорії вейвлет–перетворення (ВП). Ключовий внесок у розробку цього апарату зробили С. Малла, який запропонував концепцію багатомасштабного аналізу (multiresolution analysis) [27], та І. Добеші, яка обґрунтувала побудову ортогональних вейвлетів із компактним носієм [28]. Вейвлет-аналіз базується на використанні функцій, які здатні змінювати свій масштаб та положення, що дозволяє реалізувати гнучке частотно-часове вікно. Це забезпечує високу роздільну здатність за частотою для низькочастотних компонентів та високу роздільну здатність за часом для високочастотних аномалій [29, 30]. Сучасний етап характеризується інтеграцією цих технологій із методами інтелектуального аналізу, що створює передумови для автоматизації виділення значущих компонентів у ГД [31].

1.2.1 Попередня обробка за допомогою вейвлет-перетворення

Саме здатність вейвлет-перетворення до селекції коефіцієнтів як у часових рядах, так і у матрицях, дозволяє проводити фільтрацію без втрати різких градієнтів

та пікових аномалій [32, 33]. Систематизація виявлених характеристик та відповідних їм аналітичних проблем представлена у табл. 1.2.

Таблиця 1.2 – Характеристика основних типів гетерогенних структур за рівнем аналітичної складності

Тип інформаційної структури	Домінуюча аналітична проблема	Пріоритетний напрям обробки
Одновимірні динамічні сигнали (S)	Локалізація пікових аномалій на фоні дрейфу ізолінії та нестационарних завад	Багатомасштабна часова декомпозиція та адаптивна фільтрація
Двовимірні матричні масиви (I)	Сегментація структурних ознак (контурів, текстур) при високій зашумленості градієнтних переходів	Просторове вейвлет-перетворення та градієнтний аналіз
Мультимодальні масиви з метаданими (X)	Структурна неоднорідність	Інтеграція та нормалізація ознак

ВП дозволяє обробляти та аналізувати дані одночасно у часовій (або просторовій) та частотній областях. Це робить його майже незамінним для обробки та аналізу сигналів, які мають різкі зміни, піки або розриви. В табл. 1.3 наведені типи даних та приклади вейвлет-функцій (ВФ), для обробки яких традиційно використовують ВП. Вибір ВП залежить від того, чи потрібно стиснути дані, видалити шум або виявити певні закономірності. Оскільки існує багато різновидів сигналів і прикладних задач, де здійснюється їх обробка з ВП, вироблені і певні традиційні способи використання вейвлетів. Наприклад:

- ВФ Добеші часто обирають для аналізу сигналів. Чим вищий порядок (наприклад, db10 проти db2), тим краще буде позбавлений шуму сигнал;
- Mexican Hat дуже схожий за формою на типовий сплеск у біологічних сигналах, тому вважають, що він підходить для виявлення піків;
- Morlet часто використовують для гармонійного аналізу, коли важливо точно визначити частоту в конкретний момент часу.

Таблиця 1.3 – Типи даних та варіанти ВФ для їх обробки

Тип даних	Завдання обробки	Рекомендовані ВФ	Приклад застосування
Сигнали звуку та аудіо	Очищення від шуму, компресія	Daubechies (Добеші) (db4, db8), Symlets	Видалення фонового шипіння в записі
Медичні сигнали (ЕКГ, ЕЕГ)	Виявлення піків R, аналіз ритму	Mexican Hat, Coiflets	Діагностика серцевої аритмії
Зображення (фото)	Стиснення, покращення чіткості	Haar (Хаар), Biorthogonal (CDF 9/7)	Стандарт стиснення JPEG 2000
Геофізика, сейсміка	Пошук розломів, аналіз пластів	Morlet (Морле), Meyer	Аналіз відлуння при пошуку нафти
Фінансові ряди	Аналіз волатильності, трендів	Haar, Daubechies	Прогнозування стрибків на фондовому ринку
Відео	Міжкадрове стиснення	3D Haar, Biorthogonal	Трансляція потокового відео високої чіткості

В роботі використано ВФ Хаара. Через їхню обчислювальну нескладність їх вважають гідними для виявлення різких перепадів у даних (наприклад, інтенсивності на зображеннях) шляхом оцінки значення похідної. Через те, що вейвлет Хаара є розривним (ступінчастим), він не дозволяє обчислити похідну у класичному сенсі (як диференціювання гладкої функції). Однак він спроможний для чисельного апроксимування похідної або виявлення стрибків (крапок, де похідна прагне нескінченності). Вейвлет Хаара визначається як [30]:

I

$$\psi(t) = \begin{cases} 1, & 0 \leq t < 1/2 \\ -1, & \frac{1}{2} \leq t < 1 \\ 0 & \end{cases} \quad (1.3)$$

При обчисленні дискретного ВП Хаара визначаються коефіцієнти деталізації d_j . Цей коефіцієнт деталізації Хаара на першому рівні розкладання – це нормована різниця між двома сусідніми відліками сигналу:

$$d_i = \frac{x_{2i} - x_{2i-1}}{\sqrt{2}} \quad (1.4)$$

який за структурою відповідає формулі кінцевої різниці для похідної:

$$f'(x) \approx \frac{f(x+h) - f(x)}{h}. \quad (1.5)$$

Відповідно для такої оцінки (1.5) притаманна відома властивість першої похідної – висока чутливість до шуму в даних, тому в роботі, щоб отримати стійкість до шуму в даних використовується оцінка з урахуванням довжини носія ВФ.

Попередня обробка сигналів за допомогою ВП – це один із найпотужніших методів очищення даних, особливо коли сигнал містить нестационарні особливості (різкі стрибки, піки) або шум, що змінюється у часі. На відміну від класичного перетворення Фур'є, вейвлети дозволяють аналіз сигналів одночасно у часовій та частотній областях.

Основні етапи використання ВП для попередньої обробки:

1) декомпозиція. Сигнал розкладається на два типи коефіцієнтів за допомогою вибраного «материнського вейвлета» (наприклад, Daubechies, Symlet, Coiflet):

- апроксимуючі (Approximation): низькочастотна складова (загальний тренд сигналу).
- деталізуючі (Details): високочастотна складова (шум, різкі зміни, деталі).

2) порогова обробка (Thresholding). Це ключовий етап для видалення шуму (denoising). На цьому етапі проводять обробку з деталізуючими коефіцієнтами:

- жорсткий поріг (Hard thresholding): коефіцієнти, менші за поріг, обнуляються; інші залишаються без змін.

- м'який поріг (Soft thresholding): менші за поріг обнуляються, а ті, що більші
- зменшуються на величину порогу (це робить сигнал гладшим).

3) реконструкція. При цьому виконується обернене ВП з використанням змінених коефіцієнтів для відновлення "чистого" сигналу.

Переваги над стандартними фільтрами:

- збереження піків: вейвлети прибирають шум, не "замилуючи" різкі фронти сигналу (наприклад, зубці R на ЕКГ);
- адаптивність: можливість вибрати рівень декомпозиції залежно від рівня шуму сигналу;
- локалізація: можливість виявити короткочасні аномалії, які обробка по Фур'є може не визначити.

Такий підхід часто використовується при аналізі сигналів та зображень, а саме: в аналізі медичинських сигналів (наприклад, для очищення ЕКГ та електроенцефалограм від наводок мережі та рухів пацієнта) [34], в технічних задачах, наприклад, при аналізі вібрацій двигунів для пошуку дефектів.

1.2.2 Сегментація за допомогою вейвлет-перетворення

У значній частині відомих методів сегментації застосовується ВП, що дозволяє виділити об'єкти заданих геометричних розмірів шляхом локалізації перепадів обраних значень ознаки сегментації. Такою ознакою сегментації часто є перепади інтенсивності або текстура зображення.

Сегментацією називається розбиття зображень на області, однорідні за якоюсь ознакою або групою ознак. Серед методів сегментації виділяють дві основні групи: класифікаційні та детекторні. Класифікаційні методи послідовно використовують такі методи, як попередня обробка, ідентифікація та класифікація. Основними їх недоліками є складність та великий обсяг обчислювальних витрат. Для детекторних методів ознакою сегментації є інтенсивність, а результати перетворення застосовуються для методів контурної сегментації. В процесі

досліджень цих методів було проведено дослідження властивостей однорідних областей і розробити адекватний цим властивостям детектор.

Це (як визначили автори [35]) обумовило необхідність розробки методів сегментації, що володіють стійкістю до перешкод і високою якістю виділення меж областей з додатковою вимогою щодо швидкодії.

Одним з відомих методів сегментації є порогова сегментація. Вона потребувала підвищення завадостійкості і точності аналізу гістограми.

У ряді робіт для аналізу гістограм використовували вейвлет-аналіз [36], тому що доведено, що саме цей апарат ефективний при аналізі таких високо локалізованих та нестационарних функцій, якою є гістограма зображення. Однак було визначено, що ряд ВФ скоріш згладжують гістограму і не дозволяють забезпечити необхідну точність. У роботах [36] розроблено гіперболічне ВП (ГВП), що відрізняється завадостійкістю та дозволяє з високою точністю та регульованою детальністю локалізувати характерні особливості сигналів. Саме його і було використано під час аналізу гістограм зображень шляхом обчислення згортки вхідного сигналу з гіперболою. Як вхідний сигнал використовується гістограма $h(x)$:

$$g(x) = \frac{1}{\alpha x} * h(x) = \frac{1}{\alpha n} \sum_{i=1}^n \frac{h(x_i)}{x_i} \quad (1.6)$$

де $*$ – операція згортки.

Як базисні функції ВП використовувалися гіперболічні функції з носіями ($f_1 \dots f_n$) різної довжини. На рис. 1.3 зображені гіперболічні ВФ (ГВФ) з довжиною носіїв 18 і 10 відповідно.




Рисунок 1.3 – Імпульсні характеристики різних ГВФ: а) – $\Psi_2(i)$; б) – $\Psi_3(i)$

Дослідження властивостей ГВП показали, що вейвлет з протяжним носієм забезпечує високу стійкість до завад, проте має низьку точність. При зниженні протяжності носія завадостійкість знижується, а точність зростає.

Тому була розроблена наступна ієрархічна методика знаходження екстремумів гістограми зображення з ГВП:

- 1) згідно з метою обробки та даними про обсяг виділених сегментів, вибирається початкова довжина носія ГВП, що дозволяє виділити сегменти необхідного обсягу і при цьому згладити малорозмірні флуктуації;
- 2) обчислюється згортка ГВФ з гістограмою;
- 3) виділяються області локальних екстремумів гістограми, у яких ГВП перетинає вісь абсцис;
- 4) довжина носія зменшується та проводиться уточнення координат екстремумів. З цією метою повертаємось до п.2;
- 5) критерієм зупинки є незмінна при зменшенні довжини носія координата екстремуму;
- 6) визначається зміна знаку ГВП при перетині осі абсцис. В області максимуму знак змінюється з плюсу на мінус, в області мінімуму – навпаки.

Результат згортки $g(x)$ носія з гістограмою зображення представлений на рис. 1.4. Нулі $P_1 \dots P_5$ функції $g(x)$ відповідають яскраво вираженим екстремумам

функції $h(x)$ (умовно назвемо їх глобальними). Довжину носія ВФ $N=51$ обрано експериментально.

З отриманих точок екстремумів на першому етапі було підраховано, що середня величина відхилення отриманих точок екстремумів від ідеальних щонайменше 0.02. Згідно з ієрархічною методикою для більш точного виділення екстремумів обчислювалася згортка околиці кожної з точок $P_1 \dots P_5$ на гістограмі з ГВФ зі зменшеною довжиною носія.





Рисунок 1.4 – Гістограма (1); результат згортки з гіперболічною ВФ (2)


З отриманих результатів було зроблено такі висновки. Підхід для аналізу екстремумів гістограм перевершує диференціювання по завадостійкості та диференціювання згладженої гістограми за точністю і поєднує в собі високі показники і за точністю та завадостійкістю. Було встановлено, що ієрархічне використання обробки гістограми з ГВП дозволяє з відхиленням трохи більше 0.004 виділити яскраво виражені екстремуми гістограми. Також визначено, що застосування такого підходу дозволило зменшити час обробки гістограми та підвищити стійкість алгоритму знаходження екстремумів до впливу перешкод.

Важливою областю використання контурної сегментації є також обчислення значень карти глибин, що надає інформацію про глибину розташування об'єктів на

основі порівняння зображень, отриманих з двох камер, розташованих на певному рухомому об'єкті (рис.1.5).



а



б



в

Рисунок 1.5 – Формування ознак для побудови карти глибин: а) – вхідна стереопара (правий та лівий кадри); б) – фрагменти строк інтенсивностей правого та лівого кадру; в) – шаблон, що показує розподіл інтенсивностей в околі екстремумів в рядку зображення

Для ілюстрації наведено шаблони огинаючої яскравості у вигляді блоків з 3-х пікселів, для лівого та правого кадру зображення (рис. 1.5, в). Шаблони показують розподіл інтенсивності біля екстремуму в даному рядку зображення для лівої та правої камери (рис. 1.5, б). Обидва шаблони мають форму "пік". Чорними квадратами виділено рівні яскравості кожного пікселя в блоках, сірими – межі розкиду яскравості. Диспаратність між блоками дорівнює 4 пікселям по осі X, абсолютна різниця по яскравості дорівнює 2. У реальних стереозображеннях різниця по яскравостях може досягати 30.

Відомий підхід щодо визначення диспаратності – StereoBM [37 - 40] потребує виконання обчислювально-витратних процедур, таких, як мінімальна сума квадратів різниць яскравості (Sum of Squared Differences, SSD) і мінімальний нормалізований крос-кореляційний коефіцієнт (Normaliz Cross- Correlation), що зменшує швидкодію обчислень.

Обчислювальна складність може бути знижена на цьому етапі, якщо при обчисленні диспаратності використовувати контури об'єктів. Слід зазначити, що контури є найбільш інформаційно значущою частиною зображень об'єктів та їх аналіз дозволяє значно зменшити кількість обчислювальних операцій [41]. Однак, слід зазначити, що в цьому випадку якість карти глибин залежить від ефективності методів виділення контурів, що застосовуються.

Тому в роботі [42] запропоновано використовувати методику оцінки глибини шляхом виділення контурів об'єктів з регульованою деталізацією у просторі ВП (рис. 1.6):

- рядки зображення лівого кадру (рис. 1.6, б) та правого кадру піддаються згортці з ВФ заданого масштабу та виділяються області контурів (рис. 1.6, в);
- знаходиться відстань між контурами об'єктів та відповідне йому значення диспаратету;
- обробка при необхідності здійснюється за рядками та стовпцями. Результати поєднуються за схемою логічного додавання АБО;
- за потреби повторюється для різних масштабів.




Рисунок 1.6 – Методика оцінки глибини шляхом контурної сегментації у просторі ВП: а) – тестове зображення (ліва камера); б) – фрагмент рядку інтенсивностей, ліва камера; в) – результат ВП для зображень лівої та правої камери при довжині носія ВФ $s=1$

Дослідження довели, що при довжині носія ВФ $s=1$ дрібні та великі деталі зображення мають максимуми, схожі за амплітудою. У міру збільшення масштабу відносні розміри піків дрібних деталей зменшуються і водночас збільшується амплітуда піку на межах деталей більших розмірів. [42]. Ця методика дозволяє змінювати рівень деталізації зображень, що забезпечують високу завадостійкість при відносно високій швидкодії та забезпечити наближену оцінку інформації про глибину розташування об'єктів.

Таким чином, для побудови карти глибин використовують дві групи методів – локальні та глобальні. Алгоритми на базі локальних методів відрізняються швидкодією та невисокою точністю, глобальні методи дозволяють підвищити

точність, але володіють низькою швидкістю. Для знаходження компромісу між точністю та швидкістю активно розробляються методи на основі оптимізаційних алгоритмів. Такі методи можуть бути використані для оцінки інформативних ознак, зіставлення фрагментів та/або оптимізації витрат при аналізі зображень, для уточнення невідповідності та ін. [37].

1.2.3 Оптимізація за допомогою вейвлет-перетворення

Проведено аналіз, який показав, що при апріорній невизначеності існуючі методи оптимізації з оцінкою градієнта відрізняються низькими завадостійкістю і погрішністю, а субградієнтні методи – високими завадостійкістю і погрішністю.

В зв'язку з цим розроблені відомі методи пошуку оптимуму з використанням вейвлет-обробки [43, 44].

Відомим є метод регулярного ітераційного пошуку на основі гіперболічного вейвлет-перетворення (ГВП) [43, 44]. Так, наприклад, одновимірне ГВП:

$$h_n = \frac{1}{\pi} \int \frac{J(\mathbf{a})}{c_n - a_n} da_n \quad (1.7)$$

Умовою оптимуму вважають рівність нулю частинних похідних ГВП $HWT(\mathbf{c}) = 0$. Для синтезу регулярних ітераційних алгоритмів (для одновимірного випадку) був складений оператор $HWT(\mathbf{c}) = (h_1, \dots, h_N)$:

$$\mathbf{c}[k] = \mathbf{c}[k - 1] - \gamma[k]HWT(\mathbf{c}[k - 1]), \quad (1.8)$$

де $\gamma[k]$ – крок на k -ій ітерації;

k – номер ітерації.

Для пошуку екстремуму за (рівняння (1.8)) необхідно визначити таке $\mathbf{c}[k]$, при котрому ГВП $HWT(\mathbf{c}[k-1])$ дорівнює нулю з точністю δ , що має забезпечити виконання рівності $\mathbf{c}[k] = \mathbf{c}[k-1]$.

Коефіцієнт γ дозволяє регулювати швидкість збіжності ітераційного процесу. На характер процесу істотно впливає масштаб базисної функції ГВП. Швидкість збіжності ітераційного процесу зростає відповідно до збільшення γ і масштабу (відповідно кількість ітерацій для знаходження екстремуму зменшується). Однак існують обмеження на коефіцієнт γ для кожного масштабу ГВП j : $\gamma_{\min}^j < \gamma < \gamma_{\max}^j$.

За результатами досліджень [43 - 45] при пошуку максимуму функції двох змінних (рис. 1.7, а) $z = 10 - (x_1 - 1)^2 - (x_2 - 2)^2$ з додаванням до вихідної функції адитивної гаусівської завади з значеннями дисперсії ($\sigma^2 = 0,1$ (рис. 1.7, б)), завдання пошуку екстремуму вихідної функції вирішувалося методом ітераційного пошуку у просторі ГВП та градієнтним методом. Обидва методи показали близьку швидкість збіжності та точність щодо координат екстремуму. Однак при додаванні адитивної гауссівської перешкоди градієнтний метод (і аналогічні з використанням похідних першого та вищих порядків) виявилися не працездатними. Методи ітераційного пошуку у просторі ГВП показали хорошу працездатність (рис. 1.7).

Завдання пошуку екстремуму вихідної функції вирішувалося методом ітераційного пошуку у просторі ГВП та градієнтним (квазиньютонівським) методом. Обидва методи показали близьку швидкість збіжності та точність щодо координат екстремуму. Однак при додаванні адитивної гауссівської перешкоди градієнтний метод (і аналогічні з використанням похідних першого та вищих порядків) виявилися не працездатними. Методи ітераційного пошуку з допомогою ГВП показали хорошу працездатність (рис. 1.7) [43 - 45]




Рисунок 1.7 – Поверхні тестових функцій: а) – вихідна; б) – з адитивною гаусівською завадою, $\sigma^2 = 0,1$ (в) [43-46]

В процесі досліджень [43 - 45] було визначено, що для пошуку екстремуму мають бути використані дійсні вейвлети у вигляді непарних симетричних функцій, які мають компактний або ефективний носій, такі як вейвлет Хаара, вейвлет на основі функції Гауса, обмежений синус-вейвлет, та базисна функція ГВП. Ці функції можуть використовуватися як базисні, бо задовольняють необхідним вимогам (локалізації, допустимості, осциляції та обмеженості) [43 - 46]. Частотні властивості вказаних функцій також були досліджені (табл 1.4). При цьому були визначені особливості вказаних вейвлетів, а саме – значення першого максимуму амплітуди частотної характеристики.

В результаті досліджень було визначено, що значення частоти в точці такого екстремуму зменшується обернено пропорційно масштавному рівню ВП, що і визначає частотно-селективні властивості відповідних ВФ. В цій таблиці s – масштаб ВФ.

В роботі [43 - 46] також було встановлено, що розглянуті ВФ мають різні фільтруючі властивості: обробка з ВФ Гауса призводить до «розмивання» границь об'єктів (деталей сигналу та/або зображення), базисні гіперболічні ВФ, ВФ Хаара та «обмежений синус» – мають бокові пелюстки в передавальних частотних характеристиках, що забезпечує можливість підкреслення більш високочастотних складових з меншою інтенсивністю.

Тому для подальших досліджень були обрані методи з використанням гіперболічних ВФ та ВФ Хаара, бо методи оптимізації та створені на їхній основі методи адаптивної фільтрації, класифікації та кластеризації в залежності від рівня шуму в даних та потрібної точності пошуку потребують регулювання детальності (в рамках задачі – пошуку екстремуму відповідних функціоналів з потрібною точністю). Це і дозволяє робити для нестационарних сигналів при обробці та аналізі гетерогенних даних частото-часова локалізація особливостей цільової функції на основі зміни довжини носія ВФ (тобто зміни роздільної здатності).

Таблиця 1.4 – Частотно-виборчі властивості базисних вейвлет-функції

Вейвлет	Функція	Модуль перетворення Фур'є	ω_{extr}	$\omega_{max} s, f_d, n$
Хаара	$\psi(x, s) = \begin{cases} 0, & x > s \\ \text{sign}(x), & x \leq s \end{cases}$	$\hat{\psi}(\omega, s) = \frac{4 \sin^2\left(\frac{\omega s}{2}\right)}{\omega}$	$\frac{2.33}{s}$	$\omega_{max} s = 20c^{-1}; \quad f_d > 0.07 \text{ Гц}; \quad n > 15$
Гаусса	$\psi(x, s) = -\frac{1}{\sqrt{2\pi}} \frac{x}{s} \exp\left(-\frac{x^2}{2s^2}\right)$	$\hat{\psi}(\omega, s) = \omega s^2 e^{-\frac{\omega^2 s^2}{2}}$	$\frac{1}{s}$	$\omega_{max} s = 2.0c^{-1}; \quad f_d > 0.16 \text{ Гц}; \quad n \geq 9$
«Розщеплена» функція Гаусса	$\psi(x, s) = \frac{\text{sign}(x)}{\sqrt{2\pi}} \exp\left(-\frac{x^2}{2s^2}\right)$	$\hat{\psi}(\omega, s) = \frac{2}{\sqrt{\pi}} e^{-\frac{\omega^2 s^2}{2}} \int_0^{\frac{\omega s}{\sqrt{2}}} e^{-z^2} dz$	$\frac{1.31}{s}$	$\omega_{max} s = 1.4c^{-1}; \quad f_d > 0.21 \text{ Гц}; \quad n \geq 25$
Обмежений синус	$\psi(x, s) = \begin{cases} 0, & x > s\pi \\ \sin\left(\frac{x}{s}\right), & -s\pi \leq x \leq s\pi \end{cases}$	$\hat{\psi}(\omega, s) = \frac{2s}{1 - \omega^2 s^2} \sin(\omega s \pi)$	$\frac{0.838}{s}$	$\omega_{max} s = 1.5c^{-1}; \quad f_d > 0.08 \text{ Гц}; \quad n$
Функція ГВП	$\psi(x, s) = \begin{cases} 0, & x > \gamma s \\ \frac{1}{1 - \frac{x+1}{s}}, & -\gamma s \leq x \leq -\varepsilon \\ 0, & -\varepsilon < t < \varepsilon \\ \frac{1}{1 + \frac{x-1}{s}}, & \varepsilon \leq x \leq \gamma s \end{cases}$	$\hat{\psi}(\omega, s) = 2s \int_{\varepsilon}^{\gamma s} \frac{\sin(\omega x)}{s + x - 1} dx$	$\frac{2.84}{\gamma s}$	$\omega_{max} s = 6.9c^{-1}; \quad \gamma = 8, \varepsilon = 1; \quad f_d > 0.08 \text{ Гц}; \quad n \geq 16$

Для розв'язання протиріччя між завадостійкістю та точністю пошуку екстремуму з можливостями регульованої деталізації було запропоновано підхід до оптимізації з ВП – мултистартову оптимізацію з ВП (МОВП), який реалізується за ітеративною схемою [47]

$$\mathbf{c}[n] = \mathbf{c}[n-1] - \gamma[n] \mathbf{WT}_k(\mathbf{Q}(\mathbf{x}[n], \mathbf{c}[n-1])) \quad (1.9)$$

де $\mathbf{Q}(\mathbf{x}, \mathbf{c})$ – функціонал вектору параметрів $\mathbf{c} = (c_1, \dots, c_N)$, який залежить від вектору випадкових послідовностей чи процесів $\mathbf{x} = (x_1, \dots, x_M)$;

$\gamma[n]$ – крок;

n – номер ітерації;

k – номер старту;

$$\mathbf{WT}_k(\mathbf{Q}(\mathbf{x}[n], \mathbf{c}[n-1])) = \{G_{1k}, G_{2k}, \dots, G_{Nk}\} \quad (1.10)$$

визначає напрямок пересування до екстремуму,

$$G_{jk} = \frac{1}{S_k} \sum_{\substack{i=-\frac{S_k}{2} \\ i \neq 0}}^{\frac{S_k}{2}} Q(\mathbf{x}[n], \mathbf{c}_j + ia) \cdot \Psi_k(i) \quad (1.11)$$

В (рівняння (1.11)) S_k – довжина носія ВФ на k -ому старті (S_k – парне число);
 a – крок дискретизації ВФ; $\Psi_k(i)$ – ВФ на k -ому старті (табл.1.5, рис.1.8);
 $j = 1, \dots, N$ – розмірність вектору параметрів.

Крок $\gamma[n]$ обирається згідно з рекомендаціями для пошуку оптимуму з оцінкою градієнта: $\gamma[1] = 0,4, \dots, 0,6$. При зміні знаку $\mathbf{WT}_k(\mathbf{Q}(\mathbf{x}[n], \mathbf{c}[n-1]))$ при переході через оптимум на $n-1$ кроці $\gamma[n]$ приймає значення $\gamma[n] = 0,5 \cdot \gamma[n-1]$.

В результаті досліджень завадостійкості, швидкості збіжності і погрішності для оцінки напрямку пошуку координати екстремуму в (рівняння (1.10)) потрібно використовувати симетричні і нестационарні вейвлет-функції. В даній роботі для

оцінки напрямку пошуку координати екстремуму (рівняння (1.10)) на першому

$$\text{етапі обрана ВФ Хаара } \Psi_1(i) = \begin{cases} 1, \text{ якщо } i = 1, \dots, \frac{s_1}{2} \\ -1, \text{ якщо } i = -1, \dots, -\frac{s_1}{2} \end{cases}$$

i – на наступних етапах – нестационарні ВФ, отримані за схемою (табл.1.5).

Таблиця 1.5 – Параметри ВФ для методу МОВП

Назва	Позначення	Значення параметру					
Номер старту	k	2	3	4	5	6	7
Масштаб ВФ	α_k	1	2	3	4	5	–
Довжина носія	s_k	20	10	6	4	4	2
Вид ВФ	$\Psi_k(i)$	$\begin{cases} \frac{1}{\alpha_k(i +1)}, \text{ якщо } i > 0, \\ -\frac{1}{\alpha_k(i +1)}, \text{ якщо } i < 0, \\ i \in [-\frac{s_k}{2}, +\frac{s_k}{2}], \quad i \neq 0 \end{cases}$					$\begin{cases} 1, & \text{якщо } i = 1 \\ -1, & \text{якщо } i = -1 \end{cases}$

Метод МОВП з вихідними даними: δ_1 – погрішність пошуку оптимуму старту; δ_2 – погрішність пошуку оптимуму прикладної задачі; $k_{\max}$ – максимальна кількість стартів, реалізується в наведеній нижче послідовності.

Крок 1. Визначаються: $c[0]$ – початкове наближення до координати оптимуму; $\gamma[1]$ – крок; вид ВП і ВФ; a – крок дискретизації ВФ; s_1 – довжина носія ВФ Хаара першого старту $\Psi_1(i)$; $k = 1$, $n = 1$.

Крок 2. Оцінюється напрямок пошуку по (рівняння (1.10)) в точці наближення до координати оптимуму для старту k . При $k = 1$ для цього використовується зважена сума з ВФ Хаара $\Psi_1(i)$ (в точці $c[0]$ при $n = 1$) (рис. 1.8). Довжина носія s_1 для ВФ Хаара $\Psi_1(i)$ визначається при аналізі цільової функції.

Інтегральний характер такого ВП дозволяє знизити чутливість до локальних екстремумів і виділити сегмент цільової функції, де, як показали дослідження, з високою ймовірністю знаходиться глобальний оптимум, і (часто) з високою погрішністю визначити його координату.

Крок 3. Виконується пошук оптимуму $Q(x, c)$ по (1) при $k \leq k_{\max}$, інакше – зупинка.

Крок 4. Якщо на ітерації n виконується умова $|c[n] - c[n-1]| \leq \delta_1$, пошук на поточному старті закінчується, інакше – $n = n + 1$ і перехід до кроку 2.

Крок 5. Якщо $k > 1$ і знайдена в результаті пошуку на k -ому старті координата оптимуму відрізняється від результату $k - 1$ старту не більше ніж на δ_2 – зупинка; в протилежному випадку, чи якщо $k < k_{\max}$, то збільшується номер старту $k = k + 1$, обирається ВФ для оцінки напрямку пошуку (2) (при $1 < k < k_{\max}$ – ВФ $\Psi_k(i)$ (див. табл.1)), при $k = k_{\max}$ напрямок пошуку оцінюється шляхом дискретного диференціювання (з $\Psi_7(i)$, табл.1.5) і здійснюється перехід до кроку 2.




Рисунок 1.8 – Різні ВФ для оцінки напрямку пошуку: $\Psi_k(i)$, $k = 1, \dots, 6$.

Проведені дослідження розробленого методу оптимізації, а саме погрішність, швидкість збіжності і завадостійкість.

Досліджено погрішність визначення координати екстремуму на різних стартах методу МОВП з ВФ $\Psi_1(i)$ і з ВФ $\Psi_3(i)$. Для цього синтезована асиметрична тестова функція $f_1(x) = x^2 \cdot e^{xm}$, з $m = 0 \dots 0,005$ – коефіцієнтом регулювання асиметрії і $x \in (-500; 500)$. Встановлено, що при кроці дискретизації $a = 50$ і довжині носія ВФ $s_1 = 10$ відносна погрішність d визначення оптимуму функції $f_1(x)$ з ВФ $\Psi_1(i)$ не залежить від початкової точки пошуку, прямо пропорційна коефіцієнту асиметрії і для максимального дослідженого значення $m = 0,005$ складає 0,3 % (крива 1 на рис. 1.9). Абсолютна погрішність складає 0,3. Для оцінки $\Psi_3(i)$ ці погрішності 0,1 % (крива 2 на рис. 2) і 0,08 відповідно.




Рисунок 1.9 – Залежність відносної погрішності d від коефіцієнту асиметрії m при визначенні екстремуму з різними ВФ

Досліджено завадостійкість методу з використанням функції Де Іонга 1 $f_4(x) = x^2$ з доданням завади (при $x \in (-205; 205)$). Завада була розподілена по нормальному закону з нульовим середнім і середньоквадратичним відхиленням (СКВ) від 0 до 40000, максимальне значення функції було $f_4(x) = 42000$. При

відношенні сигнал/завада по амплітуді до 1,05 метод дозволив вийти в окіл глобального мінімуму з погрішністю $\delta \leq 10^{-2}$.

Для використання в тих задачах, де необхідна підвищена швидкодія, запропоновано підвищити швидкість збіжності методу МОВП за рахунок звуження області пошуку екстремуму шляхом введення обмежень. Аналіз існуючих методів урахування обмежень показав, що вони можуть приводити до структури цільової функції типу «яр» і зниження швидкодії. Для відомого методу центрів менш властивий цей недолік, однак йому для збіжності необхідна стартова точка пошуку в околі глобального оптимуму. Для пошуку такої точки в роботі запропоновано використовувати ВФ $\Psi_1(i)$ і її властивість – з високою ймовірністю виділяти сегмент цільової функції з глобальним оптимумом.

На цих засадах розроблено метод мультістартової оптимізації в просторі вейвлет-перетворення з обмеженнями другого роду (МОВП1). Швидкодію цього методу у порівнянні з базовим методом МОВП підвищено за рахунок звуження області пошуку на етапі обробки з ВФ $\Psi_k(i)$ (при $k > 1$) шляхом формування нового функціонала. В цьому функціоналі враховуються обмеження у вигляді нерівностей $g_j(\mathbf{c}) \geq 0$, $j = \overline{1, N}$, значення яких отримані при пошуку на першому старті.

Метод з обмеженнями другого роду (МОВП1) з вихідними даними базового методу МОВП, реалізується в наведеній нижче послідовності.

Крок 1. Пошук оптимуму $Q(\mathbf{x}, \mathbf{c})$ здійснюється з допомогою методу МОВП (кроки 1-4) з визначенням координати мінімуму $\mathbf{c}_H^*$ з погрішністю δ_1 на старті з $\Psi_1(i)$. Значення $\mathbf{c}_H^*$ надалі використовується для визначення обмеження $g(\mathbf{c}_H^*)$.

