

Оригінальна стаття

<https://doi.org/10.26565/2311-0872-2025-43-03>

УДК 537.86

В.А. ПЛАХТІЙ, доктор філософії, завідувач кафедри

e-mail: plakhtii@karazin.ua ORCID ID: <http://orcid.org/0000-0002-0442-2716>

О.А. ПРИЩЕНКО, доктор філософії

e-mail: pryshchenko@karazin.ua ORCID ID: <http://orcid.org/0000-0001-5067-9689>

О.М. ДУМІН, д. ф.-м. наук, провідний науковий співробітник

e-mail: dumin@karazin.ua ORCID ID: <http://orcid.org/0000-0001-5067-9689>

Р.Д. АХМЕДОВ, к. ф.-м. наук, старший науковий співробітник

e-mail: rolan.akhmedov@karazin.ua ORCID ID: <https://orcid.org/0000-0002-3819-1282>

Харківський національний університет імені В.Н. Каразіна, 61022, м. Харків, майдан Свободи, 4

АНАЛІЗ ЗАВАДОСТІЙКОСТІ НЕЙРОМЕРЕЖЕВОЇ СИСТЕМИ РОЗПІЗНАВАННЯ ПІДПОВЕРХНЕВИХ ОБ'ЄКТІВ

Актуальність: Системи підповерхневого зондування на основі імпульсних електромагнітних хвиль широко застосовуються для виявлення прихованих об'єктів у ґрунті. Водночас ефективність таких систем істотно знижується в умовах інтенсивних завад, спричинених зовнішніми відбиттями та радіочастотними джерелами. Особливо складною є задача автоматизованого розпізнавання об'єктів за георадарними сигналами з використанням штучних нейронних мереж, оскільки їхня завадостійкість суттєво залежить від вибору параметрів моделювання, формування вхідних даних та навчання.

Мета роботи: Дослідження та оптимізація параметрів системи виявлення підповерхневих об'єктів на основі штучної нейронної мережі з метою підвищення її завадостійкості шляхом застосування алгоритму повного перебору параметрів (grid search).

Матеріали та методи: Підповерхнєве середовище з прихованим металевим об'єктом опромінювалося плоскою імпульсною електромагнітною хвилею. Електродинамічна задача поширення та розсіяння хвилі розв'язувалася числовим методом скінченних різниць у часовій області (FDTD) з урахуванням взаємодії електромагнітного поля, однорідного ґрунту та об'єкта. Вхідні дані для нейронної мережі формувалися на основі часових залежностей прийнятих сигналів, а також додаткової інформації, отриманої з використанням підходу дискретної томографії та трасування променів. Для пошуку оптимальної конфігурації системи застосовано grid search, у межах якого досліджено вплив типу вхідних даних, кількості датчиків, параметрів часового вікна, методів аугментації даних та способів кодування цільових класів. Оцінювання завадостійкості здійснювалося за допомогою F1-міри та порогового рівню завадостійкості системи (Gate SNR).

Результати: У результаті проведеного grid search визначено конфігурації системи, які забезпечують найвищу завадостійкість розпізнавання. Показано, що вибір часового вікна є критичним фактором, який суттєво впливає на значення Gate SNR. Встановлено, що навчання нейронної мережі на зашумлених даних покращує її здатність до узагальнення та підвищує стабільність роботи в умовах шуму. Продемонстровано, що спосіб кодування класу відсутності об'єкта має найбільший вплив на ефективність системи, дозволяючи досягти нижчих порогових значень Gate SNR порівняно з іншими параметрами.

Висновки: Застосування алгоритму grid search дозволило систематично оптимізувати параметри системи підповерхневого розпізнавання об'єктів на основі штучної нейронної мережі. Отримані результати підтверджують доцільність поєднання фізично обґрунтованих методів обробки сигналів із машинним навчанням для підвищення завадостійкості георадарних систем. Запропонований підхід може бути використаний як основа для подальшого розвитку методів автоматизованого аналізу георадарних даних у реальних експериментальних умовах.

КЛЮЧОВІ СЛОВА: підповерхневий об'єкт, імпульсна електромагнітна хвиля, георадар, штучна нейронна мережа, завадостійкість, grid search, дискретна томографія.

Як цитувати: Плахтій ВА, Прищенко ОА, Думін ОМ, Ахмедов РД. Аналіз завадостійкості нейромережевої системи розпізнавання підповерхневих об'єктів. Вісник Харківського національного університету імені В. Н. Каразіна. Серія «Радіофізика та електроніка». 2025;43:34-44. <https://doi.org/10.26565/2311-0872-2025-43-03>

In cites: Plakhtii VA, Pryshchenko OA, Dumin OM, Akhmedov RD. Analysis of noise immunity of a neural network system for recognizing subsurface objects. Visnyk of V.N. Karazin Kharkiv National University. Series Radiophysics and Electronics. 2025;43:34-44. (In Ukrainian). <https://doi.org/10.26565/2311-0872-2025-43-03>

ВСТУП

Відновлення просторового профілю прихованих неоднорідностей усередині середовища є складною науково-технічною задачею. Вихідними даними для її розв'язання слугують розсіяні електромагнітні сигнали, що реєструються приймальними антенами. Для їх аналізу застосовується широкий спектр підходів, зокрема методи міграції [1–3], мікрохвильова томографія [4–6], перетворення Хафа [7], вейвлет-аналіз [8–9], штучні нейронні мережі [10–12] та інші методи.

Функціонування кожного з наведених підходів вимагає попередньої обробки первинних даних георадарного зондування. Така обробка може включати усунення відбиттів від вимірювального обладнання та межі поділу двох середовищ [13], а також зменшення впливу низького співвідношення сигнал/шум на вхідні дані [9].

