

Іван ГОРБАТИЙ, Олександр УСАТИЙ

Україна, Національний університет «Львівська політехніка»

МЕТОДИ НЕЙРОМЕРЕЖЕВОЇ КЛАСИФІКАЦІЇ СИГНАЛІВ ІЗ РОЗШИРЕНИМ СПЕКТРОМ У СИСТЕМАХ РАДІОМОНІТОРИНГУ

Розглянуто задачу автоматичної класифікації сигналів із розширеним спектром у системах радіомоніторингу, що функціонують на платформах з обмеженими обчислювальними ресурсами. Запропоновано компактний вектор інформативних ознак, який поєднує частотні, часово-частотні та статистичні характеристики. Теоретично обґрунтовано використання параметрів Гйорта на основі моментів спектральної щільності потужності. За результатами абляційного аналізу сформовано скорочений вектор із п'яти ознак. Побудовано нейромережесий класифікатор у формах з рухомою та фіксованою комою. Досягнуто точність класифікації понад 91% у діапазоні відношення сигнал/шум від 0 до 20 дБ, що підтверджує ефективність запропонованого підходу для систем радіомоніторингу в реальному часі.

Ключові слова: сигнали з розширеним спектром, цифрові радіосигнали, нейронні мережі, цілочисельна квантизація, радіомоніторинг, вбудовані системи.

Сучасні системи радіомоніторингу функціонують в умовах постійного ускладнення радіоелектронного середовища, що зумовлено збільшенням кількості джерел радіовипромінювання та активним застосуванням методів підвищення завадостійкості й прихованості зв'язку. До таких методів належать технології з розширеним спектром: перестрибування робочої частоти (*frequency-hopping spread spectrum, FHSS*), пряме розширення спектра (*direct-sequence spread spectrum, DSSS*) та лінійна частотна модуляція (*chirp spread spectrum, CSS*) [1], [2]. Їх виявлення та ідентифікація є складним завданням, особливо за низького відношення сигнал/шум (*signal-to-noise ratio, SNR*) [3], [4].

Особливого значення задача класифікації сигналів із розширеним спектром набуває у складі розподілених систем радіомоніторингу, де обробка здійснюється безпосередньо на периферійних вузлах збору — одноплатних комп'ютерах та мікроконтролерах з обмеженими ресурсами пам'яті та обчислювальної потужності. Такі платформи орієнтовані на обробку в режимі реального часу, тому основними критеріями застосовності методу класифікації є не лише точність, а й обчислювальна складність, обсяг пам'яті моделі та енергоефективність.

Існуючі методи класифікації сигналів із розширеним спектром умовно поділяють на три покоління, кожне з яких має суттєві обмеження для вбудованих систем, що працюють у режимі реального часу. Класичні детерміновані методи ґрунтуються на спектральному аналізі з використанням швидкого перетворення Фур'є, часово-частотних перетворень (короткочасне перетворення Фур'є, вейвлет-перетворення [5])

та ентропійних характеристик з фіксованими пороговими правилами [1], [6]. Основними недоліками цих методів є чутливість до рівня шуму (точність падає нижче 70% за $\text{SNR} < 0$ дБ [7]), відсутність адаптивності та висока обчислювальна складність двовимірних часово-частотних подань, яка має порядок $O(N^2 \log N)$ для сигналу довжиною N відліків.

Методи машинного навчання на основі ознак частково долають обмеження класичних підходів [4], [7]. Зокрема, у роботі [7] для ідентифікації FHSS-сигналів застосовано штучні нейронні мережі на параметричних ознаках, що забезпечує точність 92–95% за $\text{SNR} \geq 5$ дБ. Проте такі методи орієнтовані переважно на один клас сигналів, вони використовують евристичне формування вектора ознак без формалізованого обґрунтування та не передбачають оцінки стійкості до цілочисельної квантизації. У нашій попередній роботі [4] був виконаний порівняльний аналіз глибоких нейронних мереж для класифікації цифрових модуляцій, який підтвердив залежність точності від стратегії навчання та архітектури.

Методи глибокого навчання на часово-частотних поданнях забезпечують високу точність класифікації. У роботі [8] для сигналів з низькою ймовірністю перехоплення (*low probability of intercept, LPI*) застосовано згорткові нейронні мережі на спектрограмах, що дало точність 96% за $\text{SNR} \geq 0$ дБ. Водночас такі мережі характеризуються високою обчислювальною складністю (10^8 – 10^9 операцій множення-накопичення на один прямий прохід), значним обсягом моделі (5–20 Мб) та орієнтацією на офлайн-обробку [9]–[11]. Це унеможливає їх застосування на платформах з бюджетом у десятки-сотні кілобайт оперативної пам'яті.

