

# АВТОМАТИЗОВАНІ ТА ТЕЛЕМАТИЧНІ СИСТЕМИ НА ТРАНСПОРТІ

УДК 656.259.2:004.032.26

К. В. ГОНЧАРОВ<sup>1\*</sup>, Р. В. РИБАЛКА<sup>2\*</sup>, Т. М. СЕРДЮК<sup>3\*</sup>

<sup>1\*</sup>Каф. «Автоматика та телекомунікації», Український державний університет науки і технологій, ННІ ДІТ, вул. Лазаряна, 2, Дніпро, Україна, 49010, тел. +38 (056) 373 15 04, ел. пошта k.v.honcharov@ust.edu.ua, ORCID 0000-0002-0432-1077

<sup>2\*</sup>Каф. «Автоматика та телекомунікації», Український державний університет науки і технологій, ННІ ДІТ, вул. Лазаряна, 2, Дніпро, Україна, 49010, тел. +38 (056) 373 15 04, ел. пошта r.v.rybalka@ust.edu.ua, ORCID 0000-0001-7444-0517

<sup>3\*</sup>Каф. «Автоматика та телекомунікації», Український державний університет науки і технологій, ННІ ДІТ, вул. Лазаряна, 2, Дніпро, Україна, 49010, тел. +38 (056) 373 15 04, ел. пошта t.m.serdiuk@ust.diit.edu.ua, ORCID 0000-0002-2609-4071

## Застосування згорткової нейронної мережі для класифікації кодів автоматичної локомотивної сигналізації

**Мета.** Обґрунтування вибору типу та параметрів штучної нейронної мережі для класифікації кодових сигналів автоматичної локомотивної сигналізації АЛСН за наявності завад та спотворень часових параметрів кодів. **Методика.** Для досягнення поставленої мети виконано порівняльний аналіз різних типів штучних нейронних мереж. Було встановлено, що для класифікації кодів АЛСН найбільш придатною є одновимірна згорткова мережа, яка ефективно виявляє характерні часові ознаки сигналів, потребує менше даних для навчання, стійка до шумів, забезпечує стабільну класифікацію навіть при зсуві сигналу в часі. Були проведені розрахунки кількості параметрів мережі залежно від її конфігурації: кількості шарів, згорткових фільтрів та кількості нейронів у повнозв'язаних шарах. Для навчання мережі використовували синтезовані дані: до еталонних сигналів «З», «Ж», «ЧЖ» додавався шум та вносились випадкові зміни часових параметрів (тривалості імпульсів і пауз). Було синтезовано 1000 реалізацій для кожного кодового сигналу АЛСН. Програмний код для підготовки даних, тренування мережі та класифікації сигналів був написаний мовою Python із використанням бібліотек TensorFlow, Keras, Scipy.signal та NumPy. **Результати.** Відповідно до отриманої залежності між конфігурацією нейронної мережі та точністю класифікації для розпізнавання кодів АЛСН була обрана мережа, яка містить три згорткові шари, шар Dense з 16-ти нейронів та вихідний шар з трьох нейронів. Працездатність запропонованої нейронної мережі була підтверджена результатами класифікації синтезованих сигналів з низьким відношенням сигнал/шум та сильним спотворенням форми, а також реальних сигналів АЛСН. **Наукова новизна.** Авторами цієї роботи вперше проведено комплексне дослідження ефективності різних типів штучних нейронних мереж для класифікації кодів автоматичної локомотивної сигналізації АЛСН в умовах інтенсивних завад та часових спотворень, що дозволило обґрунтувати вибір конфігурації одновимірної згорткової нейронної мережі та встановити залежності між параметрами моделі (кількістю шарів, фільтрів, нейронів) та точністю класифікації. **Практична значимість.** Впровадження цифрового локомотивного приймача сигналів АЛСН із класифікатором на базі запропонованої згорткової нейронної мережі замість застарілої релейної апаратури дозволить зменшити експлуатаційні витрати, підвищити завадостійкість та надійність системи АЛСН за рахунок стійкого розпізнавання кодів в умовах інтенсивних завад та спотворень часових параметрів кодових сигналів.

*Ключові слова:* автоматична локомотивна сигналізація; часові ознаки сигналів; завадостійкість; спотворення часових параметрів кодів; згорткова нейронна мережа; розпізнавання коду АЛСН; глибоке навчання; точність класифікації

## Вступ

Система автоматичної локомотивної сигналізації (АЛС) є складовою комплексу технічних засобів, які забезпечують безпеку руху поїздів. Така система виконує дублювання сигналів колійних світлофорів у кабіні машиніста, здійснює контроль швидкості руху поїзда, перевірку пильності машиніста та автоматичне екстрене гальмування у разі порушення умов безпеки руху. В Україні застосовується система автоматичної локомотивної сигналізації неперервної дії з числовим кодуванням АЛСН, яка відповідно до показань колійних світлофорів забезпечує передачу через рейкову лінію на локомотив одного з трьох кодових сигналів: «З», «Ж» або «ЧЖ». Сигнал АЛСН наводиться у локомотивних котушках, фільтрується та підсилюється. Після цього відбувається дешифрування отриманого коду та вмикання відповідного сигналу на локомотивному світлофорі [18].

На сьогодні використовується переважно релейна апаратура АЛСН, яка є застарілою та потребує значних експлуатаційних витрат. У роботі [1] в результаті аналізу статистики відмов АЛСН було визначено, що основною причиною відмов є зношеність апаратури. Перш за все це стосується локомотивного дешифратора, який виконує розпізнавання отриманого коду. Також було встановлено, що причинами збоїв в системі АЛСН зокрема є спотворення часових параметрів коду, намагніченість рейок та нестабільне живлення [1, 10]. Крім цього, в рейковій лінії діють потужні завади (гармоніки тягового струму, імпульсні завади, що виникають в результаті різноманітних комутаційних процесів тощо), які спотворюють сигнал АЛСН та за певних умов також можуть призвести до збоїв [11].

