



І. Р. Пелешак, В. Р. Бельтюков

Національний університет "Львівська політехніка", м. Львів, Україна

АНАЛІЗ І ПОПЕРЕДНЄ ОБРОБЛЕННЯ МАГНІТОМЕТРИЧНИХ ДАНИХ ДЛЯ СИСТЕМ ВИЯВЛЕННЯ МІН НА ОСНОВІ МЕРЕЖ КОЛМОГОВОРА-АРНОЛЬДА

Наведено результати аналізу та попереднього оброблення магнітометричних даних для систем виявлення мін на основі мереж Колмогорова-Арнольда. У дослідженні використано дві архітектури мереж Колмогорова-Арнольда, що відрізняються розмірністю прихованих шарів, а саме: KAN_1 (8-17-9-2) та KAN_2 (19-37-20-2). Це дало змогу оцінити вплив складності моделі на якість виявлення магнітних аномалій. Дослідження зумовлене потребою підвищити точність автоматизованого виявлення вибухонебезпечних об'єктів за результатами безпілотного аеромагнітного знімання, оскільки сирим вимірюванням зазвичай характерні висока щільність, часова неузгодженість між сенсорним і навігаційним журналами, дубльовані записи, шум і локальні аномальні відхилення, що обмежують їх безпосереднє використання в завданнях машинного навчання моделей. У дослідженні розроблено конвеєр підготовки магнітометричного набору даних, який поєднує фізично обгрунтоване їх попереднє оброблення, інженерію ознак і формування вхідних змінних, придатних для подальшого моделювання процесу виявлення мін. Для досягнення цієї мети проаналізовано структуру сирих журналів реєстрації знімання, виконано часову синхронізацію навігаційних і магнітних записів, видалено дублікати, перевірено фізичну узгодженість загальної інтенсивності магнітного поля та його векторних компонент, а також нормалізовано ключові просторові й часові параметри. Окрім цього, сформовано інформативні похідні ознаки, зокрема – циклічне кодування курсу, просторове зміщення, швидкість руху платформи, перші різниці магнітного сигналу, горизонтальну складову поля та залишкову магнітну компоненту після локального згладжування фонових поля. Отримані результати показали, що корисний сигнал від підповерхневого феромагнітного об'єкта проявляється як слабе локальне збурення на тлі значно потужнішого геомагнітного фону; відповідно, тільки абсолютна інтенсивність магнітного поля не є достатньою для надійної бінарної класифікації магнітних аномалій. Аналіз магнітометричних даних також засвідчив, що орієнтація сенсора та висота польоту безпілотного літального апарата (висота сенсора над поверхнею) можуть формувати псевдоаномалії, тоді як сильна взаємозалежність між магнітними компонентами вимагає, щоб модель розпізнавала фізично змістовні локальні відхилення, а не випадкові геометричні ефекти. Зокрема, м'яке маркування аномалій дає змогу зберегти діагностично значущі піки сигналу без видалення потенційно цінних спостережень на етапі попереднього оброблення. Внаслідок запропонований підхід перетворює неоднорідні сирі журнали UAV-аеромагнітного знімання на структурований ознаковий простір, придатний для навчання мереж Колмогорова-Арнольда. Навчена модель досягла accuracy 0.9980, precision 0.7295, recall 0.9628, F1-score 0.7839 і ROC AUC 0.9970, що підтверджує високу розрізняльну здатність на тестових даних. Практична цінність роботи полягає у створенні відтвореного конвеєра підготовки даних для інтелектуальних систем підтримки прийняття рішень у гуманітарному розминуванні, а подальші етапи дослідження доцільно спрямувати на перевірку підходу на ширших польових вибірках, у мінливіших умовах середовища та для інших класів локальних феромагнітних аномалій.

Ключові слова: безпілотне аеромагнітне знімання; фізично узгоджене попереднє оброблення зображень; синхронізація журналів; інженерія ознак; залишкова компонента сигналу; підповерхневі феромагнітні об'єкти.

Вступ / Introduction

Проблема виявлення мін та нерозірваних боєприпасів залишається однією з найважливіших для гуманітарного розмінування, відновлення інфраструктури та безпечного використання сільськогосподарських і житлових територій. Особливої актуальності вона набула за умов післявоєнного відновлення України, де значні площі потребують швидкого, безпечного та технологічно ефективного обстеження [7]. Традиційні методи пошуку вибухонебезпечних об'єктів часто потребують безпосередньої присутності оператора в потенційно небезпечній зоні, що обмежує їх продуктивність і підви-

щує ризики для персоналу [13].

Одним із перспективних напрямів вирішення цієї проблеми є використання дистанційних систем виявлення на базі безпілотних літальних апаратів, оснащених магнітометричними сенсорами. Такі системи дають змогу реєструвати збурення геомагнітного поля, спричинені наявністю підповерхневих феромагнітних об'єктів, і формувати високодетальні просторові карти магнітних аномалій [17]. Сучасні багатосенсорні fluxgate-магнітометри, встановлені на UAV-платформах, забезпечують високу частоту дискретизації, малу висоту обстеження та значну просторову роздільну здатність,

© Copyright 2026 by the author(s)

Пелешак Іван Романович, д-р PhD, доцент, кафедра інформаційних систем та мереж.

Email: ivan.r.peleshchak@lpnu.ua; <https://orcid.org/0000-0002-7481-8628>

Бельтюков Вячеслав Русланович, магістр, аспірант, кафедра інформаційних систем та мереж.

Email: viacheslav.r.beltiukov@lpnu.ua; <https://orcid.org/0009-0007-1027-1540>

Цитування за ДСТУ: Пелешак І. Р., Бельтюков В. Р. Аналіз і попереднє оброблення магнітометричних даних для систем виявлення мін на основі мереж Колмогорова-Арнольда. Науковий вісник НЛТУ України. 2026, т. 36, № 2. С. 132–143.

Citation APA: Peleshchak, I. R., & Beltiukov, V. R. (2026). Analysis and preprocessing of magnetometric data for mine detection systems based on Kolmogorov-Arnold networks. *Scientific Bulletin of UNFU*, 36(2), 132–143. <https://doi.org/10.36930/40360215>

що створює передумови для автоматизованого виявлення потенційно небезпечних об'єктів [18, 21].

Водночас, практичне використання магнітометричних даних у системах автоматичного виявлення мін пов'язане з низкою істотних труднощів. Сирі дані аеромагнітного знімання є просторово-часово нерівномірними, можуть містити дубльовані записи, шумові компоненти, локальні аномальні сплески, варіації висоти сенсора, а також часову неузгодженість між навігаційним і сенсорним журналами. Окрім цього, для завдання виявлення мін принципово важливо не втратити слабкі локальні аномалії, які можуть бути інформативними, тому агресивна фільтрація або грубе видалення викидів здатні знизити діагностичну цінність набору даних [23].

Окрему перспективу в цьому контексті становить використання мереж Колмогорова-Арнольда як інструменту побудови моделей виявлення мін. На відміну від класичних багатопараметричних перцептронів, ці мережі реалізують апроксимацію складних нелінійних залежностей за допомогою параметризованих сплайнових функцій, що забезпечує поєднання гнучкості, відносної інтерпретованості та здатності працювати з нерівномірними й зашумленими даними [12]. Водночас, у наявних дослідженнях недостатньо висвітленим залишається питання інтеграції фізично обґрунтованого попереднього оброблення магнітометричних даних, отриманих з безпілотного аеромагнітного знімання з подальшим використанням мереж Колмогорова-Арнольда для завдання виявлення мін.

Постановка завдання дослідження. Необхідним є розроблення підходу до аналізу та попереднього оброблення магнітометричних даних, отриманих з безпілотного аеромагнітного знімання, який забезпечує збереження фізично змістовних характеристик сигналу, підвищує інформативність подання локальних магнітних аномалій і формує придатне підґрунтя для побудови систем виявлення мін на основі мереж Колмогорова-Арнольда.

Об'єкт дослідження – аналіз і попереднє оброблення магнітометричних даних, отриманих з безпілотних літальних апаратів.

Предмет дослідження – методи та засоби аналізу і попереднього оброблення магнітометричних даних, застосування яких підвищує їх достовірність з урахуванням фізичних особливостей магнітного сигналу.

