

DOI: 10.18372/2310-5461.69.20941
УДК 621.391.83:004.8

В. В. Козловський, д-р техн. наук, професор
Державний університет «Київський авіаційний інститут», Київ
<https://orcid.org/0000-0002-8301-5501>
e-mail: vvkzeos@gmail.com;

С. І. Бобров
Державний університет «Київський авіаційний інститут», Київ
<https://orcid.org/0000-0003-3604-2256>
e-mail: sergey.bobrov@snt.ua;

І. Г. Макєєв
Державний університет «Київський авіаційний інститут», Київ
<https://orcid.org/0009-0009-8679-5652>
e-mail: 8390988@stud.nau.edu.ua;

О. В. Німич
Державний університет «Київський авіаційний інститут», Київ
<https://orcid.org/0000-0003-1759-7088>
e-mail: 5356349@stud.kai.edu.ua

ГЛИБОКІ CNN ТА RESNET-АРХІТЕКТУРИ ДЛЯ АВТОМАТИЧНОЇ КЛАСИФІКАЦІЇ МОДУЛЯЦІЇ

Вступ

Автоматична класифікація модуляції (АМС) є однією з ключових задач сучасних систем радіомоніторингу, когнітивного радіо та некооперативного приймання сигналів. У складних умовах радіосередовища, що характеризуються низьким відношенням сигнал/шум, зсувами частоти та варіативністю параметрів каналу, традиційні методи АМС, засновані на статистичних характеристиках або експертно сформованих ознаках, демонструють обмежену узагальнювальну здатність.

Сучасні дослідження показують, що глибокі нейронні мережі, зокрема згорткові архітектури, здатні автоматично формувати інформативні представлення сигналів без необхідності ручного конструювання ознак. Використання комплексних IQ-вибірок як вхідних даних дозволяє зберегти повну фазово-амплітудну структуру сигналу та забезпечує універсальність підходу для різних типів модуляції.

Особливий інтерес становлять архітектури типу ResNet, які завдяки залишковим з'єднанням дозволяють ефективно навчати глибокі моделі без деградації градієнтів. Водночас зростання глибини мережі супроводжується збільшенням обчислювальних витрат і часу навчання, що обумовлює необхідність пошуку механізмів оптимізації процесу навчання без втрати якості класифікації.

Аналіз останніх досліджень та публікацій і постановка проблеми

Сучасні дослідження у сфері автоматичної класифікації модуляції (АМС) характеризуються активним впровадженням глибоких нейронних мереж, що працюють безпосередньо з комплексними IQ-вибірками. На відміну від традиційних підходів, заснованих на ручному формуванні статистичних або спектральних ознак, згорткові архітектури забезпечують автоматичне виділення інформативних часово-фазових структур сигналу. У роботі Abd-Elaziz та ін. [1] показано, що використання глибокої CNN дозволяє підвищити точність класифікації в умовах шуму та варіативності параметрів каналу. Подібні результати отримано у [2], де продемонстровано переваги глибоких моделей над класичними алгоритмами розпізнавання.

Подальший розвиток отримали залишкові архітектури, що стабілізують навчання глибоких моделей. У [3] та [4] досліджено застосування ResNet-подібних структур для задач АМС, що забезпечують покращену точність у низькоенергетичних режимах та кращу узагальнювальну здатність. Робота [5] акцентує увагу на регуляризації глибоких моделей з урахуванням апріорної інформації, що підвищує стійкість класифікації при зміні умов каналу.

Окремий напрям пов'язаний із підвищенням ефективності навчання. У [6] обґрунтовано доцільність використання важливішого семплінгування для прискорення збіжності глибоких мереж. Аналогічні підходи до фокусування навчання на складних прикладах застосовуються в задачах АМС для зменшення кількості ітерацій без втрати точності. Крім того, у [7], [8] досліджено комбінування глибоких моделей із різними способами представлення сигналу, що підтверджує актуальність пошуку архітектурних та алгоритмічних удосконалень.

Таким чином, аналіз сучасних публікацій свідчить про актуальність дослідження глибоких згорткових та залишкових архітектур для АМС, а також необхідність оптимізації процесу навчання з урахуванням складності міжкласових помилок. Це визначає наукову та практичну доцільність запропонованого підходу.

