



В. В. Литвин¹, І. Р. Пелешчак², В. А. Висоцька³, В. М. Мотика⁴, Р. М. Пелешчак⁵

¹НУ «Львівська політехніка», м. Львів, Україна, vasyi.v.lytvyn@lpnu.ua,
ORCID iD: 0000-0002-9676-0180

²НУ «Львівська політехніка», м. Львів, Україна, ivan.r.peleshchak@lpnu.ua,
ORCID iD: 0000-0002-7481-8628

³НУ «Львівська політехніка», м. Львів, Україна, victoria.a.vysotska@lpnu.ua,
ORCID iD: 0000-0001-6417-3689

⁴НУ «Львівська політехніка», м. Львів, Україна, volodymyr.motyka.mnsam.2023@lpnu.ua,
ORCID iD: 0009-0009-8086-7619

⁵НУ «Львівська політехніка», м. Львів, Україна, roman.m.peleshchak@lpnu.ua,
ORCID iD: 0000-0002-0536-3252

ПАСИВНИЙ ПІДХІД ДО ВИЯВЛЕННЯ ТА КЛАСИФІКАЦІЇ МІН ІЗ ВИКОРИСТАННЯМ МАГНІТНИХ ПОЛІВ І ЗГОРТКОВИХ НЕЙРОННИХ МЕРЕЖ

В наш час для виявлення мін широко використовуються активні детектори, що забезпечують виявлення мін з високою точністю. Однак їхній принцип роботи може бути небезпечним, оскільки він має потенціал спричинити детонацію прихованих мін. Це дослідження представляє інноваційний метод виявлення та класифікації мін, виготовлених з різних матеріалів (металевих, напівметалевих, пластикових), за допомогою згорткової нейронної мережі. Мережа аналізує аномалії, отримані з унікально розробленої матриці ознак, досягаючи значної точності у класифікації. Процес класифікації базується на вхідному векторі ознак, який включає: показники напруги від магнітометричного датчика FLC-100, який виявляє магнітні аномалії біля мін із чутливістю в діапазоні від 10^{-10} до 10^{-4} Тесла; дані з шести типів ґрунту з урахуванням їх вологості; висоту розташування датчика над міною. Оскільки міни, виготовлені з різних матеріалів та мають унікальні магнітні властивості, використання даних про магнітні аномалії дозволяє ефективно класифікувати міни. Точність класифікації оцінювалась за допомогою різних показників, таких як F1, Precision, Accuracy, FPR, FNR, Recall та TNR.

МАГНІТНІ АНОМАЛІЇ, КЛАСИФІКАЦІЯ МІН, ЗГОРТКОВІ НЕЙРОННІ МЕРЕЖІ (CNN), СЕНСОР FLC-100, БЕЗПЕЧНЕ РОЗМІНУВАННЯ.

V.V. Lytvyn, I.R. Peleshchak, V.A. Vysotska, V.M. Motyka, R.M. Peleshchak. *A Passive Approach to Mine Detection and Classification Utilizing Magnetic Fields and Convolutional Neural Networks*. Active detectors are widely used today for mine detection, providing high accuracy. However, their operating principle can pose a danger, as it has the potential to trigger the detonation of hidden mines. This study introduces an innovative method for detecting and classifying mines composed of different materials (metallic, semi-metallic, plastic) through the use of a convolutional neural network. The network analyzes anomalies derived from a uniquely designed feature matrix, achieving notable accuracy in classification. The classification process is based on a feature input vector that includes: voltage readings from the FLC-100 magnetic field sensor, which detects magnetic field anomalies near mines with sensitivities ranging from 10^{-10} to 10^{-4} Tesla; data from six soil types, considering their moisture content; and the sensor's height above the mine. Since mines made from different materials exhibit distinct magnetic properties, utilizing magnetic field anomaly data allows for effective material-based mine classification. The classification accuracy was evaluated using various metrics, such as F1, Precision, Accuracy, FPR, FNR, Recall, and TNR.