Існують кілька напрямів удосконалення системи автоматичної локомотивної сигналізації. Перший з них пов'язаний із застосуванням більш сучасних та ефективних методів передачі команд на локомотив. В роботі [2] запропоновано для передачі даних через рейкову лінію використовувати завадостійкий код Файра та квадратурну фазову маніпуляцію QPSK, а в роботі [13] – застосовувати широкосмугові сигнали, сформовані за допомогою ортогональних кодів Уолша, та бінарну фазову маніпуляцію BPSK. Впровадження таких рішень дозволить підви-

щити інформативність та завадостійкість системи АЛС, проте вимагає значних фінансових витрат, що пов'язано з необхідністю повної заміни колійної та локомотивної апаратури.

Інший напрям удосконалення системи АЛСН передбачає впровадження більш ефективних методів і засобів обробки та дешифрування кодових сигналів. В роботі [12] для розпізнавання коду, отриманого локомотивним приймачем, пропонується проводити аналіз сигналу в частотній та часовій області за допомогою перетворення Фур'є та Wavelet перетворення. Авторами роботи [7] синтезований оптимальний приймач сигналів АЛСН на тлі адитивних завад трьох типів: імпульсних, неперервних синусоїдальних та гаусового шуму.

Сучасні нейромережеві технології дозволяють вирішувати складні задачі класифікації різноманітних об'єктів, в тому числі – розпізнавання кодів автоматичної локомотивної сигналізації. В роботі [5] розроблено нейромережеву модель для розпізнавання тривалості імпульсів та інтервалів в кодових сигналах АЛСН. Автор роботи [10] для виявлення спотворень сигналів АЛСН пропонує застосовувати адаптивну систему нейрончїткого логїчного висновку (ANFIS) та ентропію Шеннона енергїї вейвлет-пакетів (WPESE). В роботі [15] для захисту автоматичної локомотивної сигналізації від завад запропоновано метод обробки сигналів, в якому застосовується алгоритм оптимізації PSO та глибока нейронна мережа DBN. Таким чином, на сьогодні існують різноманітні рішення застосування штучної нейронної мережі (ШНМ) для обробки та дешифрування кодів автоматичної локомотивної сигналізації. Проте в роботах за даним напрямом немає обґрунтування щодо вибору типу та параметрів штучної нейронної мережі: кількості та типу шарів, кількості нейронів у кожному шарі, типу функції активації тощо.

## Мета

Метою роботи є обґрунтування вибору типу та параметрів штучної нейронної мережі для класифікації кодових сигналів автоматичної локомотивної сигналізації за наявності завад та спотворень часових параметрів кодів.

### Методика

*Особливості сигналів АЛСН.* В системі автоматичної локомотивної сигналізації АЛСН використовуються амплітудно-модульовані сигнали, які забезпечують передачу на локомотив одного із трьох кодів: «З», «Ж» або «ЧЖ». Кожен кодовий сигнал має свої часові ознаки: кількість імпульсів, тривалість імпульсів та пауз. Так для коду «З» передаються три імпульси в кодовому циклі, а для коду «Ж» – два імпульси. В коді «ЧЖ» цикл містить тільки один імпульс, проте тривалість циклу вдвічі менша ніж для інших кодів. Сигнали АЛСН формують кодовий колійний трансмітер, тип якого визначає тривалість кодового циклу. В табл. 1 представлені часові параметри різних кодових сигналів: тривалості імпульсів  $t_{i1}$ ,  $t_{i2}$ ,  $t_{i3}$  пауз  $t_{n1}$ ,  $t_{n2}$ ,  $t_{n3}$  та тривалості циклу  $T_u$  [18].

На залізничних ділянках з автономною тягою та електротягою постійного струму застосовуються сигнали АЛСН з несучою частотою 50 Гц, а на ділянках з електротягою змінного струму – 25 Гц або 75 Гц. Для цифрової обробки сигналу АЛСН необхідно виконати його дискретизацію та перетворити на вектор вибіркового значення (відліків сигналу). Необхідний інтервал дискретизації  $T_\delta$  визначається відповідно до теореми Котельникова:

$$T_\delta \leq \frac{1}{2f_{\max}}, \quad (1)$$

де  $f_{\max}$  – максимальна частота спектра сигналу АЛСН.

Спектр амплітудно-модульованого сигналу містить несучу частоту та верхню і нижню бічну смуги. В даній роботі були проведені розрахунки амплітудного спектра для різних кодів АЛСН. За результатами розрахунків встановлено, що ефективна ширина кожної бічної смуги складає 7...8 Гц. Тоді для максимальної несучої частоти 75 Гц верхня границя спектру складає 83 Гц. Визначено необхідну кількість відліків сигналу АЛСН за один кодовий цикл:

$$N \geq 2f_{\max} T_u, \quad (2)$$

де  $T_u$  – тривалість кодового циклу.

Відповідно до виразу (2) при застосуванні трансмітера КППШ-5 для цифрової обробки сигналу АЛСН необхідно обирати не менше ніж 267

відліків на цикл, а при застосуванні КППШ-7 – не менше 309 відліків на цикл.

Таким чином, перед застосуванням штучної нейронної мережі необхідно виконати попередню обробку отриманого сигналу АЛСН: 1) за допомогою засобів циклової синхронізації виділити один кодовий цикл; 2) виконати дискретизацію сигналу та сформувати вектор відліків для одного циклу, який буде передаватись на входи нейронної мережі. Обираємо 500 відліків на цикл, що відповідає вимогам (2).

*Порівняльний аналіз різних типів ШНМ.* Штучна нейронна мережа представляє собою систему взаємопов'язаних вузлів (штучних нейронів), які приблизно моделюють нейрони біологічного мозку. Кожен штучний нейрон приймає сигнали від інших нейронів, знаходить їх зважену суму, обчислює передавальну функцію та передає результуючий сигнал до наступної групи нейронів. Входи мають різну синаптичну вагу, яка є мірою сили вхідних зв'язків та визначається під час навчання ШНМ [4, 6, 9].

Залежно від архітектури та способу з'єднання нейронів більшість відомих ШНМ можна розділити на два класи: рекурентні мережі та мережі прямого поширення. Рекурентні мережі мають зворотні зв'язки, що дозволяє їм зберігати інформацію про попередні стани. Це забезпечує можливість врахувати попередні відліки сигналу, моделювати динамічні процеси, розпізнавати шаблони, що залежать від історії [6, 9]. Проте наявність зворотних зв'язків може призвести до втрати стійкості рекурентної мережі. Тому такі мережі не можна використовувати в системі АЛСН та інших системах, які забезпечують безпеку руху поїздів.

