

Д.І. Скуріхін, А.О. Ловська, В.Г. Равлюк, А.В. Рибін, В.В. Бондаренко  
**ЗАСТОСУВАННЯ НЕЙРОННИХ МЕРЕЖ ДЛЯ АНАЛІЗУ СПЕКТРОГРАМ  
АКУСТИЧНИХ СИГНАЛІВ ВЗАЄМОДІЇ КОЛЕСА І РЕЙКИ**

*Анотація. У статті розглянуто застосування нейронних мереж для аналізу спектрограм акустичних сигналів взаємодії колеса і рейки з метою автоматизованого моніторингу технічного стану рухомого складу. Наведено результати експериментальних вимірювань акустичних сигналів під час проходження поїздів, виконано побудову та експертну розмітку спектрограм. Для автоматичної класифікації сигналів використано згорткову нейронну мережу на основі MobileNet. Проведене навчання моделі дозволило ідентифікувати характерні типи акустичних сигналів: ударну взаємодію колеса і рейки, шум кочення, аеродинамічний шум та скрегіт у кривих ділянках колії.*

*Проведене дослідження підтверджує ефективність застосування нейронних мереж для аналізу спектрограм акустичних сигналів, що генеруються під час взаємодії колеса та рейки. Запропонований підхід дозволяє автоматично ідентифікувати характерні акустичні події, пов'язані з різними умовами експлуатації залізничного рухомого складу. Отримані результати демонструють потенціал інтеграції методів машинного навчання в інтелектуальні інформаційно-вимірювальні системи для діагностики та моніторингу залізниць. Запропонований метод може сприяти підвищенню ефективності систем акустичного моніторингу та розробці технологій прогнозного обслуговування залізничних транспортних засобів.*

*Ключові слова: згорткова нейронна мережа, акустичний сигнал, MobileNet, акустичний моніторинг, залізничний транспортний засіб.*

**Постановка проблеми.** Сучасні інформаційно-вимірювальні системи моніторингу технічного стану транспортних об'єктів потребують ефективних методів обробки великих масивів вимірювальних даних. У сфері залізничного транспорту особливу актуальність має своєчасне виявлення дефектів колісних пар під час руху поїзда, оскільки такі пошкодження безпосередньо впливають на безпеку руху та надійність експлуатації рухомого складу. Одним із перспективних джерел діагностичної інформації є акустичні сигнали, що виникають у зоні контакту колесо–рейка. Традиційні методи аналізу таких сигналів базуються на спектральному аналізі, однак складна структура шуму та велика кількість зовнішніх факторів ускладнюють виділення інформативних ознак. Тому актуальним є застосування методів штучного інтелекту, зокрема нейронних мереж, для автоматизованого аналізу спектрограм акустичних сигналів у складі інформаційно-вимірювальних систем діагностики.

**Аналіз останніх досліджень і публікацій.** У сучасних дослідженнях технічного стану залізничного рухомого складу широко застосовуються методи вібраційної, акустичної та акустико-емісійної діагностики [1-3]. Значна увага приділяється аналізу сигналів взаємодії колесо–рейка, які містять інформацію про дефекти поверхні кочення коліс та інші несправності. У низці робіт показано ефективність використання спектрального аналізу, хвильових перетворень та статистичних параметрів сигналу для виділення діагностичних ознак [4-6]. Останніми роками активно досліджується застосування методів машинного навчання та глибоких нейронних мереж для автоматичної класифікації сигналів технічних систем, зокрема у задачах діагностики дефектів коліс та буксових вузлів [7-9]. Водночас питання використання спектрограм акустичних сигналів як вхідних даних для навчання нейронних мереж у задачах моніторингу технічного стану колісних пар залишається недостатньо дослідженим.

У попередній публікації авторів було здійснено аналітичне узагальнення сучасних цифрових технологій, що застосовуються на різних етапах життєвого циклу залізничного рухомого складу - від проектування до утилізації [11]. У цій роботі систематизовано використання PLM-, CAD/CAE-, MES-, ERP-, RFID/Barcode-, IoT-, blockchain-рішень, цифрових двійників, телематики, big data та AI-інструментів, а також показано їх місце в єдиному цифровому середовищі керування історією вагона. Особливу увагу було приділено тому, що на етапі технічного обслуговування перспективними є підходи predictive maintenance, смарт-контракти та цифрові записи сервісної історії, а серед подальших напрямів окремо виділено AI у технічному обслуговуванні, стандартизацію управління даними та локалізацію цифрових рішень для умов вагонобудування країн з перехідною економікою. Таким чином, попередня стаття сформувала загальну концептуальну рамку та показала, що інтегроване цифрове управління життєвим циклом рухомого складу є необхідною умовою підвищення ефективності, безпеки та простежуваності технічного стану вагонів.

**Метою дослідження** є розробка підходу до обробки акустичних сигналів взаємодії колесо-рейка на основі нейронних мереж для автоматизованої ідентифікації характерних режимів роботи рухомого складу. Для досягнення цієї мети запропоновано використовувати спектрограми акустичних сигналів як інформативні ознаки для навчання моделі машинного навчання. Передбачається сформувати набір спектрограм, що відповідають різним режимам взаємодії колеса з рейкою, зокрема коченню колеса по рейці, гальмуванню, ударній взаємодії та скреготу в кривих ділянках колії. На основі сформованого набору даних здійснюється навчання нейронної мережі для подальшої класифікації сигналів. Отримані результати можуть бути використані при створенні інтелектуальних інформаційно-вимірювальних систем моніторингу технічного стану залізничного рухомого складу.

