

DOI: <https://doi.org/10.36910/6775-2524-0560-2026-63-38>

УДК 621.391.83:004.8

Бобров Сергій Ігорович¹, аспірант

<https://orcid.org/0000-0003-3604-2256>

Якимчук Наталія Миколаївна², к.т.н., доцент

<https://orcid.org/0000-0002-8173-449X>

Євсюк Микола Миколайович², к.т.н., доцент

<https://orcid.org/0000-0002-3768-8959>

¹Національний університет «Київський авіаційний інститут», м. Київ, Україна

²Луцький національний технічний університет, м. Луцьк, Україна

ФОРМУВАННЯ НАВЧАЛЬНИХ IQ-ВИБІРОК ДЛЯ СИСТЕМ АВТОМАТИЧНОЇ КЛАСИФІКАЦІЇ МОДУЛЯЦІЇ В УМОВАХ НЕКООПЕРАТИВНОГО РАДІОПРИЙМАННЯ

Бобров С.І., Якимчук Н.М., Євсюк М.М. Формування навчальних IQ-вибірок для систем автоматичної класифікації модуляції в умовах некооперативного радіоприймання. У роботі досліджено проблему доменно-розподільчої невідповідності між синтетичними та реальними IQ-сигналами в задачах автоматичної класифікації модуляції для систем радіорозвідки та аналізу каналів зв'язку безпілотних літальних апаратів. Показано, що використання класичних синтетичних підходів не забезпечує необхідної узагальнювальної здатності нейромережевих моделей у реальних умовах радіоприймання через неврахування комплексної дії каналних, апаратних, динамічних та інтерференційних спотворень. Запропоновано модель доменно-розподільчої невідповідності IQ-сигналів як багатовимірного статистичного розходження між синтетичним та реальним доменами. Розроблено інтегральний показник доменної невідповідності, який дозволяє кількісно оцінювати ступінь статистичного розходження між навчальними та цільовими сигналами. Запропоновано фізично обґрунтований метод формування квазіреальних IQ-вибірок, що реалізує послідовний перехід від ідеалізованого сигналу до фізично спотвореного та квазіреального домену. Для статистичного уточнення домену використано умовну генеративно-конкуруючу мережу CGAN. На відміну від традиційних GAN-підходів, CGAN застосовується не для збільшення обсягу даних, а для наближення статистичних характеристик синтетичних сигналів до реального радіодомену. Введено поняття доменно-орієнтоване CGAN навчання, за якого дискримінатор оцінює не лише належність сигналу до класу real/fake, а й ступінь його відповідності статистичній структурі реального радіоефіру. Для експериментальної перевірки сформовано 11 наборів IQ-сигналів із поступовим ускладненням умов приймання. Результати навчання ResNet моделей підтвердили, що використання фізично спотворених сигналів разом з доменною адаптацією забезпечує зменшення доменного розриву й підвищення точності класифікації в реальному домені.

Ключові слова: автоматична класифікація модуляції, IQ-сигнали, доменно-розподільча невідповідність, детектування сигналів, нейронні мережі.

Bobrov S., Yakymchuk N., Yevsiuk M. Formation of Training IQ Datasets for Automatic Modulation Classification Systems under Non-Cooperative Radio Reception Conditions. This paper investigates the problem of domain-distribution mismatch between synthetic and real IQ signals in automatic modulation classification tasks for radio intelligence systems and unmanned aerial vehicle communication channel analysis. It is shown that conventional synthetic-data-based approaches do not provide the required generalization capability of neural network models under real radio reception conditions due to insufficient consideration of the combined influence of channel, hardware, dynamic, and interference distortions. A model of domain-distribution mismatch is proposed in the form of a multidimensional statistical discrepancy between synthetic and real signal domains. An integral domain mismatch metric is developed to quantitatively evaluate the statistical divergence between training and target signals. A physically grounded method for generating quasi-real IQ datasets is proposed, implementing a sequential transition from an idealized signal to physically distorted and quasi-real domains. A conditional generative adversarial network (CGAN) is employed for statistical domain refinement. Unlike conventional GAN-based approaches, the proposed CGAN is used not for data augmentation but for approximating the statistical characteristics of synthetic signals to those of the real radio domain. The concept of domain-oriented CGAN training is introduced, in which the discriminator evaluates not only the real/fake class membership of a signal but also the degree of its correspondence to the statistical structure of the real radio environment. For experimental validation, eleven IQ-signal datasets with progressively increasing reception complexity were generated. The results obtained using ResNet-based models confirmed that the use of physically distorted signals together with domain adaptation reduces the domain gap and improves classification accuracy in the real domain.

Keywords: automatic modulation classification, IQ signals, domain-distribution mismatch, signal detection, neural networks.

Постановка проблеми. Автоматична класифікація видів модуляції (Automatic Modulation Classification, АМС) є однією з ключових задач сучасних систем радіотехнічної розвідки, радіомоніторингу та аналізу каналів зв'язку і використовується для виявлення типу передавача, оцінювання параметрів каналу зв'язку та аналізу структури сигналів в умовах невизначеності параметрів випромінювання. Особливістю задач радіорозвідки є приймання сигналів в некооперативних умовах, за яких відсутня апріорна інформація про тип модуляції, параметри синхронізації та характеристики передавача. Додатково сигнали каналів зв'язку БПЛА

характеризуються низьким відношенням сигнал/шум, доплерівськими зсувами, нестабільністю генераторів, нестационарністю каналу та впливом радіоелектронних завад. Сукупна дія цих факторів суттєво ускладнює автоматичну класифікацію модуляції та знижує ефективність класичних алгоритмів аналізу сигналів.