В мережах прямого поширення сигнали передаються тільки в одному напрямку: від входу до виходу, без зворотних зв'язків і циклів. Це забезпечує гарантовану стійкість, передбачуваність поведінки та високу швидкодію. До такого класу, зокрема, відносяться повнозв'язані мережі та згорткові мережі [6, 9]. ШНМ цих двох типів придатні для класифікації кодів АЛСН.

Повнозв'язана мережа типу Багатошаровий перцептрон (англ. Multilayer Perceptron – MLP) містить вхідний шар, один або кілька прихованих шарів і вихідний шар. При цьому кожен нейрон попереднього шару з'єднується з усіма нейронами наступного шару. Вхідний шар мережі MLP

## АВТОМАТИЗОВАНІ ТА ТЕЛЕМАТИЧНІ СИСТЕМИ НА ТРАНСПОРТІ

виконує функцію інтерфейсу між сигналом АЛСН та нейронною мережею. Кількість нейронів у вхідному шарі дорівнює розміру вхідного вектора. Приховані шари виконують аналіз часової структури сигналу та виявлення закономірностей, характерних для конкретних кодів АЛСН. Кожен нейрон прихованого шару обчислює зважену суму всіх вхідних сигналів після чого до результату застосовується нелінійна функція активації (наприклад, сигмоїд або ReLU). Вихідний

шар містить три нейрони та відповідно три виходи, що відповідає кількості кодів АЛСН [6, 9].

Недоліком мережі MLP є велика кількість параметрів (вагових коефіцієнтів та зсувів), значення яких визначаються під час навчання. Чим більше параметрів, тим більше час навчання ШНМ, більші вимоги до обчислювальних ресурсів та менше швидкість роботи. Останнє є особливо критичним для систем реального часу, таких як система АЛСН.

Таблиця 1

## Часові параметри кодів АЛСН

Table 1

## Time parameters of ALSN codes

Тип трансмітера	Код АЛСН	Часові параметри кодів, с						
		$t_{i1}$	$t_{n1}$	$t_{i2}$	$t_{n2}$	$t_{i3}$	$t_{n3}$	$T_{ц}$
КПТШ–5	«З»	0,35	0,12	0,22	0,12	0,22	0,57	1,6
	«Ж»	0,38	0,12	0,38	0,72	–	–	1,6
	«ЧЖ»	0,23	0,57	0,23	0,57	–	–	1,6
КПТШ–7	«З»	0,35	0,12	0,24	0,12	0,24	0,79	1,86
	«Ж»	0,35	0,12	0,6	0,79	–	–	1,86
	«ЧЖ»	0,3	0,63	0,3	0,63	–	–	1,86

Крім цього, за великої кількості параметрів нейронної мережі та недостатньому обсязі тренувальних даних збільшується ризик перенавчання, тобто ШНМ добре вивчить навчальні дані, але не буде працювати в реальних умовах.

*Згорткова штучна нейронна мережа.* Структурна схема одновимірної згорткової нейронної мережі (англ. Convolutional Neural Network – CNN), яка дозволяє класифікувати коди АЛСН, зображена на рис. 1. На вхід мережі подається одновимірний вектор з 500 відліків сигналу, що відповідає одному кодовому циклу. Мережа CNN містить згорткові шари, шари Pooling, шар Flatten та повністю зв'язані шари [8, 3, 14, 17].

Кожен згортковий шар має кілька фільтрів, які виявляють різні часові ознаки сигналу. Кількість фільтрів визначає кількість локальних ознак сигналу, а розмір ядра кожного фільтра – довжину часового вікна, в межах якого «витягуються» локальні ознаки. Фільтр виконує одновимірну згортку вхідного сигналу з ядром. На рис. 2 показано приклад виконання згортки для фільтра

з трьохелементним ядром. Кожен елемент результату згортки розраховується як сума попарних добутків елементів ядра та відповідної ділянки вхідного сигналу. Після обчислення одного значення ядро зміщується вздовж вхідного вектора і процес повторюється для наступного сегмента.

Перший згортковий шар нейронної мережі виявляє прості часові ознаки сигналу: фронт імпульсу, зріз, імпульс, паузу. Наступні згорткові шари виявляють більш складні часові структури, наприклад, поєднання імпульсу і паузи заданої тривалості або поєднання кількох імпульсів і пауз.

Під час навчання згорткової мережі виникає проблема внутрішнього коваріантного зсуву, коли ваги згорткового шару постійно змінюються. Це змінює розподіл вхідних сигналів для наступних шарів, змушуючи їх безперервно адаптуватися до нових умов, що значно уповільнює процес навчання. У зв'язку із цим після згорткового шару розташовується шар Batch

## АВТОМАТИЗОВАНІ ТА ТЕЛЕМАТИЧНІ СИСТЕМИ НА ТРАНСПОРТІ

Normalization. Принцип його дії полягає в тому, що для кожного Batch (підмножини навчальних даних) обчислюється середнє значення та дисперсія, на основі яких вхідні дані центруються та масштабуються до стандартного нормального розподілу. Це дозволяє отримати вищі швидкості навчання та прискорити збіжність. Після кожного згорткового шару, доповненого Batch Normalization, йде шар Pooling, який зменшує кількість даних, зберігаючи найбільш значущі

ознаки та забезпечуючи інваріантність до невеликих зсувів у вхідному сигналі. Наприклад, шар Max Pooling 2 зменшує кількість елементів удвічі: з кожної пари елементів обирається той, що має більше значення. Після згорткових та пулінгових шарів розміщується класифікаційний блок, який містить шар Flatten та повнозв'язані шари (Dense шари).




Рис. 1. Згорткова нейронна мережа 1D-CNN

Fig. 1. Convolutional neural network 1D-CNN




Рис. 2. Приклад визначення першого (а), другого (б) та третього (в) елементів одновимірної згортки

Fig. 2. Example of defining the first (a), second (b) and third (c) elements of a one-dimensional convolution

Шар Flatten перетворює багатовимірний тензор даних у одновимірний вектор. Dense шари збирають разом всі розрізнені ознаки, виявлені згортковими шарами, та виконують фінальну класифікацію.