Окрему групу задач становить класифікація об'єктів на основі отриманих радіолокаційних зображень (радарограм). Для цього використовуються, зокрема, методи взаємної кореляції [14] та штучні нейронні мережі [10–12]. Ключовою передумовою застосування цих методів є наявність репрезентативної бази даних, що містить приклади сигналів, отриманих від різних об'єктів за різних умов. У разі кореляційного підходу здійснюється безпосереднє порівняння вимірених сигналів з еталонними зразками з бази даних. Натомість нейронні мережі проходять етап навчання, у процесі якого інформація про об'єкти кодується у вагових коефіцієнтах між нейронами. Вважається, що підходи, засновані на штучному інтелекті, мають вищу здатність до узагальнення порівняно з кореляційними методами, що робить такі системи більш адаптивними до змінних умов експлуатації [14–16].

Протягом останніх десятиліть методи штучного інтелекту набули широкого застосування у задачах підповерхневого зондування. Водночас ключовою проблемою залишається формування навчальної вибірки, яка б забезпечувала високу ефективність системи розпізнавання. У зв'язку з цим доцільним є поєднання нейронних мереж з іншими методами, що дозволяють зменшити розмірність вхідних даних із урахуванням фізичних закономірностей поширення електромагнітних хвиль. Як і в попередній роботі авторів [6], на початковому етапі було застосовано метод дискретної томографії, що дало змогу суттєво скоротити обсяг вхідної інформації, яка надалі використовувалася для навчання нейронної мережі.

Крім наведених підходів, для підвищення стійкості нейронної мережі до завад застосовується метод додавання шуму до вхідних даних. Актуальність такого підходу зумовлена значним рівнем зовнішніх перешкод: як показано в роботі [6], відбиття від сторонніх об'єктів та випромінювання базових станцій мобільного зв'язку за рівнем потужності істотно перевищують корисний сигнал, розсіяний цільовим об'єктом. Метод штучного зашумлення, який полягає у додаванні гаусівського шуму до навчальних даних, фактично адаптує нейронну мережу до роботи в умовах зашумлених вимірювань, аналогічно підходу, представленому в [18].

Основною метою даної роботи є дослідження та оптимізація параметрів системи виявлення підповерхневих об'єктів в умовах інтенсивних завад. У межах дослідження аналізується ефективність різних конфігурацій системи з урахуванням кількості датчиків електромагнітного поля, типу вхідних даних, параметрів часових вікон, методів аугментації даних та способів кодування цільових класів. Завданням є визначення оптимального поєднання зазначених параметрів, яке забезпечує максимальну завадостійкість та точність роботи системи. Для цього використовується алгоритм повного перебору параметрів (grid search), що дозволяє систематично оцінити та порівняти різні варіанти конфігурацій за критеріями шумової стійкості та точності виявлення. Отримані результати спрямовані на підвищення надійності та достовірності систем підповерхневого радіолокаційного зондування в реальних зашумлених умовах.

ПОСТАНОВКА ЗАДАЧІ

У роботі розглядається задача пошуку металевої труби, розташованої на певній глибині в ґрунті, шляхом опромінення середовища плоскою імпульсною електромагнітною хвилею. Детальний опис постановки задачі, геометрії досліджуваної структури, параметрів ґрунту та характеристик збуджувального імпульсу наведено в роботі [6]. Відбита від підповерхневого об'єкта хвиля реєструється за допомогою набору датчиків електромагнітного поля, розміщених під поверхнею землі. Після дискретизації часові залежності електричних компонент прийнятого сигналу використовуються як вхідні дані для подальшого аналізу [6].

Ефективність запропонованого підходу в [6] досліджувалася з урахуванням кількості датчиків поля та типу вхідних даних, що подаються на нейронну мережу. Кількість датчиків становила 15, 29 або 57. Щодо формату вхідних даних, розглядалися три варіанти: 1) використання лише часових залежностей прийнятого сигналу, 2) використання лише даних дискретної томографії, 3) поєднання (конкатенація) обох типів даних. Таким чином, було проаналізовано всі можливі комбінації параметрів, що відповідають дев'яти конфігураціям набору даних для навчання нейронної мережі.

Окрім цього, було досліджено три варіанти вибору часових вікон та їх вплив на результати розпізнавання. З урахуванням того, що загальна кількість нових конфігурацій системи в такому випадку

становить $8 \times 3 = 24$, візуальне порівняння результатів, застосоване в [6], стає недоцільним. У зв'язку з цим у даній роботі для кількісної оцінки якості алгоритму використовуються стандартні метрики машинного навчання, зокрема F1-міра та матриця помилок (confusion matrix). Такий підхід дозволяє уніфікувати оцінювання результатів та зробити аналіз більш обґрунтованим у порівнянні з [6].

Ще одним обмеженням попередніх досліджень є оцінювання завадостійкості системи лише для граничних випадків. З точки зору теорії машинного навчання такий підхід є некоректним, оскільки тестова вибірка має відповідати за своєю природою навчальним даним. Наприклад, у класичній задачі бінарної класифікації зображень котів і собак [19] тестова вибірка також повинна містити зображення котів і собак, але інші реалізації. У нашому випадку для первинного аналізу завадостійкості доцільно використовувати ті самі класи глибин, що були задіяні під час навчання, а тестові зразки формувати шляхом накладання шуму на ці дані. Натомість у роботах [6], [22] розглядалися граничні випадки, які не належать жодному з навчальних класів. Такі сценарії є корисними для дослідження апроксимаційних властивостей штучних нейронних мереж, однак вони не є репрезентативними для оцінювання завадостійкості. Тому аналіз впливу шуму доцільно виконувати окремо, використовуючи дані, що безпосередньо відповідають навчальним класам. Саме такий підхід забезпечує більш надійну оцінку завадостійкості системи. Відповідно, у даній роботі аналіз впливу шуму проводиться на даних, які природним чином належать до навчальних класів, визначених на початку цього розділу.

