

Іван ГОРБАТИЙ, Олександр УСАТИЙ

Україна, Національний університет «Львівська політехніка»

E-mail: giv@polynet.lviv.ua, oleksandr.a.usaty@lpnu.ua

ПОРІВНЯЛЬНИЙ АНАЛІЗ МЕТОДІВ АВТОМАТИЧНОЇ КЛАСИФІКАЦІЇ ЦИФРОВИХ МОДУЛЯЦІЙ НА ОСНОВІ ГЛИБИННИХ НЕЙРОННИХ МЕРЕЖ

Порівняно методи автоматичної класифікації цифрових способів модуляції радіосигналів у широкому діапазоні відношення сигнал/шум. Розглянуто дві сучасні глибинні нейронні мережі: згорткову та резидуальну з комплексними згортками, навчання яких проводилось у декількох режимах, зокрема на окремих рівнях шуму, на повному діапазоні та поетапне навчання зі зростанням складності. Представлено експериментальні результати на великому наборі радіосигналів, проаналізовано матриці змішування класів цифрових способів модуляції та залежність точності класифікації від рівня шуму. Показано переваги резидуальної мережі під час розпізнавання сигналів зі значним рівнем завад.

Ключові слова: класифікація цифрових способів модуляції, цифрові сигнали, резидуальна нейронна мережа, згорткова нейронна мережа, відношення сигнал/шум, глибинне навчання, завадостійкість.

Автоматична класифікація цифрових способів модуляції (англ. *automatic modulation classification, AMC*) є однією з базових задач аналізу радіосигналів у системах радіомоніторингу, когнітивного радіо та сучасних телекомунікаційних систем. Результати класифікації застосовуються для оцінювання параметрів сигналів, ідентифікації типу передавання інформації та адаптації приймальних алгоритмів до змінних умов каналу. Особливої актуальності ця задача набуває в умовах зашумлених каналів, коли відношення сигнал/шум (*signal-to-noise ratio, SNR*) змінюється в широкому діапазоні та істотно впливає на якість прийнятих рішень.

Класичні підходи до AMC ґрунтуються на використанні наперед заданих інженерних ознак, зокрема статистичних моментів, кумулянтів та спектральних характеристик сигналів [1]. Попри відносну простоту реалізації та інтерпретованість, ефективність таких методів суттєво знижується за низьких значень SNR і при збільшенні кількості класів модуляції, що обмежує їх практичне застосування у складних радіоумовах.

Подальший розвиток методів AMC пов'язаний із застосуванням глибинного навчання, яке дозволило перейти від ручного формування ознак до безпосереднього аналізу часових послідовностей комплексних відліків квадратурних складових (далі — комплексних *I/Q*-відліків). Перші роботи із використанням згорткових нейронних мереж продемонстрували суттєве підвищення точності класифікації порівняно з класичними методами, що було показано на відкритих наборах даних цифрових модуляцій [2]. Подальше розширення досліджень пов'язане

з появою більш складних наборів даних, зокрема RadioML2018.01A, які охоплюють ширший діапазон значень відношення сигнал/шум і різноманітні типи каналних спотворень [3].

Порівняно з класичними схемами автоматичної класифікації модуляції, що базуються на рішеннях у вигляді паралельного включення демодуляторів і вирішального пристрою, нейромережеві підходи мають низку принципових переваг. Наприклад, вони не потребують явного виділення інженерних ознак або попереднього вибору моделей сигналів, оскільки формують ознакові представлення безпосередньо з часових послідовностей комплексних *I/Q*-відліків. Крім того, нейромережеві класифікатори демонструють вищу завадостійкість у широкому діапазоні відношення сигнал/шум, оскільки здатні адаптивно враховувати нелінійні та високорозмірні залежності, які складно формалізувати в рамках класичних алгоритмів. Це особливо важливо в умовах обмеженої апріорної інформації про параметри сигналу та каналу передачі.