Вихідний Dense шар містить три нейрони, кожен з яких відповідає одному з трьох можливих кодів АЛСН. На вихідному шарі використовується функція активації Softmax, яка перетворює вихідні значення у ймовірності кожного класу:

$$P_k = \frac{e^{y_k}}{\sum_{j=1}^3 e^{y_j}}, \quad (3)$$

де  $y_k$  – зважена сума вхідних сигналів для  $k$ -го нейрона вихідного шару;  $p_k$  – ймовірність належності сигналу до  $k$ -го коду;  $k = 1 \dots 3$ .

Класифікація отриманого коду АЛСН здійснюється шляхом порівняння ймовірностей на виходах нейронної мережі.

Одновимірний згортковий шар (1D-CNN) має суттєво менше параметрів у порівнянні з MLP, ефективно виявляє характерні часові ознаки (патерни) сигналів, потребує менше даних для навчання, стійка до шумів і невеликих спотворень сигналу, забезпечує стабільну класифікацію навіть при зсуві сигналу в часі [14].

Загальне число параметрів згорткової нейронної мережі залежить від кількості шарів та кількості фільтрів в кожному згортковому шарі, розміру ядра фільтрів та числа нейронів у повнозв'язаних шарах. Розрахуємо кількість параметрів мережі 1D-CNN, яка містить один згортковий шар Conv1D(8,7), шари Batch Normalization, Max Pooling 2, Flatten, повнозв'язані шари Dense(8) та Dense(3).

Згортковий шар Conv1D(8,7) має 8 фільтрів з розміром ядра 7. З урахуванням зміщення кожен фільтр має 8 параметрів. Таким чином загальна кількість параметрів для такого шару дорівнює  $8 \cdot 8 = 64$ . Вхідний згортковий шар перетворює вектор з 500 відліків сигналу АЛСН на двовимірний масив розміром (500,8). Після Max Pooling 2 розмір масиву дорівнює (250,8). Шар Flatten змінює цей масив на одновимірний вектор розміром  $250 \cdot 8 = 2000$ . Кількість параметрів шару Dense(8), що складається з 8 нейронів, з урахуванням зміщення для кожного нейрона дорівнює  $2000 \cdot 8 + 8 = 16008$ . Вихідний шар Dense(3) має  $8 \cdot 3 + 3 = 27$  параметрів. Таким чином, загальна кількість параметрів даної мережі CNN дорівнює  $64 + 16008 + 27 = 16099$ .

Аналогічно були проведені розрахунки кількості параметрів нейронної мережі з одним (CNN-1), двома (CNN-2) і трьома (CNN-3) згортковими шарами та різною кількістю нейронів у повнозв'язаному шарі. Результати наведені у табл. 2.

*Навчання нейронної мережі.* В рамках даної роботи була розроблена модель мережі 1D-CNN, яка дозволяє класифікувати сигнали АЛСН. Структура мережі зображена на рис. 1.

Програмний код для підготовки даних, тренування мережі та класифікації сигналів був написаний мовою Python із використанням бібліотек TensorFlow, Keras, Scipy.signal та NumPy [9].

Для навчання мережі використовували синтезовані дані: до еталонних сигналів «З», «Ж» та «ЧЖ» додавався шум та вносились випадкові зміни часових параметрів (тривалості імпульсів і пауз). Було синтезовано 3000 реалізацій сигналів АЛСН: 1000 реалізацій для кожного коду. Половина сигналів формувались для кодового циклу КПТШ-5, інша половина – для циклу КПТШ-7.

Синтез даних проводили за наступним алгоритмом:

1) задати параметри сигналу АЛСН: тривалість кодового циклу, частоту несучого сигналу;  
2) сформувати вектор з 500 значень несучого сигналу, що відповідає одному кодовому циклу АЛСН;

3) задати патерни кодових сигналів «З», «Ж», «ЧЖ» (кількість імпульсів в циклі, тривалість імпульсів та пауз);

4) сформувати еталонні сигнали «З», «Ж» та «ЧЖ»;

5) для кожного коду АЛСН сформувати масив з 1 000 реалізацій спотворених сигналів. При цьому до еталонних сигналів з амплітудою 1,0 додати адитивний гаусовий шум із середньоквадратичним відхиленням 0,5 та випадковим чином змінити тривалості імпульсів і пауз сигналу АЛСН з максимальним відхиленням до 20% від нормативного значення;

6) сформувати об'єднану матрицю синтезованих сигналів та відповідний вектор міток класів;

7) виконати перемішування даних;

8) розділити синтезовані дані на навчальний набір (80 %) та валідаційний набір (20 %).

Під час навчання згорткової нейронної мережі використано метод оптимізації Adam (Adaptive Moment Estimation), який автоматично адаптує швидкість навчання для кожного параметра окремо та є ефективним для «зашумлених» даних. В якості функції втрат обрано розріджену категоріальну крос-ентропію (sparse categorical cross-entropy) [6].

Було проведено навчання мережі 1D-CNN з різною конфігурацією: з одним, двома та трьома згортковими шарами, з різною кількістю нейронів у Dense-шарі. Отримана точність класифікації наведена у табл. 3.

Таблиця 2

## Кількість параметрів для різних моделей згорткових нейронних мереж

Table 2

## Number of parameters for different convolutional neural network models

Шари нейронної мережі	Кількість параметрів для різних моделей CNN								
	шар Dense на 8 нейронів			шар Dense на 16 нейронів			шар Dense на 32 нейрони		
	CNN-1	CNN-2	CNN-3	CNN-1	CNN-2	CNN-3	CNN-1	CNN-2	CNN-3
Conv1D(8,7)	64	64	64	64	64	64	64	64	64
Pool(2)	0	0	0	0	0	0	0	0	0
Conv1D(16,5)		656	656	–	656	656	–	656	656
Pool(2)	–	0	0	–	0	0	–	0	0
Conv1D(32,3)	–	–	1568	–	–	1568	–	–	1568
Pool(2)	–	–	0	–	–	0	–	–	0
Flatten	0	0	0	0	0	0	0	0	0
Dense	16 008	16 008	16 008	32 016	32 016	32 016	64 032	64 032	64 032
Dense(3)	27	27	27	51	51	51	99	99	99
Загальна кількість параметрів	16 099	16 755	18 323	32 131	32787	34 355	64 195	64 851	66 419

