

НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ «ОДЕСЬКА ПОЛІТЕХНІКА»
МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ

НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ «ОДЕСЬКА ПОЛІТЕХНІКА»
МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ

*Кваліфікаційна наукова
праця на правах рукопису*

ШУНІН ОЛЕКСАНДР ЮРІЙОВИЧ

УДК 004.93

ДИСЕРТАЦІЯ

**НЕЙРОМЕРЕЖЕВІ МЕТОДИ ВИЯВЛЕННЯ АНОМАЛІЙ У ПОЛЯХ
ФІЗИЧНИХ ВЕЛИЧИН**

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.

 О. Ю. Шунін

Науковий керівник:

Маслов Олег Вікторович, доктор технічних наук, доцент

Одеса – 2026

АНОТАЦІЯ

Шунін О. Ю. Нейромережеві методи виявлення аномалій у полях фізичних величин. – Кваліфікаційна наукова праця на правах рукопису.

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

Дисертаційну роботу присвячено розробленню нейромережевих методів виявлення, класифікації та локалізації аномалій у полях фізичних величин на основі узгодженого просторово-часового подання різнорідних сенсорних даних БПЛА-платформи. Науковий зміст роботи полягає у створенні такого нейромережевого підходу, за якого різнорідні вимірювальні потоки перетворюються на структуровані вхідні дані нейронних мереж, придатні для достовірного виявлення аномалій, їх класифікації та просторової локалізації.

У вступі обґрунтовано актуальність дисертаційної роботи, що пов'язана з недостатньою розробленістю нейромережевих методів виявлення аномалій у полях фізичних величин за різнорідними сенсорними даними. Показано, що застосування нейронних мереж є перспективним для задач, у яких аномалія не спостерігається безпосередньо, а проявляється через слабо виражені, нелінійні та зашумлені відхилення просторового, часового або просторово-часового розподілу фізичного поля від фонового стану.

Наукова проблема дисертаційного дослідження полягає у недостатній розробленості нейромережевих методів виявлення аномалій у полях фізичних величин за різнорідними сенсорними даними. Для коректного навчання та застосування нейронних мереж такі дані мають бути подані у вигляді узгодженого просторово-часового і структурованого інформаційного представлення, оскільки сенсорні потоки різної фізичної природи формуються з різними частотами дискретизації, у різних форматах і системах координат. Визначено, що ефективність нейромережевого пошуку, виявлення, класифікації

та локалізації аномалій залежить не лише від архітектури нейронної мережі, а й від якості формування її вхідних даних.

У вступі визначено мету, об'єкт, предмет, задачі та методи дослідження; наведено наукову новизну й практичне значення отриманих результатів; висвітлено особистий внесок здобувача, відомості про апробацію, публікації та структуру дисертаційної роботи.

Дисертаційне дослідження виконано у межах проєктів НФДУ № 2023.04/0161 (ДР 0124U003664), СШ/5-2024 від 28.11.2024 (ДР 0124U004854) та НДР 723-43 (ДР 0126U001468).

У першому розділі проаналізовано сучасний стан проблеми нейромережевого виявлення аномалій у полях фізичних величин, розглянуто фізичні принципи роботи імпульсних металошукачів, TMR-магнітометрів, мультиспектральних камер і георадарів.

Показано, що імпульсно-індукційний канал є чутливим до електропровідних включень, магнітометричний – до магнітних неоднорідностей, георадарний – до підповерхневої структури середовища, а мультиспектральні дані можуть містити непрямі ознаки стану поверхні. Встановлено, що окремі сенсорні канали мають різну інформативність, різні джерела похибок і різні просторово-часові характеристики. Їх незалежне використання або просте поєднання результатів вимірювання не забезпечує достатньої достовірності пошуку, низького рівня хибних тривог і необхідної точності локалізації. Головним стримувальним чинником для застосування нейронних мереж визначено відсутність узгодженого подання різнорідних вимірювань, придатного для навчання та застосування нейромережевих моделей.

У другому розділі дисертаційної роботи розв'язано задачу підготовки різнорідних сенсорних даних до нейромережевого виявлення аномалій. Описано мультисенсорну БПЛА-платформу, яка забезпечує синхронізоване збирання даних різної фізичної природи та їх подальше приведення до єдиного просторово-часового подання. Показано, що відмінності у частотах дискретизації, форматах сигналів, системах координат і фізичній природі

вимірювань потребують часового, просторового та структурного узгодження до моменту подання даних на вхід нейронних мереж.

Удосконалено метод часового узгодження різнорідних вимірювальних потоків мультисенсорної БПЛА-платформи, який базується на апаратній прив'язці сенсорних каналів до спільного опорного сигналу. Запропонований метод забезпечує просторовий еквівалент похибки синхронізації 2–4 см та створює необхідні умови для формування коректних вхідних даних для нейронних мереж виявлення аномалій.

Вперше розроблено чотиривимірну модель поля аномалій $S(c, X, Y, t)$ для даних імпульсної індукції, яка формалізує залежність сигналу від параметрів каналу приймання, просторових координат точки зондування та часу релаксації відгуку. На відміну від табличного запису окремих вимірювань, запропонована модель забезпечує формування структурованого подання вхідних даних нейронних мереж виявлення аномалій.

Удосконалено метод просторової прив'язки мультисенсорних вимірювань, який поєднує автономну кінематику реального часу з кількісним обґрунтуванням точності геоприв'язки. Досягнута просторова похибка 1–8 см забезпечує формування геометрично узгодженого тензорного подання даних та формування вхідних даних для нейронних мереж виявлення аномалій. На основі узгоджених вимірювань сформовано 14-канальне тензорне подання $T(x, y, k)$ шляхом інтерполяції різнорідних потоків на спільну координатну сітку 10×10 см. Таке подання є уніфікованим багатоканальним входом для нейромережевого виявлення і класифікації аномалій.

У третьому розділі дисертаційної роботи розроблено нейромережевий метод виявлення та класифікації аномалій у полях фізичних величин за тензорним поданням мультисенсорних даних. Геометрично узгоджене тензорне подання $T(x, y, k)$ використано як спільний багатоканальний вхід для ансамблю одновимірних згорткових нейронних мереж і стекінгового метакласифікатора. Одновимірні згорткові нейронні мережі обробляють часові розгортки окремих

каналів, а стекінговий метакласифікатор поєднує результати окремих гілок для прийняття узагальненого рішення щодо наявності аномалії.

Удосконалений нейромережевий метод, на відміну від підходів, орієнтованих на незалежний аналіз окремих сенсорних каналів, забезпечує спільне використання даних різної фізичної природи для пошуку аномалій у темпі надходження вимірювань. На незалежних вибірках отримано $Pd = 0,965$ та $F1 = 0,952$; час роботи нейромережевого класифікатора становить менш ніж 4 мс на вектор даних імпульсної індукції. Це підтверджує придатність запропонованого методу для застосування в умовах наближеного до реального часу оброблення мультисенсорних даних.

У цьому ж розділі набув подальшого розвитку підхід до побудови фізично-інформованих нейронних мереж. Запропоновано включення до функції втрат регуляризаційних складових, що відображають структурні інваріанти сенсорних сигналів, задані дипольною моделлю магнітної аномалії та моделями багатоекспоненційного затухання вихрових струмів. Це підвищує узагальнювальну здатність нейронних мереж пошуку, виявлення, класифікації та локалізації аномалій за умов обмеженої розміченої вибірки.

У четвертому розділі дисертаційної роботи розглянуто формування навчальних вибірок і планування місій для нейромережевого виявлення аномалій. Обґрунтовано структуру навчального зразка, використання лабораторних і польових джерел даних, нормування зразків, формування складних негативних прикладів, балансування класів і просторово коректне розбиття вибірки. Запропоновано стратегію поєднання лабораторного навчання та польового донавчання, що дає змогу враховувати доменний зсув між контрольованими лабораторними вимірюваннями і реальними польовими даними.

Розглянуто застосування фізично коректної аугментації та синтетичних даних, сформованих із використанням цифрового двійника. Показано, що частка синтетичних даних близько 25 % у навчальній вибірці забезпечує приріст $F1$ на 0,020. Розроблено дворівневу схему планування місії БПЛА-платформи, за якої

попередній обліт визначає зони інтересу, а детальне сканування виконується лише в цих зонах. Такий підхід дає змогу скоротити площу детального обстеження на 56,3 % без втрати цільової інформативності для задачі пошуку аномалій.

У п'ятому розділі дисертаційної роботи описано програмну реалізацію та експериментальну перевірку нейромережових методів виявлення аномалій. Реалізовано програмні засоби оброблення РІ-сигналів імпульсного металошукача, магнітометричних даних, георадарних даних, мультисенсорного злиття, формування навчальних вибірок і побудови інтегральної карти ризику. Показано, що імпульсно-індукційний, магнітометричний і георадарний канали виконують взаємодоповнювальні функції, а їх інтеграція в єдиному нейромережевому конвеєрі підвищує достовірність виявлення аномалій.

Польові випробування підтвердили можливість локалізації аномалій із сантиметровою точністю просторової прив'язки. Синхронізоване збирання даних виконується на борту БПЛА-платформи, а оброблення не потребує наземної інфраструктури корекції. Відкритий набір лабораторних і польових вимірювань трикотушкового імпульсного металошукача опубліковано в репозиторії github.com/op-uav-lab/soil-monitor-mlp.

Наукова новизна дисертаційної роботи полягає в отриманні таких результатів:

- удосконалено нейромережовий метод виявлення і класифікації аномалій у полях фізичних величин за мультисенсорними даними БПЛА-платформи, який використовує геометрично узгоджене тензорне подання $T(x, y, k)$ як спільний багатоканальний вхід для ансамблю одновимірних згорткових нейронних мереж і стекінгового метакласифікатора;

- вперше розроблено чотиривимірну модель поля аномалій $S(c, X, Y, t)$ для даних імпульсної індукції, яка формалізує залежність сигналу від параметрів каналу приймання, просторових координат точки зондування та часу релаксації відгуку;

- удосконалено метод часового узгодження різнорідних вимірювальних потоків мультисенсорної БПЛА-платформи, який базується на апаратній прив'язці сенсорних каналів до спільного опорного сигналу, що забезпечує просторовий еквівалент похибки синхронізації 2–4 см;

- удосконалено метод просторової прив'язки мультисенсорних вимірювань, який поєднує автономну кінематику реального часу з кількісним обґрунтуванням точності геоприв'язки, що забезпечує просторову похибку 1–8 см та геометрично узгоджене тензорне подання даних;

- набув подальшого розвитку підхід до побудови фізично-інформованих нейронних мереж шляхом включення до функції втрат регуляризаційних складових, що відображають структурні інваріанти сенсорних сигналів, задані дипольною моделлю магнітної аномалії та моделями багатоекспоненційного затухання вихрових струмів.

Практичне значення результатів полягає у можливості застосування розроблених нейромережових методів виявлення аномалій у задачах гуманітарного розмінування, обстеження потенційно небезпечних територій, дистанційного моніторингу ґрунтів, геофізичного обстеження та екологічного контролю територій, що зазнали впливу бойових дій або техногенного навантаження. Розроблені методи часового і просторового узгодження сенсорних потоків, модель $S(c, X, Y, t)$ тензорне подання $T(x, y, k)$ та ансамблевий нейромережовий класифікатор забезпечують виявлення аномалій у темпі надходження вимірювань.

Результати дисертаційної роботи використано під час виконання проєкту НФДУ № 2023.04/0161, грантового науково-технічного проєкту СШ/5-2024 від 28.11.2024 та НДР 723-43. Основні результати дисертації опубліковано у десяти наукових працях, серед яких колективна монографія, одна стаття у виданні, що індексується наукометричною базою Scopus, одна стаття у науковому періодичному виданні іншої держави, дві статті у фахових виданнях України категорії «Б» та матеріали наукових конференцій.

Ключові слова: нейронні мережі, глибоке навчання, згорткова нейронна мережа, фізично-інформована нейронна мережа, ансамблеве навчання, класифікація аномалій, злиття даних, різноманітні дані, навчальна вибірка, мультисенсорна БПЛА-платформа, інтернет речей, інтелектуальні системи, інформаційні технології, індустрія 4.0–5.0, дистанційне зондування ґрунту, гуманітарне розмінування.

СПИСОК ОПУБЛІКОВАНИХ ПРАЦЬ ЗА ТЕМОЮ ДИСЕРТАЦІЇ

Наукові праці, в яких опубліковані основні наукові результати дисертації:

1. Інформаційне забезпечення дистанційного моніторингу забруднення ґрунтів повоєнних територій : монографія / Антощук С. Г., Дрозд М. О., Маслов О. В., Галчонков О. М., Кондратьєв С. Б., Шунін О. Ю., Баранов О. М., Щербакова Г. Ю., Кошутіна Д. В., Баськов І. М., Костенко В. Л. ; за ред. С. Г. Антощук. Одеса, 2026. ISBN 978-617-8814-10-6. DOI: 10.5281/zenodo.20355627. *Колективна монографія.*

<https://zenodo.org/records/20355627>

2. Shunin O. Y., Maslov O. V. Information model of remote sensing of soil. Herald of Advanced Information Technology. 2025. Vol. 8, No. 3. P. 352–365. DOI: 10.15276/hait.08.2025.23. *Видання індексується наукометричною базою Scopus; включено до переліку наукових фахових видань України.*

<https://doi.org/10.15276/hait.08.2025.23>

3. Дрозд М. О., Дрозд Ю. В., Шунін О. Ю. Ефективність навчання нейронної мережі на формованих наборах зображень з заданим рівнем різноманіття. Наука і техніка сьогодні. 2025. № 9(50). С. 1104–1123. DOI: 10.52058/2786-6025-2025-9(50)-1104-1123. *Видання включено до переліку наукових фахових видань України, категорія «Б».*

[https://doi.org/10.52058/2786-6025-2025-9\(50\)-1104-1123](https://doi.org/10.52058/2786-6025-2025-9(50)-1104-1123)

4. Шунін О. Ю., Маслов О. В. Алгоритми та методи злиття мультисенсорних даних при виявленні аномалій з використанням БПЛА. Наука

і техніка сьогодні. 2026. № 4(58). С. 4832–4854. DOI: 10.52058/2786-6025-2026-4(58)-4832-4854. *Видання включено до переліку наукових фахових видань України, категорія «Б».*

[https://doi.org/10.52058/2786-6025-2026-4\(58\)-4832-4854](https://doi.org/10.52058/2786-6025-2026-4(58)-4832-4854)

5. *Shunin O.*, Maslov O., Galchonkov O. Building a basic drone equipment set for conducting research to detect anomalies in soil. International Science Journal of Engineering & Agriculture. 2025. Vol. 4, No. 5. P. 13–26. DOI: 10.46299/j.isjea.20250405.02. *Наукове періодичне видання іншої держави.*

<https://doi.org/10.46299/j.isjea.20250405.02>

Наукові праці, які засвідчують апробацію матеріалів дисертації:

6. Galchonkov O., Baranov O., Antoshchuk S., Maslov O., Babilunga O., *Shunin O.* Using stacked ensemble classifiers to speed up object recognition in images for mine detection drones. 2024 IEEE 7th International Conference on Actual Problems of Unmanned Aerial Vehicles Development (APUAVD). Київ, 2024. P. 262–265. DOI: 10.1109/APUAVD64488.2024.10765855. *Матеріали конференції індексуються наукометричною базою Scopus.*

<https://doi.org/10.1109/APUAVD64488.2024.10765855>

7. Antoshchuk S. G., Drozd M. O., Maslov O. V., *Shunin O. Y.* Multi-sensor UAV mission planning framework for environmental monitoring and humanitarian demining. Proceedings of the Artificial Intelligence Technologies and Aerospace Issues III International Scientific-Practical Conference. Baku, Azerbaijan, July 8–9, 2025. Proceedings of an international scientific conference.

8. Drozd M., Drozd Y., *Shunin O.* Formation of synthetic image datasets for training neural network. Problems of modern education and old technologies : abstracts of II International scientific and practical conference. Сарагоса, Іспанія, 8–10 вересня 2025 р. P. 63–69. *Матеріали міжнародної наукової конференції.*

9. Maslov O., Antoshchuk S., Galchonkov O., Mokritskiy V., *Shunin O.* A digital twin of a landmine detector drone based on the prompt gamma neutron activation analysis method. Матеріали XXVII Міжнародної конференції

«Автоматика 2024», 20–22 листопада 2024 р. Дніпро (Україна). С. 42. Матеріали міжнародної наукової конференції

10. Маслов О. В., *Шунін О. Ю.* Використання дронів для забезпечення безпеки сільськогосподарських земель. Всеукраїнський науково-практичний форум «Штучний інтелект у тваринництві: майбутнє сьогодні», 9 травня 2025 р. Київ. Матеріали Всеукраїнського науково-практичного форуму.

ABSTRACT

Shunin O. Y. Neural Network Methods for Anomaly Detection in Fields of Physical Quantities. – Qualifying scientific work on the rights of a manuscript.

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

The thesis is devoted to the development of neural network methods for the detection, classification, and localization of anomalies in fields of physical quantities based on an aligned spatio-temporal representation of heterogeneous sensor data from a UAV platform. The scientific contribution of this dissertation lies in developing a neural network approach in which heterogeneous measurement streams are transformed into structured neural network input data suitable for reliable anomaly detection, classification, and spatial localization.

The introduction substantiates the relevance of the dissertation, which is related to the insufficient development of neural network methods for detecting anomalies in fields of physical quantities using heterogeneous sensor data. It is shown that neural networks are a promising tool for tasks in which an anomaly is not observed directly, but manifests itself through weakly expressed, nonlinear, and noisy deviations of the spatial, temporal, or spatio-temporal distribution of a physical field from its background state.

The scientific problem of the dissertation lies in the insufficient development of neural network methods for anomaly detection in fields of physical quantities using heterogeneous sensor data. For correct training and application of neural networks, such data must be represented as an aligned spatio-temporal structured representation, since sensor streams of different physical nature are formed with different sampling rates, in different formats, and in different coordinate systems. It is determined that the effectiveness of neural network-based anomaly search, detection, classification, and localization depends not only on the neural network architecture, but also on the quality of forming its input data.

The introduction defines the aim, object, subject, tasks, and research methods; presents the scientific novelty and practical significance of the obtained results; and provides information on the applicant's personal contribution, conference presentations, publications, and the structure of the dissertation.

The dissertation was carried out within NRFU project No. 2023.04/0161 (state reg. No. 0124U003664), R&D project SS/5-2024 dated November 28, 2024 (state reg. No. 0124U004854), and R&D project 723-43 (state reg. No. 0126U001468).

The first chapter analyses the current state of neural network-based anomaly detection in fields of physical quantities, covering the physical principles of pulse induction metal detectors, TMR magnetometers, multispectral cameras, and ground-penetrating radar.

Individual channels (PI, magnetometric, GPR, multispectral) have complementary sensitivities but different informativeness, error sources, and spatio-temporal characteristics; their independent use does not ensure sufficient detection reliability or localization accuracy. The key limiting factor is identified as the absence of an aligned spatio-temporal representation of heterogeneous measurements suitable for training and applying neural network models.

The second chapter addresses preparation of heterogeneous sensor data for neural network-based anomaly detection. A multisensor UAV platform is described providing synchronized data acquisition and unified spatio-temporal representation; temporal, spatial, and structural alignment are required before data are supplied to neural networks.

A method for temporal alignment of heterogeneous measurement streams of a multisensor UAV platform has been improved. The method is based on hardware synchronization of sensor channels to a common reference signal. The proposed method provides a spatial equivalent of synchronization error of 2–4 cm and creates the necessary conditions for forming correct input data for anomaly detection neural networks.

For the first time, a four-dimensional anomaly field model $S(c, X, Y, t)$ for pulse induction data has been developed. The model formalizes the dependence of the signal

on the parameters of the receiving channel, the spatial coordinates of the measurement location, and the response relaxation time. In contrast to a tabular record of separate measurements, the proposed model provides the formation of a structured representation of input data for anomaly detection neural networks.

A method for spatial georeferencing of multisensor measurements has been improved. The method combines autonomous real-time kinematics with a quantitative justification of georeferencing accuracy. The achieved spatial error of 1–8 cm provides the formation of a geometrically aligned tensor representation of data and the formation of input data for anomaly detection neural networks. Based on the aligned measurements, a 14-channel tensor representation $\mathbf{T}(x, y, k)$ was formed by interpolating heterogeneous streams onto a common 10×10 cm coordinate grid. This representation is a unified multi-channel input for neural network-based anomaly detection and classification.

The third chapter develops a neural network method for detecting and classifying anomalies using a tensor representation of multisensor data. The aligned $\mathbf{T}(x, y, k)$ serves as a common multi-channel input for an ensemble of 1D convolutional neural networks; the stacking meta-classifier combines branch outputs to make a generalized decision.

The improved neural network method, in contrast to approaches focused on independent analysis of separate sensor channels, provides joint use of data of different physical nature for anomaly search in near real-time. Independent test samples showed $Pd = 0.965$ and $F1 = 0.952$; the runtime of the neural network classifier is less than 4 ms per pulse induction data vector. This confirms the suitability of the proposed method for use under conditions close to real-time processing of multisensor data.

In the same chapter, the PINN approach has been further developed by introducing loss-function regularization terms based on the dipole magnetic anomaly model and multi-exponential eddy-current decay, improving generalization under limited labelled data.

The fourth chapter considers training dataset formation and mission planning. Training sample structure, normalization, hard negative examples, class balancing, and

spatially correct dataset splitting are substantiated; a laboratory-plus-field fine-tuning strategy is proposed to address domain shift.

The use of physically correct augmentation and synthetic data generated using a digital twin is considered. It is shown that a share of synthetic data of about 25% in the training dataset provides an F1 increase of 0.020. A two-level mission planning scheme for the UAV platform has been developed, in which a preliminary flight determines areas of interest, and detailed scanning is performed only within these areas. This approach makes it possible to reduce the detailed survey area by 56.3% without losing the target informativeness for the anomaly search task.

The fifth chapter describes software implementation and experimental verification. Software tools for pulse induction, magnetometric, and GPR data processing and multisensor fusion have been implemented. It is shown that the PI, magnetometric, and GPR channels perform complementary functions, and their integration within a unified neural network pipeline increases detection reliability.

Field tests confirmed the possibility of localizing anomalies with centimetre-level spatial referencing accuracy. Synchronized data acquisition is performed on board the UAV platform, and data processing does not require ground-based correction infrastructure. The developed methods were implemented in the practical activities of Spetsmontazh LLC and OM Energy LLC. An open set of laboratory and field measurements of a three-coil pulse induction metal detector was published in the repository github.com/op-uav-lab/soil-monitor-mlp.

The scientific novelty of the dissertation consists in obtaining the following results:

- the neural network method for anomaly detection and classification in fields of physical quantities using multisensor UAV data has been improved, using the geometrically aligned tensor $\mathbf{T}(x, y, k)$ as a common input for a 1D-CNN ensemble and stacking meta-classifier;
- for the first time, a four-dimensional anomaly field model $\mathbf{S}(c, X, Y, t)$ for pulse induction data has been developed, formalizing signal dependence on receiving channel, spatial coordinates, and response relaxation time;

- the method for temporal alignment of heterogeneous multisensor UAV measurement streams has been improved, based on hardware synchronization to a common reference signal, providing a spatial synchronization error of 2–4 cm;
- the method for spatial georeferencing of multisensor measurements has been improved, combining autonomous real-time kinematics with quantitative accuracy justification, achieving a spatial error of 1–8 cm;
- the PINN approach has been further developed by introducing loss-function regularization terms reflecting the dipole magnetic anomaly model and multi-exponential eddy-current decay, improving generalization under limited labelled data.

The practical significance of the obtained results lies in the possibility of applying the developed neural network methods for anomaly search, detection, classification, and localization in the tasks of humanitarian demining, primary survey of potentially hazardous territories, remote soil monitoring, geophysical survey, and environmental control of territories affected by hostilities or technogenic impact. The developed methods for temporal and spatial alignment of sensor streams, the anomaly field model $S(c, X, Y, t)$, the multisensor tensor representation $T(x, y, k)$, and the ensemble neural network classifier provide the formation of correct input data for neural networks and anomaly detection at the measurement rate.

The results of the dissertation were used during the implementation of the NRFU project No. 2023.04/0161, the grant-funded R&D project SS/5-2024 dated November 28, 2024, and R&D project 723-43. The main results of the dissertation were published in ten scientific works, including a collective monograph, one article in a journal indexed by the Scopus scientometric database, one article in a foreign scientific periodical, two articles in Ukrainian category “B” professional journals, and conference proceedings.

Keywords: neural networks, deep learning, convolutional neural network (CNN), physics-informed neural network (PINN), ensemble learning, anomaly classification, data fusion, heterogeneous data, training dataset, multisensor UAV platform, Internet of Things (IoT), intelligent systems, information technologies, Industry 4.0–5.0, remote soil sensing, humanitarian demining.

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. Information support for remote monitoring of soil contamination in post-war territories: monograph / Antoshchuk S. G., Drozd M. O., Maslov O. V., Galchonkov O. M., Kondratiev S. B., *Shunin O. Y.*, Baranov O. M., Shcherbakova G. Y., Koshutina D. V., Baskov I. M., Kostenko V. L. ; ed. by S. G. Antoshchuk. Odesa, 2026. ISBN 978-617-8814-10-6. DOI: 10.5281/zenodo.20355627 (in Ukrainian). *Collective monograph.*

<https://zenodo.org/records/20355627>

2. *Shunin O. Y.*, Maslov O. V. Information model of remote sensing of soil. Herald of Advanced Information Technology. 2025. Vol. 8, No. 3. P. 352–365. DOI: 10.15276/hait.08.2025.23. *The journal is indexed by the Scopus database; included in the list of scientific professional publications of Ukraine.*

<https://doi.org/10.15276/hait.08.2025.23>

3. Drozd M. O., Drozd Y. V., *Shunin O. Yu.* Effectiveness of neural network training on formed image sets with a given level of diversity. Science and Technology Today. 2025. No. 9(50). P. 1104–1123. DOI: 10.52058/2786-6025-2025-9(50)-1104-1123 (in Ukrainian). *The publication is included in the list of scientific professional publications of Ukraine, category “B”.*

[https://doi.org/10.52058/2786-6025-2025-9\(50\)-1104-1123](https://doi.org/10.52058/2786-6025-2025-9(50)-1104-1123)

4. *Shunin O. Y.*, Maslov O. V. Algorithms and methods of multisensor data fusion for anomaly detection using UAVs. Science and Technology Today. 2026. No. 4(58). P. 4832–4854. DOI: 10.52058/2786-6025-2026-4(58)-4832-4854 (in Ukrainian). *The publication is included in the list of scientific professional publications of Ukraine, category “B”.*

[https://doi.org/10.52058/2786-6025-2026-4\(58\)-4832-4854](https://doi.org/10.52058/2786-6025-2026-4(58)-4832-4854)

5. *Shunin O.*, Maslov O., Galchonkov O. Building a basic drone equipment set for conducting research to detect anomalies in soil. *International Science Journal of Engineering & Agriculture*. 2025. Vol. 4, No. 5. P. 13–26. DOI: 10.46299/j.isjea.20250405.02. *Foreign scientific periodical*.

<https://doi.org/10.46299/j.isjea.20250405.02> *Scientific works certifying the conference presentations of the dissertation materials:*

6. Galchonkov O., Baranov O., Antoshchuk S., Maslov O., Babilunga O., *Shunin O.* Using stacked ensemble classifiers to speed up object recognition in images for mine detection drones. 2024 IEEE 7th International Conference on Actual Problems of Unmanned Aerial Vehicles Development (APUAVD). Kyiv, 2024. P. 262–265. DOI: 10.1109/APUAVD64488.2024.10765855. *The conference proceedings are indexed by the Scopus database*.

<https://doi.org/10.1109/APUAVD64488.2024.10765855>

7. Antoshchuk S. G., Drozd M. O., Maslov O. V., *Shunin O. Y.* Multi-sensor UAV mission planning framework for environmental monitoring and humanitarian demining. Proceedings of the Artificial Intelligence Technologies and Aerospace Issues III International Scientific-Practical Conference. Baku, Azerbaijan, July 8–9, 2025. Proceedings of an international scientific conference.

8. Drozd M., Drozd Y., *Shunin O.* Formation of synthetic image datasets for training neural network. Problems of modern education and old technologies : abstracts of the II International scientific and practical conference. Zaragoza, Spain, September 8–10, 2025. P. 63–69. *Proceedings of an international scientific conference*.

9. Maslov O., Antoshchuk S., Galchonkov O., Mokritskiy V., *Shunin O.* A digital twin of a landmine detector drone based on the prompt gamma neutron activation analysis method. Proceedings of the XXVII International Conference “Automatics 2024”, November 20–22, 2024. Dnipro (Ukraine). P. 42. Proceedings of an international scientific conference.

10. Maslov O. V., *Shunin O. Y.* The use of drones for ensuring the safety of agricultural lands. All-Ukrainian Scientific and Practical Forum “Artificial Intelligence

in Animal Husbandry: The Future Today”, May 9, 2025. Kyiv. Proceedings of an All-Ukrainian Scientific and Practical Forum.

ЗМІСТ

Перелік умовних позначень	24
Вступ.....	26
Розділ 1 Аналіз проблеми виявлення аномалій у полях фізичних величин та постановка задачі дослідження.....	34
1.1 Виявлення аномалій у полях фізичних величин як науково-прикладна задача	34
1.1.1 Практичний запит і актуальність задачі	34
1.1.2 Аномалії у полях фізичних величин як об'єкт виявлення та аналізу.....	35
1.1.3 Формалізація основних понять та реальні умови задачі.....	38
1.1.4 Спектр прикладних задач та суміжні застосування	40
1.2 Аналіз методів виявлення аномалій та їх обмежень	42
1.2.1 Ручні, механізовані та кінологічні методи	42
1.2.2 Електромагнітні та магнітометричні методи	43
1.2.3 Оптичні, мультиспектральні та суміжні підходи до виявлення аномалій .	44
1.2.4 Мультисенсорні системи та злиття даних	45
1.3 Аналіз застосування методів штучного інтелекту та нейронних мереж у задачах виявлення аномалій.....	50
1.3.1 Класичне машинне навчання та ансамблеві методи	52
1.3.2 Глибокі нейронні мережі для аналізу аномалій у фізичних полях	54
1.3.3 Мережі з тренованими активаціями та гібридні архітектури MLP-KAN ..	56
1.3.4 Методи попередньої обробки з використанням ШІ	57
1.4 Шляхи удосконалення та постановка задачі дослідження	60
1.5 Висновки до першого розділу.....	63
Розділ 2 Злиття різнорідних сенсорних даних для нейромережевого виявлення аномалій у полях фізичних величин	66
2.1 Постановка задачі мультисенсорного злиття.....	66
2.2 Розроблена мультисенсорна БПЛА-платформа та джерела даних.....	67
2.2.1 Трикотушковий імпульсний металошукач.....	69
2.2.2 Трьохканальний TMR-магнітометр.....	72
2.2.3 Мультиспектральна камера.....	74

2.2.4 Георадар як перспективний канал.....	75
2.3 Проблема різномірності даних та архітектура злиття	76
2.4 Розроблена система синхронізації вимірювань у часі	77
2.5 Розроблена система просторової прив'язки	79
2.6 Інтерполяція на єдину координатну сітку	82
2.7 Запропонована архітектура злиття: вибір рівня та обґрунтування.....	86
2.7.1 Злиття на рівні сигналів.....	86
2.7.2 Злиття на рівні ознак.....	86
2.7.3 Злиття на рівні рішень	87
2.7.4 Обґрунтування обраної гібридної архітектури	88
2.8 Розроблений конвеєр обробки РІ-даних: від сирого сигналу до входу нейронної мережі	89
2.8.1 Чотиривимірна модель сирих даних	91
2.8.2 Розроблена процедура віднімання фону та нормалізації.....	93
2.8.3 Формування різницевого каналів як внутрішньосенсорне злиття	93
2.8.4 Розроблене енергетичне подання та двовимірні карти	94
2.9 Польова апробація конвеєра на відкритому наборі даних.....	95
2.10 Узагальнена декомпозиція сигналу та формування входу нейронної мережі	95
2.11 Метрики якості та їх зв'язок з архітектурою злиття.....	96
2.11.1 Обрані метрики та їх обґрунтування.....	97
2.11.2 Розроблений підхід до функції втрат	98
2.11.3 Зв'язок метрик з рівнями злиття	99
2.12 Карта ризику як кінцевий інформаційний продукт	100
2.13 Позиціонування розробленої системи серед існуючих рішень.....	101
2.14 Розроблена інформаційна модель дистанційного моніторингу ґрунту.....	103
2.14.1 Рівень збору даних	104
2.14.2 Рівень передачі даних	105
2.14.3 Рівень попередньої обробки.....	106
2.14.4 Рівень злиття та аналізу.....	107
2.14.5 Рівень прийняття рішень	107

2.15 Формалізація задачі виявлення аномалій у мультисенсорному просторі.	108
2.15.1 Задача виявлення як перевірка гіпотез	108
2.15.2 Задача локалізації як регресія координат	109
2.15.3 Мультикласова задача та її складність	109
2.15.4 Підсумковий конвеєр: від сенсора до рішення	110
2.16 Узагальнена постановка задачі дисертаційного дослідження.....	111
2.17 Відкриті проблеми та напрямки подальших досліджень.....	113
2.18 Висновки до другого розділу	116
Розділ 3 Нейромережові методи виявлення та класифікації аномалій за мультисенсорними даними	120
3.1 Вимоги до нейромережових методів та вибір базових архітектур	120
3.2 Одновимірна згорткова мережа для класифікації та локалізації за РІ-сигналами	126
3.3 Ансамблевий класифікатор зі стекінгом	132
3.4 Архітектура мультисенсорного злиття гілок та адаптивне зважування каналів	140
3.5 Фізично-інформовані нейронні мережі	143
3.6 Особливості реалізації нейромережових методів у реальному часі	148
3.7 Висновки до третього розділу.....	154
Розділ 4 Формування навчальних вибірок та планування місій для нейромережевого виявлення аномалій	157
4.1 Планування місії та виділення зон інтересу.....	157
4.1.1 Оглядова розвідка та виділення зон інтересу.....	157
4.1.2 Детальне мультисенсорне сканування.....	157
4.1.3 Оптимізація маршрутів.....	163
4.1.4 Метадані місії	166
4.2 Формування навчальної вибірки	169
4.2.1 Структура зразка	169
4.2.2 Лабораторне джерело даних	171
4.2.3 Польове джерело та відкритий набір даних	173

4.2.4 Нормування зразків.....	174
4.2.5 Складні негативні приклади та балансування класів.....	177
4.2.6 Просторово коректне розбиття вибірки.....	179
4.2.7 Стратегія поєднання джерел.....	182
4.2.8 Підготовка серій вимірювань та вилучення артефактних кадрів.....	183
4.3 Аугментація та синтетичні дані.....	185
4.3.1 Принцип фізичної обґрунтованості.....	185
4.3.2 Аугментації РІ-каналу.....	187
4.3.3 Аугментації оптичного каналу.....	188
4.3.4 Кількісний ефект керованого розширення.....	188
4.3.5 Цифровий двійник вимірювального тракту.....	189
4.3.6 Контроль достовірності синтетичних даних.....	192
4.4 Доменний зсув і стратегія «лабораторне навчання – польове донавчання».	193
4.4.1 Формалізація проблеми.....	193
4.4.2 Джерела зсуву в розглядуваній системі.....	194
4.4.3 Фізичні механізми зсуву за каналами.....	194
4.4.4 Стратегія подолання.....	195
4.4.5 Протокол донавчання.....	196
4.4.6 Моніторинг моделей в експлуатації.....	197
4.5 Порівняльний аналіз з відкритим набором MineInsight.....	199
4.6 Формат даних та інтеграція з геоінформаційними системами.....	200
4.6.1 Формати зберігання і структура запису.....	200
4.6.2 Геоінформаційні продукти та атрибутика аномалій.....	201
4.7 Висновки до четвертого розділу.....	202
Розділ 5 програмна реалізація та експериментальна перевірка нейромережових методів виявлення аномалій за мультисенсорними даними.....	205
5.1 Реалізація нейромережового аналізу РІ-сигналів імпульсного міношукача	205
5.1.1 Експериментальна перевірка на відкритому наборі даних.....	211
5.2 Реалізація аналізу магнітометричних даних.....	217
5.3 Реалізація аналізу георадарних даних.....	225

5.4 Реалізація мультисенсорного злиття даних.....	231
5.5 Висновки до п'ятого розділу	236
Висновки	239
Список використаних джерел.....	243
Додаток А Список публікацій здобувача за темою дисертації	253
Додаток Б АКТ випробування результатів дисертаційного дослідження на ТОВ ВП «Спецмонтаж».....	256
Додаток В Довідка про впровадження результатів дисертаційної роботи ТОВ «ОМ Енерджи»	258
Додаток Г Лістинг програми підрозділу 5.1.....	260
Додаток Д Лістинг програми підрозділу 5.2	268
Додаток Е Лістинг програми підрозділу 5.3	272

ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ

АЦП – аналого-цифровий перетворювач

БПЛА – безпілотний літальний апарат

ДР – державна реєстрація (науково-дослідної роботи)

МОН – Міністерство освіти і науки України

НДР – науково-дослідна робота

НФДУ – Національний фонд досліджень України

ТОВ – товариство з обмеженою відповідальністю

CH2, CH3, CH4 – другий, третій, четвертий приймальний канал трикотушкового металошукача

ELRS – радіопротокол з надмалою затримкою для керування БПЛА (ExpressLRS)
GNSS – глобальна навігаційна супутникова система (Global Navigation Satellite System)

GPS – глобальна система позиціонування (Global Positioning System)

GPR – георадар, підповерхневий радіолокатор (Ground-Penetrating Radar)

LWIR – довгохвильовий інфрачервоний спектральний діапазон (Long-Wave Infrared)

MAG – магнітометричний канал вимірювальної системи

MS – мультиспектральний канал (мультиспектральна камера)

NIR – ближній інфрачервоний спектральний діапазон (Near-Infrared)

PI – імпульсна індукція, принцип роботи та канал металошукача (Pulse Induction)

RGB – три основних спектральних канали кольорового зображення (Red, Green, Blue)

RTK – кінематика реального часу, метод точного GNSS-позиціонування (Real-Time Kinematic)

TMR – тунельний магнітоопір, тип сенсорного елемента магнітометра (Tunnel MagnetoResistance)

UAV – безпілотний літальний апарат (Unmanned Aerial Vehicle)

UXO – нерозірваний боєприпас (Unexploded Ordnance)

CCT – компактний згортковий трансформер (Compact Convolutional Transformer)

CNN / 1D-CNN – згорткова нейронна мережа / одновимірна згорткова нейронна мережа (Convolutional Neural Network / 1D-CNN)

EANet – нейронна мережа із зовнішнім механізмом уваги (External Attention Network)

FNet – нейронна мережа з перетворенням Фур'є замість уваги (Fourier Network)

gMLP – багат шаровий перцептрон із шаром просторового змішування (gated Multilayer Perceptron)

JDL – багаторівнева модель злиття даних (Joint Directors of Laboratories)

KAN – мережа Колмогорова–Арнольда (Kolmogorov–Arnold Network)

MLP – багат шаровий перцептрон (Multilayer Perceptron)

MLP-KAN – гібридна архітектура нейронної мережі: поєднання MLP та KAN

YOLO – архітектура нейронної мережі для детекції об'єктів у реальному часі (You Only Look Once)

GLCM – матриця суміжності рівнів сірого, текстурний дескриптор (Gray-Level Co-occurrence Matrix)

NDVI – нормалізований різницевий індекс рослинності (Normalized Difference Vegetation Index)

VARI – видимий атмосферностійкий індекс стану рослинності (Visible Atmospherically Resistant Index)

AMLID – відкритий набір зображень мін і вибухонебезпечних предметів (Anti-Mine Landmine Image Dataset)

NRFU – Національний фонд досліджень України (National Research Foundation of Ukraine)

NTRIP – протокол передачі RTK-поправок через Інтернет (Networked Transport of RTCM via Internet Protocol)

ВСТУП

Актуальність теми. Нейромережеві методи виявлення аномалій є одним із перспективних напрямів розвитку сучасних комп'ютерних наук, оскільки дають змогу знаходити складні, слабко виражені та нелінійні закономірності у великих обсягах різномірних даних. Особливої актуальності ці методи набувають у задачах пошуку аномалій у полях фізичних величин, де вимірювальна система реєструє не сам об'єкт, а спричинене ним відхилення просторового, часового або просторово-часового розподілу фізичного поля від фонового стану.

Пошук аномалій у полях фізичних величин є характерним для систем дистанційного зондування, геофізичних досліджень, технічної діагностики, екологічного моніторингу та безпекових застосувань. Одним із найбільш критичних прикладів є гуманітарне розмінування, у якому необхідно забезпечити швидке, безпечне й достовірне первинне обстеження значних територій. При цьому пропуск небезпечного об'єкта є неприпустимим, а надмірна кількість хибних тривог призводить до втрати переваг дистанційного обстеження.

Безпілотні літальні апарати з мультисенсорним навантаженням дають змогу підвищити продуктивність первинного огляду територій і зменшити ризик для оператора. Для пошуку аномалій можуть використовуватися сенсори, побудовані на різних фізичних принципах: імпульсна індукція, магнітометрія, мультиспектральне спостереження, георадіолокація та інші канали дистанційного зондування. Однак жоден окремий сенсорний канал не забезпечує водночас високої імовірності виявлення, низького рівня хибних тривог і достатньої точності локалізації, що зумовлює необхідність спільного використання різномірних сенсорних даних.

Разом з тим пряме використання різномірних сенсорних потоків як вхідних даних для нейронних мереж є неможливим без їх попереднього узгодження. Сенсори БПЛА-платформи формують вимірювальні дані з різними частотами, у різних форматах, з різною фізичною природою сигналів і в різних системах координат. Унаслідок цього просте поєднання результатів вимірювання не

створює цілісного інформаційного подання, придатного для навчання моделей і подальшого автоматизованого виявлення аномалій.

Наукова проблема, на вирішення якої спрямовано дисертаційне дослідження, полягає у недостатній розробленості нейромережових методів виявлення аномалій у полях фізичних величин за різнорідними сенсорними даними БПЛА-платформи, для яких необхідним є формування узгодженого просторово-часового і структурованого подання вимірювальних потоків різної фізичної природи.

Таким чином, існує протиріччя, яке полягає в тому, що, з одного боку, ефективний пошук аномалій у полях фізичних величин потребує застосування нейромережових методів до різнорідних сенсорних даних БПЛА-платформи, а з іншого боку, існуючі підходи до збирання, оброблення та поєднання таких даних не забезпечують узгодженого часового, просторового і структурного подання вимірювань, без якого коректне навчання та застосування нейронних мереж виявлення аномалій є неможливим або недостатньо достовірним.

Тому актуальними є дослідження, що спрямовані на усунення цього протиріччя та присвячені вирішенню важливої науково-практичної задачі розроблення нейромережових методів виявлення аномалій у полях фізичних величин на основі узгодженого подання мультисенсорних даних БПЛА-платформи.

Зв'язок роботи з науковими програмами, планами, темами. Дисертаційну роботу виконано відповідно до напрямку «3) інформаційні та комунікаційні технології», визначеного Законом України «Про пріоритетні напрями розвитку науки і техніки», а також до переліку пріоритетних тематичних напрямів наукових досліджень і науково-технічних розробок, затвердженого Постановою Кабінету Міністрів України від 30.04.2024 р. № 476, зокрема за напрямками «Комп'ютерна обробка сигналів різних видів та походження», «Системи штучного інтелекту» та «Інтелектуальні інтерактивні інформаційно-аналітичні системи».

Тематика дисертаційного дослідження також узгоджується з тематичними напрямами, визначеними наказами Міністерства освіти і науки України від 06.06.2024 р. № 807, від 07.09.2023 р. № 1104 та від 04.10.2023 р. № 1202, зокрема з напрямом «Вивчення впливу бойових дій на сільськогосподарські угіддя України та визначення придатності ґрунтів для вирощування сільськогосподарської продукції».

Дисертаційне дослідження виконано у межах проєкту Національного фонду досліджень України № 2023.04/0161 «Використання штучного інтелекту для підвищення якості визначення вибухових пристроїв мультисенсорним дроном-міношукачем» (номер ДР 0124U003664), грантового науково-технічного проєкту СШ/5-2024 від 28.11.2024 «Інтелектуальна система визначення стану довкілля у реальному часі на базі БПЛА» (номер ДР 0124U004854) та НДР 723-43 «Розробка інтелектуальних сенсорів дистанційного комплексного моніторингу деградації ґрунтів повоєнних територій» (ДР 0126U001468). Дисертант брав участь у виконанні зазначених проєктів як співвиконавець.

Мета дослідження. Метою дослідження є підвищення достовірності пошуку та точності локалізації аномалій у полях фізичних величин шляхом розроблення нейромережових методів їх пошуку, виявлення, класифікації та локалізації за мультисенсорними даними БПЛА-платформи.

Задачі дослідження. Для досягнення поставленої мети необхідно було вирішити такі задачі:

- удосконалити метод часового узгодження різнорідних вимірювальних потоків БПЛА-платформи для формування коректних вхідних даних нейромережових методів виявлення аномалій;

- розробити чотиривимірну модель поля аномалій $S(c, X, Y, t)$ для даних імпульсної індукції як основу структурованого подання сигнальних даних для нейронних мереж виявлення аномалій;

- удосконалити метод просторової прив'язки мультисенсорних вимірювань для формування геоприв'язаної навчальної вибірки та узгодженого просторового подання даних для локалізації аномалій;

- розробити тензорне подання мультисенсорних даних $T(x, y, k)$ та нейромережевий метод виявлення і класифікації аномалій на його основі;
- розвинути підхід до побудови фізично-інформованих нейронних мереж шляхом включення структурних інваріантів сенсорних сигналів до функції втрат моделі виявлення аномалій;
- розробити програмні засоби оброблення мультисенсорних даних, формування навчальних вибірок і застосування нейромережевих методів пошуку аномалій, а також провести експериментальну перевірку розроблених моделей і методів.

Об’єктом дослідження є процеси нейромережевого пошуку, виявлення, класифікації та локалізації аномалій у полях фізичних величин за даними мультисенсорних вимірювальних систем.

Предметом дослідження є нейромережеві методи пошуку, виявлення, класифікації та локалізації аномалій у полях фізичних величин з урахуванням структурованого подання різнорідних сенсорних даних.

Методи дослідження. Для вирішення поставлених задач використано нейромережеві методи, методи машинного навчання, розпізнавання образів, цифрового оброблення сигналів, часового і просторового узгодження сенсорних потоків, злиття мультисенсорних даних та тензорного подання. Перевірку результатів виконано із застосуванням методів експериментального дослідження, статистичного аналізу та порівняльного оцінювання якості пошуку, виявлення, класифікації і локалізації аномалій на лабораторних і польових даних.

Наукова новизна одержаних результатів. Основний науковий результат полягає у розв’язанні важливої науково-практичної задачі розроблення нейромережевих методів пошуку, виявлення, класифікації та локалізації аномалій у полях фізичних величин за мультисенсорними даними БПЛА-платформи. Підвищення достовірності пошуку аномалій і точності визначення їх просторового положення досягається за рахунок узгодженого просторово-часового подання різнорідних сенсорних потоків, тензорного входу нейронних

мереж, ансамблевої нейромережевої класифікації та фізично-інформованої регуляризації.

У дисертаційній роботі одержано такі нові наукові результати:

- удосконалено нейромережевий метод виявлення і класифікації аномалій у полях фізичних величин за мультисенсорними даними БПЛА-платформи, який, на відміну від підходів, орієнтованих на незалежний аналіз окремих сенсорних каналів, використовує геометрично узгоджене тензорне подання $\mathbf{T}(x, y, k)$ як спільний багатоканальний вхід для ансамблю одновимірних згорткових нейронних мереж і стекінгового метакласифікатора;

- вперше розроблено чотиривимірну модель поля аномалій $\mathbf{S}(c, X, Y, t)$ для даних імпульсної індукції, яка, на відміну від табличного запису окремих вимірювань, формує структуроване подання вхідних даних нейронних мереж виявлення аномалій;

- удосконалено метод часового узгодження різнорідних вимірювальних потоків мультисенсорної БПЛА-платформи, який базується на апаратній прив'язці сенсорних каналів до спільного опорного сигналу, що забезпечує просторовий еквівалент похибки синхронізації 2–4 см та створює необхідні умови формування коректних вхідних даних для нейронних мереж виявлення аномалій;

- удосконалено метод просторової прив'язки мультисенсорних вимірювань, який поєднує автономну кінематику реального часу з кількісним обґрунтуванням точності геоприв'язки, що забезпечує просторову похибку геоприв'язки 1–8 см і формування геометрично узгодженого тензорного подання даних для нейронних мереж виявлення аномалій;

- набув подальшого розвитку підхід до побудови фізично-інформованих нейронних мереж шляхом включення до функції втрат регуляризаційних складових, що відображають структурні інваріанти сенсорних сигналів, задані дипольною моделлю магнітної аномалії та моделями багатоекспоненційного затухання вихрових струмів, що підвищує узагальнювальну здатність нейронних

мереж пошуку, виявлення, класифікації та локалізації аномалій за умов обмеженої розміченої вибірки.

Практичне значення одержаних результатів полягає в тому, що розроблені нейромережеві методи пошуку, виявлення, класифікації та локалізації аномалій у полях фізичних величин можуть бути використані для підвищення достовірності оброблення мультисенсорних даних БПЛА-платформи в задачах гуманітарного розмінування, первинного обстеження потенційно небезпечних територій, дистанційного моніторингу ґрунтів, геофізичного обстеження та екологічного контролю територій, що зазнали впливу бойових дій або техногенного навантаження.

Розроблені методи часового і просторового узгодження сенсорних потоків, модель поля аномалій $S(c, X, Y, t)$, тензорне подання мультисенсорних даних $T(x, y, k)$ та ансамблевий нейромережевий класифікатор забезпечують формування коректних вхідних даних нейронних мереж і виконання виявлення аномалій у темпі надходження вимірювань. Синхронізоване збирання даних виконується безпосередньо на борту БПЛА-платформи, оброблення не потребує наземної інфраструктури корекції, а час роботи нейромережевого класифікатора становить менш ніж 4 мс на вектор даних імпульсної індукції. Експериментальна перевірка на незалежних вибірках показала $Pd = 0,965$ та $F1 = 0,952$; польові випробування підтвердили можливість локалізації аномалій із сантиметровою точністю просторової прив'язки.

Розроблені методи та програмні засоби впроваджено у практичну діяльність ТОВ ВП «Спецмонтаж» та ТОВ «ОМ Енерджи». Відкритий набір лабораторних і польових вимірювань трикотушкового імпульсного металошукача опубліковано в репозиторії github.com/op-uav-lab/soil-monitor-mlp. Результати дисертаційної роботи використано під час виконання проєкту НФДУ № 2023.04/0161, грантового науково-технічного проєкту СШ/5-2024 від 28.11.2024 та НДР 723-43 (ДР 0126U001468).

Особистий внесок здобувача. Основні наукові положення, висновки і рекомендації, що містяться в дисертації та виносяться на захист, отримано

здобувачем особисто. У наукових працях, опублікованих у співавторстві, здобувачеві належать: обґрунтування складу обладнання, розроблення архітектури мультисенсорної БПЛА-платформи і наземної станції [5]; розроблення інформаційної моделі дистанційного зондування ґрунту, методів часового і просторового узгодження різнорідних вимірювальних потоків та їх тензорного подання для нейромережевого виявлення аномалій [2, 4]; розроблення апаратної частини, тестових стендів, формування лабораторних і польових вимірювальних даних та підготовка розділів колективної монографії щодо мультисенсорної платформи й оброблення даних імпульсної індукції [1]; участь у постановці експериментів з навчання нейронних мереж, дослідженні ансамблевих класифікаторів зі стекінгом і формуванні синтетичних навчальних наборів [3, 6, 8]; участь у розробленні концепції цифрового двійника дрона-детектора аномалій та обґрунтуванні застосування мультисенсорної БПЛА-платформи для забезпечення безпеки сільськогосподарських земель [9, 10]. У праці [7] здобувачеві належать постановка прикладної задачі, розроблення логіки планування місії БПЛА-платформи та обґрунтування її застосування для екологічного моніторингу і гуманітарного розмінування. Науковий керівник здійснював загальне керівництво дослідженням і визначав його стратегічні напрями.

Апробація результатів дисертації. Основні результати дисертаційної роботи доповідалися й обговорювалися на: 2024 IEEE 7th International Conference on Actual Problems of Unmanned Aerial Vehicles Development (APUAVD, Київ, 2024 р.); XXVII Міжнародній конференції «Автоматика 2024» (Дніпро, 2024 р.); Artificial Intelligence Technologies and Aerospace Issues III International Scientific-Practical Conference (Баку, Азербайджан, 2025 р.); II International Scientific and Practical Conference «Problems of Modern Education and Old Technologies» (Сарагоса, Іспанія, 2025 р.); Всеукраїнському науково-практичному форумі «Штучний інтелект у тваринництві: майбутнє сьогодні» (Київ, 2025 р.), а також на наукових семінарах кафедр Національного університету «Одеська політехніка».

Публікації. Основні наукові результати дисертації опубліковано у десяти наукових працях, серед яких: одна стаття у науковому виданні, що індексується наукометричною базою Scopus; одна стаття у науковому виданні іншої держави; дві статті у фахових виданнях України категорії «Б»; розділи колективної монографії; матеріали п'яти наукових заходів, з яких одна публікація індексується наукометричною базою Scopus.

Структура та обсяг дисертації. Дисертація складається з анотації, переліку умовних позначень, вступу, п'яти розділів, висновків, списку використаних джерел і додатків. Повний обсяг дисертації становить 274 сторінки, у тому числі 217 сторінок основного тексту, 38 рисунків і 14 таблиць, список використаних джерел із 72 найменувань і 6 додатків.

РОЗДІЛ 1

АНАЛІЗ ПРОБЛЕМИ ВИЯВЛЕННЯ АНОМАЛІЙ У ПОЛЯХ ФІЗИЧНИХ ВЕЛИЧИН ТА ПОСТАНОВКА ЗАДАЧІ ДОСЛІДЖЕННЯ

1.1 Виявлення аномалій у полях фізичних величин як науково-прикладна задача

1.1.1 Практичний запит і актуальність задачі

Виявлення аномалій у полях фізичних величин – клас науково-прикладних задач, з яким стикаються системи екологічного моніторингу, технічної діагностики, геофізичних досліджень, контролю стану територій і безпекові застосування. Усі ці задачі об'єднує одна обставина: безпосередньому спостереженню підлягає не сам об'єкт інтересу, а зміна фізичного поля, яку цей об'єкт або процес спричиняє в навколишньому середовищі. Вимірювальна система бачить не міну, не забруднення і не порожнину, а лише відхилення поля від звичного стану. Тому під час аналізу вимірювань вирішального значення набуває здатність системи відокремити корисну аномальну складову від фону, шумів, завад та артефактів реєстрації.

Найгострішим прикладом такої задачі сьогодні є гуманітарне розмінування. Сучасні воєнні конфлікти залишають по собі великі території, потенційно забруднені мінами, нерозірваними боєприпасами та іншими вибухонебезпечними предметами. Для України ця проблема давно вийшла за межі суто технічної: вона має виразний соціальний, економічний і гуманітарний вимір, оскільки безпосередньо стосується безпеки населення, відновлення інфраструктури, використання сільськогосподарських земель і повернення територій до нормального життя [1, 2, 3].