З точки зору обчислювальної складності, основні витрати припадають на етап навчання моделей, який виконується офлайн. Після навчання складність класифікації одного сигналу визначається фіксованою кількістю операцій згортки та матричних перетворень і не залежить від кількості можливих класів у такий спосіб, як у схемах з паралельними демодуляторами. Це робить нейромережеві AMC-підходи привабливими для практичної реалізації в сучасних програмно-апаратних системах.

Узагальнення сучасних підходів до глибинного навчання в задачах AMC наведено в оглядових роботах, де підкреслюється роль представлення сигналів,

вибору архітектури нейронної мережі та методів навчання для забезпечення завадостійкості класифікаторів [4]. Зокрема, зазначається, що згорткові нейронні мережі демонструють високу ефективність за середніх і високих значень відношення сигнал/шум, однак їхня здатність до узагальнення результатів у шумових умовах залишається обмеженою.

Одним із перспективних напрямів підвищення завадостійкості є використання резидуальних нейронних мереж, які завдяки наявності залишкових зв'язків забезпечують стабільніше навчання глибоких моделей. Ефективність таких архітектур у задачах АМС підтверджується результатами сучасних досліджень, де показано покращення якості розпізнавання в умовах зниженого відношення сигнал/шум [5]. Водночас більшість наявних робіт зосереджується на аналізі окремих архітектур або окремих значень SNR, що ускладнює порівняння їхньої ефективності.

Метою цієї роботи є порівняння ефективності згорткової нейронної мережі та резидуальної нейронної мережі у задачі АМС в умовах змінного рівня шуму. Основна увага приділяється оцінюванню завадостійкості нейромережових моделей та їх здатності до узагальнення результатів у широкому діапазоні значень відношення сигнал/шум.

Це дослідження є продовженням наших попередніх робіт [6], [7], присвячених аналізу зашумлених та структурно складних радіосигналів, і розвиває загальний підхід до застосування методів машинного навчання для їх обробки в умовах змінного рівня шуму.

Архітектура глибоких моделей для АМС

З урахуванням вимог до точності АМС та обмежень обчислювальних ресурсів у системах аналізу радіосигналів розглянемо архітектури двох глибоких нейронних мереж: базової згорткової (*convolutional neural network*, CNN) та більш складної, резидуальної (*residual neural network*, ResNet). Обидві моделі безпосередньо обробляють часові послідовності комплексних I/Q -відліків та формують оцінку ймовірностей належності сигналу до одного з досліджуваних класів модуляції.

CNN використовується як базова модель для порівняння. Подібні архітектури широко застосовуються у задачах АМС і демонструють високу ефективність при середніх та високих значеннях відношення сигнал/шум [2], [8]. У цьому дослідженні CNN побудована як послідовність одномірних згорткових блоків із нормалізацією та підвибіркою, що забезпечує поступове виділення інформативних часових ознак сигналу. Агрегація ознак здійснюється за допомогою глобального усереднення, що дозволяє обмежити кількість параметрів моделі та зменшити ризик перенавчання. Загальна кількість параметрів CNN становить близько $4 \cdot 10^5$, що робить її придат-

ною для використання в системах з обмеженими обчислювальними ресурсами.

Для підвищення здатності моделі до узагальнення у шумових умовах розглянемо також ResNet, побудовану на основі залишкових блоків із прямими з'єднаннями. Використання таких з'єднань дозволяє стабілізувати процес навчання глибоких мереж та зменшити вплив деградації градієнтів, що є важливим для аналізу складних часових структур сигналів [5], [9]. Резидуальна модель містить кілька послідовних блоків із поступовим збільшенням кількості каналів та зменшенням часової роздільної здатності, що дозволяє враховувати локальні та глобальні особливості сигналів різних типів модуляції. Кількість параметрів ResNet-подібної моделі перевищує 10^6 , що забезпечує вищу здатність до формування ознакових представлень порівняно з базовою CNN, але супроводжується більшими обчислювальними витратами.