**Викладення основного матеріалу дослідження.** З метою формування достовірної вибірки акустичних сигналів, що надалі використовується для навчання нейронної мережі, необхідно забезпечити коректність та відтворюваність процесу вимірювання. У

зв'язку з цим у роботі наведено технічні характеристики вимірювального приладу, параметри реєстрації сигналу та умови проведення експериментальних вимірювань.

Технічні характеристики вимірювального приладу:

- робочий частотний діапазон 30Гц – 20кГц;
- частотна характеристика (рис. 1);
- чутливість мікрофона +7 – +47дБ;
- розрядність процесора 24біт;
- частота дискретизації 96кГц;
- вітрозахист в комплекті;
- карта пам'яті SD, USB-інтерфейс.

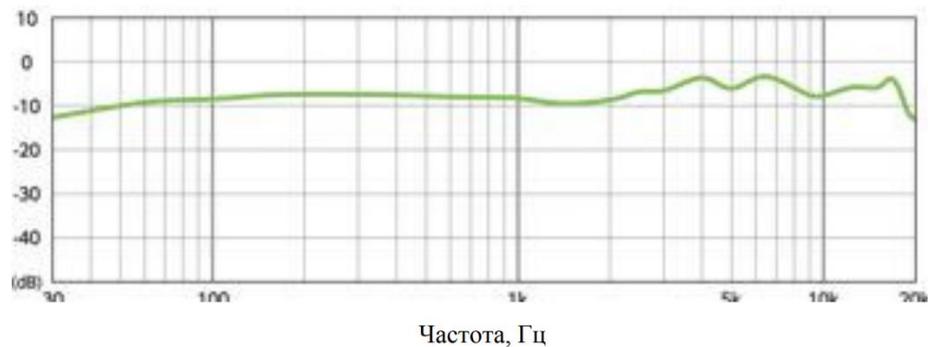


Рисунок 1 - Частотна характеристика вимірювального приладу



Рисунок 2 - Розташування звукозаписного приладу під час дослідження

Під час дослідження дотримані наступні вимоги щодо умов вимірів:

- в колі радіусом 50 м не повинно бути великих предметів, які відбивають звук (пагорбів, мостів, будинків);
- поблизу мікрофона не повинно бути предметів, які можуть порушити вільне звукове поле;

- застосування вітрозахисного пристрою при швидкості вітру більш 5м/с виміру не проводять.

- рейки типу Р65, щебеневий баласт, залізобетонні шпали;

- середні: швидкість вітру – 4м/с, температура повітря - 34°С, атмосферний тиск – 744 мм.рт.ст.

Експеримент проведений з наступними видами рухомого складу (табл. 1). Для підвищення достовірності вимірів запис проведений по двом каналам приладу.

Таблиця 1

Вибірка рухомого складу залізниць

Тип рухомого складу	Загальна кількість, од.	Діапазон швидкостей, км/год
Пасажирські вагони	204	18-80
Вантажні вагони	282	5-74
Вагони електропоїздів	38	35-60

Дотримання визначених вимог до умов експерименту забезпечує формування репрезентативної бази акустичних записів, що відображає реальні процеси взаємодії колеса і рейки під час руху поїзда. Отримані експериментальні дані у подальшому використовуються для побудови спектрограм та формування навчальної вибірки для нейронної мережі. Частина даних була використана з попереднього дослідження авторів [12].

На основі експертного аналізу спектрограм було виконано ручну розмітку акустичних сигналів, що дозволило виділити інформативні діагностичні ознаки різних джерел шуму (шум кочення, писк у кривій, аеродинамічний шум тощо). Отримані області спектру можуть бути використані як навчальна вибірка для алгоритмів машинного навчання.

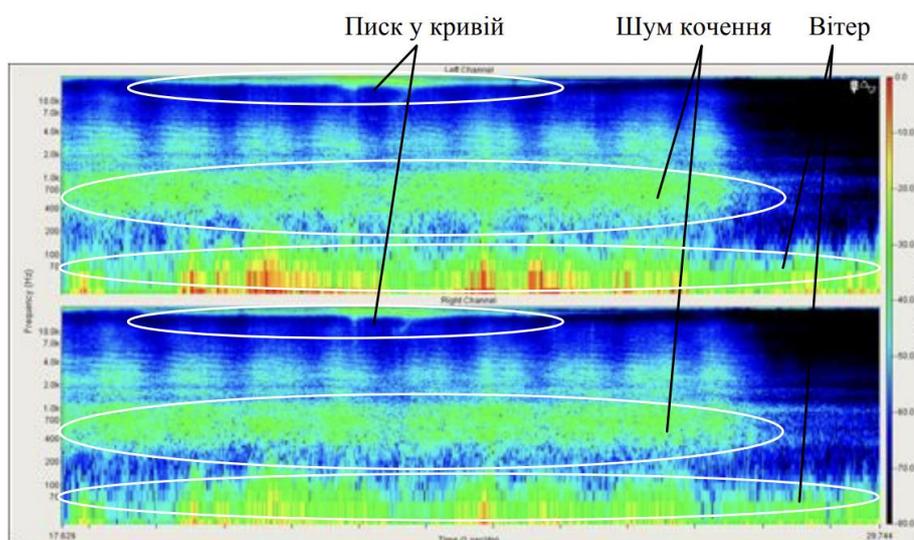


Рисунок 3 - Експертна розмітка спектрограми з виділенням частотних областей джерел акустичних сигналів

Визначення таких характерних патернів дозволяє сформувати набір інформативних ознак спектрограм, які можуть бути використані для подальшої автоматичної класифікації акустичних сигналів. На основі проведеного аналізу було систематизовано типові ознаки спектрограм та відповідні їм події або джерела шуму, що наведено у таблиці 2. Представлені ознаки використовуються як діагностичні критерії при формуванні навчальної вибірки для алгоритмів машинного навчання.

