

Міністерство освіти і науки України
Харківський національний університет радіоелектроніки

Факультет _____ кібербезпеки _____
(повна назва)

Кафедра _____ інформаційно-мережної інженерії _____
(повна назва)

КВАЛІФІКАЦІЙНА РОБОТА
Пояснювальна записка

рівень вищої освіти _____ другий (магістерський) _____

Дослідження методів підвищення завадозахищеності сигналів у
бездротових мережах

(тема)

Виконав:

здобувач 2 року навчання,
групи ІМІМ-24-2

Антон ЧЕМІСОВ
(власне ім'я, прізвище)

Спеціальність 172 Електронні комунікації
та радіотехніка
(код і повна назва спеціальності)

Тип програми освітньо-наукова
(освітньо-професійна або освітньо-наукова)

Освітня програма Інформаційно-мережна
інженерія
(повна назва освітньої програми)

Керівник проф. Микола МОСКАЛЕЦЬ
(посада, власне ім'я, прізвище)

Допускається до захисту

Зав. кафедри _____ Микола МОСКАЛЕЦЬ _____
(підпис) (власне ім'я, прізвище)

2026 р.

Не містить відомостей заборонених до відкритого публікування

Студент _____ / Чемісов А.Ф./

Керівник _____ / Москалець М.В./

Харківський національний університет радіоелектроніки

Факультет _____ кібербезпеки _____
Кафедра _____ інформаційно-мережної інженерії _____
Рівень вищої освіти _____ другий (магістерський) _____
Спеціальність _____ 172 Електронні комунікації та радіотехніка _____
Тип програми _____ освітньо-наукова _____
(код і повна назва)
Освітня програма _____ інформаційно-мережна інженерія _____
(повна назва)

ЗАТВЕРДЖУЮ:

Зав. кафедри _____

(підпис)

« _____ » _____ 20 ____ р.

ЗАВДАННЯ
НА КВАЛІФІКАЦІЙНУ РОБОТУ

здобувачеві _____ *Чемісову Антону Фардатовичу* _____
(прізвище, ім'я, по батькові)

1. Тема роботи _____ Дослідження методів підвищення завадозахищеності сигналів у
бездротових мережах _____

затверджена наказом університету від 23 березня 2026р. №232 Ст

2. Термін подання студентом роботи до екзаменаційної комісії 20 травня 2026 р.

3. Вихідні дані до роботи _____

Провести аналіз актуальних досягнень у сфері придушення інтерференції засобами
глибокого навчання. Дослідити методи, що дозволяють ідентифікувати та нівелювати
характеристики перешкод безпосередньо на основі даних, уникаючи залежності від
традиційних експертних систем. Здійснити ґрунтовний огляд провідних алгоритмів,
наявних у науковій літературі, провести їх порівняльний аналіз, а також сформулювати
практичні рекомендації щодо впровадження цих рішень у сучасні телекомунікаційні
мережі.

4. Перелік питань, що потрібно опрацювати в роботі _____
Вступ _____

1. Дослідження проблеми появи завад та їх боротьби у бездротових мережах

2. Технічні придушення перешкод на основі глибокого навчання

3. Порівняльний аналіз досліджених методів глибокого навчання

4. Переваги та недоліки схем придушення перешкод на основі глибокого навчання

Висновки _____

5. Перелік графічного матеріалу із зазначенням креслеників, схем, плакатів, комп'ютерних ілюстрацій (п.5 включається до завдання за рішенням випускової кафедри) _____

Слайди у форматі Power Point (назва та мета та актуальність роботи, розвиток 5G та 6G, фізичні та алгоритмічні методи уникнення перешкод, загальна структура придушення перешкод на основі ML з ACI та CCI, методи придушення перешкод, основи глибокого навчання, згорткові нейронні мережі, автоенкодери, загальнодоступний набір даних про перешкоди експериментальні дослідження, висновки)

КАЛЕНДАРНИЙ ПЛАН

№	Назва етапів роботи	Терміни виконання етапів роботи	Примітка
1	Ознайомлення із завданням. Уточнення ТЗ.	23.03.2026	вик.
2	Підбір літератури за темою роботи	24.03 - 10.04.2026	вик.
3	Дослідження проблеми появи завад та їх боротьби у бездротових мережах	11.04 - 20.04.2026	вик.
4	Технічні придушення перешкод на основі глибокого навчання	21.04 - 25.04.2026	вик.
5	Порівняльний аналіз досліджених методів глибокого навчання	26.04 - 12.05.2026	вик.
6	Переваги та недоліки схем придушення перешкод на основі глибокого навчання	13.04 - 18.05.2026	вик.
7	Оформлення презентаційного матеріалу, підготовка до захисту у ЕК	19.05 - 20.05.2026	вик.

Дата видачі завдання 23 березня 2026 р.

Здобувач _____
(підпис)

Керівник роботи _____
(підпис)

проф. Микола МОСКАЛЕЦЬ
(посада, власне ім'я, прізвище)

)

РЕФЕРАТ

Пояснювальна записка: 84 с., 12 рис., 5 табл., 2 додатки, 65 джерел.

Об'єкт дослідження – бездротові мережі.

Мета роботи – підвищення завадозахищеності сигналів у бездротових мережах.

У межах кваліфікаційної роботи проведено аналіз актуальних досягнень у сфері придушення інтерференції засобами глибокого навчання. Досліджено методи, що дозволяють ідентифікувати та нівелювати характеристики перешкод безпосередньо на основі даних, уникаючи залежності від традиційних експертних систем. Здійснено ґрунтовний огляд провідних алгоритмів, наявних у науковій літературі, проведено їх порівняльний аналіз, а також сформульовано практичні рекомендації щодо впровадження цих рішень у сучасні телекомунікаційні мережі.

ГЛИБОКЕ НАВЧАННЯ, ПРИДУШЕННЯ ПЕРЕШКОД, КОНВОЛЮЦІЙНІ НЕЙРОННІ МЕРЕЖІ, АВТОЕНКОДЕРИ, НЕЙРОННІ МЕРЕЖІ, РЕКУРЕНТНІ НЕЙРОННІ МЕРЕЖІ, РАДІОПЕРЕШКОДИ, БЕЗДРОТОВИЙ ЗВ'ЯЗОК.

THE ABSTRACT

Explanatory note: 84 p., 12 fig, 5 table, 2 app, 65 sources.

The object of wireless networks.

The purpose of the work a improving the noise immunity of signals in wireless networks.

This thesis analyses current developments in the field of interference suppression using deep learning techniques. Methods were investigated that allow the characteristics of interference to be identified and mitigated directly on the basis of data, avoiding reliance on traditional expert systems. A thorough review of the leading algorithms available in the scientific literature was carried out, a comparative analysis was conducted, and practical recommendations were formulated regarding the implementation of these solutions in modern telecommunications networks.

DEEP LEARNING, NOISE SUPPRESSION, CONVOLUTIONAL NEURAL NETWORKS, AUTOENCODERS, NEURAL NETWORKS, RECURRENT NEURAL NETWORKS, RADIO INTERFERENCE, WIRELESS COMMUNICATION.

ЗМІСТ

	C.
ПЕРЕЛІК СКОРОЧЕНЬ.....	9
ВСТУП.....	10
1 ДОСЛІДЖЕННЯ ПРОБЛЕМИ ПОЯВИ ЗАВАД ТА ЇХ БОРОТЬБИ У БЕЗДРОТОВИХ МЕРЕЖАХ.....	11
1.1 Хронологія нововведень у бездротових мережах.....	11
1.2 Роль ШІ/МН для 5G-ADVANCED та еволюції 5G до 6.....	14
1.3 Техніки придушення перешкод.....	16
1.4 Аналіз сучасних досліджень з використання ШІ для придушення перешкод.....	19
1.5 Типи та характеристики перешкод.....	20
1.5.1 Перешкоди від сусідніх каналів.....	20
1.5.2 Перешкоди в одному каналі та самоперешкоди.....	21
1.5.3 Перешкоди від однорідних технологій.....	22
1.5.4 Перешкоди в гетерогенних технологіях.....	22
1.6 Класифікація методів придушення перешкод.....	24
1.7 Основи глибокого навчання.....	26
1.7.1 Конволюційна нейромережа.....	28
1.7.2 Автоенкодери.....	30
1.8 Загальнодоступний набір даних про перешкоди.....	32
1.8.1 Набір даних про радарні перешкоди.....	33
1.8.2 Набір даних про радіочастотні перешкоди.....	33
1.8.3 Набір даних CRAWDAD.....	34
1.8.4 Набір даних про бездротові перешкоди.....	35
2 ТЕХНІКИ ПРИДУШЕННЯ ПЕРЕШКОД НА ОСНОВІ ГЛИБОКОГО НАВЧАННЯ.....	37
2.1 Придушення перешкод з використанням CNN.....	37
2.2 Придушення перешкод з використанням RNN.....	42
2.3 Придушення перешкод з використанням автоенкодерів.....	44
2.4 Придушення перешкод з використанням глибоких нейромереж.....	46
3 ПОРІВНЯЛЬНИЙ АНАЛІЗ ДОСЛІДЖЕНИХ МЕТОДІВ ГЛИБОКОГО НАВЧАННЯ.....	51
3.1 Алгоритм глибокого навчання.....	53

3.2 Тип набору даних.....	53
3.3 Показники ефективності.....	54
4 ПЕРЕВАГИ ТА НЕДОЛІКИ СХЕМ ПРИДУШЕННЯ ПЕРЕШКОД НА ОСНОВІ ГЛИБОКОГО НАВЧАННЯ.....	58
4.1 Відсутність інтерпретованості алгоритмів глибокого навчання.....	60
4.2 Стохастичність бездротового каналу.....	60
4.3 Необхідність дослідження часової та модельної складності.....	61
4.4 Відсутність порівняння ефективності між онлайн- і офлайн-навчанням.....	62
4.5 Аналіз ефективності.....	62
4.5.1 Проблеми з розпізнаванням відкритих множин (OSR) або даними, що виходять за межі розподілу (OOD).....	63
4.5.2 Проблеми з впровадженням.....	64
ВИСНОВКИ.....	65
ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ.....	66
ДОДАТОК А ПУБЛІКАЦІЇ.....	72
ДОДАТОК Б СЛАЙДИ ПРЕЗЕНТАЦІЇ.....	77

ПЕРЕЛІК СКОРОЧЕНЬ

ACI – перешкоди сусідніх каналів;
AI – штучний інтелект;
AUC – площа під кривою характеристик приймача;
AWGN – адитивний білий гаусівський шум;
BER – частота бітових помилок;
BLE – Bluetooth Low Energy;
BPSK – рінарна фазова маніпуляція;
BSS – розділення сліпих джерел;
CCI – соканальні перешкоди;
CNN – конволюційна нейронна мережа;
CS – послідовність чірпу;
CTI – міжтехнологічні перешкоди;
CVCNN – складна конволюційна нейронна мережа;
CWI – перешкоди від безперервної хвилі;
DBP – цифрове зворотне поширення;
DFT – дискретне перетворення Фур'є;
DL – глибоке навчання;
DNN – глибока нейронна мережа;
DSSS – розширений спектр з прямим послідовним розширенням;
EBPNN – розширена нейронна мережа з зворотним поширенням;
EVM – вектор величини похибки;
FCN – повністю згорткова мережа;
FFT – швидке перетворення Фур'є;
FMCW – безперервна хвиля з частотною модуляцією;
GAN – генеративні суперечливі мережі;
GEMS – узагальнена оцінка багатопроменевих сигналів;
GPS – глобальна система позиціонування;
GPU – графічний процесор;
GRU – блок з воротами рекурсії;
IMAT – ітераційний метод з адаптивним пороговим значенням.

ВСТУП

Технології п'ятого та наступних поколінь (5G і вище) є визначальними чинниками трансформації сфери бездротового зв'язку, забезпечуючи масову підключеність, високу пропускну здатність, мінімальні затримки та надвисоку надійність передачі даних.

З огляду на обмеженість радіочастотного спектру та стрімке зростання попиту на його використання, зумовлене технологічним прогресом, проблема інтерференції залишається критично важливою. Попри значні зусилля, спрямовані на її вирішення, перешкоди продовжують суттєво обмежувати ефективність використання спектру, зокрема через інтенсивне впровадження безліцензійних і спільних діапазонів, а також розвиток систем бездротового доступу. Незважаючи на останні досягнення у вирішенні проблем перешкод, вони все ще становлять серйозну проблему для ефективного використання спектру. Якщо раніше превалювали методи уникнення перешкод або використання експертних систем для їх мінімізації, то сучасні дослідження фокусуються на методах фізичного рівня, що базуються на технологіях штучного інтелекту та машинного навчання, зокрема методах глибокого навчання (Deep Learning), які забезпечують активне придушення або компенсацію сигналу завад.

У межах кваліфікаційної роботи проведено аналіз актуальних досягнень у сфері придушення інтерференції засобами глибокого навчання. Досліджено методи, що дозволяють ідентифікувати та нівелювати характеристики перешкод безпосередньо на основі даних, уникаючи залежності від традиційних експертних систем. Здійснено ґрунтовний огляд провідних алгоритмів, наявних у науковій літературі, проведено їх порівняльний аналіз, а також сформульовано практичні рекомендації щодо впровадження цих рішень у сучасні телекомунікаційні мережі.

1 ДОСЛІДЖЕННЯ ПРОБЛЕМИ ПОЯВИ ЗАВАД ТА ЇХ БОРОТЬБИ У БЕЗДРОТОВИХ МЕРЕЖАХ

1.1 Хронологія нововведень у бездротових мережах

У червні 2018 року було оприлюднено специфікацію 5G Release 15, що визначила три ключові сценарії використання технології: розширений мобільний широкосмуговий доступ (eMBB), масовий машинний зв'язок (mMTC) та наднадійний зв'язок із низькою затримкою (URLLC). Це стало фундаментом для глобального розгортання комерційних мереж 5G [1].

У стандарті Release 15 впроваджено новий радіоінтерфейс (5G New Radio, NR), який підтримує як неавтономний (NSA), так і автономний (SA) режими функціонування. У режимі NSA мережа 5G використовує інфраструктуру LTE для управління мобільністю та початкового доступу, тоді як режим SA передбачає повну самодостатність 5G NR. До ключових характеристик NR належать: підтримка широкого діапазону частот (FR1: 410 МГц – 7,125 ГГц; FR2: 24,25 ГГц – 52,6 ГГц), гнучкість розподілу спектра, оптимізована архітектура для мінімізації перешкод і підвищення енергоефективності, мінімальні затримки передачі даних, перспективна сумісність, а також впровадження передових антенних систем із технологією формування променя (beamforming) [2].

Згодом організацією 3GPP було представлено релізи 16 та 17, спрямовані на подальший розвиток 5G-технологій для нових галузевих сценаріїв та оптимізації продуктивності мереж. Реліз 16 зосереджений на вдосконаленні критично важливого Інтернету речей (IoT), технологій URLLC, систем V2X («автомобіль-усе»), ретрансляції даних, комунікацій «пристрій-пристрій» (D2D), сервісів позиціонування та роботи в неліцензованому спектрі. Своєю чергою, реліз 17 фокусується на підтримці абонентського обладнання з обмеженими можливостями (RedCap), неземних мереж (зокрема зв'язку через БПЛА), послуг багатоадресної та широкомовної передачі, а також розширенні діапазону робочих частот до 52 ГГц і вище [3].

Крім того, 3GPP нещодавно затвердила Release 18, що впроваджує концепцію 5G Advanced [4]. Ця версія спрямована на оптимізацію продуктивності мережі, зокрема показників покриття, пропускної здатності та

енергоефективності, з урахуванням нових сценаріїв застосування, таких як розширена реальність (XR). У Release 19, запланованому на 2024 рік, цей розвиток буде продовжено з акцентом на вдосконалення підтримки мобільності, зберігаючи при цьому всі цільові показники попередньої версії. Передбачається, що в межах Release 19 технологія масивних антенних систем (Massive MIMO) відіграватиме визначальну роль у подальшому підвищенні ефективності мережі. Для підтримки сценаріїв eMBB у 5G NR застосовуються різноманітні діапазони частот, схеми дуплексного зв'язку, технологія MIMO та робота з декількома несучими; у 5G Advanced продуктивність eMBB буде суттєво оптимізована. Крім того, вдосконалення механізмів динамічного спільного використання спектру між LTE та NR у Release 18 сприяють ефективній міграції до нових стандартів.

Стандарт 5G-Advanced (Release 19) закладає фундамент для впровадження систем зв'язку шостого покоління (6G). Після завершення попередніх дослідницьких етапів процес стандартизації 6G планується гармонізувати з Release 21. Згідно з прогнозами Ericsson та стратегічними ініціативами 3GPP, випуск 5G-Advanced очікується у 2024 році, а фіналізація ключових специфікацій 6G у межах Release 21 — у 2028 році, що покладе початок подальшій еволюції систем 6G [4].

Технологія 6G інтегрує еволюційні та революційні досягнення у сфері бездротового зв'язку. Вона визначає вектор розвитку фіксованого та мобільного широкосмугового доступу, забезпечуючи розширене покриття, мінімальну затримку, підвищену пропускну здатність та покращену надійність критично важливих сервісів. Окрім того, 6G сприятиме впровадженню інноваційних послуг, зокрема обчислювальних AI-рішень, просторово-часових сервісів та імерсивної комунікації, реалізуючи потенціал метавсесвіту через технології XR, VR та AR. Очікується, що 6G стане каталізатором інновацій для пристроїв та сценаріїв використання, актуальних після 2030 року. На рис. 1.1 відображено можливості та еволюцію технологій 5G, 5G-Advanced та 6G, а на рис. 1.2 представлено графік впровадження стандартів 3GPP 5G та прогноз розвитку 6G.