В останні роки для розв'язання задач АМС активно застосовуються методи глибокого навчання, зокрема згорткові та залишкові нейронні мережі, здатні автоматично формувати інформативні ознаки IQ-сигналів. Проте ефективність таких моделей значною мірою залежить від якості та репрезентативності навчальних вибірок. Формування великих наборів реальних маркованих сигналів є складним через обмежену доступність реальних перехоплених сигналів та високу варіативність умов приймання. У зв'язку з цим для навчання АМС-моделей переважно використовуються синтетичні IQ-вибірки, сформовані шляхом математичного моделювання сигналів і каналу зв'язку. Перевагою такого підходу є можливість генерації великих обсягів даних із контрольованими параметрами спотворень. Однак синтетичні набори часто базуються на спрощених моделях каналу та апаратури, що не дозволяє повною мірою відтворити умови реального радіоефіру. Як наслідок, між синтетичними та реальними сигналами виникає невідповідність, яка проявляється у відмінності статистичних, спектральних і фазових характеристик сигналів.

Проблема доменно-розподільчої невідповідності є однією з основних причин погіршення узагальнювальної здатності нейромережових моделей АМС під час переходу від лабораторних умов до реальних систем радіомоніторингу. Перспективним напрямом розв'язання цієї проблеми є формування квазіреальних IQ-вибірок, статистично наближених до сигналів реального радіоефіру. Такий підхід передбачає поєднання фізично обґрунтованого моделювання спотворень із використанням генеративних нейронних мереж для відтворення складних багатовимірних залежностей, характерних для реальних сигналів. Це дозволяє зменшити доменно-розподільчу невідповідність між синтетичними та реальними сигналами та підвищити узагальнювальну здатність систем автоматичної класифікації модуляції.

Аналіз останніх досліджень і публікацій.

Автоматична класифікація модуляції є одним із ключових напрямів інтелектуального аналізу радіосигналів. Перехід від класичних методів, заснованих на ручному виділенні ознак, до методів глибокого навчання дозволив виконувати класифікацію без попереднього аналітичного опису характеристик сигналу. Одними з перших робіт, які продемонстрували ефективність згорткових нейронних мереж для оброблення IQ-сигналів, стали дослідження [1], де було показано можливість безпосереднього навчання CNN на часових відліках радіосигналів

Подальший розвиток АМС значною мірою пов'язаний із появою відкритих RadioML-подібних наборів даних, сформованих за допомогою GNU Radio [2]. Вони забезпечили експериментальну базу для порівняння CNN, ResNet, LSTM та комбінованих нейромережових архітектур. Водночас подальші дослідження показали, що висока точність класифікації на синтетичних наборах не гарантує ефективної роботи моделей у реальних умовах приймання. Зокрема, у [3] було підтверджено суттєвий вплив частотного зсуву, багатопроменевого поширення та апаратних спотворень на результати АМС

Окремий напрям досліджень пов'язаний із використанням методів доповнення даних [4]. Було показано, що поворот IQ-сузір'я, додавання шуму та інші перетворення дозволяють підвищити точність класифікації за обмеженого обсягу навчальної вибірки. Однак такі підходи переважно виконують розширення даних у межах одного синтетичного домену та не враховують складну фізичну структуру реального радіоефіру.

Для подолання дефіциту маркованих сигналів активно застосовуються генеративні моделі GAN і CGAN [5-7]. Їх використання дозволяє формувати додаткові IQ-сигнали з урахуванням типу модуляції. Проте більшість існуючих підходів розглядає генеративні мережі лише як інструмент для доповнення даних, а не як механізм статистичного наближення синтетичного домену до реального.

Сучасні дослідження також демонструють зростання інтересу до методів доменної адаптації, спрямованих на підвищення переносимості АМС-моделей між різними умовами приймання [8-9]. Проте наявні підходи мають низьку обмежень. По-перше, значна частина робіт виконує навчання й тестування на близьких за статистикою синтетичних наборах, тому отримані результати не повною мірою характеризують реальну узагальнювальну здатність моделей. По-друге, більшість GAN/CGAN-підходів недостатньо враховує фізично обґрунтовану структуру доменних спотворень, характерних для реальних сигналів каналів зв'язку БПЛА. Таким чином, актуальною залишається

задача формування квазіреальних IQ-вибірок, статистично наближених до умов реального радіофіру. Для її розв'язання необхідне поєднання фізично обґрунтованого моделювання каналних, апаратних і динамічних спотворень із генеративним статистичним уточненням синтетичного домену.

Мета дослідження полягає в розробленні методу формування квазіреальних IQ-вибірок для автоматичної класифікації модуляції сигналів розвідувальної інформації на основі фізично обґрунтованого моделювання спотворень і генеративного статистичного уточнення синтетичного домену.

Виклад основного матеріалу.