Таблиця 2

Виділення інформативних ознак

Ознака спектрограми	Подія
горизонтальна вузька смуга 2–8 kHz	писк у кривій
широкий шум 100–1000 Hz	шум кочення
хаотичний сигнал <200 Hz	вітер
широкий шум 500–2000 Hz	тертя гальм
гармоніки 2–6 kHz	писк гальм
імпульсний шум 1–10 kHz	випуск повітря
вертикальні імпульси	удар колесо–рейка
часті імпульси 1–6 kHz	скрегіт
гармоніки 3–10 kHz	свист
гармоніки 1–3 kHz	гудок

Для автоматичної класифікації спектрограм шумів рухомого складу була використана модель згорткової нейронної мережі, навчена за допомогою платформи Teachable Machine.

Модель навчалась розпізнавати характерні типи акустичних сигналів:

- ударна взаємодія колеса і рейки;
- шум кочення;
- аеродинамічний шум (вітер);
- скрегіт у кривих ділянках колії.

Для підготовки даних до навчання спектрограми було розділено на квадратні фрагменти однакового розміру (рис. 4). Це дозволяє перетворити безперервний акустичний сигнал на набір стандартизованих зображень, що містять локальні часово-частотні ознаки та можуть використовуватись як навчальні приклади для класифікації нейронною мережею.

Архітектура моделі базується на попередньо навчений CNN-екстрактор ознак типу MobileNet, який використовується для автоматичного виділення просторово-частотних патернів спектрограм. На основі отриманого вектора ознак формується класифікаційний шар, що визначає ймовірність належності сигналу до відповідного класу. Навчання моделі виконується шляхом мінімізації функції втрат крос-ентропії з використанням алгоритму градієнтного спуску.

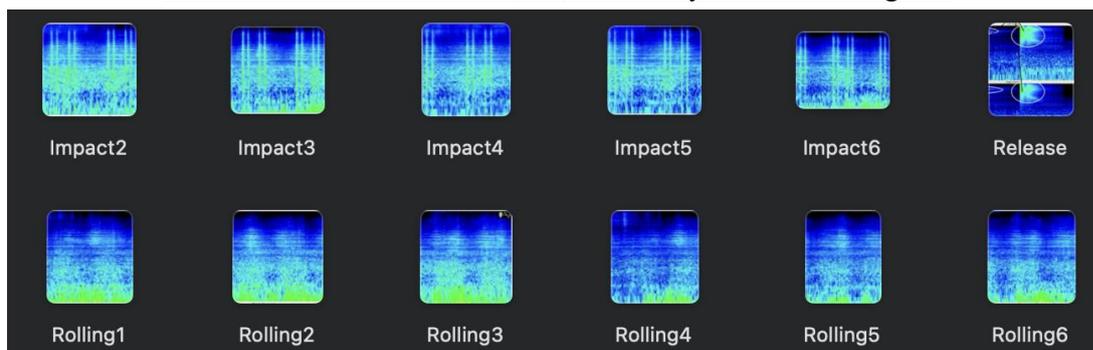


Рисунок 4 - Підготовка спектрограми до тренування нейронної мережі

Нижче наведено математичний опис, застосованої нейронної мережі.

1. Вхідні дані (спектрограма)

Спектрограма подається у вигляді зображення:

$$X \in \mathbb{R}^{H \times W \times C} \quad (1)$$

де  $H$  - висота (частотні бінни)

$W$  - ширина (часові фрейми)

$C$  - кількість каналів (RGB).

2. Згорткова нейронна мережа (CNN)

Основна операція - згортка:

$$Y_{i,j,k} = \sum_{m=0}^{M-1} \sum_{n=0}^{N-1} \sum_{c=0}^{C-1} X_{i+m,j+n,c} \times W_{m,n,c,k} + b_k \quad (2)$$

де  $X$  - вхідна матриця

$W$  - ядро згортки

$b_k$  - зміщення

$k$  - номер фільтра.

Ця операція дозволяє виділяти локальні патерни спектрограми.

3. Функція активації

Після згортки застосовується ReLU:

$$f(x) = \max(0, x) \quad (3)$$

Це додає нелінійність моделі.

4. Pooling

Для зменшення розмірності використовується max pooling:

$$y_{i,j} = \max_{(m,n) \in R} X_{i+m,j+n} \quad (4)$$

де  $R$  — область pooling.

5. Формування вектора ознак

Після проходження кількох CNN-блоків отримується вектор ознак:

$$z = \phi(X) \quad (5)$$

6. Класифікаційний шар

Фінальний шар - повнозв'язна мережа:

$$y = Wz + b \quad (6)$$

Де  $z$  - вектор ознак

$W$  - матриця ваг

$b$  - зміщення

### 7. Softmax

Ймовірність належності до класу:

$$P(y_i) = \frac{e^{z_i}}{\sum_{k=1}^K e^{z_k}} \quad (7)$$

де  $K$  - кількість класів.

