

Захожай О.І., Коррель В.В.

## КОМПЛЕКСНІ СИСТЕМИ ПОШУКУ МЕТАЛЕВИХ ОБ'ЄКТІВ: ВІД ДВОКАНАЛЬНОЇ ЛОГІКИ ДО БАГАТОСЕНСОРНОГО АНАЛІЗУ З МАШИННИМ НАВЧАННЯМ

*У статті представлено еволюційний аналіз методів виявлення та ідентифікації підповерхневих металевих об'єктів. Робота починається з розгляду базової двоканальної системи, що поєднує магнітометричний градієнтометр для виявлення феромагнітних цілей та імпульсний металодетектор для реєстрації всіх провідних об'єктів. Детально описано концепцію спільної обробки даних на основі жорстких логічних правил та вагової суми, що дозволяє проводити первинну класифікацію цілей та знижувати кількість хибних спрацьовувань. Далі в статті розкрито неминучі обмеження такого підходу при спробі масштабування та додавання нових каналів даних (напр., георадара). Продемонстровано, що зі зростанням кількості сенсорів ці методи є надмірно складними та неефективними. Як розв'язання цієї проблеми пропонується перехід до парадигми машинного навчання. Описано методологію побудови багатоканальних систем, що використовують алгоритми класифікації (нейронні мережі, метод опорних векторів) для аналізу багатомірних даних. Розглянуто практичні етапи: від збору навчальних даних на тестових полігонах до видобуття ознак та застосування навченої моделі для імовірнісної класифікації об'єктів у реальному часі..*

**Ключові слова:** магнітометр, імпульсний металодетектор, георадар, спільна обробка даних, багатоканальні системи, машинне навчання, класифікація об'єктів, нейронні мережі, sensor fusion.

**Вступ.** Завдання виявлення, локалізації та ідентифікації прихованих металевих об'єктів залишається ключовим у багатьох прикладних галузях, від археології та інженерної геології до гуманітарного розмінування. Традиційні підходи з використанням одного типу сенсора (магнітометра або металодетектора) мають суттєві обмеження, пов'язані або з вузьким класом матеріалів, що виявляються, або з високою кількістю хибних спрацьовувань. [1]

Логічним кроком у розвитку таких систем стало об'єднання двох різних фізичних методів в одній платформі. Це дозволяє отримати два незалежні канали даних про підповерхневий об'єкт, що, при спільній обробці, підвищує достовірність та інформативність пошуку. Однак сучасні виклики вимагають ще більшої точності та деталізації, що спонукає до інтеграції ще більшої кількості сенсорів.

Метою цього дослідження є послідовний розгляд еволюції підходів: від аналізу простої та ефективної двоканальної системи, з застосуванням простих методів, до демонстрації її обмежень та обґрунтування необхідності переходу до складних багатосенсорних платформ, аналіз даних в яких можливий лише за допомогою методів машинного навчання.

### Аналіз питання та постановка завдання.

Пошук, локалізація та, що найважливіше, ідентифікація підповерхневих металевих об'єктів є критично важливим завданням у широкому спектрі галузей. В археології це дозволяє відрізнити цінні артефакти від сучасного сміття. В інженерній геофізиці – знаходити комунікації та небезпечні предмети перед початком будівництва. У гуманітарному розмінуванні ефективність та точність ідентифікації безпосередньо впливають на безпеку та швидкість очищення територій. [1]

Традиційні підходи, що спираються на використання одного типу сенсора, стикаються з фундаментальними обмеженнями, які суттєво знижують їхню ефективність.

1) Магнітометрія. Ці прилади, що вимірюють локальні збурення магнітного поля Землі, ефективні лише для феромагнітних об'єктів (залізо, сталь). Вони не здатні виявити об'єкти з кольорових металів (мідь, алюміній, латунь). Більше того, їхня робота ускладнюється через високий рівень завад [1, 4]. Так геологічний шум, коли природні варіації магнітних властивостей ґрунтів та порід (наприклад, ґрунти з високим вмістом магнетиту, виходи магматичних порід) створюють аномалії, які важко відрізнити від сигналу шуканого об'єкта. Промислові та міські завади, пов'язані з лініями електропередач, трубопроводами, залізобетонними конструкціями створюють потужний фон, на якому губиться корисний сигнал.

2) Електромагнітна індукція (металодетектори). Ці прилади, що реєструють відгук від вихрових струмів, здатні виявляти всі провідні об'єкти. Однак це є одночасно і перевагою, і недоліком. Головною проблемою стає надзвичайно високий рівень хибних спрацьовувань (False Alarm Rate, FAR). Система реагує на будь-який металевий фрагмент — цвяхи, фольгу, уламки, кришки від пляшок — так само, як і на цільовий об'єкт. В умовах засмічених територій кількість хибних спрацьовувань може перевищувати кількість реальних цілей у сотні разів, що робить процес пошуку надзвичайно повільним та неефективним. [1,5]

Ці обмеження призводять до значних економічних та часових втрат, а в критичних застосуваннях, як-от розмінування, — до підвищених ризиків. Таким чином, актуальним науково-технічним завданням є перехід від простого виявлення "металевої аномалії" до її надійної класифікації ще до початку земляних робіт [1]

3) Виходячи з вищезазначеного, метою даної роботи є розробка та обґрунтування комплексної методології обробки даних, спрямованої на підвищення ймовірності правильного виявлення (Pd) та класифікації цілей при одночасному радикальному зниженні рівня хибних спрацьовувань (FAR). [1,5]

Для досягнення цієї мети завдання було декомпоновано на два послідовні етапи:

1. Розробити та всебічно проаналізувати базову двоканальну систему, що інтегрує магнітометричний та індукційний сенсори. Необхідно формалізувати алгоритм спільної обробки даних на основі запропонованих простих методів, оцінити їх переваги порівняно з односенсорними підходами та, що найважливіше, чітко визначити його теоретичні та практичні обмеження.