Отже, жоден з відомих підходів не забезпечує одночасного виконання трьох ключових вимог: високої точності за від'ємних значень SNR, низької обчислювальної складності (менше 10^5 операцій на одну реалізацію) та сумісності з цілочисельною арифметикою. Це визначає актуальність розроблення методу, що поєднує компактний вектор інформативних ознак, обчислюваних переважно у часовій області, з легкою нейромережевою моделлю, адаптованою до 8-бітового цілочисельного формату.

Метою цієї роботи є розроблення методу нейромережевої класифікації широкосмугових радіосигналів, орієнтованого на платформи з обмеженими обчислювальними ресурсами, з теоретичним обґрунтуванням вибору вектора ознак та кількісним порівнянням обчислювальних витрат з відовими підходами.

Формування вектора ознак

Для формування вектора ознак використано частотні, часово-частотні та статистичні характеристики сигналів FHSS, DSSS та CSS, які дозволяють виокремити їх за відмінностями у спектральній структурі та динамікою зміни частотних компонентів. Пріоритет надавався параметрам, що поєднують високу дискримінаційну здатність з низькою обчислювальною складністю. Повний склад ознак, їх належність до групи, алгоритмічну складність та фізичний зміст наведено у **табл. 1**.

Ключовим елементом запропонованого вектора є параметри Гйорта — активність $A(x)$, мобільність $M(x)$ та складність $C(x)$ [12], які відображають, відповідно, повну потужність сигналу, середньоквадратичну частоту та відносну ширину смуги частот [13] і обчислюються виключно у часовій області. Для дискретного сигналу $x[n]$ довжиною N ці параметри визначаються за формулами

$$A(x) = \sigma_x^2; \quad (1)$$

$$M(x) = \sigma_x' / \sigma_x; \quad (2)$$

$$C(x) = M(x') / M(x), \quad (3)$$

де σ_x , σ_x' — стандартне відхилення сигналу та першої різниці відповідно;

$x'[n]$ — перша різниця сигналу, $x'[n] = x[n] - x[n-1]$.

Згідно з теоремою Парсеваля, для стаціонарних у широкому сенсі процесів мобільність Гйорта аналітично пов'язана з нормованим другим спектральним моментом спектральної щільності потужності $S(\omega)$:

$$M^2(x) = (1/\sigma^2 x) \cdot \int \omega^2 \cdot S(\omega) d\omega. \quad (4)$$

Аналогічно, складність $C(x)$ пов'язана з четвертим спектральним моментом. Поведінка параметрів у різних класах сигналів має специфічні риси. Мобільність сигналів DSSS з майже рівномірним спектром у смузі B близька до $B/\sqrt{3}$ за найменшої складності. Для FHSS мобільність демонструє стрибкоподібні зміни у часі, що відображає дискретну зміну центральної частоти, а складність приймає найбільші значення через різкі перехідні процеси. У сигналах CSS мобільність зростає монотонно, а складність приймає проміжні значення, відображаючи плавну зміну миттєвої частоти. Отже, параметри Гйорта забезпечують опис спектральної структури без явного обчислення перетворення Фур'є зі складністю $O(N)$ порівняно з $O(N \log N)$ для частотних аналогів.

Таким чином, запропонований вектор ознак об'єднує частотні дескриптори (F1, F2, F3), часово-частотні характеристики (F4, F5, F7, F8) та статистичні показники (F6, F9, F10), причому параметри Гйорта (F6, F7, F8) виконують роль обчислювально ефективних замінників традиційних спектральних характеристик.