### 8. Функція втрат

Навчання виконується мінімізацією cross-entropy loss:

$$L = -\sum_{i=1}^K y_i \log(\hat{y}_i) \quad (8)$$

### 9. Оновлення ваг

Параметри моделі оптимізуються методом градієнтного спуску:

$$\theta_{t+1} = \theta_t - \eta \nabla_{\theta} L \quad (9)$$

де  $\eta$  - learning rate.

На рисунку 5 представлено процес навчання нейронної мережі у середовищі Teachable Machine. Для формування навчального набору даних було створено кілька класів сигналів, що відповідають різним джерелам шуму: ударна взаємодія колеса з рейкою (Impact), шум вітру (Wind), шум кочення коліс по рейці (Rolling), а також скрегіт у кривих ділянках колії (Screech). Кожен клас містив набір спектрограм, сформованих із експериментальних акустичних записів, отриманих під час проходження поїзда.

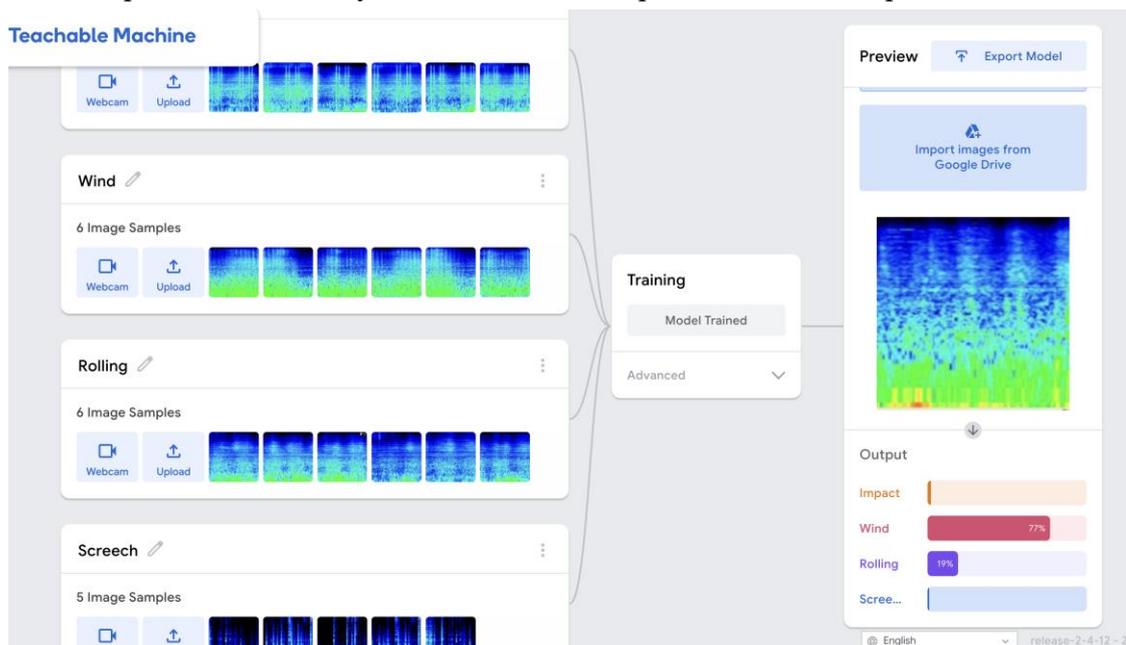


Рисунок 5 – Результат роботи моделі по розпізнаванню спектрограми вітру

Після формування навчальної вибірки було виконано навчання нейронної мережі для задачі класифікації спектрограм. У правій частині рисунка наведено результат тестування моделі на новому зразку спектрограми, що містить переважно акустичний сигнал вітру, а також компоненти шуму кочення. Модель визначила найбільш ймовірний клас Wind з імовірністю 77 %, тоді як імовірність належності сигналу до класу Rolling становила 19 %, що відповідає фактичній структурі сигналу, де присутні як аеродинамічний шум, так і фоновий шум руху поїзда.

На рисунку 6 видно, що модель визначила клас Impact з імовірністю 92 %, тоді як імовірність належності сигналу до класів Wind, Rolling та Screech була незначною і не перевищувала кількох відсотків. Такий розподіл імовірностей свідчить про чітку ідентифікацію характерних ознак ударної взаємодії колеса та рейки