2. Запропонувати та детально описати масштабовану методологію для багатоканальних систем (більше двох сенсорів), яка б долала обмеження простих методів. Ця методологія має базуватися на сучасних методах аналізу даних, забезпечувати обробку складних багатовимірних інформаційних потоків та надавати оператору деталізовану ймовірнісну класифікацію виявлених підповерхневих об'єктів.

**Вирішення завдання.** Вирішення поставленого завдання було виконано шляхом послідовного проектування та аналізу двох систем різного рівня складності.

*Етап 1. Двоканальна система: концепція та аналіз.*

На першому етапі було спроектовано та проаналізовано систему, що є логічним кроком еволюції від односенсорних приладів. Було розглянуто практичне злиття даних для системи, що використовує два магнітометри Matek RM3100 (двосенсорний градієнтометр, 2× RM3100), які розташовуються на мачті, нижній 10 см від землі та верхній по одній осі на висоті 50см від першого та PI-металодетектор Tracker-2 із 5-рівневою індикацією, котушка якого розташована на відстані 20см за магнітометрами позаду. Канали фізично незалежні (магнітна індукція vs. провідність), тому їхні помилки слабо корелюють; коректне злиття підвищує ймовірність виявлення й знижує хибні спрацьовування. [1, 3, 17]

Архітектура системи. Система складається з двох фізично поєднаних, але інформаційно незалежних каналів.

Канал 1: Магнітометричний градієнтометр. Використовує два магнітометричні сенсори, рознесені по вертикалі на фіксовану базу. Вимірюючи різницю магнітного поля, система розраховує градієнт. Ця конфігурація дозволяє ефективно придушувати віддалені (синфазні) джерела шуму, такі як добові варіації поля Землі, і виділяти лише локальні аномалії від близьких феромагнітних джерел. [1, 3, 9]

Магнітометр дає 3 компоненти вектора магнітної індукції  $\mathbf{B} = (B_x, B_y, B_z)$  у мікротеслах ( $\mu\text{T}$ ). У градієнтометрі два сенсори: нижній (ближче до ґрунту) та верхній (вище). Ми беремо їх різницю: [1]

$$\Delta\mathbf{B}(t) = \mathbf{B}_{\text{низ}}(t) - \mathbf{B}_{\text{верх}}(t), |\Delta\mathbf{B}| = \sqrt{(\Delta B_x)^2 + (\Delta B_y)^2 + (\Delta B_z)^2}.$$

Щоби сумістити різні ознаки в одній шкалі використовуємо робастне нормування до  $[0,1]$ . Це робастне приведення сигналу до шкали  $[0;1]$  стійке до викидів, де "мінімум" і "максимум" беруться не як реальні мін/макс, а як нижній і верхній перцентилі (наприклад,  $P_{10}$  і  $P_{95}$ ) лише по останніх 20–30 секундах даних. Так система автоматично підлаштовується під локальний фон ґрунту та шум.

Беремо у кожному вікні 20–30 с перцентилі  $P_{10}$  і  $P_{95}$  та масштабуємо:

$$\hat{M} = \text{clip}\left(\frac{|\Delta\mathbf{B}| - P_{10}}{P_{95} - P_{10} + \varepsilon}, 0, 1\right)$$

Канал 2: Імпульсний металодетектор (PI). Генерує короткі потужні імпульси первинного магнітного поля, які наводять вихрові струми у провідних об'єктах. Після вимкнення імпульсу система реєструє вторинне магнітне поле, що створюється цими затухаючими струмами. Форма кривої затухання сигналу несе інформацію про провідність та розмір будь-якого металевого об'єкта. Якщо доступний лише рівень ламп тоді це дискретна оцінка сили PI-відгуку. Прилад видає рівень  $D_{\text{lvl}} \in \{0,1,2,3,4,5\}$ .

$D_{\text{lvl}}$  – безрозмірний рівень 0..5. Тоді нормоване значення:

$$\hat{D} = \frac{D_{\text{lvl}}}{5} \in [0,1]$$

Якщо є розширені ознаки (сирій сигнал після імпульсу) тоді можна додатково брати амплітуду  $A_0$ , постійну часу затухання  $\tau$  та зробити їхній зважений композит і потім також нормувати до  $[0,1]$ .

Для вирішення завдання вибрані наступні методи обробки даних.