Слід також зазначити, що в роботі [2] навчальна вибірка містила лише один приклад для кожного класу, що не відповідає стандартним підходам у машинному навчанні. Класичні методи навчання передбачають наявність кількох прикладів для кожного класу з метою покращення узагальнювальних властивостей моделі. У розглянутій задачі отримання додаткових навчальних даних є ускладненим через відносно просту фізичну модель. Хоча можливе її ускладнення, наприклад шляхом введення випадкового розподілу неоднорідностей у ґрунті [20], [21], такий підхід потребує значних обчислювальних ресурсів. Тому для розширення навчальної вибірки в даній роботі використано метод аугментації даних шляхом додавання випадкового шуму до наявних часових залежностей, як це було запропоновано в [6]. Це дозволяє сформувати більшу кількість прикладів для кожного з 12 класів глибин, а також наблизити умови навчання до реальних експериментальних умов, у яких шум завжди присутній.

Аугментація навчальної вибірки в даній роботі здійснювалася за таким алгоритмом:

- формується мініпакет з 12 часових залежностей, що відповідають різним глибинам залягання об'єкта (у роботі [6] такий мініпакет відповідав одному епохальному кроку навчання);
- до кожної часової залежності окремо додається шум із відношенням сигнал/шум у діапазоні від 15 до 30 дБ, яке випадковим чином обирається для кожного сигналу, але з фіксованим початковим значенням генератора випадкових чисел для відтворюваності розподілу шуму між епохами.

У результаті формується навчальний набір із 36 зашумлених сигналів, який не містить оригінальних (незашумлених) часових залежностей. Очікується, що така аугментація сприятиме підвищенню завадостійкості розробленої системи.

Ще одним важливим параметром, що впливає на ефективність системи розпізнавання, є формат кодування цільових (вихідних) значень штучної нейронної мережі. У задачах класифікації зазвичай використовується one-hot кодування, за якого формується вектор довжиною, що дорівнює кількості класів, з одиницею на позиції відповідного класу та нулями на інших позиціях. Проте в попередніх роботах [6], [22] було запропоновано модифікований варіант цільового вектора для випадків відсутності об'єкта під поверхнею ґрунту. У цьому випадку формується вектор тієї ж довжини, заповнений нулями, включно з позицією цільового класу. Такий підхід обґрунтовувався фізичною інтерпретацією задачі: за відсутності об'єкта очікується нульовий відгук на виході мережі. Водночас слід зазначити, що подібне кодування не є стандартним у машинному навчанні, і в класичних підходах використовується звичайне one-hot кодування. Вплив цього параметра не досліджувався в попередніх роботах, тоді як у даній статті наведено результати аналізу продуктивності системи з урахуванням різних форматів кодування цільових значень.

З урахуванням усіх розглянутих параметрів, що можуть впливати на якість розпізнавання, у Таблиці 1 наведено різні конфігурації системи, досліджені в межах даної роботи. В першому стовпці таблиці вказано тип вхідних даних для штучної нейронної мережі (ШНМ) [6]:

S — використання часових залежностей прийнятого сигналу з датчиків поля;

DT — використання даних дискретної томографії, обчислених на основі часових залежностей;

S+DT — конкатенація часових сигналів та томографічних даних.

Другий стовпець Таблиці 1 відповідає кількості датчиків електромагнітного поля, розміщених над поверхнею ґрунту та використаних для імітації процесу георадарного сканування [6]. У попередніх дослідженнях розглядалися конфігурації з 15, 29 та 57 датчиками. Зазначені варіанти відповідають відстаням між сусідніми датчиками 100, 50 та 25 мм відповідно.

Таблиця 1 Моделювання параметрів задачі

Тип вхідних даних для ШНМ	Кількість датчиків електромагнітного поля	Тип часового вікна	Навчання з аугментацією вибірки	Формат кодування цільових значень ШНМ
S	15	L	True	01
S+TD	29	M	False	11
TD	57	R	-	-

Третій стовпець характеризує параметри часового вікна, яке застосовується до початкової часової залежності прийнятого сигналу. По суті, ця операція відповідає усіченню вихідного сигналу в часовій області. У даній роботі розглядаються три варіанти:

L — ранній початок часового вікна, що відповідає зсуву вліво відносно базового вікна, як це було реалізовано в [6];

M — центральне (базове) часове вікно, ідентичне до того, що використовувалося в [6];

R — пізній початок часового вікна, що моделює зсув вправо відносно початкового вікна, обраного в [6].

Четвертий стовпець визначає використання аугментації даних. Значення True означає, що до початкового набору часових залежностей застосовується описана вище процедура додавання шуму. Значення False відповідає випадку, коли аугментація даних не використовується, і навчання виконується на вихідних сигналах без модифікацій.

П'ятий стовпець описує формат кодування цільових значень штучної нейронної мережі. Позначення 01 відповідає модифікованому підходу, за якого значення цільового класу, що відповідає відсутності металеві труби, занулюється. Позначення 11 відповідає класичному one-hot кодуванню, що широко використовується в задачах багатокласової класифікації.

Таким чином, загальна кількість конфігурацій, які необхідно проаналізувати для визначення найбільш ефективного набору параметрів системи дистанційного зондування, становить $3 \times 3 \times 3 \times 2 \times 2 = 108$.