MAGNETIC ANOMALIES, MINE CLASSIFICATION, CNN, FLC-100 SENSOR, SAFE DEMINING.

Вступ

Виявлення наземних мін залишається критичною та глобальною проблемою, яка загрожує мільйонам життів. У 2016 році щодня в середньому 23 особи гинули або зазнавали поранень через міни. Наразі близько 61 країни та регіону продовжують стикатися з постійною загрозою від цих прихованих вибухових пристроїв, що становить постійну небезпеку для життя людей [1]. Виявлення та знешкодження мін є важливими кроками для забезпечення безпеки в постконфліктних зонах.

Традиційні методи виявлення мін більше не забезпечують необхідного рівня ефективності та надійності. Активні детектори, що генерують електричні сигнали для виявлення мін, можуть випадково спровокувати спрацьовування вибухового механізму, що призводить до небезпечних наслідків. З цієї причини пасивні детектори, засновані на вимірюванні магнітних аномалій у місці розташування міни, стають більш безпечним варіантом. Сучасні автоматизовані методи, такі як нейронні мережі, виявляються ефективними у вирішенні цього завдання.

Важливість використання нейронних мереж у поєднанні з даними про магнітні аномалії пояснюється такими факторами:

Безпека військових і цивільних: Виявлення мін є ключовим для порятунку життів як під час бойових дій, так і при розмінуванні територій після завершення конфліктів.

Швидкість і точність: Датчики магнітного поля сприяють швидкому виявленню закопаних мін, що дозволяє оперативно реагувати та розпізнавати міни. Нейронні мережі підвищують ефективність цього процесу, точно класифікуючи сигнали і фільтруючи шум або нерелевантні об'єкти.

Зниження ризиків: Автоматизовані системи на основі нейронних мереж зменшують ймовірність людських помилок та суттєво підвищують точність виявлення і класифікації мін.

У цій роботі представлено метод виявлення та класифікації мін із різних матеріалів (металевих, напівметалевих, пластикових) з використанням згорткової нейронної мережі. Підхід базується на даних від магнітного сенсора, який здатен виявляти магнітні аномалії з чутливістю в діапазоні від 10^{-10} до 10^{-4} Тесла, при цьому враховується тип ґрунту та висота сенсора над закопаним об'єктом. Ці дані перетворюються в спеціалізовану матрицю ознак, після чого згорткова нейронна мережа аналізує дані з цієї графічної матриці.

1. Огляд та аналіз літератури

До класичних засобів виявлення та розпізнавання вибухонебезпечних пристроїв можна віднести такі групи: апаратура з проникаючим випромінюванням, детектори парів та вибухових речовин (газоаналізатори, засоби хімічного аналізу), магнітомеханічні засоби, засоби пошукової техніки [2]. Апаратура з проникаючим випромінюванням може використовувати рентгенівське, іонізуюче випромінювання. У цьому напрямку розробляються ядерно-фізичні методи, основою яких є джерела нейтронів та виявлення гамма-випромінювання після взаємодії нейтрона з об'єктом пошуку [2]. Методи на основі хімічного аналізу дедалі частіше інтегруються в робототехнічні технології [3]. Окрім цього, пошукові пристрої, як-от металодетектори, активно вдосконалюються, і в сучасних розробках акцент робиться на створенні автоматизованих систем на їхній основі. Ці інновації підвищують безпеку та покращують точність виявлення, інтегруючи металодетектори у роботизовані платформи [4].

Детектори мін можна поділити на активні та пасивні. Активні детектори випромінюють сигнал у напрямку цілі та аналізують відбитий сигнал для виявлення мін. Незважаючи на високу точність цих пристроїв, вони мають ризик випадкового

спрацьовування вибухового механізму міни. Пасивні детектори, навпаки, засновані на виявленні порушень у магнітному полі, викликаних присутністю мін. Хоча вони менш точні, але загалом вважаються безпечнішими [5, 6]. Існує декілька подібних досліджень, які включають використання алгоритмів машинного навчання для класифікації виявлених мін за допомогою аномалії магнітного поля. Наприклад, у одному з досліджень використовували автоенкодер зі спеціальним налаштуванням, досягнувши точності класифікації 93% і показника AUC 98% для виявлення прихованих мін [7]. В іншому дослідженні [8] застосовувався алгоритм k-NN з даними від мережі з 32 магнітних датчиків, і було досягнуто точності 91,66% у виявленні мін.