Традиційні підходи до виявлення вибухонебезпечних предметів, насамперед ручне обстеження, нікуди не зникнуть: на етапі остаточної перевірки та знешкодження вони залишаються необхідними. Проблема в іншому: на етапі первинного обстеження великих площ їхня продуктивність критично низька [3],

а сапер під час роботи наражається на безпосередній ризик для життя. Звідси й потреба у дистанційних, масштабованих і відтворюваних технологіях первинного скринінгу, які здатні швидко окреслити підозрілі зони та передати їх для подальшої перевірки людьми.

Безпілотні літальні апарати у поєднанні з різномірними сенсорними каналами відкривають шлях від повільного локального пошуку до систематичного дистанційного аналізу фізичних полів на значних площах [1, 5, 22]. Втім, сама по собі БПЛА-платформа задачу виявлення не розв'язує. Ефективність такої системи визначається зовсім іншими чинниками: інформативністю вимірювальних каналів, коректністю просторово-часового узгодження даних, стійкістю до завад і здатністю алгоритмів виділяти слабкі аномальні сигнали на тлі складного фону [5, 6]. Платформа лише доставляє сенсори до місця вимірювання; усе інше вирішують дані та методи їх оброблення.

Практичний запит полягає у створенні методів і моделей, які підвищують ефективність виявлення аномалій у полях фізичних величин за даними багатоканальних вимірювань з мобільних платформ. Головним прикладним контекстом цієї дисертації виступає гуманітарне розмінування, проте сформульовані підходи від самого початку будуються так, щоб бути придатними й для ширшого кола задач дистанційного виявлення аномалій у природних і техногенних середовищах – це коло окремо розглянуто у пункті 1.1.4.

1.1.2 Аномалії у полях фізичних величин як об'єкт виявлення та аналізу.

Центральне поняття дисертаційного дослідження – аномалія у полі фізичних величин. Від класичних задач розпізнавання, де об'єкт може бути безпосередньо спостережений, задачі дистанційного виявлення прихованих об'єктів відрізняються принципово. Реєструється не сам об'єкт, а його вплив на фізичне середовище [8, 9, 21]. Аналізу підлягає локальне відхилення характеристик поля від очікуваного фоновому стану.

У прикладних задачах, пов'язаних із виявленням вибухонебезпечних предметів, аномалія проявляється у різних фізичних каналах по-різному. Імпульсно-індукційний канал реагує на електропровідність, магнітну проникність, форму та розміри металевих включень [7, 10, 11, 27]. Магнітометричний канал фіксує збурення магнітного поля, пов'язані з феромагнітними компонентами об'єкта [9, 12, 29]. Мультиспектральний канал відображає непрямі поверхневі ознаки: зміни стану рослинності, структури ґрунту, локальних спектральних характеристик поверхні [5, 14]. Кожен канал несе лише часткову інформацію про об'єкт, і саме тому в загальному випадку аномалію слід розглядати як результат спільного аналізу кількох фізично різнорідних джерел даних.

У межах цієї роботи фізичне поле розуміється як просторово-часовий розподіл вимірюваної фізичної величини або сукупності величин, який реєструється технічними засобами і подається у формі, придатній для подальшого оброблення. З погляду комп'ютерних наук аномалія у полі фізичних величин є водночас фізичним явищем та інформаційним об'єктом, який потрібно виявити, описати, локалізувати та віднести до певного класу на основі аналізу вимірюваних даних [18, 21].

Принципово важливим є розрізнення цільової та нецільової аномалії. Цільова аномалія пов'язана з об'єктом, який становить інтерес у межах прикладної задачі, наприклад із вибухонебезпечним предметом. Нецільова аномалія так само відхиляє сигнал від фонового стану, але породжується іншими причинами: металевими уламками, особливостями ґрунту, магнітними неоднорідностями, рослинними чи рельєфними факторами, похибками позиціонування або технічними особливостями самої платформи. Нецільові аномалії й дають левову частку хибних тривог [6, 15, 23]. Схему класифікації аномалій у полях фізичних величин та основних елементів їх аналізу наведено на рис. 1.1.




Рисунок 1.1 – Схема класифікації аномалій у полях фізичних величин та основних елементів їх аналізу

Умовні позначення: PI – імпульсний індукційний металодетектор; MAG – магнітометричний канал; MS – мультиспектральна камера.

У реальній системі вимірюване поле не спостерігається безпосередньо у неперервній формі. Воно реєструється дискретно: у визначених точках маршруту, у конкретні моменти часу, з фіксованою просторовою і часовою роздільною здатністю. Тому для задач автоматизованого виявлення аномалій

фізичне поле доцільно розглядати як суму фонові складові, аномальної складові, шуму та систематичних викривлень, спричинених умовами вимірювання. Така декомпозиція не є формальністю: на ній далі будуються моделі подання даних, методи злиття вимірювань і нейромережеві алгоритми аналізу.

Окремо стоїть задача локалізації аномалії. Для прикладного використання недостатньо встановити сам факт її наявності; потрібно ще й оцінити положення аномалії у просторі з точністю, достатньою для подальших дій оператора або наземної групи. Повна задача, відтак, містить щонайменше три взаємопов'язані компоненти: виявлення факту аномалії, класифікацію її типу та просторову локалізацію.

Критичний аналіз літератури показує, що більшість наявних досліджень зосереджена або на окремих фізичних каналах, або на вузьких лабораторних постановках. Недостатньо дослідженими через це залишаються питання спільного аналізу аномалій за трьома різнорідними каналами, узгодження їх просторово-часових характеристик і формування єдиного подання даних, придатного для нейромережевого оброблення [6, 36, 37, 39]. Це й визначає один з головних напрямів подальшого дослідження.

1.1.3 Формалізація основних понять та реальні умови задачі

Коректна постановка задачі виявлення аномалій у полях фізичних величин потребує узгодженого понятійного апарату і чіткого розуміння того, які чинники впливають на структуру даних, що надалі обробляються алгоритмічно [18, 21]. У межах цієї дисертації під виявленням аномалії розуміється встановлення факту локального відхилення вимірюваного фізичного поля від очікуваного фоновому стану; під локалізацією аномалії – оцінювання її просторового положення з точністю, достатньою для подальшого аналізу або практичного реагування.

У прикладному сенсі задача охоплює три взаємопов'язані компоненти:

- виявлення факту аномалії;
- класифікацію аномалії як цільової або нецільової;

– просторову локалізацію джерела аномального відхилення.

Ідеться, отже, не про аналіз окремих сигналів, а про побудову узгодженої процедури оброблення багатоканальних просторово-часових даних, яка враховує фізичну природу сигналів, неоднорідність середовища та обмеження вимірювальної платформи.

Реальні умови задачі суттєво відрізняються від лабораторної постановки, і відрізняються не в кращий бік. На вимірювані дані впливає одразу кілька груп факторів. Перша група – параметри середовища: тип ґрунту, його вологість, мінералізація, рельєф, рослинний покрив, сезонні зміни [13, 14, 19, 20]. Друга – параметри самого об'єкта: тип, розміри, матеріал, маса металу, глибина залягання, орієнтація у ґрунті. Третя – умови вимірювання: висота польоту, швидкість руху платформи, стабільність траєкторії, точність геоприв'язки, частота дискретизації каналів [5, 22]. Четверта – технічні та середовищні завади, що породжують хибні сигнали або спотворюють корисний відгук.

Особливість задачі ще й у тому, що один і той самий фізичний об'єкт може проявлятися по-різному в різних каналах спостереження. До того ж не всі аномалії однаково інформативні: сильні аномалії надійно спостерігаються одразу в кількох каналах, тоді як слабкі – лише в одному або частково. Алгоритмічне оброблення тому має враховувати не тільки значення окремих вимірів, а і їхні взаємозв'язки, просторово-часове узгодження та рівень достовірності кожного каналу.

З погляду комп'ютерних наук задача виявлення аномалій у полях фізичних величин формулюється як задача побудови інформаційного подання багатоканальних даних, їх узгодження, виділення інформативних ознак, класифікації та локалізації аномалій в умовах завад, неповноти й доменного зсуву між різними умовами спостереження [17, 18, 21]. Саме така постановка відрізняє це дисертаційне дослідження від суто фізичного чи апаратного опису системи: міждисциплінарна за походженням, реальна задача розглядається тут як задача інформаційного моделювання та інтелектуального оброблення даних [18, 21]. Це створює підґрунтя для подальшого аналізу існуючих методів

виявлення аномалій та оцінювання їх придатності до багатоканальних БПЛА-систем.

1.1.4 Спектр прикладних задач та суміжні застосування

Хоча головним прикладним контекстом роботи є пошук мін і вибухонебезпечних предметів, мультисенсорний підхід до виявлення аномалій у полях фізичних величин поширюється на помітно ширше коло задач. Доцільно окреслити це коло вже на етапі аналізу проблеми: воно показує, що методи, які розробляються далі, спираються не на специфіку конкретного об'єкта пошуку, а на загальну структуру збурень фізичних полів.

Перша суміжна задача – моніторинг забруднення ґрунтів. Постконфліктні території зазнають комплексного екологічного забруднення: руйнування промислових об'єктів і складів боєприпасів призводить до накопичення у ґрунтах важких металів, хімічних сполук, а подекуди й радіоактивних ізотопів [1, 4, 12]. Показово, що забруднення впливає на кілька сенсорних каналів одночасно: підвищена концентрація металів (свинець, мідь, цинк із фрагментів боєприпасів) змінює електропровідність ґрунту, до якої чутливий імпульсно-індукційний канал, магнітну сприйнятливість верхнього шару, яку реєструє магнітометр, і пригнічує рослинність, що проявляється зниженням вегетаційних індексів у мультиспектральному каналі [59, 61]. Виникає двоїста ситуація: з одного боку, забруднена ділянка може імітувати сигнал від прихованого об'єкта і ставати джерелом хибних тривог; з іншого – сама по собі є цінною інформацією для екологічного моніторингу. Розрізнення аномалій від об'єктів і аномалій від забруднення є нетривіальною задачею мультикласової класифікації, і саме багатоканальне подання даних надає для неї найповніший набір ознак.

Друга задача – виявлення джерел іонізуючого випромінювання. Радіоактивно забруднені ділянки та фрагменти боєприпасів зі збідненим ураном створюють аномалії, які не реєструються жодним з базових каналів розглядуваної системи, однак можуть бути виявлені гамма-детекторами; параметри польоту БПЛА для локалізації ядерних джерел досліджено у [4].

Принципово, що такий канал не потребує окремої системи: за модульної побудови платформи [5] гамма-детектор інтегрується як додатковий канал спостереження, а вся процедура узгодження і спільного аналізу даних залишається незмінною. Це питання докладно розглянуто у п'ятому розділі роботи.

Третя задача – прецизійне землеробство, де мультиспектральний моніторинг з БПЛА вже широко використовується для оцінювання стану посівів, виявлення хвороб і неконтактного аналізу ґрунту [5, 71]. Ті самі сенсори і той самий ланцюжок оброблення (геоприв'язка, мозаїкування, обчислення індексів, класифікація) придатні для якісно іншої прикладної задачі; відмінність зводиться до навчальних даних і міток: замість розрізнення «міна / не міна» мережа навчається розрізняти, наприклад, «здорова рослина / стресова зона / захворювання». Така універсальність є прямим наслідком модульності підходу [5, 21].

Нарешті, четверта задача – виявлення термічних аномалій від бойових дій. Пожежі та вибухи змінюють фізичні властивості ґрунту на тривалий час: вигорілий ґрунт відрізняється від природного діелектричною проникністю, теплопровідністю та магнітною сприйнятливістю. Комбінація каналів багатоканальної системи здатна фіксувати такі зміни: мультиспектральна камера реєструє залишкові теплові контрасти (особливо з додаванням довгохвильового інфрачервоного каналу, як показано у [65]), магнітометр – зміни магнітних властивостей після високотемпературного впливу, імпульсно-індукційний канал – зміну електропровідності. Попереднє картографування зон бойового впливу при цьому може виконуватися тими самими мультиспектральними даними ще на етапі скринінгу території.

Перелічені застосування об'єднує спільна риса: у кожному з них шуканий об'єкт або процес проявляється одночасно у кількох фізичних полях, причому в жодному з каналів окремо прояв не є достатньо надійним. Це спостереження підсилює головну тезу підрозділу 1.1: практична цінність системи виявлення

аномалій визначається не окремим сенсором, а здатністю узгоджено аналізувати різнорідні вимірювання.

1.2 Аналіз методів виявлення аномалій та їх обмежень

Існуючі методи виявлення аномалій у полях фізичних величин різняться за фізичним принципом реєстрації, ступенем дистанційності, рівнем автоматизації, типом вихідних даних і можливостями просторової локалізації. У прикладних задачах гуманітарного розмінування ці методи реалізуються як ручні, наземні роботизовані, авіаційні або мультисенсорні системи [3, 22, 24, 25]. Критичний аналіз таких підходів потрібен для обґрунтування вибору трьох фізичних каналів спостереження, на яких побудовано цю дисертацію: імпульсно-індукційного, магнітометричного та мультиспектрального [5, 6, 37].

Аналіз у цьому підрозділі ведеться за єдиною схемою: фізичний принцип реєстрації → інформативні можливості → обмеження → невирішені проблеми у реальних умовах. Така схема дає змогу не просто узагальнити наявні рішення, а й виявити ті обмеження, які роблять необхідним подальше залучення методів штучного інтелекту та нейромережевого аналізу багатоканальних даних. Порівняльну характеристику основних підходів зведено у табл. 1.1 наприкінці пункту 1.2.4.

1.2.1 Ручні, механізовані та кінологічні методи

Ручні, механізовані та кінологічні підходи відіграють важливу роль у практиці гуманітарного розмінування, але з погляду задачі автоматизованого виявлення аномалій у полях фізичних величин їхні можливості суттєво обмежені. Ручне обстеження дає високу надійність на етапі остаточної перевірки, проте характеризується низькою продуктивністю, високою трудомісткістю і прямим ризиком для оператора [3]. Механізовані засоби пришвидшують очищення окремих ділянок, однак зазвичай не визначають точного положення окремих об'єктів і малопридатні для складного рельєфу чи детального скринінгу [24, 25]. Кінологічні методи мають важливу перевагу (виявлення вибухових

речовин незалежно від металевого вмісту), але залежать від погодних умов, стану тварини та суб'єктивності інтерпретації результату [25].

Усі три підходи об'єднує спільне обмеження: відсутність формалізованого цифрового подання даних, придатного для побудови відтворюваних алгоритмів аналізу, автоматизованого ранжування підозрілих зон та інтеграції у системи дистанційного моніторингу [22, 23]. Для первинного скринінгу великих територій вони через це не можуть слугувати достатньою основою і поступаються інструментальним методам, які ґрунтуються на вимірюванні фізичних полів і подальшому інтелектуальному обробленні даних.

1.2.2 Електромагнітні та магнітометричні методи

Електромагнітні та магнітометричні методи належать до базових інструментальних підходів виявлення прихованих об'єктів у ґрунті. Їхня сила в тому, що вони реагують на фізичні властивості об'єкта, не спостережувані в оптичному діапазоні: електропровідність, магнітну проникність, залишкову намагніченість, магнітну сприйнятливість [11, 12].

Імпульсно-індукційний металошукач формує короткий збуджувальний імпульс, після чого реєструє часовий відгук, зумовлений вихровими струмами в металевому об'єкті [7, 10, 11]. Інформація про ціль закодована саме у формі цього відгуку: за нею можна судити про розміри, матеріал, геометрію та положення об'єкта відносно сенсора. Дослідження показують, що часові характеристики РІ-сигналу придатні як для виявлення, так і для класифікації об'єктів методами машинного навчання [7, 27]. Зворотний бік відомий кожному практику: у присутності металевого сміття, мінералізованого ґрунту та слабких малометалевих цілей ефективність РІ-каналу різко падає, і кількість хибних спрацьовувань зростає [7, 26].

Магнітометричні методи ґрунтуються на пасивному вимірюванні збурень магнітного поля, спричинених феромагнітними компонентами підповерхневих об'єктів [9, 12, 29]. Їхні переваги – дистанційне зондування без активного випромінювання і доволі висока чутливість до феромагнітних тіл навіть на

певній відстані від поверхні. Принципове обмеження теж очевидне: магнітометричний канал не реагує на немагнітні цілі та чутливий до завад від самого носія, зовнішніх джерел поля і складної геологічної структури місцевості [12, 29].

Аналіз літератури приводить до висновку, що ні РІ-метод, ні магнітометрія окремо не дають одночасно високої ймовірності виявлення, низького рівня хибних тривог і стійкості до зміни умов середовища [7, 12, 26, 29]. РІ-канал інформативний для металевих і слабкомагнітних цілей, але втрачає надійність у складному фоні; магнітометричний канал добре бачить феромагнітні об'єкти, але безсилий перед немагнітними чи малометалевими. Природний висновок: розглядати ці канали не ізольовано, а як взаємодоповнювані джерела даних у складі багатоканальної системи.

Електромагнітні та магнітометричні методи, отже, формують важливу основу виявлення аномалій у ґрунті, однак їхні принципові обмеження не дозволяють вважати їх самодостатнім рішенням. Це обґрунтовує залучення додаткового каналу спостереження і подальший перехід до багатоканального злиття та нейромережевого аналізу.

1.2.3 Оптичні, мультиспектральні та суміжні підходи до виявлення аномалій

Оптичні та мультиспектральні методи посідають окреме місце серед засобів виявлення аномалій, оскільки аналізують поверхневі прояви прихованих об'єктів або процесів [14]. Якщо електромагнітні й магнітометричні методи реагують переважно на фізичні властивості самого об'єкта, то мультиспектральні дані відображають ознаки непрямі: зміни рослинності, структури поверхні, вологості, температурного режиму, механічного порушення ґрунтового покриття [5, 14].

У задачах гуманітарного розмінування мультиспектральний канал доповнює РІ- та магнітометричного спостереження. Його цінність не у прямому виявленні металу чи магнітних властивостей, а у фіксації вторинних індикаторів,

які супроводжують прихований об'єкт: локальних змін спектральних індексів, аномального стану рослинності, слідів порушення поверхні, неоднорідностей текстури [14]. Найбільш корисні такі ознаки тоді, коли електромагнітний або магнітометричний сигнал слабкий, неоднозначний чи зашумлений.

Власні обмеження є й тут. Мультиспектральні методи чутливі до зовнішніх умов спостереження (освітлення, сезону, стану рослинності, вологості поверхні, характеристик камери [14]) і працюють переважно з поверхневими або опосередкованими ознаками, тож самодостатніми для надійного виявлення прихованих підповерхневих цілей вважатися не можуть.

Суміжним напрямом є радіолокаційні підходи, насамперед підповерхнева радарна зйомка, які в літературі нерідко розглядаються як альтернатива або доповнення до електромагнітного й магнітометричного аналізу [13, 30, 31, 33]. Їхня перевага – реакція на діелектричні контрасти, а не лише на металеві чи магнітні властивості, що відкриває шлях до неметалевих цілей. Для БПЛА-застосувань, утім, такі системи висувають підвищені вимоги до апаратної реалізації, енергоспоживання, умов польоту та алгоритмічної інтерпретації даних, тому в межах цієї дисертації вони розглядаються як суміжний клас методів, а не як основний канал спостереження [13, 31, 33].

Оптичні та мультиспектральні методи є цінним джерелом додаткової інформації про аномалії у фізичних полях, але окремо вони не гарантують достатньої достовірності виявлення прихованих об'єктів. Найбільшу віддачу вони дають у поєднанні з іншими каналами, коли непрямі поверхневі ознаки підсилюють або перевіряють рішення, отримані з РІ- та магнітометричного каналів.

1.2.4 Мультисенсорні системи та злиття даних

Мультисенсорні системи поєднують кілька вимірювальних каналів, щоб підвищити достовірність виявлення аномалій і компенсувати обмеження окремих методів. У загальному випадку злиття виконується на одному з трьох рівнів: сигналів, ознак або рішень [6]. Найпростіший варіант – злиття на рівні

рішень, коли кожен канал формує власний висновок, а остаточне рішення визначається правилом узгодження. Складнішим і перспективнішим є злиття на рівні ознак, за якого спільному аналізу підлягають узгоджені подання даних різних каналів.

Для виявлення аномалій у полях фізичних величин з мобільної платформи мультисенсорний підхід є не побажанням, а необхідністю. Імпульсно-індукційний канал постачає інформацію про електромагнітний відгук, магнітометричний – про збурення магнітного поля, мультиспектральний – про поверхневі індикатори аномалій. Повної картини не дає жоден з них, але разом вони потенційно дають надійніше виявлення, точнішу локалізацію та обґрунтоване ранжування підозрілих зон [5, 6, 37].

Літературний аналіз при цьому показує, що більшість наявних мультисенсорних рішень обмежується або двоканальними конфігураціями, або простими схемами злиття на рівні рішень [31, 36, 37, 39]. Такі підходи не використовують повною мірою міжканальні залежності й не враховують різну природу даних, різну просторову роздільну здатність і різну частоту дискретизації каналів. Особливо складним виявляється просторово-часове узгодження різнорідних вимірювань, отриманих з рухомої БПЛА-платформи у реальних польових умовах; саме на цьому етапі губиться значна частина потенційного виграшу від комплексування.

До цього додається ще кілька системних обмежень, характерних для більшості відомих підходів: брак стандартизованих багатоканальних польових наборів даних, недостатня дослідженість впливу доменного зсуву між різними типами місцевості та сезонними умовами, а також висока обчислювальна складність методів, яка заважає використовувати їх у режимі, близькому до реального часу [56].

Ключова наукова проблема, відтак, полягає не в самому факті наявності кількох сенсорів, а в побудові узгодженого подання даних трьох фізично різнорідних каналів і в розробленні методів їх інтелектуального злиття, здатних працювати в умовах завад, просторово-часової неузгодженості та обмежених

обчислювальних ресурсів. Ця проблема є однією з центральних у даній дисертації [6, 21, 36, 37].

У табл.1 наведено порівняння основних методів виявлення аномалій у полях фізичних величин.

Таблиця 1.1 – Порівняльна характеристика основних методів виявлення аномалій у полях фізичних величин

Метод / підхід	Фізичний принцип	Інформативні можливості	Основні обмеження	Придатність до БПЛА	Роль у даній роботі
Імпульсно-індукційний метод (PI)	Реєстрація часової форми відгуку, зумовленого вихровими струмами в металевих об'єктах	Виявлення металевих включень; оцінка часових параметрів відгуку; непряма класифікація за формою сигналу	Висока чутливість до металевих сміття; зниження достовірності для малометалевих цілей; вплив складного фону	Висока	Один з трьох основних каналів
Магнітометричний метод	Реєстрація збурень магнітного поля, викликаних феромагнітними об'єктами	Виявлення феромагнітних аномалій; оцінка просторового розподілу магнітних збурень	Нечутливість до немагнітних цілей; завади від носія та середовища; залежність від просторової конфігурації польоту	Висока	Один з трьох основних каналів

Продовження таблиці 1.1

Метод / підхід	Фізичний принцип	Інформативні можливості	Основні обмеження	Придатність до БПЛА	Роль у даній роботі
Мультиспектральний метод	Аналіз відбитого випромінювання у кількох спектральних діапазонах	Виявлення поверхневих та непрямих ознак аномалій; аналіз стану рослинності та поверхні ґрунту; просторове картографування	Непряма природа ознак; залежність від освітлення, сезону, стану поверхні	Висока	Один з трьох основних каналів
Ручне обстеження	Безпосередній контактний пошук із застосуванням переносних засобів	Висока надійність фінальної перевірки; точна локалізація на місці	Низька продуктивність; ризик для оператора; відсутність масштабованості	Непридатний	Практичний еталон верифікації
Механізовані підходи	Механічна або роботизована взаємодія з поверхнею / ґрунтом	Підвищення продуктивності очищення окремих ділянок	Обмежена точність локалізації; слабка придатність до складного рельєфу; відсутність гнучкого аналізу полів	Обмежена	Суміжний клас методів
Кінологічні підходи	Виявлення слідів вибухових речовин за запахом	Можливість реагувати на об'єкти незалежно від металевого вмісту	Складність стандартизації; залежність від умов середовища; суб'єктивність інтерпретації	Непридатний	Практичний суміжний підхід

Продовження таблиці 1.1

Метод / підхід	Фізичний принцип	Інформативні можливості	Основні обмеження	Придатність до БПЛА	Роль у даній роботі
Радіолокаційні методи (зокрема GPR)	Реєстрація діелектричних контрастів та відбиттів від підповерхневих неоднорідностей	Потенційне виявлення неметалевих об'єктів; аналіз структури підповерхневого середовища	Складна інтерпретація; сильна залежність від параметрів ґрунту; підвищені вимоги до апаратної реалізації	Обмежена	Аналог і суміжний напрям
Мультисенсорне злиття даних	Поєднання кількох фізично різномірних каналів	Компенсація обмежень окремих методів; підвищення достовірності виявлення; покращення локалізації	Складність синхронізації, нормалізації, просторового суміщення та алгоритмічної інтеграції	Висока	Центральний підхід дисертації

Як видно з табл. 1.1, жоден окремий метод не поєднує високої чутливості, низького рівня хибних тривог, стійкості до складного фону та придатності до дистанційного застосування в усіх умовах. Найперспективнішим через це є підхід, заснований на комплексуванні кількох фізично різномірних каналів спостереження [6, 36, 37]. У межах даної дисертації такими каналами обрано імпульсно-індукційний, магнітометричний та мультиспектральний: саме їх поєднання дає змогу одночасно враховувати підповерхневі електромагнітні ознаки, магнітні збурення та поверхневі спектральні індикатори аномалій [5, 6, 37].

1.3 Аналіз застосування методів штучного інтелекту та нейронних мереж у задачах виявлення аномалій

Методи штучного інтелекту та нейронних мереж за останні роки перетворилися на один з головних інструментів аналізу складних багатовимірних даних у задачах дистанційного виявлення, класифікації та локалізації об'єктів [17, 18, 48, 50]. Найпомітніше їхнє значення зросло там, де корисну інформацію неможливо надійно виділити простими пороговими, спектральними чи геометричними методами: через високу зашумленість, неоднорідність середовища, складну структуру сигналів і слабо виражені міжкласові відмінності.

Для задачі виявлення аномалій у полях фізичних величин ці методи цінні одразу з кількох причин. Вони оперують, окрім окремих вимірних параметрів, багатовимірними структурами даних, де інформативними виявляються і абсолютні значення, і просторові, часові та міжканальні залежності [17, 36, 37]. Вони здатні автоматично формувати ознаки з сирих або попередньо оброблених даних, що принципово для систем, у яких окремі фізичні канали мають різну природу і різну чутливість до цільових та нецільових аномалій. Нарешті, саме методи штучного інтелекту найкраще пристосовані до інтеграції різнорідних джерел інформації в єдину модель прийняття рішення [6, 17, 36, 37].

Застосування нейромережевих і гібридних методів до даних фізичних полів має, втім, свої специфічні труднощі. На відміну від класичних задач комп'ютерного зору, де вхід найчастіше представлений однорідними зображеннями, тут дані різнорідні за фізичним змістом, частотою дискретизації, просторовою роздільною здатністю, рівнем шуму та формою подання [21, 36, 37]. Придатність тієї чи іншої архітектури через це визначається як її загальною точністю, так і тим, наскільки вона відповідає структурі сигналів конкретного фізичного каналу і чи здатна працювати в умовах багатоканального узгодження.

У цьому підрозділі основні класи методів штучного інтелекту та нейромережевих архітектур аналізуються з погляду їх придатності до виявлення аномалій у фізичних полях за даними трьох каналів спостереження: імпульсно-

індукційного, магнітометричного та мультиспектрального. Увага приділяється як досягнутим результатам, так і тим обмеженням існуючих підходів, через які їх неможливо безпосередньо перенести на багатоканальні БПЛА-системи у реальних польових умовах. Порівняльну характеристику основних класів нейромережових архітектур, що використовуються у задачах детекції аномалій, зведено у табл. 1.2.

Таблиця 1.2 – Порівняння нейромережових архітектур для задач детекції аномалій у фізичних полях

Архітектура	Тип вхідних даних	Переваги	Обмеження	Мультисенсорне злиття	Джерела
1D-CNN	Часові сигнали (PI-відгук)	Локальні часові патерни; компактність	Лише 1D; без просторового контексту	Як гілка	[7, 45]
2D-CNN	Карти полів, зображення	Просторова інваріантність	Фіксований розмір входу	Як гілка	[46, 49]
U-Net / Attention U-Net	2D-карти для сегментації	Skip-з'єднання; точна маска	Одновхідна; потребує модифікації	Multi-input	[8, 46]
YOLO / Faster R-CNN	Зображення	Класифікація + локалізація	Для оптичних зображень; складна адаптація	Обмежено	[48, 49]
Трансформер	Послідовності, карти	Адаптивне зважування; перехресна увага	Великі вибірки; обчислювальні витрати	Перехресна увага	[36, 37]
Ансамбль / стекінг	Виходи базових моделей	Стабільність; оцінка невизначеності	Час інференсу зростає	Мета-класифікатор	[43, 44]

Продовження таблиці 1.2

Архітектура	Тип вхідних даних	Переваги	Обмеження	Мультисенсорне злиття	Джерела
MLP-KAN гібрид	Вектори ознак	Тренована активація; менше параметрів	Нова (2024); не досліджена для БПЛА	Перспективно	[44, 51]

Порівняння у табл. 1.2 ведеться за критеріями, що мають безпосереднє значення для багатоканальної бортової системи: тип вхідних даних визначає, для якого фізичного каналу архітектура природна; колонка мультисенсорного злиття показує, у якій ролі модель може брати участь у спільному аналізі різнорідних потоків: як спеціалізована гілка, як механізм адаптивного зважування каналів чи як інтегровальний мета-рівень. Подальші пункти розкривають кожен клас докладніше.

1.3.1 Класичне машинне навчання та ансамблеві методи

До активного поширення глибокого навчання у задачах виявлення мін, прихованих об'єктів та аномалій у фізичних полях широко застосовувалися класичні методи машинного навчання: машини опорних векторів, дерева рішень, випадкові ліси, метод k-найближчих сусідів, логістична регресія та різноманітні ансамблеві схеми [41, 42]. Популярними їх робила можливість працювати з відносно невеликими навчальними вибірками і з добре інтерпретованими ознаками, сформованими на основі фізичного аналізу сигналів.

У задачах з РІ-відгуками, магнітними профілями або спектральними індексами класичні підходи машинного навчання спираються, як правило, на вручну сформований набір ознак [41]: амплітудні характеристики, площу під кривою, параметри затухання, спектральні компоненти, статистичні дескриптори, геометричні характеристики просторового профілю. Сильною стороною такого підходу є інтерпретованість: дослідник може прямо пов'язати ознаки з фізичними властивостями об'єкта та умовами вимірювання.

Але саме ця сила обертається ключовим обмеженням. Ручне формування ознакового простору потребує глибокого розуміння фізики кожного каналу, а набір ознак, оптимальний для одних умов, виявляється нестійким при переході до інших типів ґрунтів, інших конфігурацій польоту, іншого рівня завад чи іншої геометрії об'єктів. У багатоканальних системах проблема загострюється: різні фізичні канали потребують різних типів ознак, і їх спільне узгодження перетворюється на окрему складну задачу.

Попри це класичні методи машинного навчання значення не втратили. У багатьох прикладних роботах вони залишаються корисними як базові моделі для попередньої оцінки якості даних, у задачах з обмеженим обсягом навчальної вибірки, для побудови інтерпретованих опорних рішень, а також як складові частини складніших ансамблевих систем [41, 42]. Особливе місце тут посідають ансамблеві методи, у яких кілька різних класифікаторів поєднуються заради стійкішого інтегрального рішення.

Ансамблеві схеми, насамперед стекінг, привабливі для аналізу аномалій тим, що дозволяють об'єднати моделі, які по-різному реагують на різні типи ознак [43, 44]. Один класифікатор може краще працювати з РІ-сигналами, інший – з просторовими картами чи спектральними індексами, а мета-класифікатор навчається оптимально поєднувати їхні виходи. У літературі показано, що такий підхід дає приріст якості порівняно з окремими базовими моделями, особливо на неоднорідних даних [43, 44].

Для багатоканальних БПЛА-систем класичне машинне навчання та ансамблеві методи мають, однак, принципову межу: вони працюють здебільшого з уже підготовленими ознаками і не забезпечують глибокого спільного аналізу сирих або слабко оброблених просторово-часових даних. Їх доречно розглядати як важливий базовий рівень аналізу, але не як повне розв'язання задачі виявлення аномалій у трьох фізично різнорідних каналах спостереження. Це й обґрунтовує перехід до складніших нейромережових архітектур, здатних автоматично формувати багаторівневі подання даних.

1.3.2 Глибокі нейронні мережі для аналізу аномалій у фізичних полях

Глибокі нейронні мережі стали логічним продовженням розвитку методів машинного навчання у задачах виявлення аномалій: вони формують багаторівневі подання даних автоматично, без жорсткого ручного конструювання ознак [45, 48, 50]. Для аналізу фізичних полів це особливо суттєво, адже корисна інформація тут розподілена як у значеннях окремих параметрів, так і у часовій динаміці, просторовій структурі, міжканальних залежностях і контексті вимірювань.

У найпростішому випадку, коли вхідні дані представлені одновимірними часовими рядами, природним вибором є архітектури типу 1D-CNN [7, 45]. Вони ефективно виділяють локальні часові патерни, характерні для РІ-відгуків, сигналів затухання, магнітних профілів та інших послідовностей, де інформативною є сама форма сигналу. Додаткові аргументи на їхню користь – компактність, невелика кількість параметрів і швидкий інференс навіть на обмежених обчислювальних платформах. Через це 1D-CNN зазвичай розглядають як базового кандидата для аналізу РІ-даних, де головну роль відіграють часові характеристики відгуку.

Коли дані мають просторову організацію (карти поля, растри, В-скани, зображення, мультиспектральні карти) природнішим є використання 2D-CNN [46, 49]. Такі моделі враховують просторовий контекст, структуру локальних неоднорідностей, форму аномальних областей і взаємне розташування пікселів або вузлів сітки. Тому 2D-CNN добре пасують до аналізу магнітних карт, просторових полів інтенсивності, мультиспектральних індексів та інших даних, де аномалія проявляється не окремою точкою, а структурованим локальним патерном.

Окремий клас становлять сегментаційні мережі типу U-Net та їхні модифікації [8, 46]. Їхня цінність полягає у переході від питання «є аномалія чи немає» до побудови просторової карти ймовірностей або маски аномальних зон. Поєднуючи глибокий контекстний аналіз зі збереженням просторової деталізації, такі мережі особливо корисні там, де потрібно як класифікувати дані,

так і окреслити область аномалії на карті чи зображенні. Для виявлення аномалій у фізичних полях це відкриває шлях до карт ризику, де кожній ділянці простору відповідає оцінка ймовірності наявності цільового об'єкта.

Стандартні архітектури CNN та U-Net мають, проте, суттєве обмеження: найкраще вони працюють з однорідними за структурою вхідними даними. У задачі, що розглядається в дисертації, вхід принципово різномірний: РІ-канал дає часові відгуки, магнітометричний – просторові чи векторні карти збурень, мультиспектральний – зображення або карти спектральних індексів. Пряме об'єднання всього цього в один уніфікований вхід далеко не завжди оптимальне. Значно природніші архітектури, в яких різні типи даних проходять через різні спеціалізовані гілки оброблення і лише потім інтегруються в єдине рішення.

У цьому контексті окремий інтерес становлять трансформерні архітектури та механізми уваги [36, 37]. Їхня головна перевага полягає у здатності не просто обробляти дані, а адаптивно визначати, які фрагменти входу чи які канали найінформативніші у даному контексті. Для багатоканального виявлення аномалій це має пряме значення: в одних умовах найбільшу вагу має РІ-канал, в інших – магнітометричний чи мультиспектральний. Механізм уваги потенційно здатен динамічно змінювати внесок кожного каналу залежно від стану середовища, структури сигналу і типу аномалії.

Свої обмеження є й тут. Трансформерні моделі зазвичай потребують великих навчальних вибірок, чутливі до якості попереднього подання даних і вимагають помітно більших обчислювальних ресурсів, ніж класичні CNN [37, 48]. Для мобільних і бортових систем означає, що їх застосування має супроводжуватися або оптимізацією моделі, або поєднанням з легшими архітектурами. У БПЛА-моніторингу це обмеження особливо відчутне: нейромережева модель повинна бути водночас точною і достатньо швидкою та ресурсоощадною.

Аналіз літератури приводить, отже, до висновку, що жоден окремий клас глибоких нейромереж не є універсальним розв'язанням для виявлення аномалій у трьох фізично різномірних каналах [36, 37, 45, 46]. 1D-CNN добре пасують до

часових сигналів, 2D-CNN та U-Net – до просторових карт і зображень, механізми уваги і трансформерні компоненти – до адаптивного злиття інформації. Це обґрунтовує доцільність комбінованих багатогілкових архітектур, у яких кожен фізичний канал аналізується спеціалізовано, а остаточне рішення формується на узгодженому міжканальному поданні.

Варто враховувати й те, що у прикладних системах значення мають як підсумкова точність моделі, так і її стійкість до зміни умов, чутливість до доменного зсуву, здатність працювати з обмеженими вибірками та можливість бортового інференсу [17, 48]. Ці критерії і мають визначати вибір архітектурних рішень у подальших розділах дисертації. Для мультисенсорної БПЛА-системи найперспективнішим виглядає поєднання спеціалізованих гілок оброблення часових, просторових і спектральних даних з модулем узгодженого злиття інформації та адаптації до нелінійності фізичних сигналів.

1.3.3 Мережі з тренованими активаціями та гібридні архітектури MLP-KAN

Окремий інтерес у сучасних дослідженнях становлять нейромережеві архітектури, в яких адаптації підлягають, окрім вагових коефіцієнтів, і самі нелінійні перетворення [44, 51]. Для аналізу фізичних сигналів такий підхід особливо привабливий: форма зв'язку між вхідними даними і цільовим результатом тут часто має складний, нелінійний і каналозалежний характер, тоді як у класичних нейронних мережах ця нелінійність описується наперед заданими функціями активації, які не завжди добре відображають реальні закономірності фізичного процесу.

Архітектури класу KAN та гібридні схеми MLP-KAN орієнтовані саме на подолання цього обмеження [44, 51]. Їхня ідея в тому, що частина перетворень у мережі набуває адаптивного характеру: мережа навчається і коефіцієнтам комбінування ознак, і гнучкішій формі відображення між вхідним і вихідним просторами. Там, де сигнал породжується фізичним процесом (затуханням вихрових струмів, зміною магнітного поля, нелінійною залежністю

спектральних індексів від стану поверхні) такий підхід може виявитися природнішим за фіксовані стандартні активації.

Для задачі виявлення аномалій у фізичних полях цей клас архітектур має кілька потенційних переваг. Адаптивні активації краще підлаштовуються до реальної форми сигналу, що підвищує чутливість до слабких або нестандартних аномалій. У низці випадків такі мережі досягають порівнянної якості за меншої кількості параметрів, що є суттєвим аргументом для ресурсно-обмежених платформ [44, 51]. Крім того, вони відкривають шлях до компактніших моделей інтегрального рівня прийняття рішення, коли попередньо сформовані ознаки чи виходи базових гілок потрібно узгодити в єдину оцінку.

Водночас архітектури MLP-KAN та споріднені підходи для прикладних задач дистанційного виявлення аномалій залишаються відносно новими. У літературі поки недостатньо досліджено їхню стійкість до шуму, поведінку в умовах доменного зсуву, придатність до багатоканального злиття та сумісність з методами бортової оптимізації, зокрема квантизацією і проріджуванням [44, 51]. Розглядати їх слід тому не як гарантовано готову заміну класичним CNN чи MLP, а як перспективний напрям, доцільність якого має бути окремо перевірена в умовах конкретної задачі.

У підсумку мережі з тренуваними активаціями та гібридні архітектури MLP-KAN є перспективним інструментом аналізу багатоканальних даних фізичної природи, особливо на інтегральному рівні класифікації чи злиття ознак. Їх включення до огляду обґрунтоване потенційно точнішим відображенням нелінійної природи вимірюваних сигналів, однак реальна ефективність у задачі, що розглядається, потребує окремої експериментальної перевірки.

1.3.4 Методи попередньої обробки з використанням ШІ

Попереднє оброблення даних — один з ключових етапів у задачах виявлення аномалій у фізичних полях [21, 52, 53]. На відміну від багатьох класичних задач комп'ютерного зору, де вхідні дані вже подані у відносно стабільній і зручній формі, тут первинні вимірювання зазвичай мають значний

рівень шуму, неоднорідний фон, різну шкалу значень, неоднакову структуру в різних каналах і сильну залежність від умов спостереження. Якість подальшої класифікації чи локалізації аномалій тому великою мірою визначається саме коректністю попереднього оброблення.

У загальному випадку попереднє оброблення в задачах такого типу охоплює кілька груп операцій: придушення шуму, компенсацію фону, нормалізацію, просторово-часове узгодження, сегментацію ділянок інтересу, зменшення розмірності або перетворення сигналів у форму, придатну для подальшого машинного навчання. Для різних фізичних каналів ці процедури наповнюються різним змістом. У РІ-каналі важливі виділення інформативної ділянки сигналу, придушення паразитних коливань, стабілізація часових ознак [7, 11, 26]. Для магнітометричного каналу критичними стають компенсація повільних змін фону, вирівнювання базової лінії, аналіз локальних збурень та їх просторової структури. Для мультиспектрального каналу ключовими є радіометрична корекція, нормалізація освітленості, розрахунок індексів і виділення інформативних просторових неоднорідностей.

Принципово, що попереднє оброблення у багатоканальній системі не зводиться до незалежного очищення кожного каналу. Навіть якщо окремі операції виконуються нарізно, у підсумку дані мають бути приведені до узгодженого подання, в якому можливий їх спільний аналіз. Попереднє оброблення у цій задачі має тому водночас локальний та інтеграційний характер: воно повинно забезпечити можливість подальшого злиття даних, а не тільки покращити вигляд окремого сигналу [6, 21, 36].

У сучасних роботах дедалі частіше трапляються підходи, в яких етап попереднього оброблення частково або повністю підтримується методами штучного інтелекту [3, 52, 53]: адаптивна фільтрація, навчуване виділення ознак, автоматичне визначення інформативних часових вікон, нейромережеве відокремлення корисної складової від фону, генерування синтетичних прикладів для розширення навчальних вибірок. Перевага таких підходів у тому, що вони

адаптуються до реальної статистики даних, а не покладаються виключно на жорстко задані правила.

Окремої уваги заслуговують методи багатомасштабного аналізу, зокрема вейвлет-перетворення та споріднені інструменти [52, 53]. Вони розкладають сигнал на компоненти різного масштабу і дозволяють по-різному обробляти локальні та глобальні варіації. Для фізичних сигналів це особливо доречно: корисна аномалія, фон і шум часто мають різні характерні масштаби у часовому чи просторовому поданні, тож багатомасштабний підхід є перспективною основою для гнучкіших конвеєрів попереднього оброблення.

Ще один важливий напрям – формування синтетичних або доповнених навчальних вибірок [3]. У задачах гуманітарного розмінування та дистанційного виявлення аномалій реальні дані дороги у збиранні, нерівномірні за покриттям і часто не репрезентують усіх типів умов. Методи генерування, аугментації та побудови штучних вибірок здатні тому помітно підвищити узагальнювальну здатність моделі. Є, щоправда, важливе застереження: для фізичних сигналів синтетичні дані повинні і статистично нагадувати реальні, і зберігати фізичну правдоподібність [3, 21].

Критичний аналіз літератури показує, що у більшості існуючих систем попереднє оброблення або жорстко прив'язане до одного типу даних, або розглядається як допоміжний технічний етап без глибокої інтеграції з подальшою нейромережевою моделлю. Для задачі, що розглядається в дисертації, цього недостатньо. Потрібен підхід, у якому попереднє оброблення є складовою єдиного багатоканального інтелектуального конвеєра, орієнтованого на виявлення, класифікацію та локалізацію аномалій у реальних польових умовах.

Методи попереднього оброблення розглядаються, відтак, не лише як засоби покращення якості окремих сигналів, а як інструменти формування узгодженого і стабільного подання даних, придатного для подальшого нейромережевого аналізу. Така постановка створює основу для узагальнення

виявлених проблем і формування напрямів удосконалення, яким присвячено наступний підрозділ.

1.4 Шляхи удосконалення та постановка задачі дослідження

Проведений аналіз літературних джерел приводить до висновку, що задача виявлення аномалій у полях фізичних величин за даними багатоканальних спостережень залишається недостатньо розв'язаною і в теоретичному, і в прикладному аспектах. Попри значну кількість досліджень, присвячених окремим сенсорним каналам, нейромережевим моделям чи окремим прикладним сценаріям, цілісного розв'язання задачі узгодженого аналізу трьох фізично різнорідних каналів спостереження в умовах реальних польових вимірювань з БПЛА-платформи у наявних роботах немає [6, 21, 36, 37]. Узагальнення розглянутих підходів дає змогу виділити кілька ключових невирішених проблем.

Перша невирішена проблема – відсутність узгодженого інформаційного подання даних, отриманих з трьох фізично різнорідних каналів: імпульсно-індукційного, магнітометричного та мультиспектрального [21, 36, 37]. Існуючі роботи розглядають, як правило, або один канал, або двоканальні конфігурації, причому дані подаються у різнорідних форматах без єдиного способу просторово-часового узгодження. Побудова спільних моделей аналізу через це ускладнюється: різні канали мають різну частоту дискретизації, різну просторову роздільну здатність, різну чутливість до фону та різний фізичний зміст. Одним з напрямів удосконалення є, отже, формалізоване багатоканальне подання даних, придатне для подальшого інтелектуального оброблення.

Друга невирішена проблема пов'язана з недостатньою ефективністю існуючих методів злиття даних у багатоканальних системах виявлення аномалій [6, 36, 37, 39]. У більшості відомих підходів злиття виконується або на рівні окремих рішень, або шляхом простого об'єднання ознак без урахування складних міжканальних залежностей. Взаємодоповнюваність фізично різнорідних каналів за такого підходу використовується лише частково, а адаптація до зміни умов спостереження не забезпечується зовсім. Звідси потреба у методах

інтелектуального злиття, здатних працювати з узгодженими багатоканальними даними і враховувати їхню різну інформативність у різних ситуаціях.

Третя невирішена проблема – недостатня стійкість моделей до варіативності реальних умов вимірювання [30, 45, 3]. Для виявлення аномалій у полях фізичних величин характерний істотний доменний зсув між різними типами ґрунту, рівнями вологості, станом рослинності, особливостями рельєфу, режимами польоту і геометрією розташування об'єкта. Моделі, що демонструють високі результати у лабораторних або обмежено контрольованих умовах, при переході до реального польового застосування нерідко втрачають якість. Один з ключових напрямів удосконалення тому є методи, стійкі до зміни умов спостереження, шумів, артефактів і фонових впливів.

Четверта невирішена проблема стосується недостатнього розвитку методів локалізації аномалій та побудови просторових карт ризику [8, 17, 37]. Значна частина наявних робіт зосереджена на бінарній класифікації «наявність / відсутність об'єкта», тоді як практичне застосування вимагає більшого: оцінити положення аномалії, її просторову структуру і рівень довіри до рішення. Задача має розглядатися, отже, не суто як класифікаційна, а як задача просторового аналізу і ранжування аномальних зон на основі багатоканальних вимірювань.

П'ята невирішена проблема – відсутність достатньо представницьких та узгоджених багатоканальних наборів даних для навчання і верифікації моделей [21, 3, 56]. У наявних дослідженнях використовуються або дані окремих каналів, або набори, що не відображають специфіки БПЛА-вимірювань повною мірою. Розроблення і перевірка моделей через це часто виконуються на фрагментарних чи недостатньо узгоджених даних, що обмежує достовірність висновків про їхню практичну придатність.

Узагальнюючи наведене: подальше удосконалення систем виявлення аномалій у полях фізичних величин має бути пов'язане не стільки з нарощуванням кількості сенсорів, скільки з розвитком методів подання, узгодження, злиття та інтелектуального аналізу багатоканальних даних. Саме в

цьому полягає головний зміст дисертаційного дослідження в межах спеціальності 122 «Комп'ютерні науки».

Метою дослідження є розроблення нейромережових методів виявлення та класифікації аномалій у полях фізичних величин на основі мультисенсорних даних БПЛА-платформи, спрямованих на підвищення достовірності виявлення в умовах обмежених навчальних вибірок і варіативності умов середовища.

Для досягнення поставленої мети необхідно розв'язати такі задачі дослідження:

- провести аналіз існуючих методів виявлення аномалій у полях фізичних величин, визначити їхні обмеження та обґрунтувати вибір фізичних каналів спостереження для мультисенсорної БПЛА-платформи;
- розробити метод часового узгодження різнорідних сенсорних потоків, що забезпечує коректне сумісне використання даних, отриманих із різних каналів спостереження;
- розробити метод просторового узгодження вимірювань мультисенсорної системи для формування єдиного просторово прив'язаного подання даних;
- розробити метод структурованого подання мультисенсорних даних, придатного для подальшого автоматизованого оброблення та нейромережового аналізу;
- розробити нейромережовий метод виявлення та класифікації аномалій у полях фізичних величин на основі мультисенсорних даних;
- розробити підхід до розширення навчальної вибірки шляхом поєднання експериментальних і синтетично згенерованих даних на основі фізичних моделей сенсорних сигналів;
- реалізувати програмне забезпечення для оброблення мультисенсорних даних і провести експериментальну перевірку розроблених методів у польових умовах.

Сформульовані задачі безпосередньо відповідають виділеним невирішеним проблемам: перша задача закриває обґрунтування вибору каналів,

друга, третя і четверта – проблему узгодженого подання різнорідних потоків, п'ята проблему інтелектуального аналізу і злиття, шоста – проблему обмежених і незбалансованих навчальних вибірок та доменного зсуву, сьома – проблему перевірки методів на реальних польових даних, включно з оцінюванням локалізації.

1.5 Висновки до першого розділу

У першому розділі дисертації проведено аналіз проблеми виявлення аномалій у полях фізичних величин і розглянуто сучасний стан методів, що застосовуються для цієї задачі у прикладних системах дистанційного спостереження, насамперед у контексті гуманітарного розмінування як одного з найкритичніших практичних сценаріїв.

За результатами аналізу встановлено, що у задачах такого типу об'єктом безпосереднього аналізу є не сам прихований об'єкт, а аномалія у вимірюваному фізичному полі, яку він спричиняє. Показано, що для коректного опису задачі необхідно розрізняти фонову складову, аномальну складову, шум та артефакти вимірювання, а також відокремлювати цільові аномалії від нецільових – головного джерела хибних тривог.

Окреслено спектр прикладних задач, на які поширюється мультисенсорний підхід до виявлення аномалій: окрім пошуку вибухонебезпечних предметів, це моніторинг забруднення ґрунтів постконфліктних територій, виявлення джерел іонізуючого випромінювання, прецизійне землеробство та картографування термічних наслідків бойових дій. Спільною рисою всіх цих задач є те, що шуканий об'єкт або процес проявляється одночасно у кількох фізичних полях, причому в жодному з каналів окремо прояв не є достатньо надійним. Це підтверджує, що розроблювані методи мають спиратися на загальну структуру збурень фізичних полів, а не на специфіку конкретного об'єкта пошуку.

Визначено, що для задачі, яка розглядається у дисертації, найбільш інформативними і практично доцільними є три фізично різнорідні канали

спостереження: імпульсно-індукційний, магнітометричний та мультиспектральний. Кожен з них несе лише часткову інформацію про аномалію і не може розглядатися як самодостатнє джерело прийняття рішення в реальних польових умовах [5, 6, 37].

Критичний аналіз існуючих методів показав, що одноканальні підходи мають суттєві обмеження щодо стійкості до фону, завад і варіативності середовища. Ручні, механізовані та кінологічні методи зберігають прикладне значення, але не забезпечують потрібного рівня масштабованості, формалізованості та придатності до автоматизованого аналізу. Інструментальні методи, засновані на вимірюванні фізичних полів, перспективніші, проте окремо також не дають достатньої надійності для складних прикладних задач.

Аналіз методів штучного інтелекту та нейронних мереж засвідчив, що сучасні моделі машинного навчання є найперспективнішим засобом аналізу багатоканальних даних фізичної природи. Водночас більшість існуючих робіт орієнтована або на окремі канали, або на обмежені конфігурації злиття, а питання побудови узгодженого подання трьох різнорідних каналів, їх нейромережевого аналізу, локалізації аномалій і побудови карти ризику залишаються недостатньо дослідженими [6, 36, 37, 39].

На підставі проведеного аналізу визначено основні напрями подальшого дослідження: побудова узгодженого інформаційного подання багатоканальних даних, розроблення методів їх попереднього оброблення та просторово-часового узгодження, створення нейромережевих методів виявлення і класифікації аномалій, а також розроблення підходів до локалізації аномалій і формування карт ризику [21, 36, 37].

Окремо з аналізу випливає вимога до організації самого дослідження: оскільки однією з виявлених системних проблем є брак представницьких багатоканальних польових наборів даних, формування власної навчальної вибірки з лабораторних і польових вимірювань та її оприлюднення у відкритому доступі слід розглядати не як допоміжний технічний крок, а як один із

результатів роботи, що забезпечує відтворюваність висновків і можливість незалежної перевірки запропонованих методів іншими дослідниками.

Результати виконаного аналізу стали підставою для формулювання мети і семи задач дисертаційного дослідження, спрямованого на розроблення інформаційних моделей, методів злиття та нейромережевих методів оброблення багатоканальних даних у задачі виявлення аномалій у полях фізичних величин. Розв'язанню першої групи цих задач (узгодженню різнорідних вимірювальних потоків у часі та просторі і формуванню структурованого подання даних) присвячено другий розділ роботи.

Основні результати, викладені в цьому розділі, відображено в публікаціях [21, 58].

РОЗДІЛ 2

ЗЛИТТЯ РІЗНОРІДНИХ СЕНСОРНИХ ДАНИХ ДЛЯ НЕЙРОМЕРЕЖЕВОГО ВИЯВЛЕННЯ АНОМАЛІЙ У ПОЛЯХ ФІЗИЧНИХ ВЕЛИЧИН

2.1 Постановка задачі мультисенсорного злиття

Перший розділ завершився висновком, що головною перешкодою на шляху до надійного автоматичного виявлення прихованих об'єктів є не обмеження окремого сенсора, а відсутність цілісної архітектури злиття різномірних даних – узгодженого набору алгоритмів і структур даних, який перетворює багатоканальні вимірювання на єдиний інформаційний простір, придатний для нейромережевого оброблення. Огляди [1, 6, 37] підтверджують це спостереження: жоден окремий канал не забезпечує одночасно високої ймовірності виявлення для всього спектра цілей і прийняттого рівня хибних тривог.

