

ГЕНЕРАЦІЯ СИНТЕТИЧНИХ РАДІОЧАСТОТНИХ СИГНАЛІВ ДЛЯ НАВЧАННЯ МОДЕЛЕЙ ГЛИБОКОГО НАВЧАННЯ У СЦЕНАРІЯХ ЕЛЕКТРОННОЇ БОРОТЬБИ

Розвиток стійких систем дистанційної локалізації та аналізу потужних сигналів завад і протидії критично залежить від наявності великих і різноманітних навчальних наборів даних. Традиційний збір даних за допомогою професійного радіообладнання та польових випробувань є дорогим, тривалим і часто обмеженим технічними та регуляторними чинниками. Синтетичне генерування радіочастотних сигналів із використанням сучасних генеративних моделей глибокого навчання пропонує привабливу альтернативу: моделі навчаються статистичній структурі реальних сигналів і каналів, а потім формують реалістичні послідовності I/Q із керованими параметрами.

У цій статті запропоновано метод синтезу RF-сигналів на основі VQ-VAE у поєднанні з авторегресивним Transformer. Запропонована схема навчається розподілу реальних RF-сигналів і генерує синтетичні послідовності, умовно задані типом модуляції, відношенням сигнал/шум (SNR) та каналом поширення. Експериментальні результати на наборі з 500 000 комплексних послідовностей показали, що архітектура VQ-VAE + Transformer досягає середньоквадратичної похибки реконструкції (MSE) 0.0245 та кореляції спектрограм 0.948, перевершуючи базові моделі GAN, VAE, WGAN і diffusion за якістю та часом навчання.

Ключові слова: синтетичні RF-сигнали; генеративні моделі; VQ-VAE; Transformer; аугментація даних; завади; електронна боротьба; класифікація модуляції.

Вступ. Сучасні системи електронної боротьби (ЕБ) та протидії БПЛА потребують точного виявлення, класифікації та локалізації потужних джерел завад і перешкод у широкому спектрі оперативних умов [1, 2, 12]. У таких сценаріях канали зв'язку, навігації та телеметрії зазнають навмисних перешкод, що погіршують якість сервісу або повністю зривають виконання місії [12, 13].

Методи глибокого навчання показали високу ефективність у задачах автоматичної класифікації модуляцій, спектрального зондування та локалізації RF-випромінювачів [6, 11, 14, 15]; однак їх результативність обмежена доступністю репрезентативних навчальних даних. Збір RF-наборів з реальними сигналами завад за допомогою лабораторних або польових стендів потребує дорогого обладнання, узгоджених експериментів і, в багатьох випадках, спеціальних дозволів [3, 16].

Синтетичне генерування RF-сигналів із використанням генеративного глибокого навчання є привабливою альтернативою [4–7, 10]. Навчаючись статистичним властивостям реальних сигналів і каналів, генеративні моделі можуть створювати великі обсяги реалістичних I/Q -даних із керованими параметрами. Синтетичні сигнали можуть використовуватися для доповнення обмежених реальних наборів даних, для покриття рідкісних або екстремальних умов, а також для систематичного моделювання ефективності алгоритмів.

У цій роботі розроблено та експериментально верифіковано повний конвеєр синтетичної генерації RF-сигналів, орієнтований на навчання моделей глибокого навчання для задач, пов'язаних із ЕБ.

Аналіз останніх досліджень і публікацій. Останні дослідження у сфері радіочастотного аналізу та електронної боротьби підтверджують, що ефективність моделей глибокого

навчання у задачах розпізнавання модуляцій, спектрального зондування та локалізації випромінювачів істотно залежить від якості подання сигналу, попередньої обробки та репрезентативності навчальної вибірки [6, 11, 14, 15]. Водночас збір реальних RF-даних залишається дорогим і технічно складним, тому все більшої уваги набувають підходи, пов'язані з аугментацією даних і синтетичним генеруванням I/Q-последовностей [3, 16]. У цьому контексті базовими для наряду стали генеративні моделі GAN, VAE та diffusion, які створили методологічну основу для подальшого розвитку засобів синтезу RF-сигналів [4,5,7].