Інноваційність нашого дослідження полягає в розробці згорткової нейронної мережі, здатної забезпечити високу точність класифікації мін, виготовлених із різних матеріалів. Процес класифікації базується на вхідному векторі ознак, який включає: показники напруги від магнітометричного датчика FLC-100; інформацію про шість різних типів ґрунтів із різним рівнем вологості; та висоту сенсора над міною.

2. Матеріали і методи

У цьому дослідженні розглядаються архітектури нейронних мереж, що включають компоненти, такі як повнозв'язані шари, згорткові шари, механізми пулінгу та різні функції активації.

Повнозв'язаний шар у нейронній мережі з'єднує кожен нейрон з усіма нейронами попереднього шару. Це забезпечує те, що кожен вихід з попереднього шару пов'язаний з кожним нейроном у поточному шарі.

Згортковий шар є основним компонентом згорткових нейронних мереж (CNN). Він застосовує згорткові операції до вхідного зображення за допомогою набору фільтрів (ядер), щоб виділити візуальні ознаки, такі як краї, кути, форми та візерунки [9–11]. Використовуючи малі квадратні ядра, ці фільтри дозволяють виявити різні характеристики у вхідних даних.

Згортка дозволяє мережі захоплювати ознаки вхідного зображення, зберігаючи просторові зв'язки між пікселями, що дає можливість мережі навчатися ознакам зображення за допомогою невеликих фрагментів вхідних даних. У згортковому шарі нові ознаки виявляються шляхом виконання матричного множення між ядром і вхідним зображенням. Розмір ядра може варіюватися, найчастіше використовуються 2×2 , 3×3 або 5×5 , і вони представлені у вигляді матриць відповідного розміру.

Застосоване ядро витягує різні ознаки з вхідних даних, і вибір та застосування цих ядер є критично важливим. Великий розмір ядра може призвести

до втрати певних характеристик у вхідних даних. Коефіцієнти ядра представляють ваги в згортковій нейронній мережі. Під час кожної ітерації коефіцієнти ядра коригуються в процесі навчання. У міру того, як значення навчаються, коефіцієнти оновлюються, що призводить до створення нових ядер.

Для кожного пікселя у вхідних даних ядро ковзає по всіх пікселях, виконуючи множення між коефіцієнтом вхідних даних і коефіцієнтом ядра. Ця операція проводиться незалежно для кожного каналу вхідних даних. Результати з усіх каналів підсумовуються, і кінцеве значення присвоюється відповідній точці у вихідних даних.

Згортка – це математичний процес, який включає вхідні дані, такі як матриця зображення, і ядро. Операцію згортки ілюструє рис. 1. Розмір виходу відображає загальну кількість різних ядер, які можуть бути отримані з зображення.

Розміри вхідного зображення: $h \times w \times d$.

Розміри ядра: $fh \times fw \times d$.

Розміри вихідної матриці: $(h - fh + 1) \times (w - fw + 1) \times 1$.




Рис. 1. Процес операції згортки

Шар пулінгу в глибоких нейронних мережах зменшує розмірність вхідних даних, зменшуючи кількість параметрів та усуваючи незначні деталі з зображення або вектору ознак. Він діє як фільтр, який обчислює статистичні властивості (такі як максимальні або середні значення) для кожного пікселя, фрагмента зображення або групи ознак у векторі.

Під час навчання моделі шар пулінгу зменшує кількість параметрів і допомагає зменшити ризик перенавчання. Шар пулінгу можна додати після кожного згорткового шару для зменшення розміру вхідних даних і відкидання менш важливих деталей.