Метою дослідження є порівняльний аналіз згорткових і ResNet-архітектур для задачі автоматичної класифікації модуляції та розроблення алгоритму адаптивного прискорення навчання на основі аналізу помилок моделі.

Виклад основного матеріалу

Автоматична класифікація модуляції (Automatic Modulation Classification, АМС) є задачею визначення типу модуляції прийнятого сигналу без апріорної інформації про параметри передавача та каналу поширення. У некооперативних сценаріях приймання, характерних для систем радіомоніторингу та когнітивного радіо, задача ускладнюється наявністю адитивного шуму, зсувів несучої частоти, фазових нестабільностей і варіативності параметрів сигналу.

У сучасних цифрових приймачах сигнал після перетворення до низької частоти представлено у вигляді комплексної огинаючої, що дискретизується та подається як послідовність комплексних IQ-вибірок. Таке подання дозволяє зберегти повну інформацію про амплітуду та фазу сигналу, а отже, є інформативним для задачі визначення типу модуляції. На відміну від підходів, заснованих на статистичних або спектральних ознаках, безпосередній аналіз IQ-вибірок дає змогу уникнути втрат інформації, пов'язаних із попередньою обробкою.

Нехай прийнятий сигнал у дискретному вигляді подано як послідовність:

$$x = \{I[n], Q[n]\}_{n=1}^N, \quad (1)$$

де $I[n]$ та $Q[n]$ – відповідно дійсна та уявна складові комплексної огинаючої, а N – довжина фрагмента сигналу.

Вважається, що фрагмент вибирається довільно в межах переданого пакета та не потребує попередньої синхронізації за фазою або частотою.

Задача автоматичної класифікації модуляції формулюється як задача багатокласової класифікації у режимі навчання з учителем. Нехай задано навчальну вибірку:

$$D = \{(x_i, y_i)\}_{i=1}^M, \quad (2)$$

де x_i – вектор IQ-вибірок довжини N , а y_i – мітка класу модуляції з множини C (наприклад BPSK, QPSK, 8PSK, 16QAM тощо). Метою навчання є побудова відображення:

$$f(x): x \rightarrow C, \quad (3)$$

що мінімізує функцію втрат класифікації на навчальній вибірці.

З точки зору статистичної теорії розпізнавання сигналів задача автоматичної класифікації модуляції може бути інтерпретована як оцінювання апостеріорної ймовірності належності сигналу до певного класу модуляції. Оптимальне правило прийняття рішення у байєсівському сенсі визначається максимізацією ймовірності:

$$c^* = \arg \max_{c \in C} P(c | x), \quad (4)$$

де x – вектор IQ-вибірок.

У запропонованому підході оцінювання цієї залежності реалізується глибокою нейронною мережею, яка апроксимує нелінійне відображення між простором сигналів та простором класів модуляції.

Складність задачі зумовлена перекриттям статистичних характеристик різних типів модуляції при низькому відношенні сигнал/шум, наявністю частотних зсувів та фазових спотворень, а також обмеженою довжиною доступного фрагмента сигналу. У таких умовах традиційні методи, засновані на ручному формуванні ознак або аналітичних критеріях, можуть демонструвати обмежену узагальнювальну здатність. З огляду на це доцільним є використання глибоких нейронних мереж, здатних автоматично виділяти інформативні часово-фазові закономірності без явного задання структури ознак.

Навчання нейронної мережі здійснюється шляхом мінімізації функції втрат категоріальної крос-ентропії з використанням стохастичного градієнтного методу. Навчальна вибірка формується з фрагментів сигналів довжиною 1024 IQ-відліки та містить приклади різних типів модуляції при різних значеннях відношення сигнал/шум. Для забезпечення коректної оцінки узагальнювальної здатності моделі дані розділяються на навчальну, валідаційну та тестову підвбірки (70 % : 15 % : 15 %).

Базова згорткова архітектура для задачі автоматичної класифікації модуляції побудована на

використанні одновимірних згорткових шарів, що обробляють часову послідовність комплексних IQ-вибірок. Вхідний сигнал подається у вигляді двоканального тензора розмірності $2 \times N$, де канали відповідають дійсній та уявній складовим. Згорткові ядра розміру 3–5 виконують локальну обробку послідовності, дозволяючи виділяти характерні фазові переходи, амплітудні зміни та мікроструктури символів, притаманні різним типам модуляції.

