



ОДНОВИМІРНА ЗГОРТКОВА МОДЕЛЬ НЕЙРОННОЇ МЕРЕЖІ ДЛЯ ОБРОБЛЕННЯ СИГНАЛІВ З АМПЛІТУДНОЮ МОДУЛЯЦІЄЮ БАГАТЬОХ СКЛАДОВИХ

І. Цимбалюк [ORCID: 0009-0005-5420-0272]

¹Національний університет «Львівська політехніка», Львів, вул. С. Бандери, 12, 79013, Україна

Відповідальний за рукопис: Іван Цимбалюк (e-mail: ivan.r.tymbaliuk@lpnu.ua).

(Подано 29 Лютого 2024)

Оброблення радіосигналів з допомогою штучних нейронних мереж (ШНМ) має великий потенціал досліджень, який можна обґрунтувати адаптивністю ШНМ до різних умов передавання та здатністю виявляти абстрактні закономірності зміни параметрів сигналів. У статті проведено огляд робіт інших авторів, присвячених різним способам використання ШНМ для оброблення радіосигналів. Беручи до уваги відомості в оглянутих роботах, було сформовано завдання дослідження, яке полягає в розробленні оптимізованої моделі ШНМ для оброблення радіосигналів. Для формування навчальних вибірок для ШНМ було обрано сигнали з амплітудною модуляцією багатьох складових (АМБС). Вибір обґрунтовано більшою енергетичною ефективністю в порівнянні з іншими широко використовуваними цифровими видами модуляції, такими як квадратурна амплітудна модуляція. Описано математичні основи формування сигналів з АМБС. Наведено співвідношення для знаходження координат сигнального сузір'я 8-АМБС з трьома складовими, формування сигналів у часовій площині на основі знайдених координат, їх дискретизації та додавання білого шуму. Запропоновано ітеративний алгоритм формування початкових даних для ШНМ на основі описаних співвідношень. Розглянуто загальну структуру одновимірних згорткових нейронних мереж. Наведено співвідношення для функцій окремих нейронів, зв'язків між ними, формування шарів та проведення операції згортки. На основі попередньо наведених співвідношень сформовано сумарне відображення мережі. Обрано конкретні розмірності та функції активації для шарів. Використання згорткових шарів обґрунтовано інваріантністю щодо зсуву. На основі наведених співвідношень, обраних функцій активації та розмірностей сформовано нейронну модель. Описано процес валідації ефективності сформованої нейронної моделі, який полягає у порівнянні імовірностей символічної помилки запропонованої та еталонної моделей при різних співвідношеннях сигнал-шум. Наведено результати валідації. Пояснено переваги отриманої моделі над раніше запропонованою суто рекурентною моделлю та еталонним приймачем АМБС.

Ключові слова: Амплітудна модуляція багатьох складових (АМБС), штучні нейронні мережі (ШНМ), згорткові нейронні мережі.

УДК: 621.126

1. Вступ

Постійне зростання продуктивності комп'ютерів та більша доступність засобів машинного навчання зумовили активацію досліджень використання штучних нейронних мереж у

телекомунікаційних системах. Дослідження демонструють потенціал використання штучних нейронних мереж (ШНМ) як потужного допоміжного інструменту в процесах оброблення сигналів, зокрема радіосигналів.

Втім, попри потенційні переваги, використання ШНМ в області оброблення радіосигналів вимагає прийняття різних компромісів. Спектр потенційних застосувань штучних нейронних мереж обмежується вимогами до швидкодії. Швидкодія ШНМ, в свою чергу, обмежується обчислювальними потужностями комп'ютерів. Відповідно, успішне впровадження ШНМ в телекомунікаційних системах вимагає досягнення балансу між точністю, залученою обчислювальною потужністю та швидкістю. При цьому слід враховувати те, що сигнали можуть бути піддані дії різних видів завад, що ускладнює їх оброблення.

Отже, актуальною проблемою, що стоїть на шляху до успішного ШНМ мереж в телекомунікаційних системах, є необхідність досягнення балансу обчислювальної складності та точності. Такий баланс досягається шляхом оптимізації архітектур та алгоритмів ШНМ.

