

## АВТОМАТИЗАЦІЯ ТА КОМП'ЮТЕРНО-ІНТЕГРОВАНІ ТЕХНОЛОГІЇ

УДК 681.5.004.8

DOI: [https://doi.org/10.32515/2664-262X.2024.10\(41\).2.142-151](https://doi.org/10.32515/2664-262X.2024.10(41).2.142-151)**С.Г. Ковальов**, докторант, канд. пед. наук, **В.В. Аулін**, проф., д-р техн. наук,**А.В. Гриньків**, ст. дослід., канд. техн. наук*Центральноукраїнський національний технічний університет, м. Кропивницький, Україна**e-mail: aulinvv@gmail.com, kovalyovserggr@ukr.net***В.В. Варваров**, канд. техн. наук*Харківський нац. ун-т повітряних сил імені Івана Кожедуба, м. Харків, Україна**e-mail: varvarov\_@ukr.net*

### Підвищення надійності та ефективності експлуатації виробничих ліній методами штучного інтелекту, використовуючи моніторинг акустичних сигналів

У статті розглянуто підвищення надійності та ефективності виробничих процесів шляхом зменшення витрат на обслуговування та мінімізації простоїв. Пропонується метод оптимізації технічного обслуговування за допомогою алгоритмів штучного інтелекту. Досліджується кореляція між акустичними спектрами вузлів обладнання та їх надійністю та ефективністю. Запропоновано використовувати конволюційні мережі для розпізнавання патернів роботи обладнання через двовимірне відображення акустичних спектрів. Дослідження підтверджує зв'язок між параметрами надійності функціонування та ефективності використання обладнання та їхніми акустичними спектрами.

**надійність функціонування, ефективність експлуатації, автоматизовані виробничі лінії, акустичний спектр, машинне навчання, конволюційні мережі**

**Постановка проблеми.** Акустичні методи є потужним інструментом для моніторингу стану виробничих ліній, оскільки багато вузлів обладнання створюють не випадкові звуки, а саме характеристичні акустичні спектри. Ці спектри відображають конкретні механічні процеси та стан вузлів. Завдяки використанню акустичних методів можна виявляти відхилення від норми та прогнозувати можливі збої, що дозволяє своєчасно здійснювати технічне обслуговування та ремонт, забезпечуючи безперебійну роботу виробничого обладнання та підвищуючи ефективність його використання.

Розвиток штучного інтелекту (ШІ) відкрив нові горизонти в аналізі параметрів, що корелюються з надійністю та ефективністю виробничого обладнання. Завдяки передовим алгоритмам і методам машинного навчання, ШІ здатен виявляти та аналізувати складні взаємозв'язки між різними експлуатаційними параметрами обладнання. Це дозволяє не лише вимірювати ці параметри з високою точністю, але й використовувати отримані дані для вдосконалення та оптимізації роботи виробничих ліній. Застосування ШІ у виробничих процесах сприяє своєчасному виявленню можливих проблем та їхньому усуненню, що підвищує загальну надійність функціонування та ефективність використання обладнання.

Звук є важливим явищем, яке може бути виміряне та проаналізоване за допомогою ШІ у контексті роботи виробничої лінії. Методи спектрального акустичного аналізу дозволяють отримувати інформацію про стан обладнання виробничих ліній на основі характеристичних звукових спектрів, що створюються в тому числі і обертовими вузлами та підшипниками.

Аналізуючи ці спектри, ШІ може ідентифікувати відхилення, які вказують на потенційні проблеми з надійністю або ефективністю роботи обладнання. Це надає можливість здійснювати превентивне технічне обслуговування та оптимізувати роботу виробничих ліній на основі реальних даних, що значно знижує ризик простоїв і збільшує продуктивність.

Дослідження, пов'язані з використанням ШІ для виявлення параметрів, що корелюються з надійністю та ефективністю виробничого обладнання, невпинно зростають. Сучасні алгоритми ШІ та методи машинного навчання відкривають нові можливості для аналізу та оптимізації роботи виробничих ліній. Виявлення і моніторинг акустичних сигналів, дозволяють з високою точністю визначати стан обладнання та прогнозувати потенційні відмови. Це забезпечує можливість своєчасного технічного обслуговування, зменшуючи ризик простоїв та знижуючи витрати на експлуатацію. Таким чином, впровадження ШІ у виробничі процеси сприяє підвищенню їх надійності та ефективності, що робить ці дослідження надзвичайно важливими та перспективними.