У низці сучасних праць показано, що для задач генерації сигналів найбільш перспективними є моделі, які поєднують стискання сигналу в латентному просторі з подальшим послідовнісним моделюванням. Зокрема, підхід VQ-VAE забезпечує дискретне та стійке латентне представлення сигналу [8], а Transformer-моделі дають змогу ефективно відтворювати послідовності кодів з урахуванням умов генерації [9]. Практичну доцільність таких архітектур для data augmentation підтверджують і нові дослідження синтезу сигналів, де VQ-VAE у поєднанні з Transformer або близькими генеративними підходами розглядається як ефективна основа для побудови реалістичних RF-вибірок [10].

Окремий інтерес становлять найновіші роботи, присвячені адаптації diffusion-підходів безпосередньо до RF-даних. Так, у дослідженні RF-Diffusion запропоновано часово-частотну diffusion-модель для генерації високоякісних радіосигналів, яка продемонструвала переваги над низкою попередніх генеративних рішень для Wi-Fi та FMCW-сценаріїв [23]. Отже, сучасний стан досліджень свідчить, що використання архітектури VQ-VAE + Transformer у цій роботі є обґрунтованим і відповідає актуальній тенденції переходу до більш структурованих, керованих і якісних методів синтезу RF-сигналів для задач електронної боротьби та автоматичного розпізнавання модуляцій [6, 10].

1. Моделі RF-сигналів та каналів.

1.1. Модульовані RF-сигнали. Ми розглядаємо аналогові та цифрові схеми модуляції, які зазвичай використовуються в системах зв'язку та придушення [17]. Комплексну базову огинаючу модульованого RF-сигналу можна записати як $s(t) = a(t) \cdot \exp(j(2\pi f_c t + \varphi(t)))$, де $a(t)$ – амплітудна огинаюча, f_c – несуча частота, а $\varphi(t)$ – фазова складова, що кодує інформацію та модуляцію. Таблиця 1 узагальнює типи модуляції, використані в цій роботі, та їхні основні характеристики.

Таблиця 1 – Огляд типів модуляції, використаних у дослідженні

Тип модуляції	Клас	Примітки
AM	Аналогова	Зміни амплітуди навколо несучої частоти; вузькосмугове мовлення.
FM	Аналогова	Частотні відхилення; стійка до амплітудного шуму.
PM	Аналогова	Фазові відхилення; часто поєднується з FM.
BPSK	Цифрова	Стійка бінарна фаза; підходить для низького SNR.
QPSK	Цифрова	2 біти на символ; баланс між стійкістю та спектральною ефективністю.
M-PSK	Цифрова	Вища спектральна ефективність; чутливіша до шуму.
M-QAM	Цифрова	Амплітудно-фазове кодування; широко використовується в стандартах.
FSK	Цифрова	Частотна маніпуляція; підходить для простих приймачів.
OFDM	Цифрова	Мультиносійна; висока спектральна ефективність; чутлива до нелінійностей.

Для чисельної обробки безперервний сигнал подано як дискретну комплексну I/Q-послідовність $s[n] = I[n] + jQ[n]$, вибірка якої здійснюється з частотою f_s , що задовольняє критерій Найквіста відносно смуги сигналу B , тобто $f_s \geq 2B$.

1.2. Спотворення каналу. Під час поширення через бездротовий канал RF-сигнал зазнає низки спотворень, які необхідно відобразити в синтетичних даних [18,19]:

- Додавання білого гаусівського шуму (AWGN), що моделюється як $y[n] = s[n] + w[n]$, де $w[n]$ – комплексний гаусовий шум із нульовим математичним сподіванням та дисперсією σ^2 , що визначається цільовим SNR.

- Багатопроменеве замирання, описане коефіцієнтом каналу Rayleigh h , так що $y[n] = h \cdot s[n] + w[n]$, де h – комплексна випадкова величина з раліївським розподілом модуля.

- Часова затримка та доплерівський зсув, що приводять до $y[n] = h \cdot s[n - n_d] \cdot \exp\left(j2\pi \frac{f_d n}{f_s}\right) + w[n]$, де n_d – затримка в семплах, а f_d – доплерівське зміщення частоти.