Беручи до уваги збільшення обсягів передавання даних та ускладнення радіосередовища, дослідження методів оброблення радіосигналів з використанням ШНМ стають все більш актуальними. Такі дослідження відкривають нові можливості для оброблення радіосигналів завдяки спроможності ШНМ виявляти абстрактні закономірності зміни параметрів сигналів, які можуть бути неочевидними чи недосяжними для тривіальних методів оброблення сигналів.

2. Аналіз літературних даних

Попри заявлені виклики, низка досліджень демонструє високу ефективність використання ШНМ в сфері оброблення радіосигналів. Серед актуальних досліджень можна виділити використання різних видів рекурентних нейронних мереж (РНМ) і згорткових нейронних мереж (ЗНМ) різних вимірів.

Використання РНМ з рекурентними вентилями запропоновано для класифікації багатоканальних сигналів, що змінюються в часі [1], також використання РНМ запропоновано для визначення частоти сигналів [2]. Використання мереж з дискретними тригонометричними перетвореннями Фур'є запропоновано для класифікації аудіосигналів [3]. Використання РНМ з довгою короткочасною пам'яттю запропоновано для аналізу сигналів з силових датчиків [4].

В [5] пропонується використовувати ШНМ не для оброблення сигналів, а для проектування ефективних аналогових схем оброблення сигналів.

Хоча РНМ здатні ефективно доповнювати системи оброблення сигналів, в тому числі радіокомунікаційні системи, втім такі системи мають деякі обмеження виявлення короткочасних закономірностей зміни параметрів сигналів. Одновимірні згорткові нейронні мережі найкраще себе проявляють саме при виявленні короткочасних особливостей. Такі мережі запропоновано використовувати для виявлення джерел радіосигналів [7], для ідентифікації конкретних радарних емітерів [7]. Гібридні моделі запропоновано використовувати для оцінювання параметрів каналів передавання та виявлення сигналів в системах з частотним ущільненням каналів та великій кількості користувачів [8].

Також були проведені різні оглядові дослідження використання згорткових нейронних мереж при обробленні сигналів. Зокрема було проведено огляд різних застосувань конкретно одновимірних згорткових мереж в обробленні сигналів [9]. Публікація [10] присвячена порівнянню ефективності одновимірних та двовимірних згорткових нейронних мереж у реальному часі для класифікації даних від давачів. Публікація [11] досліджує чинники впливу на продуктивність згорткових нейронних мереж у задачах класифікації аудіосигналів.

У загальному аналіз робіт інших авторів демонструє певний попит на знаходження нових способів використання ШНМ у завданнях оброблення сигналів. При тому спектр застосування

ШНМ у завданнях оброблення сигналів є дуже широким — від оброблення сигналів електрокардіограм до декодування інформаційних послідовностей.

Втім, попри продемонстрований потенціал використання ШНМ в обробленні сигналів, все ж існують проблеми, які ще не були повністю вирішені. До таких проблем належать обмежена спроможність моделей адаптуватись до умов, що динамічно змінюються, та умов високих шумів чи сильних завад.

Також актуальною залишається проблема оптимізації архітектур та алгоритмів ШНМ для оброблення сигналів. Оглянуті моделі часто використовують велику кількість системних ресурсів як в процесі навчання, так і в процесі роботи. Така особливість також може бути спричинена великою громіздкістю апробованих наборів даних для навчання ШНМ оброблення радіосигналів, наприклад RadioML [12].

Для вирішення задачі оптимізації ШНМ при збереженні відносно високого рівня точності у цій статті пропонується компактна модель оброблення радіосигналів з використанням одновимірної нейронної мережі та мінімалістичний метод генерації наборів даних для навчання.

3. Завдання та цілі дослідження

Беручи до уваги виявлені в відомих публікаціях виклики, можна сформулювати наступну задачу: розроблення оптимізованої моделі ШНМ для оброблення радіосигналів з метою підвищення ефективності використання системних ресурсів. Основна гіпотеза дослідження полягає в тому, що поставленої задачі можна досягнути, використавши одновимірну згорткову нейронну мережу.

Відповідно, ціллю дослідження буде розробка математичної моделі одновимірної згорткової нейронної мережі оброблення сигналів, формування на базі математичної моделі відповідної архітектури та порівняння ефективності сформованої моделі з ефективністю еталонної моделі приймача.

