

ВИЯВЛЕННЯ МІН ЗА ДОПОМОГОЮ CNN+BiLSTM+ATTENTION НА ОСНОВІ B-SCAN СИГНАЛІВ

Іван Пелешак¹, Юрій Футрик²

^{1,2} Національний університет «Львівська політехніка»,
кафедра інформаційних систем та мереж, Львів, Україна

¹ E-mail: ivan.r.peleshchak@lpnu.ua, ORCID: 0000-0002-7481-8628

² E-mail: yurii.v.futryk@lpnu.ua, ORCID: 0000-0001-5271-9883

© Пелешак І., Футрик Ю., 2025

У сучасних умовах проблема виявлення мін залишається однією з найактуальніших через серйозну загрозу для життя і здоров'я людей на забруднених територіях. У цій роботі представлено підхід до виявлення мін за допомогою гібридної нейронної мережі CNN+BiLSTM+Attention, яка аналізує B-scan сигнали, отримані від систем наземної радіолокації. Для підвищення якості навчання при обмеженій кількості даних було застосовано аугментацію зображень, що включає зсув, віддзеркалення, масштабування та додавання шуму. Початкові шари архітектури використовують згорткові операції для виділення локальних просторових ознак, після чого застосовується двонаправлений рекурентний шар BiLSTM, який дозволяє моделі вивчати залежності в межах кожного B-scan з урахуванням контексту в обох напрямках. Додатково інтегровано механізм уваги для фокусування на найбільш інформативних фрагментах сигналу. Фінальні шари моделі – це щільні шари з сигмоїдною функцією активації для реалізації виявлення мін. Результати комп'ютерного експерименту продемонстрували високу ефективність моделі: точність класифікації перевищує 99%, а значення Precision, Recall, F1-score та AUC свідчать про надійність підходу. Візуалізація результатів (графіки втрат і точності, матриця плутанини, гістограма метрик) підтверджує стабільне навчання без перенавчання. Запропонована архітектура є перспективною для застосування в задачах дистанційного мінного моніторингу та може бути використана як основа для подальших досліджень у сфері військової безпеки.

Ключові слова: система наземної радіолокації, виявлення мін, попереднє опрацювання даних, надмірна вибірка, гібридна нейронна мережа, двонапрявлена нейронна мережа довготривалої короткочасної пам'яті.

Постановка проблеми

Проблема виявлення мін залишається однією з найгостріших як у військовій сфері, так і в гуманітарному контексті. Мінна небезпека становить серйозну загрозу для цивільного населення та військових у зонах активних або колишніх бойових дій. Традиційні методи розмінування, які передбачають участь саперів або використання важкої техніки, є надзвичайно трудомісткими, повільними та пов'язаними з високим ризиком для життя. У цьому контексті особливого значення набуває застосування безпілотних платформ, зокрема наземної радіолокації (Ground Penetrating Radar, GPR), яка дозволяє виявляти об'єкти під поверхнею ґрунту.

Одним із ключових типів даних, що генерує GPR, є B-scan зображення – двовимірні зрізи, які візуалізують відбитий сигнал у залежності від глибини та горизонтального положення. Визначення наявності міни за B-scan сигналом є задачею бінарної класифікації, де кожен зразок (B-scan) необхідно віднести до одного з двох класів: "є міна" або "немає міни". Через складність сигналів, високий рівень

шуму, варіативність ґрунтових умов та обмеженість обсягів даних, виникає потреба у застосуванні потужних методів глибинного навчання, здатних автоматично видобувати релевантні ознаки та робити точні класифікації. Саме тому розроблення архітектури оптимальної нейромережевої системи для допомоги розпізнавання мін на основі даних георадарів є актуальною задачею.

Незважаючи на значний прогрес у впровадженні сенсорних технологій для виявлення мін, задача точного та безпечного розпізнавання залишається відкритою. Традиційні методи часто залежать від участі людини, що створює додаткові ризики у реальних умовах. Використання георадарів є перспективним напрямом, однак опрацювання отриманих сигналів потребує удосконалення. Саме тому для підвищення її ефективності необхідне глибоке опрацювання сигналів з урахуванням як просторових, так і часових патернів.