**Аналіз останніх досліджень і публікацій.** Розвиток ШІ та конволюційних нейронних мереж (КНМ) відкрили нові можливості у сфері обробки та аналізу даних. КНМ здатні ефективно розпізнавати зображення або двовимірні матриці даних, що можуть бути отримані з акустичних сигналів. Ці методи дозволяють аналізувати спектральні характеристики звукових сигналів, які відображають стан виробничого обладнання.

Сучасні методи акустичного спектрального аналізу значно розширили свої можливості завдяки розвитку інформаційних технологій і математичних методів. Одним із найбільш поширених методів є аналіз за допомогою рядів Фур'є, який дозволяє розкласти складні звукові сигнали на окремі гармонічні компоненти та виявляти їх спектральні характеристики [1, 4, 5,8]. Метод Фур'є базується на перетворенні Фур'є:

$$F(\omega) = \int_{-\infty}^{\infty} \exp(i\omega t) dt,$$

де  $F(\omega)$  – спектральна густина потужності;

$f(t)$  – вихідний сигнал у часовій області;

$\omega$  – кутова частота.

Завдяки цим методам можна отримувати детальну інформацію про стан обертових вузлів і підшипників у виробничому обладнанні. Крім рядів Фур'є, активно використовуються такі методи, як вейвлет-перетворення, які дозволяють аналізувати сигнали як у частотній, так і в часовій областях [9, 10]. Вейвлет-перетворення можна записати у вигляді:

$$W(a, b) = \int_{-\infty}^{\infty} f(t) \psi_{a,b}(t) dt,$$

де  $W(a, b)$  – коефіцієнти вейвлет-перетворення;

$\psi_{a,b}(t)$  – вейвлет-функція;

$a$  і  $b$  – параметри масштабування і зсуву.

Особливо корисними зазначені методи є для виявлення короткочасних аномалій. Сучасні алгоритми спектрального аналізу у поєднанні з можливостями штучного інтелекту забезпечують високу точність та ефективність моніторингу стану обладнання, сприяючи підвищенню надійності та ефективності виробничих процесів [2, 3, 6, 7].

Використання ШІ для аналізу та оптимізації виробничих процесів вимагає апаратних засобів та програмного забезпечення. Це включає обчислювальні процесори, які здатні швидко обробляти великі обсяги даних, а також спеціалізоване програмне забезпечення для виконання алгоритмів ШІ. Зокрема ШІ може бути реалізований на компактних і доступних платформах, таких як Raspberry Pi [11, 12]. Цей мікрокомп'ютер дозволяє розробникам виконувати обчислення та обробку даних прямо на пристрої, використовуючи спеціалізовані бібліотеки Python для ШІ та машинного навчання. Використання Raspberry Pi відкриває нові можливості для створення інтелектуальних систем моніторингу та оптимізації у виробничих процесах, завдяки своїй гнучкості та низькій вартості.

Серед спеціалізованих бібліотек Python, що орієнтовані на роботу з ШІ, конволюційними нейронними мережами та обробкою акустичних сигналів, слід відзначити такі бібліотеки, як TensorFlow, PyTorch та Keras для створення та тренування нейронних мереж, а також librosa та scipy для обробки аудіосигналів [13 - 15]. Ці бібліотеки забезпечують широкий спектр інструментів та функцій, які допомагають розробникам швидко та ефективно реалізовувати складні алгоритми ШІ.

Для обробки акустичних сигналів, зокрема спектрального аналізу, використовуються бібліотеки, такі як librosa та scipy. Вони дозволяють виконувати різноманітні операції з аудіосигналами, включаючи перетворення Фур'є, вейвлет-перетворення та інші види спектрального аналізу. Це надає можливість отримувати важливу інформацію про стан обладнання на основі його акустичних характеристик, що дозволяє виявляти відхилення та аномалії у роботі виробничих вузлів і елементів.