1. Базове й надійне злиття - вагова сума (feature-level). Це метод низького рівня, який працює безпосередньо із сирими або мінімально обробленими сигналами від сенсорів. Суть методу полягає в тому, що кожному каналу (сенсору) надається певний "коефіцієнт довіри" або вага. Підсумкове рішення є простою сумою сигналів від кожного сенсора, помножених на їхні вагові коефіцієнти.

$$S = w_M \hat{M} + w_D \hat{D}, w_M + w_D = 1.$$

Нехай  $q_M, q_D \in [0,1]$  (оцінки SNR/стабільності/відсутності насичення). Тоді вагові коефіцієнти будуть визначатися так:

$$w_M = \frac{q_M}{q_M + q_D}, \quad w_D = \frac{q_D}{q_M + q_D}.$$

В цьому випадку при пошуку залізного предмету сигнал від магнітометра  $\hat{M}$  є дуже важливим, а від імпульсного металодетектора  $\hat{D}$  — підтверджуючим. Можна надати їм ваги:  $w_M = 0.7$ ,  $w_D = 0.3$ . При вимірюваннях були отримані значення  $\hat{M} = 0.65$ ,  $\hat{D} = 0.35$  і тоді  $S = 0.7 \cdot 0.65 + 0.3 \cdot 0.35 = 0.56$ , а це упевнена аномалія ( $\approx L$  3 із 5)

Переваги цього методу:

- простота реалізації;
- швидкість, що забезпечує мінімазацію обчислень і дозволяє працювати в реальному часі;
- гарна схожість методу та зрозумілість критеріїв, так як ваги підбираються експертним шляхом;

Недоліки цього методу:

- негнучкість, яка викликана фіксованими значеннями вагів, які не адаптуються до зміни умов.
- Обмеженість, так як отримується лише одне числове значення, а не класифікація об'єкта.
- Не забезпечує однозначного результату, якщо сенсори дають суперечливу інформацію.

2. Прості логічні правила (швидка типізація). Це метод середнього рівня, який працює не з сирими сигналами, а з їхньою інтерпретацією або "станами" (напр., "сигнал є / сигналу немає"). Сутність методу в тому, що створюється набір правил у форматі "ЯКЩО ... ТО ... ІНАКШЕ ..." і надалі система працює як блок-схема або дерево рішень, швидко відкидаючи або підтверджуючи гіпотези.

4) Після нормування задаємо пороги  $\theta_M, \theta_D$  (зручно брати  $P_{90}$  на «чистій» смузі) [1,5].

- Якщо  $\hat{M} > \theta_M$  і  $\hat{D} > \theta_D \rightarrow$  феромагнітний провідник (сталь: і магнітиться, і проводить).
- Якщо  $\hat{M} \leq \theta_M$  і  $\hat{D} > \theta_D \rightarrow$  неферомагнітний провідник (мідь/алюміній/кабель).
- Якщо  $\hat{M} > \theta_M$  і  $\hat{D} \leq \theta_D \rightarrow$  глибокий/слабопровідний феромагніт (крупний або кородований).

Переваги цього методу:

- істотно висока швидкість, так як логічні операції є найшвидшими для мікропроцесора;
- інтерпретованість, так як правила зрозумілі людині, їх легко створювати та коригувати;
- ідеально підходить для швидкої типізації, так як дозволяє миттєво віднести об'єкт до однієї з кількох великих категорій.

Недоліки цього методу:

- крихкість, так як система не працює з невизначеністю і приймаються тільки порогові значення "сигнал є", або "сигналу немає", а проміжні значення ігноруються;
- проблема масштабування, так як при додаванні 3-го чи 4-го сенсора кількість правил зростає експоненціально ("комбінаторний вибух"), і система стає надто складною. [5, 7]

*Етап 2. Багатоканальна система, перехід до інтелектуального аналізу*

Для подолання виявлених обмежень був запропонований перехід до нової парадигми, що базується на об'єднанні даних (sensor fusion) більш складними, адаптивними методами. [7,13 ]

Пропонується модульна платформа, що може інтегрувати дані від різноманітних сенсорів:

- магнітометричний градієнтметр (канал магнітних властивостей) [1, 4];
- імпульсний металодетектор (канал провідності) [3];
- Георадар (канал діелектричної проникності, форми та структури) [7];
- Багаточастотний ЕМІ-сенсор (канал для детальної оцінки провідності та магнітної сприйнятливості) [6].

Для вирішення завдання існують такі методи обробки даних:

1. Імовірнісні підходи (Байєсівський висновок, Фільтр Калмана) [12]. Ці методи працюють не з жорсткими правилами, а з імовірностями, що дозволяє їм краще обробляти невизначені та зашумлені дані.