Однією з основних причин зниження ефективності систем автоматичної класифікації модуляції є невідповідність статистичних характеристик синтетичних та реальних IQ-сигналів. Навіть за використання фізично обґрунтованих моделей каналу та апаратних спотворень аналітичне моделювання не дозволяє повністю відтворити складні нелінійні залежності, характерні для реального радіофіру. У результаті нейромережеві моделі АМС формують ознаки, надмірно адаптовані до модельного домену, що призводить до деградації якості класифікації під час роботи з реальними сигналами. Ця проблема в сучасних дослідженнях розглядається як проблема доменно-розподільчої невідповідності.

У задачах АМС доменно-розподільча невідповідність проявляється в тому, що синтетичні IQ-сигнали, сформовані в модельованому середовищі, мають інші статистичні, спектральні та фазові характеристики порівняно з реальними сигналами некооперативного радіоприймання. Особливо критично це проявляється для сигналів каналів зв'язку БПЛА, параметри яких змінюються під впливом руху апарата, нестабільності генераторів, багатопроменового поширення та зовнішніх завад.

Формально введемо два домени:

$$D_s = X_s, P_s(x), D_r = X_r, P_r(x), \quad (1)$$

де X_s, X_r – множина синтетичних та реальних IQ-сигналів; $P_s(x), P_r(x)$ – відповідні функції розподілу ознак сигналів.

Доменно-розподільча невідповідність виникає за умови $P_s(x) \neq P_r(x)$.

На відміну від класичних задач класифікації, у системах АМС джерелом такої невідповідності є не лише шум, а сукупна дія фізичних факторів, що впливають на структуру IQ-сигналу. Основними причинами формування доменного розриву є каналні спотворення, нестабільність генераторів, рух БПЛА, апаратні дефекти приймального тракту та інтерференційний вплив.

Узагальнену модель реального IQ-сигналу подамо у вигляді:

$$x(t) = \alpha(t)s((1 + \varepsilon)t - \tau)e^{j(2\pi\Delta f t + \phi(t))} + i(t) + n(t), \quad (2)$$

де $s(t)$ – ідеальний модульований сигнал; $\alpha(t)$ – коефіцієнт каналного ослаблення; ε – похибка частоти дискретизації; τ – часовий зсув; Δf – частотний зсув несучої; $\phi(t)$ – фазовий шум; $i(t)$ – інтерференційна складова; $n(t)$ – адитивний шум.

Запропонована модель описує основні фактори, які формують відмінність між синтетичним та реальним доменами.

Канальні спотворення виникають унаслідок багатопроменового поширення, селективного завмирання та зміни умов поширення сигналу. Для каналів зв'язку БПЛА характерними є доплерівські зсуви та нестационарність параметрів каналу, що призводить до часової нестабільності спектра та зміни статистики IQ-послідовностей.

Нестабільність генераторів проявляється у вигляді фазового шуму та частотного дрейфу, які спричиняють випадкові фазові флуктуації та зміщення спектра сигналу. Для АМС такі ефекти є критичними, оскільки нейромережа може формувати ознаки, чутливі до спектрального положення та фазової структури сигналу.

Особливістю реальних IQ-сигналів також є наявність апаратних дефектів приймального тракту, зокрема I/Q-дисбалансу, зсуву нульового рівня, нелінійності підсилювачів та похибок

аналого-цифрового перетворення. Такі спотворення призводять до деформації сигнального сузір'я та зміни статистичних характеристик сигналу.

Інтерференційні спотворення виникають через одночасну присутність суміжних каналів, інших джерел випромінювання та навмисних завад. У результаті змінюється часова та спектральна структура IQ-сигналів, що суттєво ускладнює задачу автоматичної класифікації модуляції.

Для кількісного оцінювання відмінності між синтетичним і реальним доменами запропоновано інтегральний показник доменно-розподільчої невідповідності, що базується на зваженій оцінці нормованих часткових показників спотворень:

$$\Delta_D = w_1 \Delta_{SNR} + w_2 \Delta_{CFO} + w_3 \Delta_{IQ} + w_4 \Delta_{PSD} + w_5 \Delta_\phi + w_6 \Delta_{INT}, \quad (3)$$

де Δ_{SNR} – відмінність розподілів відношення сигнал/шум; Δ_{CFO} – різниця статистики частотних зсувів; Δ_{IQ} – показник I/Q-дисбалансу; Δ_{PSD} – спектральне розходження; Δ_ϕ – фазова нестабільність; Δ_{INT} – рівень інтерференційної невідповідності; w_i – вагові коефіцієнти.

На відміну від підходів, у яких доменний розрив оцінюється лише через SNR або окремі параметри каналу, запропонований показник комплексно враховує сукупну дію каналних, апаратних та динамічних спотворень.

Для оцінювання спектральної складової доменно-розподільчої невідповідності використовується нормована відстань між спектральними густинами потужності:

$$\Delta_{PSD} = \frac{\int |S_s(f) - S_r(f)| df}{\int S_r(f) df}, \quad (4)$$

де $S_s(f)$ – спектральна густина синтетичних сигналів; $S_r(f)$ – спектральна густина реальних сигналів.