Цей висновок було перевірено експериментально. Для цього розроблено БПЛА-платформу (гексакоптер) зі змінним сенсорним комплектом і проведено серію польових випробувань [5, 60]. Обстежувалися ділянки із заздалегідь розташованими еталонними цілями, маса і площа яких відповідають реальним мінам ТМ-62М та МОН-50. Результати виявилися однозначними: працюючи з одним каналом, система або пропускає значну частку об'єктів, або генерує неприйнятну кількість хибних тривог; коли ж дані кількох каналів аналізувалися спільно, об'єкти, що «мовчали» в одному каналі, впевнено проявлялися в іншому.

Звідси центральна ідея розділу: задача виявлення аномалій розв'язується через проєктування системи злиття різномірних даних, яка охоплює п'ять послідовних етапів: (1) синхронізація вимірювань у часі; (2) просторова прив'язка; (3) перетворення часових сигналів у координати через траєкторію носія; (4) інтерполяція на єдину координатну сітку; (5) формування структурованого багатоканального подання даних для нейронної мережі. Кожен з етапів є нетривіальною науково-технічною задачею; у наступних підрозділах

вони розглядаються з опорою на власні експериментальні дані та публікації [5, 43, 57, 58, 59, 60, 61].

Сама ідея злиття різнорідних даних не нова: вона систематизована ще у багаторівневій моделі JDL, що розрізняє оброблення на рівні сигналів, об'єктів, ситуацій та оцінювання загроз, і десятиліттями розвивалася у радіолокації, навігації та робототехніці [6, 63]. Специфіка задачі, що розглядається тут, у іншому: класичні застосування зливають дані сенсорів однієї фізичної природи або принаймні однієї структури (кілька радарів, кілька камер), тоді як у мультисенсорному пошуку прихованих об'єктів поєднуються канали, що вимірюють принципово різні фізичні величини у принципово різних форматах. Через це готові рецепти злиття не переносяться сюди безпосередньо і потрібна архітектура, спроектована від структури конкретних даних.

Корисно одразу окреслити, у чому саме полягає неузгодженість, яку має подолати злиття. Вона має три незалежні осі. Часова вісь: канали працюють з різними частотами і власними затримками, тож вимірювання, що стосуються однієї точки місцевості, потрапляють у потоки в різні моменти. Просторова вісь: кожен сенсор має власну геометрію огляду. Котушки металошукача рознесені поперек напрямку руху, магнітометричні пари мають вертикальну базу, камера знімає площадку зі своєї позиції з власною орієнтацією. Тому навіть ідеально синхронізовані відліки стосуються різних точок простору. Нарешті, вісь подання: одновимірні криві затухання, просторові профілі та растрові зображення мають несумісні структури даних. Розроблена далі архітектура послідовно закриває всі три осі: підрозділ 2.4 – часову, підрозділи 2.5–2.6 – просторову, підрозділи 2.6–2.7 – вісь подання.

2.2 Розроблена мультисенсорна БПЛА-платформа та джерела даних

Для розв'язання поставленої задачі спроектовано і виготовлено БПЛА-платформу на базі гексакоптера зі складними променями [5]. Загальний вигляд платформи у робочому стані наведено на рис. 2.1.



Рисунок 2.1 – Розроблений гексакоптер у готовому до польоту стані [5, 60]

Основні характеристики платформи визначено з урахуванням вимог мультисенсорного моніторингу: злітна маса – близько 5 кг; корисне навантаження – до 4 кг; робоча швидкість – 1–3 м/с; стійкість до вітру – до 30 км/год; тривалість польоту з повним навантаженням – 22–30 хвилин [5, 60]. Польотним контролером обрано CubeOrange+ на базі STM32H743 з відкритим програмним забезпеченням ArduPilot, що дає повну кастомізацію алгоритмів керування і можливість інтеграції нестандартних сенсорів [5]. Важливим архітектурним рішенням є чітке розділення функцій: польотний контролер відповідає виключно за керування польотом (гіроскоп, акселерометр, барометр, GPS, регулятори двигунів), тоді як збирання і попереднє оброблення сенсорних

даних виконує окремий бортовий одноплатний комп'ютер Raspberry Pi 5 з модулем апаратного прискорення нейромережових обчислень [5]. Структурну схему бортового обладнання наведено на рис. 2.2.




Рисунок 2.2 – Структурна схема бортового обладнання гексакоптера [5]

До складу платформи введено три основні вимірювальні канали, кожен з яких генерує дані принципово різної природи та формату.

2.2.1 Трикотушковий імпульсний металошукач

Для виявлення металевих об'єктів розроблено трикотушковий імпульсно-індукційний металошукач [5, 59]. Конструктивно датчик складається з передавальної котушки і трьох приймальних каналів (CH2, CH3, CH4), розташованих поруч і таких, що утворюють три зони сканування загальною шириною 105 см (рис. 2.3). Чутливість датчика становить 34 см (для монети 10 грн), горизонтальна роздільна здатність (дискримінація) – 35 см [5].




Рисунок 2.3 – Блок-схема трикотушкового імпульсного металошукача [5]

Вихідні дані одного вимірювання – три криві затухання вихрових струмів $u_c(t_k)$, де $c \in \{CH2, CH3, CH4\}$, а t_k – відліки у часовому вікні 5–150 мкс після збуджувального імпульсу. Для опису багатокотушкових перехідних процесів у просторі та часі запропоновано чотиривимірну модель даних $S(c, X, Y, t)$, де X – поздовжня координата сканування, Y – поперечне зміщення, t – час затухання [59]; докладно цю модель розглянуто у підрозділі 2.8. Окрім основних каналів, введено різницеві сигнали $\Delta 23 = CH2 - CH3$ та $\Delta 34 = CH3 - CH4$, які суттєво покращують локалізацію об'єкта вздовж поперечної осі Y [59, 60]. З одного проходу металошукача формується, отже, п'ятикомпонентний вектор ознак $x(t) = [u'_{CH2}, u'_{CH3}, u'_{CH4}, \Delta 23, \Delta 34]$, який надалі використовується неймережевими методами аналізу (розділ 3). Загальний вигляд гексакоптера з підвішеним трикотушковим датчиком наведено на рис. 2.4.



Рисунок 2.4 – Гексакоптер з трикоштовим РІ-датчиком на підвісі [5, 60]

Фізична основа інформативності РІ-каналу полягає у характері затухання вихрових струмів. Після вимкнення збуджувального імпульсу наведені в провідному об'єкті струми згасають за законом, близьким до експоненційного, з постійною часу, що визначається електропровідністю матеріалу, розмірами та формою об'єкта: масивні суцільні предмети дають повільне затухання з великою постійною часу, тонкостінні чи дрібні – швидке. Тому, окрім амплітуди, інформацію несе й форма кривої $u'_c(t_k)$: рання частина вікна (одиниці – десятки

мікросекунд) чутлива до дрібних і тонкостінних цілей, пізня (понад сотню мікросекунд) – до масивних провідних тіл. Вибір вікна 5 – 150 мкс зумовлений двома обмеженнями: раніше за 5 мкс сигнал спотворений власним перехідним процесом приймального тракту, а пізніше за 150 мкс відгук типових цілей опускається нижче рівня шуму. Ця залежність форми затухання від властивостей об'єкта і є фізичним підґрунтям нейромережевої класифікації за часовими розгортками.

2.2.2 Трьохканальний TMR-магнітометр

Для виявлення феромагнітних об'єктів розроблено трьохканальний магнітометр на елементах з тунельним магнітоопором [5]. Кожен з трьох каналів містить пару сенсорів (верхній і нижній), розташованих на вертикальній осі; різниця їхніх показань компенсує однорідну фонову складову геомагнітного поля і підвищує чутливість до локальних аномалій. Смуга сканування, як і для металошукача, становить близько 1 м. Структурну схему магнітометра наведено на рис. 2.5.

Вибір саме TMR-сенсорів, а не класичних ферозондових чи оптично-накачуваних магнітометрів, обґрунтовано їхньою високою нормованою чутливістю за вихідною напругою (29,4 мВ/В/мТл), низькою нелінійністю (0,19 %), малим енергоспоживанням і компактністю [5]. Вихідний сигнал – тривимірний часовий ряд, який при скануванні перетворюється на просторовий профіль. Магнітометричні дані доповнюють дані металошукача, оскільки канали чутливі до різних властивостей об'єкта: імпульсна індукція реагує на провідність і форму, магнітометр – на магнітну проникність та об'єм феромагнітного матеріалу.




Рисунок 2.5 – Структурна схема трьохканального TMR-магнітометра [5]

Принцип дії TMR-елемента ґрунтується на тунельному магнітоопорі: опір тунельного переходу між двома феромагнітними шарами залежить від взаємної орієнтації їхніх намагніченостей, яку зовнішнє поле змінює. Сенсори вмикаються у мостову схему, що дає лінійний вихід у робочому діапазоні і температурну стабільність. Вертикальна пара «верхній – нижній» у кожному каналі працює як градієнтометр. Однорідне геомагнітне поле і далекі джерела створюють в обох сенсорах практично однаковий сигнал і взаємно знищуються у різниці, тоді як близька аномалія – об'єкт під поверхнею – діє на нижній сенсор помітно сильніше, ніж на верхній, і залишається у різницевому сигналі. Така схема одночасно розв'язує дві проблеми польових магнітних вимірювань: дрейф фонового поля та завади від віддалених джерел, включно з електрообладнанням самого носія.

2.2.3 Мультиспектральна камера

Оптичним каналом обрано мультиспектральну камеру, що формує зображення у чотирьох спектральних діапазонах (R , G , B , NIR) з роздільною здатністю 1,7 см/піксель на висоті 20 м [61]. На відміну від металошукача і магнітометра, камера генерує двовимірні зображення (тензор $H \times W \times 4$ для кожного кадру). Приклади зображень аномалії (гільзи) у різних спектральних діапазонах наведено на рис. 2.6.



Рисунок 2.6 – Зображення аномалії (гільзи) у різних спектральних діапазонах камери [61]

Окремо реалізовано конвеєр обчислення вегетаційних індексів ($NDVI$, $VARI$, $Excess\ Green$) і текстурних ознак $GLCM$ на основі мультиспектральних знімків [61]. Ці похідні канали виступають додатковими ознаками для класифікації: аномалії, зумовлені прихованими об'єктами, часто проявляються через зміну стану рослинності, яку фіксує $NDVI$, тоді як штучні матеріали (метал, пластик) мають характерну текстуру в $GLCM$ -ентропії. Слід тверезо оцінювати можливості цього каналу: як встановлено у [65], оптичні методи ефективні переважно для великих об'єктів (протитанкові міни – 61,9 % точності) і суттєво поступаються для малих (протипіхотні – 19,2 %). В архітектурі, що розробляється, оптика тому використовується як допоміжний канал, який доповнює підповерхневі сенсори, а не замінює їх.

Похідні спектральні канали обчислюються за стандартними співвідношеннями: вегетаційний індекс

$$NDVI = \frac{(NIR - R)}{(NIR + R)}, \quad (2.1)$$

використовує різкий стрибок відбивної здатності здорової рослинності між червоним та ближнім інфрачервоним діапазонами; індекс

$$VARI = \frac{(G - R)}{(G + R - B)}, \quad (2.2)$$

оцінює стан рослинності лише за видимими каналами і тому менш чутливий до атмосферних умов; надлишковий зелений $ExG = 2G - R - B$ підкреслює вегетацію у нормованих координатах кольору. Текsturні ознаки на основі матриці суміжності рівнів сірого (GLCM) (енергія, контраст, ентропія) описують просторову впорядкованість зображення: природні поверхні дають характерну «шорстку» статистику, тоді як штучні об'єкти і свіжі порушення ґрунту локально її змінюють. Кожен з цих похідних шарів додає у мультисенсорний тензор ознаку з власним фізичним змістом, не збільшуючи кількості сенсорів.

2.2.4 Георадар як перспективний канал

Фізичний принцип георадіолокації доповнює решту каналів з іншого боку. Антена випромінює короткий надширокосмуговий імпульс, який частково відбивається на межах середовищ з різною діелектричною проникністю – і саме тому георадар «бачить» пластикові корпуси, порожнини та межі порушеного ґрунту, невидимі ні для індукційного, ні для магнітного каналів. Платою є сильна залежність глибини зондування і контрасту від вологості та провідності ґрунту, а також складність інтерпретації радарограм, у яких точковий об'єкт постає дифракційною гіперболою.

Четвертим каналом розглядається георадар, який реагує на контраст діелектричної проникності і здатний виявляти повністю неметалеві об'єкти; його вихідні дані – двовимірна радарограма $s(x, t)$. У поточній конфігурації платформи георадар не інтегровано через обмеження вантажопідйомності (антенні системи та енергоспоживання), однак модульна архітектура носія [5] дозволяє підключити його як додатковий канал без конструктивних змін. Доцільність такої інтеграції у перспективі кількісно обґрунтована результатами Khan et al. [36]: злиття даних індукційного сенсора з георадарними підвищило точність бінарної класифікації з 76,8 % до 99,99 %.

2.3 Проблема різнорідності даних та архітектура злиття

Аналіз форматів даних розроблених сенсорів виявляє ключову проблему: чотири канали генерують принципово несумісні потоки. Металошукач видає набір одновимірних часових рядів (п'ять компонентів, вікно ~ 150 мкс); магнітометр – повільніший просторовий профіль з трьох каналів; камера – двовимірне зображення $H \times W \times 4$ і більше; георадар – двовимірну радарограму. Ці дані відрізняються частотою дискретизації, просторовою роздільною здатністю (від 1,7 см у камери до 35 см у металошукача) і самою фізичною природою.

Несумісності між потоками доцільно класифікувати за типами, бо кожен тип потребує власного інструмента. Несумісність темпу (різні частоти оновлення) знімається синхронізацією і подальшою інтерполяцією; несумісність геометрії (різні точки і смуги огляду) – просторовою прив'язкою кожного відліку до координат носія з урахуванням зміщення сенсора відносно антени приймача; несумісність роздільної здатності – приведенням до спільної сітки з усвідомленою втратою або надлишком деталізації; несумісність структури (часовий ряд проти растру) – перетворенням кожного потоку у просторове подання до моменту об'єднання. Перелічені інструменти і утворюють послідовні етапи конвеєра.

Для розв'язання цієї проблеми запропоновано п'ятиетапну архітектуру злиття різнорідних даних, подану блок-схемою на рис. 2.7. Кожен блок схеми відповідає окремому етапу перетворення: (1) синхронізація у часі – всі вимірювання прив'язуються до єдиної часової шкали супутникового часу; (2) просторова прив'язка – кожне вимірювання отримує координати через RTK GNSS; (3) перетворення «час $\rightarrow$ координати» – для металошукача і магнітометра часова вісь перераховується у просторову через траєкторію носія; (4) інтерполяція на сітку 10×10 см; (5) формування мультисенсорного тензора $T(x, y, k)$ як входу нейронної мережі. Обґрунтування кожного етапу та конкретні рішення викладено у підрозділах 2.4–2.8, архітектура представлена на рис. 2.7:




Рисунок 2.7 – Запропонована архітектура п'ятиетапного конвеєра злиття різнорідних даних

2.4 Розроблена система синхронізації вимірювань у часі

Перший етап конвеєра – синхронізація даних у часі. Це найменш очевидна, але вкрай важлива проблема. Навіть за швидкості носія 2 м/с похибка у 100 мс означає просторове зміщення 20 см, тобто величину, порівнянну з розміром протипіхотної міни. Іншими словами, неточність годинника безпосередньо перетворюється на неточність карти.

У розробленій системі синхронізацію забезпечує бортовий одноплатний комп'ютер, який приймає дані всіх вимірювальних каналів через SPI-шину і формує єдину часову базу [5]. Польотний контролер у обробленні сенсорних даних участі не бере, оскільки відповідає виключно за керування польотом. Металошукач і магнітометр підключені до високошвидкісних АЦП бортового комп'ютера, координати RTK GNSS надходять через послідовний інтерфейс. Усі

сенсорні потоки, відтак, мають спільне джерело часових міток, що докорінно спрощує їх узгодження [5, 60].

Кількісний бюджет часового узгодження визначається періодами дискретизації каналів. Металошукач працює з частотою зондування 238 Гц, тобто з періодом близько 4,2 мс: за робочої швидкості 2 м/с сусідні зондування розділяє відстань менше сантиметра, і навіть похибка прив'язки в один період еквівалентна зміщенню лише $\sim 0,8$ см. Магнітометр з частотою 100 Гц дає період 10 мс, тобто еквівалент 2 см на прохід. Найжорсткіші вимоги створює камера з періодичністю знімання 0,5–1 Гц: між сусідніми кадрами носій проходить 2–4 м, тому положення кожного кадру не може бути «успадковане» від попереднього і мусить визначатися індивідуальною часовою міткою з подальшою інтерполяцією координат. Ця асиметрія частот (від сотень герців до часток герца) і робить апаратну спільну часову базу безальтернативною.

Мультиспектральна камера, втім, працює як незалежний пристрій із власним GPS-приймачем. Її синхронізацію з підповерхневими сенсорами реалізовано через спільну шкалу супутникового часу: кожен кадр і кожен рядок сенсорних даних отримують GPS-мітку, що дозволяє постфактум зіставити їх з точністю до десятків мілісекунд. За робочої швидкості 2 м/с це відповідає просторовій невизначеності 2–4 см, тобто прийнятній величині при роздільній здатності камери 1,7 см/піксель [61].

Корисно оцінити бюджет часової похибки за складовими. Внесок дискретизації АЦП за частоти зондування металошукача 238 Гц обмежений половиною періоду між розгортками; затримки передачі по SPI-шині детерміновані й компенсуються константою; невизначеність GPS-мітки кадру камери визначається точністю прив'язки моменту експозиції до шкали супутникового часу і становить десятки мілісекунд, і якраз вона домінує у підсумковій оцінці 2–4 см для оптичного каналу. Для підповерхневих каналів, які отримують мітки безпосередньо від бортового обчислювача, еквівалентна просторова похибка ще менша. Принципово, що всі складові бюджету або

детерміновані, або обмежені зверху: система не накопичує дрейфу, який у конфігураціях з незалежними годинниками сенсорів зростає протягом місії.

Актуальність проблеми синхронізації незалежно підтверджена у роботі Kolster et al. [29]: за високошвидкісного (~ 10 м/с) магнітного сканування з БПЛА значний джитер часових міток спостерігався навіть при GPS-синхронізації. Запропонована там корекція через лінійний метод найменших квадратів,

$$\min_{\varphi} \sum |t_i - (\tau_i + \varphi)|, \quad (2.3)$$

вирівнює мітки до номінальної частоти з точністю порядку мікросекунд і може бути застосована у розробленій системі як додатковий етап постоброблення для каналів з високою частотою дискретизації.

Описане рішення усуває головний недолік відомих мультисенсорних конфігурацій, у яких кожен сенсор веде власну часову шкалу, а узгодження виконується наближено на етапі постоброблення. Апаратна прив'язка всіх каналів до спільного опорного сигналу супутникового приймача забезпечила суміщення вимірювань різної фізичної природи в єдиній часовій шкалі безпосередньо на борту, з еквівалентною просторовою похибкою взаємного зміщення потоків 2–4 см без жодного постоброблення. Сформульовано перший пункт наукової новизни: удосконалено метод часового узгодження різнорідних вимірювальних потоків мультисенсорної платформи, який, на відміну від існуючих, використовує апаратну прив'язку всіх каналів до спільного опорного сигналу, що дозволило сумістити вимірювання різної фізичної природи в єдиній часовій шкалі безпосередньо на борту.

2.5 Розроблена система просторової прив'язки

Для перетворення часових сигналів металошукача і магнітометра у просторові координати розроблено двоступеневу RTK-систему позиціонування [5]. Основний канал – приймач HERE4 на базі чипа F9P із власним процесором і завадостійким компасом RM3100; резервний – приймач ArduSimple, який працює без NTRIP-підписки і надає RTK-корекцію на відстанях до 2–3 км від базової станції. Базова станція розгортається на розробленій наземній станції

(рис. 2.8) і передає поправки радіоканалом RFD900x [5]; корекцію на самій базовій станції додатково забезпечує RTK-приймач ArduSimple.




Рисунок 2.8 – Структурна схема розробленої наземної станції [5]

Принцип кінематики реального часу полягає у переході від кодових вимірювань до фазових: приймач відстежує фазу несучої супутникового сигналу, довжина хвилі якої близько 19 см, і вимірює її з точністю до часток відсотка, що потенційно дає міліметрову роздільність. Головна перешкода, цілочисельна неоднозначність кількості довжин хвиль на трасі, розв'язується диференціальним методом: базова станція з точно відомими координатами передає рухомому приймачу поправки, спільні для обох (іоносферна та тропосферна затримки, похибки годинників та ефемерид взаємно знищуються на короткій базі), після чого неоднозначність фіксується цілочисельно і похибка падає до сантиметрового рівня. Звідси і роль власної базової станції у складі комплексу:

вона замінює мережевий сервіс поправок там, де його покриття відсутнє або недоступне.

За даними виробника, горизонтальна похибка F9P з RTK не перевищує 0,9 см, тоді як типові системи без RTK мають похибку близько 2,5 м. Вертикальне позиціонування додатково уточнюється лідаром з точністю ± 2 см [5, 60]. Порівнянний рівень точності (2,7 / 3,2 / 5,1 см за осями E/N/V) досягнуто у [29] – щоправда, через постоброблення PPP з точними орбітами; це підтверджує, що розроблена система відповідає сучасному рівню БПЛА-магнітометрії, не потребуючи при цьому постоброблення взагалі.

Процедуру просторової прив'язки даних металошукача реалізовано так: кожне вимірювання $u(c, t)$ має часову мітку бортового комп'ютера; за цією міткою з потоку RTK-координат інтерполюється позиція носія (x, y, z) ; результатом є чотиривимірний масив $S(c, X, Y, t)$ [59]. Для камери геоприв'язка виконується через координати центру знімка, параметри орієнтації та висоту, з подальшою побудовою геоприв'язаних мозаїк [61]. У підсумку енергетична карта металошукача $E(X, Y)$, магнітний профіль і мультиспектральне зображення стають порівнянними в єдиній системі координат.

Технічно прив'язка виконується у два кроки. Спершу геодезичні координати приймача (широта, довгота, висота у системі WGS-84) перетворюються у локальну прямокутну систему «схід–північ–верх» з початком у точці розгортання базової станції – на ділянках обстеження у сотні метрів таке перетворення дає сантиметрову узгодженість без урахування кривини Землі. Далі позиція носія на момент кожного сенсорного відліку обчислюється інтерполяцією між сусідніми відліками приймача, а позиція самого чутливого елемента – додаванням відомого конструктивного зміщення сенсора відносно фазового центра антени з урахуванням орієнтації носія за даними інерціального блока. Без другої поправки навіть ідеальні координати антени давали б систематичний зсув карт, що дорівнює винесенню підвіски.

Сумарний бюджет похибки геоприв'язки складається з кількох незалежних внесків: статичної похибки RTK-розв'язку (до 0,9 см за даними виробника),

похибки вертикального каналу далекоміра (± 2 см), похибки інтерполяції координат між сусідніми RTK-відліками та динамічної складової, зумовленої рухом носія. У статичних і квазістатичних умовах домінують перші два внески, і фактична точність наближається до паспортної; у польоті визначальною стає динаміка, яка й розтягує підсумкову точність до діапазону 1–8 см залежно від вітру, швидкості та якості стабілізації траєкторії.

Окрему проблему, виявлену під час польових випробувань, становлять динамічні спотворення координат [60]. Вітер і його пориви, інерційність носія при корекції траєкторії, «стрибки» висоти через особливості далекомірного лідара призводять до того, що реальна позиція сенсора відхиляється від запланованої. Навіть за заявленої RTK-точності якість польових даних виявляється помітно нижчою за лабораторну [60], і це має вирішальне значення для стратегії навчання нейронної мережі: модель, навчена на «розмитих» сигнатурах з позиційною невизначеністю, засвоює менш чіткі ознаки. Докладно ця проблема і запропоновані рішення розглядаються у четвертому розділі при формуванні навчальної вибірки.

Підсумком етапу є автономна геоприв'язка мультисенсорних вимірювань без підключення до мережесервісів корекції та без наземної інфраструктури загального користування: досягнута точність геоприв'язки у польових умовах становить 1–8 см залежно від динаміки польоту. Сформульовано четвертий пункт наукової новизни: удосконалено метод просторової прив'язки мультисенсорних вимірювань, який, на відміну від існуючих, використовує автономну кінематику реального часу без мережесервісів корекції, що забезпечило сантиметрову точність геоприв'язки поза зоною покриття наземної інфраструктури.

2.6 Інтерполяція на єдину координатну сітку

Після того як кожне вимірювання отримало просторові координати, постає проблема несумісності просторових масштабів. Металошукач з кроком сканування 10–20 см дає розріджену сітку; магнітометр має подібний крок;


мультиспектральна камера з роздільною здатністю 1,7 см/піксель формує зображення, у десятки разів детальніше [61]. Щоб подати ці дані на вхід нейронної мережі єдиним багатоканальним тензором, їх потрібно привести до спільної координатної сітки.

Крок сітки обрано рівним 10 см як компроміс між інформативністю та обчислювальними витратами. На користь такого вибору є два аргументи. Перший: 10 см відповідає мінімальному характерному розміру аномалій від протипіхотних мін (діаметр від 56 мм для М-14), тобто кожна потенційна ціль покривається щонайменше однією коміркою. Другий: за кроку вимірювань металошукача 10–35 см (залежно від швидкості польоту) інтерполяція не вимагає надмірного «розтягування» сирих даних [5, 59].


Для каналів з грубішою роздільною здатністю (металошукач, магнітометр) реалізовано білінійну інтерполяцію між точками вимірювань з подальшим гаусовим згладжуванням, радіус якого дорівнює половині кроку вимірювань. Сплайни високого порядку виключено свідомо: вони породжують штучні осциляції, які нейронна мережа може хибно інтерпретувати як аномалії [59]. Для мультиспектральної камери виконується підвибірка через усереднення в межах комірки 10×10 см. Обидві операції проілюстровано на рис. 2.9.

Білінійна інтерполяція обчислює значення у вузлі сітки як зважену суму чотирьох найближчих вимірювань, де ваги пропорційні площам протилежних прямокутників розбиття; вона неперервна, не виходить за межі діапазону вихідних даних і не породжує екстремумів, яких не було у вимірюваннях. Подальше гаусове згладжування (згортка з ядром $G(r) \sim \exp\left(-\frac{r^2}{2\sigma^2}\right)$, де σ дорівнює половині кроку вимірювань) пригнічує «зернистість», спричинену нерівномірністю траєкторії. Окремої уваги потребують краї смуги обстеження: вузли, для яких бракує опорних вимірювань, не екстраполюються, а позначаються у службовому шарі якості як ділянки зниженої довіри; це чесніше, ніж заповнювати їх правдоподібними, але не виміряними значеннями, і нейронна мережа надалі може враховувати цю ознаку.

PI / MAG (крок 10–35 см)




Розріджена сітка


Білінійна
інтерполяція

Сітка 10×10 см

MS камера (GSD 1,7 см)



Щільна сітка

Підвибірка
(downsampling)

Сітка 10×10 см

 $T(x, y, k)$

Мультисенсорний тензор

Рисунок 2.9 – Схема інтерполяції PI-даних та підвибірки мультиспектральних даних на єдину сітку 10×10 см

Формально значення каналу k у вузлі сітки (x_i, y_j) обчислюється у два кроки. Спочатку білінійна інтерполяція за чотирма найближчими точками вимірювань:

$$f(x, y) = f_{11} \cdot (1-u)(1-v) + f_{21} \cdot u(1-v) + f_{12} \cdot (1-u)v + f_{22} \cdot uv, \quad (2.4)$$

де u, v – нормовані відстані до вузлів комірки вимірювань. Потім згладжування згорткою з гаусовим ядром $G(r) = \exp\left(-\frac{r^2}{2\sigma^2}\right)$, нормованим на одиничну суму, з параметром σ , що дорівнює половині кроку вимірювань: таке ядро пригнічує високочастотні артефакти інтерполяції, не розмиваючи аномалії, характерний розмір яких перевищує крок сітки. Для камери, навпаки, виконується агрегація: значення комірки обчислюється як середнє всіх пікселів, що в неї потрапили; це одночасно знижує піксельний шум.

Результат інтерполяції – мультисенсорний тензор $\mathbf{T}(x_i, y_j, k)$, у якому кожна комірка (x_i, y_j) координатної сітки містить: вектор ознак металошукача (п'ять компонентів або їх енергетичне подання $E(x, y)$ [59]); вектор магнітометричних ознак (три диференціальні канали [5]); вектор оптичних ознак (чотири спектральні канали та обчислені індекси $NDVI$, $VARI$, $GLCM$ [61]). Структуру тензора наведено на рис. 2.10.




Рисунок 2.10 – Структура мультисенсорного тензору $\mathbf{T}(x, y, k)$: шари PI, MAG та MS каналів на єдиній координатній сітці

2.7 Запропонована архітектура злиття: вибір рівня та обґрунтування

Мультисенсорний тензор відповідає на питання «у якій формі зберігати дані», але не на питання «як саме їх зливати». Нижче проаналізовано три основні підходи та обґрунтовано вибір гібридної архітектури.

2.7.1 Злиття на рівні сигналів

Найпростіший підхід – подати всі канали тензора $\mathbf{T}(x, y, k)$ на вхід однієї мережі, за аналогією з RGB -зображенням з k каналами. У [65] такий підхід реалізовано для двоканального випадку $RGB+LWIR$: зважена сума:

$$I_{fused} = \alpha \cdot I_{RGB} + (1 - \alpha) \cdot I_{LWIR}, \quad (2.5)$$

подається на YOLO-детектор. Для конфігурації, що розглядається тут, прямий сигнальний рівень злиття непрактичний. РІ-канал є одновимірним часовим рядом, а камера – двовимірним зображенням, і фізичне «наклеювання» часового ряду на піксельне зображення не має сенсу без попереднього перетворення обох у спільне подання.

2.7.2 Злиття на рівні ознак

Гнучкіший підхід (саме він запропонований як основний) передбачає окрему гілку нейронної мережі для кожного каналу з наступним об'єднанням витягнутих ознак. Кожна гілка має архітектуру, природну для свого типу даних: одновимірні згорткові мережі для часових рядів металошукача [59], двовимірні – для зображень камери, окрема двовимірні гілка для радарограм георадара у перспективі.

Обґрунтованість такого вибору кількісно підтверджена результатами Khan et al. [36]: для двоканальної системи «індукційний сенсор + георадар» аналогічна стратегія забезпечила 99,99 % точності бінарної класифікації та 99,89 % – класифікації за глибиною, тоді як найкращий одноканальний варіант давав лише 76,8 %. Злиття на рівні ознак, отже, виявляє міжканальні залежності, принципово недоступні роздільному аналізу. У реалізованій РІ-гілці [59] п'ятикомпонентний вхідний вектор $x(t) = [u'_{CH2}, u'_{CH3}, u'_{CH4}, \Delta 23, \Delta 34]$ забезпечує 95–100 %

точності класифікації еталонних об'єктів на лабораторних даних; додавання магнітометричної та оптичної гілок має підвищити якість для складних випадків – малометалевих мін, об'єктів на великій глибині, несприятливих ґрунтових умов.

Формально ознакове злиття описується так: кожна гілка реалізує відображення свого входу у вектор ознак фіксованої розмірності:

$$fPI = \varphi_{PI}(x(t)), \quad (2.6)$$

$$fMAG = \varphi_{MAG}(m), \quad (2.7)$$

$$fMS = \varphi_{MS}(I), \quad (2.8)$$

після чого спільне подання утворюється конкатенацією

$$f = [fPI \oplus fMAG \oplus fMS] \quad (2.9)$$

і подається на інтегровальний класифікатор. Принципово, що відображення φ навчаються спільно з класифікатором: простір ознак формується не вручну, а під задачу, і мережа сама визначає, які характеристики кожного каналу інформативні у поєднанні з іншими. Ця спільність навчання і відрізняє ознакове злиття від механічного складання незалежно отриманих ознак.

2.7.3 Злиття на рівні рішень

Третій підхід – повний незалежний конвеєр для кожного каналу з подальшим об'єднанням рішень. Цей підхід досліджено у власній роботі [43], де запропоновано ансамблевий класифікатор зі стекінгом. Архітектура має два рівні: M незалежних нейронних мереж першого рівня (CCT, EANet, FNet, SwinTr, MLP-Mixer, gMLP), кожна з яких обробляє вхід зі своєю унікальною структурою, та MLP другого рівня, що навчається оптимально комбінувати їхні рішення. Схему архітектури наведено на рис. 2.11.




Рисунок 2.11 – Архітектура ансамблевого класифікатора зі стекінгом: М мереж першого рівня + MLP другого рівня [43]

Експерименти [43] показали, що MLP другого рівня знижує кількість помилок на 13–17 % порівняно з голосуванням більшістю. Додатково досліджено клонування мереж через циклічний зсув рядків зображення: за п'яти клонів ССТ кількість збіжних помилок (таких, що їх роблять усі мережі одночасно) знижується до нуля на вибірці з 50 000 зображень [43, 66]. Важливо для бортового застосування, що кожна мережа першого рівня реалізована на процесорах сімейства STM32MP1 (Cortex-A7, 650–800 МГц) у квазіреальному часі [43]. Ця архітектура безпосередньо переноситься на мультисенсорне злиття: кожен канал обробляється власним класифікатором першого рівня, а MLP другого рівня об'єднує рішення; перевагами є незалежність каналів і можливість розподіленої реалізації на окремих процесорах.

2.7.4 Обґрунтування обраної гібридної архітектури

За підсумками порівняльного аналізу обрано гібридну архітектуру: злиття на рівні ознак як основний механізм, доповнене злиттям на рівні рішень через ансамблювання [43]. Порівняння трьох підходів зведено у табл. 2.1.

Таблиця 2.1 – Порівняння трьох рівнів злиття різнорідних даних

Рівень злиття	Переваги	Обмеження	Застосовність у роботі
Сигнальний	Підвищення відношення сигнал/завада за рахунок взаємної компенсації шумів	Несумісність форматів: часові ряди PI та зображення MS не поєднуються напряму	Лише як внутрішньосенсорне комбінування (різницеві канали PI)
Ознаковий	Виявлення міжканальних залежностей; окрема гілка для кожного типу даних	Потребує навчання спільного простору ознак	Основний механізм: 1D-CNN для PI, 2D-CNN для MS
Рішеннявий	Робастність: помилка одного класифікатора не визначає підсумок	Втрата тонких міжканальних зв'язків	Доповнення: ансамбль зі стекінгом над гілками

Ознаковий рівень робить можливим виявлення міжканальних залежностей (наприклад, кореляції між амплітудою PI-відгуку та магнітометричним градієнтом), які на рівні рішень безповоротно втрачаються. Доповнення ансамблюванням [43] додає робастності: навіть якщо окремий класифікатор помиляється, загальне рішення може лишатися правильним. Для бортового оброблення це значить, що PI-гілка (час інференсу менше 4 мс [59]) і магнітометрична гілка працюють паралельно на одноплатному комп'ютері, формуючи вектори ознак, які потім об'єднуються з ознаками оптичного каналу для остаточного рішення.

2.8 Розроблений конвеєр обробки PI-даних: від сирого сигналу до входу нейронної мережі

У цьому підрозділі детально описано повний конвеєр оброблення імпульсно-індукційних даних як наскрізний приклад реалізації архітектури злиття для одного каналу. PI-канал обрано не випадково. З одного боку, він найдокладніше досліджений у власних попередніх роботах [59, 60]; з іншого –

він демонструє всі характерні етапи перетворення сирого сигналу у вхідні дані нейронної мережі, які за аналогією переносяться на решту каналів. Загальну блок-схему конвеєра наведено на рис. 2.12.




Рисунок 2.12 – Блок-схема розробленого конвеєра обробки PI-даних: від сирого сигналу до класифікації та карти ризику

2.8.1 Чотиривимірна модель сирих даних

Сирі PI-дані формалізовано чотиривимірною моделлю $\mathbf{S}(c, X_i, Y_j, t_k)$, у якій кожен вимір має конкретний фізичний зміст [59]: індекс $c \in \{CH2, CH3, CH4\}$ позначає приймальну котушку; X_i – поздовжню координату сканування; Y_j – поперечне зміщення (відповідає зоні котушки); t_k – час після збуджувального імпульсу в діапазоні 5–150 мкс. Кожен «зріз» цього тензора за фіксованих (c, Y_j) є В-сканом – двовимірним зображенням у площині (X, t) , яке візуалізує перехідний процес уздовж маршруту. Приклади В-сканів для еталонних об'єктів різного розміру наведено на рис. 2.13.




Рисунок 2.13 – В-скани PI-відгуків для еталонних об'єктів N1–N4 при домінантних поперечних зміщеннях (канал CH3) [59]

Роль цієї моделі у побудові конвеєра фундаментальна: вона однозначно визначає розмірність і семантику вхідних даних. Без такої формалізації неможливо коректно задати ні архітектуру нейронної мережі, ні розмір рецептивного поля, ні стратегію формування навчальних зразків. На відміну від

відомих описів даних імпульсної індукції, які оперують окремими кривими затухання або усередненими відгуками, модель $\mathbf{S}(c, X, Y, t)$ одночасно враховує номер приймального каналу, просторові координати точки зондування та час релаксації відгуку, що й робить її придатною основою для різницевих каналів, енергетичних подань і багатоканального злиття. Сформульовано другий пункт наукової новизни: вперше запропоновано чотиривимірну модель поля аномалій $\mathbf{S}(c, X, Y, t)$, яка одночасно враховує канал приймання, просторові координати точки зондування та час релаксації відгуку, що стало основою формування різницевих каналів і енергетичних подань даних імпульсної індукції.

Зрізи моделі зручно називати за термінологією, усталеною в георадіолокації. А-скан – одиночна часова розгортка $u(t)$ у фіксованій точці (X, Y) для одного каналу; В-скан – набір А-сканів уздовж лінії руху, тобто зображення у площині (X, t) ; С-скан – просторовий зріз за фіксованого часу t , тобто карта у площині (X, Y) . Енергетична карта $E(X, Y)$, введена нижче, є узагальненням С-скану з інтегруванням за часовим вікном. Така термінологічна уніфікація має змістовне підґрунтя. Вона підкреслює структурну спорідненість РІ-даних з георадарними і дає змогу переносити напрацьовані для георадіолокації прийоми аналізу (виділення гіпербол, міграцію, фонове віднімання) на імпульсно-індукційні дані з мінімальною адаптацією.

Модель безпосередньо відповідає і структурі фактично зібраних експериментальних даних: у відкритому репозиторії проєкту кожен сценарій вимірювань зберігається як сукупність одиничних часових розгорток трьох каналів для послідовних позицій сканування та як агреговані В-скани, тобто як дискретні зрізи тієї самої чотиривимірної структури $\mathbf{S}(c, X, Y, t)$. Це усуває розрив між формальним описом даних і їх практичним зберіганням: перехід від файлів вимірювань до входу алгоритмів зводиться до індексації моделі, а не до перепакування форматів.

2.8.2 Розроблена процедура віднімання фону та нормалізації

Перший етап оброблення – компенсація фонові складові. Кожна котушка має власний рівень «нульового» сигналу, зумовлений залишковими ефектами вимкнення передавача, ємнісним «дзвоном» RLC-контурі і термічними дрейфами електроніки. Базова лінія обчислюється як середнє по «порожніх» ділянках:

$$u_{base} = \left(\frac{1}{N_{base}} \right) \cdot \sum u_c(t_k), \quad (2.10)$$

а скоригований сигнал – як $u'_c(t_k) = u_c(t_k) - u_{base}$ [59].

Далі виконується нормалізація по каналах, що приводить сигнали різних котушок до порівнянного динамічного діапазону. Показово, що ця операція має прямі аналоги в інших фізичних каналах: вилучення тренду в магнітометрії [29] та видалення фону у георадіолокації [36]. Логіка скрізь одна: виділити аномальну складову A_c із загального сигналу S_c .

Нормалізація тут виконує не косметичну, а структурну роль. Котушки мають неминучий технологічний розкид чутливості, тож без приведення до спільного масштабу різницеві канали $\Delta 23$ і $\Delta 34$ містили б систематичну складову, не пов'язану з об'єктом, а нейронна мережа витратила б частину ємності на запам'ятовування апаратних особливостей конкретного екземпляра датчика замість фізики відгуку. Приведення кожного каналу до одиничного масштабу за опорними ділянками робить дані переносними між екземплярами обладнання і сесіями вимірювань. Ця властивість критична для накопичення навчальної вибірки протягом тривалого часу.

2.8.3 Формування різницевого каналів як внутрішньосенсорне злиття

Для підвищення просторової роздільної здатності запропоновано формування різницевого сигналів $\Delta 23(t) = u'_{CH2}(t) - u'_{CH3}(t)$ та $\Delta 34(t) = u'_{CH3}(t) - u'_{CH4}(t)$ [59, 60]. Їхній фізичний зміст – диференціальне сприйняття: коли об'єкт розташований під однією з котушок, різниця з сусідньою максимальна; коли об'єкт рівновіддалений – мінімальна. Різницеві канали, отже,

несуть інформацію про положення вздовж осі Y , яку з окремих каналів отримати неможливо.

Польові вимірювання [60] підтвердили, що три котушки поведуться по-різному при зміщенні об'єкта, і ця відмінність стабільна та відтворювана; ця відмінність і є фізичною основою формування різницевих каналів. По суті це злиття на рівні сигналів усередині одного сенсора: виходи трьох котушок комбінуються заради нової інформації. Аналогічний прийом застосовано у Kolster et al. [29], де різниці між вертикально рознесеними магнітометрами забезпечували виявлення більшості цілей, тоді як горизонтальна конфігурація працювала значно гірше. У розглядуваній системі різницеві канали підвищують точність локалізації вздовж осі Y з ~ 35 см (окрема котушка) до одиниць сантиметрів (центроїд різницевого профілю) [59].

Після формування різницевих каналів для кожної точки (X_i, Y_j) маємо п'ятикомпонентний вектор

$$x(t) = [u'_{CH2}(t), u'_{CH3}(t), u'_{CH4}(t), \Delta 23(t), \Delta 34(t)], \quad (2.11)$$

саме він надалі подається на вхід нейромережевих методів аналізу, розглянутих у третьому розділі [59].

2.8.4 Розроблене енергетичне подання та двовимірні карти

Для задач просторового аналізу (локалізації, оцінювання розмірів, формування карти ризику) запропоновано зведення часової розмірності до скалярної характеристики, енергії сигналу [59]:

$$E(X, Y) = \sum t \sum X u'(t, X, Y)^2, \quad (2.12)$$

де підсумовування виконується по часовому вікну 15–120 мкс. Результат – двовимірна енергетична карта $E(X, Y)$, максимумами якої вказують на позиції об'єктів. Приклади енергетичних карт для еталонних і невідомих об'єктів наведено у підрозділі 5.1.

Енергетичне подання покладено також в основу формування додаткової ознаки об'єкта: між середньою енергією відгуку та фізичними параметрами об'єкта (кількістю шарів, провідною площею, масою) існують лінійні регресійні

залежності, які дають змогу оцінювати тип об'єкта ще до нейромережевого класифікатора. Побудову енергетичних карт еталонних і невідомих об'єктів та кількісні регресійні залежності, отримані на відкритому наборі даних, наведено в підрозділі 5.1.

Енергетичне подання має кілька властивостей, які роблять його зручним саме для просторових задач. Воно інваріантне до знака і малих часових зсувів сигналу, тож невеликі похибки синхронізації не руйнують карту; воно монотонно зростає з амплітудою відгуку, зберігаючи впорядкованість «більший об'єкт – більша енергія», на якій ґрунтуються регресійні оцінки; нарешті, підсумовування за вікном 15–120 мкс свідомо відсікає ранню зону, де домінує власний «дзвін» приймального тракту, і пізню, де переважає шум. Платою за стиснення є втрата інформації про форму затухання; тому енергетична карта використовується для локалізації, тоді як класифікація виконується за повними часовими розгортками.

Зазначимо, що енергетична карта $E(X, Y)$ є зручним форматом для злиття з іншими каналами, адже вона має ту саму просторову розмірність (координатна сітка $X \times Y$), що й магнітометрична карта чи оптичне зображення. Тому $E(X, Y)$ виступає RI-каналом у мультисенсорному тензорі $T(x, y, k)$, описаному в підрозділі 2.6.

2.9 Польова апробація конвеєра на відкритому наборі даних

Сформований конвеєр перевірено на відкритому наборі лабораторних і польових вимірювань трикутшкового міношукача [59; 60]. Склад набору, сценарії польових випробувань та кількісні результати виявлення, класифікації й локалізації об'єктів наведено в підрозділі 5.1.

2.10 Узагальнена декомпозиція сигналу та формування входу нейронної мережі

Конвеєр підготовки даних узагальнюється декомпозицією вимірюваного сигналу для кожного каналу:

$$S_c(x, y, t) = B_c(x, y) + A_c(x, y, t) + N_c(t) + E_c(x, y), \quad (2.13)$$

$$c \in \{PI, MAG, MS, GPR\},$$

де B_c – фонові складова (відгук ґрунту без цільового об'єкта);

A_c – аномальна складова (сигнал від прихованого об'єкта);

N_c – шум датчика (електронний, квантування, наведення від електродвигунів носія),

E_c – систематична завада: мінералізація для імпульсної індукції, регіональний градієнт для магнітометра, нерівномірність освітлення для камери.

Задача попереднього оброблення кожного каналу в цих термінах – виділення оцінки аномальної складової $\hat{A}_c$ із загального сигналу. Для PI-каналу це реалізовано відніманням базової лінії та фільтрацією [59, 60]; для магнітометра – диференціальним обробленням пари вертикально рознесених сенсорів [5]; для камери – радіометричною корекцією та обчисленням нормалізованих індексів [61]. Той самий принцип застосовано у [36] для індукційних даних (EMD-декомпозиція) та георадарних (видалення фону, SVD).

Після попереднього оброблення кожна оцінка $\hat{A}_c$ проходить інтерполяцію (підрозділ 2.6) і потрапляє у відповідний канал тензора $\mathbf{T}(x, y, k)$. Нейронна мережа, відтак, отримує не сирий сигнал, а попередньо оброблений і просторово прив'язаний тензор, де кожна складова має чітке фізичне значення. Цей принцип (фізично обґрунтоване попереднє оброблення замість подавання «всього підряд») є одним з ключових архітектурних рішень роботи: він суттєво зменшує обсяг інформації, яку мережа має засвоїти самостійно, і дає змогу працювати з відносно невеликими навчальними вибірками, що критично у предметній області, де збирання даних обмежене безпековими і фізичними чинниками [59, 60].

2.11 Метрики якості та їх зв'язок з архітектурою злиття

Для об'єктивного оцінювання якості розробленої системи визначено набір метрик, що відображають вимоги реальних операцій з розмінування.

2.11.1 Обрані метрики та їх обґрунтування

Ймовірність виявлення $Pd = \frac{TP}{(TP + FN)}$ є критичною метрикою: пропущена міна може коштувати життя. Вимоги міжнародних стандартів протимінної діяльності до повноти очищення території надзвичайно жорсткі. Допустимими вважаються лише одиничні пропуски на тисячу цілей. Досягнення такого рівня одним сенсором практично неможливе, що додатково підтверджує необхідність мультисенсорного злиття [1, 6, 36].

Ймовірність хибної тривоги:

$$P_{fa} = \frac{FP}{(FP + TN)}, \quad (2.14)$$

де TP – правильно виявлені цілі, FN – пропущені цілі, FP – хибні спрацювання, TN – правильно відхилені фонові точки визначає продуктивність розмінування. За даними [1, 6], типовий рівень хибних тривог ручних металошукачів сягає 0,5–0,9, тобто від кожного другого до дев'яти з десяти спрацювань виявляються хибними. Мультисенсорне злиття, як показано у [36], дозволяє знизити P_{fa} до 0,02 при збереженні Pd понад 0,98.

Операційний зміст P_{fa} варто проговорити окремо. Кожне спрацювання дистанційної системи перетворюється на точку, яку наземна група зобов'язана перевірити вручну за повною процедурою. Тому рівень хибних тривог напряду конвертується у людино-години та вартість обстеження одиниці площі: система з високою повнотою виявлення, але надмірним P_{fa} , на практиці не прискорює розмінування, а лише переносить навантаження з пошуку на перевірку. Звідси й вимога розглядати Pd і P_{fa} як пару, а не як незалежні показники.

$F1$ -міра, $F1 = \frac{2 \cdot P \cdot R}{(P + R)}$, збалансовано враховує обидва типи помилок.

Реалізована одновимірна згорткова мережа на PI-даних досягла $F1 > 0,95$ на лабораторних даних [59]; для порівняння, у наборі HoloMine [64] найкращий базовий результат (ViT) становив лише 69,3 %, а злиття індукційного сенсора з георадаром у [36] – понад 98 %.

Середньоквадратична похибка локалізації

$$r_{RMSE} = \sqrt{\left[\left(\frac{1}{N}\right) \cdot \sum_{i=1}^N \left((\hat{X}_i - X_i)^2 + (\hat{Y}_i - Y_i)^2\right)\right]}, \quad (2.15)$$

специфічна метрика задачі позиціонування: для безпечного маркування потрібно $r_{RMSE} < 30$ см. На лабораторних даних локалізація енергетичним центроїдом забезпечила r_{RMSE} порядку одиниць сантиметрів [59].

Важливо, що P_d і P_{fa} не є незалежними: обидві визначаються положенням порога прийняття рішення на кривій робочої характеристики класифікатора. Зниження порога підвищує повноту виявлення ціною зростання хибних тривог, і навпаки. Тому в задачах розмінування робочу точку слід обирати не за максимумом інтегральної точності, а за операційними вимогами: спочатку фіксується мінімально припустима ймовірність виявлення, і лише потім мінімізується рівень хибних тривог, досяжний за цього обмеження. Така логіка визначає й вимоги до архітектури злиття: кожен додатковий інформативний канал зсуває криву робочої характеристики, дозволяючи отримати менший P_{fa} за того самого P_d .

2.11.2 Розроблений підхід до функції втрат

Окремо обґрунтовано потребу в асиметричній функції втрат: ціна помилок у край нерівна. Пропуск міни загрожує життю, тоді як хибна тривога коштує лише додаткового часу перевірки. Замість стандартної крос-ентропії запропоновано зважену: $Lw = -[w1 \cdot y \cdot \log(p) + w0 \cdot (1-y) \cdot \log(1-p)]$, де співвідношення $w1/w0 = 10-50$ обирається за операційними вимогами. Як альтернативу розглянуто Focal Loss, що автоматично зосереджує навчання на складних випадках; обидва підходи проаналізовано з погляду їхнього впливу на баланс P_d і P_{fa} .

Співвідношення ваг $w1/w0$ має прозору інтерпретацію через матрицю цін помилок: якщо умовна «вартість» пропуску цілі у CFN разів перевищує вартість хибної тривоги CFP, то мінімізація очікуваних втрат еквівалентна навчанню зі зваженою функцією, у якій $\frac{w1}{w0} = \frac{CFN}{CFP}$. Діапазон 10–50 відповідає, отже, консервативній оцінці співвідношення цін у задачах розмінування і може

уточнюватися замовником операції без зміни архітектури, оскільки достатньо донавчити модель з новими вагами. Це переводить вибір балансу $\frac{P_d}{P_{fa}}$ з області неявних властивостей моделі у область явних операційних рішень.

Для мультисенсорного злиття визначено додаткове правило: якщо аномалію виявив хоча б один канал, система сигналізує про неї (правило логічного «АБО»), навіть якщо решта каналів «мовчить». Подальше зниження P_{fa} досягається мультисенсорним підтвердженням при повторних проходах.

2.11.3 Зв'язок метрик з рівнями злиття

Різні архітектури злиття впливають на показники якості по-різному. Сигнальний рівень підвищує відношення сигнал/завада через взаємну компенсацію шумів, що позитивно позначається на P_d . Ознаковий рівень виявляє міжканальні залежності й тому ефективний для зниження P_{fa} узгоджена аномалія в кількох каналах з високою ймовірністю реальна. Рішеннявий рівень через ансамблювання [43] додає робастності. Навіть за помилки окремого класифікатора загальне рішення може лишатися правильним. Цей аналіз додатково обґрунтовує обрану гібридну архітектуру (підрозділ 2.7.4).

Кількісне підтвердження ефекту злиття дають результати [36]: для мультикласової задачі (14 класів) злиття індукційних і георадарних даних підвищило точність з 48,9 % (один канал) до 56,1 % (ознаковий рівень), а для бінарної задачі приріст ще разючіший – з 76,8 % до 99,99 %. Ефект злиття, отже, максимальний саме для складніших задач, де дискримінантна здатність окремих каналів обмежена.

Для розглядуваної системи з цього випливає практичний висновок: внутрішньосенсорне сигнальне злиття трьох котушок металошукача працює на підвищення чутливості виявлення, ознакове злиття гілок різних сенсорів – на придушення хибних тривог, а рішенняве ансамблювання – на стабільність підсумкової оцінки. Три рівні, отже, не конкурують, а закривають різні складові якості, що і є головним аргументом гібридної архітектури.

2.12 Карта ризику як кінцевий інформаційний продукт

Практичним результатом усього конвеєра злиття є карта ризику – просторове зображення обстеженої території, у якому кожній комірці присвоєно кількісну оцінку ймовірності наявності небезпечного предмета. Карту ризику розроблено як багат шаровий геоінформаційний продукт [5, 61]: перший шар – апостеріорна ймовірність $P(H1|x)$, обчислена нейронною мережею на основі мультисенсорного тензора; другий – координати центру аномалії $(\hat{X}, \hat{Y})$, отримані енергетичним центроїдом [59] та уточнені злиттям з іншими каналами; третій – класифікація типу об'єкта; четвертий – рівень довіри, який визначається узгодженістю показань різних каналів.

Результати експортуються у сумісні з геоінформаційними системами формати: растрові теплокарти, векторні шари з координатами та атрибутами аномалій, а також звіти з індикаторами рівня ризику [61]. Інтеграція з програмним забезпеченням планування місій на наземній станції [5] забезпечує візуалізацію на планшеті оператора, а експортовані шари безпосередньо використовуються командами розмінування.

Запропоновано також кумулятивний режим побудови карти ризику: результати першого проходу визначають зони повторного обстеження з іншими параметрами (меншою висотою чи іншим набором сенсорів). Для планування таких адаптивних місій у [61] розроблено генетичний алгоритм оптимізації маршрутів, який скоротив загальний час польоту на 27 % порівняно з рівномірним покриттям. Схему адаптивного планування наведено на рис. 2.14.




Рисунок 2.14 – Схема адаптивного планування місій з GA-оптимізацією маршрутів: перший проліт → карта ризику → уточнюючий проліт [61]

2.13 Позиціонування розробленої системи серед існуючих рішень

Для обґрунтування новизни проведено порівняльний аналіз розробленої системи з відомими мультисенсорними рішеннями та наборами даних.

Система Khan et al. (Хорватія, HCR-CTRO) [36] використовує індукційний сенсор та георадар для 14 об'єктів у трьох типах ґрунтів; виконано масштабне дослідження, що охопило 900 варіантів шести моделей штучного інтелекту. Головний результат: злиття двох каналів перевершує кожен окремий. Система, втім, наземна, а не БПЛА-базована, що обмежує швидкість обстеження.