4. Формування навчального набору даних

Вид модуляції, на роботу з яким буде розрахована модель – амплітудна модуляція багатьох складових (АМБС) (рис. 1). Це такий вид амплітудно-фазової модуляції, що характеризується більшою енергетичною ефективністю в порівнянні з, наприклад, широко використовуваними сигналами з квадратурною амплітудною модуляцією [13].




Рис. 1. Сигнальне сузір'я 8-АМБС

АМБС-сигнал формується як сума його N компонент з різницею їх початкових фаз у $\varphi_0 + \varphi_n$ (рад):

$$U_{AMBC}(t) = U_n a_n U_{mn}(t) \cos(\omega_0 + \varphi_0 + \varphi_n), \quad (1)$$

де a_n – це коефіцієнт пропорційності n -ого підканалу, та $U_{mn}(t)$ - модуляційні сигнали n -ого входу модуляторів.

Відповідно, Евклідова відстань між найближчими точками сигнального сузір'я АМБС обчислюється за наступним співвідношенням:

$$d_{\text{сигн}} = U(M_u - 1), \quad (2)$$

Евклідову відстань також можна представити через d_m – відстань між горизонтальними рівнями, на яких розташовуються символні точки у сузір'ях АМБС з трьома складовими:

$$d_{\text{сигн}} = 2 \frac{d_m}{\sqrt{3}}, \quad (3)$$

Задавши певне значення d_m , можна вивести координати окремих сигнальних точок. Спершу варто визначити кількість горизонтальних рівнів (враховуючи, що обрана АМБС містить три складові):

$$N_y = 1/d_m + 1. \quad (4)$$

Відповідно, кількість точок на кожному горизонтальному рівні визначатиметься наступним чином:

$$N_x = 1 / \left(\frac{d_m}{\sqrt{3}} \right). \quad (4)$$

У випадку АМБС з трьома складовими координати для точок на парних і непарних горизонтальних рівнях сузір'я будуть визначатись дещо різним чином. Декартові X-координати точок на парних рівнях можна визначити наступним співвідношенням:

$$x_i = i \frac{d_{\text{сигн}}}{2}, \quad (6)$$

де $i \in \{-N_x; N_x + 1\}$.

Декартові X-координати точок на непарних рівнях, відповідно, можна визначити наступним співвідношенням:

$$x_i = i \frac{d_{\text{сигн}}}{2} + \frac{d_m}{2}, \quad (7)$$

де $i \in \{-N_x; N_x + 1\}$.

Y-координати, в свою чергу, обчислюються за наступною формулою:

$$y_j = j d_m, \quad (8)$$

де $j \in \{-N_y; N_y\}$.

Для представлення символів АМБС-сигналу в часовому форматі потрібно перевести Декартові координати в значення фази та амплітуди сигналу. В результаті отримується наступне співвідношення миттєвої амплітуди сигналу:

$$U_{ij}(t) = \sqrt{x_i^2 + y_j^2} \sin\left(t + \arctan\left(y_j / x_i\right)\right). \quad (9)$$

Також сигнал потрібно дискретизувати. Для цього величину t можна замінити на вектор \bar{t} , розмірність якого відповідає мінімальній частоті дискретизації згідно доповненої теореми Шеннона:

$$\bar{t} = \{t_1; t_2; t_3\} = \{\pi/4; \pi; 5\pi/4\}. \quad (10)$$

Відповідно один символ буде представлений вектором \bar{x}_{ij} :

$$\bar{x}_{ij} = \{U_{ij}(t_1); U_{ij}(t_2); U_{ij}(t_3)\}. \quad (11)$$

Додавши до \bar{x}_{ij} білий шум $n(\bar{t})$, отримається вектор вхідних значень для навчання ШНМ:

$$\bar{x}_{ij} = \{U_{ij}(t_1) + n(t_1); U_{ij}(t_2) + n(t_2); U_{ij}(t_3) + n(t_3)\}. \quad (12)$$

На основі отриманих співвідношень можна сформувавши ітеративний алгоритм генерації навчальних даних для ШНМ (рис. 2).