Таким чином, доменно-розподільча невідповідність IQ-сигналів розглядається як багатовимірне статистичне розходження між синтетичними та реальними реалізаціями сигналів. Запропонований показник Δ_D дозволяє формалізувати ступінь цієї невідповідності та використовувати його як критерій оцінювання ефективності формування квазіреальних IQ-вибірок.

Загальний метод генерації квазіреальних IQ-сигналів.

Ефективність систем автоматичної класифікації модуляції значною мірою залежить від відповідності навчальних даних реальним умовам радіоприймання. У більшості існуючих підходів синтетичні IQ-вибірki формуються шляхом генерації ідеалізованих сигналів із подальшим додаванням окремих типів шуму або спрощених моделей каналу. Такий підхід дозволяє формувати великі обсяги даних, однак не відтворює повною мірою складну структуру спотворень реального радіоефіру.

Процес формування квазіреальних IQ-сигналів складається з трьох основних етапів.

1. Формування ідеального сигналу. На першому етапі генерується ідеальний цифровий сигнал заданого типу модуляції: BPSK; QPSK; QAM; FSK; OFDM; APSK та ін. у вигляді комплексної IQ-послідовності $s(t) = I(t) + jQ(t)$. На цьому етапі сигнал ще не містить спотворень і відповідає ідеалізованому домену передавання.

2. Формування фізично спотвореного домену.

На другому етапі до IQ-сигналу застосовується параметризована модель фізичних спотворень. Узагальнено процес формування спотвореного сигналу можна представити через F_{phys} – оператор фізично обґрунтованих спотворень:

$$x_d(t) = F_{phys}\{s(t)\}, \quad (5)$$

На цьому етапі формується проміжний домен спотворених IQ сигналів, який вже містить AWGN; CFO; SFO; фазовий шум; I/Q-дисбаланс; згасання; доплерівські зсуви; імпульсні та суміжні завади. Порівняно з класичними синтетичними наборами, такий підхід дозволяє суттєво розширити статистичне різноманіття сигналів та наблизити їх до реальних умов радіоефіру.

3. Генеративне статистичне уточнення та доменна адаптація.

Навіть після врахування фізичних спотворень синтетичний домен не повністю відповідає реальним умовам приймання. Це пов'язано з тим, що аналітичні моделі каналу та апаратури не здатні описати всі багатовимірні залежності реального радіоефіру.

Для подальшого зменшення доменно-розподільчої невідповідності використовується генеративне статистичне уточнення синтетичного домену та доменна адаптація. На цьому етапі виконується наближення статистичних характеристик IQ-сигналів до реального радіодомену, що дозволяє формувати квазіреальні IQ-вибірки для навчання АМС-моделей.

Для цього запропоновано використовувати генеративно-конкуруючу мережу CGAN, яка виконує статистичне уточнення синтетичного домену.

Процес формування квазіреального IQ-сигналу описується виразом:

$$x_q(t) = G_{CGAN}\{x_d(t), y\}, \quad (6)$$

де $x_d(t)$ – фізично спотворений сигнал; y – мітка класу модуляції; G_{CGAN} – генеративна модель CGAN; $x_q(t)$ – квазіреальний IQ-сигнал.

На відміну від класичних GAN-підходів, орієнтованих на розширення навчальної вибірки, CGAN використовується не лише для збільшення кількості навчальних прикладів, а й для статистичного узгодження синтетичного та реального доменів. У результаті формується проміжний квазіреальний домен, статистично наближений до сигналів реального радіомоніторингу.

Подальший етап доменної адаптації виконує узгодження статистичних характеристик вихідного та цільового доменів без необхідності повного повторного навчання моделі. Основною задачею доменної адаптації є мінімізація статистичної різниці між доменами $P_s(x) \rightarrow P_t(x)$.

Для цього використовується метод змагальної доменної адаптації, у якому додатковий доменний дискримінатор визначає походження ознак сигналу, тоді як основна мережа навчається формувати доменно-інваріантні представлення IQ-сигналів.

Функцію втрат доменної адаптації подамо у вигляді:

$$L = L_{AMC} + \lambda L_{DA}, \quad (7)$$

де L_{AMC} – функція втрат класифікації модуляції; L_{DA} – функція доменної адаптації; λ – ваговий коефіцієнт.

Таким чином, неймережа одночасно оптимізується для коректної класифікації модуляції та статистичного узгодження доменів. Це дозволяє зменшити інтегральний показник доменно-розподільчої невідповідності, підвищити інваріантність ознак та покращити узагальнювальну здатність АМС-моделей.

Отже, запропонована схема формування навчальних даних реалізує послідовний перехід «Ідеальний \rightarrow Спотворений \rightarrow Квазіреальний» сигнал що забезпечує поступове наближення статистичних характеристик синтетичних IQ-сигналів до умов реального радіоефіру.

Архітектура CGAN для формування квазіреального радіодомену.

Для статистичного уточнення синтетичного домену запропоновано використати умовну генеративно-конкуруючу мережу CGAN. Її призначення в межах роботи полягає не лише у збільшенні обсягу навчальних даних, а у формуванні квазіреальних IQ-сигналів, статистично наближених до реального радіодомену.