Шар пулінгу зменшує розмір зображення, зберігаючи важливі ознаки. Пулінг зменшує висоту та ширину вхідних даних, що прискорює процес навчання нейронної мережі, хоча це може призвести до деякої втрати ознак. Однією з обмежень пулінгу є те, що він не вводить навчальні параметри, оскільки розмір ядра та крок є заздалегідь визначеними та фіксованими.

Одним з найбільш поширених методів пулінгу є макс-пулінг. У цій техніці обирається вікно розміром $n \times n$, де n менше розміру зображення, і вибирається найбільше значення в цьому вікні. Потім вікно переміщується по зображенню з певною довжиною кроку,

і ця операція повторюється. Рис. 2 ілюструє операцію макс-пулінгу.

Отже, шари пулінгу відіграють вирішальну роль у зменшенні розміру даних, запобіганні перенавчанню та забезпеченні швидших обчислень, зберігаючи найважливішу інформацію.




Рис. 2. Приклад максимального пулінгу з ядром 2×2

Метриками для моделей машинного навчання у цьому дослідженні були обрані:

F1 Score: метрика є гармонійним середнім значенням Accuracy та Recall. Вона фіксує компроміс між цими двома аспектами, пропонуючи всебічну оцінку ефективності моделі.

Precision: метрика оцінює відсоток правильних позитивних прогнозів, зроблених моделлю. Вища точність свідчить про меншу кількість хибнопозитивних прогнозів.

Accuracy (точність): метрика оцінює частку всіх прогнозів моделі, які є правильними. Вона відображає загальну ефективність моделі, незалежно від класу, який прогнозується.

FPR: метрика вимірює частку негативних прикладів (класу, який не прогнозується), які були неправильно класифіковані моделлю як позитивні.

FNR: метрика оцінює відсоток фактичних позитивних випадків, які модель помилково ідентифікувала як негативні.

Recall: метрика оцінює відсоток фактичних позитивних випадків, які модель успішно розпізнала.

TNR: метрика оцінює відсоток негативних випадків, які модель правильно класифікувала. Вона показує, наскільки добре модель може розрізнити негативні класи.

3. Набір даних та передобробка даних

Це дослідження зосереджується на класифікації мін на основі характеристик аномалій магнітного поля, використовуючи дані з [12], параметри яких детально описані в Таблиці 1, Таблиці 2 та Таблиці 3. Крім того, було проведено кореляційний аналіз між аномаліями магнітного поля, складом ґрунту та відстанню сенсора до міни. Також були виявлені типові патерни магнітних аномалій для кожного типу міни. Для виявлення магнітних аномалій поблизу закопаних мін використовувався ферозондовий сенсор FLC100 [13, 14].

Таблиця 1

Параметри даних				
Параметри				
	Вхідні дані			Вихідні дані
	Вольтаж (V)	Висота (H)	Тип ґрунту (S)	Тип міни (M)
Означення	Вихідна напруга сенсора FLC	Висота датчика над землею	Шість різних типів ґрунтів	П'ять різних класів мін
Граничні значення/Класи	[0 V, 10.6 V]	[0 cm, 20 cm]	Посушливий і піщаний	Null
			Посушливий і багnistий	Протитанкова
			Посушливий і крейдяний	Протипіхотна
			Мокрий і піщаний	Протипіхотна мінована пастка
			Вологий і гумусний	M14 Протипіхотна
			Вологий і крейдяний	

Таблиця 2

Зв'язок між аномаліями магнітного поля для мін і типом ґрунту

Тип ґрунту	Null, V	Протитанкова, V	Протипіхотна, V	Протипіхотна мінована пастка, V	M14 Протипіхотна, V
Посушливий і піщаний	3.570	10.410	3.840	5.600	3.210
Посушливий і багnistий	3.510	7.510	3.930	5.600	4.430
Посушливий і крейдяний	3.730	10.410	6.900	2.416	5.000
Мокрий і піщаний	3.790	10.410	6.230	4.500	5.240
Вологий і гумусний	3.360	10.410	5.060	2.780	4.210
Вологий і крейдяний	3.620	10.410	5.970	4.410	4.560