Таблиця 3

## Точність класифікації на тренувальних та валідаційних даних

Table 3

## Classification accuracy on training and validation data

Тип даних	Модель згорткової нейронної мережі								
	шар Dense на 8 нейронів			шар Dense на 16 нейронів			шар Dense на 32 нейрони		
	CNN-1	CNN-2	CNN-3	CNN-1	CNN-2	CNN-3	CNN-1	CNN-2	CNN-3
Точність на тренувальних даних	100 %	100 %	100 %	100 %	100 %	100 %	100 %	100 %	100 %
Точність на валідаційних даних	97,5 %	98,7 %	99,1 %	98,8 %	99,6 %	100 %	99,1 %	100 %	100 %

## Результати

Відповідно до результатів розрахунку, які представлені у табл. 2, для кожного наступного згорткового шару мережі 1D–CNN кількість параметрів суттєво збільшується, що пов'язано зі

збільшенням розміру вхідних даних. Найбільшу кількість параметрів має перший шар Dense, причому збільшення кількості нейронів у цьому шарі призводить до значного зростання числа параметрів.

## АВТОМАТИЗОВАНІ ТА ТЕЛЕМАТИЧНІ СИСТЕМИ НА ТРАНСПОРТІ

За результатами навчання мережі 1D–CNN, які представлені у табл. 3, для всіх моделей мережі точність на тренувальних даних склала 100 %, тобто моделі повністю «вивчили» тренувальний набір. Збільшення кількості нейронів у шарі Dense з 8 до 16 призвело до помітного підвищення точності на валідаційних даних. Використання більшого числа згорткових шарів також забезпечує вищу точність валідації. При застосуванні шару Dense на 16 та 32 нейрони на валідаційному наборі була отримана точність класифікації 100 %. Це показує, що класи кодів АЛСН добре відокремлюються. З урахуванням результатів досліджень, які наведені у табл. 2 та 3, пропонуємо застосовувати для класифікації кодів АЛСН мережу CNN–3 з трьома згортковими шарами та шаром Dense на 16 нейронів. Використання більш складної конфігурації мережі через більшу кількість параметрів призведе до збільшення часу навчання, зменшення швидкості роботи та створює ризик перенавчання моделі.

Для перевірки здатності запропонованої моделі узагальнювати та класифікувати дані були синтезовані нові реалізації сигналів АЛСН, які не використовувались для навчання і валідації. Для цього за допомогою модуля Scipy.signal еталонні сигнали АЛСН відфільтрували смуговим фільтром зі смугою пропускання 45...55 Гц, що призводило до спотворення фронту і зрізу імпульсів. Дослідження проводили для частоти несучого сигналу 50 Гц. До отриманих сигналів додавали гаусовий шум різного рівня.

На рис. 3 зображені отримані реалізації сигналів АЛСН при відношенні сигнал/шум 10 децибел, а на рис. 4 – при відношенні нуль децибел. На даних рисунках також представлені результати класифікації сигналів згортковою мережею. У правому нижньому куті кожного графіка на рис. 3 та рис. 4 наведені ймовірності кожного класу, а у правому верхньому куті – результат передбачення. Відповідно до отриманих результатів запропонована згорткова нейронна мережа зі стовідсотковою ймовірністю класифікує коди АЛСН навіть при дуже низькому відношенні сигнал/шум та сильному спотворенні форми сигналу.

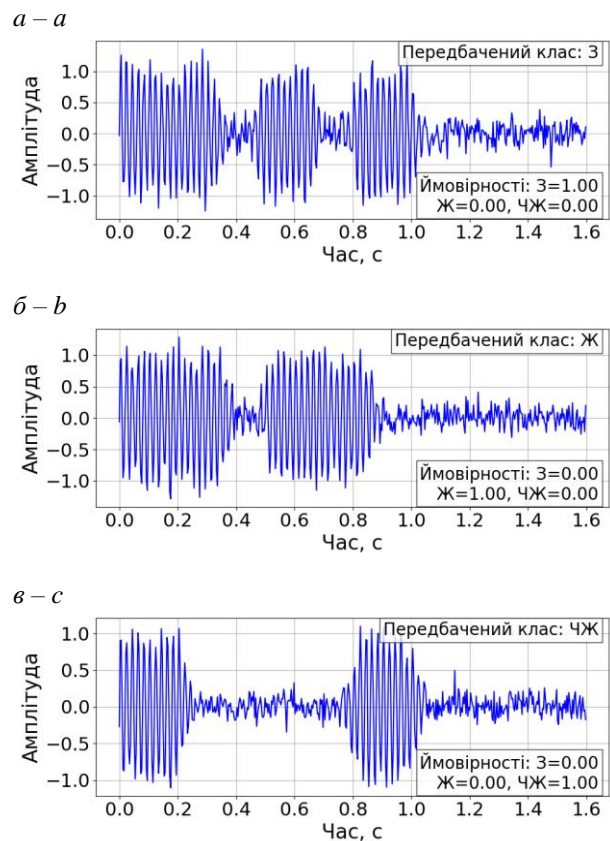


Рис. 3. Результати класифікації спотворених та «зашумлених» кодів «3» (а), «Ж» (б), «ЧЖ» (в) при відношенні сигнал/шум 10 дБ


Fig. 3. Classification results of distorted and «noisy» codes «Z» (a), «Zh» (b), «ChZh» (c) at a signal-to-noise ratio of 10 dB

В роботі також було виконано тестування згорткової нейронної мережі на реальних сигналах АЛСН. Для цього проведено вимірювання сигналів на живильному та релейному кінці у кодових рейкових колах змінного струму [16]. Для дослідження використовували цифровий USB-осцилограф Hantek 6254 VC, який має частотну смугу пропускання до 250 МГц, частоту дискретизації до 1 ГГц, вхідний імпеданс 1 МОм, вертикальну роздільну здатність 8 біт. В результаті вимірювань було отримано 30 записів сигналів з різними кодами АЛСН. З кожного запису виділяли масив значень, який відповідає одному кодовому циклу. Далі шляхом лінійної інтерполяції цей масив перетворювали на одновимірний вектор з 500 елементів, який використовувався для класифікації. В підсумку для всіх


## АВТОМАТИЗОВАНІ ТА ТЕЛЕМАТИЧНІ СИСТЕМИ НА ТРАНСПОРТІ

сигналів нейронна мережа безпомилково визначила класи кодів АЛСН. На рис. 5 як приклад показаний результат класифікації кодового сигналу «ЧЖ».