CGAN – це модель машинного навчання, де як генератор, так і дискримінатор обумовлені допоміжною інформацією, такою як мітки класів y , які діють як розширення латентного простору z для генерації та розрізнення синтезованих даних [6]. Отже, CGAN може навчитися відображенню випадкового вектора шуму z на вихідні дані модуляції x , обумовлені міткою класу y . CGAN також можна змоделювати як мінімаксу гру для двох гравців, де функція значення задається як [6]:

$$\min_G \max_D V \max(D, G) = E_{x \sim p_{data}(x)} [\log D(x|y)] + E_{z \sim p_z(z)} [\log (1 - D(G(z|y)))] \quad (8)$$

де $D(x|y)$ та $G(z|y)$ – це функції дискримінатора та генератора для заданої мітки y відповідно.

На відміну від класичних GAN, умовна структура CGAN дозволяє керувати типом згенерованого сигналу та формувати IQ-вибірки для конкретних класів модуляції. Це є важливим

для задач АМС, оскільки навчальна вибірка має зберігати відповідність між сигналом і його міткою класу.

У запропонованій методиці CGAN використовується як засіб статистичного уточнення домену. Тобто генератор навчається формувати не просто додаткові синтетичні зразки, а квазіреальні IQ-сигнали, які зберігають мітку модуляції та мають статистичні характеристики, ближчі до реальних сигналів радіомоніторингу.

Архітектура генератора може бути реалізована як послідовність повнозв'язних шарів із функцією активації LeakyReLU та пакетною нормалізацією (рис. 1). Така структура стабілізує навчання, зменшує ризик деградації градієнтів і забезпечує формування узгоджених IQ-послідовностей для заданого класу модуляції.

Дискримінатор D, структура якого наведена на рис. 2, виконує оцінювання ступеня відповідності IQ-сигналу реальному радіодомену. У класичних GAN дискримінатор вирішує задачу бінарної класифікації $D(x) \rightarrow \{real, fake\}$. Проте для задач АМС такого критерію недостатньо, оскільки навіть формально «реалістичний» сигнал може не відповідати статистичній структурі реального радіоефіру.

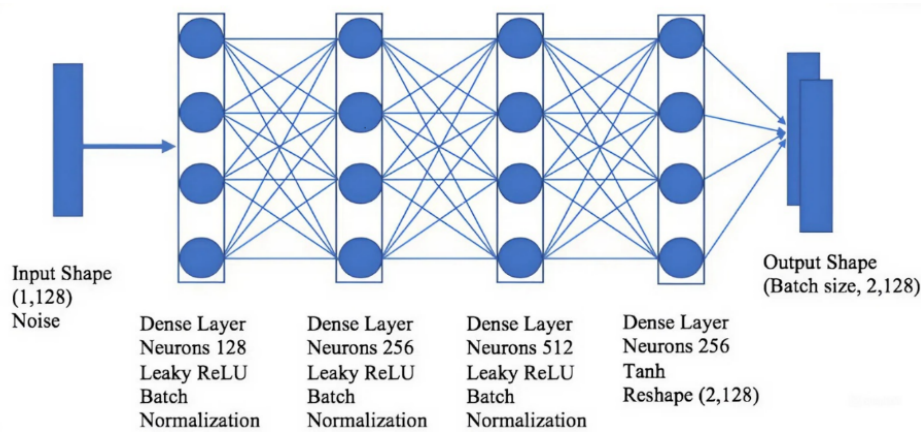


Рисунок 1 – Модель генератора CGAN [6]

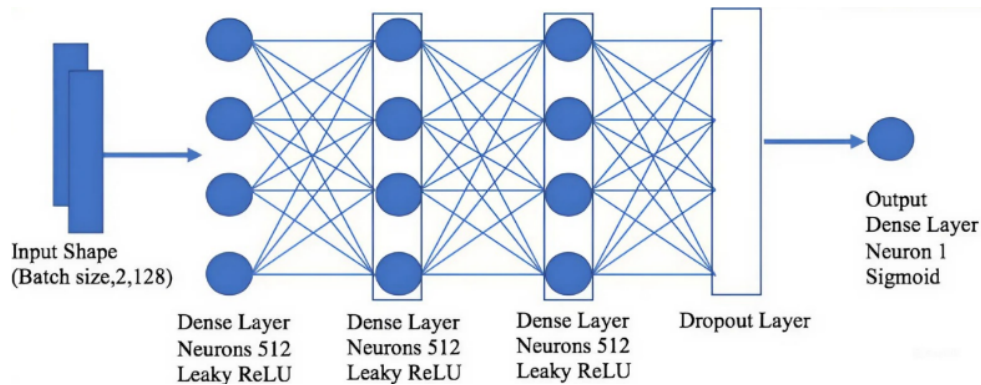


Рисунок 2 – Модель дискримінатора CGAN [6]

У зв'язку з цим вводиться поняття доменно-орієнтоване CGAN навчання, під яким розуміється режим навчання CGAN, де дискримінатор оцінює не лише належність сигналу до класу real/fake, а й ступінь його статистичного наближення до реального домену.

У такому випадку дискримінатор виконує дві функції розпізнавання синтетичних і реальних сигналів та оцінювання подібності доменів.