Таблиця 3

Вплив відстані від сенсора до землі на аномалії магнітного поля біля мін

Висота (cm)	Null, V	Протитанкова, V	Протипіхотна, V	Протипіхотна мінована пастка, V	M14 Протипіхотна, V
0.00	3.7	10.5	4.2	6.0	6.3
1.83	3.5	10.5	4.1	5.6	4.8
3.65	3.5	10.5	3.9	5.1	3.7
5.46	2.9	10.5	4.0	4.5	3.6
7.28	3.0	9.6	3.7	4.4	3.2
9.10	2.8	8.4	3.5	4.3	3.0
10.92	3.0	7.1	3.5	4.3	2.9
12.74	2.7	6.5	3.5	4.1	2.8
14.56	2.6	6.3	3.6	4.0	2.7
16.37	2.7	4.9	3.7	3.3	2.6
18.19	2.7	4.7	3.3	3.3	2.6
20.00	2.5	4.6	3.3	3.2	2.6

Набір даних містить інформацію про п'ять типів мін у шести різних типах ґрунту, з висотою сенсора над землею, що варіюється від 0 см до 20 см. Наступним кроком є створення матриці 101x6, яка відображає дані з навчального набору (рис. 3).




Рис. 3. Матриця візуалізації даних

Процес створення матриці починається з визначення осі X, використовуючи унікальні значення типів ґрунту (S), які варіюються від 1 до 6. Ось Y встановлюється за значеннями висоти (H), які коливаються від 0,00 до 20,00, але були нормалізовані до діапазону від 0,00 до 1,00 з кроком 0,01.

Ініціалізується порожня матриця, заповнена нулями, де кількість рядків відповідає значенням осі Y, а кількість стовпців відповідає значенням осі X.

Функція проходить через кожен рядок DataFrame, визначаючи відповідний стовпець на основі типу ґрунту (S) та правильного рядка на основі висоти (H). Для кожного запису значення напруги (V) розміщується в клітинці матриці у вказаному рядку та стовпці.

Якщо кілька записів мають однакові значення S та H, останнє значення напруги переписує попереднє в матриці.

Це призводить до створення структурованої матриці, яка представляє значення напруги для різних

типів ґрунту та висот. Нарешті, завершена матриця повертається для подальшої обробки. Цей систематичний підхід організовує дані таким чином, щоб підкреслити взаємозв'язки між напругою, типом ґрунту та висотою.

4. Модель CNN та результати

Для порівняння були використані дві структури згорткових нейронних мереж. Для створення та оцінки ефективності моделі були використані Python 3.9 та бібліотека Keras 2.10.

Structure #1

1@101x6 - 16@3x3/2x2 - 32@3x3/2x2 - F128 - F64 - F32 - S5

Вхідний шар, який приймає матрицю розміром 101x6, позначається як 1@101x6. Повністю з'єднаний шар з 128 нейронами позначається як F128, тоді як S5 вказує на шар з активаційною функцією Softmax. Згортковий шар з 16 фільтрами, ядром згортки 3x3 та ядром пулінгу 2x2 представлений як 16@3x3/2x2.