GPR-сканування генерує двовимірні B-scan зображення, які містять просторову інформацію про об'єкти під поверхнею. Визначення наявності мін за цими зображеннями ускладнюється низьким співвідношенням сигнал/шум, варіативністю даних, залежністю від типу ґрунту, а також обмеженою кількістю розмічених прикладів для навчання. Класичні алгоритми машинного навчання або окремі згорткові нейронні мережі (CNN) не забезпечують належної якості класифікації в умовах таких викликів. Це створює потребу в адаптивних та стійких моделях, які можуть ефективно навчатися на невеликих вибірках та демонструвати високу точність навіть за складних умов. Саме тому виникає необхідність у розробленні гібридної архітектури, що поєднує переваги згорткових шарів та двонаправлених рекурентних мереж LSTM для підвищення точності виявлення мін на основі B-scan даних, що буде здатна працювати навіть на малих наборах даних, в складних умовах зашумленості та змінних характеристик середовища.

Аналіз останніх досліджень та публікацій

Класичні методи виявлення мін можна умовно поділити на активні та пасивні (Landmine and Cluster Munition Monitor, 2024), (Rangole et al., 2024). До активних належать, зокрема, металодетектори та радари проникаючого випромінювання, що випромінюють сигнали та аналізують їх відбиття від підземних об'єктів (Rangole et al., 2024), (Madavha et al., 2020). Окрім електромагнітних методів, досліджуються також акустичні сенсори (для реєстрації вібрацій ґрунту), газоаналізатори для виявлення парів вибухових речовин та ядерні методи (нейтронне опромінення, ядерний квадрупольний резонанс) (Adhikari et al., 2024). Проте у практиці розмінування саме поєднання металодетекторів і GPR є найпоширенішим підходом для підвищення ймовірності виявлення мін.

Останніми роками спостерігається тенденція підвищувати ефективність мінних детекторів шляхом застосування алгоритмів машинного та глибинного навчання для опрацювання сигналів різних сенсорів. Зокрема, Yilmaz et al., (2018) запропонували пасивну систему пошуку мін з нейронною гібридною моделлю класифікації (поєднання алгоритму k-NN та штучної нейронної мережі), що дозволило досягти ~95% точності розпізнавання мін за їхніми магнітними аномаліями. Також дослідники успішно застосовують глибокі нейронні мережі до даних активних сенсорів (GPR, EMI). Наприклад, Gurkan et al., (2017) приводять приклад використання згорткової нейронної мережі (CNN) для автоматичного розпізнавання характерних гіперболічних відгуків від мін на B-сканах GPR, а Yilmaz et al., (2016) застосовують автокодувач для виокремлення ознак мін у об'ємних даних багатополаризаційного GPR.

Сучасні методи класифікації на основі глибинного навчання мають ряд переваг для аналізу сенсорних даних типу B-scan. Зокрема, CNN ефективно виявляють просторові шаблони в сигналах або зображеннях, автоматично виокремлюючи характерні ознаки мін (наприклад, форму магнітної аномалії чи радарного відгуку) без потреби в ручній побудові ознак (Gurkan et al., 2017), (Yilmaz et al., 2016). Автокодуювальні нейронні мережі (autoencoders) дають змогу виконувати неконтрольоване навчання прихованих представлень даних та видаляти шум, що підсилює слабкі сигнали від мін на фоні перешкод (Yilmaz et al., 2016). Окрім того, набули розвитку гібридні архітектури, які комбінують згорткові та рекурентні шари (CNN+RNN) і враховують як просторові, так і часові

властивості сигналів (Yilmaz et al., 2018). Такий підхід дає змогу згортковій частині мережі виділяти локальні особливості з В-скану, а рекурентній (наприклад, LSTM) – аналізувати послідовність цих особливостей уздовж траєкторії руху сенсора.