Кожен згортковий блок включає операцію згортки, нелінійну активацію (ReLU) та підвибірку, що забезпечує поступове збільшення рецептивного поля та формування ієрархічного представлення сигналу. На початкових шарах мережа виділяє локальні часові закономірності, тоді як глибші рівні інтегрують їх у більш абстрактні ознаки, пов'язані з геометрією сузір'я та структурою фазових станів. Завершальний повнозв'язаний шар виконує агрегацію ознак і формує апостеріорні ймовірності класів через Softmax.

Аналіз використання базової CNN для задач АМС показує, що така архітектура ефективно замінює традиційне ручне формування статистичних ознак, забезпечуючи автоматичне навчання представлень без втрати фазової інформації. Перевагою є відносно невелика кількість параметрів і висока узагальнювальна здатність у середніх режимах SNR. Водночас обмежена глибина моделі може знижувати роздільну здатність у низькоенергетичних умовах, що обумовлює необхідність використання поглиблених або залишкових архітектур. Для аналізу впливу глибини мережі на якість класифікації розглянуто поглиблену CNN-архітектуру з трьома згортковими блоками. Збільшення кількості шарів дозволяє формувати ієрархічне представлення сигналу: від локальних фазових переходів до більш складних структур, що характеризують конкретні типи модуляції.

Проте зростання глибини мережі супроводжується ризиком деградації градієнтів і уповільненням навчання. Це обмежує практичну ефективність надто глибоких моделей без додаткових механізмів стабілізації.

Для розв'язання задачі автоматичної класифікації модуляції на основі IQ-вибірок розглянуто декілька архітектур глибоких нейронних мереж із близькою кількістю параметрів, що дозволяє виконати коректне порівняння їх ефективності: класична згорткова нейронна мережа, повністю згорткова мережа (All-Convolutional), глибока згорткова мережа та залишкова нейронна мережа (див. рис. 1). Регулювання складності моделей здійснювалося шляхом зміни кількості згорткових фільтрів та розмірності повнозв'язаних шарів при збереженні однакової довжини вхідного фрагмента IQ-вибірок та структури класифікаційного виходу.

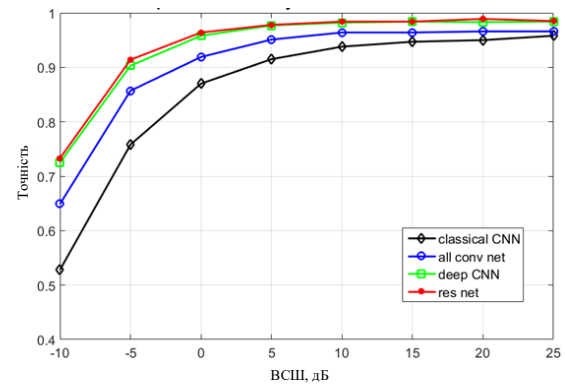


Рис. 1. Аналіз точності різних моделей залежно від відношення сигнал/шум

Кількість параметрів для кожної моделі обчислювалася аналітично як сума ваг згорткових і повнозв'язаних шарів з урахуванням зміщень. Відхилення між архітектурами не перевищувало 5–7 %, що дозволяє вважати їх еквівалентними за моделлю ємності та порівнювати саме структурні особливості, а не розмір мережі.

Найкращі показники демонструє глибока згорткова мережа (Deep CNN) (17 шарів) з 93,7 % та залишкова мережа (Residual Network) (41 шар) з 94,1 % вірного результату. Хоча залишкова мережа має набагато більше шарів, в цьому експерименті вона показала невелике покращення точності. Отримані результати свідчать, що за використаних умов навчання перевага ResNet над Deep CNN є помірною; імовірно, подальше налаштування режиму навчання може збільшити цей розрив.

З метою подолання зазначених обмежень у роботі запропоновано адаптовану архітектуру типу ResNet, що включає залишкові зв'язки між згортковими блоками. Залишкові зв'язки реалізують передачу вхідного сигналу блоку безпосередньо до його виходу, що дозволяє мережі навчати коригувальні (residual) представлення замість повного перетворення сигналу (рис. 2).