Рисунок 1.1 - Комунікаційні можливості 5G, 5G-advanced та бачення 6G




Рисунок 1.2 - Розвиток 5G та 6G

Наразі триває розробка та впровадження передових методів, спрямованих на задоволення динамічних потреб сучасних мереж 5G. Такі технологічні рішення, як ущільнення гетерогенних мереж (HCN), оптимізація використання спектру, формування променя (beamforming) та технологія Massive MIMO, забезпечують суттєве підвищення пропускної здатності, спектральної ефективності та надійності з'єднань.

Водночас ефективне управління перешкодами залишається критичним чинником для забезпечення стабільного функціонування інфраструктури.

Неконтрольовані завади можуть спричиняти розриви з'єднань, зниження швидкості передачі даних та деградацію якості обслуговування (QoS). Відтак, управління перешкодами є стратегічним завданням для підтримки високих стандартів продуктивності 5G та 6G. Далі проаналізуємо доцільність застосування методів штучного інтелекту (ШІ) та машинного навчання (МН) для вирішення завдань управління перешкодами в мережах 5G та при переході до стандарту 6G.

1.2 Роль ШІ/МН для 5G-ADVANCED та еволюції 5G до 6G

З огляду на постійний розвиток технологій бездротового зв'язку, що виходять за межі стандарту 5G, виникає потреба в адаптації до складних сценаріїв розгортання та експлуатації мереж. Інтеграція методів штучного інтелекту (ШІ) та машинного навчання (МН) є критично важливою для подолання цієї складності та забезпечення еволюції систем 5G-Advanced у напрямку 6G.

Зокрема, специфікація 3GPP Release 18 визначає принципи проектування повітряного інтерфейсу 5G NR із застосуванням ШІ/МН для оптимізації продуктивності мережі, зокрема в частині уточнення зворотного зв'язку щодо стану каналу (CSI), управління променем та підвищення точності позиціонування. Стандарт також охоплює вдосконалення механізмів збору даних та сигналізації для ефективного балансування навантаження, управління мобільністю та енергозбереження [5]. Наскрізна (E2E) комунікація на основі ШІ/МН є фундаментальним фактором переходу до мереж 6G, де використання динамічної розподіленої обчислювальної інфраструктури (хмарні, периферійні та термінальні ресурси) сприятиме підвищенню загальної ефективності мережевих систем. Наразі провідними дослідницькими групами здійснюється масштабна наукова робота з вивчення застосування методів ШІ/МН у мережах радіодоступу (RAN) наступного покоління - від фізичного рівня до балансування та управління базовою мережею (управління ланцюжками функцій послуг, віртуалізація мережевих функцій тощо) [6].

Сфокусуємося на мережах радіодоступу (RAN) з підтримкою ШІ/МН, зокрема в контексті виявлення та мінімізації перешкод у мережах 5G та 6G. Зважаючи на широке розмаїття сценаріїв використання 5G від автономних транспортних засобів та доповненої реальності до масштабного розгортання

Інтернету речей (IoT), - проблема впливу перешкод набуває особливої гостроти. Традиційні підходи до їх усунення (зокрема повторне використання частот, адаптивне формування променя тощо) можуть виявитися недостатніми для вирішення викликів, пов'язаних із технологіями масивного МІМО, міліметровими хвилями, терагерцовими діапазонами та динамічним доступом до спектру.

З огляду на зазначене, розробка спеціалізованих стратегій управління перешкодами, що враховують специфічні вимоги 5G, є необхідною умовою забезпечення надвисокої надійності зв'язку (URLLC). Алгоритми ШІ та МН, завдяки можливостям ситуаційної обізнаності, прогнозування та автоматизації, дозволяють здійснювати динамічний розподіл ресурсів та корекцію параметрів мережі в реальному часі.

Проведемо короткий огляд різних методів машинного навчання. Машинне навчання, одна з основних галузей штучного інтелекту, дозволяє мережевим вузлам і пристроям виконувати завдання без явного програмування. Алгоритми машинного навчання зазвичай поділяють на три типи: навчання з наставником (SL), навчання без наставника та підкріплювальне навчання (RL). Алгоритми SL використовують мічені навчальні дані для побудови моделей, що дозволяють прогнозувати вихідні значення на основі вхідних ознак. Прикладами є класифікація (наприклад, KNN, дерево рішень, випадковий ліс, SVM) та регресія (наприклад, лінійна, поліноміальна, експоненціальна, логістична). Алгоритми навчання без наставника виявляють закономірності в немаркованих даних, включаючи кластеризацію (наприклад, K-середніх, DBSCAN, гаусівська суміш) та зменшення розмірності. RL дозволяє вузлам навчатися стратегіям управління шляхом взаємодії з середовищем для максимізації винагород. Приклади включають оптимізацію політики (наприклад, DDPG, TD3, PPO, SAC, A2C) та Q-навчання (наприклад, DQN, SARSA) [7].

Глибоке навчання (DL) — це підгалузь машинного навчання, що використовує багатошарові штучні нейронні мережі. Ці методи можуть застосовуватися в сценаріях супервізованого навчання, навчання без наставника та навчання з підкріпленням. Глибоке навчання охоплює різні архітектурні моделі, включаючи глибокі нейронні мережі (DNN), глибоке підкріплення (DRL), рекурентні нейронні мережі (RNN), згорткові нейронні мережі (CNN), автоенкодери та трансформери [7].

1.3 Техніки придушення перешкод

Проблема виникнення перешкод залишається фундаментальним та незмінним викликом у сфері бездротового зв'язку. З огляду на стрімкий розвиток технологій, таких як 5G, Інтернет речей (IoT), LTE-U, LAA, спектр CBRS, технології V2X, а також широке впровадження доступних програмно-конфігурованих радіоприймачів (SDR) в умовах обмеженості радіочастотного ресурсу, ризик виникнення завад зберігає свою актуальність [1].

З огляду на значну щільність бездротових пристроїв та прогнозоване зростання обсягів масової міжмашинної комунікації (mMTC), взаємні перешкоди від однорідних та неоднорідних систем продовжуватимуть суттєво впливати на надійність передачі даних. Зокрема, виникають конфлікти як між легітимними вторинними користувачами (SU), що використовують спільний спектр, так і з боку зловмисних суб'єктів, які навмисно створюють завади для традиційних та санкціонованих користувачів.

У неліцензованих діапазонах мережі Wi-Fi традиційно стикаються з перешкодами від побутових пристроїв (радіонянь, бездротових аудіосистем, приводів воріт), а в останні роки - також від неліцензованих користувачів стільникових мереж. Для мінімізації впливу зазначених факторів застосовуються різні підходи: ранні методи базувалися на принципах уникнення завад шляхом розділення сигналів у часовій, частотній, кодовій або просторовій областях, тоді як сучасні дослідження [2, 4] зосереджені на методах фізичного рівня для ефективного придушення перешкод.

У роботі розглядається широкий спектр застосувань, у яких перешкоди становлять значні технічні виклики. До таких сфер належать автомобільні радары, системи неортогонального множинного доступу (NOMA), щільні мережі Інтернету речей (IoT), системи повного дуплексу, динамічне використання спектра, а також питання співіснування різних радіотехнологій. У контексті каналу зв'язку перешкоди класифікують на перешкоди суміжного каналу та перешкоди спільного каналу: перші виникають між сусідніми частотними діапазонами, тоді як другі - в межах одного діапазону. За технологічним критерієм розрізняють однорідні перешкоди (між сигналами однієї технології) та неоднорідні перешкоди (між різними технологіями). Додатково, у повнодуплексних системах, призначених для підвищення

спектральної ефективності, виникають самоперешкоди (SI), зумовлені одночасною передачею та прийомом у межах одного частотного ресурсу. Детальний аналіз цих категорій наведено у розділі 2.

Традиційні методи мінімізації перешкод базуються на їх класифікації для визначення оптимальної стратегії протидії. До них, зокрема, належать методи фізичного рівня та алгоритми сліпого розділення джерел (BSS). Методи фізичного рівня передбачають придушення перешкод шляхом оптимізації архітектури рівня або забезпечення надмірності для коректної обробки сигналів приймачем [5]. В їх межах застосовуються евристичні моделі, методи оптимізації та жадібні алгоритми. Наприклад, у роботі [9] для придушення лінійних радіолокаційних перешкод із частотною модуляцією застосовано фільтри з частотно-часовою зміною параметрів (TV-FRESH), що використовують спектральну надмірність сигналів із ортогональним частотним поділом (OFDM). Також ефективним інструментом є адаптивна фільтрація, здатна коригувати критерії обробки залежно від характеристик перешкод без викривлення корисної інформації. Попередні підходи спиралися на властивості сигналів, такі як циклостационарні характеристики [10], параметри огинаючої [11] та пропускна здатність каналу [12]. Як зазначено в [13], ключовим обмеженням методів фізичного рівня, що оптимізують ваги фільтрів на основі часово-частотних статистичних даних, є зниження ефективності традиційних алгоритмів (наприклад, методу найменших середніх квадратів - LMS) при роботі з динамічними перешкодами, що змінюються в часі. Крім того, необхідність залучення специфічних знань про сигнали обмежує масштабованість таких рішень в умовах високої щільності та гетерогенності сучасних бездротових середовищ.

У межах дослідження методів сліпого розділення сигналів (BSS) Фабріціо та співавтори [14] запропонували алгоритм, що базується на оцінці форм хвиль перешкод у спільному каналі з корисним сигналом (SOI), із застосуванням методу узагальненої оцінки багатопромених сигналів (GEMS). Технологія BSS дозволяє виокремити набір сигналів із суміші без попередньої інформації про процес змішування чи параметри вихідних сигналів. По суті, BSS забезпечує відновлення цільової складової з прийнятого сигналу. SOI, відповідно до визначення, є компонентом без шумів, який підлягає аналізу або відновленню на приймальній стороні [15]. Хоча в науковій літературі переважають дослідження розділення сигналів низької розмірності, методи BSS

ефективно застосовуються і до багатовимірних даних. Прикладом є аналіз головних компонент (PCA), який використовується в обробці зображень для зниження розмірності. У роботі [13] автори реконструювали компоненти перешкод на основі оціненої форми сигналу, після чого виконували їх віднімання від даних у часовій області. Інші підходи до придушення перешкод охоплюють методику Уйсала [16], що передбачає розкладання сигналів у часовій області для відокремлення завад автомобільного радара від SOI, а також підхід Лі та співавт. [17], у якому спочатку оцінюються параметри сигналу за допомогою часомодульованого віконного дискретного перетворення Фур'є (DFT), а потім проводиться реконструкція та віднімання оціненої перешкоди. Ключовою вадою цих методів є необхідність високої точності визначення характеристик перешкод, таких як їхнє розташування, тривалість та інші параметри. Відтак, можна констатувати три основні обмеження традиційних методів: залежність від апіорних знань про середовище, низька здатність до узагальнення та складність точної локалізації перешкод.

Встановлено, що методи придушення перешкод на основі глибокого навчання (DL), які не потребують попереднього моделювання, ефективно вирішують вищезазначені проблеми. Підходи, що не вимагають розробки моделей (model-free), усувають потребу в глибоких знаннях про предметну область, що значно підвищує практичну цінність їх впровадження. Попри стохастичну природу радіочастотного (RF) середовища, методи глибокого навчання здатні ефективно функціонувати в реальних умовах, навчаючись безпосередньо на даних. Попри складнощі формування репрезентативних наборів даних для різноманітних каналних середовищ, використання програмно-керованих радіоприймачів (SDR) суттєво спрощує цей процес завдяки їхній доступності та можливості моделювання різних сценаріїв. Попри часові витрати, такий підхід сприяє розвитку бездротових комунікацій через розширення бази знань про методи придушення перешкод. Важливою перевагою глибокого навчання є здатність моделювати складні нелінійні взаємозв'язки, які недоступні для традиційних методів. Більшість класичних схем придушення демонструють обмежену надійність у разі складної нелінійної структури меж прийняття рішень, тоді як технології глибокого навчання успішно долають ці бар'єри. Крім того, застосування DL дозволяє ефективно вирішити питання масштабованості, що залишається проблемним аспектом для багатьох традиційних алгоритмів.

1.4 Аналіз сучасних досліджень з використання ІІІ для придушення перешкод

Станом на момент написання роботи, у фаховій літературі відсутнє комплексне дослідження, присвячене методам придушення перешкод на основі глибокого навчання (DL). Нам вдалося ідентифікувати лише дві оглядові роботи, що частково охоплюють цю тематику. Зокрема, у [18] автори проаналізували методи глибокого навчання в контексті радіолокаційних систем, приділивши обмежену увагу технікам придушення перешкод. Тому дана робота присвячена більш розширеній класифікації завад, включаючи самоперешкоди, перешкоди суміжних каналів, а також вплив однорідних та неоднорідних технологій. Крім того, на відміну від [18], де фокус зміщений на класифікацію та розпізнавання сигналів, дана робота зосереджена безпосередньо на алгоритмах придушення перешкод.

Інша робота, Чен та ін. [19], надає огляд методів співіснування та пом'якшення перешкод для WPAN та WLAN, проте вона базується переважно на традиційних (не-DL) підходах, розглядаючи методи глибокого навчання лише поверхнево. Вданій роботі проводиться глибинний аналіз критичних характеристик перешкод, обґрунтовується доцільність застосування DL-методів для їх усунення.

У низці інших оглядів розглядаються класичні методи обробки сигналів, що не передбачають використання машинного навчання. Зокрема, у роботах [20 – 21] проаналізовано техніки регулювання потужності, динамічного вибору частоти, перемикання каналів, адаптивної обробки масивів у GPS та специфічних схем для сенсорних мереж. Кунерт та ін. [1] класифікували методи придушення радіолокаційних перешкод за часовими, частотними, просторовими та іншими параметрами. Хоча ці підходи є ефективними, вони часто потребують глибокої експертизи в предметній області та демонструють обмежену масштабованість у середовищах IoT та 5G, де спостерігається висока щільність пристроїв у спільному частотному ресурсі. Більше того, реалізація стратегій «комунікації та уникнення» (detect-and-avoid) може виявитися нежиттєздатною для додатків із жорсткими вимогами до затримок, таких як 5G NR або системи V2X. Саме ці обмеження нівелюються за допомогою методів глибокого навчання, детально розглянутих у роботі.

Стосовно алгоритмів придушення перешкод в автомобільних радарних системах, у роботі Toth та ін. [22] було проаналізовано низку сучасних методів, зокрема нульове формування (nulling), лінійну фільтрацію, ітеративний метод з адаптивним порогом (IMAT) та параметричну інтерполяцію в часовій області (IVMir). Зазначене дослідження обмежувалося виключно автомобільними радарними системами та не охоплювало підходи на основі машинного (ML) або глибокого навчання (DL). Аналогічним чином, у праці Nabil та ін. [23] розглянуто розвиток методів придушення власних та взаємних перешкод у бездротових мережах, включаючи технології MIMO, трансформатори Балуна, ізоляцію трактів передавача та приймача, фазове зміщення та методи просторової рознесеності.

Поточне дослідження суттєво відрізняється від існуючих оглядів завдяки систематичному аналізу методів придушення перешкод із застосуванням глибокого навчання (DL) у широкому спектрі прикладних сфер та за різноманітних характеристик сигналів перешкод. Робота містить порівняльний аналіз зазначених методів та ідентифікує ключові виклики, пов'язані з використанням DL для подолання перешкод.

1.5 Типи та характеристики перешкод

Розглянемо типи та характеристики перешкод у мережах бездротового зв'язку.

1.5.1 Перешкоди від сусідніх каналів

Завади від сусіднього каналу (Adjacent Channel Interference, ACI) виникають, коли рівень потужності сигналу в суміжному каналі створює перешкоди для прийому корисного сигналу в цільовому каналі (табл. 1.1). Виникнення ACI зумовлене низкою технічних факторів. Зокрема, у системах із частотною модуляцією (FM) причиною може стати недостатньо ефективна фільтрація сигналу. Також до появи ACI призводить неналежне налаштування частотного розподілу як у каналі, що створює завади, так і в опорному каналі.

Для мінімізації впливу ACI застосовують відповідні стратегії управління частотним ресурсом. Наприклад, у мережах Wi-Fi діапазону 2,4 ГГц, попри

наявність 11 доступних каналів, з метою уникнення інтерференції рекомендовано використовувати лише канали 1, 6 та 11, що не перетинаються.

Таблиця 1.1 - Бездротові технології, що використовують діапазон 2,4 ГГц, та їхні методи уникнення перешкод.

Технологія	Кількість каналів	Метод уникнення завад
Wi-Fi (IEEE 802.11b/g/n/ax)	3 статичні канали по 20 МГц	Запобігання колізіям (Collision avoidance)
Bluetooth	79 динамічних каналів по 1 МГц	Стрибкоподібна перебудова частоти (Frequency hopping)
Wireless USB (включаючи бездротову клавіатуру, мишу тощо)	79 динамічних каналів по 1 МГц	Частотна гнучкість (Frequency agility)
IEEE 802.15.4	16 статичних каналів по 5 МГц	Фіксоване запобігання колізіям (Fixed collision avoidance)
Bluetooth Low Energy (BLE)	40 каналів по 2 МГц	Стрибкоподібна перебудова частоти (Frequency hopping)
Бездротовий телефон (Cordless Phone)	100 кГц (аналоговий телефон); 800 кГц (телефон зі Frequency hopping)	Стрибкоподібна перебудова частоти (Frequency hopping)

У системах когнітивного радіо (CR) внутрішньосмугова повнодуплексна передача та прийом на одній частоті є ефективними методами подвоєння спектральної ефективності, що забезпечує оптимальне використання доступних ресурсів. Для мінімізації перешкод застосовуються такі методи, як антенне, аналогове та цифрове гасіння сигналу (рис 1.3). Проте, як свідчать дослідження, повна нейтралізація завад від власного випромінювання (SI) є складним завданням через вплив таких чинників, як дисбаланс I/Q-сигналів, нелінійність підсилювачів потужності та інші апаратні недосконалості [24].