Окремо варто відзначити рекурентні нейронні мережі, зокрема архітектури довготривалої короткочасної пам'яті (далі LSTM від *англ.* Long Short-Term Memory) та блокованого рекурентного елементу (далі GRU від *англ.* Gated Recurrent Unit), які призначені для роботи з послідовними даними (Lytvyn et al., 2022), (Pol, 2020). LSTM-мережі завдяки механізмам пам'яті та «вентилів» здатні зберігати контекстну інформацію та придушувати перешкоди, що дозволяє їм вловлювати довготривалі залежності в часових рядах сенсорних показників (Lytvyn et al., 2022), (Peleshchak et al., 2023). Спрощена GRU – містить подібні можливості з меншим числом параметрів, забезпечуючи швидше навчання моделі при близькій точності до LSTM (Pol, 2020). У задачах мінної детекції такі рекурентні моделі застосовуються для прогнозування очікуваного сигналу або безпосередньої класифікації цілі у послідовності вимірів. Вони враховують динаміку зміни сигналу уздовж руху датчика і тим самим підвищують стійкість розпізнавання до шумів та завад у даних (Peleshchak et al., 2023).

Разом з тим, попередні роботи мають ряд обмежень. Основною проблемою є малий обсяг доступних даних. Експериментальні набори GPR-вимірювань з реальними мінами зазвичай невеликі, що ускладнює тренування глибоких моделей і знижує впевненість у їх здатності узагальнювати знання на різних умовах (Yilmaz et al., 2016), (Yilmaz et al., 2018). Крім того, у багатьох дослідженнях не аналізувався вплив архітектури нейронної мережі на результати. Як показали Markoulidakis et al., (2021), морфологія мережі (кількість шарів, нейронів та їхня симетрія) може змінювати точність класифікації на десятки відсотків, тому ігнорування цього аспекту призводить до неоптимальних рішень. Також попередні алгоритми нерідко випробувані лише на вузькому наборі сценаріїв та без аналізу стійкості до завад (шумів, зміни типу ґрунту), що ставить під сумнів їх надійність у польових умовах. Враховуючи ці фактори, актуальним є розроблення нової моделі на основі CNN+BiLSTM+Attention, яка поєднає переваги згорткових та рекурентних мереж, буде оптимізованою за структурою і здатною забезпечити точне виявлення навіть за умов обмежених даних та високого рівня шуму.

Формулювання цілі статті

Мета дослідження полягає у розробленні гібридної нейромережевої моделі CNN+BiLSTM+Attention для виявлення мін на основі GPR-даних у форматі B-scan. Основний акцент зроблено на поєднанні згорткових нейронних мереж (CNN) для виділення просторових ознак та двонаправлених рекурентних мереж BiLSTM для аналізу послідовностей інформації в межах зображення.

У рамках цього дослідження поставлено такі завдання:

Обрати метрики для оцінювання гібридної моделі CNN + BiLSTM + Attention.

Провести попереднє опрацювання та аугментацію GPR B-scan сигналів, включаючи нормалізацію, додавання шуму, горизонтальні зсуви та масштабування амплітуди, з метою розширення та збагачення навчального набору даних. Сформувати вхідні тензори для моделі, де кожне B-scan зображення буде представлене у вигляді послідовності рядків (або стовпців), що імітує сканування, а пікселі розглядаються як інтенсивність сигналу.

Провести комп'ютерний експеримент та порівняти продуктивність розробленої моделі з іншими нейромережевими підходами (наприклад, лише CNN або лише LSTM) з метою визначення переваг запропонованого гібридного підходу. Оцінити ефективність класифікації за допомогою обраних метрик якості, а також проаналізувати результати за допомогою матриці плутатини.

Досягнення поставленої мети дозволить підвищити ефективність систем автоматизованого розпізнавання мін, забезпечуючи більшу безпеку та точність у задачах дистанційного розмінування. Наукова новизна дослідження полягає у застосуванні гібридної архітектури нейронної мережі CNN + BiLSTM + Attention до аналізу GPR B-scan сигналів у задачі виявлення мін. Це дає змогу досягти високої точності навіть за умов обмежених даних та високого рівня шуму.

Виклад основного матеріалу

Метрики оцінювання гібридної моделі CNN + BiLSTM + Attention

Для оцінювання ефективності розробленої гібридної моделі класифікації сигналів використовуються класичні метрики якості бінарної класифікації, зокрема Accuracy, Precision, Recall та F1-score. Ці метрики забезпечують комплексну характеристику здатності моделі правильно класифікувати об'єкти як позитивного (наявність міни), так і негативного (відсутність міни) класу.