Завдяки поєднанню апаратних засобів та спеціалізованого програмного забезпечення, сучасні методи ШІ забезпечують високий рівень точності та ефективності у моніторингу та оптимізації виробничих процесів. Використання бібліотек Python та алгоритмів ШІ дозволяє автоматизувати багато задач, пов'язаних з обробкою та аналізом даних, що робить виробничі лінії більш надійними та продуктивними. Це, у свою чергу, сприяє зменшенню витрат та підвищенню якості продукції.


**Постановка завдання.** Мета дослідження полягає у розробці методу для обробки та аналізу акустичних сигналів, генерованих виробничим обладнанням, із застосуванням апаратних та програмних засобів, що реалізують ШІ та КНМ, для підвищення надійності експлуатації та ефективності функціонування виробничих ліній. Основна концепція даного методу передбачає попередню обробку акустичних сигналів за допомогою спеціалізованих бібліотек Python, результатом чого є формування двовимірних матриць або зображень. Це дозволяє ефективно використовувати методи КНМ для аналізу спектральних характеристик і змін акустичних сигналів у часі, здійснення діагностики, контролю та оптимізації роботи виробничого обладнання, а також виявлення аномалій, що підвищує надійність та ефективність його функціонування.

Для реалізації мети розв'язувалися наступні завдання:

1. Запропонувати підхід використання двовимірних уявлень акустичних спектрів у часі як вхідних даних для КНМ з метою виявлення параметрів роботи виробничого обладнання, що корелюються з надійністю функціонування та ефективністю використання обладнання.

2. Провести дослідження щодо впровадження методів акустичного спектрального аналізу в поєднанні з КНМ у виробничі процеси для покращення ефективності використання та надійності функціонування обладнання у виробничій системі, що сприятиме оптимізації функціонування сучасного виробництва.

**Викладення основного матеріалу.** Зміну акустичного спектру роботи електродвигуна в часі, показано у вигляді двовимірного зображення на рис. 1.



а - двовимірне; б - миттєве

Рисунок 1 – Представлення в часі акустичних спектрів роботи обладнання

*Джерело: розроблено авторами*

Як видно з рисунку 1, разом з фоновими акустичними сигналами на зображенні містяться характеристичні спектральні лінії, які з часом (у верхній частині зображення) мають нахил вліво, що відповідає зменшенню обертів двигуна. Оскільки ці лінії є характеристичними, то вони повинні корелюватись з порушенням роботи електроприводу, а відповідно і з надійністю функціонування такого вузла.

Створення моделі КНМ, яка здатна визначати аномальну роботу вузлів виробничої лінії за акустичними спектрами їхньої роботи, встановлює кореляцію між надійністю функціонування та ефективністю експлуатації виробничої лінії та їхніми акустичними спектрами. Це дозволяє на ранньому етапі виявляти аномалії та виправляти їх до того, як вони призведуть до серйозних збоїв або зупинок виробництва. Крім того, така модель може бути використана для оптимізації процесів виробництва, забезпечуючи високу якість продукції та знижуючи витрати на обслуговування та ремонт.

Для виконання поставлених завдань було проведено комп'ютерне моделювання роботи виробничої лінії, спрямоване на встановлення кореляції між надійністю її функціонування та акустичними спектрами роботи вузлів. Моделювання передбачало дослідження виробничої лінії, в якій за нормальної роботи вузлів можливо лише лінійне змінювання спектральних акустичних ліній в часі. Якщо виробнича лінія, що відповідає моделі, формувала не лінійні зміни спектральних ліній акустичного сигналу, то це вважалося ознакою аномальної роботи вузлів, що формують цей акустичний сигнал. Для такої моделі була побудована нейронна мережа, здатна виділяти як лінійні, так і нелінійні зміни в акустичних спектрах, що вказувало на кореляцію між акустичними спектрами та надійністю функціонування виробничої лінії.