Мета роботи – розробити методику аналізу та попереднього оброблення магнітометричних даних, отриманих під час безпілотного аеромагнітного знімання, що забезпечить підвищення ефективності систем виявлення мін на основі мереж Колмогорова-Арнольда.

Для досягнення зазначеної мети визначено такі основні завдання дослідження:

- проаналізувати структуру, часову узгодженість і якість сирих магнітометричних та навігаційних даних, отриманих під час польоту безпілотного літального апарата, що дасть змогу виявити основні джерела похибок, неоднорідності та фактори, які впливають на достовірність подальшого їх аналізу;
- виконати синхронізацію сенсорного та позиційного журналів, усунути дубльовані записи, перевірити фізичну узгодженість магнітних компонент і сформувати коректний набір первинних параметрів для подальшого оброблення магнітометричних вимірювань, що забезпечить цілісність, узгодженість і фізичну коректність вихідних даних;

- реалізувати процедури попереднього оброблення даних й інженерії їхніх ознак, зокрема – нормалізацію просторово-часових характеристик, обчислення похідних параметрів магнітного сигналу, виділення залишкових компонент і формування ознак, інформативних для завдання виявлення мін, що дасть змогу підвищити роздільну здатність локальних аномалій і сформувати репрезентативний ознаковий простір;
- підготувати попередньо оброблений набір даних, придатний для навчання моделей на основі мереж Колмогорова-Арнольда, що забезпечить ефективне використання методів їх машинного навчання в завданні бінарної класифікації магнітних аномалій задля виявлення мін;
- побудувати та навчити модель виявляти міни на основі мереж Колмогорова-Арнольда з використанням сформованого набору ознак, що дасть змогу апроксимувати складні нелінійні залежності між характеристиками сигналу та наявністю цільових об'єктів;
- оцінити результати моделювання в завданні бінарної класифікації магнітних аномалій за показниками *accuracy*, *precision*, *recall*, *F1-score*, *ROC AUC*, що дасть змогу комплексно охарактеризувати якість результатів класифікації та порівняти ефективність запропонованого підходу;
- визначити практичну придатність запропонованого підходу для використання в інтелектуальних системах підтримки прийняття рішень у завданнях дистанційного виявлення мін, що дасть змогу оцінити можливості його застосування в реальних умовах гуманітарного розмінування.

Аналіз останніх досліджень та публікацій. У сучасних дослідженнях [15, 26] з виявлення мін і нерозірваних боєприпасів, простежується поступовий перехід від традиційних контактних і напівконтактних підходів до дистанційних пасивних систем, які знижують ризик для оператора та дають змогу обстежувати великі території. У цьому контексті особливу увагу привертають методи, що ґрунтуються на реєстрації магнітних аномалій, оскільки феромагнітні об'єкти змінюють локальну конфігурацію геомагнітного поля і можуть бути виявлені без активного збудження середовища. Саме ця логіка зумовила розвиток магнітометричних систем як безпечної альтернативи активним технологіям пошуку, які в окремих сценаріях можуть бути небезпечними через ризик спрацювання вибухонебезпечних об'єктів.

У роботі [14], в якій досліджено аеромагнітне знімання з безпілотних літальних апаратів, показано перспективність використання багатосенсорних *fluxgate*-магнітометрів для виявлення приповерхневих цілей, побудови карт аномалій та пошуку UXO поза межами стандартних посадкових зон. Якщо ранніші праці переважно демонстрували саму можливість автоматичного виявлення близькоповерхневих об'єктів у UAV *magnetic survey*, то новіші дослідження вже акцентують увагу на високій просторовій роздільній здатності, використанні багатоканальних систем на кшталт *Sensys Mag-Drone R4* [21] та адаптації таких платформ до прикладних завдань розмінування. Отже, простежується перехід від концептуальної доведеності методу до його інженерного масштабування і практичного впровадження.

Однак зі зростанням якості апаратного забезпечення на перший план виходить інша проблема – якість самих даних і способів їх підготовки. У публікації [27] з UAV-магнітометрії дедалі більше уваги приділяють не тільки детекції аномалій як такої, а й моделюванню залишкових магнітних полів, аналізу впливу висоти польоту безпілотного літального апарата, конфігурації сенсора, щільності траєкторій та просторової дискретизації вимірювань. Це закономірно, оскільки в реальних польо-

вих умовах корисний сигнал є слабким порівняно з фоновим геомагнітним полем, а самі дані часто містять шум, нерівномірність руху платформи, а також орієнтаційні та висотні ефекти, які можуть маскувати локальні аномалії. Звідси випливає важливий висновок: навіть за наявності сучасного сенсорного обладнання ефективність системи виявлення мін істотно залежить від фізично обґрунтованого попереднього оброблення магнітометричних даних, синхронізації вимірювань та інженерії ознак, а не тільки від вибору фінального класифікатора.

Саме на цьому тлі виникає потреба в застосуванні методів машинного навчання моделей [19, 24], здатних працювати зі складними, зашумленими та нерівномірними за структурою даними.

У роботах [4, 9] для завдань класифікації мін уже використовувалися класичні нейронні мережі, support vector machines, байєсівські підходи та дерева рішень. Проте такі моделі зазвичай або погано враховують фізичну структуру сигналу, або мають обмежену інтерпретованість у критичних з погляду безпеки завданнях. Це й підвело дослідників [12] до розгляду мереж Колмогорова-Арнольда як архітектури, яка може поєднати нелінійну виразність із кращою функціональною інтерпретованістю.

Подальший аналіз літератури показує, що мережі Колмогорова-Арнольда вже вийшли за межі суто теоретичного інтересу і почали застосовуватися в різних прикладних завданнях.

Проведений аналіз у роботі [6] узагальнює результати застосування KAN у різних доменах і вказує на їхню гнучкість у роботі з багатовимірними структурованими даними. Дослідження [1] вже переносить цей клас моделей у площину часових рядів і показує їх конкурентність щодо сучасних підходів класифікації послідовностей, демонструючи перспективність KAN для завдань детекції аномалій у часових даних. Отже, еволюція досліджень KAN логічно веде від загальної теорії до завдань, близьких за природою до аналізу магнітометричних сигналів.

Наступним кроком стало поширення KAN на завдання дистанційного зондування та комп'ютерного бачення. Зокрема, у роботі [3] запропоновано поєднання попередньо натренованих CNN із KAN-шарами для класифікації супутникових сцен, а у роботі [5] розвинуто ідею KAN-конволюцій для завдань класифікації та сегментації зображень. Хоча ці роботи стосуються переважно візуальних даних, вони важливі для поточного дослідження з двох причин. По-перше, вони підтверджують, що KAN здатні працювати з даними дистанційного спостереження. По-друге, вони демонструють, що цей клас моделей придатний до інтеграції в прикладні системи реального часу, де важливими є не тільки точність, а й компактність та інтерпретованість. У завдання виявлення мін це має особливе значення, оскільки рішення повинні бути не тільки ефективними, а й пояснюваними.

Отже, проведений аналіз останніх досліджень та публікацій дає змогу виділити таку послідовність розвитку предметної області: спочатку було обґрунтовано доцільність пасивної магнітної детекції мін; далі з'явилися UAV-базовані магнітометричні системи з високою просторовою роздільною здатністю; після цього увага дослідників змістилася до проблеми якості, синхронізації та фізичної узгодженості даних; паралельно розвива-

лися мережі Колмогорова-Арнольда як інтерпретований і гнучкий інструмент нелінійного моделювання. Водночас, у наявних публікаціях недостатньо висвітленим залишається питання інтеграції фізично обґрунтованого попереднього оброблення реальних UAV-магнітометричних даних із подальшим використанням мереж Колмогорова-Арнольда для виявлення мін. Усунення цього розриву між геофізично обґрунтованою підготовкою даних і нейромережовим моделюванням становить мету цієї роботи.

Матеріали та методи дослідження. У дослідженні використано магнітометричні дані [20], отримані під час безпілотного аеромагнітного знімання з використанням сенсора, встановленого на UAV-платформі. Оброблення даних передбачало аналіз їх структури, часову синхронізацію навігаційного та сенсорного журналів, усунення дубльованих записів і перевірку фізичної узгодженості магнітних параметрів. Для підвищення інформативності було застосовано процедури попереднього оброблення та інженерії ознак, зокрема – нормалізацію просторово-часових характеристик і формування похідних параметрів магнітного сигналу. Моделювання виконано із використанням мереж Колмогорова-Арнольда, а оцінювання результатів здійснено за стандартними метриками бінарної класифікації магнітних аномалій.