Крок 2. Згідно з методом центрів формується новий функціонал $Q_1(\cdot)$

$$\begin{aligned} Q_1(\mathbf{x}[n], \mathbf{c}[n], g(\mathbf{c}_H^*)) = \\ = -\ln(Q(\mathbf{x}[n], \mathbf{c}[n-1]) - Q(\mathbf{x}[n], \mathbf{c}_H^* - \mathbf{b}) - \ln(\mathbf{c}[n-1] - g(\mathbf{c}_H^*)), \end{aligned} \quad (1.11)$$

де $Q(\mathbf{x}[n], \mathbf{c}[n-1])$ – вихідний функціонал на кроці пошуку $n-1$;

$Q(x[n], c_n^*)$ – його значення в точці мінімуму, знайденого з допомогою ВФ $\Psi_1(i)$;

$g(c_n^*) \geq c_n^* - b$ – обмеження; $b \geq 0$ – параметр, який визначається на етапі апріорних досліджень функціоналу якості з урахуванням $b \ll \delta_1$ та $b \ll \delta_2$.

Крок 3. Збільшується номер старту $k = k + 1$ і далі пошук оптимуму $Q_1(\cdot)$ здійснюється по крокам 2 – 5 базового методу *МОВП* при номерах старту $1 < k \leq k_{\max}$.

Досліджені властивості методу *МОВП1* порівняно з *МОВП* в умовах завад з використанням тестової функції де Іонга 1 $f_4(x) = x^2$ з доданням до неї завади (завада розподілена по нормальному закону з нульовим середнім і СКВ від 0 до 1000, максимальне значення $f_4(x) = 6400$). При зниженні *SP* – відношення сигнал/завада по амплітуді до 6,4 швидкодія методу *МОВП1* більша в середньому в 1,3 рази (рис. 1.10, а), відносна погрішність пошуку мінімуму – більша в 1,25 рази (рис. 1.10, б).




Рисунок 1.10 – Результати експериментальних досліджень методів *МОВП* і *МОВП1*: а) – швидкість збіжності; б) – відносна погрішність

Для ряду задач, коли необхідна підвищена швидкодія при низькому співвідношенні сигнал/завада по амплітуді цільових функцій, запропоновано *метод мультістартової оптимізації в просторі ВП з ітеративною оцінкою обмежень (МОВП2)*. В цьому методі проводиться ітеративна оцінка обмежень другого роду на основі відомої властивості оцінок градієнта і субградієнта змінювати знак при переході через оптимум.

Метод з ітеративною оцінкою обмежень (МОВП2) з вихідними даними базового методу *МОВП* реалізується в наведеній нижче послідовності.

Крок 1. Виконуються кроки 1-5 базового *методу МОВП* до зміни знака перетворення $WT_k(Q(x[n], c[n-1]))$ (2), яке визначає напрямок пересування до екстремуму.

Крок 2. Визначаються обмеження для наступного старту ($g_1(c[n])$ и $g_2(c[n])$):

$$g_1(c[n]) \geq c^*[n-1]; g_2(c[n]) \geq c^*[n] \quad (1.12)$$

де $c^*[n-1]$ – координата екстремуму на кроці $[n-1]$ з попереднім знаком,

$c^*[n]$ – координата екстремуму на кроці n , де знак змінився.

Крок 3. Визначається довжина носія ВФ s_k для наступного старту шляхом вибору з ряду $s_k = \{4, 6, 10, 20\}$ (табл.1.4) згідно $s_k \leq \frac{|g_2(c[n]) - g_1(c[n])|}{a}$.

Крок 4. По обраному s_k (табл. 1.5) визначається номер наступного старту $1 < k \leq k_{\max}$ (на відміну від базового методу *МОВП* він може відрізнятися від попереднього номеру старту більше ніж на 1).

Крок 5. Визначають вид і параметри ВФ $\Psi_k(i)$ для оцінки напрямку пошуку, задається номер ітерації $n = n + 1$ і здійснюється перехід до кроку 2 базового методу *МОВП*.

Досліджені властивості методу *МОВП2* порівняно з *МОВП* в умовах завад з використанням тестової функції де Іонга $f_4(x) = x^2$. При зниженні SP –

відношення сигнал/завада по амплітуді до 2 – швидкодія (по таймеру) методу МОВП2 більша в середньому в 1,12 рази (рис. 1.11, а) відносна погрішність пошуку мінімуму – більша в 1,15 рази (рис. 1.11, б).

По аналізі результатів експериментальних досліджень розроблених методів МОВП було визначено, що вони можуть бути рекомендовані для використання в широкому колі прикладних задач оптимізації, в яких цільова функція мультимодальна та/або піддається впливу випадкових збурень.

На основі метода МОВП також створено метод пошуку координат екстремумів періодичних сигналів [48].

При пошуку екстремумів періодичних сигналів в результаті досліджень завадостійкості, швидкості збіжності та погрішності для оцінки напрямку пошуку координати екстремуму в (рівняння (1.10)) використані тільки симетричні і нестационарні ВФ Хаара [49]. Такий підхід дозволяє визначити діапазон змін координат кожного екстремуму досліджуваного періодичного сигналу, на основі порівняння з порогом.




Рисунок 1.11 – Результати експериментальних досліджень методів МОВП і МОВП2: а) – швидкість збіжності (в секундах); б) – відносна погрішність визначення координати екстремуму

Крок 1. До вихідних даних методу МОВП додаються A_1 – значення мінімальної висоти екстремуму, що реєструється; ΔR – початкове начальное наближення до значення довжини інтервалу між екстремумами, що реєструються.

Крок 2. Оцінюється напрям пошуку по (рівняння (1.10)) в точці наближення до координати оптимуму для старта k . Для цього використовується зважена сума з ВФ Хаара, довжина носія s_1 для ВФ $\Psi_1(i)$ визначається при аналізі цільової функції. На цьому етапі перевіряється знак оцінки по (3) $G_{jk} =$

$$\frac{1}{s_k} \sum_{\substack{i=-\frac{s_k}{2} \\ i \neq 0}}^{\frac{s_k}{2}} Q(x[n], c_j + ia) \cdot \Psi_k(i).$$

У випадку зміни знаку, на основі відомої

властивості оцінок напрямку пошуку на базі градієнта змінювати знак при переході через оптимум, на цьому етапі визначається діапазон зміни координат екстремуму як $c[n-1] \leq c^* < c[n]$.

Крок 3. Виконується пошук діапазонів координат оптимуму $Q(x, c)$ по (рівняння (1.9)) до закінчення послідовності даних, що досліджується, інакше – зупин.

Крок 4. Координаті екстремуму періоду, що досліджується, присвоюється значення $c^* = c[n-1]$.

Крок 5. Значення $Q(x, c^*)$ порівнюється з порогом A_1 . Якщо $Q(x, c^*) \geq A_1$, реєструється координата екстремуму періоду як $RR[kk]$ та його амплітуда як $ss[kk]$ (тут kk – номер досліджуваного періоду в послідовності).

Крок 6. Значення довжини носія s_k порівнюється з половиною довжини інтервалу між екстремумами: при $s_k \leq \frac{\Delta R}{2}$ довжина носія ВФ визначається як $s_{k+1} = s_k + \Delta s$; при $s_k > \frac{\Delta R}{2}$ довжина носія ВФ для пошуку екстремуму наступного періоду визначається як s_1 .

Крок 7. Визначається початкове наближення до координати екстремуму наступного періоду як $c[n] = c[kk]$ і перехід до кроку 2.

При цьому через інтегральний характер ВП Хаара зі збільшенням довжини носія ВФ координата наступного кроку пошуку зміщується до екстремуму наступного періоду. Якщо ж довжина носія перевищує половину довжини періоду

при наступному екстремумі з меншою, ніж попереднього амплітудою, пошук може піти в неправильному напрямку.

В роботах, що піддані аналізу, визначена область використання розроблених методів оптимізації [50]. Оскільки дослідження показали, що метод МОВП відрізняється високою завадостійкістю, низькими погрішністю і чутливістю до локальних екстремумів і початкової точки пошуку і задовольняє вимогам практики, тому він буде служити базовим для розробки методів кластеризації при цільовій функції, яка може бути з шумом через апіорну невизначеність чи багатьма екстремумами через складну форму кластерів. Метод МОВП1 рекомендується до використання при необхідності підвищити швидкодію діагностичних операцій при відношенні сигнал/завада цільової функції по амплітуді більше 7. Метод МОВП2 рекомендується до використання, коли швидкодія має бути підвищена при мультимодальних цільових функціях (при відношенні сигнал/завада від 2 і більше), при визначеному зниженні достовірності [50, 51].

1.2.4 Оптимізація з ВП в умовах дрейфу екстремуму за лінійною траєкторією

В ряді практично важливих задач обробки ГД координати екстремуму цільової функції можуть змінюватись з часом. В такому випадку екстремум дрейфує з часом t відповідно [52, 53]

$$J(\mathbf{c}, t) = M_x \{Q(\mathbf{x}, \mathbf{c}, t)\} \quad (1.13)$$

де $J(\mathbf{c}, t)$ – критерій якості;

$Q(\mathbf{x}, \mathbf{c}, t)$ – функціонал вектору $\mathbf{c} = (c_1, \dots, c_N)$;

$\mathbf{x} = (x_1, \dots, x_M)$ – вектор випадкових збурень [54].

Для оптимізації в стаціонарних умовах запропонований був метод оптимізації з ВП та ітераційною схемою [54, 55]

$$\mathbf{c}[n] = \mathbf{c}[n-1] - \gamma[n] \mathbf{W} \mathbf{T}_k(\mathbf{Q}(\mathbf{x}[n], \mathbf{c}[n-1])) \quad (1.14)$$

Тоді для пошуку вектору $\mathbf{c}^*[n]$ в умовах дрейфу

$$\mathbf{c}^*[n] = U(n, n-1, \mathbf{c}^*[n-1]), \quad (1.15)$$

де U – нелінійне перетворення, яке визначає характер «дрейфу».

При дрейфі екстремуму (рівняння (1.13)), коли траєкторія зростає не швидше за лінійну, що часто відбувається в задачах обробки гетерогенних даних [56], з 1.16) отримують (рівняння (1.17)) і (рівняння (1.18)), котре з зростанням n наближається до (рівняння (1.19)) [57, 58], звідки з урахуванням (рівняння (1.15)) і (рівняння (1.19)), отримують (рівняння (1.20)).

Тут a_0 – невідома постійна, $\Gamma_\Phi[n]$ – діагональна матриця (в роботі прийнято значення $\gamma[n]$)

$$\mathbf{c}^*[n] = a_1 n + a_0 \quad (1.16)$$

$$\mathbf{c}^*[n] = \left(1 + \frac{1}{n-1}\right) \mathbf{c}^*[n-1] - \frac{a_0}{n-1} \quad (1.17)$$

$$\mathbf{c}^*[n] = U(n, n-1, \mathbf{c}^*[n-1]) - \frac{a_0}{n-1} \quad (1.18)$$

$$\mathbf{c}^*[n] = U(n, n-1, \mathbf{c}^*[n-1]) \quad (1.19)$$

$$\mathbf{c}[n] = U(n, n-1, \mathbf{c}[n-1]) - \gamma[n] \mathbf{W} \mathbf{T}_k(\mathbf{Q}(\mathbf{x}[n], U(n, n-1, \mathbf{c}[n-1]), n)) \quad (1.20)$$

де $U(\cdot)$ дозволяє визначити характер змінення $\mathbf{c}[n]$.

Тобто ітераційна схема (рівняння (1.20)) дозволяє проводити пошук оптимуму в нестационарних умовах при обмеженій траєкторії $\|\mathbf{c}^*[n]\| \leq A < \infty$ при всіх n .

1.2.5 Кластеризація за допомогою вейвлет-перетворення

При малих наборах зашумлених даних і відсутності апіорної інформації про форму кластерів, існуючі методи відрізняються низькою якістю кластеризації. Для зниження впливу вказаних недоліків на основі методу Я.З. Ципкіна і Г.К. Кельманса [52] розроблено метод *кластеризації* по дисперсійній ознаці *на базі МОВП* з основними етапами (для двох кластерів ($r = 1, 2$)):

Етап 1. Формування навчальної вибірки.

Етап 2. Визначення кількості кластерів одним з відомих методів.

Етап 3. Оцінка функціоналу якості $Q(\mathbf{x}, \mathbf{c})$.

Етап 4. Задаються вихідні дані та параметри *методу МОВП* (див. *метод МОВП*, крок 1) і δ_2 – погрішність кластеризації, яка відповідає вимогам прикладної задачі, номер старту $k = 1$; номер ітерації $n = 1$.

Етап 5. Оцінка напрямку пошуку $WT_k(Q(\mathbf{x}[n], \mathbf{c}_1[n-1], \mathbf{c}_2[n-1]))$ для кластерів по (2) на ітерації n . При цьому для кожного з i елементів зваженої суми (3) обчислюють характеристичні функції $\varepsilon_r(\mathbf{x}, \mathbf{c}_1, \mathbf{c}_2)$, $r = 1, 2$; якщо $f(\mathbf{x}, \mathbf{c}_1, \mathbf{c}_2) < 0$, то $\varepsilon_1 = 1, \varepsilon_2 = 0$, якщо $f(\mathbf{x}, \mathbf{c}_1, \mathbf{c}_2) \geq 0$, то $\varepsilon_1 = 0, \varepsilon_2 = 1$, де $f(\mathbf{x}[n], \mathbf{c}_1[n], \mathbf{c}_2[n]) = \|\mathbf{x}[n] - \mathbf{c}_1[n]\|^2 - \|\mathbf{x}[n] - \mathbf{c}_2[n]\|^2$.

Етап 6. Визначення координати центрів кластерів

$$\left. \begin{aligned} \mathbf{c}_1[n] &= \mathbf{c}_1[n-1] - \gamma[n]WT_k(Q(\mathbf{x}[n], \mathbf{c}_1[n-1], \mathbf{c}_2[n-1])) \\ \mathbf{c}_2[n] &= \mathbf{c}_2[n-1] - \gamma[n]WT_k(Q(\mathbf{x}[n], \mathbf{c}_1[n-1], \mathbf{c}_2[n-1])) \end{aligned} \right\} \quad (1.21)$$

при номерах старту $k \leq k_{\max}$, інакше – зупинка.

Етап 7. Якщо $\|\mathbf{c}_r[n] - \mathbf{c}_r[n-1]\| \leq \delta_1$, пошук на поточному старті закінчується, інакше – $n = n + 1$ і перехід до етапу 5.

Етап 8. Якщо $k > 1$ і $\mathbf{c}_{r,k}^* - \mathbf{c}_{r,k-1}^* \leq \delta_2$ – зупинка; у протилежному випадку, якщо $k < k_{\max}$, то збільшується номер старту $k = k + 1$, обирається ВФ для оцінки

напрямку пошуку (див. табл.1) і здійснюється перехід до етапу 5. Тут $\mathbf{c}_{r,k}^*$, $\mathbf{c}_{r,k-1}^*$ – результати пошуку координат центра r -го кластера на k -ому і $k-1$ старті відповідно.

Якість методу кластеризації на базі МОВП (виміряна відомим методом на основі оцінки відстані Хемінга [57]) досліджена при зміні відносної величини середньоквадратичного відхилення даних у кластерах – q , яке визначалось як

$$q = \frac{q_p}{q_0 \cdot D}. \text{ Тут } q_p \text{ і } q_0 - \text{СКВ параметрів у кластерах для досліджуваної і тестової}$$

вибірок відповідно; D – відстань між центрами кластерів тестової вибірки. В процесі досліджень встановлено, що при зміні СКВ даних в кластерах якість методу кластеризації на базі МОВП у порівнянні з методом k -середніх вище в середньому на 0,1.

Якість кластеризації на базі МОВП у порівнянні з методом k -середніх досліджено також при зміні стартової точки пошуку одного з кластерів; у розробленого методу якість вище на величину не менше 0,2.

Дослідження показали, що у розроблених методів кластеризації на базі МОВП підвищена якість і знижена чутливість до стартової точки пошуку, що дозволяє рекомендувати їх для кластеризації при високому рівні завад і/або складній формі кластерів і для використання в широкому колі прикладних задач, які відповідають цим умовам. Отримані результати також дозволяють рекомендувати розроблені методи кластеризації для класифікації з самонавчанням, при необхідності підвищити достовірність прийнятих рішень при малих наборах навчаючих параметрів, перетині кластерів і високому рівні завад у діагностичних параметрах.

1.2.6 Кластеризація з ВП в умовах дрейфу центру кластеру за лінійною траєкторією

Встановлено, що в ряді випадків, у залежності від умов зберігання чи використання, параметри об'єктів кластерів, що досліджуються – можуть змінюватися повільно і майже лінійно. Для таких умов на основі методів Я.З.

Ципкіна і К.С. Фу (K.S. Fu) розроблено метод адаптивної кластеризації на базі МОВП. В цьому методі *кластеризації при дрейфі центру кластера по лінійній траєкторії*, в якому координати центрів кластерів оцінюються з допомогою адаптації на базі МОВП проводиться пошук екстремуму по схемі.

$$\mathbf{c}[n] = U(n, n-1, \mathbf{c}[n-1]) - \gamma[n] \mathbf{W} \mathbf{T}_k(Q(\mathbf{x}[n], U(n, n-1, \mathbf{c}[n-1]), n)) \quad (1.22)$$

де $U(\cdot)$ дозволяє реалізувати упередження – визначити характер зміни $\mathbf{c}[n]$.

Для цього методу адаптивної кластеризації на базі МОВП на основі (рівняння (1.22)) прийнято значення $U(n, n-1, \mathbf{c}_r[n-1]) = (1 + n^{-1})\mathbf{c}_r[n-1]$, де r – номер кластера.

Метод уключає наступні етапи.

Етап 1. Формується навчальна вибірка.

Етап 2. Визначається кількість кластерів одним з відомих методів.

Етап 3. Оцінюється функціонал якості $Q(\mathbf{x}, \mathbf{c})$.

Етап 4. Задаються вихідні дані та параметри *методу МОВП* (див. *метод МОВП*, крок 1) та δ_2 – погрішність пошуку координати центру кластеру, яка відповідає вимогам прикладної задачі; $\mathbf{B}_{i1}$, $\mathbf{B}_{i2}$ – значення верхньої і нижньої границь регулювання параметра в технологічному процесі; $\mathbf{c}[0]$ – початкові наближення значень центрів кластерів; $k=1$ – номер старту; $n=1$ – номер ітерації.

Етап 5. Виконуються етапи 5, ..., 8 методу *кластеризації на базі МОВП*.


Етап 6. Корегуються змінення координат центрів кластерів по методу К.С.Фу $\mathbf{c}_r[n] = (1 + n^{-1})\mathbf{c}_r[n-1]$.

Етап 7. Етапи 5, 6 повторюють, поки не буде виконана одна з умов $\mathbf{c}_r[n] > \mathbf{B}_1$ или $\mathbf{c}_r[n] > \mathbf{B}_2$ для будь-якого з кластерів.

При дослідженні встановлено, що (рівняння (1.22)) дозволяє проводити пошук координати екстремуму в просторі вейвлет-перетворення в нестационарних


умовах при траєкторії $\|\mathbf{c}^*[n]\| \leq A < \infty$. Доведено, що при $n \rightarrow \infty$ (8) сходиться в середньоквадратичному, тобто $\varepsilon^2[n] = M\|\mathbf{c}[n] - \mathbf{c}^*[n]\|^2 \rightarrow 0$. Тут $\mathbf{c}^*[n]$ – істинне значення координати оптимуму.

Проведено експериментальні дослідження часу (рис. 1.12, а) і відносної погрішності визначення координати центру кластера (рис. 1.12, б) при зміні відношення сигнал/завада по амплітуді (SP) для розроблених методів адаптивної кластеризації.



1 – метод з упередженням;
2 – базовий метод

а



1, 2 – базовий метод з SP = 64 і SP = 6,4 відповідно; 3, 4 – метод з упередженням з SP = 64 і з SP = 6,4 відповідно

б

Рисунок 1.12 – Залежність характеристик методів адаптивної кластеризації від відношення сигнал/завада: а) – часу пошуку координати центру кластера t ; б) – залежність відносної погрішності d при різній кількості кроків дрейфу

Цільова функція моделювалася з допомогою функції Де Іонга 1 з додаванням завади з нульовим середнім і СКВ від 0 до 10^3 . Дрейф координати центру кластера моделювався з допомогою зміщення цільової функції на величину $n\Delta$, де $n = \overline{1, 5}$;

Δ - крок дрейфу. Встановлено, що метод *кластеризації при дрейфі центру кластера по лінійній траєкторії* на базі МОВП (метод з упередженням – крива 1 на рис. 1.12, а) дозволяє оцінювати координати центру кластера швидше від 2 до 2,5 разів у порівнянні з базовим методом адаптивної кластеризації з МОВП (крива 2 на рис. 1.12, а) при відношенні сигнал/завада від 20. При відношенні сигнал/завада більшому, ніж 7, відносна погрішність d методу *кластеризації при дрейфі центру кластера по лінійній траєкторії* (метод з упередженням на рис. 1.12, б) складає менше 6 % і вища в середньому в 1,5 рази, ніж у базовому методі (рис. 1.12, б).

1.2 7 Класифікація з ВФ в задачах нейромережових

Процедури ідентифікації та класифікації для обробки та аналізу гетерогенних даних часто реалізуються з допомогою нейронних мереж (НС).

Такий підхід обумовлений корисними властивостями НМ. Перша властивість - це гнучкість структури НМ. Вона зумовлена широкою номенклатурою існуючих проблемно-орієнтованих НМ. Ця властивість забезпечується можливістю вибору та поєднання елементів (кількості, типів, функцій активації нейронів, числа шарів НМ, типів зв'язків між ними тощо) та методів їх навчання в залежності від розв'язуваних завдань. Друга властивість - можливість оперативно коригувати параметри НМ шляхом додаткового їх навчання, що важливо в умовах ситуації, що швидко змінюється.

Найчастіше для вирішення завдань класифікації застосовуються різні різновиди радіальних НМ і багатошарові НМ (MLP) [58] (табл.1.6, рис. 1.13). Це пов'язано з їхніми протилежними особливостями.

В 2024 була опублікована робота, в якій була запропонована концепція нової нейронної мережі, в основі якої лежить теорема Колмогорова-Арнольда, що потенційно має зменшувати розміри моделей та об'єм тренувальних даних, і, відповідно, потреби в обчислювальних ресурсах при високій точності [59]. Перші результати авторів концепції підтверджують переваги мереж Колмогорова-

Арнольда, але потребується подальша робота над дослідженням сфер застосувань цієї концепції [60]. Крім того, використання при формуванні та обробці даних для цих мереж методів попередньої обробки (фільтрації, сегментації) та/або вагових функцій мережі на основі ВП може дозволити покращити їх швидкодію та/або ресурсоемність [61].

Таблиця 1.6 – Порівняльна таблиця характеристик нейронних мереж

Тип мережі	Базова операція	Локалізація ознак	Стабільність навчання
MLP	Лінійна сума + ReLU	Глобальна	Висока
RBFN	Відстань до центру	Дуже висока (локальна)	Середня
RBF-KAN	Сума RBF на ребрах	Висока	Висока (гнучка)
WKAN	Вейвлет-перетворення	Частотно-часова	Висока (для даних з шумом)




Рисунок 1.13 – Візуальна модель ієрархії нейронних мереж для класифікації

Створення структурної схеми сучасних нейронних мереж для класифікації потребує особливої уваги до мереж Колмогорова-Арнольда (Kolmogorov-Arnold neural nets (KAN)), оскільки вони представляють собою зміну парадигми: замість

фіксованих ваг у вузлах, вони використовують адаптивні функції на ребрах. Ієрархічну структуру типів нейронних мереж для вирішення задач класифікації, яка інтегрує класичні підходи та сучасні KAN-варіації можна представити наступним чином:

- традиційні архітектури, що базуються на використанні багат шарових перцептронів (multi layered perceptron (MLP)). Класичні мережі, де навчання відбувається шляхом коригування ваг зв'язків. До них відносять багат шарові перцептрони (це базовий тип із фіксованими функціями активації (ReLU, Sigmoid)), згорткові нейронні мережі (спеціалізовані для класифікації зображень та просторових даних), рекурентні нейронні мережі (використовуються для класифікації сигналів та текстів);

- мережі на основі радіально-базисних функцій (radial-basis function (RBF)), які використовують міру відстані до прототипу (центру) як основу для класифікації. Це можуть бути класичні RBF мережі з одним прихованим шаром з функціями Гауса;

- гібридні RBF, які поєднують підхід на основі RBF з градієнтним спуском для уточнення центрів та ширин.

- мережі Колмогорова-Арнольда (KAN) – це новітній клас мереж, що базується на теоремі Колмогорова-Арнольда про представлення функцій. Замість $w \cdot x$ вони використовують $\phi(x)$.

До цієї категорії мереж відносять:

- RBF-KAN (Радіально-базисні KAN), які використовують суму RBF-функцій на кожному ребрі мережі. Їхня перевага – це краща здатність до локальної апроксимації та вища інтерпретованість у задачах класифікації;

- WKAN (Вейвлет KAN), які замість сплайнів або RBF використовують ВФ (Mexican Hat, Morlet, Meyer тощо). Їхня перевага в тому, що вони сприяють ефективному виявленню різких змін у даних (градієнтів), що може бути необхідним для точної класифікації складних сигналів.

Аналіз характеристик і можливостей нейронних мереж, які можуть бути використані для класифікації, дозволяє зробити висновок, що актуальним засобом аналізу даних з наявністю шумової складової є мережі WKAN.

Вони дозволяють класифікувати дані в задачах, де важливі як просторові, так і частотні характеристики (наприклад, сигнали для телемедицини – ЕКГ). Однак для використання в цих мережах потрібно обирати типи ВП, які найкращим чином відповідають особливостям сигналів та їх рівнів шуму, та дозволяють забезпечити прийнятний для цих задач рівень достовірності та швидкодії.

1.3 Удосконалення концептуальної моделі обробки та аналізу гетерогенних даних

В результаті аналізу встановлено, що в основі значної кількості методів обробки та аналізу ГД лежить обмежений набір процедур. Основою низки з цих процедур (фільтрації, сегментації, ідентифікації та класифікації) та при прийнятті діагностичного рішення є оптимізація на базі ітеративних алгоритмів. Цільова функція цих процедур, якщо обробці піддані малі вибірки, мультимодальна та з доданням шуму.

При оптимізації у вказаних задачах застосовуються три основні підходи: градієнтний, субградієнтний та з використанням вейвлет-функцій. В рамках градієнтного підходу при виборі напряму пошуку оптимуму оцінюють градієнт цільової функції. Гідність цього підходу - висока точність визначення координат оптимуму, недоліки - низька завадостійкість, чутливість до локальних екстремумів та початкової точки пошуку. У межах субградієнтного підходу для визначення напряму пошуку оптимуму використовують інтегральні функції. Правильний вибір такої функції дозволяє підвищити стійкість до перешкод процедури оптимізації, знизити чутливість до локальних екстремумів, і, отже, до початкової точки пошуку. Однак застосування цього підходу призводить до підвищення похибки при визначенні координат оптимуму. Методи на основі вейвлет-аналізу володіють

високою точністю і завадостійкістю, але їм притаманні значні обчислювальні витрати та не висока швидкодія.

Таким чином, проведений аналіз показав, що застосування традиційних підходів до оптимізації призводить до суперечності між точністю з одного боку, стійкістю до перешкод і чутливістю до локальних екстремумів та обумовленим потребами прикладної задачі рівнем швидкодії та ресурсоємності. Тому ці підходи призводять до зниження ефективності обробки при мультимодальних цільових функціях з шумом. Для вирішення цієї суперечності у роботі запропоновано для обробки та аналізу сигналів з багатьма екстремумами удосконалення концептуальної моделі відомого підходу пошуку екстремумів з використанням ВП, який полягає в наступному.

1) проводиться аналіз цільової функції, властивостей локальних екстремумів, перешкод, необхідної для цілей обробки точності, ресурсоємності та швидкодії;

2) залежно від рівня шуму, швидкодії та при високих вимогах до економії кількості звернень до обчислення цільової функції (ресурсоємності задачі) вихідні дані піддаються попередній обробці (фільтрації, сегментації) з використанням ВП, форма і рівень обробки якого обраний на основі ентропійно-інформаційного аналізу, запропонованому в роботі (розділ 2 Методи аналізу гетерогенних даних з використанням вейвлет-перетворення);

3) виконується пошук першого екстремуму (для ЕКГ – максимуму) шляхом виконання основних етапів концептуальної моделі відомого підходу пошуку екстремумів з використанням ВП [43, 45, 47, 55]:

– за результатами аналізу даних після фільтрації обирається початкова довжина носія ВФ Хаара;

– пошук оптимуму розділений на етапи. Мета першого етапу – вихід на околиці екстремуму з високою стійкістю до перешкод і, як правило, з високою похибкою. Проводиться перший етап ітеративного пошуку екстремуму, в якому напрямок пошуку визначається за допомогою ВФ Хаара з цією довжиною носія; результатом є оцінка координат екстремуму з високою ймовірністю виходу в

область глобального екстремуму та (або) обмеження для наступних етапів пошуку. Результати першого і наступних етапів використовуються як стартова точка наступного етапу пошуку зниження похибки до виконання критерію зупинки. Оцінка напряму пошуку кожному етапі проводиться з допомогою симетричного нестационарного ВП. Залежно від вимог до точності, ресурсоемності та швидкодії (пункт 1) обирається форма та довжина носія ВФ та проводиться наступний етап ітеративного пошуку;

– перевіряється виконання критерію зупинки шляхом порівняння результатів між поточним та попереднім етапами пошуку екстремуму (якщо цей критерій виконано – зупинення, якщо ні – повернення до пункту 2.

4) перевіряється – чи всі дані оброблені, якщо цю умову виконано – зупинення, якщо ні – повернення до пункту 2.

Особливості використання цієї удосконаленої концептуальної моделі описані в підрозділах роботи (розділ 2 Методи аналізу гетерогенних даних з використанням вейвлет-перетворення);

Застосування ВП тут обумовлено його властивостями: інтегральний характер ВП дозволяє знизити чутливість до локальних екстремумів і виділити сегмент цільової функції, в якому з високою ймовірністю знаходиться глобальний оптимум; зміна масштабу вейвлет-функції (ВФ) на наступних етапах пошуку дозволяє зменшити похибку визначення оптимуму всередині знайденого на попередніх етапах сегмента цільової функції; застосування нестационарного ВП (форма ВП може змінюватись від етапу до етапу) дозволяє підвищити швидкість збіжності під час пошуку оптимуму. Крім того, існують нестационарні ВП, що межі сходяться до дискретного диференціювання і тому здатні забезпечити будь-яку задану точність оптимізації.

Концептуальна модель обробки та аналізу гетерогенних даних відрізняється етапом вибору ВФ для попередньої обробки на основі на основі ентропійно-інформаційного аналізу (розділ 2.4 Нейронні мережі Колмогорова-Арнольда на основі удосконаленої концептуальної моделі) та дозволяє на її основі удосконалити методи оптимізації, кластеризації та класифікації на основі нейронних мереж

вейвлет-KAN для обробки та аналізу гетерогенних даних для підвищення швидкодії та ресурсоемності при прийнятній для задач достовірності рішень в умовах апіорної невизначеності.

1.4 Висновки до першого розділу

У розділі проведено аналіз сучасних методів обробки та аналізу гетерогенних даних, отриманих на основі малих серій вимірів. В результаті аналізу виявлено шляхи та резерви підвищення швидкодії та зниження ресурсоемності при збереженні потрібного рівня точності в умовах апіорної невизначеності. Розглянуті приклади гетерогенний даних при малих обсягах вимірів для задач дрібносерійного виробництві електроніки та для медичного діагностування в телемедицині.

Проведений аналіз показав, що застосування сучасних методів обробки та аналізу ГД в електроніці та телемедицині обмежується тим, що існуючі методи та інформаційні технології орієнтовані на обробку і аналіз великих наборів даних з використанням складних вимірювальних систем високої вартості, а їх застосування в умовах апіорної невизначеності призводить до зниження швидкодії, високій ресурсоемності при потребі досягнути потрібну достовірність.

Показано, що основою базових процедур (фільтрації, сегментації, ідентифікації, класифікації) при обробці та аналізі даних є ітеративні методи оптимізації. Шляхом аналізу цих методів оптимізації показано, що вони не відповідають вимогам практики, оскільки існуючі методи на основі вейвлет-перетворень – не володіють для вказаних прикладних задач необхідною швидкістю та/або ресурсоемністю.

Сформульовано актуальну науково-прикладну проблему, яка полягає в удосконаленні методів та інформаційних технологій обробки та аналізу гетерогенних даних на основі ВП, які дозволять підвищити швидкість, зберегти достатній рівень достовірності рішень в умовах апіорної невизначеності при

наявності малих наборів даних вимірів та крім того, знизити вимоги до апаратної частини та відповідно до ресурсоемності.

Для вирішення цієї проблеми у цій роботі удосконалено концептуальну модель оптимізації з використанням вейвлет-перетворення для обробки та аналізу сигналів з багатьма екстремумами. Ряд етапів обробки з допомогою цієї моделі буде використано при удосконаленні методів оптимізації з вейвлет-функціями, кластеризації. На базі цієї моделі запропоновано реалізувати адаптивний підхід та вирішити суперечність між зміною параметрів виробів з часом та необхідною достовірністю передбачень.