1.5.2 Перешкоди в одному каналі та самоперешкоди

З іншого боку, перешкоди в спільному каналі (CCI) виникають у випадках, коли два пристрої або передавачі використовують ідентичну частоту, створюючи взаємні завади [25]. У системах стільникового зв'язку вплив CCI стає особливо відчутним при повторному використанні частотних діапазонів. Оскільки стандартні методи уникнення перешкод не забезпечують належного

рівня придушення CCI, у межах цього огляду ми зосереджуємося на вирішенні цієї складної проблеми. На рис. 1.3 наочно продемонстровано вплив CCI та ACI на корисний сигнал (SOI).




Рисунок 1.3 - Загальна структура придушення перешкод на основі ML з ACI та CCI

Варто зауважити, що процеси збору даних, офлайн-навчання та інші складні операції глибокого навчання реалізуються на стороні приймача. Докладний огляд стратегій мінімізації перешкод із застосуванням методів машинного навчання наведено у розділі 3. На рис. 1.3 представлено загальну схему застосування алгоритмів машинного та глибокого навчання для придушення або мінімізації рівня завад.

Самоперешкоди (SI) є поширеним явищем у повнодуплексних системах зв'язку, де передавачі та приймачі функціонують в одній смузі частот для забезпечення одночасної передачі та прийому даних.

1.5.3 Перешкоди від однорідних технологій

Гомогенні технологічні перешкоди, що виникають внаслідок впливу сигналів ідентичних технологій, проявляються як у межах одного каналу (со-

channel interference), так і в суміжних каналах (adjacent-channel interference). Інтенсивність таких завад залежить від типу частотного діапазону та характеристик домінуючого сигналу. Подібні перешкоди є типовими для технологій множинного доступу, зокрема стандартів IEEE 802.15.1 та IEEE 802.15.4. Фарид та співавтори [26] досліджували стратегії мінімізації впливу гомогенних завад у бездротових сенсорних мережах (WBAN), включаючи механізми CSMA/CA, методи придушення на основі адаптивних алгоритмів, розфарбовування графів, протоколи TDMA та евристичні методи.

Крім того, технологія множинного доступу з кодовим розділенням (CDMA), що застосовується у стільниковому зв'язку, також піддається впливу гомогенних перешкод. У системах CDMA зі спектром, що розширюється, коректна передача даних забезпечується за рахунок призначення унікальних псевдовипадкових (PN) кодів для кожного користувача, що дозволяє приймачу ефективно ідентифікувати сигнали. Протягом останніх тридцяти років для компенсації таких завад у CDMA-системах було розроблено низку лінійних та нелінійних методів оцінювання. Варто зауважити, що інтенсивність наукових досліджень у сфері гомогенних технологічних перешкод є нижчою порівняно з вивченням гетерогенних перешкод (розглянутих у розділі 2). Відповідно, сучасні методи придушення перешкод на основі глибокого навчання (DL) переважно фокусуються на мінімізації впливу саме гетерогенних джерел завад.

1.5.4 Перешкоди в гетерогенних технологіях

Розуміння механізмів виникнення перехресних перешкод (Cross-Technology Interference, CTI) є критично важливим для забезпечення ефективного співіснування різних бездротових технологій, що функціонують у спільних неліцензованих діапазонах частот. CTI виникають внаслідок впливу сигналів однієї бездротової системи на іншу. До типових сценаріїв такої взаємодії належать: LTE у ліцензованих діапазонах та Wi-Fi, неліцензовані версії LTE та Wi-Fi, радіолокаційні системи та Wi-Fi, а також спеціалізований зв'язок малого радіусу дії (DSRC) та Wi-Fi.

З огляду на ризики, пов'язані з проблемами співіснування, у наукових працях [27-28] представлено низку методів придушення перешкод для поглибленого вивчення взаємодії між гетерогенними технологіями. Зазвичай CTI характеризуються специфічними патернами, які можуть бути

ідентифіковані протоколами, що враховують наявність завад [27]. Зокрема, Грунау та ін. [28] проаналізували вплив СТІ на сигнал IEEE 802.11 b/g з боку IEEE 802.15.1, встановивши, що сигнали IEEE 802.15.1 є менш деструктивними порівняно зі зворотним впливом. Це зумовлено меншою смугою пропускання сигналів стандартів IEEE 802.15.4 та IEEE 802.15.1 порівняно з IEEE 802.11 b/g. Проте для бездротових пристроїв з низьким енергоспоживанням СТІ може мати непропорційно високий негативний вплив на їхню здатність до співіснування.

У Таблиці 1.1 наведено перелік бездротових технологій, зокрема IEEE 802.11 (стандарт Wi-Fi), Bluetooth, Bluetooth Low Energy (BLE), Wireless USB, IEEE 802.15.4 тощо.

Стандарт IEEE 802.11p, що є поправкою до IEEE 802.11, був розроблений для інтеграції системи автомобільного зв'язку WAVE (Wireless Access in Vehicular Environments) з метою забезпечення роботи інтелектуальних транспортних систем. Дана технологія використовує діапазон 5,85–5,925 ГГц. Оскільки Wi-Fi функціонує як вторинний користувач у межах радіолокаційних діапазонів, він може створювати перешкоди для застарілих радіолокаційних систем, що працюють у спектрі 2,4 ГГц. Незважаючи на відмінності у рівнях потужності та ширині зайнятої смуги частот, ці технології можуть спричиняти взаємні завади, враховуючи високу щільність використання неліцензованого діапазону 2,4 ГГц.

1.6 Класифікація методів придушення перешкод

Методи придушення завад можна класифікувати за такими категоріями (див. рис. 1.4): базові методи, методи на основі диверсифікації, порогові методи, методи інтерполяції та підходи з використанням глибокого навчання. Окрему групу становлять поліноміальні методи усунення власних завад (SI) [29]. Використання поліноміальних моделей у повнодуплексних системах зазвичай супроводжується значним зростанням кількості параметрів, що ускладнює їх практичну реалізацію. Попри те, що цей огляд зосереджений на методах глибокого навчання, у цьому розділі наведено стислий опис альтернативних підходів для формування теоретичного підґрунтя, необхідного для аналізу, представленого в розділі 3. Таксономію методів придушення завад, що охоплює як класичні, так і інтелектуальні алгоритми, відображено на рис. 1.4.

До впровадження методів машинного та глибокого навчання для мінімізації або усунення завад застосовувалися різноманітні підходи. Зважаючи на обмеженість обчислювальних та енергетичних ресурсів у багатьох мережах з низьким енергоспоживанням, для придушення завад від гетерогенних технологій було запропоновано використовувати дані фізичного рівня (PHY) та часову диверсифікацію бездротового каналу. Зокрема, у роботі [30] для виявлення завад здійснювався моніторинг індикатора якості каналу (LQI) пошкоджених кадрів у поєднанні з традиційними пороговими механізмами. За умови ідентифікації завад проводився аналіз динаміки індикатора сили прийнятого сигналу (RSSI), що базується на дискретизації сигналу. Отримані значення RSSI оброблялися алгоритмом виявлення, а відновлення пошкоджених пакетів реалізовувалося шляхом повторної передачі та буферизації коректно декодованих фрагментів даних [30].



Рисунок 1.4 - Методи придушення перешкод

Хоча в літературі розглядалися схеми запобігання завадам, такі як адаптація потужності передачі або динамічне перемикавання частот, цей огляд фокусується саме на методах придушення завад. До них належать: обнулення вибірок із завадами [31], ітеративна інтерполяція (IMAT) [32], параметрична інтерполяція в часовій області [33], фільтрація лінійного наростання (RFmin) [34] та інші. Попри простоту реалізації, метод обнулення компонентів завад може призвести до зниження відношення сигнал/шум або пошкодження корисного сигналу. Метод RFmin спирається на диверсифікацію спектра дальності на лінійних ділянках [22]. У підході IMAT зразки із завадами обнуляються, після чого проміжок, що утворився, ітеративно інтерполюється шляхом заміни на обернене перетворення Фур'є домінуючої спектральної

складової [22, 32]. Параметрична інтерполяція в часовій області базується на схожому принципі, проте для відновлення проміжків використовує параметричну модель сигналу [33]. Варто зауважити, що наведений перелік класичних методів не є вичерпним і має на меті лише окреслення контексту для кращого розуміння переваг алгоритмів глибокого навчання. Детальнішу інформацію щодо інших підходів можна знайти в джерелах [1, 21].

Методи глибокого навчання поділяють на навчання з учителем та навчання без учителя. Ключова відмінність між цими підходами полягає у використанні розмічених наборів даних: навчання з учителем базується на розмічених вхідних і вихідних даних, тоді як навчання без учителя використовує алгоритми для виявлення прихованих структур у нерозмічених даних. У межах навчання з учителем методи придушення перешкод на основі CNN розглянуто в роботах [35-36], на основі глибоких нейронних мереж (DNN) - у [24, 37], а на основі рекурентних нейронних мереж (RNN) - у [38-39]. Стосовно навчання без учителя, методи придушення перешкод із застосуванням автоенкодерів представлені в джерелах [40-41].

Крім того, існують методи машинного навчання, що використовують інформацію про стан каналу (CSI) [42] для оцінки рівня потужності передачі, необхідної для мінімізації інтерференції. Ефективність цього підходу значною мірою залежить від точності оцінки потужності, що є критично важливим для бездротових сенсорних мереж (WSN). В інших роботах, зокрема [30] та [43], реалізовано методи спрощеного вилучення ознак та дерев рішень для виявлення й ідентифікації перешкод у мережах Wi-Fi, Bluetooth та мікрохвильових системах.

З огляду на зростання кількості пристроїв, що конкурують за використання бездротового спектру, традиційні методи придушення перешкод можуть втрачати свою ефективність через обмежену масштабованість. Оскільки підходи на основі глибокого навчання демонструють вищу точність класифікації та ідентифікації інтерференції [28], дослідники активно вивчають їхній потенціал для завдань придушення перешкод [35, 36, 38]. Детальний огляд цих методів наведено у розділі 4.

1.7 Основи глибокого навчання

Протягом останніх двох десятиліть спостерігається безпрецедентний

технологічний прогрес у сфері обчислювального обладнання, що забезпечив широку доступність високопродуктивних ресурсів. Зокрема, значне зростання обчислювальної потужності графічних процесорів дозволило суттєво скоротити час виконання складних операцій. Методи глибокого навчання (deep learning) забезпечують можливість ієрархічного формування складних концепцій на основі простіших структур [44]. Традиційно алгоритми глибокого навчання класифікують на три основні категорії: навчання з учителем (supervised learning), що базується на розмічених даних; навчання без учителя (unsupervised learning), яке не потребує маркування даних; та навчання з підкріпленням (reinforcement learning), де інтелектуальний агент оптимізує свої дії для максимізації сукупної винагороди. Окрему увагу привертає метод напівкерованого навчання (semi-supervised learning) [45], що інтегрує підходи навчання з учителем та без нього. Попри те, що в роботах, таких як Longi et al., напівкероване навчання було використано для ідентифікації джерел перешкод у мережах WLAN, питання його застосування для безпосереднього придушення перешкод залишається недостатньо висвітленим.

Методи глибокого навчання продемонстрували високу ефективність у вирішенні складних завдань у таких галузях, як класифікація зображень, медична біоінформатика та обробка природної мови. Надихнувшись цими досягненнями, фахівці в галузі бездротового зв'язку активно інтегрують глибоке навчання для розв'язання критичних проблем, зокрема ідентифікації, класифікації [28, 44] та придушення перешкод, а також для розпізнавання модуляції, ідентифікації передавачів, моніторингу спектра та класифікації трафіку. Зважаючи на високу масштабованість, здатність до узагальнення та можливість автономного навчання на емпіричних даних, методи глибокого навчання є перспективними інструментами для вирішення проблем співіснування в мережах п'ятого (5G NR) та шостого (6G) поколінь. Таким чином, впровадження глибокого навчання для оцінювання, прогнозування та придушення динамічних перешкод сприяє підвищенню завадостійкості фізичного рівня зв'язку.

У попередніх дослідженнях застосування методів глибокого навчання (DL) у бездротових комунікаціях розглядалися наскрізні системи для багатокористувацьких багатоантенних конфігурацій, у яких здійснюється спільна оптимізація передавача та приймача задля підвищення ефективності порівняно з традиційними підходами, що не використовують технології

машинного навчання [41, 46]. Окремим напрямом є використання методів глибокого навчання для моделювання та оцінювання каналів. Зокрема, у роботі [47] генеративні суперечливі мережі (GAN) застосовуються для апроксимації стохастичної характеристики каналу на основі необроблених даних з метою забезпечення моделювання в режимі реального часу.

Архітектура GAN базується на навчанні представлень шляхом протиборства двох нейронних мереж - генератора та дискримінатора [47]. Генератор спрямовує зусилля на створення синтетичних зразків, здатних імітувати реальні дані, тоді як дискримінатор виконує класифікацію, відрізняючи автентичні зразки від фальшивих. У процесі ітеративного навчання обидві мережі взаємно вдосконалюють свої характеристики.

Крім того, методи глибокого навчання впроваджуються в архітектури OFDM-приймачів для оцінювання каналу та декодування сигналів. Зокрема, Liang et al. [48] запропонували алгоритм поширення переконань на основі глибокого навчання, що інтегрує згорткові нейронні мережі (CNN) для підвищення точності оцінювання шуму. Попри те, що ці методи не є інструментами безпосереднього придушення перешкод, вони забезпечують формування інформаційної бази, необхідної для подальшої обробки сигналів із метою мінімізації інтерференції.

Фундаментальна відмінність між методами глибокого навчання та підходами на основі моделей полягає в тому, що перші базуються на аналізі даних, тоді як останні потребують глибоких експертних знань у предметній галузі (так звані експертні системи). Проведене дослідження підтверджує, що значна частина методів глибокого навчання демонструє вищу продуктивність, ніж традиційні алгоритми на основі моделей.

1.7.1 Конволюційна нейромережа

Згорткові нейронні мережі (CNN) належать до методів глибокого навчання з учителем, що забезпечують виявлення взаємозв'язків між вхідними даними та відповідними цільовими мітками. Зокрема, у роботі [49] представлено підхід до придушення радіочастотних перешкод (RFI) із застосуванням архітектури U-Net - різновиду CNN з U-подібною структурою.

Алгоритми CNN застосовуються для класифікації чистих сигналів та сигнатур радіоперешкод у двовимірних часових масивах даних, отриманих за

допомогою радіотелескопів. Попри зосередженість на методах класифікації перешкод, поточні дослідження переважно обмежені космологічними застосуваннями, зокрема системами супутникового зв'язку, навігацією повітряного руху та роботою радіотелескопів. Аналогічно до придушення радіочастотних перешкод, питання придушення радіолокаційних завад також є предметом активних наукових розвідок [35, 36, 38]. Слід зазначити, що використання CNN для придушення перешкод залишається новітнім напрямом досліджень, розвиток якого стримується низкою факторів, зокрема обмеженістю доступних еталонних наборів даних.

На рис. 1.5 представлена типова архітектура CNN, що складається з послідовності згорткових шарів, активаційних функцій на основі випрямлених лінійних одиниць (ReLU) та шарів об'єднання (pooling layers), результати яких передаються на два повнозв'язні шари. Ця модель відповідає структурі, описаній у джерелі [50]. Вхідні дані можуть бути представлені у вигляді зображень, що продемонстровано на прикладі модифікованої бази даних MNIST розмірністю $28 \times 28 \times 1$ [51]. База даних MNIST, що містить великий масив рукописних цифр, є загальновизнаним стандартом для навчання та тестування систем обробки зображень.




Рисунок 1.5 - Загальна архітектура CNN із конволюційними шарами, активаційною функцією ReLU, шарами об'єднання, що переплітаються між собою, та двома повністю з'єднаними шарами

Наступним етапом обробки є проходження вхідного зображення крізь згортковий шар, у якому використовуються фільтри (ядра) для виконання операції скалярного добутку, що дозволяє виокремити специфічні ознаки з масиву даних. Переміщення ядра здійснюється з певним кроком (stride), що визначає зміщення вікна по вхідній матриці. Для впровадження нелінійності в модель застосовуються активаційні функції, які забезпечують навчання

складних залежностей між вхідними даними та цільовими змінними. До поширених активаційних функцій належать ReLU, сигмоїда, tanh, leaky ReLU тощо. Серед них функція ReLU є найбільш вживаною завдяки своїй кусково-лінійній природі, яка визначається наступним чином:

$$ReLU(x) = \max(0, x). \quad (1.1)$$

З рівняння 1.1 випливає, що якщо $x > 0$, функція є додатньою, а якщо $x < 0$, вихідний сигнал дорівнюватиме нулю. Шар об'єднання (pooling layer) забезпечує зменшення розмірності ознак, отриманих у результаті згортки, що сприяє мінімізації ризику перенавчання моделі. Повнозв'язний шар відіграє ключову роль у формуванні нелінійних комбінацій високорівневих ознак; архітектура може включати кілька таких шарів. Кількість вихідних нейронів останнього повнозв'язного шару визначається специфікою завдання та числом цільових класів. Згорткові нейронні мережі (CNN) ефективно опрацьовують дані як у часовій, так і у частотній областях, що робить їх придатними для моделювання пристроїв, вихідні характеристики яких виходять за межі частотного спектра [28]. Крім того, CNN демонструють високу ефективність при аналізі нелінійностей у часовій області, зокрема для завдань ідентифікації або класифікації.