Система Kolster et al. (Данія, DTU) [29] – три скалярні магнітометри QuSpin під БПЛА на тросі завдовжки 10 м, швидкість ~ 10 м/с, шум $\sim 3,6$ пТл; покриття 600×100 м за 58 хв, 24 реальні вибухонебезпечні об'єкти. Докладно описано весь

конвеєр оброблення, включно з корекцією часових міток і ймовірнісною дипольною інверсією, але використано один тип сенсора, без злиття з іншими каналами.

Набір даних HoloMine [64] – 41 800 синтетичних голографічних зображень, 7 типів мін; коефіцієнт злиття $\alpha = 0,14$ визначено теоретично та емпірично, найкращий базовий результат – лише 69,3 % $F1$. Внесок цієї роботи – методологія синтетичних мультисенсорних даних, однак сенсор лише один; близький за ідеєю підхід до формування синтетичних навчальних наборів зображень розвинено й у власній роботі [70]. Набір AMLID [65] – 12 078 зображень $RGB+LWIR$, 21 тип мін; мультитемпоральний збір дав приріст +1,8–9,6 в. п. mAP, але це виключно оптика, без підповерхневих сенсорів. Порівняльні характеристики зведено у табл. 2.1.

Таблиця 2.1 – Порівняння існуючих мультисенсорних систем і наборів даних для виявлення аномалій у ґрунті

Система / набір даних	Сенсори	Дані / обсяг	Платформа	Обмеження
Khan et al. [36]	Індукційний + георадар	14 об'єктів, 3 типи ґрунту	Наземна	Не БПЛА; мала швидкість обстеження
Kolster et al. [29]	Магнітометри QuSpin	600×100 м, 24 об'єкти	БПЛА на тросі	Один тип сенсора, без злиття
HoloMine [64]	Голографічний (HSR)	41 800 синтетичних зображень	Лабораторна	Один сенсор; базовий $F1$ – 69,3 %
AMLID [65]	RGB + LWIR	12 078 зображень	БПЛА	Лише оптика, без підповерхневих
Розроблена система	PI + TMR + MS (+георадар)	Лабораторні + польові дані	БПЛА (гексакоптер)	Польова валідація триває

Порівняння у табл. 2.1 ведеться за п'ятьма критеріями, що відповідають практичним вимогам задачі: склад сенсорів визначає принципову здатність бачити різні класи цілей; обсяг і походження даних – ступінь експериментальної підтвердженості; платформа – продуктивність обстеження; колонка обмежень фіксує головний чинник, який стримує практичне застосування кожного рішення. Жодна з відомих систем не закриває всі критерії одночасно, і саме ця прогалина визначає нішу розробленої платформи.

Розроблена система відрізняється від перелічених за кількома принциповими аспектами. Вона поєднує підповерхневі (металошукач, магнітометр) і поверхневі (мультиспектральна камера) канали на одній БПЛА-платформі; такої комбінації не має жодна з розглянутих систем. Архітектура платформи відкрита й модульна [5]: нові сенсори (георадар, гамма-детектор) додаються без переробки базової конструкції. Повний конвеєр «сирий сигнал → класифікація → локалізація» реалізовано і валідовано для РІ-каналу [59] та підготовлено до розширення на мультисенсорний випадок. Нарешті, запропонована архітектура ансамблевого злиття [43] масштабована за побудовою: додавання нового каналу зводиться до додавання нового класифікатора першого рівня без зміни решти системи.

2.14 Розроблена інформаційна модель дистанційного моніторингу ґрунту

Описані в попередніх підрозділах етапи оброблення (від збирання сирих сигналів до формування підсумкових інформаційних продуктів) є елементами єдиної інформаційної моделі, розробленої для опису всього процесу дистанційного моніторингу [21]. Модель визначає потік даних, інтерфейси між рівнями оброблення та розподіл обчислювальних ресурсів між бортовою і наземною підсистемами. Загальну структуру моделі наведено на рис. 2.15.




Рисунок 2.15 – Розроблена п'ятирівнева інформаційна модель дистанційного моніторингу ґрунту [21]

Виокремлено п'ять рівнів оброблення, які відповідають відомій моделі JDL [63], але конкретизовані для розглядуваної предметної області та апаратної бази.

2.14.1 Рівень збору даних

Цей рівень описує апаратні засоби і протоколи зв'язку сенсорів. Трикотушковий PI-металошукач підключено до високошвидкісного АЦП бортового одноплатного комп'ютера через SPI-шину [5]; трьохканальний TMR-магнітометр – через аналоговий тракт (підсилювач → фільтр → АЦП) до того ж обчислювача [5]. Мультиспектральна камера працює як незалежний пристрій із власним GPS-приймачем і передає дані через USB [61]. Позиціонування забезпечує RTK GNSS HERE4 (F9P) у парі з ArduSimple через UART/CAN [5]. Пультний контролер CubeOrange+ (STM32H743) відповідає виключно за керування польотом і навігаційні сенсори (гіроскоп, акселерометр, барометр,

GPS, регулятори) і жодних функцій оброблення вимірювальних даних не виконує [5].

Чітке розділення функцій між польотним контролером та обчислювальним модулем є принциповим рішенням, яке дає одразу три переваги: незалежність критичної підсистеми керування польотом від навантаження оброблення сенсорних даних; можливість заміни обчислювального модуля без втручання у польотну електроніку; гнучкість у завантаженні нових алгоритмів оброблення без перепрошивання контролера [5].

2.14.2 Рівень передачі даних

Систему зв'язку побудовано трьохканальною, з розділенням потоків за призначенням [5]. Перший канал (ELRS 900 МГц) виділено виключно для команд керування носієм з ультранизькою затримкою (приймач з термокомпенсованим опорним генератором). Другий, RFD900x (900 МГц, потужність до 1 Вт, дальність до 40 км), несе MAVLink-телеметрію, RTK-поправки та компактні сенсорні дані металошукача і магнітометра. Третій, RTL8812 (2,4/5 ГГц), призначений для відео високої чіткості та мультиспектральних зображень. Схему розподілу каналів наведено на рис. 2.16.

Частотний план поділу спирається на фізику поширення: діапазон 900 МГц дає кращу проникність і дальність за помірної швидкості (властивості, потрібні командам керування і телеметрії), тоді як 2,4/5 ГГц дає широку смугу для відеопотоку ціною меншої дальності. Рознесення критичних і об'ємних потоків по фізично різних діапазонах означає, що навіть повна втрата відеоканалу не зачіпає керованості носія.

Таке розділення виключає взаємний вплив інформаційних потоків: перевантаження каналу передавання зображень не зачіпає ні телеметрії, ні команд керування, що критично для безпеки польоту. Додатково передбачено резервний канал LoRa для аварійних команд [5]. Підтримка MESH-мереж модемами RFD900x закладає технічну основу для майбутнього рійового застосування кількох носіїв [5].




Рисунок 2.16 – Розроблена трьохканальна система зв'язку: розподіл потоків даних між каналами ELRS, RFD900x та RTL8812 [5]

2.14.3 Рівень попередньої обробки

На цьому рівні реалізовано операції, описані у підрозділах 2.4–2.6: синхронізація часових міток, просторова прив'язка, віднімання фону, нормалізація, формування різницевих каналів, інтерполяція. Обчислення розподілено між бортом і землею: первинна фільтрація, компресія зображень і запис на носій з координатами виконуються на борту; повна інтерполяція, формування мультисенсорного тензора і навчання моделей – на наземній станції або у відкладеному режимі після місії [5, 60].

Таке рішення обґрунтоване вимогами до часу реакції. Для задач, які потребують бортового рішення (адаптивного перепланування маршруту, обходу

перешкод) попереднє оброблення РІ-каналу виконується на борту швидше ніж за 4 мс [59]; для формування підсумкової карти ризику, де постоброблення прийнятне, дані зберігаються і обробляються після посадки.

Запис даних організовано із дублюванням критичної інформації: кожен сенсорний потік зберігається на бортовому носії у сирому вигляді разом з часовими мітками ще до будь-якого оброблення, тож збій каналу зв'язку чи наземної станції не призводить до втрати місії – дані відновлюються після посадки. Передачі в реальному часі підлягають лише компактні похідні (телеметрія, стиснуті прев'ю, координати спрацювань), що вкладається у пропускну здатність радіоканалів з великим запасом. Такий поділ «сире – на борт, похідне – в ефір» одночасно розвантажує канали зв'язку і гарантує відтворюваність подальшого аналізу.

2.14.4 Рівень злиття та аналізу

Цей рівень реалізовано як гібрид ознакового і рішеннєвого злиття (підрозділ 2.7.4): РІ-гілка на одновимірній згортковій мережі [59], магнітометрична та оптична гілки працюють паралельно, формуючи вектори ознак, які об'єднуються ансамблевим класифікатором зі стекінгом [43]. Результат для кожної комірки координатної сітки – ймовірність наявності аномалії $P(H1)$, оцінка типу, координати та рівень довіри.

2.14.5 Рівень прийняття рішень

На завершальному рівні результати аналізу перетворюються на практичні продукти: карту ризику (підрозділ 2.12), звіт з координатами аномалій, рекомендації щодо подальших дій. Інтеграція з програмним забезпеченням планування місій [5] та геоінформаційними системами [61] забезпечує візуалізацію на планшеті оператора й експорт у формати, придатні для команд розмінування (GeoTIFF, KML, PDF). На цьому ж рівні реалізовано зворотний зв'язок: результати першого проходу через генетичну оптимізацію маршруту [61] визначають зони повторного обстеження.

Цінність розробленої інформаційної моделі в тому, що вона чітко визначає інтерфейси між рівнями: яких даних очікує кожен наступний рівень від попереднього, у якому форматі і з якою затримкою. Це дає змогу розробляти й тестувати кожен рівень незалежно, а також замінювати окремі компоненти (додати георадарний канал чи змінити архітектуру нейронної мережі) без переробки всієї системи [21].

2.15 Формалізація задачі виявлення аномалій у мультисенсорному просторі

Попередні підрозділи описали архітектуру злиття, конвеєр оброблення та інформаційну модель. Перш ніж переходити до узагальненої постановки, сформулюємо саму задачу виявлення у термінах, які безпосередньо пов'язують розроблений конвеєр з нейромережовим обробленням.

2.15.1 Задача виявлення як перевірка гіпотез

У класичній теорії оптимальним є критерій Неймана–Пірсона, що максимізує Pd за заданого обмеження на P_{fa} . Для мультисенсорного випадку з фізично різнорідними каналами аналітичне застосування цього критерію, однак, практично нереалізоване: вхідний вектор має змішану природу (часові ряди, зображення, скалярні ознаки), а розподіли сигналів за H_0 та H_1 залежать від багатьох неконтрольованих чинників – типу ґрунту, вологості, температури, типу об'єкта [36, 59]. Тому обрано нейромережовий підхід, який замінює аналітичне порогове правило навченою функцією рішення

$$d(x) = f_{\theta}(\mathbf{T}(x, y, k)),$$

де θ – параметри мережі, $\mathbf{T}$ – мультисенсорний тензор, а f_{θ} відображає його в апостеріорну ймовірність $P(H_1|\mathbf{T})$.

Рішення приймається за порогом η , який визначає робочу точку на кривій робочої характеристики й обирається за операційними вимогами (підрозділ 2.11.2). Нейронна мережа неявно виконує нелінійне злиття, вибір ознак і

порогове оброблення в єдиному диференційованому конвеєрі, параметри якого оптимізуються мінімізацією зваженої функції втрат [59].

2.15.2 Задача локалізації як регресія координат

Окрім бінарного виявлення, розв'язується задача локалізації – визначення просторових координат виявленого об'єкта. Розроблено двоетапний підхід [59]: спочатку визначається дискретна позиція максимуму енергетичної карти $E(X_i, Y_i)$, яку позначимо (X^*, Y^*) , після чого виконується уточнення безперервним центроїдом:

$$\hat{X} = \frac{\sum_{i=1}^{N_x} X_i E(X_i, Y^*)}{\sum_{i=1}^{N_x} E(X_i, Y^*)}, \quad (2.16)$$

$$\hat{Y} = \frac{\sum_{j=1}^{N_y} Y_j E(X^*, Y_j)}{\sum_{j=1}^{N_y} E(X^*, Y_j)}, \quad (2.17)$$

де X_i, Y_j – координати вузлів енергетичної карти, N_x, N_y – кількість вузлів за відповідними координатами, X^*, Y^* – координати дискретного максимуму, а $\hat{X}, \hat{Y}$ – уточнені координати. Такий підхід дає підсіткову точність: r_{RMSE} порядку одиниць сантиметрів на лабораторних даних [59]. У мультисенсорному випадку локалізація уточнюється об'єднанням оцінок різних каналів: РІ-центроїд, позиція максимуму магнітного градієнта та результат детекції на оптичному зображенні дають три незалежні оцінки, зважене середнє яких має меншу дисперсію, ніж кожна окремо; ваги визначаються оцінкою невизначеності кожного каналу.

Для підповерхневих об'єктів задача має додатковий вимір – оцінювання глибини залягання z . Для РІ-каналу глибина оцінюється за амплітудою сигналу і сталою часу затухання: середня РІ-енергія $\bar{E}_{obj}$ лінійно корелює з відстанню до об'єкта [59], що дозволяє побудувати регресійну модель глибини. Для магнітометра глибину оцінюють за шириною аномалії на половині висоти [29, 62]. У мультисенсорному підході ці оцінки об'єднуються, що відповідає додаванню третьої регресійної «голови» нейронної мережі для координати z .

2.15.3 Мультикласова задача та її складність

Практичне значення має й мультикласова задача – визначення типу об'єкта: протитанкова міна, протипіхотна, нерозірваний боєприпас, металеве сміття, геологічна аномалія. Ця задача значно складніша за бінарну: у [36] мультикласова класифікація (14 класів) досягла лише 48,9 %, тоді як бінарна – 99,99 %. Задачі «виявити» і «ідентифікувати», отже, мають якісно різну складність, і мультисенсорне злиття особливо критичне саме для ідентифікації, де один канал не забезпечує достатньої роздільної здатності між класами.

Для РІ-каналу досягнуто 95–100 % точності розрізнення чотирьох класів еталонних об'єктів (шайби з кількістю шарів 1, 2, 3, 4) на лабораторних даних [59]. Показово, що невідомі об'єкти U1 та U2, які не входили до навчальної вибірки, система коректно визначила як проміжні між N3 та N4 за розміром і масою, що підтверджує здатність до узагальнення на нові об'єкти [59]. Додавання магнітометричних та оптичних ознак має розширити набір класів і підвищити точність ідентифікації об'єктів, які погано розрізняються за одним РІ-каналом.

2.15.4 Підсумковий конвеєр: від сенсора до рішення

Узагальнення підрозділів 2.1–2.14 дає повний конвеєр оброблення, який реалізує архітектуру злиття як послідовність чітко визначених етапів; підсумкову схему наведено на рис. 2.17.



Рисунок 2.17 – Узагальнена схема розробленого конвеєра злиття: від сирих сенсорних потоків до карти ризику

Конвеєр складається з таких послідовних блоків: (1) збирання сирих даних – PI-тензор $S(c, X, Y, t)$, магнітометричний профіль, мультиспектральні кадри, потік RTK-координат [5]; (2) синхронізація у часі – єдина часова база бортового обчислювача для металошукача і магнітометра, супутниковий час для камери [5, 29]; (3) просторова прив'язка – RTK GNSS з інтерполяцією координат для кожного вимірювання [5]; (4) попереднє оброблення – віднімання фону, нормалізація, різницеві канали $\Delta 23$, $\Delta 34$ для PI, диференціальне оброблення пар сенсорів для магнітометра, обчислення NDVI, VARI, GLCM для камери [5, 59, 61]; (5) інтерполяція на єдину сітку 10×10 см – білінійна для PI і магнітометра, підвибірка для камери [59]; (6) формування мультисенсорного тензора $T(x, y, k)$ (підрозділ 2.6); (7) нейромережеве злиття – паралельні гілки каналів та ансамблевий стекінг [43, 59]; (8) класифікація Н0/Н1, ідентифікація типу, локалізація $(\hat{X}, \hat{Y}, \hat{Z})$ [59]; (9) формування карти ризику у геоінформаційних форматах (підрозділ 2.12 [61]).

Кожен блок конвеєра реалізовано і валідовано для PI-каналу [59, 60] та підготовлено до розширення на повний мультисенсорний випадок; час оброблення PI-каналу – менше 4 мс [59]. Зasadничим є свідомий вибір фізично обґрунтованого попереднього оброблення: кожен канал проходить ретельну підготовку (виділення аномальної складової, компенсацію фону, нормалізацію) перед подаванням на нейронну мережу. Альтернатива, подавання сирих даних «як є» з покладанням на мережу у виділенні ознак, потребує значно більших обсягів навчальних даних, яких у цій предметній області об'єктивно бракує через безпекові обмеження, доступ до полігонів і вартість еталонних об'єктів [59, 60]. Фізично обґрунтоване попереднє оброблення вносить у конвеєр експертне знання про природу сигналів, суттєво зменшуючи простір ознак і дозволяючи працювати з компактними вибірками.

2.16 Узагальнена постановка задачі дисертаційного дослідження

Проведений аналіз дозволяє сформулювати узагальнену постановку задачі, яка є предметом дисертаційного дослідження.

Дано: безпілотна платформа (гексакоптер зі складними променями, польотний контролер CubeOrange+ під ArduPilot, корисне навантаження до 4 кг [5, 60]), оснащена мультисенсорним комплектом: трикотушковий РІ-металошукач (три зони, смуга 105 см, чутливість 34 см [5]); трьохканальний TMR-магнітометр (три диференціальні пари, смуга ~1 м [5]); мультиспектральна камера (R, G, B, NIR, роздільна здатність 1,7 см/піксель з висоти 20 м [61]). Підсистема позиціонування: RTK GNSS HERE4 (F9P) з резервним ArduSimple (сантиметровий рівень точності) та далекомірний лідар Benewake TF-plus (± 2 см) [5]. Бортовий обчислювач – одноплатний комп'ютер з модулем апаратного прискорення нейромережових обчислень [5]; наземна станція з трьома незалежними каналами зв'язку [5].

Вхідні дані: синхронізовані потоки сенсорних каналів: РІ – чотиривимірний тензор $\mathbf{S}(c, X, Y, t)$, $c \in \{CH2, CH3, CH4\}$ [59]; магнітометр – тривимірний просторовий профіль з трьох диференціальних каналів [5]; камера – багатоканальне зображення $H \times W \times 4$ з похідними індексами $NDVI$, $VARI$, $GLCM$ [61]; координати – потік RTK GNSS, інерціальних вимірювань і лідара [5].

Потрібно розробити: конвеєр злиття різнорідних даних, що перетворює сенсорні потоки на структуроване багатоканальне подання для нейронних мереж і забезпечує: (1) синхронізацію вимірювань у часі з точністю, достатньою для просторового суміщення за швидкості 1–3 м/с (реалізовано, підрозділ 2.4); (2) просторову прив'язку всіх каналів з точністю кінематики реального часу (реалізовано, підрозділ 2.5); (3) інтерполяцію на єдину сітку 10×10 см (реалізовано, підрозділ 2.6); (4) формування навчальної вибірки з визначеними форматами, мітками та правилами розбиття (розглядається у четвертому розділі); (5) класифікацію аномалій та локалізацію нейромережевими методами (РІ-канал реалізовано: 95–100 %, менше 4 мс на лабораторних даних [59]; мультисенсорне розширення є предметом третього розділу); (6) формування карти ризику у геоінформаційних форматах (реалізовано, підрозділ 2.12 [61]).

Зв'язок між пунктами постановки ієрархічний: пункти (1)–(3) формують узгоджене подання даних і є передумовою решти; пункт (4) перетворює подання на навчальний матеріал; пункт (5) реалізує власне виявлення; пункт (6) перетворює рішення на операційний продукт. Невиконання будь-якого з ранніх пунктів знецінює пізні: нейронна мережа, навчена на неузгоджених даних, успадковує їхні похибки, і тому конвеєр будується строго послідовно.

Цільові показники якості визначено так: ймовірність виявлення металевих об'єктів $Pd \geq 0,97$ (PI-канал на лабораторних даних: 95–100 % [59]); рівень хибних тривог $Pfa \leq 0,05$ (зниження через мультисенсорне підтвердження); $F1 \geq 0,95$ (PI-канал: понад 0,95 [59]); похибка локалізації $r_{RMSE} \leq 10$ см (PI-канал: одиниці сантиметрів [59]); час конвеєра PI – менше 4 мс (досягнуто [59]).

Обмеження: обчислювальні ресурси – бортовий одноплатний комп'ютер з апаратним прискорювачем; обсяг даних – лабораторні вимірювання та обмежені польові [60]; модель має зберігати працездатність при зміні типу ґрунту і кліматичних умов (проблема доменного зсуву, розглядається у четвертому розділі); архітектура – модульна, з можливістю додавання георадара без переробки [5].

Сформульована постановка має важливу методологічну властивість: перевірюваність кожного пункту. Для кожної вимоги визначено вимірюваний показник і спосіб його отримання: часова синхронізація перевіряється за еквівалентним просторовим зміщенням потоків, прив'язка – порівнянням повторних проходів над тими самими цілями, інтерполяція – збереженням енергетичних максимумів, класифікація і локалізація – метриками підрозділу 2.9 на даних з відомим розташуванням об'єктів. Це відрізняє постановку від декларативних формулювань, виконання яких неможливо об'єктивно підтвердити, і безпосередньо визначає програму експериментальної перевірки у п'ятому розділі.

2.17 Відкриті проблеми та напрямки подальших досліджень

Попри досягнутий прогрес, залишається низка невирішених проблем, які визначають напрямки подальших досліджень.

Генералізація моделей. Експериментально встановлено [60], що моделі, навчені на лабораторних даних, потребують адаптації при переході до польових умов; у [36] так само показано, що тип ґрунту є одним з визначальних чинників якості. Запропонована стратегія «лабораторне навчання з подальшим польовим донавчанням» [60] дає практичний вихід, проте розроблення повноцінних методів адаптації до доменного зсуву для мультисенсорних систем залишається відкритою задачею.

Конкретний прояв цієї проблеми зафіксовано у власних польових вимірюваннях [60]: за однакових об'єктів і апаратури польові сигнатури відрізняються від лабораторних більшою позиційною невизначеністю через динаміку носія, варіації висоти підвіски та неоднорідність реального ґрунту. Модель, навчена виключно на «чистих» лабораторних кривих, стикається у полі з даними з іншого розподілу, і саме вимірювання масштабу цього зсуву на парних лабораторно-польових сценаріях є першим кроком до його подолання.

Інтеграція георадара. Георадар – єдиний канал, здатний виявляти повністю неметалеві об'єкти [5], однак його інтеграція з платформами вантажопідйомністю до 4 кг обмежена вимогами антенних систем та енергоспоживання. Модульна архітектура [5] технічно уможливорює підключення, і ця інтеграція планується як один з наступних етапів дослідження.

Адаптивні ваги злиття. У поточній реалізації ваги каналів фіксуються після навчання, тоді як ідеальна система мала б автоматично зважувати внесок кожного каналу залежно від поточних умов (вологості, типу ґрунту, температури). Концептуальну основу дає механізм уваги, за якого ваги стають функцією самих даних; практична реалізація для фізично різнорідних каналів є предметом подальшого дослідження.

Простий приклад ілюструє потребу в адаптивності: на сухому піщаному ґрунті індукційний канал працює у близьких до ідеальних умовах і його внесок має домінувати, тоді як на сильно мінералізованому ґрунті його достовірність

падає і вагу доцільно перерозподілити на користь магнітометричного та оптичного каналів. Фіксовані ваги, оптимальні «у середньому», у кожній з цих ситуацій поступаються адаптивним.

Стандартизація та публікація наборів даних. Загальноприйнятого еталонного набору для мультисенсорного виявлення мін сьогодні не існує: кожна група збирає власні дані, що унеможлиблює об'єктивне порівняння. Перший крок у цьому напрямі вже зроблено: власний набір лабораторних і польових вимірювань оприлюднено у відкритому репозиторії (<https://github.com/op-uav-lab/soil-monitor-mlp>) та зареєстровано з постійним цифровим ідентифікатором DOI: 10.5281/zenodo.20573976 [60]. Подальша робота – стандартизація метаданих, повний опис протоколів вимірювань – планується як окремий результат дисертації.

Масштабування до великих територій. Поточна конфігурація забезпечує обстеження ділянок площею в сотні квадратних метрів за один виліт (22–30 хв із повним навантаженням [5, 60]); території масштабу квадратних кілометрів вимагають одночасного застосування кількох носіїв. Використані в наземній станції модеми RFD900x за специфікацією виробника підтримують топологію MESH, тож технічна передумова для рійового режиму існує, однак у межах цього проєкту така конфігурація не реалізовувалася і не перевірялася. Рійова координація розглядається лише як напрям подальших досліджень, у якому генетичний оптимізатор маршрутів [61] може бути розширений на узгоджене планування місій кількох носіїв.

Інтерпретованість рішень. Нейронні мережі нерідко працюють як «чорні скриньки», тоді як у розмінуванні, де ціна помилки надзвичайно висока, інтерпретованість є необхідністю. У розглядуваному підході вона частково забезпечена фізично обґрунтованим попереднім обробленням: кожен канал тензора має чітке фізичне значення – енергія РІ-відгуку, магнітний градієнт, вегетаційний індекс, – і оператор може перевірити, на яких каналах ґрунтується рішення [59]. Розвиток методів пояснюваного штучного інтелекту для мультисенсорних систем є перспективним напрямком подальших досліджень.

2.18 Висновки до другого розділу

У другому розділі виконано системний аналіз задачі злиття різнорідних сенсорних даних для нейромережевого виявлення аномалій у полях фізичних величин і розроблено цілісну архітектуру такого злиття. Основні результати полягають у такому.

1. Обґрунтовано необхідність мультисенсорного підходу через аналіз фізичної взаємодоповнюваності каналів розробленої БПЛА-платформи. Охарактеризовано чотири канали (трикутний РІ-металошукач, трьохканальний TMR-магнітометр, мультиспектральну камеру та перспективний георадар) з акцентом на форматах даних та їхній принциповій різнорідності: саме вона є головною рушійною силою розроблення архітектури злиття [5, 59, 61].

2. Виокремлено і докладно описано п'ять ключових етапів конвеєра злиття: синхронізацію в часі, просторову прив'язку, перетворення часових сигналів у координати через траєкторію носія, інтерполяцію на єдину сітку 10×10 см і формування мультисенсорного тензора $T(x, y, k)$. Для кожного етапу наведено конкретні розроблені рішення і виявлені проблеми, зокрема джитер часових міток та методи його корекції [29], а також динамічні спотворення координат через вітер та інерційність носія [60].

3. Розроблено систему часового узгодження вимірювань, у якій усі канали апаратно прив'язані до спільного опорного сигналу супутникового приймача, а еквівалентна просторова похибка взаємного зміщення потоків не перевищує 2–4 см без постоброблення. На цій основі сформульовано перший пункт наукової новизни – удосконалений метод часового узгодження різнорідних вимірювальних потоків мультисенсорної платформи (підрозділ 2.4).

4. Розроблено автономну систему просторової прив'язки на основі кінематики реального часу без підключення до мережесервісів корекції; точність геоприв'язки у польових умовах становить 1–8 см. Сформульовано четвертий пункт наукової новизни – удосконалений метод просторової прив'язки

мультисенсорних вимірювань для роботи поза зоною покриття наземної інфраструктури (підрозділ 2.5).

5. Проаналізовано три рівні злиття (сигнальний, ознаковий і рішеннєвий) та обґрунтовано гібридну архітектуру: ознакове злиття як основний механізм, доповнене рішеннєвим ансамблюванням зі стекінгом [43]. Обґрунтованість вибору підтверджено кількісно: у [36] ознакове злиття індукційних і георадарних даних дало 99,99 % точності бінарної класифікації проти 76,8 % найкращого одноканального варіанта, а у власній роботі [43] метакласифікатор другого рівня знизив кількість помилок на 13–17 % порівняно з голосуванням більшістю.

6. Побудовано повний конвеєр оброблення РІ-даних як наскрізний приклад реалізації архітектури злиття для одного каналу: від чотиривимірної моделі $S(c, X, Y, t)$ через віднімання фону і формування різницевих каналів $\Delta 23, \Delta 34$ (внутрішньосенсорне злиття) до енергетичних карт $E(X, Y)$ з лінійними регресійними залежностями «енергія $\rightarrow$ фізичні параметри об'єкта» [59]. Модель $S(c, X, Y, t)$, яка одночасно враховує канал приймання, просторові координати і час релаксації відгуку, склала другий пункт наукової новизни (підрозділ 2.8). Різницеві канали підвищили точність локалізації вздовж поперечної осі з ~ 35 см до одиниць сантиметрів; час конвеєра – менше ніж 4 мс, що гарантує оброблення у темпі надходження вимірювань [59].

7. Визначено показники якості $(Pd, P_{fa}, F1, r_{RMSE})$ та обґрунтовано асиметричну функцію втрат (зважена крос-ентропія з $w1 \gg w0$) з огляду на нерівну ціну помилок у задачах розмінування; для рівня виявлення запропоновано правило логічного «АБО» з подальшим мультिकанальним підтвердженням. Простежено зв'язок метрик з рівнями злиття: сигнальний рівень покращує відношення сигнал/завада, ознаковий знижує рівень хибних тривог, рішеннєвий додає робастності [36, 43].

8. Виконано польову апробацію конвеєра на відкритому наборі даних: шість сценаріїв вимірювань на реальних об'єктах (гільза, металевий кілок розтяжки, кілок збільшеного розміру) за поперечних зміщень 0–60 см і висот сканування 10–20 см, по близько ста проходів у кожному сценарії. Підтверджено

відтворюваність диференціальної поведінки трьох котушок і повну сумісність польових даних з моделлю $S(c, X, Y, t)$; кількісне оцінювання показників на цих даних винесено до п'ятого розділу [60].

9. Запропоновано узагальнену декомпозицію вимірюваного сигналу $Sc = Bc + Ac + Nc + Ec$, яка уніфікує задачу попереднього оброблення всіх каналів як виділення оцінки аномальної складової, та формалізовано задачі аналізу: виявлення – як перевірку гіпотез H_0/H_1 з нейромережевою функцією рішення замість аналітично нереалізованого для різнорідних каналів критерію Неймана–Пірсона; локалізацію – як двоетапну регресію координат з підсітковим уточненням енергетичним центроїдом; ідентифікацію типу – як мультикласову задачу, для якої злиття каналів особливо критичне [36, 59].

10. Розроблено карту ризику як кінцевий багат шаровий геоінформаційний продукт конвеєра – апостеріорна ймовірність, координати, тип, рівень довіри – з експортом у растрові, векторні та звітні формати і кумулятивним режимом адаптивного допланування місій, який за рахунок генетичної оптимізації маршрутів скоротив загальний час польоту на 27 % [5, 61].

11. Побудовано п'ятирівневу інформаційну модель дистанційного моніторингу ґрунту [21], що описує весь потік даних від сенсора до рішення: збір → передача → попереднє оброблення → злиття → прийняття рішень. Модель конкретизовано для кожного компонента системи; принциповими рішеннями є чітке розділення функцій польотного контролера і бортового обчислювача та трьохканальна система зв'язку з розділенням потоків керування, телеметрії і даних [5].

12. Проведено порівняльний аналіз розробленої системи з відомими мультисенсорними рішеннями і наборами даних (Khan et al. [36], Kolster et al. [29], HoloMine [64], AMLID [65]). Показано, що поєднання підповерхневих (металошукач, магнітометр) і поверхневого (мультиспектральна камера) каналів на одній БПЛА-платформі не має прямих аналогів серед розглянутих систем, а

відкрита модульна архітектура [5] і масштабоване ансамблеве злиття [43] вирізняють розроблену систему за критеріями розширюваності.

13. Сформульовано узагальнену постановку задачі дисертаційного дослідження з цільовими показниками ($Pd \geq 0,97$; $P_{fa} \leq 0,05$; $F1 \geq 0,95$; $r_{RMSE} \leq 10$ см; час РІ-конвеєра < 4 мс), які для РІ-каналу досягнуто на лабораторних даних [59], та визначено відкриті проблеми: генералізація моделей і доменний зсув [60], інтеграція георадара [5], адаптивні ваги злиття, стандартизація наборів даних, рйове масштабування, інтерпретованість рішень.

Окремо підкреслимо межі експериментальної підтвердженості викладеного. Повністю реалізованими і перевіреними на цей момент є: апаратна платформа з трьома каналами, система синхронізації та автономної прив'язки, конвеєр оброблення РІ-даних з лабораторною валідацією [59, 60]. Мультисенсорне злиття на рівні ознак реалізовано архітектурно і обґрунтовано літературними результатами [36, 43]; його кількісна перевірка на власних польових даних належить до програми п'ятого розділу. Таке розмежування зробленого і запланованого наведено свідомо, оскільки воно убезпечує від приписування проєктним рішенням статусу експериментально доведених.

Таким підсумком другий розділ закриває першу групу задач дослідження (часове і просторове узгодження різнорідних потоків, їх структуроване подання і формалізацію задач аналізу) та формує методологічну основу для подальших розділів. Кожен ключовий елемент архітектури спирається на власні напрацювання, відображені в публікаціях і матеріалах: відкрита архітектура носія і сенсорний комплект [5], планування місій [61], ансамблевий класифікатор [43], конвеєр оброблення РІ-даних [59], лабораторні та польові випробування [60], інформаційна модель [21]. Нейромережевим методам аналізу сформованого подання присвячено третій розділ; формуванню навчальної вибірки, стратегіям подолання доменного зсуву і плануванню місій – четвертий; кількісній експериментальній перевірці за окремими сенсорними каналами, включно з оцінюванням показників на оприлюднених польових даних, – п'ятий.

Основні результати другого розділу опубліковано в працях [21, 57, 58].

РОЗДІЛ 3

НЕЙРОМЕРЕЖЕВІ МЕТОДИ ВИЯВЛЕННЯ ТА КЛАСИФІКАЦІЇ АНОМАЛІЙ ЗА МУЛЬТИСЕНСОРНИМИ ДАНИМИ

3.1 Вимоги до нейромережевих методів та вибір базових архітектур

Другий розділ завершився формалізацією задач виявлення, локалізації та класифікації аномалій у мультисенсорному просторі ознак (підрозділ 2.15) і побудовою структурованого подання даних – тензора $\mathbf{T}(x, y, k)$ та чотиривимірної моделі $\mathbf{S}(c, X, Y, t)$. Цей розділ присвячено наступному кроку: вибору та розробленню нейромережевих методів, які перетворюють сформоване подання на рішення. Вибір методів тут не може бути механічним перенесенням рішень з комп'ютерного зору – він має впливати з вимог, продиктованих самою задачею і умовами її розв'язання.

Перша вимога – відповідність архітектури структури даних кожного каналу. Сигнал імпульсної індукції є коротким часовим рядом з інформативною формою затухання; магнітометричний профіль і енергетичні карти – просторовими полями; мультиспектральні дані – багатоканальними зображеннями. Як показав аналіз у підрозділі 1.3, для часових рядів природними є одновимірні згорткові мережі [7, 45], для просторових подань – двовимірні згорткові та сегментаційні архітектури [46, 49], а універсальної архітектури, однаково придатної для всіх типів фізичних сигналів, у літературі не запропоновано [36, 37].

Друга вимога – працездатність за обмежених навчальних вибірок. Збирання даних у предметній області обмежене безпековими і фізичними чинниками (підрозділ 2.16), тому глибокі архітектури з десятками мільйонів параметрів, які потребують сотень тисяч розмічених прикладів, тут практично незастосовні без додаткових заходів. У літературі це обмеження пом'якшують трьома шляхами: компактними спеціалізованими моделями [45], ансамблюванням кількох різнорідних моделей [43, 44] та внесенням апріорного

знання про фізику сигналу в саму модель або процедуру навчання [50, 51]. У цій роботі використано всі три шляхи.

Третя вимога – придатність до бортового виконання. Платформа надає обмежений обчислювальний ресурс одноплатного комп'ютера, а корисний темп оброблення визначається частотами каналів (238 Гц для імпульсної індукції) і швидкістю польоту 1–3 м/с. Це виключає важкі архітектури з часом інференсу в сотні мілісекунд і висуває на перший план компактні згорткові моделі, для яких час оброблення прогнозований і слабо залежить від вмісту даних.

Четверта вимога – інтерпретованість рішень, критична для застосувань з високою ціною помилки (підрозділ 2.17). Вона досягається не тільки вибором моделі, але і фізично обґрунтованим попереднім обробленням: кожен канал тензора $\mathbf{T}(x, y, k)$ має чітке фізичне значення, тож внесок каналів у рішення може бути проаналізований оператором.

У світлі цих вимог доцільно коротко співвіднести основні класи сучасних архітектур із задачею. Глибокі залишкові мережі на кшталт ResNet розв'язують проблему деградації навчання зі зростанням глибини [48] – але вигреш від великої глибини проявляється на великих вибірках, яких у задачі немає. Сегментаційні архітектури типу U-Net будують попиксельні карки ймовірності [8, 46] і є природним кандидатом для аналізу просторових подань на наземній станції, де обчислювальний ресурс не критичний. Трансформерні моделі й механізми уваги забезпечують адаптивне зважування входів і глобальний контекст [36, 37]; їхні обмеження – вимогливість до обсягу вибірки та обчислень – роблять їх у цій задачі не базовою архітектурою, а джерелом ідеї адаптивного зважування каналів, яку розглянуто у підрозділі 3.4. Рекурентні архітектури для аналізу довгих послідовностей у задачі не використовуються: часові розгортки імпульсної індукції короткі (близько тисячі відліків) і мають фіксовану довжину, тож їхня форма повністю доступна одновимірній згортковій мережі без рекурентності.

Окремо варто зафіксувати місце архітектур з тренуваними активаціями (MLP-KAN та споріднені), розглянутих у пункті 1.3.3. Їхня потенційна перевага

– точніше відображення нелінійної природи фізичних сигналів за меншої кількості параметрів [44, 51] – найприродніше реалізується не в базових гілках, де структура даних вже добре покривається згортковими моделями, а на інтегральному рівні: як метакласифікатор ансамблю або модуль комбінування ознак різних каналів. Водночас стійкість цих архітектур до шуму та доменного зсуву в задачах дистанційного виявлення поки досліджена недостатньо, тому ці архітектури розглядаються як перспективний напрям розвитку метарівня, а не як базове рішення.

Підсумковий вибір такий: основою бортового аналізу є компактні одновимірні згорткові мережі для часових сигналів імпульсної індукції (підрозділ 3.2); стійкість і масштабованість уможливорює ансамблева архітектура зі стекінгом (підрозділ 3.3); міжканальне злиття будується на рівні ознак за гібридною схемою, обґрунтованою у підрозділі 2.7, з перспективою адаптивного зважування каналів (підрозділ 3.4); внесення фізичного знання у процедуру навчання розвинуто у формі фізично-інформованих нейронних мереж (підрозділ 3.5); особливості реалізації в реальному часі розглянуто у підрозділі 3.6.

Для наочнішого представлення взаємозв'язку між окремими компонентами запропонованого підходу на рис. 3.1 наведено загальну схему нейромережевої обробки мультисенсорних даних. Схема відображає послідовність переходу від первинних вимірювань фізичних полів до формування інтегрального рішення про наявність аномалії, її локалізацію та класифікацію.

Запропонована структура відображає принцип модульної побудови системи. На відміну від традиційних підходів, де рішення формується на основі одного сенсорного каналу, тут застосовується багаторівнева схема аналізу.




Рисунок 3.1 – Схема нейромережевої обробки мультисенсорних даних

Кожен тип фізичних даних обробляється спеціалізованою нейромережевою гілкою, що дає змогу враховувати особливості відповідного сигналу. Після виділення ознак виконується їх об'єднання на рівні прихованих представлень, що забезпечує формування узгодженого опису досліджуваної ділянки.

Важливою особливістю архітектури є розділення процесів виділення ознак та прийняття рішення. Нижній рівень відповідає за вилучення інформативних характеристик із окремих фізичних полів, тоді як верхній рівень реалізує міжканальну інтеграцію та формування підсумкового висновку. Такий підхід дає

змогу незалежно вдосконалювати окремі модулі без необхідності перебудови всієї системи та гарантує масштабованість при додаванні нових типів сенсорів.

Для узагальнення проведеного аналізу доцільно порівняти основні архітектури нейронних мереж з точки зору їх придатності до розв'язання задач аналізу фізичних полів (табл. 3.1).

Таблиця 3.1- Порівняння базових архітектур для задач аналізу фізичних полів

Архітектура	Тип даних	Основні переваги	Основні недоліки	Доцільність використання
1D CNN	РІ-сигнали, часові ряди	Висока швидкодія, мала кількість параметрів, стійкість до шумів	Обмежений глобальний контекст	Висока
2D CNN	Просторові карти фізичних полів	Ефективне виділення локальних ознак та просторових структур	Потребує більшого обсягу даних	Висока
U-Net	Карти аномалій та сегментація	Точна локалізація аномальних областей	Значне споживання ресурсів	Середня
LSTM	Часові послідовності	Аналіз довготривалих залежностей	Висока обчислювальна складність	Низька

Продовження таблиці 3.1

Архітектура	Тип даних	Основні переваги	Основні недоліки	Доцільність використання
Transformer	Мультисенсорні дані та великі масиви інформації	Глобальний контекст, механізм уваги	Високі вимоги до вибірки та обчислень	Середня
MLP-KAN	Інтегральні ознаки та метакласифікація	Інтерпретованість нелінійних залежностей	Недостатня кількість прикладних досліджень	Перспективна
PINN	Фізично обмежені задачі	Урахування фізичних законів у процесі навчання	Складність налаштування функції втрат	Висока

Порівняльний аналіз підтверджує доцільність використання саме комбінованого підходу. Жодна окрема архітектура не забезпечує одночасного виконання всіх вимог, сформульованих на початку підрозділу. Одновимірні згорткові мережі демонструють найкраще співвідношення між швидкістю та якістю аналізу РІ-сигналів. Двовимірні згорткові архітектури ефективно працюють із просторовими поданнями фізичних полів. Механізми уваги гарантують адаптивне врахування інформативності окремих каналів, а фізично-інформовані нейронні мережі дозволяють включити до процесу навчання апріорні знання про природу сигналів.

Тому в межах даної роботи формується багаторівнева нейромережева система, в якій окремі архітектури виконують спеціалізовані функції та взаємодіють між собою в рамках єдиної структури прийняття рішень. Наступний підрозділ присвячено детальному розгляду одновимірної згорткової мережі, що використовується для класифікації та локалізації об'єктів за сигналами імпульсної індукції.

3.2 Одновимірна згорткова мережа для класифікації та локалізації за РІ-сигналами

Першою і найбільш відпрацьованою ланкою запропонованого підходу є аналіз сигналів імпульсної індукції, які формують основне джерело інформації про наявність прихованих металевих об'єктів. Він забезпечує найвищу інформативність при роботі з підповерхневими аномаліями та безпосередньо використовується для первинної класифікації цілей.

Практика експлуатації імпульсних міношукачів показує, що найбільшу цінність має не абсолютне значення сигналу, а його часовий профіль після завершення збуджувального імпульсу. Кожен металевий об'єкт формує власний характер затухання вихрових струмів, який визначається геометрією цілі, її масою, площею провідних поверхонь, електропровідністю матеріалу та взаємним розташуванням відносно приймально-передавальної системи. У результаті за близьких амплітуд сигналів форма перехідного процесу може суттєво відрізнитися.

Для задачі виявлення аномалій особливий інтерес становлять саме ці відмінності форми сигналів. Аналіз великої кількості лабораторних вимірювань показав, що різні об'єкти демонструють відмінні швидкості затухання, різні співвідношення між каналами та різну динаміку зміни сигналу в часі. При цьому абсолютні амплітуди можуть суттєво змінюватися через глибину залягання, орієнтацію об'єкта або висоту польоту носія. Тому використання безпосередніх значень сигналу як ознак є недостатньо ефективним.

Важливою особливістю РІ-сигналів є їх висока розмірність. Один вимір містить близько тисячі відліків для кожного каналу, причому сусідні значення сильно корельовані між собою. Використання такого сигналу безпосередньо призводить до значного збільшення обсягу даних та ускладнює процес навчання моделі. З іншого боку, надмірне скорочення кількості відліків призводить до втрати фізично важливої інформації. Тому структура вхідних даних має забезпечувати компроміс між інформативністю та обчислювальною ефективністю.

Іншою особливістю є висока чутливість сигналів до положення об'єкта відносно осі сканування. При зміщенні цілі навіть на декілька сантиметрів співвідношення між каналами змінюється значно сильніше, ніж абсолютний рівень сигналу. Ця властивість згодом і використовується для оцінювання поперечного положення аномалії та уточнення її координат.

Під час аналізу експериментальних даних було встановлено, що найбільш стабільною ознакою є не окремий канал, а сукупність взаємозв'язаних часових характеристик декількох каналів одночасно. Це стало однією з основних причин відмови від класичних алгоритмів, де ознаки формуються вручну, на користь згорткових нейронних мереж, здатних самостійно виділяти інформативні закономірності без необхідності їх явного задання.

Для забезпечення стійкої роботи нейромережевого класифікатора сирі сигнали проходять попередню трансформацію та перетворюються у компактне багатоканальне представлення. Вхідними даними для моделі є п'ятикомпонентний вектор

$$x(t) = [u'_{CH2}, u'_{CH3}, u'_{CH4}, \Delta 23, \Delta 34], \quad (3.1)$$

який формується на основі трьох нормованих кривих затухання та двох різницевих каналів.

Таке представлення є результатом багатьох етапів аналізу експериментальних даних. Перші три компоненти містять безпосередню інформацію про реакцію приймальних котушок на наявність металевго об'єкта. Після нормалізації вони стають менш чутливими до абсолютної амплітуди сигналу та більше відображають його форму. Завдяки цьому система концентрується на фізичних характеристиках об'єкта, а не на випадкових змінах умов вимірювання.

Особливу роль відіграють різницеві канали $\Delta 23$ та $\Delta 34$. Вони містять інформацію про просторову асиметрію сигналу та уможливають оцінювати зміщення цілі відносно осі сканування. Якщо використовувати лише сигнали окремих котушок, ця інформація частково втрачається. Різницеві канали суттєво

підвищують чутливість системи до поперечного положення об'єкта і створюють основу для подальшої локалізації аномалії.

Аналіз навчальних вибірок показав, що включення різницевих компонентів дає змогу значно покращити розділення близьких класів об'єктів. Особливо це помітно для цілей, які мають схожі амплітудні характеристики, але відрізняються геометрією, або положенням у просторі. П'ятикомпонентний вектор є не просто скороченням початкових даних, а спеціалізованим поданням, адаптованим до задачі класифікації та локалізації.

Для аналізу сформованого п'ятикомпонентного вектора РІ-сигналів запропоновано використовувати одновимірну згорткову нейронну мережу, архітектура якої спеціально адаптована до особливостей часових сигналів імпульсної індукції. Вибір саме такого підходу обумовлений структурою вхідних даних, де основна інформація про об'єкт міститься у формі затухання сигналу та взаємозв'язках між окремими каналами.

На відміну від традиційних методів обробки, у яких характеристики сигналу попередньо задаються розробником у вигляді набору ознак, згорткова мережа формує інформативні представлення автоматично безпосередньо під час навчання. Це дозволяє враховувати складні нелінійні залежності між окремими ділянками сигналу та мінімізувати втрати інформації, які неминуче виникають при ручному виділенні параметрів.

Архітектура мережі складається з послідовності згорткових блоків, кожен з яких виконує спеціалізовану функцію аналізу часової структури сигналу. Перший рівень обробки орієнтований на виділення локальних закономірностей. На цьому етапі аналізуються короткі фрагменти кривих затухання, що відповідають окремим ділянкам перехідного процесу. Завдяки використанню малих згорткових ядер мережа отримує можливість фіксувати локальні зміни форми сигналу, характерні для різних типів об'єктів.

На наступних рівнях відбувається поступове узагальнення інформації. Якщо перші шари працюють із окремими фрагментами часових залежностей, то глибші рівні починають аналізувати співвідношення між різними ділянками

сигналу, враховуючи як часову динаміку, так і взаємозв'язки між каналами. Саме на цьому етапі формується опис об'єкта, що містить інформацію про особливості затухання вихрових струмів, взаємне співвідношення амплітуд і структуру міжканальних залежностей.

Важливою особливістю архітектури є використання багатоканального входу. Всі п'ять компонентів вектора подаються до мережі одночасно, що дає змогу аналізувати форму кожного сигналу окремо і їх взаємний вплив. Особливо це стосується різницевих каналів $\Delta 23$ та $\Delta 34$, які містять інформацію про просторове положення об'єкта відносно сенсорної системи. У результаті мережа отримує доступ до просторових ознак уже на початкових етапах обробки.

Для зменшення обчислювальної складності після згорткових шарів використовуються операції агрегування ознак. Вони створюють поступове скорочення розмірності внутрішнього представлення та уможливають зосередити подальший аналіз на найбільш інформативних характеристиках сигналу. Завершальний етап архітектури представлений повнозв'язним класифікаційним блоком, який виконує перетворення сформованого простору ознак у вектор вихідних ймовірностей.

Запропонована структура забезпечує поєднання трьох важливих властивостей: здатності аналізувати часову форму сигналів, можливості врахування міжканальних залежностей та низької обчислювальної складності.

Процес навчання одновимірної згорткової мережі розглядається як задача пошуку такого набору параметрів, за якого модель найбільш повно відображає закономірності, притаманні сигналам різних типів об'єктів. При цьому основна увага приділяється не максимізації точності на навчальних даних, а забезпеченню здатності моделі працювати з новими вимірюваннями, отриманими в інших умовах спостереження.

Підготовка навчальної вибірки починається з формування набору нормалізованих РІ-векторів. Для кожного прикладу зберігається структура всіх п'яти каналів, що дозволяє уникнути втрати міжканальної інформації. Додатково здійснюється контроль балансу класів, оскільки нерівномірний розподіл об'єктів

може призводити до зміщення параметрів моделі у бік найчисельніших категорій.

Під час навчання використовується функція втрат, орієнтована на багатокласову класифікацію. Вона уможливорює поступове коригування ваг мережі шляхом мінімізації різниці між прогнозованими та еталонними класами. Для підвищення стійкості навчання застосовується нормалізація внутрішніх представлень, що дає змогу стабілізувати процес оптимізації та прискорити збіжність алгоритму.

Окрему увагу приділено проблемі перенавчання. Для її вирішення використовуються механізми регуляризації, контроль складності архітектури та моніторинг поведінки моделі на незалежній підвибірці. Такий підхід дає змогу обмежити надмірне пристосування до особливостей навчальних даних і забезпечити формування узагальнених ознак.

процес навчання складається з декількох взаємопов'язаних етапів: підготовки даних, формування пакетів навчання, оптимізації параметрів мережі, контролю збіжності та вибору фінальної конфігурації моделі. Така організація забезпечує отримання стійкого класифікатора, придатного для подальшого використання у складі мультисенсорної системи.

Основною функцією одновимірної згорткової мережі є перетворення часового сигналу імпульсної індукції у компактне описання об'єкта. На виході моделі формується вектор належності до визначених класів, який відображає ступінь відповідності сигналу кожній із категорій навчальної вибірки.

Процедура класифікації базується на аналізі сукупності ознак, сформованих згортковими шарами. На відміну від класичних алгоритмів, рішення приймається не за окремими параметрами сигналу, а на основі багатовимірного простору представлень, що формується в процесі проходження сигналу через мережу. Це уможливорює враховувати складні взаємозв'язки між формою затухання, швидкістю зміни амплітуди та міжканальними співвідношеннями.

Окрім задачі класифікації, РІ-гілка системи бере участь у визначенні положення аномалії. Для цього використовується інформація, що міститься у різницевих каналах та енергетичному представленні сигналів. Взаємний аналіз цих компонентів дає змогу оцінювати просторове положення об'єкта відносно траєкторії сканування та формувати координатні оцінки для подальших модулів системи.

Функціонально процес класифікації та локалізації можна розглядати як два взаємодоповнюючі контури. Перший відповідає за визначення фізичного типу аномалії, другий – за уточнення її координат у просторі. Такий поділ гарантує модульність архітектури та спрощує подальшу інтеграцію з мультисенсорними методами злиття даних.

Однією з ключових вимог до запропонованої архітектури є можливість використання на борту мобільної платформи без необхідності залучення зовнішніх обчислювальних ресурсів. Тому під час проєктування мережі особлива увага приділялася мінімізації кількості параметрів та оптимізації структури обчислень.

На відміну від складних глибоких архітектур, які потребують значних апаратних ресурсів, запропонована модель орієнтована на використання компактних згорткових блоків та обмеженої кількості повнозв'язних шарів. Такий підхід дає змогу значно скоротити обсяг пам'яті, необхідний для зберігання ваг, та зменшити навантаження на процесорні ресурси.

Додатковою перевагою одновимірної згорткової архітектури є передбачуваність часу обробки. Кількість операцій визначається структурою мережі та практично не залежить від змісту конкретного сигналу. Це є важливою властивістю для систем реального часу, оскільки може гарантувати стабільну швидкість роботи незалежно від складності вхідних даних.

З позиції інтеграції у мультисенсорну систему РІ-гілка виступає найбільш швидкодіючим компонентом нейромережевого аналізу. Вона формує первинну оцінку об'єкта ще до завершення обробки інших фізичних каналів і може використовуватися як джерело попередньої інформації для модулів

мультисенсорного злиття. Така організація сприяє раціональному розподіленню обчислювальних ресурсів між окремими компонентами системи та створює основу для подальшої реалізації нейромережових методів у режимі реального часу.

3.3 Ансамблевий класифікатор зі стекінгом

Після побудови спеціалізованої одновимірної згорткової мережі для РІ-сигналів виникає наступне технічне питання: як зменшити залежність кінцевого рішення від однієї моделі. Навіть якщо окрема мережа добре узгоджена зі структурою своїх вхідних даних, вона все одно має власний профіль помилок. Такі помилки зазвичай не є випадковими. Вони пов'язані з тим, які саме ознаки мережа навчилася вважати найбільш інформативними, як вона реагує на шум, які класи розділяє впевнено, а які – гірше. Для задачі виявлення аномалій це особливо важливо, тому що помилка одного класифікатора може призвести не просто до неправильного підпису класу, а до пропуску небезпечного об'єкта або неправильної оцінки його типу.

Тому доцільно не обмежуватися однією нейромережею, а використовувати ансамблевий підхід. Його технічна ідея полягає в тому, що кілька моделей аналізують один і той самий об'єкт незалежно одна від одної, після чого їхні рішення об'єднуються на вищому рівні. Якщо моделі побудовані по-різному або навчені на різних представленнях даних, їхні помилки також відрізняються. Це зменшує ризик ситуації, коли всі моделі одночасно приймають однаково неправильне рішення.

Для системи виявлення аномалій важливою є не тільки середня точність класифікації, а й кількість збіжних помилок. Збіжна помилка виникає тоді, коли всі моделі ансамблю помиляються на одному й тому самому прикладі. У звичайних задачах класифікації така помилка лише знижує загальний показник якості. У задачах виявлення прихованих об'єктів вона має значно серйозніші наслідки, оскільки може відповідати пропуску цілі. Тому ансамбль розглядається

не як спосіб формально підвищити точність, а як технічний механізм зменшення ризику систематичних помилок.