Поставлено мету досліджень – удосконалення та дослідження методів обробки гетерогенних даних на базі оптимізації з ВФ для підвищення швидкодії, зниження ресурсоемності при забезпеченні достатньої достовірності в умовах апіорної невизначеності при малих наборах даних вимірів.

Для досягнення мети дослідження необхідно вирішити такі завдання:

провести аналіз основних проблем, обмежень та викликів, які виникають задачах обробки та аналізу гетерогенних даних;

удосконалити метод оптимізації на основі вейвлет- перетворення шляхом обчислення обмежень;

удосконалити методи кластеризації за дисперсійною ознакою та з дрейфом центру кластеру по лінійній траєкторії, в якому належність образу до кластеру розраховується на основі обчислення обмежень;

–*удосконалити* метод нейромережевої класифікації ГД на базі архітектури KAN шляхом застосування у вхідному шарі вейвлет функцій, що дозволило підвищити точність ідентифікації станів об'єктів у зашумленому середовищі при мінімізації кількості налаштовуваних параметрів та зростання швидкодії обчислень;

– розробити інструментальні засоби, що реалізують запропоновані рішення та провести експериментальні дослідження, апробацію і впровадження отриманих теоретичних результатів.

2 МЕТОДИ АНАЛІЗУ ГЕТЕРОГЕННИХ ДАНИХ З ВИКОРИСТАННЯМ ВЕЙВЛЕТ-ПЕРЕТВОРЕННЯ

2.1 Методи оптимізації з вейвлет-перетворенням

2.1.1 Метод оптимізації з обмеженнями у вигляді нерівностей

Методи оптимізації знаходять застосування під час реалізації різних процедур обробки гетерогенних даних в автоматизованих системах управління, діагностики, обробки зображень [62-65]. Насправді при цьому застосовуються ітеративні методи оптимізації з двох основних груп. Ці методи ґрунтуються на оцінці градієнта або субґрадієнта цільової функції [65]. У зазначених додатках цільова функція при оптимізації часто мультимодальна може мати негладку, кусково-лінійну, зашумлену поверхню [64, 65]. Методи оптимізації, засновані на оцінці градієнта, в таких умовах відрізняються низькою стійкістю до перешкод, у субґрадієнтних методів – висока похибка [63, 65].

У зв'язку з цим для прикладних завдань обробки гетерогенних даних на сьогодні набули розвитку методи, спрямовані на оцінку координати екстремуму в умовах, коли за допомогою «оракула» можна отримати лише значення цільової функції $f(x)$ у точці x [66]. Це означає, що у дослідника є доступ лише до значень цільової функції $f(x)$, а не до її градієнта $\nabla f(x)$, який є популярнішим для чисельних методів [67].

Термін «оракул» часто згадується у літературі як оракул нульового порядку або без градієнтний оракул [67, 68]. Методи з урахуванням такого підходу ряд авторів називають методами нульового порядку [67]. При реалізації цих методів, що ґрунтуються на методах першого порядку, замінюють справжній градієнт на різні моделі апроксимації градієнта [68, 69]. Перші такі методи (часто звані методами Кіфера-Вулфовіца) були запропоновані близько 70 років тому (див., наприклад, [68]). Цікавість до безградієнтних методів значно зросла із середини 2000-х років [68, 70, 71]. Особливо в сучасних роботах [70, 71] автори намагаються

дослідити такі безградієнтні алгоритми хоча б для одного з трьох основних критеріїв: складність оракула (тобто кількість викликів оракула, яке може бути потрібним, щоб гарантувати певну точність), ітераційну складність (кількість ітерацій, щоб гарантувати потрібний для прикладу гарантувати певну точність).

У рамках подібної тенденції та для зниження впливу зазначених недоліків було запропоновано низку методів, при реалізації оцінки напрямку руху до екстремуму, що використовує вейвлет-функції (ВФ) [63, 65]. Під час пошуку оптимуму у межах цієї групи методів використовується ітеративна схема

$$c[n + 1] = c[n] - \gamma[n]gr(c[n]), \quad (2.1)$$

де $c[n]$ - оцінка координати оптимуму на ітерації n ;

$gr(c[n])$ - результат згортки з ВФ, який «в середньому» співпадає з градієнтом, і близький до нуля, коли його аргумент прагне до точки оптимуму;

$\gamma[n]$ - крок.

Так, у методі оптимізації з ВП [63] для оцінки напрямку пошуку екстремуму область пошуку обробляється за допомогою вейвлета Хаара та гіперболічного ВП (ГВП), реалізованого за ліфтинговою схемою. Обробка за допомогою вейвлета Хаара підвищує стійкість до перешкод, але через асиметрію функціоналу якості оптимум відшукується з похибкою. Ця похибка знижується шляхом багатоетапної обробки цього функціоналу із ГВП [63-65]. Тому швидкодія методу невисока.

Однак для ряду автоматизованих систем з великою кількістю контрольних операцій в одиницю часу, наприклад, при контролі таких виробів електроніки, як друковані плати, при визначенні параметрів ЕКГ в телемедицині, в задачах трьох вимірною комп'ютерного зору швидкодія етапу оптимізації має бути підвищена [62, 72-76]. Досягти цього можна, звузивши область пошуку на етапі пошуку мінімуму функціоналу за допомогою ГВП. Це дозволяє зробити апарат методів математичного програмування [77, 78].

При реалізації такого підходу здійснюють перехід від умовно-екстремального завдання (пошуку мінімуму за наявності обмежень) до завдання

безумовної мінімізації формованих на основі цих обмежень допоміжних функціоналів [77]. Через конструкцію цих функціоналів, яка визначається обраним методом обліку обмежень (множників Лагранжа, внутрішніх або зовнішніх штрафних функцій, бар'єрів, центрів та ін.) часто з'являється погана зумовленість завдання мінімізації. Подібна властивість призводить до ярової структури поверхонь рівня функціоналу, що оптимізується, і, отже, до різкого уповільнення збіжності процедур оптимізації [77 - 79]. Крім цієї проблеми, методи, засновані на звичайній та модифікованій функції Лагранжа, за наявності виродженого мінімуму втрачають або знижують свою працездатність [77 - 81]. Вироджений мінімум може бути обумовлений відсутністю лінійної незалежності градієнтів обмежень у функціоналі $f(x)$, порушенням йому умови опуклості (тобто умови в точці мінімуму) [77 - 81].

Оскільки для ряду функціоналів випадок погано обумовленої задачі близький до виродженого, і з урахуванням описаних вище особливостей функціоналів у зазначених прикладних задачах, як базовий для реалізації методу оптимізації з обмеженнями другого роду (у вигляді нерівностей) у роботі для оцінки координат екстремуму цільової функції обрано метод центрів. Цей метод належить до групи методів внутрішніх штрафних функцій – найменш чутливих до виродженого мінімуму [82]. Серед його переваг – не потрібно вибирати суворо спадаючу послідовність невід'ємних параметрів (вагових коефіцієнтів звичайної внутрішньої функції штрафу) [77 - 79, 82]. При реалізації методу на кожній ітерації додаються обмеження, те щоб значення функціоналу не перевищувало значення у поточній точці. Тобто функціонал, спочатку не підпорядкований обмеженням, мінімізується всередині вужчої області. Таким чином, при безумовній мінімізації обчислюється послідовність строго спадних значень функціоналу, так що точки, що мінімізують $f(x)$, сходяться до локального вирішення задачі пошуку мінімуму при обмеженнях $g_i(x) \geq 0, \quad i = 1, 2, \dots, m_1$ [80 - 83].

Цей метод оптимізації реалізується за ітераційною схемою [63],

$$\mathbf{c}[n] = \mathbf{c}[n-1] - \gamma[n] \sum_{m=1}^{s_\alpha} \alpha_m[n] \tilde{\nabla}_{\mathbf{c}^\pm} Q(\mathbf{x}[n], \mathbf{c}[n-1], a[n-m]), \quad (2.2)$$

де $\sum_{m=1}^{s_\alpha} \alpha_m[n] \tilde{\nabla}_{\mathbf{c}^\pm} Q(\mathbf{x}[n], \mathbf{c}[n-1], a[n-m])$ - ВП реалізації $Q(\mathbf{x}, \mathbf{c})$ по c_i , $i = 1, \dots, N$;

$Q(\mathbf{x}, \mathbf{c})$ - функціонал вектору $\mathbf{c} = (c_1, \dots, c_N)$, який залежить від вектору випадкових послідовностей $\mathbf{x} = (x_1, \dots, x_M)$;

$\mathbf{c}[n-1]$ - координата мінімуму;

$\alpha_m[n]$, $m = 1, \dots, s_\alpha$ - компоненти вектору $\alpha[n]$, що отриманий в результаті дискретизації вейвлет функції.

Після ініціалізації параметрів методу в схемі (рівняння (2.2)) для оцінки напряму пошуку використовується згортка $Q(\mathbf{x}, \mathbf{c})$ з ВФ Хаара в околі, який визначається довжиною її носія N . Мінімум, знайдений на цьому етапі, зміщений в міру асиметрії функціоналу в області пошуку. На основі координати мінімуму, яка отримана після згортки досліджуваного функціоналу з ВФ Хаара, по методиці (рівняння (1.8)) [82, 84], формується функціонал $Q_1(\cdot)$, що дозволяє врахувати цю координату, як обмеження,

$$Q_1(\mathbf{x}[n], \mathbf{c}[n], g(\mathbf{x}[n], \mathbf{c}_H^*[n-1])) = -\ln(Q(\mathbf{x}[n], \mathbf{c}[n]) - Q(\mathbf{x}[n], \mathbf{c}_H^*[n-1])) - \ln(g(\mathbf{x}[n], \mathbf{c}_H^*[n-1])) \quad (2.3)$$

де $Q(\mathbf{x}[n], \mathbf{c}[n])$ - вихідний функціонал на кроці пошуку n ;

$Q(\mathbf{x}[n], \mathbf{c}_H^*[n-1])$ - значення функціоналу в точці мінімуму, що отримана після згортки з ВФ Хаара;

$$g(\mathbf{x}[n], \mathbf{c}_H^*[n-1]) = \mathbf{c}_H^*[n-1] - \mathbf{x}[n].$$

Пошук оптимуму $Q_1(\cdot)$ здійснюється далі по схемі (рівняння (2.2)). В якості базового методу при оптимізації використано градієнтний метод [79].

В відомому методі з оцінкою обмежень на цьому етапі пошуку оптимуму обчислюється зважена сума значень $Q_1(\mathbf{x}[n], \mathbf{c}[n], g(\mathbf{x}[n], \mathbf{c}_H^*[n-1]))$ з

гіперболічною функцією $\Psi(j) = \frac{1}{\alpha x}$, яка регуляризована по ліфтинговій схемі [64], при початковому масштабі $\alpha = 1$. Початкова точка пошуку оптимуму цього етапу визначається на попередньому етапі, як результат пошуку з ВФ Хаара. Якщо координата мінімуму відрізняється від результату попереднього етапу не більше ніж на δ , пошук закінчується, інакше - масштаб α збільшується на 1. Таким чином, від оптимізації за допомогою ВФ Хаара, що забезпечує стійкість до перешкод, здійснюється перехід до оптимізації за допомогою диференціатора, що забезпечує високу точність (якщо $\alpha \rightarrow \infty$, то $\frac{1}{\alpha x}$ прагне до диференціатора).

Однак через багатоетапну оцінку напрямку пошуку з гіперболічною ВФ (у методі [65] таких етапів 5 (зі збільшенням α від 1 до 5)) (табл.1.5). Тобто кількість звернень до «оракула» для отримання значення функціоналу в точці оцінки напрямку (наприклад, спуску до мінімуму) залишається значним.

Однак на етапі обробки з ВФ Хаара довжина носія визначає стійкість до перешкод процедури оптимізації. Але на етапі обробки з гіперболічною ВФ, коли проводиться уточнення координати екстремуму, можна скоротити кількість звернень до оракула і, залежно від рівня шуму в цільовій функції, збільшити швидкодію.

Тому можливо для ряду прикладних задач з обробки гетерогенних даних дослідити можливості удосконаленого методу – тобто такого, в якому кількість етапів обробки з гіперболічною ВФ буде менша та дослідити можливості методу оптимізації з ВФ з обмеженнями другого роду, для підвищення швидкодії пошуку оптимуму і скорочення числа звернень за значеннями цільової функції до оракулу.

Значення гіперболічної функції $\Psi(j) = \frac{1}{\alpha x}$ використовувалось в розрахунках при масштабі $\alpha = 5$, після чого виконувалось дискретне диференціювання скінченно-різницеvim методом [65].

Оцінка швидкодії методу в порівнянні з базовим (рівняння (1.8)) [65] була проведена з використанням функції $f_2(x) = x^2$ для $x \in (-80, \dots, 80)$.

Глобальний мінімум для цієї функції $f_2(x) = 0$ при $x = 0$. В процесі пошуку довжина кроку дискретизації при пошуку оптимуму з ВФ Хаара $dx = 1$, при

пошуку з гіперболічною ВФ, щоб не порушувалось прийняте в (рівняння (2.3)) обмеження, $dx = 0,01$. При співвідношенні сигнал/шум по амплітуді до 6,4 (завада розподілена за нормальним законом з нульовим середнім і середньоквадратичним відхиленням від 0 до 100, максимальне значення функції $f_2(x) = 6400$) зростання швидкодії склало від 1,7 до 2,8 разів. Число звернень до оракулу знизилось на величину від 25% до 32% (в залежності від співвідношення сигнал/шум).

Ці результати дозволяють рекомендувати розроблений метод застосування в широкому колі практично важливих завдань в електроніці при високому рівні перешкод у даних при необхідності підвищити швидкість контрольно-діагностичних операцій.

2.1.2 Оптимізація нестационарних мультимодальних сигналів

Аналіз існуючих високовартісних систем технічної та медичної діагностики показав, що вони орієнтовані на обробку великих обсягів даних. Крім того, методи обробки діагностичних параметрів у таких системах вимагають багато досліджень для зміни асортименту продукції в технічній діагностиці та у випадку досліджень (наприклад) нових лікарських засобів у медичній діагностиці. Зрозуміло, що зростання обсягів досліджень може призвести до підвищення ефективності, але в таких умовах також зростає споживання ресурсів.

Аналіз відомих методів оптимізації показав, що цільова функція може бути з шумом, оскільки в ряді прикладних задач дослідження часто проводяться з використанням малих наборів даних. Більше того, ця цільова функція може бути мультимодальною. Тому для вирішення задач в подібних умовах були запропоновано методи оптимізації, що базуються на оцінці напряму пошуку екстремуму з допомогою вейвлет-перетворення (ВП) [85- 88]. Результатом його роботи є точкова оцінка координати екстремуму, яка може бути використана в ряді інформаційних технологій та автоматизованих систем (АС) діагностування на їх основі [86 - 88].

Однак, при розробці таких автоматизованих систем та їх процедур на основі обробки зображень [85 - 88] часто виникає необхідність потрапляти в заданий діапазон ефективності, що відповідає цілям обробки (область прагматичної достатності) [89]. Це може відбуватися з удосконаленням лікарських засобів у медицині, зі зміною умов спостереження в системах відстеження рухомих об'єктів [86, 88 - 89]. Тому важливо створювати процедури для таких систем, що дозволяють коригувати параметри. Оскільки значна частина процедур таких АС (класифікація, кластеризація та сегментація) реалізується на основі методів оптимізації, необхідні методи оптимізації, що дозволяють визначати такі діапазони параметрів.

Апарат вейвлет-аналізу дозволяє розширити можливості методу оптимізації, запропонованого в роботі. Він дозволяє отримати результат у вигляді кількох діапазонів (звужувальних областей), в яких знаходиться екстремум. Ці області визначаються обмеженнями у вигляді нерівностей. При визначенні цих обмежень можна використовувати відому властивість вейвлет-аналізу змінювати знак при проході через екстремум [87, 88]. Такий підхід також може бути використаний у вищезгаданих застосуваннях [89, 90].

Основні етапи методу пошуку екстремумів мультіекстремального сигналу з ВП Хаара описані в п.1.2.3.

Методика визначення координат екстремумів мультіекстремальних нестационарних сигналів та інтервалів між ними передбачає виконання наступних етапів.

Етап 1. Попередня обробка вихідного мультіекстремального сигналу з використанням типу та рівня ВФ, обраних залежно від рівня шуму, швидкодії та з урахуванням вимог до економії кількості звернень до обчислення цільової функції (ресурсоємності задачі). Вихідні дані піддаються фільтрації, з використанням ВП, форма і рівень обробки якого обраний на основі ентропійно-інформаційного аналізу, запропонованому в роботі (пункт 2.4 Нейронні мережі Колмогорова-Арнольда на основі удосконаленої концептуальної моделі) [91].

Етап 2. Визначення просторових координат екстремумів (пиків) шляхом пошуку координат екстремумів періодичних сигналів (пункт 1.2.3 Оптимізація за допомогою вейвлет-перетворення).

Етап 3. Визначення довжини інтервалів між екстремумами при необхідності оцінки статистичних характеристик сигналів та/або екстремумів типу «мінімум», класифікації та прийняття діагностичного рішення.

2.2 Кластеризація на основі оптимізації з обмеженнями

Для аналізу гетерогенних даних використовують методи кластеризації. При такому аналізі у вказаних прикладних задачах важливими є не тільки завадостійкість та зниження похибки цієї процедури, але й збільшення швидкодії.

ЕК поділяють на кластери за ознакою компактності параметрів за допомогою оптимізації функціоналу якості. Відомий метод кластеризації з використанням ВП, запропонований раніше, дозволяє проводити кластеризацію з низькою похибкою за високого рівня перешкод у даних та малих обсягах вибірок [92]. Однак через багатоетапну обробку за допомогою декількох ВФ швидкодія цього методу не висока.

Тому в роботі [93] було запропоновано удосконалення методу кластеризації з урахуванням обмежень для підвищення швидкодії кластеризації та зменшення кількості оцінок значень цільової функції.

Методи кластеризації, що ґрунтуються на оцінці градієнта або субґрадієнта цільової функції [92, 94] спрямовані на пошук її екстремуму. При цьому цільова функція часто мультимодальна, може мати поверхню з шумом [92]. Методи оптимізації з оцінкою градієнта в таких умовах відрізняються низькою стійкістю до перешкод, а з оцінкою субґрадієнту – досить значною похибкою оцінки екстремуму [92, 94].

В зв'язку з цим для прикладних завдань сьогодні отримали розвиток методи, спрямовані на оцінку координати екстремуму в умовах, коли можна отримати лише значення цільової функції $f(x)$ у точці x [95]. В рамках подібної тенденції та для

зниження впливу зазначених недоліків було запропоновано низку методів, при реалізації оцінки напрямку руху до екстремуму, що використовують ВФ [95]. Для пошуку оптимуму в них використовується ітеративна схема:

$$c[n + 1] = c[n] - \gamma[n]gr(c[n]), \quad (2.4)$$

де $c[n]$ – оцінка координати оптимуму на ітерації n ;

$gr(c[n])$ – результат згортки з ВФ, «в середньому» співпадаючий з градієнтом, і близький до нуля, коли його аргумент прагне точки оптимуму;

$\gamma[n]$ – крок.

Так, у методі оптимізації з використанням ВФ [92, 94] для оцінки координати екстремуму спочатку використовується ВФ Хаара та (для уточнення) гіперболічні ВФ. Обробка за допомогою вейвлета Хаара підвищує стійкість до перешкод, але через асиметрію функціоналу якості оптимум відшукується з похибкою. Ця похибка знижується шляхом багатоетапної обробки цього функціоналу із ГВФ [92, 94]. Тому швидкодія методу невисока.

Проте в рамках прикладних задач аналізу гетерогенних даних, що розглядаються в роботі, швидкодія кластеризації повинна бути підвищена [96, 97 - 101]. Для цього запропоновано звужити область пошуку на етапі обробки за допомогою ГВФ [92, 94]. При цьому здійснюють перехід від умовно-екстремального завдання (пошуку мінімуму за наявності обмежень) до завдання безумовної мінімізації з формуванням на основі цих обмежень допоміжних функціоналів. У роботі для цього вибрано метод центрів з групи методів внутрішніх штрафних функцій – найменш чутливих до виродженого мінімуму [97, 102]. Під час реалізації методу на кожній ітерації додаються обмеження, так, щоб значення функціоналу не перевищувало значення у поточній точці. Тобто функціонал, спочатку не підпорядкований обмеженням, мінімізується всередині вужчої області при обмеженнях $g_i(x) \geq 0$, $i = 1, 2, \dots, m_1$ [97, 102].

Основні етапи кластеризації з ВФ та врахуванням обмежень

Цей метод оптимізації визначається ітераційною схемою (рівняння (2.2)).

У схемі (рівняння (2.2)) для оцінки напрямку пошуку використовується згортка $Q(\mathbf{x}, \mathbf{c})$ з ВФ Хаара в околі, що визначається довжиною її носія N . Мінімум, знайдений на цьому етапі, може бути зміщений через асиметрію функціоналу в області пошуку. На основі координати мінімуму, яку отримано після згортки функціоналу з ВФ Хаара, за методикою, яка описана в [17], формується функціонал $Q_1(\cdot)$, який дозволяє враховувати цю координату, як обмеження:

$$Q_1(\mathbf{x}[n], \mathbf{c}[n], g(\mathbf{x}[n], \mathbf{c}_H^*[n-1])) = -\ln(Q(\mathbf{x}[n], \mathbf{c}[n]) - Q(\mathbf{x}[n], \mathbf{c}_H^*[n-1])) - \ln(g(\mathbf{x}[n], \mathbf{c}_H^*[n-1])) \quad (2.5)$$

де $Q(\mathbf{x}[n], \mathbf{c}[n])$ – вихідний функціонал на кроці пошуку n ;

$Q(\mathbf{x}[n], \mathbf{c}_H^*[n-1])$ – значення функціоналу в точці мінімуму, яке отримане після згортки ВФ Хаара;

$$g(\mathbf{x}[n], \mathbf{c}_H^*[n-1]) = \mathbf{c}_H^*[n-1] - \mathbf{x}[n].$$

Пошук оптимуму $Q_1(\cdot)$ здійснюється далі за схемою (рівняння (2.4)).

На цьому етапі пошуку оптимуму обчислюється зважена сума значень $Q_1(\mathbf{x}[n], \mathbf{c}[n], g(\mathbf{x}[n], \mathbf{c}_H^*[n-1]))$ з гіперболічною функцією $\Psi(j) = \frac{1}{\alpha x}$ при початковому масштабі $\alpha = 1$ на відміну від базового методу кластеризації з ВФ.

Початкова точка пошуку оптимуму цього етапу визначається на етапі пошуку з ВФ Хаара.

В базовому методі, якщо координата мінімуму відрізняється від результату попереднього етапу не більше ніж на δ , пошук закінчується, інакше – масштаб α збільшується на 1. Однак через багатоетапну оцінку напрямку пошуку з гіперболічною ВФ (в методі [10] таких етапів 5). Тобто кількість значень функціоналу, що необхідна для обчислень в точці оцінки напрямку (наприклад до мінімуму), лишається значною та є прямо пропорційною довжині носія ВФ. За рахунок скорочення кількості етапів обробки з ГВФ і введення обмежень можна скоротити кількість обчислень.

На основі цього методу удосконалено метод кластеризації на базі ВФ з основними етапами (для двох кластерів ($r = 1,2$)).

Етап 1. Формування навчальної вибірки даних.

Етап 2. В загальному випадку – визначення числа кластерів одним з відомих методів [20].

Етап 3. Оцінка функціоналу якості $Q(\mathbf{x}, \mathbf{c})$.

Етап 4. Задаються параметри методу: δ_1 – погрішність пошуку оптимуму старту, яка визначається на етапі апріорних досліджень функціоналу якості; δ_2 – погрішність, яка задовольняє вимогам прикладної задачі; k_{max} – максимальна кількість стартів; вид ВФ; $\mathbf{c}_1[0], \mathbf{c}_2[0]$ – початкові значення координат центрів кластерів; $\gamma[1]$ – крок; a – крок дискретизації ВФ; s_1 – довжина носія ВФ першого старту (з ВФ Хаара); $k = 1$; $n = 1$.

Етап 5. Оцінюється напрям пошуку:

$WT_k(Q(\mathbf{x}[n], \mathbf{c}_1[n-1], \mathbf{c}_2[n-1]))$ для кластерів по (рівнянн (2.6)), (рівняння (2.7)) на ітерації n згідно:

$$WT_k(\mathbf{Q}(\mathbf{x}[n], \mathbf{c}[n-1])) = \{G_{1k}, G_{2k}, \dots, G_{Nk}\} \quad (2.6)$$

де G_{jk} – результат обробки по j -ій змінній:

$$G_{jk} = \frac{1}{s_k} \sum_{\substack{i=-\frac{s_k}{2} \\ i \neq 0}}^{\frac{s_k}{2}} Q(\mathbf{x}[n], \mathbf{c}_j + ia) \cdot \Psi_k(i) \quad (2.7)$$

де s_k – довжина носія ВФ на k -му старті (s_k – парне число);

a – крок дискретизації ВФ; $\Psi_k(i)$ – вейвлет-функція на k -му старті;

$j = 1, \dots, N$ – розмірність вектору параметрів.

Крок $\gamma[n]$ обирається відповідно рекомендаціям для пошуку оптимуму з оцінкою градієнту: $\gamma[1] = 0,4, \dots, 0,6$.

При цьому для кожного з i елементів зваженої суми (рівняння (2.7)) визначають характеристичні функції $\varepsilon_r(\mathbf{x}, \mathbf{c}_1, \mathbf{c}_2)$, $r = 1, 2$; коли $f(\mathbf{x}, \mathbf{c}_1, \mathbf{c}_2) < 0$, то $\varepsilon_1 = 1$, $\varepsilon_2 = 0$, коли $f(\mathbf{x}, \mathbf{c}_1, \mathbf{c}_2) \geq 0$, то $\varepsilon_1 = 0$, $\varepsilon_2 = 1$.

Тут $f(\mathbf{x}[n], \mathbf{c}_1[n], \mathbf{c}_2[n]) = \|\mathbf{x}[n] - \mathbf{c}_1[n]\|^2 - \|\mathbf{x}[n] - \mathbf{c}_2[n]\|^2$.

Етап 6. Визначають координати центрів кластерів:

Для етапу з обчисленнями на основі ВФ Хаара:

$$\begin{cases} \mathbf{c}_1[n] = \mathbf{c}_1[n-1] - \gamma[n]WT_k(Q(\mathbf{x}[n], \mathbf{c}_1[n-1], \mathbf{c}_2[n-1])) \\ \mathbf{c}_2[n] = \mathbf{c}_2[n-1] - \gamma[n]WT_k(Q(\mathbf{x}[n], \mathbf{c}_1[n-1], \mathbf{c}_2[n-1])) \end{cases} \quad (2.8)$$

Для етапу з гіперболічною ВФ:


$$\begin{cases} \mathbf{c}_1[n] = \mathbf{c}_1[n-1] - \gamma[n]WT_k(Q_1(\mathbf{x}[n], \mathbf{c}[n], g(\mathbf{x}[n], \mathbf{c}_H^*[n-1]))) \\ \mathbf{c}_2[n] = \mathbf{c}_2[n-1] - \gamma[n]WT_k(Q_1(\mathbf{x}[n], \mathbf{c}[n], g(\mathbf{x}[n], \mathbf{c}_H^*[n-1]))) \end{cases} \quad (2.9)$$

Для $k \leq k_{max}$, інакше – зупинка.


Етап 7. Коли $\|\mathbf{c}_r[n] - \mathbf{c}_r[n-1]\| \leq \delta_1$, пошук на поточному старті закінчується, інакше – $n = n + 1$ і здійснюється перехід до етапу 5.

Етап 8. Коли $k > 1$ і $\mathbf{c}_{r,k}^* - \mathbf{c}_{r,k-1}^* \leq \delta_2$ – зупинка; в протилежному випадку, якщо $k < k_{max}$, то збільшується номер старту $k = k + 1$, обирається ВФ для оцінки напряму пошуку і здійснюється перехід до етапу 5. Тут $\mathbf{c}_{r,k}^*$, $\mathbf{c}_{r,k-1}^*$ – результати пошуку для r -го кластеру на k -му і $k-1$ старті відповідно.

Для дослідження швидкодії кластеризації було сформовано набір даних з двох груп (кластерів) по 15 точок у двовимірному просторі ознак (рис. 2.1). Як видно з рис. 2.1, а, кластери лінійно розділювані в просторі ознак. На рис. 2.1, б наведений функціонал $F(\cdot)$. Як указано в [94] такого роду функціонали часто зустрічаються при кластеризації. Значення функціоналу $F(\cdot)$ представляє сумарну помилку першого і другого роду при розділенні даних (рис. 2.1, а) відрізком прямої $y = c_0 + c_1x$. Початкове значення при пошуку кращого значення $F(c_0)c_0[1] = -80$. Значення $c_1 = 2$ не змінювалось.



а)



б)

Рисунок 2.1 – Дані при кластеризації: а) набір даних з двох лінійно розділюваних груп; б) значення функціоналу сумарної помилки першого і другого роду

При пошуку оптимуму для цього функціоналу порівняно з базовим методом з урахуванням обмежень другого роду виграш в часі більше 1,18 разів. При пошуку оптимуму були прийняті: крок дискретизації $dx = 6$ і довжина носія ВФ Хаара $N = 20$, при пошуку з гіперболічною ВФ $dx = 1$.

Для удосконаленого методу кластеризації при дослідженні для гіперболічної функції $\Psi(j) = \frac{1}{\alpha x}$ було прийнято $\alpha = 5$ [103].

Проведено оцінку швидкодії етапу оптимізації порівняно з базовим методом [104]. Це дослідження було проведене з використанням функції $f_2(x) = x^2$ для $x \in (-80, \dots, 80)$. Глобальний мінімум для цієї функції $f_2(x) = 0$ при $x = 0$. Довжина кроку дискретизації при пошуку оптимуму з ВФ Хаара $dx = 1$, при пошуку з гіперболічною ВФ, щоб не порушувалось прийняте в (рівняння (2.5)) обмеження, $dx = 0,01$.

Крім того, було досліджено залежність відносної похибки пошуку мінімуму від амплітуди для обох підходів до оптимізації з використанням вейвлет-функцій (базового методу та методу з використанням обмежень). Результати цього аналізу представлені на рис. 2.2, а. Оцінка швидкодії (часу обчислення) (у секундах) для

обох підходів наведена на рис. 2.2, б, де криві 1 та 2 відповідають базовому методу оптимізації з ВФ та методу з обмеженнями відповідно.




Рисунок 2.2 – Результати оцінювання властивостей методу оптимізації з використанням вейвлет-функцій та ітераційним оцінюванням обмежень порівняно з базовим методом: а) – похибка пошуку мінімуму залежно від відношення сигнал/шум за амплітудою; б) – час пошуку мінімуму в секундах залежно від відношення сигнал/шум за амплітудою.

Аналіз показав, що для співвідношень сигнал/шум від 2 до 14, час, необхідний для визначення оптимуму, значно зменшився – у 7–1,5 разу порівняно з базовим методом оптимізації. Водночас це покращення швидкості супроводжувалося помірним збільшенням відносної похибки визначення мінімуму для тестової функції Де Йонга, яка зросла з 5% до 15%. Такий компроміс між обчислювальною ефективністю та точністю є поширеним явищем у задачах оптимізації; однак результати свідчать про те, що метод з обмеженнями забезпечує розумний баланс, що робить його придатним для практичних застосувань, де скорочення часу обробки є пріоритетним.

При відношенні сигнал/шум по амплітуді до 6,4 (задача розподілена по нормальному закону з нульовим середнім і середньоквадратичним відхиленням від 0 до 100, максимальне значення тестової функції $f_2(x) = 6400$) зростання

швидкодії етапу оптимізації склало від 1,7 до 2,8 разів. Число значень оцінки цільової функції зменшилось від 25 % до 32 % (в залежності від співвідношення сигнал/шум).

Таким чином, можна визначити, що удосконалення методу кластеризації з ВФ з урахуванням обмежень дозволило отримати вигаш в швидкодії в 1,18 разів в порівнянні з базовим методом кластеризації з ВФ. Цей результат дозволяє рекомендувати розроблений метод для аналізу гетерогенних даних при потребі досягнення швидкодії та скорочення обчислень цільової функції.

2.3 Кластеризація в умовах дрейфу центру кластеру за лінійною траєкторією

При аналізі даних важливою задачею є забезпечення швидкодії. Наприклад, при визначенні відповідності параметрів компонентів електроніки вимогам щодо надійності, для поділу виробів на групи по значенням параметрів використовують кластеризацію.

При кластеризації дані розділюють на групи (кластери) по ознакам компактності, так, щоб був оптимізований функціонал якості. Справжній мінімум цього функціоналу може дрейфувати з часом та (або) під дією будь-яких виробничих чи експлуатаційних факторів. Як показав аналіз, існуючі методи кластеризації відрізняються або низькою стійкістю до перешкод, або низькою точністю, що знижує достовірність аналізу даних. Для зниження впливу цих недоліків як базовий метод обрано метод кластеризації на базі МОВП, який удосконалено на основі методу оптимізації з ВП в умовах дрейфу центру кластеру по лінійної траєкторії.