Слід зазначити, що до цього переліку включено також конфігурації, розглянуті в попередніх роботах [6], що дозволяє отримати більш повну порівняльну картину з використанням формалізованих метрик та уточнити висновки, зроблені раніше на основі візуального аналізу.

Оцінювання зазначених конфігурацій здійснюється шляхом застосування алгоритму повного перебору параметрів (grid search) у просторі, визначеному в Таблиці 1. Кожна комбінація параметрів фактично формує окрему постановку задачі, для якої необхідно оцінити завадостійкість та якість роботи системи. Алгоритм проведення такого оцінювання докладно описано в наступному розділі.

АЛГОРИТМ ПОШУКУ ПО СІТЦІ

Пошук оптимальних параметрів запропонованого підходу здійснюється за допомогою алгоритму повного перебору (grid search) і складається з п'яти основних етапів (Рис. 1).

Етап 1.

На першому етапі послідовно обирається одна з 108 конфігурацій параметрів, сформованих на основі Таблиці 1. Обрана конфігурація надалі використовується на етапах 2–5 алгоритму.

Етап 2. Формування набору даних.

Оскільки майже кожна з 108 конфігурацій передбачає власний принцип формування набору даних, на цьому етапі здійснюється побудова відповідної навчальної та тестової вибірок. Процес складається з чотирьох підетапів.

2.1) На першому підетапі завантажуються часові залежності сигналів, отриманих із датчиків електромагнітного поля. Для кожної конфігурації використовується 11 сигналів, що відповідають різним класам глибини залягання прихованого об'єкта, а також один додатковий випадок, що описує відсутність об'єкта під поверхнею ґрунту. На цьому етапі набори даних для різних конфігурацій уже відрізняються між собою, оскільки використовуються різні кількості датчиків (15, 29 або 57), що відповідає відстаням між ними 100, 50 або 25 мм відповідно. Це, у свою чергу, визначає кількість сигналів, які використовуються для формування одного зразка даних на завершальному підетапі.

2.2) Другий підетап пов'язаний із застосуванням аугментації даних. Якщо відповідний параметр конфігурації має значення True, до часових залежностей додається випадковий шум згідно з процедурою,

описаною в попередньому розділі. Якщо параметр має значення False, аугментація не виконується, і використовуються лише вихідні сигнали без модифікацій.

2.3) Третій підетап є обов'язковим і виконується для всіх конфігурацій незалежно від інших параметрів. Він полягає в інтерполяції часових залежностей. Початкові сигнали, отримані з датчиків, мають незначні відмінності у часових точках дискретизації на наносекундному масштабі. Інтерполяція дозволяє уніфікувати часову сітку для всіх сигналів із заданим кроком, що забезпечує вибір однакових часових відліків для всіх залежностей. Після цього з інтерпольованих сигналів вирізається необхідне часове вікно, яке визначається одним із трьох варіантів (L, M або R), заданих у поточній конфігурації з Таблиці I. Таким чином, на цьому підетапі виконуються інтерполяція та вибір часового вікна.

2.4) На четвертому підетапі отримані часові залежності перетворюються у одновимірні вектори, які безпосередньо подаються на вхід штучної нейронної мережі. Далі, за умови, що це передбачено конфігурацією grid search, до сформованого вектора застосовується множення на матрицю томографічної складової з метою отримання додаткових ознак. Детальніше цей процес описано в [1]. Рішення про використання або пропуск етапу формування томографічних даних визначається параметрами поточної конфігурації. Після цього формуються цільові значення для кожного зразка даних відповідно до обраного способу кодування класів: класичного one-hot або модифікованого варіанта для класу відсутності об'єкта, як було описано раніше. У результаті формується повноцінний набір даних, який використовується для навчання нейронної мережі.



Рис. 1. Робочий процес дослідження простору параметрів, спрямований на визначення конфігурації з максимальною завадостійкістю

Fig. 1. Parameter space exploration workflow aimed at identifying the configuration with maximum robustness to noise

Етап 3. Навчання нейронної мережі.

Розмірність вхідного вектора визначає кількість нейронів у вхідному шарі штучної нейронної мережі. Це єдиний шар, розмірність якого змінюється залежно від конфігурації grid search. Архітектура решти мережі залишається сталою та має вигляд: input – 1000 – 200 – 100 – 12, де 12 відповідає кількості вихідних нейронів із функцією активації softmax, що забезпечує оцінювання ймовірності належності зразка до одного з 12 класів.

Слід зазначити, що процес компіляції нейронної мережі є однаковим для всіх конфігурацій: використовується оптимізатор Adam із параметрами за замовчуванням бібліотеки TensorFlow 2, а як функцію втрат застосовано категоріальну крос-ентропію. Навчання моделі здійснюється з використанням механізму зворотних викликів, зокрема алгоритму ранньої зупинки (Early Stopping), який активується у разі зростання значення функції втрат на валідаційній вибірці. При цьому зберігаються найкращі вагові коефіцієнти мережі. Навчання припиняється після спрацювання Early Stopping або досягнення значення функції втрат 0,001.

Етап 4. Тестування та оцінювання завадостійкості.

Після завершення навчання виконується тестування моделі, основною метою якого є кількісна оцінка завадостійкості з метою подальшого порівняння всіх конфігурацій. Тестування проводиться ітеративно. На початковому кроці формується пакет із 12 початкових сигналів відповідно до процедури, описаної на етапі 2. Для формування тестової вибірки кожен зразок зашумлюється 1000 разів гаусівським шумом.

Завдяки випадковому характеру шуму формується 1000 унікальних реалізацій для кожного рівня SNR. Оскільки використовується 12 початкових зразків, загальний обсяг тестової вибірки становить 12 000 сигналів.