Обидві архітектури мають уніфіковану вихідну частину, яка містить агрегування ознак та повнозв'язний класифікаційний шар із функцією активації Softmax. Такий підхід забезпечує коректне порівняння моделей за ідентичних умов навчання та тестування. Застосування двох архітектур із суттєво різною складністю дозволяє дослідити, наскільки ускладнення моделі та використання залишкових зв'язків впливають на якість АМС у широкому діапазоні значень SNR.

Сценарій навчання та експериментальний план

Для забезпечення коректного порівняння двох нейромережових архітектур CNN та ResNet усі експерименти проводилися на основі єдиного набору даних RadioML2018.01A з використанням уніфікованих процедур попередньої обробки, навчання та оцінювання. Такий підхід забезпечує мінімізацію впливу сторонніх факторів і відтворюваність отриманих результатів.

Для дослідження було використано вибірку з набору даних, що містить вісім найбільш поширених модуляцій: BPSK, QPSK, 8PSK, 16QAM, 64QAM, GFSK, CPFSK, GMSK, представлених у вигляді часових послідовностей комплексних I/Q -відліків довжиною 1024. Рівень відношення сигнал/шум у вибірках змінювався в діапазоні від -10 до $+10$ дБ, що є критичним для практичної класифікації сигналів у шумових умовах. Перед поданням на вхід нейромережових моделей сигнали нормалізувалися за середньоквадратичним значенням.

Навчання моделей здійснювалося з використанням кількох режимів, що відрізнялися характером шумового навантаження у навчальних даних. Зокрема, розглядалися режими навчання на фіксованому значенні SNR, на високих значеннях SNR, на повному діапазоні шумів (*full*), а також режим поступового введення шуму (*curriculum learning*). Такий вибір

режимів дозволяє оцінити вплив як архітектури нейронної мережі, так і стратегії навчання моделі на її здатність до узагальнення результатів у змінних шумових умовах.

Для обох архітектур застосовувалися однакові налаштування оптимізації та параметри навчання, що забезпечує коректність порівняння. Навчання проводилося з обмеженою кількістю епох із використанням механізмів ранньої зупинки та адаптації швидкості навчання на основі значень точності на контрольній вибірці. Як функцію втрат використовували крос-ентропійну функцію, а основними метриками оцінювання були точність класифікації цифрових способів модуляції та точність за двома найбільш ймовірними класами.

Результати оцінювалися на єдиній тестовій множині для кожного значення SNR у досліджуваному діапазоні. Окрім кількісних показників формувалися матриці невідповідностей, що забезпечують якісний аналіз характерних міжкласових помилок і дозволяють виявити закономірності, пов'язані зі структурною подібністю окремих типів модуляцій.

Запропонований експериментальний план забезпечує узгоджене та репрезентативне порівняння нейромережових моделей різної складності та дає можливість обґрунтовано оцінити вплив архітектури та стратегії навчання на ефективність AMC у шумових умовах.

Для кількісного оцінювання якості AMC використаємо метрики точності класифікації (*accuracy*). Точність класифікації для фіксованого значення SNR визначається як

$$\text{Accuracy}(s) = \frac{1}{N_s} \sum_{i=1}^{N_s} 1\{\hat{y}_i = y_i\}, \quad (1)$$

де N_s — кількість тестових зразків із відношення сигнал/шум;

y_i — істинна мітка модуляції i -го сигналу;

$\hat{y}_i$ — передбачений клас моделі;

$1\{\cdot\}$ — індикаторна функція, що дорівнює 1, якщо умова істинна, і 0, якщо інакше.

Для додаткового оцінювання якості розпізнавання використовувалася метрика точності за двома найбільш ймовірними класами (далі — точність Top-2), яка визначає частку випадків, коли істинний клас модуляції входить до двох найбільш ймовірних передбачень моделі

$$\text{Top2}(s) = \frac{1}{N_s} \sum_{i=1}^{N_s} 1\{y_i \in \text{Top2}(\hat{p}_i)\}, \quad (2)$$

де $\hat{p}_i$ — вектор прогнозованих ймовірностей для всіх класів;

$\text{Top2}(\hat{p}_i)$ — множина двох класів з найбільшими ймовірностями.