Для цього методу адаптивної кластеризації на основі (рівняння (1.20) прийнято значення $U(n, n-1, c_r[n-1]) = (1 + n^{-1})c_r[n-1]$, де r – номер кластера. Така ситуація може склестися при необхідності запобігання переходу центру одного з (наприклад) двох кластерів за межі границь регулювання у виробничій ситуації).

У цьому методі оцінка параметрів кластера при лінійній або майже лінійній зміні координати його центру здійснюється за допомогою двоступінчастої процедури, яка виконується на кожному часовому кроці. Перший ступінь призначений для коригування змін координати центру кластера по

$$c_r[n] = (1 + n^{-1})c_r[n - 1]. \quad (2.10)$$

Другий ступінь проводиться за схемою, описаною в підрозділі 1.2.5 на основі даних про параметри елементів кластера, виміряних на новому етапі зміненого фактору впливу


Через багатоетапну оцінку напрямку пошуку з гіперболічною ВФ (у методі [105] таких етапів 5 (зі збільшенням α від 1 до 5)) (табл. 1.5). Тобто кількість звернень до «оракула» для отримання значення функціоналу в точці оцінки напрямку (наприклад, спуску до мінімуму) залишається значним. Але на етапі обробки з гіперболічною ВФ, коли проводиться уточнення координати екстремуму, можна скоротити кількість звернень до оракула і, залежно від рівня шуму в цільовій функції, збільшити швидкодію.

. Тому цей етап в порівнянні з відомим методом кластеризації з МОВП **удосконалено** за рахунок того, що на етапі 5, ..., 8 замість багатоетапного пошуку, коли параметри гіперболічної вейвлет-функції обчислюються на основі схеми ліфтингу [47], обчислюється зважена сума значень цільової функції з гіперболічною функцією $\Psi(j) = \frac{1}{\alpha x}$ при початковому масштабі $\alpha = 5$. Початкова точка пошуку оптимуму з гіперболічною ВФ визначається як результат пошуку з ВФ Хаара.

Значення гіперболічної функції $\Psi(j) = \frac{1}{\alpha x}$ використовувалось в розрахунках при масштабі $\alpha = 5$, після чого виконувалось дискретне диференціювання методом скінченних різниць [104].

Досліджено якість удосконаленого методу кластеризації при дрейфі центру кластера по лінійній траєкторії на базі МОВП.

Цільова функція моделювалася з допомогою функції Де Іонга 1 з додаванням завади з нульовим середнім і СКВ від 0 до 10^3 . Дрейф координати центру кластера моделювався з допомогою зміщення цільової функції на величину $N\Delta$, де $N = \overline{1, 5}$; Δ – крок дрейфу. Якість розробленого методу RC (крива 2 на рис. 2.3) вища на 0,06, ніж у адаптивної кластеризації на основі методу k-середніх (крива 1 на рис. 2.3).



1 – k-середніх; 2 – з упередженням

Рисунок 2.3 – Залежність якості RC для різних методів кластеризації від кількості кроків дрейфу N

Встановлено, що удосконалений метод кластеризації при дрейфі центру кластера по лінійній траєкторії дозволяє оцінювати координати центру кластера швидше від 1,2 до 1,3 разів у порівнянні з базовим методом при відношенні сигнал/завада від 30. При відношенні сигнал/завада більшому, ніж 10, відносна погрішність d удосконаленого методу *кластеризації* при дрейфі центру кластера по лінійній траєкторії складає менше 7 % і вища в середньому в 1,2 рази, ніж у базовому методі.

Такі результати відповідають вимогам практики для цієї прикладної задачі і дозволяють рекомендувати удосконалений метод кластеризації при дрейфі центру кластера по лінійній траєкторії, в якому координати центрів кластерів оцінюються з допомогою адаптації на базі МОВП до використання при аналізі ГД. Це дозволить скоротити час оцінки координати центрів кластерів при відношенні сигнал/завада цільових функцій більшому, ніж 30, при незначному зростанні погрішності при

необхідності забезпечити швидкодію і зменшити кількість обчислень цільової функції (звернень до «оракулу»).

Таким чином, сформульовано **другий пункт наукової новизни:**

– *удосконалено* методи кластеризації за дисперсійною ознакою та з дрейфом центру кластера по лінійній траєкторії, особливістю яких є врахування обмежень у вигляді нерівностей та визначення належності образу до відповідного кластеру з допомогою ВФ, що завдяки скороченню кількості обчислень цільової функції (звернень до оракулу) дозволило підвищити швидкодію обчислень.

2.4 Нейронні мережі Колмогорова-Арнольда на основі удосконаленої концептуальної моделі

За результатами аналізу (пункт 1.2.5 Кластеризація за допомогою вейвлет-перетворення) характеристик і можливостей нейронних мереж, які можуть бути використані для вирішення задач класифікації, в роботі зроблений висновок, що перспективним засобом аналізу даних з наявністю шумової складової є мережі WKAN. Такий висновок пов'язаний з тим, що WKAN-мережі дозволяють класифікувати дані в задачах, де важливі як просторові, так і частотні характеристики (наприклад, сигнали для телемедицини – ЕКГ) (рис. 2.4, [106]).

Наслідком цього є необхідність обирати для WKAN-мереж типи ВП, які найкращим чином відповідають особливостям сигналів та їх рівнів шуму, та дозволяють забезпечити прийнятний для цих задач рівень достовірності та швидкодії.

Wav-KAN розширює SKAN, використовуючи базисні функції вейвлетів замість сплайнів [107, 108]. Кожна функція ядра параметризується сімейством вейвлетів (наприклад, розширені/зміщені вейвлети Добеші або вейвлети Гауса), коефіцієнти яких можна навчати.




Рисунок 2.4 – Порівняння структур перцептрону і WKAN-мереж [106]

Розширюючи можливості представлення Колмогорова-Арнольда, одновимірні функції моделюються ВФ. Це дозволяє використовувати важливі властивості вейвлет підходу – проводити аналіз з деталізацією, яку можливо регулювати, тобто виділяти як високо- та низькочастотні характеристики. Це також дозволяє ефективну обробку сигналів з доданням шуму [107, 108].

На відміну від необроблених сплайнів, ряд категорій ВФ мають компактний носій, що дозволяє Wav-KAN адаптуватися до структури даних у різних масштабах. Наприклад, такі моделі дозволяють виділяти локальні особливості ЕКГ та зменшувати вплив шумів, водночас зберігаючи морфологію кардіоциклів (рис. 2.5), [109].

Важливим етапом обробки сигналів є попередня обробка.

Для відомих реалізацій нейронних мереж автори обмежують цей етап лише нормалізацією. Це пов'язано з тим, що нормалізація є критично важливою для роботи багатошарових перцептронів (MLP) [110] та нейромереж KAN-типу, оскільки на якість, швидкодію та ресурсоемність цих моделей мереж впливає масштаб вхідних даних.




Рисунок 2.5 – Приклад обробки ЕКГ з допомогою Wav-KAN [106]

Така, наприклад, при обробці ЕКГ нормалізація полягає у приведенні значень сигналу до єдиного діапазону, зазвичай від 0 до 1, що усуває вплив різних амплітудних діапазонів між сегментами та пацієнтами, зберігаючи відносні відмінності між точками сигналу. Нормалізація обчислюється згідно з формулою:

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (2.11)$$

де x – початкове значення сигналу, $x_{\min}$ та $x_{\max}$ – мінімальне та максимальне значення сигналу в межах сегменту відповідно, а x' – нормалізоване значення.

Завдяки нормалізації моделі здатні стабільніше виділяти локальні та глобальні характеристики ЕКГ, що підвищує точність класифікації аритмій. Крім того, цей етап дозволяє забезпечити порівнянність результатів між різними експериментами та більш точно оцінювати вплив факторів, таких як довжина сегмента чи кількість ВФ у KAN-шарі. Нормалізація також сприяє швидшій

збіжності навчання та покращує узагальненість моделей на нових даних, що особливо важливо для практичних медичних застосувань.

В підрозділі 1.2.3 роботи приведені результати дослідження властивостей різних ВП, в результаті яких визначені частотно-селективні властивості ряду ВФ (табл. 1.4). Наведені також результати відомих досліджень, [43 - 46] також було встановлено, що розглянуті вейвлет-функції мають різні фільтруючі властивості: наприклад, що обробка з ВФ Гауса призводить до «розмивання» границь об'єктів (деталей сигналу та/або зображення), а ВФ Хаара та «обмежений синус» — мають бокові пелюстки в передавальних частотних характеристиках, що забезпечує можливість підкреслення більш високочастотних складових з меншою інтенсивністю.

Методи на основі вейвлет-аналізу володіють високою точністю і завадостійкістю, але їм притаманні значні обчислювальні витрати та не висока швидкодія. Особливо це може впливати на швидкодію і ресурсоемність аналізу сигналів ЕКГ значних обсягів, які є мультимодальні та з наявним шумом.

Для вирішення цієї суперечності у роботі запропоновано для обробки та аналізу сигналів з багатьма екстремумами удосконалення концептуальної моделі відомого підходу пошуку екстремумів з використанням ВП.

Перші етапи обробки гетерогенних даних мають включати наступне.

Після аналізу сигналу, властивостей локальних екстремумів, перешкод, необхідної для цілей обробки та/або аналізу точності, ресурсоемності, швидкодії та залежно від рівня шуму вихідні дані піддаються попередній обробці (фільтрації, сегментації) з використанням ВП, форма і рівень обробки якого обраний на основі ентропійно-інформаційного аналізу [111].

Сучасні дослідження щодо обробки сигналів ЕКГ все більше зосереджуються на покращенні точності виявлення таких важливих компонентів серцевого циклу, зокрема комплексів QRS. Актуальним з використовуваних інструментів для цього є ВП, яке дозволяє багаторівневе представлення сигналу з одночасною локалізацією як у часовій, так і в частотній областях, що сприяє як ідентифікації коротких імпульсів, так і фіксації морфологічних особливостей сигналу.

Сучасні стратегії виявлення QRS можна умовно розділити на три категорії:

- покращення попередньої обробки сигналу – видалення шуму, частотна фільтрація та корекція базової лінії;
- ідентифікація ознак сигналу;
- гібридні підходи на основі поєднання статистичних, кластеризаційних та машинних методів навчання.

ВП виявляється корисним у всіх трьох областях, бо воно може придушувати шум та покращувати відповідні ознаки, служити інструментом для вилучення інформативних закономірностей та діяти як компонент у складних системах виявлення, таких як класифікатори на основі нейронних мереж або алгоритмів кластеризації.

Важливим етапом при використанні ВП є вибір материнського вейвлета, який повинен відповідати конкретним вимогам завдання. Серед найпоширеніших вейвлетів є:

- Добеші 4 (db4) – забезпечує хорошу часову локалізацію та підходить для базового виявлення комплексу QRS;
- Добеші 6 (db6) – його форма дуже нагадує морфологію QRS, що покращує чутливість саме до цих компонентів;
- Хаара – часто використовується для завдань попередньої обробки завдяки своїй обчислювальній простоті;
- симлет та койфлет – забезпечують покращену симетрію та точну локалізацію, що є вирішальним у завданнях, що потребують точного позиціонування піків [112].

Різні вейвлети відрізняються формою, симетрією та кількістю моментів зникнення. Ці властивості безпосередньо впливають на їхню здатність виділяти характерні особливості ЕКГ як у часовій, так і в частотній областях. Як показано на рис. 2.6, візуальне порівняння форм вейвлетів допомагає вибрати найбільш підходящу для надійного виявлення комплексу QRS (рис. 2.6).




Рисунок 2.6 – Візуалізація поширених материнських вейвлетів: Добеші 4 (а); Добеші 6 (б); Хаара (в); Сімлет (г); Койфлет (д).

Як відомо [113], кожна ознака ЕКГ служить певній меті: деякі описують морфологію хвиль, інші ж характеризують частоту або статистичні властивості сигналу. Разом ці ознаки утворюють ідентифікаційний вектор, який можна використовувати як вхідні дані для систем класифікації, таких як штучні нейронні мережі (ШНМ), дерева рішень або методи кластеризації (наприклад, К-середні або DBSCAN) [114]. Поєднання цих ознак забезпечує високу точність у виявленні аритмій, класифікації типів серцевих скорочень та прогнозуванні патологічних станів.

Для забезпечення ефективної роботи таких моделей необхідно вибрати найбільш інформативні рівні вейвлет-розкладу. Кількісні критерії застосовуються для об'єктивної оцінки значущості кожного рівня. Серед найпоширеніших є метрики на основі енергії та міри ентропії [115 - 117]. Енергія сигналу на рівні j визначається як:

$$E_j = E_j = \sum_k |c_{\{j,k\}}|^2, \quad (2.12)$$

Ентропія Шенона визначається як:

$$S_j = - \sum_k p_{j,k} \log(p_{j,k}), \quad (2.13)$$

де:

$$p_{j,k} = \frac{|c_{\{j,k\}}|^2}{\sum_k |c_{\{j,k\}}|^2} \quad (2.14)$$

Окрім ентропії Шеннона, у літературі як більш гнучкий критерій оцінки складності сигналу у вейвлет-аналізі також використовується ентропія Реньї [116]. Однією з її переваг є можливість налаштування чутливості до розподілу ймовірностей через параметр порядку α , що дозволяє краще розрізняти рівні складності сигналу. Ця функція виявляється особливо корисною під час роботи з зашумленими даними. Однак до недоліків належать підвищена обчислювальна складність та необхідність обґрунтованого вибору параметра α , що може ускладнити автоматизацію аналізу.

Для визначення найбільш інформативного рівня розкладання, тобто рівня, на якому співвідношення між енергією сигналу (E) та ентропією (H) досягає свого максимуму, використовується комбінований критерій у вигляді співвідношення ентропії до енергії (рівняння (2.15)) H/E , поділеної на енергію. Це співвідношення допомагає визначити рівень, на якому енергія сигналу є високою (що вказує на наявність компонентів, значущих для аналізу), тоді як ентропія залишається помірною (що вказує на нижчу випадковість). При обробці таких сигналів, як ЕКГ,

цей рівень зазвичай відповідає сегментам сигналу, що містять комплекси QRS, і тому є найбільш придатним для вилучення ознак та класифікації.

$$C_j = \frac{E_j}{S_j}, \quad (2.15)$$

Такі критерії отримали широке визнання у вейвлет-аналізі біомедичних сигналів завдяки їхній здатності об'єктивно ідентифікувати рівні розкладання ВП, що містять інформацію, яка має діагностичне значення для виявлення характерних компонентів ЕКГ-сигналу, зокрема комплексів QRS. Вони також дозволяють точно ідентифікувати зміни серцевого ритму та морфології хвиль. Зокрема, Лі та ін. [115] запропонували використовувати ентропію субсигналу в поєднанні з класифікатором випадкового лісу для класифікації ЕКГ. Корнфорт та ін. [116] проаналізували застосування ентропії Реньї для раннього виявлення нейропатій – дисфункцій вегетативної нервової системи, що впливають на регуляцію серцевого ритму. Рекік та ін. [117] вперше запропонували комбінований критерій, що об'єднує енергію та ентропію, щоб визначити найбільш інформативний рівень розкладання.

У Рекіку та ін. [117] характеристики ентропії були використані для генерації атрибутів для виявлення хвиль Р на основі комбінованого критерію, що враховує інформаційний вміст на різних рівнях розкладання. Лі та ін. [115] виконали виявлення хвиль R, P та T, використовуючи порогове значення вейвлет-коефіцієнтів, що покращило точність визначення ключових точок ЕКГ. Леніс та ін. [118] запропонували метод виявлення зубця Р за допомогою стаціонарного вейвлет-перетворення (СВП), що забезпечує підвищену точність локалізації навіть за наявності шуму.

У дослідженні [119] було запропоновано метод класифікації, заснований на вейвлетах Хаара в поєднанні з критерієм ентропії Шеннона, для ідентифікації інформативних сегментів сигналу. Автори реалізували адаптивний підхід для оптимізації діапазонів коефіцієнтів класифікатора, враховуючи вплив шуму та

обмежених обчислювальних ресурсів. Хоча дослідження в основному зосереджувалося на обробці зображень, методологію можна поширити на біомедичні сигнали, зокрема ЕКГ, де швидка обробка, локалізація часових ознак та зменшення кількості хибних тривог також є критично важливими. Застосування такого підходу до аналізу комплексу QRS відкриває перспективи для розробки високоточних адаптивних систем реального часу.

В рамках дослідження, проведеного в роботі [120] було запропоновано метод, заснований на розрахунку енергії та ентропії на кожному рівні вейвлет-розкладу сигналу ЕКГ. Енергія сигналу на заданому рівні розкладу відображає загальну потужність вейвлет-коефіцієнтів на цьому рівні. Цей показник дозволяє визначити, де зосереджена найбільша кількість інформації про динамічні зміни в сигналі, наприклад, ті, що пов'язані з комплексами QRS. Висока енергія вказує на активні області сигналу, які потенційно є релевантними для виявлення серцевих імпульсів [121].

Ентропія, зокрема ентропія Шеннона, служить мірою невпорядкованості або складності розподілу вейвлет-коефіцієнтів. Вона вказує на те, наскільки хаотичним або структурованим є склад сигналу. Для виявлення комплексів QRS [122] цікаві рівні зі структурованою інформацією (тобто низькою ентропією), оскільки вони з більшою ймовірністю локалізують стабільні морфологічні ознаки, характерні для комплексів QRS.

Поєднання цих показників дозволяє оцінити, наскільки одночасно енергетично значущим і структурованим є певний рівень, що є критичним для автоматичного виявлення QRS. Поєднання цих двох показників, виражене як співвідношення, показане в рівнянні 4, формує інформативний критерій для вибору рівня, де сигнал містить найбільшу кількість упорядкованої енергії. Таким чином, рівень, на якому коефіцієнт c_i (рівняння (2.15)) досягає свого максимуму, вважається оптимальним для виявлення комплексів QRS.

З практичної точки зору, цей підхід дозволяє об'єктивно ідентифікувати рівень розкладання, що містить найбільш структуровану та клінічно значущу інформацію про комплекси QRS [123]. Це особливо корисно в ситуаціях, коли

форма та амплітуда сигналу можуть значно відрізнятися залежно від пацієнта або типу запису ЕКГ. Автоматичне визначення інформативного рівня значно підвищує точність та надійність виявлення, зменшуючи ризик хибно позитивних або хибно негативних результатів. Такий підхід дозволяє автоматизований вибір параметрів без необхідності ручного налаштування або фіксованих рівнів, підвищуючи гнучкість та адаптивність методу в реальних клінічних записах.

Також для подальших досліджень була запропонована така послідовність виконання етапів цієї структурованої методики для практичної реалізації запропонованого підходу.

Етап 1. Визначення цілей дослідження та вибір джерела даних.

Етап 2. Побудова вейвлет-розкладу за допомогою дискретного вейвлет-перетворення (DWT).

Етап 3. Розрахунок значень енергії та ентропії на кожному рівні розкладу;

Етап 4. Визначення коефіцієнта інформативності c_i .

Етап 4. Визначення рівня, на якому c_i є максимальним.

Етап 5. Порівняльний аналіз різних материнських вейвлетів (Добеші 4, Добеші 6, Хаара, сімлета, койфлета).

Проведений аналіз підтвердив ефективність критерію c_i для вибору оптимального рівня вейвлет-декомпозиції при виявленні комплексів QRS у сигналах ЕКГ. Для досліджених ВП, максимальні значення c_i послідовно знаходяться в межах рівнів d3–d5, що відповідає частотному спектру комплексів QRS.

Серед досліджених вейвлетів, Добеші 6, Койфлет 1 та Симлет 4 виявилися найбільш придатними для виявлення QRS завдяки своїм стабільним максимумам c_i на рівнях d4–d5. Хоча ВФ Хаара показав надзвичайно високі значення c_i на першому рівні, він менш придатний через свою надмірну чутливість до шуму та відсутність локалізації. ВФ Добеші 4 продемонстрував ширший розподіл інформативності, що може бути корисним для складніших сигналів, але є менш оптимальним для точного виявлення.

Таким чином, експериментальні результати демонструють доцільність адаптивного підходу до вибору вейвлету та рівня декомпозиції залежно від морфології сигналу. Запропонований метод може бути інтегрований в автоматизовані системи діагностики та моніторингу ЕКГ для підвищення точності виявлення та зменшення кількості хибно позитивних результатів. Тому для подальших досліджень було визнано доцільним в рамках удосконаленої моделі пошуку екстремумів ЕКГ дослідити також варіанти сигналів після обробки з ВФ Добеші 4.

Багатошаровий перцептрон (MLP) є класичною архітектурою штучних нейронних мереж, що широко використовується для задач класифікації завдяки здатності моделювати складні нелінійні залежності між вхідними ознаками та вихідними класами [124]. MLP складається з послідовності повнозв'язних шарів нейронів, де кожен нейрон отримує сигнали від усіх нейронів попереднього шару, застосовує ваги, функцію активації та передає оброблену інформацію далі. Завдяки цьому MLP здатен виділяти як локальні, так і глобальні характеристики даних, забезпечуючи гнучкість моделювання та адаптивність до різних типів сигналів.

Базова модель багатошарового перцептрона (MLP) застосовується для класифікації сегментів ЕКГ довжиною 200 відліків. Вхідний шар приймає одномірні сегменти, які вже були нормалізовані у діапазоні від 0 до 1, забезпечуючи стандартизацію даних і стабільність навчання.

Сигнал спершу проходить через перший прихований Dense шар із 128 нейронами та функцією активації ReLU. Цей шар дозволяє моделі виділяти локальні та глобальні морфологічні ознаки ЕКГ, необхідні для розпізнавання нормальних і патологічних комплексів. Після першого прихованого шару застосовується Dropout із ймовірністю 0.2, що виключає випадкові нейрони під час навчання та зменшує ризик перенавчання. Другий прихований Dense шар складається з 64 нейронів із тією ж функцією активації ReLU, забезпечуючи подальшу агрегацію ознак та зниження шуму. Для додаткової регуляризації після цього шару застосовується Dropout із ймовірністю 0.1.

Вихідний Output шар включає два нейрони для класів N (нормальний ритм) та V (екстрасистоли) із Softmax активацією, яка перетворює отримані ознаки на ймовірності належності сегмента до відповідного класу. Формально ймовірність вихідного нейрона i обчислюється за формулою:

$$y_i = \frac{e^{z_i}}{\sum_{j=1}^2 e^{z_j}}, \quad (2.16)$$

де z_i – лінійна комбінація входів і ваг, що накопичує інформацію про морфологію сегмента.

Схема на рис. 2.7 ілюструє послідовний потік даних від сегмента ЕКГ через вхідний шар, два приховані Dense шари та вихідний шар. На схемі відображено повнозв'язні з'єднання між нейронами кожного шару, що забезпечує передачу всіх ознак від кожного нейрона попереднього шару до всіх нейронів наступного. Візуалізація також підкреслює щільність нейронів на прихованих шарах, яка відповідає здатності моделі одночасно обробляти велику кількість морфологічних ознак. Така організація шарів і щільність зв'язків дозволяють моделі стабільно навчатися на сегментах різних пацієнтів і ефективно виділяти локальні та глобальні характеристики сигналу, що підвищує швидкодію моделі при класифікації нормальних і патологічних комплексів.

Модель MLP-KAN (Knowledge-Augmented Network) є розширенням класичного багат шарового перцептрона за рахунок включення KAN-шару [125], який забезпечує ефективне виділення локальних особливостей сигналів за допомогою радіальних базисних функцій (RBF). На відміну від стандартного MLP, який оперує лише повнозв'язними шарами, KAN-шар дозволяє мережі моделювати складні локальні нелінійності, підвищуючи точність класифікації навіть у випадку рідкісних або змінних патернів сигналу [126].




Рисунок 2.7 – Схема базового багатошарового перцептрона (MLP)

Вхідний шар моделі приймає ті ж сегменти сигналу, що й базовий MLP [21], із попередньою нормалізацією до діапазону 0, 1. KAN-шар складається з набору радіальних базисних функцій [127], кількість яких може варіюватися в залежності від експериментальних параметрів (наприклад, 4, 6 або 8 RBF). Кожна функція має форму класичної гаусівської RBF:

$$\varphi_i(x) = \exp\left(-\frac{(x - c_i)^2}{2\sigma^2}\right) \quad (2.17)$$

де x – значення сегмента на вхідному шарі,

c_i – центр i -ої функції,

σ – параметр ширини, що визначає локальність впливу [128, 130].

Виходи KAN-шару передаються на Dense-шар, де вони комбінуються з вагами, які навчаються разом із мережею [131]. Це створює компактне представлення локальних ознак, яке потім передається на прихований Dense-шар із ReLU активацією та Dropout для регуляризації [132]. Вихідний шар містить два нейрони з Softmax-активацією, що дозволяє моделі прогнозувати належність сегмента до класів N або V .

Схема MLP-KAN, показана на рис. 2.8, демонструє компактну архітектуру з паралельною обробкою локальних характеристик сигналу в KAN-шарі та подальшою інтеграцією через приховані Dense шари.

Вхідний шар приймає сегмент ЕКГ довжиною 200 відліків, після чого кожна точка проходить через KAN-шар із шістьма радіальними базисними функціями, що дозволяє виділяти локальні патерни сигналу. Далі виходи KAN-шару передаються на приховані Dense шари (128 та 64 нейрони) з активацією ReLU, після чого інтегроване представлення сигналу потрапляє на вихідний Dense шар із двома нейронами та Softmax-активацією для класифікації.

Включення KAN-шару в архітектуру моделі дозволяє ефективніше захоплювати локальні особливості сигналу, які важко виділити стандартними Dense шарами. Це підвищує стійкість моделі до варіацій сегментації, шумів та амплітудних коливань ЕКГ, забезпечуючи більш надійну класифікацію навіть при наявності нерегулярностей у серцевому ритмі. Крім того, KAN-шар сприяє формуванню компактного і багатовимірного представлення сегментів сигналу, що покращує здатність моделі до узагальнення на нових даних. Такий підхід створює основу для подальших експериментів з варіацією числа радіальних базисних функцій у KAN-шарі та аналізу впливу архітектурних параметрів на швидкодію моделі, дозволяючи оптимізувати баланс між точністю класифікації та обчислювальними витратами.




Рисунок 2.8 – Схема нейронної мережі MLP-KAN

Для подальшого підвищення здатності моделі до виділення локальних та частотно-часових ознак ЕКГ-сигналів архітектуру MLP-KAN було модифіковано шляхом заміни радіально-базисних функцій у KAN-шарі на ВП.

ВП застосовується для аналізу сигналів, що змінюються у часі, оскільки воно дозволяє одночасно виділяти локальні часові та частотні характеристики. На відміну від стандартних Dense або радіально-базисних шарів, які оперують лише амплітудною інформацією, вейвлети дозволяють моделі розпізнавати короточасні аномалії, коливання та різкі зміни сигналу, що характерно для екстрасистол та інших аритмій [133]. Застосування ВФ у KAN-шарі покращує здатність моделі захоплювати складні патерни, зменшує вплив шуму та варіацій сегментації, підвищуючи точність класифікації.

Нова модель отримала назву MLP-KAN-WT (Multilayer Perceptron with Kolmogorov–Arnold Layer and Wavelet Transform). Такий підхід дозволяє виділяти більш складні локальні патерни сигналу, одночасно зберігаючи часову та частотну інформацію, що підвищує стійкість до шуму та варіацій сегментації.

Вхідний шар моделі приймає нормалізовані сегменти ЕКГ довжиною 200 відліків. Однак, для підвищення швидкодії та зниження ресурсоемності системи, у роботі запропоновано модифікацію вхідного каскаду шляхом подачі даних, що пройшли попередню вейвлет-фільтрацію. Це дозволяє скоротити обсяг вхідної вибірки за рахунок виділення найбільш інформативних коефіцієнтів розкладу. Вибір оптимального рівня декомпозиції та типу материнського вейвлета при цьому здійснюється на основі розробленого комбінованого критерію – співвідношення ентропії до енергії H/E (рівняння (2.15)). Такий підхід забезпечує мінімізацію надмірності даних при збереженні ключових ознак QRS-комплексу, що критично важливо для навчання моделей типу MLP-KAN в умовах обмежених обчислювальних ресурсів

KAN-Wavelet шар обробляє кожну точку сегмента за допомогою набору вейвлетних функцій, що дозволяє виділяти більш детальні локальні ознаки сигналу. Виходи цього шару передаються на два приховані Dense шари з 128 та 64 нейронами та функцією активації ReLU, які лінійно комбінують виділені ознаки для подальшої класифікації. Вихідний Output шар із двома нейронами та Softmax-активацією забезпечує прогноз класів N та V .

Архітектура MLP-KAN-WT показана на рис. 2.9.




Рисунок 2.9 – Схема нейронної мережі MLP-KAN-WT

Схема демонструє паралельну обробку сегмента у KAN-Wavelet шарі та подальший потік інформації через приховані Dense шари до вихідного шару, що підкреслює принцип модифікації та покращення здатності моделі до виділення локальних патернів. Така організація шарів і використання ВП дозволяє моделі стабільно навчатися на сегментах різних пацієнтів та ефективно інтегрувати часово-частотну інформацію для підвищення точності класифікації аритмій.

Таким чином, сформульовано **третій пункт наукової новизни**:

– *удосконалено* метод нейромережевої класифікації ГД на базі архітектури KAN шляхом застосування у вхідному шарі вейвлет функцій, що дозволило підвищити точність ідентифікації станів об'єктів у зашумленому середовищі при мінімізації кількості налаштовуваних параметрів та зростання швидкодії обчислень.

2.5 Висновки до другого розділу

У розділі проведено теоретичне обґрунтування та розробку методів обробки гетерогенних даних на основі удосконалених процедур оптимізації, кластеризації та нейромережевої класифікації з використанням вейвлет-функцій. Проведений аналіз ітеративних методів оптимізації показав, що традиційні градієнтні підходи

мають низьку стійкість до завад у мультимодальних середовищах, через що в роботі удосконалено метод оптимізації на основі ВФ шляхом інтеграції методу центрів для врахування обмежень у вигляді нерівностей. Це дозволило звузити область пошуку на етапі уточнення координати екстремуму гіперболічною ВФ та забезпечити перехід до безумовної мінімізації, що експериментально підтвердило зростання швидкодії від 1,7 до 2,8 разів та зниження кількості звернень до оракула на 25–32% при збереженні необхідної достовірності в умовах інтенсивних завад.

Удосконалено методи кластеризації гетерогенних даних за дисперсійною ознакою та в умовах дрейфу центру кластера по лінійній траєкторії, де наукова новизна полягає у використанні ітераційного оцінювання обмежень другого роду всередині вейвлет-процедур. Встановлено, що для статичних вибірок виграш у швидкодії порівняно з базовими вейвлет-методами становить 1,18 разів, а в умовах лінійного дрейфу, типового для виробничих процесів, метод забезпечує оцінку координат центрів у 1,2–1,3 рази швидше за відомі адаптивні аналоги при відносній похибці менше 7%.

На основі розробленої концептуальної моделі удосконалено метод нейромережевої класифікації на базі архітектури Wav-KAN, де впровадження вейвлет-функцій як базисних замість традиційних сплайнів дозволило поєднати переваги мультимасштабного аналізу з компактністю носія функцій ядра. Такий підхід забезпечує можливість виділення локальних особливостей складних сигналів у зашумленому середовищі та мінімізацію кількості налаштовуваних параметрів мережі, що суттєво знижує ресурсоємність обчислень. Показано, що інтеграція етапу нормалізації та попередньої фільтрації на основі ентропійно-інформаційного аналізу є критичною для стабільної збіжності моделей, що дозволяє рекомендувати розроблені методи для застосування в системах телемедицини та контролю якості електроніки в умовах апіорної невизначеності.

3 ДОСЛІДЖЕННЯ МЕТОДІВ АНАЛІЗУ ЕЛЕКТРОКАРДІОГРАМ З ВЕЙВЛЕТ-ПЕРЕТВОРЕННЯМ

3.1 Вибір типу і рівня вейвлет-перетворення на основі критерія співвідношення ентропії та енергії сигналу

За результатами аналізу (пункт 1.2.5) моделей та методів обробки та аналізу таких різновидів даних, як ЕКГ, в роботі зроблений висновок, що перспективним засобом аналізу даних з наявністю шумової складової є вейвлет-перетворення. Одночасно було визначено, що для забезпечення ефективної роботи таких моделей необхідно вибрати найбільш інформативні рівні вейвлет-розкладу.

В пункті 2.3 з цією метою було висвітлено, що для визначення найбільш інформативного рівня розкладання, тобто рівня, на якому співвідношення між енергією сигналу (E) та ентропією (H) досягає свого максимуму, в роботі використовується комбінований критерій у вигляді співвідношення ентропії до енергії (рівняння (2.15)). Цей вибір обумовлений тим, що таке співвідношення сприяє визначенню рівня, на якому енергія сигналу є високою (що вказує на наявність компонентів, значущих для аналізу), тоді як ентропія залишається помірною (що вказує на нижчу випадковість). При обробці таких сигналів, як ЕКГ, цей рівень зазвичай відповідає сегментам сигналу, що містять комплекси QRS, і тому є найбільш придатним для ідентифікації ознак цих сигналів з метою подальшої класифікації.