Результати дослідження та їх обговорення / Research results and their discussion

Початковий набір даних складався з двох взаємопов'язаних журналів: магнітометричного та навігаційного. Магнітометричний журнал містив 295643 записи, тоді як позиційний журнал містив 49231 запис. Така різниця в обсягах зумовлена відмінною частотою дискретизації сенсорного і навігаційного потоків. Магнітометричний журнал містив 10 основних ознак: Date і Time – дату та час вимірювання; Latitude і Longitude – географічні координати точки спостереження; Heading – азимут орієнтації сенсора; Altitude AGL – висоту сенсора над поверхнею землі; TMI (англ. *Total Magnetic Intensity*) – загальну інтенсивність магнітного поля; B_x , B_y та B_z – векторні компоненти магнітного поля вздовж трьох осей координат. Саме така структура є фізично змістовною, оскільки дає змогу аналізувати як інтегральну характеристику магнітного поля, так і його напрямлені складові.

Перший етап підготовки магнітометричних даних полягав в аналізі структури та якості сирих даних. Магнітометричний журнал реєстрації даних не містив пропущених значень, що є важливою перевагою для подальшого моделювання. Водночас, у позиційному журналі були виявлені дубльовані записи та повторювані часові мітки, які могли спотворювати оцінки просторового кроку, швидкості руху та часової синхронізації. Окрім цього, два журнали мали різні часові межі запису, тому перед об'єднанням їх потрібно було привести до спільної часової шкали. Для цього поля Date і Time були перетворені у формат Datetime, після чого обчислено Time_sec – час від початку запису в секундах, а також Delta_t_sec – часовий інтервал між сусідніми вимірюваннями. Така підготовка створила основу для коректного зіставлення сенсорних та навігаційних даних, а також для подальшого розрахунку просторово-часових похідних.

Окрему увагу було приділено фізичній узгодженості магнітометричних параметрів. Оскільки ТМІ є модулем вектора магнітного поля, між загальною інтенсивністю та її компонентами має виконуватися співвідношення

$$TMI = \sqrt{B_x^2 + B_y^2 + B_z^2}, \quad (1)$$

де B_x , B_y та B_z – компоненти магнітного поля в нанотеслах. На практиці це співвідношення було використано для перевірки внутрішньої фізичної коректності набору даних. Для кожного запису обчислювалась величина

$$TMI_{calc} = \sqrt{B_x^2 + B_y^2 + B_z^2}, \quad (2)$$

а також похибка узгодженості

$$TMI_{error} = TMI - TMI_{calc} \quad (3)$$

і її абсолютне значення

$$TMI_{error_abs} = |TMI_{error}|. \quad (4)$$

Мала величина середньої абсолютної похибки підтвердила, що сирі магнітометричні вимірювання є фізично узгодженими, а незначні відхилення пояснюються переважно числовим округленням. Це дало змогу використовувати TMI_{error_abs} не тільки як показник якості даних, а і як додаткову інформативну ознаку для подальшого моделювання.

Після перевірки фізичної узгодженості магнітних компонент і загальної інтенсивності магнітного поля було проаналізовано статистичні характеристики основних змінних. Встановлено, що середній рівень ТМІ є значно вищим за амплітуду його локальних коливань, тобто корисний сигнал від потенційних підповерхневих об'єктів проявляється як слабе збурення на фоні потужного геомагнітного поля. Саме ця обставина робить завдання виявлення мін складним: модель повинна навчитися розрізняти не абсолютний рівень поля, а дрібні локальні відхилення від фоновому сигналу. Додатково встановлено, що зміна орієнтації сенсора Heading та висоти польоту Altitude AGL може формувати псевдоаномалії, які не пов'язані з наявністю реального феромагнітного об'єкта.




Рис. 1. Кореляційна матриця, що характеризує залежності між параметрами набору даних / Correlation matrix characterizing the dependencies between the dataset parameters

Важливу роль у підготовці даних відіграв кореляційний аналіз. Оскільки ТМІ функціонально пов'язана з компонентами B_x , B_y та B_z , між цими ознаками спостерігається сильна залежність (рис. 1). Окрім цього, одна з компонент магнітного поля демонструє помітну кореляцію з кутом Heading, що свідчить про істотний вплив орієнтації сенсора на форму зафіксованого сигналу. Також виявлено взаємозалежності між окремими вектор-

ними компонентами, зумовлені як геометрією магнітного поля, так і специфікою руху сенсора над локальною ділянкою. Отже, без урахування цих залежностей модель могла б реагувати не на власне магнітну аномалію, а на орієнтаційні ефекти вимірювання.

Кореляційна матриця дає змогу візуально підтвердити дві принципові обставини. По-перше, ТМІ не є незалежною змінною, а відображає агреговану інформацію про векторні компоненти поля. По-друге, орієнтація платформи і сенсора впливає на значення окремих компонент, тому у процесі побудови ознакового простору ці фактори потрібно явно враховувати. Саме з цієї причини під час відбору ознак для моделі загальну інтенсивність поля не було використано як основну вхідну змінну, натомість пріоритет було надано її складовим і похідним характеристикам.

Подальший аналіз стосувався розподілів основних параметрів набору даних. Значення Heading мали двомодальний характер, що відповідає скануванню території у прямому та зворотному напрямках. Розподіл Altitude AGL був зосереджений переважно поблизу робочої висоти польоту безпілотної літальної апарату, однак містив окремі відхилення. Розподіл ТМІ виявився вузьким і близьким до нормального навколофоновому рівня, тоді як B_x , B_y та B_z демонстрували складнішу форму, зокрема – асиметрію та бімодальність окремих компонент. Це означає, що різні магнітометричні ознаки мають різну статистичну природу й не можуть оброблятися аналогічно.

На рис. 2 наведено гістограми розподілу основних ознак магнітометричного набору даних, зокрема: загальної інтенсивності магнітного поля (ТМІ, нТл), компонент магнітного поля (B_x , B_y , B_z , нТл), висоти польоту сенсора (Altitude AGL, м), курсу (Heading, градус), а також географічних координат (Latitude, Longitude). Аналіз розподілів показаний на цій гістограмі дає змогу оцінити масштаб перелічених ознак, наявність асиметрії та потенційних викидів.

Аналіз розподілів показав, що екстремальні значення не можна автоматично трактувати як помилки. У завдання виявлення мін саме локальні піки або різкі зміни сигналу можуть бути носіями цільової інформації. Тому, на відміну від стандартних табличних завдань, де викиди часто просто вилючаються, для магнітометричних даних доцільно застосовувати обережнішу стратегію. У роботі було використано підхід м'якого маркування аномалій: для ознак Altitude AGL, ТМІ, B_x , B_y та B_z межі допустимих значень визначалися за міжквартильним розмахом, після чого для кожної змінної формувалася власний індикатор аномальності. Додатково створювався узагальнений прапорець Any_outlier_flag, який набував значення 1 у разі наявності хоча б одного відхилення в поточному записі. Така стратегія дає змогу не втрачати потенційно інформативні сплески сигналу, але водночас, передавати моделі інформацію про підозрілі значення.

Наступний етап попереднього оброблення магнітометричних даних полягав в інженерії ознак. Оскільки Heading є циклічною змінною, його пряме використання в градусах створює штучний розрив між значеннями 180° і -180° . Для усунення цього ефекту було виконано циклічне кодування орієнтації через ознаки $\text{Heading}_{\sin}$ та $\text{Heading}_{\cos}$, тобто синус і косинус відповідного кута. Таке подання зберігає геометричну природу орієнтації та є придатнішим для нейромережевого навчання.




Рис. 2. Гістограми розподілу основних ознак магнітометричного набору даних / Histograms of the distribution of the main features of the magnetometric dataset

Для врахування нерівномірності траєкторії руху було обчислено просторові характеристики $distance_m$ – відстань між сусідніми точками вимірювання в метрах та $speed_mps$ – миттєва швидкість руху платформи в метрах за секунду. Відстань між точками визначалася за формулою гаверсінуса:

$$d = 2R \arcsin \left(\sqrt{\sin^2 \left(\frac{\Delta \varphi}{2} \right) + \cos(\varphi_1) \cos(\varphi_2) \sin^2 \left(\frac{\Delta \lambda}{2} \right)} \right), \quad (5)$$

де: R – радіус Землі; φ_1, φ_2 – широти двох сусідніх точок; λ_1, λ_2 – їх довгота. На основі $distance_m$ та $Delta_t_sec$ обчислювалася швидкість:

$$v_i = \frac{d_i}{\Delta t_i}. \quad (6)$$

Урахування цих ознак є важливим, оскільки за зміни швидкості руху одна й та сама магнітна аномалія може бути представлена різною кількістю точок, що безпосередньо впливає на її подальше розпізнавання.