Функцію дискримінатора можна подати як $D(x) \rightarrow \{P_{real}, P_{domain}\}$, для якої P_{real} – ймовірність належності сигналу до реального класу; P_{domain} – оцінка близькості до статистики реального домену.

На відміну від класичних GAN, запропонований підхід орієнтований не на візуальну або формальну подібність сигналів, а на узгодження всіх часткових характеристик. У результаті

генератор навчається формувати сигнали, які мінімізують інтегральний показник доменної невідповідності $\Delta D \rightarrow \min$.

Таким чином, запропонована архітектура CGAN реалізує перехід від класичної генерації синтетичних наборів до формування квазіреального радіодомену, орієнтованого на практичне застосування систем АМС у задачах радіорозвідки та аналізу сигналів каналів зв'язку БПЛА.

На відміну від існуючих GAN-підходів, запропонована методика враховує фізично обґрунтовану структуру доменних спотворень і забезпечує статистичне наближення навчальних IQ-вибірок до умов реального радіоефіру.

Експериментальна перевірка.

Для експериментальної перевірки запропонованого методу сформовано серію з одинадцяти наборів IQ-сигналів, які відрізняються ступенем наближення до реальних умов некооперативного радіоприймання (Табл.1). Перший набір містить ідеалізовані сигнали без спотворень D0, тоді як кожен наступний послідовно доповнюється окремими групами фізично обґрунтованих каналних, апаратних та інтерференційних спотворень. Останній набір D10 формується шляхом статистичного уточнення фізично спотворених сигналів за допомогою CGAN та подальшої доменної адаптації.

Таблиця 1 – Серії наборів тестових IQ-сигналів

№	Назва	Склад спотворень	Призначення
D0	Ideal	Без спотворень	Базова оцінка класифікатора
D1	AWGN	Адитивний білий шум	Перевірка впливу SNR
D2	CFO	Частотний зсув + AWGN	Оцінка чутливості до нестабільності генераторів
D3	Phase	Фазовий зсув + CFO + AWGN	Оцінка впливу фазової нестабільності
D4	SFO	Зсув частоти дискретизації	Перевірка часової деформації сигналу
D5	Fading	Rayleigh/Rician/Watterson-завмирання	Оцінка впливу каналу поширення
D6	Band-limited	Обмеження смуги пропускання	Імітація фільтрів приймача
D7	Hardware	I/Q-дисбаланс, DC offset, фазовий шум	Оцінка апаратних дефектів
D8	Interference	Суміжні сигнали, імпульсні завади	Оцінка стійкості до радіоелектронного впливу
D9	Full physical	Усі фізично обґрунтовані спотворення	Наближений до реального синтетичний домен
D10	Quasi-real	D9 + CGAN refinement + domain adaptation	Основний набір запропонованого методу

Для кожного класу модуляції та кожного рівня SNR формується однакова кількість IQ-фрагментів, що забезпечує баланс класів і виключає зміщення результатів через нерівномірність навчальної вибірки (Табл. 2).

Таблиця 2 – Розподіл фрагментів тестування

Частина вибірки	Частка	Призначення
Навчальна вибірка	70 %	Навчання CNN/ResNet
Валідаційна вибірка	15 %	Підбір гіперпараметрів
Тестова синтетична вибірка	15 %	Тестування в synthetic domain
Тестова вибірка реального домену	окремо	Оцінювання узагальнювальної здатності

Запропонована конфігурація дозволяє оцінити не лише загальну точність АМС, а й внесок окремих груп спотворень у формування доменно-розподільчої невідповідності між синтетичними та реальним наборами даних.

Для експериментальної перевірки використано базову CNN-модель та ResNet-архітектуру із залишковими зв'язками, яка характеризується підвищеною стійкістю до складних статистичних спотворень. Точність класифікації оцінювалась як частка правильно визначених типів модуляції для тестових IQ-сигналів у діапазоні SNR від -10 до +25 дБ. Експериментальне порівняння проводилось за чотирма сценаріями (Табл. 3).

Таблиця 3 – Сценарії тестування

Сценарій	Навчання	Тестування	Призначення
S1	D0	D0	Базова точність в ідеальних умовах
S2	D0	D9 / real-like	Оцінювання впливу доменного розриву
S3	D9	D9 / real-like	Ефект фізично обґрунтованих спотворень

S4	D10	D9 / real-like / real	Ефект CGAN та доменної адаптації
----	-----	-----------------------	----------------------------------

Такий підхід дозволяє послідовно оцінити вплив фізично обґрунтованих спотворень, статистичного уточнення домену та адаптації на узагальнювальну здатність АМС-моделі.

Рисунок 3 демонструє залежність точності автоматичної класифікації модуляції від рівня SNR для різних типів доменів IQ-сигналів. Отримані результати підтверджують наявність суттєвого доменного розриву між ідеалізованими синтетичними даними та реальними сигналами радіоефіру. Під час переходу до реальних даних спостерігається помітне зниження точності класифікації, що свідчить про недостатню узагальнювальну здатність моделей, навчених лише на класичних синтетичних вибірках. Використання фізично обґрунтованих спотворень у наборі D9 дозволяє суттєво зменшити втрату точності, а застосування CGAN-уточнення та доменної адаптації у наборі D10 забезпечує подальше наближення характеристик моделі до еталонного синтетичного домену.