Таблиця 4

Результати навчання мережі

№	Структура	Критерій	Оптимізатор	Параметри оптимізатора	F1	Accuracy	Precision	Recall	FPR	FNR	TNR
1	1@101x6 - 16@3x3/2x2 - 32@3x3/2x2 - F128 - F64 - F32 - F5	Cross Entropy Loss	Adam	lr = 0.001	0.9215	0.9230	0.9230	0.9230	0.0443	0.0770	0.9557
2	1@101x6 - 16@3x3/2x2 - 32@3x3/2x2 - F128 - F64 - F32 - S5	Cross Entropy Loss	Adam	lr = 0.001	0.933	0.9347	0.9345	0.9347	0.0845	0.0973	0.9155
3	1@101x6 - 8@3x3/2x2 - 16@3x3/2x2 - F128 - F64 - F32 - S5	Cross Entropy Loss	Adam	lr = 0.001	0.9012	0.9006	0.9043	0.9006	0.1308	0.0628	0.8692
4	1@101x6 - 32@3x3/2x2 - 64@3x3/2x2 - F128 - F64 - F32 - S5	Cross Entropy Loss	Adam	lr = 0.001	0.9074	0.9078	0.9179	0.9078	0.2268	0.0959	0.7732
5	1@101x6 - 16@3x3/2x2 - 24@3x3/2x2 - F128 - F64 - F32 - S5	Cross Entropy Loss	Adam	lr = 0.001	0.9347	0.9363	0.9376	0.9363	0.0813	0.1015	0.9187
6	@101x6 - 16@4x4/2x2 - 24@3x3/2x2 - F128 - F64 - F32 - S5	Cross Entropy Loss	Adam	lr = 0.0001	0.9037	0.9091	0.9277	0.9091	0.1917	0.0595	0.8083
7	1@101x6 - 16@3x3/2x2 - 24@3x3/2x2 - F128 - F64 - F32 - S5	NLLoss	Adam	lr = 0.001	0.929	0.9307	0.9362	0.9307	0.1532	0.0304	0.8468
8	1@101x6 - 16@3x3/2x2 - 24@3x3/2x2 - F128 - F64 - F32 - LS5	NLLoss	Adam	lr = 0.001	0.9375	0.9387	0.9385	0.9387	0.0978	0.082	0.9022
9	1@101x6 - 16@3x3/2x2 - 24@T3x3/2x2 - F128 - F64 - F32 - LS5	NLLoss	Adam	lr = 0.001	0.9271	0.9291	0.9307	0.9291	0.0463	0.1545	0.9537

№	Структура	Критерій	Оптимізатор	Параметри оптимізатора	F1	Accuracy	Precision	Recall	FPR	FNR	TNR
10	1@101x6 - 16@T3x3/2x2 - 24@3x3/2x2 - F128 - F64 - F32 - LS5	NLLoss	Adam	lr = 0.001	0.939	0.9408	0.9419	0.9408	0.081	0.1063	0.919
11	1@101x6 - 16@T3x3/2x2 - 24@3x3/2x2 - F128 - F64 - F32 - LS5	NLLoss	AdamW	lr = 0.001	0.9312	0.9326	0.9313	0.9326	0.0825	0.0932	0.9175
12	1@101x6 - 16@T3x3/2x2 - 24@3x3/2x2 - F128 - F64 - F32 - LS5	NLLoss	NAdam	lr = 0.001	0.9251	0.9304	0.9395	0.9304	0.0634	0.2752	0.9366
13	1@101x6 - 16@T3x3/2x2 - 24@3x3/2x2 - F128 - F64 - F32 - LS5	NLLoss	RAdam	lr = 0.001	0.9361	0.9382	0.9375	0.9382	0.0683	0.1315	0.9317
14	1@101x6 - 16@T3x3/2x2 - 24@3x3/2x2 - F128 - F64 - F32 - LS5	NLLoss	RAdam	lr = 0.002	0.9121	0.9134	0.9157	0.9134	0.1887	0.0441	0.8113

Structure #2

1@101x6 - 16@T3x3/2x2 - 24@3x3/2x2 - F128 - F64 - F32 - LS5

У 16@T3x3/2x2 літера 'T' вказує на те, що матриці транспонуються перед подачею в згортковий шар. LS5 відноситься до повністю з'єднаного шару з активаційною функцією LogSoftMax.

Результати навчання для кожної мережі, разом із відповідними метриками продуктивності, представлені в Таблиці IV. Комплексний аналіз тестових результатів підкреслює складні взаємовідносини між архітектурою мережі, критеріями втрат, оптимізаторами та їх параметрами, а також те, як ці фактори разом впливають на метрики продуктивності. Проектування архітектури є вирішальним для здатності моделі навчатися та ефективно узагальнювати інформацію з даних. Наприклад, моделі з глибшими згортковими шарами, такі як Тест #2 та Тест #5, які включають кілька згорткових та пулінгових шарів, а також повністю з'єднані шари, послідовно досягають вищих показників F1 та точності. Це свідчить про те, що більш складна архітектура з достатньою кількістю шарів може захоплювати складніші шаблони в даних.