Байєсівський висновок. Дозволяє динамічно оновлювати ймовірність того, що об'єкт належить до певного класу, по мірі надходження нових даних від кожного сенсора. Це потужний інструмент для роботи в умовах невизначеності. В основі методу лежить теорема Томаса Байєса [9]

$$P(A | B) = \frac{P(B | A) * P(A)}{P(B)},$$

де А – це гіпотеза, яку потрібно перевірити, наприклад: "Під землею знаходиться міна";

В – це доказ або нові дані, які були отримані від сенсора. Наприклад: "Магнітометр зафіксував сильну магнітну аномалію" [1, 4];

$P(A)$  – апіорна ймовірність (Prior Probability), ймовірність того, що гіпотеза (А) є правильною, до отримання будь-яких нових доказів (В), наприклад, "ймовірність знайти міну на цій ділянці зазвичай дуже низька", скажімо,  $P(A) = (0.1\%)$ ;

$P(B | A)$  – ймовірність правдоподібності (Likelihood) або ймовірність отримати доказ (B) за умови, що гіпотеза (A) є правильною, наприклад, якщо під землею дійсно міна, то ймовірність того, що магнітометр покаже сильну аномалію висока, скажімо, (95%);

$P(B)$  – повна ймовірність доказу (Marginal Likelihood), тобто повна ймовірність зафіксувати доказ (B) за будь-яких умов (незалежно від того, правильна гіпотеза чи ні), наприклад, загальна ймовірність того, що магнітометр покаже сильну аномалію на цій ділянці. Сигнал може бути не тільки від міни (гіпотеза A), але і від будь-якого іншого залізного сміття, наприклад, великого цвяха (гіпотеза "не A"). Розраховується за формулою повної ймовірності:  $P(B)=P(B|A) \cdot P(A)+P(B|\text{не } A) \cdot P(\text{не } A)$ . Це найскладніша частина, але вона є нормалізуючим коефіцієнтом. [1, 1]

$P(A | B)$  – апостеріорна ймовірність (Posterior Probability), яку як раз і потрібно знайти. Ймовірність того, що гіпотеза (A) є правильною, після того, як було отримано доказ (B). Наприклад, ймовірність, що під землею міна, після того, як магнітометр показав сильну аномалію.

Після застосування формули впевненість у тому, що об'єкт є міною, зростає з 0.1% до 1.87%. Це все ще низька ймовірність, але вона в 18.7 разів вища, ніж була до отримання даних від магнітометра!

В багатоканальній системі цей процес ітеративний. Отриманий результат (апостеріорна ймовірність 1.87%) стає новою апіорною ймовірністю для наступного сенсора. Далі береться сигнал від імпульсний металодетектора, і він дає сигнал, характерний для великого об'єкта правильної форми (новий доказ C). Далі знову застосовується теорема Баєса, але тепер  $P(A)=0.0187$  і розраховується  $P(A | C)$ , що може підняти впевненість, наприклад, до 60-70%. Таким чином, кожен сенсор додає свій внесок, послідовно уточнюючи гіпотезу. [3, 9]

Фільтр Калмана. Є стандартом для задач трекінгу – відстеження рухомих об'єктів. Для завдання пошуку статичних об'єктів він менш релевантний, але є ключовим у навігації та робототехніці. [12]

Ці підходи є потужними, але для класифікації об'єктів зі складною та нелінійною залежністю сигналів найкращим рішенням є машинне навчання. [1, 7]

2. Машинне навчання (ML) як найпотужніший метод класифікації [1, 7]. Цей підхід є вирішенням другої частини завдання. Замість того, щоб програмувати правила вручну, модель (наприклад, нейронна мережа) самостійно вивчає складні патерни, що притаманні різним класам об'єктів, на основі великого набору даних. [1, 7]

Переваги машинного навчання:

- найвища точність, здатність знаходити складні, нелінійні залежності, недоступні для простих методів;
- масштабованість, коли додавання нового сенсора лише додає нові входи до моделі, не вимагаючи перебудови всієї логіки;
- адаптивність, за рахунок того, що модель може бути перенавчена або донавчена на нових даних, адаптуючись до нових умов чи типів об'єктів.

Недоліки машинного навчання:

- потреба у великій кількості даних, при тому, що збір та розмітка якісних даних це найдорожчий та найтриваліший етап.
- ефект "чорної скриньки" (Black Box), особливо для нейронних мереж, іноді важко зрозуміти, чому саме модель прийняла те чи інше рішення [1, 7];
- обчислювальна складність, тому що навчання великих моделей потребує значних ресурсів (потужних комп'ютерних систем).

Існує три головні напрямки ML.

1) Навчання з учителем (Supervised Learning). Це найпоширеніший тип. Моделі даються марковані дані - тобто, приклади, де правильна відповідь вже відома. Треба навчити модель передбачати правильну відповідь для нових, небачених раніше даних. На прикладі поставленої задачі показуємо моделі тисячі сигналів від сенсорів (репрезентативні дані) і зазначаємо відповідь, яка є відповідною для такого набору (мітка/відповідь).

Типи задач для яких використовується цей підхід:

- класифікація, яка пов'язана з віднесенням об'єкту до однієї з кількох категорій (напр., "міна", "осколок", "цвях");
- регресія, що базується на передбаченні числового значення (наприклад, глибину залягання об'єкта в сантиметрах);

2) Навчання без учителя (Unsupervised Learning).

Тут моделі надаються немарковані дані і ставиться задача самостійно знайти в них якусь структуру чи закономірності. Такий підхід може бути використаний, наприклад, для групування схожих об'єктів, пошуку аномалії тощо. В прикладі близькому до задачі, що вирішується можна представити моделі дані з великої ділянки і попросити її згрупувати всі наявні аномалії в кластери. Можливо, вона сама виділить групу "великі глибокі об'єкти" та "дрібні поверхневі об'єкти", навіть не знаючи, що це таке.

3) Навчання з підкріпленням (Reinforcement Learning).