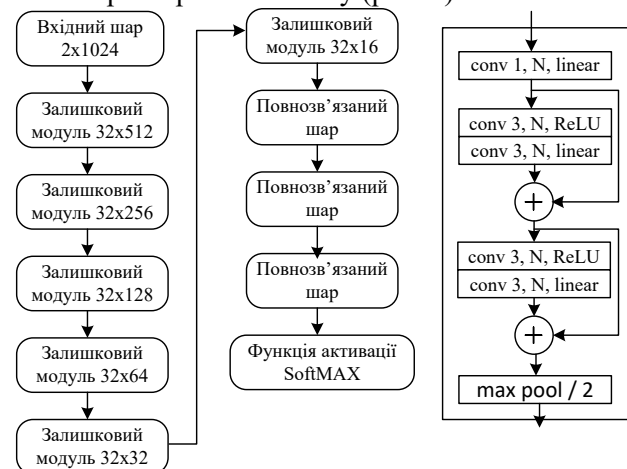


Рис. 2. Структура залишкової нейронної мережі ResNet автоматичного розпізнання модуляції та детектування сигналів (зліва) та модуль залишкової нейронної мережі (ResNet) (справа)

Такий підхід забезпечує стабільніше навчання глибших моделей та зменшує ризик втрати інформації на ранніх шарах. У задачі АМС це особливо важливо, оскільки навіть слабо виражені фазові закономірності можуть бути інформативними для класифікації при низькому відношенні сигнал/шум.

Мережа орієнтована на обробку одномірних часових послідовностей та побудована з урахуванням специфіки фазо-амплітудної структури цифрових сигналів. Вхідний шар формує тензор розмірності 2×1024 , що відповідає двом каналам (I та Q) і 1024 дискретним відлікам сигналу. Такий формат зберігає повну інформацію про миттєву фазу та амплітуду сигналу, що є критично важливим для розрізнення модуляцій із близькими статистичними характеристиками. Основу мережі становить каскад залишкових модулів зі зменшенням розмірності часової осі. Така ієрархічна структура забезпечує поступове укрупнення рецептивного поля та перехід від локальних часових ознак до глобальних структур сигналу. Зменшення розмірності реалізується через операції підвибірки (max pooling / stride), що одночасно знижує обчислювальну складність і підвищує інваріантність до часових зсувів.

Кожен залишковий модуль містить послідовність згорткових шарів із ядрами розміру 3, функціями нелінійності ReLU та лінійними перетвореннями, об'єднаними через операцію додавання з пропуском (skip) з'єднанням. Формально залишковий блок реалізує відображення:

$$y = \mathcal{F}(x, W) + x, \quad (5)$$

де \mathcal{F} – композиція згорткових перетворень, а x – вхід блоку.

Така структура дозволяє моделі навчати залишкове представлення, що суттєво зменшує проблему згасання градієнтів і стабілізує процес оптимізації при збільшенні глибини мережі.

Використання одномірних згортків уздовж часової осі є обґрунтованим з огляду на природу задачі: модуляційні ознаки проявляються у вигляді локальних фазових переходів, зміни амплітуди або характерних патернів символів. Глибші шари мережі інтегрують ці локальні ознаки в більш абстрактні представлення, що відображають структурні відмінності між класами модуляції (наприклад, відмінності у кількості фазових станів або щільності сузір'я).

Після проходження залишкових блоків формується компактне багатовимірне представлення сигналу, яке подається на повнозв'язані шари. Повнозв'язані рівні виконують нелінійну агрегацію високорівневих ознак та здійснюють перехід до

простору рішень. Фінальний шар із функцією активації Softmax реалізує багатокласову класифікацію, формуючи апостеріорні ймовірності належності сигналу до кожного класу модуляції.

Запропонована архітектура поєднує декілька ключових переваг сучасних глибоких моделей:

- автоматичне виділення ознак без ручного конструювання статистичних характеристик;
- ієрархічне формування представлення сигналу;
- стабільне навчання глибоких моделей завдяки залишковим з'єднанням;
- зменшення кількості параметрів у порівнянні з повнозв'язаними мережами аналогічної глибини;
- підвищена стійкість до шуму та варіативності параметрів каналу.

Матриця вірогідності класифікації, отримана для запропонованої залишкової нейронної мережі, наведена на рис. 3 свідчить про високу ефективність автоматичного розпізнавання видів модуляції сигналів розвідувальної інформації. Діагональні елементи матриці характеризують точність класифікації для кожного класу, тоді як позадіагональні елементи відображають структуру міжкласових помилок.