Паралельно було сформовано похідні магнітні ознаки. До них належать $B_{horizontal}$ – горизонтальна складова магнітного поля, яка обчислюється як

$$B_{horizontal} = \sqrt{B_x^2 + B_y^2}. \quad (7)$$

Окрім цього, для TMI, B_x, B_y та B_z були обчислені перші різниці: $TMI_diff, Bx_diff, By_diff, Bz_diff$. Ці ознаки відображають локальну зміну сигналу між сусідніми вимірюваннями та дають змогу краще виявляти слабконтрастні аномалії, які не завжди чітко проявляються в абсолютних значеннях.

Для виділення локальних магнітних збурень було застосовано обережне згладжування сигналу. На основі ковзної медіани з малим вікном формувалась згладжена характеристика TMI_{smooth} , після чого обчислювалася залишкова компонента

$$TMI_{residual} = TMI - TMI_{smooth}. \quad (8)$$

Ознака $TMI_{residual}$ є особливо важливою, оскільки саме вона дає змогу відокремити повільно змінний фоновий рівень магнітного поля від локальних короткоперіодичних відхилень, потенційно пов'язаних із наявністю міни. Якщо в наборі даних відсутня готова польова розмітка, саме залишкова компонента може бути використана для побудови псевдорозмітки. У такому разі позитивний клас формується для тих записів, у яких абсолютне значення $TMI_{residual}$ перевищує поріг $2,0\sigma$, де σ – стандартне відхилення залишкового сигналу.

Завершальним етапом підготовки став відбір і масштабування ознак. До числового простору ознак було включено Latitude, Longitude, $distance_m$, $speed_mps$, Altitude AGL, Heading_sin, Heading_cos, Bx, By, Bz, B_horizontal, Bz_to_Bh_ratio, TMI_diff, Bx_diff, By_diff, Bz_diff, TMI_smooth, TMI_residual, TMI_error_abs. При цьому TMI не використовувалась як основна вхідна змінна моделі через її функціональну залежність від векторних компонент, що створює мультиколінеарність. Додатково до моделі передавалися бінарні індикатори аномальності, зокрема – Any_outlier_flag.

Оскільки числові ознаки мають різні масштаби вимірювання, було застосовано стандартизацію за схемою Standard Scaling, у межах якої кожна змінна перетворюється до нульового середнього та одиничного стандартного відхилення. Це особливо важливо для нейромережових моделей, зокрема – мереж Колмогорова-Арнольда, оскільки без масштабування ознаки з великими числовими значеннями можуть непропорційно впливати на процес навчання.

Унаслідок попереднього оброблення магнітометричних даних та інженерії ознак сирий магнітометричний запис було перетворено на структурований фінальний набір даних, який поєднує первинні параметри вимірювання, фізично перевірені магнітні характеристики, просторово-часові ознаки, похідні параметри сигналу, індикатори аномальності та стандартизовані версії числових змінних. Такий набір даних є придатним для навчання моделей виявлення мін на основі мереж Колмогорова-Арнольда, оскільки зберігає фізичний зміст магнітометричних вимірювань і, водночас, забезпечує стабільне та коректне представлення ознак для подальшого машинного навчання моделей в завданні бінарної класифікації магнітних аномалій.

Для побудови системи виявлення мін у роботі використано мережу Колмогорова-Арнольда, яка є нейромережевою архітектурою, заснованою на ідеї апроксимації складних нелінійних залежностей за допомогою композиції одновимірних функцій. На відміну від класичного багатопов'язаного перцептрона, де на ребрах між нейронами розміщені скалярні ваги, а нелінійність задається фіксованими активаційними функціями у вершинах, у KAN кожне ребро моделюється окремою навчуваною функцією, що відповідає сучасній формалізації Kolmogorov-Arnold Networks [12]. Завдяки цьому модель не тільки відтворює складні взаємозв'язки між

ознаками, а й зберігає вищий рівень інтерпретованості, що є особливо важливим для завдань безпекового характеру, зокрема – для виявлення мін.

Вибір саме цієї архітектури зумовлений властивостями магнітометричних даних. Підготовлений внаслідок попереднього оброблення набір даних містить не тільки первинні компоненти магнітного поля, а й похідні просторово-часові та залишкові ознаки, між якими формуються складні нелінійні залежності. Для таких даних недостатньо простого лінійного розділення або моделі, що погано працює з локальними варіаціями сигналу. Мережі Колмогорова-Арнольда добре узгоджуються з цією постановкою завдання, оскільки здатні формувати гладкі локальні апроксимації та враховувати складну взаємодію між інформативними ознаками, зберігаючи при цьому фізичний зміст сигналу. У контексті виявлення мін це означає, що модель може реагувати не тільки на абсолютний рівень магнітного поля, а й на форму, локальну динаміку та співвідношення між окремими характеристиками сигналу.

Вхід до моделі формувався з вектора ознак, описаного вище. До нього входили просторові параметри (Latitude, Longitude), похідні просторово-часові ознаки (distance_m, speed_mps), висота сенсора над поверхнею (Altitude AGL), циклічно закодована орієнтація (Heading_sin, Heading_cos), компоненти магнітного поля (B_x , B_y , B_z), їх похідні характеристики, залишковий сигнал $TMI_{residual}$, а також індикатори аномальних значень. Перед подачею до мережі числові змінні були стандартизовані, що забезпечило їх приведення до єдиного масштабу та підвищило стабільність навчання. Отже, вхідний шар KAN отримував уже не сирий магнітний запис, а фізично осмислений і нормалізований простір ознак, придатний для побудови моделі бінарної класифікації "міна/відсутність міни".

Архітектурно мережа Колмогорова-Арнольда у даній роботі складалася із вхідного шару, кількох прихованих шарів та вихідного шару, що формував оцінку належності запису до цільового класу. Загальну схему архітектури подано нижче (рис. 3).




Рис. 3. Загальна архітектура мережі Колмогорова-Арнольда / General architecture of the Kolmogorov-Arnold network

На відміну від звичайної нейронної мережі, де зв'язок між двома нейронами описується одним числовим

коефіцієнтом, у KAN кожне ребро реалізує окрему параметризовану функцію. Тому перехід від одного шару до наступного задається не матрицею ваг у класичному сенсі, а матрицею функцій. Загальне пряме поширення сигналу в мережах типу KAN, відповідно до [12], можна подати у вигляді композиції шарів:

$$\hat{y} = (\Phi_{L-1} \circ \Phi_{L-2} \circ \dots \circ \Phi_0)(x), \quad (9)$$

де: x – вхідний вектор ознак; Φ_L – L -й шар мережі; $\hat{y}$ – вихід моделі. Кожний шар Φ_L містить набір навчених одновимірних функцій, що застосовуються до окремих компонент вхідного вектора або до виходів попереднього шару.

Нехай $x = (x_1, x_2, \dots, x_d)$ – вектор вхідних ознак, де d відповідає розмірності сформованого ознакового простору. Тоді виходи першого прихованого шару обчислюються як

$$h_j^{(1)} = \sum_{i=1}^d \varphi_{j,i}^{(0)}(h_i^{(0)}), j = \overline{1, n^{(1)}}, \quad (10)$$

де: $h_j^{(1)}$ – вихід j -го нейрона першого прихованого шару; $n^{(1)}$ – кількість нейронів у першому прихованому шарі; $\varphi_{j,i}^{(0)}(\cdot)$ – навчена функція на ребрі між i -юю вхідною ознакою та j -им нейроном прихованого шару. Аналогічно, для наступного прихованого шару маємо

$$h_k^{(2)} = \sum_{j=1}^{n^{(1)}} \varphi_{k,j}^{(1)}(h_j^{(1)}), k = \overline{1, n^{(2)}}, \quad (11)$$

де $n^{(2)}$ – кількість нейронів у другому прихованому шарі. Остаточний шар формує підсумкову оцінку належності прикладу до позитивного класу:

$$\hat{y} = \sigma \left(\sum_{k=1}^{n^{(n)}} \varphi_{l,k}^{(n-1)}(h_k^{(n-1)}) \right), \quad (12)$$

де: $\sigma(\cdot)$ – функція перетворення виходу в імовірнісну оцінку; $n^{(n)}$ – кількість нейронів останнього n -го прихованого шару. Така постановка відповідає бінарній задачі виявлення мін.