- Нелінійні спотворення через насичення підсилювача потужності, які моделюються за допомогою амплітудного кліпінгу або поліноміальних моделей.

Таблиця 2 якісно підсумовує ці ефекти каналу та їхній вплив на моделі, що навчаються.

Таблиця 2 – Спотворення каналу та їхній вплив

Спотворення	Опис моделі	Вплив на моделі навчання
AWGN	Додавання гаусівського шуму	Погіршує SNR; перевіряє стійкість до шуму.
Rayleigh fading	Випадковий комплексний коефіцієнт h	Спричиняє швидкі замирання; потребує різноманітності.
Delay & Doppler	Часовий зсув і частотний зсув	Спотворює фазу; впливає на синхронізацію.
Нелінійності	Кліпінг амплітуди, поліноміальний підсилювач	Створює спектральне розширення та додаткові спотворення.

2. Генеративні моделі для синтезу RF-сигналів.

2.1. Генеративні змагальні мережі (GAN). Генеративні змагальні мережі (GAN) складаються з генератора G та дискримінатора D , які навчаються в постановці мінімаксової гри. Генератор відображає вектор шуму z синтетичний зразок $\hat{x} = G(z)$, тоді як дискримінатор намагається відрізнити реальні зразки x від згенерованих. Стандартна функція втрат GAN має вигляд

$$\min_G \max_D \mathbb{E}_x[\log D(x)] + \mathbb{E}_z[\log (1 - D(G(z)))]. \quad (1)$$

Умовні GAN (conditional GAN, CGAN) розширюють цю схему, вводячи додаткову умову c (наприклад, клас модуляції, рівень SNR) як у генератор, так і в дискримінатор, що дає змогу генерувати RF-сигнали, умовні за класом c . Хоча GAN успішно застосовуються до зображень та аудіосигналів, їх навчання для RF-сигналів часто є нестабільним, із колапсом мод і високою чутливістю до вибору гіперпараметрів.

2.2. Варіаційні автокодери (VAE). Варіаційні автокодери (VAE) поєднують енкодер $q_\phi(z | x)$, латентний простір і декодер $p_\theta(x | z)$. Енкодер відображає вхідні зразки x у розподіл у латентному просторі, який зазвичай параметризується гаусовим розподілом із математичним сподіванням $\mu(x)$ та дисперсією $\sigma^2(x)$. Декодер відновлює $\hat{x}$ з латентних векторів z . Функція навчання – це нижня оцінка правдоподібності (evidence lower bound, ELBO):

$$L_{VAE} = \mathbb{E}_{q_\phi(z|x)}[-\log p_\theta(x | z)] + \text{KL}\left(q_\phi(z | x) \parallel p(z)\right), \quad (2)$$

де перший доданок є втратою відновлення, а другий – дивергенцією Кульбака – Лейблера відносно апіорного розподілу $p(z)$.

VAE забезпечують гладкий латентний простір, але схильні формувати надто згладжені

синтетичні хвильові форми та можуть мати труднощі з відтворенням тонких фазових деталей RF-сигналів.

2.3. Дифузійні моделі. Дифузійні моделі генерують дані, навчаючись відтворювати зворотний процес поступового додавання шуму. У прямому процесі до чистого зразка додається гаусовий шум відповідно до заданого графіка дисперсії; далі нейронну мережу навчають апроксимувати зворотну динаміку очищення від шуму. Дифузійні моделі досягають найкращої на сьогодні якості для зображень і аудіо, а останні дослідження також розглядають їх застосування для генерації вібраційних та RF-сигналів, однак вони є обчислювально затратними через велику кількість кроків денойзингу.