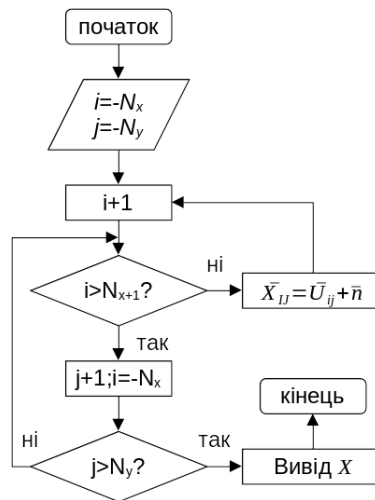


Рис. 2. Алгоритм генерації навчальних даних

Якщо застосувати до $n(t)$ умови знаходження в рівносторонньому шестикутнику під час обчислення варіацій сигнального символу в нулі координат та надалі екстраполювати отримані варіації сигналу на координати інших символів - масив вибірок буде представлений у вигляді заповнених комірок Вороного [14]. Такий підхід до генерації робить масив вибірок сигналів більш систематизованим.

5. Формування моделі штучної нейронної мережі

Готова модель повинна буде містити згорткові шари для визначення локальних особливостей та рекурентні шари для узагальнення локальних особливостей в одну цілісну картину, що дасть змогу ефективно декодувати сигнал (рис. 3). Попередньо отримані варіації вектора \bar{x} будуть виконувати роль вхідних даних сформованої мережі.

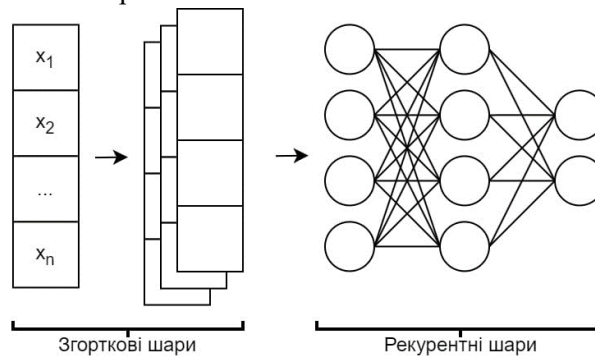


Рис. 3. Приблизна структура моделі

Варто розпочати опис моделі з найпростішого елемента – одиничного нейрона:

$$\bar{x}_1 = f(\bar{x}_0 \cdot \bar{w}_0 + b_0), \tag{13}$$

де \bar{x}_1 - вихідне значення (може бути як одне значення, так і вектор у випадках небінарної класифікації), \bar{x}_0 - вектор вхідних даних, f – функція активації, \bar{w} – вектор вагових коефіцієнтів (встановлюється в процесі навчання ШНМ), та b – зсув функції активації.

У випадку повноз'єднаних шарів (характерних для РНМ) вихід нейрона в першому шарі буде вхідом для кожного нейрона в наступному шарі (рис 4.).




Рис. 4. Повноз'єднані нейрони

Отже, вихід першого нейрона другого шару можна описати наступним співвідношенням:

$$\bar{x}_{20} = f(\bar{x}_{10} \cdot \bar{w}_{10} + b_1). \tag{14}$$

Тобто загальна формула виходу рекурентного шару матиме наступний вигляд:

$$\bar{x}_n = f(W_n \cdot x_n + W_{n-1} + b_n), \tag{15}$$

де n – номер шару.

При застосуванні операції згортки вихід шару починає мати наступний вигляд:

$$\bar{x}_n = f\left(\sum_{m=1}^k w_m \cdot x_{n+m-1} + b_n\right), \tag{16}$$

де k – розмір згорткового фільтра (або ширина згортки).

Додавши згорткові та рекурентні шари, можна отримати сумарне відображення мережі:

$$\bar{y}_t = f_{\text{вих}}\left(f_{\text{ЗНМ}}\left(\sum_{i=1}^{n_{\text{ЗНМ}}} (f_{\text{РНМ}}(W_{\text{РНМ}} \cdot \bar{x}_i + W_{\text{РНМ}i-1} \cdot \bar{y}_{t-1} + b_{\text{РНМ}}))\right) + b_{\text{ЗНМ}}\right) + b_{\text{вих}}, \tag{17}$$

де y_t – вихідне значення всієї мережі, $f_{\text{вих}}$ – функція активації на виході мережі, $f_{\text{ЗНМ}}$ – сумарна функція активації згорткових шарів, $f_{\text{РНМ}}$ – сумарна функція активації рекурентних шарів, W – матриця вагових коефіцієнтів, $b_{\text{РНМ}}$ – зсув рекурентного шару, $b_{\text{ЗНМ}}$ – зсув згорткового шару, $b_{\text{вих}}$ – зсув функції активації на виході.