Попередні дослідження засвідчили, що CNN здатні автоматично виділяти специфічні для конкретних пристроїв ознаки шляхом опрацювання великих масивів навчальних даних, що сприяє суттєвому підвищенню продуктивності моделей.

1.7.2 Автоенкодера

Автоенкодери (АЕ) досліджуються як перспективний метод придушення перешкод у таких сферах, як радіолокаційні системи та технології Wi-Fi. АЕ - це клас нейронних мереж, призначених для вивчення стисненого представлення вхідних даних у латентному просторі, що дозволяє здійснювати ефективну реконструкцію вихідного сигналу [52]. Латентне представлення дозволяє ідентифікувати корисні характеристики сигналу, що містить перешкоди, які згодом можуть бути мінімізовані на етапі декодування. Архітектура мережі включає кодер, який стискає вхідні дані згідно з функцією $h = f(x)$, та декодер,

що відтворює дані з прихованого представлення за допомогою функції $x' = g(h)$. Ключовим завданням автоенкодера є мінімізація різниці між реконструйованим сигналом x' та вихідним сигналом x . На рис. 1.6 наведено блок-схему типової архітектури автоенкодера.




Рисунок 1.6 - Загальна архітектура автоенкодера

Латентне представлення h має високу аналітичну цінність, оскільки дозволяє виділяти найбільш значущі ознаки вхідних даних. За концептуальним рівнем автоенкодер функціонує як засіб ідентичного відтворення вхідного сигналу. Однак завдяки накладанню обмежень, таких як зменшення розмірності h порівняно з x , мережа змушена оптимізувати навчання та виділяти лише найбільш суттєві характеристики вхідних даних. Надмірна ємність мережі може призвести до неефективного навчання та ігнорування важливої інформації про розподіл даних. Створення штучного «вузького місця» (bottleneck) сприяє формуванню компактного та інформативного представлення вихідних сигналів. У разі наявності кореляції між ознаками вхідних даних, зазначене обмеження дозволяє ефективно структурувати дані. За відсутності таких обмежень мережа схильна до простого копіювання вхідних значень на вихід.

Як функцію втрат зазвичай використовують середньоквадратичну похибку (MSE) або втрату реконструкції на основі перехресної ентропії. Мережа отримує штраф за розбіжність між вихідними та вхідними даними. Для запобігання перенавчанню та простому запам'ятовуванню вхідних даних автоенкодери калібруються таким чином, щоб забезпечити баланс між чутливістю, необхідною для точної реконструкції, та нечутливістю, яка запобігає надмірній адаптації до навчальної вибірки. Одним із перспективних напрямків використання автоенкодерів у задачах фільтрації перешкод є модифікація латентного представлення h шляхом його фільтрації або відсікання, що дозволяє цілеспрямовано усувати небажані сигнали.

Автоенкодери знаходять широке застосування в таких сферах, як очищення даних від шуму, зниження розмірності, виявлення аномалій, відновлення зображень та інформаційний пошук. У задачах шумопоглинання автоенкодер опановує узагальнені функції кодування та декодування, що забезпечує стійкість точності реконструкції до спотворень вхідних даних. У контексті зниження розмірності автоенкодери, порівняно з методом головних компонент (PCA) та іншими традиційними підходами, демонструють здатність до ефективного вивчення складних проєкцій даних. Це дозволяє оптимізувати відображення з простору високої розмірності у простір з меншою кількістю ознак. Зазначені характеристики зумовлюють ключову роль автоенкодерів у завданнях виявлення та придушення перешкод.

1.8 Загальнодоступний набір даних про перешкоди

На відміну від інших галузей застосування глибокого навчання, де наявна значна кількість загальнодоступних еталонних наборів даних, дослідження в межах придушення перешкод мають обмежену базу даних. Створення уніфікованого набору даних, придатного для навчання та тестування моделей у різноманітних сценаріях бездротового зв'язку, є складним завданням. Це зумовлено стохастичною природою бездротового каналу, динаміка якого виключає можливість безпосередньої адаптації навчальних даних, згенерованих для одного сценарію, до інших середовищ. Отже, для більшості прикладних задач бездротового зв'язку стандартизовані еталонні набори даних відсутні, що змушує дослідників витратити значні ресурси на генерацію власних даних. Попри відсутність повної репрезентативності, такі набори даних залишаються цінним інструментом для навчання алгоритмів, зокрема при використанні програмно-визначених радіосистем (SDR) для збору інформації в реальних умовах.

Доступність еталонних даних є критичною передумовою ефективності моделей глибокого навчання. У таких сферах, як комп'ютерний зір чи медична біоінформатика, наявність масштабних репозиторіїв (наприклад, MNIST або EMNIST) сприяє розвитку інновацій. При цьому експерти з комп'ютерного зору вказують на обмежену цінність синтетичних даних, оскільки результати їх використання можуть суттєво відрізнятись від показників у реальних («over-the-air») умовах. Зокрема, імітовані середовища з каналом AWGN не здатні

повною мірою відтворити складність реальних сигналів. Незважаючи на дефіцит еталонних ресурсів у сфері придушення перешкод, існують ініціативи та окремі дослідницькі бази даних, які можуть бути адаптовані для розв'язання практичних задач. Тож наведемо огляд таких ресурсів, а також обґрунтуємо методологію перетворення реальних даних шляхом масштабування та регулювання частоти дискретизації для розширення можливостей синтетичного моделювання.

1.8.1 Набір даних про радарні перешкоди

У дослідженні Ristea та співавт. [35] було автоматично згенеровано 48 000 зразків даних автомобільного радара, що містять одне джерело перешкод. Попри обмежений обсяг, цей набір даних є вагомим внеском у розвиток відкритої наукової бази, що спрямована на вирішення завдань придушення перешкод. Автори зафіксували такі технічні параметри, як пропускна здатність, частота дискретизації, центральна частота та час розгортки. Інші показники, зокрема SNR, SIR, амплітуда цілі, відстань та фаза, визначалися шляхом рівномірного розподілу в заданих межах [35].

Сформований набір даних включає три категорії: сигнал у часовій області без перешкод, аналогічний сигнал із перешкодами, а також вектор міток, що містить значення комплексної амплітуди в точці розташування цілі. Вивчення радарних сигналів є критично важливим аспектом через складність моделювання динамічної поведінки радарів та проблеми, спричинені спільним використанням спектра з системами зв'язку.

1.8.2 Набір даних про радіочастотні перешкоди

Набір даних радіочастотних перешкод (RFI) був сформований авторами дослідження [53] шляхом інтеграції сигналу інтересу (SOI) з трьома типами завад: безперервною хвилею (CWI), багатоканальною безперервною хвилею (MCWI) та лінійною частотною модуляцією (CI). Генерація набору даних відбувалася при різних значеннях відношення сигнал/шум (SNR). Корисний сигнал, що представляє відеопотік у реальному часі, було модульовано за допомогою GNU Radio та передано через пристрій Universal Software Radio Peripheral (USRP-N210). Об'єднання сигналу завади з SOI здійснювалося за

допомогою комбайнера, а прийом сигналу виконувався модемом MegaBee. Детальна методологія формування набору даних представлена в роботі [53]. На рис. 1.7 наведено скалограму набору даних RFI, яка демонструє чітку ідентифікацію характерних ознак кожного класу перешкод алгоритмами глибокого навчання.




Рисунок 1.7 - Скалограма набору даних RFI (Ліворуч: оригінальний SOI без перешкод; у центрі ліворуч: SOI з перешкодами від багатоканальних безперервних хвиль; у центрі праворуч: сигнал, що цікавить, з перешкодами від лінійно-модульованих сигналів; праворуч: сигнал з перешкодами від безперервних хвиль)

Скалограма відображає квадратичну амплітуду неперервного вейвлет-перетворення (CWT) - інструменту, що використовується для аналізу нестационарних та перехідних сигналів. CWT є функцією перетворення сигналу, що забезпечує надповне представлення даних шляхом безперервної зміни параметрів зсуву та масштабу вейвлетів. Як зазначено в роботі [53], метод CWT характеризується високою стійкістю до впливу шумів у сигналі.

1.8.3 Набір даних CRAWDAD

Ресурс спільноти для архівування бездротових даних у Дартмуті (CRAWDAD) було створено з метою усунення дефіциту емпіричних даних, отриманих у ході експлуатації діючих бездротових мереж, для глибшого аналізу моделей поведінки користувачів та функціонування пристроїв у реальних умовах [54]. На момент написання цієї роботи репозиторій налічує 125 наборів даних для різноманітних завдань бездротового зв'язку, а кількість користувачів перевищує 14 тисяч осіб зі 120 країн світу [54].

Зокрема, набір даних, представлений Шмідтом та співавт. [43], містить траси передачі пакетів стандартів IEEE 802.11b/g, IEEE 802.15.4 та Bluetooth із варіативними показниками відношення сигнал/шум (SNR) у базовій смузі. Додатково автори інтегрували частотні зсуви в основній смузі [28]. Загальна структура даних охоплює п'ятнадцять класів, десять із яких відповідають пристроям IEEE 802.15.1, три - IEEE 802.11, а два - IEEE 802.15.4.

Архів CRAWDAD також містить два набори даних щодо перешкод, призначені для вимірювання HTTP-запитів через протокол 802.11 у середовищах із високою щільністю бездротових пристроїв, а також масив даних, що включає індикатор сили прийнятого сигналу (RSSI) для кадрів, коректно отриманих вузлами за наявності шумів. Детальнішу інформацію про набори даних CRAWDAD можна отримати у джерелі [54].

1.8.4 Набір даних про бездротові перешкоди

У роботі [55] автори здійснили збір експериментальних даних у чотирьох різнорідних середовищах: без перешкод, з контрольованими перешкодами та у двох середовищах із неконтрольованими завадами від реальних пристроїв. Джерелами перешкод слугували протоколи Bluetooth та Bluetooth Low Energy (IEEE 802.15.1 та IEEE 802.15.1 BLE), ZigBee (IEEE 802.15.4) і WLAN (IEEE 802.11). Сформований набір даних містить понад 110 000 імпульсів перешкод верифікованого походження. Ключовою перевагою дослідження є гетерогенність розглянутих сценаріїв, що забезпечує високу репрезентативність даних та їхню придатність для широкого використання фахівцями у сфері бездротових технологій.

У таблиці 1.2 наведено порівняльний аналіз наборів даних, розглянутих у кваліфікаційній роботі.

Таблиця 1.2 - Порівняння наборів даних про перешкоди

Набір даних (Dataset)	Тип завад (Interference type)	Типи сигналів (Signal Types)
Набір даних радіолокаційних завад (Radar Interference Dataset)	Однорідні завади (Homogeneous technology interference)	3 класи, зокрема: • Сигнал у часовій області із завадами (Time domain signal with interference) • Сигнал у часовій області без завад (Time domain without interference) • Амплітудна інформація для цілей (Amplitude information for targets)
Набір даних радіочастотних завад	Неоднорідні завади	4 класи, зокрема: • Корисний сигнал (Signal of Interest, SOI) • Неперервна завада (Continuous-wave interference, CWI) • Багатокомпонентна неперервна завада (Multi-continuous-wave interference, MCWI) • ЛЧМ-завада (Chirp interference, CI)
Набір даних CRAWDAD	Однорідні та неоднорідні завади	15 класів, зокрема: • Bluetooth (10) • WLAN (3) • ZigBee (2)
Набір даних завад бездротових сигналів	Неоднорідні завади	4 класи, зокрема: • Bluetooth • Bluetooth Low Energy (BLE) • ZigBee • WLAN

2 ТЕХНІКИ ПРИДУШЕННЯ ПЕРЕШКОД НА ОСНОВІ ГЛИБОКОГО НАВЧАННЯ

У цьому розділі проаналізуємо найбільш поширені методи придушення перешкод на основі глибокого навчання. До розглянутих підходів належать згорткові нейронні мережі (CNN), автоенкодери, рекурентні нейронні мережі (RNN) та глибокі нейронні мережі (DNN). Незважаючи на існування інших архітектур глибокого навчання, результати нашого дослідження засвідчують, що саме ці чотири методи є найбільш репрезентативними у фаховій літературі, присвяченій завданням придушення перешкод.

2.1 Придушення перешкод з використанням CNN

Згорткові нейронні мережі (CNN), як приклад безмодельних методів, продемонстрували високу ефективність у широкому спектрі дисциплін, зокрема у радіоідентифікації [51] та класифікації зображень [56]. CNN здатні обробляти необроблені IQ-дані або іншу інформацію канального рівня для автоматичного вилучення унікальних ознак сигналів за наявності завад. Стандартна архітектура CNN передбачає використання згорткових шарів, операцій пулінгу (pooling), функцій активації ReLU та механізмів пакетної нормалізації (рис. 2.1). На відміну від класичних методів машинного навчання, що базуються на ручному виборі ознак, CNN забезпечують автоматичне виявлення найбільш релевантних характеристик, необхідних для ефективного придушення перешкод. Можливість навчання як у часовій, так і у частотній областях робить ці мережі універсальним інструментом для моделювання пристроїв, вихідні дані яких виходять за межі специфічних частотних характеристик.

Хоча в роботах [28, 43] CNN успішно застосовувалися переважно для класифікації завад, сучасні дослідження свідчать про потенціал цих мереж у задачах безпосереднього придушення завад. Зокрема, у праці Rock та співавт. [36] архітектура CNN була використана для ідентифікації структурованої інформації у вхідному сигналі з метою нівелювання перешкод автомобільного радара. Ключовим аспектом даного підходу є видалення шуму та придушення завад на основі навчальної вибірки, що містить як чисті сигнали, так і сигнали з перешкодами. Для калібрування потужності завад та шуму відносно цільового

сигналу застосовувалися метрики відношення сигнал/перешкода (SIR) та відношення сигнал/шум (SNR). Модель, представлена на рис. 2.1, містить початковий згортковий шар з активацією ReLU, чотири проміжні блоки, що включають операції пакетної нормалізації, згортки та ReLU, а також фінальний шар, що складається з пакетної нормалізації та згортки.




Рисунок 2.1 - Архітектура CNN для шумозаглушення радіолокаційних сигналів (N позначає кількість зразків швидкого часу, а M - кількість зразків повільного часу/лінійних змін)

Нормалізація пакетів (batch normalization) зазвичай застосовується в процесі навчання моделей глибокого навчання для прискорення збіжності та стабілізації навчання шляхом стандартизації вхідних даних для кожного міні-пакета. Придушення завад [31] здійснюється з використанням спектрограм вхідних сигналів (розміром 1024 відліки) як вхідних даних для подальшого отримання очищених сигналів на виході.

Згорткові шари в архітектурах CNN часто адаптуються до специфічних артефактів вхідних даних, що сприяє ефективній ідентифікації сигналів завад. Результати досліджень підтверджують, що підхід до придушення на основі CNN перевершує традиційні методи, які не використовують глибоке навчання. Зокрема, модель на базі CNN продемонструвала перевагу над методами обнулення (nulling), фільтрації типу «рампа» (ramp filtering) та IMAT більш ніж на 40% за метрикою відношення сигнал/завада плюс шум (SINR) [36]. Попри зазначені переваги, методи придушення на базі CNN демонстрували вищі показники величини вектора помилки (EVM) порівняно з класичними підходами. У радіолокаційних системах, подібних до розглянутих авторами, високий рівень EVM може спричинити спотворення пікових значень цілей. Варто зауважити, що дослідження Рока та співавт. [36] базувалося на

симуляційній платформі, що обмежує можливість узагальнення результатів для бездротових застосувань (ОТА). Це зумовлено тим, що реальні ОТА-системи зазнають впливу значнішої кількості каналних невизначеностей, таких як затухання, шум, мобільність та інші фактори. Відповідно, для сигналів зв'язку формату QAM, де інформація кодується у фазі сигналу, очікуються відмінні результати.

Аналогічно до роботи [36], Рістя та співавт. [35] застосували повністю згорткову нейронну мережу (FCN - альтернативний архітектурний підхід CNN) для виявлення закономірностей у вхідних даних з використанням обмеженої кількості параметрів. Ними було запропоновано дві архітектури глибокого навчання, які продемонстрували вищу ефективність порівняно з традиційними методами обнулення.

Вхідні сигнали, що містять шум та некорельовані завади, обробляються за допомогою повністю згорткової нейронної мережі (FCN). Головна архітектурна відмінність FCN від стандартних CNN полягає у відсутності повнозв'язного шару, який зазвичай застосовується для вирішення завдань класифікації [40].

Для формування сигналу биття часові дані перетворюються на спектрограму за допомогою короточасного перетворення Фур'є (STFT). Еталонні дані отримують шляхом застосування швидкого перетворення Фур'є (FFT) до розмічених сигналів у часовій області, що дозволяє навчити мережу відображенню вхідних даних STFT на цільові спектри FFT. У сфері бездротового зв'язку для навчання архітектур глибокого навчання часто застосовують I/Q-вибірки. Важливим висновком дослідження є те, що через низьку розмірність I/Q-рядів (рівну 2) використання стандартних фільтрів у згорткових шарах може призвести до перенавчання або невиправданого ускладнення моделі. Застосування фільтрів замалого розміру знижує здатність моделі до узагальнення, оскільки вона стає схильною до вивчення специфічних ознак навчальної вибірки.