Таблиця 1

Класифікація вектора інформативних ознак сигналів

Назва ознаки	Позначення	Група	Складність	Фізичний зміст
Спектральна ентропія	F1	Частотні	$O(N \log N)$	Міра впорядкованості спектра
Спектральна рівномірність	F2	Частотні	$O(N)$	Оцінка шумоподібності
Ефективна ширина спектра (99%)	F3	Частотні	$O(N)$	Еквівалент ширини спектра
Варіація спектра у часі	F4	Часово-частотні	$O(N)$	Нестаціонарність частотної структури
Показник перестрибування частоти	F5	Часово-частотні	$O(N \log N)$	Оцінка дискретної частотної динаміки
Активність Гйорта	F6	Часові	$O(N)$	Енергія сигналу
Мобільність Гйорта	F7	Часово-частотні	$O(N)$	Оцінка середньої частоти
Складність Гйорта	F8	Часово-частотні	$O(N)$	Оцінка ширини спектра
Експес амплітудного розподілу	F9	Статистичні	$O(N)$	Негаусовість розподілу
Дисперсія енергетичної обвідної	F10	Часові	$O(N)$	Нестаціонарність амплітудної обвідної

Оцінка обчислювальної складності

Для кількісного обґрунтування ефективності оцінювали обчислювальну складність повного конвеєра класифікації для реалізації сигналу довжиною $N = 1024$ комплексних відліків. Сумарна кількість операцій множення-накопичення на обчислення скороченого вектора (F3, F5, F7, F8, F9) становить приблизно $3 \cdot 10^4$ з таким розподілом витрат: F3 — близько 10240 операцій для оцінки спектра потужності; F5 — 7200 для короткочасного перетворення Фур'є з вісьмома вікнами по 128 відліків; F7 та F8 — 8200 для обчислення двох рівнів різниць та відповідних дисперсій; F9 — 4100 для обчислення моментів вищого порядку. Для повного вектора з десяти ознак сумарна кількість зростає до $7 \cdot 10^4$ операцій.

Для архітектури багатошарового перцептрона з двома прихованими шарами (32 та 16 нейронів) кількість операцій множення-накопичення на один інференс становить $5 \cdot 32 + 32 \cdot 16 + 16 \cdot 5 = 752$, що відповідає близько 2,5% від вартості обчислення ознак. Тобто, основна частина обчислювальних ресурсів витрачається на етап формування вектора характеристик, що виправдовує використання низько-складних часових ознак в процесі його проєктування.

З табл. 2 видно, що запропонований підхід у цілочисельній конфігурації на скороченому векторі забезпечує зменшення обчислювальних витрат на чотири порядки та скорочення обсягу моделі приблизно у 5000 разів порівняно з підходом на основі згорткових мереж [8], зберігаючи при цьому еквівалентну точність у діапазоні SNR ≥ 0 дБ. У зіставленні з методом [7], орієнтованим лише на FHSS, запропонований підхід характеризується удвічі меншою складністю та ширшим охопленням класів сигналів.

Час інференсу оцінювався для типових платформ радіомоніторингу — одноплатних комп'ютерів BeagleBone AI та Raspberry Pi з тактовою частотою процесора близько 1 ГГц. Наведені у табл. 2 кіль-

кість операцій та обсяг пам'яті моделі слід розглядати як теоретичні оцінки порядку величини, отримані з аналітичних виразів складності алгоритмів. Час інференсу визначався на основі тактової частоти процесора, він може відрізнятися від результатів вимірювань залежно від рівня оптимізації реалізації та ступеня паралелізму обчислень.

Нейромережева модель та абляційний аналіз

Для побудови класифікатора використано архітектуру багатошарового перцептрона з двома прихованими шарами, схему якої наведено на рис. 1. Вхідний шар приймає N ознак ($N = 10$ для повного вектора та $N = 5$ для скороченого), вихідний шар формує ймовірнісні оцінки належності сигналу до п'яти класів: адитивний білий гаусовий шум, вузькосмуговий сигнал, FHSS, DSSS, CSS. Приховані шари застосовують нелінійні функції активації для апроксимації залежностей між ознаками. Вибір такої архітектури зумовлений необхідністю досягнення достатньої точності за обмеженої обчислювальної складності: на відміну від згорткових мереж багатошаровий перцептрон не потребує операцій згортки, що знижує складність на три-чотири порядки при зіставній точності для компактних векторів ознак.

Для зменшення розмірності вектора виконано абляційний аналіз шляхом послідовного виключення кожної ознаки з оцінкою зміни точності ΔAcc відносно базового варіанту (10 ознак, точність 91,42%) на валідаційній вибірці у діапазоні SNR від 0 до 20 дБ. Застосовано формалізований кількісний критерій відбору, що складається з трьох умов:

K1 (індивідуальна значущість) — ознака залишається, якщо $|\Delta Acc| \geq 0,5\%$;

K2 (некорельованість) — ознака вилучається при коефіцієнті кореляції Пірсона $|\rho| \geq 0,7$ з іншою ознакою, що має більше значення $|\Delta Acc|$;

K3 (негативний внесок) — ознака вилучається, якщо $\Delta Acc \geq 0$ (тобто її видалення не погіршує модель).

