

КЛАСИФІКАЦІЯ РОБОЧОГО СТАНУ ПІДШИПНИКІВ КОЧЕННЯ ЗА ДОПОМОГОЮ ЗГОРТКОВОЇ НЕЙРОННОЇ МЕРЕЖІ ЗІ ЗМІННИМИ ФАКТОРАМИ ДИЛАТАЦІЇ

Робота описує процес обробки даних роботи підшипників кочення, та їх використання в задачі побудови математичної моделі бінарної класифікації робочого стану підшипників методом згорткової нейронної мережі зі змінними факторами дилатациї ядер згорткових шарів. Для класифікації підшипників, що мають дефекти, були використані дані віброприскорень з власного випробувального стенду та з набору даних, що знаходяться у вільному доступі. В роботі також було досліджено спосіб узагальнення класифікації сигналів підшипників, що були отримані в результаті принципово різних експериментів, та що мають різний типорозмір. Для уніфікації сигналів пропонується наступний спосіб обробки: виділити ділянки даних із зсувиом, перейти до частотного простору за допомогою швидкого перетворення Фур'є, відсісти частоти, що перевищують 10-кратну частоту обертання валу, відновити сигнал зі збереженням 10 періодів обертання валу, відмасштабувати отриманий сигнал діленням його на діаметр орбіти обертання тіла кочення та інтерполювати сигнал на 2048 точок. Даний алгоритм також дає можливість генерувати збалансовану вибірку для побудови математичної моделі. Ця можливість надається за допомогою варіювання кроку розбиття початкового сигналу. Перевага даного алгоритму над класичними методами копіювання чи видалення прикладів постає у створенні нових об'єктів, які уточнюють статистичні параметри генеральної сукупності. Алгоритм обробки сигналу було використано як для задачі бінарної класифікації всередині одного набору даних, так і для навчання на одному та тестуванні на іншому. Для збільшення набору даних для навчання та тестування математичної моделі використовується метод бутстрепування, який засновано на багаторазовій генерації вибірок методом Монте-Карло. Якість математичної моделі бінарної класифікації оцінювалась за часткою правильних відповідей. Задача сформульована як задача мінімізації бінарної перехресної ентропії. Отримані результати представлено в вигляді графіків, демонструючих процес навчання нейронної мережі та графіків щільноти розподілу метрик.

Ключові слова: згорткова нейронна мережа, підшипники кочення, вібродіагностика дефектів, швидке перетворення Фур'є, бутстрап, метод Монте-Карло, змінна дилатація, класифікація незбалансованих наборів даних

Работа описывает процесс обработки данных работы подшипников качения, и их использование в задаче построения математической модели бинарной классификации рабочего состояния подшипников методом сверточной нейронной сети с изменяющимися факторами дилатации ядер сверточных слоев. Для классификации подшипников, имеющих дефекты, были использованы данные виброускорений из собственного испытательного стендса и набора данных, находящихся в свободном доступе. В работе также был исследован способ обобщения классификации сигналов подшипников, полученных в результате принципиально разных экспериментов и имеющих разный типоразмер. Для унификации сигналов предлагается следующий способ обработки: выделить участки данных со смещением, перейти в частотному пространству с помощью быстрого преобразования Фурье, отсечь частоты превышающие 10-кратную частоту вращения вала, восстановить сигнал с сохранением 10 периодов вращения вала, отмасштабировать полученный сигнал делением его на диаметр орбиты вращения тела качения и интерполировать сигнал на 2048 точек. Данный алгоритм также позволяет генерировать балансированную выборку для построения математической модели. Эта возможность предоставляется с помощью варьирования шага разбиения исходного сигнала. Преимущество данного метода над классическими способами копирования либо удаления примеров выражается в генерации новых объектов, уточняющих статистические характеристики генеральной совокупности. Алгоритм обработки сигнала был использован как для задач бинарной классификации внутри одного набора данных, так и для обучения на одном и тестировании на другом. Для увеличения набора данных для обучения и тестирования математической модели используется метод бутстрэппинга, основанный на многократной генерации выборок методом Монте-Карло. Качество математической модели бинарной классификации оценивалось по доле правильных ответов. Задача сформулирована как задача минимизации бинарной перекрестной энтропии. Полученные результаты представлены в виде графиков, демонстрирующих процесс обучения нейронной сети и графиков плотности распределения метрик.