Загальна точність (Accuracy) відображає частку правильних передбачень серед усіх прогнозів. Формула для розрахунку:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}, \quad (1)$$

де TP – кількість істинно позитивних передбачень (правильне виявлення мін), вектор значень вихідного сигналу.

TN – кількість істинно негативних передбачень (правильне виявлення відсутності мін).

FP – кількість хибно позитивних передбачень (хибні сигнали класифіковані як міни).

FN – кількість хибно негативних передбачень (невиявлені міни).

Точність (Precision) визначає, яка частка передбачених як «міна» (позитивні класи) є справді мінами. Високе значення показника точності означає, що модель робить мало помилкових спрацьовувань, що особливо важливо у сценаріях, де помилкове виявлення міни може спричинити непотрібне втручання або евакуацію. Формула для розрахунку:

$$Precision = \frac{TP}{TP + FP}. \quad (2)$$

Повнота (Recall) визначає, яку частку істинно позитивних передбачень модель успішно виявила. Високе значення цього показника означає, що модель виявляє більшість істинно позитивних передбачень, що критично важливо для безпеки в гуманітарному розмінуванні. Формула для розрахунку:

$$Recall = \frac{TP}{TP + FN}. \quad (3)$$

F1-score — це метрика, яка використовується для оцінки якості класифікаційної моделі (бінарної або багатокласової, хоч найчастіше згадується саме у бінарному контексті). Вона об'єднує в собі точність і повноту в єдине число. Формула для розрахунку:

$$F1 - score = 2 \cdot \frac{Precision \cdot Recall}{Precision + Recall}. \quad (4)$$

Попереднє опрацювання даних GPR-сигналів

Для проведення комп'ютерного експерименту було використано експериментальний набір, сформований на основі дослідження "SPHE Integrated Systems – GPR-for-UXO" (Study on evaluating airborne GPR's potential for UXO and Landmine Detection in a Controlled Environment, 2023). У цьому дослідженні здійснено польові випробування безпілотної системи, оснащеної георадаром, що застосовується для виявлення об'єктів, схованих під поверхнею землі, зокрема мін (TM62M, O3M72).

Опрацювання сигналів виконувалась у програмному забезпеченні RadSys Prism (версія 2.7), де застосовано такі етапи:

- Видалення фонових шумів.
- Підсилення сигналу.
- Застосування високочастотного фільтру для усунення горизонтальних перешкод.
- Використано коефіцієнт діелектричної проникності 4 (характерний для сухого піску).

Подане дослідження детально описує випробування безпілотної системи з GPR для виявлення мін, включаючи опис апаратного забезпечення, методики збору та опрацювання даних, а також аналіз ефективності.




Рис. 1. Зображення міни TM62M із дослідження «SPHE Integrated Systems - GPR-for-UXO»

Для навчання гібридної нейронної мережі CNN + BiLSTM + Attention ми використали дані GPR та оптимізатор Adam. B-scan дані містять матриці розміром 101×512, де 101 – часові відліки (інтервал 32 мс, що дозволяє співвіднести глибину), а 512 – просторові вимірювання уздовж поверхні. Рядки відповідають часовим відлікам (з інтервалом 32 мс), тобто глибинам сигналу, а стовпці — це положення вздовж траєкторії руху давача. Мітки класів складаються із даних з “targets.csv”, що містять 45 класів, де значення 2 означає підтверджена міна, а 0 та 1 – хибні спрацювання. Кожна така матриця зберігається в окремому CSV-файлі, іменованому відповідно до дати та часу вимірювання. Додатково файл “targets.csv” містить мітки, які відповідають кожному B-scan зображенню та класифікують об’єкт як:

- 0 — вибухонебезпечного об’єкта не виявлено,
- 1 — хибне спрацювання,
- 2 — підтверджена міна.

Для задачі виявлення мін було виконано перетворення міток: значення 2 — перетворено у клас 1 (міна), значення 0 та 1 — об’єднано у клас 0 (немає міни / хибне спрацювання).