У роботі Рока та співавторів [36] досліджено методи квантування на основі CNN для мінімізації або усунення шумів у радіолокаційних сигналах. Особливу увагу приділено оптимізації вимог до пам'яті та обчислювальних ресурсів, оскільки висока складність моделей обмежує енергоефективність та швидкість виконання операцій на вбудованому апаратному забезпеченні. Для вирішення цієї проблеми автори проаналізували потенціал квантування різних архітектур CNN. Отримані результати (рис. 2.2) свідчать, що запропоновані

моделі перевершують традиційні методи зменшення завад (обнулення, IMAT та фільтрування рампами) і демонструють стійкість до різних рівнів та патернів перешкод. Під час тестування на сигналах, отриманих у реальних міських умовах, застосування методів зменшення завад на основі CNN забезпечило покращення співвідношення сигнал-шум (SNR) на 7 дБ.




Рисунок 2.2 - Порівняння CDF показника F1-Score для окремих зразків між двома моделями CNN, методами нульового обнулення, IMAT та Ramp-фільтрування для зменшення перешкод (де x — число з дійсною частиною)

Додатково Фукс та співавт. [37] запропонували використання комплекснозначних згорткових нейронних мереж (CVCNN) для придушення взаємних перешкод в автомобільних радіолокаційних системах. Ключовим завданням дослідження було відновлення фазової складової корисних сигналів на основі дійсної та уявної частин комплексних спектрів. Традиційні алгоритми виявлення об'єктів часто базуються виключно на амплітудних компонентах спектральних карт, що призводить до втрати критично важливої фазової інформації. Попри те, що інтеграція фазових даних підвищує складність алгоритму, використання комплексного аналізу дозволяє обмежити ступені свободи моделі. Автори довели, що таке обмеження сприяє врахуванню фізичних характеристик даних, забезпечуючи більш ефективне перетворення сигналів і загальну оптимізацію архітектури. Розроблена модель CVCNN базується на комплексному аналізі всіх операцій, включаючи комплексну

згортку, нормалізацію пакетів та активаційну функцію ReLU, що дозволяє коректно враховувати взаємозв'язок між дійсною та уявною частинами сигналу. Експериментальні результати підтвердили перевагу CVCNN над методами з дійсними значеннями, зокрема такими як обнулення, RFmin та ІМАТ, за критеріями F1-score, EVM та PPMSE (показник середньоквадратичної помилки фази для виявлених об'єктів).

У контексті практичної реалізації моделі CNN повинні демонструвати високу здатність до узагальнення для забезпечення точності класифікації на тестових вибірках. З метою підвищення ефективності навчання застосовуються методи попередньої обробки, зокрема спектрограми [35] або безперервне вейвлет-перетворення (CWT), які забезпечують збільшення розмірності вхідних даних у часово-частотній області. Перетворення сигналів часової області у двовимірне представлення є визначальним фактором, що дозволяє нейронній мережі ефективніше виділяти репрезентативні ознаки. Зокрема, у роботі [35] використання спектрограми з розмірністю вхідних даних 154×2048 дозволило алгоритму FCN продемонструвати кращі результати за показником площі під кривою характеристик приймача (AUC) порівняно з традиційними методами фільтрації, такими як обнулення.

Варто зазначити, що запропонована методика забезпечує покращення показників SNR та AUC для вихідного сигналу, а не лише для його спектрального представлення. Це підтверджує, що інтеграція традиційних методів попередньої обробки сигналів із технологіями глибокого навчання дозволяє істотно підвищити ефективність придушення завад, мінімізуючи при цьому ризик перенавчання.

Наукова спільнота все частіше впроваджує практику попередньої обробки вхідних даних, що дозволяє раціонально поєднувати переваги класичної теорії обробки сигналів та глибокого навчання. Зокрема, методи попередньої обробки, такі як безперервне вейвлет-перетворення (CWT), виявляються високоефективними при виділенні специфічних ознак пристроїв, зумовлених нелінійністю підсилювачів потужності, похибками генераторів та іншими апаратними характеристиками. У бездротових каналах зв'язку завади та стохастичні чинники можуть суттєво послаблювати ці унікальні атрибути сигналу. Для їх підсилення необроблені IQ-дані доцільно трансформувати за допомогою таких інструментів, як дискретне вейвлет-перетворення (DWT), STFT або перетворення Фур'є. На відміну від останнього, STFT забезпечує

аналіз сигналу на локальних часових інтервалах, а DWT дозволяє отримати розріджене представлення даних.

CWT забезпечує деталізовану візуалізацію частотних компонентів сигналу залежно від часу, виявляючи просторові кореляції, які є малопомітними в оригінальних сигналах. Формування двовимірного представлення дозволяє ефективно виділити індивідуальні особливості передавача, що значно підвищує точність класифікації за допомогою CNN. Завдяки високій роздільній здатності, яка досягається шляхом розкладу сигналу за допомогою масштабованих та зміщених версій материнської вейвлети, CWT є оптимальним вибором для аналізу часових рядів. Результатом такої обробки стає двовимірна матриця, структура якої відображає кореляцію між масштабами та тривалістю сигналу. Доведено, що застосування цього підходу в поєднанні з архітектурами CNN дозволяє суттєво оптимізувати аналітичну ефективність систем [57].

2.2 Придушення перешкод з використанням RNN

У низці досліджень, зокрема [38], для придушення перешкод у роботі автомобільних радарів та одночасного відновлення корисного сигналу застосовувалися рекурентні нейронні мережі (RNN) з архітектурою GRU (Gated Recurrent Units). На відміну від прямопрохідних нейронних мереж, які опрацьовують вхідні дані як незалежні вибірки, RNN враховують часові та послідовні залежності завдяки наявності внутрішніх циклів у структурі мережі. З огляду на послідовний характер збору даних у часовій області, використання RNN є доцільним, що підтверджується високою ефективністю таких моделей під час аналізу послідовних даних. Подібно до інших методів глибокого навчання, RNN продемонстрували вищу ефективність порівняно з пороговим методом у часовій області та методом усунення перешкод у частотній області [34], який призводить до послаблення амплітудної характеристики записаних сигналів (чірпів).

Як впливає з результатів Муна та співавт. [38], використання моделі RNN із блоками GRU дозволило успішно обробити послідовні дані. Проте зазначена модель виявилася недостатньою для повної реконструкції вихідного сигналу за наявності перешкод. Для вирішення цієї проблеми Мун запропонував вдосконалену модель RNN із механізмом самоуваги (self-

attention) для зменшення перешкод у радарях на основі OFDM та FMCW. Для коректного відновлення сигналу модель навчалася на даних про оточення, застосовуючи механізм уваги для точної ідентифікації дальності та швидкості цілі за допомогою БПФ (FFT). Автори використовували блоки уваги для врахування послідовних взаємозалежностей між часовими кроками, оскільки перешкоди розподілені по всьому масиву даних. На рис. 2.3 представлено двовимірний графік FFT сигналу з перешкодами та після їх усунення, що підтверджує ефективність RNN у придушенні радіолокаційних завад. Слід зауважити, що запропонований метод був протестований виключно на модельованих даних, без надання результатів випробувань у реальних умовах експлуатації.




Рисунок 2.3 - Графік, що ілюструє результати двовимірного дискретного перетворення Фур'є (2D FFT) для методу зменшення перешкод на основі RNN.

Ліворуч: з радіолокаційними перешкодами; праворуч: після усунення радіолокаційних перешкод за допомогою RNN

З іншого боку, у роботі Мао та співавт. [39] було досліджено метод придушення завад у глобальних навігаційних супутникових системах (GNSS/GPS) із застосуванням рекурентних нейронних мереж (RNN) на основі фільтра Калмана без обчислення похідних (Unscented Kalman Filter, UKF). Модель UKF-RNN була використана для мінімізації впливу безперервних (CWI), багатотональних, свип-сигнальних та імпульсних завад. Попри те, що RNN демонструють вищу ефективність у моделюванні нелінійних часових рядів порівняно з класичними методами обробки сигналів, висока нестаціонарність певних типів завад потребує використання моделей, адаптованих до таких динамічних змін. Результати дослідження [39]

підтверджують, що алгоритм UKF-RNN забезпечує підвищення відношення сигнал/шум (SNR) та зниження середньоквадратичної похибки прогнозування (MSPE) порівняно з традиційними методами. Зокрема, у контексті нестационарних завад алгоритм UKF-RNN забезпечив приріст SNR у діапазоні від 3,34 дБ до 8,30 дБ відносно інших підходів.

2.3 Придушення перешкод з використанням автоенкодерів

Ще одним ефективним методом глибокого навчання для придушення завад є використання глибоких автоенкодерів. Унікальність автоенкодерів полягає у здатності енкодера ідентифікувати специфічні компоненти завад вхідного сигналу шляхом їхнього представлення у латентному просторі. У дослідженні [41] автори застосували підхід на основі CNN для придушення завад у роботі автомобільних радарів. Подібно до методу, описаного в [36], цей алгоритм використовує механізм шумозаглушення: мережа тренується на парах зашумлених та чистих сигналів. Оскільки ефективність моделей глибокого навчання залежить від обсягу якісних даних, автори забезпечили формування великого масиву даних у вигляді діапазонно-Доплерівських зображень.

Паралельно Лін та ін. [40] запропонували метод із використанням автоенкодерів шумозаглушення для вивчення патернів завад із невідомою структурою, що дозволяє нейтралізувати гетерогенні технологічні перешкоди. Концепція методу полягає у вивченні розподілу вхідних даних для відокремлення та подальшого придушення компонента завад. Важливо підкреслити, що автори не передбачали координатії або синхронізації між передавачем, приймачем та джерелом завад. Для мінімізації витрат на збір даних було застосовано генеративну суперечливу мережу (GAN), яка створювала синтетичні навчальні зразки для тренування автоенкодера, що відновлює чистий Wi-Fi сигнал. Архітектура GAN, що базується на конкуренції генератора та дискримінатора [47], дозволяє генерувати дані, максимально наближені до реальних сигналів. Експериментальна частина дослідження передбачала використання USRP N200 SDR для збору даних під впливом завад від мікрохвильової печі. Ключовим висновком роботи стало підтвердження високої ефективності автоенкодерів у випадках, коли потужність завад перевищує амплітуду корисного сигналу. Значною перевагою цього підходу є відсутність додаткових витрат на передачу службових сигналів, оскільки

алгоритм функціонує в пасивному режимі [40].

Крім того, Чен та співавт. [42] дослідили підхід, що поєднує архітектуру автоенкодера з фільтром виявлення перешкод для їх ефективного придушення в автомобільних радарних системах. Автори встановили, що застосування гейтованої згортки дозволяє мережі енкодера ідентифікувати структуру корисного сигналу, очищеного від завад, тоді як мережа декодера відновлює компоненти сигналу, що містять перешкоди. Результати дослідження підтверджують, що цей метод забезпечує підвищення відношення сигнал/шум плюс завади (SINR) та гарантує надійність радарних вимірювань навіть у складних умовах, які не були включені до навчальної вибірки. На рис. 2.4, запозиченому з [42], представлено залежність SINR (у дБ) від частки відкинутих вибірок для різних методів обробки, зокрема обнулення, авторегресійних (AR) моделей, автоенкодерів та вихідних сигналів. Аналіз показує, що при відсіканні 15% і більше вибірок показники SINR для методів AR та обнулення суттєво знижуються, тоді як автоенкодер демонструє вищу стабільність характеристик.




Рисунок 2.4 - Порівняння методу зменшення перешкод на основі автоенкодера з обнуленням та авторегресійними моделями

Методи на основі каналних автоенкодерів також застосовуються для спільної оптимізації передавачів і приймачів з метою ефективного придушення завад. Зокрема, у роботі Егрек та ін. [41] досліджено підхід до придушення перешкод у MIMO-системах, де кодер і декодер проходять спільне навчання в умовах наявності завад. Автори розглянули сценарій гауссових завад, що діють

у межах того самого каналу, який використовується для передачі корисного сигналу. Запропонована методика базується на використанні структури сигналу завади для мінімізації частоти помилок на символ (SER).

Згідно з отриманими результатами, для системи конфігурації 2×2 при SINR понад 16 дБ модель на основі автоенкодера демонструє значно вищу ефективність порівняно з базовою моделлю (SISO-система з модуляцією QPSK без канального кодування та впливу завад). Ключовою перевагою спільного навчання приймально-передавального тракту в архітектурі автоенкодера є здатність приймача адаптивно пригнічувати завади, що забезпечує перевагу над традиційними методами. Попри те, що використання канального кодування може підвищувати результативність базових рішень, підхід, описаний у [41], демонструє кращі показники порівняно з некодованими системами завдяки механізму активного усунення завад. Крім того, автори підтвердили, що продуктивність автоенкодера зростає пропорційно тривалості процесу навчання мережі на кожному рівні SINR.

2.4 Придушення перешкод з використанням глибоких нейромереж

Далі розглянемо методи глибинного навчання, що базуються на використанні глибоких нейронних мереж (DNN) для придушення перешкод. Варто зазначити, що значна частина алгоритмів глибинного навчання може розглядатися як підкатегорії DNN. У межах цього розділу аналізуються нейронні мережі без згорткової структури, які містять щонайменше чотири шари, включаючи вхідний та вихідний.

Методи на основі DNN є особливо ефективними для придушення самоінтерференції (SI), оскільки вони дозволяють успішно оптимізувати велику кількість параметрів при значно нижчій обчислювальній складності. Зокрема, у роботі Muranov та ін. [58] запропоновано два підходи на основі DNN для мінімізації нелінійної самоінтерференції у повнодуплексних релейних каналах, адаптовані до часонезалежних та часозалежних нелінійних спотворень відповідно. В обох випадках використовувалася повнозв'язна нейронна мережа з двома прихованими шарами та активаційною функцією ReLU. Для першого методу DNN застосовувалася для оцінки часонезалежних нелінійних спотворень, після чого для оцінки SI у часозмінному каналі використовувався метод найменших квадратів. Другий метод передбачав застосування навчання з

перенесенням (transfer learning) для оцінки часозалежних спотворень: сигнал SI розділявся на лінійні та нелінійні компоненти, після чого лінійна складова віднімалася, а залишкова частина подавалася на вхід DNN.

На рис. 2.5 представлено порівняння розглянутих підходів - компенсації часонезалежних (TID) та часозалежних (TVD) нелінійних спотворень - з іншими існуючими методами скасування SI. Варто зауважити, що компенсатор на основі DNN, запропонований у [24], є окремою технікою придушення нелінійних перешкод, розробленою як альтернатива традиційним методам, що базуються на поліноміальних базисних функціях. Подібно до підходу [58], DNN застосовувалася для моделювання нелінійної складової цифрового сигналу. Ключова відмінність полягає в тому, що в роботі [24] використовувався лише один прихований шар, що забезпечило вищу обчислювальну ефективність. Таке рішення зумовлене метою дослідження - оптимізацією складності порівняно з не-DNN методами, такими як поліноміальні придушувачі.




Рисунок 2.5 - Порівняння методів придушення самоперешкод на основі DNN з методами, що не базуються на DNN

У межах іншого дослідження, присвяченого придушенню завад від власного сигналу (SI), Гуо та співавт. [59] застосували метод глибоких нейронних мереж (DNN) для компенсації нелінійних складових SI. Збір даних каналу здійснювався за допомогою програмно-визначеного радіокомплексу (USRP) у різних сценаріях передачі графічних, текстових та числових даних. Архітектура запропонованої DNN охоплює два приховані шари з функціями активації ReLU. Результати дослідження продемонстрували стабільність, швидкодію та високу точність моделі при компенсації SI.

Своєю чергою, Ші та співавт. [57] проаналізували застосування прямої нейронної мережі (NN) для реконструкції сигналу SI. На початковому етапі використовувався адаптивний лінійний фільтр для вилучення характеристик

сигналу основної смуги, які згодом слугували вхідними даними для навчання NN. Як і в роботі [24], архітектура мережі передбачає один прихований шар, що зумовлює схожі функціональні обмеження.

Варто зауважити: попри те, що методи на базі DNN демонструють вищу ефективність порівняно з традиційними підходами в різномірних каналних умовах та системах модуляції, окремі альтернативні методи придушення SI забезпечують нижчу обчислювальну складність або потребують менших апаратних ресурсів. Таким чином, нейромережеві підходи не завжди мають перевагу над методами, що базуються на поліноміальній апроксимації.

Альтернативне дослідження [37], присвячене придушенню перешкод за допомогою глибоких нейронних мереж (DNN), представлено роботою Ху та співавторів, у якій розроблено метод мінімізації інтерференції для систем неортогонального множинного доступу (NoMA). У системах на основі OFDM ортогональність піднесучих дозволяє усунути міжсимвольні перешкоди; проте використання циклічного префікса (CP) та рознесення піднесучих призводять до зниження спектральної ефективності через додаткові накладні витрати. Натомість алгоритми NoMA, зокрема спектрально ефективне частотне мультиплексування (SEFDM), застосовують неортогональні піднесучі, що спричиняє виникнення міжпіднесучих перешкод (ICI).