2.4. Векторно-квантизовані автокодекери (VAE) та авторегресивні Transformer. Щоб краще відобразити дискретну структуру RF-сигналів і водночас забезпечити ефективну генерацію, ми використовуємо Vector Quantized Variational Autoencoder (VQ-VAE) у поєднанні з авторегресивним Transformer. Енкодер f_{enc} перетворює вхідну I/Q-послідовність x у набір латентних векторів, які квантуються за допомогою навченої кодової книги, а декодер f_{dec} відновлює сигнал із квантизованого латентного представлення [8]. Функцію втрат VQ-VAE можна записати як:

$$L_{\text{VQ-VAE}} = L_{\text{rec}} + \| \text{sg}[z_e] - e \|_2^2 + \beta \| z_e - \text{sg}[e] \|_2^2, \quad (3)$$

де L_{rec} – похибка відновлення, z_e – вихід енкодера, e – вектор кодової книги, $\text{sg}[\cdot]$ позначає операцію stop-gradient, а β – коефіцієнт commitment loss.

Після навчання VQ-VAE кожен сегмент сигналу подається у вигляді послідовності дискретних кодів. Далі авторегресивний Transformer моделює розподіл над цими кодами з урахуванням умовної інформації c , наприклад класу модуляції та SNR. На етапі генерації він послідовно прогнозує токени за розподілом $p(\text{token}_t | \text{token}_{<t}, c)$, після чого декодер VQ-VAE перетворює їх назад у синтетичний I/Q-сигнал. На рисунку 1 концептуально показано повний конвеєр синтезу.



Рисунок 1 – Запропонований конвеєр синтезу RF-даних на основі VQ-VAE та Transformer

3. Побудова синтетичного набору даних.

3.1. Збір і попередня обробка реальних даних. Запропонована методика починається зі збирання репрезентативного набору реальних RF-сигналів, релевантних для цільового сценарію EW. Сигнали зберігаються як комплексні I/Q-послідовності, дискретизовані з частотою f_s , вибраною відповідно до критерію Найквіста для максимальної смуги сигналу.

Попередня обробка включає:

- Нормалізацію амплітуди: масштабування I/Q-відліків до діапазону $[-1, 1]$.
- Видалення DC-зсуву: віднімання середнього значення вибірки для усунення статичних зміщень.
- Нормалізацію довжини: сегментування або доповнення нулями всіх послідовностей до фіксованої довжини N (наприклад, 1024 відліки).
- Вікновування: застосування вікна Ганна для зменшення спектральних витоків перед часово-частотним аналізом.

Таблиця 3 узагальнює основні параметри набору даних, використані в експериментах.

Таблиця 3 – Основні параметри синтетичного RF-набору даних

Параметр	Значення
Кількість сигналів	500 000 комплексних I/Q-послідовностей
Типи модуляції	2FSK, 4ASK, 8PSK, 16PSK, 32QAM, 64QAM, OFDM-256
Частота дискретизації	200 кГц
Довжина сегмента	1024 відліки (5.12 мс)
Діапазон SNR	-20 дБ ... 20 дБ із кроком 2 дБ

3.2. Навчання VQ-VAE. Енкодер VQ-VAE обробляє попередньо підготовлені I/Q-сегменти та формує латентні вектори, упорядковані як послідовність нижчої часової роздільної здатності. Під час навчання ініціалізується та оновлюється кодова книга з K елементів, у якій кожному латентному вектору призначається найближчий кодовий запис. Декодер відновлює I/Q-сегмент із квантизованої латентної послідовності.

VQ-VAE навчається на змішаному наборі даних, що містить як реальні, так і змодельовані сигнали, які охоплюють множину типів модуляції та умов каналу, описаних у розділі 2. Цільова функція оптимізації є зваженою сумою втрати відновлення (наприклад, MSE) та втрат кодової книги й commitment loss [8].

3.3. Навчання генератора Transformer. Після збіжності VQ-VAE кожен навчальний сегмент кодується у послідовність індексів кодів. Ці токен-послідовності разом із умовними мітками (тип модуляції, SNR, тип каналу) використовуються для навчання авторегресивного Transformer із багатоголовою самоувагою [9, 24]. На кожному кроці модель отримує раніше згенеровані токени та умовний вектор і прогнозує розподіл для наступного токена.

На етапі генерації токен-послідовності вибираються з навченої моделі Transformer за допомогою жадібного декодування або nucleus sampling і подаються на декодер VQ-VAE для отримання синтетичних I/Q-сигналів.

4. Експериментальна постановка та оцінювання.