Метрика точності Top-2 є інформативним показником якості AMC, оскільки допомагає оцінити ступінь

пінь наближеності помилкових рішень моделі до істинного класу. Для модуляцій, які характеризуються близькими сигнальними властивостями та часто демонструють взаємне змішування (зокрема, 16QAM та 64QAM), використання точності Top-2 дозволяє визначити, чи формує модель коректні ознакові представлення сигналів, навіть у випадках, коли остаточне рішення не відповідає істинному класу.

Усі експерименти з моделювання та обробка даних проводилися в програмному середовищі Python з використанням відкритих бібліотек для обробки сигналів і глибокого навчання. Формування та попередня обробка вибірок виконувалися за допомогою бібліотек NumPy та SciPy, тоді як реалізація нейромережових моделей і процес навчання — з використанням фреймворку TensorFlow/Keras.

Навчання та тестування моделей проводилося у відтворюваному експериментальному середовищі з фіксованими початковими значеннями генераторів випадкових чисел, що забезпечує стабільність і порівнюваність результатів. Для прискорення обчислень використовувалося апаратне прискорення на графічному процесорі, однак запропонований підхід є незалежним від апаратної платформи та може бути відтворений у стандартному програмному середовищі загального призначення.

Методика експерименту передбачала розділення даних на навчальну, валідаційну та тестову множини з однаковим розподілом за класами модуляції та значеннями відношення сигнал/шум. Якість класифікації оцінювалася виключно на тестовій множині, яка не використовувалася на етапі навчання або підбору гіперпараметрів.

Результати експериментів

Проведемо порівняння моделей CNN та ResNet у розв'язанні задачі автоматичної класифікації цифрових способів модуляції у діапазоні значень SNR від -10 до $+10$ дБ. Оцінювання проводилося в різних режимах навчання з використанням єдиної тестової вибірки, що забезпечує об'єктивність отриманих результатів.

Як видно з **рис. 1**, у випадку навчання моделей на одному фіксованому рівні завад спостерігається локальне зростання точності поблизу значення SNR, на якому здійснювалося навчання, тоді як при відхиленні від нього якість класифікації різко знижується. За критично високого рівня шумів (менше -6 дБ) точність обох моделей наближається до рівня випадкової класифікації, що свідчить про втрату інформативних ознак сигналу в умовах сильного шуму.

Навчання на високих значеннях SNR забезпечує високу точність класифікації цифрових способів модуляції в умовах слабого шуму, однак супроводжується суттєвим погіршенням результатів при зменшенні SNR. Така поведінка характерна як для CNN, так і для ResNet і свідчить про обмежену здатність




Рис. 2. Залежність точності класифікації (а) та точності Top-2 (б) від відношення сигнал/шум

моделей, навчених у вузькому діапазоні рівня шумів, до узагальнення результатів у складніших умовах.

З рис. 1 видно, що у разі навчання на всьому досліджуваному інтервалі обидві моделі демонструють найбільш рівномірну зміну як точності класифікації, так і точності Top-2, що проявляється у плавному зростанні показників без різких стрибків. Водночас використання стратегії навчання з послідовним введенням шуму дозволяє досягти вищих значень точності та точності Top-2 у малозашумлених умовах, особливо для ResNet, однак супроводжується менш плавною зміною характеристик у середньому діапазоні значень SNR. При цьому ResNet стабільно перевершує CNN для всіх розглянутих стратегій навчання, що підтверджує його вищу здатність до формування узагальнених ознакових представлень за наявності шуму.

Додатковий аналіз матриць невідповідностей (рис. 2) дозволив виявити характерні тенденції між-

класових помилок для розглянутих архітектур. Для обох моделей основні труднощі пов'язані з розрізненням модуляцій із близькими сигнальними характеристиками, зокрема фазових модуляцій, а також модуляцій одного сімейства, таких як 16QAM та 64QAM. Натомість модуляції з більш відмінними спектрально-часовими властивостями, зокрема частотні модуляції, у більшості випадків демонструють кращу відокремлюваність у всьому досліджуваному діапазоні значень SNR.