У роботі [37] автори запропонували чотиришарову DNN із двома прихованими шарами та сигмоїдною активаційною функцією на кожному рівні. Навчання моделі здійснювалося в офлайн-режимі на вибірці з 40 000 QAM-символів, згенерованих на основі випадкових даних. Оцінка ефективності проводилася за допомогою показника частоти бітових помилок (BER). Дослідження підтвердило здатність DNN ефективно придушувати ICI у сигналах SEFDM, забезпечуючи значне покращення показника SNR порівняно з традиційними детекторами жорсткого прийняття рішень. Також встановлено, що продуктивність мережі залежить від архітектурних особливостей: зокрема, порівнювалися архітектури незалежних нейронних мереж (N-NN) та мереж із частковими зв'язками (P-NN), де в межах однієї підмережі об'єднувалися два символи.

Крім того, Promsuk та ін. [60] запропонували алгоритм багатошарового Багатошаровий перцептрон (MLP) застосовується для зниження рівня суміжних каналних перешкод (ACI) у мережах IoT. У межах запропонованої моделі як вхідні дані використовуються результати швидкого перетворення Фур'є (FFT)

та амплітудні характеристики. Вхідні сигнали, модульовані за допомогою BPSK та 16QAM, було синтезовано з урахуванням втрат у тракці поширення та загасання, що дозволило максимально наблизити умови моделювання до реальних параметрів мереж IoT. Для оптимізації процесу придушення АСІ автори інтегрували MLP з фільтром мінімальної середньоквадратичної похибки (MMSE). При використанні амплітудних даних модель забезпечує оцінку амплітуди сигналу перешкоди, яка надалі обробляється згідно з математичним апаратом, описаним у [60]. У разі використання даних FFT модель генерує оцінку спектра перешкоди, після чого виконується зворотне перетворення Фур'є. Емпіричні результати підтвердили, що MLP-модель за обома типами вхідних даних демонструє вищі показники точності (Accuracy, Precision, Recall та F1-score) порівняно з методами, що базуються виключно на MMSE.

У дослідженні Mosavi та співавт. [61] розглянуто метод придушення вузькосмугових перешкод у навігаційних системах GPS, що базується на архітектурі DNN. Запропонований підхід поєднує адаптивні режекторні фільтри з простою структурою нейронної мережі. Перевагою цього методу є висока швидкість навчання, досягнута за рахунок використання адаптивних фільтрів замість стандартного оновлення ваг та порогів, притаманного MLP. Такий підхід мінімізує обчислювальну складність, що робить його перспективним для апаратної реалізації [61]. Результати моделювання засвідчили значне покращення відношення сигнал/шум (SNR) за наявності однотональних (SCWI) та багатотональних (MCWI) безперервних перешкод порівняно з моделями MLP, RNN та іншими комбінованими алгоритмами.

Ши та співавт. [62] запропонували метод придушення перешкод у системах із прямим розширенням спектра (DSSS), що базується на поєднанні вейвлет-пакетного перетворення з розподілом потужності (PDP-WPT) та розширеної нейронної мережі зі зворотним поширенням (EBPNN). Запропонований алгоритм передбачає поетапне відстеження сигналу перешкоди з подальшою ідентифікацією переданого сигналу засобами EBPNN. Дослідження доводить, що цей метод забезпечує ефективне усунення інтенсивних перешкод зі збереженням високої кореляції сигналів. Запропонована техніка демонструє нижчу середньоквадратичну похибку (MSE) та швидшу збіжність порівняно з традиційними методами придушення перешкод у часовій області [62].

Отже, застосування глибоких нейронних мереж (DNN) є ефективним

інструментом для моделювання та фільтрації перешкод. Ключовою перевагою DNN порівняно з аналітичними моделями є їх здатність адаптуватися до реальних недосконалостей середовища передачі даних. Нижче наведено порівняльний аналіз розглянутих технік глибокого навчання, що дозволяє виявити доцільність їх використання у задачах придушення перешкод та оцінити потенційні виклики під час їх впровадження.

3 ПОРІВНЯЛЬНИЙ АНАЛІЗ ДОСЛІДЖЕНИХ МЕТОДІВ ГЛИБОКОГО НАВЧАННЯ

У таблиці 3.1 представлено огляд обраних методів глибокого навчання, що застосовуються в актуальних наукових дослідженнях у сфері придушення завад. Аналіз охоплює такі параметри, як сфера застосування (тип завад), архітектури нейронних мереж, характеристики наборів даних та метрики оцінки ефективності. До розглянутих типів завад належать, зокрема, радіолокаційні, оптичні та перешкоди, характерні для різних стандартів бездротового зв'язку. Результати дослідження свідчать про переважання використання згорткових нейронних мереж (CNN) для завдань відхилення або придушення завад порівняно з іншими методами глибокого навчання.

Таблиця 3.1 - Аналіз набору даних та порівняння ефективності вибраних методів придушення перешкод на основі глибокого навчання

Алгоритм глибокого навчання (DL Algorithm)	Область застосування / Тип завад	Тип набору даних (Dataset type)	Розмір набору даних (Dataset Size)	Метрика ефективності (Performance Metric)
CNN [71]	FMCW радары	Моделювання	48k	SNR, площа під робочою характеристикою приймача (AUC), середня абсолютна похибка (MAE) в дБ
CNN [72]	FMCW радары / Послідовність ЛЧМ-сигналів (CS)	Моделювання	2250 сценаріїв	SINR; EVM
CNN [73]	FMCW радары / CS	Моделювання та ОТА + змодельовані завади	3k карт дальності-Доплера (RD)	F1-міра; Амплітудні спектри дальності-Доплера; SNR
CNN [74]	FMCW радары / CS	ОТА + змодельовані завади	2.5k карт дальності-Доплера (RD)	F1-міра; EVM; PPMSE
DNN [75]	Оптичні системи зв'язку	Моделювання	40k	Коефіцієнт бітових помилок (BER)
Learned DBP [76]	Нелінійні завади в оптичних системах зв'язку	Моделювання	Невідомо	Потужність передачі відносно Q-фактора

Продовження таблиці 3.1

Artificial Neural Network - Multi-layer Perceptron (MLP) [77]	Мережа IoT	Моделювання	Невідомо	Кумулятивна функція розподілу (CDF) для BER
DNN [78]	Вузькосмугові завади для систем GPS-навігації	Моделювання	62.854k тестових зразків	SNR; RMS
DNN - Extended backpropagation NN (EBPNN) [79]	Система із розширенням спектра прямою послідовністю (DSSS)	Моделювання	Невідомо	BER; MSE; Значення кореляції
DNN [80]	Повнодуплексний ретрансляційний канал зв'язку	Моделювання	8k (розмір навчальних даних)	BER; SNR
DNN [81]	Внутрішньосмуговий повнодуплексний бездротовий зв'язок	Моделювання та ОТА	Невідомо	MSE; BER
Feed Forward Neural Network [82]	Повнодуплексні бездротові системи зв'язку	Моделювання	Невідомо	PSD (спектральна щільність потужності)
Neural Network [83]	Повнодуплексні радіосистеми	Апаратний експеримент	Невідомо	Пропускна здатність, Ефективність, Придушення власної завади (SI) в дБ
Feed Forward Neural Network [85]	CDMA з прямою послідовністю (DS-CDMA)	Моделювання	Невідомо	BER, SINR, SNR
Gated Recurrent Units (GRU), recurrent neural network (RNN) [86]	Завади в часовій області для радарів із ЛЧМ-послідовністю	Моделювання	150k	Відношення сигналу до залишкового шуму завади (SRINR)
Attention RNN [87]	Трикутний FMCW; CS; багаточастотна маніпуляція (MFSK); завади OFDM радарів	Моделювання	150k	SINR; Двовимірне швидке перетворення Фур'є (2D-FFT)
RNN [88]	Однотональна CWI; Багатотональна CWI (MCWI); Імпульсна CWI, лінійний FMCW	Моделювання	Невідомо	Покращення SNR; середня квадратична помилка прогнозування (MSPE)
Denoising Autoencoders (DAE) [91]	Неоднорідні технологічні завади (Wi-Fi, ZigBee, LTE-U)	ОТА, синтетичні (дані, розширені за допомогою GAN)	8.7k	Коефіцієнт символічних помилок (SER), відношення сигнал/шум (SNR), потужність завади (дБм)

Продовження таблиці 3.1

Autoencoder-based convolutional neural network [92]	FMCW радары	ОТА	8.78k	Величина вектора помилки (EVM), відношення сигнал/завада+шум (SINR), індекс абсолютної та фазової структурної подібності (SSIM)
Autoencoder [98]	FMCW/CS для автомобільних радарів	Змодельовані навчальні дані; реальні дані ОТА для валідації	2k	SINR
Linear regression (LR) without regularization [99]	Бездротові сенсорні мережі	Моделювання	Невідомо	Оцінка класифікатора; коефіцієнт отримання пакетів (PRR); економія заряду батареї

3.1 Алгоритм глибокого навчання

Алгоритми глибокого навчання охоплюють як методи навчання з учителем, зокрема звичайні глибокі нейронні мережі (DNN), CNN та RNN, так і методи навчання без учителя, такі як автокодер. Останні використовують архітектуру «кодер-декодер» для вивчення характеристик завад на основі вхідних даних з подальшим їх усуненням із сигналів. Варто зазначити, що в окремих дослідженнях компоненти автокодера інтегруються з алгоритмами навчання з учителем, такими як CNN. Попри те, що ефективність методів глибокого навчання здебільшого залежить від обсягу даних, у роботах [36, 40] використані вибірки є порівняно обмеженими, що суперечить рекомендаціям щодо складності вибірки, наведеним у дослідженні [57].

3.2 Тип набору даних

Крім того, проаналізовано типи наборів даних, що застосовуються для вирішення зазначених завдань. У низці досліджень використовувалися ОТА-дані (Over-the-Air), отримані в результаті вимірювань за допомогою реальних апаратних передавачів та приймачів у натурних умовах. В інших працях застосовувалися симуляційні набори даних, згенеровані засобами MATLAB, NS-3 та аналогічних середовищ моделювання. Окремі автори послуговувалися синтетичними даними, що часто є комбінацією симульованих та емпіричних

показників. У деяких роботах [36, 42] практикувалося навчання моделей на симуляційних даних із наступним тестуванням на реальних ОТА-даних. Попри наявність численних надійних моделей, припущення, закладені в їхню основу, не завжди відповідають реальним умовам передачі сигналів ОТА, що негативно позначається на сприйнятті таких результатів професійною спільнотою. Як свідчать останні дослідження, інтеграція ОТА-даних із симуляційними, а також використання розширених (синтетично модифікованих ОТА) даних дозволяє оптимізувати необхідний обсяг навчальних вибірок.

3.3 Показники ефективності

Основними показниками ефективності систем є частота бітових помилок (BER), частота символічних помилок (SER), SNR, SINR, EVM, відношення сигнал/залишковий шум та інтерференція (SRINR), потужність інтерференції, коефіцієнт успішного прийому пакетів (PRR), F1-метрика, PPMSE та середньоквадратична похибка прогнозування (MSPE). У дослідженні Ху та ін. [37] для оцінки методології придушення перешкод використано графічну залежність BER від оптичного відношення сигнал/шум (OSNR), при цьому здійснено порівняльний аналіз традиційної техніки жорсткого прийняття рішень та алгоритмів глибоких нейронних мереж. Важливо зазначити, що для статистичної достовірності оцінки BER, враховуючи робочі діапазони значень від 10^{-1} до 10^{-9} , потрібна обробка значних масивів даних для фіксації 10–100 помилок. Цей показник є стандартом у комп'ютерному моделюванні для аналізу продуктивності цифрових систем зв'язку.

Аналогічно, показник SER, який визначається як відношення кількості помилкових символів до загального обсягу переданих даних, зазвичай візуалізується залежно від SNR. Метрика SNR широко застосовується для параметризації продуктивності систем обробки сигналів за умови гаусового розподілу шуму, що забезпечує інтуїтивно зрозумілу оцінку якості зв'язку. Зокрема, Лін та ін. [40] використовували графіки SER залежно від потужності перешкод для порівняння ефективності власного автоенкодера з функцією шумозаглушення. Для аналізу дієвості методів глибокого навчання у придушенні завад, автори [40] порівняли характеристики Wi-Fi сигналів до та після фільтрації, використовуючи залежність SNR від потужності перешкод. Вихідні показники нейронної мережі у поєднанні з порівнянням очищеного

сигналу з еталонним (без завад) дозволяють об'єктивно оцінити ефективність застосованого підходу.

SINR характеризує відношення потужності цільового сигналу до сумарної потужності інтерференції та фонового шуму. У сфері радіолокаційних технологій відношення потужності відбитого сигналу до середньої потужності залишкових завад після їх усунення визначається як SRINR [34]. Цей показник був застосований у роботі Муна та ін. [38] для порівняльної оцінки ефективності алгоритмів придушення завад в автомобільних системах на базі рекурентних нейронних мереж (RNN).

Більшість методів придушення перешкод на основі глибокого навчання, проаналізованих у розділі 2, базуються на припущенні про офлайн-навчання [37, 40], у зв'язку з чим питання часової складності процесу навчання зазвичай залишаються поза увагою. На відміну від комп'ютерного зору, обробки природної мови та інших сфер інтенсивного впровадження методів глибокого навчання, у значній частині фахової літератури з придушення перешкод бракує аналізу часової чи обчислювальної складності алгоритмів. Натомість складність моделі переважно оцінюється через кількість параметрів, що підлягають навчанню: зі зростанням їхньої кількості підвищується і складність самої архітектури. Так, у роботі Rock et al. [36] представлено шість моделей з варіативним рівнем складності, що зумовлено різною кількістю параметрів. До ключових чинників, що визначають складність моделі, належать розміри ядер (фільтрів), кількість шарів, кількість ядер у шарі, а також кількість шарів субдискретизації (pooling layers), що застосовуються в архітектурах CNN. Варто зазначити, що в більшості опрацьованих джерел детальна інформація про часову та модельну складність відсутня. У таблиці 3.2 наведено узагальнені показники складності моделей для тих досліджень, де ці дані були доступні. Оскільки часова та модельна складність є критично важливими аспектами практичної реалізації в глибокому навчанні, автори вбачають перспективним напрямом подальших досліджень детальний аналіз усіх згаданих чинників.

Крім того, розглянуто інші поширені показники ефективності, характерні для літератури з глибокого навчання, які, попри нетиповість для систем бездротового зв'язку, можуть бути релевантними для оцінки якості придушення перешкод.

Таблиця 3.2 - Параметри складності моделей для вибраних методів придушення перешкод на основі глибокого навчання

Алгоритм глибокого навчання	Вхідні набори даних, розмір	Модель	Кількість шарів	Розмір ядра	Кількість параметрів
CNN	1024 x 128 x 2	Модель А	4	2 ядра розміром 3 x 3	160
		Модель В	8	8 ядер розміром 3 x 3	3,898
		Модель С	4	16 ядер розміром 3 x 3	5,208
		Модель D	6	16 ядер розміром 3 x 3	10,002
		Модель E	8	16 ядер розміром 3 x 3	14,706
		Модель F	6	32 ядра розміром 3 x 3	38,434
CNN	2x128		9 (2 шари згортки, 2 шари максимального об'єднання, 1 плоский шар і 4 щільні шари)	128 фільтрів розміром 2 x 8 64 фільтри розміром 1 x 16	324,330
CNN	154 x 2048		15 шарів (12 шарів згортки з 3 шарами об'єднання)	5x 5 фільтрів	Н/Д
	1024 x 2048		21 шар (15 шарів згортки з 6 шарами об'єднання)		
CNN	10000 x 2 x 1024		2 шари	Перший шар: 128 фільтрів розміром 1 x 8	Н/Д
				Другий шар: 64 фільтри розміром 1 x 1	

Параметр AUC

Показник AUC є загальноприйнятим інструментом оцінювання якості моделей класифікації при різних порогових значеннях. Робоча характеристика приймача (ROC) відображає ймовірнісні показники, тоді як площа під цією кривою (AUC) кількісно визначає здатність моделі до дискримінації класів. Фактично, даний показник демонструє спроможність моделі розрізняти об'єкти різних класів, базуючись на співвідношенні частки істинно позитивних (TPR) та хибнопозитивних (FPR) результатів. Вищі значення AUC свідчать про вищу ефективність класифікації. У дослідженні Ristea та співавторів [35] цей показник було використано для порівняльного аналізу розробленого методу придушення з традиційними підходами. У контексті даної роботи наближення значення AUC до 1 інтерпретувалося як підвищення точності моделі. Результати дослідження підтвердили, що глибока повністю згорткова нейронна мережа демонструє вищу ефективність порівняно з методами, що не базуються на глибокому навчанні (зокрема, обнуленням), як на валідаційній, так і на тестовій вибірках.

Середня абсолютна помилка (MAE)

MAE є додатковим показником ефективності, що визначає величину похибки між фактичними та прогнозованими значеннями. Зокрема, у роботі [35] за допомогою MAE обчислювалася різниця (у дБ) між амплітудою профілю діапазону цілей, отриманою на основі еталонних сигналів, та амплітудою, розрахованою за прогнозованими сигналами. Подібно до метрик SNR та AUC, показник MAE у [35] було використано для порівняння ефективності запропонованого методу придушення перешкод з альтернативними підходами. Таким чином, цей індикатор є придатним для використання на рівні прикладного застосування.

Амплітуда вектора помилки (EVM)

EVM (Error Vector Magnitude) визначається як середньоквадратичне значення (RMS) амплітуди вектора похибки - двовимірний вектор в I/Q-площині, що відображає відхилення між спотвореним та еталонним сигналами, нормоване до амплітуди ідеального сигналу. У дослідженні Fuchs та співавторів [41] показник EVM було застосовано для порівняння вихідних та прогнозованих зображень. Rock та співавтори [36] також використовували EVM для оцінки ефективності розробленої схеми порівняно з існуючими передовими рішеннями. Отже, цей показник є стандартизованою метрикою для аналізу I/Q-даних.