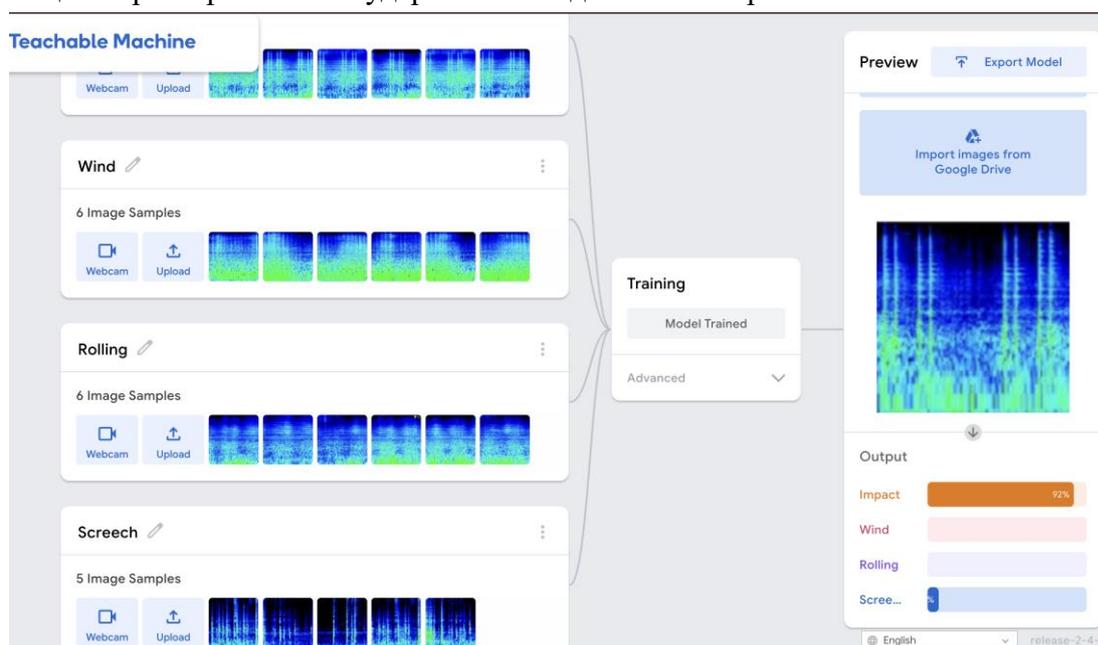


Рисунок 6 – Результат роботи моделі по розпізнаванню спектрограми ударної взаємодії колеса з рейкою

Високе значення ймовірності для класу Impact 92 % свідчить про достатню якість навчання моделі та її здатність впевнено виділяти інформативні ознаки ударної взаємодії серед інших типів акустичних сигналів. Таким чином, для даного тестового зразка модель продемонструвала коректну роботу та правильну класифікацію спектрограми, що підтверджує ефективність використаного підходу для автоматизованого розпізнавання імпульсних акустичних подій у системі моніторингу рухомого складу.

На рисунку 7 також наведено результат тестування моделі на іншому зразку спектрограми, що відповідає переважно шуму кочення коліс по рейці. Як видно з результатів класифікації, нейронна мережа визначила найбільш ймовірний клас Rolling з імовірністю 83 %, тоді як імовірність належності сигналу до класу Wind становить лише 11 %, а до класу Impact — незначну частку. Аналіз спектрограми показує характерний розподіл енергії сигналу в середньому та високочастотному діапазонах, що є типовим для шуму кочення рухомого складу під час стабільного руху поїзда.

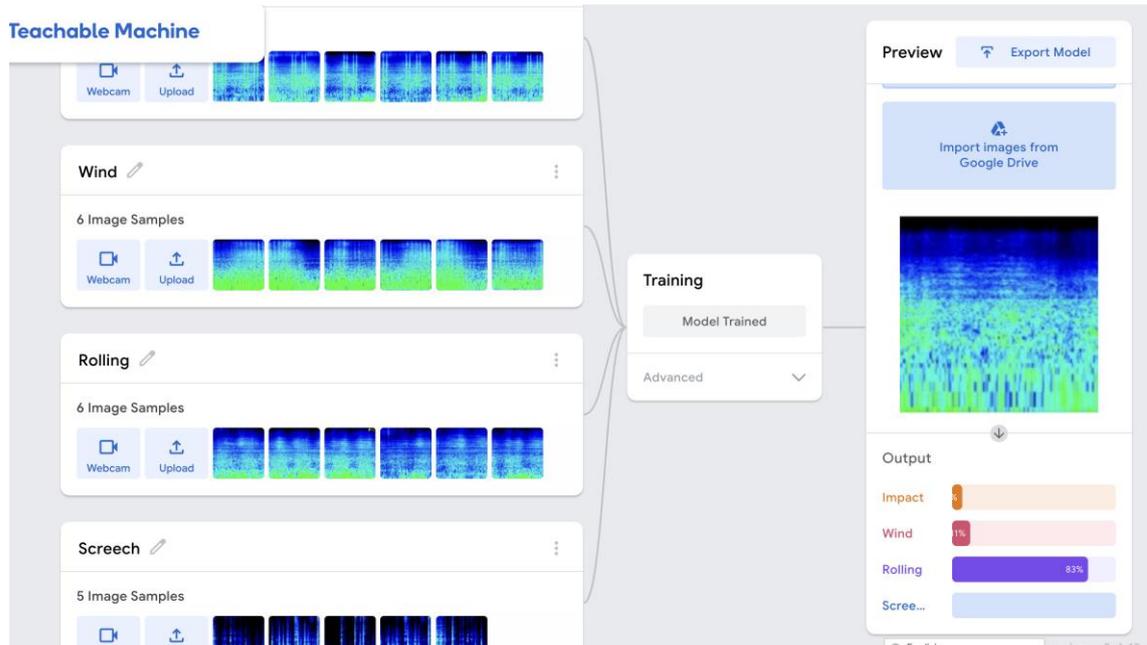


Рисунок 7 – Результат роботи моделі по розпізнаванню спектрограми шуму кочення

На тестовому зразку (рис. 8) спостерігається характерна структура сигналу у вигляді численних вертикальних смуг підвищеної інтенсивності в широкому діапазоні частот, що відповідає високочастотним коливанням, типовим для процесів тертя колеса об рейку у кривих ділянках колії.