У процесі моделювання була створена КНМ з параметрами, які наведено на рис. 2:

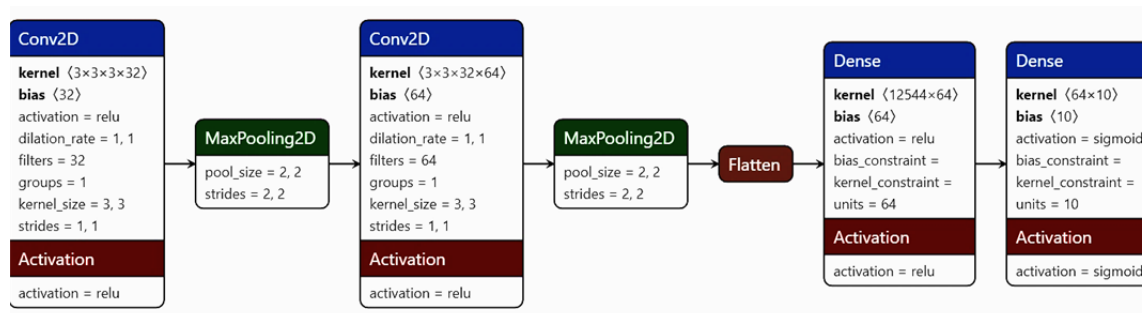


Рисунок 2 – Опис структури запропонованої конфолуційної нейронної мережі для виявлення аномалій у акустичних спектрах модельованої виробничої лінії

*Джерело: розроблено авторами*

Навчання запропонованої КНМ було реалізовано на датасеті графічних спектрів, який містив спектри нормальної та аномальної роботи вузлів виробничої лінії у пропорції 40% аномальних спектрів та 60% нормальною роботою.

Така структура КНМ була обрана через кілька ключових причин:

- КНМ використовує фільтри для виявлення локальних призначень на зображенні, що дозволяє ефективно виокремлювати важливі характеристики, такі як контурні лінії та текстури.

- Шляхом використання максимального підсумування (max pooling) та згорткових фільтрів (convolutional filters), КНМ зменшує розмір входу, що допомагає зменшити кількість обчислень та пам'яті, не втрачаючи важливу інформацію.

- КНМ має багат шарову структуру, що дозволяє вивчати більш складні та абстрактні характеристики зображень з кожним наступним шаром.

- КНМ може бути навчена на одному наборі даних та успішно застосована на іншому, що робить її дуже універсальною.

Ця структура базується на багат шарових нейронних мережах, які були успішно застосовані в різних задачах обробки зображень, таких як розпізнавання образів, класифікація зображень та інші.

Вигляд тренувального датасету наведено на рис. 3:




Рисунок 3 – Вигляд dataset для навчання конволюційних нейронних мереж виявляти аномальну роботу електродвигуна

*Джерело: розроблено авторами*

Програмний код для створення і навчання КНМ вказаному датасеті з використанням бібліотеки Tensorflow та Keras показано на рис.4:

```
import tensorflow as tf
from tensorflow.keras.preprocessing.image import ImageDataGenerator
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Conv2D, MaxPooling2D, Flatten, Dense
import matplotlib.pyplot as plt
import os
import numpy as np
from sklearn.model_selection import train_test_split

# Параметри
image_size = (300, 300)
batch_size = 10
epochs = 20

# Функція для завантаження зображень і міток
def load_dataset(data_dir):
    images = []
    labels = []
    for file_name in os.listdir(data_dir):
        if file_name.endswith('.png'):
            img = tf.keras.preprocessing.image.load_img(os.path.join(data_dir, file_name), target_size=image_size)
            img_array = tf.keras.preprocessing.image.img_to_array(img)
            images.append(img_array)
            if "image_" in file_name and int(file_name.split('_')[1].split('.')[0]) >= 32:
                labels.append(1) # Зігнуті лінії
            else:
                labels.append(0) # Прямі лінії
    return np.array(images), np.array(labels)

# Завантаження даних
data_dir = 'dataset'
images, labels = load_dataset(data_dir)

# Розділення на тренувальний, валідаційний і тестовий набори
X_train, X_temp, y_train, y_temp = train_test_split(images, labels, test_size=0.30, random_state=42)
X_val, X_test, y_val, y_test = train_test_split(X_temp, y_temp, test_size=0.33, random_state=42)

# Нормалізація даних
X_train = X_train / 255.0
X_val = X_val / 255.0
X_test = X_test / 255.0

# Побудова моделі
model = Sequential([
    Conv2D(32, (3, 3), activation='relu', input_shape=(image_size[0], image_size[1], 3)),
    MaxPooling2D((2, 2)),
    Conv2D(64, (3, 3), activation='relu'),
    MaxPooling2D((2, 2)),
    Conv2D(128, (3, 3), activation='relu'),
    MaxPooling2D((2, 2)),
    Flatten(),
    Dense(128, activation='relu'),
    Dense(1, activation='sigmoid')
])

# Компіляція моделі
model.compile(optimizer='adam', loss='binary_crossentropy', metrics=['accuracy'])

# Навчання моделі
history = model.fit(X_train, y_train, epochs=epochs, batch_size=batch_size, validation_data=(X_val, y_val))

# Оцінка моделі
test_loss, test_acc = model.evaluate(X_test, y_test, verbose=2)
print(f'\nТестова точність: {test_acc:.4f}')


# Візуалізація графіка залежності помилки від епох
plt.plot(history.history['loss'], label='Тренувальні дані')
plt.plot(history.history['val_loss'], label='Валідаційні дані')
plt.xlabel('Епоха')
plt.ylabel('Значення втрати')
plt.legend(loc='upper right')
plt.show()
```