Таблиця 2

Порівняння обчислювальних витрат методів класифікації сигналів

Метод	Кількість операцій на реалізацію	Обсяг пам'яті моделі, Кб	Час інференсу, мкс	Примітка
Класичний спектральний аналіз з пороговими правилами [1]	$1 \cdot 10^4$	< 1	10	Низька адаптивність до SNR
Машинне навчання на параметричних ознаках FHSS [7]	$5 \cdot 10^4$	10	50	Один клас сигналів
Згорткові мережі на спектрограмах 224×224 [8]	$5 \cdot 10^8$	10240	50	Офлайн-обробка
Запропонований: 10 ознак, формат з рухомою комою	$7 \cdot 10^4$	15	70	Максимальна точність за низького SNR
Запропонований: 5 ознак, формат з рухомою комою	$3 \cdot 10^4$	8	30	Компроміс точність / ресурси
Запропонований: 5 ознак, цілочисельний формат	$3 \cdot 10^4$	2	15	Рекомендовано для вбудованих систем




Рис. 1. Структурна схема нейромережевого класифікатора

Додатково застосовується правило винятку K1*: ознака зберігається при $|\Delta Acc| < 0,5\%$, якщо коефіцієнт кореляції Пірсона з найбільш корельованою іншою ознакою $|\rho^*| < 0,3$ (тобто вона несе унікальну некорельовану інформацію). Остаточне рішення приймається за мажоритарним правилом.

Як видно з табл. 3, п'ять залишених ознак {F3, F5, F7, F8, F9} є комплементарними: F3 та F5 забезпечують частотний опис, F7 та F8 — часово-частотний з меншими обчислювальними витратами, а F9 — статистичну характеристику для розрізнення гаусових та негаусових процесів. Середнє попарне значення $|\rho|$ для цих ознак становить 0,34, що підтверджує їхню функціональну незалежність.

Принциповим результатом абляційного аналізу є вилучення F6: додатне значення $\Delta Acc = +0,13\%$ свідчить про те, що повна енергія сигналу, яка суттєво залежить від рівня шуму, вносить систематичну похибку у рішення класифікатора. Ознака F1 (спектральна ентропія) стає критичною лише при $SNR < -5$ дБ, що визначає обмеження скороченого вектора (розглядатимуться у наступному розділі). Таким чином, під повним вектором ознак надалі розуміється набір із 10 компонентів (F1...F10), під скороченим — набір

із п'яти компонентів {F3, F5, F7, F8, F9}. Значення коефіцієнтів кореляції $|\rho^*|$, наведені у табл. 3, отримані на підмножині навчальних даних у діапазоні SNR від 0 до 20 дБ та можуть незначно змінюватися залежно від обсягу та характеристик вибірки.

Для реалізації моделі на платформах з обмеженими ресурсами застосовано цілочисельну квантизацію до 8-бітового формату після навчання у форматі з рухомою комою одинарної точності. Діапазони ваги та активації визначаються на основі статистичних характеристик навчальних даних, що мінімізує втрати точності. Процедура квантизації виконується після завершення навчання і не потребує повторного повного тренування, що суттєво спрощує виробниче розгортання моделі.

Результати досліджень та їх обговорення

Для експериментальних досліджень було сформовано репрезентативний набір даних із 10 000 реалізацій комплексних аналітичних сигналів (по 20 000 на клас). Частота дискретизації становила 1 МГц, довжина кожної реалізації — 1024 комплексні відліки. Сигнали DSSS моделювалися з використанням 11-чипового коду Баркера [14], [15], FHSS — зі швид-

Таблиця 3

Абляційний аналіз та формування скороченого вектора

Ознака	$\Delta Acc, \%$	$ \rho^* $	Критерій	Рішення	Обґрунтування
F1	-0,30	0,72 (F2)	K2	Вилучити	Корелює з F2; критична лише при $SNR < -5$ дБ
F2	-0,23	0,74 (F7)	K2	Вилучити	Корельована з F7 при меншій складності обчислення
F3	-1,17	0,41	K1	Залишити	Критична для розрізнення DSSS від вузькосмугових
F4	-0,27	0,68 (F5)	K1	Вилучити	Індивідуальний вплив нижче порога; F5 перебиває
F5	-0,87	0,52	K1	Залишити	Унікально фіксує дискретні стрибки частоти FHSS
F6	+0,13	0,38	K3	Вилучити	Додатне ΔAcc — видалення покращує модель
F7	-1,70	0,74	K1	Залишити	Найбільший індивідуальний внесок; пов'язаний з $M^2(x)$ (див. формулу (4))
F8	-0,77	0,41	K1	Залишити	Важлива для CSS — плавна зміна миттєвої частоти
F9	-0,43	0,22	K1*	Залишити	Гранична $ \Delta Acc $, але найнижча кореляція (0,22) та роль при низькому SNR
F10	-0,07	0,31	K1	Вилучити	Дубльована функціональність з F6, F9