Модель навчається, взаємодіючи з середовищем і отримуючи "нагороди" за правильні дії та "штрафи" за неправильні. Цей метод доцільно використовувати для задач розробки оптимальної стратегії поведінки.

В прикладі близькому до задачі, що вирішується, це навчання робота-сапера найефективніше сканувати територію, щоб максимізувати кількість знайдених об'єктів за мінімальний час.

Серед розглянутих трьох підходів до реалізації методів машинного навчання, для задачі, що вирішується, доцільне застосування саме першого підходу навчання з учителем. Розглянемо практичний процес розробки ML-системи з учителем.

Процес створення моделі для ідентифікації об'єктів складається з кількох ключових етапів.

1. Збір даних (Data Collection);
2. Видобуття та підготовка ознак (Feature Engineering);
3. Вибір та навчання моделі (Model Training);
4. Оцінка та валідація (Evaluation).
5. Розгортання та моніторинг (Deployment)

Перший етап є фундаментом усього проекту. Необхідно створити велику та різноманітну навчальну вибірку. Для цього на тестовому полігоні збирають тисячі "знімків" аномалій від різних об'єктів (міни, снаряди, гільзи, цвяхи, фольга) на різній глибині, в різних орієнтаціях та типах ґрунту. Чим якісніші та різноманітніші дані, тим розумнішою буде модель.

На другому етапі необроблені дані з сенсорів (типу "масив чисел"), як правило, не подаються в модель напряму. Їх перетворюють на інформативні ознаки (features) – конкретні числові характеристики, такі як:

- дані від магнітометра: амплітуда аномалії, її ширина, коефіцієнт асиметрії;
- дані від PI-детектора: амплітуда відгуку, швидкість затухання сигналу (константа), співвідношення сигналу на ранніх та пізніх стадіях [2];
- дані від георадара: глибина відбиття, яскравість гіперболи, її ширина. В результаті кожен об'єкт описується вектором чисел: [150.5, 0.8, -0.2, 120.1, 15.3, ...] [7].

На третьому етапі підготовлені дані (вектори ознак та правильні мітки) подаються на вхід алгоритму. Алгоритм налаштовує свої внутрішні параметри так, щоб найкращим чином "проводити лінію" між різними класами об'єктів у багатовимірному просторі ознак. Алгоритми бувають такі:

- випадковий ліс (Random Forest): створює сотні простих "дерев рішень" і усереднює їхні прогнози. Це надійний та стійкий до шумів алгоритм;
- метод опорних векторів (SVM): шукає оптимальну "межу" (гіперплощину), яка найкращим чином розділяє дані різних класів.

- нейронні мережі: є набором з'єднаних між собою "нейронів", які навчаються розпізнавати дуже складні патерни. Це найпотужніший, але й найскладніший інструмент. Вони можуть навіть пропускати етап видобуття ознак, працюючи безпосередньо з 2D-картами аномалій. [1, 7]

На четвертому етапі, після навчання, модель потрібно перевірити на даних, яких вона ніколи не бачила (тестова вибірка). Це дозволяє об'єктивно оцінити її точність. Ключові метрики при цьому:

- Accuracy – загальний відсоток правильних відповідей;
- Precision (Точність) – Який відсоток об'єктів, названих моделлю "міною", дійсно є мінами;
- Recall (Повнота) – який відсоток всіх реальних мін, що були в землі, модель змогла знайти.

На наступному, п'ятому етапі, якщо модель показує хороші результати, її вбудовують у програмне забезпечення пошукового приладу. Вона починає працювати в реальному часі, надаючи оператору класифікацію виявлених аномалій. Навчена модель інтегрується в програмне забезпечення приладу. Під час польових робіт система в реальному часі збирає дані, виділяє ознаки та подає їх на вхід моделі. Результатом є не просто "сигнал", а імовірнісна класифікація для оператора: "Об'єкт на глибині 1.2 м. Імовірність: Снаряд – 89%, Фрагмент труби – 10%, Інше – 1%".

Цей підхід повністю вирішує проблему масштабованості - додавання нового сенсора лише збільшує розмірність вектора ознак, що для моделі машинного навчання не є проблемою, а навпаки, часто покращує якість класифікації. Серед перерахованих методів навчання пропонується вибрати нейронні мережі, так як це найпотужніший інструмент у машинному навчанні, архітектура якого натхненна будовою людського мозку. На відміну від інших методів, де ми все ще допомагаємо машині, виділяючи для неї ознаки (features), нейронні мережі здатні вчитися безпосередньо із сирих даних (зображень, звуку, масивів чисел), самостійно знаходячи найважливіші патерни. [1, 7] В основі будь-якої мережі лежить штучний нейрон (перцептрон), який є спрощеною математичною моделлю біологічного нейрона. Він виконує три прості дії:

1. Отримує вхідні сигнали (Inputs). Це отримані дані, наприклад, для задачі, що вирішується, це можуть бути показники з магнітометра, PI-детектора та георадара. Кожен показник - це окремий вхід ( $x_1, x_2, x_3, \dots$ ) [3, 7].
2. Обробляє сигнали. Кожен вхідний сигнал множиться на вагу (weight,  $w$ ). Вага - це коефіцієнт, що показує важливість цього конкретного входу. Чим важливіший вхід, тим більша його вага. Потім усі зважені

сигнали складаються, і до них додається зміщення (bias,  $b$ ). Зміщення можна уявити як поріг спрацьовування нейрона.