Рисунок 4 – Програмна модель створення та навчання КНМ  
виявляти аномальну роботу електродвигуна

*Джерело: розроблено авторами*



Процес навчання запропонованої КНМ дав результат, який відображено у вигляді графіка на рисунку 5 а. Навчання тривало двадцять епох в результаті яких сітка отримала можливість з точністю 99,02 % визначати аномалії на навчальних даних та з точністю 68,75% на даних валідації рисунок 5 б.



а

```

Epoch 17/20
6/6 ██████████ 28s 5s/step - accuracy: 0.7841 - loss: 0.3980 - val_accuracy: 0.7500 - val_loss: 0.5841
Epoch 18/20
6/6 ██████████ 28s 5s/step - accuracy: 0.9141 - loss: 0.2583 - val_accuracy: 0.6250 - val_loss: 0.5595
Epoch 19/20
6/6 ██████████ 28s 5s/step - accuracy: 0.9790 - loss: 0.1800 - val_accuracy: 0.7500 - val_loss: 0.7218
Epoch 20/20
6/6 ██████████ 41s 5s/step - accuracy: 0.9920 - loss: 0.1131 - val_accuracy: 0.6875 - val_loss: 0.9100
1/1 - 1s - 939ms/step - accuracy: 0.7500 - loss: 0.8823

```

б

Рисунок 5 – Результати навчання конволюційної нейронної мережі, що визначає кореляцію між надійністю функціонування та акустичними спектрами обладнання:

а – графік залежності помилки від номера епохи навчання; б - значення помилки для останніх трьох епох навчання

*Джерело: розроблено авторами*

Розглянутий метод кореляції між характеристиками звукових сигналів та надійністю обладнання, дозволяє використовувати акустичні спектри, для ідентифікації патернів аварійного функціонування обладнання, що є важливим для підвищення ефективності технічного обслуговування та запобігання аваріям.

Запропонований підхід демонструє перспективи використання машинного навчання у виробничих процесах, де раннє виявлення проблем може значно зменшити витрати та підвищити якість продукції. Завдяки високій точності та швидкості обробки даних, КНМ стає важливим інструментом для покращення надійності функціонування та ефективності експлуатації автоматизованих виробничих ліній.

#### **Висновки:**

1 Запропоновано метод виявлення кореляції між акустичним спектром роботи обладнання та його параметрами надійності. При цьому використовували фононові

акустичні сигнали з характеристичними спектральними лініями, які мали нахил у відповідності до зменшення обертів двигуна, як електроприладу.

2 Розглянуто спосіб впровадження машинного навчання в автоматизовані виробничі лінії для підвищення їх ефективності. Машинне навчання було реалізовано на DataSet графічних матеріалах конволюційних нейронних мереж для виявлення аномальної роботи електродвигуна.

3 Побудована структура та програмна модель створення та навчання конволюційних нейронних мереж для розпізнавання двовимірних патернів стану виробничого обладнання. Визначено, що результат процесу навчання здійснюється з точністю 99,02% відносно аномалії процесів функціонування виробничого обладнання і 68,75% – на даних валідації. Показано можливість ідентифікації патернів аварійного функціонування обладнання, що важливо для підвищення ефективності і надійності функціонування виробничих ліній технічним обслуговуванням.

