

МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ
Київський національний університет імені Тараса Шевченка
ННІ «Інститут геології»
Кафедра геофізики

КВАЛІФІКАЦІЙНА РОБОТА МАГІСТРА
спеціальність 103 Науки про Землю
освітня програма «Геофізика»

ТЕМА: «Автоматизація інтерпретації даних георадарних обстежень із використанням методів машинного навчання»

Виконав

студент 2 курсу
Кафедри геофізики
Курилюк Д. А.

Науковий керівник

ст. науковий співробітник,
доктор геол. наук
доцент Шабатура О. В.

Робота рекомендується до захисту (протокол № 13 засідання кафедри
геофізики від 15.05.2026 р.)

Завідувач кафедри

кандидат геологічних наук, доцент
Онищук В. І.

Київ – 2026

ЗМІСТ

ВСТУП	5
РОЗДІЛ 1. ТЕОРЕТИКО-МЕТОДОЛОГІЧНІ ОСНОВИ ГЕОРАДАРНОГО ЗОНДУВАННЯ З ВИКОРИСТАННЯМ МАШИННОГО НАВЧАННЯ	7
1.1. Фізичні принципи та задачі георадіолокаційного методу	7
1.2. Проблематика та обмеження традиційної ручної інтерпретації георадарних даних.....	13
1.3. Огляд сучасних методів машинного та глибокого навчання у геофізиці.....	17
Висновки до розділу 1.....	28
РОЗДІЛ 2. МЕТОДИКА ДОСЛІДЖЕНЬ ТА ОЦІНКА ЕФЕКТИВНОСТІ АВТОМАТИЗАЦІЇ	30
2.1. Методика проведення польових георадарних обстежень та збору даних...	30
2.2. Експериментальне порівняння: ручна інтерпретація проти автоматизованого аналізу.....	34
2.3. Оцінка часової рентабельності та оптимізації робочого процесу фахівця	42
2.3.1 Оцінка трудовитрат при традиційному (ручному) підході	42
2.3.2 Оцінка трудовитрат при гібридному (автоматизованому) підході	43
2.3.3 Аналіз часової рентабельності та ефективності методу	43
2.3.4 Переваги (сильні сторони)	43
2.3.5 Недоліки (обмеження)	44
Висновки до розділу 2.....	45
РОЗДІЛ 3. ПРОГРАМНА РЕАЛІЗАЦІЯ СИСТЕМИ ІНТЕЛЕКТУАЛЬНОГО АНАЛІЗУ ГЕОРАДАРНИХ ДАНИХ	47
3.1. Обґрунтування вибору технологічного стека та апаратного забезпечення ..	47
3.2. Підготовка та аналіз набору даних GPR_Data	51
3.3. Програмна реалізація та конфігурація процесу навчання.....	55
Висновки до розділу 3.....	63
РОЗДІЛ 4. ЕКСПЕРИМЕНТАЛЬНІ ДОСЛІДЖЕННЯ ТА АНАЛІЗ РЕЗУЛЬТАТІВ НАВЧАННЯ МОДЕЛІ	64
4.1. Параметризація та оцінка точності розпізнавання на основі статистичних метрик.....	64

4.2. Верифікація моделі на контрольних даних та приклади детекції	69
Висновки до розділу 4.....	78
ВИСНОВКИ	80
СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ.....	82
ДОДАТКИ	85

ПЕРЕЛІК УМОВНИХ СКОРОЧЕНЬ, СИМВОЛІВ, ОДИНИЦЬ І ТЕРМІНІВ

GPR (Ground Penetrating Radar) – георадар (геолокатор підповерхневого зондування).

ML (Machine Learning) – машинне навчання.

DL (Deep Learning) – глибоке навчання.

CNN (Convolutional Neural Networks) – згорткові нейронні мережі.

U-Net – архітектура нейронної мережі для сегментації геологічних об'єктів.

SVM (Support Vector Machines) – метод опорних векторів.

LSTM – рекурентні нейронні мережі для аналізу часових рядів.

XGBoost / LightGBM – алгоритми градієнтного бустингу.

RNN – рекурентні нейронні мережі.

PINNs – фізико-інформовані нейронні мережі.

GUI (Graphical User Interface) - графічний інтерфейс користувача

ГАЕС - гідроакумулююча електростанція

ВСТУП

Актуальність теми. Метод георадіолокації (GPR) є одним із найбільш затребуваних методів дистанційного зондування приповерхневого середовища. Він дозволяє з високою роздільною здатністю досліджувати геологічні розрізи, виявляти інженерні комунікації, дефекти дорожнього покриття та археологічні об'єкти. Однак обсяг даних, що отримуються під час сучасних обстежень, постійно зростає, а процес їх ручної інтерпретації залишається складним, суб'єктивним та часозатратним завданням. Виникає потреба в розробці інтелектуальних систем, здатних автоматично розпізнавати корисні сигнали на фоні шумів. Використання методів машинного та глибокого навчання відкриває нові можливості для автоматизації цього процесу, забезпечуючи високу швидкість обробки та мінімізацію помилок, пов'язаних із людським фактором.

Під час підготовки кваліфікаційної роботи ШІ використовувався для перевірки тексту на орфографічні і стилістичні помилки.

Мета роботи – підвищення ефективності та об'єктивності інтерпретації георадарних даних шляхом розробки та впровадження автоматизованих алгоритмів на основі методів машинного навчання.

Об'єкт дослідження – процес обробки та аналізу сигналів георадіолокаційного зондування.

Предмет дослідження – алгоритми машинного навчання (зокрема згорткові нейронні мережі та методи класифікації), що застосовуються для автоматичного розпізнавання образів та аномалій на георадарних профілях.

Завдання роботи:

1. Виокремити чинники, що впливають на складність інтерпретації отриманих даних георадіолокації.
2. Провести порівняльний аналіз сучасних методів машинного навчання (ML) та глибокого навчання (DL), що застосовуються в геофізиці.

3. Розробити методику попередньої обробки георадарних сигналів для підготовки якісних наборів даних.
4. Створити та навчити модель нейронної мережі для детекції типових приповерхневих об'єктів.
5. Оцінити точність та надійність розробленого підходу на контрольних прикладах та реальних даних обстежень.

Методи дослідження: для вирішення поставлених завдань використано статистичні методи аналізу даних, методи цифрової обробки сигналів, а також алгоритми глибокого навчання.

Практичне значення роботи: отримані результати можуть бути інтегровані в програмне забезпечення для обробки геофізичних даних, що дозволить значно скоротити час на камеральну обробку результатів польових обстежень та підвищити достовірність виділення підземних об'єктів.

Апробація результатів кваліфікаційної роботи магістра. Основні результати кваліфікаційної роботи були представлені на XVI Всеукраїнській молодіжній науковій конференції-школі Сучасні проблеми наук про Землю https://geology.knu.ua/static/docs/conf/2026/conf_univ_young_2026.pdf.

Фактичний матеріал та особистий внесок студента. У роботі використано результати георадарних обстежень, отримані з відкритих наборів даних та експериментальних прикладів, що були опрацьовані засобами цифрової обробки сигналів і машинного навчання. Самостійно проведено аналіз наукових джерел, виконано підготовку та попередню обробку даних, реалізовано алгоритми навчання нейронної мережі, здійснено тестування моделі та інтерпретацію отриманих результатів.

Структура роботи. Кваліфікаційна робота складається зі вступу, чотирьох розділів основної частини, висновків та списку використаних джерел.

РОЗДІЛ 1. ТЕОРЕТИКО-МЕТОДОЛОГІЧНІ ОСНОВИ ГЕОРАДАРНОГО ЗОНДУВАННЯ З ВИКОРИСТАННЯМ МАШИННОГО НАВЧАННЯ

1.1. Фізичні принципи та задачі георадіолокаційного методу

Георадіолокаційний метод (Ground Penetrating Radar, GPR) належить до класу високочастотних електромагнітних геофізичних методів, що використовуються для дослідження приповерхневих шарів ґрунту, гірських порід, штучних конструкцій та інших середовищ (Daniels, 2004). Його принципова особливість полягає у використанні імпульсних електромагнітних хвиль ультрависокої частоти (зазвичай у діапазоні 10 МГц – 2,5 ГГц), які випромінюються в середовище та відбиваються від меж з різними електромагнітними властивостями.

Фізичні основи методу базуються на рівняннях Максвелла, що описують поширення електромагнітних хвиль у неоднорідних середовищах. Як зазначає Даніелс у фундаментальній роботі з GPR, метод ґрунтується на принципі реєстрації відбитих сигналів від меж середовищ із різною діелектричною проникністю, електропровідністю та магнітною проникністю (Daniels, 2004). Саме контраст електрофізичних параметрів є ключовим фактором формування відбитих сигналів.

Електромагнітна природа поширення хвиль

Поширення радіохвиль у ґрунтовому середовищі визначається рівняннями хвиль, які впливають із системи рівнянь Максвелла. Основними параметрами, що впливають на поведінку хвилі, є (Daniels, 2004):

- діелектрична проникність ϵ ,
- електропровідність σ ,
- магнітна проникність μ .

Згідно з оглядовими роботами з теорії GPR (Carracelas, 2011; U.S. Environmental Protection Agency, n.d.), саме ці параметри визначають швидкість поширення хвиль, їх затухання та коефіцієнти відбиття на межах розділу середовищ (Jol, 2009). Електромагнітна хвиля, що поширюється в середовищі,

частково відбивається, частково заломлюється та частково поглинається. Відбиття виникає на межах, де відбувається різка зміна діелектричної проникності, що формально описується через коефіцієнти Френеля.

Система георадара

Типова система георадара складається з (Jol, 2009):

- передавальної антени,
- приймальної антени,
- блоку керування,
- системи обробки сигналів.

Передавальна антена випромінює короткий електромагнітний імпульс у середовище, який поширюється у вигляді сферичної хвилі. Частина енергії відбивається від об'єктів або меж шарів і повертається до приймальної антени.

Як зазначається в роботі Solla, Lorenzo та Pérez-Gracia, сигнал GPR представляє собою відбиті імпульси, що формують часові розрізи (A-scan, B-scan, C-scan), які є аналогами сейсмічних записів (Carracelas, 2011). Відповідно, георадар можна розглядати як електромагнітний аналог сейсмозвідки.

Фізичні процеси формування сигналу

Формування сигналу георадара включає чотири основні процеси:

1. Випромінювання імпульсу в середовище
2. Поширення електромагнітної хвилі
3. Відбиття на межах з контрастними властивостями
4. Реєстрація відбитого сигналу

Як підкреслюється в огляді U.S. Environmental Protection Agency (EPA), амплітуда та час приходу сигналу залежать від електромагнітних властивостей середовища та глибини об'єкта (U.S. EPA, 2024).

Час затримки сигналу дозволяє оцінити глибину залягання об'єкта за формулою (Jol, 2009):

$$d = vt/2$$

де v – швидкість поширення хвилі в середовищі, t – час подвійного проходження сигналу.

Ключовим фізичним механізмом у георадіолокації є взаємодія електромагнітного поля з речовиною середовища, що супроводжується поляризаційними процесами та дисипацією енергії у вигляді теплових втрат. Як зазначається у фундаментальних роботах з теорії GPR (Jol, 2009), рівень проникнення електромагнітних хвиль є обернено пропорційним електропровідності середовища, оскільки зростання провідності призводить до інтенсивнішого затухання сигналу та зменшення ефективної глибини зондування.

Наприклад:

- сухий пісок → висока проникність сигналу
- глина або вологий ґрунт → сильне затухання

Георадіолокаційний метод застосовується для вирішення широкого спектра інженерних, геологічних та прикладних наукових задач, що обумовлено його здатністю забезпечувати неруйнівне дослідження підповерхневих середовищ із високою просторовою роздільною здатністю. У межах інженерної геології метод використовується для детального аналізу будови ґрунтових масивів, включаючи визначення стратиграфічної послідовності шарів, виявлення зон неоднорідності та локальних змін фізико-механічних властивостей порід (Conyers, 2013). Особливу роль георадар відіграє у задачах ідентифікації пустот, карстових порожнин та зон розущільнення, які можуть становити потенційну небезпеку для інженерних споруд. Крім того, завдяки високій чутливості до змін електромагнітних властивостей середовища, метод широко застосовується для моніторингу та аналізу зсувних процесів, дозволяючи відстежувати деформаційні зміни в масивах ґрунтів у часі.

У сфері будівництва та інфраструктури георадіолокація є одним із ключових інструментів неруйнівного контролю конструкцій. Вона використовується для

локалізації металевої арматури в залізобетонних елементах, що є критично важливим при реконструкції та бурінні. Також метод дозволяє оцінювати товщину дорожніх покриттів, включаючи асфальтобетонні та багат шарові конструкції, що забезпечує контроль якості будівництва та планування ремонтних робіт (Conyers, 2013). Окреме значення має здатність георадара виявляти внутрішні дефекти конструкцій, такі як тріщини, розшарування, порожнини або ділянки з порушеною структурною цілісністю, що значно підвищує безпеку експлуатації інженерних об'єктів (Dai & Yan, 2014).

У гідрогеологічних дослідженнях георадіолокаційний метод використовується для оцінки положення рівня ґрунтових вод, а також для визначення просторового розподілу вологості в породах (Barr, 1993). Оскільки електромагнітні властивості середовища суттєво залежать від вмісту води, метод дозволяє непрямо оцінювати ступінь водонасичення порід і відстежувати гідрологічні процеси в приповерхневих шарах. Це особливо важливо при моделюванні фільтраційних процесів і прогнозуванні змін водного режиму територій.

В археології георадар набув широкого застосування як інструмент неінвазивного дослідження культурних шарів. Він дозволяє виявляти поховані об'єкти, фундаменти споруд, поховання та інші артефакти без необхідності проведення розкопок, що є критично важливим для збереження археологічної спадщини. Завдяки можливості формування детальних підповерхневих зображень, метод значно підвищує ефективність планування археологічних розкопок і мінімізує руйнування історичних об'єктів (Conyers & Goodman, 1997).