Результати класифікації показали, що модель визначила найбільш ймовірний клас Screech з імовірністю 99 %, тоді як ймовірності належності сигналу до інших класів (Impact, Wind, Rolling) є мінімальними. Такий результат свідчить про коректне розпізнавання характерних ознак сигналу та високу впевненість моделі у правильності класифікації.

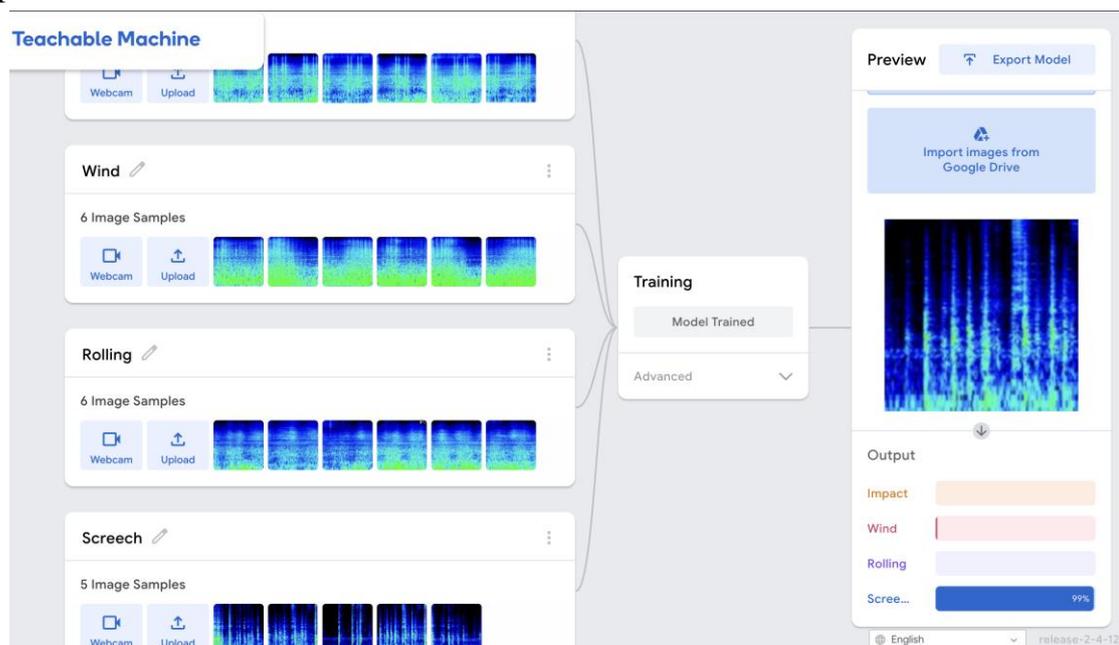


Рисунок 8 – Результат роботи моделі по розпізнаванню спектрограми скрегіту у кривій малого радіусу

Отримані результати підтверджують здатність нейронної мережі розрізняти різні джерела акустичних сигналів навіть за обмеженої кількості навчальних прикладів. У даному випадку модель коректно визначила домінуючий тип акустичного процесу, що відповідає реальним умовам експлуатації рухомого складу. Це свідчить про можливість застосування подібних підходів у системах акустичного моніторингу для автоматичного розпізнавання режимів взаємодії колеса та рейки.

Таким чином, використання спектрограм акустичних сигналів у поєднанні з методами машинного навчання дозволяє підвищити ефективність обробки вимірювальної інформації та створює передумови для побудови інтелектуальних інформаційно-вимірювальних систем діагностики технічного стану колісних пар залізничного рухомого складу.

**Висновки.** У роботі запропоновано підхід до обробки акустичних сигналів взаємодії колеса і рейки на основі нейронних мереж. Експериментальні вимірювання виконано під час проходження 204 пасажирських, 282 вантажних вагонів та 38 вагонів електропоїздів у діапазоні швидкостей 5–80 км/год. На основі отриманих акустичних записів побудовано спектрограми та виконано їх експертну розмітку, що дозволило сформувати навчальну вибірку для моделі машинного навчання. Для класифікації сигналів використано згорткову нейронну мережу на базі MobileNet. Результати тестування показали, що модель розпізнає характерні акустичні події з імовірністю до 99 %, що підтверджує ефективність застосування нейронних мереж у системах акустичного моніторингу технічного стану рухомого складу.

**Подяка.** Дане дослідження проведено в рамках науково-дослідної роботи “Підвищення безпеки руху залізничного рухомого складу шляхом впровадження інтегрованих технологій підтримки життєвого циклу” (№ДР 0125U001907), яка виконується за рахунок коштів державного бюджету України з 2025 р.