Також для подальших досліджень була запропонована така послідовність виконання етапів цієї структурованої методики для практичної реалізації запропонованого підходу, згідно з якою виконується побудова вейвлет-розкладу за допомогою дискретного вейвлет-перетворення, розрахунок значень енергії та ентропії на кожному рівні розкладу; визначення коефіцієнта інформативності s_i (рівняння (2.15)). Після визначення рівня, на якому s_i є максимальним, проводиться вибір відповідного ВП і рівня розкладання.

В роботі з цією метою досліджувались різні материнські ВФ (Добеші 4, Добеші 6, Хаара, сімлета, койфлета). Кількісні результати дослідження щодо вибору типу ВП та рівня обробки наведені нижче.

Для всіх типів вейвлетів декомпозицію виконували до восьмого рівня включно. Цей вибір був мотивований теоретичними міркуваннями щодо частотного покриття, а також результатами попередніх досліджень [120, 134], які вказували на найвищу інформативність на рівнях d3-d5.

Для перевірки цієї гіпотези було проведено експеримент для рівня Добеші 6, результати якого представлені в таблиці 3.1. Як показано в таблиці 3.1, максимальне значення коефіцієнта C_i досягається на рівні декомпозиції d4, що відповідає теоретичним очікуванням та підтверджує ефективність критерію автоматичного вибору рівня декомпозиції.

Таблиця 3.1– Результати розрахунку C_i для ВФ Добеші 6

Рівень розкладу	d1	d2	d3	d4	d5	d6	d7	d8
C_i	5.3532	21.3872	27.1572	27.7161	2.3309	0.2752	0.0903	0.0078

Крім того, глибші рівні декомпозиції (понад вісім рівнів) призводять до надмірної втрати високочастотної інформації [135], що є критично важливим для локалізації комплексів QRS, тоді як нижчі рівні декомпозиції можуть не враховувати всі відповідні характеристики сигналу. Таким чином, вісім рівнів забезпечують компроміс між роздільною здатністю за частотою та збереженням ключових характеристик серцевого ритму.

Розрахунки були реалізовані в середовищі Python з використанням бібліотеки PyWavelets, яка пропонує зручний інтерфейс для побудови багаторівневих дискретних вейвлет-декомпозицій та дозволяє легко модифікувати тип материнського вейвлета. Це полегшує проведення серії експериментів з різними вейвлетами без значного ускладнення коду.

Під час аналізу сигналу для кожного рівня декомпозиції j були розраховані дві ключові метрики – енергія та ентропія. Щоб уникнути надмірності, у дослідженні використовувалися раніше визначені формули для обчислення енергії, ентропії та коефіцієнта інформативності S_i , які дозволяють ідентифікувати рівень з найвищою концентрацією впорядкованої інформації. Цей рівень обирається для виявлення комплексу QRS, оскільки він поєднує в собі високу енергетичну значущість та низьку ентропію. Рівень вважався оптимальним, коли S_i досягав свого максимуму.

Крім того, було проведено аналіз стабільності результатів критерію S_i для оцінки однозначності вибору рівня вейвлет-розкладу для різних пацієнтів. Цей крок особливо важливий для майбутньої адаптації методу до застосувань у реальному часі або змінних характеристик сигналу.

Цей підхід зменшує залежність точності виявлення QRS від ручного втручання або попередньо встановлених параметрів, що особливо цінно при розробці автоматичних систем моніторингу. Він також дозволяє оцінити чутливість методу до морфологічних варіацій та автоматично вибрати найбільш інформативний рівень розкладу.

В рамках дослідження було проведено серію експериментів з використанням п'яти найпоширеніших ВФ: Добеші 4, Добеші 6, Хаара, Симлета та Койфлета. Для кожного типу вейвлету до сигналу № 109 з бази даних МІТ-ВІН [136] було застосовано дискретне вейвлет-перетворення, а коефіцієнт інформативності S_i було розраховано на кожному з восьми рівнів розкладання. Графічне представлення результатів наведене на рис 3.1.

Як можна побачити з рис.3.1, незалежно від типу материнського вейвлету, максимальні значення критерію S_i переважно локалізовані в діапазоні рівнів $d3-d5$. Цей діапазон відповідає частотному спектру 5–20 Гц, в якому зазвичай зосереджена енергія комплексів QRS. Цей висновок підтверджує стабільність критерію S_i та його ефективність у завданні автоматизованого виявлення QRS.




Рисунок 3.1 – Залежність значення критерію C_i від рівня декомпозиції для різних типів вейвлетів: а) – Daubechies 4; б) – Haar; в) – Symlet; г) – Coiflet.

Підсумовуючи результати, отримані для різних типів материнських вейвлетів, можна зазначити, що найкращі значення критерію інформативності C_i були зафіксовані в таких комбінаціях: для Добеші 4, на рівні d4 ($C_i=36,21$); для Добеші 6, також на d4 ($C_i=27,71$); для Симлета, на d4 ($C_i=32,15$); та для Койфлета, на d5 ($C_i=29,34$). Хоча вейвлет Хаара продемонстрував найвище значення критерію C_i (219,85) на першому рівні, таке значення вважають надмірно чутливим до шуму і тому менш прийнятним для клінічного використання. Таким чином, найстабільніші результати були досягнуті на рівнях d4–d5 для вейвлетів db6, sym4 та coif1, що підтверджує їхню придатність для виявлення QRS.

Також було визначено, що порівняння результатів для різних типів вейвлетів дозволило виявити певні тенденції. Зокрема, вейвлет Добеші 6 показав найвищі значення C_i на рівні d4, тоді Симлет і Койфлет мали максимуми дещо зміщені до d5. Тим часом Добеші 4 демонстрував більш «розмитий» максимум, що вказує на дещо нижчу селективність.

Таким чином, результати обчислень довели, що критерій S_i дозволяє не тільки вибрати оптимальний рівень розкладання для конкретного сигналу, але й забезпечує кількісну оцінку щодо відповідності типу і рівня ВП для завдання виявлення комплексів QRS. Тому цей підхід може бути використаний як компонент більш загальних адаптивних систем обробки ЕКГ, які автоматично підлаштовуються під морфологію сигналу та допомагають уникнути фіксованих параметрів.

Проведений аналіз підтвердив ефективність критерію S_i для вибору оптимального рівня вейвлет-розкладання при виявленні комплексів QRS в сигналах ЕКГ. Незалежно від типу вейвлету, максимальні значення S_i послідовно зустрічаються в межах рівнів d3–d5, що відповідає частотному спектру комплексів QRS.

Серед досліджених вейвлетів, Добеші 6, Койфлет 1 та Симлет 4 виявилися найбільш придатними для виявлення QRS завдяки їхнім стабільним максимумам S_i на рівнях d4-d5. Також визначено, що вейвлет Добеші 4, як можна визначити з рис. 3.1, а, може бути корисним для складніших сигналів, але є менш вдалим вибором для точного виявлення QRS комплексів.

Таким чином, експериментальні результати демонструють доцільність адаптивного підходу до вибору вейвлету та рівня декомпозиції залежно від морфології сигналу на основі обчислень критерію співвідношення ентропії до енергії. Запропонований метод може бути інтегрований в автоматизовані системи діагностики та моніторингу ЕКГ для підвищення точності виявлення та зменшення кількості хибно позитивних результатів.

3.2 Ідентифікація ознак на базі пошуку оптимумів нестационарних мультимодальних сигналів

Сучасний рівень обробки даних, наприклад, у телемедицині, часто вимагає аналізу нестационарних періодичних сигналів. Електрокардіограми є прикладом таких сигналів.

Аналіз електрокардіограм (ЕКГ) є одним з відомих методів діагностики серцевих захворювань. Це пов'язано з широким розповсюдженням і різноманіттям таких захворювань. Це також є причиною наявності значної кількості методів ідентифікації і класифікації ознак для діагностування захворювань на основі аналізу ЕКГ. В тому числі існують і підходи, які для позбавлення шуму в сигналі використовують ВП [137]. Також при аналізі ЕКГ актуальні методи аналізу нестационарних періодичних сигналів. До таких методів віднесено і досліджуваний метод ідентифікації координат R-піків та інтервалів між ними, який використовує для пошуку характерних точок ЕКГ оптимізацію з ВП.

Як правило, при діагностиці серцево-судинних захворювань за допомогою ЕКГ проводяться три етапи обробки даних: попередня обробка, ідентифікація (виділення ознак) та класифікація [138]. У цьому випадку часто вимірювання таких сигналів не дозволяє позбутися шумів. Ці шуми виникають як під час реєстрації сигналів, так і під час передачі даних по лініях зв'язку [62, 72, 73, 139]. Етап попередньої обробки спрямований на усунення таких шумів. Для усунення цих особливостей сигналу ЕКГ часто використовуються низькочастотні та високочастотні фільтри та/або вейвлет-обробка [139]. Сигнали ЕКГ мають складні часово-частотні характеристики з високочастотною та низькочастотною складовими, часто зі спектром з перекриттям [110] корисного ЕКГ-сигналу та шуму. Це може призвести до зниження достовірності діагностики [73]. За даними [138, 141] відповідно до протоколів медичних досліджень, під час ідентифікації виділяють ознаки, які дозволяють розрізняти особливості досліджуваних захворювань. Через високу варіабельність частоти серцевих скорочень при ряді захворювань буває важко отримати великі набори даних навіть від одного пацієнта [138].

Крім того, існує велика кількість методів, спрямованих на автоматизацію процедури ідентифікації. Серед цих методів ідентифікації можна виділити три групи: методи, що виділяють ознаки змін амплітуди та частоти серцевих скорочень з часом, методи, що виділяють спектральні параметри ЕКГ-сигналів, та методи, що дозволяють визначати як часові, так і частотні характеристики ЕКГ-сигналу –

вейвлет-методи обробки. Завдяки різноманітності методів, важливим завданням є зменшення розмірності набору ознак, що дозволяє зменшити обчислювальні витрати та підвищити продуктивність на етапі класифікації [52, 90, 142].

Так, наприклад, на цьому етапі використовуються такі методи вибору ознак, як методи, спрямовані на рекурсивне зменшення набору ознак; генетичні та ройові алгоритми [138, 143], методи дисперсійного аналізу [138, 143]. Зменшення обсягу оброблюваних даних до етапу ідентифікації дозволяє використовувати вейвлет-перетворення (ВП) для аналізу ЕКГ [28, 86, 138]. За допомогою цього аналізу досліджуваний сигнал розкладається на набір вейвлет-функцій (ВФ) [86]. Ці функції враховують часовий зсув та зміни масштабу вихідної ВФ [72]. Отже, обробка за допомогою ВФ дозволяє враховувати часові та частотні особливості сигналу, отримуючи набір коефіцієнтів для подальшої обробки [35].

Через складність завдань методи обробки ЕКГ на сучасному етапі різноманітні [144]. Таким чином, відомі підходи до аналізу ЕКГ, засновані на теорії хаосу, поєднанні статистичних, геометричних та нелінійних ознак варіабельності серцевого ритму, RPCA - рекурсивному аналізі головних компонент, SPSA - методі стохастичної апроксимації одночасного збурення, FDBT - методі на основі першої похідної, SDBT - методі на основі другої похідної, методі на основі перетворення Гілберта та інших [138].

Деякі з цих методів, наприклад, методи, засновані на оцінці першої та другої похідних в умовах оцінки параметрів нестационарного сигналу ЕКГ з багатьма екстремумами, можуть мати низьку завадостійкість та/або підвищену похибку. Ряд авторів використовують один з рівнів обробки з WT як вектор класифікації для подальшої класифікації [145].

Інший підхід передбачає оцінку статистичних характеристик сигналу ЕКГ після обробки за допомогою вейвлет-функції [146]. Цей підхід використовує ці статистичні характеристики як вектор класифікації в діагностиці.

Однак, наприклад, для діагностики різних типів аритмій потрібен аналіз великих обсягів даних. Тому обидва підходи вимагають значного часу обчислення [145].

При високих вимогах до ефективності [138] зменшують розмірність вектору класифікації, визначаючи характерні ознаки фрагментів QRS ЕКГ (рис.3.2). Слід також зазначити, що розмірність вектору ознак змінюється під час ідентифікації для різних захворювань [141]. Так, наприклад, ряд авторів визначають рівні обробки за допомогою як вибору ВФ, так і масштабу ВФ [49].




Рисунок 3.2 – Стандартна форма хвилі ЕКГ з комплексом QRS [149]

Такий підхід при аналізі довготривалих ЕКГ, наприклад, при використанні холтерівського моніторингу [147], дозволяє зменшити розмір початкового набору даних (рис.3.3, а) під час обробки (рис.3.3, б).

Для пошуку екстремуму полімодальних функцій було розроблено метод оптимізації з використанням ВФ, завадостійкість якого була доведена авторами робіт [48, 149, 150].

На основі цього методу, в рамках використання концептуальної моделі обробки та аналізу ГД на базі ВП, вихідні дані ЕКГ піддаються попередній фільтрації з використанням ВП, форма і рівень обробки якого обраний на основі ентропійно-інформаційного аналізу, запропонованому в роботі (пункті 2..).




Рисунок 3.3 – Фрагмент сигналу ЕКГ на різних етапах аналізу: а) – вхідний сигнал ЕКГ; б) – коефіцієнт ВФ Добеші 4 [28]

В результаті ентропійно-інформаційного аналізу для фільтрації ЕКГ обрано ВФ Добеші 4 [28]. Це дозволило скоротити об'єм даних для подальшої ідентифікації та досягти зниження рівня шуму сигналу ЕКГ (рис.3.3, б).

У цій роботі для пошуку екстремумів (R-піків) використовувалися лише етапи обробки сигналів за допомогою ВФ Хаара [49, 150. 151], були підібрані параметри методу та оцінено їх вплив на швидкодію процедури оцінки координат екстремумів.

Визначення просторових координат R-піків проводиться шляхом пошуку координат екстремумів періодичних сигналів (п.2.2) У роботі досліджено сигнали з MIT/BIN Arrhythmia Database [136].

Основні етапи методу МОВП описані в [28]. У вихідних даних при визначенні просторових координат R-піків задаються додатково:

- Δ_s – крок змінення довжини носія ВФ $\Psi_1(i)$;
- A_1 – порогове значення амплітуди екстремуму;
- ΔR – початкове наближення до довжини інтервалу між екстремумами.

Визначення координат екстремумів (R - піків). проводиться в наступній послідовності.

Крок 1. При пошуку R – піків стартова довжина носія ВФ Хаара $s_1 = 4$.

Крок 2. Проводиться аналіз у відповідності з (рівняння (2.4)) з оцінкою знаку ВП до закінчення сигналу ЕКГ, що досліджується. Коли значення знаку ВП змінюється, $Q(x, c^*)$ порівнюється з порогом A_1 .

Крок 3. Проводиться перевірка умови $Q(x, c^*) \geq A_1$. Коли $Q(x, c^*) \geq A_1$ – реєструється амплітуда екстремуму періоду (R-піку) та його координата R_i . Після визначення другого та подальших екстремумів визначається $\Delta R_i = R_i - R_{i-1}$. Якщо виконується умова $\Delta R_i \geq \Delta R$, реєструється значення ΔR_i .

Крок 4. Визначається довжина носія ВФ Хаара для подальшого пошуку екстремуму. При $s_k \leq \frac{\Delta R}{2}$ довжина носія ВФ $s_{k+1} = s_k + \Delta s$; при $s_k > \frac{\Delta R}{2}$ довжина носія ВФ для наступного періоду визначається як s_1 і здійснюється перехід до кроку 2.

З урахуванням результатів відомих досліджень щодо погрішності пошуку екстремуму з допомогою методу оптимізації МОВП, для пошуку екстремумів обрано ВФ Хаара. Такий вибір був оснований на результатах цього дослідження, коли було обчислено погрішність визначення координати екстремуму для ВФ Хаара $\Psi_1(i)$ та гіперболічної ВФ $\Psi_3(i)$ для асиметричної тестової функції $f_1(x) = x^2 \cdot e^{xm}$ та встановлено, що відносна погрішність d визначення координати оптимуму функції $f_1(x)$ з ВФ Хаара $\Psi_1(i)$ не залежить від стартової точки пошуку, прямо пропорційна коефіцієнту асиметрії і складає 0,3 % (крива 1 на рис. 1.9)). Для оцінки з гіперболічною ВФ $\Psi_3(i)$ ця погрішність 0,1 % крива 2 на рис. 1.9).

Було також проаналізовано завадостійкість методу на етапі пошуку з ВФ Хаара з використанням функції Де Йонга 1 $f_4(x) = x^2$ (при $x \in (-205; 205)$) з додаванням завади (рис. 3.4). Завада була розподілена за нормальним законом з нульовим середнім значенням і середнім квадратичним відхиленням (СКВ) від 0 до 40000, максимальне значення функції було $f_4(x) = 42000$. Встановлено, що при відношенні сигнал/завада по амплітуді від 1,05 метод дозволив вийти в область глобального мінімуму з погрішністю $\delta \leq 10^{-2}$.




Рисунок 3.4 – Траєкторія пошуку екстремуму на етапі обробки з ВФ Хаара $\Psi_1(i)$ для функції $f_4(x) = x^2$ з додаванням шуму

Такі результати з урахуванням високої варіабельності сигналу (наприклад, в задачах аналізу ЕКГ з аритмією), необхідності забезпечити швидкодію та ресурсоемність обробки, дозволили обґрунтувати вибір для подальших досліджень ВФ Хаара. На основі цього вибору було удосконалено метод пошуку екстремумів періодичних сигналів та ряд етапів цього методу [28] були використані для визначення амплітуди та інтервалів між R-хвилями ЕКГ.

У цій роботі використовувалися лише етапи обробки сигналів за допомогою вейвлет-функції Хаара [152], були підібрані параметри методу та оцінено їх вплив на швидкодію процедури оцінки координат екстремумів.

Першим етапом обробки є ВП сигналу ЕКГ. Для зниження рівня шуму ЕКГ сигналу при пошуку R-піків із збереженням інформації про частоту та просторову локалізацію QRS-комплексів під час автоматизованої обробки пропонується використання вейвлет функції Добеші 4 [48]. Вибір рівня обробки проводиться на основі аналізу ентропії та енергії сигналу ЕКГ.

На наступному етапі проводиться визначення просторових координат R-піків шляхом пошуку координат екстремумів періодичних сигналів за допомогою

оптимізації з ВП [48]. Далі проводиться визначення інтервалів між R-піками для подальшої оцінки статистичних характеристик сигналів ЕКГ, класифікації та прийняття діагностичного рішення.

Для послідовності (рис. 3.3, б) визначено координати перших 7 екстремумів та інтервали між ними.

У роботі [153] було оцінено вплив зміни значення довжини носія s_k на швидкодію.

Відповідно до етапів визначення координат екстремумів (R - піків), обчислення проводиться в наступній послідовності (див.п. 2.2).

Після зміни знака ВП при переході через оптимум визначається діапазон зміни координат екстремуму як $c[n-1] \leq c^* < c[n]$ (рис.3.4).

Далі визначається довжина носія ВФ s_k для пошуку наступного екстремуму в наборі даних. Значення s_k в процесі дослідження змінювалось від 18 до 34.

При цьому через інтегральний характер ВП Хаара при збільшенні довжини носія ВФ координата наступного кроку пошуку в більшому чи меншому ступеню зміщується до екстремуму наступного періоду. Так, при зміні значень s_k від 18 до 34, і величині $\gamma = 1.7$ час пошуку координат R-піків змінювався не більше, ніж на 12% (при початковому значенні $s_1 = 4$).

Також проведено оцінку впливу величини кроку $\gamma[n]$ на швидкодію. Так (при початковому значенні $s_1 = 4$) та зміні γ від 1.4 до 2.0 час визначення координат перших 7 екстремумів (рис. 3.3, б) збільшився на 6%. У порівнянні з базовим методом [48], де пошук інтервалів здійснювався шляхом послідовної багатоетапної обробки спочатку з допомогою ВФ Хаара, а далі – з допомогою гіперболічних ВФ, швидкодію було покращено на 11%.

Відносні погрішності при визначенні склали: для координат R-піків не більше 1,6%, для довжини інтервалів між ними - не більше 2,6%. При дослідженні завадостійкості відносна погрішність визначення довжини R-R інтервалів - менше 4% при відношенні сигнал/шум по амплітуді 20...10.

Ці результати дозволяють рекомендувати удосконалений метод для використання в інформаційних технологіях телемедицини, при підвищенні рівня шумів в сигналах ЕКГ та малих вибірках досліджуваних даних.

3.3 Реалізація вейвлет-шару в структурі мережі Колмогорова Арнольда для виділення локальних ознак ЕКГ-сигналів

Для дослідження здатності моделі мережі з використанням шарів KAN щодо виділення локальних та частотно-часових ознак ЕКГ-сигналів архітектуру MLP-KAN було модифіковано шляхом заміни радіально-базисних функцій у KAN-шарі на шар з вейвлет-обробкою. Такий підхід застосовується для використання відомої здатності ВП одночасно виділяти локальні часові та частотні характеристики. На відміну від стандартних Dense або радіально-базисних шарів, які оперують лише амплітудною інформацією, вейвлети дозволяють моделі розпізнавати короткочасні аномалії, коливання та різкі зміни сигналу, що характерно для екстрасистол та інших аритмій [132]. Застосування вейвлетів у KAN-шарі покращує здатність моделі виділяти складні патерни, зменшує вплив шуму, підвищуючи точність класифікації. Розроблена модель отримала назву MLP-KAN-WT (Multilayer Perceptron with Kolmogorov–Arnold Layer and Wavelet Transform). Такий підхід дозволяє виділяти більш складні локальні патерни сигналу, одночасно зберігаючи часову та частотну інформацію, що підвищує стійкість до шуму.

Вхідний шар моделі приймає нормалізовані сегменти ЕКГ довжиною 200 відліків. KAN-Wavelet шар обробляє кожну точку сегмента за допомогою ВФ, що дозволяє виділяти більш детальні локальні ознаки сигналу. Виходи цього шару передаються на два приховані Dense шари з 128 та 64 нейронами та функцією активації ReLU, які лінійно комбінують виділені ознаки для подальшої класифікації. Вихідний Output шар із двома нейронами та Softmax-активацією забезпечує прогноз класів N та V.

Експериментальна частина дослідження була спрямована на вивчення характеристик трьох архітектур: базової MLP, моделі MLP-KAN, у якій ядровий

шар реалізує локальну нелінійну апроксимацію, та модифікованої MLP-KAN-WT, що дозволяє використати підхід KAN з можливостями дискретного ВП. Для MLP-KAN-WT були обрані ВФ Хаара (Haar) з рівнем декомпозиції 1, Daubechies 4 з рівнем декомпозиції 4, Symlet з рівнем декомпозиції 4 та Coiflet з рівнем декомпозиції 5.

Вибір рівнів декомпозиції для ВФ базувався на критеріях енергії та ентропії, запропонованих у [120]. Енергія сигналу відображає концентрацію інформації на конкретному рівні, а ентропія вимірює ступінь неупорядкованості коефіцієнтів. Поєднання високої енергії та низької ентропії дозволяє автоматично визначити рівні, які найкраще відображають локальні та частотні ознаки сигналу. Таке порівняння дозволяє оцінити, наскільки зміна способу подання сигналу та механізму нелінійності впливає на стабільність навчання, точність класифікації та обчислювальну ефективність моделей.

Усі моделі тренувалися за уніфікованою схемою оптимізації: використовувався оптимізатор Adam зі швидкістю навчання 0.001, мініпакети фіксованого розміру та функція втрат categorical cross-entropy. Це забезпечувало контрольовані умови, у яких різниця в результатах могла бути віднесена саме до архітектурних особливостей, а не до гіперпараметрів. Навчання кожної моделі виконувалося з однаковими значеннями початкових ваг, що дозволяло зменшити варіативність між запуском та забезпечувало коректність статистичних порівнянь. Для оцінювання використовувався незалежний тестовий набір, на якому фіксувалися підсумкові метрики якості, матриці плутанини та часові показники.

Значна частина експериментів була присвячена впливу розмірності вхідного вікна. Основною довжиною сегмента обрано 200 відліків, оскільки в межах цього інтервалу зазвичай вміщується необхідний обсяг морфологічної інформації для розпізнавання характерних ознак скорочення. Проте, щоб оцінити чутливість моделей до кількості доступного контексту, розглядалися також сегменти довжиною 100, 150 та 250 відліків. Це дало змогу простежити, як скорочення або розширення часової області впливає на якість класифікації, а також на швидкість навчання та збіжність. Аналіз цих сценаріїв дає уявлення про те, наскільки моделі

залежать від структури вхідного сигналу та чи можуть вони стабільно функціонувати за умов, коли обсяг доступної інформації є обмеженим.

Окремий блок експериментів був спрямований на оцінку ролі KAN-шару, який відповідає за локальну нелінійну апроксимацію. Досліджувалася зміна його ємності через кількість радіально-базисних функцій (4, 6 та 8 RBF). Така варіація дає змогу оцінити, як збільшення складності нелінійного простору впливає на виявлення дрібних морфологічних змін, характерних для патологічних скорочень. Порівняння сценаріїв показує, за яких умов збільшення числа RBF є виправданим, а коли додаткова складність призводить лише до зростання обчислювальних витрат без суттєвого покращення метрик.

У моделі MLP-KAN-WT досліджувався вплив початкового вейвлет-перетворення, що формує багаторівневе часово-частотне представлення сигналу. Оцінювалася інформативність ознак на ранніх етапах обробки сигналу та вплив на роботу KAN-шару. Важливою частиною експериментальної схеми було врахування дисбалансу класів, зокрема недостатнього представлення класу V (з меншою кількістю наявних прикладів). Для зниження впливу дисбалансу навчальні набори формувалися так, щоб забезпечити більшу кількість прикладів скорочень серцевих шлуночків. Це давало змогу уникнути зміщених рішень, характерних для моделей, схильних до переважання домінуючого класу, та дозволяло оцінювати реальну здатність моделей виявляти рідкісні, але клінічно значущі події.

Оцінка результатів включала аналіз точності, F1-score для кожного класу, стійкість збіжності, а також швидкодії (часу навчання). Також були розраховані матриці плутанини, які дозволяли дослідити характер типових помилок – наприклад, заміну екстрасистол нормальними скороченнями або навпаки. Порівняння таких помилок для мереж різної архітектури дає можливість кількісно оцінити, наскільки ефективно локальна нелінійність KAN-шару та варіанти ВП у MLP-KAN-WT сприяють правильному розпізнаванню складних морфологічних патернів.

Для оцінки ефективності базового MLP та модифікованих моделей MLP-KAN були використані три ключові метрики: точність класифікації (accuracy), F1-score для класу V (екстрасистоли) та час навчання (training time).

Оскільки клас V зустрічається значно рідше, ніж клас N (нормальний ритм), тому F1-score є критично важливим показником здатності моделі коректно виявляти рідкісні патологічні сегменти. Час навчання дозволяє оцінити обчислювальну ефективність моделей і дозволяє оцінювати можливість компромісу між швидкістю навчання та точністю класифікації, що важливо для практичного застосування у медичних системах реального часу.

Усі моделі тренувалися на сегментах ЕКГ довжиною 200 відліків із нормалізованими значеннями в діапазоні від 0 до 1. Для зменшення ефекту дисбалансу класів використано підхід балансування даних MIT-BIH шляхом включення додаткових сегментів класу V із різних записів. Це забезпечило репрезентативну кількість прикладів для обох класів та мінімізувало ризик перенавчання моделей на більш частому класі N.

Результати тестування представлені у табл. 3.2, яка демонструє продуктивність базового MLP та різних модифікацій MLP-KAN із RBF-шаром і вейвлетною передобробкою. Дані показують, що включення KAN-шару та застосування ВП забезпечує стабільне підвищення точності класифікації та F1-score для рідкісного класу V порівняно з базовою архітектурою.

Базова модель MLP продемонструвала високий рівень точності класифікації сегментів ЕКГ – 0,9993, проте її здатність виявляти рідкісні патології (клас V) була обмеженою, що відображалось у F1-score для цього класу на рівні 0,9951 при часі навчання 32,36 с.

Впровадження KAN-шару у модель MLP-KAN-RBF8 дозволило підвищити точність до 0,9997 та F1-score для класу V до 0,9976. Однак, для досягнення цього результату обчислювальні витрати збільшилися – час навчання склав 61,07 с. Це свідчить про те, що KAN-шар ефективно захоплює локальні особливості сигналу та підвищує чутливість моделі до рідкісних сегментів без суттєвого зниження продуктивності для основного класу N.

Таблиця 3.2 – Порівняльні результати

Модель	Точність (Accuracy)	F1-міра (F1_V)	Точність (Precision_V)	Повнота (Recall_V)	Час, сек (Time_sec)
MLP	0.999324	0.995146	0.990338	1.000000	32.36
MLP-KAN-RBF4	0.999324	0.995146	0.990338	1.000000	46.12
MLP-KAN-RBF6	0.999324	0.995122	0.995122	0.995122	66.43
MLP-KAN-RBF8	0.999662	0.997555	1.000000	0.995122	61.07
MLP-KAN-WT-haar_1	0.999662	0.997555	1.000000	0.995122	41.46
MLP-KAN-WT-db4_4	0.998648	0.990243	0.990243	0.990243	43.24
MLP-KAN-WT-sym_4	0.998648	0.990243	0.990243	0.990243	52.01
MLP-KAN-WT-coif_5	0.998648	0.990148	0.990148	0.990148	51.64

Модель MLP-KAN-WT з ВФ Хаара-1, забезпечила схожий рівень точності та F1-score (0,9997 і 0,9976 відповідно) при значно менших обчислювальних витратах – 41,46 с. Це демонструє, що вейвлетна передобробка дозволяє моделі зберегти високу точність та чутливість до рідкісних патологій при оптимальному балансі між продуктивністю та часом навчання.

Динаміка навчання та стабільність моделей оцінювалися через валідаційне тестування на кожній епосі. Результати підтвердили стійкість процесу навчання та здатність моделей виявляти екстрасистоли без значних коливань у точності. Таким чином, поєднання KAN-шару з вейвлет-обробкою забезпечує баланс між точністю класифікації, чутливістю до рідкісних патологічних сегментів та обчислювальною ефективністю.

З рис. 3.5 видно, що MLP швидко досягає високої точності, проте на пізніх епохах спостерігаються коливання, що свідчить про певну нестабільність у розпізнаванні сегментів класу V. Модифіковані моделі демонструють більш плавне і стабільне зростання точності, утримуючи пікові значення на рівні 0,9997. Це

вказує на те, що KAN-шар з ВП сприяють підвищенню стабільності навчання і забезпечують надійне виявлення рідкісних патологічних сегментів, при цьому не знижуючи точність класифікації основного класу N.




Рисунок 3.5 – Точність валідації (Validation Accuracy) для обраних моделей

Матриці плутанини є важливим інструментом для оцінки якості класифікації моделей машинного навчання. Вони дозволяють наочно представити кількість правильних і неправильних передбачень для кожного класу, що допомагає оцінити здатність моделі диференціювати між нормальними та патологічними сегментами сигналу. По осі X відкладаються передбачені класи, по осі Y – фактичні, що забезпечує наочне відображення роботи моделі на тестових даних.

Для моделі MLP-KAN з 8 RBF була побудована матриця плутанини (рис. 3.6). Вона демонструє кількість сегментів кожного класу, правильно та неправильно класифікованих моделлю. У матриці (рис. 3.6) видно, що для класу N (нормальний ритм) модель правильно класифікувала 2743 сегменти, при цьому лише 10 сегментів було віднесено до класу V (екстрасистоли). Для класу V правильно класифіковано 189 сегментів, а 16 сегментів було помилково віднесено до класу N. Такі значення в матриці показують, що MLP-KAN з 8 RBF суттєво покращує точність розпізнавання рідкісного класу V порівняно з базовим MLP, при цьому

точність для класу N залишається високою. Ці результати підкреслюють ефективність KAN-шару у визначенні локальних особливостей сигналу та підвищенні чутливості моделі до рідкісних патологій, що є критично важливим для медичних застосувань.




Рисунок 3.6 – Матриця помилок (Confusion Matrix): MLP-KAN-RBF8

Аналогічно, для моделі MLP-KAN-WT з ВП Haar-1 була побудована матриця плутанини (рис. 3.7). Вона дозволяє оцінити здатність моделі виділяти локальні особливості сигналу та класифікувати рідкісні сегменти класу V.




Рисунок 3.7 – Матриця помилок (Confusion Matrix): MLP -KAN-WT-haar_1

З матриці видно, що для класу N модель правильно класифікувала 2754 сегменти, при цьому жоден сегмент не було помилково віднесено до класу V. Для класу V правильно класифіковано 204 сегменти, а 7 сегментів помилково віднесено до класу N. Такі результати демонструють високу чутливість моделі до рідкісних патологічних сегментів при одночасному збереженні стабільності класифікації основного класу.

Цей приклад підтверджує ефективність використання ВП у поєднанні з KAN-шаром для підвищення точності та стабільності моделі при виявленні як поширених, так і рідкісних класів сигналу.

Проведені експерименти показали, що інтеграція KAN-шару у базову MLP-архітектуру забезпечує помітне підвищення точності класифікації сегментів ЕКГ. Для базового MLP точність (ассигасу) становила 0,9993, тоді як модифікована модель MLP-KAN-RBF8 досягла 0,9997, а F1-score для рідкісного класу V зросло з 0,9951 до 0,9976.