Description	Photo	Depth, m	Size, m	Detected with GPR	Detected with magnetometer	GPR signal
Russian anti-tank mine TM-62M (1)		0.3	D: 310 / H: 101	Yes	Yes	
Russian anti-tank mine TM-62M (2)		0.3	D: 310 / H: 101	No	Yes	-
Russian anti-tank mine TM-62M (3)		0.3	D: 310 / H: 101	Yes	Yes	
Russian anti-tank mine TM-62M (4)		0.3	D: 310 / H: 101	Yes	Yes	

Рис. 2. Зображення мін (TM62M) та їх B-scan із дослідження «SPHE Integrated Systems - GPR-for-UXO»

Запропонована модель гібридної мережі CNN + BiLSTM + Attention на основі даних GPR B-scan здійснює автоматичне виявлення мін, тобто бінарну класифікацію, об'єднавши мітки 0 та 1 у клас “немає міни”, а мітку 2 — у клас “є міна” (Study on evaluating airborne GPR's potential for UXO and Landmine Detection in a Controlled Environment, 2023).

Для покращення навчального процесу була застосована агресивна аугментація даних — штучне розширення набору даних за рахунок імітації реалістичних варіацій B-scan сигналів. Було реалізовано наступні перетворення:

Щоб модель CNN + BiLSTM + Attention могла інтерпретувати B-scan як послідовність, було виконано реформатування тензора зображень:

- Зсуви по рядках і стовпцях із обгортанням,
- Віддзеркалення по горизонталі або вертикалі,
- Додавання шуму до амплітуди сигналу,
- Масштабування амплітуди з випадковим коефіцієнтом.

Кожне зображення було розширено на 10 нових варіацій, у результаті чого обсяг навчальної вибірки збільшився в 11 разів.

Також було виконано нормалізацію амплітуд кожного зразка в межах $[0, 1]$, що дозволяє вирівняти масштаб значень для ефективного навчання моделі. Для коректного сприйняття вхідних даних рекурентною мережею було виконано трансформацію вхідного вектора:

Кожне B-scan зображення (розмірністю 101×512) інтерпретується як послідовність із 101 кроку,

На кожному кроці (тобто для кожного рядка зображення) модель отримує 512 ознак — інтенсивностей сигналу вздовж горизонтального зрізу.

Було прийнято рішення розподілити дані таким чином, щоб 80 % усіх даних було використано для навчання, 20 % — для тестування.

Комп'ютерний експеримент та аналіз результатів

У цьому дослідженні було реалізовано комп'ютерний експеримент, метою якого було навчання моделі CNN + BiLSTM + Attention (Рис. 3) для виявлення мін, на основі даних отриманих з B-scan матриць, що були розділені на дві категорії - наявність міни та відсутність міни. Для тестування цієї нейромережі B-scan зображення були перетворені на послідовності, де кожен рядок матриці трактувався як один часовий крок, а 512 стовпців відповідали кількості ознак.

CNN + BiLSTM + Attention: Архітектура моделі для виявлення мін




Рис. 3. Блок-схема гібридної нейронної мережі CNN + BiLSTM + Attention для виявлення мін на основі бінарної класифікації.

Опис архітектури моделі:

TimeDistributed(Conv1D) передбачає, що кожен з 101 часових кроків опрацьовується за допомогою конволюційного шару, що витягує просторові ознаки з 512 вимірів.

MaxPooling1D зменшує розмірність ознак на кожному кроці.

Flatten перетворює кожен часовий крок у вектор ознак.

Bidirectional LSTM двонаправлений LSTM з 128 блоків для кожного напрямку опрацьовує послідовність часових кроків, дозволяючи моделі врахувати контекст як з початку, так і з кінця послідовності.

Attention (реалізована через Lambda) обчислює ваговий розподіл по часових кроках, дозволяючи моделі фокусуватися на найбільш інформативних моментах сигналу.

Dense шари забезпечує фінальну класифікацію за допомогою вихідного шару з сигмоїдальною активацією (бінарна задача).

Також для досягнення вищої точності було використано оптимізатори та функція втрат. Для навчання моделі використовувалися такі оптимізатори:

Adam (learning_rate = 0.0001) — оптимізатор, який забезпечує хорошу збіжність і адаптивне коригування швидкості навчання.

Альтернативно тестувався RMSprop, однак Adam показав кращі результати на даних із шумом і складною морфологією.