## Список літератури

1. Zhiqiang Gao, Qi Chang, Yu Deng, Wei Liu, Pengfei M, Pu Zhou, Lei Si. "Tilt noise extraction method based on fourier transform and fitting of 2D images". Optics Communications. Volume 577, March 2025, 131372. URL: <https://doi.org/10.1016/j.optcom.2024.131372>
2. Аулін В.В., Гриньків А.В., Лисенко С.В., Голуб Д.В. Синергетика підвищення надійності машин використанням моделей марківських процесів. *Перспективи і тенденції розвитку конструкцій та технічного сервісу с/х машин і знарядь*: зб. матеріалів доп. учасн. V Всеукраїнської науково-практичної конф. Житомир: Житомирський агротехнічний коледж, 2019. С. 242-245.
3. Аулін В. В., Гриньків А. В., Головатий А. О., Лисенко С. В., Голуб Д. В., Кузик О.В., Тихий А. А. Методологічні основи проектування та функціонування інтелектуальних транспортних і виробничих систем: монографія під заг. ред. д.т.н., проф. Ауліна В.В. Кропивницький: Видавець Лисенко В.Ф., 2020. 428с.
4. Kenta Ohira, Toru Ohira. Solving a delay differential equation through the Fourier transform. Physics Letters A. Volume 531, 28 January 2025, Page 130138. URL: <https://doi.org/10.1016/j.physleta.2024.130138>.
5. Mehieddine Derbas, Stephan Frömel-Frybort, Hans-Christian Möhring, Martin Riegler. Accelerated Singular Spectrum Analysis and Machine Learning to investigate wood machining acoustics. Mechanical Systems and Signal Processing. Volume 223, 15 January 2025, 111879. URL: <https://doi.org/10.1016/j.ymsp.2024.111879>.
6. В.В. Аулін, С.Г. Ковальов, А.В. Гриньків, В.В. Варваров. Алгоритм оптимізації надійності функціонування та ефективності використання виробничого обладнання методами штучного інтелекту. *Збірник наукових праць «Центральноукраїнський науковий вісник. Технічні науки»*. Вип.10 (41), ч. I. Кропивницький. 2024, С. 60-67.
7. Ковальов С.Г. Ковальов Ю.Г. Особливості реалізація моделі штучної нейронної мережі апаратними засобами. «Наука і технікасьогодні» (Серія «Педагогіка», Серія «Право», Серія «Економіка», Серія «Фізико-математичні науки», Серія «Техніка»): журнал. 2024. №6(34) 2024. С. 1131. URL: DOI: [https://doi.org/10.52058/2786-6025-2024-6\(34\)](https://doi.org/10.52058/2786-6025-2024-6(34))
8. Tao Liu, Xinsan Li, Junshuai Sun, Mindong Lyu. Shaoze Yan A post-processing method called Fourier transform based on local maxima of autocorrelation function for extracting fault feature of bearings. Advanced Engineering Informatics. Volume 62, Part B, October 2024, 102766 URL: <https://doi.org/10.1016/j.aei.2024.102766>.
9. Xuanqi Lin, Yong Zhang, Shun Wang, Yongli Hu, Baocai Yin. Multi-scale wavelet transform enhanced graph neural network for pedestrian trajectory prediction. Physica A: Statistical Mechanics and its Applications. Volume 659, 1 February 2025, 130319. URL: <https://doi.org/10.1016/j.physa.2024.130319>.
10. Seong-Heon Seo. Instantaneous frequency estimation by interpolating continuous wavelet transform coefficients. Digital Signal Processing. Volume 159, April 2025, 104989. URL: <https://doi.org/10.1016/j.dsp.2025.104989>.
11. Elizabeth Shoop, Suzanne J. Matthews, Richard Brown, Joel C. Adams. Hands-on parallel & distributed computing with Raspberry Pi devices and clusters. Journal of Parallel and Distributed Computing. Volume 196, February 2025, 104996. URL: <https://doi.org/10.1016/j.jpdc.2024.104996>.
12. M.D. Rakesh, M. Jeevankumar, S.B. Rudraswamy. Implementation of real time root crop leaf classification using CNN on raspberry-Pi microprocessor. Smart Agricultural Technology. Volume 10, March 2025, 100714. URL: <https://doi.org/10.1016/j.atech.2024.100714>.