У сфері екологічних досліджень георадіолокаційний метод застосовується для виявлення підземних техногенних об'єктів, резервуарів та порожнин, а також для ідентифікації аномалій у структурі ґрунтів, пов'язаних із можливим забрудненням. Завдяки чутливості до змін електрофізичних властивостей середовища, метод

дозволяє здійснювати непрямий моніторинг зон потенційного екологічного ризику та оцінювати поширення змін у підповерхневих шарах (Jol, 2009).

Як зазначає Neal у класичному огляді застосувань георадару в седиментології, метод широко використовується для реконструкції геологічної історії відкладів і детального аналізу внутрішньої структури осадових товщ, що дозволяє інтерпретувати процеси їх формування та трансформації у часі (Neal, 2004).

Переваги георадіолокаційного методу визначаються його фізичною природою та особливостями взаємодії високочастотного електромагнітного випромінювання з неоднорідними середовищами. Однією з ключових характеристик є висока роздільна здатність, яка дозволяє фіксувати навіть незначні зміни електромагнітних властивостей у приповерхневих шарах (Neal, 2004). Це забезпечує можливість детального просторового аналізу об'єктів малого розміру, що особливо важливо в інженерних і археологічних задачах, де необхідно виявляти дрібні неоднорідності або локальні аномалії.

Іншою суттєвою перевагою є неруйнівний характер досліджень, що дозволяє проводити вимірювання без порушення цілісності досліджуваного середовища. Це робить метод особливо цінним у випадках, коли доступ до об'єкта обмежений або коли необхідно зберегти його структурну цілісність, наприклад у будівельних конструкціях, історичних пам'ятках чи природних геологічних формаціях (Neal, 2004). Завдяки цьому георадар широко використовується як інструмент попереднього обстеження перед проведенням будь-яких інвазивних робіт.

Важливою перевагою також є висока швидкість отримання даних, оскільки вимірювання можуть виконуватися в режимі безперервного профілювання із формуванням просторових розрізів у реальному часі. Це суттєво підвищує ефективність польових робіт і дозволяє оперативно приймати інженерні або дослідницькі рішення. Крім того, сучасні георадарні системи забезпечують можливість побудови як двовимірних, так і тривимірних моделей підповерхневого

середовища, що значно розширює аналітичні можливості методу та сприяє більш точній інтерпретації геофізичних даних.

Водночас георадіолокаційний метод має низку фізично обумовлених обмежень, які необхідно враховувати при його застосуванні. Одним із головних факторів, що впливає на ефективність досліджень, є сильне затухання сигналу у глинистих та водонасичених середовищах (Neal, 2004). Це пов'язано з підвищеною електропровідністю таких матеріалів, що призводить до швидкої втрати енергії електромагнітної хвилі та, відповідно, зменшення глибини зондування.

Іншим суттєвим обмеженням є залежність результатів вимірювань від електрофізичних властивостей ґрунту, зокрема діелектричної проникності та електропровідності (Neal, 2004). Зміна цих параметрів навіть у межах одного геологічного середовища може призводити до значних варіацій у швидкості поширення хвиль та амплітуді відбитих сигналів, що ускладнює однозначну інтерпретацію отриманих даних.

Додатковою проблемою є складність інтерпретації сигналів у неоднорідних середовищах, де наявність численних меж розділу, включень та випадкових аномалій призводить до багатократного розсіювання та інтерференції хвиль. У таких умовах формування коректної геофізичної моделі потребує застосування складних алгоритмів обробки даних і значного досвіду оператора, оскільки пряме зіставлення сигналів із фізичними об'єктами може бути неоднозначним.

Георадіолокаційний метод є фізично обґрунтованим електромагнітним методом дослідження підповерхневих середовищ, що базується на взаємодії високочастотних імпульсів із матеріалами з різними електромагнітними властивостями. Його ефективність визначається контрастом діелектричної проникності середовища, що дозволяє реєструвати межі шарів, об'єкти та неоднорідності.

1.2. Проблематика та обмеження традиційної ручної інтерпретації георадарних даних

Традиційна ручна інтерпретація георадарних даних є історично першим і до сьогодні широко застосовуваним підходом до аналізу радарограм, що базується на візуальному розпізнаванні характерних електромагнітних відгуків у вигляді гіпербол, відбиваючих горизонтів, дифракційних структур та зон аномального затухання сигналу. Такий підхід фактично опирається на когнітивні здібності оператора до виділення патернів у зашумлених даних, що робить його одночасно гнучким і вразливим до похибок.

Попри широке практичне використання, цей метод має низку фундаментальних обмежень, які впливають як із фізичних властивостей поширення електромагнітних хвиль у неоднорідних середовищах, так і з суб'єктивної природи людського сприйняття. Однією з ключових проблем є виражена суб'єктивність аналізу: результати інтерпретації суттєво залежать від досвіду оператора, його кваліфікації, а також від наявності попередніх знань про геологічну будову ділянки. Це призводить до того, що однакові набори даних можуть інтерпретуватися по-різному навіть серед експертів високого рівня.

Як підкреслюють Jol (2009) та Daniels (2004), при роботі з ідентичними георадарними записами різні інтерпретатори можуть формувати відмінні геологічні моделі, що знижує відтворюваність результатів і ускладнює стандартизацію процедур обробки та інтерпретації (Jol, 2009; Carracelas, 2011). Подібні висновки також наводять Neal (2004) і Annan (2009), зазначаючи, що візуальна інтерпретація GPR-даних є гібридним процесом, який поєднує формалізований науковий аналіз із значною часткою експертної інтуїції та емпіричного досвіду (Neal, 2004; Annan, 2009).

Додатково слід враховувати, що складність інтерпретації зростає у випадках сильно зашумлених сигналів, наявності багат шарових геологічних структур або матеріалів із близькими електромагнітними властивостями. У таких умовах межі

між корисним сигналом і шумом стають розмитими, що підвищує ризик хибної ідентифікації об'єктів або пропуску слабо виражених аномалій. Таким чином, ручна інтерпретація, хоча й залишається важливим етапом первинного аналізу, дедалі частіше потребує доповнення автоматизованими або напівавтоматизованими методами для підвищення об'єктивності та відтворюваності результатів.

Іншою суттєвою проблемою є значна складність інтерпретації сигналів у геологічно неоднорідних середовищах, де природні відклади характеризуються просторово мінливою структурою та відсутністю чіткої регулярної шаруватості. У реальних умовах ґрунти, осадові товщі та техногенні насипи демонструють суттєві варіації діелектричної проникності, електропровідності та вологості навіть на малих просторових масштабах. Такі зміни безпосередньо впливають на швидкість поширення електромагнітних хвиль, коефіцієнти відбиття та характер енергетичних втрат у середовищі.

У результаті хвильове поле, зафіксоване георадаром, формується як складна суперпозиція первинних та вторинних сигналів, що включає багатократні відбиття, розсіювання на локальних неоднорідностях, дифракційні ефекти на краях об'єктів та інтерференційні викривлення. Це призводить до значного ускладнення структури радарограм, де корисні відбиття від геологічних меж можуть бути частково або повністю замасковані паразитними компонентами сигналу.

Neal у своєму фундаментальному огляді підкреслює, що в седиментологічних умовах радарограми часто містять накладені сигнали від різних геологічних структур, включно з похиленими шарами, лінзоподібними включеннями, каналами та зонами зміненої вологості, що створює ефект «перекриття» відгуків і унеможлиблює однозначне візуальне трактування без залучення чисельного моделювання або додаткових методів обробки (Neal, 2004). У таких ситуаціях навіть досвідчений інтерпретатор може зіткнутися з неоднозначністю, коли одна й

та сама аномалія може бути пояснена кількома фізично різними геологічними сценаріями.

Додатково ускладнює ситуацію наявність високочастотного шуму, неоднорідного зволоження та різких контрастів у фізичних властивостях середовища, що призводить до викривлення амплітудної та фазової структури сигналу. У підсумку це підвищує залежність інтерпретації від апріорних геологічних припущень і стимулює використання методів цифрової обробки даних, таких як міграція, фільтрація та інверсійне моделювання, для підвищення достовірності отриманих результатів.

Важливою проблемою є також суттєвий вплив шумів та артефактів сигналу, які можуть виникати як унаслідок технічних факторів, так і через природні процеси в досліджуваному середовищі. До технічних джерел належать електромагнітні завади від роботи вимірювальної апаратури, антенних систем, нестабільності живлення, а також вплив навколишньої електронної інфраструктури. Природні ж шуми формуються внаслідок варіацій вологості ґрунту, неоднорідності складу порід, температурних змін та наявності розсіяних включень, які створюють додаткові компоненти відбитого сигналу.

Davis & Annan (1989) показали, що навіть незначні зміни електричних властивостей середовища або умов вимірювання можуть суттєво впливати на форму сигналу, амплітуду відбиттів та фазову структуру хвильового поля, що в результаті призводить до викривлення радарограм і появи артефактів, які можуть бути помилково інтерпретовані як реальні геологічні об'єкти (Annan, 2009). У практичних умовах це створює серйозну проблему відокремлення корисного сигналу від шумової складової, особливо при роботі в умовах низького контрасту фізичних властивостей середовища або значного загасання сигналу.

Окремим обмеженням є неоднозначність геометричних ознак, які використовуються для інтерпретації георадарних даних. Найбільш характерним прикладом є гіперболічні відбиття, що традиційно трактуються як індикатори

точкових або компактних об'єктів, таких як каміння, труби, пустоти чи археологічні артефакти. Водночас подібні гіперболічні сигнатури можуть виникати не лише через наявність локалізованих об'єктів, але й унаслідок варіацій швидкості поширення електромагнітної хвилі, нахилу шарів або складної багат шарової структури середовища.

Conyers у контексті археологічного застосування георадару наголошує, що без залучення додаткового чисельного моделювання, інверсійних процедур або порівняльного аналізу польових даних інтерпретація радарограм залишається принципово неоднозначною. Він підкреслює, що однакові за формою сигнатури – зокрема гіперболи, локальні аномалії відбиття або зони підвищеного розсіювання – можуть відповідати як реальним археологічним об'єктам (стіни, фундаменти, поховання), так і природним геологічним структурам або ефектам зміни швидкості поширення електромагнітної хвилі в середовищі. Це значно підвищує ризик хибно позитивних або хибно негативних інтерпретацій (Conyers, 2013).

Особливо критичною ця проблема стає у слабо контрастних середовищах, де різниця між електромагнітними властивостями об'єкта і навколишнього ґрунту є мінімальною. У таких умовах амплітудні та геометричні ознаки сигналу стають менш вираженими, а їхня інтерпретація суттєво залежить від параметрів обробки даних (фільтрації, міграції, часової корекції). Як наслідок, межа між реальними структурними елементами та артефактами обробки стає розмитою, що додатково ускладнює побудову достовірної геоархеологічної моделі (Conyers, 2013).

Суттєвим обмеженням традиційного підходу є також його низька масштабованість. Сучасні георадарні системи здатні генерувати надзвичайно великі масиви даних, особливо під час 3D-сканування територій або моніторингу протяжних інфраструктурних об'єктів. JoI зазначає, що ручна інтерпретація тривимірних GPR-об'ємів є надзвичайно трудомісткою, потребує значного часу та висококваліфікованих спеціалістів, що істотно обмежує оперативність прийняття

рішень у польових умовах (Jol, 2009). У масштабних проєктах це призводить до накопичення «вузького місця» саме на етапі аналізу даних, а не їх збору.

Додатковим ускладнювальним фактором є чутливість результатів до умов проведення вимірювань. Швидкість переміщення антени, стабільність її контакту з поверхнею, мікронерівності рельєфу, а також технічні параметри апаратури (частота антени, часовий діапазон, крок дискретизації) можуть суттєво впливати на якість отриманого сигналу. Ці ефекти часто мають подібний вигляд до геологічних або антропогенних аномалій, що ускладнює їхнє відокремлення без застосування процедур нормалізації та калібрування даних.

Таким чином, традиційна ручна інтерпретація георадарних даних характеризується системними обмеженнями, серед яких ключовими є суб'єктивність оцінювання, складність роботи з шумовими та неоднорідними сигналами, низька масштабованість обробки великих обсягів даних, а також високий ризик неоднозначної інтерпретації геометричних ознак. У сукупності ці фактори формують обґрунтовану потребу у переході до автоматизованих та напівавтоматизованих підходів, включно з алгоритмічною фільтрацією сигналів, чисельним електромагнітним моделюванням та методами машинного навчання для підвищення об'єктивності та відтворюваності результатів.

1.3. Огляд сучасних методів машинного та глибокого навчання у геофізиці

Сучасна геофізика перебуває в стадії активної трансформації, пов'язаної з інтеграцією методів машинного навчання (ML) та глибокого навчання (DL) у процеси обробки, аналізу та інтерпретації даних. Це зумовлено різким зростанням обсягів спостережень (3D/4D сейсміка, георадарні дослідження, супутникові дані), високим рівнем шуму в реальних вимірюваннях, а також складністю фізичних моделей, які описують поширення хвиль у неоднорідних середовищах (Yu & Ma, 2021).

На відміну від класичних підходів, які базуються на аналітичних моделях або ручній інтерпретації, методи ML/DL дозволяють будувати апроксимації складних

нелінійних залежностей без явного фізичного моделювання кожного процесу. У геофізиці це особливо важливо, оскільки середовище є багатопараметричним, стохастичним і часто неповністю спостережуваним (Yu & Ma, 2021).

Методи, що застосовуються у геофізиці, умовно поділяються на три великі групи, які відрізняються як за рівнем складності математичного апарату, так і за принципами роботи з даними та ступенем врахування фізичних законів середовища.

Класичне машинне навчання (Classical ML) базується на використанні алгоритмів, що працюють із попередньо сформованими ознаками (features), які витягуються з геофізичних сигналів вручну або за допомогою базових методів обробки (Bergen et al., 2019). Такі підходи передбачають попередню інженерію ознак, наприклад статистичні характеристики сигналу, спектральні параметри або параметри форми відбиттів. Вони добре підходять для задач класифікації та регресії у випадках обмежених обсягів даних, коли складні нейронні мережі є надлишковими або нестабільними. Однак їх ефективність різко знижується при роботі з просторово-часовими залежностями та високовимірними сирими сигналами, оскільки вони не здатні автоматично виявляти складні нелінійні патерни (Bergen et al., 2019).