3. Видає вихідний сигнал (Output). Отримана сума пропускається через функцію активації. Це нелінійна функція, яка вирішує, чи "спрацює" нейрон і який сигнал він передасть далі. Якщо сума перевищує певний поріг, нейрон активується і видає сигнал (наприклад, 1), якщо ні – сигнал буде слабким або нульовим (наприклад, 0).

Один нейрон може вирішувати лише дуже прості задачі. Їхня справжня сила проявляється, коли вони об'єднуються у багат шарову структуру - нейронну мережу [1, 7].

Нейронні мережі, в свою чергу, для конкретних завдань поділяються за архітектурою на: MLP, CNN, RNN [9,14,18].

MLP (Multi-Layer Perceptron або Багат шаровий Перцептрон) нейронні мережі [1, 7] – це класичний та один з найпоширеніших типів нейронних мереж прямого поширення. Її архітектура є основою для розуміння більш складних моделей. Така мережа складається з трьох типів шарів [9,14,18]:

1) Вхідний шар (Input Layer) – просто отримує початкові дані. Кількість нейронів у цьому шарі дорівнює кількості ознак у отриманих даних (наприклад, 10 показників з сенсорів = 10 вхідних нейронів).

2) Приховані шари (Hidden Layers). Нейрони кожного шару отримують сигнали від нейронів попереднього шару, обробляють їх і передають далі. У цих шарах мережа вчиться розпізнавати все складніші патерни. Перший прихований шар може навчитися розпізнавати прості речі: "сильний сплеск сигналу", "повільне затухання". Другий прихований шар, комбінуючи ці прості патерни, може навчитися розпізнавати складніші концепції: "сигнал, схожий на великий залізний об'єкт" або "сигнал, схожий на алюмінієву банку".

3) Вихідний шар (Output Layer) формує фінальний результат. Кількість нейронів тут залежить від задачі, наприклад для класифікації на 3 класи ("міна", "осколок", "сміття") у вихідному шарі буде 3 нейрони, кожен з яких показуватиме ймовірність належності об'єкта до свого класу. Мережі з великою кількістю прихованих шарів називаються глибокими нейронними мережами (Deep Learning) [9,14,18].

Надалі проводиться навчання мережі. Це процес підбору правильних ваг ( $w$ ) та зміщень ( $b$ ) для всіх її нейронів. Спочатку вони ініціалізуються випадковими числами, тому мережа видає абсолютно стохастичні результати. Процес навчання відбувається ітеративно:

1) Пряме поширення (Forward Propagation). На вхід мережі подається один приклад з навчальної вибірки (наприклад, сигнали від відомої міни). Сигнал проходить через усі шари, і на виході мережа робить свій прогноз (наприклад, "ймовірність міни 30%, осколка 60%, сміття 10%").

2) Обчислення помилки (Loss Function). Тут порівнюється прогноз мережі з правильною відповіддю ("міна 100%, осколок 0%, сміття 0%"). Функція втрат (Loss function) обчислює, наскільки великою є помилка. Чим гірший прогноз, тим більше значення цієї функції.

3) Зворотне поширення помилки (Backpropagation) – це ключовий алгоритм. Помилка "поширюється" у зворотному напрямку, від вихідного шару до вхідного. На цьому етапі для кожного нейрона обчислюється його "внесок" у загальну помилку.

4) Коригування ваг (Gradient Descent). Використовуючи інформацію про "внесок" кожного нейрона, алгоритм оптимізації (найчастіше - градієнтний спуск або adam) трішки коригує ваги та зміщення кожного нейрона в такому напрямку, щоб зменшити загальну помилку.

Згорткові нейронні мережі (Convolutional Neural Networks, CNN) ідеальні для роботи із зображеннями та даними, що мають просторову структуру (на запропонованому прикладі це 2D-карти аномалій). Вони використовують "згортки" (фільтри) для пошуку патернів (країв, кутів, текстур) незалежно від їхнього положення на зображенні. Тобто можуть бути одновимірні 1D-CNN, це коли важлива форма сигналу вздовж траєкторії: «подвійні гребені», симетрія, плавні «плечі» аномалій. Такі згортки по шляху (1D-CNN/TCN) вчать стійкі контури типових цілей – саме те, чого бракує точковому MLP. Є ще двовимірні 2D-CNN, це коли вже потрібні теплокarti ймовірностей і контури на плані, щоб розуміти, де саме копати. Такі 2D-згортки «бачать» просторові візерунки: неперервність сліду, геометрію меж [1, 7, 14].

Рекурентні нейронні мережі (Recurrent Neural Networks, RNN) створені для роботи з послідовностями даних (текст, мова, часові ряди). Вони мають "пам'ять", що дозволяє враховувати попередню інформацію при обробці поточної [1, 7].