Ітеративний характер тестування полягає у поступовому зменшенні відношення сигнал/шум. Початкове значення SNR обирається рівним 0 дБ, що було визначено експериментально, оскільки зазвичай нейронні мережі успішно розпізнають сигнали з нижчим рівнем зашумлення. Варто також зазначити, що значення 0 дБ є істотно меншим за максимальний рівень SNR, характерний для валідаційної вибірки, який зазвичай становить близько 15 дБ.

Для заданого рівня SNR формується відповідний тестовий набір даних, на якому нейронна мережа виконує прогнозування, після чого обчислюється F1-міра [23]. Якщо значення F1 перевищує 0,6, тестування продовжується для наступного рівня SNR, зменшеного на 1 дБ. Процедура повторюється до того моменту, поки значення F1 не стане меншим або рівним 0,6. Рівень SNR, за якого мережа перестає задовольняти вказаний критерій, вважається пороговим рівнем надійності для даної задачі та надалі позначається як Gate SNR. Результат вважається прийнятним, якщо F1-міра перевищує 0,6.

Етап 5. Агрегація результатів.

На завершальному етапі збирається отримане значення Gate SNR для поточної конфігурації grid search. Після цього алгоритм переходить до наступної конфігурації, і всі описані вище етапи повторюються доти, доки не будуть отримані порогові значення SNR для всіх 108 конфігурацій.

Слід зазначити, що для кожної конфігурації grid search та для кожного тестового рівня SNR набори даних формуються заново. Це зумовлено унікальністю кожної конфігурації. Для забезпечення коректного порівняння результатів усі навчальні та тестові набори даних генеруються з використанням фіксованого початкового значення генератора випадкових чисел, що гарантує однакові реалізації шуму для заданого рівня SNR незалежно від конфігурації.

Результати пошуку оптимальної (найбільш завадостійкої) конфігурації параметрів наведено в наступному розділі.

РЕЗУЛЬТАТИ ПОШУКУ МЕТОДОМ ПОВНОГО ПЕРЕБОРУ ПАРАМЕТРІВ

На Рис. 2 наведено результуючі значення порогового рівня завадостійкості (Gate SNR), отримані для всіх 108 конфігурацій параметрів, розглянутих у межах алгоритму grid search. По осі абсцис відкладено номер конфігурації, а по осі ординат — відповідне значення Gate SNR. Таким чином, результати представлені у вигляді множини з 108 дискретних точок (x,y)




Рис. 2. Розподіл значень Gate SNR для всіх оцінених конфігурацій grid search
Fig. 2. Distribution of Gate SNR values across all evaluated grid search configurations

Навіть без явного позначення п'яти параметрів, що формують кожну конфігурацію, у наведених результатах можна спостерігати певні закономірності. Зокрема, для окремих груп конфігурацій значення Gate SNR є низькими, для інших — вищими, а для деяких варіантів нейронна мережа взагалі не змогла коректно пройти етап навчання. Хоча на Рис. 2 відображено результати тестування, нульові значення Gate SNR були додатково перевірені за журналами процесу навчання. Встановлено, що у відповідних конфігураціях спостерігається недонавчання нейронної мережі: значення функції втрат зростає вже з першої епохи навчання, що унеможливує подальшу коректну роботу моделі.

Для наочного аналізу впливу окремих параметрів на отримані результати на Рис. 3–7 подано ті самі дані, що і на Рис. 2, збережено однакові осі координат, проте застосовано кольорове кодування, яке відображає значення конкретного параметра для кожної конфігурації.




Рис. 3. Значення Gate SNR, згруповані відповідно до застосованого варіанта часового вікна для кожної конфігурації grid search. Зелена група відповідає правому зсуву часового вікна, синя — стандартному часовому вікну, використаному в попередніх дослідженнях, червона — лівому зсуву часового вікна

Fig. 3. Gate SNR values categorized according to the applied time window selection for each grid search configuration. The green group corresponds to a right-shifted time window, the blue group represents the standard window used in previous studies, and the red group indicates a left-shifted time window

На Рис. 3 проілюстровано вплив вибору часового вікна. Конфігурації з лівим зсувом часового вікна позначено червоним кольором, із базовим (стандартним) часовим вікном, як у [1], — синім, а з правим зсувом — зеленим. Такий підхід до візуалізації дозволяє швидко виявити тенденції та оцінити, які параметри сприяють (або, навпаки, не сприяють) досягненню низьких значень Gate SNR. Крім того, це дає змогу безпосередньо виділити набір параметрів, що забезпечує мінімальний Gate SNR, тобто найвищу завадостійкість системи, що і є основною метою даного дослідження. З аналізу Рис. 3 випливає, що використання правого зсуву часового вікна забезпечує найкращі результати, далі за ефективністю йдуть стандартний та лівий варіанти. Таким чином, підтверджуються висновки, отримані в [2]: використання сигналу без початкової «хвостової» частини дозволяє досягти найвищої якості розпізнавання незалежно від інших чотирьох параметрів конфігурації, представлених на Рис. 4–7.