Вибір критерію втрат також суттєво впливає на продуктивність моделі. Моделі, які використовують втрати крос-ентропії, зазвичай перевершують ті, що використовують NLLoss, з точки зору F1 та точності. Це може бути пов'язано з тим, що крос-ентропійні втрати забезпечують більш інформативні градієнти, що веде до більш ефективного процесу навчання.

Однак деякі конфігурації з NLLoss, такі як Тест #8 та Тест #10, все ще демонструють конкурентоспроможні результати, вказуючи на те, що за відповідних структурних налаштувань та параметрів оптимізатора NLLoss може бути ефективно використано.

Вибір оптимізатора та його параметри є критично важливими для тонкого налаштування процесу навчання. Adam з швидкістю навчання 0.001 виявляється найбільш ефективним у кількох тестах, постійно забезпечуючи високі значення точності та F1. Наприклад, Тест #2 та Тест #5, які використовують Adam з цією швидкістю навчання, демонструють хороші результати. Навпаки, альтернативні оптимізатори, такі як NAdam та RAdam, показують змішані результати; NAdam у Тесті #12 досягає високого TNR, але низького FPR, в той час як RAdam у Тесті #13 ефективно балансує точність і Recall. Крім того, нижча швидкість навчання, як видно в Тесті #6 з Adam, встановленим на 0.0001, призводить до більш стабільного навчання, але з трохи нижчою продуктивністю, що підкреслює компроміс між швидкістю навчання та продуктивністю моделі.

Аналіз метрик продуктивності показує, що висока точність і Recall корелюють з високими показниками F1, що є показником збалансованої та ефективної класифікації. Тести #2, #5 та #8 виділяються з F1, що перевищують 0.93, демонструючи їх надійність у правильному визначенні як позитивних, так і негативних класів. Частота хибнопозитивних прогнозів (FPR) і частота хибнонегативних прогнозів (FNR)

надають додаткове розуміння специфічних помилок, які допускають моделі. Моделі з нижчими FPR і FNR, такі як Тест #10 та #14, демонструють кращий баланс між чутливістю та специфічністю, що робить їх більш надійними для практичного застосування.

В цілому, запропонований метод, що використовує згорткову нейронну мережу, може ефективно класифікувати міни з точністю 94.08% та F1 93.75%. Однак може знадобитися додаткове дослідження та налаштування параметрів, щоб адаптувати цей метод для інших наборів даних.

Висновки

Запропонований метод класифікації мін, оснований на даних магнітних аномалій, зібраних сенсором FLC-100, демонструє високу ефективність і безпеку в порівнянні з активними детекторами, які можуть становити ризик детонації. Модель згорткової нейронної мережі (CNN) дозволяє точно класифікувати міни, побудовані з різних матеріалів, таких як метал, напівметал і пластик.

Дослідження показало, що використання магнітного поля як основи для аналізу аномалій дозволяє ефективно розпізнавати міни, враховуючи тип ґрунту та висоту сенсора. Комплексний аналіз результатів продемонстрував, що найкраща продуктивність досягається за допомогою складних архітектур мереж і оптимізаторів, таких як Adam, з швидкістю навчання 0.001.

Найвища точність (94.08%) та F1 (93.75%) підкреслюють надійність моделі, що робить її обіцяючою для реальних застосувань. Однак для забезпечення високої продуктивності на інших наборах даних може знадобитися додаткове налаштування моделі, враховуючи специфічні умови навколишнього середовища та параметри ґрунту.

Запропонований метод не тільки забезпечує високу точність класифікації, але й підвищує безпеку при розмінуванні, оскільки використовує пасивний підхід виявлення, усуваючи ризик випадкової детонації.

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».

Список літератури:

[1] International Campaign to Ban Landmines, Landmine Monitor 2023 (ICBL-CMC: January 2023). [Online]. Available: www.the-monitor.org.