На основі наведеного аналізу було визначено наступні кроки для вирішення задачі бінарної класифікації, а саме навчити модель на основі даних з сенсорів відповідати на питання: "Чи є виявлена аномалія значущим об'єктом (напр., міна, великий артефакт), чи це дрібне сміття/геологічна завада?". В такій постановці задачі апріорно визначається 2 класи: Клас 1: "Значущий об'єкт"; Клас 0: "Дрібне сміття / Завада";

За основу береться MLP нейронна мережа. Вона проста, дешева, швидка, тримає FAR, дає рівну роботу в полі [1, 5, 7].

Додається ще один канал – від магнітометру просторовий градієнт (як змінюється магнітне поле уздовж шляху/на сітці)  $G$ . Далі робиться проходка приладом з сенсорами по тестовому полігону, де заздалегідь закопані як значущі об'єкти, так і різне сміття. Для кожної зафіксованої аномалії записуються показники.

та беруться нормовані ознаки (див. попередні розділи):

$\hat{M}_t \in [0,1]$  – сила аномалії |  $\Delta V$  (із  $2 \times RM$ );

$\hat{G}_t \in [0,1]$  – просторовий градієнт (уздовж шляху/на сітці);

$\hat{D}_t \in [0,1]$  – PI-відгук (для Tracker-2 мінімально  $D/5$ ).

Отримуться ознаки ( $X$ ) та цільова змінна ( $y$ ):

$$X = [\hat{M}_t, \hat{G}_t, \hat{D}_t]$$

$$y = \text{target\_class}$$

Пропонується взяти такий розподіл де є 1000 прикладів аномалій, з них 800 для навчання (train set) і 200 для тестування (test set). Далі проектується архітектура моделі нейронної мережі, описана вище. Вхідний шар буде мати 3 нейрони, по одному на кожну ознаку. Прихованих шарів буде 2. Наприклад, перший з 12 нейронами, а другий з 8. Теоретично, перший шар може навчитися розпізнавати базові патерни ("сильний магнітний відгук", "сила аномалії"), а другий шар, комбінуючи їх, навчиться розпізнавати більш складні концепції ("сигнал, схожий на великий залізний об'єкт"). Вихідний шар буде мати 1 нейрон, оскільки була обрана бінарна класифікація. Функція активації для прихованих шарів береться ReLU, а для вихідного шару Sigmoid, оскільки потрібно отримати на виході ймовірність від 0 до 1.

Надалі визначається процес навчання. Функція втрат Binary Crossentropy буде сильно "штрафувати" модель, якщо та з високою впевненістю (напр., 0.95) назве сміття (клас 0) значущим об'єктом (клас 1). Оптимізатор Adam буде інтелектуально коригувати ваги мережі, щоб якомога швидше зменшити помилку (значення функції втрат). Метрика Accuracy (точність) потрібна, щоб в реальному часі бачити, який відсоток аномалій модель класифікує правильно.

Після цього запускається ітеративний процес навчання по циклу прямого-зворотного поширення та оновлення ваг.

– Пряме поширення. Модель бере невелику групу (batch) з 32 аномалій з навчальної вибірки. Для однієї аномалії з даними [0.8, 0.9, 0.85] (після масштабування) вона робить прогноз, наприклад, 0.92.

– Обчислення втрат. Правильна відповідь для цієї аномалії - 1 ("Значущий об'єкт"). Функція Binary Crossentropy обчислює помилку між прогнозом 0.92 та правильною відповіддю 1.

– Зворотне поширення. Ця помилка поширюється назад по мережі. Алгоритм визначає, що нейрони, які відповідають за "сильний магнітний відгук", зробили правильний внесок, а нейрони, що реагують на "середню швидкість затухання", можливо, спрацювали не зовсім коректно.

– Оновлення ваг. Оптимізатор Adam трохи збільшує ваги, що ведуть до правильного рішення, і зменшує ті, що ведуть до неправильного.

Цей цикл повторюється для всіх 800 прикладів у навчальній вибірці, і все це повторюється задану кількість епох (напр., 50 разів). Далі проводимо перевірку якості моделі на тестових даних. Проганяємо через навчену модель 200 тестових прикладів, які модель ніколи не бачила. На основі цього проводиться аналіз метрик і модель показує точність 95%. Це означає, що вона правильно класифікувала 190 з 200 аномалій. Тепер можна зробити висновок, що розроблена модель є ефективною для розрізнення значущих об'єктів від сміття на основі даних з магнітометра та металошукача. Вона готова для інтеграції в реальний прилад.

Коли точкових ознак недостатньо, підключається моделі там, де важлива форма або багато протяжних об'єктів. [1, 7, 14]. згорткові архітектури уздовж траєкторії (1D-CNN/TCN) та на карті (2D-CNN/U-Net). Буде карту ділянки, контури та ранжування цілей, але треба більші потужності обчислювання [9, 14, 18].

### **Висновки.**

У ході роботи було послідовно вирішено поставлене завдання щодо розробки та обґрунтування методології для надійної ідентифікації підповерхневих металевих об'єктів. Основні висновки полягають в наступному.

1. Двоканальна система з запропонованими методами обробкою даних є ефективним, але обмеженим рішенням. Вона є значним кроком уперед порівняно з односенсорними приладами, дозволяючи проводити базову класифікацію та знижувати кількість хибних тривог. Проте її жорсткість та неможливість масштабування роблять її непридатною для вирішення складних завдань ідентифікації.