З аналізу діагональних значень видно, що запропонована ResNet-архітектура демонструє високу точність для більшості цифрових модульованих сигналів. Найкращі результати отримано для класів usb (0.99), navtex (0.98), mt63_1000 (0.98), rtty100_850 (0.97) та morse (0.97), що свідчить про ефективне виділення характерних часово-частотних структур цих сигналів. Такі модулювання мають чітко виражені спектральні та фазові ознаки, що добре узагальнюються згортковими шарами.

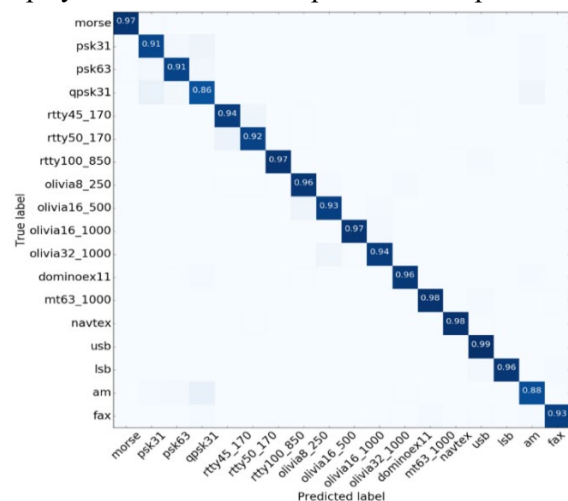


Рис. 3. Матриця вірогідності визначення сигналів

Дещо нижчі показники спостерігаються для класів qpsk31 (0.86) та am (0.88). Це пояснюється близькістю статистичних характеристик до інших фазових або амплітудних модуляцій, а також впли-

вом шуму на розподіл сузір'їв у низькоенергетичних режимах. Для аналогових модуляцій (AM, LSB, USB) частина помилок пов'язана з подібністю спектральної структури та перекриттям енергетичних характеристик.

Аналіз позадіагональних елементів показує, що помилки мають структурований характер і переважно виникають між класами з близькою фазовою або частотною організацією. Наприклад, спостерігається часткове перекриття між різними варіантами PSK або між цифровими вузькосмуговими телеграфними сигналами з близькою швидкістю передачі. Це підтверджує, що модель навчається на фізично інтерпретованих ознаках сигналу, а не демонструє випадковий характер помилок.

Висока концентрація маси ймовірності на головній діагоналі свідчить про добру роздільну здатність сформованого ознакового простору. Ієрархічна структура залишкових блоків дозволяє поєднувати локальні фазові переходи та глобальні часові патерни, що забезпечує стійкість класифікації до шуму та варіативності параметрів сигналу.

Аналіз матриці класифікації показав, що більшість помилок має структурований характер і концентрується між класами з близькими фазово-частотними характеристиками. Це свідчить про те, що у процесі навчання модель витрачає значну кількість ітерацій на обробку «легких» зразків, які вже коректно класифікуються, тоді як складні приклади потребують більшої уваги.

У класичній схемі навчання всі зразки вибираються з однаковою ймовірністю, що не враховує поточний стан моделі. Такий підхід призводить до надлишкових ітерацій і збільшення часу оптимізації, особливо при великих навчальних наборах.

З огляду на це запропоновано метод адаптивного добору навчальних зразків, що базується на перерозподілі ймовірностей їх вибору відповідно до поточних помилок класифікації.

Нехай для кожного навчального зразка x_i визначається поточна похибка класифікації:

$$e_i = 1 - p_{true}(x_i), \quad (6)$$

де $p_{true}(x_i)$ – апостеріорна ймовірність правильного класу, отримана з виходу Softmax.

На основі цієї величини формується адаптивна ймовірність вибору зразка:

$$w_i = \frac{e_i^\alpha}{\sum_{j=1}^M e_j^\alpha}, \quad (7)$$

де M – розмір навчальної вибірки, α – параметр чутливості перерозподілу.

Таким чином, зразки з більшою похибкою мають вищу ймовірність бути включеними до наступних міні-пакетів. Параметр α дозволяє керувати ступенем концентрації навчання на складних прикладах.

Такий механізм є аналогом важливісного семплінгу у стохастичній оптимізації, але реалізується на основі поточних помилок моделі, що дозволяє динамічно адаптувати процес навчання.