13. Luca Barillaro. Deep Learning Platforms: TensorFlow. Reference Module in Life Sciences. 2024. URL: <https://doi.org/10.1016/B978-0-323-95502-7.00167-6>.
14. Luca Barillaro. Deep Learning Platforms: Keras. Reference Module in Life Sciences 2024. URL: <https://doi.org/10.1016/B978-0-323-95502-7.00092-0>.
15. Sharnil Pandya, Hemant Ghayvat. Ambient acoustic event assistive framework for identification, detection, and recognition of unknown acoustic events of a residence. *Advanced Engineering Informatics*. Volume 47, January 2021, 101238. URL: <https://doi.org/10.1016/j.aei.2020.101238>.

## References

1. Zhiqiang Gao, Qi Chang, Yu Deng, Wei Liu, Pengfei M, Pu Zhou, & Lei Si. (2025) "Tilt noise extraction method based on fourier transform and fitting of 2D images". *Optics Communications*. Volume 577, March 2025, 131372. URL: <https://doi.org/10.1016/j.optcom.2024.131372> [in English].
2. Aulin V.V., Hrynkiv A.V., Lysenko S.V., & Holub D.V. Synergetics of increasing machine reliability using Markov process models. Prospects and trends in the development of structures and technical service of agricultural machines and tools: collection of materials of the participants of the V All-Ukrainian Scientific and Practical Conference. Zhytomyr: Zhytomyr Agrotechnical College, 2019. P. 242-245. [in Ukrainian].
3. Aulin V.V., Hrynkiv A. V., Holovaty A. O., Lysenko S. V., Holub D. V., Kuzyk O. V., & Tykhy A. A. Methodological foundations of design and functioning of intelligent transport and production systems: monograph under the general editorship of Dr. Tech., Prof. Aulina V. V. Kropyvnytskyi: Publisher Lysenko V. F., 2020. 428p. [in Ukrainian].
4. Kenta Ohira, Toru Ohira. Solving a delay differential equation through the Fourier transform. *Physics Letters A*. Volume 531, 28 January 2025, Page 130138. URL: <https://doi.org/10.1016/j.physleta.2024.130138>. [in English].
5. Mehieddine Derbas, Stephan Frömel-Frybort, Hans-Christian Möhring, Martin Riegler. Accelerated Singular Spectrum Analysis and Machine Learning to investigate wood machining acoustics. *Mechanical Systems and Signal Processing*. Volume 223, 15 January 2025, 111879. URL: <https://doi.org/10.1016/j.ymsp.2024.111879>. [in English].
6. V.V. Aulin, S.G. Kovalev, A.V. Hrynkiv, & V.V. Varvarov. Algorithm for optimizing the reliability of functioning and efficiency of the use of production equipment using artificial intelligence methods. Collection of scientific papers "Central Ukrainian Scientific Bulletin. Technical Sciences". Issue 10 (41), part I. Kropyvnytskyi.. 2024, P. 60-67. [in Ukrainian].
7. Kovalev S.G. & Kovalev Yu.G. Features of the implementation of the artificial neural network model by hardware means. "Science and Technology Today" (Series "Pedagogy", Series "Law", Series "Economics", Series "Physical and Mathematical Sciences", Series "Technology")": journal. 2024. No. 6(34) 2024. P. 1131. URL: DOI: [https://doi.org/10.52058/2786-6025-2024-6\(34\)](https://doi.org/10.52058/2786-6025-2024-6(34)) [in Ukrainian].
8. Tao Liu, Xinsan Li, Junshuai Sun, Mindong Lyu. Shaoze Yan A post-processing method called Fourier transform based on local maxima of autocorrelation function for extracting fault feature of bearings. *Advanced Engineering Informatics*. Volume 62, Part B, October 2024, 102766 URL: <https://doi.org/10.1016/j.aei.2024.102766>. [in English].
9. Xuanqi Lin, Yong Zhang, Shun Wang, Yongli Hu, Baocai Yin. Multi-scale wavelet transform enhanced graph neural network for pedestrian trajectory prediction. *Physica A: Statistical Mechanics and its Applications*. Volume 659, 1 February 2025, 130319. URL: <https://doi.org/10.1016/j.physa.2024.130319>.
10. Seong-Heon Seo. Instantaneous frequency estimation by interpolating continuous wavelet transform coefficients. *Digital Signal Processing*. Volume 159, April 2025, 104989. URL: <https://doi.org/10.1016/j.dsp.2025.104989>. [in English].
11. Elizabeth Shoop, Suzanne J. Matthews, Richard Brown, Joel C. Adams. Hands-on parallel & distributed computing with Raspberry Pi devices and clusters. *Journal of Parallel and Distributed Computing*. Volume 196, February 2025, 104996. URL: <https://doi.org/10.1016/j.jpdc.2024.104996>. [in English].
12. M.D. Rakesh, M. & Jeevankumar, S.B. Rudraswamy. Implementation of real time root crop leaf classification using CNN on raspberry-Pi microprocessor. *Smart Agricultural Technology*. Volume 10, March 2025, 100714. URL: <https://doi.org/10.1016/j.atech.2024.100714>. [in English].
13. Luca Barillaro. Deep Learning Platforms: TensorFlow. Reference Module in Life Sciences. 2024. URL: <https://doi.org/10.1016/B978-0-323-95502-7.00167-6>. [in English].
14. Luca Barillaro. Deep Learning Platforms: Keras. Reference Module in Life Sciences 2024. URL: <https://doi.org/10.1016/B978-0-323-95502-7.00092-0>. [in English].
15. Sharnil Pandya, Hemant Ghayvat. Ambient acoustic event assistive framework for identification, detection,