Рис. 4. Значення Gate SNR, згруповані за кількістю датчиків електромагнітного поля, використаних у кожній конфігурації grid search. Червона група відповідає конфігураціям з 15 датчиками, синя — з 29 датчиками, зелена — з 57 датчиками

Fig. 4. Gate SNR values grouped by the number of electromagnetic field sensors employed in each grid search configuration. The red group represents configurations with 15 sensors, the blue group corresponds to 29 sensors, and the green group indicates configurations using 57 sensors

На Рис. 4 наведено порівняння конфігурацій з різним кроком розташування датчиків електромагнітного поля, що еквівалентно кроку сканування моделі ґрунту в розглянутій постановці задачі. Видно, що варіанти з кроками 100 мм та 50 мм демонструють загалом подібні результати, однак конфігурації з кроком 100 мм у середньому забезпечують нижчі значення Gate SNR. Для випадку з кроком 25 мм спостерігається значна кількість конфігурацій, у яких нейронні мережі не змогли коректно навчитися та показують низьку стійкість до зашумлення. Причиною цього є надмірно велика розмірність вхідного шару (28 500 нейронів, що відповідає 57 сигналам, кожен із яких містить 500 дискретних часових відліків) за відносно компактною структурою мережі типу 28 000–1000–500–200–12. Така архітектура є неефективною як з точки зору обчислювальних витрат, так і з огляду на схильність до недонавчання або перенавчання. Для випадку з кроком 25 мм доцільно застосовувати інші архітектури, наприклад із використанням одномірних згорткових шарів. Проте в такому разі втрачається можливість коректного порівняння з іншими конфігураціями через порушення єдності архітектури мережі, яка в даному дослідженні обмежується лише повнозв'язними шарами без використання згорткових або рекурентних структур. Таким чином, випадок з кроком 25 мм потребує окремого подальшого дослідження та підбору оптимальної архітектури нейронної мережі. Загалом, на основі результатів, наведених на Рис. 4, можна зробити висновок, що для даної задачі найбільш доцільним є використання кроку 100 мм між датчиками.




Рис. 5. Значення Gate SNR, класифіковані відповідно до типу вхідних даних, що подаються на штучну нейронну мережу для кожної конфігурації grid search. Червона група відповідає часовим залежностям прийнятого сигналу, зелена — томографічним даним, синя — поєднанню часових залежностей прийнятого сигналу та томографічних даних.

Fig. 5. Gate SNR values classified according to the type of input data supplied to the artificial neural network for each grid search configuration. The red group corresponds to received time-domain signals, the green group represents tomography-based data, and the blue group indicates the combined use of time-domain signals and tomography data.

На Рис. 5 представлено порівняння конфігурацій із різними типами вхідних даних. Чіткої залежності між типом вхідної інформації та значеннями Gate SNR не спостерігається, однак можна відзначити, що використання конкатенації часових залежностей та томографічних даних у середньому дає дещо гірші результати порівняно з використанням лише одного з цих типів даних. Це пояснюється тим, що проста конкатенація двох векторів не є оптимальним способом об'єднання ознак, і в такому випадку доцільно застосовувати додаткові методи формування ознак або змінювати архітектуру нейронної мережі, аналогічно до ситуації, описаної для Рис. 4.




Рис. 6. Значення Gate SNR, розрізнені за застосуванням аугментації даних на основі додавання гаусівського шуму для конфігурацій grid search. Червона група відповідає випадкам із застосуванням аугментації даних, синя — випадкам без застосування аугментації.

Fig. 6. Gate SNR values differentiated by the application of Gaussian noise-based data augmentation across the grid search configurations. The red group denotes configurations with data augmentation enabled, while the blue group corresponds to configurations without data augmentation.

Результати, наведені на Рис. 3–5, відображають вплив параметрів, які визначають виключно процес формування набору даних. Натомість на Рис. 6–7 представлено результати для параметрів, що безпосередньо впливають на процес навчання нейронної мережі.

На Рис. 6 показано порівняння значень Gate SNR для конфігурацій із використанням аугментації даних шляхом додавання шуму (червоний колір) та без її застосування (синій колір). Загалом найнижчі значення Gate SNR відповідають конфігураціям із використанням аугментації. Крім того, у верхній правій частині графіка видно конфігурації, для яких нейронна мережа не змогла коректно навчитися. Всі ці випадки належать до конфігурацій без аугментації даних. Серед конфігурацій із додаванням шуму відсутні випадки повного провалу навчання. Починаючи приблизно з 72-ї конфігурації, спостерігається суттєвий дисбаланс між розмірністю вхідного шару та наступних шарів мережі, що ускладнює процес навчання. Проте навіть за таких умов використання аугментації повністю виправдало себе, оскільки всі відповідні мережі змогли пройти етап навчання. У середньому конфігурації з аугментацією демонструють стабільні результати в діапазоні Gate SNR від -10 до -15 дБ.




Рис. 7. Значення Gate SNR, згруповані відповідно до стратегії кодування цільових значень, застосованої у штучній нейронній мережі для кожної конфігурації grid search. Червона група відповідає модифікованому one-hot кодуванню з нульовим кодуванням класу відсутності об'єкта, синя — стандартному one-hot кодуванню

Fig. 7. Gate SNR values grouped according to the target encoding strategy applied in the artificial neural network for each grid search configuration. The red group represents a modified one-hot encoding with the absence-of-object class encoded as zero, while the blue group corresponds to the standard one-hot encoding scheme

На Рис. 7 наведено порівняння конфігурацій із різними способами кодування цільових значень нейронної мережі. Синім кольором позначено стандартне one-hot кодування, тоді як червоним — модифікований варіант, у якому відсутність об'єкта під поверхнею ґрунту кодується нульовим значенням замість одиниці. Такий підхід, на думку авторів, краще узгоджується з фізичним змістом задачі розпізнавання прихованих об'єктів. З наведених результатів видно, що спосіб кодування цільових значень суттєво впливає на ефективність системи: спостерігається стійка тенденція до зменшення Gate SNR при використанні нульового кодування класу відсутності об'єкта порівняно зі стандартним one-hot підходом. Саме цей параметр виявився найбільш значущим чинником, що визначає успішність конфігурації grid search у задачі дистанційного підповерхневого зондування.