Рис. 2. Матриця невідповідностей моделі у цілочисельному форматі:
а — усереднений результат для SNR від -10 до 20 дБ; б — SNR = -10 дБ

кістю 500 стрибків/с, CSS — як лінійна частотна модуляція з випадковими граничними частотами (імітація фізичного рівня технології LoRa). Сигнали генерувалися з випадковою початковою фазою та центральною частотою у діапазоні SNR від -10 до +20 дБ для моделювання критичних умов приймання, характерних для сигналів з низькою ймовірністю перехоплення. Навчання та тестування здійснювалося на підмножині даних, які не перетинаються, що забезпечує коректність оцінки узагальнювальної здатності моделі.

Модель з рухомою комою на повному векторі ознак забезпечує точність понад 91,4% при SNR > 0 дБ, досягаючи 93,2% при SNR = 20 дБ. Навіть за інтенсивних завад (SNR = -10 дБ) точність залишається на рівні 87,1%, що підтверджує високу дискримінативну здатність вектора ознак. Для аналізу характеру помилок класифікації використано матриці невідповідностей, наведені на **рис. 2**.

Як видно з **рис. 2, а**, система майже безпомилково ідентифікує DSSS та шум, що підтверджує ефективність ознаки F9 (ексцес амплітуди) для розрізнення негаусовості DSSS-сигналів. Водночас спостерігається певний перетин між вузькосмуговими сигналами та FHSS, що є фізично обґрунтованим явищем: на коротких інтервалах FHSS-сигнал може виглядати як вузькосмуговий. Точність ідентифікації CSS залишається стабільно високою (близько 89%), що доводить ефективність параметра F8 (складність Гюрта). У випадку SNR = -10 дБ (**рис. 2, б**) FHSS помилково класифікується як шум у 34% випадків, а 39% CSS розпізнаються як шум через недостатню потужність для статистичного виявлення параметрами Гюрта.

Проведені експерименти для трьох конфігурацій моделі дозволяють зазначити, що перехід від повного вектора ознак до скороченого демон-

струє високу стабільність при SNR > 0 дБ: точність оптимізованої моделі становить 91,2–91,8%, це лише на 1,5% нижче за базову при удвічі меншій розмірності вектора. Найбільша різниця між моделями спостерігається при високому рівні завад (SNR = -10 дБ): базова модель зберігає точність 87%, тоді як оптимізовані версії демонструють зниження до 70% — з рухомою комою та 66% — цілочисельний формат. Це підтверджує зроблений в абляційному аналізі висновок, що вилучена ознака F1 (спектральна ентропія) стає критичною в умовах глибокого маскування сигналу шумом. Для критичних застосувань при SNR < -5 дБ рекомендується попередньо застосувати алгоритми придушення шуму, збільшити час спостереження для накопичення статистики або використати повний вектор ознак.

Перехід від формату з рухомою комою до цілочисельного призводить до незначної втрати точності, що ілюструється графіками на **рис. 3**. При SNR ≥ 0 дБ криві практично збігаються, що підтверджує мож-




Рис. 3. Залежність точності моделей з рухомою комою (базової 1 та оптимізованої 2) та у цілочисельному форматі (3) від SNR

ливість цілочисельних обчислень без суттєвої втрати якості. Для типових сценаріїв приймання сигналу при $\text{SNR} = 5$ дБ оптимальною є модель із п'ятьма ознаками у цілочисельному форматі: точність понад 91% за вимог до пам'яті у чотири рази менше порівняно з базовою моделлю з рухомою комою.