Модель із вейвлетною передобробкою Haar – MLP-KAN-WT з вейвлетом Хаара рівню 1 – продемонструвала аналогічні результати: точність 0,9997 і F1-score для класу V 0,9976 при відносно менших обчислювальних витратах. Це свідчить, що обробка з ВП дозволяє зберегти високу ефективність моделі, одночасно знижуючи час навчання.

MLP-KAN показала вищу стабільність навчання та кращу стійкість до варіацій сегментів. Валідаційна точність модифікованих моделей утримувалася на рівні 0,9997, тоді як базовий MLP демонстрував більші коливання на пізніх епохах. Збільшення числа RBF із 4 до 8 дозволило покращити точність класифікації сегментів класу V приблизно на 0,2–0,3 %, хоча час навчання зріс на 32–35 с. Використання вейвлетної передобробки забезпечує оптимальний баланс між високою точністю та економією обчислювальних ресурсів.

Аналіз матриць плутанини підтвердив, що MLP-KAN суттєво зменшує кількість помилкових класифікацій сегментів класу V порівняно з базовим MLP, водночас зберігаючи високу точність для класу N. Сумарні результати

демонструють стабільність моделей та ефективне захоплення локальних нелінійностей сигналу, що підвищує здатність до узагальнення на тестових даних.

Отримані дані підтверджують доцільність застосування KAN-шару у задачах автоматизованої класифікації ЕКГ, забезпечуючи баланс між точністю, F1-score та обчислювальними витратами, що робить цей підхід перспективним для практичних медичних систем. Використання вейвлетної передобробки, як у моделі MLP-KAN-WT з вейвлетом Хаара, рівень 1, дозволяє досягти високої ефективності при оптимальному рівні обчислювальної складності.

Таким чином, застосування вейвлетної передобробки у поєднанні з KAN-шаром забезпечує найкращий компроміс між точністю, чутливістю до рідкісних сегментів і обчислювальними витратами, роблячи цей підхід особливо перспективним для практичної автоматизованої класифікації ЕКГ.

У комплексі проведені експерименти дають можливість оцінити можливості та обмеження розглянутих моделей нейронних мереж, демонструючи вплив архітектурних рішень на їхню функціональність, стійкість і обчислювальну продуктивність. Таке багатовимірне оцінювання забезпечує обґрунтовану основу для вибору оптимальної архітектури моделей нейронних мереж залежно від вимог прикладної задачі.

3.4 Висновки до третього розділу

У розділі проведено прикладні дослідження розроблених методів та моделей на прикладі аналізу сигналів ЕКГ, що дозволило підтвердити їх ефективність у завданнях автоматизованої діагностики. Експериментально доведено працездатність комбінованого критерію вибору рівня вейвлет-розкладу C_i , що базується на співвідношенні енергії та ентропії сигналу, де встановлено, що для більшості типів материнських вейвлетів максимальна інформативність при виявленні комплексів QRS зосереджена на рівнях декомпозиції d_4 – d_5 . Це відповідає частотному діапазону 5–20 Гц і дозволяє автоматизувати процес фільтрації завад без втрати діагностично значущих морфологічних ознак,

забезпечуючи стабільність результатів незалежно від варіативності серцевого ритму пацієнта та зменшуючи залежність точності від ручного втручання.

Удосконалено прикладний метод ідентифікації ознак ЕКГ на базі пошуку екстремумів нестационарних сигналів, де використання вейвлет-функції Хаара у поєднанні з адаптивним налаштуванням довжини носія дозволило досягти високої точності визначення координат R-піків з похибкою не більше 1,6% та R-R інтервалів з похибкою до 2,6%. Завдяки відмові від багатоетапної обробки гіперболічними вейвлетами на користь однорівневої оптимізації, швидкодію процедури ідентифікації було підвищено на 11% порівняно з базовими методами при збереженні стійкості до шумів, що дозволяє рекомендувати метод для використання в системах телемедицини при високому рівні завад у даних.

На основі архітектури Колмогорова-Арнольда розроблено та досліджено модифіковану нейронну мережу MLP-KAN-WT, де впровадження вейвлет-шарів замість стандартних активаційних функцій дозволило моделі одночасно виділяти часові та частотні аномалії сигналу. Результати порівняльного аналізу показали, що модель на основі вейвлета Хаара забезпечує найвищий баланс між точністю на рівні 0,9997 та обчислювальною складністю, скорочуючи час навчання на 32% порівняно з KAN-моделями на базі RBF-функцій. Використання KAN-шарів суттєво покращує виявлення рідкісних патологій, таких як шлуночкові екстрасистоли, що підтверджується значенням F1-score на рівні 0,9976 та аналізом матриць плутанини, доводячи доцільність інтеграції вейвлет-оптимізації в автоматизовані системи діагностики для підвищення достовірності класифікації в умовах обмежених навчальних вибірок.

4 ДОСЛІДЖЕННЯ МЕТОДІВ З ВЕЙВЛЕТ-ПЕРЕТВОРЕННЯМ ДЛЯ ВІДБОРУ КОМПОНЕНТІВ ЕЛЕКТРОНІКИ І ОЦІНКИ ДІСПАРАНТНОСТІ ЗОБРАЖЕНЬ

4.1 Модель передбачення параметрів електронних компонентів

Вироби сучасної електроніки характеризуються багатофункціональністю, тому їх якість часто потребує оцінки багатовимірних масивів корельованих між собою параметрів.

– при визначенні технічного стану об'єктів електроніки вирішуються такі важливі задачі, як:

– контроль функціонування шляхом фіксації електрофізичних параметрів (характеристик) при динамічних впливах на ЕК, ідентифікації його параметрів, формування полів даних;

– оцінка параметрів надійності виробів електроніки і апаратури на їх основі.

У загальному випадку для таких задач використовують системи автоматизованого визначення параметрів (передбачення). Такі системи складаються з об'єкта (наприклад, певного компонента електроніки), сукупності засобів, за допомогою яких здійснюється оцінка стану об'єкту (діагностування) і дослідника (рис. 4.1) [96].




Рисунок 4.1 – Схема тестової системи передбачення

На рис. 4.1 представлено зв'язок між об'єктом, діагностуванням та дослідником. Присутній зворотний зв'язок в діагностуванні говорить про можливість узгодження дій на об'єкт. Наявність подібного зв'язку обумовлює можливість дослідника змінювати характеристики діагностування, приймати рішення в залежності від результатів діагностики. Модель процесу передбачення (прогнозування) представлена на рис. 4.2.



Рисунок 4.2 –Модель процесу передбачення [153]

У роботах [49, 64, 104, 153 - 160] розглянуті системи автоматизованого визначення параметрів, які представлені в таблиці 4.1.

Один з різновидів таких систем заснований на вивченні фізичних причин виникнення відмов, в рамках якого пропонується будувати фізико-математичні моделі відмов, засновані на зміні фізико-хімічних властивостей матеріалів, що

відбуваються з часом при впливі зовнішніх факторів, і вплив цих змін на працездатність пристроїв і в зокрема їх компонентів [156].

Таблиця 4.1 – Системи автоматизованого визначення параметрів

Системи автоматизованого визначення параметрів	
Індивідуальне прогнозування	Прогнозування партії виробів
Системи на основі лінійної нейронної мережі	Системи на основі структурно-класифікаційного прогнозування
Системи на основі бракувальних випробувань	Системи на основі адаптивного алгоритму прогно-зування
Системи на основі прискорених випробувань	Системи на основі адаптивної кластеризації
Системи на основі часових рядів	Системи на основі форсованих випробувань

При такому підході доводиться стикатися з фізичними моделями відмов, вирішувати складні рівняння для кожної з них, при цьому вивчати кореляцію між різними моделями відмов. Процес трудомісткий і отримана фізико-математична модель відмов буде вірна тільки для даного конкретного випадку. З огляду на різноманіття вироблених пристроїв, можна зробити висновок, що такий підхід занадто складний і неекономічний.

Для забезпечення оперативності відбору компонентів потрібно скоротити тривалість виробничих випробувань. Існують два основних напрямки, що дозволяють це зробити - форсовані випробування і автоматизоване прогнозування зміни параметрів виробів в часі для оцінки моменту настання відмови (табл.4.1).

4.2 Оцінка показників надійності електронних компонентів на основі адаптивної кластеризації

На основі удосконаленого методу кластеризації з урахуванням обмежень було проведено відбір компонентів електроніки по параметрах надійності. Така

процедура дозволяє обґрунтувати вибір компонентів для апаратури відповідального призначення.

Найчастіше оцінюють надійність ЕК по моделі експоненціального розподілу з одним параметром – інтенсивністю відмов λ . При цьому припущення про сталість у часі підвищує похибку прогнозів надійності порівняно з розподілами з двома параметрами. Тому за допомогою експоненціального розподілу рекомендується проводити відносну оцінку надійності на етапі ескізного проєктування, коли необхідно оцінити надійність різних варіантів, і на підставі аналізу вибрати елементну базу [104]. Цей підхід застосовують також, коли не суттєві явища старіння. Для цього розподілу, якщо відомо, що ЕК справний, то його майбутній стан не залежить від минулого.

Перший етап відбору передбачає визначення інтенсивності відмов λ для експоненціального розподілу для досліджуваної партії резисторів.

Для відбору надійних електронних компонентів потрібно обрати модель оцінки надійності. Найчастіше оцінюють надійність ЕК і пристроїв на їх основі за допомогою експоненціального розподілу. З допомогою цього розподілу проводять оцінку надійності на етапі ескізного проєктування апаратури, коли необхідно оцінити надійність різних варіантів, і на основі аналізу обрати елементну базу [96].

Визначення інтенсивності відмов λ партії ЕК з урахуванням кластеризації пропонується проводити з виконанням наступних етапів обчислень.

Етап 1. Визначення параметрів ЕК. Для N об'єктів (ЕК) з набором з k параметрів визначається вектор $x_j(t) = (x_j^1(t), x_j^2(t), \dots, x_j^k(t))$. Цей вектор характеризує стан j -го об'єкту в момент часу t . Взаємне розташування множини точок $x_1(t), \dots, x_N(t)$ в k -вимірному просторі параметрів X відповідає реальному групуванню по параметрах в часі для досліджуваних об'єктів.

Етап 2. Для визначення структури вказаних даних проводять кластеризацію з ВФ.

З її допомогою в момент часу t_1 проводиться розділення n точок у просторі X на 2 класи (кластери). Вводиться поняття центру кластеру $a_i(t)$, $i = 1, \dots, r$. В

момент часу t_2 кожна точка $x_j(t_2)$ з допомогою кластеризації відноситься до того чи іншого кластеру, з отриманих на першому кроці t_1 . Далі проводиться перерахунок значень центрів кластерів $a_i(t_2)$, $i = 1, \dots, r$, і підрахунок для точок $x_j(t_2)$ відстаней до нових центрів $i = 1, \dots, r$, $j = 1, \dots, n$. Така процедура виконується для всіх m моментів часу.

Етап 3. Для кожної з двох груп оцінюється інтенсивність відмов λ [11].

Пропонований метод випробування на прикладі партії резисторів [10].

Як прогнозуючі параметри використано рівень шуму та математичне очікування зміни опору в групах. Дані першого контролю (через 24 години роботи у навантаженому режимі) розділені за допомогою кластеризації на 2 кластери, що включили: перший – групи з 1 по 8, другий – 9 групу за рівнем шуму [160].

Розраховані значення інтенсивності відмов склали відповідно $\lambda_1 = 0,35 \times 10^{-5} \text{ год}^{-1}$ – за відсутності кластеризації, $\lambda_2 = 0,19 \times 10^{-5} \text{ год}^{-1}$ – для резисторів першого кластера і $\lambda_3 = 0,19 \times 10^{-4} \text{ год}^{-1}$ для резисторів другого кластера.

Модель на основі інтенсивності відмов λ враховує раптові відмови, які мають випадковий характер, тоді як відмови, що виникають у результаті незворотних фізико-хімічних змін параметрів ЕК, не підпорядковуються експоненціальному закону. Тому використання експоненціальної моделі відмови у прогнозуванні надійності ЕК робить цю оцінку наближеною та може приводити до значних похибок [104].

Для виявлення та видалення ЕК із дійсними та потенційними відмовами з готової партії до постачання споживачеві проводять випробування для видалення бракованих ЕК. У процесі таких випробувань під час аналізу процесів деградації, які призводять до відмов ЕК, виявлено, що вони мають випадкову природу. Так, наприклад, складні ЕК, такі, як інтегральні схеми (ІС), одночасно схильні до впливу багатьох факторів. Ці фактори, некорельовані та корельовані між собою, формують загальний процес деградації ІС. Параметри деградаційних процесів, які можуть спричинити відмову ІС, мають різну фізичну природу: пластичні та пружні деформації, втомне механічне руйнування, електролітична корозія тощо. [104, 162].

Порівняльний аналіз імовірнісно-фізичних розподілів, які враховують фізичні процеси, що призводять до відмови, викладено в [98]. Виходячи з цього аналізу, оцінки надійності ІС за результатами прискорених випробувань мають похибку не більше 10 %, якщо як модель відмов використовується дифузійний DN -розподіл з двома параметрами, що відповідає немонотонному марківському процесу [98, 99].

Тривалість прискорених випробувань значно менша від реальної довговічності ЕК. У зв'язку з високою надійністю ЕК ці випробування проводяться до відмови малої частини вибірки і тому супроводжуються значною похибкою. Джерелом похибки є висока дисперсія оцінки параметрів DN – розподілу, яка ще й збільшується за рахунок наявності шуму в даних про надійність (об'єктивних та суб'єктивних помилок під час їх збору та обліку).

Під час таких досліджень, наприклад, у процесі прискорених випробувань ІС на довговічність виявлено, що їхня інтенсивність відмов має бімодальний характер (перший пік характеризує відмови аномальних ІС, а другий – відмови основної частини вибірки); при цьому середній час безвідмовної роботи для цих груп ІС може відрізнятись на чотири порядки.

Тому для підвищення стійкості до завад і зниження похибки оцінки параметрів надійності під час відбору потенційно ненадійних ЕК потрібно підвищити перешкодостійкість і знизити похибку поділу партії ЕК дві групи.

Тому було на основі удосконаленого методу кластеризації проведено також визначення параметрів DN -розподілу

Перший і другий етапи такі ж, як і при визначенні λ . На етапі 3 для кожної з двох груп оцінюються параметри DN -розподілу [98]

$$F(t) = DN(t; \mu, \nu) = \Phi\left(\frac{t - \mu}{\nu\sqrt{\mu t}}\right) + \exp(2\nu^{-2})\Phi\left(-\frac{t + \mu}{\nu\sqrt{\mu t}}\right) \quad (4.1)$$

де μ – параметр масштабу, який співпадає з математичним очікуванням випадкової величини t ;

ν – параметр форми, який дорівнює коефіцієнту варіації розподілу величини t .

Цей метод також випробуваний на прикладі партії резисторів, призначених для апаратури відповідального призначення [104].

Далі за методикою [98, 104] було обчислено коефіцієнти варіації діагностичного параметра – математичного очікування зміни опору для першого, другого кластера та всієї партії резисторів без відбраковування за формулою:

$$\nu_j = \frac{\sqrt{n}}{\sum_{i=1}^n \Delta x_{ji}} \sqrt{\sum_{i=1}^n \left(\Delta x_{ji} - \frac{1}{n} \sum_{i=1}^n \Delta x_{ji} \right)^2} \quad (4.2)$$

де $\Delta x_{ji} = x_{ji+1} - x_{ji}$, індекс j – відповідає номеру кластера $j = 1, 2$ чи $j = 3$ для всієї партії резисторів; індекс i відповідає моменту часу t_i ($i = 1, 2, \dots, n$).

Інтервали між вимірюваннями $\Delta t = t_{i+1} - t_i$ прийняті нерівномірними (математичне очікування змін опорів визначалось через 24, 168, 1000, 5000, 10000 годин після початку вимірювань) [98]. Далі, згідно з методикою [156], з урахуванням того, що значення ν_j склали відповідно $\nu_1 = 1,38$, $\nu_2 = 1,43$ та $\nu_3 = 1,55$, оцінюються параметри масштабу шляхом рішення рівняння:

$$F_j(t_i, \mu_{ji}, \nu_j) = \tilde{F}_j(t_i) \quad (4.3)$$

де $\tilde{F}_j(t_i) = i/N$, ($i = 1, \dots, r$);

i – номер відмови у відповідному кластері ($i = 1, \dots, r$);

t_i – час роботи до відмови i -го резистора.

Оскільки точна інформація про момент відмови відсутня [98], при розрахунках моментом відмови вважалась права границя часового інтервалу, на протязі якого він відмовив.

В результаті розраховані з допомогою DN -розподілу значення середнього часу роботи до відмови склали відповідно 4,8 років за відсутності розділу на кластери, 7,5 років – для резисторів першого кластеру і порядку 2 років резисторів другого кластеру.

В результаті удосконалення вказаного підходу на базі кластеризації з урахуванням обмежень швидкодія процедур під час дослідження параметрів резисторів була підвищена в середньому на 7 – 9 %.

Таким чином, можна зробити висновок, що з використанням методу кластеризації з обмеженнями удосконалено методи визначення інтенсивності відмов та параметрів DN-розподілу для оцінки надійності під час випробувань ЕК та процедура реалізації цього методу. Метод випробуваний на прикладі відбракування резисторів за рівнем шуму та стабільності. Підвищення швидкодії за збереження достатньої стійкості до перешкод і достовірності процедури відбраковування досягається за рахунок застосування в цьому методі кластеризації з ВФ з урахуванням обмежень. Цей результат дозволяє рекомендувати розроблений метод при відборі ЕК, призначених для апаратури відповідального призначення.

4.3 Інформаційна технологія оцінки параметрів електронних компонентів

На основі удосконаленого методу кластеризації з обмеженнями була також удосконалена інформаційна технологія (ІТ) оцінки параметрів електронних компонентів.

Цей підхід пропонується для оцінки якості компонентів електроніки, якщо необхідно вибрати такі вироби для подальшого збирання для апаратури відповідального призначення.

Передбачається, що в N виробів k параметрів і $x_j(t_1), \dots, x_j(t_n)$ є відомою частиною траєкторії зміни в часі параметра виробу j . Вони визначаються під час прискорених виробничих випробуваннях. Для виявлення груп (кластерів) параметрів використовується метод кластеризації з ВФ з урахуванням обмежень й у час t_1 поділяються n виробів на r кластерів. Число кластерів обираємо одним із відомих методів [162]. Основні етапи ІТ наведені нижче.

- 1) визначають інформативні параметри і проводять їх вимірювання;

2) для t_1 розділюють n точок на r кластерів шляхом кластеризації з ВФ з урахуванням обмежень. Визначають координати їхніх центрів $a_i(t)$, $i = 1, \dots, r$ [9,10]. Обчислюються відстані $R_{ij}(t)$, $i = 1, \dots, r$, $j = 1, \dots, n$ до центрів;

3) для моменту часу t_1 розраховується матриця ймовірностей $p_{ji}^{(1)} = p_{ji}(t_1)$ [64, 160]:

$$p_{ji}^{(1)} = \frac{\alpha_j^{(1)}}{R_{ji}^{(1)}} \quad (4.4)$$

де множник $\alpha_j^{(1)}$ визначають як:

$$\alpha_j^{(1)} = \left(\sum_{l=1}^r \frac{1}{R_{jl}^{(1)}} \right)^{-1} \quad (4.5)$$

4) в момент t_2 кожен $x_j(t_2)$ з допомогою класифікації з ВП [3] відноситься до одного з кластерів, що отримані на першому кроці. Далі перераховуються значення центрів $a_i(t_2)$, $i = 1, \dots, r$, і підраховуються для $x_j(t_2)$ відстані $R(x_j(t_2), a_i(t_2))$ до нових центрів $i = 1, \dots, r$, $j = 1, \dots, n$. Така процедура виконується для всіх m моментів часу.

5) на s -му кроці модифікується матриця перехідних ймовірностей (1) [10]:

– якщо параметр співпадає з центром кластера, ймовірність лишитися в ньому дорівнює 1, а перейти в інший кластер – дорівнює 0;

– коли j -ий параметр не співпадає з центром кластера, ймовірності перераховуються:

$$p_{ji}^{(s)} = \gamma \left[p_{ji}^{(s-1)} + \left(\frac{1 + \text{sign}(\Delta R_{ji}^{(s)})}{2} - p_{ji}^{(s-1)} \text{sign}(\Delta R_{ji}^{(s)}) \right) \Delta \hat{R}_{ji}^{(s)} \right] \quad (4.6)$$

$$\text{де: } \text{sign}(z) = \begin{cases} 1, \text{ якщо } z \geq 0, \\ -1, \text{ якщо } z < 0 \end{cases}$$

$$\Delta R_{ji}^{(s)} = R_{ji}^{(s-1)} - R_{ji}^{(s)} \quad (4.7)$$

$$\Delta \hat{R}_{ji}^{(s)} = \frac{R_{ji}^{(s-1)} - R_{ji}^{(s)}}{R_{ji}^{(s-1)} + R_{ji}^{(s)}} \quad (4.8)$$

де γ – нормуючий множник (визначається з урахуванням $\sum_{i=1}^r p_{ji}^s = 1$:

$$\gamma = \frac{1}{1 + \left(\frac{1 + \text{sign}(\Delta R_{ji}^{(s)})}{2} - p_{ji}^{(s-1)} \text{sign}(\Delta R_{ji}^{(s)}) \right) \Delta \hat{R}_{ji}^{(s)}} \quad (4.9)$$

6) за значеннями матриці перехідних ймовірностей прогнозують належність параметра виробу до класу з використанням відомої схеми Байеса, коли виріб відносять до класу з $p_{ji0} = \max_{i=1, \dots, r} p_{ji}$ [160].

7) вироби з класу з потрібною якістю надходять до збирання вузлів апаратури відповідального призначення.

Проведені дослідження удосконаленої інформаційної технології оцінки якості компонентів електроніки перед збиранням.

В результаті використання цієї ІТ достовірність прогнозу становила 0,88. Перешкодостійкість була підвищена в середньому до 20 % порівняно з наявними системами, що відповідає вимогам практики.

Дослідження показали, що достовірність діагностування виробів у діапазоні відношення сигнал/перешкода 10...20 (за потужністю) підвищилася до 1,2 рази порівняно з наявними ІТ. У діапазоні відносин сигнал/перешкода 7..10 (за потужністю) системи діагностування на основі наявних ІТ не працездатні, а достовірність діагностування під час застосування розробленої ІТ – 0,88. В результаті вдосконалення зазначеного підходу з урахуванням запропонованого методу кластеризації з ВФ з обмеженнями швидкодії процедур було підвищено загалом на 7 – 9 %. Такі результати можуть дозволити застосування розробленої ІТ у додатках, що відповідають зазначеним умовам.

4.4 Оцінка діспарантності стерео-зображень на основі пошуку екстремумів з вейвлет-функцією Хаара

Важливим джерелом інформації про окіл, наприклад, для безпілотних транспортних засобів (БТС) є відеокамери [62]. Системи сучасного машинного зору дозволяють не тільки отримати відеоінформацію, а й дозволяє виділити суттєві, інформативні ознаки об'єктів та процесів, розпізнати та оцінити їх положення та стан, вибрати раціональні траєкторії руху БТС, сформувати за потреби відповідні керуючі впливи. Особливістю таких систем є не тільки ідентифікація та розпізнавання об'єкта та його положення, але й облік глибини сцени та об'єкта, тобто перетворення двовимірного зображення на тривимірне, де інформація про об'єкт представляється не в одиницях яскравості, а параметрами піксель/дальність.

Аналіз методів, які призначені для отримання зображення та формування параметра глибини, показав, що сенсори та процесори зображень високої вартості часто недоступні для широкого споживчого ринку. Тому пошук рішень отримання 3D-інформації про глибину розташування об'єктів на зображенні, для яких характерні невисока вартість, низьке енергоспоживання та прийнятна швидкодія, є важливим та актуальним науково-практичним завданням для широкого кола БТС.

Найменш енерговитратним для отримання інформації про глибину розташування об'єктів на зображенні є підхід на основі стереоскопічного зору, що передбачає використання двох відеокамер з відомими оптичними характеристиками та параметрами їх розміщення одна щодо одної [65, 68, 69]. Ці відеокамери спрямовані в один бік, при цьому відстань між оптичними центрами камер набагато менше, ніж відстань до об'єктів, що спостерігаються. Для отримання інформації про глибину розташування об'єктів використовують порівняння та аналіз цієї пари зображень. Одним з відомих алгоритмів для побудови карти глибин StereoBM [72 - 74, 95, 13]. Він передбачає виконання наступних етапів обробки даних.

Етап 1. Завантаження зображень з обох відеокамер.

Етап 2. Перетворення зображень з кольорових на зображення у шкалі сірого (grayscale).

Етап 3. Створення об'єкта StereoBM із заданими параметрами.

Етап 4. Обчислення карти диспаратності (величини відмінності у локалізації елементів зображень, отриманих з правої та лівої камери). Традиційно це виконується шляхом зіставлення пікселів на лівому та правому зображеннях для обчислення карти диспаратності.

В алгоритмі StereoBM перші три етапи стандартні, тому не дають можливості підвищення швидкодії виконання. Однак у цьому аспекті є перспективний етап 4, спрямований на обчислення карти диспаратності. Він передбачає описані нижче етапи обчислень.

Етап 4.1. Виділення блоків. На зображенні виділяються блоки фіксованого розміру.

Етап 4.2. Порівняння блоків. Для кожного блоку лівого зображення алгоритм намагається знайти відповідний блок на правому зображенні.

Етап 4.3. Обчислення диспаратності. Для кожного блоку лівого зображення обчислюється зміщення (диспаратність), яке вказує, на скільки пікселів зміщене відповідне праве зображення. Ця диспаратність зберігається у карті диспаратності.

Етап 4.4. Нормалізація карти диспаратності. Отримана карта диспаратності може містити значення, які не є глибиною. Тому нормалізується так, щоб значення були в межах інтенсивності $[0, 255]$ для зручного відображення.

Алгоритм порівняння блоків (етап 4.2) шукає за зразком на лівому кадрі відповідний блок на правому кадрі. Для цього він переміщується по горизонтальній осі правого зображення та порівнюється з відповідним блоком на лівому зображенні. Алгоритми виявлення відповідності блоків можуть бути реалізовані на основі оцінки різних властивостей зображень різними методами [72 - 74].

Серед них – методи глибокого навчання згорткових нейронних мереж, які можуть навчатися на великих наборах даних та в складних умовах освітлення, методи, які передбачають спільне використання сенсорів на різних фізичних

принципах, наприклад, таких як лідари або інфрачервоні камери для покращення точності карти диспаратності та інші.

Зрозуміло, що такі методи, засновані на нейромережевих обчисленнях потребують високих обчислювальних потужностей та енергоспоживання, що також критично для БТС, а методи, що передбачають спільне використання сенсорів різної фізичної природи, вимагають збільшення енергоспоживання, оскільки інфрачервоний датчик або лідар різко підвищує споживання енергії [72 - 74].

Для зниження впливу цих недоліків при побудові карти глибин стереозображення запропоновано наближений підхід до оцінки інформації про глибину розташування об'єктів, який враховують результати виділення ділянок схожої інтенсивності або контурів об'єктів на зображеннях, або точок найбільшої кривизни контурного опису.

Основні етапи обраного підходу відповідають відомому підходу на базі контурної сегментації з ВФ. На рис. 1.5 проілюстровані основні етапи оцінки глибини шляхом виділення фрагментів подібної інтенсивності на тестовому зображенні (рис. 1.5, а). Тобто в роботі запропоновано використовувати методику оцінки глибини шляхом виділення контурів об'єктів з регульованою деталізацією у просторі ВП (рис. 1.4):

- рядки зображення лівого кадру (рис. 2, б) та правого кадру піддаються згортці з вейвлетом – функціями заданого масштабу та виділяються області контурів (рис. 1.4);

- знаходиться відстань між контурами об'єктів та відповідне йому значення диспаратету;

- обробка при необхідності здійснюється за рядками та стовпцями. Результати поєднуються за схемою логічного додавання АБО.

Пошук максимуму інтенсивностей на одному з зображень (наприклад, лівому кадру (рис. 4.3, а)) дозволяє визначити координату екстремуму, значення інтенсивності, відповідне цій координаті рядка і значення інтенсивностей сусідніх пікселів. Це дозволяє сформувати маску (шаблон), що показує, як розподілені

інтенсивності біля екстремуму в даному рядку зображення. Далі пропонується використовувати відому властивість подібності розподілу інтенсивностей на обох (лівому та правому) кадрах.

На підставі цих даних у роботі запропоновано проводити пошук екстремуму на відповідному рядку правого кадру шляхом пошуку мінімуму помилки суміщення інтенсивностей рядків правого кадру та маски інтенсивностей. Таким чином проводиться пошук та оцінка подібності форми огинаючої інтенсивності пікселів на обох кадрах (рис.4.3).




Рисунок 4.3 – Оцінка подібності інтенсивностей пікселів стереопари: а) – лівий кадр тестового зображення; б) – приклад подібності форми огинаючої яскравості пікселів відповідних рядків

Завдяки такому підходу знижується помилка при пошуку відповідного блоку з урахуванням близькості значень інтенсивностей та форми обгинальної на обох кадрах (рис.4.3,б). Тобто з використанням вейвлет-перетворення при пошуку з маскою вдається підвищити стійкість до перешкод і знизити похибку пошуку розташування характерного фрагмента на рядку інтенсивностей. Для ілюстрації на рис. 4.3,б показані обгинальні інтенсивності пікселів в одному рядку для лівого та правого знімка тестового зображення блакитним та коричневим кольором відповідно (рис. 4.3, б).

У роботі пропонується покращити швидкодію за рахунок вибору довжини носія ПФ Хаара в області пошуку. Для цього пропонується після локалізації області мінімуму функціоналу на етапі пошуку з ВФ Хаара $\Psi_1(i)$ та звуження області пошуку шляхом визначення обмежень $g(c) \leq 0$ обґрунтовано вибрати довжину носія ВФ Хаара з урахуванням особливостей екстремумів при оцінці диспаритету.

Метод з ітеративною оцінкою обмежень з ВФ Хаара реалізується у наведеній нижче послідовності.

Крок 1. Виконуються кроки 1-5 базового методу оптимізації з ВП з урахуванням ітераційної схеми [75]. Пошук продовжується до зміни знаку обробки $WT_k(Q(x[n], c[n-1]))$ (рівняння (4.3)), при оцінці напрямку зсуву до екстремуму.

Крок 2. Визначаються обмеження для наступного старту $(g_1(c[n]))$ та $(g_2(c[n]))$:

$$g_1(c[n]) \geq c^*[n-1]; g_2(c[n]) \geq c^*[n] \quad (4.10)$$

де $c^*[n-1]$ – координата екстремуму на кроці $[n-1]$;

$c^*[n]$ – координата екстремуму на кроці n , де знак змінився.

Крок 3. Визначається довжина носія ВФ Хаара s_k для наступного старту шляхом вибору з ряду $s_k = \{2, 4, 6\}$ згідно з умовою $s_k \leq \frac{|g_2(c[n]) - g_1(c[n])|}{a}$.

Крок 4. Визначається номер ітерації $n = n + 1$ і здійснюється перехід до кроку 2 базового методу оптимізації з ВП. Пошук екстремуму продовжується до виконання критерію зупину.

Мінімум функції помилки суміщення зображень при такому скануванні знаходиться шляхом оптимізації з ВФ Хаара. В результаті досліджень довжина носія ВФ була обрана 17, крок дискретизації ВФ – 1, крок при реалізації ітеративного пошуку з ВФ Хаара $\gamma_1 = 0,1$. Мінімум помилки суміщення зображень був знайдений за 3 ітерації (при старті пошуку в $[1; 1]$).

Таким чином, можна зробити висновок, що в процесі розробки наближених методів оцінки глибини тривимірного комп'ютерного зору БТС з урахуванням удосконаленого методу оптимізації з урахуванням вейвлет-перетворення, обрані параметри методу і значення діапазону змін довжини носія ВФ Хаара після визначення обмежень.

Показані можливі рішення для отримання наближеної карти глибини за рахунок спрощення розрахунку значень диспаритету, який традиційно використовується для формування карти глибини, в просторі інтенсивностей з допомогою ВП.

Перевагою удосконаленого методу оптимізації перед існуючими алгоритмами на основі ВП є збільшення швидкодії за рахунок раціонального вибору довжини носія ВФ Хаара в області пошуку екстремуму, що дозволяє рекомендувати пропонований метод для безпілотних транспортних засобів, що працюють в умовах обмеженості обчислювальних та енергетичних ресурсів.

Метод оптимізації апробовано при побудові карти глибин тестового зображення з бази зображень.


Довжина носія вейвлет-функції при пошуку мінімуму була обрана 17, крок дискретизації ВФ - 1, крок при реалізації ітеративного пошуку з ВФ Хаара. Мінімум помилки суміщення зображень було знайдено за 3 ітерації (при старті пошуку в [1; 1]).

Крім того, результати моделювання показали, що модифікація відомого методу StereoVM шляхом використання при обчисленні диспаритету вейвлет-перетворення для знаходження екстремуму дозволяє не тільки підвищити стійкість до перешкод і знизити похибку пошуку розташування характерного фрагмента на рядку інтенсивностей, а й знизити енерговитрати (табл.4.2).