У даному дослідженні пропонується гібридна архітектура нейромережі CNN+BiLSTM+Attention, яка поєднує модулі TimeDistributed (Conv1D), які застосовуються для виділення просторових ознак із кожного кроку B-scan послідовності. Завдяки TimeDistributed-шару ці операції виконуються незалежно для кожного часового кроку, що дозволяє зберегти часову структуру сигналу. BiLSTM (Bidirectional LSTM) дозволяє моделі враховувати залежності як у прямому, так і зворотному напрямках по часових кроках. Це дає змогу повніше охопити динаміку зміни сигналу, зокрема при зашумлених або нечітких сигналах. Механізм уваги (Attention) додається після BiLSTM, щоб зосередити вагу мережі на найбільш інформативних часових кроках, підвищуючи ефективність класифікації.

Було проведено порівняння класичних моделей (LSTM, BiLSTM, GRU, CNN + LSTM) з нашою моделлю CNN+BiLSTM+Attention. Як видно з таблиці 1, всі класичні моделі LSTM, GRU та навіть гібрид CNN+LSTM показали досягнення точності на рівні 86%, що свідчить про обмеженість стандартних архітектур у повному охопленні особливостей B-scan сигналів.

Таблиця 2.

Порівняння ефективності різних моделей

Модель	Accuracy	F1-макро
LSTM	0.86	0.84
BiLSTM	0.87	0.84
GRU	0.86	0.84
CNN + LSTM	0.86	0.84
CNN+BiLSTM+Attention	0.99	0.99

Модель CNN+BiLSTM+ Attention значно перевершила інші моделі, досягнувши 99,6% точності та максимального значення F1-макро = 0.99. Це свідчить про здатність механізму уваги фокусуватися на найбільш інформативних частинах сигналу; ефективну взаємодію між просторовим аналізом (CNN) та часовим опрацюванням (BiLSTM).

Для оцінки якості навчання та класифікації було побудовано графіки точності (accuracy), функції втрат (loss), матриці плутанини, а також діаграми класифікаційних метрик.

На рис. 4.а. зображено зміну точності класифікації моделі протягом навчання для тренувальної та валідаційної вибірок.

Вісь X (горизонтальна) — кількість епох навчання.

Вісь Y (вертикальна) — значення точності.

З перших епох модель стрімко підвищує точність як на тренувальній, так і на валідаційній вибірках. Точність на тренувальних даних досягає майже 99,6%, а точність на валідаційних даних становить приблизно 95 %, що свідчить про високу здатність моделі узагальнювати нові (невідомі) дані без ознак перенавчання.


На рис. 4.б. зображено значення функції втрат протягом навчання моделі. Лінії показують значення втрат для тренувальної вибірки та валідаційної вибірки.

Вісь X (горизонтальна) — кількість епох.


Вісь Y (вертикальна) — значення функції втрат. Чим нижче значення, тим краще модель узгоджується з даними.

Спостерігається чітка тенденція зменшення значень втрат на обох вибірках упродовж навчання. Починаючи приблизно з 30 епохи, значення втрат стабілізуються як на тренувальній, так і на валідаційній вибірках. Відсутність різкого розходження між тренувальною та валідаційною кривими свідчить про:

- Відсутність перенавчання;
- Високу стійкість моделі до зміни даних;
- Правильно підбрану архітектуру нейромережі та її гіперпараметрів (регуляризація, Dropout, кількість нейронів і шарів, оптимізатор Adam).



а. Графік точності;



б. Графік втрат;

Рис. 4. а) Графік точності (Accuracy), б) графік втрат (Loss)

На рис. 5 представлено матрицю плутанини — це візуалізація, що дозволяє оцінити, як модель класифікує об'єкти кожного класу.

Вісь Y (вертикальна) — фактичні (правильні) мітки.

Вісь X (горизонтальна) — прогнозовані мітки.

True Negatives (TN) = 56 — клас 0 правильно класифіковано.

False Positives (FP) = 0 — немає помилкового класифікування класу 0 як 1.

False Negatives (FN) = 10 — клас 1 помилково класифіковано як 0.

True Positives (TP) = 31 — клас 1 правильно класифіковано.