Отримані експериментальні результати узгоджуються з теоретичним аналізом обчислювальної складності (див. табл. 2): запропонований метод у цілочисельній конфігурації на скороченому векторі ознак забезпечує оптимальний компроміс між точністю класифікації та обчислювальними витратами. Додатково слід зазначити стійкість методу до типових впливів у реальних умовах: варіацій центральної частоти сигналу, випадкової початкової фази, різної тривалості сигналу у межах вікна спостереження. Це досягається використанням статистичних інтегральних ознак, інваріантних до фазових зсувів та короткочасних флуктуацій.

Висновки

Запропонований метод нейромережевої класифікації ширококугових радіосигналів для вбудованих платформ радіомоніторингу поєднує високу точність при малих значеннях відношення сигнал/шум, низьку обчислювальну складність та сумісність із цілочисельною арифметикою. Теоретичне обґрунтування інформативності параметрів Гйорта дозволило замінити частотні дескриптори часовими еквівалентами зі складністю $O(N)$ замість $O(N \log N)$, що суттєво зменшило обчислювальні витрати. Розроблена методика абляційного аналізу дозволила сформувати скорочений вектор із п'яти ознак, який забезпечує точність понад 91% при $\text{SNR} \geq 0$ дБ та потребує лише близько $3 \cdot 10^4$ операцій на одну реалізацію і приблизно 2 Кб пам'яті моделі, що на чотири порядки менше порівняно з підходами на основі згорткових мереж.

Експериментальні результати підтвердили стійкість методу до варіацій центральної частоти, випадкової початкової фази та різної тривалості сигналу, що робить його придатним для застосування у розподілених мережах радіомоніторингу, портативних засобах радіотехнічної розвідки, системах виявлення сигналів з низькою ймовірністю перехоплення та бортових комплексах моніторингу літальних апаратів.

Подальший розвиток методу варто спрямувати на інтеграцію алгоритмів придушення шуму для умов $\text{SNR} < -5$ дБ, розширення набору класів для охоплення сучасних технологій зв'язку (OFDM, 5G, супутникові системи низької орбіти), дослідження апаратного прискорення на DSP та FPGA, а також на перехід від класифікації до оцінювання параметрів сигналу з використанням багатозадачних нейромережевих архітектур.

ВИКОРИСТАНІ ДЖЕРЕЛА

- [1] D. Torrieri, *Principles of Spread-Spectrum Communication Systems*, 5th ed. Cham, Switzerland: Springer, 2022, 710 p. doi: 10.1007/978-3-030-75343-6
- [2] D. Stanescu, A. Digulescu, C. Ioana, and A. Serbanescu, "Spread spectrum modulation recognition based on phase diagram entropy," *Frontiers in Signal Processing*, vol. 3, art. no. 1197619, 2023. doi: 10.3389/frsip.2023.1197619
- [3] N. Islam and S. Shin, "Deep learning in physical layer: review on data driven end-to-end communication systems and their enabling semantic applications," *IEEE Open Journal of the Communications Society*, vol. 5, pp. 4207–4240, 2024. doi: 10.1109/ojcoms.2024.3425314
- [4] I. В. Горбатий та О. А. Усатий, "Порівняльний аналіз методів автоматичної класифікації цифрових модуляцій на основі глибинних нейронних мереж," *Технологія та конструювання в електронній апаратурі*, № 3–4, с. 33–39, 2025. doi: 10.15222/TKEA2025.3.4.33
- [5] C. M. Akujobi, *Wavelets and Wavelet Transform Systems and Their Applications: A Digital Signal Processing Approach*. Cham, Switzerland: Springer, 2022, 644 p. doi: 10.1007/978-3-030-87528-2
- [6] I. В. Горбатий та О. А. Усатий, "Дослідження методів спектрального аналізу сигналів із розширеним спектром у сучасних комунікаційних системах," *Інформаційно-комунікаційні технології та електронна інженерія*, т. 5, № 1, с. 125–135, 2025. doi: 10.23939/ictee2025.01.125
- [7] M. T. Khan, A. Z. Sha'ameri, and M. M. A. Zabidi, "Classification of FHSS signals in a multi-signal environment by artificial neural network," *International Journal of Computing and Digital Systems*, vol. 11, no. 1, pp. 775–789, 2022. doi: 10.12785/ijcds/110163
- [8] T. Huynh-The, V.-S. Doan, C.-H. Hua, Q.-V. Pham, T.-V. Nguyen, and D.-S. Kim, "Accurate LPI radar waveform recognition with CWD-TFA for deep convolutional network," *IEEE Wireless Communications Letters*, vol. 10, no. 8, pp. 1638–1642, 2021. doi: 10.1109/LWC.2021.3075880
- [9] B. Jacob et al., "Quantization and training of neural networks for efficient integer-arithmetic-only inference," in *Proc. IEEE Conf. Computer Vision and Pattern Recognition (CVPR)*, Salt Lake City, USA, 2018, pp. 2704–2713. doi: 10.1109/CVPR.2018.00286
- [10] H. Zhao, D. Liu, and H. Li, "Efficient integer-arithmetic-only convolutional neural networks," *arXiv preprint, arXiv:2006.11735*, 2020. [Online]. Available: <https://arxiv.org/abs/2006.11735>
- [11] A. Gholami, S. Kim, Z. Dong, Z. Yao, M. W. Mahoney, and K. Keutzer, "A survey of quantization methods for efficient neural network inference," in *Low-Power Computer Vision*. Boca Raton, FL, USA: CRC Press, 2022, pp. 291–326. doi: 10.1201/9781003162810-13
- [12] B. Hjorth, "EEG analysis based on time domain properties," *Electroencephalography and Clinical Neurophysiology*, vol. 29, no. 3, pp. 306–310, 1970. doi: 10.1016/0013-4694(70)90143-4
- [13] W. H. Alawee, A. Basem, and L. A. Al-Haddad, "Advancing biomedical engineering: Leveraging Hjorth features for electroencephalography signal analysis," *Journal of Electrical Bioimpedance*, vol. 14, no. 1, pp. 66–72, 2023. doi: 10.2478/joeb-2023-0009
- [14] M. A. Richards, *Fundamentals of Radar Signal Processing*, 2nd ed. New York, NY, USA: McGraw-Hill, 2014, 656 p.
- [15] V. Maksimov and I. Khrapovitsky, "New composite Barker codes in the synchronization system of broadband signals," *Information and Telecommunication Sciences*, no. 2, pp. 24–30, 2020. doi: 10.20535/2411-2976.22020.24-30