Алгоритм навчання включає такі етапи, рис. 4.:

1. Початкове рівномірне навчання протягом декількох епох.
2. Обчислення похибок для всіх зразків навчальної вибірки.
3. Формування адаптивного розподілу ймовірностей.
4. Генерація міні-пакетів відповідно до нового розподілу.
5. Періодичне оновлення вагового розподілу.

Для оцінювання ефективності запропонованого методу порівнювалися: класичне стохастичне градієнтне навчання (рис. 5, крива 1); адаптивне навчання з перерозподілом ймовірностей вибору (рис. 5, крива 2).

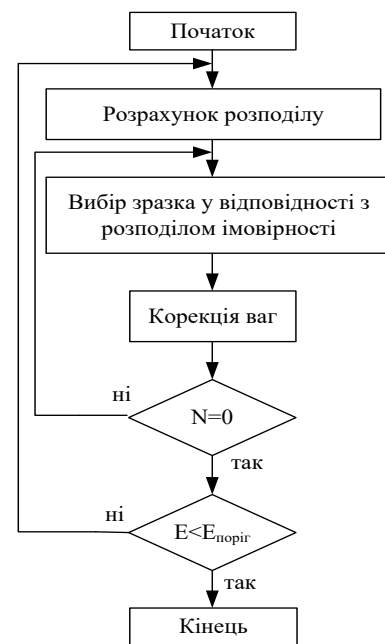


Рис. 4. Блок-схема навчання;

N – число зразків для навчання, $E_{поріг}$ – необхідне значення сумарної помилки, i – номер ітерації

Критеріями оцінювання були кількість ітерацій до досягнення заданого рівня точності, стабільність збіжності, фінальна точність класифікації. Результати показали, що адаптивний підхід дозволяє скоротити кількість необхідних ітерацій на 180–25% без зниження фінальної точності. Найбільший вигравш спостерігається у низькоенергетичних режимах, де частка складних прикладів є вищою.

З аналізу графіків на рис. 5 видно, що при малих значеннях початкової похибки кількість необхідних ітерацій навчання є відносно невеликою, оскільки параметри моделі вже знаходяться поблизу оптимального розв'язку. У цьому режимі різниця між стандартним і адаптивним алгоритмами є незначною.




Рис. 5. Залежності числа ітерацій навчання N для досягнення заданого рівня точності, від: а) початкового рівня похибки ϵ_0 ; б) від номера ітерації процедури навчання i (праворуч) для стандартного та адаптивного алгоритмів

Скорочення кількості ітерацій навчання при збереженні фінальної точності пояснюється зміною розподілу градієнтних оновлень у процесі оптимізації. У класичному стохастичному навчанні міні-пакети формуються з однаковою ймовірністю для всіх зразків, що призводить до значної частки оновлень, спрямованих на вже добре класифіковані приклади. У таких випадках величина градієнта є малою, а внесок у зменшення функції втрат – незначним.

У асимптотичному випадку при збільшенні обсягу навчальної вибірки емпіричний ризик збігається до математичного сподівання функції втрат, що забезпечує збіжність параметрів мережі до оптимального класифікатора для заданої статистичної моделі сигналу. Адаптивний механізм вибору навчальних зразків не змінює асимптотичної точки збіжності алгоритму, але змінює швидкість збіжності стохастичної оптимізації. Це пояснюється концентрацією градієнтних оновлень на прикладах із найбільшим внеском у функцію втрат.

Запропонований адаптивний механізм перерозподілу ймовірностей вибору зразків базується на похибці класифікації, що фактично реалізує важливісне семплінгування (importance sampling) у просторі навчальних даних. Це призводить до концентрації градієнтних оновлень на прикладах з найбільшою похибкою, для яких величина градієнта є більшою, а внесок у мінімізацію функції втрат – суттєвішим. У результаті швидкість змен-

шення емпіричного ризику на початкових і середніх етапах навчання зростає, що і зумовлює скорочення кількості необхідних ітерацій на 18–25 %.

Експериментально це підтверджується порівнянням кривих збіжності функції втрат і точності класифікації для стандартного та адаптивного режимів навчання. Для однакових початкових умов та ідентичної архітектури мережі адаптивний підхід демонструє швидше досягнення заданого порогу точності без статистично значущої різниці у фінальному значенні точності на тестовій вибірці.