Рис. 5. Матриця плутанини та метрики класифікації

Метрики класифікації моделі (Рис. 6) демонструють високий рівень точності, повноти та F1-міри для задачі виявлення мін.

Класифікаційні категорії:

Negative — зразки, що не містять вибухонебезпечних об'єктів.

UXO — зразки ділянок, де міна була виявлена.

accuracy — загальна точність

macro avg — макро-середнє значення по всіх класах

Всі показники перебувають на рівні 96–97 %, що свідчить про високу узгодженість між передбаченням та реальними класами.




Рис. 6. Метрики класифікації моделі

Баланс між precision та recall дозволяє зробити висновок, що модель не тільки не пропускає небезпечні об'єкти (високий recall), але й рідко виявляє міни на безпечних ділянках – хибно позитивне виявлення (високий precision). Значення F1-score підтверджує загальну ефективність моделі при роботі з обома класами. Такий графік є наочним підтвердженням стабільної роботи моделі в умовах високої точності та узагальнення.

Подяка

Дана стаття підготована завдяки грантової підтримки Національного Фонду Досліджень України, реєстраційний номер проєкту 273/0024 від 1/08/2024 (2023.04/0024) «Методи та засоби активного та пасивного розпізнавання мін на основі глибоких нейронних мереж» за конкурсом «Наука для зміцнення обороноздатності України».

Висновки

1. Розроблено гібридну модель CNN + BiLSTM + Attention з оптимізатором Adam для виявлення мін (TM62M, O3M72) на основі GPR B-scan зображень. Для оцінювання моделі обрано метрики Ассурасу, F1-score. Розраховано значення метрик класифікації Ассурасу, F1-score для ділянок, де не було виявлено мін (Negative), були виявлені міни (UXO), загальна точність (ассурасу) та середнє значення по всіх класах (macro avg). Показано, що показники для всіх типів метрик становлять 96–97%, що свідчить про високу узгодженість між передбаченням та реальними класами.
2. Проведене попереднє опрацювання та аугментація GPR B-scan сигналів, отримані B-scan зображення (розмірністю 101×512) подаються на вхід гібридної моделі CNN + BiLSTM + Attention.
3. Комп'ютерний експеримент показав, що запропонована гібридна модель CNN + BiLSTM + Attention має високу точність виявлення мін (99,6%) порівняно з класичними моделями (LSTM, BiLSTM, GRU, CNN + LSTM), які забезпечують точність розпізнавання на рівні ~86 %. На основі комп'ютерного експерименту отримано матрицю плутанини в якій зазначено, що істинно позитивні значення становлять 31, а хибно позитивні 0, що означає правильність класифікації позитивних значень. Істинно негативні значення становлять 56, тоді як хибно негативні 10.

Напрямок подальших досліджень є оптимізація продуктивності нейромережевої моделі для її використання у режимі реального часу. Можливі заходи включають спрощення архітектури або знесення деяких шарів без значної втрати якості, використання для розгортання на борту мобільних пристроїв. Подальша робота в цьому напрямку допоможе зробити розроблений метод ще більш практичним та дієвим: від підвищення його точності й стійкості на розширених даних — до забезпечення швидкодії і зручності інтеграції в реальні системи розмінування. Таким чином, отримані результати створюють потужну основу для подальшого розроблення автономних систем виявлення мін, які будуть надійними, точними та придатними для роботи в умовах реального середовища.