#### ЛІТЕРАТУРА

1. Molodova, M., Li, Z., Dollevoet, R. *Axle box acceleration: Measurement and simulation for detection of short track defects*. Mechanical Systems and Signal Processing, 2014. <https://doi.org/10.1016/j.ymssp.2013.10.011>
2. Zhang, W., Li, Z., Dollevoet, R. *Rail defect detection using axle box acceleration measurements*. Mechanical Systems and Signal Processing, 2018. <https://doi.org/10.1016/j.ymssp.2017.10.020>
3. Li, Z., Molodova, M., Núñez, A. *Condition monitoring of railway infrastructure and vehicles based on vibration measurements*. Sensors, 2020. <https://doi.org/10.3390/s20051472>
4. Antoni, J. *The spectral kurtosis: A useful tool for characterising non-stationary signals*. Mechanical Systems and Signal Processing, 2006. <https://doi.org/10.1016/j.ymssp.2004.09.001>
5. Randall, R., Antoni, J. *Rolling element bearing diagnostics — A tutorial*. Mechanical Systems and Signal Processing, 2011. <https://doi.org/10.1016/j.ymssp.2010.07.017>
6. Zhao, R., Yan, R., Chen, Z., Mao, K., Wang, P., Gao, R. *Deep learning and its applications to machine health monitoring*. Mechanical Systems and Signal Processing, 2017. <https://doi.org/10.1016/j.ymssp.2016.11.030>

7. Lei, Y., Li, N., Guo, L., Li, N., Yan, T., Lin, J. *Machinery health prognostics: A systematic review*. Mechanical Systems and Signal Processing, 2020.  
<https://doi.org/10.1016/j.ymssp.2019.106587>
8. Zhang, Y., Qin, Y., Mao, Y. *Deep learning for intelligent fault diagnosis in mechanical systems*. IEEE Transactions on Industrial Electronics, 2021.  
<https://doi.org/10.1109/TIE.2020.2972442>
9. Peng, Z., Chu, F. *Application of wavelet transform in machine condition monitoring*. Mechanical Systems and Signal Processing, 2004.  
<https://doi.org/10.1016/j.ymssp.2003.09.007>
10. Jia, F., Lei, Y., Lin, J., Zhou, X., Lu, N. *Deep neural networks: A promising tool for fault characteristic mining*. Mechanical Systems and Signal Processing, 2016.  
<https://doi.org/10.1016/j.ymssp.2015.10.025>
11. Скуріхін Д. І., Ловська А. О., Равлюк В. Г., Рибін А. В. Цифрові технології підтримки життєвого циклу залізничного рухомого складу: аналітика та вектори розвитку. Розвиток транспорту. 2025. № 3(26). С. 113–125. DOI: <https://doi.org/10.33082/td.2025.3-26.08>.
12. Bondarenko V. V., Skurikhin D. I., Vizniak R. I., Ravlyuk V. H., Skurikhin V. I. Experimental study of the method and device for wheel-sets acoustic monitoring of railway cars in motion. *Naukovyi Visnyk Natsionalnoho Hirnychoho Universytetu*. 2019. № 4. С. 30–37.  
<https://doi.org/10.29202/nvngu/2019-4/7>.

#### REFERECES

1. Molodova, M., Li, Z., Dollevoet, R. Axle box acceleration: Measurement and simulation for detection of short track defects. *Mechanical Systems and Signal Processing*, 2014.  
<https://doi.org/10.1016/j.ymssp.2013.10.011>
2. Zhang, W., Li, Z., Dollevoet, R. Rail defect detection using axle box acceleration measurements. *Mechanical Systems and Signal Processing*, 2018.  
<https://doi.org/10.1016/j.ymssp.2017.10.020>
3. Li, Z., Molodova, M., Núñez, A. Condition monitoring of railway infrastructure and vehicles based on vibration measurements. *Sensors*, 2020. <https://doi.org/10.3390/s20051472>
4. Antoni, J. The spectral kurtosis: A useful tool for characterising non-stationary signals. *Mechanical Systems and Signal Processing*, 2006.  
<https://doi.org/10.1016/j.ymssp.2004.09.001>
5. Randall, R., Antoni, J. Rolling element bearing diagnostics — A tutorial. *Mechanical Systems and Signal Processing*, 2011. <https://doi.org/10.1016/j.ymssp.2010.07.017>
6. Zhao, R., Yan, R., Chen, Z., Mao, K., Wang, P., Gao, R. Deep learning and its applications to machine health monitoring. *Mechanical Systems and Signal Processing*, 2017.  
<https://doi.org/10.1016/j.ymssp.2016.11.030>
7. Lei, Y., Li, N., Guo, L., Li, N., Yan, T., Lin, J. *Machinery health prognostics: A systematic review*. Mechanical Systems and Signal Processing, 2020.  
<https://doi.org/10.1016/j.ymssp.2019.106587>
8. Zhang, Y., Qin, Y., Mao, Y. Deep learning for intelligent fault diagnosis in mechanical systems. *IEEE Transactions on Industrial Electronics*, 2021.  
<https://doi.org/10.1109/TIE.2020.2972442>

9. Peng, Z., Chu, F. Application of wavelet transform in machine condition monitoring. *Mechanical Systems and Signal Processing*, 2004. <https://doi.org/10.1016/j.ymssp.2003.09.007>
10. Jia, F., Lei, Y., Lin, J., Zhou, X., Lu, N. Deep neural networks: A promising tool for fault characteristic mining. *Mechanical Systems and Signal Processing*, 2016. <https://doi.org/10.1016/j.ymssp.2015.10.025>
11. Skurikhin D. I., Lovska A. O., Ravliuk V. H., Rybin A. V. Tsyfrovi tekhnolohii pidtrymky zhyttievoho tsykladu zaliznychnoho rukhomoho skladu: analityka ta vek-tory rozvytku. *Rozvytok transportu*. 2025. № 3(26). S. 113–125. DOI: <https://doi.org/10.33082/td.2025.3-26.08>.
12. Bondarenko V. V., Skurikhin D. I., Vizniak R. I., Ravlyuk V. H., Skurikhin V. I. Experimental study of the method and device for wheel-sets acoustic monitoring of railway cars in motion. *Naukovyi Visnyk Natsionalnoho Hirnychoho Universytetu*. 2019. № 4. S. 30–37. <https://doi.org/10.29202/nvngu/2019-4/7>.