4.1. Набір даних і розбиття. Для оцінювання запропонованого підходу було сформовано набір даних із 500 000 комплексних I/Q-послідовностей. Набір випадково розбитий на підмножини навчання, валідації та тестування у співвідношенні 70/15/15, причому всі типи модуляції та всі рівні SNR були представлені в кожній підмножині.

4.2. Метрики якості синтетичних сигналів. Ми застосували кілька взаємодоповнювальних метрик для оцінювання якості синтетичних сигналів. Середньоквадратична помилка відновлення (MSE) вимірює відхилення між початковими та відновленими хвильовими формами. Кореляція спектрограм, визначена як коефіцієнт кореляції Пірсона між спектрограмами реальних і відновлених сигналів, характеризує збереження часово-частотної структури. Додатково використовуються топологічні метрики precision і recall у відповідному ознаковому просторі, наприклад після вбудовування за допомогою embedding-мережі, щоб оцінити, наскільки добре синтетичні зразки покривають багатовид реальних сигналів без появи хибних мод. У Таблиці 4 наведено ці показники для VQ-VAE + Transformer.

Таблиця 4 – Метрики якості для VQ-VAE + Transformer на RF-наборі даних

Метрика	Значення
MSE реконструкції	0.0245
Кореляція спектрограм	0.948
Topological precision	0.92
Topological recall	0.88

4.3. Базові архітектури. Було порівняно архітектуру VQ-VAE + Transformer з кількома базовими моделями: класичним GAN, VAE, WGAN та дифузійною моделлю, адаптованою для 1D комплексних послідовностей. Для кожної моделі вимірювався час навчання, Fréchet-подібна відстань (FID) між ознаками реальних і синтетичних сигналів, а також метрика різноманітності. Результати узагальнено в Таблиці 5.

Таблиця 5 – Порівняння генеративних моделей для синтезу RF-сигналів

Архітектура	Час навчання	FID	Різнорманітність
GAN	8 год	35.2	0.75
VAE	3 год	48.5	0.82
WGAN	10 год	28.7	0.79
Diffusion	6 год	12.1	0.91
VQ-VAE + Transformer	5 год	10.5	0.94

Запропонована архітектура VQ-VAE + Transformer демонструє найкращі значення FID і різноманітності за конкурентного часу навчання, поєднуючи переваги дискретного латентного подання та потужного послідовнісного моделювання.

Рисунок 2 візуалізує відносну продуктивність різних генеративних моделей з точки зору FID та різноманітності.




Рисунок 2 – Продуктивність генеративних моделей для синтезу RF-сигналів (FID і різноманітність)

4.4. Вплив синтетичних даних на класифікацію модуляції. Щоб кількісно оцінити вплив синтетичних даних на подальші задачі, ми навчали CNN-класифікатор модуляції на наборах із різною часткою синтетичних і реальних сигналів [6, 11].

Таблиця 6 – Вплив синтетичних даних на CNN-класифікацію модуляції

Частка синтетичних даних	Точність при SNR= 0 дБ	Точність при SNR= -10 дБ	Час навчання
0%	88.5%	72.3%	1.0 год
20%	89.7%	75.1%	0.9 год
30%	92.1%	78.6%	0.8 год
50%	93.8%	81.2%	0.7 год
70%	94.5%	82.9%	0.6 год

Результати показують, що додавання синтетичних даних суттєво підвищує стійкість за низького SNR і скорочує час навчання. Оптимальна частка синтетичних даних становить приблизно 40–50 % навчального набору. Рисунок 3 ілюструє залежність точності класифікації при SNR = -10 дБ від частки синтетичних сигналів у наборі.




Рисунок 3 – Точність CNN-класифікації модуляції за SNR = -10 дБ залежно від частки синтетичних даних

Експериментальні результати показали, що синтетичні RF-дані можуть суттєво підвищити ефективність подальших задач радіочастотного навчання за умови їх збалансованого використання. Найкраще співвідношення між якістю узагальнення та продуктивністю було досягнуто тоді, коли частка синтетичних зразків становила приблизно 40–50 % навчальної вибірки. Це підтверджує, що синтетичні RF-дані доцільно використовувати як доповнення до реальних вимірювань, а не як повну заміну.