Додатково встановлено, що метод не призводить до деградації узагальнювальної здатності моделі за умови помірних значень параметра α . Надмірна концентрація на складних прикладах може спричинити перенавчання, що підтверджує необхідність контролю адаптивності.

Найбільший вигравш спостерігається у низькоенергетичних режимах (низький SNR), що пояснюється збільшенням частки складних прикладів у навчальному наборі. У таких умовах класи модуляції мають перекриті статистичні характеристики, а частина зразків розташована поблизу межі прийняття рішення. Адаптивне семплінгування автоматично підвищує частоту обробки саме цих прикладів, що сприяє кращому формуванню роздільної поверхні класифікатора та прискорює стабілізацію параметрів мережі.

Висновки

У статті проведено системний аналіз глибоких згорткових архітектур для задачі автоматичної класифікації модуляції на основі комплексних IQ-вибірок фіксованої довжини. Обґрунтовано доцільність використання одномірних згорткових шарів для автоматичного виділення часово-фазових закономірностей сигналу без ручного формування статистичних ознак. Показано, що ієрархічне формування представлення дозволяє моделі ефективно інтегрувати локальні фазові переходи та глобальні структурні особливості модуляції.

Порівняльний аналіз нейромережових архітектур із близькою кількістю параметрів підтвердив, що адаптована ResNet-структура забезпечує більш стабільну точність класифікації, особливо у низькоенергетичних режимах. Залишкові з'єднання сприяють покращенню збіжності навчання та формуванню більш інформативного ознакового простору.

Запропоновано метод адаптивного добору навчальних зразків, що базується на перерозподілі ймовірностей їх вибору відповідно до поточних помилок класифікації. Експериментально встановлено, що адаптивний підхід дозволяє скоротити кількість ітерацій навчання на 18–25 % без зниження фінальної точності, причому найбільший ефект досягається в умовах низького відношення сигнал/шум. Отримані результати підтверджують ефективність поєднання архітектурних удосконалень і оптимізації процесу навчання для задач АМС.

ЛІТЕРАТУРА

- [1] Abd-Elaziz O. F., Abdalla M., Elsayed R. A. Deep Learning-Based Automatic Modulation Classification Using Robust CNN Architecture for Cognitive Radio Networks. *Sensors*. Vol. 23, No. 23. Art. 9467. 2023. DOI: <https://doi.org/10.3390/s23239467>.
- [2] Harper C. A., Thornton M. A., Larson E. C. Automatic Modulation Classification with Deep Neural Networks. *Electronics*. Vol. 12, No. 18. Art. 3962. 2023. DOI: <https://doi.org/10.3390/electronics12183962>.
- [3] Peng Y., Guo L., Yan J., Tao M., Fu X., Lin Y., Gui G. Automatic Modulation Classification Using Deep Residual Neural Network with Masked Modeling for Wireless Communications. *Drones*. Vol. 7, No. 6. Art. 390. 2023. DOI: <https://doi.org/10.3390/drones7060390>.
- [4] Ben Chikha H., Alaerjan A., Jabeur R. Automatic Classification of 5G Waveform-Modulated Signals Using Deep Residual Networks. *Sensors*. Vol. 25, No. 15. Art. 4682. 2025. DOI: <https://doi.org/10.3390/s25154682>.
- [5] Zheng Q., Tian X., Yu Z., Wang H., Elhanashi A., Saponara S. DL-PR: Generalized automatic modulation classification method based on deep learning with priori regularization. *Engineering Applications of Artificial Intelligence*. Vol. 122. Art. 106082. 2023. DOI: <https://doi.org/10.1016/j.engappai.2023.106082>.
- [6] Katharopoulos A., Fleuret F. Not All Samples Are Created Equal: Deep Learning with Importance Sampling. In: *Proceedings of the 35th International Conference on Machine Learning (ICML 2018)*. PMLR. Vol. 80. P. 2525–2534. 2018. URL: <https://proceedings.mlr.press/v80/katharopoulos18a.html>.
- [7] Leblebici M., Çalhan A., Cicioğlu M. Deep learning-based modulation recognition with constellation diagram: A case study. *Physical Communication*. Vol. 63. Art. 102285. 2024. DOI: <https://doi.org/10.1016/j.phycom.2024.102285>.
- [8] Nasir S., Sheikh S. A., Malik F. M. Automatic modulation classification using convolutional neural network and support vector machine. *Digital Signal Processing*. Vol. 164. Art. 105249. 2025. DOI: <https://doi.org/10.1016/j.dsp.2025.105249>.