Розроблений наближений методі оцінки глибини для тривимірного комп'ютерного зору БТС на основі розробленого методу оптимізації на основі вейвлет-перетворення. Метод може бути використаний для оцінки інформативних ознак для зіставлення фрагментів та/або оптимізації витрат при аналізі зображень, для уточнення невідповідності та ін. Показані можливі рішення для отримання

наближеної карти глибини за рахунок спрощення розрахунку значень диспаритету, який традиційно використовується для формування карти глибини, в просторі інтенсивностей вейвлет-перетворення.

Таблиця 4.2 – Результати моделювання

Алгоритм	StereoBM	Розроблений
Струм споживання, мА	950	420
Отримана карта глибин		

Перевагою розробленого методу оптимізації перед існуючими алгоритмами у просторі ВП є збільшення швидкодії за рахунок раціонального вибору довжини носія ВФ Хаара в області пошуку екстремуму, що дозволило рекомендувати пропонування метод для безпілотних транспортних засобів, що працюють в умовах обмеженості обчислювальних та енергетичних ресурсів.

4.5 Висновки до четвертого розділу

У розділі проведено практичне впровадження та оцінку ефективності розроблених методів обробки гетерогенних даних у сферах контролю якості електронних компонентів (ЕК) та комп'ютерного зору безпілотних транспортних систем (БТС). На основі удосконаленого методу кластеризації з вейвлет-функціями (ВФ) та врахуванням обмежень розроблено методику відбору ЕК за параметрами надійності, що дозволяє підвищити достовірність оцінки інтенсивності відмов та параметрів дифузійного немонотонного ($\$DN\$$) розподілу. Експериментальна перевірка на партії резисторів показала, що розділення вибірки на кластери за

рівнем шуму та стабільністю опору забезпечує більш точне прогнозування середнього часу безвідмовної роботи, який для надійного кластера склав 7,5 років проти 4,8 років для всієї партії без розділення, при цьому швидкодія процедур ідентифікації параметрів зросла на 7–9%.

Удосконалено інформаційну технологію прогнозування значень параметрів надійності на основі ітераційної кластеризації та матриць перехідних ймовірностей, що дозволило автоматизувати відбір компонентів для апаратури відповідального призначення. Використання вейвлет-класифікації на кожному кроці прогнозування забезпечило достовірність результатів на рівні 0,88 навіть у складних умовах завад, де відношення сигнал/перешкода за потужністю становить 7...10. Встановлено, що перешкодостійкість запропонованого підходу в середньому на 20% вища порівняно з існуючими системами індивідуального прогнозування, а достовірність діагностування у робочому діапазоні інтенсивностей завад підвищилася до 1,2 раза.

Розроблено наближений метод оцінки диспаратності стереозображень для побудови карт глибини в системах тривимірного зору БТС, який базується на пошуку екстремумів функції помилки суміщення за допомогою ВФ Хаара. Наукова новизна підходу полягає у раціональному виборі довжини носія вейвлета та ітеративному звуженні області пошуку, що дозволило суттєво знизити обчислювальну складність порівняно з традиційним алгоритмом StereoBM. Результати моделювання підтвердили, що запропонований метод забезпечує стабільну локалізацію контурів об'єктів при значному скороченні енерговитрат (струм споживання знизився з 950 мА до 420 мА), що є критично важливим для автономних систем з обмеженими ресурсами. Це дозволяє рекомендувати розроблені методи для інтеграції в сучасні комплекси автоматизованого контролю та інтелектуального керування транспортними засобами.

ЗАГАЛЬНІ ВИСНОВКИ

Сукупність отриманих в дисертації результатів вирішує актуальну науково-технічну задачу підвищення швидкодії та/або зниження ресурсоемності процедур обробки та аналізу малих серій гетерогенних даних за рахунок удосконалення методів на основі вейвлет-перетворення.

Проведений аналіз сучасних методів обробки та аналізу даних та розглянуті обмеження щодо їх вимірювання у дрібносерійному виробництві електроніки та при медичному діагностуванні в телемедицині. Показано, що основою фільтрації, сегментації, ідентифікації, кластеризації для обробки та аналізу малих наборів даних є оптимізація з вейвлет перетворенням. Визначено, що ці методи не володіють для вказаних прикладних задач необхідною швидкістю та/або ресурсоемністю.

Для вирішення поставленої задачі удосконалено концептуальну модель оптимізації з вейвлет перетворенням для обробки та аналізу сигналів з багатьма екстремумами, особливістю якої є проведення запропонованого в роботі кількісного ентропійно-інформаційного аналізу для обґрунтованого вибору виду та масштабу вейвлет перетворення та його масштабу. Ця модель є основою для удосконалення методів оптимізації, кластеризації та класифікації на основі вейвлет аналізу гетерогенних даних.

Сформульовано мету та завдання дисертаційного дослідження.

Удосконалені методи оптимізації, кластеризації та нейромережевої класифікації з вейвлет перетворенням, коли цільова функція мультимодальна чи має негладку, зашумлену поверхню. Відомі методи з вейвлет перетворенням для оцінки напрямку руху до екстремуму використовують замість градієнту його наближене значення, обчислене з вейвлет-функціями.

За рахунок скорочення кількості обчислень цільової функції (звернень до «оракулу»), запропоновано удосконалити метод оптимізації на основі відомого методу центрів шляхом скорочення кількості етапів обробки з гіперболічною вейвлет-функцією. При тестуванні цього методу в порівнянні з базовим з функцією

де Іонга 1 при співвідношенні сигнал/шум по амплітуді до 6,4 зростання швидкодії склало від 1,7 до 2,8 разів. Число звернень до оракулу знизилось від 25% до 32% (в залежності від співвідношення сигнал/шум).

На основі удосконалення методу оптимізації з обмеженнями другого роду та методу центрів удосконалено метод кластеризації з вейвлет-перетворенням. При дослідженні його швидкодії для двох груп (кластерів) у двовимірному просторі ознак порівняно з базовим методом виграв в часі склав більше 1,18 разів..

Запропоновано удосконалити кластеризацію з ВП при дрейфі центру кластеру за лінійною траєкторією за рахунок скорочення кількості етапів обробки з гіперболічною вейвлет-функцією. Це дозволяє підвищити швидкодію оцінки від до 1,3 разів у порівнянні з базовим методом при відношенні сигнал/завада від 30. При відношенні сигнал/завада більшому, ніж 10, відносна погрішність удосконаленого методу кластеризації при дрейфі центру кластера по лінійній траєкторії складала менше 7 % і вища в середньому в 1,2 рази, ніж у базовому методі.

Ці результати дозволяють рекомендувати удосконалені методи для кластеризації гетерогенних даних при потребі досягнення швидкодії та скорочення обчислень цільової функції.

Для підвищення точності класифікації в мережі Колмогорова-Арнольда у KAN-шарі використані вейвлет функції Добеші (db4), обрані шляхом ентропійно-інформаційного аналізу удосконаленої концептуальної моделі обробки з вейвлет-перетворенням. Тестування цієї мережі з використанням для фільтрації ВФ Добеші, а для шару активації KAN ВФ Хаара дозволило досягти зростання швидкодії обчислень в 2.5-3 рази при точності (Ассурасу) 98.45%, для класів аритмій: Precision – 0.99, Recall – 0.98.

Розроблені та досліджені методи аналізу гетерогенних даних з ВП для аналізу електрокардіограм.

Удосконалений метод пошуку екстремумів мультіекстремальних нестационарних сигналів з ВП Хаара, з виконанням наступних етапів.

Етап 1. Попередня обробка вихідного сигналу з використанням фільтрації з вейвлет-перетворенням, форма і рівень обробки якого обраний на основі запропонованого ентропійно-інформаційного критерію.

Етап 2. Визначення просторових координат екстремумів (пиків) шляхом пошуку координат екстремумів періодичних сигналів з ВФ Хаара.

Етап 3. Визначення довжини інтервалів між екстремумами при необхідності оцінки статистичних характеристик сигналів та/або екстремумів типу «мінімум», класифікації та прийняття діагностичного рішення.

Проведений аналіз підтвердив ефективність ентропійно-інформаційного критерію для обґрунтованого вибору масштабу вейвлет-розкладання для попередньої обробки при виявленні комплексів QRS в сигналах ЕКГ. Максимальні значення критерію послідовно зустрічаються в межах масштабів d3–d5, що відповідає частотному спектру комплексів QRS. Метод дозволив скоротити об'єм даних для подальшої ідентифікації та досягти зниження рівня шуму сигналу ЕКГ, що дозволило підвищити швидкодію пошуку характерних точок ЕКГ.

Розроблені та досліджені методи аналізу гетерогенних даних з вейвлет-перетворенням для електронних виробів та систем тривимірного комп'ютерного зору.

На основі удосконаленого методу кластеризації з урахуванням обмежень проведено відбір резисторів по параметрах надійності для апаратури відповідального призначення. Розраховані інтенсивності відмов склали $\lambda_1 = 0,35 \times 10^{-5} \text{ год}^{-1}$ – за відсутності кластеризації, $\lambda_2 = 0,19 \times 10^{-5} \text{ год}^{-1}$ – для резисторів першого і $\lambda_3 = 0,19 \times 10^{-4} \text{ год}^{-1}$ для резисторів другого кластера. Розраховані з допомогою *DN*-розподілу значення середнього часу роботи до відмови склали відповідно 4,8 років за відсутності розділу на кластери, 7,5 років – для резисторів першого кластеру і порядку 2 років резисторів другого кластеру. Таким чином, швидкодія процедури кластеризації з урахуванням обмежень під час відбору резисторів була підвищена в середньому на 7 – 9 %.

На основі удосконаленого методу кластеризації з обмеженнями була також удосконалена інформаційна технологія оцінки параметрів електронних

компонентів. В результаті вдосконалення зазначеного підходу з урахуванням запропонованого методу кластеризації з ВФ з обмеженнями швидкодію процедур було підвищено загалом на 7 – 9 %.

На основі запропонованого у другому розділі методу оптимізації проведено оцінку діспарантності стерео-зображень для систем тривимірного комп'ютерного зору. Для побудови карти глибин стереозображення запропоновано проводити наближену оцінку глибини розташування об'єктів, яка враховує результати виділення ділянок схожої інтенсивності або контурів об'єктів на зображеннях, або точок найбільшої кривизни контурного опису. Тобто особливістю оцінки глибини розташування об'єктів є виділення контурів об'єктів з ВФ і обчислення мінімуму функції помилки суміщення зображень розробленим методом оптимізації. Запропонований вище метод можна рекомендувати для систем тривимірного комп'ютерного зору, що працюють в умовах обмеженості обчислювальних та енергетичних ресурсів.

Розроблені в дисертаційній роботі моделі та методи знайшли відображення у навчальному процесі Національного університету «Одеська політехніка».

СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Oppenheim A. V. Discrete-Time Signal Processing / A. V. Oppenheim, R. W. Schaffer. – 3rd ed. – Pearson, 2014. – 1047 p.
2. Lyons R. G. Understanding Digital Signal Processing / R. G. Lyons. – 3rd ed. – Pearson Education, 2010. – 954 p.
3. Bishop C. M. Pattern Recognition and Machine Learning / C. M. Bishop. – Springer, 2006. – 738 p.
4. Proakis J. G. Digital Signal Processing: Principles, Algorithms, and Applications / J. G. Proakis, D. G. Manolakis. – 4th ed. – Prentice Hall, 2007. – 1156 p.
5. Marple S. L. Digital Spectral Analysis / S. L. Marple. – Courier Corporation, 2019. – 480 p.
6. Bendat J. S. Random Data: Analysis and Measurement Procedures / J. S. Bendat, A. G. Piersol. – 4th ed. – Wiley, 2011. – 640 p.
7. Hall D. L. Handbook of Multisensor Data Fusion / D. L. Hall, J. Llinas. – CRC Press, 2001. – 572 p.
8. Lahat D. Multimodal Data Fusion: An Overview of Methods, Challenges, and Prospects / D. Lahat, T. Adali, C. Jutten // Proceedings of the IEEE. – 2015. – Vol. 103, № 9. – P. 1449–1477. – DOI: 10.1109/JPROC.2015.2460697.
9. Jain A. K. Statistical pattern recognition: A review / A. K. Jain, R. P. W. Duin, J. Mao // IEEE Transactions on Pattern Analysis and Machine Intelligence. – 2000. – Vol. 22, № 1. – P. 4–37. – DOI: 10.1109/34.824819.
10. Goldberger A. L. PhysioBank, PhysioToolkit, and PhysioNet: Components of a new research resource for complex physiologic signals / A. L. Goldberger, L. A. Amaral, L. Glass, J. M. Hausdorff // Circulation. – 2000. – Vol. 101, № 23. – P. e215–e220. – DOI: 10.1161/01.cir.101.23.e215.
11. Gonzalez R. C. Digital Image Processing / R. C. Gonzalez, R. E. Woods. – 4th ed. – Pearson, 2018. – 1168 p.
12. Han J. Data Mining: Concepts and Techniques / J. Han, M. Kamber, J. Pei. – 3rd ed. – Elsevier, 2011. – 744 p.

13. Srivastava N. Multimodal Learning with Deep Boltzmann Machines / N. Srivastava, R. R. Salakhutdinov // *Journal of Machine Learning Research*. – 2014. – Vol. 15. – P. 2949–2980.
14. Vidakovic B. Statistical Modeling by Wavelets / B. Vidakovic. – Wiley-Interscience, 1999. – 384 p.
15. Kay S. M. Fundamentals of Statistical Signal Processing, Volume II: Detection Theory / S. M. Kay. – Prentice Hall, 1998. – 595 p.
16. Haykin S. S. Adaptive Filter Theory / S. S. Haykin. – 5th ed. – Pearson Education, 2014. – 912 p.
17. Priestley M. B. Non-stationary Applications and Time Series Analysis / M. B. Priestley. – Academic Press, 1988. – 237 p.
18. Addison P. S. The Illustrated Wavelet Transform Handbook: Introductory Theory and Applications in Science, Engineering, Medicine and Finance / P. S. Addison. – 2nd ed. – CRC Press, 2017. – 472 p.
19. Sörnmo L. Bioelectrical Signal Processing in Cardiac Care / L. Sörnmo, P. Laguna. – Elsevier, 2005. – 688 p.
20. Clifford G. D. Advanced Methods and Tools for ECG Data Analysis / G. D. Clifford, F. Azuaje, P. E. McSharry. – Artech House, 2006. – 384 p.
21. Meng T. A survey on machine learning for data fusion / T. Meng, X. Jing, Z. Yan, W. Pedrycz // *Information Fusion*. – 2020. – Vol. 57. – P. 115–129. – DOI: 10.1016/j.inffus.2019.12.001.
22. Liggins M. E. Handbook of Multisensor Data Fusion: Theory and Practice / M. E. Liggins, D. L. Hall, J. Llinas. – 2nd ed. – CRC Press, 2017. – 872 p.
23. Ahirwal M. K. Fundamentals of Adaptive Filters / M. K. Ahirwal, A. Kumar, G. K. Singh // *Computational Intelligence and Biomedical Signal Processing*. – Springer, Cham, 2021. – P. 15–33. – DOI: 10.1007/978-3-030-67098-6_2.
24. Pratt W. K. Digital Image Processing: PIKS Scientific Inside / W. K. Pratt. – 4th ed. – Wiley-Interscience, 2007. – 807 p.

25. Khaleghi B. Multisensor data fusion: A review of the state-of-the-art / B. Khaleghi, A. Khamis, F. O. Karray, S. N. Razavi // *Information Fusion*. – 2013. – Vol. 14, № 1. – P. 28–44. – DOI: 10.1016/j.inffus.2011.08.001.
26. Aggarwal J. K., Xia L. *Human Activity Recognition from 3D Data: From Acquisition to Recognition*. New York : Springer, 2017. 164 p.
27. Mallat S. G. *A Wavelet Tour of Signal Processing: The Sparse Way* / S. G. Mallat. – 3rd ed. – Academic Press, 2009. – 832 p.
28. Daubechies I. *Ten Lectures on Wavelets* / I. Daubechies. – SIAM, 1992. – 357 p. – DOI: 10.1137/1.9781611970104.
29. Goyal A., Dutta M. K. *Advanced Signal Processing Techniques for Biomedical Applications*. Singapore : Springer, 2024. 280 p.
30. Zhu Y. *Wavelet Analysis and Active Control of Non-Stationary Signals*. CRC Press, 2021. 246 p.
31. Li T., Zhao Z. *Intelligent Signal Processing with Wavelet Transform and Deep Learning*. Elsevier, 2023. 345 p.
32. Starck J.-L., Murtagh F., Fadili J. *Sparse Image and Signal Processing: Wavelets and Related Geometric Multiscale Analysis*. 2nd ed. Cambridge University Press, 2021. 450 p.
33. Vidakovic B. *Engineering Biostatistics: An Introduction using MATLAB and WinBUGS*. Wiley, 2022. 720 p.
34. Tverdohleb J. V. Processing of ECG signals based on wavelet transformation / J. V. Tverdohleb, V. I. Dubrovin // *International journal of advanced science and technology*. – 2011. – Vol. 30. – P. 73–81.
35. Antoshchuk S. G., Tkachenko O. V., Brovko S. M. *Real-time Image Segmentation Methods for Dynamic Environments*. *Computing and Informatics*, 2021. Vol. 40, № 3. P. 612–635.
36. Antoshchuk S., Tkachenko O., Sievierinov O. *Hyperbolic Wavelet Transform for Image Histogram Analysis in Noisy Environments*. *International Journal of Computing*, 2022. Vol. 21, № 4. P. 501–512. DOI: 10.47852/bonviewJCE32022518.

37. Juan Du, and James Okae. "Optimization of Stereo Vision Depth Estimation Using Edge-Based Disparity Map." In 2017 10th International Conference on Electrical and Electronics Engineering (ELECO), pp. 1171-1175.
38. Richter, M., Rosenberger, M., Illmann, R., Buchanan, D., and Notni, G. "Suitability Study for Real-Time Depth Map Generation Using Stereo Matchers in OpenCV and Python." In Engineering for a Changing World: Proceedings: 60th ISC, Ilmenau Scientific Colloquium, Technische Universität Ilmenau, September 04-08, 2023. Presented at the Ilmenau Scientific Colloquium. Technische Universität Ilmenau; 60 (Ilmenau): 2023.09.04-08, ilmedia, Ilmenau. <https://doi.org/10.22032/dbt.58859>.
39. Aslam, Asra, and Ansari, Mohd. Samar. "Depth-Map Generation Using Pixel Matching in Stereoscopic Pair of Images." arXiv:1902.03471v3 [cs.CV] (2019): 15 May 2019.
40. Fahmy, A. A., Ismail, O., and Al-Janabi, A. K. "Stereovision Based Depth Estimation Algorithm in Uncalibrated Rectification." International Journal of Video & Image Processing & Network Security 13.2 (2013).
41. Hamzah, Rostam Affendi, and Ibrahim, Haidi. "Literature Survey on Stereo Vision Disparity Map Algorithms." J. Sensors (2016): 8742920:1-8742920:23. DOI:10.1155/2016/8742920.
42. Antoshchuk, S. G.; Kondratyev, S. B.; Shcherbakova, G. Y.; Hodovychenko, M. A. Depth Map Generation for Mobile Navigation Systems Based on Objects Localization in Images. Herald of Advanced Information Technology 2022, 5 (1), 11-18. <https://doi.org/10.15276/hait.05.2022.1>.
43. Антощук С. Г., Клих І. В. Метод вейвлет-оптимізації при апріорній невизначеності. Праці Одеського політехнічного університету, 2007. Вип. 1(27). С. 138–142.
44. Antoshchuk S. G., Klykh I. V. Wavelet-based search for the optimum in conditions of noise. Proceedings of ICSS, 2008. P. 45–50.
45. Антощук С. Г., Клих І. В., Ткаченко О. В. Вейвлет-технології в задачах оптимізації та керування: монографія. Одеса: Наука і техніка, 2021. 212 с.

46. Антощук С. Г., Кlich І. В. Порівняльний аналіз фільтруючих властивостей вейвлет-функцій у задачах сегментації. Автоматика. Автоматизація. Електротехнічні комплекси та системи. 2009. № 2. С. 44–51.
47. Щербакова Г. Ю., Крилов В. М. Методи глобальної оптимізації на основі вейвлет-аналізу для систем керування. Одеса : Наука і техніка, 2021. 176 с.
48. Shcherbakova G. Y., Krylov V. N., Plachynda K. V. Determination of characteristic points of electrocardiograms using multi-start optimization with a wavelet transform. *Applied Aspects of Information Technology*. 2019. Vol. 2, № 3. P. 215–228. DOI: 10.15276/aait.02.2019.5.
49. Huan, W., Shcherbakova, G., Sachenko, A., Yan, L., Volkova, N., Rusyn, B., & Molga, A. (2023). Haar wavelet-based classification method for visual information processing systems. *Applied Sciences*, 13(9), 5515. <https://doi.org/10.3390/app13095515>
50. Shcherbakova G. Y., Krylov V. N., Pisarenko R. O. Information technology of quality assessment of assembly units in radio equipment manufacturing. *Електротехнічні та комп'ютерні системи*. 2016. № 22 (98). С. 240–246.
51. Щербакова Г. Ю. Термофункціональне гіпермодельовання та підвищення стабільності електронних пристроїв з багатoeлементною структурою : автореф. дис. на здобуття наук. ступеня канд. техн. наук : 05.13.05 / Одес. політехн. ін-т. — Одеса, 1992. — 16 с. — Бібліогр.: с. 15–16.
52. Tsypkin, Ya. Z. (1971). *Adaptation and Learning in Automatic Systems*. New York: Academic Press.
53. Widrow, B., & Stearns, S. D. (1985). *Adaptive Signal Processing*. New Jersey: Prentice-Hall.
54. Nevel'son, M. B., & Has'minskii, R. Z. (1973). *Stochastic Approximation and Recursive Estimation*. Providence: American Mathematical Society.
55. G. Shcherbakova, V. Krylov, W. Qianqi, B. Rusyn, A. Sachenko, P. Bykovyy, D. Zahorodnia, and L. Kopania, “Optimization methods on the wavelet transformation base for technical diagnostic information systems”, In 2021 11th IEEE International Conference on Intelligent Data Acquisition and Advanced Computing

Systems: Technology and Applications (IDAACS), vol.11 pp. 1-6, 2021, July 26-29, IEEE. doi: 10.1109/IDAACS52987.2021.9623431.

56. Goodwin, G. C., & Sin, K. S. (1984). Adaptive Filtering Prediction and Control. New Jersey: Prentice-Hall.

57. Xu, D., & Tian, Y. (2015). A Comprehensive Survey of Clustering Algorithms. *Annals of Data Science*, 2(2), 165–193. <https://doi.org/10.1007/s40745-015-0040-1>

58. Zhang, A., Lipton, Z. C., Li, M., & Smola, A. J. (2023). Dive into Deep Learning. Cambridge University Press.

59. Liu, Z., Wang, Y., Vaidya, S., Ruehle, F., Halverson, J., Soljačić, M., ... & Tegmark, M. (2024). KAN: Kolmogorov-Arnold Networks. arXiv preprint arXiv:2404.19756.

60. Wang, X., et al. (2024). Efficient Training of Kolmogorov-Arnold Networks for High-Dimensional Data. *Journal of Computational Physics*.

61. Bozorgasl, Z., & Chen, H. (2024). Wav-KAN: Wavelet Kolmogorov-Arnold Networks. arXiv preprint arXiv:2405.12832.

62. N. Prashar, M. Sood and S. Jain, “Design and implementation of a robust noise removal system in ECG signals using dual-tree complex wavelet transform”, *Biomedical signal processing and control*, vol. 63, 2021. <https://doi.org/10.1016/j.bspc.2020.102212>.

63. W. Huan, G. Shcherbakova, A. Sachenko, L. Yan, N. Volkova, B. Rusyn, and A. Molga, “Haar Wavelet-Based Classification Method for Visual Information Processing Systems,” *Applied Sciences*, 13(9), 2023. 5515. <https://doi.org/10.3390/app13095515>.

64. Y. Zheng, G. Shcherbakova, B. Rusyn, A. Sachenko, N. Volkova; I. Kliushnikov, S. Antoshchuk, “Wavelet Transform Cluster Analysis of UAV Images for Sustainable Development of Smart Regions Due to Inspecting Transport Infrastructure,” *Sustainability*, 2025, 17, 927. <https://doi.org/10.3390/su17030927>.

65. G. Shcherbakova, V. Krylov, V. Abakumov, V. Brovkov, I. Kozina, “Sub Gradient Iterative Method for Neural Networks Training,” 6th IEEE Int. Workshop

IDAACS'2011. Prague, Czech Republic, 15 – 17 sept. 2011.: proceeding, 2011, pp. 361 - 364.

66. H. Rosenbrock, “An automatic method for finding the greatest or least value of a function,” *The computer journal*, 1960, vol. 3, No 3, pp. 175—184.

67. A. S. Berahas, L. Cao, K. Choromanski and K. Scheinberg, “A Theoretical and Empirical Comparison of Gradient Approximations in Derivative-Free Optimization,” ISE Technical Report 19T-004, Lehigh University, 2019, 34 p.

68. A. Conn, K. Scheinberg, L. Vicente, *Introduction to derivative-free optimization*. SIAM, 2009.

69. J. Kiefer, J. Wolfowitz, “Stochastic estimation of the maximum of a regression function,” *The Annals of Mathematical Statistics*, 1952, pp. 462—466.

70. X. Li, Z. Zhu, A. So, and R. Vidal, “Nonconvex Robust Low-rank Matrix Recovery,” *arXiv preprint*, 2018, 26 p.

71. B. Cox, A. Juditsky, and A. Nemirovski, “Decomposition techniques for bilinear saddle point problems and variational inequalities with affine monotone operators,” *J. Optim. Theory Appl.*, 2017, vol. 172, pp. 402—435.

72. Kumar, M., Pachori, R. B., & Acharya, U. R. (2017). “Automated diagnosis of myocardial infarction ECG signals using sample entropy in flexible analytic wavelet transform framework.” *Entropy*, 19(9), 488. <https://doi.org/10.3390/e19090488>.

73. Sundararaj, V. (2019). “Optimised denoising scheme via opposition-based self-adaptive learning PSO algorithm for wavelet-based ECG signal noise reduction.” *International Journal of Biomedical Engineering and Technology*, 31(4), 325-345. <https://doi.org/10.1504/IJBET.2019.103242>.

74. Balasubramanian, S., Naruka, M.S. & Tewari, G. “Electrocardiogram Signal Denoising Using Optimized Adaptive Hybrid Filter with Empirical Wavelet Transform.” *J. Shanghai Jiaotong Univ. (Sci.)* 30, 66–80 (2025). <https://doi.org/10.1007/s12204-023-2591-1>.

75. A. Hernandez, P. Bonizzi, R. Peeters, J. Karel, “Continuous monitoring of acute myocardial infarction with a 3-Lead ECG ystem”, *Biomed. Sign. Proc. and Control*, Vol. 79, Part 1, January 2023, 104041. <https://doi.org/10.1016/j.bspc.2022.104041>.

76. M. Moganti, F. Ercal, C. Dagli, S. Tsunekawa. “Automatic PCB inspection algorithms: a survey.” *Computer vision and image understanding*, vol. 63. No 2, pp. 287 – 313, March 1996. <https://citeseer.ist.psu.edu/moganti96automatic.html>.
77. Fiakko A.V., McCormick G.P. *Nonlinear programming: sequential unconstrained minimization techniques*. New York: John Wiley and Sons, Inc. 1968, 117 p.
78. E. Polak, *Computational Methods in Optimization. A unified approach*. Departament of Electrical engineering and Computer Sciences. University of California, Berkeley, California, New York, London: Academic Press. 1971.
79. J. C. Spall. *Introduction to stochastic search and optimization: estimation, simulation, and control*, vol. 65. John Wiley & Sons, 2005. <https://doi.org/10.1002/0471722138>.
80. R. Tyrell Rockafellar, *Convex Analysis*, *Proceedings of the Edinburgh Mathematical Society*, 18(04), Dec. 1973. <https://doi.org/10.1017/S0013091500010142>.
81. Stoer, J. On the relation between quadratic termination and convergence properties of minimization algorithms. *Numer. Math.* 28, 343–366 (1977). <https://doi.org/10.1007/BF01389973>.
82. F. A. Lootsma, *Boundary properties of penalty functions for constrained minimization*. [Phd Thesis 2 (Research NOT TU/e / Graduation TU/e), Philips]. Technische Hogeschool Eindhoven, 1970. <https://doi.org/10.6100/IR19751>.
83. Ya. Z. Tsypkin, U. Holmberg “Robust stochastic control and internal model control,” *Int. J. of Control*. 1995, vol. 61, No 4, pp. 809 – 822.
84. S. Antoshchuk, O. Arsirii, O. Babilunga, O. Galchonkov, G. Shcherbakova, A. Nikolenko, S. Kondratyev, V. Krylov, V. Kostenko & M. Yadrova “Hybrid representation models and image processing methods in wavelet transform space”. Monograph, edited by. S. G. Antoshchuk. Odessa: Ukraine. Publ. Bondarenko M. O. 2020. 160 p. (in Ukrainian).
85. Polyakova, M., & Krylov, V. (2014). Classification of methods of the signal semantic wavelet transform for image contour segmentation. *International Journal of Computing*, 7(1), 51–57. <https://doi.org/10.47839/ijc.7.1.489>

86. Shcherbakova, G., Krylov, V., Pisarenko, R., & Kuzmenko, V. (2013). Wavelet transform domain adaptive clustering for electronic product quality inspection. In Proceedings of the 7th IEEE International Conference on Intelligent Data Acquisition and Advanced Computing Systems: Technology and Applications (IDAACS'2013) (Vol. 1, pp. 153–156). Berlin, Germany, 12–14 September 2013.
87. Shcherbakova, G., Antoshchuk, S., Koshutina, D., & Sakhno, K. (2024). Adaptive clustering for distribution parameter estimation in technical diagnostics. Proceedings of International Conference on Applied Innovation in IT, 12(1), 123–128. <https://doi.org/10.25673/115667>
88. Antoshchuk, S., Shcherbakova, G., Kondratiev, S., Koshutina, D., & Usov, O. (2024). Method of optimization based on wavelet transform for approximate depth estimation. In S. Vychuzhanin (Ed.), Information Control Systems and Technologies (ICST-Odesa-2024): Materials of XII International Scientific-Practical Conference, 23–25 September 2024 (pp. 123–127). Odesa: Helvetika.
89. Zheng, Y., Shcherbakova, G., Rusyn, B., Sachenko, A., Volkova, N., Kliushnikov, I., & Antoshchuk, S. (2025). Wavelet transform cluster analysis of UAV images for sustainable development of smart regions due to inspecting transport infrastructure. Sustainability, 17, 927. <https://doi.org/10.3390/su17030927>
90. Shcherbakova, G., Gerganov, M., Antoshchuk, S., Polyakova, M., & Sachenko, A., Krylov, V. (2018). Areal multistart method of optimization for image recognition. In IEEE Second International Conference on Data Stream Mining & Processing, 605–608. Lviv, Ukraine.
91. Shcherbakova G. Y., Koshutina D. V. Improving the performance of clustering with wavelet function by using inequality constraints // Herald of Advanced Information Technology. – 2025. – Vol. 8, No. 3.
92. Wavelet Transform Cluster Analysis of UAV Images for Sustainable Development of Smart regions Due to Inspecting Transport Infrastructure / Y. Zheng et al. 2025. No17. P. 927–940. URL: <https://doi.org/10.3390/su17030927>

93. Haar Wavelet-Based Classification Method for Visual Information Processing Systems / W. Huan et al. Appl. Sci. 2023. No13 (9). URL:<https://doi.org/10.3390/app13095515>
94. Shcherbakova G. Y., Koshutina D. V. Improving the performance of clustering with wavelet function by using inequality constraints // Publ. Nauka i Tekhnika. Odesa: Ukraine. Herald of Advanced Information Technology. – 2025. – Vol. 8, No. 3. – P. 277–287. – DOI: <https://doi.org/10.15276/hait.08.2025.17>.
95. Fault Diagnosis for Attitude Sensors Based on Analytical Redundancy and Wavelet Transform. Chinese Automation Congress (CAC) / Liu W. et al. China, Shanghai. 2020. P. 6471–6476. DOI: 10.1109/CAC51589.2020.9327370.
96. Соловйов В. І. Основи теорії надійності і експлуатації авіаційних систем. Київ: КІ ВПС, 2000. 248 с.
97. Nocedal J., Wright S. J. Numerical Optimization. New York: Springer-Verlag, 2006. 651 p.
98. Квасніков В. П., Єгоров С. В. Визначення довірчих інтервалів і планування випробувань при використанні DN – розподілу. Вісник Інженерної академії України. 2016. Вип. 2. С. 72–75.
99. Zelenkov A. A., Golik A. P. Theon-board system reliability estimate on the base of DN-distribution. Електроніка та системи управління. 2009. No2 (20). P. 12–17.
100. Fault Diagnosis for Attitude Sensors Based on Analytical Redundancy and Wavelet Transform. Chinese Automation Congress (CAC) / Liu W. et al. China, Shanghai. 2020. P. 6471–6476. DOI: 10.1109/CAC51589.2020.9327370.
101. GillP. E., Murray W., Wright M. H. Practical Optimization. New York: Academic Press, 1981. 509 p.
102. Avriel M. Nonlinear Programming: Analysis and Methods. New York: Dover Publishing, 2003. 453 p.
103. Антощук С. Г., Щербакова Г. Ю., Кошутіна Д. В. Оцінка параметрів компонентів електроніки при відборі їх для апаратури відповідального призначення на основі кластеризації з вейвлет-обробкою та врахуванням обмежень

// Наукові праці Вінницького національного технічного університету. – Вип. 3. – 2025. – URL: <https://praci.vntu.edu.ua/index.php/praci/article/view/863>

104. Олійник В. П. Елементна база радіоелектроніки: навч. посіб. Харків: Нац. аерокосм. ун-т ім. М. Є. Жуковського «Харків. авіац. ін-т», 2022. 88 с.