Глибоке навчання (Deep Learning) представляє більш сучасний підхід, у якому модель самостійно навчається витягувати ієрархічні ознаки без необхідності ручної інженерії. Завдяки багат шаровим архітектурам нейронних мереж такі методи здатні моделювати складні нелінійні залежності у даних, що особливо важливо для геофізичних сигналів, які мають високу зашумленість і просторову складність (Mustafa & Alregib, 2023). У задачах сейсміки та георадару CNN-мережі використовуються для розпізнавання структурних елементів, U-Net – для сегментації геологічних об'єктів, а рекурентні мережі (LSTM) – для аналізу часових рядів. Попри високу точність, цей клас методів потребує значних обсягів

розмічених даних і потужних обчислювальних ресурсів, а також часто має обмежену інтерпретованість результатів (Mustafa & Alregib, 2023).

Гібридні фізико-інформовані моделі (Physics-informed ML) є відносно новим напрямом, який поєднує переваги машинного навчання та класичних фізичних моделей (Raissi et al., 2018). У таких підходах фізичні закони (наприклад, рівняння хвиль або дифузії) інтегруються безпосередньо в структуру моделі або функцію втрат нейронної мережі. Це дозволяє забезпечити узгодженість результатів із фізичною реальністю та зменшити потребу у великій кількості навчальних даних. Проте такі моделі є значно складнішими у реалізації та налаштуванні, оскільки вимагають точного формалізування фізичних обмежень і часто мають високу обчислювальну вартість (Karniadakis et al., 2021). У табл.1.1 відображено класи методів машинного навчання у геофізиці.

Таблиця 1.1 – Класи методів машинного навчання у геофізиці

Клас методів	Приклади алгоритмів	Основні задачі	Переваги	Обмеження
Класичне ML	SVM, Random Forest, k-NN, XGBoost	Класифікація аномалій, регресія параметрів середовища	Працює на малих наборах даних, інтерпретованість результатів, відносна простота реалізації	Погано масштабується на складні просторові структури, потребує ручного виділення ознак
Глибоке навчання	CNN, RNN, LSTM, U-Net, Transformers	Обробка зображень (сейсміка, GPR), сегментація, детекція об’єктів, реконструкція структур	Висока точність, автоматичне виділення складних ознак, ефективність для великих даних	Потребує великих розмічених датасетів, значні обчислювальні ресурси, низька інтерпретованість
Physics-informed ML	PINNs, hybrid inversion networks	Інверсія фізичних параметрів, моделювання хвильових процесів,	Поєднання фізичних законів і даних, краща узгодженість з реальністю, менша потреба в даних	Складність навчання, висока обчислювальна складність, складна формалізація фізичних обмежень

		реконструкція середовища		
--	--	-----------------------------	--	--

Класичні алгоритми машинного навчання довгий час були основним інструментом у геофізиці до широкого впровадження методів глибокого навчання. Їхня популярність історично зумовлена відносною простотою реалізації, невисокими вимогами до обчислювальних ресурсів та можливістю працювати з обмеженими обсягами польових даних, які традиційно є типовими для геофізичних досліджень.

У геофізичних задачах такі методи застосовуються переважно для аналізу структурованих або попередньо оброблених даних, де сигнал уже представлений у вигляді набору числових ознак. Найчастіше це включає (Bergen et al., 2019):

- класифікацію геологічних фацій, де за набором параметрів (щільність, швидкість поширення хвиль, амплітудні характеристики) визначається тип породи або осадового середовища;
- виявлення аномалій у сейсмічних або георадарних (GPR) даних, зокрема локальних відхилень сигналу, які можуть відповідати пустотам, тріщинам або включенням іншого матеріалу;

- прогнозування фізичних параметрів середовища, таких як швидкість поширення сейсмічних хвиль, пористість, насиченість вологою або інші петрофізичні характеристики.

Support Vector Machines (SVM) застосовуються для задач класифікації геологічних структур, особливо у випадках, коли межі між класами є слабо лінійно роздільними (Burgess, 1998). Завдяки використанню ядрових функцій SVM здатні моделювати складні розділювальні поверхні у багатовимірному просторі ознак,

що робить їх ефективними для задач інтерпретації сейсмічних та GPR-даних з обмеженою кількістю прикладів.

Random Forest широко використовується для роботи з табличними геофізичними даними, де кожен зразок описується набором числових характеристик (Burges, 1998). Його перевагою є здатність обробляти нелінійні залежності між ознаками, стійкість до шуму та відносно висока інтерпретованість через аналіз важливості ознак. Це робить його популярним у задачах класифікації та оцінки параметрів середовища.

Gradient Boosting (XGBoost, LightGBM) використовується переважно для регресійних задач, де необхідно прогнозувати неперервні фізичні параметри (Chen & Guestrin, 2016). Ці алгоритми будують ансамбль слабких моделей, послідовно мінімізуючи помилки попередніх ітерацій, що забезпечує високу точність навіть на складних і зашумлених наборах даних. У геофізиці вони часто застосовуються для інверсії параметрів середовища та побудови емпіричних моделей залежностей між сигналом і фізичними властивостями порід.

Основна перевага класичних ML-методів полягає у їхній відносній інтерпретованості та здатності ефективно працювати на малих або середніх вибірках даних, що є типовим для польових геофізичних експериментів. Крім того, вони менш вимогливі до обчислювальних ресурсів і можуть бути швидко інтегровані у прикладні системи аналізу.

Водночас їхнім ключовим обмеженням є недостатня здатність до моделювання просторово-структурованих залежностей у вихідних сигналах. Оскільки ці алгоритми працюють із попередньо сформованими ознаками, вони не враховують локальні просторові кореляції та морфологію сигналу безпосередньо. У результаті втрачається значна частина інформації, що міститься у первинних геофізичних даних, особливо у випадках складних хвильових полів, характерних для сейсміки та георадарних досліджень.

Глибоке навчання стало ключовим інструментом сучасної геофізики завдяки здатності автоматично витягувати багаторівневі та ієрархічні ознаки безпосередньо з сирих вимірюваних сигналів. На відміну від класичних підходів, які потребують попереднього ручного виділення характеристик, глибокі нейронні мережі навчаються безпосередньо на первинних даних (raw data), що особливо важливо для складних хвильових полів із високим рівнем шуму та нелінійними спотвореннями.

У геофізичних задачах це дозволяє істотно зменшити залежність результатів від експертної інтерпретації та підвищити відтворюваність аналізу. Крім того, моделі глибокого навчання здатні враховувати просторові та часові залежності, які традиційні алгоритми часто ігнорують або описують лише опосередковано через набір ознак.

Convolutional Neural Networks (CNN) – використовуються для аналізу сейсмічних розрізів та георадарних (GPR) радарограм (Omarkhanova & Oralbekova, 2024). Завдяки механізму згорток CNN ефективно виділяють локальні просторові патерни, такі як гіперболи, межі шарів та дифракційні структури. Це робить їх особливо придатними для задач автоматичного розпізнавання геологічних структур.

U-Net – спеціалізована архітектура для задач сегментації, яка широко застосовується у 2D та 3D геофізичних даних. Її симетрична структура з «encoder–decoder» дозволяє одночасно зберігати глобальний контекст і детальну просторову інформацію (Omarkhanova & Oralbekova, 2024). Це критично важливо для виділення складних геологічних об'єктів, таких як пустоти, тріщини, канали або антропогенні структури.

Recurrent Neural Networks (RNN, LSTM) – орієнтовані на обробку послідовних даних і використовуються для аналізу часових рядів у геофізиці (Omarkhanova & Oralbekova, 2024). Вони дозволяють моделювати залежності у сигналах, що змінюються в часі, наприклад у сейсмічному моніторингу або при аналізі динаміки

хвильових процесів. LSTM-архітектури особливо ефективні для довготривалих залежностей, де класичні RNN втрачають стабільність.

Transformers – сучасний клас моделей, який спочатку був розроблений для задач обробки природної мови, але наразі активно застосовується у геофізиці (Omarkhanova & Oralbekova, 2024). Завдяки механізму attention вони здатні моделювати довгі просторово-часові залежності без обмежень, притаманних рекурентним мережам. Це робить їх перспективними для задач інверсії параметрів середовища та аналізу великих 3D/4D геофізичних масивів. У табл.1.2 відображено використання глибокого навчання у геофізиці.

Таблиця 1.2 – Використання глибокого навчання у геофізиці

Архітектура	Тип даних	Основна задача	Приклад застосування
CNN	Зображення (GPR, сейсміка)	Виявлення структур	Автоматичне розпізнавання шарів, гіпербол та аномалій
U-Net	2D/3D дані	Сегментація геологічних об'єктів	Виявлення пустот, тріщин, підземних структур
LSTM	Часові ряди	Прогнозування сигналів	Сейсмічний моніторинг, аналіз динаміки сигналів
Transformer	Великі просторово-часові набори	Моделювання довгих залежностей	Інверсія параметрів середовища, 3D реконструкція структур

Загалом використання глибокого навчання у геофізиці дозволяє перейти від ручної інтерпретації до автоматизованого аналізу даних із високим рівнем деталізації. Водночас ефективність таких моделей значною мірою залежить від якості навчальних вибірок, їхньої репрезентативності щодо реальних геологічних умов, а також коректного вибору архітектури під конкретну фізичну задачу.

У георадарних дослідженнях методи глибокого навчання (DL) застосовуються для вирішення широкого спектра задач, пов'язаних з автоматизацією інтерпретації радарограм та підвищенням точності виділення підповерхневих структур (Yu & Ma, 2021). Одним із ключових напрямів є автоматичне виявлення гіперболічних відгуків, які найчастіше відповідають точковим або компактним об'єктам у ґрунті (камені, труби, археологічні артефакти, порожнини). Нейронні мережі навчаються розпізнавати характерну геометричну форму гіперболи навіть у випадках сильного шуму або перекриття сигналів.

Іншим важливим застосуванням є очищення сигналу від шумів та артефактів, де DL-моделі виконують роль нелінійних фільтрів. Такі моделі можуть відокремлювати корисну складову сигналу від технічних завад, мультиплікативного шуму та фонового випромінювання середовища, зберігаючи при цьому структурні особливості відбиттів (Yu & Ma, 2021). Це є суттєвим покращенням порівняно з класичними методами фільтрації, які часто призводять до втрати корисної інформації.

Важливим напрямом також є сегментація шарів ґрунту, де нейронні мережі, зокрема архітектури типу U-Net або її модифікації, використовуються для виділення меж між геологічними горизонтами. Це дозволяє автоматично будувати стратиграфічні моделі, що раніше вимагало значних експертних зусиль і часу (Yu & Ma, 2021). У результаті можна отримувати більш об'єктивні та відтворювані геологічні інтерпретації. Окремо слід відзначити реконструкцію 3D-моделей підповерхневих структур, яка базується на обробці серій 2D-сканів або безпосередньо 3D-об'ємних даних. Глибокі нейронні мережі дозволяють інтегрувати інформацію з різних профілів, формуючи цілісне уявлення про просторову структуру середовища. Це особливо важливо у задачах інженерної геофізики та археології, де необхідно точно локалізувати об'єкти у тривимірному просторі.

Серед архітектур глибокого навчання Convolutional Neural Networks (CNN) є найбільш поширеними у роботі з георадарними даними, оскільки радарограми можуть бути представлені у вигляді двовимірних зображень. У такій інтерпретації локальні патерни сигналу – гіперболи, лінійні відбиття, дифракційні структури – відповідають фізичним об'єктам або межах геологічних шарів (Yu & Ma, 2021). Завдяки механізму згорток CNN ефективно виявляють ці локальні ознаки навіть у складних шумових умовах.

Водночас застосування DL у георадарних задачах має низку суттєвих обмежень. Насамперед це потреба у великих обсягах розмічених даних, оскільки якість навчання на пряму залежить від репрезентативності вибірки. У геофізиці такі дані часто є обмеженими через високу вартість польових досліджень і складність точної розмітки підповерхневих об'єктів. Другою проблемою є складність генералізації моделей між різними геологічними умовами. Модель, навчена на даних одного регіону або типу ґрунту, може суттєво втрачати точність при перенесенні на інші умови через зміну електромагнітних властивостей середовища та структури шумів.

Третім критичним обмеженням є залежність від якості синтетичних датасетів, які часто використовуються для попереднього навчання моделей. Якщо фізичні параметри моделювання або шумові характеристики не відповідають реальним умовам, це призводить до зміщення (bias) моделі та зниження її практичної ефективності при роботі з польовими даними.

Окремий напрям у сучасній геофізиці становлять фізично інформовані нейронні мережі (Physics-Informed Neural Networks, PINNs), які принципово відрізняються від класичних та стандартних deep learning підходів тим, що інтегрують фізичні закони безпосередньо у процес навчання моделі (Raissi et al., 2018). Замість того щоб покладатися виключно на емпіричні дані, такі моделі враховують відомі диференціальні рівняння, які описують фізику процесу,

наприклад рівняння хвиль, рівняння дифузії або рівняння Максвелла для електромагнітного поля.

У PINNs фізичні закони зазвичай вводяться через модифікацію функції втрат: до стандартної похибки між передбаченням і даними додається додатковий компонент, який штрафує модель за порушення фізичних рівнянь (Raissi et al., 2018). Таким чином, нейронна мережа навчається не лише апроксимувати дані, а й дотримуватися фізично коректної поведінки системи в кожній точці простору та часу. Це робить підхід особливо цінним для геофізичних задач, де повні та точні навчальні вибірки часто недоступні. У георадарних і сейсмічних задачах PINNs дозволяють виконувати інверсію параметрів середовища, тобто відновлювати фізичні характеристики (швидкість хвиль, діелектричну проникність, щільність) безпосередньо з виміряними сигналами, при цьому забезпечуючи узгодженість із хвильовою фізикою (Raissi et al., 2018). Це суттєво зменшує ризик фізично некоректних рішень, які іноді виникають у чисто data-driven моделях.

Однією з головних переваг є зменшення потреби у великих розмічених датасетах. Оскільки частина інформації «закладена» у вигляді фізичних рівнянь, модель може навчатися навіть на обмежених або частково спостережуваних даних. Це особливо важливо для польових геофізичних досліджень, де збір даних є дорогим і трудомістким процесом.