ВИСНОВОК

Проведення алгоритму grid search для дослідження параметрів моделювання дало змогу визначити оптимальні конфігурації системи, які забезпечують ефективне виявлення підповерхневих об'єктів в умовах зашумлених даних. Отримані результати показали, що правильний вибір часового вікна є одним із ключових факторів успішної роботи розробленого алгоритму. Також було продемонстровано, що використання різних типів вхідних даних вимагає застосування більш складних архітектур штучних нейронних мереж та відповідних методів попередньої підготовки даних.

Показано, що розширення навчальної вибірки шляхом тренування на зашумлених зразках сприяє підвищенню здатності нейронної мережі до узагальнення в межах розглянутої задачі. Окрім цього, спосіб кодування цільових значень нейронної мережі для випадку відсутності об'єкта виявився найбільш впливовим параметром системи: відповідне кодування дозволило досягти суттєво нижчих порогових значень Gate SNR порівняно з іншими параметрами задачі.

КОНФЛІКТ ІНТЕРЕСІВ

Автори повідомляють про відсутність конфлікту інтересів.

REFERENCES

1. Gazdag J, Sguazzero P. Migration of seismic data. Proc IEEE. 1984;72(10):1302–1315. doi:[10.1109/PROC.1984.13044](https://doi.org/10.1109/PROC.1984.13044).
2. Smitha N, Bharadwaj DRU, Abilash S, Sridhara SN, Singh V. Kirchhoff and F-K migration to focus ground penetrating radar images. Geo-Engineering. 2016;7:4. doi:[10.1186/s40703-016-0019-6](https://doi.org/10.1186/s40703-016-0019-6).
3. Plakhtii V, Dumin O, Pryshchenko O. Kirchhoff migration method for tube detection with UWB GPR. In: Proc. 2021 IEEE Int. Conf. on Direct and Inverse Problems of Electromagnetic and Acoustic Wave Theory (DIPED); 2021 Sep. p. 1–5. doi:[10.1109/DIPED53165.2021.9552330](https://doi.org/10.1109/DIPED53165.2021.9552330).
4. Alani AM, et al. The use of ground penetrating radar and microwave tomography for the detection of decay and cavities in tree trunks. Remote Sens. 2019;11(18):2073. doi:[10.3390/rs11182073](https://doi.org/10.3390/rs11182073).
5. Chen Y, Witten AJ. Pseudoinverse imaging for multimono-static ground-penetrating radar data. Proc SPIE. 2001. doi:[10.1117/12.445458](https://doi.org/10.1117/12.445458).
6. Pryshchenko O, Dumin O, Plakhtii V. Discrete tomography approach for subsurface object detection by artificial neural network. In: Proc. 2022 IEEE Ukrainian Microwave Week (UkrMW); 2022 Nov. p. 1–4. doi:[10.1109/UKRMW58013.2022.10037072](https://doi.org/10.1109/UKRMW58013.2022.10037072).

7. Windsor CG, Capineri L, Falorni P. A data pair-labeled generalized Hough transform for radar location of buried objects. *IEEE Geosci Remote Sens Lett.* 2014;11(1):124–127. doi:[10.1109/LGRS.2013.2248119](https://doi.org/10.1109/LGRS.2013.2248119).
8. Varyanitzha-Roshchupkina LA, Pochanin G. Wavelet analysis of signals in short-range radiolocation problems. In: *Proc. 2013 Int. Conf. on Antenna Theory and Techniques (ICATT)*; 2013 Sep. p. 1–4. doi:[10.1109/ICATT.2013.6650794](https://doi.org/10.1109/ICATT.2013.6650794).
9. Plakhtii V, Dumin O, Pryshchenko O, Shyrokorad D, Pochanin G. Influence of noise reduction on object location classification by artificial neural networks for UWB subsurface radiolocation. In: *Proc. 2019 IEEE Int. Seminar on Direct and Inverse Problems of Electromagnetic and Acoustic Wave Theory (DIPED)*; 2019 Sep. p. 1–4. doi:[10.1109/DIPED.2019.8882590](https://doi.org/10.1109/DIPED.2019.8882590).
10. Wang S, Han L, Gong X, Zhang S, Huang X, Zhang P. MCMC method of inverse problems using a neural network: application in GPR crosshole full waveform inversion. *Remote Sens.* 2022;14(6):1320. doi:[10.3390/rs14061320](https://doi.org/10.3390/rs14061320).
11. Persanov I, Dumin O, Plakhtii V, Shyrokorad D. Subsurface object recognition in soil using UWB irradiation by butterfly antenna. In: *Proc. 2019 IEEE DIPED*; 2019. p. 160–163. doi:[10.1109/DIPED.2019.8882577](https://doi.org/10.1109/DIPED.2019.8882577).
12. Pryshchenko OA, et al. Implementation of an artificial intelligence approach to GPR systems for landmine detection. *Remote Sens.* 2022;14(17):4421. doi:[10.3390/rs14174421](https://doi.org/10.3390/rs14174421).
13. Capineri L, Falorni P, Borgioli G, Bossi L, Pochanin G, Ruban V, et al. Background removal for processing scans acquired with the “UGO-1st” landmine detection platform. In: *Proc. 2019 Photonics & Electromagnetics Research Symposium—Spring (PIERS)*; Rome, Italy; 2019 Jun. p. 3965–3973.
14. Dumin O, Plakhtii V, Pryshchenko O, Pochanin G. Comparison of ANN and cross-correlation approaches for ultra-short pulse subsurface survey. In: *Proc. 2020 IEEE TCSET*; 2020. p. 1–6. doi:[10.1109/TCSET49122.2020.235459](https://doi.org/10.1109/TCSET49122.2020.235459).
15. Feng K, Zhao Y, Wu J, Ge S. Cross-correlation attribute analysis of GPR data for tunnel engineering. In: *Proc. 2014 Int. Conf. on Ground Penetrating Radar (ICGPR)*; 2014 Jun. p. 1–4. doi:[10.1109/ICGPR.2014.6970461](https://doi.org/10.1109/ICGPR.2014.6970461).
16. Feng K, Zhao Y, Wu J, Ge S. Cross-correlation attribute analysis of GPR data for tunnel engineering. In: *Proc. 2014 Int. Conf. on Ground Penetrating Radar (ICGPR)*; 2014 Jun. p. 1–4. doi:[10.1109/ICGPR.2014.6970461](https://doi.org/10.1109/ICGPR.2014.6970461).
17. Mint Mohamed Mostapha A, Faize A, Alsharahi G, Louzazni M, Driouach A. Effect of external noise on ground penetrating radar ability to detect objects. *Int J Microw Opt Technol.* 2019;14:124–131.
18. Agapiou A, Sarris A. Working with Gaussian random noise for multi-sensor archaeological prospection: fusion of GPR depth slices and ground spectral signatures. *Remote Sens.* 2019;11(16):1895. doi:[10.3390/rs11161895](https://doi.org/10.3390/rs11161895).
19. Lee Y. Image classification with artificial intelligence: cats vs dogs. *IEEE Xplore*; 2021 Jan 1. doi:[10.1109/CDS52072.2021.00081](https://doi.org/10.1109/CDS52072.2021.00081)
20. Pryshchenko O, Dumin O, Plakhtii V, Pochanin G. Subsurface object detection in randomly inhomogeneous medium model. In: *Proc. 2021 IEEE UKRCON*; 2021 Aug. p. 1–4. doi:[10.1109/UKRCON53503.2021.9575688](https://doi.org/10.1109/UKRCON53503.2021.9575688).
21. Pryshchenko O, Dumin O, Plakhtii V, Pochanin G. Classification of objects buried in inhomogeneous medium by artificial neural network using impulse GPR with 1Tx + 4Rx antenna system. In: *Proc. 2021 Int. Workshop on Advanced Ground Penetrating Radar (IWAGPR)*; 2021 Dec. p. 1–4. doi:[10.1109/IWAGPR50767.2021.9843169](https://doi.org/10.1109/IWAGPR50767.2021.9843169).
22. Dumin O, Plakhtii V, Shyrokorad D, Pryshchenko O, Pochanin G. UWB subsurface radiolocation for object location classification by artificial neural networks based on discrete tomography approach. In: *Proc. 2019 IEEE UKRCON*; 2019 Jul. p. 1–4. doi:[10.1109/UKRCON.2019.8879827](https://doi.org/10.1109/UKRCON.2019.8879827).
23. Avola D, et al. A shape comparison reinforcement method based on feature extractors and F1-score. *IEEE Access.* 2019;7:1–10. doi:[10.1109/SMC.2019.8914601](https://doi.org/10.1109/SMC.2019.8914601).