Висновки. У цій роботі запропоновано повний фреймворк для генерації синтетичних RF-сигналів на основі архітектури VQ-VAE + Transformer та продемонстровано його переваги для навчання моделей глибокого навчання в сценаріях електронної боротьби. Запропонований підхід забезпечує високу достовірність і різноманітність сигналів, перевершуючи базові моделі GAN, VAE, WGAN і diffusion за значеннями FID та кореляції спектрограм при збереженні прийнятної часу навчання. Показано, що доповнення CNN-класифікатора модуляції синтетичними даними суттєво підвищує точність у режимі низького SNR та скорочує час навчання. Загалом частка синтетичних даних на рівні близько 40–50 % забезпечила найкращий баланс між продуктивністю та узагальненням, що підтверджує практичну доцільність використання синтетичних RF-даних для подолання дефіциту та вартості реальних вимірювань у задачах EW і counter-UAV. Подальші дослідження будуть спрямовані на розширення фреймворку синтезу на складніші каналні моделі, зокрема частотно-селективне завмирання та апаратні спотворення, вивчення дифузійних генераторів RF-сигналів, а також інтеграцію конвеєрів синтетичних даних у системи реального часу для EW і RF-сенсингу.

ЛІТЕРАТУРА

1. Parallax Advanced Research. *Cognitive Electronic Warfare and the Fight for Spectrum Superiority* // Parallax Advanced Research. 2025. URL: <https://parallaxresearch.org/news/blog/cognitive-electronic-warfare-and-fight-spectrum-superiority> (дата звернення: 06.06.2026).