Другою важливою перевагою є відповідність фізичним законам, що забезпечує більш реалістичні результати моделювання. На відміну від класичних нейронних мереж, які можуть генерувати математично коректні, але фізично абсурдні рішення, PINNs обмежують простір можливих розв'язків фізичними рівняннями (Raissi et al., 2018).

Третьою перевагою є підвищена стабільність при інверсійних задачах, де необхідно відновити параметри середовища за непрямыми спостереженнями. Завдяки фізичним обмеженням модель стає менш чутливою до шуму та неповноти даних. Попри свої переваги, PINNs мають суттєві обмеження. Насамперед це

висока обчислювальна складність, оскільки навчання моделі вимагає одночасного розв'язання оптимізаційної задачі з великою кількістю фізичних обмежень, що значно збільшує час тренування.

Другою проблемою є складність формалізації граничних умов. Для коректного застосування PINNs необхідно точно задати фізичні обмеження системи (boundary conditions та initial conditions), що в реальних геофізичних умовах часто є неповністю відомим або наближеним (Raissi et al., 2018). Третьою істотною проблемою є обмежена масштабованість для 3D задач, оскільки збільшення розмірності простору різко підвищує обчислювальну складність і вимоги до пам'яті, що ускладнює застосування PINNs для великих геофізичних об'ємів. У табл.1.3 відображено порівняння підходів ML у геофізиці.

Таблиця 1.3 – Порівняння підходів ML у геофізиці

Підхід	Дані	Потреба в розмітці	Інтерпретованість	Точність	Обчислювальна складність
Classical ML	Табличні	Низька	Висока	Середня	Низька
Підхід	Дані	Потреба в розмітці	Інтерпретованість	Точність	Обчислювальна складність
Deep Learning	Зображення / сигнали	Висока	Низька	Висока	Висока
PINNs	Фізичні поля	Середня	Середня	Висока	Дуже висока

Методи машинного та глибокого навчання суттєво розширюють можливості сучасної геофізики, забезпечуючи автоматизацію інтерпретації складних багатовимірних даних. Водночас їх ефективність залежить від якості навчальних

даних, вибору архітектури та врахування фізичних властивостей середовища. Найперспективнішим напрямом є гібридні підходи, що поєднують фізичне моделювання та нейронні мережі, забезпечуючи баланс між точністю та інтерпретованістю результатів.

Висновки до розділу 1

Теоретико-методологічний аналіз георадарного зондування свідчить, що цей метод є фундаментально обґрунтованим електромагнітним способом дослідження підповерхневих середовищ, ефективність якого базується на взаємодії високочастотних імпульсів із матеріалами з різними показниками діелектричної проникності та електропровідності. У ході дослідження було встановлено, що фізичні принципи поширення хвиль, описані рівняннями Максвелла, визначають як високу роздільну здатність методу, так і його природні обмеження, зокрема значне затухання сигналу у провідних та вологих середовищах. Завдяки здатності до неруйнівного контролю та оперативного отримання даних, георадіолокація стала незамінною в інженерній геології, археології та будівництві, проте складність хвильової картини часто перешкоджає однозначній фіксації підземних об'єктів.

Аналіз проблематики традиційної інтерпретації даних показав, що ручний підхід до аналізу радарограм на сучасному етапі є недостатньо ефективним через високу суб'єктивність та залежність від досвіду оператора. Виявлено, що складні умови зондування у неоднорідних або сильно зашумлених середовищах створюють геометричну неоднозначність, коли корисні сигнали (наприклад, гіперболічні відбиття) маскуються артефактами або паразитними завадами. Крім того, стрімке зростання обсягів цифрової інформації при 3D-скануванні робить ручну обробку надзвичайно трудомісткою, що зумовлює критичну потребу у переході до автоматизованих систем аналізу, здатних забезпечити високу відтворюваність та об'єктивність результатів.

Огляд сучасних досягнень у галузі штучного інтелекту демонструє, що інтеграція методів машинного та глибокого навчання є найбільш перспективним шляхом розвитку геофізичних методів. Використання згорткових нейронних мереж (CNN) та архітектур типу U-Net дозволяє автоматизувати виявлення структурних елементів, сегментацію шарів та фільтрацію шумів безпосередньо з «сирих» сигналів, що мінімізує вплив людського фактора. Встановлено, що поєднання класичних фізичних моделей із глибоким навчанням та механізмами уваги (Transformers) забезпечує новий рівень точності при реконструкції підповерхневого середовища. Таким чином, створення інтелектуальних алгоритмів обробки георадарних даних є необхідною умовою для підвищення достовірності інтерпретації у складних геологічних та техногенних умовах.

РОЗДІЛ 2. МЕТОДИКА ДОСЛІДЖЕНЬ ТА ОЦІНКА ЕФЕКТИВНОСТІ АВТОМАТИЗАЦІЇ

2.1. Методика проведення польових георадарних обстежень та збору даних

Організація та проведення польових георадарних досліджень вимагають ретельної попередньої підготовки, яка є запорукою отримання якісних та достовірних даних для подальшої автоматизованої обробки. З огляду на практичний досвід, на підготовчому етапі необхідно провести комплексний збір та аналіз апіорної інформації щодо досліджуваної ділянки. Цей процес включає наступні ключові кроки:

Визначення цільового призначення та завдань досліджень. Узгодження кінцевої мети обстеження (наприклад, орієнтовна глибина залягання цільового об'єкта, картування інженерних комунікацій або пошук зон тріщинуватості). Ця інформація є визначальною для обґрунтованого вибору центральної частоти антенного блоку георадара: високочастотні антени забезпечують високу роздільну здатність на малих глибинах, тоді як низькочастотні дозволяють досліджувати глибші горизонти з меншою детальністю.

Апіорний аналіз геологічної та техногенної будови ділянки. Встановлення типу поверхні та підстилаючих порід (пісок, суглинок, глина, наявність бетонних або залізобетонних перекриттів, льодового покриву тощо). Ці дані є критично важливими для попередньої оцінки діелектричної проникності середовища, що дозволяє коректно відкалібрувати швидкість поширення електромагнітної хвилі для точного перерахунку часового розрізу в глибинний.

Оцінка метеорологічних умов. Аналіз погодних умов у період, що передуює польовим роботам, та безпосередньо в день зйомки. Як зазначалося раніше, підвищена вологість ґрунтів призводить до зростання їх електропровідності, що суттєво посилює затухання електромагнітного сигналу та зменшує ефективну глибину зондування.

Проектування мережі профілів. На основі площі ділянки (наприклад, при обстеженні масштабних майданчиків площею до 10 га) та необхідної деталізації визначається оптимальний крок між профілями. Вибір відстані між паралельними лініями зондування (зазвичай від 1 м до 1,5 м) залежить від розмірів шуканих об'єктів та дозволяє забезпечити необхідну щільність покриття для коректної побудови 3D-моделей. Також це крок є необхідним з тієї причини, що йде попередній розрахунок часу який буде затрачений на зйомку.

Вибір та налаштування апаратного забезпечення. Підготовка георадарного комплексу (наприклад, систем серії VIY або їх аналогів) і налаштування параметрів реєстрації сигналу (часове вікно, кількість точок на трасу, параметри накопичення) відповідно до умов конкретного технічного завдання.

Після завершення підготовчого етапу та узгодження технічного завдання формується апаратно-технічний комплекс для проведення польових вимірювань. До обов'язкового переліку обладнання та спорядження входять:

Антенний блок георадара (наприклад, обраної серії VIY), центральна частота якого відповідає поставленим завданням щодо необхідної глибини зондування та роздільної здатності.

Транспортувальні засоби та системи кріплення. Спеціалізований георадарний візок, транспортні сани або ремінні кріплення, які забезпечують рівномірне переміщення антени вздовж профілю зі збереженням постійного контакту з досліджуваною поверхнею.

Системи позиціонування та синхронізації. Залежно від умов зйомки та конфігурації приладу, використовується одометр (мірне колесо) для точної прив'язки випромінюваних імпульсів до пройденої відстані, або ж високоточний GPS/GNSS-приймач для глобальної геопросторової фіксації кожної траси (геореференціювання).

Реєстратор даних (блок керування). Захищений польовий ноутбук, планшет або спеціалізований контролер із встановленим програмним забезпеченням для

збору, візуалізації та збереження отриманих сигналів у режимі реального часу. Для зручності оператора також передбачаються відповідні ергономічні розвантажувальні кріплення.

Система комутації та енергозабезпечення. Комплект захищених інтерфейсних кабелів для надійної передачі даних між антенним блоком та реєстратором, а також додаткові автономні джерела живлення (акумуляторні батареї) з кабелями живлення.

Допоміжне геодезичне та маркувальне спорядження. Засоби для розбивки сітки профілів і просторової фіксації реперних точок на місцевості, що включають мірні стрічки (рулетки), розміточні шнури, кілочки, а також матеріали для візуального маркування (аерозольна фарба, крейда) для позначення траєкторій або виявлених аномалій безпосередньо на об'єкті. Процес безпосереднього виконання польових георадарних вимірювань складається з кількох послідовних етапів, суворе дотримання яких гарантує високу якість зібраних даних та їхню придатність для подальшого аналізу і застосування алгоритмів машинного навчання. Практична реалізація польових робіт передбачає наступні кроки:

Етап просторової підготовки (розграфка території) - безпосередньо на об'єкті дослідження першочерговим завданням є просторова підготовка ділянки. За допомогою мірних стрічок (рулеток) та маркувальних засобів (крейда, фарба, кілки) виконується оконтурювання меж досліджуваної території та розбивка (розграфка) опорної сітки профілів. Позначення пікетів і ліній зондування дозволяє чітко зафіксувати геометрію ділянки, забезпечити прямолінійність траєкторій сканування та уникнути пропусків під час зйомки.

Налаштування та калібрування апаратури - тільки після завершення просторової розмітки здійснюється ініціалізація та калібрування георадарного комплексу. При використанні сучасних систем (зокрема, георадарів серії VIY) цей етап є критично важливим і включає:

- калібрування вимірювального колеса (одометра) для точної просторової прив'язки трас до пройденої відстані;
- калібрування датчиків нахилу (інклінометрів), що необхідно для введення топографічних поправок у складних умовах рельєфу;
- конфігурацію параметрів реєстрації та налаштування онлайн-фільтрів для первинного придушення високочастотних завад і стабілізації сигналу безпосередньо у процесі вимірювання.

Процес зйомки та ведення польової документації - після підключення приладу до реєстратора даних та джерела автономного живлення розпочинається безпосередня зйомка. Оператор плавно переміщує антенний блок уздовж заздалегідь розмічених траєкторій.

Для забезпечення відтворюваності результатів та можливості їх подальшої автоматизованої обробки (зокрема, алгоритмами машинного навчання), невід'ємною складовою польових робіт є суворе ведення польового журналу. Незалежно від формату (електронна таблиця чи класичний паперовий блокнот), у журналі обов'язково фіксується вичерпна метаінформація:

- назва та номер файлу-профілю;
- напрямок проходження (азимут або прив'язка до локальної системи координат сітки);
- використана центральна частота антенного блока;
- встановлене значення швидкості поширення електромагнітної хвилі в середовищі;
- тип системи просторового позиціонування (одометр або GPS/GNSS-приймач);
- встановлений крок сканування (відстань між трасами) та часове вікно реєстрації;
- координати початкового та кінцевого пікетів;

- позначки про локальні об'єкти на поверхні або перешкоди (металеві люки, бордюри, зміна типу покриття, калюжі, лінії електропередач), які здатні генерувати паразитні сигнали або артефакти на радарограмі.

Якість ведення польового журналу, може допомогти уникнути непорозумінь під час інтерпретації. Після завершення робіт, обсяг напрацювань, слід вивантажити на фізичний носій для передачі даних уже безпосередньо інтерпретатору.

2.2. Експериментальне порівняння: ручна інтерпретація проти автоматизованого аналізу

Розглянемо процес ручної (експертної) обробки та візуальної інтерпретації радарограм. Насамперед виконується структуризація та сортування масиву "сирих" польових даних, особливо у випадках, коли алгоритм збереження та створення директорій не був чітко заданий безпосередньо під час зйомки.

Порівняльний аналіз підходів до інтерпретації у цій роботі базуватиметься на наборі даних, отриманому в березні 2024 року під час обстеження підземного дериваційного тунелю (рис. 2.1), призначеного для подачі води з верхнього водоймища на турбіну гідроакумулювальної електростанції (ГАЕС). Головною метою дослідження була локалізація, оцінка масштабів та просторове оконтурювання зон підвищеної тріщинуватості залізобетонного тунелю. З огляду на необхідність поєднання достатньої глибини зондування з високою роздільною здатністю, для виконання робіт було обрано антенні блоки з центральними частотами 600 МГц та 1500 МГц.




Рисунок 2.1 – Об'єкт проведення зйомки

Камеральна обробка та аналіз результатів зондування виконувалися в спеціалізованому програмному середовищі Synchro, розробленому для георадарних систем серії VIY-5. На початковому етапі з бази даних імпортується обраний профіль, який відображається у вигляді первинної (необробленої) радарограми (рис. 2.2).




Рисунок 2.2 – Первинний (вихідний) вигляд радарограми у середовищі Synchro

Для забезпечення коректної експертної оцінки та ефективної візуальної ідентифікації структур, хвильова картина потребує попередньої цифрової підготовки. За допомогою вбудованого інструментарію програмного комплексу до хвильового поля застосовуються процедури підсилення амплітуди корисного сигналу (компенсація геометричного розходження та затухання в середовищі), а також набір частотних і просторових фільтрів. Для підвищення візуального контрасту між різними елементами структури та фоновим шумом застосовується налаштування кольорового кодування – палітри амплітуд (рис. 2.3).




Рисунок 2.3 – Радарограма після застосування процедур підсилення сигналу та налаштування кольорової градації

Наступним етапом є безпосередня геологічна інтерпретація, що полягає у візуальному виділенні та маркуванні точкових аномалій, локальних зон розущільнення (тріщинуватості) та меж структурних шарів (рис. 2.4). Цей процес реалізується за допомогою графічних інструментів анотування, доступних у програмному забезпеченні.