Стаття надійшла до редакції: 16 вересня 2025

Рекомендовано до друку: 28 жовтня 2025

Опубліковано: 30 грудня 2025

ANALYSIS OF NOISE IMMUNITY OF A NEURAL NETWORK SYSTEM FOR RECOGNIZING SUBSURFACE OBJECTS

V.A. Plakhtii, O.A. Pryshchenko, O.M. Dumin, R.D. Akhmedov

V. N. Karazin Kharkiv National University, 4 Svobody sq., Kharkiv, 61022, Ukraine

Background: Subsurface sensing systems based on impulse electromagnetic waves are widely used for detecting hidden objects in soil. However, the performance of such systems significantly degrades in the presence of strong interference caused by external reflections and radio-frequency sources. The task of automated object recognition from ground-penetrating radar (GPR) signals using artificial neural networks (ANNs) is particularly challenging, since the noise robustness of such systems strongly depends on the selection of modeling parameters, input data formation, and training procedures.

Objective: To investigate and optimize the parameters of an ANN-based subsurface object detection system in order to improve its noise robustness by applying a parameter grid search algorithm.

Materials and Methods: A subsurface medium containing a hidden metallic object was irradiated with a plane impulse electromagnetic wave. The electrodynamic problem of wave propagation and scattering was solved numerically using the finite-difference time-domain (FDTD) method, taking into account the interaction between the electromagnetic field, soil, and the object. The input data for the neural network were formed from the time-domain responses of the received signals, as well as from additional information obtained using a discrete tomography approach and ray tracing. A grid search was employed to identify the optimal system configuration by analyzing the influence of input data type, number of field sensors, time window parameters, data augmentation techniques, and target encoding strategies. Noise robustness was evaluated using the F1-score and the threshold Gate SNR metric.

Results: The grid search analysis identified system configurations that provide the highest noise robustness for object recognition. It was shown that the selection of the time window is a critical factor significantly affecting the Gate SNR values. Training the neural network on noisy data was found to enhance its generalization capability and improve stability under noisy conditions. Furthermore, the encoding strategy for the absence-of-object class was demonstrated to have the strongest impact on system performance, enabling lower Gate SNR thresholds compared to other investigated parameters.

Conclusions: The application of the grid search algorithm enabled systematic optimization of the parameters of an ANN-based subsurface object recognition system. The obtained results confirm the effectiveness of combining physically motivated signal processing methods with machine learning techniques to improve the noise robustness of ground-penetrating radar systems. The proposed approach can serve as a basis for further development of automated GPR data analysis methods under real experimental conditions.

KEY WORDS: *subsurface object, impulse electromagnetic wave, ground-penetrating radar, artificial neural network, noise robustness, grid search, discrete tomography.*

The article was received by the editors: September 16 2025

The article is recommended for printing: October 28 2025

Published: December 30 2025