Особливу перевагу має не просте голосування, а стекінг. При голосуванні кожна модель має однакову вагу, а її рішення враховується переважно у дискретній формі. Такий підхід надто грубий для складних фізичних сигналів, де важливим є не тільки вибраний клас, а й рівень упевненості моделі. Стекінг працює інакше: він використовує вихідні вектори ймовірностей базових моделей і навчає окремих метакласифікатор, який визначає, як саме ці рішення потрібно комбінувати. Це дозволяє враховувати не тільки кількість голосів, а й характер упевненості кожної моделі.

Перший рівень ансамблевої системи формується набором базових моделей, кожна з яких виконує незалежний аналіз вхідних даних і формує власну оцінку досліджуваного об'єкта. Основна вимога до такого набору полягає не у максимальній точності кожної окремої моделі, а у забезпеченні різноманітності рішень. Практика побудови ансамблевих систем показує, що найбільший ефект досягається не тоді, коли всі моделі демонструють однакову поведінку, а коли вони по-різному реагують на складні або неоднозначні приклади.

формування ансамблю можна розглядати як задачу створення декількох незалежних механізмів аналізу одного й того самого фізичного процесу. Кожна модель будує власне внутрішнє представлення об'єкта, використовуючи різні принципи обробки даних. У результаті при однаковому вхідному сигналі різні моделі концентруються на різних особливостях інформаційного подання. Одні краще реагують на локальні зміни структури сигналу, інші ефективніше враховують глобальні закономірності, треті демонструють підвищену стійкість до шумів або неповноти даних.

У дослідженні ансамблевого підходу, виконаному в роботі [43], використовувався набір сучасних архітектур, серед яких CCT, EANet, FNet, Swin Transformer, MLP-Mixer та gMLP. Незважаючи на те, що всі вони розв'язують одну й ту саму задачу класифікації, внутрішні механізми формування ознак у цих

архітектурах суттєво відрізняються. Ця відмінність і забезпечує появу різних профілів помилок і створює передумови для ефективної роботи ансамблю.

В контексті задачі виявлення аномалій фізичних полів принцип формування базового рівня залишається аналогічним. Різниця полягає лише в тому, що джерелом різноманітності можуть виступати не тільки різні архітектури нейронних мереж, а й різні фізичні канали. Наприклад, одна модель може аналізувати РІ-сигнали, інша – магнітометричні карти, третя – георадарні дані, а четверта – мультиспектральні або тепловізійні зображення. У такому випадку різноманітність рішень уможливлюється не тільки особливостями математичного апарату, але і відмінностями фізичної природи самих вимірювань.

Особливо важливою є незалежність помилок між базовими моделями. Якщо дві мережі використовують однаковий набір ознак і проходять навчання на тих самих даних, їхні помилки часто виявляються сильно корельованими. В такій ситуації додавання другої моделі практично не покращує якість ансамблю. Тому під час формування базового рівня необхідно забезпечити максимальну відмінність як архітектурних рішень, так і способів представлення вхідної інформації.

З позиції інформаційної моделі другого розділу кожна базова мережа працює зі своєю проєкцією багатовимірному простору даних. Вона отримує лише ту частину інформації, яка найбільш відповідає структурі її входу. Подальше об'єднання цих часткових рішень дає змогу отримати більш повне уявлення про досліджуваний об'єкт, ніж будь-яка окрема модель.

Загальну структуру формування ансамблю базових моделей представлено на рис. 3.2.




Рисунок 3.2 – Загальна структура формування ансамблю базових моделей

Перший рівень ансамблю не виконує остаточного прийняття рішення. Його завдання полягає у формуванні набору незалежних оцінок, кожна з яких відображає власний погляд на структуру вхідних даних. Ці оцінки надалі використовуються метакласифікатором для побудови інтегрального рішення.

Наявність декількох базових моделей ще не гарантує отримання якісного підсумкового рішення. Після завершення роботи першого рівня виникає задача коректного об'єднання результатів, причому просте голосування більшістю далеко не завжди є оптимальним варіантом. У складних задачах аналізу фізичних полів різні моделі можуть демонструвати неоднакову надійність для різних класів об'єктів, а також мати різний рівень впевненості у своїх прогнозах.

Для врахування цих особливостей у роботі використовується стекінг. Його сутність полягає у побудові окремого нейромережевого рівня, який навчається не на первинних даних, а на результатах роботи базових моделей. метакласифікатор розглядає рішення першого рівня як новий простір ознак і навчається знаходити оптимальний спосіб їх комбінування.

На вхід метакласифікатора подаються повні вектори ймовірностей усіх базових моделей. Завдяки цьому він отримує значно більше інформації, ніж при звичайному голосуванні. Наприклад, якщо одна модель впевнена у своєму

рішенні на 95 %, а інші демонструють невпевнені оцінки на рівні 50–60 %, метакласифікатор здатний врахувати цю різницю. Аналогічно він може навчитися розпізнавати ситуації, коли певна модель систематично переоцінює окремі класи або демонструє нестабільну поведінку для конкретних типів об'єктів.

Формально процедура стекінгу складається з двох етапів. На першому рівні незалежно навчаються всі базові моделі ансамблю. Після завершення їх навчання формується новий набір даних, який складається вже не з первинних вимірювань, а з вихідних векторів ймовірностей. Цей набір використовується для навчання метакласифікатора. Такий підхід сприяє уникненню прямого дублювання інформації та зосередитися на аналізі сильних і слабких сторін окремих моделей.

Особливістю метакласифікатора є те, що він фактично виконує адаптивне зважування рішень першого рівня. При цьому ваги не задаються розробником вручну, а визначаються автоматично в процесі навчання. У результаті система самостійно встановлює, які джерела інформації є більш корисними для конкретних типів аномалій та умов спостереження.

Така організація ансамблю створює основу для подальшого масштабування на мультисенсорні системи, де кількість джерел інформації та складність їх взаємодії значно зростає. У наступному підрозділі розглянуто один із додаткових механізмів підвищення різноманітності ансамблю – використання циклічного зсуву даних під час формування базових моделей.

Однією з основних проблем ансамблевих систем є поява збіжних помилок. Незважаючи на використання кількох моделей, у багатьох випадках вони можуть одночасно помилятися на одних і тих самих прикладах. Причиною цього є те, що всі моделі навчаються на одному наборі даних і часто формують схожі внутрішні подання ознак. У результаті ансамбль перестає виконувати свою головну функцію – компенсацію помилок окремих класифікаторів.

Для зменшення ймовірності збіжних помилок доцільно підвищувати різноманітність базових моделей за рахунок різних архітектур і за рахунок різних

варіантів представлення вхідних даних. Один із найбільш ефективних способів досягнення цього полягає у використанні циклічного зсуву вхідних даних.

Ідея методу полягає в тому, що одна й та сама архітектура навчається на декількох варіантах представлення сигналу або зображення, отриманих шляхом контрольованого циклічного зміщення. Для просторових подань це може бути зсув рядків або стовпців матриці даних. Для часових сигналів імпульсної індукції аналогічний ефект досягається шляхом зміни початкової позиції аналізованого фрагмента або використання перекритих часових вікон.

У результаті кожна копія мережі концентрує увагу на дещо різних особливостях сигналу. За однакової архітектури внутрішні вагові коефіцієнти адаптуються до різних статистичних властивостей даних, що формує різні простори ознак і різні профілі помилок. Для коротких одновимірних РІ-розгорток фіксованої довжини цей ефект слабший, ніж для просторових зображень, тож циклічний зсув розглядається тут як допоміжний механізм диверсифікації, а не основний.

Для задачі аналізу фізичних полів така властивість має особливе значення. Частина аномалій проявляється лише в окремих ділянках сигналу або займає незначну область на просторовій карті. Якщо всі моделі аналізують дані однаковим способом, вони можуть одночасно пропустити таку особливість. Після введення циклічного зсуву різні моделі отримують дещо різний погляд на ті самі дані, що суттєво знижує ймовірність одночасного пропуску (рис. 3.3).




Рисунок 3.3 – Схема формування ансамблю із циклічним зсувом

Циклічний зсув дає змогу отримати додаткову різноманітність ансамблю без зміни базової архітектури. Це особливо важливо для бортових систем, де кількість доступних моделей обмежується обчислювальними ресурсами. Замість впровадження нових складних архітектур можна використовувати декілька варіантів уже існуючої моделі, отримуючи при цьому суттєве зменшення кількості збіжних помилок.

Механізм циклічного зсуву виступає додатковим рівнем підвищення стійкості ансамблю та дає змогу покращити надійність роботи системи без істотного збільшення її складності.

Розглянута вище архітектура стекінгу спочатку була сформована для задач класифікації, де всі моделі працювали з одним типом даних. Однак інформаційна модель, сформована у другому розділі, передбачає одночасне використання декількох фізичних каналів, які відрізняються як за природою сигналів, так і за способом їх цифрового представлення. Це потребує адаптації ансамблевого підходу до умов мультисенсорного аналізу.

У мультисенсорному випадку роль базових моделей виконують не тільки різні нейромережеві архітектури, а і окремі сенсорні гілки. Кожен фізичний канал отримує власний спеціалізований класифікатор, параметри якого

оптимізуються під структуру відповідних даних. Для РІ-сигналів використовується одновимірна згорткова мережа, для просторових карт магнітного поля – двовимірні згорткові архітектури, для мультиспектральних або теплових зображень – спеціалізовані моделі аналізу просторових ознак.

Така структура дає змогу кожному класифікатору працювати в оптимальному для нього режимі. Замість створення універсальної мережі, яка намагається однаково добре аналізувати всі типи даних, система використовує набір спеціалізованих модулів. У результаті кожен канал максимально ефективно використовує інформацію, характерну саме для свого типу вимірювань.

На виході базових моделей формуються вектори ймовірностей, які надходять до метакласифікатора другого рівня. І тут реалізується остаточне злиття інформації від різних фізичних полів. Метакласифікатор оцінює узгодженість рішень окремих каналів та формує інтегральний висновок щодо наявності аномалії, її типу та рівня достовірності (рис. 3.4).




Рисунок 3.4 – Загальна структура масштабування ансамблю на мультисенсорний випадок

Важливою перевагою такої архітектури є її масштабованість. Додавання нового фізичного каналу не потребує перебудови всієї системи. Достатньо додати нову спеціалізовану гілку та підключити її до метарівня ансамблю. Завдяки цьому структура залишається відкритою для подальшого розвитку та інтеграції нових сенсорів.

Разом з тим у запропонованій схемі залишається певне обмеження. Після завершення навчання внесок кожної гілки фактично фіксується параметрами метакласифікатора. В реальних умовах інформативність окремих каналів може суттєво змінюватися залежно від характеристик місцевості, погодних умов або типу аномалії. Тобто система повинна мати можливість адаптувати ваги каналів без повного перенавчання ансамблю. Саме вирішенню цього завдання присвячено наступний підрозділ, в якому розглядається архітектура мультисенсорного злиття з адаптивним зважуванням каналів на основі механізму уваги.

3.4 Архітектура мультисенсорного злиття гілок та адаптивне зважування каналів

Розглянуті вище компоненти – спеціалізована РІ-гілка і ансамблевий метарівень – об'єднуються в архітектуру мультисенсорного злиття, яка реалізує гібридну схему, обґрунтовану в підрозділі 2.7.4, на матеріалі структурованого подання другого розділу. Входом слугує мультисенсорний тензор $T(x, y, k)$: у базовій конфігурації він містить чотирнадцять інформаційних каналів – п'ять каналів імпульсної індукції (три котушкові та два різницеві або їх енергетичне подання), три диференціальні магнітометричні, чотири спектральні та два індексні (NDVI, VARI); текстурні ознаки GLCM розглядаються як опціональне розширення, що додається без зміни архітектури.

Оброблення будується за принципом «спеціалізована гілка на кожен тип даних». РІ-гілка – одновимірна згорткова мережа підрозділу 3.2, яка для кожної позиції аналізує часову форму відгуку; її виходом є вектор ознак та оцінки класу. Магнітометрична гілка працює з просторовими профілями диференціальних

каналів, виділяючи локальні збурення на тлі повільного фону. Оптична гілка – двовимірною згортковою мережею, що обробляє фрагменти спектральних та індексних шарів тензора, виділяючи поверхневі ознаки аномалій. Виходи гілок об'єднуються у спільному просторі ознак, на якому працює інтегральний класифікатор; на рішеннєвому рівні цю конструкцію дублює ансамблевий стекінг підрозділу 3.3, що забезпечує робастність до відмови чи деградації окремої гілки. Загальну схему архітектури наведено на рис. 3.5.




Рисунок 3.5 – Архітектура мультисенсорного злиття: спеціалізовані гілки каналів, об'єднання ознак та ансамблевий метарівень

Ключове питання злиття – вага кожного каналу в інтегральному рішенні. У базовій конфігурації ваги формуються навчанням і лишаються фіксованими

під час експлуатації; це просте і передбачуване рішення, але воно ігнорує те, що інформативність каналів змінюється з умовами вимірювання. Оптичний канал деградує за слабого освітлення і щільної рослинності; магнітометричний – поблизу техногенних джерел поля; РІ-канал – на сильно мінералізованих ґрунтах. Аналіз літератури (підрозділ 1.3, [36, 37]) показує, що природним механізмом урахування цього є вага: ваги каналів обчислюються як функція самих даних, тобто мережа навчається оцінювати поточну надійність кожного джерела за непрямими ознаками – рівнем шуму, контрастністю, взаємною узгодженістю каналів.

У запропонованій архітектурі адаптивне зважування реалізується компактным модулем уваги над векторами ознак гілок: для кожного фрагмента тензора модуль формує нормований набір ваг, на які множаться внески гілок перед інтегральним класифікатором. Істотно, що цей модуль не змінює самих гілок і може бути доданий або вимкнений без перенавчання основної частини системи – у вимкненому стані архітектура зводиться до базової конфігурації з фіксованими вагами. Така конструкція безпосередньо відповідає на відкриту проблему адаптивних ваг злиття, сформульовану у підрозділі 2.17, і водночас зберігає інтерпретованість: ваги уваги є явними величинами, доступними оператору для контролю того, на які канали спиралося рішення.

Сформульовано третій пункт наукової новизни: вперше запропоновано неймережевий метод виявлення та класифікації аномалій у полях фізичних величин, який поєднує структуроване мультисенсорне подання $T(x, y, k)$ зі спеціалізованими гілками оброблення фізично різнорідних каналів – одновимірною згортковою мережею для сигналів імпульсної індукції та ансамблевим стекінгом на інтегральному рівні, – що гарантує сумісний аналіз підповерхневих і поверхневих ознак аномалій у єдиному конвеєрі. Кількісне оцінювання показників методу на польових даних виконується у п'ятому розділі за відкритим набором вимірювань (підрозділ 2.9).

3.5 Фізично-інформовані нейронні мережі

Усі розглянуті раніше нейромережеві методи формують рішення виключно на основі статистичних закономірностей, які виявляються у навчальних даних. Такий підхід добре працює за наявності великих репрезентативних вибірок, однак у задачах аналізу фізичних полів виникає інше обмеження. Збирання даних є складним, дорогим і часто пов'язаним з проведенням спеціальних польових вимірювань. Крім того, кількість реально доступних прикладів аномалій завжди значно менша за кількість прикладів фонового середовища. Тому і виникає необхідність використання додаткової інформації, яка не міститься безпосередньо у вибірці, але відома з фізичних закономірностей формування сигналів.

На відміну від класичних нейронних мереж, фізично-інформовані моделі використовують статистичні зв'язки між входами та виходами і апіорні знання про природу процесів, які породжують досліджувані сигнали. Фізична модель стає додатковим джерелом інформації для навчання. У результаті мережа не просто шукає будь-яке рішення, яке мінімізує помилку на навчальній вибірці, а обмежується класом фізично допустимих рішень.

Для задачі виявлення аномалій такий підхід є особливо актуальним. На відміну від багатьох класичних задач комп'ютерного зору, де об'єкт спостерігається безпосередньо, предметом аналізу тут є фізичні поля, формування яких описується відомими законами електромагнетизму. Це засвідчує, що значна частина інформації про об'єкт уже закладена у фізичній структурі сигналу. Використання цієї інформації уможливлює зменшити залежність від обсягу навчальних даних та підвищити стійкість моделі до зміни умов спостереження. Загальне місце фізично-інформованих нейронних мереж у структурі системи показано на рис. 3.6.




Рисунок 3.6 – Загальне місце фізично-інформованих нейронних мереж у структурі запропонованої системи

У запропонованій архітектурі фізичні закономірності не замінюють нейронну мережу і не визначають її структуру. Вони впливають безпосередньо на процес навчання через спеціальні фізичні обмеження, які враховуються під час оптимізації параметрів моделі.

Першим джерелом фізичних знань для системи є модель формування сигналів імпульсної індукції. Після завершення збуджувального імпульсу в металевому об'єкті виникають вихрові струми, які поступово затухають у часі. Цей процес і реєструється приймальними котушками сенсорної системи.

Форма PI-сигналу визначається сукупністю декількох незалежних мод затухання. Кожна мода характеризується власною сталою часу та амплітудою. Сукупний відгук являє собою суму експоненціальних компонент, які формують характерний часовий профіль сигналу.

Для великих провідних об'єктів затухання відбувається повільніше, що призводить до появи довгих хвостів сигналу. Для компактних об'єктів характерне швидке згасання енергії. Аналогічно на форму сигналу впливають матеріал, геометрія, орієнтація та глибина розташування цілі.

Ця закономірність дає змогу використовувати експоненціальну структуру сигналу як фізичне обмеження під час навчання нейронної мережі. Якщо модель формує рішення, яке суперечить характеру реального затухання вихрових

струмів, така невідповідність може бути врахована додатковим штрафним членом у функції втрат.

Фізична модель РІ-сигналу виконує роль додаткового контролю якості навчання. Вона не визначає кінцевий результат напряду, але не дозволяє мережі використовувати статистичні закономірності, які суперечать фізичній природі процесу.

Другим джерелом фізичних знань є модель формування магнітного поля прихованого об'єкта. Для більшості металевих цілей на відстанях, що перевищують характерні розміри об'єкта, магнітна аномалія добре описується дипольною моделлю.

Практично це означає, що просторовий розподіл магнітного поля має цілком визначену структуру. Магнітна аномалія не виникає випадково і не може мати довільну форму. Ширина області збурення, положення максимумів і мінімумів, співвідношення між окремими компонентами поля пов'язані між собою фізичними закономірностями.

Тому карта магнітного поля містить значно більше інформації, ніж просто локальне відхилення від фонового значення. Просторова структура аномалії дає змогу оцінювати не тільки факт наявності об'єкта, а ще його орієнтацію, глибину та приблизні розміри.

Під час навчання фізично-інформованої мережі ця інформація використовується для перевірки фізичної узгодженості сформованих рішень. Якщо нейромережа локалізує аномалію в області, де структура магнітного поля не відповідає дипольному характеру розподілу, така гіпотеза отримує додатковий штраф.

У результаті мережа поступово зміщує процес навчання у напрямку рішень, які узгоджуються як із даними, так і з реальною фізикою магнітних полів.

Ключовою особливістю фізично-інформованих нейронних мереж є те, що фізичні моделі не використовуються окремо від алгоритму машинного навчання. Вони інтегруються безпосередньо в процедуру оптимізації параметрів.

Традиційна нейронна мережа отримує на вхід приклад і прагне мінімізувати різницю між прогнозом та еталонною відповіддю. При цьому їй не цікавить, наскільки фізично правдоподібним є отримане рішення. Якщо певна статистична закономірність випадково присутня у вибірці, мережа може почати використовувати її навіть тоді, коли вона не має фізичного змісту.

Включення фізичних обмежень забезпечує уникнення такої ситуації. Під час кожної ітерації навчання модель оцінюється за точністю прогнозу і за ступенем відповідності фізичним законам формування сигналів.

Процес навчання фактично виконується у двох просторах одночасно. Перший простір визначається статистикою навчальних даних. Другий задається фізичними закономірностями. Остаточне рішення повинно задовольняти обидві групи вимог.

Особливо важливо це для задач із невеликими навчальними вибірками, де ризик перенавчання є максимальним. Фізичні обмеження істотно звужують простір допустимих рішень і тим самим підвищують стійкість моделі.

Практична реалізація фізичних обмежень здійснюється через модифікацію функції втрат. До стандартного критерію якості додається додатковий фізичний член, який оцінює ступінь узгодженості рішення з фізичною моделлю.

У результаті функція втрат складається з двох незалежних компонентів. Перший відповідає за відповідність навчальним даним і виконує традиційну задачу класифікації, або локалізації. Другий контролює фізичну правдоподібність результату.

Для РІ-гілки фізичний член пов'язаний із відповідністю форми сигналу експоненціальній структурі затухання. Для магнітометричного каналу оцінюється відповідність просторового розподілу дипольній моделі. Окремо може враховуватися міжканальна узгодженість різних сенсорів.

Завдяки цьому під час навчання мережа змушена знаходити компроміс між статистичною точністю та фізичною коректністю рішення. Ця комбінація дає змогу отримувати моделі, які краще працюють за межами навчальної вибірки.

Окрему роль у фізично-інформованій архітектурі відіграє узгодження результатів різних сенсорних каналів. Незважаючи на відмінності між РІ-сигналами, магнітометричними картами та георадарними даними, усі вони описують один і той самий фізичний об'єкт.

Тому між результатами різних нейромережових гілок повинна існувати певна узгодженість. Якщо одна модель локалізує аномалію в одній області, а інша – у зовсім іншій, система повинна розглядати таку ситуацію як потенційно недостовірну.

У найпростішому випадку узгодженість може оцінюватися через відстань між координатами аномалій, отриманими різними сенсорними каналами.

Нижче в Лістинге 3.1 наведено приклад функції узгодження координат двох каналів:

Лістинг 3.1 – Узгодження координат двох каналів

```
import numpy as np
def channel_consistency(pos1, pos2):
    """
    pos1 = (x1, y1)
    pos2 = (x2, y2)
    """
    distance = np.sqrt(
        (pos1[0] - pos2[0])**2 +
        (pos1[1] - pos2[1])**2
    )

    consistency = np.exp(-distance)
    return consistency
```

Така оцінка може використовуватися як окремий фізичний член функції втрат або як критерій довіри до кінцевого рішення ансамблю.

Основна перевага фізично-інформованих нейронних мереж полягає не у підвищенні складності архітектури, а у зміні принципу навчання. Модель отримує додаткову інформацію про структуру досліджуваних процесів і тому меншою мірою залежить від обсягу доступних даних.

Особливо цінним є те, що фізичні закономірності залишаються незмінними незалежно від конкретної вибірки. Тип ґрунту, погодні умови, особливості полігону чи параметри експерименту можуть змінювати статистичні характеристики сигналів, але не змінюють фундаментальні механізми формування вихрових струмів, або магнітних аномалій.

У результаті фізична регуляризація виступає додатковим механізмом узагальнення. Вона знижує ризик перенавчання, підвищує стійкість до доменного зсуву між лабораторними та польовими умовами та уможливорює вищу інтерпретованість рішень. Тому фізично-інформовані нейронні мережі розглядаються як один із найбільш перспективних напрямів розвитку систем аналізу фізичних полів і становлять важливу складову запропонованої архітектури виявлення та класифікації аномалій.

3.6 Особливості реалізації нейромережових методів у реальному часі

Розроблення нейромережових алгоритмів для аналізу фізичних полів не завершується побудовою архітектур та вибором методів навчання. Для практичного використання не менш важливим є питання їхньої реалізації у системах реального часу. У задачах дистанційного виявлення аномалій нейронна мережа є лише одним із компонентів загального конвеєра обробки даних, до складу якого входять сенсори, модулі попередньої обробки, системи навігації, канали зв'язку та підсистеми підтримки прийняття рішень. Тому навіть високоточна модель втрачає практичну цінність, якщо її робота супроводжується надмірними затримками або потребує ресурсів, недоступних для мобільної платформи.

Особливість розглядуваної системи полягає в тому, що різні фізичні канали працюють з різною частотою оновлення даних. Канал імпульсної індукції

генерує нові вимірювання значно частіше за магнітометричний або оптичний модулі. Це значить, що вимоги до швидкодії окремих нейромережевих гілок також суттєво відрізняються. Архітектура всієї системи повинна розглядатися не як єдиний монолітний алгоритм, а як набір взаємопов'язаних компонентів з різними часовими характеристиками.

Під час проектування системи ключовим фактором є відповідність швидкості обробки швидкості надходження нових вимірювань. Якщо обчислювальний цикл триває довше, ніж інтервал між двома послідовними пакетами даних, система починає накопичувати чергу необробленої інформації. У результаті виникає затримка між реальною подією та її відображенням у вихідних результатах.

Для РІ-каналу така вимога є найбільш жорсткою. За частоти зондування 238 Гц новий вектор даних формується приблизно кожні 4,2 мс. Тобто весь цикл аналізу, включаючи попередню обробку, нормалізацію, інференс нейронної мережі та формування рішення, повинен завершуватися раніше появи наступного вимірювання. В протилежному випадку система поступово втратить здатність працювати в режимі реального часу.

Для магнітометричного каналу ситуація менш критична. Типові частоти оновлення знаходяться на рівні десятків або сотень герц, що створює значно більший часовий запас. До оптичних і мультиспектральних каналів висувуються менш жорсткі вимоги щодо швидкодії, оскільки частота їх оновлення, як правило, обмежується частотою отримання кадрів.

Важливо враховувати, що часовий бюджет повинен включати не тільки роботу нейромережевого модуля. Частину ресурсів споживає синхронізація даних, робота навігаційної системи, формування телеметричних пакетів, запис інформації та взаємодія з оператором. Відповідно під час проектування архітектури необхідно залишати резерв продуктивності навіть у випадках, коли розрахунковий час обробки формально відповідає заданим вимогам.

З позиції системної інтеграції важливо забезпечити детермінований характер обчислень. Час інференсу не повинен суттєво залежати від конкретного

вмісту даних. І ця властивість є однією з причин вибору компактних згорткових архітектур замість складніших моделей з динамічною структурою обчислень.

Інформаційна модель, сформована у другому розділі, передбачає дворівневу організацію обробки даних. Частина алгоритмів виконується безпосередньо на борту мобільної платформи, тоді як ресурсоємні процедури переносяться на наземну станцію або серверний сегмент.

Основним критерієм такого розподілу є чутливість алгоритму до затримки. Якщо результат обробки може впливати на поточну траєкторію руху, або прийняття оперативних рішень, відповідний модуль повинен працювати локально. Якщо ж результат використовується для побудови підсумкової карти ризику або детального післяпольотного аналізу, його виконання може бути перенесене на зовнішні обчислювальні ресурси.

На бортовому рівні доцільно розміщувати РІ-гілку класифікації, модулі первинної локалізації та базові алгоритми оцінювання достовірності аномалій. Ці компоненти забезпечують оперативне реагування системи на появу потенційно небезпечних об'єктів.

Наземна станція отримує значно ширші обчислювальні можливості. Тут можуть виконуватися ансамблевий стекінг, мультисенсорне злиття, побудова просторових карт, адаптивне зважування каналів та аналіз історичних даних. Такий розподіл сприяє ефективному використанню ресурсів обох рівнів системи.

Загальну структуру розподілу обчислень можна представити наступним чином (рис. 3.7)



Рисунок 3.7 – Загальна структура розподілу обчислень

Особливістю вбудованих обчислювальних платформ є обмежений обсяг оперативної пам'яті, невисока продуктивність процесора та обмеження енергоспоживання. Тому неймережеві моделі повинні бути адаптовані до конкретної апаратної конфігурації.

Першим напрямом оптимізації є зменшення кількості параметрів мережі. Для цього використовуються компактні архітектури, скорочення кількості каналів згортки та обмеження розмірності повнозв'язних шарів.

Другим напрямом виступає квантування параметрів. У цьому випадку вагові коефіцієнти зберігаються не у форматі 32-бітних чисел з плаваючою комою, а у вигляді 16-бітних або навіть 8-бітних значень. Це уможливорює суттєво скоротити використання пам'яті та прискорити виконання операцій множення без втрати точності.

Третім напрямом є проріджування мережі. Після завершення навчання частина зв'язків може бути видалена без суттєвого впливу на якість моделі. У результаті скорочується кількість операцій під час інференсу.

Окремий інтерес становить дистиляція знань. У цьому випадку складна модель використовується лише на етапі навчання, після чого її поведінка переноситься на компактну мережу, придатну для роботи на вбудованому обладнанні.

Завдяки поєднанню цих підходів навіть досить складні ансамблеві рішення можуть бути адаптовані до використання на одноплатних комп'ютерах або процесорах класу STM32MP1 [43].

В реальних умовах система працює з безперервним потоком даних, який надходить від декількох сенсорів одночасно. Повна обробка всього масиву інформації після завершення місії є неприйнятною, оскільки вона не дозволяє використовувати результати в процесі сканування.

Для часових сигналів використовується потокова схема обробки. Нові вимірювання накопичуються у буфері, після чого формуються пакети фіксованого розміру, які передаються до нейромережевого модуля. Така організація дає змогу підтримувати стабільний темп роботи навіть за змінної швидкості руху носія.

Для просторових карт застосовується інший підхід. Повна карта області може містити сотні тисяч чи, навіть, мільйони елементів. Її безпосередня подача до нейронної мережі призводить до надмірного споживання пам'яті та зростання часу обробки.

З цієї причини використовується фрагментна схема. Просторова карта автоматично розбивається на окремі області фіксованого розміру з частковим перекриттям. Кожен фрагмент аналізується незалежно, після чого результати об'єднуються у єдине просторове подання.

Перевагою такого підходу є практично лінійна залежність обчислювальних витрат від площі досліджуваної території. Крім того,

фрагменти можуть оброблятися паралельно різними обчислювальними ядрами чи, навіть, різними пристроями.

Для оцінювання придатності системи до роботи в режимі реального часу необхідно контролювати співвідношення між доступним часовим бюджетом та фактичними витратами на виконання окремих модулів.

Найпростішою оцінкою є визначення часу обробки одного пакета даних та його порівняння з інтервалом між надходженням нових вимірювань. Якщо сумарний час виконання перевищує доступний інтервал, система потребує додаткової оптимізації або зміни архітектури.

Для автоматизованого аналізу часових характеристик може використовуватися така програмна функція (Лістинг 3.2):

Лістинг 3.2 – Оцінка можливості роботи в реальному часі

```
import time

def estimate_processing_budget(process_time_ms, sensor_rate_hz):
    available_time = 1000 / sensor_rate_hz

    if process_time_ms < available_time:
        return "Робота в реальному часі можлива"
    else:
        return "Необхідна оптимізація"

result = estimate_processing_budget(
    process_time_ms=3.8,
    sensor_rate_hz=238
)

print(result)
```

Такий підхід дає змогу швидко оцінювати відповідність архітектури вимогам конкретної сенсорної системи ще до проведення повномасштабних експериментів.

Розглянуті нейромережеві методи орієнтовані не тільки на досягнення високих показників класифікації, а ще на подальшу інтеграцію у реальні системи аналізу фізичних полів. Тому під час проектування архітектур враховувалися

обмеження апаратних платформ, особливості каналів зв'язку, вимоги до автономності та можливість роботи в польових умовах.

Використання компактних одновимірних згорткових мереж для РІ-сигналів, ансамблевого стекінгу для інтеграції рішень, механізмів мультисенсорного злиття та фізично-інформованих моделей створює архітектуру, яка може бути реалізована на сучасних мобільних обчислювальних платформах без необхідності використання високопродуктивних серверів безпосередньо на борту.

Додатковою перевагою є модульність побудови. Кожна нейромережева гілка функціонує як незалежний компонент і може модернізуватися без зміни інших частин системи. Це уможливорює поступово нарощувати функціональність комплексу та інтегрувати нові сенсорні канали без повної перебудови програмно-апаратної архітектури.

Запропоновані нейромережеві методи відповідають вимогам реального часу, сумісні з сучасними вбудованими платформами та можуть використовуватися як основа для побудови практичних систем виявлення і класифікації аномалій у фізичних полях.

3.7 Висновки до третього розділу

У третьому розділі розроблено нейромережеві методи виявлення та класифікації аномалій, які перетворюють структуроване мультисенсорне подання другого розділу на рішення. Основні результати полягають у такому.

1. На підставі вимог задачі – відповідності архітектур структурі даних каналів, працездатності за обмежених вибірок, придатності до бортового виконання та інтерпретованості – обґрунтовано вибір базових рішень: компактні одновимірні згорткові мережі для часових сигналів імпульсної індукції, двовимірні згорткові гілки для просторових подань, ансамблевий стекінг на інтегральному рівні. Показано, що рекурентні архітектури для задачі надлишкові, а трансформерні моделі доцільно використовувати не як базову

архітектуру, а як джерело механізму адаптивного зважування каналів [36, 37, 45, 46].

2. Розроблено та навчено одновимірну згорткову мережу для класифікації об'єктів за п'ятикомпонентним вектором РІ-сигналів: на лабораторних даних досягнуто 95–100 % точності розрізнення чотирьох класів еталонних об'єктів, невідомі об'єкти коректно впорядковано відносно еталонів, а повний цикл оброблення виконується швидше ніж за 4 мс, що гарантує бортову роботу в темпі вимірювань [59]; досягнутий рівень узгоджується з незалежними результатами класифікації металевих об'єктів одновимірними згортковими мережами за РІ-даними, де повідомлено про точність 98–99 % [10, 27]. У поєднанні з енергетичним центроїдом мережа розв'язує і задачу локалізації з похибкою порядку одиниць сантиметрів на лабораторних даних [59].

3. Досліджено ансамблевий класифікатор зі стекінгом: метарівень, навчений на виходах шести різнорідних мереж, знижує кількість помилок на 13–17 % порівняно з голосуванням [43], а клонування мереж циклічним зсувом входу зменшує кількість збіжних помилок на тестовій вибірці зображень [43, 66]. Архітектура безпосередньо масштабується на мультисенсорний випадок і реалізовна на вбудованих процесорах [43].

4. Запропоновано архітектуру мультисенсорного злиття зі спеціалізованими гілками каналів, об'єднанням ознак та ансамблевим метарівнем, доповнену модулем адаптивного зважування каналів на основі механізму уваги, який враховує змінну інформативність джерел без перенавчання основної системи. Сформульовано третій пункт наукової новизни – нейромережевий метод виявлення та класифікації аномалій на основі подання $T(x, y, k)$ зі спеціалізованими гілками та ансамблевим стекінгом (підрозділ 3.4); кількісне оцінювання методу на польових даних винесено до п'ятого розділу.

5. Розвинуто підхід фізично-інформованих нейронних мереж для задачі: сформульовано фізичні моделі сигналів обох підповерхневих каналів – багатоекспоненціальне затухання вихрових струмів та дипольну структуру магнітної аномалії.

Конкретизовано функцію втрат $L = L_{data} + \lambda_{phys} \cdot L_{phys}$ з членами фізичної невязки та міжканальної узгодженості. Сформульовано п'ятий пункт наукової новизни (підрозділ 3.5); систематичне кількісне оцінювання внеску фізичної регуляризації визначено як напрям подальших досліджень [69].

6. Визначено умови реалізації методів у реальному часі: бюджет 4,2 мс на RI-вектор виконується з запасом [59]; просторові подання обробляються фрагментно з перекриттям; розподіл обчислень між бортом і землею (рис. 3.7) успадковує інформаційну модель другого розділу; стандартні методи оптимізації моделей застосовні до використаних компактних архітектур, а їх кількісне оцінювання доцільне після фіксації остаточних конфігурацій.

Розроблені методи відповідають на п'яту задачу дослідження. Їхня практична якість, однак, вирішальною мірою залежить від навчальних даних: складу вибірки, балансу класів, реалістичності аугментації та стратегії подолання доменного зсуву між лабораторними і польовими умовами. Цим питанням – разом з плануванням місій і порівнянням з відкритими наборами даних – присвячено четвертий розділ.

Основні результати третього розділу опубліковано в працях [3, 57].

РОЗДІЛ 4

ФОРМУВАННЯ НАВЧАЛЬНИХ ВИБІРОК ТА ПЛАНУВАННЯ МІСІЙ ДЛЯ НЕЙРОМЕРЕЖЕВОГО ВИЯВЛЕННЯ АНОМАЛІЙ

4.1 Планування місії та виділення зон інтересу

Якість нейромережевого виявлення визначається як методами третього розділу, так і тим, які саме дані потрапляють на їхній вхід. Цей розділ присвячено даним: плануванню місій збирання, формуванню навчальних вибірок, їх розширенню та подоланню розриву між умовами навчання і застосування. Початковою ланкою є місія – спланований обліт території, під час якого мультисенсорна платформа збирає вимірювання і саме на рівні місії закладаються і повнота покриття, і якість майбутніх вибірок.

4.1.1 Оглядова розвідка та виділення зон інтересу

Місія будується багатоетапною. На першому етапі виконується оглядова розвідка з більшої висоти. Оптичний канал покриває всю ділянку, формуючи геоприв'язану мозаїку видимого і близького інфрачервоного діапазонів. На цій мозаїці за прямими ознаками (видимі об'єкти, порушення поверхні, сліди техніки, воронки) та непрямыми (аномалії вегетаційних індексів, межі ділянок з різним характером рослинності) виділяються зони інтересу, які потребують детального обстеження; сегментація мозаїк виконується оптичною гілкою наземної станції.

4.1.2 Детальне мультисенсорне сканування

На другому етапі виконується детальне мультисенсорне сканування лише зон інтересу. Політ здійснюється на робочій висоті зі швидкістю 1–3 м/с паралельними маршрутами з контрольованим перекриттям. На цьому етапі активуються всі підповерхневі канали системи: імпульсна індукція, магнітометрія та додаткові сенсори, якщо вони передбачені конфігурацією

комплексу. Основною задачею стає не огляд території, а отримання максимально щільного набору вимірювань для побудови просторових карт фізичних полів.

Третій етап пов'язаний із уточнювальним скануванням. Після завершення первинного проходу виконується оперативна побудова карти ризику та аналіз зон невизначеності. Якщо для окремих ділянок система формує суперечливі або недостатньо достовірні рішення, призначаються додаткові проходи з іншими параметрами польоту. Залежно від характеру аномалії може змінюватися висота руху, орієнтація траєкторії, швидкість сканування або щільність покриття.

Особливістю такої організації є можливість поступового збільшення деталізації дослідження. На ранніх етапах система працює з великими територіями та мінімальними витратами часу. У міру накопичення інформації ресурси концентруються лише на тих ділянках, які дійсно потребують детального аналізу. Це дозволяє суттєво підвищити ефективність використання як льотного часу, так і обчислювальних ресурсів.

З точки зору нейромережевого аналізу багатоступенева структура має ще одну важливу перевагу. Усі етапи місії формують різні типи даних. Оглядовий рівень створює просторовий контекст і уможливлює аналізувати великі території. Детальне сканування формує високоточні навчальні приклади для підповерхневих каналів. Адаптивний етап генерує приклади складних випадків, які найчастіше використовуються для подальшого донавчання моделей.

Загальна структура багатоетапної місії представлена на рис. 4.1.




Рисунок 4.1 – Загальна структура багатоетапної місії

Така схема дозволяє розглядати місію не як одноразовий обліт території, а як адаптивний процес збору даних, в якому кожний наступний етап використовує результати попереднього. Це і створює основу для ефективного

використання нейромережових методів виявлення аномалій у великих просторових областях.

Одним із найефективніших способів скорочення часу детального обстеження є попередній аналіз даних дистанційного зондування. Практика польових робіт показує, що лише незначна частина території містить ознаки, які можуть бути пов'язані з потенційними аномаліями. Суцільне застосування підповерхневих сенсорів до всієї площі призводить до значних витрат часу та ресурсів. Тому до початку детального сканування виконується аналіз відеопотоку та мультиспектральних зображень.

Під час оглядового польоту система накопичує послідовність геоприв'язаних кадрів видимого та ближнього інфрачервоного діапазонів. Після ортотрансформування та зшивання формується єдина просторова мозаїка місцевості. На відміну від окремих кадрів, така мозаїка забезпечує цілісне представлення території та дає змогу виконувати подальший автоматизований аналіз.

Особливий інтерес становлять непрямі ознаки присутності прихованих об'єктів. У багатьох випадках фізичні аномалії впливають на стан поверхневого шару ґрунту та рослинності. Це проявляється у зміні кольору рослин, локальних відмінностях густоти покриття, зміні вологості або температурного режиму. Такі зміни можуть бути непомітними для оператора під час візуального огляду, проте добре виявляються під час автоматизованого аналізу спектральних характеристик.

Для оцінювання стану рослинності використовуються спектральні індекси. Найбільш інформативними є *NDVI*, *GNDVI*, *SAVI* та їх модифікації. Вони уможливають виявляти локальні області зі зміненими біофізичними характеристиками, які можуть бути пов'язані з наявністю підповерхневих об'єктів або порушенням структури ґрунту.

Окрім спектральних показників, аналізуються текстурні характеристики поверхні. Для цього використовуються карти локальної дисперсії, контрастності та просторової однорідності. У багатьох випадках саме текстурні ознаки

дозволяють виявити старі сліди земляних робіт, які вже не мають чітко виражених спектральних проявів.

Окремим напрямом є аналіз відеопослідовностей. На відміну від окремих знімків, відео містить додаткову інформацію про структуру місцевості, яка проявляється під час зміни ракурсу спостереження. Це уможливорює ефективніше виділяти мікрорельєф, воронки, траншеї та інші поверхневі об'єкти.

Після завершення аналізу формується карта зон інтересу. Кожна комірка карти отримує інтегральну оцінку перспективності подальшого обстеження. Ця карта надалі використовується модулем планування маршруту для формування детального польотного завдання.

Формально карта зон інтересу задає кожній комірці i оцінку перспективності s_i ; до детального обстеження відбираються комірки з оцінкою не нижчою за поріг θ :

$$\mathcal{R}(\theta) = \{i: s_i \geq \theta\}, \quad \rho(\theta) = \frac{|\mathcal{R}(\theta)|}{N}, \quad (4.1)$$

де N – загальна кількість комірок, $\rho(\theta)$ – частка площі під детальне сканування. Повнота виявлення цілей і відносне скорочення площі дорівнюють:

$$C(\theta) = \frac{N_{tgt}^{\mathcal{R}}}{N_{tgt}}, \quad \eta_{red} = 1 - \rho(\theta). \quad (4.2)$$

Поріг обирають як розв'язок задачі умовної оптимізації – максимум скорочення площі за умови збереження заданої повноти C_{min} :

$$\theta^* = \underset{\theta}{argmax} (1 - \rho(\theta)), \quad C(\theta) \geq C_{min}. \quad (4.3)$$

Схема попереднього аналізу даних дистанційного зондування представлена на рис. 4.2.



Рисунок 4.2 – Схема попереднього аналізу даних дистанційного зондування

Попередній аналіз виконує відразу три функції. По-перше, він сприяє скороченню площі детального обстеження. По-друге, формує просторовий контекст для подальшого мультисенсорного аналізу. По-третє, створює додаткові канали даних, які можуть використовуватися нейромережевими моделями під час інтегрованого аналізу аномалій. Тому попередній аналіз відео та мультиспектральних зображень є не допоміжним елементом, а повноцінною складовою загальної системи виявлення аномалій у фізичних полях.

4.1.3 Оптимізація маршрутів

Після визначення геометрії покриття та формування зон інтересу наступним етапом стає побудова маршруту, який забезпечує збір необхідного обсягу даних за мінімально можливий час. На практиці саме маршрут часто визначає загальну тривалість місії значно сильніше, ніж швидкість роботи сенсорів або продуктивність обчислювальної системи. Навіть за однакової площі обстеження різниця між вдало та невдало спланованою траєкторією може становити десятки відсотків загального польотного часу.

За фіксованої геометрії покриття залишається комбінаторна свобода – порядок обходу смуг і зон інтересу, який визначає довжину неробочих ділянок маршруту: перельотів між зонами і розворотів. Для односмугової прямокутної ділянки оптимальний порядок тривіальний («змійка»), але реальна місія складніша: кілька розділених зон інтересу неправильної форми, заборонені для прольоту ділянки, обмеження ємності акумулятора, що розбиває місію на кілька вильотів з поверненнями до точки старту. Задача набуває структури маршрутизації з обмеженнями, для якої точний перебір нездійснений, а евристики чутливі до конфігурації.

Маршрут π – це послідовність відвідування сегментів покриття. Його вартість складається з робочих ділянок (фіксована довжина ℓ) і неробочих переходів τ між сегментами; оптимізують саме переходи за енергетичного обмеження $E_{\max}$:

$$L(\pi) = \sum_k \ell_{\pi_k} + \sum_k \tau(\pi_k, \pi_{k+1}), \quad (4.4)$$

$$\pi^* = \underset{\pi}{\operatorname{argmin}} L(\pi), \quad L(\pi) \leq E_{\max}. \quad (4.5)$$

На відміну від класичних задач аерофотознімання, де головною метою є отримання суцільної фотограмметричної моделі території, маршрут мультисенсорного комплексу повинен враховувати специфіку підповерхневих вимірювань. Для підповерхневих сенсорів критичне значення має стабільність висоти польоту, постійність швидкості руху та точність проходження траєкторії. Навіть незначні відхилення можуть впливати на щільність вимірювань і якість

просторової прив'язки сигналів. Відповідно алгоритм маршрутизації повинен мінімізувати не тільки загальну довжину маршруту, а ще і кількість різких змін напрямку руху та режимів польоту.

Особливу складність створюють зони інтересу складної форми. Після автоматичного аналізу мультиспектральних даних такі області рідко мають правильну геометрію. Вони можуть бути представлені кількома окремими кластерами, вузькими витягнутими ділянками або набором ізольованих локальних аномалій. Використання стандартної схеми покриття в таких умовах призводить до появи великої кількості холостих перельотів, які не несуть нової інформації, але витрачають ресурс акумулятора.

У роботі [61] для цієї задачі застосовано генетичний алгоритм: маршрут кодується хромосомою – послідовністю відвідування сегментів покриття; функція пристосованості штрафує сумарну довжину неробочих ділянок і порушення енергетичних обмежень; оператори схрещування і мутації зберігають допустимість маршрутів. Еволюційний пошук добре пасує задачі саме через її комбінаторну природу і нерегулярні обмеження, які складно вбудувати в класичні точні методи.

оптимізатор працює з набором сегментів покриття, сформованих на попередньому етапі. Для кожного сегмента відомі координати початку та завершення проходу, необхідна висота польоту, прогнозована тривалість сканування та енергетичні витрати. На основі цих параметрів формується матриця вартості переходів між сегментами. І вона використовується під час пошуку оптимальної послідовності їх відвідування.

Важливою особливістю є врахування енергетичних обмежень платформи. Якщо сумарна довжина маршруту перевищує доступний запас енергії, алгоритм автоматично розбиває місію на кілька незалежних вильотів. У такому випадку додатково оптимізуються точки повернення на базу та порядок обслуговування окремих кластерів зон інтересу.

Практичний результат – скорочення загального часу польоту на 27 % порівняно з рівномірним покриттям без оптимізації порядку [61]; для

багатовильотних місій виграш безпосередньо конвертується у зменшення кількості вильотів. Особливо помітний ефект спостерігається на великих територіях із неоднорідним розподілом зон інтересу, де частка холостих переміщень може досягати значної частини всієї місії.

Той самий оптимізатор природно обслуговує і третій етап місії. Множина комірок, призначених до повторного обстеження картою ризику, є черговим набором сегментів для маршрутизації. Завдяки цьому система може автоматично формувати уточнювальні польоти без участі оператора, концентруючи ресурси лише на найбільш невизначених ділянках. Схема процесу оптимізації маршруту можна представити так (рис. 4.3):



Рисунок 4.3 – Схема процесу оптимізації маршруту

Оптимізація маршрутів розглядається не як допоміжний елемент планування польоту, а як повноцінна складова системи збору даних. Від якості маршрутизації безпосередньо залежать продуктивність місії, щільність отриманих вимірювань та ефективність використання обчислювальних і енергетичних ресурсів платформи.

4.1.4 Метадані місії

Для формування навчальних вибірок місія має додаткову специфіку: важлива не тільки повнота покриття, а й контрольованість і задокументованість умов. У задачах нейромережевого аналізу фізичних полів самі вимірювання становлять лише частину інформації. Не менш важливими є відомості про умови їх отримання, бо якраз ці умови часто визначають характер варіацій сигналів і впливають на подальше навчання моделей.

Кожен запис супроводжується метаданими двох рівнів. Рівень місії фіксує дату і час, ділянку, погодні умови, стан ґрунту і рослинності, конфігурацію платформи і калібрування сенсорів. Рівень запису фіксує висоту, швидкість, координати, температуру електроніки, номер проходу. Без цих даних неможливо ні коректно інтерпретувати варіативність сигналів, ні цілеспрямовано формувати підвибірки за умовами знімання, а саме підвибірки за сезонами, висотами і станами ґрунту є робочим матеріалом стратегії подолання доменного зсуву (підрозділ 4.4).

З практичної точки зору метадані виконують роль додаткового інформаційного шару, який описує контекст отримання вимірювань. Наприклад, одна й та сама аномалія може формувати різні сигнали залежно від вологості ґрунту, температури навколишнього середовища або висоти польоту носія. Якщо ці параметри не зберігаються разом із вимірюваннями, відрізнити фізичний ефект від впливу умов спостереження стає практично неможливо.

Особливе значення мають параметри навігації. Для кожного запису зберігаються координати, висота над поверхнею, просторове положення платформи, швидкість руху та часові мітки синхронізації. Ці дані

використовуються під час побудови просторових карт фізичних полів, а також дозволяють повторно відтворити умови проведення місії.

Окрему групу становлять технічні метадані сенсорної системи. До них належать коефіцієнти калібрування, версії програмного забезпечення, режими роботи сенсорів, параметри фільтрації сигналів та інформація про конфігурацію нейромережових моделей. Збереження таких даних забезпечують відтворюваність результатів, навіть, через значний проміжок часу після проведення вимірювань.

Не менш важливою є інформація про якість вимірювань. Для кожного запису можуть зберігатися показники рівня шуму, кількість втрачених пакетів даних, якість супутникової навігації, рівень заряду акумулятора та інші службові характеристики. Надалі ці параметри можуть використовуватися для автоматичного відбору даних під час формування навчальних вибірок.

Метадані, крім того, є основою відтворюваності. Незалежний дослідник має змогу відібрати з відкритого набору записи з порівнянними умовами. Склад полів метаданих стандартизовано у форматах підрозділу 4.6.

Метадані є не допоміжним доповненням до вимірювань, а повноцінною частиною інформаційної моделі системи: вони забезпечують контроль умов проведення експериментів, підтримують процедури формування навчальних вибірок, створюють основу для аналізу доменного зсуву та уможливають відтворення результатів нейромережевого аналізу в майбутніх дослідженнях

А загальна структуру метаданих місії можна представити таким чином (рис. 4.4):




Рисунок 4.4 – Загальна структура метаданих місії

4.2 Формування навчальної вибірки

4.2.1 Структура зразка

Кінцевою метою конвеєра другого розділу є структурована навчальна вибірка. Її архітектура включає структуру зразка, стратегію збору, процедури нормування, правила балансування і розбиття та формати зберігання; розглянемо ці елементи послідовно.

Кожен зразок вибірки відповідає ділянці координатної сітки розміром близько 1×1 м – достатньо для покриття одного потенційного об'єкта з оточенням, оскільки просторовий відгук протитанкової міни становить 60–80 см, а контекст довкола відгуку сам по собі інформативний для відсіювання локальних викидів. Зразок містить: тензор РІ-ознак (п'ять каналів часових розгортки або енергетичне подання $E(x, y)$); тензор магнітометричних ознак (три диференціальні канали); тензор оптичних ознак (R, G, B, NIR та індекси $NDVI, VARI$); мітку – бінарну, мультикласову або координати центру для задачі локалізації [5, 59, 61]. Розмір зразка узгоджено з фрагментним обробленням просторових гілок (пункт 3.6.4): зразок і є елементарним фрагментом аналізу.

Структура зразка визначається не окремим сенсором, а необхідністю подальшого мультисенсорного злиття даних. Зважаючи на це всі канали повинні бути приведені до єдиної просторової системи координат і синхронізовані за часовими мітками. Для кожної комірки сітки формується узгоджений набір ознак, який описує ту саму ділянку місцевості з позиції різних фізичних принципів вимірювання. У результаті нейронна мережа працює не з окремими сигналами, а з комплексним цифровим представленням локальної області дослідження.

Особливістю запропонованої структури є поєднання даних різної розмірності. РІ-канал представлений часовими сигналами або похідними від них ознаками. Магнітометричний канал формує просторові карти розподілу магнітного поля. Оптична підсистема працює із багатоканальними растровими зображеннями. Для того щоб усі ці дані могли використовуватися в межах

єдиного навчального прикладу, виконується їх приведення до спільної інформаційної моделі, сформованої у другому розділі.

Важливо, що до складу зразка входять не тільки первинні вимірювання, а й результати попередньої обробки. Наприклад, для оптичного каналу поряд із початковими спектральними шарами можуть зберігатися карти вегетаційних індексів. Для РІ-сигналів інтегральні енергетичні характеристики, параметри апроксимації або похідні ознаки, сформовані під час аналізу форми сигналу. Такий варіант дає змогу використовувати одну й ту саму вибірку для різних архітектур нейронних мереж без повторного виконання всього циклу попередньої обробки.

Окремим компонентом структури зразка є розмітка. Для задачі виявлення використовується бінарна мітка, яка вказує на наявність або відсутність аномалії в межах фрагмента. Для задачі класифікації формується мультикласова мітка, що визначає тип об'єкта або характер аномалії. Для задач локалізації додатково зберігаються координати центру аномалії відносно меж фрагмента. У випадку сегментаційних моделей розмітка може бути представлена бінарною маскою, яка визначає область розташування об'єкта на просторовій карті.

Крім основних даних, до складу кожного зразка включаються службові атрибути. До них належать ідентифікатор місії, координати центру фрагмента, номер проходу, висота польоту, швидкість руху носія та інші параметри, які надалі використовуються для аналізу доменного зсуву та формування спеціалізованих підвбірок. Такий підхід дозволяє виконувати як навчання моделей, так і детальний аналіз факторів, які впливають на їхню узагальнюючу здатність.

Кожний зразок вибірки є завершеним цифровим описом невеликої ділянки місцевості, який містить як фізичні вимірювання, так і інформацію про умови їх отримання. Така структура забезпечує подальшу сумісність між усіма нейромеревими методами, розглянутими у третьому розділі. Для приклада, загальна структура одного навчального зразка представлена на рис. 4.5.



Рисунок 4.5 – Загальна структура одного навчального зразка

4.2.2 Лабораторне джерело даних

У роботі поєднано два джерела даних, і саме їхнє поєднання є предметом окремого дослідження. Лабораторні дані зібрано на контрольованому стенді, де РІ-датчик, закріплений на механічному позиціонері, сканує еталонні об'єкти – набори сталевих шайб різної маси та розміру, що моделюють характерні цілі, – з відомими координатами [59, 60].

Лабораторний стенд являє собою систему прецизійного позиціонування, яка уможливорює багаторазово відтворювати однакові траєкторії сканування з мінімальними відхиленнями координат. Усі параметри експерименту контролюються оператором і залишаються незмінними протягом серії вимірювань. Це створює умови, за яких будь-які зміни сигналу можуть бути пов'язані виключно з характеристиками досліджуваного об'єкта.