Застосування стратегії навчання з послідовним введенням шуму супроводжується зменшенням інтенсивності міжкласового змішування та більш впорядкованим розподілом помилок у матрицях невідповідностей, що особливо виразно проявляється для ResNet.

Таким чином, результати експериментів свідчать, що стратегія навчання має не менший вплив на якість AMC, ніж вибір нейромережевої архітектури. Поєднання ResNet із навчанням у широкому діапазо-




Рис. 2. Матриці невідповідностей для досліджуваних нейромережових моделей

ні шумових умов забезпечує найбільш збалансовану завадостійкість та стабільність класифікації.

Проведений аналіз показує, що ефективність АМС визначається сукупним впливом рівня шуму, архітектури нейронної мережі та стратегії її навчання. За низьких значень SNR для обох досліджуваних моделей спостерігається суттєве зниження точності класифікації, що є типовим для задач АМС і узгоджується з висновками сучасних оглядових досліджень [4].

Порівняння архітектур показало, що ResNet забезпечує вищі значення як загальної точності, так і точності Top-2 порівняно з базовою CNN, особливо за середніх і низьких значень SNR. Така перевага узгоджується з результатами робіт, у яких продемонстровано ефективність використання глибоких архітектур і залишкових з'єднань для підвищення завадостійкості систем АМС [5, 9]. При цьому ResNet може розглядатися як коректна базова модель, що узгоджується з результатами, наведеними в літературі з АМС на основі комплексних I/Q -відліків [2].

Аналіз впливу стратегій навчання показав, що моделі, натреновані в обмеженому діапазоні шумових умов, демонструють прийнятну якість класифікації лише поблизу цього діапазону. Натомість навчання на широкому діапазоні SNR та застосування адаптивних стратегій сприяють формуванню більш стабільних ознакових представлень сигналів і забезпечують рівномірнішу зміну точності класифікації в усьому досліджуваному інтервалі. Подібні закономірності також описуються у сучасних дослідженнях, де підкреслюється визначальна роль сценарію навчання для забезпечення завадостійкості нейромережових АМС-систем [10].

Висновки

Проведений в роботі порівняльний аналіз архітектур CNN та ResNet у задачі автоматичної класифікації цифрових способів модуляції на основі часових послідовностей комплексних I/Q -відліків дозволив встановити, що рівень шуму є ключовим чинником точності АМС: за низьких значень відношення сигнал-шум точність істотно знижується через деградацію інформативних ознак сигналу. Показано, що архітектура нейронної мережі визначає завадостійкість системи: ResNet перевершує базову CNN за загальною та Top-2 точністю, особливо в умовах середнього та низького SNR. Доведено важливість стратегії навчання: використання широкого діапазону SNR та послідовного введення шуму забезпечує стабільнішу якість класифікації порівняно з навчанням у вузькому діапазоні. Аналіз матриць невідповідностей підтвердив характерні міжкласові помилки для близьких типів модуляцій, а метрика Top-2 точності дозволила адекватніше оцінити якість класифікації.

Запропонований підхід орієнтований не лише на офлайн-аналіз, але й придатний для використання в режимі, близькому до реального часу: після завер-

шення навчання моделі працюють у режимі прямого поширення, що не потребує значних обчислювальних ресурсів. Обробка одного фрагмента сигналу у вигляді послідовності комплексних I/Q -відліків фіксованої довжини виконується за час, суттєво менший за тривалість самого фрагмента, особливо за умови використання сучасних процесорів або вбудованих прискорювачів. Отже, запропонований підхід є сумісним із вимогами реального часу для задач радіомоніторингу, когнітивного радіо та адаптивних приймальних систем.

Таким чином, отримані результати підтверджують доцільність застосування глибоких архітектур із залишковими з'єднаннями та адаптивних стратегій навчання для підвищення завадостійкості АМС-систем.