and recognition of unknown acoustic events of a residence. *Advanced Engineering Informatics*. Volume 47, January 2021, 101238. URL: <https://doi.org/10.1016/j.aei.2020.101238>. [in English].

**Serhii Kovalov**, Doctoral student, Ph.D., ped. sci., **Viktor Aulin**, Prof., DSc., **Andrii Hrynkiv**, Senior Researcher, PhD tech. sci.

*Central Ukrainian National Technical University, Kropyvnytskyi, Ukraine*

**Valerii Varvarov**, PhD tech. sci.

*Kharkiv National Ivan Kozhedub Air Force University, Kharkiv, Ukraine*

### **Increasing the Reliability and Efficiency of Production Lines Using Artificial Intelligence Methods Using Acoustic Signal Monitoring**

The article provides an in-depth analysis of a method to improve the reliability and efficiency of automated production lines by reducing maintenance costs and minimizing downtime using artificial intelligence algorithms. The method involves the application of acoustic spectra generated by the production line nodes during operation to establish a correlation with the reliability and efficiency of these lines. A model for representing acoustic spectra as a two-dimensional data array, which captures the change in acoustic spectra over time, has been proposed. The format of acoustic spectra as two-dimensional data is used to recognize equipment operation patterns. To recognize these patterns, the use of a convolutional neural network is proposed, and its software model has been developed, allowing simulation and assessment of the accuracy of using machine learning methods.

Additionally, the article highlights the results of the functioning of the developed neural network, which indicate a significant correlation between the measured acoustic spectra of the production line equipment and its reliability and efficiency indicators. The importance of this approach lies in the ability to timely detect potential problems and quickly eliminate them, which in turn contributes to reducing maintenance costs and increasing productivity.

Moreover, the implementation of this method can significantly impact the overall efficiency of production processes, providing more accurate and reliable monitoring of equipment conditions. Further research may be directed towards improving the proposed models and algorithms, as well as developing new approaches to the analysis and interpretation of acoustic spectra.

Furthermore, the integration of such advanced technologies into the production environment demonstrates a progressive shift towards more intelligent and autonomous manufacturing systems. These advancements not only enhance the performance and sustainability of industrial operations but also pave the way for future innovations. By continually refining the models and algorithms used in acoustic spectrum analysis, industries can achieve higher levels of precision in fault detection and maintenance planning. This proactive approach ensures that equipment operates at optimal levels, thereby extending its lifespan and reducing unexpected downtime. Overall, the adoption of AI-driven methodologies in industrial settings represents a significant leap forward in modernizing production lines and achieving unprecedented levels of operational excellence.

**reliability of operation, efficiency of operation, automated production lines, acoustic spectrum, machine learning, convolutional networks**

*Одержано (Received) 31.10.2024*

*Прорецензовано (Reviewed) 05.12.2024*

*Прийнято до друку (Approved) 23.12.2024*