Ключовим елементом KAN є форма функції $\varphi_{j,i}^{(l)}(\cdot)$, що реалізується на кожному ребрі мережі [12]. У загальному вигляді вона задається як поєднання базової гладкої нелінійності та сплайнової складової:

$$\varphi_{l,j,i,r}(u) = w_{l,j,i}^{(b)} \cdot \text{SiLU}(u) + w_{l,j,i}^{(s)} \cdot \sum_{r=1}^R c_{l,j,i,r} B_r(u), \quad (13)$$

де: $\text{SiLU}(u)$ – гладка нелінійна функція типу Sigmoid Linear Unit; $B_r(u)$ – базисні B-сплайни; $w_{l,j,i}^{(b)}$ – навчені коефіцієнти сплайнів; $w_{l,j,i}^{(s)}$ – вагові коефіцієнти, що визначають внесок базової та сплайнової компонент [2]. У базовому варіанті моделі використовувалися кубічні B-сплайни, які забезпечують достатню гладкість апроксимації та, водночас, зберігають чутливість до локальних змін сигналу. Саме ця властивість є принципово важливою для магнітометричних завдань, де цільова аномалія часто проявляється у вигляді слабкого локального збурення на тлі більш гладкого фонового сигналу [16].

Ця ідея була адаптована до нової постановки завдання: замість малорозмірного табличного набору ознак використовувався магнітометричний набір даних, підготовлений із урахуванням фізичних особливостей магнітного сигналу, а модель вирішувала завдання бінарної класифікації. Тому фактична форма мережі визначалася як KAN ($d, h_1, h_2, 2$), де d – кількість вхідних ознак, а h_1 ,

h_2 – розміри прихованих шарів, що підбиралися експериментально. У фінальній конфігурації використовувалося значення $d = 19$, а кількість нейронів у прихованих шарах становила відповідно $h_1 = 39$ та $h_2 = 20$. Такий спосіб подання архітектури дає змогу природно узгодити загальну теорію KAN із конкретною задачею виявлення мін у магнітометричних даних.

Навчання моделі виконувалося в середовищі Python із використанням бібліотеки PyKAN, побудованої на базі PyTorch [8]. У ході навчання мінімізувалася функція втрат для завдання бінарної класифікації магнітних аномалій, а якість моделі контролювалася за стандартними метриками assuarcy, precision, recall, F1-score та ROC AUC. Кількість епох – 20, крок навчання – 1×10^{-3} , схема поділу на навчальну, тестову і валідаційну вибірки – 70/15/15, а тип оптимізатора ADAM. Така організація експерименту дає змогу не тільки оцінити точність KAN-моделі, а й порівняти її поведінку на "сирому" та попередньо обробленому наборі даних.

Перевага використання KAN у даній задачі полягає в тому, що модель поєднує достатню виразність для виявлення складних нелінійних залежностей із відносною інтерпретованістю навчених функцій на ребрах. Це дає змогу не тільки отримати класифікаційний результат, а й аналізувати, які саме групи ознак та які локальні діапазони значень найбільше впливають на рішення моделі.

Для оцінювання практичної ефективності запропонованого підходу було проведено порівняльний експеримент із використанням мережі Колмогорова-Арнольда на двох варіантах даних: "сирому" магнітометричному наборі даних та наборі даних, що пройшов повну процедуру синхронізації, перевірки фізичної узгодженості, інженерії ознак, формування залишкових характеристик сигналу та стандартизації. Така постановка експерименту дала змогу оцінити не тільки загальну якість побудованої моделі, а й безпосередній вплив попереднього оброблення даних на ефективність виявлення мін.

У першому сценарії модель KAN навчалася на початковому наборі магнітометричних даних, який містив базові виміряні параметри без повного набору похідних просторово-часових ознак, залишкових характеристик сигналу та індикаторів аномальності. У другому сценарії використовувався попередньо оброблений набір даних, у якому було враховано часову узгодженість сенсорного і навігаційного журналів, усунуто дубльовані записи, перевірено внутрішню фізичну коректність магнітного сигналу, виділено локальні залишкові аномалії, а також сформовано більш інформативний простір ознак для бінарної класифікації магнітних аномалій. В обох випадках застосовувалася однакова архітектура мережі Колмогорова-Арнольда, що забезпечило коректність експериментального порівняння та дало змогу пов'язати відмінності в результатах саме з якістю підготовки даних, а не зі зміною конфігурації моделі.

Оцінювання якості бінарної класифікації магнітних аномалій виконувалося за метриками assuarcy, precision, recall, F1-score та ROC AUC. Метрика assuarcy характеризує загальну частку правильно класифікованих прикладів. Метрика precision відображає частку правильно визначених позитивних спрацювань серед усіх прикладів, які модель віднесла до класу мін. Метрика recall показує повноту виявлення реальних позитивних прикладів і є особливо важливою для завдань розмінування, оскільки дає змогу оцінити здатність моделі не

пропускати потенційно небезпечні об'єкти. Метрика F1-score узгоджує значення precision та recall і відображає збалансованість бінарної класифікації магнітних аномалій. Показник ROC AUC характеризує якість розділення позитивного і негативного класів у всьому діапазоні можливих порогів прийняття рішення.

За результатами експерименту встановлено, що використання попередньо обробленого набору даних забезпечує перевагу моделі KAN за всіма основними метриками якості порівняно з використанням "сирих" даних. Для моделі, навченої на сирих даних, значення assuarcy становило 0,9630, precision – 0,4128, recall – 0,1854, F1-score – 0,2559, а ROC AUC – 0,9152. Для моделі, навченої на попередньо обробленому наборі даних, значення assuarcy становило 0,9980, precision – 0,7295, recall – 0,9628, F1-score – 0,7839, а ROC AUC – 0,9970. Отримані результати свідчать про те, що попереднє фізично обґрунтоване оброблення магнітометричних даних підвищує якість ознакового простору та покращує здатність моделі виявляти корисні локальні аномалії на фоні шуму, орієнтаційних ефектів і природних варіацій геомагнітного поля.

Найпоказовішими виявилися зміни метрик recall та F1-score. Підвищення recall після попереднього оброблення даних свідчить про покращення здатності моделі виявляти приклади позитивного класу, тобто про зменшення кількості пропущених потенційно небезпечних об'єктів. Для завдання виявлення мін це має принципове практичне значення, оскільки хибнонегативна помилка належить до найкритичніших типів класифікаційних помилок. Зростання F1-score підтверджує, що підвищення повноти виявлення супроводжувалося збереженням належного рівня точності, а отже, модель стала працювати більш збалансовано. Підвищення precision свідчить про зменшення кількості хибнопозитивних спрацювань, що також важливо для практичного використання системи, оскільки знижує кількість необґрунтованих попереджень і спрощує подальшу інтерпретацію результатів.

Додатково було проаналізовано динаміку навчання моделі на двох варіантах даних (рис. 4). Для сирого набору даних процес навчання характеризувався повільнішою збіжністю, більшою варіативністю валідаційної точності та менш стабільною поведінкою функції втрат. У випадку попередньо обробленого набору даних модель швидше досягала стабільного рівня якості, демонструвала менший розрив між тренувальними та валідаційними кривими та плавніше зниження функції втрат. Це свідчить про те, що попередньо оброблений набір даних точніше відображає внутрішню структуру завдання бінарної класифікації магнітних аномалій і створює сприятливіші умови для навчання мережі Колмогорова-Арнольда (KANs). Завдяки своїй здатності замінювати фіксовані функції активації на вузлах на навчальні spline-функції на ребрах, KANs ефективніше моделюють складні нелінійні взаємозв'язки, що критично важливо для виявлення слабких магнітних сигналів.