2. Inzpire. *The future is now: machine learning in electromagnetic warfare* // Inzpire. 2024. URL: <https://www.inzpire.com/news/the-future-is-now-machine-learning-in-electromagnetic-warfare> (дата звернення: 14.06.2026).
3. Mind UA. *REB: shcho tse i yak zasoby radioelektronnoi borotby protydiyut vorozhym raketam (РЕБ: що це і як засоби радіоелектронної боротьби протидіють ворожим ракетам)* // Mind.ua. 2024. URL: <https://mind.ua/publications/20269499-reb-shcho-ce-i-yak-zasobi-radioelektronnoyi-borotbi-protidyut-vorozhim-raketam> (дата звернення: 21.06.2026).
4. Goodfellow I., Pouget-Abadie J., Mirza M., Xu B., Warde-Farley D., Ozair S., Courville A., Bengio Y. *Generative adversarial nets* // *Advances in Neural Information Processing Systems* 27 / eds. Z. Ghahramani, M. Welling, C. Cortes, N. D. Lawrence, K. Q. Weinberger. Red Hook, NY : Curran Associates, Inc., 2014. p. 2672–2680. DOI: 10.48550/arXiv.1406.2661.
5. Kingma D. P., Welling M. *Auto-Encoding Variational Bayes* // International Conference on Learning Representations (ICLR 2014). Banff, AB, Canada, 2014. 14 p. DOI: 10.48550/arXiv.1312.6114.
6. Clark W. H. IV, Hauser S. C., Headley W. C., Michaels A. J. *Training data augmentation for deep learning radio frequency systems* // *The Journal of Defense Modeling and Simulation: Applications, Methodology, Technology*. 2021. Vol. 18, No. 3. P. 217–237. DOI: 10.1177/1548512921991245.
7. Ho J., Jain A., Abbeel P. *Denoising diffusion probabilistic models* // *Advances in Neural Information Processing Systems* 33 (NeurIPS 2020). Red Hook, NY : Curran Associates, Inc., 2020. DOI: 10.48550/arXiv.2006.11239.
8. Van den Oord A., Vinyals O., Kavukcuoglu K. *Neural discrete representation learning* // *Advances in Neural Information Processing Systems* 30 (NeurIPS 2017). Red Hook, NY : Curran Associates, Inc., 2017. DOI: 10.48550/arXiv.1711.00937.
9. Razavi A., Van den Oord A., Vinyals O. *Generating diverse high-fidelity images with VQ VAE 2* // *Advances in Neural Information Processing Systems* 32 (NeurIPS 2019). Red Hook, NY : Curran Associates, Inc., 2019.
10. Kaasaragadda Y. V. N. *Efficient signal synthesis for data augmentation using generative AI* : Master's thesis. Glassboro, NJ : Rowan University, 2025. URL: <https://rdw.rowan.edu/etd/3376> (дата звернення: 21.06.2026).
11. Liu K., Zhang C., Zhao X., Wang Y., Zhang Y. *Radio frequency database construction and modulation recognition in wireless sensor networks* // *Sensors*. 2022. Vol. 22, No. 15. Article 5715. DOI: 10.3390/s22155715.
12. Sormayli J., Darvishi M., Zarrinnegar K., Mosavi M. R. *Real-time jamming detection using windowing and hybrid machine learning models for pre-saturation alerts* // *Scientific Reports*. 2025. Vol. 15, No. 1. Article 24748. DOI: 10.1038/s41598-025-10567-0.
13. GlobalSecurity. *Electronic warfare* // GlobalSecurity.org. [6. p.]. URL: <https://www.globalsecurity.org/military/systems/ground/ew.htm> (дата звернення: 14.06.2026).
14. Morehouse T., Montes C., Zhou R. *Faster region-based CNN spectrum sensing and signal identification in cluttered RF environments* // *The Journal of Defense Modeling and Simulation: Applications, Methodology, Technology*. 2023.
15. Chen M., Mao X., Wang X. *Performance analysis of deep neural networks for direction of arrival estimation of multiple sources* // *IET Signal Processing*. 2023. Article e12178. DOI: 10.1049/sil2.12178.
16. Panoramio. *Overview of open datasets for RF signal classification* // Panoramio-SDR. 2025. URL: <https://panoramio-sdr.de/overview-of-open-datasets-for-rf-signal-classification/> (дата звернення: 14.06.2026).
17. IEEE. *IEEE Standard for Information technology – Telecommunications and information exchange between systems – Local and metropolitan area networks – Specific requirements – Part 11: Wireless LAN Medium Access Control (MAC) and Physical Layer (PHY) Specifications – Amendment 4: Enhancements for Very High Throughput for Operation in Bands below 6 GHz*. IEEE Std 802.11ac 2013. New York IEEE, 2013.
18. CRFS. *Radio Direction Finding Techniques and Applications for EW and SIGINT* // CRFS Blog. 2024. URL: <https://www.crfs.com/blog/radio-direction-finding-techniques-and-applications-for-ew-and-sigint> (дата звернення: 17.06.2026).
19. Quasar. *Direction Finding and Geolocation Solutions* // Quasar.ai. [6. p.]. URL: <https://www.quasar.ai> (дата звернення: 14.07.2026).
20. Riyaz S., Sankhe K., Ioannidis S., Chowdhury K. *Deep learning convolutional neural networks for radio fingerprinting* // *IEEE Communications Magazine*. 2018. Vol. 56, No. 4. p. 146–152. DOI: 10.1109/MCOM.2018.1800153.

21. Caillon A., Esling P. *RAVE: a variational autoencoder for fast and high-quality audio synthesis* // *arXiv*. 2021. arXiv:2111.05011. 18 p. DOI: 10.48550/arXiv.2111.05011.
22. Sohl-Dickstein J., Weiss E. A., Maheswaranathan N., Ganguli S. *Deep unsupervised learning using nonequilibrium thermodynamics* // *Proceedings of the 32nd International Conference on Machine Learning (ICML 2015)* // *JMLR Workshop and Conference Proceedings*. 2015. Vol. 37. p. 2256–2265.
23. Chi G., Yang Z., Wu C., Xu J., Gao Y., Liu Y., Han T. X. *RF-Diffusion: Radio Signal Generation via Time-Frequency Diffusion* // *Proceedings of the 30th Annual International Conference on Mobile Computing and Networking (ACM MobiCom'24)*. New York : Association for Computing Machinery, 2024. DOI: 10.1145/3636534.3649348.