а – а



б – б



в – в




Рис. 4. Результати класифікації спотворених та «зашумлених» кодів «З» (а), «Ж» (б), «ЧЖ» (в) при відношенні сигнал/шум 0 дБ

Fig. 4. Classification results of distorted and «noisy» codes «Z» (a), «Zh» (b), «ChZh» (c) at a signal-to-noise ratio of 0 dB




Рис. 5. Результат класифікації реального кодового сигналу «ЧЖ»

Fig. 5. The result of classification of the real code signal «ChZh»

Таким чином, результати тестування запропонованої нейронної мережі на синтезованих та реальних даних підтверджують її здатність виконувати класифікацію кодів АЛСН, зокрема за наявності сильних завад та спотворень часових параметрів.

### Наукова новизна та практична значимість

Авторами цієї роботи вперше проведено комплексне дослідження ефективності різних типів штучних нейронних мереж для класифікації кодів автоматичної локомотивної сигналізації АЛСН в умовах інтенсивних завад та часових спотворень, що дозволило обґрунтувати вибір конфігурації одновимірної згорткової нейронної мережі та встановити залежності між параметрами моделі (кількістю шарів, фільтрів, нейронів) та точністю класифікації.

Впровадження цифрового локомотивного приймача сигналів АЛСН із класифікатором на базі запропонованої згорткової нейронної мережі замість застарілої релейної апаратури дозволить зменшити експлуатаційні витрати, підвищити завадостійкість та надійність системи АЛСН за рахунок стійкого розпізнавання кодів в умовах інтенсивних завад та спотворень часових параметрів кодових сигналів.

### Висновки

1. Однією з основних причин відмов системи автоматичної локомотивної сигналізації АЛСН є зношеність застарілої релейної апаратури. Збої в системі також можуть відбуватись через спотворення часових параметрів коду, намагніченість рейок, нестабільне живлення, вплив різноманітних завад, які діють в рейковій лінії.

2. Один із напрямків удосконалення локомотивної апаратури АЛСН пов'язаний із застосуванням штучної нейронної мережі для розпізнавання кодових сигналів. Рекурентні нейронні мережі мають зворотні зв'язки, що може призвести до втрати стійкості. У зв'язку із цим такі мережі не можна використовувати в системі АЛСН та інших системах, які забезпечують безпеку руху поїздів. Серед мереж прямого поширення найбільш придатною для класифікації кодів АЛСН є одновимірна згорткова мережа 1D–CNN, яка ефективно виявляє характерні часові ознаки сигналів, потребує менше даних для

## АВТОМАТИЗОВАНІ ТА ТЕЛЕМАТИЧНІ СИСТЕМИ НА ТРАНСПОРТІ

навчання, стійка до шумів, забезпечує стабільну класифікацію навіть при зсуві сигналу в часі.

3. В результаті дослідження залежності між параметрами моделі мережі 1D–CNN (кількістю шарів, фільтрів, нейронів) та точністю класифікації було встановлено, що для розпізнавання кодів АЛСН доцільно застосовувати наступну конфігурацію мережі: три згорткових шари, доповнені шарами Batch Normalization та Max Pooling 2, шар Dense з 16-ти нейронів та вихідний шар з трьох нейронів. Під час тестування на синтезованих та реальних даних запропонована нейронна мережа точно класифікувала коди АЛСН

навіть при дуже низькому відношенні сигнал/шум та сильному спотворенні форми сигналу.

4. Дана робота передбачає проведення подальших досліджень за наступними напрямками: дослідження спотворень часових параметрів кодів автоматичної локомотивної сигналізації та завад, що діють в рейковій лінії; проведення вимірювань кодів АЛСН та отримання великого масиву експериментальних даних для навчання нейронної мережі на реальних сигналах.

## СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Гололобова О. О., Буряк С. Ю., Гаврилюк В. І., Маркуль Р. В., Афанасов А. М., Білухін Д. С. Визначення причин порушень у роботі автоматичної локомотивної сигналізації. *Наука та прогрес транспорту*. 2021. № 6(96). С. 5–13. DOI: <https://doi.org/10.15802/stp2021/257914>
2. Гончаров К. В., Рибалка Р. В., Маловічко В. В. Підвищення ємності та завадостійкості каналу передачі даних в системі автоматичної локомотивної сигналізації. *Наука та прогрес транспорту*. 2025. № 4(112). С. 5–16. DOI: <https://doi.org/10.15802/stp2025/338389>
3. Машкіна І. В., Носенко Т. І., Мельник І. Ю. Застосування одновимірних згорткових нейронних мереж для ідентифікації слабких радіоактивних сигналів у системах динамічного моніторингу. *Кібербезпека : освіта, наука, техніка*. 2025. Том 3, № 31. С. 780–791. DOI: <https://doi.org/10.28925/2663-4023.2025.31.1074>
4. Наконечний М. В., Івахів О. В., Наконечний Ю. М. *Вступ до поглибленого навчання та нейромережеве керування* : навч. посіб. Львів : Видавництво Львівської політехніки, 2024. 354 с.
5. Сотник В. О., Бабаєв М. М., Чепцов М. М. Нейромережева модель розпізнавання тривалості імпульсів та інтервалів кодів АЛСН. *Збірник наукових праць ДонІЗТ*. 2013. № 36. С. 67–79.
6. Aggarwal C. C. *Neural Networks and Deep Learning* : textbook. Cham : Springer International Publishing, 2023. 553 p. DOI: <https://doi.org/10.1007/978-3-031-29642-0>
7. Ananieva O., Babaiev M., Blyndiuk V., Davidenko M. Development of a Device for the Optimal Reception of Signals Against the Background of an Additive Three-component Interference. *Eastern-European Journal of Enterprise Technologies*. 2019. Vol. 2, № 9(98). P. 6–13. DOI: <https://doi.org/10.15587/1729-4061.2019.159310>
8. Cai W., Zhu X., Bai K., Ye A., Zhang R. An explainable dual-mode convolutional neural network for multivariate time series classification. *Knowledge-Based Systems*. 2024. Vol. 299. Art. 112015. DOI: <https://doi.org/10.1016/j.knosys.2024.112015>
9. Chollet F., Watson M. *Deep Learning with Python*. Manning Publications Co, 2025. 648 p.
10. Havryliuk V. Detecting of Signal Distortions in Cab Signaling System Using ANFIS and WPESE. *2020 IEEE 4th International Conference on Intelligent Energy and Power Systems (IEPS)*. (Istanbul, 7–11 Sep. 2020). Istanbul, 2020. P. 231–236. DOI: <https://doi.org/10.1109/ieps51250.2020.9263165>
11. Havryliuk V. Investigation of the Influence of Traction Current Harmonics on Automatic Locomotive Signaling. *2025 IEEE International Conference on Environment and Electrical Engineering and 2025 IEEE Industrial and Commercial Power Systems Europe (EEEIC / I&CPS Europe)*. (Chania, July 2025). Chania, 2025. P. 1–6. DOI: <https://doi.org/10.1109/EEEIC/ICPSEurope64998.2025.11169221>
12. Hololobova O. O., Havryliuk V. I. Application of Fourier transform and Wavelet decomposition for decoding the continuous automatic locomotive signaling code. *Science and Transport Progress*. 2017. № 1(67). С. 7–17. DOI: <https://doi.org/10.15802/stp2017/92771>
13. Honcharov K. V., Rybalka R. V. Multi-Valued Automatic Cab Signaling System Based on the CDMA Technology. *Science and Transport Progress*. 2021. № 6(96). С. 14–21. DOI: <https://doi.org/10.15802/stp2021/258171>
14. Kiranyaz S., Avcı O., Abdeljaber O., Ince T., Gabbouj M., Inman D. J. 1D convolutional neural networks and applications : A survey. *Mechanical Systems and Signal Processing*. 2021. Vol. 151. Art. 107398. DOI: <https://doi.org/10.1016/j.ymsp.2020.107398>