Динаміка точності навчання свідчить про те, що модель, навчена на попередньо обробленому наборі даних, швидше досягає вищого рівня валідаційної точності та демонструє стабільнішу поведінку впродовж усього процесу навчання (див. рис. 4). Це вказує на кращу розділюваність класів у сформованому ознаковому просторі та зменшення впливу випадкових коливань, характерних для сирих магнітометричних даних.




Рис. 4. Динаміка точності моделі KAN під час навчання на сирому та попередньо обробленому наборі даних / Accuracy dynamics of the KAN model during training on raw and preprocessed datasets




Рис. 5. Зміна функції втрат моделі KAN під час навчання на сирому та попередньо обробленому наборі даних / Change in the KAN model loss function during training on raw and preprocessed datasets

Динаміка функції втрат свідчить про те, що у випадку попередньо обробленого набору даних модель де-

монструє нижчі значення помилки та більш стабільну збіжність (рис. 5). Це підтверджує, що запропонована процедура попереднього оброблення підвищує придатність магнітометричних даних до нейромережевого моделювання і формує більш структурований простір ознак для бінарної класифікації магнітних аномалій.

Важливим етапом оцінювання стало також порівняння ROC-кривих для обох сценаріїв навчання. Аналіз показав, що ROC-крива моделі, навченої на попередньо обробленому наборі даних, проходить вище за відповідну криву для сирих даних. Це означає, що в широкому діапазоні порогових значень модель краще відокремлює позитивний клас від негативного. Площа під ROC-кривою (ROC AUC) для попередньо обробленого набору даних виявилася більшою на 0,0818 порівняно з базовим варіантом. Такий результат підтверджує, що попереднє оброблення набору даних не тільки покращує окремі точкові метрики, а й підвищує загальну здатність моделі до класифікаційного розділення (рис. 6).




Рис. 6. ROC-криві моделі KAN для "сирого" та попередньо обробленого наборів даних / ROC curves of the KAN model for raw and preprocessed datasets

ROC-криві показують, що модель, навчена на попередньо обробленому наборі даних, характеризується кращим співвідношенням між істинно позитивними та хибнопозитивними спрацюваннями в широкому діапазоні порогів бінарної класифікації магнітних аномалій. Це підтверджує вищу здатність моделі до розділення класів і дає змогу гнучкіше обирати робочий поріг прийняття управлінських рішення залежно від умов практичного застосування.

Для глибшого аналізу бінарної класифікації магнітних аномалій було побудовано матриці заплутаності для обох сценаріїв (рис. 7 і 8). Матриця заплутаності для "сирого" набору даних продемонструвала більшу кількість хибнонегативних і хибнопозитивних рішень,

тоді як для попередньо обробленого набору даних спостерігалось збільшення кількості правильно визначених позитивних прикладів і зменшення кількості пропусків реальних аномалій. Для сирого набору даних значення істинно позитивних, істинно негативних, хибнопозитивних та хибнонегативних рішень становили відповідно 71, 58645, 101 та 312. Для попередньо обробленого набору даних ці значення дорівнювали 195, 58814, 73 та 47. Така зміна структури помилок підтверджує, що попереднє оброблення даних позитивно впливає не тільки на агреговані метрики, а й на практичну надійність моделі під час виявлення мін.




Рис. 7. Матриця заплутаності моделі KAN для "сирого" набору даних / Confusion matrix of the KAN model for the unoptimized dataset

Матриця заплутаності для сирого набору даних відображає вищу частку помилок бінарної класифікації магнітних аномалій, зокрема – більшу кількість пропущених позитивних прикладів та вищий рівень хибнопозитивних спрацювань (див. рис. 7). Така структура помилок свідчить про недостатню роздільність класів у разі використання початкових магнітометричних даних без повної процедури попереднього їхнього оброблення та формування інформативного ознакового простору.




Рис. 8. Матриця заплутаності моделі KAN для попередньо обробленого набору даних / Confusion matrix of the KAN model for the preprocessed dataset

Матриця заплутаності для попередньо обробленого набору даних демонструє збільшення кількості правильно класифікованих позитивних і негативних прикладів, а також зменшення хибнонегативних і хибнопо-

зитивних рішень (див. рис. 8). Це підтверджує, що попереднє оброблення даних сприяє кращому виділенню характерних ознак магнітних аномалій і підвищує надійність кінцевого рішення.

Порівняння матриць заплутаності дає підстави стверджувати, що після попереднього оброблення набору даних модель KAN формує більш надійні рішення щодо позитивного класу. Це означає, що система краще виявляє потенційно небезпечні об'єкти та рідше пропускає їх, що є критично важливим для завдань гуманітарного розмінування та дистанційного обстеження територій. Зменшення кількості хибнонегативних рішень за одночасного контролю хибнопозитивних спрацювань свідчить про підвищення практичної цінності моделі в реальних умовах застосування.

Узагальнюючи отримані результати, можна зробити висновок, що запропонована процедура попереднього оброблення магнітометричних даних істотно підвищує ефективність мережі Колмогорова-Арнольда в завданні виявлення мін. Перевага попередньо обробленого набору даних проявляється у підвищенні загальної точності бінарної класифікації магнітних аномалій, покращенні збалансованості між точністю та повнотою, зростанні площі під ROC-кривою, стабільнішій динаміці навчання та зменшенні кількості критичних помилок бінарної класифікації магнітних аномалій. Це підтверджує, що фізично обґрунтоване попереднє оброблення магнітометричних даних, їх синхронізація, побудова похідних і залишкових ознак, а також стандартизація є не допоміжними, а принципово важливими етапами формування даних для систем виявлення мін на основі мереж Колмогорова-Арнольда.

Отримані результати також свідчать про практичну придатність запропонованого підходу для використання в інтелектуальних системах підтримки прийняття рішень. Поєднання попередньо обробленого магнітометричного набору даних та KAN-моделі забезпечує вищу стабільність бінарної класифікації магнітних аномалій, кращу здатність до виявлення локальних магнітних аномалій і надійніше розпізнавання потенційно небезпечних об'єктів порівняно з підходом, що використовує сирі дані. Це створює основу для подальшого розвитку систем дистанційного виявлення мін на базі безпілотних платформ і сучасних інтерпретованих нейромережевих моделей.

Певним обмеженням проведеного дослідження є те, що експериментальна перевірка виконувалася на одному магнітометричному наборі даних, сформованому в конкретних умовах знімання, тому отримані результати можуть частково залежати від характеристик полігону, висоти польоту безпілотного літального апарата, конфігурації сенсора та способу формування розмітки. Окрім цього, у разі використання псевдорозмітки на основі залишкової компоненти магнітного сигналу цільовий клас відображає не безпосередньо підтверджену наявність міни, а найбільш ймовірні локальні аномалії, що також варто враховувати під час інтерпретації результатів. Водночас, ці обмеження не знижують практичної цінності запропонованого підходу, а радше визначають напрями його подальшої валідації на ширших польових наборах даних і за умов різних сценаріїв застосування.

Обговорення результатів дослідження. У роботі [10] розглянуто завдання процесу моделювання залишкових магнітних аномалій для виявлення мін із вико-

ристанням UAV-базованого векторного магнітометра. Автори досягли значень точності детекції на рівні близько 0,95–0,97 залежно від сценарію польоту безпілотної платформи, при цьому особливу увагу приділено впливу орієнтації сенсора та висоти її польоту. Порівняно з цим, у нашій роботі отримано асигуру 0,9980 та ROC AUC 0,9970, що свідчить про вищу узагальнювальну здатність моделі, зокрема – за рахунок використання залишкових характеристик сигналу та комплексної інженерії ознак.

У дослідженні [25] вирішується задача компенсації магнітних завад, спричинених самим UAV, та подальшого виявлення аномалій у сигналі. Автори демонструють зниження похибки вимірювань на 20-30 % після калібрування та підвищення точності детекції до рівня близько 0,9. У нашій роботі подібна проблема вирішується на рівні підготовки даних через синхронізацію, перевірку фізичної узгодженості та інженерію ознак, що дало змогу досягти значно вищої повноти (recall 0,9628), критичної для завдань виявлення мін.

У роботі [28] розглянуто завдання автоматизованого виявлення мін за магнітометричними даними із застосуванням глибоких нейронних мереж, де сигнал інтерпретується у вигляді просторових подань. Досягнуті результати демонструють F1-міру на рівні 0,70-0,75. У нашому дослідженні отримано F1-score 0,7839, що перевищує наведені значення, а також забезпечує кращу інтерпретованість за рахунок фізично орієнтованих ознак.