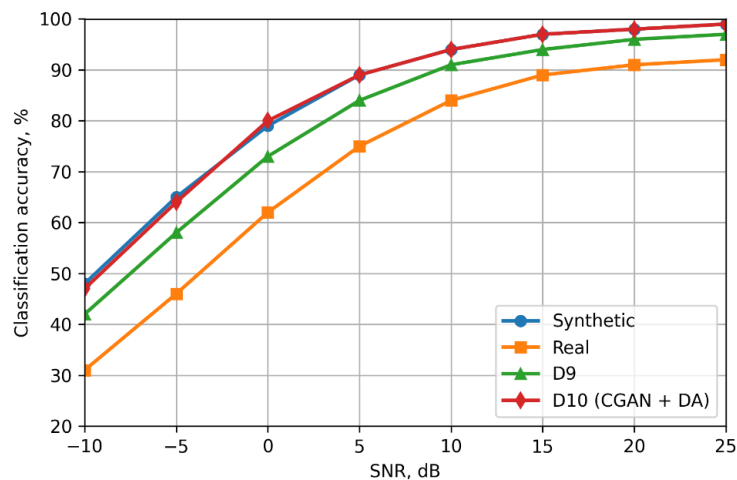


Рисунок 3 – Залежність точності класифікації ResNet-моделі від рівня SNR

Рисунок 4 містить порівняння значень показників якості класифікації Macro F1-score для CNN- та ResNet-моделей за різних типів навчальних доменів. Показано, що використання фізично спотворених та квазіреальних IQ-сигналів забезпечує суттєве покращення якості класифікації. Для CNN-моделі значення Macro F1-score зростає від 82 % до 92 %, а для ResNet від 86 % до 95 % після застосування CGAN-уточнення та доменної адаптації. Отримані результати демонструють, що запропонований метод не лише збільшує обсяг навчальних даних, а забезпечує статистичне узгодження ознак наборів. Додатково підтверджено вищу стійкість ResNet-архітектури до доменних спотворень, що пояснюється кращим формуванням доменно-інваріантних ознак.

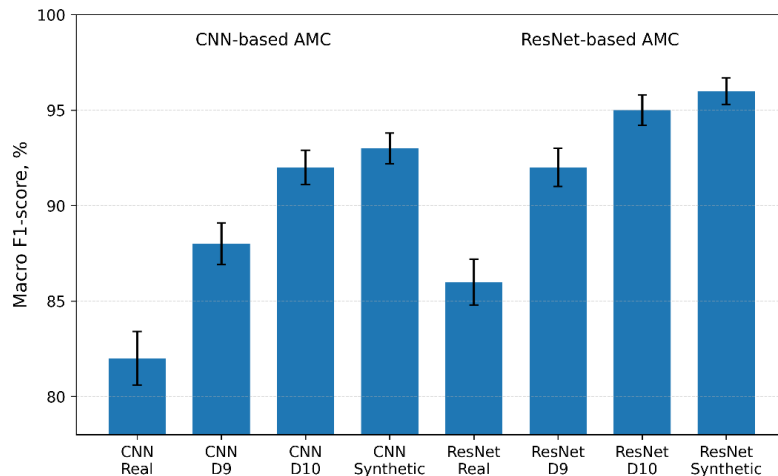


Рисунок 4 – Порівняння якості АМС-моделей у різних доменах даних

Таким чином, результати експериментальних досліджень підтверджують, що запропонований підхід до формування квазіреальних IQ-вибірок дозволяє суттєво скоротити доменно-розподільчу невідповідність між синтетичними та реальними сигналами та підвищити достовірність автоматичної класифікації модуляції в умовах некооперативного радіоприймання.

Висновки.

У роботі досліджено проблему доменно-розподільчої невідповідності між синтетичними та реальними IQ-сигналами в задачах автоматичної класифікації модуляції для систем радіорозвідки та аналізу каналів зв'язку БПЛА. Показано, що основними джерелами доменного розриву є каналні, апаратні, динамічні та інтерференційні спотворення, які не повністю враховуються в класичних підходах.

Запропоновано модель доменно-розподільчої невідповідності IQ-сигналів як багатовимірною статистичного розходження між синтетичним та реальним доменами. Розроблено інтегральний показник ΔD , який дозволяє кількісно оцінювати ступінь статистичної невідповідності між навчальними та реальними сигналами.

Розроблено фізично обґрунтовану схему формування IQ-вибірок, що реалізує перехід від ідеальних синтетичних до квазіреальних сигналів. На відміну від традиційних GAN-підходів, CGAN використано не для збільшення обсягу даних, а для статистичного наближення синтетичних IQ-сигналів до реального радіодомену. Введено поняття доменно-орієнтоване CGAN навчання, за якого дискримінатор оцінює не лише належність сигналу, а й ступінь його відповідності реальному домену.