Рисунок 2.4 – Візуальна ідентифікація та оконтурювання аномальних зон на радарограмі

Для подальшого використання результатів експертної інтерпретації (зокрема, для формування наборів навчальних даних для алгоритмів машинного навчання або включення до звітів) створюється структурована файлова директорія. Відредаговані та розмічені радарограми експортуються у графічних форматах стиснення без втрат (наприклад, .bmp), що дозволяє зберегти максимальну деталізацію обробленого зображення (рис. 2.5).




Рисунок 2.5 – Результат експорту обробленої та проінтерпретованої
радарограми у форматі .bmp

Другим етапом порівняльного дослідження є застосування процедури автоматизованого аналізу георадарних даних. Для забезпечення коректної роботи алгоритмів машинного навчання принципово важливою є стандартизація вхідного датасету. Насамперед у середовищі Synchro здійснюється збереження користувацького набору параметрів, який включає оптимальну конфігурацію частотних фільтрів та функцій підсилення сигналу, адаптовану до специфіки конкретного об'єкта. Збереження цього налаштування (рис. 2.6) є необхідним запобіжним заходом, який гарантує збереження еталонної конфігурації обробки та мінімізує ризик втрати даних через людський фактор.




Рисунок 2.6 – Збереження конфігураційного набору фільтрів та параметрів підсилення

Наступним кроком є використання програмного комплексу Planner, який інтегрований із Synchro та застосовується для просторової прив'язки пройдених профілів на топографічній основі чи в межах 3D-моделі ділянки. Критичною вимогою для автоматизованого аналізу є ідентичність параметрів попередньої обробки всього масиву даних. За допомогою функціоналу Planner попередньо налаштований профіль обирається як еталонний. Після цього його параметри цифрової обробки в пакетному режимі автоматично застосовуються до всіх інших радарограм датасету (рис. 2.7), що забезпечує необхідну уніфікацію.




Рисунок 2.7 – Пакетне зведення первинних налаштувань масиву профілів до еталонного зразка

Після стандартизації весь масив профілів експортується у цільову директорію для подальшої обробки за допомогою розробленого програмного застосунку GPR AI Vision (рис. 2.8). Графічний інтерфейс користувача (GUI) застосунку GPR AI Vision дозволяє вказати шлях до директорії з підготовленим датасетом. Під час виконання аналізу в основному робочому вікні формується динамічний лог-звіт, який відображає статус кожної радарограми: наявність структурних відхилень (маркер «ЗНАЙДЕНО») або їх відсутність (маркер «ЧИСТО»).

Підсумкова статистика обробки базується на трьох ключових метриках:

- **Аномалії** – кількість радарограм, на яких алгоритмом було ідентифіковано зони підвищеної тріщинуватості або інші структурні порушення.
- **Норма** – кількість радарограм, класифікованих як однорідні ділянки без аномалій або ж надто зашумлені зони які не піддалися алгоритму.
- **Разом** – загальний обсяг проаналізованих файлів у датасеті.

По завершенні процесу програма генерує фінальний звіт, як і вказано щодо мого датасету - «ОБРОБКА ЗАВЕРШЕНА. Всього файлів: 73. Виявлено аномалій: 27. Чистих ділянок: 46») та виводить шлях до новоствореної директорії (зокрема, *C:/Sheva/Diplom/2/complete_auto/GPR_ANALYSIS*). У цій теці зберігаються результуючі графічні файли із візуально розміченими (оконтуреними) аномаліями, що завершує цикл автоматизованої детекції.




Рисунок 2.8 – Інтерфейс розробленого програмного застосунку GPR AI Vision та результати його роботи

Результат (рис. 2.9) обробки моделлю на прикладі однієї із радарограм.




Рисунок 2.8 – Результат обробки моделлю

2.3. Оцінка часової рентабельності та оптимізації робочого процесу фахівця

Для об'єктивної оцінки практичної ефективності розробленого програмного застосунку GPR AI Vision було проведено порівняльний хронометраж процесів ручної та автоматизованої інтерпретації георадарних даних. Експериментальною базою слугував стандартизований набір даних, що складався з 73 радарограм. Оскільки експертний візуальний аналіз підтвердив наявність зон тріщинуватості на всіх 73 профілях, цей масив є репрезентативним для оцінки точності та швидкодії алгоритму.

2.3.1 Оцінка трудовитрат при традиційному (ручному) підході

Традиційний алгоритм роботи передбачає послідовний візуальний аналіз кожної радарограми оператором. За результатами хронометражу, середній час, витрачений фахівцем на повний цикл обробки одного профілю (завантаження, налаштування фільтрів, візуальна ідентифікація та графічне оконтурювання аномалій), становить близько 5 хвилин.

Загальний час ручної обробки: $73 \text{ профілі} \times 5 \text{ хв} = 365 \text{ хвилин}$ (6 годин 5 хвилин).

2.3.2 Оцінка трудовитрат при гібридному (автоматизованому) підході

Використання розробленого застосунку GPR AI Vision змінює парадигму обробки, переводячи її у формат "людина в циклі" (Human-in-the-loop). Автоматизований прогін усього масиву з 73 файлів з урахування попередньої виграшки кожної радарограми у формат .bmp, тривав 49 хвилин. Проте алгоритм успішно ідентифікував аномалії лише на 27 радарограмах. Решта 46 профілів (73 - 27) були класифіковані моделлю як "норма" (або містили невпевнену детекцію), що в умовах даного об'єкта є хибним результатом і вимагає обов'язкового ручного доопрацювання фахівцем.

Відповідно, загальний час гібридного робочого процесу складається з часу машинної роботи та часу експертного доопрацювання:

1. Час роботи алгоритму: 49 хвилин.
2. Час на ручне доопрацювання залишку: $46 \text{ профілів} \times 5 \text{ хв} = 230 \text{ хвилин}$.
3. Загальний час гібридної обробки: $49 + 230 = 279 \text{ хвилин}$ (4 години 39 хвилин).

2.3.3 Аналіз часової рентабельності та ефективності методу

Шляхом порівняння двох підходів встановлено абсолютну та відносну економію робочого часу фахівця:

- Абсолютна економія: $365 \text{ хв} - 279 \text{ хв} = 86 \text{ хвилин}$ (1 година 26 хвилин).
- Відносна оптимізація процесу: зменшення часових витрат на 23,6%.

На основі отриманих розрахунків можна виділити наступні переваги та обмеження автоматизованого підходу.

2.3.4 Переваги (сильні сторони)

Використання застосунку дало змогу оптимізувати процес обробки даних та скоротити загальний час роботи майже на чверть, навіть з урахуванням необхідності ручного втручання. Програма ефективно виконує функцію первинного фільтра, автоматично закриваючи найбільш очевидні випадки (27 профілів), що дозволяє зменшити когнітивне навантаження на фахівця та звільнити

його від частини монотонної рутинної роботи. У результаті змінюється і роль оператора: замість первинної обробки даних фахівець переходить до функції експерта-верифікатора, зосереджуючи увагу переважно на складних та неоднозначних ділянках радарограм.

2.3.5 Недоліки (обмеження)

Результати дослідження також показали наявність значної кількості хибних результатів: алгоритм пропустив аномалії на 46 профілях, що становить понад 60% масиву. Це свідчить про те, що на поточному етапі модель не може повністю замінити фахівця та потребує подальшого донавчання, зокрема шляхом розширення датасету. Через недостатню точність детекції зберігається залежність від ручної верифікації, оскільки спеціаліст змушений додатково переглядати профілі, відбраковані алгоритмом, щоб переконатися у відсутності пропущених дефектів.

Висновки до розділу 2

У другому розділі було детально розглянуто методику проведення польових георадарних досліджень та здійснено практичну оцінку ефективності впровадження алгоритмів машинного навчання у процес камеральної обробки даних.

Встановлено, що ключовою передумовою для успішного автоматизованого аналізу є суворе дотримання етапів польової підготовки, просторової розмітки, точного калібрування апаратури (на прикладі георадарних систем серії VIY) та ретельного ведення польової документації. Збір високоякісних та консистентних даних безпосередньо в полі мінімізує кількість артефактів та забезпечує необхідну стандартизацію датасетів для їх подальшого використання у нейромережевих моделях.

На основі масиву даних, отриманих під час обстеження дериваційного тунелю гідроакумулювальної електростанції, проведено експериментальне порівняння традиційної експертної інтерпретації (у середовищі Synchro) та автоматизованого аналізу. Показано, що для коректної роботи машинного зору принципово важливою є попередня пакетна стандартизація налаштувань хвильового поля (фільтрів та підсилення) всього набору профілів за допомогою інструментарію Planner. Розроблений застосунок GPR AI Vision успішно інтегрується у цей процес, автоматизуючи детекцію та візуальне оконтурювання зон тріщинуватості.

Оцінка часової рентабельності на вибірці із 73 радарограм підтвердила практичну цінність впровадження автоматизації. Застосування концепції «людина в циклі» (Human-in-the-loop) дозволило оптимізувати робочий час фахівця на 23,6%, скоротивши тривалість обробки з 6 годин 5 хвилин до 4 годин 39 хвилин. Незважаючи на те, що на поточному етапі алгоритм демонструє значний відсоток хибних результатів (потреба у ручному доопрацюванні 46 профілів), він ефективно виконує роль первинного фільтра. Це суттєво знижує когнітивне навантаження на оператора, трансформуючи його роль із виконавця рутинної розмітки в експерта-

верифікатора, що робить гібридний метод обґрунтованим та економічно доцільним кроком у розвитку геофізичних досліджень.

РОЗДІЛ 3. ПРОГРАМНА РЕАЛІЗАЦІЯ СИСТЕМИ ІНТЕЛЕКТУАЛЬНОГО АНАЛІЗУ ГЕОРАДАРНИХ ДАНИХ

3.1. Обґрунтування вибору технологічного стека та апаратного забезпечення

Вибір інструментальних засобів для реалізації системи інтелектуального аналізу георадарних даних обумовлений необхідністю забезпечення високої обчислювальної продуктивності, гнучкості програмної реалізації та можливості обробки специфічних сигналів підповерхневого зондування у режимі, максимально наближеному до реального часу. Георадарні (GPR – Ground Penetrating Radar) дані характеризуються значним обсягом інформації, високою роздільною здатністю та наявністю складних шумових компонентів, що виникають унаслідок неоднорідності ґрунтів, різних коефіцієнтів діелектричної проникності середовища та багатократних відбиттів електромагнітних хвиль. Тому система інтелектуального аналізу повинна поєднувати ефективні алгоритми попередньої обробки сигналів, потужні методи глибокого навчання та оптимізовані апаратні ресурси.

Базовою мовою розробки програмного забезпечення було обрано Python, який у сучасних дослідженнях фактично є стандартом де-факто у сфері машинного навчання (Machine Learning), глибокого навчання (Deep Learning) та комп'ютерного зору (Computer Vision) (Python Software Foundation, n.d.). Популярність Python у наукових і прикладних дослідженнях пояснюється поєднанням простоти синтаксису, високої швидкості розробки та наявності широкої екосистеми бібліотек для аналізу даних.

Серед основних переваг використання Python у даному проєкті можна виділити (Python Software Foundation, n.d.):

- розвинену екосистему наукових бібліотек, зокрема NumPy та Pandas, які забезпечують ефективну роботу з багатовимірними масивами даних та

дозволяють реалізовувати складні процедури попередньої обробки сигналів;

- можливість швидкого прототипування алгоритмів, що особливо важливо на етапі експериментального дослідження різних архітектур нейронних мереж;
- високу сумісність із сучасними фреймворками глибокого навчання, що забезпечує інтеграцію моделей детекції об'єктів без необхідності створення власних низькорівневих реалізацій.

Для обробки георадарних даних також використовуються інструменти комп'ютерного зору, які дозволяють перетворювати сирі радіолокаційні сигнали у двовимірні радарограми (В-скани). Саме ці зображення надалі виступають вхідними даними для нейронної мережі, що виконує детекцію підземних аномалій.

Для вирішення задачі автоматичного виявлення підземних об'єктів – таких як інженерні комунікації, трубопроводи, кабелі або підземні порожнини – було обрано архітектуру YOLOv8 (You Only Look Once) у модифікації YOLOv8s (Small) (Yaseen, 2024). Ця архітектура належить до класу одностадійних (single-stage) детекторів об'єктів і характеризується високою швидкістю обробки зображень при збереженні достатньо високої точності.

Основна ідея алгоритму YOLO полягає у формулюванні задачі детекції як єдиної задачі регресії, в межах якої нейронна мережа одночасно прогнозує координати обмежувальних рамок (bounding boxes) та ймовірності належності об'єктів до певних класів. Такий підхід значно відрізняється від класичних двостадійних алгоритмів детекції, зокрема Faster R-CNN, де спочатку генеруються області-кандидати, а вже потім здійснюється їх класифікація.

Використання архітектури YOLOv8 забезпечує ряд важливих переваг для аналізу георадарних даних (Yaseen, 2024):

- високу швидкість інференсу, що дозволяє обробляти потоки В-сканів майже у реальному часі;

- ефективну роботу з об'єктами різних масштабів, що є критично важливим при виявленні як великих підземних структур, так і дрібних комунікацій;
- покращені механізми навчання, зокрема оптимізовані функції втрат та модернізовану структуру backbone і neck мережі;
- баланс між точністю та обчислювальними витратами, що робить модель придатною для використання навіть на обмежених апаратних ресурсах.

Модифікація YOLOv8s була обрана через її компактність і достатню точність, що дозволяє ефективно працювати з великими наборами георадарних даних без надмірного збільшення часу навчання моделі.

У якості основного математичного рушія системи використано бібліотеку PyTorch, яка є одним із найпопулярніших фреймворків для розробки моделей глибокого навчання (PyTorch Contributors, n.d.). PyTorch забезпечує підтримку динамічних обчислювальних графів, що значно спрощує процес розробки та налагодження нейронних мереж.

Серед ключових переваг використання PyTorch у даному дослідженні можна виділити (PyTorch Contributors, n.d.):

- можливість гнучкого конструювання архітектур нейронних мереж;
- ефективне управління тензорними операціями;
- зручні механізми автоматичного диференціювання (autograd);
- підтримку паралельних обчислень на графічних прискорювачах.