15. Liu S., Yang S., Liu C., Liu T., Xiong Q. Research on Anti-interference Algorithm for Cab Signal Demodulation Based on Deep Learning. *2020 16th International Conference on Control, Automation, Robotics and Vision (ICARCV)*. (Shenzhen, 13 December 2020). Shenzhen, China. 2020. P. 248–254.  
DOI: <https://doi.org/10.1109/icarcv50220.2020.9305349>
16. Serdiuk T., Serchenko M., Profatylov V., Botnarevscaia R., Mandaris D., Smirnov A. Monitoring Electromagnetic Interference and Code Current in the Station Interlocking System. *IEEE 2025 Asia-Pacific International Symposium and Exhibition on Electromagnetic Compatibility (APEMC)*. (Taipei, 19 May 2025). Taipei, 2025. P. 156–159. DOI: <https://doi.org/10.1109/apemc62958.2025.11051974>
17. Taherkhani A., Cosm G., McGinnity T. M. A Deep Convolutional Neural Network for Time Series Classification with Intermediate Targets. *SN Computer Science*. 2023. Vol. 4, Iss. 6. Art. 832.  
DOI: <https://doi.org/10.1007/s42979-023-02159-4>
18. Theeg G., Vlasenko S. *Railway Signalling and Interlocking. International Compendium*. Hamburg : Eurailpress, 2009. 448 p.

K. V. HONCHAROV<sup>1\*</sup>, R. V. RYBALKA<sup>2\*</sup>, T. M. SERDIUK<sup>3\*</sup>

<sup>1\*</sup>Dep. «Automatics and Telecommunications», Ukrainian State University of Science and Technologies, SEI DIIT, Lazaryana St., 2, Dnipro, Ukraine, 49010, tel. +38 (056) 373 15 04, e-mail k.v.honcharov@ust.edu.ua, ORCID 0000-0002-0432-1077

<sup>2\*</sup>Dep. «Automatics and Telecommunications», Ukrainian State University of Science and Technologies, SEI DIIT, Lazaryana St., 2, Dnipro, Ukraine, 49010, tel. +38 (056) 373 15 04, e-mail r.v.rybalka@ust.edu.ua, ORCID 0000-0001-7444-0517

<sup>3\*</sup>Dep. «Automatics and Telecommunications», Ukrainian State University of Science and Technologies, SEI DIIT, Lazaryana St., 2, Dnipro, Ukraine, 49010, tel. +38 (056) 373 15 04, e-mail t.m.serdiuk@ust.diit.edu.ua, ORCID 0000-0002-2609-4071

## Application of Convolutional Neural Network for Classification of Automatic Cab Signalling Codes

**Purpose.** Justification the selection of architecture and hyperparameters for an artificial neural network designed to classify Automatic Cab Signalling (ALSN) code signals under conditions of intense interference and temporal distortion. **Methodology.** To achieve the purpose, a comparative analysis of different types of artificial neural networks was performed. It was found that for the classification of ALSN codes, a one-dimensional convolutional network (1D-CNN) is the most suitable, as it effectively detects the characteristic temporal features of signals, requires less data for training, is resistant to noise, and provides stable classification even with a signal shift in time. Calculations of the number of network parameters were performed based on its configuration, including the number of layers, convolutional filters, and the number of neurons in fully connected layers. For model training, synthetic data were generated by adding noise and stochastic timing variations to reference signals («Z», «Zh», and «ChZh»). 1000 implementations were synthesized for each ALSN code signal. The program code for data preparation, network training, and signal classification was written in Python using the TensorFlow, Keras, Scipy.signal, and NumPy libraries.

**Findings.** Based on the observed correlation between network configuration and recognition accuracy for the ALSN codes, an optimized model was selected featuring three convolutional layers, a 16-neuron Dense layer, and a 3-neuron output layer. The robustness of the proposed network was validated against both heavily distorted synthetic waveforms with low signal-to-noise ratios and empirical ALSN signals. **Originality.** This work represents the first comprehensive study of artificial neural networks efficacy for ALSN code classification under severe interference and temporal distortions. It justifies the specific 1D-CNN configuration and establishes the dependencies between model structural parameters (number of layers, filters, and neurons) and classification accuracy. **Practical value.** Replacing legacy relay-based equipment with the proposed 1D-CNN-based digital receiver will reduce operational expenditures while significantly enhancing the noise immunity and reliability of the ALSN system through stable code recognition in adverse settings, i.e. intensive noise and temporal parameters disturbances of the code signals.