[2] Ishchenko, A.V.; Kobets, M.V. "Means and Methods of Detecting Explosive Substances and Devices in the Fight against Terrorism: Training and Practice," NAVSU Publishing House: Kyiv, Ukraine, 2005; p. 144.

[3] Krausa, M.; Massong, H.; Rabenecker, P.; Ziegler, H. "Chemical methods for the detection of mines and explosives. In Detection of Explosives and Landmines," Eds.; NATO Science Series; Springer: Dordrecht, The Netherlands, 2002; Volume 66. https://doi.org/10.1007/978-94-010-0397-1_1.

[4] Masunaga, S.; Nonami, K. "Controlled metal detector mounted on mine detection robot," Int. J. Adv. Robot. Syst. 2007, 4, pp. 237–245. <https://doi.org/10.5772/5692>

[5] Yilmaz, C.; Kahraman, H.T.; Söyler, S. "Passive Mine Detection and Classification Method Based on Hybrid Model," IEEE Access 2018, 6, 47870–47888. <https://doi.org/10.1109/ACCESS.2018.2866538>.

[6] Peleshchak R.M., Lytvyn V.V., Nazarkevych M.A., Peleshchak I.R., Nazarkevych H.Y. "Influence of the Symmetry Neural Network Morphology on the Mine Detection Metric," Symmetry. 2024; 16(4):485. <https://doi.org/10.3390/sym16040485>

[7] Bestagini, P., Lombardi, F., Lualdi, M., Picetti, F., & Tubaro, S. "Landmine Detection Using Autoencoders on Multi-polarization GPR Volumetric Data," 2018. [Online]. Available: <https://arxiv.org/pdf/1810.01316.pdf>

[8] S. Gürkan, M. Karapinar and S. Doğan, "Classification of explosives materials detected by magnetic anomaly method," 2017 4th International Conference on Electrical and Electronic Engineering (ICEEE), Ankara, Turkey, 2017, pp. 347-350, doi: 10.1109/ICEEE2.2017.7935848.

[9] Xiaohui Wei, Changbao Zhou, Hengshan Yue, Joey Tianyi Zhou. "TC-SEPM: Characterizing soft error resilience of CNNs on Tensor Cores from program and microarchitecture perspectives," Journal of Systems Architecture, Volume 145, 2023, 103024, ISSN 1383-7621. <https://doi.org/10.1016/j.sysarc.2023.103024>.

[10] Martin Tetard, Veronica Carlsson, Mathias Meunier, Taniel Danelian. "Merging databases for CNN image recognition, increasing bias or improving results?" Marine Micropaleontology, Volume 185, 2023, 102296, ISSN 0377-8398. <https://doi.org/10.1016/j.marmicro.2023.102296>.

[11] Huanhua Liu, Wei Wang, Hanyu Liu, Shuheng Yi, Yonghao Yu, Xunwen Yao. "A Degradation Type Adaptive and Deep CNN-Based Image Classification Model for Degraded Images," CMES - Computer Modeling in Engineering and Sciences, Volume 138, Issue 1, 2023, Pages 459-472, ISSN 1526-1492. <https://doi.org/10.32604/cmescs.2023.029084>.

[12] Dataset Land Mines - UCI Machine Learning Repository, 2022. [Online]. Available: <https://archive.ics.uci.edu/dataset/763/land+mines-1>

[13] C. Yilmaz, Y. Sönmez, H. T. Kahraman, S. Soyler, and U. Güvenç, "Developing of decision support system for land mine classification by metaheuristic classifier," in Proc. Int. Symp. Innov. Intell. Syst. Appl. (INISTA), Aug. 2016, pp. 1–5.

[14] A. Barnawi, K. Kumar, N. Kumar, B. Alzahrani, and A. Almansour "A Deep Learning Approach for Landmines Detection Based on Airborne Magnetometry Imaging and Edge Computing," Comput. Model. Eng. Sci., vol. 139, no. 2, pp. 2117-2137. 2024. <https://doi.org/10.32604/cmescs.2023.044184>