Надійшла до редакції 24.03.2026

Прийнято до друку 20.04.2026

NEURAL NETWORK-BASED METHODS FOR SPREAD SPECTRUM SIGNAL CLASSIFICATION IN RADIO MONITORING SYSTEMS

Automatic classification of spread spectrum signals — frequency-hopping, direct-sequence, and chirp — is a key task in modern radio monitoring systems, particularly relevant for distributed sensor networks with constrained computational resources. A critical review of existing approaches shows that none of the three generations of classification methods — classical deterministic, feature-based machine learning, and deep learning on time-frequency representations — simultaneously meets three essential requirements: high accuracy at negative signal-to-noise ratios, computational complexity below 10^5 multiply-accumulate operations per realization, and compatibility with integer arithmetic for embedded deployment. This paper proposes a method that addresses this gap through a compact, informative feature vector combining frequency-domain, time-frequency, and statistical characteristics. The informativeness of Hjorth parameters is theoretically justified via their analytical link to spectral moments of the power spectral density, enabling $O(N)$ time-domain computation equivalent to frequency-domain analysis. A formalized ablation analysis with three quantitative selection criteria (individual significance, pairwise correlation below 0.7, and absence of negative contribution) yields a reduced vector of five components. Complexity analysis confirms approximately $3 \cdot 10^4$ operations per realization and 2 kB model memory in integer configuration — four orders of magnitude less than convolutional network-based approaches. Experimental evaluation of a multilayer perceptron classifier demonstrates stable accuracy above 91% across a wide SNR range, 93.2% at 20 dB and 87% at -10 dB, with negligible degradation under integer quantization, confirming practical applicability to embedded and distributed radio monitoring systems.

Keywords: spread spectrum signals, digital radio signals, neural networks, integer quantization, radio monitoring, embedded systems.