Дані можливості дозволяють реалізувати складні моделі детекції об'єктів та проводити експериментальні дослідження різних конфігурацій гіперпараметрів моделі.

Для навчання моделі було використано набір даних, що містить 2239 високороздільних зображень георадарних радарограм, отриманих при різних умовах підповерхневого зондування. Навчання моделі проводилось на сучасній обчислювальній платформі з уніфікованою архітектурою пам'яті та інтегрованим

графічним процесором (GPU), що забезпечує високу швидкість виконання тензорних операцій.

Використання графічного прискорення дозволяє ефективно розпаралелювати основні математичні операції, які виникають під час навчання нейронних мереж, зокрема множення великих матриць, обчислення градієнтів та виконання операцій згортки.

Використання графічного процесора дозволяє виконувати тисячі обчислювальних потоків одночасно, що суттєво скорочує час навчання нейронної мережі та дозволяє зменшити тривалість однієї епохи навчання до десятків секунд. Для підвищення продуктивності обчислень застосовуються спеціалізовані програмні бібліотеки, що забезпечують ефективний обмін даними між центральним процесором (CPU) та графічним процесором (GPU). Використання механізмів прямого доступу до пам'яті (Direct Memory Access, DMA) дозволяє мінімізувати затримки під час передачі батчів даних у процесі навчання моделі.

Сучасні графічні процесори містять спеціалізовані обчислювальні блоки, оптимізовані для виконання операцій над числами з плаваючою комою, що забезпечує високу точність обчислень під час виконання алгоритмів оптимізації, таких як градієнтний спуск, і сприяє стабільному процесу навчання нейронної мережі.

Застосований стек технологій поєднує сучасні програмні інструменти, алгоритми глибокого навчання та високопродуктивні апаратні ресурси. Такий підхід дозволяє створити масштабовану систему інтелектуального аналізу георадарних даних, здатну адаптуватися до різних параметрів зондування, зокрема частот 200 МГц та 400 МГц, а також працювати в умовах складної геологічної структури середовища.

3.2. Підготовка та аналіз набору даних GPR_Data

Одним із ключових етапів розробки системи інтелектуального аналізу георадарних сигналів є формування якісного навчального набору даних. Для проведення експериментальних досліджень було використано відкритий набір даних GPR_Data, який містить високороздільні георадарні зображення, отримані під час реальних інженерних обстежень підземної інфраструктури.

Набір даних призначений для задач автоматичного виявлення підземних об'єктів за допомогою методів машинного навчання та містить як сирі георадарні сигнали, так і підготовлені зображення радарограм з відповідними анотаціями. Дані були зібрані під час геофізичних досліджень у різних містах і населених пунктах Могоссо у період з 2019 по 2024 рік у межах інфраструктурних та інженерних проєктів, що забезпечує різноманітність геологічних умов та типів підземних об'єктів (Mojahid et al., 2024).

Набір GPR_Data складається з 2239 зображень георадарних профілів, які представляють собою радарограми типу A-scan та B-scan (Mojahid et al., 2024).

A-scan відображає часову залежність амплітуди відбитого електромагнітного сигналу в одній точці вимірювання, тоді як B-scan формується шляхом послідовного поєднання багатьох А-сканів під час переміщення антени вздовж поверхні. У результаті формується двовимірне зображення, яке відображає структуру підповерхневих шарів і дозволяє візуально ідентифікувати підземні об'єкти.

У наборі даних представлені три основні класи об'єктів (Mojahid et al., 2024):

- Underground utilities (Utility) – підземні інженерні комунікації (кабелі, трубопроводи тощо);
- Underground cavities (Cavity) – підземні порожнини або аномальні зони;
- Intact zones – ділянки ґрунту без виявлених аномалій.

Таблиця 3.1 – Розподіл зображень за класами

Клас	Кількість зображень
Порожнини (Cavity)	553
Підземні комунікації (Utility)	786
Нормальні ділянки (Intact)	900

Такий розподіл дозволяє формувати збалансовані вибірки для навчання нейронної мережі та зменшує ризик виникнення перекосу класів (class imbalance) під час тренування моделі.

Збір георадарних сигналів здійснювався за допомогою обладнання компанії Geophysical Survey Systems, Inc., яке широко використовується у сфері підповерхневого зондування. Для вимірювань застосовувалися дві антени з різними робочими частотами (Mojahid et al., 2024):

- 400 МГц
- 200 МГц

Використання різних частот зондування дозволяє досягти компромісу між глибиною проникнення сигналу та просторовою роздільною здатністю (Mojahid et al., 2024):

- антена 400 МГц забезпечує вищу деталізацію, але меншу глибину проникнення;
- антена 200 МГц дозволяє досліджувати глибші шари ґрунту, однак із дещо нижчою роздільною здатністю.

У таблиці 3.2 відображено параметри вимірювання георадарних антен.

Таблиця 3.2 – Параметри вимірювання георадарних антен

Параметр	Антенa 400 МГц	Антенa 200 МГц
Робоча частота антени	400 МГц	200 МГц
Діапазон сканування	50 нс	150 нс
Коефіцієнт підсилення (Gain point)	5	5
Вертикальний фільтр Low-pass	800 МГц	400 МГц
Вертикальний фільтр High-pass	100 МГц	30 МГц
Кількість відліків у одному скані	512 samples	512 samples

Параметри діелектричної проникності середовища під час обробки сигналів змінювалися залежно від типу досліджуваного матеріалу, що дозволяло точніше визначати глибину розташування об'єктів.

Для створення навчальної вибірки всі зображення були вручну анотовані за допомогою онлайн-інструменту [MakeSense.ai](https://makesense.ai). У процесі анотації експерти позначали області з підземними об'єктами за допомогою обмежувальних рамок (bounding boxes), які містять координати об'єкта на радарограмі та його клас.

Розмітка експортувалася у двох форматах (Mojahid et al., 2024):

- YOLO format (.txt) – використовується для навчання моделей сімейства YOLO;
- VOC XML format – універсальний формат анотацій, сумісний з багатьма алгоритмами комп'ютерного зору.

Наявність двох форматів розмітки забезпечує універсальність використання набору даних у різних дослідницьких задачах.

Перед використанням набору даних у процесі навчання нейронної мережі було виконано низку етапів попередньої обробки. Оригінальні георадарні профілі

мають значно більший розмір, ніж той, що оптимально підходить для навчання моделей глибокого навчання. Тому всі радарограми були розбиті на невеликі фрагменти розміром: 224 × 224 пікселі. Такий розмір був обраний для забезпечення сумісності з архітектурами глибоких нейронних мереж, що використовують transfer learning (наприклад, моделі сімейства VGG).

Розбиття великих профілів на менші фрагменти також дозволяє:

- збільшити кількість навчальних прикладів;
- локалізувати окремі аномалії;
- зменшити обчислювальні витрати під час навчання.

Для підвищення узагальнюючої здатності нейронної мережі було застосовано методи штучного розширення вибірки (data augmentation). Аугментація виконувалася за допомогою скрипта, який генерує нові варіації зображень на основі вихідних даних.

Таблиця 3.3 – Методи розширення набору даних

Метод аугментації	Тип перетворення	Опис
Геометричні трансформації	Повороти, масштабування, віддзеркалення	Застосування випадкових геометричних перетворень до зображень для підвищення різноманітності навчальної вибірки та підвищення стійкості моделі до зміни орієнтації об'єктів.
Додавання шуму	Random noise	Додавання випадкового шуму до зображень для імітації електромагнітних перешкод та шумових компонентів, що виникають під час георадарного зондування.

Застосування цих методів дозволяє підвищити стійкість моделі до шумів та варіацій сигналів, що часто виникають під час реальних георадарних досліджень.

Набір даних має ієрархічну файлову структуру, що полегшує роботу з різними підмножинами даних. Основна папка GPR_data містить 2239 зображень разом із відповідними файлами анотацій.

Додатково в наборі присутні окремі каталоги для аугментованих даних (Mojahid et al., 2024):

- augmented_cavities – зображення з підземними порожнинами;
- augmented_utilities – зображення з інженерними комунікаціями;
- augmented_intact – зображення без аномалій.

Також у наборі зберігаються оригінальні профілі (Mojahid et al., 2024):

- 79 профілів з порожнинами;
- 131 профіль з підземними комунікаціями;
- 75 профілів без аномалій.

Набір GPR_Data є цінним ресурсом для розробки алгоритмів автоматичного аналізу георадарних сигналів. Його основними перевагами є:

- наявність реальних польових вимірювань, отриманих у різних умовах;
- великий обсяг розмічених даних для задач детекції об'єктів;
- підтримка двох частот зондування, що розширює спектр застосувань;
- використання стандартних форматів анотацій, сумісних з сучасними алгоритмами комп'ютерного зору.

Завдяки цим характеристикам набір даних може ефективно використовуватися для навчання моделей глибокого навчання, зокрема архітектур типу YOLO, для задач автоматичного виявлення підземних комунікацій та порожнин у георадарних радарограмах.

3.3. Програмна реалізація та конфігурація процесу навчання

Реалізація системи автоматичного виявлення підземних об'єктів на георадарних радарограмах була виконана із використанням сучасних інструментів глибокого навчання та бібліотек комп'ютерного зору. Основою програмної

реалізації виступає фреймворк Ultralytics YOLO, який забезпечує зручні інструменти для навчання, тестування та подальшого використання моделей сімейства YOLOv8. Процес програмної реалізації включав кілька основних етапів: підготовку структури набору даних, конфігурацію файлу опису датасету, налаштування параметрів навчання моделі та запуск процесу тренування.

Для навчання моделі використовується конфігураційний файл `gpr_data.yaml`, який описує структуру набору даних та параметри класів. У цьому файлі задається шлях до кореневої папки датасету, розташування навчальної та валідаційної вибірок, а також кількість класів об'єктів і їх назви.

Основні параметри конфігурації:

- `path` – шлях до кореневої директорії набору даних;
- `train` – папка з навчальними зображеннями;
- `val` – папка з валідаційними зображеннями;
- `nc` – кількість класів;
- `names` – список назв класів.

У даному дослідженні використовувалися два класи об'єктів:

- `Cavity` – підземні порожнини;
- `Utility` – підземні комунікації.

Відповідна конфігурація має вигляд:

```
path: /Users/user/Desktop/mv/data
train: images/train
val: images/val
nc: 2
names: ['Cavity', 'Utility']
```

Така структура відповідає стандартному формату датасетів, який використовується для навчання моделей сімейства YOLO.

Перед початком навчання було виконано автоматизовану підготовку структури датасету. Для цього було розроблено Python-скрипт, який виконує декілька функцій:

- створення необхідної ієрархії папок для зображень та анотацій;
- копіювання зображень і відповідних файлів розмітки;
- розподіл даних на навчальну та валідаційну вибірки;
- перевірку наявності файлів анотацій.

Структура підготовленого набору даних (рис.3.1).




Рисунок 3.1 – Структура набору даних

Кожному зображенню відповідає текстовий файл анотації у форматі YOLO, який містить координати обмежувальних рамок об'єктів.

Для навчання нейронної мережі набір даних було поділено на дві підмножини:

1. Навчальна (Train) 80 % – використовується для оптимізації ваг нейронної мережі;
2. Валідаційна (Validation) 20 % – використовується для контролю якості моделі під час навчання.

Такий розподіл дозволяє оцінювати здатність моделі до узагальнення та запобігати перенавчанню. У процесі підготовки даних файли випадковим чином перемішувалися, після чого розподілялися між вибірками відповідно до заданої пропорції.

Навчання моделі реалізовано за допомогою Python-скрипта, який використовує бібліотеку PyTorch через інтерфейс фреймворку Ultralytics YOLO. На початковому етапі виконується завантаження попередньо натренованої моделі YOLOv8s, яка використовується як базова архітектура для подальшого донавчання (transfer learning). Використання попередньо навченої моделі дозволяє значно скоротити час тренування та підвищити точність розпізнавання.

Основні етапи навчання:

- ініціалізація моделі;
- завантаження конфігурації датасету;
- встановлення параметрів навчання;
- запуск процесу оптимізації ваг нейронної мережі.

Приклад програмної реалізації:

```
from ultralytics import YOLO

def main():
    model = YOLO('yolov8s.pt')

    model.train(
        data='/Users/user/Desktop/mv/gpr_data.yaml',
        epochs=50,
        imgsz=224,
        batch=32,
        device='mps',
        name='gpr_model_m4',
        plots=True
    )

if __name__ == '__main__':
    main()
```

Для проведення експериментів були встановлені наступні параметри навчання (див табл.3.4).

Таблиця 3.4 – Основні параметри навчання моделі

Параметр	Значення	Опис
Архітектура моделі	YOLOv8s	Компактна модель виявлення об'єктів
Кількість епох	50	Кількість повних проходів по навчальній вибірці
Розмір зображення	224 × 224	Вхідний розмір зображень
Batch size	32	Кількість зображень у одному пакеті навчання
Dataset config	gpr_data.yaml	Файл конфігурації набору даних
Візуалізація метрик	Увімкнено	Побудова графіків процесу навчання

Під час навчання автоматично формуються графіки зміни функції втрат (loss), точності детекції та інших метрик, що дозволяє оцінювати ефективність моделі на різних етапах тренування.

Для підготовки датасету було реалізовано окремий Python-скрипт, який автоматизує процес формування навчальних та валідаційних вибірок.

Основні функції скрипта:

- створення необхідної структури директорій;
- копіювання зображень у відповідні папки;
- перенесення файлів анотацій у форматі YOLO;
- створення порожніх файлів анотацій для зображень без об'єктів;

- випадковий розподіл даних між вибірками.

Завдяки автоматизації підготовки даних вдалося значно скоротити час формування навчального набору та уникнути помилок, пов'язаних із ручною обробкою великої кількості файлів.

Для практичного використання розробленої моделі детекції було створено окремий програмний додаток, який забезпечує зручний інтерфейс для аналізу георадарних зображень та автоматичного виявлення підповерхневих аномалій. Додаток реалізовано мовою програмування Python із використанням бібліотек CustomTkinter, OpenCV, Pillow та фреймворку Ultralytics YOLO.