Для експериментальної перевірки сформовано 11 наборів квадратурних IQ-сигналів із поступовим ускладненням умов радіоприймання. Результати дослідження для згорткової нейронної мережі та ResNet-архітектури показали, що використання фізично обґрунтованих спотворень, генеративного уточнення сигналів за допомогою CGAN та доменної адаптації дозволяє суттєво зменшити статистичну невідповідність між синтетичними та реальними сигналами. Запропонований підхід забезпечив підвищення точності класифікації в реальному домені в середньому на 4-6 % порівняно з традиційними методами навчання на синтетичних наборах даних. Отримані результати підтверджують ефективність запропонованого методу для формування квазіреальних IQ-вибірок і створення стійких АМС-систем для задач радіорозвідки та аналізу сигналів каналів зв'язку БПЛА.

Список бібліографічного опису:

1. O'Shea T. J., Corgan J., Clancy T. C. Convolutional Radio Modulation Recognition Networks. arXiv:1602.04105, 2016. DOI: 10.48550/arXiv.1602.04105.
2. West N. E., O'Shea T. J. Deep Architectures for Modulation Recognition. IEEE DySPAN, 2017, pp. 1–6. DOI: 10.48550/arXiv.1703.09197.
3. O'Shea T. J., Roy T., Clancy T. C. Over-the-Air Deep Learning Based Radio Signal Classification. IEEE Journal of Selected Topics in Signal Processing, 2018, vol. 12, no. 1, pp. 168–179. DOI: 10.1109/JSTSP.2018.2797022.
4. Huang L., Pan W., Zhang Y., Qian L., Gao N., Wu Y. Data Augmentation for Deep Learning-Based Radio Modulation Classification. IEEE Access, 2019, vol. 8, pp. 1498–1506. DOI: 10.1109/ACCESS.2019.2960775.
5. Li M., Li O., Liu G., Zhang C. Generative Adversarial Networks-Based Semi-Supervised Automatic Modulation Recognition for Cognitive Radio Networks. Sensors, 2018, vol. 18, no. 11, article 3913. DOI: 10.3390/s18113913.
6. Patel M., Wang X., Mao S. Data Augmentation with Conditional GAN for Automatic Modulation Classification. ACM WiseML, 2020, pp. 31–36. DOI: 10.1145/3395352.3402622.
7. Jdid B., Hassan K., Dayoub I., Lim W. H., Mokayef M. Machine Learning Based Automatic Modulation Recognition for Wireless Communications: A Comprehensive Survey. IEEE Access, 2021, vol. 9, pp. 57851–57873. DOI: 10.1109/ACCESS.2021.3071801.
8. Li T., Xiao Y. Domain Adaptation-Based Automatic Modulation Recognition. Scientific Programming, 2021, article 4277061. DOI: 10.1155/2021/4277061.
9. Zhou Q., Zhang R., Jing Z., Jing X. Semi-Supervised-Based Automatic Modulation Classification with Domain Adaptation for Wireless IoT Spectrum Monitoring. Frontiers in Physics, 2023, vol. 11, article 1158577. DOI: 10.3389/fphy.2023.1158577.

References:

1. O'Shea T. J., Corgan J., Clancy T. C. Convolutional Radio Modulation Recognition Networks. arXiv:1602.04105, 2016. DOI: 10.48550/arXiv.1602.04105.
2. West N. E., O'Shea T. J. Deep Architectures for Modulation Recognition. IEEE DySPAN, 2017, pp. 1–6. DOI: 10.48550/arXiv.1703.09197.
3. O'Shea T. J., Roy T., Clancy T. C. Over-the-Air Deep Learning Based Radio Signal Classification. IEEE Journal of Selected Topics in Signal Processing, 2018, vol. 12, no. 1, pp. 168–179. DOI: 10.1109/JSTSP.2018.2797022.

4. Huang L., Pan W., Zhang Y., Qian L., Gao N., Wu Y. Data Augmentation for Deep Learning-Based Radio Modulation Classification. *IEEE Access*, 2019, vol. 8, pp. 1498–1506. DOI: 10.1109/ACCESS.2019.2960775.
5. Li M., Li O., Liu G., Zhang C. Generative Adversarial Networks-Based Semi-Supervised Automatic Modulation Recognition for Cognitive Radio Networks. *Sensors*, 2018, vol. 18, no. 11, article 3913. DOI: 10.3390/s18113913.
6. Patel M., Wang X., Mao S. Data Augmentation with Conditional GAN for Automatic Modulation Classification. *ACM WiseML*, 2020, pp. 31–36. DOI: 10.1145/3395352.3402622.
7. Jdid B., Hassan K., Dayoub I., Lim W. H., Mokayef M. Machine Learning Based Automatic Modulation Recognition for Wireless Communications: A Comprehensive Survey. *IEEE Access*, 2021, vol. 9, pp. 57851–57873. DOI: 10.1109/ACCESS.2021.3071801.
8. Li T., Xiao Y. Domain Adaptation-Based Automatic Modulation Recognition. *Scientific Programming*, 2021, article 4277061. DOI: 10.1155/2021/4277061.
9. Zhou Q., Zhang R., Jing Z., Jing X. Semi-Supervised-Based Automatic Modulation Classification with Domain Adaptation for Wireless IoT Spectrum Monitoring. *Frontiers in Physics*, 2023, vol. 11, article 1158577. DOI: 10.3389/fphy.2023.1158577.

Історія статті:

Отримано: 17.04.2026 Доопрацьовано: 02.05.2026 Прийнято до друку: 23.05.2026 Опубліковано: 29.05.2026