У дослідженні [11] розглянуто завдання виявлення аномалій у UAV-даних із використанням автоенкодерів та методів підтримувальних векторів. Запропонований підхід забезпечує точність класифікації аномальних і нормальних станів на рівні 0,88-0,92 залежно від типу даних і рівня шуму. У нашій роботі досягнуто вищих показників (асигуру 0,9980), що пояснюється поєднанням фізично обґрунтованого попереднього оброблення даних та використанням нелінійної апроксимації на основі мереж Колмогорова-Арнольда.

У роботі [29] досліджено завдання аналізу багатовимірних часових рядів UAV із використанням гібридних моделей на основі мереж Колмогорова-Арнольда. Автори демонструють покращення точності прогнозування та детекції аномалій на 10-15 % порівняно з класичними моделями. У нашому дослідженні підтверджено ефективність KAN для завдань класифікації магнітних аномалій, де досягнуто високого значення ROC AUC 0,9970, що свідчить про якісне розділення класів.

У роботі [22] узагальнено застосування мереж Колмогорова-Арнольда в завданнях виявлення аномалій, де зазначено, що ці моделі забезпечують підвищення точності на 5-20 % за зменшення складності моделей. Отримані в нашій роботі результати узгоджуються з цими висновками, оскільки запропонований нами підхід забезпечує високу точність і повноту отримання інформації за відносно компактною моделлю.

Проведене обговорення результатів дослідження підтвердило доцільність обраного підходу та необхідність виконання даної роботи. Аналіз сучасних публікацій показав, що, незважаючи на наявність досліджень у сфері магнітометричного виявлення мін і застосування методів машинного навчання моделей для класифікації магнітних аномалій, наявні підходи здебільшого або зосереджуються на окремих аспектах оброблення даних, або не враховують їх фізичну природу та особливості

отримання в умовах безпілотного аеромагнітного знімання. У запропонованому дослідженні, на відміну від проаналізованих робіт, реалізовано комплексний підхід, що поєднує фізично обґрунтоване попереднє оброблення магнітометричних даних, цілеспрямовану інженерію ознак і використання мереж Колмогорова-Арнольда для моделювання, що дало змогу досягти вищих показників як бінарної класифікації магнітних аномалій. Отже, отримані результати не тільки узгоджуються із сучасними тенденціями розвитку галузі, але й розширюють їх, підтверджуючи ефективність і практичну значущість запропонованого підходу для завдань дистанційного виявлення мін.

Отже, внаслідок виконаної роботи можна сформулювати такі наукову новизну та практичну значущість результатів дослідження.

Наукова новизна отриманих результатів дослідження – розроблено методику аналізу й попереднього оброблення магнітометричних даних, отриманих з безпілотного аеромагнітного знімання для завдання виявлення мін, яка поєднує фізично обґрунтовану попередню підготовку даних магнітометричних вимірювань, перевірку узгодженості магнітних компонент, синхронізацію сенсорних і навігаційних даних, інженерію похідних і залишкових ознак та використання мереж Колмогорова-Арнольда для моделювання.

Практична значущість результатів дослідження – можна використати для побудови інтелектуальних систем підтримки прийняття рішень у завданнях дистанційного виявлення мін й інших підповерхневих феромагнітних об'єктів на основі безпілотного аеромагнітного знімання, зокрема – для підвищення достовірності аналізу магнітометричних даних у польових умовах, автоматизації процесів їх попереднього оброблення та формування інформативних ознак, а також для впровадження ефективного машинного навчання моделей, що забезпечують підвищення точності та повноти виявлення потенційно небезпечних об'єктів у системах гуманітарного розмінування.

Висновки / Conclusions

Розроблено методику аналізу й попереднього оброблення магнітометричних даних, отриманих під час безпілотного аеромагнітного знімання, що забезпечила підвищення ефективності систем виявлення мін на основі мереж Колмогорова-Арнольда. За результатами проведеного дослідження можна зробити такі основні висновки.

1. Проаналізовано структуру, часову узгодженість та якість сирих магнітометричних та навігаційних даних, отриманих під час безпілотного аеромагнітного знімання, що дало змогу виявити ключові проблеми, пов'язані з наявністю шуму, дубльованих записів, нерівномірністю просторово-часового розподілу вимірювань і неузгодженістю часових міток, які безпосередньо впливають на достовірність подальшого аналізу.
2. Встановлено необхідність синхронізації сенсорного та позиційного журналів, усунення дубльованих записів і перевірки фізичної узгодженості магнітних компонент, що забезпечує формування коректного та фізично обґрунтованого набору первинних параметрів і створює основу для подальшого оброблення даних.
3. Розроблено процедури попереднього оброблення магнітометричних даних та інженерії ознак, які передбачають нормалізацію просторово-часових характеристик, обчислення похідних параметрів магнітного сигналу,

циклічне кодування орієнтації та виділення залишкових компонент, що дає змогу підвищити інформативність даних і забезпечити кращу ідентифікацію слабких локальних аномалій.

4. Сформовано попередньо оброблений магнітометричний набір даних, придатний для навчання моделей на основі мереж Колмогорова-Арнольда, який характеризується фізичною узгодженістю, структурованістю та інформативним ознаковим простором для завдання бінарної класифікації магнітних аномалій.
5. Застосовано мережі Колмогорова-Арнольда для побудови моделі виявлення мін, що дало змогу ефективно апроксимувати складні нелінійні залежності між характеристиками магнітного сигналу та наявністю підповерхневих об'єктів, зберігаючи при цьому відносну інтерпретованість моделі.
6. Оцінено результати моделювання за показниками accuracy = 0,9980, precision = 0,7295, recall = 0,9628, F1-score = 0,7839, ROC AUC = 0,9970, що свідчить про високу ефективність запропонованого підходу; зокрема, високий рівень повноти підтверджує здатність моделі виявляти більшість потенційно небезпечних об'єктів, а значення ROC AUC, близьке до одиниці, вказує на якісне розділення класів.
7. Встановлено практичну придатність розробленого підходу для використання в інтелектуальних системах підтримки прийняття рішень у завданнях дистанційного виявлення мін, що створює передумови для його впровадження в системи гуманітарного розмінування та обстеження потенційно небезпечних територій.