Козловський В. В., Бобров С. І., Макєєв І. Г., Німич О. В.

ГЛИБОКІ CNN ТА RESNET-АРХІТЕКТУРИ ДЛЯ АВТОМАТИЧНОЇ КЛАСИФІКАЦІЇ МОДУЛЯЦІЇ

У статті розглянуто задачу автоматичної класифікації модуляції сигналів у сучасних системах радіомоніторингу та когнітивного радіо. Виконано системний аналіз застосування глибоких згорткових і залишкових нейронних мереж для розпізнавання типів модуляції на основі комплексних IQ-вибірок фіксованої довжини. Обґрунтовано доцільність використання одномірних згорткових шарів, що дозволяють автоматично виділяти часово-фазові закономірності сигналів без попереднього формування статистичних або спектральних ознак. Розглянуто декілька архітектур глибоких нейронних мереж, зокрема базову згорткову модель, поглиблену CNN-архітектуру та адаптовану залишкову мережу типу ResNet з близькою кількістю параметрів, що забезпечує коректність порівняння їх ефективності.

Проведене моделювання показало, що використання залишкових з'єднань дозволяє підвищити стабільність навчання глибоких моделей і забезпечує вищу точність класифікації, особливо в умовах низького відношення сигнал/шум. Аналіз матриці класифікації дозволив виявити структурований характер міжкласових помилок, що свідчить про наявність складних прикладів у навчальній вибірці. На основі цього запропоновано адаптивний алгоритм добору навчальних зразків, який здійснює перерозподіл ймовірностей їх вибору відповідно до поточних помилок класифікації. Запропонований метод фактично реалізує механізм важливішого семплінгування у процесі стохастичної оптимізації та забезпечує концентрацію навчання на найбільш інформативних прикладах.

Результати експериментальних досліджень показали, що використання адаптивного механізму формування міні-пакетів дозволяє скоротити кількість ітерацій навчання на 18–25% без зниження фінальної точності класифікації. Отримані результати підтверджують ефективність поєднання глибоких нейромережових архітектур та алгоритмічної оптимізації процесу навчання для задач автоматичної класифікації модуляції сигналів в умовах невизначеності параметрів радіосередовища.

Ключові слова: фазова модуляція, частотна модуляція, виявлення сигналів, детектування сигналів, нейронні мережі.

Kozlovskiy V., Bobrov S., Makieiev I., Nimych O.

DEEP CNN AND RESNET ARCHITECTURES FOR AUTOMATIC MODULATION CLASSIFICATION.

The paper addresses the problem of automatic modulation classification (AMC) in modern radio monitoring and cognitive radio systems. A systematic analysis of deep convolutional and residual neural network architectures for modulation recognition based on fixed-length complex IQ samples is presented. The feasibility of using one-dimensional convolutional layers is substantiated, as they enable the automatic extraction of time–phase signal patterns without preliminary construction of statistical or spectral features. Several deep neural network architectures are investigated, including a baseline convolutional model, a deeper CNN architecture, and an adapted ResNet structure with a comparable number of parameters, which ensures a fair comparison of their performance.

The simulation results demonstrate that the use of residual connections improves the stability of training deep models and provides higher classification accuracy, especially under low signal-to-noise ratio (SNR) conditions. The analysis of the confusion matrix reveals a structured pattern of inter-class errors, indicating the presence of difficult samples in the training dataset. Based on this observation, an adaptive training sample selection algorithm is proposed, which redistributes sampling probabilities according to the current classification errors. The proposed method effectively implements an importance sampling mechanism in the stochastic optimization process and focuses training on the most informative examples.

Experimental results show that the use of the adaptive mini-batch formation mechanism reduces the number of training iterations by 18–25% without degrading the final classification accuracy. The obtained results confirm the effectiveness of combining deep neural network architectures with adaptive training optimization strategies for automatic modulation classification tasks under uncertain radio channel conditions.

Keywords: phase modulation, frequency modulation, signal detection, signal demodulation, neural networks.

Дата першого надходження: 13.02.2026 р.

Дата прийняття до друку: 10.03.2026 р.

Дата публікації: 27.04.2026 р.