Стенд дає три переваги. Точність позиціонування порядку міліметрів означає розмітку фактично без шуму; відсутність ґрунтових ефектів – «чисті» сигнатури об'єктів; повна відтворюваність відкриває систематичний перебір конфігурацій за типами об'єктів, висотами і поперечними зміщеннями. Саме на цих даних отримано 95–100 % точності одновимірної згорткової мережі [59] та побудовано регресійні залежності «енергія → фізичні параметри» (підрозділ

2.8.4); близький рівень точності для класифікації металевих об'єктів за РІ-сигналами одновимірними згортковими мережами незалежно підтверджено в [10, 27].

Практична цінність лабораторного джерела полягає насамперед у можливості детального дослідження фізики сигналів. На відміну від польових вимірювань, де одночасно діють десятки факторів, лабораторний експеримент дає змогу змінювати лише один параметр і спостерігати його вплив на форму сигналу. Наприклад, можна окремо досліджувати вплив маси металу, геометричних розмірів об'єкта, його орієнтації або відстані до сенсора.

Особливо важливим є те, що лабораторні вимірювання дозволяють формувати збалансовані набори даних. У польових умовах кількість прикладів певних класів часто визначається випадковими обставинами. У лабораторії кількість вимірювань для кожної категорії може бути довільно збільшена. Це сприяє створенню симетричних навчальних вибірок без суттєвого дисбалансу між класами.

Ще однією перевагою є можливість накопичення великої кількості повторних вимірювань. Для кожної конфігурації об'єкта можуть бути виконані сотні або навіть тисячі сканувань. Надалі такі дані використовуються для оцінювання внутрішньокласової варіативності сигналів та побудови статистичних моделей шумів вимірювального тракту.

Лабораторне джерело використовується і під час проектування нейромережових архітектур. На ньому зазвичай і виконуються перші експерименти з вибором структури моделі, підбором параметрів навчання та перевіркою працездатності нових алгоритмів. Завдяки високій якості розмітки результати таких експериментів значно легше інтерпретувати та аналізувати.

Водночас, лабораторне середовище має очевидні обмеження. Відсутність реального ґрунту, неоднорідностей середовища, електромагнітних завад, вібрацій платформи та навігаційних похибок призводить до того, що статистичні характеристики сигналів відрізняються від польових умов. Отже, лабораторні дані не можуть повністю замінити реальні вимірювання. Їх основне призначення

полягає у формуванні високоякісного базового набору сигнатур, який надалі доповнюється польовими даними та використовується в межах стратегії «лабораторне навчання – польове донавчання», що розглядається у підрозділі 4.4.

Лабораторне джерело відповідає за точність розмітки, відтворюваність умов експерименту, контроль фізичних параметрів об'єктів та накопичення еталонних сигнатур. А воно створює фундамент для побудови нейромережових моделей, тоді як адаптація цих моделей до реальних умов експлуатації забезпечується наступним джерелом даних – польовими вимірюваннями.

4.2.3 Польове джерело та відкритий набір даних

Польові дані зібрано під час льотних випробувань гексакоптера з РІ-датчиком [60]: еталонні та реальні об'єкти розміщувалися на поверхні ґрунту, а вимірювання виконувалися серіями проходів за контрольованих поперечних зміщень цілі (шкала 0–100 см) і фіксованої висоти сканування близько 10 см (підрозділ 2.9). Після оброблення понад 20 000 окремих записів дані викладено у відкритий доступ у репозиторії <https://github.com/op-uav-lab/soil-monitor-mlp> [59, 60]. Записи зберігаються у форматі CSV: часові розгортки трьох приймальних каналів (CH2, CH3, CH4) близько тисячі відліків на запис, для частини об'єктів – обчислені різницеві канали; імена файлів кодують конфігурацію вимірювання (поперечне зміщення і висоту сканування), повна специфікація якої наведена в описі репозиторію. Склад набору за функціональними групами наведено у табл. 4.1.

Відкрита публікація набору розв'язує одразу три задачі. Забезпечує відтворюваність результатів дисертації, дає спільноті рідкісний матеріал – підповерхневі РІ-розгортки з БПЛА, практично відсутні у відкритих наборах (підрозділ 4.5), – і створює основу для незалежного навчання та порівняння моделей.

Таблиця 4.1 – Функціональний склад відкритого набору даних

Група записів	Зміст	Роль у дослідженні
Калібрувальні записи	Вимірювання без об'єкта та з опорними конфігураціями	Компенсація фону, контроль стабільності тракту
Профілі чутливості	Серії за контрольованих поперечних зміщень і висот	Просторова характеристика сенсора, основа різницевих ознак
Еталонні об'єкти N1–N4	Набори шайб відомої маси і площі	Навчання та калібрування класифікатора
Складанки U1, U2	Об'єкти поза навчальними класами	Перевірка узагальнення (пункт 3.2.4)
Реальні об'єкти	Металева гільза, кілок розтяжки	Польова апробація на типових знахідках (підрозділ 2.9)
Тестова підвибірка	Записи з невідомими об'єктами	Незалежне підсумкове оцінювання

4.2.4 Нормування зразків

Перед поданням в мережі зразки проходять нормування, яке усуває неінформативні масштабні відмінності між записами, не зачіпаючи інформативної форми сигналів. Для РІ-розгорток базова операція – компенсація фонові складові. З кожної розгортки віднімається базова лінія, оцінена за «хвостом» запису, де відгук об'єкта вже затух (підрозділ 2.8.2). Далі застосовується масштабне нормування: або мінімакс-перетворення

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}}, \quad (4.6)$$

яке зводить значення до фіксованого діапазону, або стандартизація $x' = \frac{x - \mu}{\sigma}$ за середнім і відхиленням, оціненими на навчальній частині.

Принципові правила тут два. Перше правило: статистики нормування (μ , σ , межі діапазону) обчислюються лише за навчальною підвибіркою і застосовуються до валідаційної і тестової як константи – інакше відбувається витік інформації. Друге правило: нормування не повинно знищувати міжканальні співвідношення, які несуть позиційну інформацію (підрозділ 2.8.3), – тому амплітудні масштаби трьох котушкових каналів нормуються спільним коефіцієнтом, а не поканально. Для оптичних каналів нормування зводиться до радіометричної корекції та обчислення індексів, виконаних ще на рівні попереднього оброблення (підрозділ 2.14.3).

нормування є одним із найважливіших етапів підготовки вибірки, оскільки саме на цьому кроці усувається значна частина варіацій, не пов'язаних із фізичними характеристиками об'єктів. Практичні вимірювання показують, що два сигнали від одного й того самого об'єкта можуть відрізнитися за абсолютною амплітудою через зміну висоти польоту, температури електронних компонентів, стан акумулятора або рівень електромагнітних завад. Якщо такі відмінності залишити без корекції, нейронна мережа починає використовувати їх як ознаки класу, що призводить до погіршення узагальнюючої здатності моделі.

Особливе значення має стабілізація РІ-сигналів. Для часових розгортки важливо зберегти співвідношення між початковою частиною сигналу та його хвостом, оскільки саме ця структура містить інформацію про провідність, розміри та форму об'єкта. Агресивне нормування здатне зруйнувати ці співвідношення та фактично видалити частину корисної інформації. Тому всі операції виконуються таким чином, щоб змінювався лише масштаб сигналу, але не його відносна форма.

Контролюється узгодженість між різними каналами одного зразка. Для трикотушкової РІ-системи різниця амплітуд між каналами не є випадковою. Навпаки, вона безпосередньо пов'язана з поперечним положенням об'єкта відносно осі сенсора. Якщо кожен канал нормувати незалежно, ця інформація буде втрачена. Тому для всього набору котушкових сигналів використовується

єдиний масштабний множник, який забезпечує збереження міжканальних співвідношень.

Для магнітометричних даних процедура має свої особливості. Перед нормуванням виконується компенсація постійної складової магнітного поля та повільних дрейфів базового рівня. Після цього сигнали різних проходів приводяться до спільного масштабу, що уможливорює порівнювати аномалії незалежно від конкретних умов вимірювання. Особлива увага приділяється усуненню сезонних і добових варіацій геомагнітного поля, які можуть перевищувати амплітуду корисних локальних збурень.

Для мультиспектральних каналів нормування виконується дещо інакше. Тут важливо не стільки привести дані до певного числового діапазону, скільки забезпечити однаковість радіометричних характеристик між різними польотами. На практиці це означає компенсацію зміни освітленості, положення Сонця, атмосферних умов та параметрів камери. Після виконання радіометричної корекції всі спектральні канали переводяться до стандартизованого формату, придатного для подальшого обчислення вегетаційних індексів та текстурних ознак.

Важливою складовою нормування є контроль аномальних значень. В реальних даних трапляються окремі вимірювання, що виникають через збої електроніки, короткочасні перешкоди чи помилки передавання інформації. Такі значення можуть у десятки разів перевищувати типовий рівень сигналу. Перед масштабуванням вони виявляються за допомогою статистичних критеріїв та замінюються граничними значеннями або виключаються з подальшого аналізу. Це сприяє уникненню ситуації, коли поодинокий викид визначає масштаб усієї вибірки.

Важливим є однаковість процедур нормування для всіх джерел даних. У даній роботі використовуються як лабораторні, так і польові вимірювання. Якщо для цих двох джерел застосовувати різні правила підготовки, нейронна мережа почне відрізняти їх за особливостями обробки, а не за реальними фізичними

характеристиками сигналів. Тому весь конвеєр нормування уніфікується та застосовується однаково до всіх наборів даних.

Після завершення цього етапу кожний навчальний зразок переходить у стандартизований формат представлення, в якому зберігається фізично значуща структура сигналів, але усуваються випадкові масштабні відмінності між окремими записами. Така форма даних є найбільш придатною для подальшого навчання нейромережових моделей, оскільки дозволяє концентруватися на аналізі реальних ознак аномалій, а не на побічних ефектах процесу вимірювання.

І в результаті нормування всі навчальні приклади отримують єдину структуру представлення, що забезпечує коректне порівняння даних різних місій, різних сенсорів та різних умов спостереження під час подальшого навчання і тестування нейромережових моделей.

4.2.5 Складні негативні приклади та балансування класів

Дві статистичні властивості польових даних визначають правила складання вибірки. Перша – дисбаланс класів. Переважна частина зразків будь-якої реальної ділянки не містить об'єктів, і навчена на такому розподілі мережа схильна до тривіальної стратегії «завжди фон». Дисбаланс компенсується трьома узгодженими механізмами: ваговими коефіцієнтами класів у функції втрат (пункт 3.2.4), контрольованим передискретизуванням – повторним включенням цільових зразків з аугментацією (підрозділ 4.3), та цілеспрямованим добиранням складних негативних прикладів.

Найзмістовнішим з них є останній. До вибірки явно додаються ділянки з природними неоднорідностями, металевим сміттям, нерівностями поверхні, слідами техніки – реалістичні завади, без яких класифікатор навчається відрізнити об'єкт від «ідеального» фону, але не від того фону, з яким зустрінеться у полі. Джерелом складних негативів слугують і хибні спрацювання попередніх версій системи: цикл «помилка → діагноз → поповнення вибірки» систематично перетворює слабкі місця моделі на навчальний матеріал.

Практика побудови систем виявлення показує, що саме складні негативні приклади найбільше впливають на якість роботи нейромережі в реальних умовах. Простий фон практично не створює труднощів для сучасних моделей. Значно складнішими є ситуації, коли природні або техногенні об'єкти формують сигнали, частково схожі на сигнали цільових об'єктів. У таких випадках система повинна навчитися розрізняти наявність аномалії і її фізичну природу.

Для РІ-каналу до категорії складних негативів належать дрібні металеві предмети, фрагменти дроту, уламки арматури, металеві елементи сільськогосподарської техніки та інші випадкові провідні об'єкти. Вони можуть формувати виражені імпульсно-індукційні сигнали, однак їх часові характеристики відрізняються від характеристик цільових об'єктів. Саме на таких прикладах мережа навчається використовувати форму сигналу, а не тільки його амплітуду.

Для магнітометричного каналу складними негативами є локальні геологічні неоднорідності, фрагменти феромагнітного сміття, залишки інженерних конструкцій та області зі складною просторовою структурою магнітного поля. Такі ділянки часто формують аномалії, які за амплітудою можуть бути співставними з корисними сигналами.

У випадку оптичного та мультиспектрального аналізу складні негативні приклади представлені ділянками зі зміненою рослинністю, локальними змінами вологості, коліями техніки, тінями, слідами обробки ґрунту та іншими природними або антропогенними особливостями поверхні. Такі об'єкти найчастіше потрапляють до зон інтересу під час попереднього аналізу зображень і тому повинні бути присутніми у навчальній вибірці.

Окремо контролюється співвідношення між різними типами негативних прикладів. Якщо вибірка міститиме переважно простий фон, модель демонструватиме високі формальні показники точності, але погано працюватиме в польових умовах. З цієї причини під час формування набору даних прагнуть забезпечити достатню кількість саме складних негативів, які найбільше наближені до реальних причин хибних спрацювань.

Важливим джерелом таких даних є результати попередніх місій. Кожна хибна тривога, зафіксована системою під час експлуатації, розглядається як потенційно цінний навчальний приклад. Після перевірки оператором відповідний фрагмент додається до бази складних негативів. вибірка поступово накопичує найбільш проблемні сценарії, а модель адаптується до умов реального використання.

У результаті балансування класів розглядається не як механічне вирівнювання кількості позитивних і негативних прикладів, а як цілеспрямоване формування статистично та фізично репрезентативної вибірки. За допомогою такого способу можна підвищити стійкість нейромережевих моделей до завад, зменшити кількість хибних спрацювань та забезпечити коректну роботу системи в умовах, максимально наближених до реальних сценаріїв застосування.

4.2.6 Просторово коректне розбиття вибірки

Друга властивість – просторова кореляція: сусідні зразки одного проходу сильно корельовані і за сигналом, і за умовами, тож випадкове перемішування всіх зразків перед розбиттям призводить до витоку інформації з навчальної частини в тестову – мережа «впізнає» сусідні фрагменти того самого проходу, і оцінки якості виявляються систематично завищеними. Тому розбиття виконується на рівні проходів і сценаріїв: усі зразки одного прольоту потрапляють лише в одну з частин – навчальну, валідаційну чи тестову; та сама вимога поширюється на перехресну перевірку.

Формально кожному зразку x зіставлено групу $g(x)$ – прохід (сценарій). Розбиття на фолди виконують на рівні груп: усі зразки одного проходу потрапляють в один фолд, що гарантує відсутність витоку між навчанням і контролем:

$$\forall x \in g: fold(x) = fold(g) \Rightarrow \mathcal{D}_{train} \cap \mathcal{D}_{test} = \emptyset, \quad (4.7)$$

де $g(x)$ – група зразків одного проходу;

$fold(g)$ – номер фолду групи;

$D_{train} \cap D_{test} = \emptyset$ означає, що навчальна і тестова вибірки не містять спільних зразків.

Ця проблема є однією з найважливіших під час побудови нейромережових моделей для просторових даних. На відміну від класичних задач класифікації незалежних об'єктів, при безперервному скануванні території сусідні зразки тісно корельовані між собою. Якщо платформа рухається зі швидкістю 1–3 м/с, а РІ-канал працює з частотою 238 Гц, то два сусідні вимірювання можуть бути розділені лише кількома міліметрами або сантиметрами. У результаті їхні сигнали практично повторюють один одного.

Проблема посилюється ще й тим, що корелюють не самі сигнали, а й умови їх отримання. Сусідні фрагменти мають однакову висоту польоту, однаковий стан ґрунту, однакові погодні умови, схожий рівень шумів і практично ідентичні параметри сенсорів. Якщо один із таких фрагментів потрапляє до навчальної вибірки, а інший – до тестової, модель фактично перевіряється на даних, які вже бачила раніше.

Відповідно, випадкове розбиття окремих зразків, яке часто використовується в задачах машинного навчання, для аналізу фізичних полів є неприйнятним. Формально така модель може демонструвати дуже високі показники точності, однак після перенесення на нову територію або нову місію її ефективність різко знижується. Причина полягає не в якості архітектури, а в помилковій процедурі оцінювання.

Для усунення цього ефекту розбиття виконується на рівні проходів і сценаріїв. Усі зразки, отримані під час одного проходу, розглядаються як єдина неподільна група. Якщо прохід потрапив до навчальної частини, жоден його фрагмент не може використовуватися під час валідації або тестування. Аналогічне правило застосовується і до окремих польових місій, полігонів та експериментальних сценаріїв.

Особливо важливим це стає під час роботи з мультисенсорними даними. Оскільки всі канали синхронізуються за координатами та часовими мітками, витік інформації через один сенсор автоматично поширюється і на інші канали.

Тому процедура розбиття виконується ще до формування остаточних навчальних зразків і використовує первинні структури даних – проходи, маршрути або місії.

Практично це значить, що під час формування навчальної вибірки система спочатку працює зі списком проходів, а не зі списком окремих записів. Після випадкового перемішування проходів вони розподіляються між навчальною, валідаційною та тестовою частинами у заданих пропорціях. Лише після цього виконується генерація окремих зразків для кожної підвибірки.

Додатково контролюється баланс сценаріїв між частинами вибірки. Наприклад, якщо певний тип ґрунту, або конфігурація об'єктів присутні лише в навчальній частині, тестування не дозволить оцінити здатність моделі працювати в інших умовах. Тому розподіл проходів виконується таким чином, щоб усі основні категорії сценаріїв були представлені в кожній частині набору даних.

Ще суворіші вимоги застосовуються під час перехресної перевірки. В цьому випадку одиницею розбиття також виступає не окремий зразок, а цілий прохід чи місія. кожна ітерація перевірки моделює реальну ситуацію, коли система працює на нових даних, отриманих в інших умовах.

Важливо відзначити, що саме така процедура оцінювання найбільшою мірою відповідає майбутній експлуатації системи. В реальній місії нейромережа завжди буде працювати з новою територією, новими умовами спостереження та новими наборами вимірювань. Тому тестова вибірка повинна максимально наближатися до цього сценарію.

Логіку формування зразків з польових CSV-файлів і розбиття за проходами ілюструє наведений нижче фрагмент (Лістинг 4.1):

Лістинг 4.1 – завантаження даних та фрагмент проходу CSV-файлів

```
import numpy as np, glob
def load_pass(path):
    a = np.loadtxt(path, delimiter=',') # CH2, CH3, CH4
    base = a[-100:, :].mean(axis=0) # базова лінія по хвосту
    u = a - base # компенсація фону
    d23, d34 = u[:,0]-u[:,1], u[:,1]-u[:,2] # різницеві канали
    return np.column_stack([u, d23, d34]) # вектор 5 каналів
```

```
def split_by_pass(files, seed=42):
    rng = np.random.default_rng(seed) # розбиття на рівні
    files = sorted(files); rng.shuffle(files) # проходів, не зразків
    n = len(files)
    return files[:int(.7*n)], files[int(.7*n):int(.85*n)], files[int(.85*n):]
```

4.2.7 Стратегія поєднання джерел

Поєднання двох джерел дало принциповий практичний результат: навчати мережу безпосередньо на польових даних виявилось менш ефективно, ніж на лабораторних [60]. Причина – невизначеність просторової прив'язки польових записів: пориви вітру, інерційність носія, стрибки показань висотоміра, ґрунтові ефекти і температурні дрейфи погіршують якість розмітки, і мережа частково навчається на хибних відповідностях «сигнал – позиція». Звідси стратегія. Модель спочатку навчається на «чистих» лабораторних сигнатурах, де справжнє положення відоме з міліметровою точністю, і лише потім адаптується до реальних умов донавчанням на обмеженій польовій підвибірці з підтвердженою розміткою [60].

Лабораторне і польове джерела виконують різні функції. Лабораторні дані забезпечують високу якість розмітки, стабільність умов експерименту та можливість систематичного перебору конфігурацій об'єктів. Польові дані, навпаки, містять усі фактори, з якими система зустрічається під час реальної експлуатації: неоднорідність ґрунту, зміни вологості, зовнішні електромагнітні завади, похибки навігації та варіації умов вимірювання. Використання лише одного з цих джерел неминуче призводить до втрати частини інформації.

Практика показала, що найкращі результати дає послідовне використання обох наборів даних. На першому етапі нейромережа формує базові уявлення про структуру сигналів, працюючи з лабораторними прикладами. В цей момент модель навчається розпізнавати фізичні закономірності, пов'язані з формою РІ-відгуків, магнітних аномалій або просторових ознак. Після завершення цього етапу виконується донавчання на польових вимірюваннях, яке адаптує вже сформовані ознаки до реальних умов експлуатації.

Важливо, що польові дані використовуються не як заміна лабораторних, а як засіб корекції моделі. Такий підхід дає змогу зберегти переваги високоякісної лабораторної розмітки і водночас врахувати особливості реального середовища. У результаті, мережа отримує можливість працювати зі складними польовими сценаріями без втрати базових фізичних закономірностей, засвоєних під час первинного навчання.

Кількісна перевірка п'ятого розділу виконується на тих конфігураціях відкритого набору, де еталонна розмітка достовірна, за протоколами вилучення серій; пряме відтворення повного дворівневого протоколу «лабораторне ядро – польове донавчання» включено до програми наступних кампаній, для якої потрібне оприлюднення лабораторних серій еталонів. Ця стратегія є першим компонентом загальної програми подолання доменного зсуву, якій присвячено підрозділ 4.4.

4.2.8 Підготовка серій вимірювань та вилучення артефактних кадрів

Реальні серії вимірювань містять окремі розгортки, які не відповідають штатному режиму зондування, тому перед подальшим аналізом виконується очищення набору даних. У вихідному датасеті кожен файл подано у вигляді масиву розміром 1001×4 , де перший стовпець відповідає часовій осі, а наступні стовпці містять сигнали вимірювальних каналів CH2–CH4. Тому в межах підготовки даних аналізуються не просторові кадри по координаті X, а окремі часові розгортки сигналу, отримані під час проходження вимірювальної системи над досліджуваною ділянкою.

Аналіз відкритого набору показав наявність кількох типів артефактних розгорток. Частина з них пов'язана з початком запису, коли в сигналі ще присутній перехідний процес запуску реєстрації. Окремі розгортки наприкінці деяких серій можуть відповідати завершенню запису та не відображати сталий режим роботи приймального тракту. Найбільш помітними є розгортки з аномально високою енергією сигналу, які виникають у моменти, коли вікно реєстрації накриває залишковий сплеск зондувального імпульсу або ділянку

мертвої зони приймального тракту. Такі сигнали суттєво відрізняються від робочих вимірювань: їх амплітуда та інтегральна енергія можуть перевищувати типові значення серії на один або кілька порядків, тому їх залишення у вибірці призводить до спотворення статистики, масштабування ознак і результатів подальшої класифікації.

Вилучення таких розгортки доцільно виконувати автоматично за енергетичним критерієм. Для кожної розгортки обчислюється сумарна енергія по робочих каналах CH2–CH4, після чого отримане значення порівнюється з медіанною енергією відповідної серії. Якщо енергія розгортки перевищує медіану серії у вісім разів, така розгортка позначається як артефактна і не використовується в подальшому аналізі. Використання саме медіанного рівня є зручним для такого набору, оскільки медіана менш чутлива до поодиноких потужних сплесків, ніж середнє значення. Це уможлиблює адаптувати поріг до кожної окремої серії та не задавати фіксований список номерів файлів, який не буде універсальним для інших проходів.

Просторова прив'язка розгортки у цьому випадку не є явно заданою в структурі файлів. Якщо потрібно оцінити орієнтовний просторовий крок між сусідніми розгортками, його можна визначати лише розрахунково через швидкість переміщення системи та частоту реєстрації. За частоти 238 Гц крок між послідовними розгортками становить приблизно 4,2 мм при швидкості 1 м/с, 6,7 мм при швидкості 1,6 м/с і 12,6 мм при швидкості 3 м/с. Тому значення близько 6,8 мм не слід подавати як безпосередньо виміряний параметр датасету; воно може використовуватися лише як оцінка для конкретного режиму руху зі швидкістю приблизно 1,6 м/с.

Після очищення формується підготовлений набір робочих розгортки, у якому вилучені сигнали запуску, завершення реєстрації та розгортки з надмірною енергією. Такий підхід зберігає основну частину корисної інформації серій і водночас зменшує вплив технічних артефактів на подальшу обробку. У підготовленому вигляді кожен приклад залишається триканальною часовою розгорткою CH2–CH4 довжиною близько тисячі відліків, що дозволяє

застосовувати до нього однакову процедуру нормалізації, виділення ознак і подальшого розпізнавання.

4.3 Аугментація та синтетичні дані

4.3.1 Принцип фізичної обґрунтованості

Обмежений обсяг реальних вимірювань – головний дефіцит предметної області, тому окремий блок роботи присвячено розширенню вибірки. До всіх перетворень висувається вимога фізичної обґрунтованості. Аугментація має породжувати сигнали, які могли б виникнути в реальному вимірюванні за іншої, але фізично можливої конфігурації, а не довільні спотворення. Перетворення, що порушує фізику сигналу – наприклад, інвертування знаку РІ-відгуку чи довільне перемішування каналів, – не розширює, а отруює вибірку. Мережа витрачає ємність на запам'ятовування неможливих образів. Кожна аугментація, отже, має відповідати конкретному фізичному чиннику варіативності.

З практичної точки зору фізично обґрунтована аугментація є продовженням вимірювального процесу у цифровому просторі. Якщо реальна система може зіткнутися зі зміною висоти польоту, коливанням швидкості руху, зміною вологості ґрунту, незначними похибками позиціонування або різним рівнем шуму електроніки, то саме ці фактори повинні відображатися під час розширення вибірки. нейромережа отримує додаткові приклади, які моделюють реальні сценарії експлуатації, а не штучно створені математичні трансформації.

Особливе значення цей принцип має для аналізу фізичних полів. На відміну від задач комп'ютерного зору, де допустимими є повороти, дзеркальні відображення або масштабування зображень, у сигналах фізичних сенсорів далеко не кожне перетворення має фізичний зміст. Наприклад, зміна амплітуди РІ-сигналу може відповідати зміні висоти розташування сенсора або розмірів об'єкта. Додавання шуму може моделювати роботу системи в умовах підвищених електромагнітних завад. Натомість випадкове переставлення часових відліків руйнує причинно-наслідкову структуру процесу затухання вихрових струмів і створює сигнали, які в реальному середовищі не виникають.

Аналогічна ситуація спостерігається для магнітометричних даних. Реальні магнітні аномалії можуть змінюватися за амплітудою через різну висоту польоту або зміну відстані до об'єкта. Можливі також локальні спотворення, спричинені шумами навігаційної системи чи неточністю геоприв'язки. Водночас довільне порушення просторової структури магнітного поля призводить до появи аномалій, які суперечать дипольній природі джерела і тому не можуть використовуватися як коректні навчальні приклади.

Для мультиспектральних зображень принцип фізичної обґрунтованості також залишається визначальним. Допустимими є зміни яскравості, контрасту, кольорового балансу, моделювання різного рівня освітленості або атмосферних умов. Такі перетворення відображають реальні варіації, які виникають під час польотів у різний час доби, або за різних погодних умов. Натомість надмірні геометричні трансформації можуть спотворити просторову структуру поверхні та змінити реальний вигляд об'єктів.

Ще одним важливим аспектом є узгодженість між каналами. У мультисенсорній системі всі дані описують одну й ту саму фізичну ділянку місцевості. Тому аугментація окремого каналу не повинна порушувати зв'язок між ним та іншими джерелами інформації. Якщо змінюється положення об'єкта на магнітометричній карті, аналогічна зміна повинна бути відображена і в інших пов'язаних поданнях даних. Інакше мережа отримуватиме суперечливі приклади, які не відповідають реальним умовам спостереження.

Кожне перетворення у процесі аугментації повинно мати відповідь на просте запитання: який фізичний процес або фактор експлуатації воно моделює. Якщо така відповідь відсутня, використання відповідного перетворення є сумнівним незалежно від того, наскільки воно покращує статистичні показники на навчальній вибірці. Ця вимога і відрізняє фізично орієнтований підхід до розширення вибірок від універсальних методів аугментації, що широко застосовуються в інших галузях машинного навчання.

4.3.2 Аугментації РІ-каналу

Для РІ-даних набір аугментацій відповідає чотирьом чинникам реальної варіативності.

Перший – висота датчика. Амплітуда відгуку масштабується за законом спадання $\sim \frac{1}{r^6}$, тож зміна висоти з r до r' моделюється множенням сигнальної складової на $\left(\frac{r}{r'}\right)^6$; це уможливорює з вимірювань на одній висоті породжувати правдоподібні зразки для діапазону висот, фактично присутніх у польоті через динаміку носія.

Другий – шуми тракту. До сигналу додається гаусівський шум з дисперсією, оціненою за калібрувальними записами, та імпульсний шум з малою ймовірністю появи, що моделює комутаційні наведення.

Третій – ґрунтовий відгук. Фонова складова варіюється у межах, що відповідають різній мінералізації, чим модель привчається не спиратися на конкретний фон навчального полігону.

Четвертий – просторова конфігурація: зсуви, повороти і дзеркальні відображення зразків відтворюють довільність взаємної орієнтації траєкторії і об'єкта; для енергетичних карт ці перетворення застосовуються безпосередньо, для часових розгорток – через перестановки, узгоджені з геометрією катушок (дзеркальне відображення поперечної осі відповідає обміну крайніх каналів і зміні знаку різницевих).

Логіку цих перетворень, переробленої під фізику РІ-каналу, ілюструє наведений нижче фрагмент (Лістинг 4.2):

Лістинг 4.2 – Аугментація сигналу імпульсно-індукційного датчика

```
def augment_pi(sample, rng, r0=0.10):
    s = sample.copy() # 5 каналів x T відліків

    r = rng.uniform(0.08, 0.20) # нова висота, м
    s *= (r0 / r) ** 6 # закон спадання ~1/r^6

    s += rng.normal(0, sigma_cal, s.shape) # гаусів шум тракту

    mask = rng.random(s.shape) < 1e-4 # імпульсні наведення
    s[mask] += rng.choice([-1, 1]) * 5 * sigma_cal

    if rng.random() < 0.5: # дзеркало поперечної осі
```

```
s = s[[2, 1, 0, 4, 3], :] # обмін крайніх котушок
s[3:, :] *= -1 # зміна знаку різницевих

return s
```

4.3.3 Аугментації оптичного каналу

Для оптичних даних застосовуються перетворення, що моделюють умови знімання: зміни яскравості і контрасту (рівень освітлення), корекція колірного балансу (висота сонця, хмарність), невеликі геометричні деформації (рельєф і нахили платформи). Окреме правило стосується індексних каналів: *NDVI* і *VARI* перераховуються з аугментованих спектральних каналів, а не аугментуються незалежно – інакше порушується їхній детермінований зв'язок зі спектральними значеннями, і мережа отримує внутрішньо суперечливі зразки. Це частковий вияв загального принципу. Аугментація застосовується до первинних величин, а похідні ознаки перераховуються.

4.3.4 Кількісний ефект керованого розширення

Ефект керованого розширення вибірки підтверджено кількісно у власній роботі, присвяченій навчанню нейронних мереж на формованих наборах зображень із заданим рівнем різноманіття: доповнення навчальної вибірки синтетичними зразками на 25 % дало приріст *F1*-міри на 0,020 відносно базового рівня, отриманого без розширення (абсолютне значення *F1* для *PI*-каналу визначається на польових даних у п'ятому розділі). Істотний методичний висновок цієї роботи – важлива не сама кількість доданих зразків, а керованість їхнього різноманіття. Розширення має закривати конкретні прогалини розподілу, а не дублювати вже покриті конфігурації.

Незалежним підтвердженням коректності синтетичного підходу в суміжній модальності слугує набір HoloMine [64]: 41 800 синтетичних голографічних зображень сформовано злиттям окремо відсканованих об'єктів і ділянок ґрунту за правилом $H = \alpha \cdot H_{in} + (1 - \alpha) \cdot H_{out}$, причому коефіцієнт $\alpha = 0,14$ визначено двома незалежними шляхами – з фізичних міркувань (співвідношення діелектричних проникностей повітря і ґрунту) та емпірично – з

практично однаковим результатом. Збіг фізичної та емпіричної оцінок – сильний аргумент на користь того, що фізично параметризована синтетика відтворює реальні дані, а не тільки їхню зовнішню подоби.

4.3.5 Цифровий двійник вимірювального тракту

Наступний щабель за аугментацією – повністю синтетичні зразки, які для РІ-каналу породжує цифровий двійник вимірювального тракту, побудований на фізичних моделях підрозділу 3.5 [72]. На відміну від звичайної аугментації, де змінюється вже наявний реальний сигнал, цифровий двійник формує новий зразок від початку: задається умовний об'єкт, його положення, висота сенсора, шумові параметри, після чого генерується повний багатоканальний відгук у тому ж форматі, в якому зберігаються реальні вимірювання.

Генерація виконується послідовно. Спочатку відгук об'єкта задається багатоекспоненціальною моделлю

$$u(t) = \sum_i A_i \cdot \exp\left(-\frac{t}{\tau_i}\right), \quad (4.8)$$

з параметрами, що відповідають провідності, магнітній проникності та геометрії цілі. Для масивного провідного об'єкта використовуються повільніші компоненти затухання, для компактного – швидші. Саме набір сталих часу τ_i і амплітуд A_i визначає форму РІ-сигналу, тобто ту частину інформації, яку надалі аналізує одновимірна згорткова мережа.

Далі працює геометричний блок. Він масштабує амплітуди сигналів для кожної з трьох приймальних котушок залежно від висоти сенсора, поперечного зміщення об'єкта та відстані до відповідної котушки. Це важливо, оскільки реальна трикотушкова система формує не три однакові сигнали, а набір взаємопов'язаних каналів. Якщо об'єкт зміщений ближче до однієї котушки, амплітуда в цьому каналі зростає, тоді як у сусідніх каналах вона зменшується. І такі міжканальні співвідношення потім використовуються для формування різницевих каналів $\Delta 23$ та $\Delta 34$.

Після формування ідеального відгуку додається модельований фон. У реальному вимірюванні сигнал ніколи не складається лише з відгуку об'єкта. На

нього накладаються повільні зміни базової лінії, електронний шум, випадкові імпульсні завади, температурний дрейф і слабкі ґрунтові ефекти. Тому цифровий двійник повинен генерувати не «чистий» сигнал, а сигнал, схожий на результат роботи реального вимірювального тракту. Для цього використовуються статистики шуму, отримані під час калібрувальних записів: середній рівень, дисперсія, характер повільного дрейфу, частка викидів.

Нарешті, сформовані три котушкові канали проходять той самий конвеєр, що й реальні дані: компенсацію базової лінії, нормування та побудову різницевих каналів. У результаті синтетичний зразок має той самий формат, що й реальний п'ятикомпонентний РІ-вектор. Це принципово важливо: нейромережа не повинна бачити різницю між способом підготовки реальних і синтетичних даних. Відрізнитися може тільки джерело сигналу, але не структура запису.

Для магнітометричного каналу цифровий двійник будується аналогічно, але замість багатоекспоненціального часовго відгуку використовується просторова модель магнітної аномалії. Компактне джерело на відстанях, більших за його власні розміри, задається як магнітний диполь із певним моментом, глибиною та орієнтацією. На основі цих параметрів формується синтетична карта поля, після чого до неї додаються фонові варіації, просторовий шум і похибки геоприв'язки. Такий варіант дає змогу отримувати магнітометричні карти для різних глибин залягання, різних орієнтацій джерела та різних рівнів завад.

Просторову модель магнітного відгуку задають полем магнітного диполя з моментом m на віддалі r від датчика:

$$\Delta \mathbf{B}(\mathbf{r}) = \frac{\mu_0}{4\pi} \frac{3(\mathbf{m} \cdot \hat{\mathbf{r}}) \hat{\mathbf{r}} - \mathbf{m}}{|\mathbf{r}|^3}. \quad (4.9)$$

Цінність двійника полягає в цілеспрямованому закритті прогалин реальної вибірки. В реальних умовах складно, або небезпечно багаторазово відтворювати окремі конфігурації: великі глибини, рідкісні типи об'єктів, екстремальні рівні завад, проміжні висоти або нестандартні поперечні зміщення. Цифровий двійник дає змогу створювати саме такі приклади контролювано, змінюючи один параметр і фіксує решту. Завдяки цьому можна дослідити, як саме змінюється

сигнал при збільшенні глибини, при зміщенні об'єкта відносно осі сенсора або при зростанні шуму.

Нижче наведено код, який ілюструє принцип генерації синтетичного РІ-сигналу для трьох котушкових каналів. Він показує логіку цифрового двійника: експоненціальний відгук, геометричне масштабування, додавання шуму та формування різницевих каналів (Лістинг 4.3):

Лістинг 4.3 – Генерація синтетичного сигналу імпульсного індукційного датчика

```
import numpy as np

def generate_pi_sample(
    n=1000,
    taus=(40, 180, 650),
    amps=(1.0, 0.55, 0.22),
    lateral_offset=0.0,
    height=0.25,
    coil_positions=(-0.18, 0.0, 0.18),
    noise_std=0.015,
    drift_level=0.01,
    seed=None
):
    rng = np.random.default_rng(seed)
    t = np.arange(n)

    base_response = np.zeros(n)
    for A, tau in zip(amps, taus):
        base_response += A * np.exp(-t / tau)

    channels = []
    for coil_x in coil_positions:
        distance = np.sqrt((lateral_offset - coil_x) ** 2 + height ** 2)
        geom_gain = 1.0 / (distance ** 3 + 1e-6)

        signal = geom_gain * base_response
        signal = signal / (np.max(np.abs(signal)) + 1e-8)

        drift = drift_level * np.linspace(0, 1, n)
        noise = rng.normal(0, noise_std, n)

        channels.append(signal + drift + noise)

    ch2, ch3, ch4 = channels

    baseline = np.mean(np.vstack(channels)[: , -100:], axis=1)

    ch2 = ch2 - baseline[0]
    ch3 = ch3 - baseline[1]
    ch4 = ch4 - baseline[2]

    d23 = ch2 - ch3
    d34 = ch3 - ch4

    return np.column_stack([ch2, ch3, ch4, d23, d34])
```

Такий генератор дає змогу варіювати фізично зрозумілі параметри: сталі часу затухання, амплітуди мод, висоту сенсора, поперечне зміщення об'єкта, рознос котушок, рівень шуму та дрейф базової лінії. При цьому структура вихідного зразка відповідає реальному входу нейромережевої РІ-гілки.

Двійник також корисний для попереднього навчання. Мережа може спочатку навчатися на великій кількості синтетичних прикладів, де представлені різні фізично допустимі конфігурації, а потім донавчатися на реальних лабораторних і польових даних. У такому сценарії навчання починається не з випадкової ініціалізації, а з уже сформованих ознак, пов'язаних із реальною фізикою сигналів. Це зменшує потребу у великій кількості розмічених польових вимірювань і підвищує стійкість моделі до рідкісних сценаріїв.

Водночас, синтетичні зразки не можуть повністю замінити реальні дані. Їхнє завдання – не створити ідеальну копію польового середовища, а розширити простір фізично допустимих прикладів. Тому цифровий двійник використовується як допоміжний інструмент: для попереднього навчання, перевірки чутливості моделей, дослідження впливу окремих параметрів і заповнення прогалин у вибірці. Остаточна перевірка якості завжди має виконуватися на реальних даних, оскільки тільки вони містять повний комплекс неврахованих факторів вимірювального процесу.

4.3.6 Контроль достовірності синтетичних даних

Синтетика корисна рівно настільки, наскільки вона достовірна, тому двійник супроводжується процедурою контролю на перетині з реальними даними. Для конфігурацій, наявних і в реальній вибірці (еталонні об'єкти на виміряних висотах і зміщеннях), синтетичні сигнали мають відтворювати фактичні форми кривих, енергетичні співвідношення між каналами і статистики шуму; розбіжності оцінюються залишками апроксимації і порівнянням розподілів ознак.

Другий, операційний критерій – поведінка моделей. Мережа, навчена на синтетиці, має на реальних перевірних даних показувати якість, порівнянну з

мережею, навченою на реальних зразках тієї самої конфігурації. Систематичні розбіжності за будь-яким критерієм – сигнал для уточнення параметрів двійника, а не для відкидання підходу. Саме ітеративне звіряння «модель – вимірювання» і робить двійник інструментом, а не припущенням.

Кількісним критерієм достовірності слугує розбіжність розподілів синтетичних P_s і реальних P_r даних у просторі ознак (максимальна середня розбіжність MMD):

$$MMD^2(P_s, P_r) = \| \mathbb{E}_{x \sim P_s}[\varphi(x)] - \mathbb{E}_{x \sim P_r}[\varphi(x)] \|_{\mathcal{H}}^2. \quad (4.10)$$

Мала MMD свідчить, що синтетичні зразки статистично сумісні з реальними і не зміщують навчальний розподіл.

4.4 Доменний зсув і стратегія «лабораторне навчання – польове донавчання»

4.4.1 Формалізація проблеми

Доменний зсув – систематична розбіжність між розподілом даних, на яких модель навчалася, і розподілом, на якому вона застосовується. У формальних термінах навчальна вибірка походить з розподілу $P_s(x, y)$, експлуатаційні дані – з $P_t(x, y)$, і $P_s \neq P_t$. У задачі домінує коваріатний тип зсуву. Умовний зв'язок «сигнал $\rightarrow$ клас» $P(y|x)$ визначається фізикою об'єктів і лишається стабільним, тоді як розподіл самих сигналів $P(x)$ змінюється з умовами – ґрунтом, сезоном, висотою, станом апаратури. Ця структура зсуву і визначає стратегію: фізично змістовні ознаки, засвоєні в одних умовах, переносні, але їхні масштаби і фонові статистики потребують адаптації. Модель, бездоганна на даних, подібних до навчальних, деградує тим сильніше, чим далі експлуатаційний розподіл від навчального, і саме ступінь цієї деградації, а не лабораторні показники, визначає реальну придатність системи.

4.4.2 Джерела зсуву в розглядуваній системі

Ідентифіковано три основні джерела зсуву.

Перше з них – розрив між лабораторними і польовими умовами. Власні вимірювання показали помітно вищу варіативність польових сигналів за рахунок невизначеності прив'язки і ґрунтових ефектів [60]; ця різниця безпосередньо видима у польових В-сканах відкритого набору (підрозділ 2.9).

Другим є тип ґрунту. У [36] показано, що ґрунтові умови є одним із визначальних чинників якості виявлення для індукційних і георадарних каналів.

Третє джерело, сезонні й добові варіації, кількісно оцінене у [65]: навчання на мультитемпоральних даних, зібраних у різні пори року та за різного освітлення, підвищило якість виявлення на 1,8–9,6 процентних пунктів порівняно з навчанням на даних одного сезону – пряма кількісна міра ціни сезонного зсуву.

4.4.3 Фізичні механізми зсуву за каналами

За фізичними механізмами джерела зсуву розкладаються по каналах так. Для імпульсної індукції визначальними є мінералізація і провідність ґрунту, які змінюють фонову складову відгуку, та металеве сміття – уламки, дріт, гільзи, – що створює відгуки, подібні до цільових; тому складні негативні приклади включено до вибірки (пункт 4.2.5). Для магнітометрії аналогічну роль відіграють техногенні джерела поля і геологічні неоднорідності. Для оптичного каналу головні чинники – освітлення, вологість поверхні та стан рослинності, які змінюють і яскравісні характеристики, і вегетаційні індекси. Спільними для всіх каналів є геометричні чинники – варіації висоти і швидкості носія, що через закон спадання відгуку масштабують амплітуди, – та повільні дрейфи самих сенсорів: температурний дрейф електроніки і поступова зміна калібрувань, через які навіть за незмінного середовища структура сигналу зміщується з часом.

4.4.4 Стратегія подолання

Для подолання зсуву запропоновано стратегію з чотирьох компонентів. Перший – навчання на лабораторних даних як базовий етап. Лабораторні сигнатури з міліметровою прив'язкою формують «чисте» ядро, на якому мережа засвоює фізично змістовні ознаки [60]. На цьому етапі модель навчається не на випадкових польових варіаціях, а на контрольованих сигналах, де форма відгуку пов'язана саме з параметрами об'єкта. Це сприяє формуванню стабільної основи класифікатора ще до переходу до складніших умов.

Другий компонент – донавчання на обмеженій польовій підвибірці з підтвердженою розміткою. Його призначення полягає не в повному перенавчанні мережі, а в адаптації вже сформованих ознак до реальної статистики фону і завад. Польові дані вводять у модель ті ефекти, яких немає у лабораторному стенді: нестабільність висоти, ґрунтовий фон, похибки координатної прив'язки, температурний дрейф, нерівномірність руху носія. Завдяки цьому мережа не втрачає базові фізичні закономірності, але поступово коригує межі класів під реальні умови застосування.

Третій компонент – фізично обґрунтована аугментація (підрозділ 4.3). Вона розширює діапазон умов ще до польового донавчання. За рахунок контрольованої зміни амплітуди, шуму, положення об'єкта, висоти сенсора та інших фізично допустимих параметрів модель отримує додаткові приклади, які не суперечать природі сигналу. Такий підхід зменшує розрив між лабораторним і польовим доменами та знижує ризик різкого падіння якості під час перенесення моделі.

Четвертий компонент – мультитемпоральне збирання даних: повторні місії над тими самими ділянками у різні сезони і час доби, ефективність якого кількісно підтверджена у [65]. Цей компонент важливий тому, що доменний зсув не обмежується різницею між лабораторією і полем. Навіть одна й та сама ділянка може формувати різні сигнали залежно від вологості ґрунту, стану рослинності, температури поверхні та освітленості. Повторні місії дозволяють

накопичити приклади для різних режимів середовища і зробити вибірку менш прив'язаною до одного конкретного сценарію.

Концепцію стратегії підтверджено окремими складниками: фізична змістовність ознак – лабораторними результатами [59], а реалістичність польової статистики – характеристиками відкритого набору [60]; повне відтворення двоступеневого протоколу потребує оприлюднення лабораторних серій і віднесене до наступного етапу. Додатковим механізмом стійкості слугує фізична регуляризація навчання (підрозділ 3.5): фізичні закономірності, на відміну від статистики конкретної вибірки, не змінюються з типом ґрунту чи погодою. Тому поєднання лабораторного ядра, польового донавчання, фізично обґрунтованої аугментації та мультитемпорального збору даних формує практичну основу для зменшення доменного зсуву.

4.4.5 Протокол донавчання

Донавчання виконується за протоколом, що захищає лабораторне ядро від руйнування малою польовою вибіркою. Головна небезпека полягає в тому, що польових прикладів зазвичай небагато, а їхня розмітка має більшу невизначеність, ніж лабораторна. Якщо оновлювати всі параметри мережі з високим темпом навчання, модель може швидко пристосуватися до шумових особливостей польового набору і втратити ознаки, сформовані на чистих сигнатурах.

Тому згортова основа гілки, яка кодує фізичні ознаки форми сигналу, заморожується чи донавчається з малим темпом; повнозв'язна частина, що відповідає за межі класів, донавчається повноцінно. Така схема дає змогу зберегти фільтри, які реагують на форму РІ-відгуку, і водночас скоригувати класифікаційний рівень під польову статистику. змінюється не саме розуміння сигналу, а правило розділення класів у нових умовах.

Темп навчання знижується на порядок відносно базового етапу, а рання зупинка контролюється за польовою валідаційною підвибіркою, сформованою за правилами просторового розбиття (пункт 4.2.6). Це важливо, бо випадкове

перемішування польових фрагментів знову призвело б до витоку інформації та завищення якості. Валідаційна частина повинна містити окремі проходи або сценарії, які не використовувалися під час донавчання.

Формально донавчання – це оптимізація на польовій вибірці зі стартом із лабораторних ваг, замороженою згортковою основою та зниженим темпом навчання:

$$\theta^* = \underset{\theta}{\operatorname{argmin}} L(\theta; D_{field}), \quad \theta \leftarrow \theta_{lab}, \quad \theta_{conv} = \text{const}, \quad \eta = \frac{\eta_0}{10} \cdot 0.8, \quad (4.10)$$

де θ^* – оптимальні параметри моделі після донавчання;

θ_{lab} – ваги, отримані під час лабораторного навчання;

$\theta_{conv} = \text{const}$ – незмінні параметри згорткової основи;

$\eta = \eta_0/10$ – зменшений у десять разів темп навчання;

$L(\theta; D_{field})$ – функція втрат на польовій вибірці D_{field} .

Обсяг польової підвибірки компенсується аугментацією; контрольним орієнтиром слугує якість на лабораторній тестовій підвибірці – її помітне падіння означає, що донавчання почало стирати засвоєні сигнатури, і темп слід знизити. У практичному протоколі доцільно контролювати одразу два показники: покращення на польовій валідації та збереження якості на лабораторному тесті. Якщо польова якість зростає, але лабораторна різко падає, модель надто сильно підлаштовується під новий домен. Якщо обидва показники стабільні, донавчання можна вважати коректним.

Після завершення донавчання модель не замінюється автоматично. Її потрібно перевірити на відкладених польових сценаріях і порівняти з базовою версією. Лише після цього оновлена модель може бути включена до робочого конвеєра. Такий порядок уможливорює уникнути випадкових погіршень, які можуть виникати через малий обсяг польової підвибірки або локальні особливості конкретної місії.

4.4.6 Моніторинг моделей в експлуатації

Доменний зсув не закінчується введенням системи в експлуатацію – він триває. Сенсори дрейфують, сезон змінюється, з'являються нові ділянки з

іншими ґрунтами. Тому стратегію доповнює моніторинг якості в експлуатації. Без такого контролю модель може поступово втрачати точність, а це не буде помітно одразу, особливо якщо немає постійної еталонної розмітки для нових територій.

Прямий контроль виконується на еталонних ділянках – фрагментах полігону з відомими закладеними об'єктами, які періодично переобстежуються. Падіння показників на еталоні є об'єктивним сигналом деградації. Такий контроль особливо корисний після зміни сезону, оновлення сенсорів, калібрування обладнання або зміни програмної версії нейромережевого конвеєра. Еталонна ділянка фактично виконує роль контрольного вимірювального стенда у польових умовах.

Непрямі індикатори доступні безперервно: зростання частки рішень з низькою впевненістю і відмов від рішення (пункт 3.7.3), систематичне зміщення розподілу ваг модуля уваги (пункт 3.4.3), розбалансування узгодженості каналів. Якщо модель дедалі частіше формує невпевнені прогнози або починає покладатися майже виключно на один канал, це може свідчити про зміну статистики вхідних даних. Такі ознаки не дають остаточного висновку, але вказують на необхідність додаткової перевірки.

Перевищення індикаторами порогових рівнів запускає регламентний цикл: збирання свіжої підвибірki з підтвердженою розміткою – донавчання за протоколом пункту 4.4.5 – перевірка на еталоні – введення оновленої моделі. Такий цикл підтримує працездатність системи без повного перенавчання з нуля. Нові дані не замінюють попередні, а доповнюють їх, щоб модель поступово накопичувала досвід роботи в різних умовах.

Версії моделей і вибірок при цьому документуються, що замикає вимогу відтворюваності: для кожної карти ризику відомо, якою моделлю і за якими даними її побудовано. Це важливо не тільки для наукового аналізу, але і для практичного використання результатів. Якщо згодом виникає потреба перевірити, або повторити обробку певної ділянки, система має зберігати повну

інформацію про версію моделі, склад навчальної вибірки, параметри донавчання та умови місії.

4.5 Порівняльний аналіз з відкритим набором MineInsight

Оцінювання власного набору даних потребує зовнішнього орієнтира. Найближчим відкритим аналогом є MineInsight – мультисенсорний набір даних для робототехніки гуманітарного розмінування, зібраний наземною роботизованою платформою у позашляхових умовах з розміткою тестових об'єктів [56]. Набір розповсюджується за ліцензією CC BY-NC-SA 4.0, що дозволяє його використання у некомерційних дослідженнях з обов'язковою атрибуцією, – умови, сумісні з цією роботою. Порівняння за ключовими критеріями зведено у табл. 4.2.

Таблиця 4.2 – Порівняння власного набору даних з MineInsight [56]

Критерій	Власний набір	MineInsight
Платформа	БПЛА (гексакоптер), повітряне сканування	Наземна роботизована платформа, позашляхові умови
Режим знімання	Швидке покриття смугами, 1–3 м/с, варіації геометрії	Повільне детальне обстеження з малої відстані
Сенсорне ядро	Підповерхневі канали: PI-розгортки трьох катушок, різницеві канали	Канали огляду місцевості наземною платформою
Структура даних	CSV-розгортки ~1000 відліків, B-скани, профілі чутливості	Синхронізовані потоки бортових сенсорів з розміткою
Об'єкти	Еталони N1–N4, складанки U1–U2, гільза, кілок; глибини 0–10 см	Тестові об'єкти розмінування у позашляхових сценаріях
Розмітка	Контрольовані зміщення і висоти; без поздовжньої геодезії	Еталонна практика документування сценаріїв
Ліцензія	Відкритий репозиторій [60]	CC BY-NC-SA 4.0

Порівняння виявляє принципову взаємодоповнюваність, а не конкуренцію наборів. За платформою MineInsight репрезентує наземний сегмент, власний

набір – повітряний з характерними для БПЛА варіаціями геометрії знімання. За сенсорним складом ядро власного набору підповерхневі РІ-розгортки, яких відкриті аналоги практично не містять; саме ця прогалина і мотивувала оприлюднення власних даних (підрозділ 2.17). За структурою розмітки MineInsight надає еталонну практику документування сценаріїв, яку доцільно наслідувати під час стандартизації метаданих власного набору.

З цього випливають два практичні висновки. Перший полягає в тому, що пряме перенесення моделей між наборами неможливе – відрізняються і фізичні канали, і геометрія знімання, тож MineInsight не може слугувати навчальною базою для РІ-гілки системи. Другий полягає в тому, що набори природно поєднуються у перспективних гетерогенних сценаріях «повітряна розвідка – наземне підтвердження», де БПЛА-платформа виконує швидке покриття і формує карту ризику, а наземна платформа класу MineInsight детальну верифікацію позначених аномалій.

4.6 Формат даних та інтеграція з геоінформаційними системами

4.6.1 Формати зберігання і структура запису

Відтворюваність і практична застосовність вибірок забезпечуються фіксованими форматами зберігання. Для РІ-даних використовуються HDF5 та CSV зі структурою, аналогічною відкритим наборам індукційних вимірювань [36]; для оптичних даних – GeoTIFF із вбудованою геоприв'язкою; для метаданих – JSON; для розмітки – формати COCO або YOLO. Комбінація відкритих форматів робить набір придатним для незалежного використання без спеціалізованого програмного забезпечення. Одиницею зберігання є запис вимірювання – мінімальна самодостатня порція даних, структуру якої наведено у Табл. 4.3: вона гарантує, що кожне значення супроводжується всім контекстом, потрібним для його незалежної інтерпретації.

Таблиця 4.3 – Структура запису вимірювання

Поле	Зміст	Призначення
Ідентифікатори	Місія, проліт, сенсор, номер запису	Простежуваність, розбиття за проходами
Часова мітка	Єдина бортова часова база	Синхронізація каналів (підрозділ 2.4)
Координати	RTK-позиція з оцінкою якості розв'язку	Геоприв'язка, інтерполяція (підрозділ 2.5)
Дані сенсора	Розгортка / відліки / кадр	Власне вимірювання
Параметри знімання	Висота, швидкість, температура	Нормування, аналіз доменного зсуву
Метадані місії	Погода, стан ґрунту, калібрування	Формування підвибірок за умовами

Передавання даних з борту реалізовано трьома незалежними каналами [5]: широкосмуговим для мультиспектральних зображень, вузькосмуговим телеметричним для компактних РІ- і магнітометричних даних та локальним записом на знімний носій як резервним контуром, що гарантує збереження повних сирих даних незалежно від якості радіоканалів (підрозділ 2.14.2). Після місії дані обробляються у програмному забезпеченні наземної станції, інтегрованому із системою планування місій [5, 61].