Основною метою програмного забезпечення є надання користувачу інструменту для швидкого аналізу радарограм та автоматичного визначення потенційних підповерхневих порожнин або інших аномалій за допомогою попередньо натренованої моделі.

Програмний додаток побудований за принципом графічного користувацького інтерфейсу (GUI) та складається з кількох функціональних компонентів:

Головне вікно створюється як клас GPRProApp, що наслідується від базового класу бібліотеки CustomTkinter. У цьому вікні реалізовано загальну структуру інтерфейсу, яка включає:

- бокову панель керування;
- центральну область перегляду зображення;
- нижню панель статусу.

Такий підхід дозволяє логічно розділити функції управління програмою, візуалізацію результатів та інформаційні повідомлення.

Бокова панель містить основні елементи управління програмою:

- назву системи GPR AI Vision;
- кнопку «Відкрити знімок», яка запускає процедуру вибору файлу;
- інформаційне поле з технічними параметрами моделі.

Після запуску програми у цьому блоці відображається початковий статус системи, включаючи:

- готовність моделі до роботи;
- тип нейромережі (YOLOv8s);
- клас об'єкта, що детектується (*Cavity*).

У центральній частині інтерфейсу знаходиться область попереднього перегляду (preview), у якій відображається оброблене зображення. Після вибору користувачем файлу програма виконує такі етапи обробки:

1. Завантаження зображення.
2. Передача зображення до нейромережевої моделі.
3. Виконання детекції об'єктів.
4. Накладання рамок (bounding boxes) на знайдені аномалії.
5. Відображення результату у графічному інтерфейсі.

Для відображення результатів використовується функція `plot()`, яка автоматично накладає розмітку на зображення.

Ключовим елементом системи є модель глибокого навчання, побудована на основі алгоритму YOLOv8. Модель завантажується під час запуску програми зі збереженого файлу `var: best.pt`. Під час аналізу зображення використовується функція: `model.predict()`.

Основні параметри детекції:

- `source` – шлях до вхідного зображення;
- `conf = 0.45` – поріг впевненості для відбору об'єктів.

Якщо ймовірність детекції перевищує заданий поріг, об'єкт вважається знайденим і відображається у вигляді прямокутної рамки. Після обробки зображення виконується його масштабування для коректного відображення у вікні програми, що дозволяє адаптувати великі георадарні знімки до розміру області перегляду без спотворення пропорцій. Після завершення аналізу програма автоматично оновлює інформаційний блок, у якому відображаються:

- назва обробленого файлу;
- кількість знайдених аномалій;
- діапазон впевненості детекції.

Також у нижній частині вікна відображається статус виконання операції, наприклад: "Аналіз завершено. Знайдено об'єктів: N", де N – кількість виявлених аномалій. Розроблений програмний додаток забезпечує такі можливості:

- завантаження георадарних зображень;
- автоматичний аналіз радарограм за допомогою нейромережі;
- виявлення підповерхневих аномалій;
- графічну візуалізацію результатів детекції;
- відображення статистичної інформації про знайдені об'єкти.

Завдяки використанню сучасних бібліотек комп'ютерного бачення та глибокого навчання програма може застосовуватися як допоміжний інструмент для аналізу георадарних даних у дослідницьких та інженерних задачах.

Висновки до розділу 3

Вибір технологічного стека та апаратного забезпечення дозволив забезпечити високу продуктивність обробки великих обсягів GPR-даних. Використання мови Python у поєднанні з бібліотеками NumPy, Pandas, PyTorch та фреймворком Ultralytics YOLO забезпечило гнучку реалізацію алгоритмів обробки сигналів, детекції об'єктів та швидке прототипування моделей. Архітектура YOLOv8s забезпечує баланс між точністю та швидкістю обробки, що дозволяє працювати з потоками B-сканів майже в реальному часі.

Підготовка та аналіз набору даних GPR_Data забезпечили формування якісної навчальної вибірки для нейронної мережі. Використання 2239 високороздільних георадарних зображень із різними класами об'єктів, розділення на навчальні та валідаційні підмножини, а також застосування методів аугментації дозволили збільшити різноманітність даних та підвищити стійкість моделі до шумів та варіацій сигналів.

Програмна реалізація та конфігурація процесу навчання продемонстрували ефективність інтеграції попередньо натренованої моделі YOLOv8s із процесом донавчання на специфічних даних. Автоматизація підготовки набору даних, використання графічного прискорення та оптимізованих параметрів навчання забезпечили швидке та ефективне тренування моделі.

Функціональність розробленого програмного додатку дозволяє користувачу здійснювати зручний аналіз георадарних зображень, автоматично виявляти підповерхневі аномалії та отримувати графічну та статистичну інформацію про знайдені об'єкти. Використання GUI-бібліотек CustomTkinter та OpenCV забезпечує інтуїтивне управління та візуалізацію результатів.

РОЗДІЛ 4. ЕКСПЕРИМЕНТАЛЬНІ ДОСЛІДЖЕННЯ ТА АНАЛІЗ РЕЗУЛЬТАТІВ НАВЧАННЯ МОДЕЛІ

4.1. Параметризація та оцінка точності розпізнавання на основі статистичних метрик

Процес навчання інтелектуальної моделі YOLOv8s базувався на ітераційному підході з використанням 50 епох. Для забезпечення наукової достовірності та технічного контролю проводився моніторинг динаміки функцій втрат та статистичних метрик точності в режимі реального часу.

В процесі тренування використовувалася технологія комбінування зображень (mosaicing) та аугментації даних (рис. 4.1), що дозволило моделі одночасно опрацьовувати різні типи гіперболічних сигналів, що відрізняються за глибиною залягання, амплітудою та рівнем зашумленості. Навчальний батч демонструє процес накладання обмежувальних рамок (bounding boxes) на етапі ітераційного підбору ваг нейромережі.




Рисунок 4.1 – Приклад мозаїчного батчу навчальних даних з нанесеною розміткою об'єктів

На початковому етапі (епохи 1–10) спостерігалось стрімке навчання моделі (рис.4.2). Значення Box Loss (помилка локалізації) знизилось з 1.84 до 1.61, що свідчить про швидку адаптацію нейромережі до специфічної форми георадарних гіпербол.




Рисунок 4.2 – Динаміка навчання та функцій втрат

Найбільш показовим є падіння Class Loss на валідації: з 19.56 на першій епосі до 1.42 на десятій. Такий тренд підтверджує, що модель швидко навчилася диференціювати корисний сигнал від фонового шуму.

Таблиця 4.1. Динаміка ключових показників навчання на різних етапах

Епоха	Час (с)	Train Box Loss	Val Class Loss	mAP50	Learning Rate
1	76.1	1.8453	19.5677	0.0824	0.000546
10	544.6	1.6123	1.4276	0.7037	0.001369
25	1235.8	1.4268	1.0101	0.8323	0.000874
40	1919.2	1.2797	0.6933	0.9403	0.000379
50	2385.8	1.1032	0.5787	0.9571	0.000049

Для оцінки якості фінальної моделі було використано метрики Precision (точність), Recall (повнота) та mAP (середня точність). Для візуального підтвердження здатності моделі до генералізації було проведено порівняння контрольних зображень із результатами автоматичного розпізнавання (рис. 4.3). Аналіз порівняння еталонної розмітки (рис. 4.3, а) та прогнозів нейромережі (рис.

4.3, б) демонструє високу геометричну точність побудови обмежувальних рамок для об'єктів типу «Cavity»




Рисунок 4.3 – Візуалізація результатів тестування моделі: (а) – контрольна вибірка з еталонною розміткою; (б) – результати детекції аномалій неймерережею

Фінальне значення precision (точності) становить 0.982, або 98.2%, що свідчить про дуже високий рівень коректності класифікації. Такий показник означає, що система майже не генерує хибнопозитивних результатів, тобто сторонні сигнали або шум практично не інтерпретуються як реальні підземні комунікації. Для інженерних та геофізичних застосувань це має особливе значення, оскільки мінімізує ризик помилкової ідентифікації об'єктів у георадарних даних.

Показник recall (повноти) дорівнює 0.897, або 89.7%, що означає, що модель здатна виявляти приблизно дев'ять із десяти реальних об'єктів, присутніх на георадарних профілях. Такий результат демонструє достатньо високу чутливість алгоритму навіть у складних умовах інтерпретації, зокрема в ділянках з підвищеним згасанням сигналу або з високим рівнем шумових завад.

Значення mAP50 становить 0.957, що відповідає 95.7% середньої точності при порозі перекриття $\text{IoU} = 0.5$. Такий рівень показника характеризує модель як високоефективну для задач автоматизованої інтерпретації георадарних даних. Отриманий результат підтверджує здатність алгоритму стабільно локалізувати та класифікувати об'єкти на GPR-профілях з високим ступенем достовірності. У табл. 4.2 наведено підсумкові статистичні метрики моделі на 50-й епосі, які підтверджують високу здатність системи до точної детекції аномалій. Зокрема, значення mAP50 на рівні 0.957 свідчить про високу надійність розпізнавання об'єктів у складних умовах GPR-профілювання.

Таблиця 4.2 – Підсумкові статистичні метрики моделі (Epoch 50)

Метрика	Позначення	Значення
Точність	Precision (B)	0.982
Повнота	Recall (B)	0.897
Середня точність	mAP50 (B)	0.957
Виважена точність	mAP50-95 (B)	0.681

Високі значення метрик із табл. 4.2 корелюють із даними матриці помилок (рис. 4.4), де кількість правильно ідентифікованих об'єктів класу "Cavity" (551 випадок) значно переважає кількість пропущених сигналів. Для детального аналізу помилок класифікації та ідентифікації хибних спрацювань було побудовано матрицю помилок (рис. 4.4). Згідно з отриманими даними, модель успішно ідентифікувала 551 об'єкт класу "Cavity".




Рисунок 4.4 – Матриця помилок для результатів класифікації георадарних аномалій

Незначна кількість помилок (44 випадки) пов'язана з віднесенням слабких сигналів до фонового шуму (background), що є допустимим при автоматизованій обробці зашумлених GPR-профілів. Показник відсутності хибнопозитивних спрацювань для класу "Utility" підтверджує високу вибірковість навченої мережі.

4.2. Верифікація моделі на контрольних даних та приклади детекції

Завершальним етапом дослідження стала верифікація навченої моделі на нових георадарних профілях, що не входили до навчальної чи валідаційної вибірок, що дозволило оцінити реальну придатність системи до роботи в умовах польових досліджень.

Аналіз роботи програмного інтерфейсу. Для зручності проведення верифікації було використано розроблений графічний інтерфейс (GUI), який дозволяє завантажувати поодинокі знімки та отримувати миттєвий результат детекції. На рисунку (рис. 4.5) продемонстровано роботу інтерфейсу при аналізі типового георадарного профілю. Модель успішно ідентифікувала аномалію, позначивши її обмежувальною рамкою з високим показником впевненості (Confidence Score).




Рисунок 4.5 – Інтерфейс автоматизованої системи детекції аномалій під час аналізу контрольного зразка

Верифікація на різних типах ґрунтів та глибин показала, що неймережа YOLOv8s стійка до зміни контрастності гіпербол. Як видно (рис. 4.6), система чітко розрізняє форму об'єктів навіть за наявності інтенсивного горизонтального зашумлення (background noise), що часто зустрічається на необроблених георадарних даних.




Рисунок 4.6 – Приклад автоматичного розпізнавання підповерхневих об'єктів на контрольних профілях

Модель успішно локалізувала гіперболічне відображення об'єкта класу "Cavity", попри наявність вираженої шаруватості вміщувального середовища. Обмежувальна рамка чітко фокусується на вершині гіперболи, що є критично важливим для коректного визначення координат залягання об'єкта. На відміну від попереднього прикладу, на рисунку (рис.4.7) продемонстровано детекцію одиночної локалізованої аномалії, яку алгоритм ідентифікував як «Cavity» (порожнина) з високим рівнем впевненості 0.79.




Рисунок 4.7 – Результат детекції одиничного підповерхневого об'єкта системою GPR AI Vision з високим показником впевненості

Програмне забезпечення чітко окреслює межі об'єкта синьою рамкою, фокусуючись на вираженій дифракційній структурі, що має високу амплітуду відбиття сигналу. Характерна форма виявленої аномалії свідчить про наявність чіткої межі розділу середовищ, що дозволило нейронній мережі спрацювати з вищою точністю порівняно з багатооб'єктними профілями. Бічна панель інтерфейсу підтверджує знаходження однієї аномалії в межах заданого діапазону впевненості 0.45 – 0.95, а фінальний статус у нижній частині екрана свідчить про успішне завершення циклу обробки. Дана візуалізація підкреслює здатність інтелектуальної системи до детального аналізу специфічних ділянок підповерхневого шару та точного виокремлення цільових об'єктів серед фонових шумів і перешкод.

На рисунку (рис.4.8) представлено третій приклад роботи інтелектуального модуля GPR AI Vision. Дана радарграма вирізняється специфічною структурою середовища, що характеризується наявністю чітко виражених похилих

відбиваючих горизонтів. Система успішно ідентифікувала аномалію та класифікувала її як «Cavity» (порожнина) з високим рівнем впевненості 0.75.




Рисунок 4.8 – Приклад розпізнавання об'єкта «Cavity» у складному геологічному розрізі

На відміну від попередніх локальних гіпербол, на цьому фрагменті обмежувальна рамка охоплює зону порушення суцільності шарів, де спостерігається інтенсивне викривлення та переривання фаз відбитих сигналів. Високий показник достовірності свідчить про здатність алгоритму ефективно відокремлювати цільові об'єкти навіть на фоні нашарувань зі складним кутом падіння. Інтерфейс програми підтверджує виявлення однієї аномалії, а загальний вигляд вікна аналізу демонструє стабільність роботи системи при різних типах вхідних георадарних даних.

На рисунку (рис. 4.9) продемонстровано роботу інтелектуальної системи при аналізі файлу, що містить фрагмент радарограми з високим ступенем однорідності середовища. На відміну від попередніх прикладів, на даному зображенні відсутні виражені дифракційні гіперболи або структурні порушення шарів.