Надалі формується кінцева модель (рис. 5). В якості входу виступає послідовність з 48 числових значень, що відповідають 16 послідовним символам (по 3 значення амплітуди на символ). При формуванні моделі зроблено припущення щодо певної стабільності системи синхронізації в процесі приймання сигналу.

Вибір конкретних структурних елементів (таб. 1) кінцевої моделі обумовлений ключовою особливістю згорткових шарів – інваріантністю щодо зсувів. Тобто згорткові шари можуть

виявляти фрагменти символів чи цілі символи як особливості, незалежно від їхнього розміщення у вхідній послідовності, а наступні рекурентні шари аналізують мапи особливостей в контексті всієї вхідної послідовності. Такий підхід є більш гнучким в порівнянні з попередньо запропонованим суто рекурентним підходом [15].

Таблиця 1

Структурні елементи кінцевої моделі

Шар	Розмірність	Призначення
Input	48 (16,3)	Вхідний шар — 48 значень, що відповідають 16 послідовним символам 8-АМБС
Conv1D ReLu	48x32	Перший згортковий шар — визначення більш поверхневих особливостей вхідного сигналу
Pooling	-	Перший пулінговий шар — узагальнення особливостей та зменшення ширини даних, що обробляються
Conv1D ReLu	24x64	Другий згортковий шар — визначення більш абстрактних особливостей вхідного сигналу

Також варто відзначити, що в згорткових шарах зазначений параметр “обрамлення”. При проведенні згортки автоматично зменшується ширина даних, з допомогою “обрамлення” до крайніх елементів у даних, що обробляються, додаються нульові значення, таким чином зберігаючи дані в повному обсязі і запобігаючи втраті значень першого та кінцевого символів.

Для валідації ефективності вдосконаленої математичної моделі нейронної мережі було проведено її тестування на великому наборі фрагментів сигналів. Той самий набір фрагментів також було оброблено еталонною моделлю, яка є еквівалентном реального приймального пристрою, що працює з АМБС [13]. Основним критерієм оцінки була кількість помилкових визначень символів під час обробки сигналів.

Перевірочні вибірки не брали участь у навчанні, тому можна припустити, що результати тестування об’єктивні і дають змогу оцінити реальну здатність моделі коректно обробляти нові, раніше невідомі їй дані.




Рис. 5. Будова сформованої моделі

Ключовим показником, який проаналізовано, стала імовірність помилки при розпізнаванні символів. Цей показник відображає відсоткове співвідношення помилково визначених символів до загальної кількості символів у вибірці і представлений у таблиці. Важливо зауважити, що тестування моделей проводилось при різних рівнях шумів на вхідних сигналах, що дозволило оцінити стійкість моделей до різних умов прийому радіосигналів і їхню здатність адаптуватися до різноманітних завад.

Таблиця 2

Порівняння імовірностей помилки при різних ВСШ запропонованої та еталонної моделей

Модель	ВСШ, дБ	-12	-8	-4	0	4
Еталон	Імовірність помилки δ	0.703	0.613	0.421	0.205	0.041
Одновимірний згортковий		0.423	0.378	0.269	0.141	0.036

З даних, отриманих в процесі валідації (табл. 2), можна отримати певну залежність (рис. 6), яка демонструє значне покращення точності оброблення радіосигналів у порівнянні з еталонною моделлю при високих рівнях шумів, та зменшення різниці між розробленою та еталонною моделлю при менших рівнях шумів.

Загалом, отримана модель є вдосконаленням раніше запропонованої суто рекурентної моделі [15] та демонструє кращу здатність адаптуватися до різних умов середовища передавання сигналу. Такий результат досягнуто за рахунок використання згорткових шарів, що дають змогу виявляти фрагменти сигналів в суміші сигнал-шум незалежно від їх позиції в часі та надалі формувати цілісний контекст сигналу на основі виявлених особливостей.