Індекс структурної схожості (SSIM)

Індекс SSIM традиційно застосовується для якісної візуальної оцінки. Згідно з результатами досліджень, він демонструє вищу ефективність порівняно із середньоквадратичною похибкою (MSE). Як зазначається у роботі [40], цей показник дозволяє порівнювати такі характеристики зображення, як яскравість, контраст і структурні особливості. Це є особливо доцільним при усуненні завад, оскільки дозволяє зберігати пікові значення об'єктів, що зумовлені впливом перешкод. Відповідно, Фукс та співавтори [40] використали цей підхід для порівняння еталонного спектра без завад із реконструйованим спектром після їх видалення. Таким чином, цей метод є придатним до застосування у випадках, коли вихідні дані можуть бути представлені як двовимірний масив I/Q.

4 ПЕРЕВАГИ ТА НЕДОЛІКИ СХЕМ ПРИДУШЕННЯ ПЕРЕШКОД НА ОСНОВІ ГЛИБОКОГО НАВЧАННЯ

У цьому розділі наведено порівняльний аналіз переваг та недоліків методів придушення перешкод на основі глибокого навчання. Оцінка цих аспектів є критично важливою, оскільки попри високу ефективність, застосування глибокого навчання супроводжується певними обмеженнями. Розуміння цих нюансів дозволяє глибше досягнути функціональне призначення алгоритмів та зробити обґрунтований вибір відповідно до конкретних технічних потреб. Детальну інформацію щодо характеристик кожної техніки систематизовано в таблиці 4.1

Незважаючи на прогрес у впровадженні алгоритмів глибокого навчання для придушення перешкод, залишається низка викликів, які необхідно вирішити до етапу промислового впровадження. Варто зауважити, що окремі з цих проблем є релевантними й для інших задач бездротового зв'язку, що базуються на методах глибокого навчання.

Таблиця 4.1 - Переваги та недоліки підходів до придушення перешкод на основі глибоких нейронних мереж.

Алгоритм глибокого навчання (DL Algorithm)	Технічний підхід (Technical Approach)	Переваги (Benefits)	Недоліки (Drawbacks)
Convolutional neural network (CNN)	• Некорельовані завади вивчаються за допомогою повнозв'язної згорткової мережі (FCN). • Короткочасне перетворення Фур'є використовується для перетворення сигналу з часової області у спектрограму. • CNN застосовується для шумозаглушення і придушення завад з використанням як чистих даних, так і даних із завадами.	• Алгоритми CNN перевершують традиційні методи придушення, такі як занулення (zeroing), фільтрація похилої поверхні (ramp filtering) та методи ІМАТ. • Дуже ефективні для навчання, коли обсяг доступних даних є відносно невеликим. • Подібно до автокодувальників, CNN можуть успішно використовуватися безпосередньо для шумозаглушення.	• Може призвести до дуже високого значення EVM порівняно із зануленням, фільтрацією похилої поверхні та ІМАТ. • Високе значення EVM також може викликати серйозні спотворення в радіолокаційних застосуваннях. • Зазвичай вимагає великого обсягу оперативної пам'яті для навчання на великих наборах даних.

Продовження таблиці 4.1

Deep neural network (DNN)	• DNN можуть бути корисними для скасування завад у системах неортогонального множинного доступу (NoMA). • Багатошарові перцептрони (MLP) можна поєднувати з фільтрами для ефективного придушення завад. • Алгоритми NoMA використовують неортогональні піднесучі, що може призвести до міжканальних завад (ACI). • Ефективність роботи прямо залежить від характеристик форми сигналу. • Зазвичай вони є структурно простішими порівняно з іншими складними архітектурами глибокого навчання.	• Корисні для послаблення нелінійних завад та загального зниження обчислювальної складності. • DNN здатні пригнічувати міжсимвольну/міжнесучу інтерференцію (ICI) в певних формах сигналів. • Здатні оптимізувати величезну кількість параметрів для ефективного придушення власної завади (SI). • Можуть використовуватися для зменшення математичної складності при обробці нелінійного придушення завад. • Забезпечують приріст SNR порівняно з методами, які використовують детектори жорстких рішень.	• Висока обчислювальна складність на етапі навчання. • Дослідження на основі моделювання, які використовують DNN, є дуже чутливими до нереалістичних або спрощених припущень. • Може призвести до меншої середньоквадратичної помилки (MSE) порівняно з традиційними методами. • Нестабільна складність (зміна кількості прихованих шарів, параметрів тощо) в моделі DNN може призвести до значного погіршення підсумкової ефективності.
Recurrent neural network (RNN)	• Динаміку послідовностей можна фіксувати за допомогою RNN завдяки структурі взаємопов'язаних вузлів. • Завади можна пригнічувати безпосередньо в часовій області для радіолокаційних систем. • Переданий сигнал повністю відновлюється навіть за наявності різноманітних сигналів завад. • Зазвичай вони використовуються, коли вхідні дані мають часову кореляцію.	• Низька затримка. • Корисні для застосувань, де частота сигналу змінюється лінійно. • RNN з блоками уваги можуть ефективно вловлювати послідовні зв'язки між часовими кроками. • Висока точність при відновленні оригінального вигляду корисного сигналу. • RNN здатні працювати з довільною довжиною вхідних або вихідних послідовностей.	• RNN вразливі до відомої проблеми вибуху або згасання градієнта (exploding/vanishing gradient). • Більшість існуючих реалізацій тестувалися виключно на змодельованих (синтетичних) даних для придушення завад. • Для деяких специфічних застосувань методи на основі RNN мають низьку швидкість збіжності, через що нездатні відстежувати швидкі завади, які динамічно змінюються в часі.
Autoencoders (Denoising AE and CNN-based AE)	• Автокодувальник на основі CNN використовується для очищення від завад двовимірних зображень дальності-Доплера (RD). • Автокодувальник застосовується для вивчення статистичного розподілу компоненти завади з метою її подальшого віднімання. • Сигнал відновлюється без попередніх знань про структуру символів та імпульсну характеристику.	• Використання вимірювань реальних фізичних даних додатково покращує стабільність та ефективність методів AE. • Шумозаглушуючі автокодувальники (DAE) працюють чудово, коли потужність завади значно перевищує амплітуду корисного сигналу. • Як правило, AE не створюють додаткових накладних витрат на сигналізацію.	• Методи автокодувальників часто демонструють незадовільні результати за низьких значень SNR. • AE працюють неефективно у разі недостатньої кількості даних для навчання. • Вимагають значного часу обробки, тривалого підбору гіперпараметрів, а також обов'язкової додаткової валідації моделі.

4.1 Відсутність інтерпретованості алгоритмів глибокого навчання

Однією з ключових проблем застосування методів глибокого навчання для класифікації перешкод є недостатня інтерпретованість моделей.

Інтерпретованість визначається як ступінь прозорості моделі та можливість обґрунтування її рішень після завершення обробки даних. Вказана характеристика є критично важливою для завдань придушення перешкод, оскільки сприяє ефективній ідентифікації джерел завад або пристроїв, що несанкціоновано використовують спектр у межах парадигми опортуністичного доступу (зокрема, у діапазонах ISM). Це зумовлює об'єктивну потребу впровадження концепції інтерпретованого штучного інтелекту. Розгляд моделей глибокого навчання як «чорних скриньок» суттєво обмежує рівень довіри кінцевих користувачів до таких систем. Крім того, зі зростанням ефективності алгоритмів глибокого навчання в контексті придушення перешкод виникають актуальні питання забезпечення конфіденційності, що відповідає аналогічним тенденціям в інших сферах застосування ШІ.

4.2 Стохастичність бездротового каналу

Додатковою проблемою застосування методів глибокого навчання (DL) для придушення завад є стохастична природа бездротових каналів. Більшість опрацьованих досліджень базуються на навчанні моделей в обмежених умовах (наприклад, у каналах без відбитків або з адитивним білим гаусовим шумом). Проте в реальних мережевих інфраструктурах тестові сигнали зазнають впливу динамічних змін каналних середовищ, що знижує здатність навчених моделей до адаптації. У зв'язку з варіативністю радіочастотних умов, критично важливим є забезпечення інтерпретованості DL-моделей для їхньої ефективної роботи в різних середовищах. Будь-яка розбіжність між навчальним та тестовим середовищами може негативно вплинути на продуктивність алгоритмів. У цьому контексті розробка ефективних підходів на основі генеративних суперечливих мереж (GAN) для синтезу навчальних даних є перспективним напрямком.

Враховуючи високі вимоги до обсягу даних для навчання DL-моделей, виникає дилема між їхньою якістю та кількістю, що суттєво ускладнює впровадження цих алгоритмів. Процес збору та маркування даних у межах навчання з учителем є надзвичайно трудомістким.

Для вирішення проблеми дефіциту даних дослідники часто звертаються до методів аугментації. Якщо в задачах комп'ютерного зору ефективними є прості трансформації (дзеркальне відображення, обрізання, обертання), то для I/Q-даних, що використовуються при придушенні завад, вони є непридатними. Це зумовлює використання складніших генеративних моделей, таких як GAN та варіаційні автоенкодері (VAE), для створення нових даних, які відповідають розподілу навчальної вибірки. Проте в задачах бездротового зв'язку, зокрема придушення завад та класифікації випромінювачів, такі методи мають обмежений успіх, оскільки алгоритми часто «заучують» шумові компоненти та небажані артефакти сигналу. Незважаючи на складність розширення наборів даних через стохастичність радіочастотного середовища, дослідження Кларка та ін. [63] підтверджують, що комбінування реальних (OTA) даних, модельованих даних та синтетично модифікованих OTA-даних дозволяє ефективно оптимізувати обсяг необхідних навчальних вибірок.

4.3 Необхідність дослідження часової та модельної складності

Важливість комплексного аналізу часової та структурної складності алгоритмів глибокого навчання є незаперечною. Як правило, підвищення складності моделі зумовлює зростання потреби в обчислювальних ресурсах та часі виконання. Аналіз часової складності є інструментом оцінки ефективності навчання та валідації моделі у співвідношенні з показниками її точності. Крім того, часова складність безпосередньо залежить від технічних характеристик апаратного забезпечення. Зокрема, графічні процесори (GPU) демонструють вищу швидкість обробки даних порівняно з центральними процесорами (CPU) завдяки архітектурній адаптованості до складних математичних операцій, властивих глибокому навчанню. Можливість паралельного виконання ідентичних завдань у великих обсягах, яку надають сучасні графічні прискорювачі, суттєво оптимізує продуктивність та скорочує тривалість обчислювальних процесів.

Розуміння складності моделі є фундаментальним аспектом для оцінки її потенціалу та функціональних обмежень. Відповідно до класифікації, запропонованої Ну та співавт. [64], складність моделей глибокого навчання диференціюється на виражальну здатність та ефективну складність. Виразальна здатність, що є похідною від параметризації архітектури, визначає теоретичну межу обсягу інформації, яку здатна засвоїти модель. Водночас

ефективна складність відображає реальний обсяг знань, здобутих моделлю під час навчання на конкретному наборі даних, і, як правило, є нижчою за виражальну здатність.

Попри значущість цих показників, багато досліджень у сфері придушення завад на основі глибокого навчання не приділяють їм належної уваги. Відтак, існує потреба в системному висвітленні питань часової та структурної складності в науковій літературі, що дозволить дослідникам глибше розуміти принципи роботи алгоритмів та проектувати ефективні моделі, адаптовані до специфіки їхніх навчальних вибірок.

4.4 Відсутність порівняння ефективності між онлайн- і офлайн-навчанням

За винятком дослідження Muranov et al. [58], у більшості проаналізованих праць навчання моделей розглядається як офлайн-процес, що зумовлює відсутність детального порівняння переваг та обмежень онлайн- і офлайн-підходів. Для офлайн-навчання характерним є використання фіксованих наборів даних для тренування та тестування, на основі яких формується архітектура моделі. Натомість онлайн-навчання передбачає обробку поточкових даних, де прогнозування здійснюється на основі попередніх значень із динамічним оновленням параметрів моделі в реальному часі.

З огляду на те, що дані в задачах придушення перешкод переважно мають послідовний характер, інтеграція методів онлайн-навчання є перспективним напрямом для вдосконалення сучасних технологій, які наразі здебільшого базуються на офлайн-методологіях. Крім того, онлайн-навчання є ефективною альтернативою у випадках, коли обсяг даних перевищує можливості оперативної пам'яті. Прикладом архітектури, що поєднує обидва підходи, є рекурентні нейронні мережі (RNN): їх тренування зазвичай проводиться в офлайн-режимі, тоді як безпосередня експлуатація відбувається в онлайн-режимі.

4.5 Аналіз ефективності

Як було продемонстровано в цьому огляді, дослідники застосовують різноманітні метрики для оцінки ефективності своїх алгоритмів. Більшість сучасних методів придушення завад на основі глибокого навчання використовують I/Q-дані як вхідні параметри. На відміну від суворого

математичного апарату, сформованого основоположниками теорії бездротового зв'язку (зокрема, теоретико-інформаційними висновками Клода Шеннона), недостатня теоретична обґрунтованість аналізу результатів алгоритмів глибокого навчання може обмежувати їхнє практичне впровадження у системах придушення перешкод. Крім того, враховуючи розбіжність розподілів навчальних та тестових даних, доцільним є подальше дослідження методів теорії інформації для розробки релевантних метрик ефективності. Варто також зауважити, що такі показники, як BER, попри їхню важливість для комунікаційних систем, є менш ефективними порівняно з EVM через значні обсяги обчислень, необхідні для оцінки областей з низьким рівнем бітових помилок.

4.5.1 Проблеми з розпізнаванням відкритих множин (OSR) або даними, що виходять за межі розподілу (OOD)

Розпізнавання відкритих множин (Open Set Recognition, OSR) - це поширений феномен, при якому під час етапу тестування виявляються класи, відсутні в навчальній вибірці. Ця проблема, також ідентифікована як виявлення даних поза розподілом (Out-of-Distribution, OOD), здатна суттєво знизити надійність моделей глибокого навчання (DL), оскільки в реальних сценаріях, зокрема в системах бездротового зв'язку, тестові дані є необмеженими та динамічними. Раніше було обґрунтовано, що стохастична природа бездротового каналу спричиняє деградацію ефективності класифікаторів на основі DL. Традиційні алгоритми глибокого навчання спираються на припущення, що навчальні та тестові дані належать до одного й того самого розподілу, що акцентує увагу на здатності моделі до узагальнення. Проте в практичних додатках таке припущення не завжди є валідним, оскільки тестові дані можуть суттєво відрізнятися від навчальних.

Попередні дослідження [65] засвідчили, що моделі глибокого навчання часто генерують прогнози з необґрунтовано високим рівнем впевненості для вхідних даних, які не стосуються поставленої задачі або є нерозпізнаваними. Попри те, що це питання частково висвітлено в [65], воно потребує глибшого аналізу в контексті завдань придушення перешкод із застосуванням DL. У критично важливих системах, таких як автономний транспорт, ефективна обробка OSR- або OOD-даних є обов'язковою умовою для запобігання помилкам сприйняття, що можуть призвести до відмови системи. Окрім того,

вплив OOD-даних може негативно позначатися на алгоритмах виявлення та придушення перешкод. Особливу небезпеку становить те, що ці явища часто не супроводжуються явними помилками моделі, залишаючись прихованими від оперативного моніторингу. З огляду на це, забезпечення безпечного функціонування систем глибокого навчання для придушення перешкод вимагає розробки методів чіткої диференціації між відомими та невідомими класами в тестових даних.

4.5.2 Проблеми з впровадженням

Навчання алгоритмів глибокого навчання є процесом, що потребує значних часових та обчислювальних ресурсів. З огляду на це, більшість дослідників надають перевагу офлайн-навчання з подальшим розгортанням готових моделей у прикладних системах. Зокрема, Грімальді та співавт. [55] зазначають, що онлайн-класифікатор для розрізнення технологій Bluetooth та Bluetooth Low Energy (BLE) демонструє вдсятеро вищий рівень помилок порівняно з автономними методами, які мають показник похибки лише 2%. Така розбіжність зумовлена значною схожістю фізичного рівня (PHY) обох технологій, що базуються на гауссовій частотній маніпуляції (GFSK).

Крім того, Шмідт та співавт. [43] використовували багат шарові алгоритми CNN, що потребували потужних серверів з графічними процесорами (GPU) для процесу навчання. Висока вартість такого обладнання створює суттєві бар'єри для впровадження методів глибокого навчання у практичні задачі придушення перешкод. Хоча офлайн-навчання є ефективним у комп'ютерному зорі, де вплив сторонніх факторів на продуктивність мінімізований, у сфері придушення перешкод такий підхід є менш результативним. Через динамічний характер параметрів сигналу, офлайн-моделі можуть виявитися непридатними для роботи в умовах інших сценаріїв, каналів передачі даних або часових інтервалів. Як наслідок, виникає потреба в постійному перенавчанні, що в системах з обмеженими обчислювальними потужностями призводить до критичних затримок.

Одним із перспективних рішень є впровадження алгоритмів глибокого навчання безпосередньо на цільовому обладнанні, що дозволяє оптимізувати процес навчання в системах реального або майже реального часу. Проте для пристроїв Інтернету речей (IoT), що характеризуються обмеженими ресурсами, реалізація такого підходу залишається складним технічним завданням.