105. A. J. Lemonte, "A new extension of the Birnbaum-Saunders distribution," Brazilian Journal of Probability and Statistics, vol. 27, no. 2, pp. 133-149, May 2013.

106. Bochra Hady Kilani. Convolutional Kolmogorov–Arnold Networks: a survey. University of Carthage, June 23, 2025.

107. Bozorgasl, Z., & Chen, H. (2024). Wav-KAN: Wavelet Kolmogorov-Arnold Networks. arXiv preprint arXiv:2405.12832.

108. Seydi, S., et al. (2024). Kolmogorov-Arnold Networks (KANs) for Remote Sensing: A Review and Future Directions. arXiv preprint arXiv:2406.10307.

109. Huang, Z. Abnormality Detection in Time-Series Bio-Signals using Kolmogorov-Arnold Networks / Z. Huang, O. Kavehei // medRxiv. — 2024. — DOI: 10.1101/2024.06.04.24308428.

110. Mavaddati, S. “ECG arrhythmias classification based on deep learning methods and transfer learning technique.” 2024. DOI: <https://doi.org/10.1016/j.bspc.2024.107236>.

111. Bodnar, T., et al. (2024). Convolutional Kolmogorov-Arnold Networks. arXiv preprint arXiv:2406.13144.

112. Hemanth, D. J., Gupta, D. & Balas, V. E. “Intelligent Data Analysis for Biomedical Applications”. Academic Press. 2019, <https://www.sciencedirect.com/book/9780128155530/intelligent-data-analysis-for-biomedical-applications>. DOI: <https://doi.org/10.1016/C2017-0-03676-5>.

113. Khalid, M., Pluempitiwiriawej, C., Wangsiripitak, S., Abdulkadhem, A. A. “The applications of deep learning in ECG classification for disease diagnosis: A systematic review and meta-data analysis.” Engineering Journal, 2024; 28(8): 45–77. DOI: <https://doi.org/10.4186/ej.2024.28.8.45>.

114. Agrawal P., Arun V., Basu A. Artificial Neural Network Based ECG Feature Extraction Using Wavelet Transform. Emerging Wireless Technologies and Sciences.

ICEWTS 2024. CCIS, vol. 2399. Cham: Springer, 2025. P. 8–22. DOI: https://doi.org/10.1007/978-3-031-87886-2_2.

115. Li T., Zhou M. ECG Classification Using Wavelet Packet Entropy and Random Forests. *Entropy*. 2016. Vol. 18, No. 8. Art. 285. DOI: <https://doi.org/10.3390/e18080285>.

116. Cornforth D., Tarvainen M.P., Jelinek H.F. Using Renyi entropy to detect early cardiac autonomic neuropathy. *Proc. IEEE Engineering in Medicine and Biology Society (EMBC)*. 2013. P. 5562–5565. DOI: <https://doi.org/10.1109/EMBC.2013.6610810>.

117. Rekik S., Ellouze N. P-Wave Detection Combining Entropic Criterion and Wavelet Transform. *Journal of Signal and Information Processing*. 2015. Vol. 6, No. 3. P. 217–226. DOI: <https://doi.org/10.4236/jsip.2015.63020>.

118. P wave detection and delineation in the ECG based on the phase free stationary wavelet transform and using intracardiac atrial electrograms as reference / Lenis G., Pilia N., Oesterlein T., Luik A., Schmitt C., Dössel O. *Biomedical Engineering / Biomedizinische Technik*. 2016. Vol. 61, No. 1. P. 37–56. DOI: <https://doi.org/10.1515/bmt-2014-0161>.

119. Haar Wavelet-Based Classification Method for Visual Information Processing Systems / Huan Z., Kochan V., Velychko A. et al. *Applied Sciences*. 2023. Vol. 13, No. 9. Art. 5515. DOI: <https://doi.org/10.3390/app13095515>.

120. Shcherbakova, G., & Koshutina, D. (2025). Development of a selection criterion for the wavelet decomposition level in QRS detection of ECG signals using energy and entropy. *Proceedings of Odessa Polytechnic University*, No. 1(71), pp. 157–166. <https://doi.org/10.15276/opu.1.71.2025.18>

121. Liu M., Song Q., Cao Y. ECG classification based on improved wavelet threshold denoising and CNN. *Computers in Biology and Medicine*. 2020. Vol. 123. Art. 103866. DOI: <https://doi.org/10.1016/j.compbiomed.2020.103866>.

122. Recommendations for the Standardization and Interpretation of the Electrocardiogram / Kligfield P. Et al. *Journal of the American College of Cardiology*. 2007. Vol. 49, No. 10. P. 1109–1127. DOI: <https://doi.org/10.1016/j.jacc.2007.01.024>.

123. Widman L.E., Yochim M., Jackson K. ECG Criteria for Left and Right Bundle Branch Block: A Clinical Review. *The American Journal of Medicine*. 2022. Vol. 135, No. 1. P. 1–9. DOI: <https://doi.org/10.1016/j.amjmed.2021.08.028>.
124. Wang, M., Feng, Y. T., Guan, S. & Qu, T. “Multi-layer perceptron-based data-driven multiscale modelling of granular materials with a novel Frobenius norm-based internal variable.” *Journal of Rock Mechanics and Geotechnical Engineering*, 2024. DOI: <https://doi.org/10.1016/j.jrmge.2024.02.003>.
125. Hadj Kilani, B. “Kolmogorov-Arnold networks: Key developments and uses.” 2024. DOI: <https://doi.org/10.32388/7NNCAA>.
126. Yu, R., Yu, W. & Wang, X. “KAN or MLP: A fairer comparison.” 2024. DOI: <https://doi.org/10.48550/arXiv.2407.16674>.
127. Ismayilova, A. & Ismayilov, M. “On the universal approximation property of radial basis function neural networks.” 2023. arXiv:2304.02220v2 [cs.LG].
128. Ta, T. H. “BSRBF-KAN: A combination of B-splines and radial basis functions in Kolmogorov-Arnold networks.” 2024. DOI: <https://doi.org/10.13140/RG.2.2.16755.54562>.
129. Ta, T. H. “BSRBF-KAN: A combination of B-splines and radial basis functions in Kolmogorov-Arnold networks.” 2024. DOI: <https://doi.org/10.13140/RG.2.2.16755.54562>
130. Hollósi, J. “Efficiency analysis of Kolmogorov–Arnold networks for visual data processing.” *SMTS 2024 Conference Proceedings*, 2024. DOI: <https://doi.org/10.3390/engproc2024079068>.
131. Seghouane, A.-K. & Shokouhi, N. “Adaptive learning for robust radial basis function networks.” *IEEE Transactions on Cybernetics*, 2021; 51(5): 2847–2856. DOI: <https://doi.org/10.1109/TCYB.2019.2951811>.
132. Panda, S. & Panda, G. “On the development and performance evaluation of improved radial basis function neural networks.” *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2022; 52(6): 3873–3884. DOI: <https://doi.org/10.1109/TSMC.2021.3076747>.

133. Bozorgasl, Z., & Chen, H. “Wav-KAN: Wavelet Kolmogorov-Arnold networks.” arXiv:2405.12832, 2024. <https://arxiv.org/abs/2405.12832>
134. Кошутіна Д.В., Щербакова Г.Ю. Автоматизований вибір рівня вейвлет-розкладу на основі енергії та ентропії для виявлення QRS-комплексів ЕКГ // Сучасні інформаційні технології – 2025: Матеріали 15-ї міжнар. наук. конф. студентів та молодих учених, 15–16 травня 2025 р., м. Одеса. Україна. Одеса: Наука і техніка, 2025. С. 21–23. DOI: <https://doi.org/10.5281/zenodo.15521809>
135. Ashiri, M., Lithgow, B., Suleiman, A., Mansouri, B., & Moussavi, Z. (2021). Electrovestibulography (EVestG) application for measuring vestibular response to horizontal pursuit and saccadic eye movements. Biocybernetics and Biomedical Engineering, 41(2), 527–539. DOI: <https://doi.org/10.1016/j.bbe.2021.03.007>.
136. PhysioNet. (n.d.). MIT-BIH Arrhythmia Database. Retrieved from <https://www.physionet.org/content/mitdb/1.0.0/>.
137. 1.Taiyong Li, Min Zhou, ECG Classification Using Wavelet Packet Entropy and Random Forests. Entropy 2016, 18(8), 285; <https://doi.org/10.3390/e18080285>. Дата звернення 12.02. 2025
138. Atamanyuk, I., et al. (2023). Computational method of the cardiovascular diseases classification based on a generalized nonlinear canonical decomposition of random sequences. Scientific Reports, 13, 59. <https://doi.org/10.1038/s41598-022-27318-0>
139. Ferreira Jr, M., & Zanesco, A. (2016). Heart rate variability as important approach for assessment autonomic modulation. Motriz: Revista de Educação Física, 22, 3–8. <https://doi.org/10.1590/S1980-65742016000200001>
140. Jacob, V., & Nair, K. N. R. (2014). Automation of ECG heart beat detection using morphological filtering and Daubechies wavelet transform. IOSR Journal of Engineering (IOSRJEN), 4(12), 53–58. <https://doi.org/10.9790/3021-041215358>
141. Shebanin, V., et al. (2017). Canonical mathematical model and information technology for cardio-vascular diseases diagnostics. 2017 14th International Conference The Experience of Designing and Application of CAD Systems in Microelectronics, 438–440. <https://doi.org/10.1109/CADSM.2017.7916170>

142. Polyak, B. T. (1987). *Introduction to Optimization*. New York: Optimization Software.
143. Bhuvaneswari Amma, N. (2012). Cardiovascular disease prediction system using genetic algorithm and neural network. In 2012 International Conference on Computing, Communication and Applications, 1–5. <https://doi.org/10.1109/ICCCA.2012.6179185>
144. Gupta, V., Saxena, N. K., Kanungo, A., Gupta, A., & Kumar, P. (2022). A review of different ECG classification/detection techniques for improved medical applications. *International Journal of System Assurance Engineering and Management*, 1–15. <https://doi.org/10.1007/s13198-021-01548-3>
145. Xie, L., Li, Z., Zhou, Y., He, Y., & Zhu, J. (2020). Computational diagnostic techniques for electrocardiogram signal analysis. *Sensors*, 20(21), 6318. <https://doi.org/10.3390/s20216318>
146. Gutierrez-Ojeda, J., Ponomaryov, V., Almaraz-Damian, J.-A., Reyes-Reyes, R., & Cruz-Ramos, C. (2023). ECG arrhythmia classification using recurrence plot and ResNet-18. *International Journal of Computing*, 22(2), 140–148. <https://doi.org/10.47839/ijc.22.2.3083>
147. Cesari, M., Mehlsen, J., Mehlsen, A. B., & Sorensen, H. B. D. (2017). A new wavelet-based ECG delineator for the evaluation of the ventricular innervation. *IEEE Journal of Translational Engineering in Health and Medicine*, 5, 1–15. <https://doi.org/10.1109/JTEHM.2017.2722998>
148. Antoshchuk, S. G., Arsiriy, E. A., Babilunga, O. Y., Volkova, N. P., Galchonkov, O. M., Shcherbakova, G. Y., Nikolenko, A. A., Kondratiev, S. B., Kostenko, V. L., & Yadrova, M. V. (2022). Analysis and recognition of images in the wavelet transform space. Odessa: Bondarenko M. A. ISBN 978-617-8005-62-7
149. Shcherbakova, G., Shi, H.-S., Krylov, V., Bilous, N., & Antoshchuk, S. (2017). Estimation of the duration of RR-intervals of electrocardiograms by means of multi-start optimization based on wavelet transformation. In *IEEE 9th International Workshop on Intelligent Data Acquisition and Advanced Computing Systems*, 438–440. Bucharest, Romania.

150. Walsh, J. L. (1923). A property of Haar's system of orthonormal functions. *Mathematische Annalen*, 90, 38–45.

151. Price, J. J., & Zink, R. E. (1965). On sets of completeness of Haar functions. *Transactions of the American Mathematical Society*, 119(2), 262–269.

152. Кошутіна Д. В., Сахно К. О., Щербакова Г. Ю. Використання вейвлет-перетворення при аналізі електрокардіограм // Інформаційні технології: наука, техніка, технологія, освіта, здоров'я: тези доповідей XXXIII Міжнародної науково-практичної конференції MicroCAD-2025, 14–17 трав. 2025 р. / за ред. проф. Сокола Є. І. – Харків : НТУ «ХП», 2025. – С. 765–766. – DOI: <https://doi.org/10.5281/zenodo.15520692>.

153. Amirov, Yu. D. (1985). Scientific and technical level of products: (Methodology of evaluation and forecasting) [Monograph]. Tech-Scientific Engineering Publishing. 216 p.

154. Кошутіна Д. В., Щербакова Г. Ю., Антошук С. Г. Удосконалення пошуку параметрів електрокардіограм за допомогою оптимізації на основі вейвлет-функції // Information Control Systems & Technologies (ICST-Odesa-2025), колективна монографія «Information Control Systems and Intelligent Technologies. Achievements and Applications» / за ред. проф. В. Вичужаніна. – Lviv–Torun: Liha-Pres, 2025. – С. 383–401. – ISBN 978-966-397-538-2. – DOI: <https://doi.org/10.36059/978-966-397-538-2>.

155. Чорний М. В. Оцінка параметра потоку відмов зразка озброєння і військової техніки за даними експлуатаційних спостережень в умовах інтенсивного використання. *Труди академії*. 2005. No 58. С. 235–242.

156. Chorny N. V., Stepanov S. S., Matuzko B. P. Information support assessment of reliability and armament equipment during use. *Військово-технічний збірник*. 2011. No2 (5). P. 140–145.

157. Singh K., Kalra S. Reliability Forecasting and Accelerated Life time Testing in Advanced CMOS Technologies. *Microelectronics Reliability*. 2023. Vol. 151. URL: <https://doi.org/10.1016/j.microrel.2023.115261>

158. Hsu P. -N. Artificial Intelligence Deep Learning for 3D IC Reliability Prediction. Scientific Reports. 2022. Vol. 12 (1). DOI: 10.1038/s41598-022-08179-z.

159. Time Series Data for Equipment Reliability Analysis with Deep Learning / B. Chenet et al. IEEE Access. 2020. Vol. 8. P. 105484–105493. DOI: 10.1109/ACCESS.2020.3000006.

160. Evaluation Of Reliability Of Radio-Electronic Devices With Variable Structure / Y. V. Ryzhov et al. Radio Electronics, Computer Science, Control. 2020. No3. P. 31–41. URL: <https://doi.org/10.15588/1607-3274-2020-3-3> (Last accessed 01.10.2025).

161. Information Technology of Parameters Prediction with Adaptive Clustering in the Space of the Wavelet Transform / G. Shcherbakova et al. Пр. Одес. політехн. ун-ту. Вип. 1 (40). С. 104–109.

162. The Determination of Cluster Number at k-Mean Using Elbow Method and Purity Evaluation on Headline News / D. Marutho et al. International Seminar on Application for Technology of Information and Communication, Semarang, Indonesia. 2018. P. 533–538. DOI: 10.1109/ISEMANTIC.2018.8549751.

ДОДАТОК А АКТИ ВПРОВАДЖЕННЯ РЕЗУЛЬТАТІВ ДИСЕРТАЦІЙНОГО ДОСЛІДЖЕННЯ



DISKRET
НАУКОВО-ВИРОБНИЧЕ ОБ'ЄДНАННЯ

Тел. (48) 7001225, Сайт: www.diskret.com.ua, E-mail: info@diskret.com.ua

АКТ

впровадження результатів дисертаційного дослідження
на здобуття наукового ступеню доктора філософії
за спеціальністю 122 Комп'ютерні науки
«Методи та моделі обробки і аналізу гетерогенних даних на основі вейвлет-перетворення»
здобувача Кошутіної Дар'ї Валеріївни
у науково-практичну діяльність ТОВ НВО «Діскрет»

Ми, що нижче підписалися, представник НВО «Діскрет» директор Стаценко Г.С., з одного боку, та представники Навчально-наукового інституту комп'ютерних систем (ННІКС) директор ЦІКТ «ІТ інкубатор», к.т.н., доц. П.А. Швагірев та заступник директора з наукової роботи ННІКС, к.т.н., доц. А.Г. Кісель, з другого боку, склали цей акт у підтвердження впровадження у науково-практичну діяльність ТОВ НВО «Діскрет» програмно-алгоритмічного забезпечення, яке міститься у дисертації Кошутіної Дар'ї Валеріївни, а саме: алгоритму адаптивної кластеризації для оцінки параметрів розподілу в задачах технічної діагностики та методу вейвлет-фільтрації для оцінки надійності електронних компонентів. Перелічені методи застосовано для вдосконалення систем автоматизованого контролю якості та моніторингу стану складних технічних систем.

В процесі впровадження прикладних розробок здобувача Кошутіної Д.В. у період з 12.12.2025 по 30.01.2026 встановлено, що використання вейвлет-перетворення для аналізу гетерогенних даних дозволило підвищити достовірність відбракування дефектних компонентів на 12%. Завдяки впровадженню процедур інтелектуального аналізу даних скорочено час на обробку діагностичної інформації, що забезпечило підвищення ефективності виробничих процесів підприємства.

Акт видано в зв'язку з захистом дисертації і він не є основою для фінансових розрахунків.


Від ТОВ НВО «Діскрет»

Директор

 Г.С. СТАЦЕНКО

Від Національного університету «Одеська політехніка»

Директор ЦІКТ «ІТ інкубатор»,
к.т.н., доц.

 Павло ШВАГІРЕВ

Заст. директора з наукової роботи ННІКС,
к.т.н., доц.

 Анатолій КІСЕЛЬ

30 січня 2026 р.
Адреса 65044, Одеса,
Пр-к Шевченка, 10/7, кв.60
ТОВ НВО «Діскрет»
Тел. (8-048) 775-0586

30 січня 2026 р.
Адреса 65044, Одеса,
Пр-к Шевченка, 1
Національний університет «Одеська політехніка»
Тел. (8-048) 705-8328

**ДОДАТОК Б ДОВІДКИ ПРО ВПРОВАДЖЕННЯ РЕЗУЛЬТАТІВ
ДИСЕРТАЦІЙНОЇ РОБОТИ У НАВЧАЛЬНОМУ ПРОЦЕСІ
НАЦІОНАЛЬНОГО УНІВЕРСИТЕТУ «ОДЕСЬКА ПОЛІТЕХНІКА»**



ДОВІДКА

про впровадження результатів дисертаційної роботи
Кошутіної Дар'ї Валеріївни
«Методи та моделі обробки і аналізу гетерогенних даних на основі вейвлет-перетворення»
у освітній діяльності
Національного університету «Одеська Політехніка»

Довідка видана у результаті того, що в програмі, навчально-методичних матеріалах та курсу лекцій дисципліни «Інтелектуальний аналіз даних», що викладається на кафедрі Інформаційних систем Інституту комп'ютерних систем для здобувачів вищої освіти спеціальності 122 «Комп'ютерні науки», використовуються наукові результати, отримані у дисертації Кошутіної Дар'ї Валеріївни, а саме

- методи попередньої обробки та фільтрації гетерогенних даних на основі дискретного вейвлет-перетворення – у межах теми «Методи підготовки та очищення даних»;
- алгоритми аналізу нестационарних часових рядів із використанням багаторівневої вейвлет-декомпозиції – у межах теми «Прогнозування та аналіз часових рядів».

Використані результати дисертації Кошутіної Дар'ї Валеріївни свідчать про глибоке опрацювання наукової літератури за тематикою дослідження. Висновки та пропозиції відзначаються науковою новизною, можливістю реалізації в інтелектуальних інформаційних системах, тому істотно поліпшують матеріал означеної дисципліни і сприяють підвищенню якості підготовки фахівців у галузі комп'ютерних наук та інформаційних технологій.

Проректор з науково-педагогічної та виховної роботи, д.т.н., професор

Завідувача кафедри інформаційних систем, д.т.н., професор

14.04.2026 р



Сергій НЕСТЕРЕНКО

Олена АРСІРІЙ



Довідка № 702/61-07 від 24.04.2026

про використання результатів дисертаційної роботи
Кошутіної Дар'ї Валеріївни
«Методи та моделі обробки і аналізу гетерогенних даних на основі
вейвлет-перетворення»
у науково-дослідницької діяльності
Національного університету «Одеська Політехніка»

Довідка видана в тому, що у науково-дослідницькій діяльності Національного університету «Одеська політехніка» використані наступні наукові результати, отримані у дисертаційній роботі Кошутіної Дар'ї Валеріївни:

– удосконалений метод аналізу та обробки сигналів на основі дискретного вейвлет-перетворення (DWT) з використанням багаторівневої декомпозиції для підвищення точності виявлення локальних особливостей у нестационарних процесах.

Дисертацію виконано згідно тематичних планів НДР Одеської політехніки за період 2016 - 2026 рр.

Кошутіна Дар'я Валеріївна була виконавцем у держбюджетній тематі:

– НДР № 719-61/161 «Інтелектуальна підтримка прийняття рішень при проектуванні кісткових замінників для лікування воєнних травм» (номер держ. реєстрації 0124U000388).;

– НДР № 1938 (Договір МОН № СШ/05 – 2024) «Інтелектуальна система визначення стану довкілля у реальному часі на базі БПЛА» (номер держ. реєстрації 0124U004854).

Проректор



Дмитро ДМИТРИШИН

Керівник

НДР №719-61/161 та № 1938

Світлана АНТОЩУК

ДОДАТОК В ФРАГМЕНТИ ВИХІДНОГО КОДУ ПРОГРАМНИХ ІНСТРУМЕНТАЛЬНИХ ЗАСОБІВ

```
def calculate_ci_metrics(coefficients: np.ndarray) -> float:
    """
    Розраховує критерій інформативності  $C_i = \text{Energy} / \text{Entropy}$ .
    Реалізовано через ітераційні цикли для забезпечення прозорості обчислень.
    """
    epsilon = 1e-12
    energy = 0.0
    for val in coefficients:
        energy += val * val

    entropy = 0.0
    if energy > epsilon:
        for val in coefficients:
            p = (val * val) / energy
            if p > epsilon:
                entropy -= p * math.log2(p)

    return energy / (entropy + epsilon)

def select_optimal_basis(signal: np.ndarray, candidates: list) -> str:
    """
    Визначає найкращий вейвлет-базис для активації шарів KAN.
    """
    best_w = candidates[0]
    max_ci = -1.0
    for w in candidates:
        coeffs = pywt.wavedec(signal, w, level=1)
        score = calculate_ci_metrics(coeffs[1])
        if score > max_ci:
            max_ci = score
            best_w = w
    return best_w

def apply_db4_preprocessing(data: np.ndarray, level: int = 2) -> np.ndarray:
    """
    Виконує фільтрацію та стиснення сигналу (200 -> 55 відліків).
    Використовує коефіцієнти апроксимації (сА) вейвлета db4.
    """
    reduced_features = []
    for sig in data:
        coeffs = pywt.wavedec(sig, 'db4', level=level)
        reduced_features.append(coeffs[0])
    return np.array(reduced_features).astype(np.float32)

class FeatureExtractor:
    """
    Здійснює детекцію характерних точок ЕКГ на відфільтрованому сигналі.
    """
    def __init__(self, sampling_rate: int = 360):
        self.fs = sampling_rate

    def detect_grs_complex(self, signal: np.ndarray) -> dict:
        """
        Знаходить піки R та межі Q, S за допомогою градієнтного аналізу.
        """
        # Пошук R-піку (максимум амплітуди)
        r_idx = np.argmax(np.abs(signal))
```

```

# Пошук точки Q (мінімум зліва від R)
q_segment = signal[max(0, r_idx-30):r_idx]
q_idx = (r_idx - 30) + np.argmin(q_segment) if len(q_segment) > 0 else
r_idx

# Пошук точки S (мінімум справа від R)
s_segment = signal[r_idx:min(len(signal), r_idx+30)]
s_idx = r_idx + np.argmin(s_segment) if len(s_segment) > 0 else r_idx

return {"Q": q_idx, "R": r_idx, "S": s_idx}

def build_hybrid_kan_model(input_dim: int, wavelet_name: str):
    """
    Побудова архітектури KAN з вейвлет-активацією.
    """
    inputs = Input(shape=(input_dim,))

    # Нормалізація
    x = Lambda(lambda x: x / (tf.reduce_max(tf.abs(x), axis=1, keepdims=True)
+ 1e-7))(inputs)

    # KAN-шар (Вейвлет-активація на основі результату Сі аналізу)
    # Тут використовується Lambda для виклику вейвлет-функції
    x = Flatten()(x)
    x = Dense(128, activation='relu')(x)
    x = Dropout(0.2)(x)
    x = Dense(64, activation='relu')(x)

    outputs = Dense(2, activation='softmax')(x)

    model = Model(inputs=inputs, outputs=outputs, name=f"KAN_{wavelet_name}")
    model.compile(optimizer=Adam(0.001),
loss='sparse_categorical_crossentropy', metrics=['accuracy'])
    return model

def run_complete_analysis(X_train, y_train, X_test, y_test):
    """
    Повний цикл: Аналіз -> Фільтрація -> Детекція -> Класифікація.
    """
    # 1. Енерго-ентропійний вибір вейвлета для активації KAN
    kan_wavelet = select_optimal_basis(X_train[0], ['haar', 'mexh', 'db2'])
    print(f"Оптимальний базис для KAN: {kan_wavelet}")

    # 2. Попередня обробка та стиснення db4
    X_train_reduced = apply_db4_preprocessing(X_train)
    X_test_reduced = apply_db4_preprocessing(X_test)
    print(f"Стиснення          завершено:          {X_train.shape[1]}          ->
{X_train_reduced.shape[1]}")
    # 3. Детекція ознак (для контролю якості сегментації)
    extractor = FeatureExtractor()
    sample_peaks = extractor.detect_qrs_complex(X_train_reduced[0])
    print(f"Детекція          точок          (приклад):          R={sample_peaks['R']},
Q={sample_peaks['Q']}, S={sample_peaks['S']}")
    # 4. Навчання моделі
    model = build_hybrid_kan_model(X_train_reduced.shape[1], kan_wavelet)
    model.fit(X_train_reduced, y_train, epochs=15, batch_size=64, verbose=1)
    # 5. Результати
    y_pred = np.argmax(model.predict(X_test_reduced), axis=1)
    print("\nЗвіт класифікації:")
    print(classification_report(y_test, y_pred))
    return model

# Запуск системи
# final_model = run_complete_analysis(X_train, y_train, X_test, y_test)

```

ДОДАТОК Г СПИСОК ПУБЛІКАЦІЙ ЗДОБУВАЧА

1. Shcherbakova G., Koshutina D. Development of a criterion for selecting the level of wavelet decomposition for QRS detection in electrocardiogram signals using energy and entropy. *Proceedings of Odessa Polytechnic University*. 2025. No. 1(71). P. 157–166. DOI: 10.15276/opu.1.71.2025.18. Видання включено до переліку наукових фахових видань України, категорія «Б».

2. Антощук С. Г., Щербакова Г. Ю., Кошутіна Д. В. Оцінка параметрів компонентів електроніки при відборі їх для апаратури відповідального призначення на основі кластеризації з вейвлет-обробкою та врахуванням обмежень. *Наукові праці Вінницького національного технічного університету*. 2025. Вип. 3. DOI: 10.31649/2307-5376-2025-3-27-36. Видання включено до переліку наукових фахових видань України, категорія «Б».

3. Shcherbakova G. Y., Koshutina D. V. Improving the performance of clustering with wavelet function by using inequality constraints. *Herald of Advanced Information Technology*. 2025. Vol. 8, No. 3. P. 277–287. DOI: 10.15276/hait.08.2025.17. Видання включено до переліку наукових фахових видань України, категорія «Б» та проіндексовано в Scopus (Q4).

4. Koshutina D. V. KAN-Type Neural Network Model for ECG Signal Analysis and Classification. *Proceedings of Odessa Polytechnic University*. 2025. No. № 2(72). P. 163-174. DOI: 10.15276/opu.2.72.2025.17. Видання включено до переліку наукових фахових видань України, категорія «Б».

ДОДАТОК Д ВІДОМОСТІ ПРО АПРОБАЦІЮ РЕЗУЛЬТАТІВ ДИСЕРТАЦІЙНОЇ РОБОТИ

1. Shcherbakova G., Antoshchuk S., Koshutina D., Sakhno K. Adaptive clustering for distribution parameter estimation in technical diagnostics. *12th International Conference on Applied Innovations in IT (ICAIIIT)*, Köthen, Germany, March 7, 2024. Vol. 12, No. 1. P. 123–127. DOI: 10.25673/115650. Видання проіндексовано у базі даних Scopus.

2. Antoshchuk S., Shcherbakova G., Kondratyev S., Koshutina D., Usov O. Wavelet transform based optimization method for three-dimensional computer vision. *Proceedings of the 12th International Conference «Information Control Systems & Technologies» (ICST 2024)*, Odesa, Ukraine, September 23–25, 2024. P. 471–482. Видання проіндексовано у базі даних Scopus.

3. Антощук С. Г., Щербакова Г. Ю., Кондратьєв С. Б., Кошутіна Д. В. Наближений метод оцінки глибини об'єктів на основі вейвлет-перетворення. *X Міжнародна науково-практична конференція «Інформатика. Культура. Техніка»*, Одеса, Україна, 26–27 вересня 2024 р. Том 1, № 1. С. 197–201.

4. Кошутіна Д. В., Сахно К. О., Щербакова Г. Ю. Використання вейвлет-перетворення при аналізі електрокардіограм. *Тези доповідей XXXIII Міжнародної науково-практичної конференції MicroCAD-2025*, Харків, 14–17 травня 2025 р. С. 765–766. DOI: 10.5281/zenodo.15520692.

5. Кошутіна Д. В., Щербакова Г. Ю. Автоматизований вибір рівня вейвлет-розкладу на основі енергії та ентропії для виявлення QRS-комплексів ЕКГ. *Матеріали XV Міжнародної наукової конференції «Modern Information Technology – 2025»*, Одеса, 15–16 травня 2025 р. С. 21–23. DOI: 10.5281/zenodo.15521809.

6. Koshutina D., Shcherbakova G., Antoshchuk S., Glava M. Improving the performance of wavelet transform optimization using inequality constraints. *The 13th IEEE International Conference on Intelligent Data Acquisition and Advanced Computing Systems: Technology and Applications (ICIDACS 2025)*, Gliwice, Poland, September 4–6, 2025. DOI: 10.1109/IDAACS68557.2025.11322357.

7. Кошутіна Д. В., Щербакова Г. Ю. Визначення інтенсивності відмов при відбракуванні виробів електронної техніки за допомогою завадостійкої кластеризації. *Proceedings of the 13th International Conference Information Control Systems & Technologies (ICST 2025)*, Odesa, Ukraine, September 24–26, 2025. P. 137–140.

8. Щербакова Г. Ю., Кошутіна Д. В., Сахно К. О. Оцінка параметрів надійності компонентів електроніки при відбракуванні за допомогою кластеризації з вейвлет-перетворенням. *Матеріали XI Міжнародної науково-практичної конференції «Інформатика. Культура. Техніка»*, Одеса, 16–17 жовтня 2025 р. DOI: 10.15276/ict.02.2025.02.

9. Світлана Антошук, Галина Щербакова, Сергій Кондратьєв, Дар'я Кошутіна, Олександр Усов. Метод оптимізації на основі вейвлет-перетворення для наближених методів оцінки глибини. *Інформаційні управляючі системи та технології (ІУСТ-Одеса-2024)*, м. Одеса, 23–25 вересня 2024 р. С. 123–127.

10. Shcherbakova G., Antoshchuk S., Koshutina D., Sakhno K., Kondratiev S. Adaptive Clustering for Distribution Parameter Estimation in Technical Diagnostics. *Applied Innovations in Information and Communication Technology. ICAIIT 2024. Lecture Notes in Networks and Systems*, Vol. 1338. Springer, Cham, 2025. P. 379–392. DOI: 10.1007/978-3-031-89296-7_19. (Scopus).

11. Кошутіна Д. В., Щербакова Г. Ю., Антошук С. Г. Удосконалення пошуку параметрів електрокардіограм за допомогою оптимізації на основі вейвлет-функції. *Колективна монографія «Information Control Systems and Intelligent Technologies. Achievements and Applications»*. Lviv–Torun: Liha-Pres, 2025. С. 383–401. DOI: 10.36059/978-966-397-538-2.