СПИСОК ЛІТЕРАТУРИ

1. Abhishek Rangole, De, S., Nilesh Kuchekar, & Bazil, A. (2024). A Comprehensive Review of Ground Penetrating Radar: Techniques, Applications and Future Directions. 12(3), 30–53. doi: 10.5281/zenodo.13842586
2. Adhikari, S., Noh, D., Kim, M., Ahn, D., Jang, Y., Oh, E., & Lee, D. (2024). Vapor phase detection of explosives by surface enhanced Raman scattering under ambient conditions with metal nanogap structures. *Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy*, 311, 123996. doi: 10.1016/j.saa.2024.123996
3. Gurkan S., Karapinar M., & Dogan, S. (2017). Classification of explosives materials detected by magnetic anomaly method. 347–350. doi: 10.1109/iceee2.2017.7935848
4. Landmine and Cluster Munition Monitor. (2024). Retrieved from <https://www.the-monitor.org>
5. Madavha L., Laseinde, T., Ilesanmi Daniyan, & Khumbulani Mpofu. (2020). Functional design and performance evaluation of a metal handheld detector for land mines detection. *Procedia CIRP*, 91, 696–703. doi: 10.1016/j.procir.2020.04.134
6. Lytvyn V., Peleshchak, I., Vysotska, V., Motyka, V., & Peleshchak, R. (2022). Passive Method for Mine Detection and Classification Using Magnetic Fields and Convolutional Neural Networks. 2022 IEEE 16th International Conference on Advanced Trends in Radioelectronics, Telecommunications and Computer Engineering (TCSET), 1–6. doi: 10.1109/tcset64720.2024.10755852
7. Markoulidakis, I., Rallis, I., Georgoulas, I., Kopsiaftis, G., Doulamis, A., & Doulamis, N. (2021). Multiclass Confusion Matrix Reduction Method and Its Application on Net Promoter Score Classification Problem. *Technologies*, 9(4), 81. doi: 10.3390/technologies9040081
8. Peleshchak, R., Vasyly Lytvyn, Oleksandr Mediakov, & Peleshchak, I. (2023). Morphology of Convolutional Neural Network with Diagonalized Pooling. *Communications in Computer and Information Science*, 161–172. doi: 10.1007/978-3-031-27034-5_11

9. Pol, A. A. (2020). Machine Learning Anomaly Detection Applications to Compact Muon Solenoid Data Quality Monitoring. Hal.science. Retrieved from <https://theses.hal.science/tel-02924477>
10. Study on evaluating airborne GPR's potential for UXO and Landmine Detection in a Controlled Environment. (2023). Retrieved from <https://www.sphengineering.com/news/study-on-evaluating-airborne-gprs-potential-for-uxo-and-landmine-detection-in-a-controlled-environment>
11. Yilmaz, C., Sonmez, Y., Kahraman, H. T., Salih Soyler, & Ugur Guvenc. (2016). Developing of decision support system for land mine classification by meta-heuristic classifier. 1–5. doi: 10.1109/inista.2016.7571867
12. Yilmaz, C., Kahraman, H. T., & Soyler, S. (2018). Passive Mine Detection and Classification Method Based on Hybrid Model. IEEE Access, 6, 47870–47888. doi: 10.1109/access.2018.2866538

MINE DETECTION USING CNN+BILSTM+ATTENTION BASED ON B-SCAN SIGNALS

Ivan Peleshchak¹, Yurii Futryk²

^{1,2}Lviv Polytechnic National University,

Information Systems and Networks Department, Lviv, Ukraine

¹ E-mail: ivan.r.peleshchak@lpnu.ua, ORCID: 0000-0002-7481-8628

² E-mail: yurii.v.futryk@lpnu.ua, ORCID: 0000-0001-5271-9883

© Peleshchak I., Futryk Y., 2025

In modern conditions, the problem of mine detection remains one of the most urgent due to the serious threat to the life and health of people in contaminated areas. This paper presents an approach to mine detection using a hybrid neural network CNN+BiLSTM+Attention, which analyzes B-scan signals received from ground-penetrating radar systems. To improve the quality of training with a limited amount of data, image augmentation was used, which includes shifting, reflecting, scaling, and adding noise. The initial layers of the architecture use convolutional operations to extract local spatial features, after which a bidirectional recurrent layer BiLSTM is used, which allows the model to learn dependencies within each B-scan, taking into account the context in both directions. An attention mechanism is additionally integrated to focus on the most informative fragments of the signal. The final layers of the model are dense layers with a sigmoid activation function for mine detection. The results of the computer experiment demonstrated the high efficiency of the model: the classification accuracy exceeds 99%, and the values of Precision, Recall, F1-score and AUC indicate the reliability of the approach. Visualization of the results (loss and accuracy graphs, confusion matrix, metric histogram) confirms stable learning without overtraining. The proposed architecture is promising for application in remote mine monitoring tasks and can be used as a basis for further research in the field of military security.

Keywords: Ground penetrating radar, mine detection, pre-processing of data, oversampling, hybrid neural network, bidirectional LSTM.