REFERENCES:

1. Parallax Advanced Research (2025) *Cognitive Electronic Warfare and the Fight for Spectrum Superiority*.
2. Inzpire (2024) *The future is now: machine learning in electromagnetic warfare*.
3. Mind UA (2024) *РЕБ: що це і як засоби радіоелектронної боротьби протидіють ворожим ракетам*.
4. Goodfellow, I. et al. (2014) 'Generative Adversarial Nets', *NeurIPS*.
5. Kingma, D. P. and Welling, M. (2014) 'Auto-Encoding Variational Bayes', *ICLR*.
6. Clark, W. H. et al. (2020) 'Training Data Augmentation for Deep Learning Radio Modulation Classification', *arXiv*.
7. Ho, J. et al. (2020) 'Denoising Diffusion Probabilistic Models', *NeurIPS*.
8. van den Oord, A. et al. (2017) 'Neural Discrete Representation Learning', *NeurIPS*.
9. Razavi, A. et al. (2019) 'Generating Diverse High-Fidelity Images with VQ-VAE-2', *NeurIPS*.
10. Kaasaragadda, Y. et al. (2025) *Efficient Signal Synthesis for Data Augmentation using Generative AI*.
11. Liu, K. et al. (2022) 'Radio Frequency Database Construction and Modulation Recognition', *IEEE Sensors Journal*.
12. Sormayli, J. et al. (2025) 'Real-Time Jamming Detection Using Windowing and Hybrid Models', *Scientific Reports*.
13. HSC (2025) *Які бувають види РЕБ*.
14. Morehouse, T. et al. (2023) 'Faster Region-Based CNN Spectrum Sensing', *arXiv*.
15. Chen, M. et al. (2023) 'Performance Analysis of Deep Neural Networks for Direction of Arrival Estimation', *IEEE*.
16. Panoradio (2025) *Overview of Open Datasets for RF Signal Classification*.
17. IEEE (2013) *802.11ac: Physical Layer Specifications*.
18. CRFS (2024) *Radio Direction Finding Techniques and Applications for EW and SIGINT*.
19. Quasar (2024) *Direction Finding and Geolocation Solutions*.
20. Riyaz, S. et al. (2018) 'Deep Learning Convolutional Neural Networks for Radio Fingerprinting', *IEEE Communications Magazine*.
21. Caillon, A. et al. (2021) 'RAVE: a variational autoencoder for fast and high-quality audio synthesis', *ICLR*.
22. Sohl-Dickstein, J. et al. (2015) 'Deep Unsupervised Learning using Nonequilibrium Thermodynamics', *ICML*.
23. Chi G., Yang Z., Wu C., Xu J., Gao Y., Liu Y., Han T. X. *RF-Diffusion: Radio Signal Generation via Time-Frequency Diffusion* // *Proceedings of the 30th Annual International Conference on Mobile Computing and Networking (ACM MobiCom'24)*. New York : Association for Computing Machinery, 2024. doi: 10.1145/3636534.3649348.

GENERATION OF SYNTHETIC RADIO FREQUENCY SIGNALS FOR TRAINING DEEP LEARNING MODELS IN ELECTRONIC WARFARE SCENARIOS

For the development of robust systems for remote localization and analysis of powerful jamming and countermeasure signals, a critical aspect is the availability of large and diverse training datasets. Traditional data collection using professional radio equipment and field testing is expensive, time-consuming, and often limited by technical and regulatory factors. Synthetic generation of radio frequency signals using state-of-the-art generative deep learning models offers an attractive alternative: models learn the statistical structure of real signals and channels, and then generate realistic I/Q sequences with controllable parameters. This article proposes an RF signal synthesis method based on VQ-VAE combined with an autoregressive Transformer. The proposed scheme learns the distribution of real RF signals and generates synthetic sequences conditionally specified by the modulation type, signal-to-noise ratio (SNR), and propagation channel. Experimental results on a dataset of 500,000 complex sequences showed that the VQ-VAE + Transformer architecture achieves a mean squared reconstruction error (MSE) of 0.0245 and a spectrogram correlation of 0.948, outperforming baseline GAN, VAE, WGAN, and diffusion models in terms of quality and training time.

Keywords: synthetic RF signals, generative models, VQ-VAE, Transformer, data augmentation, jamming, electronic warfare, modulation classification.