Received 26.03.2026  
Accepted 27.03.2026  
Published 31.03.2026

### ***Application of neural networks for spectrogram analysis of acoustic signals of wheel-rail interaction***

*Analysis of recent research and publications. Modern information-measuring systems for monitoring the technical condition of transport objects require effective methods for processing large volumes of measurement data. In railway engineering, particular attention is paid to the timely detection of defects in wheelsets during train operation, since such defects directly affect traffic safety and the reliability of rolling stock. Various methods of vibration, acoustic and acoustic-emission diagnostics are widely used in modern studies of railway vehicle condition monitoring. Researchers have demonstrated the effectiveness of spectral analysis, wavelet transforms and statistical signal processing for identifying diagnostic features of mechanical systems. Recently, machine learning and deep neural networks have been increasingly applied to automatic classification of signals and fault detection in technical systems. However, the use of spectrograms of acoustic signals as input data for neural networks in the tasks of monitoring wheel–rail interaction remains insufficiently investigated.*

*Purpose of the research. The purpose of this study is to develop an approach for processing acoustic signals of wheel–rail interaction using neural networks for automated identification of characteristic operating modes of railway rolling stock. The approach is based on the use of spectrograms of acoustic signals as informative features for training a machine learning model capable of classifying different types of acoustic events.*

*Presentation of the main research material. Experimental acoustic measurements were performed during the passage of railway rolling stock under real operating conditions. The study included recordings from passenger wagons, freight wagons and electric train cars at different speed ranges. The measurements were conducted using a digital recording device with a frequency range of 30 Hz–20 kHz and a sampling frequency of 96 kHz. To ensure reliable results, the measurement conditions were controlled to minimize external acoustic interference.*

*Based on the obtained recordings, spectrograms of acoustic signals were constructed and analyzed. Expert analysis and manual labeling of spectrograms allowed identification of characteristic patterns corresponding to different noise sources such as rolling noise, aerodynamic noise, braking friction, wheel–rail impacts and squeal in curved track sections. These patterns were used to form a labeled dataset for training a convolutional neural network.*

*For automatic classification of acoustic events, a convolutional neural network architecture based on a pre-trained MobileNet feature extractor was used. Spectrograms were divided into equal square fragments, which allowed the continuous acoustic signal to be transformed into a standardized set of images containing local time-frequency features. The trained model was able to classify four main types of acoustic signals: wheel–rail impact, rolling noise, aerodynamic noise and curve squeal. Experimental results demonstrated that the neural network successfully identified characteristic patterns of acoustic signals with high classification probability.*

*Conclusions. The conducted study confirms the effectiveness of applying neural networks for the analysis of spectrograms of acoustic signals generated during wheel–rail interaction. The proposed approach allows automatic identification of characteristic acoustic events associated with different operating conditions of railway rolling stock. The obtained results demonstrate the potential of integrating machine learning methods into intelligent information-measuring systems for railway diagnostics and monitoring. The proposed method can contribute to improving the efficiency of acoustic monitoring systems and to the development of predictive maintenance technologies for railway vehicles.*

**Скуріхін Дмитро Ігорович** - доцент кафедри інженерії вагонів та якості продукції Українського державного університету залізничного транспорту.

ORCID: <https://orcid.org/0000-0002-3746-5157>

**Ловська Альона Олександрівна** - професор кафедри інженерії вагонів та якості продукції Українського державного університету залізничного транспорту.

ORCID: <https://orcid.org/0000-0002-8604-1764>

**Равлюк - Василь Григорович** професор кафедри інженерії вагонів та якості продукції Українського державного університету залізничного транспорту.

ORCID: <https://orcid.org/0000-0003-4818-9482>

**Рибін Андрій Вікторович** - доцент кафедри інженерії вагонів та якості продукції Українського державного університету залізничного транспорту.

ORCID: <https://orcid.org/0000-0003-4430-8018>

**Бондаренко - В'ячеслав Володимирович** доцент кафедри інженерії вагонів та якості продукції Українського державного університету залізничного транспорту.

ORCID: <https://orcid.org/0000-0003-4019-4017>

**Skurikhin Dmytro**– Associate Professor of the Department of Wagon Engineering and Product Quality, Ukrainian State University of Railway Transport.

ORCID: <https://orcid.org/0000-0002-3746-5157>

**Lovska Alona**– Professor of the Department of Wagon Engineering and Product Quality, Ukrainian State University of Railway Transport.

ORCID: <https://orcid.org/0000-0002-8604-1764>

**Ravlyuk Vasyl**– Professor of the Department of Wagon Engineering and Product Quality, Ukrainian State University of Railway Transport.

ORCID: <https://orcid.org/0000-0003-4818-9482>

**Rybin Andrii**– Associate Professor of the Department of Wagon Engineering and Product Quality, Ukrainian State University of Railway Transport.

ORCID: <https://orcid.org/0000-0003-4430-8018>

**Bondarenko Viacheslav**– Associate Professor of the Department of Wagon Engineering and Product Quality, Ukrainian State University of Railway Transport.

ORCID: <https://orcid.org/0000-0003-4019-4017>