ВИСНОВКИ

У кваліфікаційній роботі проаналізовано ключові характеристики завад у мережах бездротового зв'язку, а також здійснено порівняльний аналіз методів глибокого навчання, що застосовуються для їх придушення. Результати дослідження свідчать, що використання підходів на основі глибокого навчання забезпечує суттєве підвищення ефективності фільтрації завад порівняно з традиційними методами. Здатність цих алгоритмів ідентифікувати складні нелінійні залежності у вхідних даних дозволяє ефективно визначати складні нелінійні межі прийняття рішень.

Водночас встановлено, що для досягнення високих показників точності моделі глибокого навчання потребують великих обсягів валідованих даних для навчання. Прогнозується, що інтеграція методів глибокого навчання у системи придушення завад набуватиме подальшого поширення. Особливу увагу в межах дослідження приділено архітектурам автоенкодерів та згорткових нейронних мереж (CNN), які демонструють високу ефективність у контексті поставлених завдань.

Попри значні переваги, впровадження технологій глибокого навчання супроводжується низкою викликів, зокрема проблемою дефіциту репрезентативних еталонних наборів даних. Використання бази даних CRAWDAD є перспективним рішенням для забезпечення необхідних ресурсів. Подальші наукові розвідки доцільно спрямувати на вивчення концепцій пояснюваного штучного інтелекту, оптимізацію обчислювальної складності та розробку онлайн-методів навчання для глибшої інтерпретації внутрішніх механізмів нейромережових моделей.

ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ

1. X. Lin et al., “5G New Radio: Unveiling the essentials of the next generation wireless access technology,” *IEEE Commun. Stand. Mag.*, vol. 3, no. 3, pp. 30–37, Sep. 2019.
2. “5G wireless access: An overview,” Ericsson, Stockholm, Sweden, White Paper, Apr. 2020. [Online]. Available: <https://www.ericsson.com/en/reports-and-papers/white-papers/5g-wireless-access-an-overview>
3. A. Ghosh, A. Maeder, M. Baker, and D. Chandramouli, “5G evolution: A view on 5G cellular technology beyond 3GPP release 15,” *IEEE Access*, vol. 7, pp. 127639–127651, 2019.
4. “5G Advanced: Evolution towards 6G,” Ericsson, Stockholm, Sweden, White Paper, Jun. 2023. [Online]. Available: <https://www.ericsson.com/en/reports-and-papers/white-papers/5g-advanced-evolution-towards-6g>
5. X. Lin, “An overview of 5G advanced evolution in 3GPP release 18,” *IEEE Commun. Stand. Mag.*, vol. 6, no. 3, pp. 77–83, Sep. 2022.
6. “Setting off the 5G advanced evolution,” Qualcomm, San Diego, CA, USA, White Paper, Jan. 2022. [Online]. Available: <https://www.qualcomm.com/content/dam/qcomm-martech/dmassets/documents/setting-off-the-5g-advanced-evolution-with-3gpp-release-18.pdf>
7. Vision, market drivers, and research directions on the path to 6G, Qualcomm, San Diego, CA, USA, White Paper, Dec. 2022. [Online]. Available: <https://www.qualcomm.com/content/dam/qcomm-martech/dmassets/documents/Qualcomm-Whitepaper-Vision-market-drivers-and-research-directions-on-the-path-to-6G.pdf>
8. M. Kunert, F. Bodereau, M. Goppelt, C. Fischer, A. John, T. Wixforth, A. Ossowska, and T. Schipper, “D1.5-study on the state-of-the-art interference mitigation techniques,” Eur. Commission, More Saf. All Radar, Tech. Rep., 2010. Accessed: Nov. 4, 2021. [Online]. Available: <https://cordis.europa.eu/project/rcn/94234/reporting/enhttps://cordis.europa.eu/docs/projects/cnect/1/248231/080/deliverables/001-MOSARIMDeliverable15V161.pdf>

9. J. A. Mahal, A. Khawar, A. Abdelhadi, and T. C. Clancy, "Spectral coexistence of MIMO radar and MIMO cellular system," *IEEE Trans. Aerosp. Electron. Syst.*, vol. 53, no. 2, pp. 655–668, Apr. 2017.
10. A. Khawar, A. Abdel-Hadi, and T. C. Clancy, "Spectrum sharing between S-band radar and LTE cellular system: A spatial approach," in *Proc. IEEE Int. Symp. Dyn. Spectr. Access Netw. (DYSPAN)*, Apr. 2014, pp. 7–14.
11. M. Carrick, J. H. Reed, and F. Harris, "An optimal filter for signals with time-varying cyclostationary statistics," in *Proc. 22nd Int. Conf. Digit. Signal Process. (DSP)*, Aug. 2017, pp. 1–5.
12. M. Carrick, J. H. Reed, and C. M. Spooner, "Mitigating linear-frequency-modulated pulsed radar interference to OFDM," *IEEE Trans. Aerosp. Electron. Syst.*, vol. 55, no. 3, pp. 1146–1159, Jun. 2019.
13. A. Batra, J. R. Zeidler, and A. Beex, "Mitigation of narrowband interference using adaptive equalizers," in *Proc. 14th Eur. Signal Process. Conf.*, 2006, pp. 1–5.
14. M. Kesteven, G. Hobbs, R. Clement, B. Dawson, R. Manchester, and T. Uppal, "Adaptive filters revisited: Radio frequency interference mitigation in pulsar observations," *Radio Sci.*, vol. 40, no. 5, pp. 1–14, Oct. 2005.
15. J. R. Mohammed, "Interference mitigation in the wireless communication systems using adaptive filters," *IOP Conf. Ser., Mater. Sci. Eng.*, vol. 1152, no. 1, May 2021, Art. no. 012001.
16. . D. Fite, S. P. Bruzzzone, and B. G. Agee, "Blind separation of voice modulated single-side-band using the multi-target variable modulus algorithm," in *Proc. IEEE Int. Conf. Acoust., Speech, Signal Process. Conf.*, May 1996, pp. 2726–2729.
17. K. Kim, I. A. Akbar, K. K. Bae, J.-S. Um, C. M. Spooner, and J. H. Reed, "Cyclostationary approaches to signal detection and classification in cognitive radio," in *Proc. 2nd IEEE Int. Symp. New Frontiers Dyn. Spectr. Access Netw.*, Apr. 2007, pp. 212–215.
18. Z. Geng, H. Yan, J. Zhang, and D. Zhu, "Deep-learning for radar: A survey," *IEEE Access*, vol. 9, pp. 141800–141818, 2021.
19. D. Chen, Y. Zhuang, J. Huai, X. Sun, X. Yang, M. Awais Javed, J. Brown, Z. Sheng, and J. Thompson, "Coexistence and interference mitigation for WPANs and WLANs from traditional approaches to deep learning: A review," *IEEE Sensors J.*, vol. 21, no. 22, pp. 25561–25589, Nov. 2021.

20. N. Azmi, L. M. Kamarudin, M. Mahmuddin, A. Zakaria, A. Y. M. Shakaff, S. Khatun, K. Kamarudin, and M. N. Morshed, "Interference issues and mitigation method in WSN 2.4GHz ISM band: A survey," in *Proc. 2nd Int. Conf. Electron. Design (ICED)*, Aug. 2014, pp. 403–408.
21. T. T. Le and S. Moh, "Interference mitigation schemes for wireless body area sensor networks: A comparative survey," *Sensors*, vol. 15, no. 6, pp. 13805–13838, 2015.
22. M. Toth, P. Meissner, A. Melzer, and K. Witrissal, "Performance comparison of mutual automotive radar interference mitigation algorithms," in *Proc. IEEE Radar Conf. (RadarConf)*, Apr. 2019, pp. 1–6.
23. A. Nabil, Y. T. Hou, R. Zhu, W. Lou, and S. F. Midkiff, "Recent advances in interference management for wireless networks," *IEEE Netw.*, vol. 29, no. 5, pp. 83–89, Sep./Oct. 2015.
24. A. Balatsoukas-Stimming, "Non-linear digital self-interference cancellation for in-band full-duplex radios using neural networks," in *Proc. IEEE 19th Int. Workshop Signal Process. Adv. Wireless Commun. (SPAWC)*, Jun. 2018, pp. 1–5.
25. X. Yang and A. P. Petropulu, "Co-channel interference modeling and analysis in a Poisson field of interferers in wireless communications," *IEEE Trans. Signal Process.*, vol. 51, no. 1, pp. 64–76, Jan. 2003.
26. S. Farid, Y. Zia, A. Farhad, and F. B. Hussain, "Homogeneous interference mitigation techniques for wireless body area network under coexistence: A survey," in *Proc. IEEE Asia Pacific Conf. Wireless Mobile (APWiMob)*, Sep. 2016, pp. 124–129.
27. A. Hithnawi, H. Shafagh, and S. Duquennoy, "Understanding the impact of cr ss technology interference on IEEE 802.15.4," in *Proc. 9th ACM Int. Workshop Wireless Netw. Testbeds, Exp. Eval. Characterization (WiNTECH)*, 2014, pp. 49–56.
28. S. Grunau, D. Block, and U. Meier, "Multi-label wireless interference identification with convolutional neural networks," 2018, arXiv:1804.04395.
29. D. Korpi, L. Anttila, and M. Valkama, "Nonlinear self-interference cancellation in MIMO full-duplex transceivers under crosstalk," *EURASIP J. Wireless Commun. Netw.*, vol. 2017, no. 1, pp. 1–15, Dec. 2017.
30. A. Hithnawi, "Exploiting physical layer information to mitigate cross-technology interference effects on low-power wireless networks," in *Proc. 11th ACM Conf. Embedded Netw. Sensor Syst. (SenSys)*, 2013, pp. 1–2.

31. C. Fischer, *Studies on the Interference Behavior of Automotive Radar Sensors*. Göttingen, Germany: Cuvillier Verlag, 2016.
32. J. Bechter, F. Roos, M. Rahman, and C. Waldschmidt, “Automotive radar interference mitigation using a sparse sampling approach,” in *Proc. Eur. Radar Conf. (EURAD)*, Oct. 2017, pp. 90–93.
33. B.-E. Tullsson, “Topics in FMCW radar disturbance suppression,” in *Proc. Radar Syst. (RADAR)*, 1997, pp. 1–5.
34. M. Wagner, F. Sulejmani, A. Melzer, P. Meissner, and M. Huemer, “Threshold-free interference cancellation method for automotive FMCW radar systems,” in *Proc. IEEE Int. Symp. Circuits Syst. (ISCAS)*, May 2018, pp. 1–4.
35. N.-C. Ristea, A. Anghel, and R. T. Ionescu, “Fully convolutional neural networks for automotive radar interference mitigation,” 2020, arXiv:2007.11102.
36. J. Rock, M. Toth, E. Messner, P. Meissner, and F. Pernkopf, “Complex signal denoising and interference mitigation for automotive radar using convolutional neural networks,” in *Proc. 22th Int. Conf. Inf. Fusion (FUSION)*, 2019, pp. 1–8.
37. T. Xu, T. Xu, and I. Darwazeh, “Deep learning for interference cancellation in non-orthogonal signal based optical communication systems,” in *Proc. Prog. Electromagn. Res. Symp. (PIERS-Toyama)*, Aug. 2018, pp. 241–248.
38. J. Mun, H. Kim, and J. Lee, “A deep learning approach for automotive radar interference mitigation,” in *Proc. IEEE 88th Veh. Technol. Conf. (VTC-Fall)*, Aug. 2018, pp. 1–5.
39. D.-J. Xu, P.-J. Zhao, F. Shen, and H. Zhao, “Narrowband interference suppression using RKF-based recurrent neural network in spread spectrum system,” in *Proc. 4th Int. Conf. Wireless Commun., Netw. Mobile Comput.*, Oct. 2008, pp. 1–5.
40. C.-L. Lin, K. C.-J. Lin, C.-C. Lee, and Y. Tsao, “Cross-technology interference mitigation using fully convolutional denoising autoencoders,” in *Proc. IEEE Global Commun. Conf. (GLOBECOM)*, Dec. 2020, pp. 1–6.
41. T. Erpek, T. J. O’Shea, and T. C. Clancy, “Learning a physical layer scheme for the MIMO interference channel,” in *Proc. IEEE Int. Conf. Commun. (ICC)*, May 2018, pp. 1–5.
42. P. Lynggaard, “Using machine learning for adaptive interference suppression in wireless sensor networks,” *IEEE Sensors J.*, vol. 18, no. 21, pp. 8820–8826, Nov. 2018.

43. A. Suzain, R. A. Rashid, M. Sarijari, A. S. Abdullah, and O. A. Aziz, "Machine learning based lightweight interference mitigation scheme for wireless sensor network," *Telkomnika*, vol. 18, no. 4, pp. 1762–1770, 2020.
44. I. Goodfellow, Y. Bengio, and A. Courville, *Deep Learning*. Cambridge, MA, USA: MIT Press, 2016.
45. X. Zhu and A. B. Goldberg, "Introduction to semi-supervised learning," *Synth. Lect. Artif. Intell. Mach. Learn.*, vol. 3, no. 1, pp. 1–130, 2009.
46. T. J. O'Shea, T. Erpek, and T. C. Clancy, "Physical layer deep learning of encodings for the MIMO fading channel," in *Proc. 55th Annu. Allerton Conf. Commun., Control, Comput. (Allerton)*, Oct. 2017, pp. 76–80.
47. T. J. O'Shea, T. Roy, N. West, and B. C. Hilburn, "Physical layer communications system design over-the-air using adversarial networks," in *Proc. 26th Eur. Signal Process. Conf. (EUSIPCO)*, Sep. 2018, pp. 529–532.
48. F. Liang, C. Shen, and F. Wu, "An iterative BP-CNN architecture for channel decoding," *IEEE J. Sel. Topics Signal Process.*, vol. 12, no. 1, pp. 144–159, Feb. 2018.
49. J. Akeret, C. Chang, A. Lucchi, and A. Refregier, "Radio frequency interference mitigation using deep convolutional neural networks," *Astron. Comput.*, vol. 18, pp. 35–39, Jan. 2017.
50. K. O'Shea and R. Nash, "An introduction to convolutional neural networks," 2015, arXiv:1511.08458.
51. E. Kussul and T. Baidyk, "Improved method of handwritten digit recognition tested on MNIST database," *Image Vis. Comput.*, vol. 22, no. 12, pp. 971–981, 2004.
52. C. Doersch, "Tutorial on variational autoencoders," 2016, arXiv:1606.05908.
53. S. Ujan, N. Navidi, and R. J. Landry, "An efficient radio frequency interference (RFI) recognition and characterization using end-to-end transfer learning," *Appl. Sci.*, vol. 10, no. 19, p. 6885, Oct. 2020.
54. CRAWDAD a Community Resource for Archiving Wireless Data at Dartmouth. Accessed: Jun. 17, 2021. [Online]. Available: <https://crawdad.org/>
55. S. Grimaldi, A. Mahmood, and M. Gidlund, "Real-time interference identification via supervised learning: Embedding coexistence awareness in IoT devices," *IEEE Access*, vol. 7, pp. 835–850, 2019.

56. D. Ciresan, U. Meier, and J. Schmidhuber, "Multi-column deep neural networks for image classification," in *Proc. IEEE Conf. Comput. Vis. Pattern Recognit.*, Jun. 2012, pp. 3642–3649.
57. K. Youssef, L. Bouchard, K. Haigh, J. Silovsky, B. Thapa, and C. V. Valk, "Machine learning approach to RF transmitter identification," *IEEE J. Radio Freq. Identificat.*, vol. 2, no. 4, pp. 197–205, Dec. 2018.
58. K. Muranov, M. A. Islam, B. Smida, and N. Devroye, "On deep learning assisted self-interference estimation in a full-duplex relay link," *IEEE Wireless Commun. Lett.*, vol. 10, no. 12, pp. 2762–2766, Dec. 2021.
59. H. Guo, S. Wu, H. Wang, and M. Daneshmand, "DSIC: Deep learning based self-interference cancellation for in-band full duplex wireless," in *Proc. IEEE Global Commun. Conf. (GLOBECOM)*, Dec. 2019, pp. 1–6.
60. N. Promsuk, "Development of interference mitigation techniques based artificial neural network for IoT network," in *Proc. 18th Int. Conf. Electr. Eng./Electron., Comput., Telecommun. Inf. Technol. (ECTI-CON)*, May 2021, pp. 374–377.
61. M. R. Mosavi and F. Shafiee, "Narrowband interference suppression for GPS navigation using neural networks," *GPS Solutions*, vol. 20, no. 3, pp. 341–351, Jul. 2016.
62. Y. C. Shi and Y. B. Liu, "Interference suppression for satellite navigation based on neural network and wavelet packets transform," *Adv. Mater. Res.*, vols. 457–458, pp. 1111–1117, Jan. 2012.
63. W. H. Clark, S. Hauser, W. C. Headley, and A. J. Michaels, "Training data augmentation for deep learning radio frequency systems," *J. Defense Model. Simul., Appl., Methodol., Technol.*, vol. 18, no. 3, pp. 217–237, Jul. 2021.
64. X. Hu, L. Chu, J. Pei, W. Liu, and J. Bian, "Model complexity of deep learning: A survey," *Knowl. Inf. Syst.*, vol. 63, no. 10, pp. 2585–2619, Oct. 2021.
65. A. Nguyen, J. Yosinski, and J. Clune, "Deep neural networks are easily fooled: High confidence predictions for unrecognizable images," in *Proc. IEEE Conf. Comput. Vis. Pattern Recognit. (CVPR)*, Jun. 2015, pp. 427–436.