**Keywords:** automatic cab signalling; time signatures of signals; interference immunity; distorting the time parameters of codes; convolutional neural network; ALSN code recognition; deep learning; classification accuracy

### REFERENCES

1. Hololobova, O. O., Buriak, S. Y., Havryliuk, V. I., R. V. Markul, R. V., Afanasov, A. M., & Bilukhin, D. S. (2021). Determination of the Origin of Failures in the Operation of the Automatic Locomotive Signaling. *Science and Transport Progress*, (6(96)), 5-13. DOI: <https://doi.org/10.15802/stp2021/257914> (in Ukrainian)

## АВТОМАТИЗОВАНІ ТА ТЕЛЕМАТИЧНІ СИСТЕМИ НА ТРАНСПОРТІ

2. Honcharov, K. V., Rybalka, R. V., & Malovichko, V. V. (2025). Increasing the Capacity and Interference Immunity of the Data Transmission Channel in the Automatic Cab Signalling System. *Science and Transport Progress*, 4(112), 5-16. DOI: <https://doi.org/10.15802/stp2025/338389> (in Ukrainian)
3. Mashkina, I., Nosenko, T., & Melnyk, I. (2025). Application of one-dimensional convulsive neural networks for identification of weak radioactive signals in dynamic monitoring systems. *Cybersecurity: Education, Science, Technique*, 3(31), 780-791. DOI <https://doi.org/10.28925/2663-4023.2025.31.1074> (in Ukrainian)
4. Nakonechnyi, M. V., Ivakhiv, O. V., & Nakonechnyi, Yu. M. (2024). *Vstup do pohlyblyenoho navchannia ta neiromerzheve keruvannia*. Lviv: Vydavnytstvo Lvivskoi politekhniki. (in Ukrainian)
5. Sotnyk, V. O., Babaiev, M. M., & Cheptsov, M. M. (2013). Neiromerzheva model rozpoznavannia tryvalosti impulsiv ta intervaliv kodiv ALSN. *Zbirnyk naukovykh prats DonIZT*, 36, 67-79. (in Ukrainian)
6. Aggarwal, C. C. (2023). *Neural Networks and Deep Learning*. Cham: Springer International Publishing. DOI: <https://doi.org/10.1007/978-3-031-29642-0> (in English)
7. Ananieva, O., Babaiev, M., Blyndiuk, V., & Davidenko, M. (2019). Development of a Device for the Optimal Reception of Signals Against the Background of an Additive Three-component Interference. *Eastern-European Journal of Enterprise Technologies*, 2(9(98)), 6-13. DOI: <https://doi.org/10.15587/1729-4061.2019.159310> (in English)
8. Cai, W., Zhu, X., Bai, K., Ye, A., & Zhang, R. (2024). An explainable dual-mode convolutional neural network for multivariate time series classification. *Knowledge-Based Systems*, 299, 112015. DOI: <https://doi.org/10.1016/j.knosys.2024.112015> (in English)
9. Chollet, F., & Watson, M. (2025). *Deep Learning with Python*. Manning Publications Co. (in English)
10. Havryliuk, V. (2020, September). Detecting of Signal Distortions in Cab Signalling System Using ANFIS and WPESE. In *2020 IEEE 4th International Conference on Intelligent Energy and Power Systems (IEPS)* (pp. 231-236), Istanbul, Turkey. DOI: <https://doi.org/10.1109/ieps51250.2020.9263165> (in English)
11. Havryliuk, V. (2025, July). Investigation of the Influence of Traction Current Harmonics on Automatic Locomotive Signaling. In *IEEE International Conference on Environment and Electrical Engineering and 2025 IEEE Industrial and Commercial Power Systems Europe (EEEIC / I&CPS Europe)* (pp. 1-6), Chania, Crete, Greece. DOI: <https://doi.org/10.1109/EEEIC/ICPSEurope64998.2025.11169221> (in English)
12. Hololobova, O. O., & Havryliuk, V. I. (2017). Application of Fourier transform and Wavelet decomposition for decoding the continuous automatic locomotive signaling code. *Science and Transport Progress*, 1(67), 7-17. DOI: <https://doi.org/10.15802/stp2017/92771> (in English)
13. Honcharov, K. V., & Rybalka, R. V. (2021). Multi-Valued Automatic Cab Signalling System Based on the CDMA Technology. *Science and Transport Progress*, 6(96), 14-21. DOI: <https://doi.org/10.15802/stp2021/258171> (in English)
14. Kiranyaz, S., Avci, O., & Abdeljaber, O. (2021). 1D convolutional neural networks and applications : A survey. *Mechanical Systems and Signal Processing*, 151, 107398. DOI: <https://doi.org/10.1016/j.ymsp.2020.107398> (in English)
15. Liu, S., Yang, S., Liu, C., Liu, T., & Xiong, Q. (2020, December). Research on Anti-interference Algorithm for Cab Signal Demodulation Based on Deep Learning. In *2020 16th International Conference on Control, Automation, Robotics and Vision (ICARCV)* (pp. 248-254). Shenzhen, China. DOI: <https://doi.org/10.1109/icarcv50220.2020.9305349> (in English)
16. Serdiuk, T., Serchenko, M., Profatylov, V., Botnarevscaia, R., Mandaris, D., & Smirnov, A. (2025, May). Monitoring Electromagnetic Interference and Code Current in the Station Interlocking System. In *IEEE 2025 Asia-Pacific International Symposium and Exhibition on Electromagnetic Compatibility (APEMC)* (pp. 156-159). Taipei, Taiwan. DOI: <https://doi.org/10.1109/apemc62958.2025.11051974> (in English)
17. Taherkhani, A., Cosm, G., & McGinnity, T. M. (2023). A Deep Convolutional Neural Network for Time Series Classification with Intermediate Targets. *SN Computer Science*, 4(6), 832. DOI: <https://doi.org/10.1007/s42979-023-02159-4> (in English)
18. Theeg, G., & Vlasenko, S. (2009). *Railway Signalling and Interlocking. International Compendium*. Hamburg: Eurailpress. (in English)

Надійшла до редколегії: 01.12.2025

Рекомендовано до публікації: 22.12.2025

Дата публікації: 27.03.2026