4.6.2 Геоінформаційні продукти та атрибутика аномалій

Кінцевим продуктом для споживача є геоінформаційні шари: геоприв'язані растрові карти ризику, векторні шари аномалій та автоматично сформовані звіти [61]. Кожна аномалія описується уніфікованим набором атрибутів, який формується постобробкою карт імовірності (пункт 3.6.4) і робить шари придатними і для візуального аналізу оператором, і для машинного оброблення в зовнішніх системах; склад атрибутів наведено у табл. 4.4.

Таблиця 4.4 – Атрибутивний опис аномалії у геоінформаційному шарі

Атрибут	Зміст	Призначення
Центр аномалії	Координати ($\hat{X}$, $\hat{Y}$) за результатами локалізації	Позначення об'єкта на карті, цілевказання
Межі області	Контур або обмежувальна рамка	Визначення розміру небезпечної зони
Інтенсивність	Рівень відхилення від фону за каналами	Оцінювання сили прояву аномалії
Площа	Кількість комірок сітки 10×10 см	Відсіювання дрібних шумових спрацювань
Канали підтвердження	Перелік сенсорів, що зафіксували відхилення	Рівень довіри до рішення
Ймовірність $P(H1)$	Апостеріорна калібрована оцінка нейромережевого злиття	Пріоритезація перевірки
Клас об'єкта	Результат мультикласової ідентифікації або позначка «нерозпізнано»	Планування подальших дій

Атрибутика навмисно відокремлює факти (інтенсивність, площа, канали підтвердження) від інтерпретацій (клас, ймовірність): за повторного оброблення вдосконаленими моделями фактична частина шару лишається незмінною, а інтерпретаційна перераховується. Це уможливорює накопичувати багаторічні архіви обстежень, цінність яких зростає разом з якістю методів аналізу, і прямо підтримує регламент оновлення моделей (пункт 4.4.6).

4.7 Висновки до четвертого розділу

У четвертому розділі розв'язано задачі формування даних для нейромережевого виявлення аномалій – від планування місії до форматів кінцевих продуктів. Основні результати такі.

1. Обґрунтовано багатоетапну організацію місії – оглядова розвідка з виділенням зон інтересу, детальне мультисенсорне сканування лише цих зон, адаптивне доповнення за картою ризику – та виведено геометричні

співвідношення суцільного покриття, що зв'язують ширину смуги чутливості, перекриття, довжину маршруту і час обстеження. За результатами планування місій у зони інтересу охопили 56,3 % площі ділянки, а генетична оптимізація порядку обходу сегментів скоротила час польоту на 27 %.

2. Визначено архітектуру навчальної вибірки: зразок 1×1 м з тензорами РІ-, магнітометричних та оптичних ознак і міткою; поєднання лабораторного стенда з міліметровою прив'язкою та польових льотних вимірювань; понад 20 000 записів оприлюднено у відкритому репозиторії зі структурованим функціональним складом – калібрувальні записи, профілі чутливості еталона на низці поперечних зміщень, серії з реальними об'єктами та тестова підвибірка з невідомим об'єктом – що забезпечує відтворюваність і незалежну перевірку [59, 60].

3. Сформульовано процедури підготовки зразків – компенсацію фону, масштабне нормування зі статистиками лише за навчальною частиною і збереженням міжканальних співвідношень – та правила складання вибірки, критичні для коректності оцінок: цілеспрямоване включення складних негативних прикладів, потрібний механізм балансування класів і розбиття на рівні проходів з огляду на просторову кореляцію сусідніх вимірювань.

4. Розроблено систему фізично обґрунтованої аугментації за чотирма чинниками варіативності РІ-каналу та умовами знімання оптичного, а також синтетичне розширення на основі цифрового двійника вимірювального тракту з двоступеневим контролем достовірності – за формами сигналів і за поведінкою моделей. Кількісний ефект керованого розширення підтверджено у власній роботі [3]: доповнення вибірки на 25 % дало приріст $F1$ -міри на 0,020 відносно базового рівня без розширення; фізичну коректність синтетичного підходу незалежно підтверджує збіг фізичної та емпіричної оцінок коефіцієнта злиття у [64].

5. Формалізовано доменний зсув як коваріатний, ідентифіковано три його джерела – лабораторно-польовий розрив [60], тип ґрунту [36], сезонні варіації з ціною 1,8–9,6 процентних пунктів [65] – і розкладено їх за фізичними

механізмами каналів. Розроблено стратегію подолання з чотирьох компонентів і захищений протокол донавчання із замороженням згорткового ядра; повну реалізацію двоступеневого протоколу «лабораторне ядро – польове донавчання» віднесено до програми наступних кампаній, оскільки вона потребує оприлюднення лабораторних серій еталонів. Стратегію доповнено регламентом моніторингу моделей в експлуатації з прямим контролем на еталонних ділянках і непрямыми індикаторами деградації.

6. Виконано порівняльний аналіз з відкритим набором MineInsight [56] за сімома критеріями: встановлено взаємодоповнюваність повітряного і наземного сегментів, унікальність власних підповерхневих РІ-даних серед відкритих наборів та перспективність гетерогенних сценаріїв «повітряна розвідка – наземне підтвердження». Зафіксовано формати зберігання, структуру запису вимірювання та атрибуту геоінформаційних шарів, що відокремлює факти вимірювань від інтерпретацій.

Сформовані вибірки, стратегія подолання доменного зсуву та протокол розбиття за проходами безпосередньо визначають методику експериментальної перевірки: кількісному оцінюванню розроблених методів за окремими сенсорними каналами – насамперед за РІ-каналом на оприлюднених польових даних – присвячено п'ятий розділ.

Основні результати четвертого розділу опубліковано в працях [3, 5, 61].

РОЗДІЛ 5

ПРОГРАМНА РЕАЛІЗАЦІЯ ТА ЕКСПЕРИМЕНТАЛЬНА ПЕРЕВІРКА НЕЙРОМЕРЕЖЕВИХ МЕТОДІВ ВИЯВЛЕННЯ АНОМАЛІЙ ЗА МУЛЬТИСЕНСОРНИМИ ДАНИМИ

5.1 Реалізація нейромережевого аналізу РІ-сигналів імпульсного міношукача

Реалізація нейромережевого аналізу розпочинається з побудови повного ланцюга отримання даних від імпульсного міношукача до програмного модуля обробки. Для експериментальної перевірки методів, розроблених у попередніх розділах, використовується трикотушкова РІ-система, яка формує багатоканальні часові сигнали після кожного циклу збудження та реєстрації відгуку об'єкта. На відміну від класичних одноканальних металошукачів, така конфігурація дозволяє отримувати не лише інформацію про наявність металевих об'єктів, а й оцінювати його положення відносно осі сканування та формувати ознаки для подальшої локалізації.

Схема вимірювання включає передавальну котушку, яка формує короткий імпульс магнітного поля, та три приймальні канали, розташовані вздовж поперечної осі сенсорного модуля. Після вимкнення збуджувального імпульсу система реєструє процес затухання вторинного поля, що виникає внаслідок вихрових струмів у провідному об'єкті. Цей перехідний процес надалі використовується як джерело інформації для нейромережевого аналізу.

Важливо, що під час реалізації програмного комплексу використовуються не окремі значення амплітуд, а повні часові розгортки кожного каналу. Таким чином зберігається інформація про форму сигналу, швидкість затухання, взаємне співвідношення між каналами та локальні особливості окремих ділянок відгуку. Практичні випробування показали, що саме форма сигналу містить найбільшу кількість інформації про фізичні характеристики об'єкта.

Всі вимірювання зберігаються у вигляді цифрових файлів формату CSV. Кожен запис відповідає окремому проходу сенсора над досліджуваною

ділянкою. Структура файлу включає часові відліки трьох приймальних каналів, службову інформацію про номер вимірювання, координати, часову мітку та допоміжні параметри експерименту. Такий формат виявився зручним як для лабораторних досліджень, так і для польових вимірювань, оскільки легко інтегрується з Python-бібліотеками для подальшої обробки.

На етапі формування набору даних кожен файл проходить автоматичну перевірку цілісності. Контролюється кількість відліків, відсутність пропусків, коректність часових міток та відповідність структури запису встановленому формату. Це дає змогу усунути помилки ще до початку побудови навчальної вибірки.

З технічної точки зору один РІ-сигнал являє собою часовий ряд довжиною близько тисячі відліків. Для кожного циклу зондування одночасно формуються три такі сигнали – від каналів СН2, СН3 та СН4. Частота збору даних відповідає параметрам реального вимірювального тракту та гарантує достатню деталізацію форми затухання. Всі подальші операції виконуються над цими первинними сигналами без втрати інформації.

Формально результат одного проходу сенсора над ділянкою подається як сукупність трьох синхронних часових розгортки приймальних каналів СН2–СН4:

$$\mathbf{S} = \{s_c[n]\}, \quad c \in \{2,3,4\}, \quad n = \overline{1,L}, \quad L \approx 1001, \quad (5.1)$$

де $s_c[n]$ – амплітуда c -го каналу на n -му відліку, L – довжина розгортки.

Схема проходження даних від сенсора до нейромережевого аналізу представлена на рис. 5.1.



Рисунок 5.1 – Схема проходження даних від сенсора до нейромережевого аналізу

Схема зберігання універсальна. Вона дає змогу однаково ефективно працювати і з лабораторними, і з польовими записами, тому вся подальша обробка йде за єдиною схемою незалежно від джерела даних.

Далі – повний цикл попередньої обробки. Саме він перетворює набір часових сигналів у форму, придатну для нейромережових алгоритмів. Якість підготовки даних прямо впливає на ефективність класифікації, тому всі операції виконуються автоматизовано й однаково для всіх записів.

Першою йде компенсація фону. Для кожного каналу визначають базову лінію – ділянку сигналу після повного затухання відгуку; її оцінюють за останніми відліками розгортки і віднімають від усіх значень.

Базову лінію кожного каналу оцінюють як середнє за останніми N_b відліками розгортки (зона повного затухання відгуку) і віднімають її з усього сигналу:

$$b_c = \frac{1}{N_b} \sum_{n=L-N_b+1}^L s_c[n], \quad \tilde{s}_c[n] = s_c[n] - b_c. \quad (5.2)$$

де b_c – оцінка базової лінії c -го каналу;

N_b – кількість останніх відліків розгортки, використаних для оцінювання фону;

$s_c[n]$ – початковий сигнал c -го каналу;

$\tilde{s}_c[n]$ – сигнал після компенсації базової лінії;

L – загальна кількість відліків розгортки.

Після компенсації фону сигнали трьох каналів переводяться до спільної шкали. Для цього використовується нормування, яке дає однаковий діапазон значень незалежно від конкретного проходу. При цьому принципово важливо зберегти співвідношення між каналами, бо саме вони несуть інформацію про поперечне положення об'єкта відносно осі сенсора.

Нормування виконують за піковою амплітудою кожного каналу: усі канали зводяться до спільного діапазону $[-1, 1]$, що робить ознаки інваріантними до абсолютного підсилення вимірювального тракту:

$$\hat{s}_c[n] = \frac{\tilde{s}_c[n]}{\max_m |\tilde{s}_c[m]|} \in [-1, 1]. \quad (5.3)$$

Наступним кроком є формування набору ознак, який використовується нейромережевою моделлю. На основі трьох нормованих сигналів автоматично обчислюються два різницеві канали. Перший визначається як різниця між

каналами CH2 та CH3, другий – як різниця між CH3 та CH4. В результаті формується п'ятикомпонентне подання, яке містить як первинну інформацію про форму сигналів, так і просторову інформацію про положення джерела аномалії.

Практичний аналіз показав, що різницеві канали часто містять більше інформації про положення об'єкта, ніж окремі котушкові сигнали. Якщо об'єкт зміщується вліво або вправо відносно центру сенсорної системи, це одразу відображається у співвідношенні амплітуд між сусідніми каналами. Тому різницеві ознаки включаються до складу вхідного вектора на рівних правах із первинними сигналами.

Різницеві канали формують як попарні різниці нормованих сигналів суміжних котушок; вони підкреслюють просторовий градієнт відгуку і чутливі до поперечного зміщення об'єкта відносно осі сенсора:

$$\Delta_{23}[n] = \hat{s}_2[n] - \hat{s}_3[n], \quad \Delta_{34}[n] = \hat{s}_3[n] - \hat{s}_4[n]. \quad (5.4)$$

Підсумкове подання одного відліку – п'ятиканальний вектор ознак, що подається на вхід нейромережевої моделі:

$$\mathbf{x}[n] = (\hat{s}_2[n], \hat{s}_3[n], \hat{s}_4[n], \Delta_{23}[n], \Delta_{34}[n])^T \in \mathbb{R}^5. \quad (5.5)$$

Після формування п'яти каналів виконується перевірка якості даних. Виявляються аномальні значення, випадкові викиди, пошкоджені записи та сигнали з порушеною структурою. Такі вимірювання автоматично вилучаються з подальшого аналізу. Це допомагає уникнути ситуацій, коли окремі помилкові записи впливають на навчання моделі.

Усі підготовлені ознаки зберігаються окремими масивами. Тож попередня обробка виконується лише раз, а далі нейромережеві алгоритми працюють із готовими наборами – це помітно скорочує час експериментів і дає змогу швидко перебирати архітектури моделей.

Загальна схема формування ознак представлена на рис. 5.2.




Рисунок 5.2 – Загальна схема формування ознак

5.1.1 Експериментальна перевірка на відкритому наборі даних

Експериментальну перевірку нейромережевого аналізу РІ-сигналів виконано на відкритому наборі даних трикотушкового імпульсного міношукача (репозиторій проекту [59; 60]). Набір містить 1658 записів формату CSV: лабораторна частина – 1016 файлів (порожній фон calibrovka – 90; еталонні об’єкти N1–N4 – 352; гільза – 107; кілок – 107; об’єкти невідомої конфігурації – 360), польова частина – 642 файли (шість сценаріїв за поперечних зміщень 0–60 см). Кожен запис – часова розгортка трьох приймальних каналів (CH2, CH3, CH4) по 1000 відліків. Лабораторну частину використано для навчання й перехресної перевірки (5-кратна стратифікована крос-валідація), польову – для оцінювання стійкості до доменного зсуву за протоколом «навчання на лабораторних вимірюваннях – перевірка на польових сценаріях».

Дані з цього набору та опис (склад) наведені в таблиці 5.1, а сценарії польових випробувань трикотушкового РІ-металошукача в табл. 5.2.

Таблиця 5.1 – Склад відкритого набору РІ-вимірювань

Група	Опис	Файлів
calibrovka	порожній фон (шумова доріжка без об’єкта)	90
N1–N4 (psf_33...psf_100)	еталонні об’єкти зі зростанням провідної площі	352
Гільза	компактний малометалевий об’єкт	107
Кілок	протяжний феромагнітний об’єкт	107
Невідомі об’єкти	об’єкти невідомої конфігурації (U1, U2)	360
Лабораторна частина	разом	1016
Польова частина	6 сценаріїв × 107 (гільза/кілок, зміщення 0–60 см)	642
Усього		1658

Таблиця 5.2 – Сценарії польових випробувань трикотушкового РІ-металошукача

Об'єкт	Поперечне зміщення, см	Висота сканування, см	Склад даних
Гільза	20	20	~100 проходів × 1001 відлік × (CH2–CH4 + різниці); В-скан
Гільза	60	20	те саме
Металевий кілок розтяжки	20	10	те саме
Металевий кілок розтяжки	60	10	те саме
Кілок збільшеного розміру	0	10	те саме
Кілок збільшеного розміру	40	10	те саме

Енергетичне впорядкування еталонів, закладене в підрозділі 2.8, підтверджується на цьому наборі: середня енергія відгуку монотонно зростає від N1 до N4 (умовно 4685, 4832, 4887 та 4885 одиниць), а об'єкти невідомої конфігурації займають проміжне положення з вищою енергією (близько 7650 одиниць).

Двовимірні енергетичні карти $E(X, Y)$ для еталонних об'єктів N1–N4 (а) та невідомих U1, U2 (б) представлені на рис. 5.3, нормалізовані енергетичні профілі $EX(X)$ для еталонних N1–N4 та невідомих U1, U2 на рис. 5.4.




Рисунок 5.3 – Двовимірні енергетичні карти $E(X, Y)$ для еталонних об'єктів N1–N4 (а) та невідомих U1, U2 (б) [59]




Рисунок 5.4 – Нормалізовані енергетичні профілі $E_X(X)$ для еталонних N1–N4 та невідомих U1, U2 [59]

Багатокласову класифікацію об'єктів за повними часовими розгортками виконано для шести класів (чотири еталони N1–N4, гільза та кілок) з контролем розбиття на рівні вимірювальних серій: крос-валідація проводилася по файлах, тож відліки однієї серії не потрапляли одночасно до навчальної та контрольної вибірок, що виключає завищення оцінки через витік даних. Загальна точність класифікації становила 95,5 %, усереднена за класами $F1$ -міра – 0,952, що підтверджує задекларований рівень 95–100 % на реальних лабораторних даних; найбільший внесок у похибку дають суміжні еталони N2–N3 з найближчими фізичними параметрами, тоді як гільза та кілок розпізнаються майже безпомилково ($F1 \approx 0,985$).

Щоб уникнути оптимістичного зсуву оцінок через просторову автокореляцію сусідніх відліків, розбиття на навчальну та контрольну підвибірки виконано на рівні файлів (file-level): усі відліки одного проходу (одного CSV-запису) повністю належать лише одній підвибірці. Застосовано стратифіковану 5-кратну групову крос-валідацію, де групою слугує вихідний файл вимірювання.

Показники якості обчислено за матрицею невідповідностей. Для кожного класу c визначено точність (*Precision*) і повноту (*Recall*), а також $F1$ -міру як їх гармонічне середнє:

$$Precision_c = \frac{TP_c}{TP_c + FP_c}, \quad Recall_c = \frac{TP_c}{TP_c + FN_c}, \quad (5.6)$$

$$F1_c = \frac{2 Precision_c \cdot Recall_c}{Precision_c + Recall_c}. \quad (5.7)$$

Інтегральними показниками слугують частка правильних рішень (*Accuracy*) та макро-усереднена $F1$ -міра за усіма $C = 6$ класами:

$$Accuracy = \frac{1}{M} \sum_{c=1}^C TP_c, \quad \text{macro-}F1 = \frac{1}{C} \sum_{c=1}^C F1_c, \quad (5.8)$$

де M – загальна кількість класифікованих об'єктів.

Обчислені за формулами (5.6)–(5.8) значення наведено в табл. 5.3.

Таблиця 5.3 – Показники класифікації об'єктів (5-кратна крос-валідація)

Клас	Precision	Recall	F1
N1 (psf_33)	0,957	1,000	0,978
N2 (psf_50)	0,986	0,800	0,883
N3 (psf_80)	0,899	0,976	0,936
N4 (psf_100)	0,917	0,978	0,946
Гільза	0,980	0,990	0,985
Кілок	0,990	0,980	0,985
Точність / macro-F1	0,955	—	0,952

Щоб оцінити стійкість показника до варіації розбиття, для макросередньої $F1$ -міри побудовано довірчий інтервал за результатами п'яти фолдів ($k = 5$):

$$\overline{F1} \pm t_{0,975,k-1} \frac{s}{\sqrt{k}} \quad (5.9)$$

де $\overline{F1}$ – середнє по фолдах;

s – вибіркове середньоквадратичне відхилення;

$$t_{0,975;4} = 2,776.$$

За пофолдовими значеннями macro- $F1 = 0,952$ (розкид 0,91–0,97; $s \approx 0,03$), 95 % довірчий інтервал [0,92; 0,99], що підтверджує статистичну стійкість оцінки.

Задачу виявлення сформульовано як розрізнення «об'єкт – порожній фон». На чистому лабораторному фоні (негативний клас – записи calibrovnka) транзйентні відгуки об'єктів відокремлюються від фону практично безпомилково (площа під ROC-кривою $AUC=1,00$); це значення є лише верхньою межею для ідеалізованих умов чистого фону і не відображає реальної складності задачі.

Операційно показовою є перевірка лабораторно навченого детектора безпосередньо на польових даних із мінералізованим ґрунтом: за прямого перенесення без донавчання ймовірність виявлення становить $Pd=0,965$ (600 польових серій), тобто розрізнення «об'єкт/фон» зберігає високу повноту навіть за доменного зсуву. Робочу точку з рівнем хибних тривог $P_{fa} \leq 0,05$ на лабораторних даних досягнуто без втрати повноти; у польових умовах рівень

хибних тривог очікувано вищий і потребує окремого оцінювання на репрезентативному фоновому наборі.

Якість виявлення «об'єкт – фон» характеризують імовірністю правильного виявлення P_d та імовірністю хибної тривоги P_{fa} :

$$P_d = \frac{TP}{TP+FN}, \quad P_{fa} = \frac{FP}{FP+TN} \quad (5.10)$$

Здатність до поперечної локалізації перевірено на польових сценаріях із відомим зміщенням об'єкта (0–60 см): розрізнення позицій за міжканальним розподілом енергії досягає 94,5–99,5 %. Неперервну середньоквадратичну похибку локалізації r_{RMSE} у сантиметрах оцінено на стендових вимірюваннях із щільною координатною прив'язкою (одиниці сантиметрів).

Точність неперервної локалізації характеризують середньоквадратичною похибкою координати r_{RMSE} :

$$r_{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N \|\hat{\mathbf{p}}_i - \mathbf{p}_i\|^2} \quad (5.11)$$

де $\hat{p}_i, p_i$ – оцінена та істинна позиції об'єкта;

N – кількість тестових сценаріїв;

на стендових вимірюваннях r_{RMSE} становить одиниці сантиметрів.

Окремо оцінено стійкість лабораторно навчених моделей до доменного зсуву. За прямого перенесення на польові дані без донавчання точність тонкого розпізнавання типу об'єкта знижується до 41,3 %. Показово, що саме розрізнення «об'єкт/фон» при цьому лишається робастним ($P_d=0,965$): переноситься здатність виявити об'єкт, тоді як визначення його типу потребує польового донавчання, розглянутого в четвертому розділі. Це кількісно ілюструє проблему доменного зсуву між лабораторними та польовими умовами.

Кількісною мірою доменного зсуву слугує розрив узагальнення – різниця точності тонкого розпізнавання типу об'єкта на польовій і лабораторній підвибірках за прямого перенесення моделі без донавчання:

$$\Delta_{dom} = Acc_{lab}^{type} - Acc_{field}^{type}. \quad (5.12)$$

5.2 Реалізація аналізу магнітометричних даних

Магнітометричний канал у дисертації реалізований на рівні програмного конвеєра. Натурні польові вимірювання за ним не виконувалися: у лабораторних умовах проведено лише контроль формату даних, а накопичення репрезентативної вибірки винесено на подальші дослідження. Тому далі розглядається програмна реалізація конвеєра обробки та її перевірка на демонстраційних синтетичних даних, що підтверджує працездатність алгоритмічного ланцюга, але не замінює натурального експерименту.

Після реалізації алгоритмів аналізу РІ-сигналів наступним етапом практичної перевірки є магнітометричний канал. На відміну від імпульсного міношукача, який працює з активним збудженням об'єкта, магнітометрична система виконує пасивний контроль просторового розподілу магнітного поля та реєструє його локальні збурення. В рамках реалізованої системи магнітометричний канал використовується як незалежне джерело інформації про наявність феромагнітних об'єктів та додатковий механізм підтвердження аномалій, виявлених іншими сенсорами.

Структура системи включає трикомпонентний магнітометр, блок збору даних, модуль геоприв'язки та програмний комплекс обробки. Під час вимірювань реєструються значення компонент магнітної індукції V_x , V_y та V_z , а також просторові координати точки вимірювання. Кожен запис містить набір магнітних відліків, часову мітку та координатну інформацію, що дає змогу надалі формувати просторові карти магнітного поля.

У лабораторних умовах перевірено лише формат даних – структуру записів і коректність геоприв'язки; репрезентативної вибірки сигнатур не накопичено. Передбачена робота в полі з просторовими профілями, які отримують під час переміщення платформи над територією; у цьому випадку до корисного сигналу додаються природні геомагнітні варіації, вплив металевих конструкцій, транспортної інфраструктури та неоднорідностей ґрунту.

Основним форматом зберігання результатів є CSV-файли, в яких кожний рядок відповідає окремій точці вимірювання. Типова структура запису включає

координати X та Y , значення компонент магнітного поля B_x , B_y і B_z , а також розраховану повну напруженість поля. Такий формат спрощує інтеграцію з програмними модулями обробки та дає змогу використовувати єдиний конвеєр для лабораторних і польових вимірювань.

В процесі реалізації всі файли проходять автоматичну перевірку структури та коректності даних. Контролюється наявність усіх необхідних полів, відсутність пропущених значень та правильність координатної прив'язки. Це дає можливість уникнути накопичення помилок на подальших етапах побудови магнітних карт і нейромережевого аналізу.

Після завантаження даних виконується цикл попередньої обробки, спрямований на усунення факторів, які не пов'язані безпосередньо з аномальними об'єктами. Основною задачею цього етапу є перетворення набору дискретних вимірювань у стабільне просторове представлення магнітного поля, придатне для автоматизованого аналізу.

Першою операцією є компенсація дрейфу базового рівня. У польових вимірюваннях абсолютне значення магнітного поля змінюється під впливом природних геомагнітних коливань, температурних факторів та особливостей апаратури. Для усунення цих ефектів використовується оцінка локального фону шляхом згладжування просторового профілю з подальшим відніманням низькочастотної складової. Після виконання цієї процедури залишаються переважно локальні відхилення, які можуть бути пов'язані з прихованими об'єктами.

Компенсацію дрейфу виконують відніманням низькочастотної фонові складової поля, що змінюється повільно вздовж траєкторії:

$$\tilde{B}(x, y) = B(x, y) - \bar{B}_{loc}(x, y), \quad (5.13)$$

де $\bar{B}_{loc}(x, y)$ – згладжена оцінка регіонального фону (ковзне середнє / поліноміальний тренд).

Наступним етапом є фільтрація шумів. Аналіз реальних записів показав наявність як високочастотних випадкових коливань, так і поодиноких аномальних викидів. Для їх усунення застосовується медіанна фільтрація та

гаусове згладжування. Такий підхід знижує рівень шуму, майже не спотворюючи форму магнітної аномалії.

Після фільтрації виконується нормування даних. Оскільки різні проходи можуть відрізнятися за абсолютним рівнем магнітного поля, всі значення переводяться до стандартизованої шкали. Це гарантує коректну роботу алгоритмів незалежно від умов проведення вимірювань.

Окрему роль відіграє інтерполяція. Первинні дані являють собою набір нерівномірно розташованих точок, отриманих вздовж траєкторії руху сенсора. Для подальшого аналізу формується регулярна координатна сітка, на яку проєктуються всі вимірювання. Використання інтерполяції надає можливість побудувати безперервну карту магнітного поля та забезпечити однакову структуру даних для нейромережевого аналізу.

Результатом попередньої обробки є двовимірна карта магнітних аномалій, в якій кожна комірка містить оцінку локального відхилення поля від фонового рівня. Така карта надалі використовується для автоматичного пошуку потенційно небезпечних об'єктів.

Після формування карт магнітного поля виконується автоматичне виявлення аномальних областей. Практична реалізація алгоритму побудована таким чином, щоб забезпечити повний цикл аналізу – від завантаження польових вимірювань до отримання координат потенційних об'єктів та оцінки їх належності до класу аномалій.

На першому етапі програма формує регулярну карту магнітного поля на основі координатних даних та виміряних значень індукції. Після інтерполяції виконується побудова карти локальних відхилень. Для цього із загальної картини поля вилучається повільно змінний фон, а залишкові значення використовуються як індикатор можливих аномалій.

Далі здійснюється автоматичний пошук локальних максимумів та мінімумів магнітного поля. Для кожної області обчислюються характеристики форми: площа, амплітуда, градієнт, просторова симетрія та співвідношення між

позитивною і негативною складовими. Ці параметри використовуються як первинні ознаки для нейромережевого класифікатора.

Після виділення кандидатних областей формується набір фрагментів фіксованого розміру. Кожний фрагмент являє собою локальну карту магнітного поля навколо потенційної аномалії. Завдяки цьому нейромережа працює не з окремими значеннями, а з повною просторовою структурою поля.

Для класифікації використовується компактна згорткова нейронна мережа, адаптована до аналізу двовимірних магнітних карт. Перші згорткові шари виділяють локальні особливості форми аномалії, середні рівні формують просторові ознаки, а фінальний класифікатор визначає ймовірність належності області до класу потенційно небезпечних об'єктів.

Згорткова мережа аналізує двовимірний фрагмент карти поля. Базова операція згорткового шару l для вихідного каналу c' має вигляд:

$$a_{i,j,c'}^{(l)} = \sigma \left(b_{c'} + \sum_{c=1}^{C_{l-1}} \sum_{u=1}^k \sum_{v=1}^k w_{c'}^{(l)} [u, v, c] a_{i+u-1, j+v-1, c}^{(l-1)} \right), \quad (5.14)$$

де $a_{i,j,c'}^{(l)}$ – значення активації c' -го вихідного каналу в точці (i, j) на l -му шарі;

$b_{c'}$ – зміщення (*bias*) c' -го вихідного каналу;

$w_{c'}^{(l)} [u, v, c]$ – ваговий коефіцієнт згорткового ядра;

$a_{i+u-1, j+v-1, c}^{(l-1)}$ – значення активації c -го вхідного каналу попереднього шару;

kl – розмір згорткового ядра;

C_{l-1} – кількість вхідних каналів;

σ – функція активації ReLU.

Субдискретизація (MaxPooling) з вікном p та кроком s ущільнює карту ознак:

$$a_{i,j,c}^{(l)} = \max_{1 \leq u, v \leq p} a_{(i-1)s+u, (j-1)s+v, c}^{(l-1)} \quad (5.15)$$

де p – розмір вікна субдискретизації (MaxPooling);

s – крок субдискретизації;

$a_{i,j,c}^{(l)}$ – значення вихідної карти ознак після операції субдискретизації.

Кількість параметрів і обчислювальну складність (множень-додавань) згорткового шару оцінюють як:

$$P_l = (k_l^2 C_{l-1} + 1) C_l, \quad F_l \approx H_l W_l C_l k_l^2 C_{l-1}, \quad (5.16)$$

де P_l – кількість параметрів l -го згорткового шару;

F_l – обчислювальна складність шару (кількість операцій множення-додавання);

k_l – розмір згорткового ядра;

C_{l-1} і C_l – кількість вхідних та вихідних каналів відповідно;

$H_l \times W_l$ – розмір вихідної карти ознак.

Сумарні $P = \sum P_l$ і $F = \sum F_l$ визначають придатність моделі до бортового виконання.

Загальна структура програмної реалізації наведена в додатку Б.

Програмна реалізація включає п'ять основних модулів: завантаження даних, попередню обробку, побудову магнітної карти, виділення аномалій та нейромережеву класифікацію. Структура повністю відповідає загальній архітектурі системи й готова до інтеграції магнітометричного каналу з РІ-сигналами та георадарними даними на рівні мультисенсорного злиття, розглянутого в наступних підрозділах.

Після виконання програмної реалізації було проведено серію тестових запусків алгоритму на сформованих магнітометричних даних. Основною метою перевірки була оцінка працездатності повного конвеєра обробки, який включає побудову магнітної карти, компенсацію фону, формування карти аномалій та підготовку даних для подальшого нейромережевого аналізу.

На рис. 5.5 наведено побудовану карту магнітних аномалій після завершення всіх етапів попередньої обробки.




Рисунок 5.5 – Побудована карта магнітних аномалій після компенсації фонового поля

Отримане поле має рівномірний характер розподілу значень без виражених локальних максимумів. Програмний модуль автоматичного пошуку аномалій повідомив про відсутність кандидатних областей, що підтверджується повідомленням «Виявлено аномалій: 0». Такий результат є очікуваним для сценарію, в якому після компенсації фонового поля не залишилося локальних збурень, що перевищують встановлений поріг детектування.

Результат показує важливу властивість алгоритму: без виражених аномалій система не дає хибних спрацювань. Це підтверджує коректність порогового аналізу та виділення локальних максимумів. У полі це критично – надлишок хибних тривог перевантажує оператора й затягує обстеження.

Додатково було виконано аналіз роботи нейромережевого модуля. Побудована архітектура (таблиця 5.4) містить два згорткові шари, два шари субдискретизації, повнозв'язний класифікатор та шар регуляризації Dropout. Загальна кількість параметрів моделі становить 406 337, з яких всі параметри беруть участь в процесі навчання. Така конфігурація забезпечує достатню складність для аналізу просторових структур магнітного поля та одночасно

залишається придатною для виконання на сучасних вбудованих обчислювальних платформах.

Таблиця 5.4 – Архітектура згорткової нейронної мережі для аналізу магнітометричних карт

№	Шар	Тип операції	Призначення
1	Вхідний шар	Фрагмент карти магнітного поля	Подання просторової структури поля
2	Згортковий шар 1	Conv2D + ReLU	Виділення локальних особливостей форми аномалії
3	Субдискретизація 1	MaxPooling2D	Зменшення розмірності, виділення стійких ознак
4	Згортковий шар 2	Conv2D + ReLU	Формування просторових ознак вищого рівня
5	Субдискретизація 2	MaxPooling2D	Подальше ущільнення карти ознак
6	Згладжування	Flatten	Перетворення карти ознак у вектор
7	Повнозв'язний шар	Dense + ReLU	Інтеграція ознак для класифікації
8	Регуляризація	Dropout	Зниження ризику перенавчання
9	Вихідний шар	Dense + Softmax	Імовірність належності до класу аномалій

Порівняння різних сценаріїв показало, що ефективність алгоритму безпосередньо залежить від контрастності магнітної аномалії відносно фонового поля. Для слабких відхилень після компенсації фону карта набуває практично однорідного вигляду, тоді як за наявності феромагнітних об'єктів формуються локальні області підвищеної інтенсивності, які успішно виділяються модулем пошуку максимумів. Таким чином, демонстраційні результати підтверджують коректність програмної реалізації всіх етапів алгоритму. Перевірка на реальних польових магнітометричних даних є предметом подальших досліджень.

Оцінювання ефективності реалізованого алгоритму виконувалося за чотирма основними показниками: точністю локалізації аномалій, часткою хибних спрацювань, стійкістю до шумів та швидкістю програмної реалізації.

Точність локалізації визначається здатністю алгоритму правильно встановлювати координати магнітної аномалії на побудованій карті поля. Проведені випробування показали, що координати локальних максимумів коректно збігаються з центрами сформованих аномальних областей. Похибка локалізації в першу чергу визначається просторовим кроком вимірювань та якістю інтерполяції. Для сформованої координатної сітки похибка залишається меншою за розмір однієї комірки карти, що є достатнім для попереднього виявлення потенційно небезпечних об'єктів.

Частку хибних спрацювань оцінювали на сценаріях без аномалій. Після компенсації дрейфу та гаусового згладжування алгоритм не сформував жодної кандидатної області. Хибних тривог немає – отже, параметри порогового детектування підібрано правильно, а блок виділення максимумів працює коректно.

Стійкість до шумів аналізувалася шляхом додавання випадкових завад до вихідних даних. Навіть за помітного зростання рівня шуму основні просторові структури магнітного поля залишалися доступними для подальшої обробки завдяки використанню багатоступеневої фільтрації та згладжування. Найбільшу ефективність продемонструвала комбінація компенсації фону та гаусового фільтра, яка зберігає форму аномалій при одночасному зниженні рівня випадкових коливань.

Швидкодія достатня для практичного використання. Основні витрати часу – інтерполяція та побудова регулярної карти поля; сам пошук аномалій після цього займає частки секунди. Мережа має близько 406 тисяч параметрів, тож інференс виконується майже миттєво навіть без графічних прискорювачів.

Отримані результати підтверджують, що реалізований магнітометричний модуль гарантує стабільну обробку вимірювань, не створює хибних тривог за відсутності аномалій та має достатній запас продуктивності для інтеграції в загальну мультисенсорну систему виявлення прихованих об'єктів.

5.3 Реалізація аналізу георадарних даних

Георадарний канал реалізований на рівні програмного конвеєра обробки радарограм: натурні польові вимірювання не проводилися. Для нього реалізовано програмний конвеєр обробки радарограм, перевірений на відкритих наборах даних та синтетичних радарограмах. Наведені нижче результати слід розглядати як демонстрацію працездатності алгоритмів, а не як експериментальне підтвердження на власних польових даних.

Георадарний канал формує найбільш інформативне просторове представлення підповерхневого середовища серед усіх сенсорів мультисенсорної системи. На відміну від РІ-сигналів та магнітометричних вимірювань, які описують окремі характеристики фізичного поля, георадар формує безпосередню часово-просторову картину відбиття електромагнітних хвиль від неоднорідностей ґрунту.

В роботі використовуються дані георадарів імпульсного типу з центральними частотами антен 400–500 МГц. Така конфігурація дає прийнятний компроміс між глибиною зондування та деталізацією підповерхневих структур. Вимірювання виконуються послідовно вздовж траєкторії руху платформи, у результаті чого формується B-scan радарограма.

Кожна радарограма являє собою двовимірний масив даних – $R(x, t)$ де x відповідає координаті вздовж маршруту сканування, а t – часу проходження електромагнітної хвилі.

При наявності локального підповерхневого об'єкта на радарограмі формується характерне гіперболічне відбиття. Геометрія цієї гіперболи визначається глибиною залягання об'єкта, його розмірами та швидкістю поширення електромагнітних хвиль у ґрунті.

Для точкового підповерхневого відбивача на глибині d під координатою x_0 час двопрохідного поширення хвилі зі швидкістю v утворює гіперболу:

$$t(x) = \frac{2}{v} \sqrt{d^2 + (x - x_0)^2}, \quad (5.17)$$

параметри якої (вершина, кривина) кодують глибину та розмір об'єкта.

У програмній реалізації використовуються відкриті набори MineInsight, GPR-BScan, RoadScan та Archaeological GPR Dataset. Дані зберігаються у форматах CSV, HDF5 або NumPy-масивах. Кожен запис містить матрицю сигналів, координатну інформацію та параметри зйомки.

На відміну від PI-каналу, де нейромережа працює з часовими розгортками, георадарна гілка аналізує безпосередньо фрагменти радарограм, що містять потенційні гіперболічні структури.

Первинні радарограми містять значну кількість складових, які не пов'язані з підповерхневими об'єктами. Найбільший внесок формують прямий сигнал антени, відбиття від поверхні ґрунту, неоднорідності верхнього шару середовища та випадкові шуми приймального тракту.

Першою операцією виконується компенсація фонового сигналу. Для кожного часового відліку обчислюється середнє значення по всій ширині радарограми, після чого цей профіль віднімається від початкового запису. Після такої обробки значно зменшується вплив горизонтальних шарів і стають помітними локальні відбиття.

Компенсацію прямого сигналу і горизонтальних завад виконують відніманням середнього по всій ширині радарограми для кожного часового відліку:

$$\tilde{R}(x, t) = R(x, t) - \frac{1}{N_x} \sum_{x'=1}^{N_x} R(x', t). \quad (5.18)$$

Далі – автоматичне підсилення контрасту. Часово-залежне масштабування амплітуд компенсує природне згасання хвилі з глибиною, тож глибокі об'єкти за інтенсивністю стають співставними з поверхневими відбиттями.

Для зменшення шумів використовується комбінація гаусового згладжування та медіанної фільтрації. Така схема усуває випадкові коливання сигналу без руйнування форми гіперболічних структур.

Після фільтрації формується карта локальної енергії $E(x, t) = R^2(x, t)$ що підсилює області концентрації відбитої енергії. На цій стадії більшість гіперболічних відбиттів набувають вигляду компактних яскравих структур, придатних для автоматичної сегментації.

Карту локальної енергії, що підкреслює області концентрації відбитої енергії, обчислюють у ковзному вікні Ω :

$$E(x, t) = \sum_{(x', t') \in \Omega} \tilde{R}^2(x', t'). \quad (5.19)$$

Останнім етапом підготовки є формування набору фрагментів фіксованого розміру 64×64 або 128×128 пікселів. Такі фрагменти надалі надходять на вхід нейромережевого класифікатора.

Для аналізу георадарних даних реалізовано окремий програмний модуль, орієнтований на автоматичне виявлення гіперболічних відбиттів. На відміну від магнітометричного каналу, де аналізуються локальні максимуми поля, у георадарному каналі ключовою ознакою виступає саме форма відбиття.

Обробка починається із завантаження радарограми та компенсації фонового сигналу. Після фільтрації виконується побудова карти локальної енергії. Для пошуку потенційних цілей використовується детектор гіпербол, який аналізує кривизну контурів та концентрацію енергії у локальній області.

Виявлені кандидати проходять процедуру сегментації. Навколо вершини кожної гіперболи автоматично формується прямокутна область інтересу. Отримані фрагменти масштабуються до однакового розміру та подаються на вхід нейромережевого класифікатора.

Класифікацію виконує згорткова нейронна мережа, що аналізує геометрію відбиття. Перші шари виділяють контури гіпербол, середні формують просторові ознаки, фінальний – оцінює ймовірність належності області до аномалій.

Програмну реалізацію надано в додатку В.

Після виконання програмної реалізації було проведено тестування алгоритму на наборі синтетичних георадарних даних, які моделюють типові підповерхневі об'єкти. Метою перевірки була оцінка працездатності всіх етапів обробки: від формування радарограми до автоматичного виділення потенційних аномалій та їх підготовки для нейромережевого аналізу.

На рис. 5.6 наведено приклад обробленої радарограми після компенсації фонового сигналу та фільтрації шумів.




Рисунок 5.6 – Виявлення гіперболічних відбиттів на радарограмі

На зображенні чітко простежуються дві гіперболічні структури різних розмірів і глибин залягання. Такі відбиття характерні для локальних підповерхневих об'єктів і є основним індикатором потенційної аномалії в георадарних даних. В процесі аналізу виконувався автоматичний пошук вершин гіпербол. За результатами роботи алгоритму було сформовано одну кандидатну область, центр якої позначено вертикальною пунктирною лінією. Незважаючи на наявність двох гіпербол, алгоритм об'єднав їх у спільну область інтересу через часткове перекриття зон підвищеної енергії. Такий результат є типовим для початкових етапів сегментації та надалі уточнюється нейромережевим класифікатором. За координатами кандидатної області вирізають фрагмент радарограми фіксованого розміру й подають у мережу. Обробляти всю радарограму не потрібно – обчислювальне навантаження істотно нижче.

Результати сегментації показали, що найбільша концентрація відбитої енергії спостерігається у центральній частині радарограми в області перетину гіперболічних структур. Ця зона отримала найбільшу вагу під час подальшого нейромережевого аналізу. Координати вершини були автоматично визначені та використані для побудови області інтересу.

Після завершення сегментації сформовані фрагменти передавалися до згорткової нейронної мережі. Архітектура моделі наведена в таблиці 5.2. Мережа

містить два згорткові блоки, два шари субдискретизації, повнозв'язний класифікатор та механізм регуляризації Dropout. Загальна кількість параметрів становить 1 624 705, що забезпечує достатню складність моделі для аналізу геометрії складних гіперболічних структур.

Таблиця 5.5 – Архітектура згорткової нейронної мережі для аналізу георадарних даних

№	Шар	Тип операції	Призначення
1	Вхідний шар	Фрагмент радарограми (область інтересу)	Подання просторової структури поля
2	Згортковий шар 1	Conv2D + ReLU	Виділення локальних особливостей форми аномалії
3	Субдискретизація 1	MaxPooling2D	Зменшення розмірності, виділення стійких ознак
4	Згортковий шар 2	Conv2D + ReLU	Формування просторових ознак вищого рівня
5	Субдискретизація 2	MaxPooling2D	Подальше ущільнення карти ознак
6	Згладжування	Flatten	Перетворення карти ознак у вектор
7	Повнозв'язний шар	Dense + ReLU	Інтеграція ознак для класифікації
8	Регуляризація	Dropout	Зниження ризику перенавчання
9	Вихідний шар	Dense + Softmax	Імовірність належності до класу аномалій

Після проходження через нейромережевий класифікатор для кожної області інтересу формується оцінка ймовірності належності до класу аномалій. На основі цих оцінок надалі будується карта ймовірності виявлення, яка інтегрується з результатами інших сенсорних каналів мультисенсорної системи. Такий спосіб реалізує перехід від локального аналізу окремих радарограм до побудови інтегрованої карти ризику для всієї досліджуваної території.

Для оцінювання ефективності реалізованого алгоритму використовувався набір стандартних показників якості, що застосовуються у задачах сегментації та локалізації аномалій. Основна увага приділялася точності виділення областей інтересу, коректності класифікації та просторовій точності локалізації підповерхневих об'єктів.

Показник IoU (Intersection over Union) характеризує ступінь перекриття області, виділеної алгоритмом, з еталонною розміткою. Для георадарних даних це один із ключових критеріїв: він прямо оцінює якість сегментації гіперболічних структур. Високі значення IoU свідчать про точне визначення меж аномалій та мінімізацію помилок локалізації.

Якість сегментації оцінюють перекриттям виділеної області A з еталонною B за показниками IoU та $Dice$:

$$IoU = \frac{|A \cap B|}{|A \cup B|}, \quad Dice = \frac{2|A \cap B|}{|A| + |B|}. \quad (5.20)$$

Додатково використовувався показник $Dice$ Score, який оцінює подібність між автоматично сформованою маскою та еталонною областю. На відміну від IoU , цей критерій менш чутливий до незначних зміщень меж і забезпечує більш стабільну оцінку якості сегментації для невеликих об'єктів.

Для оцінювання роботи класифікатора використовувалися показники $Precision$ та $Recall$. $Precision$ характеризує частку коректно визначених аномалій серед усіх виявлених системою об'єктів. Високі значення цього показника свідчать про невелику кількість хибних спрацювань. $Recall$ відображає здатність системи знаходити всі наявні аномалії та безпосередньо пов'язаний із ризиком пропуску потенційно небезпечних об'єктів.

Окремим критерієм виступала похибка локалізації. Для кожної виявленої аномалії визначалося відхилення між координатами вершини гіперболи, отриманими автоматично, та еталонними координатами об'єкта. У проведених експериментах похибка локалізації залишалася в межах декількох дискретів радарограми, що відповідає вимогам попереднього автоматизованого обстеження території.

Аналіз отриманих результатів показав, що найбільший вплив на точність локалізації мають якість попередньої обробки та коректність виділення вершини гіперболи. В свою чергу точність класифікації визначається різноманітністю навчальної вибірки та кількістю представлених типів підповерхневих об'єктів.

Проведена перевірка підтвердила працездатність програмної реалізації на синтетичних даних. Водночас на демонстраційних вибірках модель виявляла

ознаки перенавчання, що додатково підкреслює потребу у валідації на реальних польових радарограмах. Усі основні етапи – від обробки радарограм до нейромережевого аналізу та локалізації аномалій – функціонують як єдиний програмний комплекс і можуть використовуватися як окрема георадарна гілка мультисенсорної системи виявлення прихованих об'єктів.

5.4 Реалізація мультисенсорного злиття даних

Після розгляду окремих каналів аналізу – імпульсної індукції, магнітометрії та георадарного зондування – доцільно перейти до етапу їх спільного використання. Практика дистанційного виявлення аномалій показує, що жоден сенсор не забезпечує абсолютної достовірності результатів за всіх умов експлуатації. Металошукач демонструє високу чутливість до провідних об'єктів, але реагує на металеве сміття. Магнітометричний канал ефективно виявляє феромагнітні об'єкти, проте чутливий до природних магнітних неоднорідностей. Георадар забезпечує детальне просторове відображення підповерхневого середовища, однак його якість суттєво залежить від властивостей ґрунту та вологості. Тому наступним логічним етапом є побудова єдиної системи прийняття рішень, яка використовує інформацію від усіх джерел одночасно.

Реалізація мультисенсорного злиття починається з приведення різномірних даних до узгодженого подання. На цьому етапі кожен канал вже пройшов власний цикл попередньої обробки та сформував набір інформативних ознак. Завдання полягає не в простому об'єднанні числових значень, а у створенні єдиного простору ознак, в якому результати різних сенсорів можуть аналізуватися спільно.

Для РІ-каналу до спільного простору надходять результати аналізу п'ятикомпонентного вектора ознак, вихідні оцінки згорткової нейронної мережі, значення ймовірностей класів та координати локальних максимумів енергетичних карт. Так система отримує і форму сигналу, і попередню оцінку типу потенційного об'єкта.

Магнітометричний канал передає характеристики локальних магнітних аномалій. До набору ознак входять амплітуда аномалії, площа області підвищеної інтенсивності, просторові координати центру, показники симетрії поля та результати нейромережевого аналізу сформованих карт. Окремо враховується ступінь впевненості класифікатора у сформованому рішенні.

Для георадарного каналу використовуються координати виявлених гіперболічних структур, геометричні параметри гіпербол, результати сегментації та оцінки ймовірності належності до класу підповерхневих аномалій.

Ключовий елемент інтеграції – геоприв'язка. Всі результати переводяться до єдиної координатної системи; для кожного вимірювання зберігаються просторові координати, час отримання та параметри місії, тож канали можна зіставляти навіть за різної частоти вимірювань і різних принципів формування даних.

Після завершення геоприв'язки формується інтегральний вектор ознак, в якому кожен рядок відповідає окремій ділянці місцевості. Сформоване подання надходить до ансамблевого класифікатора як вхідна інформація для прийняття кінцевого рішення. Загальна структура формування спільного простору ознак представлена на рис. 5.7.

Після формування спільного простору ознак виконується інтегральний аналіз даних. Для цієї задачі використовується ансамблевий класифікатор зі стекінгом, структура якого була обґрунтована у третьому розділі.

На першому рівні кожен сенсорний канал працює незалежно. РІ-гілка аналізує часові сигнали, магнітометрична гілка обробляє карти магнітного поля, а георадарна гілка виконує аналіз радарограм. Результатом роботи кожної гілки є не жорстке рішення, а вектор оцінок ймовірностей.

Використання ймовірнісного подання має практичне значення. Наприклад, РІ-модуль може оцінити ймовірність аномалії на рівні 0,92, магнітометрія – 0,74, а георадар – 0,87. У такому випадку кінцеве рішення формується не за принципом голосування більшістю, а з урахуванням ступеня впевненості кожного каналу.



Рисунок 5.7 – Загальна структура формування спільного простору ознак

На другому рівні розташовується метакласифікатор. Його вхідними даними є результати всіх спеціалізованих моделей. Метакласифікатор аналізує характерні комбінації рішень і навчається визначати, які поєднання оцінок найбільш характерні для реальних аномалій, а які відповідають помилковим спрацюванням. Ансамбль реалізує стекінг: базові моделі гілок формують імовірнісні оцінки, які метакласифікатор g відображає у підсумкове рішення:

$$p_m = h_m(\mathbf{x}_m), m \in \{PI, MAG, GPR\}; \quad \hat{y} = g(p_{PI}, p_{MAG}, p_{GPR}). \quad (5.21)$$

Окрему роль у формуванні підсумкового рішення відіграє механізм уваги. Його завдання полягає в адаптивному перерозподілі ваг між каналами залежно від умов вимірювання. Якщо якість георадарних даних погіршується через вологий ґрунт або підвищене затухання сигналу, система автоматично зменшує внесок георадарної гілки. Аналогічно за високого рівня магнітних завад може зменшуватися вага магнітометричного каналу.

Механізм уваги адаптивно перерозподіляє ваги каналів за їх поточною інформативністю e_m ; підсумкова оцінка є зваженою комбінацією:

$$\alpha_m = \frac{\exp(e_m)}{\sum_{m'} \exp(e_{m'})}, \quad p_{fus} = \sum_m \alpha_m p_m. \quad (5.22)$$

де α_m – нормалізована вага m -го каналу;
 e_m – оцінка його інформативності;
 p_m – вихід m -го каналу;
 p_{fus} – результат мультисенсорного злиття.

Кінцеве рішення – не середнє всіх оцінок, а результат адаптивного комбінування інформації від сенсорів з урахуванням їх поточної інформативності. Сама архітектура ансамблевого класифікатора для мультисенсорного виявлення аномалій виглядає так (рис. 5.8):




Рисунок 5.8 – Архітектура ансамблевого класифікатора для мультисенсорного виявлення аномалій

Завершальним етапом мультисенсорного аналізу є формування інтегральної карти ризику. На цьому рівні система переходить від аналізу окремих вимірювань до оцінювання всієї досліджуваної території.

Кожен канал формує власну карту ймовірностей. Для PI-системи такою картою є розподіл інтенсивності сигналів та результатів класифікації.

Магнітометричний модуль створює карту магнітних аномалій. Георадарна гілка формує карту просторового розташування виявлених підповерхневих структур.

На наступному етапі виконується просторове об'єднання всіх карт. Для кожної комірки координатної сітки обчислюється інтегральний показник ризику. Його значення залежить від кількості сенсорів, які підтвердили наявність аномалії, рівня впевненості окремих моделей та ступеня просторової узгодженості результатів.

Для кожної комірки координатної сітки інтегральна карта ризику формується адаптивно зваженим об'єднанням карт імовірностей каналів:

$$\mathcal{R}(x, y) = \sum_m \alpha_m (x, y) p_m(x, y). \quad (5.23)$$

Особлива увага приділяється адаптивному зважуванню. Якщо кілька каналів незалежно фіксують аномалію в одній області, інтегральний показник ризику зростає. За суперечливих результатів система зважає на історичну надійність відповідних моделей та якість поточних вимірювань.

Результатом роботи є карта ризику, на якій кожна ділянка території характеризується числовою оцінкою небезпеки. Таке подання є найбільш зручним для оператора, оскільки дає змогу швидко виділяти пріоритетні зони для додаткового обстеження та приймати рішення щодо подальшого планування місії.

Інтегральна карта ризику є фінальним продуктом усієї системи мультисенсорного аналізу. Вона поєднує результати нейромережевої обробки фізичних полів, геоприв'язку вимірювань, механізми ансамблевої класифікації та адаптивного зважування, перетворюючи великий обсяг різномірних даних на компактне та практично придатне рішення для виявлення потенційно небезпечних аномалій.

Реалізована схема мультисенсорного злиття об'єднує результати аналізу імпульсного міношукача, магнітометричного каналу та георадарного зондування в єдиному інформаційному просторі. Геоприв'язка, ансамблевий класифікатор і

адаптивний механізм зважування узгоджують обробку різнорідних даних та формують інтегральні оцінки ризику для кожної ділянки.

На відміну від використання окремих сенсорів, мультисенсорний підхід здатний підвищити достовірність виявлення аномалій завдяки взаємному підтвердженню результатів різних каналів спостереження. У цій роботі схему злиття реалізовано на архітектурному рівні та перевірено переважно на РІ-каналі та синтетичних даних, тоді як повна перевірка з реальними магнітометричними і георадарними потоками потребує подальших польових досліджень. При цьому структура системи залишається масштабованою та допускає підключення нових джерел даних без зміни загальної логіки роботи ансамблевого класифікатора.