Рис. 6. Залежності імовірності символічної помилки від відношення сигнал/шум в розробленій та еталонній моделях

Висновки

На основі задачі, сформованої в результаті огляду праць, присвячених використанню нейронних моделей для оброблення сигналів, в тому числі радіосигналів, було запропоновано модель одновимірної згорткової нейронної мережі. Було розглянуто особливості сигналів з АМБС та описано спосіб генерації навчальних вибірок для запропонованої моделі. Отримані послідовності значень амплітуд було надалі представлено як вектор вхідних значень для нейронної моделі. Описані математичні моделі основних структурних елементів одновимірних згорткових нейронних мереж.

На основі отриманих співвідношень сформовано нейронну модель. Представлено результати порівняння ефективності еталонної моделі, що відповідає реальному приймальному пристрою, з ефективністю запропонованої моделі. Відмічено значне зменшення імовірності помилки при більших рівнях шумів, що показує переваги використання запропонованого підходу в складних умовах передавання. Пояснено переваги підходу в порівнянні з попередньо запропонованим суто рекурентним способом оброблення радіосигналів. Сформовано архітектуру запропонованої моделі, пояснено призначення окремих структурних елементів та інші особливості моделі.

Список використаних літературних джерел

- [1]. Xu, S., Li, J., Liu, K., & Wu, L. (2019). A Parallel GRU Recurrent Network Model and its Application to Multi-Channel Time-Varying Signal Classification. *IEEE Access*, 7, 118739-118748. <https://doi.org/10.1109/ACCESS.2019.2936516>
- [2]. Huang, B., Lin, C.-L., Chen, W., Juang, C.-F., & Wu, X. (2020). Signal Frequency Estimation Based on RNN. 2020 Chinese Control And Decision Conference (CCDC) (pp. 2030-2034). Hefei, China. <https://doi.org/10.1109/CCDC49329.2020.9164504>
- [3]. Xian, Y., Pu, Y., Gan, Z., Lu, L., & Thompson, A. (2017). Adaptive DCTNet for audio signal classification. 2017 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP) (pp. 3999-4003). New Orleans, LA, USA. <https://doi.org/10.1109/ICASSP.2017.7952907>
- [4]. Liu, Q., Dai, Y., Li, M., Yao, B., Xin, Y., & Zhang, J. (2022). Real-time processing of force sensor signals based on LSTM-RNN. 2022 IEEE International Conference on Robotics and Biomimetics (ROBIO) (pp. 167-171). Jinghong, China. <https://doi.org/10.1109/ROBIO55434.2022.10011703>
- [5]. Teich, W. G. (2017). Low-power high-speed signal processing: From iterative algorithm to analog circuits. 2017 11th International Conference on Signal Processing and Communication Systems (ICSPCS) (pp. 1-1). Surfers Paradise, Australia. <https://doi.org/10.1109/ICSPCS.2017.8270449>
- [6]. Vijayamohan, J., Gupta, A., Noakoosteen, O., & Christodoulou, C. (2021). Convolutional Neural Networks for Radio Source Detection. 2021 IEEE International Symposium on Antennas and Propagation and USNC-URSI Radio Science Meeting (APS/URSI) (pp. 1491-1492). Singapore, Singapore. <https://doi.org/10.1109/APS/URSI47566.2021.9704525>
- [7]. Pan, J., Guo, L., Chen, Q., Zhang, S., & Xiong, J. (2022). Specific Radar Emitter Identification Using 1D-CBAM-ResNet. 2022 14th International Conference on Wireless Communications and Signal Processing (WCSP) (pp. 483-488). Nanjing, China. <https://doi.org/10.1109/WCSP55476.2022.10039094>
- [8]. Rahman, M. H., Sejan, M. A. S., Aziz, M. A., You, Y.-H., & Song, H.-K. (2023). HyDNN: A Hybrid Deep Learning Framework Based Multiuser Uplink Channel Estimation and Signal Detection for NOMA-OFDM System. *IEEE Access*, 11, 66742-66755. <https://doi.org/10.1109/ACCESS.2023.3290217>
- [9]. Kiranyaz, S., Ince, T., Abdeljaber, O., Avci, O., & Gabbouj, M. (2019). 1-D Convolutional Neural Networks for Signal Processing Applications. ICASSP 2019 - 2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP) (pp. 8360-8364). Brighton, UK. <https://doi.org/10.1109/ICASSP.2019.8682194>
- [10]. Shahid, S. M., Ko, S., & Kwon, S. (2022). Performance Comparison of 1D and 2D Convolutional Neural Networks for Real-Time Classification of Time Series Sensor Data. 2022 International Conference on Information Networking (ICOIN) (pp. 507-511). Jeju-si, Korea, Republic of. <https://doi.org/10.1109/ICOIN53446.2022.9687284>
- [11]. Wang, H., Chong, D., Huang, D., & Zou, Y. (2019). What Affects the Performance of Convolutional Neural Networks for Audio Event Classification. 2019 8th International Conference on Affective Computing and Intelligent Interaction Workshops and Demos (ACIIW) (pp. 140-146). Cambridge, UK. <https://doi.org/10.1109/ACIIW.2019.8925277>
- [12]. T. J. O'Shea, T. Roy and T. C. Clancy, "Over-the-Air Deep Learning Based Radio Signal Classification," in *IEEE Journal of Selected Topics in Signal Processing*, vol. 12, no. 1, pp. 168-179, Feb. 2018, <https://doi.org/10.1109/JSTSP.2018.2797022>
- [13]. Горбатий, І. В. (2013). Нові різновиди модуляції сигналу в цифрових радіорелейних системах передавання. *Проблеми телекомунікацій*, (2)11, с. 44–55. https://pt.nure.ua/wp-content/uploads/2020/01/132_gorbatyy_modulation.pdf
- [14]. Горбатий, І.В., Цимбалюк, І.Р.. (2022). Метод формування вибірок сигналів з амплітудною модуляцією багатьох складових. *Інфокомунікаційні та комп'ютерні технології*. 2, с. 172 — 181. <http://dx.doi.org/10.36994/2788-5518-2021-02-02-12>
- [15]. Horbatiy, I., Tsymbaliuk, I. (2022). Neural Network Based Approach for Demodulation of Signals with Amplitude Modulation of Many Components. 2022 IEEE 16th International Conference on Advanced Trends in Radioelectronics, Telecommunications and Computer Engineering (TCSET), pp. 114-117. <https://doi.org/10.1109/TCSET55632.2022.9766952>