2. Багатоканальна система на основі машинного навчання є парадигмальним зрушенням від "виявлення" до "інтелектуальної ідентифікації". Цей підхід вирішує ключові проблеми попереднього етапу: він є гнучким, легко масштабується та здатний навчатися на реальних даних для розрізнення об'єктів зі складними та схожими сигнатурами. Було запропонований метод з класу навчання з вчителем на нейронних мережах на базі архітектури MLP та можливим доповненням ще CNN. Застосування цього методу дозволяє кардинально підвищити ефективність та безпеку пошукових робіт.

### **Перспективи подальших досліджень.**

Розвиток запропонованого підходу надалі може рухатися у наступних напрямках:

- Розробка передових архітектур глибокого навчання (Deep Learning), здатних працювати безпосередньо із сирими даними, мінімізуючи етап ручного видобуття ознак.
- Інтеграція систем з безпілотними платформами (БПЛА) для створення повністю автоматизованих комплексів для швидкого обстеження великих територій.
- Створення відкритих стандартизованих баз даних сигнатур різних об'єктів для навчання та тестування нових алгоритмів, що прискорить розвиток усієї галузі.
- Адаптивне навчання: розробка моделей, здатних донавчатися та адаптуватися до умов конкретної місцевості безпосередньо в процесі роботи.

### Література

1. Butler, D. K. (2009). Near-Surface Geophysics. Society of Exploration Geophysicists.
2. Blakely, R. J. (1996). Potential Theory in Gravity and Magnetic Applications. Cambridge University Press.
3. Colani, C., & Breiner, S. (2012). Pulse Induction Metal Detectors. Geometrics, Inc. Technical Report.
4. Kearey, P., Brooks, M., & Hill, I. (2002). An Introduction to Geophysical Exploration. Blackwell Science Ltd.
5. Billings, S. D. (2004). Discrimination and classification of buried UXO. The Leading Edge, 23(6), 546-551.
6. Won, I. J., Keiswetter, D. A., Fields, G. R. A., & Sutton, L. C. (1996). GEM-2: a new multifrequency electromagnetic sensor. Journal of Environmental and Engineering Geophysics, 1(2), 129-137.
7. Pao, H. T., Deaett, M., & Lutes, C. (2011). Sensor fusion for buried object detection. Proceedings of SPIE, The International Society for Optical Engineering.
8. Fawcett, T. (2006). An introduction to ROC analysis. Pattern Recognition Letters, 27(8), 861–874.
9. Murphy, K. P. (2012). Machine Learning: A Probabilistic Perspective. MIT Press.
10. Kay, S. M. (1998). Fundamentals of Statistical Signal Processing, Volume 2: Detection Theory. Prentice Hall.
11. Hosmer, D. W., Lemeshow, S., & Sturdivant, R. X. (2013). Applied Logistic Regression (3rd ed.). Wiley.
12. Bar-Shalom, Y., Li, X. R., & Kirubarajan, T. (2001). Estimation with Applications to Tracking and Navigation. Wiley.
13. Hall, D. L., & Llinas, J. (1997). An introduction to multisensor data fusion. Proceedings of the IEEE, 85(1), 6–23.
14. Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep Learning. MIT Press.
15. Saito, T., & Rehmsmeier, M. (2015). The Precision-Recall plot is more informative than the ROC plot when evaluating binary classifiers on imbalanced datasets. PLoS ONE, 10(3), e0118432.
16. Thrun, S., Burgard, W., & Fox, D. (2005). Probabilistic Robotics. MIT Press.
17. PNI Sensor Corp. (2020). RM3100 Geomagnetic Sensor – Datasheet & Application Note.
18. LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. Nature, 521, 436–444. <https://doi.org/10.1038/nature14539>.

*In this article, we present an evolutionary analysis of methods for detecting and identifying subsurface metallic objects. The work begins with a review of a basic two-channel system that combines a magnetic gradiometer for detecting ferromagnetic targets and a pulse-induction metal detector for registering all conductive objects. We describe in detail the concept of joint data processing based on hard logical rules, which enables initial target classification and reduces the number of false alarms. The article then reveals the inherent limitations of this approach when attempting to scale and add new data channels (e.g., ground-penetrating radar). We demonstrate that as the number of sensors increases, such rule-based methods become excessively complex and inefficient. As a solution, we propose a transition to the machine-learning paradigm. We outline a methodology for building multichannel systems that use classification algorithms (neural networks, support vector machines) to analyze high-dimensional data. Practical stages are discussed: from collecting training data on test ranges to feature extraction and deploying the trained model for probabilistic, real-time object classification.*

**Keywords:** magnetometer, pulse-induction metal detector, ground-penetrating radar, joint data processing, multichannel systems, machine learning, object classification, neural networks, sensor fusion.

**Захожай О. І.** - Східноукраїнський національний університет імені Володимира Даля, завідувач кафедри інформаційних технологій та програмування, д.т.н., професор.

**Коррель В. В.** - Східноукраїнський національний університет імені Володимира Даля, здобувач вищої освіти третього (освітньо-наукового) рівня.

Стаття надійшла до редакції: 26.10.2025 р.

Стаття прийнята до друку: 10.11.2025 р.

Стаття опублікована: 09.12.2025 р.