Перспективними напрямками подальших досліджень є поширення запропонованого підходу на сигнали з розширеним спектром (зокрема, з псевдовипадковим перебудовуванням робочої частоти, чірповим та прямим розширенням спектра), а також аналіз впливу нестационарних умов каналу на ефективність класифікації. Окрему увагу слід приділити розробленню гібридних нейромережових моделей та адаптивних стратегій навчання для підвищення завадостійкості задач АМС у складних часово-частотних умовах. Крім того, перспективним є дослідження можливостей застосування алгоритмів АМС на основі нейромереж у вбудованих обчислювальних системах з обмеженими ресурсами, призначених для децентралізованого та польового радіомоніторингу.

ВИКОРИСТАНІ ДЖЕРЕЛА

1. Azzouz E., Nandi A. *Automatic Modulation Recognition of Communication Signals*. Springer, 1996. <https://doi.org/10.1007/978-1-4757-2469-1>
2. O'Shea T., Corgan J., Clancy T. Convolutional Radio Modulation Recognition Networks. *arXiv preprint*, 2016, arXiv:1602.04105. Режим доступу: <https://arxiv.org/abs/1602.04105>
3. RadioML 2018.01A Dataset / DeepSig Inc., 2018. Режим доступу: <https://deepsig.ai/datasets> (дата звернення: 12.12.2025)
4. Peng S., Sun S., Yao Y.-D. A Survey of Modulation Classification Using Deep Learning: Signal Representation and Data Preprocessing. *IEEE Transactions on Neural Networks and Learning Systems*, 2022. <https://doi.org/10.1109/TNNLS.2021.3085433>
5. Peng Y., Guo L., Yan J. et al. Automatic Modulation Classification Using Deep Residual Neural Network with Masked Modeling for Wireless Communications. *Drones*, 2023. <https://doi.org/10.3390/drones7060390>
6. Горбатий І., Усатий О. Дослідження методів аналізу сигналів з повним або частковим перекриттям у сучасних інформаційно-комунікаційних системах. *Інформаційно-комунікаційні технології та електронна інженерія*, 2025, т. 5, № 2, с. 140–151. <https://doi.org/10.23939/ict2025.02.140>
7. Горбатий І., Усатий О. Дослідження методів аналізу сигналів з розширеним спектром у сучасних системах зв'язку. *Інформаційно-комунікаційні технології та електронна інженерія*, 2025, т. 5, № 1, с. 125–129. <https://doi.org/10.23939/ict2025.01.125>
8. Jiang H., Wang H., Alwageed H. Modulation Classification Using Convolutional Neural Network-Based Deep Learning Model.

Wireless and Optical Communication Conference (WOCC), 2017. <https://doi.org/10.1109/WOCC.2017.7929000>

9. Han J., Yu Z., Yang J. A lightweight deep learning architecture for automatic modulation classification of wireless internet of things. *IET Communications*, 2024. <https://doi.org/10.1049/cmu2.12823>

10. Артемук С. І. Застосування штучних нейронних мереж для визначення координат джерела акустичного сигналу: дис. ... д-ра філософії. Львів: Нац. ун-т «Львівська політехніка», 2023. Режим доступу: <https://surl.li/fzpedu>

Дата надходження рукопису
до редакції 15.11 2025 р.

DOI: 10.15222/TKEA2025.3-4.33
UDC 621.396.96+004.932

Ivan HORBATYI, Oleksandr USATYI

Ukraine, Lviv Polytechnic National University

E-mail: giv@polynet.lviv.ua oleksandr.a.usatyi@lpnu.ua

COMPARATIVE ANALYSIS OF DIGITAL MODULATION CLASSIFICATION METHODS BASED ON DEEP NEURAL NETWORKS

Automatic classification of digital modulation formats (AMC) is a critical component of modern radio monitoring systems, cognitive communication platforms, and interference-resilient wireless communication systems. The rapid expansion of wideband and dynamically varying radio environments creates the need for classifiers that remain reliable across a broad range of signal-to-noise ratios (SNR). Recent advances in deep learning have significantly improved digital modulation classification performance, yet the impact of training strategies and neural-network architectures under low-SNR conditions remains insufficiently studied. This work addresses this gap by performing a comparative evaluation of two deep neural architectures — a 1D Convolutional Neural Network (CNN) and a complex-valued Residual Network — trained and tested on a large-scale dataset of digitally modulated I/Q signals.