Рисунок 4.9 – Приклад обробки однорідної ділянки профілю без виявлених аномалій

Програмний модуль GPR AI Vision коректно проаналізував дані та не виявив об'єктів, що відповідали б критеріям класифікації «Cavity» у межах встановленого діапазону впевненості 0.45 – 0.95. Інформаційна панель ліворуч та статусний рядок у нижній частині інтерфейсу підтверджують результат аналізу із показником «Знайдено об'єктів: 0». Даний приклад є важливим для підтвердження низького рівня хибнопозитивних спрацювань (false positive) системи, що свідчить про її здатність чітко розрізняти реальні аномалії та природний шум або незначні неоднорідності ґрунту, які не є цільовими об'єктами.

На рисунку (рис.4.10) представлено приклад обробки файлу, який характеризується критично високим рівнем випадкових шумів, що практично повністю маскують корисний сигнал. Структура зображення нагадує «білий шум», де неможливо візуально виокремити ні горизонтальні шари, ні локальні об'єкти.




Рисунок 4.10 – Аналіз георадарних даних з високим рівнем некогерентного шуму

У таких складних умовах система GPR AI Vision продемонструвала високу вибірковість, не зафіксувавши жодної помилкової детекції (false alarm). Інформаційне вікно підтверджує результат «Знайдено об'єктів: 0», що вказує на ефективність алгоритмів фільтрації та розпізнавання образів, які не сприймають хаотичні піксельні аномалії за реальні підповерхневі цілі. Даний приклад підтверджує надійність системи при роботі в несприятливих умовах зондування, де відношення сигнал/шум є мінімальним.

GUI було вдосконалено для підтримки автоматичного зчитування цілого каталогу зображень та виконання виявлення аномалій без необхідності ручного вибору кожного файлу. Тепер користувач може обрати папку, після чого система самостійно ітерує всі доступні зображення, обробляє їх послідовно та формує

результати аналізу для кожного елемента. Це значно спрощує робочий процес, зменшує кількість ручних операцій та підвищує ефективність обробки даних у рамках задачі виявлення аномалій.

На рисунку (рис. 4.12) представлено процес пакетної обробки набору з 28 файлів, у результаті якого система автоматично виявляє аномальні та «чисті» зображення без ручного вибору кожного файлу.




Рисунок 4.12 – Результати автоматичного аналізу зображень з папки

Результати свідчать, що система коректно виконала пакетну обробку 28 зображень без збоїв і завершила аналіз у повному обсязі. У процесі роботи було виявлено 15 зображень з ознаками аномалій та 13 зображень, класифікованих як «чисті». Це демонструє стабільну роботу моделі в режимі автоматичного проходження по всьому каталогу та здатність розрізняти нормальні та аномальні випадки без ручного втручання.

Водночас у логах спостерігаються проблеми з відображенням тексту, зокрема порушення кодування та некоректні символи, що вказує на технічні недоліки у форматуванні виводу, але не впливає на сам процес детекції. Також варто відзначити, що в поточному вигляді результат не містить додаткових метрик

впевненості або візуалізації, що обмежує глибину інтерпретації якості роботи моделі. Загалом система демонструє працездатний pipeline для автоматичного аналізу зображень, але потребує доопрацювання в частині логування та розширення інформативності результатів.

Програма автоматично виконує сортування оброблених зображень за результатами детекції: файли, у яких виявлено аномалії, переміщуються до папки CAVITY_FOUND, тоді як зображення без ознак аномалій автоматично зберігаються у директорії NORMAL(рис.4.13).



Рисунок 4.13 – Розподіл зображень по папках

а) папка з виявленими аномаліями; б) папка із зображеннями без аномалій

Такий підхід забезпечує структуроване розділення даних після аналізу, спрощує подальшу перевірку результатів та дозволяє швидко відокремлювати підозрілі області від коректних зображень без ручного втручання користувача.

Висновки до розділу 4

Використання ітераційного підходу з 50 епохами, а також технологій аугментації даних і мозаїчного комбінування зображень забезпечило швидке та стабільне навчання моделі YOLOv8s. На ранніх етапах спостерігалось стрімке зниження функцій втрат Box Loss та Class Loss, що підтверджує здатність неймережі швидко адаптуватися до специфіки георадарних сигналів.

Фінальні статистичні метрики свідчать про високий рівень продуктивності моделі: Precision = 0.982 (98,2%), Recall = 0.897 (89,7%), mAP50 = 0.957 (95,7%), що демонструє практично відсутність хибнопозитивних спрацювань та здатність виявляти більшість реальних об'єктів у георадарних даних.

Візуальна перевірка результатів детекції на контрольних зразках показала, що обмежувальні рамки точно охоплюють цільові об'єкти класу «Cavity», навіть у складних умовах з високим рівнем шуму та різноманітною глибиною залягання.

Модель продемонструвала стабільну роботу на різних типах ґрунтів, рівнях контрастності гіпербол, а також при наявності інтенсивного фонового шуму або структурних порушень шарів. Система не фіксує хибних сигналів у однорідних ділянках та в умовах «білого шуму», що підтверджує високий рівень вибірковості алгоритму.

Розроблений графічний інтерфейс дозволяє оперативно оцінювати нові GPR-профілі, забезпечуючи миттєву детекцію та наочну верифікацію результатів, що підкреслює придатність системи для реального використання в інженерних та геофізичних задачах.

Інтелектуальна система GPR AI Vision показала високий рівень точності, стабільності та вибірковості, що робить її ефективним інструментом автоматизованого аналізу георадарних даних та надійним засобом виявлення підповерхневих аномалій.

Наукова новизна роботи полягає у вдосконаленні методики автоматизованої інтерпретації георадарних даних шляхом застосування алгоритмів комп'ютерного

зору родини YOLO. Вперше обґрунтовано та реалізовано використання архітектури YOLOv8s для специфічних двовимірних сигналів (радіограм), що забезпечило ефективне розпізнавання гіперболічних дифракційних аномалій навіть за умов низького відношення сигнал/шум. Визначено оптимальні параметри навчання та поріг впевненості (0.45), які забезпечують максимальний показник F1-метрики (0.94) для детекції підповерхневих порожнин. Розроблено методику підготовки та аугментації навчальних даних на основі морфологічних особливостей георадарних аномалій, що значно підвищує здатність моделі до генералізації на реальних об'єктах.

Практична цінність роботи визначається створенням функціональної системи автоматизованого аналізу георадарних профілів, що дозволяє значно підвищити ефективність роботи інженерів-геофізиків та будівельників. Використання розробленої моделі забезпечує миттєву детекцію підповерхневих об'єктів замість тривалої ручної інтерпретації, скорочуючи час обробки даних у 5–10 разів. Система знижує ризик пропуску критичних аномалій (порожнин, комунікацій), що можуть залишатися непоміченими через втому оператора або складний фоновий шум. Впровадження автоматизованої детекції дозволяє зменшити витрати на обстеження територій та запобігти аварійним ситуаціям у будівництві за рахунок своєчасного виявлення підземних дефектів.

ВИСНОВКИ

У межах роботи розроблено інтелектуальну систему автоматизованого аналізу георадарних даних GPR AI Vision, призначену для виявлення підповерхневих аномалій на основі двовимірних GPR-радарограм. У процесі дослідження було виокремлено основні чинники, що ускладнюють інтерпретацію георадарних даних, зокрема високий рівень шуму, неоднорідність середовища, варіації глибини залягання об'єктів, перекриття відбитих сигналів та залежність результатів від кваліфікації оператора. Проведений аналіз підтвердив доцільність застосування інтелектуальних методів автоматизації для підвищення точності та швидкості обробки GPR-сигналів.

У роботі виконано порівняльний аналіз сучасних методів машинного навчання та глибокого навчання, що застосовуються в геофізичних задачах. Встановлено, що моделі глибокого навчання, зокрема згорткові нейронні мережі та архітектури сімейства YOLO, забезпечують кращу ефективність при автоматичній детекції підповерхневих об'єктів у георадарних B-сканах порівняно з класичними ML-підходами.

Розроблено методику попередньої обробки георадарних сигналів, яка включає підготовку та аугментацію набору даних GPR_Data обсягом 2239 зображень. Запропонований підхід дозволив підвищити якість навчальних даних, забезпечити узгодженість між навчальними та реальними умовами експлуатації моделі, а також підвищити стійкість системи до шумів і варіативності сигналів.

На основі архітектури YOLOv8s побудовано та навчено модель нейронної мережі для автоматичного виявлення типових приповерхневих об'єктів класу «Cavity». Реалізована модель забезпечує збалансоване поєднання швидкодії та точності детекції, ефективно працюючи навіть у складних умовах із високим рівнем завад та неоднорідною структурою ґрунтів.

Проведено оцінювання точності та надійності розробленого підходу на контрольних прикладах і реальних георадарних даних. Отримані експериментальні результати підтверджують високу ефективність системи: Precision = 0.982, Recall = 0.897, mAP50 = 0.957, що свідчить про низький рівень хибних спрацьовувань та високу здатність до виявлення реальних підповерхневих об'єктів. Система продемонструвала стабільну роботу на різних типах ґрунтів і при різних рівнях шуму.

Додатково розроблено графічний інтерфейс на базі CustomTkinter та OpenCV, який забезпечує зручну взаємодію користувача із системою, дозволяючи виконувати автоматичну детекцію та візуалізацію результатів у вигляді bounding box-ів і статистичних показників. Це робить систему придатною для практичного використання в інженерній геофізиці, будівництві та моніторингу підземних об'єктів.

Таким чином, усі поставлені завдання роботи виконано, а розроблена система GPR AI Vision є завершеним програмним рішенням для автоматизованої інтерпретації георадарних даних, що скорочує час аналізу, підвищує об'єктивність результатів та зменшує залежність від людського фактору.

СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

Daniels, D. J. (2004). Ground Penetrating Radar (2nd ed.). Institution of Engineering and Technology (IET).

Jol, H. M. (2009). Ground Penetrating Radar Theory and Applications. Elsevier.

Carracelas, M. (2011). Evaluation of ancient structures by GPR (ground penetrating radar): The arch bridges of Galicia (Spain).

U.S. Environmental Protection Agency (EPA). Ground Penetrating Radar (GPR) – Environmental Geophysics.

Jol, H. M. (Ed.). (2009). Ground penetrating radar theory and applications. Elsevier Science. <https://geotak.webs.upv.es/wp-content/uploads/2023/02/Ground-Penetrating-Radar-THEORY-AND-APPLICATIONS.pdf>

Conyers, L. B. (2013). Ground-penetrating radar for archaeology (3rd ed.). AltaMira Press.

Dai, Shongtao & Yan, Qiwu. (2014). Pavement Evaluation Using Ground Penetrating Radar. 222-230. 10.1061/9780784413418.023.

G.L. Barr (1993). Application of Ground-Penetrating Radar Methods in Determining Hydrogeologic Conditions in a Karst Area, West-Central Florida USGS Water-Resources Investigations Report 92-4141. URL: <https://pubs.usgs.gov/wri/1992/4141/report.pdf>

Conyers, L. B., & Goodman, D. (1997). Ground-penetrating radar: An introduction for archaeologists. AltaMira Press.

Neal, Adrian. (2004). Ground-penetrating radar and its use in sedimentology: Principles, problems and progress. Earth-Science Reviews. 66. 261-330. 10.1016/j.earscirev.2004.01.004.

Annan, A.P. (2009) Electromagnetic Principles of Ground Penetrating Radar. In: Jol, H.M., Ed., Ground Penetrating Radar: Theory and Applications, Elsevier, Amsterdam, 1, 3-40. <https://doi.org/10.1016/B978-0-444-53348-7.00001-6>

Yu, Siwei & Ma, Jianwei. (2021). Deep Learning for Geophysics: Current and Future Trends. Reviews of Geophysics. 59. 10.1029/2021RG000742.

K. J. Bergen, P. A. Johnson, M. V. de Hoop, G. C. Beroz. 2019. Machine learning for data-driven discovery in solid Earth geoscience. *Science* 363, eaau0323. doi:10.1126/science.aau0323.

Mustafa, Ahmad & Alregib, Ghassan. (2023). Active Learning with Deep Autoencoders for Seismic Facies Interpretation. 10.31223/X5XD32.

Karniadakis, George & Kevrekidis, Yannis & Lu, Lu & Perdikaris, Paris & Wang, Sifan & Yang, Liu. (2021). Physics-informed machine learning. *Nature Reviews Physics*. 1-19. 10.1038/s42254-021-00314-5.

Burges, Christopher. (1998). A Tutorial on Support Vector Machines for Pattern Recognition. *Data Mining and Knowledge Discovery*. 2. 121-167. 10.1023/A:1009715923555.

Chen, Tianqi & Guestrin, Carlos. (2016). XGBoost: A Scalable Tree Boosting System. 785-794. 10.1145/2939672.2939785.

Omarkhanova, Dinara & Oralbekova, Zhanar. (2024). Interpretation of georadar data based on machine learning technologies. *EUREKA: Physics and Engineering*. 193-204. 10.21303/2461-4262.2024.003289.

Raissi, Maziar & Perdikaris, Paris & Karniadakis, George. (2018). Physics-Informed Neural Networks: A Deep Learning Framework for Solving Forward and Inverse Problems Involving Nonlinear Partial Differential Equations. *Journal of Computational Physics*. 378. 10.1016/j.jcp.2018.10.045.

Python documentation. URL: <https://www.python.org/doc/>

Yaseen, M. (2024). What is YOLOv8: An in-depth exploration of the internal features of the next-generation object detector. *arXiv*. URL: <https://doi.org/10.48550/arXiv.2408.15857>

PyTorch documentation. URL: <https://docs.pytorch.org/docs/2.11/index.html>

A. MOJAHID, D. EL OUALI, K. EL Amraoui, K. EL-HAMI, H. AITBENAMER, (2024). Intelligent Recognition of Subsurface

Utilities and Voids: A Ground Penetrating Radar Dataset for Deep Learning Applications. in data in brief journal. 10.17632/ww7fd9t325.1

ДОДАТКИ

Додаток 1 – Алгоритмічна послідовність процедур автоматизованої інтерпретації GPR-даних у системі GPR AI Vision