REFERENCES

- [1] D. Torrieri, *Principles of Spread-Spectrum Communication Systems*, 5th ed. Cham, Switzerland: Springer, 2022, 710 p. doi: 10.1007/978-3-030-75343-6
- [2] D. Stanescu, A. Digulescu, C. Ioana, and A. Serbanescu, "Spread spectrum modulation recognition based on phase diagram entropy," *Frontiers in Signal Processing*, vol. 3, art. no. 1197619, 2023. doi: 10.3389/frsip.2023.1197619
- [3] N. Islam and S. Shin, "Deep learning in physical layer: review on data driven end-to-end communication systems and their enabling semantic applications," *IEEE Open Journal of the Communications Society*, vol. 5, pp. 4207–4240, 2024. doi: 10.1109/ojcoms.2024.3425314
- [4] I. V. Horbatiy and O. A. Usaty, "Comparative analysis of digital modulation classification methods based on deep neural networks (in Ukrainian)," *Technology and Design in Electronic Equipment*, no. 3–4, pp. 33–39, 2025. doi: 10.15222/TKEA2025.3-4.33
- [5] C. M. Akujobi, *Wavelets and Wavelet Transform Systems and Their Applications: A Digital Signal Processing Approach*. Cham, Switzerland: Springer, 2022, 644 p. doi: 10.1007/978-3-030-87528-2
- [6] I. V. Horbatiy and O. A. Usaty, "Investigation of spread spectrum signal analysis methods in modern communication systems (in Ukrainian)," *Information and Communication Technologies and Electronic Engineering*, vol. 5, no. 1, pp. 125–135, 2025. doi: 10.23939/ictet2025.01.125
- [7] M. T. Khan, A. Z. Sha'ameri, and M. M. A. Zabidi, "Classification of FHSS signals in a multi-signal environment by artificial neural network," *International Journal of Computing and Digital Systems*, vol. 11, no. 1, pp. 775–789, 2022. doi: 10.12785/ijcds/110163
- [8] T. Huynh-The, V.-S. Doan, C.-H. Hua, Q.-V. Pham, T.-V. Nguyen, and D.-S. Kim, "Accurate LPI radar waveform recognition with CWD-TFA for deep convolutional network," *IEEE Wireless Communications Letters*, vol. 10, no. 8, pp. 1638–1642, 2021. doi: 10.1109/LWC.2021.3075880
- [9] B. Jacob et al., "Quantization and training of neural networks for efficient integer-arithmetic-only inference," in *Proc. IEEE Conf. Computer Vision and Pattern Recognition (CVPR)*, Salt Lake City, USA, 2018, pp. 2704–2713. doi: 10.1109/CVPR.2018.00286
- [10] H. Zhao, D. Liu, and H. Li, "Efficient integer-arithmetic-only convolutional neural networks," *arXiv preprint, arXiv:2006.11735*, 2020. [Online]. Available: <https://arxiv.org/abs/2006.11735>
- [11] A. Gholami, S. Kim, Z. Dong, Z. Yao, M. W. Mahoney, and K. Keutzer, "A survey of quantization methods for efficient neural network inference," in *Low-Power Computer Vision*. Boca Raton, FL, USA: CRC Press, 2022, pp. 291–326. doi: 10.1201/9781003162810-13
- [12] B. Hjorth, "EEG analysis based on time domain properties," *Electroencephalography and Clinical Neurophysiology*, vol. 29, no. 3, pp. 306–310, 1970. doi: 10.1016/0013-4694(70)90143-4
- [13] W. H. Alawee, A. Basem, and L. A. Al-Haddad, "Advancing biomedical engineering: Leveraging Hjorth features for electroencephalography signal analysis," *Journal of Electrical Bioimpedance*, vol. 14, no. 1, pp. 66–72, 2023. doi: 10.2478/joeb-2023-0009
- [14] M. A. Richards, *Fundamentals of Radar Signal Processing*, 2nd ed. New York, NY, USA: McGraw-Hill, 2014, 656 p.
- [15] V. Maksimov and I. Khrapovitsky, "New composite Barker codes in the synchronization system of broadband signals," *Information and Telecommunication Sciences*, no. 2, pp. 24–30, 2020. doi: 10.20535/2411-2976.22020.24-30

Відомості про авторів

Іван Горбатий, докт. техн. наук, професор, зав. кафедри, Львівська політехніка, Україна;
e-mail: giv@polynet.lviv.ua;
ORCID: <https://orcid.org/0000-0001-6495-192X>

Олександр Усатий, аспірант, Львівська політехніка, Україна;
e-mail: oleksandr.a.usaty@lpnu.ua;
ORCID: <https://orcid.org/0009-0007-3470-702X>

About the authors

Ivan Horbatiy, Dr.Sc., Professor, Head of Department, Lviv Polytechnic National University, Ukraine;
e-mail: giv@polynet.lviv.ua;
ORCID: <https://orcid.org/0000-0001-6495-192X>

Oleksandr Usaty, Ph.D. Student, Lviv Polytechnic National University, Ukraine;
e-mail: oleksandr.a.usaty@lpnu.ua;
ORCID: <https://orcid.org/0009-0007-3470-702X>



Copyright: © 2026, 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/>).