The research aimed to construct a mapping from raw time-domain I/Q sequences to discrete digital modulation labels while ensuring stability of the classifier with respect to SNR variations. Four training strategies are investigated: training at a single low SNR, training at a single high SNR, training over the full SNR range, and curriculum learning with gradually decreasing SNR. Both models are evaluated across the entire SNR interval using accuracy curves, Top-2 accuracy, and confusion matrices.

The experimental results demonstrate that the complex-valued Residual Network consistently outperforms the CNN, particularly in low-SNR scenarios, and benefits most from curriculum learning. The CNN provides competitive performance at moderate and high SNR but exhibits reduced robustness in noisy conditions. The findings highlight the practical relevance of selecting appropriate architectures and training schemes for reliable modulation classification in non-ideal radio environments. The presented framework enables reproducible benchmarking and can be applied to the design of noise-resilient AMC modules in real communication systems.

Keywords: digital modulation classification, digital signals, residual neural network; convolutional neural network; signal-to-noise ratio; deep learning; noise robustness.

REFERENCES

[1] E. E. Azzouz, and A. K. Nandi, *Automatic Modulation Recognition of Communication Signals*. Boston, MA, USA: Springer, 1996, doi: 10.1007/978-1-4757-2469-1.

[2] T. O'Shea, J. Corgan, and T. Clancy, "Convolutional Radio Modulation Recognition Networks," *arXiv preprint*, arXiv:1602.04105, 2016. [Online]. Available: <https://arxiv.org/abs/1602.04105>

[3] DeepSig Inc., "RadioML 2018.01A Dataset," 2018. [Online]. Available: <https://deepsig.ai/datasets>. Accessed: Dec. 12, 2025.

[4] S. Peng, S. Sun, and Y.-D. Yao, "A Survey of Modulation Classification Using Deep Learning: Signal Representation and Data Preprocessing," *IEEE Trans. Neural Netw. Learn. Syst.*, vol. 33, no. 12, pp. 7020–7038, Nov. 2022, doi: 10.1109/TNNLS.2021.3085433.

[5] Y. Peng, L. Guo, J. Yan, M. Tao, X. Fu, Y. Lin, et al., "Automatic Modulation Classification Using Deep Residual Neural Network with Masked Modeling for Wireless Communications," *Drones*, vol. 7, no. 6, Art. 390, 11 June 2023, doi: 10.3390/drones7060390.

[6] I. Horbatiy, and O. Usaty, "Investigation of signal analysis methods for full or partial overlap in modern information and communication systems," in *Proc. ICTEE*, vol. 5, no. 2, pp. 140–151, 2025. doi: 10.23939/ict2025.02.140.

[7] I. Horbatiy, and O. Usaty, "Investigation of spread spectrum signal analysis methods in modern communication systems," in *Proc. ICTEE*, vol. 5, no. 1, pp. 125–135, 2025. doi: 10.23939/ict2025.01.125.

[8] H. Jiang, H. Wang, and H. Alwageed, "Modulation Classification Using Convolutional Neural Network–Based Deep Learning Model," in *Proc. WOCC*, 2017. doi: 10.1109/WOCC.2017.7929000.

[9] J. Han, Z. Yu, and J. Yang, "A lightweight deep learning architecture for automatic modulation classification of wireless internet of things," *IET Commun.*, 2024. doi: 10.1049/cmu2.12823.

[10] S. I. Artemuk, *Application of artificial neural networks for determining the coordinates of the acoustic signal source*, Ph.D. dissertation, Lviv Polytechnic National University, Lviv, 2023. [Online]. Available: <https://lpnu.ua/sites/default/files/2024/radaphd/27261/phdartemukfinal.pdf>



Copyright: © 2025, The author(s). Licensee: Politekhperiodika, Odesa, Ukraine. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).