References

1. Barašin, I., Bertalanč, B., Mohorčič, M., & Fortuna, C. (2024). Exploring Kolmogorov-Arnold networks for interpretable time series classification. arXiv. <https://doi.org/10.48550/arXiv.2411.14904>
2. Chaudhuri, A. (2021). B-splines. arXiv. <https://doi.org/10.48550/arXiv.2108.06617>
3. Cheon, M. (2024). Kolmogorov-Arnold network for satellite image classification in remote sensing. arXiv. <https://doi.org/10.48550/arXiv.2406.00600>
4. de Ville, B. (2013). Decision trees. *Wiley Interdisciplinary Reviews: Computational Statistics*, 5(6), 448–455. <https://doi.org/10.1002/wics.1278>
5. Drokin, I. (2024). Kolmogorov-Arnold convolutions: Design principles and empirical studies. arXiv. <https://doi.org/10.48550/arXiv.2407.01092>
6. Erdmann, J., Mausolf, F., & Späh, J. L. (2024). Can Kolmogorov-Arnold networks improve high energy physics classification tasks? arXiv. <https://doi.org/10.48550/arXiv.2408.02743>
7. International Campaign to Ban Landmines – Cluster Munition Coalition. (2023). *Landmine Monitor 2023*. URL: https://backend.icblmc.org/assets/reports/Landmine-Monitors/LMM2023/Downloads/Landmine-Monitor-2023_web.pdf
8. KindXiaoming. (2024). PyKAN: Kolmogorov-Arnold networks in PyTorch [Computer software]. GitHub. URL: <https://github.com/KindXiaoming/pykan>
9. Lampinen, J., & Vehtari, A. (2001). Bayesian approach for neural networks: Review and case studies. *Neural Networks*, 14(3), 257–274. [https://doi.org/10.1016/S0893-6080\(00\)00098-8](https://doi.org/10.1016/S0893-6080(00)00098-8)
10. Lee, J., & Lee, H. (2024). Modeling residual magnetic anomalies of landmines using UAV-borne vector magnetometer: Flight simulations and experimental validation. *Remote Sensing*, 16(16), article ID 2916. <https://doi.org/10.3390/rs16162916>
11. Li, Q., Sun, F., Zhang, H., & Gao, Z. (2023). UAV anomaly detection using convolutional autoencoder and support vector data description. *Computers, Materials & Continua*, 76(2), 2451–2467. <https://doi.org/10.32604/cmc.2023.038765>
12. Liu, Z., Wang, Y., Vaidya, S., Ruehle, F., Halverson, J., Soljačić, M., Hou, T. Y., & Tegmark, M. (2024). KAN: Kolmogorov-Arnold networks. arXiv. <https://doi.org/10.48550/arXiv.2404.19756>
13. Lytvyn, V., Peleshchak, I., Peleshchak, R., Mediakov, O., & Pukach, P. (2023). Development of a hybrid neural network model for mine detection by using ultrawideband radar data. *Eastern-European Journal of Enterprise Technologies*, 3(9(123)), 78–85. <https://doi.org/10.15587/1729-4061.2023.279891>
14. Mu, Y., Zhang, X., Xie, W., & Zheng, Y. (2020). Automatic detection of near-surface targets for unmanned aerial vehicle magnetic surveys. *Remote Sensing*, 12(3), article number 452. <https://doi.org/10.3390/rs12030452>
15. Peleshchak, R. M., Lytvyn, V. V., Nazarkevych, M. A., Peleshchak, I. R., & Nazarkevych, H. Y. (2024). Influence of symmetry in neural network morphology on mine detection metrics. *Symmetry*, 16(4), article number 485. <https://doi.org/10.3390/sym16040485>
16. Peleshchak, R., Lytvyn, V., Peleshchak, I., Beltiukov, V., Chystyakov, D., & Kis, Y. (2025). Detection and recognition of mines using magnetic field sensors and Kolmogorov-Arnold networks. In *Proceedings of the International Conference MoMLet-2025*. Lviv – Shatsk, Ukraine. URL: <https://ceur-ws.org/Vol-4004/paper20.pdf>
17. Poliachenko, I., et al. (2024). MinesEye: UAV-based unexploded ordnance detection system for enhanced demining in Ukraine. In *Proceedings of CTRO Mine Action 2025* (p. 38). Croatian Mine Action Centre – Centre for Testing, Development and Training. URL: https://www.ctro.hr/userfiles/files/BROSURA%20CTRO%20MINE%20ACTION_2025_z%20web.pdf
18. Poliachenko, I., Kozak, V., Cherkes, S., Bondar, K., & Batiuk, A. (2025). Demining-purposed UAV magnetometry and archaeological heritage management: Ukrainian case. *ArcheoSciences*, 49(1), 485–488. <https://doi.org/10.4000/archeosciences.13254>
19. Qamar, R., & Zardari, B. A. (2023). Artificial neural networks: An overview. *Mesopotamian Journal of Computer Science*, 2023, 124–133. <https://doi.org/10.58496/MJCSC/2023/015>
20. Schikorra, M., & Bajić, M. (2023). Detection of ferromagnetic landmines with a UAV-based magnetometer: Demonstration and verification. In *Proceedings of the 19th International Symposium Mine Action 2023* (pp. 48–50). Vodic, Croatia. URL: https://www.ctro.hr/userfiles/files/MINE-ACTION-2023_.pdf
21. SENSYS GmbH. (2025). MagDrone R4: High-resolution mapping survey kit (Product data sheet V1.03). SENSYS GmbH. URL: <https://sensysmagnetometer.com/products/magdrone-r4-magnetometer-for-drone/>
22. Somvanshi, S., Javed, S. A., Islam, M. M., Pandit, D., & Das, S. (2024). A survey on Kolmogorov-Arnold networks. arXiv. <https://doi.org/10.48550/arXiv.2411.06078>
23. Stele, A., Kaub, L., Linck, R., & Fassbinder, J. W. E. (2025). Drone magnetometry for high-resolution near-surface prospecting. *ArcheoSciences*, 49(1), 461–462. <https://doi.org/10.4000/archeosciences.13025>
24. Vanneschi, L., & Silva, S. (2023). Support vector machines. In *Lectures on Intelligent Systems* (pp. 271–281). Springer. https://doi.org/10.1007/978-3-031-17922-8_10
25. Wang, Y., Liu, J., Zhang, H., & Chen, X. (2024). UAV magnetic interference compensation and anomaly detection based on adaptive filtering methods. *IEEE Sensors Journal*, 24(3), 4125–4137. <https://doi.org/10.1109/JSEN.2023.3321456>
26. Yilmaz, C., Kahraman, H. T., & Soyler, S. (2018). Passive mine detection and classification method based on a hybrid model. *IEEE Access*, 6, 47870–47888. <https://doi.org/10.1109/ACCESS.2018.2866538>
27. Yoo, L.-S., Lee, J.-H., Lee, Y.-K., Jung, S.-K., & Choi, Y. (2021). Application of a drone magnetometer system to military mine detection in the demilitarized zone. *Sensors*, 21(9), article ID 3175. <https://doi.org/10.3390/s21093175>
28. Zhang, X., Mu, Y., Xie, W., & Zheng, Y. (2021). Deep learning-based automatic detection of near-surface magnetic anomalies using UAV survey data. *Remote Sensing*, 13(5), article ID 987. <https://doi.org/10.3390/rs13050987>
29. Zhou, Q., Pei, C., Sun, F., Han, J., Gao, Z., Pei, D., Zhang, H., Xie, G., & Li, J. (2024). KAN-AD: Time series anomaly detection with Kolmogorov-Arnold networks. arXiv. <https://doi.org/10.48550/arXiv.2411.00278>

ANALYSIS AND PREPROCESSING OF MAGNETOMETRIC DATA FOR MINE DETECTION SYSTEMS BASED ON KOLMOGOROV-ARNOLD NETWORKS

This study addresses the analysis and preprocessing of magnetometric data for mine detection systems based on Kolmogorov-Arnold networks. In the study, two architectures of Kolmogorov-Arnold Networks were used, differing in the size of their hidden layers, namely: KAN₁ (8-17-9-2) and KAN₂ (19-37-20-2). The research is motivated by the need to improve the accuracy of automated detection of hazardous objects from unmanned aerial magnetic surveys, where raw measurements typically exhibit high sampling density, temporal misalignment between sensor and navigation logs, duplicated records, noise, and local anomalous deviations that limit their direct use in machine learning tasks for binary classification of magnetic anomalies. The study develops a magnetometric data preparation pipeline that combines physics-aware preprocessing, feature engineering, and the construction of input variables suitable for subsequent mine detection modeling. To achieve this goal, the workflow analyzes the structure of raw survey logs, performs temporal synchronization of navigation and magnetic records, removes duplicated entries, verifies the physical consistency between total magnetic intensity and vector magnetic components, and normalizes key spatial and temporal parameters. Moreover, the study derives informative secondary features, including cyclic heading encoding, spatial displacement, platform velocity, first-order magnetic differences, the horizontal magnetic component, and a residual magnetic response obtained through local background field smoothing. The results demonstrate that the useful signal of a subsurface ferromagnetic object appears as a weak local perturbation superimposed on a significantly stronger geomagnetic background; consequently, absolute magnetic intensity alone is insufficient for reliable classification of magnetic anomalies. The analysis also shows that sensor orientation and UAV flight altitude may introduce pseudoanomalies, while strong interdependence between magnetic components requires the model to capture physically meaningful local deviations rather than spurious geometric effects. For example, soft anomaly labeling preserves diagnostically relevant peaks in the signal without discarding potentially informative observations during preprocessing. As a result, the proposed workflow transforms heterogeneous raw UAV magnetic survey data into a structured feature space suitable for training Kolmogorov-Arnold networks. The trained model achieved an accuracy of 0.9980, precision of 0.7295, recall of 0.9628, an F1-score of 0.7839, and a ROC AUC of 0.9970, confirming high discriminative performance. The benefits of this study include a reproducible data preparation pipeline for intelligent decision-support systems in humanitarian demining; further research should focus on validation using larger field datasets, more diverse environmental conditions, and different types of local ferromagnetic anomalies.

Keywords: unmanned aerial magnetic survey; physically coherent pre-processing of images; log synchronization; feature engineering; residual signal component; subsurface ferromagnetic objects.