ONE-DIMENSIONAL CONVOLUTIONAL NEURAL NETWORK MODEL FOR PROCESSING AMPLITUDE MODULATION ON MANY COMPONENTS SIGNALS

Ivan Tsymbaliuk

Lviv Polytechnic National University, Stepana Bandery str., 12, 79013, Lviv, Ukraine

The processing of radio signals using artificial neural networks (ANNs) has great potential for research, which can be explained by the adaptability of ANNs to various transmission conditions and the ability to detect abstract patterns of changes in signal parameters. The article reviews the works of other authors devoted to different ways of using ANNs for processing radio signals. Taking into account the information in the reviewed works, the research task was formed, which consists in developing an optimized ANN model for radio signal processing. Signals with amplitude modulation of many components (AMMC) were chosen to form training samples for ANN. The choice of modulation type is justified by greater energy efficiency compared to other widely used digital modulation types, such as quadrature amplitude modulation. Mathematic basis of AMMC signal generation is described. The process of finding the coordinates of three component 8-AMMC signal constellation is explained, the formation of signals in the time plane based on the found coordinates is explained as well as their discretization and the addition of white noise. An iterative algorithm for generating initial data for ANN based on the described ratios is proposed. The general structure of one-dimensional convolutional neural network is considered. Functions of individual neurons, connections between them, the formation of layers and the convolution operation are described mathematically. On the basis of the previously given ratios, a final display of the network was formed. Specific dimensions and activation functions for layers are selected. The use of convolutional layers is justified by time invariance. Based on the reviewed mathematical models, selected activation functions and dimensions, a neural model was formed. The process of validating the effectiveness of the formed neural model is described, which is based on comparing the symbolic error probabilities of the proposed and reference models at different signal-to-noise ratios. The validation results are presented. The advantages of the obtained model over the previously proposed purely recurrent model and the AMMC reference receiver are explained.

Keywords: *Amplitude modulation of many components (AMMC), artificial neural network (ANN), convolutional neural network (CNN)*