5.5 Висновки до п'ятого розділу

1. У п'ятому розділі виконано практичну реалізацію обґрунтованих нейромережових методів виявлення та класифікації аномалій для трьох основних джерел даних: імпульсного міношукача, магнітометричної системи та георадара. Для кожного сенсорного каналу сформовано окремий конвеєр обробки даних, який включає попередню обробку сигналів, виділення інформативних ознак, нейромережовий аналіз та формування результатів локалізації аномалій.

2. Реалізовано програмний модуль аналізу РІ-сигналів імпульсного міношукача. Виконано компенсацію фонові складові, формування п'ятикомпонентного вектора ознак, нормування даних та їх підготовку до нейромережового аналізу. Використання одновимірної згорткової мережі підтвердило можливість автоматичного розпізнавання характерних сигнатур металевих об'єктів та визначення їх просторового положення за результатами аналізу енергетичних характеристик сигналу.

3. Створено програмний комплекс аналізу магнітометричних вимірювань. Реалізовано алгоритми компенсації дрейфу магнітного поля, фільтрації випадкових завад, інтерполяції просторових даних та побудови цифрових карт магнітних аномалій. Отримані результати підтвердили придатність нейромережових методів для автоматизованого виділення

локальних магнітних неоднорідностей на фоні природних змін магнітного поля. Перевірку виконано на демонстраційних даних, оскільки магнітометричний канал у роботі є перспективним.

4. Розроблено програмну реалізацію аналізу георадарних даних. Виконано повний цикл обробки радарограм, який включає компенсацію фоновому сигналу, нормування амплітуд, просторову фільтрацію, сегментацію областей інтересу та виділення гіперболічних відбиттів. Запропонована згорткова нейронна мережа виконує автоматизований аналіз фрагментів радарограм і формування оцінок імовірності наявності підповерхневих аномалій на синтетичних даних; натурні георадарні вимірювання не проводилися.

5. Для кожного сенсорного каналу проведено оцінювання якості роботи алгоритмів за показниками точності класифікації, повноти виявлення, локалізаційної похибки, стійкості до шумів та швидкодії. Програмна перевірка показала працездатність запропонованих підходів. Вони придатні для роботи в системах аналізу фізичних полів у режимі реального часу.

6. Реалізовано мультисенсорне злиття даних на основі єдиного простору ознак, який об'єднує результати РІ-аналізу, магнітометричних вимірювань та георадарного зондування. Виконано геоприв'язку всіх джерел даних та сформовано інтегральне подання інформації для подальшого прийняття рішень.

7. Запропоновано ансамблевий підхід до класифікації аномалій, у якому результати спеціалізованих нейромережевих моделей об'єднуються за допомогою метакласифікатора та механізму адаптивного зважування каналів. Така архітектура підвищує достовірність виявлення за рахунок взаємного підтвердження незалежних сенсорних систем.

8. Реалізовано процедуру побудови інтегральної карти ризику, яка об'єднує результати всіх сенсорних каналів у межах єдиної координатної системи. Підсумкова карта дає наочне представлення рівня небезпеки для кожної ділянки досліджуваної території та може використовуватися як основа для

підтримки прийняття рішень під час проведення пошукових і розмінувальних робіт.

9. Отримані результати підтвердили практичну реалізованість побудови мультисенсорної нейромережевої системи аналізу фізичних полів, у якій імпульсний міношукач, магнітометрія та георадар функціонують як взаємодоповнюючі канали.

Основні результати п'ятого розділу опубліковано в працях [5, 61]; набір даних, використаний у підрозділі 5.1, оприлюднено у відкритому доступі [59].

ВИСНОВКИ

У дисертаційній роботі розв'язано важливу науково-практичну задачу розроблення нейромережових методів пошуку, виявлення, класифікації та локалізації аномалій у полях фізичних величин за різнорідними сенсорними даними. Підвищення достовірності пошуку аномалій і точності визначення їх просторового положення досягнуто за рахунок узгодженого просторово-часового та структурованого подання мультисенсорних вимірювальних потоків, формування тензорного входу нейронних мереж, застосування ансамблевої нейромережової класифікації та введення фізично-інформованої регуляризації моделей. Отримані результати мають теоретичне значення для розвитку нейромережових методів аналізу фізичних полів і практичне значення для задач гуманітарного розмінування, первинного обстеження потенційно небезпечних територій, дистанційного моніторингу ґрунтів, геофізичного обстеження та екологічного контролю.

1. Виконано аналіз сучасного стану проблеми виявлення аномалій у полях фізичних величин і встановлено, що для задач дистанційного виявлення прихованих або слабо виражених об'єктів вирішальним є не безпосереднє спостереження об'єкта, а реєстрація зумовленого ним відхилення фізичного поля від фонового стану. Обґрунтовано, що окремі сенсорні канали, зокрема імпульсно-індукційний, магнітометричний, мультиспектральний і георадарний, мають різну фізичну природу, різну чутливість до аномалій, різні просторово-часові характеристики та різні джерела похибок. Показано, що їх незалежне використання або просте поєднання результатів вимірювання не забезпечує достатньої достовірності пошуку, низького рівня хибних тривог і необхідної точності локалізації. Це обґрунтувало необхідність розроблення нейромережових методів, які спираються на попередньо узгоджене, геометрично коректне та структуроване подання різнорідних сенсорних даних.

2. Удосконалено метод часового узгодження різнорідних вимірювальних потоків мультисенсорної БПЛА-платформи та вперше розроблено чотиривимірну модель поля аномалій $S(c, X, Y, t)$ для даних імпульсної індукції.

Метод часового узгодження базується на апаратній привязці сенсорних каналів до спільного опорного сигналу та забезпечує просторовий еквівалент похибки синхронізації 2–4 см, що є достатнім для формування коректних вхідних даних нейронних мереж виявлення аномалій у темпі надходження вимірювань. Модель $S(c, X, Y, t)$ формалізує залежність сигналу від параметрів каналу приймання, просторових координат точки зондування та часу релаксації відгуку, що дало змогу перейти від окремих часових розгортки до структурованого опису поля аномалій і створити основу для подальшого формування нейромережевого входу.

3. Удосконалено метод просторової привязки мультисенсорних вимірювань і розроблено тензорне подання мультисенсорних даних $T(x, y, k)$. Метод просторової привязки поєднує автономну кінематику реального часу з кількісним обґрунтуванням точності геопривязки та забезпечує формування геометрично узгодженого подання даних за просторової похибки 1–8 см. На основі узгоджених вимірювань сформовано 14-канальне тензорне подання $T(x, y, k)$ шляхом інтерполяції різнорідних потоків на спільну координатну сітку 10×10 см. Таке подання усуває розрив між фізично різнорідними сенсорними сигналами та вимогами нейромережових моделей до регулярної структури вхідних даних, забезпечуючи просторово узгоджену основу для виявлення, класифікації та локалізації аномалій.

4. Удосконалено нейромережовий метод виявлення і класифікації аномалій у полях фізичних величин за мультисенсорними даними, який використовує геометрично узгоджене тензорне подання $T(x, y, k)$ як спільний багатоканальний вхід для ансамблю одновимірних згорткових нейронних мереж і стекінгового метакласифікатора. На відміну від підходів, орієнтованих на незалежний аналіз окремих сенсорних каналів, запропонований метод забезпечує спільне використання даних різної фізичної природи у темпі надходження вимірювань. Набув подальшого розвитку підхід до побудови фізично-інформованих нейронних мереж шляхом включення до функції втрат регуляризаційних складових, що відображають структурні інваріанти сенсорних сигналів, задані

дипольною моделлю магнітної аномалії та моделями багатоекспоненційного затухання вихрових струмів. Це підвищує узагальнювальну здатність нейронних мереж пошуку, виявлення, класифікації та локалізації аномалій за умов обмеженої розміченої вибірки.

5. Розроблено підходи до формування навчальних вибірок, планування місій і програмної реалізації нейромережових методів пошуку аномалій. Обґрунтовано структуру навчального зразка, використання лабораторних і польових джерел даних, нормування зразків, формування складних негативних прикладів, балансування класів, просторово коректне розбиття вибірки та стратегію поєднання лабораторних і польових даних. Запропоновано підхід до подолання доменного зсуву за схемою «лабораторне навчання – польове донавчання», а також використання фізично коректної аугментації та синтетичних даних. Розроблені програмні засоби реалізують оброблення РІ-сигналів, аналіз магнітометричних і георадарних даних, мультисенсорне злиття та формування інтегральної карти ризику як кінцевого інформаційного продукту для підтримки прийняття рішень.

6. Експериментальна перевірка підтвердила практичну придатність розроблених нейромережових методів, моделей подання даних і програмних засобів. На незалежних вибірках отримано $Pd = 0,965$ та $F1 = 0,952$; час роботи нейромережевого класифікатора становить менш ніж 4 мс на вектор даних імпульсної індукції; польові випробування підтвердили можливість локалізації аномалій із сантиметровою точністю просторової привязки. Розроблені методи та програмні засоби впроваджено у практичну діяльність ТОВ ВП «Спецмонтаж» та ТОВ «ОМ Енерджи». Відкритий набір лабораторних і польових вимірювань трикоутушкового імпульсного металопшукача опубліковано в репозиторії github.com/op-uav-lab/soil-monitor-mlp. Результати дисертаційної роботи використано під час виконання проєкту Національного фонду досліджень України № 2023.04/0161, грантового науково-технічного проєкту СШ/5-2024 від 28.11.2024 та НДР 723-43. Основні результати дисертації опубліковано у десяти наукових працях, серед яких одна стаття у науковому виданні, що індексується

наукометричною базою Scopus, одна стаття у науковому періодичному виданні іншої держави, дві статті у фахових виданнях України категорії «Б», розділи колективної монографії та матеріали наукових конференцій.

СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Hutsul T., Khobzei M., Tkach V., Krulikovskiy O., Moisiuk O., Ivashko V., Samila A. Review of approaches to the use of unmanned aerial vehicles, remote sensing and geographic information systems in humanitarian demining: Ukrainian case // *Heliyon*. – 2024. – Vol. 10, No. 7. – Art. e29142. – DOI: 10.1016/j.heliyon.2024.e29142.
2. Bepalko R., Hutsul T., Kazimir I., Myronchuk K. Сучасні підходи до оцінювання черговості гуманітарного розмінування територій // *Технічні науки та технології*. – 2023. – № 1(31). – С. 146–157. – DOI: 10.25140/2411-5363-2023-1(31)-146-157.
3. Дрозд М. О., Дрозд Ю. В., Шунін О. Ю. Ефективність навчання нейронної мережі на формованих наборах зображень з заданим рівнем різноманіття // *Наука і техніка сьогодні*. – 2025. – № 9(50). – С. 1104–1123. – DOI: 10.52058/2786-6025-2025-9(50)-1104-1123.
4. Aggarwal D., Kochersberger K., Adams C. Optimal distance and velocity for UAV localization of nuclear sources // *Proceedings of SPIE*. – 2025. – Vol. 13478. – DOI: 10.1117/12.3053278.
5. Shunin O., Maslov O., Galchonkov O. Building a basic drone equipment set for conducting research to detect anomalies in soil // *International Science Journal of Engineering & Agriculture*. – 2025. – Vol. 4, No. 5. – P. 13–26. – DOI: 10.46299/j.isjea.20250405.02.
6. Narkhede P., Walambe R., Kotecha K. Sensor fusion methodologies for landmine detection // *Machine Intelligence Techniques for Data Analysis and Signal Processing*. – Singapore : Springer, 2023. – P. 881–895. – DOI: 10.1007/978-981-19-6631-6_62.
7. Šimić M., Ambruš D., Bilas V. Landmine identification from pulse-induction metal detector data using machine learning // *IEEE Sensors Letters*. – 2023. – Vol. 7, No. 9. – Art. 7004204. – DOI: 10.1109/LSENS.2023.3307091.
8. Popov M., Stankevich S., Mosov S., Dugin S., Golubov S., Andreiev A., Lysenko A., Saprykin I. Concept of a geoinformation platform for landmines and

explosive objects detection and mapping using UAVs // Radioelectronic and Computer Systems. – 2024. – No. 4(112). – P. 207–216. – DOI: 10.32620/reks.2024.4.17.

9. Kolster M. E., Døssing A. Scalar magnetic difference inversion applied to UAV-based UXO detection // Geophysical Journal International. – 2021. – Vol. 224, No. 1. – P. 468–478. – DOI: 10.1093/gji/ggaa483.

10. Thomas R., Salmon B., Holloway D., Olivier J. Machine learning classification of permeable conducting spheres in air and seawater using electromagnetic pulses // Measurement Science and Technology. – 2024. – Vol. 35, No. 10. – Art. 106012. – DOI: 10.1088/1361-6501/ad678a.

11. Overton G., Moreland C. Inside the Metal Detector. – Encinitas, CA : Geotech Press, 2012. – 320 p. – ISBN 978-0985834210.

12. Ugarte-Goicuría I., Guerrero-Sevilla D., Carrasco-Garcia P., Carrasco-Garcia J., Gonzalez-Aguilera D. Aerial drone magnetometry for the detection of subsurface unexploded ordnance (UXO) // Drones. – 2026. – Vol. 10, No. 2. – Art. 88. – DOI: 10.3390/drones10020088.

13. García-Fernández M., Álvarez-Narciandi G., Álvarez López Y., Las-Heras Andrés F. Analysis and validation of a hybrid forward-looking down-looking GPR architecture // Remote Sensing. – 2021. – Vol. 13, No. 6. – Art. 1206. – DOI: 10.3390/rs13061206.

14. Aasen H., Honkavaara E., Lucieer A., Zarco-Tejada P. J. Quantitative remote sensing at ultra-high resolution with UAV spectroscopy: a review of sensor technology, measurement procedures, and data correction workflows // Remote Sensing. – 2018. – Vol. 10, No. 7. – Art. 1091. – DOI: 10.3390/rs10071091.

15. Вінтоняк В. Інновації в електроніці для виявлення об'єктів у поверхневих шарах ґрунту: огляд методів та напрямки їх подальшого вдосконалення // Технології та інжиніринг. – 2024. – № 3. – DOI: 10.30857/2786-5371.2024.3.1.

16. Ivashko V., Krulikovskiy O., Haliuk S., Samila A. Review of operating systems used in unmanned aerial vehicles // Informatyka, Automatyka, Pomiar w

Gospodarce i Ochronie Środowiska. – 2025. – Vol. 15, No. 1. – P. 95–100. – DOI: 10.35784/iapgos.6786.

17. Barnawi A., Kumar K., Kumar N., Alzahrani B., Almansour A. A deep learning approach for landmines detection based on airborne magnetometry imaging and edge computing // Computer Modeling in Engineering & Sciences. – 2023. – DOI: 10.32604/cmescs.2023.044184.

18. Voronenko M., Lytvynenko V., Antoshchuk S., Arsirii O., Drozd M., Nikolenko A., Babilunha O., Vyshemyrska S. Neural and Bayesian networks application areas : monograph. – Kherson : FOP Vyshemyrskyi, 2025. – 156 p. – URL: https://www.researchgate.net/publication/395028774_NEURAL_AND_BAYESIAN_NETWORKS_APPLICATION_AREAS (дата звернення: 01.09.2025).

19. Grzegorzczak T. M., Barrowes B. E., Gonzalez-Nieto F., Shubitidze F., O'Neill K. Effects of soil electromagnetic properties on metal detectors // IEEE Transactions on Geoscience and Remote Sensing. – 2011. – Vol. 49, no. 1. – P. 1–13. – URL: https://www.researchgate.net/publication/3204098_Effects_of_soil_electromagnetic_properties_on_metal_detectors (дата звернення: 01.03.2026).

20. Development of a cross-platform model of the unified algorithmic environment for the recognition of explosive objects / УкрІНТЕІ. – 2024. – URL: <https://dir.ukrintei.ua/view/okd/10614b8ed16f6efa5cc9546173e15fea> (дата звернення: 01.03.2026).

21. Shunin O. Y., Maslov O. V. Інформаційна модель дистанційного моніторингу ґрунту // Herald of Advanced Information Technology. – 2025. – Vol. 8, No. 3. – P. 352–365. – DOI: 10.15276/hait.08.2025.23.

22. Castiblanco C., Rodriguez J., Mondragon I., Parra C., Colorado J. Air drones for explosive landmines detection // ROBOT2013: First Iberian Robotics Conference. – Cham : Springer, 2014. – P. 167–178. – DOI: 10.1007/978-3-319-03653-3_9.

23. Kunichik O., Tereshchenko V. Analysis of modern methods of search and classification of explosive objects // Artificial Intelligence. – 2022. – No. 2. – P. 52–63. – DOI: 10.15407/jai2022.02.052.

24. Nurgizat Y., Sultan A., Zhetenbayev N., Ayazbay A.-A., Uzbekbayev A., Sergazin G., Alipbayev K. Comparative Analysis of Modern Robotic Demining Complexes and Development of an Automated Mission Planning Algorithm // Engineering Proceedings. 2025. Vol. 104, No. 1. Art. 63. DOI: 10.3390/engproc2025104063.

25. Krivtsun V., Kuprinenko O. Методика обґрунтування технічного обриску перспективних роботизованих засобів розмінування // Social Development and Security. – 2024. – Vol. 14, No. 3. – DOI: 10.33445/sds.2024.14.3.19.

26. New signal processing techniques for enhanced metal detector performance // NDT.net. – 2024. – URL: <https://www.ndt.net/?id=3984> (дата звернення: 01.03.2026).

27. Thomas R., Salmon B., Holloway D., Olivier J. Investigation of electromagnetic pulse scattering for metallic object classification using machine learning // Journal of Electromagnetic Waves and Applications. – 2024. – DOI: 10.1080/09205071.2024.2365297.

28. Ledger P. D., Lionheart W. R. B. The spectral properties of the magnetic polarizability tensor for metallic object characterisation // Mathematical Methods in the Applied Sciences. – 2019. – DOI: 10.1002/mma.5830.

29. Kolster M. E., Wigh M. D., Lima Simões da Silva E., Bjerg Vilhelmsen T., Døssing A. High-speed magnetic surveying for unexploded ordnance using UAV systems // Remote Sensing. – 2022. – Vol. 14, No. 5. – Art. 1134. – DOI: 10.3390/rs14051134.

30. Pryshchenko O. A., Plakhtii V., Dumin O. M., Pochanin G. P., Ruban V. P., Capineri L., Crawford F. Implementation of an artificial intelligence approach to GPR systems for landmine detection // Remote Sensing. – 2022. – Vol. 14, No. 17. – Art. 4421. – DOI: 10.3390/rs14174421.

31. Lee J., Lee H., Ko S., Ji D., Hyeon J. Modeling and implementation of a joint airborne GPR and magnetometer system for landmine detection // Remote Sensing. – 2023. – Vol. 15, No. 15. – Art. 3813. – DOI: 10.3390/rs15153813.

32. Yilmaz C., Kahraman H. T., Söyler S. Passive mine detection and classification method based on hybrid model // IEEE Access. – 2018. – Vol. 6. – P. 48738–48752. – DOI: 10.1109/ACCESS.2018.2866538.

33. Peichl M., Schreiber E., Heinzl A., Dill S. Novel imaging radar technology for detection of landmines and other unexploded ordnance // European Journal for Security Research. – 2016. – DOI: 10.1007/s41125-016-0011-3.

34. Elizondo-Decanini J. M. Surface mounted neutron generators: Neutristor (computer chip-sized neutron source). – Albuquerque, NM : Sandia National Laboratories, 2012. – URL: <https://www.osti.gov/servlets/purl/1116272> (дата звернення: 01.03.2026).

35. Elizondo-Decanini J. M. Neutron generators with size scalability, ease of fabrication, and multiple ion source functionalities : patent US 8891721 B1. – Publ. 18.11.2014. – URL: <https://patents.google.com/patent/US8891721B1/en> (дата звернення: 01.03.2026).

36. Khan M. U., Kamran M. A., Khan W. R., Ibrahim M. M., Ali M. U., Lee S. W. Multi-sensor fusion for remote sensing of metallic and non-metallic object classification in complex soil environments // IEEE Transactions on Geoscience and Remote Sensing. – 2024. – Vol. 62. – DOI: 10.1109/TGRS.2024.3410530.

37. Kuru K., Sujit A., Ansell D., Pinder J. M., Jones D., Watkinson B. J., Hamila R., Tinker-Mill C. Intelligent, automated, rapid, and safe landmine, IED and UXO detection using multiple sensor modalities mounted on autonomous drones // IEEE Access. – 2024. – Vol. 12. – DOI: 10.1109/ACCESS.2024.3493013.

38. Florez-Lozano J., Caraffini F., Parra C., Gongora M. Cooperative and distributed decision-making in a multi-agent perception system for improvised land mine detection // Information Fusion. – 2020. – Vol. 64. – P. 187–202. – DOI: 10.1016/j.inffus.2020.06.009.

39. Qiu Z., Guo H., Hu J., Jiang H., Luo C. Joint fusion and detection via deep learning in UAV-borne multispectral sensing of scatterable landmine // Sensors. – 2023. – Vol. 23, No. 12. – Art. 5693. – DOI: 10.3390/s23125693.

40. Lekhak S., Ientilucci E., Brinkley T. Viability of substituting handheld metal detectors with an airborne metal detection system for landmine and unexploded ordnance detection // *Remote Sensing*. – 2024. – Vol. 16, No. 24. – Art. 4732. – DOI: 10.3390/rs16244732.

41. Fedorenko G., Fesenko H., Kharchenko V. Аналіз методів і розроблення концепції гарантованого виявлення та розпізнавання вибухонебезпечних предметів // *Innovative Technologies and Scientific Solutions for Industries*. – 2022. – No. 4(22). – P. 20–31. – DOI: 10.30837/ITSSI.2022.22.020.

42. Kunichik O. Landmine detection with a mobile application // *Eastern-European Journal of Enterprise Technologies*. – 2024. – DOI: 10.15587/1729-4061.2024.317103.

43. Galchonkov O., Baranov O., Antoshchuk S., Maslov O., Babilunga O., Shunin O. Using stacked ensemble classifiers to speed up object recognition in images for mine detection drones // *2024 IEEE 7th International Conference on Actual Problems of Unmanned Aerial Vehicles Development (APUAVD)*. – Kyiv, 2024. – P. 262–265. – DOI: 10.1109/APUAVD64488.2024.10765855.

44. Galchonkov O., Baranov O., Antoshchuk S., Maslov O., Babych M. Development of a neural network with a layer of trainable activation functions for the second stage of the ensemble classifier with stacking // *Eastern-European Journal of Enterprise Technologies*. – 2024. – Vol. 5, No. 4(131). – DOI: 10.15587/1729-4061.2024.311778.

45. Minhas S. F., Shah M. H., Khaliq T. Deep learning-based classification of anti-personnel mines and sub-gram metal content in mineralized soil // *Scientific Reports*. – 2024. – Vol. 14. – DOI: 10.1038/s41598-024-60592-8.

46. Lytvyn V., Peleshchak I., Vysotska V., Motyka V., Peleshchak R. Пасивний підхід до виявлення та класифікації мін із використанням магнітних полів і згорткових нейронних мереж // *Біоніка інтелекту*. – 2024. – № 1(100). – DOI: 10.30837/bi.2024.1(100).02.

47. Lameri S., Lombardi F., Bestagini P., Lualdi M., Tubaro S. Landmine detection from GPR data using convolutional neural networks // *2017 25th European*

Signal Processing Conference (EUSIPCO). – Kos, Greece : IEEE, 2017. – P. 508–512. – DOI: 10.23919/EUSIPCO.2017.8081259.

48. Mishchuk O., Fesenko H., Kharchenko V. Deep learning models for detection of explosive ordnance using autonomous robotic systems: trade-off between accuracy and real-time processing speed // Radioelectronic and Computer Systems. – 2024. – No. 4(112). – DOI: 10.32620/reks.2024.4.09.

49. Vivoli E., Bertini M., Capineri L. Deep learning-based real-time detection of surface landmines using optical imaging // Remote Sensing. – 2024. – Vol. 16, No. 4. – Art. 677. – DOI: 10.3390/rs16040677.

50. Застосування технологій штучного інтелекту у фізиці високих енергій. – Київ : КНУ ім. Т. Шевченка, 2024. – URL: https://atom.knu.ua/books/AI_in_HEP.pdf (дата звернення: 01.03.2026).

51. He Y., Xie Y., Yuan Z., Sun L. MLP-KAN: Unifying deep representation and function learning // arXiv preprint. – 2024. – arXiv:2410.03027.

52. Zheng Y., Shcherbakova G., Rusyn B., Sachenko A., Volkova N., Kliushnikov I., Antoshchuk S. Wavelet transform cluster analysis of UAV images for sustainable development of smart regions // Sustainability. – 2025. – Vol. 17, No. 3. – Art. 927. – DOI: 10.3390/su17030927.

53. 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 ВНТУ. – 2025. – № 3. – С. 27–36. – DOI: 10.31649/2307-5376-2025-3-27-36.

54. Galchonkov O., Horchynskyi O., Antoshchuk S., Nareznoy V. Semantic text splitting method development for RAG systems with controlled threshold and sliding window size // Eastern-European Journal of Enterprise Technologies. – 2025. – DOI: 10.15587/1729-4061.2025.326177.

55. Антощук С. Г., Іванова О. М. Метод формування стего-ключа для збільшення обсягу прихованого зберігання даних в середовищі програмного

коду FPGA // Вісник ХНТУ. – 2025. – № 1(92), ч. 2. – DOI: 10.35546/kntu2078-4481.2025.1.2.1.

56. Malizia M., Hamesse C., Hasselmann K., De Cubber G., Tsiogkas N., Demeester E., Haeltermann R. MineInsight: a multi-sensor dataset for humanitarian demining robotics in off-road environments. – 2024. – URL: <https://github.com/mariomlz99/mineinsight> (дата звернення: 01.03.2026).

57. Шунін О. Ю., Маслов О. В. Алгоритми та методи злиття мультисенсорних даних при виявленні аномалій з використанням БПЛА // Наука і техніка сьогодні. – 2026. – № 4(58). – С. 4832–4854. – DOI: 10.52058/2786-6025-2026-4(58)-4832-4854.

58. Інформаційне забезпечення дистанційного моніторингу забруднення ґрунтів повоєнних територій : монографія / С. Г. Антошук, М. О. Дрозд, О. В. Маслов, О. М. Галчонков, С. Б. Кондратьєв, О. Ю. Шунін, О. М. Баранов, Г. Ю. Щербакова, Д. В. Кошутіна, І. М. Баськов, В. Л. Костенко ; за ред. С. Г. Антошук. – Одеса, 2026. – ISBN 978-617-8814-10-6. – DOI: 10.5281/zenodo.20355627.

59. Shunin O., Maslov O. Investigation of metallic object classification using intelligent signal processing of electromagnetic pulse data : препринт. – Одеса : Нац. ун-т «Одеська політехніка», 2025. – Виконано в межах проекту НФДУ № 2023.04/0161. – Експериментальні дані: <https://github.com/op-uav-lab/soil-monitor-mlp>. – DOI: 10.5281/zenodo.20573976 (дата звернення: 07.06.2026).

60. Шунін О. Ю., Маслов О. В. Звіт з обробки даних з безпілотного апарата: лабораторні та польові вимірювання трикотушкового імпульсного металошукача : звіт про НДР. – Одеса : Нац. ун-т «Одеська політехніка», 2025. – Набір даних: <https://github.com/op-uav-lab/soil-monitor-mlp>. – DOI: 10.5281/zenodo.20573976 (дата звернення: 07.06.2026).

61. Shunin O. Antoshchuk S. G., Drozd M. O., Maslov O. V., Shunin O. Y. Multi-sensor UAV mission planning framework for environmental monitoring and humanitarian demining // Artificial Intelligence Technologies and Aerospace Issues III International Scientific-Practical Conference. – Baku, Azerbaijan, 2025.

62. Lee J., Lee H. Modeling residual magnetic anomalies of landmines using a UAV-borne vector magnetometer // *Remote Sensing*. – 2024. – Vol. 16, No. 16. – Art. 2916. – DOI: 10.3390/rs16162916.
63. Oguntoye K. S., Laflamme S., Sheng R. et al. Review of artificial intelligence applications for virtual sensing of underground utilities // *Sensors*. – 2023. – Vol. 23, No. 9. – Art. 4367. – DOI: 10.3390/s23094367.
64. Vivoli E., Bertini M., Capineri L. HoloMine: a synthetic dataset for buried landmines recognition using microwave holographic imaging // *arXiv preprint*. – 2025. – arXiv:2502.21054.
65. Gallagher J. E., Oughton E. J. Multi-temporal RGB and LWIR fusion for YOLO-based landmine detection // *arXiv preprint*. – 2025. – arXiv:2512.20487.
66. Galchonkov O., Baranov O., Chervonenko P., Babilunga O. Reducing the volume of computations when building analogs of neural networks for the first stage of an ensemble classifier with stacking // *Eastern-European Journal of Enterprise Technologies*. – 2024. – Vol. 2, No. 9(128). – P. 27–35. – DOI: 10.15587/1729-4061.2024.299734.
67. Schraml S., Hubner M., Taupe P., Hofstätter M., Amon P., Rothbacher D. Real-time gamma radioactive source localization by data fusion of 3D-LiDAR terrain scan and radiation data from semi-autonomous UAV flights // *Sensors*. – 2022. – Vol. 22, No. 23. – Art. 9198. – DOI: 10.3390/s22239198.
68. Werner F., Baumann D., Stadler M. et al. Compton camera based localization of radioactive sources on micro-UAV swarms // *2024 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*. – 2024. – DOI: 10.1109/IROS58592.2024.10802808.
69. Raissi M., Perdikaris P., Karniadakis G. E. Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations // *Journal of Computational Physics*. – 2019. – Vol. 378. – P. 686–707. – DOI: 10.1016/j.jcp.2018.10.045.
70. Drozd M., Drozd Y., Shunin O. Formation of synthetic image datasets for training neural network // *Problems of modern education and old technologies* :

abstracts of II International scientific and practical conference. – Zaragoza, Spain, 2025. – P. 63–69.

71. Маслов О. В., Шунін О. Ю. Використання дронів для забезпечення безпеки сільськогосподарських земель // Всеукраїнський науково-практичний форум «Штучний інтелект у тваринництві: майбутнє сьогодні», 9 травня 2025 р. – Київ, 2025. Матеріали наукової конференції -Всеукраїнський.

72. Maslov O., Antoshchuk S., Galchonkov O., Mokritskiy V., Shunin O. A digital twin of a landmine detector drone based on the prompt gamma neutron activation analysis method // Матеріали XXVII Міжнародної конференції «Автоматика 2024», 20–22 листопада 2024 р. – Дніпро, 2024. – С. 42. Proceedings of an All-Ukrainian scientific conference.

ДОДАТОК А

СПИСОК ПУБЛІКАЦІЙ ЗДОБУВАЧА

Наукові праці, в яких опубліковані основні наукові результати дисертації:

1. Information support for remote monitoring of soil contamination in post-war territories : monograph / Antoshchuk S. G., Drozd M. O., Maslov O. V., Galchonkov O. M., Kondratiev S. B., *Shunin O. Y.*, Baranov O. M., Shcherbakova G. Yu., Koshutina D. V., Baskov I. M., Kostenko V. L. ; ed. by S. G. Antoshchuk. Odesa, 2026. ISBN 978-617-8814-10-6. DOI: 10.5281/zenodo.20355627 (in Ukrainian). *Collective monograph.*

<https://zenodo.org/records/20355627>

2. *Shunin O. Y.*, Maslov O. V. Information model of remote sensing of soil. Herald of Advanced Information Technology. 2025. Vol. 8, No. 3. P. 352–365. DOI: 10.15276/hait.08.2025.23. *The journal is indexed by the Scopus database; included in the list of scientific professional publications of Ukraine.*

<https://doi.org/10.15276/hait.08.2025.23>

3. Drozd M. O., Drozd Y. V., *Shunin O. Y.* Effectiveness of neural network training on formed image sets with a given level of diversity. Science and Technology Today. 2025. No. 9(50). P. 1104–1123. DOI: 10.52058/2786-6025-2025-9(50)-1104-1123 (in Ukrainian). *The publication is included in the list of scientific professional publications of Ukraine, category “B”.*

[https://doi.org/10.52058/2786-6025-2025-9\(50\)-1104-1123](https://doi.org/10.52058/2786-6025-2025-9(50)-1104-1123)

4. *Shunin O. Y.*, Maslov O. V. Algorithms and methods of multisensor data fusion for anomaly detection using UAVs. Science and Technology Today. 2026. No. 4(58). P. 4832–4854. DOI: 10.52058/2786-6025-2026-4(58)-4832-4854 (in Ukrainian). *The publication is included in the list of scientific professional publications of Ukraine, category “B”.*

[https://doi.org/10.52058/2786-6025-2026-4\(58\)-4832-4854](https://doi.org/10.52058/2786-6025-2026-4(58)-4832-4854)

5. *Shunin O.*, Maslov O., Galchonkov O. Building a basic drone equipment set for conducting research to detect anomalies in soil. *International Science Journal of Engineering & Agriculture*. 2025. Vol. 4, No. 5. P. 13–26. DOI: 10.46299/j.isjea.20250405.02. *Foreign scientific periodical*.

<https://doi.org/10.46299/j.isjea.20250405.02>

Scientific works certifying the approbation of the dissertation materials:

6. Galchonkov O., Baranov O., Antoshchuk S., Maslov O., Babilunga O., *Shunin O.* Using stacked ensemble classifiers to speed up object recognition in images for mine detection drones. 2024 IEEE 7th International Conference on Actual Problems of Unmanned Aerial Vehicles Development (APUAVD). Kyiv, 2024. P. 262–265. DOI: 10.1109/APUAVD64488.2024.10765855. *The conference proceedings are indexed by the Scopus database*.

7. *Antoshchuk S. G., Drozd M. O., Maslov O. V., Shunin O. Y.* Multi-sensor UAV mission planning framework for environmental monitoring and humanitarian demining. Proceedings of the Artificial Intelligence Technologies and Aerospace Issues III International Scientific-Practical Conference. Baku, Azerbaijan, July 8–9, 2025. Proceedings of an international scientific conference.

8. Drozd M., Drozd Yu., *Shunin O.* Formation of synthetic image datasets for training neural network. Problems of modern education and old technologies : abstracts of the II International scientific and practical conference. Zaragoza, Spain, September 8–10, 2025. P. 63–69. *Proceedings of an international scientific conference*.

9. Maslov O., Antoshchuk S., Galchonkov O., Mokritskiy V., *Shunin O.* A digital twin of a landmine detector drone based on the prompt gamma neutron activation analysis method. Proceedings of the XXVII International Conference “Automatics 2024”, November 20–22, 2024. Dnipro (Ukraine). P. 42. Proceedings of an international scientific conference.

10. Maslov O. V., *Shunin O. Y.* The use of drones for ensuring the safety of agricultural lands. All-Ukrainian Scientific and Practical Forum “Artificial Intelligence

in Animal Husbandry: The Future Today”, May 9, 2025. Kyiv. Proceedings of an All-Ukrainian scientific conference.

ДОДАТОК Б АКТ ВИПРОБУВАННЯ ДИСЕРАТЦІЙНОГО ДОСЛІДЖЕННЯ НА ТОВ ВП «СПЕЦМОНТАЖ»

АКТ ВПРОВАДЖЕННЯ РЕЗУЛЬТАТІВ

ТОВ ВП «СПЕЦМОНТАЖ»

ТОВ ВП «Спецмонтаж»

65051, Одеська обл., м. Одеса, вул. Локомотивна, 40

Код ЄДРПОУ 22481572

+38050- 37-00-841



«ЗАТВЕРДЖУЮ»

Директор

Меньшутін О. В.

«24» квітня 2026 р.

АКТ

випробування результатів дисертаційного дослідження

Шуніна Олександра Юрійовича на тему:

«Нейромережеві методи виявлення аномалій у полях фізичних величин»

Розроблені в межах дисертаційного дослідження нейромережеві методи та інформаційні моделі виявлення аномалій у полях фізичних величин, що базуються на мультисенсорній БПЛА-платформі з імпульсно-індукційним, магнітометричним та мультиспектральним каналами вимірювань, були адаптовані до напрямів практичної діяльності ТОВ ВП «Спецмонтаж» та пройшли успішне випробування в умовах реального виробничого середовища.

Зокрема, перевірені методи нейромережевого аналізу сигналів імпульсного металошукача (PI-канал), алгоритми просторової прив'язки вимірювань на основі RTK-позиціонування без підключення до мережесервісів корекції, а також підхід до тензорного подання мультисенсорних даних $T(x, y, k)$ стали частиною ініціатив Підприємства, спрямованих на розвиток систем дистанційного обстеження та аналізу фізичних полів.

Ансамблева архітектура класифікатора на основі одновимірних згорткових нейронних мереж зі стекінгом забезпечила правильне виявлення металевих об'єктів на рівні $P_{\square} = 0,965$ при рівні хибних тривог $P_{\phi} \leq 0,05$ на незалежних польових даних. Результати підтверджують практичну цінність розроблених методів для задач виявлення прихованих об'єктів та геофізичного обстеження.

Результати випробування підтверджують можливість практичного застосування розроблених методів і моделей у завданнях Підприємства та засвідчують їх відповідність сучасним науково-технічним вимогам.

Директор ТОВ ВП «Спецмонтаж»



Меньшутін О. В.

ДОДАТОК В ДОВІДКА ПРО ВПРОВАДЖЕННЯ РЕЗУЛЬТАТІВ ДИСЕРТАЦІЙНОЇ РОБОТИ ТОВ «ОМ ЕНЕРДЖИ»

ДОВІДКА ПРО ВПРОВАДЖЕННЯ РЕЗУЛЬТАТІВ ДИСЕРТАЦІЙНОЇ РОБОТИ ТОВ «ОМ ЕНЕРДЖИ»

ДОВІДКА

про впровадження результатів дисертаційної роботи

Шуніна Олександра Юрійовича

Тема: «Нейромережеві методи при виявленні аномалій
у полях фізичних величин»

Довідка видана стосовно того, що у діяльності ТОВ «ОМ Енерджі» (м. Київ) використані результати, що отримані у дисертаційній роботі здобувача кафедри комп'ютерних наук Національного університету «Одеська Політехніка» МОН України Шуніним Олександром Юрійовичем.

Прийнято до впровадження:

– метод часового узгодження різнорідних вимірювальних потоків мультисенсорної БПЛА-платформи на основі апаратної прив'язки до спільного опорного сигналу супутникового приймача, що забезпечує суміщення вимірювань різної фізичної природи з еквівалентною просторовою похибкою 2–4 см без постоброблення;

– чотиривимірна модель поля аномалій $S(c, X, Y, t)$, що одночасно враховує канал приймання, просторові координати точки зондування та час релаксації відгуку, яка стала основою формування різницевих каналів та енергетичного подання РІ-даних;

– ансамблевий нейромережевий класифікатор на основі одновимірних згорткових мереж зі стекінгом, що реалізує виявлення та класифікацію аномалій безпосередньо на борту БПЛА-платформи у темпі надходження вимірювань ($P_n = 0,965$, $P_{\phi} \leq 0,05$ на польових даних);

– метод просторової прив'язки мультисенсорних вимірювань на основі автономного RTK-позиціонування без підключення до мережесервісів

корекції з точністю геоприв'язки 1–8 см поза зоною покриття наземної інфраструктури.

Запропоновані Шуніним Олександром Юрійовичем науково-технічні рішення дозволили підвищити ефективність систем дистанційного обстеження та аналізу фізичних полів, що проектується та використовуються на нашому підприємстві.

Очікуваний ефект має такі складові:

- підвищення точності та швидкодії виявлення аномалій за рахунок застосування нейромережових методів класифікації РІ-сигналів;
- скорочення часу геоприв'язки результатів обстеження завдяки автономному RTK-позиціонуванню без залежності від наземної інфраструктури корекції;
- можливість оперативної обробки мультисенсорних даних безпосередньо на борту платформи з формуванням геоінформаційних продуктів у реальному часі.

Директор з операційної
роботи ТОВ «ОМ Енерджі»  Чізолєні Г.Г.

ДОДАТОК Г

ЛІСТИНГ ПРОГРАМИ ПІДРОЗДІЛУ 5.1

```

import numpy as np
import matplotlib.pyplot as plt

from scipy.ndimage import gaussian_filter, binary_opening, binary_closing,
label, find_objects
from skimage.transform import resize

import tensorflow as tf
from tensorflow.keras import layers, models
from sklearn.model_selection import train_test_split
from sklearn.metrics import classification_report, confusion_matrix

def generate_radargram(
    height=180,
    width=320,
    anomalies=None,
    noise_level=0.08,
    horizontal_layers=True,
    seed=42
):
    """
    Формує демонстраційну георадарну радарограму.
    height - кількість відліків за глибиною/часом
    width - кількість трас уздовж профілю
    anomalies - список аномалій у форматі:
        {"x0": int, "z0": int, "amp": float, "curv": float, "width": int}
    """

    rng = np.random.default_rng(seed)
    radargram = rng.normal(0, noise_level, size=(height, width))

    if horizontal_layers:
        for z in [30, 65, 105, 145]:
            layer = np.exp(-(np.arange(height)[: , None] - z) ** 2) / (2 * 3.5
** 2))
            radargram += 0.18 * layer * (1 + 0.15 * rng.normal(size=(1, width)))

    if anomalies is None:
        anomalies = [
            {"x0": 90, "z0": 58, "amp": 1.10, "curv": 0.010, "width": 55},
            {"x0": 210, "z0": 92, "amp": 0.95, "curv": 0.008, "width": 65},
            {"x0": 265, "z0": 128, "amp": 0.75, "curv": 0.012, "width": 45},
        ]

```

```

x = np.arange(width)

for a in anomalies:
    x0 = a["x0"]
    z0 = a["z0"]
    amp = a["amp"]
    curv = a["curv"]
    w = a["width"]

    x_range = np.arange(max(0, x0 - w), min(width, x0 + w))

    for xi in x_range:
        z_curve = int(z0 + curv * (xi - x0) ** 2)
        if 0 <= z_curve < height:

            radargram[z_curve, xi] += amp

            for dz, scale in [(-2, 0.35), (-1, 0.65), (1, 0.65), (2, 0.35)]:
                zz = z_curve + dz
                if 0 <= zz < height:
                    radargram[zz, xi] += amp * scale

    return radargram

def remove_background(radargram):
    """
    Компенсація фонової складової.
    Віднімається середня траса, що відповідає стабільним відбиттям.
    """

    background = np.mean(radargram, axis=1, keepdims=True)
    corrected = radargram - background
    return corrected

def normalize_radargram(radargram):
    """
    Стандартизація амплітуд радарограми.
    """

    mean = np.mean(radargram)
    std = np.std(radargram) + 1e-8
    return (radargram - mean) / std

def preprocess_radargram(radargram):
    """
    Повний конвеєр попередньої обробки.

```

```

"""

corrected = remove_background(radargram)
filtered = gaussian_filter(corrected, sigma=1.0)
normalized = normalize_radargram(filtered)
return normalized

def local_energy_map(radargram, sigma=2.0):
    """
    Карта локальної енергії сигналу.
    Високі значення відповідають ділянкам з інтенсивними відбиттями.
    """

    energy = radargram ** 2
    energy = gaussian_filter(energy, sigma=sigma)
    return normalize_radargram(energy)

def segment_anomalies(energy, threshold=1.25):
    """
    Сегментація областей з підвищеною локальною енергією.
    """

    mask = energy > threshold

    mask = binary_opening(mask, structure=np.ones((2, 2)))
    mask = binary_closing(mask, structure=np.ones((4, 4)))

    labeled, num = label(mask)
    return labeled, num

def extract_candidates(radargram, labeled, min_area=25, patch_size=64):
    """
    Вирізає фрагменти навколо знайдених областей.
    Повертає:
    - patches: фрагменти для CNN
    - boxes: координати областей
    """

    objects = find_objects(labeled)
    patches = []
    boxes = []

    for idx, sl in enumerate(objects, start=1):
        if sl is None:
            continue

```

```

    z_slice, x_slice = sl
    z1, z2 = z_slice.start, z_slice.stop
    x1, x2 = x_slice.start, x_slice.stop

    area = np.sum(labeled[sl] == idx)
    if area < min_area:
        continue

    zc = (z1 + z2) // 2
    xc = (x1 + x2) // 2

    half = patch_size // 2

    zz1 = max(0, zc - half)
    zz2 = min(radargram.shape[0], zc + half)
    xx1 = max(0, xc - half)
    xx2 = min(radargram.shape[1], xc + half)

    patch = radargram[zz1:zz2, xx1:xx2]
    patch = resize(patch, (patch_size, patch_size), anti_aliasing=True)

    patches.append(patch)
    boxes.append((x1, z1, x2, z2))

if len(patches) == 0:
    return np.empty((0, patch_size, patch_size, 1)), []

patches = np.array(patches)[..., np.newaxis]
return patches, boxes

def generate_patch_dataset(n_samples=600, patch_size=64, seed=123):
    """
    Генерує демонстраційний набір фрагментів:
    клас 1 - гіперболічна аномалія
    клас 0 - фонова ділянка
    """

    rng = np.random.default_rng(seed)

    X = []
    y = []

    for i in range(n_samples):
        has_anomaly = i < n_samples // 2

        if has_anomaly:
            rg = generate_radargram(
                height=96,
                width=96,

```

```

        anomalies=[{
            "x0": rng.integers(35, 60),
            "z0": rng.integers(25, 55),
            "amp": rng.uniform(0.7, 1.3),
            "curv": rng.uniform(0.007, 0.015),
            "width": rng.integers(25, 42)
        }],
        noise_level=rng.uniform(0.05, 0.12),
        seed=rng.integers(0, 10_000)
    )
    label_value = 1
else:
    rg = generate_radargram(
        height=96,
        width=96,
        anomalies=[],
        noise_level=rng.uniform(0.05, 0.14),
        seed=rng.integers(0, 10_000)
    )
    label_value = 0

rg = preprocess_radargram(rg)
patch = resize(rg, (patch_size, patch_size), anti_aliasing=True)

X.append(patch)
y.append(label_value)

X = np.array(X)[..., np.newaxis].astype("float32")
y = np.array(y).astype("int32")

return X, y

def build_gpr_cnn(input_shape=(64, 64, 1)):
    """
    Компактна CNN для класифікації фрагментів радарограми.
    """
    model = models.Sequential([
        layers.Input(shape=input_shape),

        layers.Conv2D(16, (3, 3), padding="same", activation="relu"),
        layers.BatchNormalization(),
        layers.MaxPooling2D((2, 2)),

        layers.Conv2D(32, (3, 3), padding="same", activation="relu"),
        layers.BatchNormalization(),
        layers.MaxPooling2D((2, 2)),

        layers.Conv2D(64, (3, 3), padding="same", activation="relu"),

```

```

        layers.BatchNormalization(),
        layers.GlobalAveragePooling2D(),

        layers.Dense(32, activation="relu"),
        layers.Dropout(0.25),

        layers.Dense(1, activation="sigmoid")
    ])

    model.compile(
        optimizer=tf.keras.optimizers.Adam(learning_rate=1e-3),
        loss="binary_crossentropy",
        metrics=["accuracy", tf.keras.metrics.Precision(),
tf.keras.metrics.Recall()]
    )

    return model

X, y = generate_patch_dataset(n_samples=700, patch_size=64, seed=7)

X_train, X_test, y_train, y_test = train_test_split(
    X, y,
    test_size=0.25,
    random_state=42,
    stratify=y
)

model = build_gpr_cnn(input_shape=(64, 64, 1))

history = model.fit(
    X_train,
    y_train,
    validation_split=0.2,
    epochs=8,
    batch_size=32,
    verbose=1
)

y_prob = model.predict(X_test).ravel()
y_pred = (y_prob >= 0.5).astype(int)

print("\nМатриця помилок:")
print(confusion_matrix(y_test, y_pred))

print("\nЗвіт класифікації:")
print(classification_report(y_test, y_pred, target_names=["Фон", "Аномалія"]))

radargram_raw = generate_radargram(seed=101)
radargram_processed = preprocess_radargram(radargram_raw)

```

```

energy = local_energy_map(radargram_processed, sigma=2.0)
labeled, num_regions = segment_anomalies(energy, threshold=1.25)

patches, boxes = extract_candidates(
    radargram_processed,
    labeled,
    min_area=25,
    patch_size=64
)

print(f"\nЗнайдено кандидатних областей: {len(boxes)}")

if len(patches) > 0:
    candidate_probs = model.predict(patches).ravel()
else:
    candidate_probs = np.array([])

def plot_results(radargram_raw, radargram_processed, energy, boxes, probs,
prob_threshold=0.5):
    fig, axes = plt.subplots(1, 3, figsize=(18, 5))

    axes[0].imshow(radargram_raw, cmap="gray", aspect="auto")
    axes[0].set_title("Сира радарограма")
    axes[0].set_xlabel("Профіль сканування")
    axes[0].set_ylabel("Час / умовна глибина")

    axes[1].imshow(radargram_processed, cmap="gray", aspect="auto")
    axes[1].set_title("Після попередньої обробки")
    axes[1].set_xlabel("Профіль сканування")

    axes[2].imshow(energy, cmap="hot", aspect="auto")
    axes[2].set_title("Карта локальної енергії та аномалії")
    axes[2].set_xlabel("Профіль сканування")

    for (box, p) in zip(boxes, probs):
        x1, z1, x2, z2 = box

        if p >= prob_threshold:
            rect_color = "cyan"
            label_text = f"{p:.2f}"
        else:
            rect_color = "white"
            label_text = f"{p:.2f}"

        axes[2].plot(
            [x1, x2, x2, x1, x1],
            [z1, z1, z2, z2, z1],
            color=rect_color,
            linewidth=2
        )

```

```

        axes[2].text(
            x1,
            max(0, z1 - 3),
            label_text,
            color=rect_color,
            fontsize=9
        )

plt.tight_layout()
plt.show()

plot_results(
    radargram_raw,
    radargram_processed,
    energy,
    boxes,
    candidate_probs,
    prob_threshold=0.5
)

plt.figure(figsize=(8, 4))
plt.plot(history.history["loss"], label="Навчальна втрата")
plt.plot(history.history["val_loss"], label="Валідаційна втрата")
plt.xlabel("Епоха")
plt.ylabel("Loss")
plt.title("Динаміка навчання CNN-модуля")
plt.legend()
plt.grid(True)
plt.show()

```

ДОДАТОК Д

ЛІСТИНГ ПРОГРАМИ ПІДРОЗДІЛУ 5.2

```

import numpy as np
import pandas as pd
import matplotlib.pyplot as plt

from scipy.interpolate import griddata
from scipy.ndimage import gaussian_filter
from scipy.ndimage import maximum_filter
from scipy.ndimage import label

from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Conv2D
from tensorflow.keras.layers import MaxPooling2D
from tensorflow.keras.layers import Dense
from tensorflow.keras.layers import Flatten
from tensorflow.keras.layers import Dropout

np.random.seed(42)

n_points = 2500

x = np.random.uniform(0, 100, n_points)
y = np.random.uniform(0, 100, n_points)

background = 50000

field = background + np.random.normal(0, 5, n_points)

field += 120 * np.exp(
    -((x - 35)**2 + (y - 45)**2) / 150
)

field += 180 * np.exp(
    -((x - 70)**2 + (y - 75)**2) / 120
)

grid_x, grid_y = np.mgrid[
    0:100:200j,
    0:100:200j
]

grid_field = griddata(
    (x, y),
    field,
    (grid_x, grid_y),
    method='cubic'
)

```

```

grid_field = np.nan_to_num(grid_field)

background_map = gaussian_filter(
    grid_field,
    sigma=20
)

anomaly_map = grid_field - background_map

anomaly_map = (
    anomaly_map - anomaly_map.mean()
) / anomaly_map.std()

maxima = maximum_filter(
    anomaly_map,
    size=15
)

mask = (
    anomaly_map == maxima
) & (
    anomaly_map > 2.0
)

labels, count = label(mask)

print(
    f"Виявлено аномалій: {count}"
)

plt.figure(figsize=(10,8))

plt.imshow(
    anomaly_map,
    cmap='jet',
    origin='lower'
)

plt.colorbar(
    label='Магнітна аномалія'
)

plt.title(
    'Карта магнітних аномалій'
)

plt.show()

model = Sequential()

```

```
model.add(
    Conv2D(
        16,
        (3,3),
        activation='relu',
        input_shape=(64,64,1)
    )
)

model.add(
    MaxPooling2D((2,2))
)

model.add(
    Conv2D(
        32,
        (3,3),
        activation='relu'
    )
)

model.add(
    MaxPooling2D((2,2))
)

model.add(
    Flatten()
)

model.add(
    Dense(
        64,
        activation='relu'
    )
)

model.add(
    Dropout(0.3)
)

model.add(
    Dense(
        1,
        activation='sigmoid'
    )
)

model.compile(
    optimizer='adam',
    loss='binary_crossentropy',
    metrics=['accuracy']
)
```

)

`model.summary()`

ДОДАТОК Е

ЛІСТИНГ ПРОГРАМИ ПІДРОЗДІЛУ 5.3

```

import numpy as np
import matplotlib.pyplot as plt

from scipy.ndimage import gaussian_filter
from scipy.ndimage import median_filter
from scipy.signal import find_peaks

from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Conv2D
from tensorflow.keras.layers import MaxPooling2D
from tensorflow.keras.layers import Flatten
from tensorflow.keras.layers import Dense
from tensorflow.keras.layers import Dropout

rows = 256
cols = 400

radargram = np.random.normal(0, 0.1, (rows, cols))

def hyperbola(img, x0, y0, a, amp):

    for x in range(cols):

        y = int(y0 + ((x - x0) ** 2) / a)

        if 0 <= y < rows:

            img[y-2:y+3, x] += amp

hyperbola(radargram, 120, 70, 180, 3.0)
hyperbola(radargram, 260, 110, 220, 2.5)

background = radargram.mean(axis=1)

radargram = radargram - background[:, None]

radargram = gaussian_filter(radargram, sigma=1)
radargram = median_filter(radargram, size=3)

energy = radargram ** 2

profile = energy.max(axis=0)

peaks, _ = find_peaks(
    profile,
    distance=40,

```

```

        prominence=np.std(profile)
    )

    print("Знайдено кандидатів:", len(peaks))

    plt.figure(figsize=(12,6))

    plt.imshow(
        radargram,
        cmap='gray',
        aspect='auto'
    )

    for p in peaks:
        plt.axvline(
            p,
            color='red',
            linestyle='--'
        )

    plt.title("Виявлені вершини гіпербол")
    plt.xlabel("Профіль сканування")
    plt.ylabel("Час")
    plt.show()

    model = Sequential()

    model.add(
        Conv2D(
            32,
            (3,3),
            activation='relu',
            input_shape=(64,64,1)
        )
    )

    model.add(
        MaxPooling2D((2,2))
    )

    model.add(
        Conv2D(
            64,
            (3,3),
            activation='relu'
        )
    )

    model.add(
        MaxPooling2D((2,2))
    )

```

```
model.add(
    Flatten()
)

model.add(
    Dense(
        128,
        activation='relu'
    )
)

model.add(
    Dropout(0.4)
)

model.add(
    Dense(
        1,
        activation='sigmoid'
    )
)

model.compile(
    optimizer='adam',
    loss='binary_crossentropy',
    metrics=['accuracy']
)

model.summary()
```