Ключевые слова: сверточная нейронная сеть, подшипники качения, вибродиагностика дефектов, быстрое преобразование Фурье, бутстрэп, метод Монте-Карло, сменная дилатация, классификация несбалансированных наборов данных.

The work describes rolling bearings operation data processing, and their use in the problem of constructing a mathematical model of the binary classification of the operating state of bearings by the method of a convolutional neural network with varying factors of dilatation of the kernel of convolutional layers. To classify bearings with defects, we used vibration acceleration data from our own test bench and a publicly available data set. The work also investigated a method for generalizing the classification of bearing signals obtained as a result of fundamentally different experiments and having different standard sizes. To unify signals, the following processing method is proposed: select data areas with displacement, go to the frequency space using fast Fourier transform, cut off frequencies exceeding 10 times the shaft rotation frequency, restore the signal while maintaining 10 shaft rotation periods, scale the received signal by dividing it by its diameter orbits of the rolling body and interpolate the signal at 2048 points. This algorithm also allows to generate a balanced sample for building a mathematical model. This feature is provided by varying the step of splitting the initial signal. The advantage of this algorithm over the classical methods of oversampling or undersampling is the generation of new objects that specify the statistical parameters of the general population. The signal processing algorithm was used both for binary classification problems within one dataset, and for training on one and testing on another. To increase the data set for training and testing the mathematical model, the bootstrapping method is used, based on multiple generation of samples using the Monte Carlo method. The quality of the mathematical model of binary classification was assessed by the proportion of correct answers. The problem is formulated as the problem of minimizing binary cross entropy. The results obtained are presented in the form of graphs demonstrating the neural network training process and graphs of the distribution density of metrics.

Keywords: convolutional neural network, rolling bearings, vibration diagnostics of defects, fast Fourier transform, bootstrap, Monte Carlo method, plug-in dilation, classification of unbalanced datasets.

Вступ. Заміна детермінованих моделей діагностики, створених на основі експертних правил прийняття рішень, на стохастичні математичні моделі, наприклад, нейронні мережі, набуває все більшого поширення у промисловості для покращення та

автоматизації виробничих процесів. Навіть після століть існування підшипників, проблема неочікуваного виходу з ладу так само актуальна і залишається однією з найпоширеніших задач діагностики машин та механізмів. Тому у цій області

дослідники приходять до використання нейронних мереж для вібродіагностики стану підшипників кочення.

Класичні емпіричні підходи вібродіагностики використовуються й зараз, та демонструють задовільні результати. Проте якість таких підходів все ще не ідеальна, та призводить до значних економічних втрат. Тому активно створюються методи діагностики стану підшипників, що включають в себе досягнення сучасної науки для створення якісних моделей, що здатні точно та автоматизовано передбачати наявність дефектів.

Метою роботи є дослідження власного способу обробки сигналів підшипників, для досягнення їх уніфікації, тобто незалежності від режиму роботи та типорозміру. Отримані сигнали пропонується обробляти згортковою нейронною мережою зі змінними факторами дилатації у ядрах згорткових шарів.

Огляд проблеми. Задача вібродіагностики підшипників має чимало можливих інструментів для її вирішення. Наприклад у [1] пропонується використовувати комбінацію з вейвлет-трансформації, методу опорних векторів та Марковських ланцюгів. Також існує чимало архітектур нейронних мереж для роботи з сигналами: FaultNet [2], AlexNet [3], WaveNet [4]. Згорткові нейронні мережі – перспективний напрямок, який дає непогані результати, і оскільки задача постає у уніфікації сигналів з різних джерел, ми обрали архітектуру, подібну до WaveNet.

Не менш проблематичним є аспект обробки сигналів. Більшість статей використовують різні описові функції для створення кумулятивного простору ознак сигналу, як наприклад у [5, 6, 7]. Але, як показав досвід, таким чином неможливо оминути проблему типорозміру та режиму роботи. Необхідно виключити з сигналу аспект невизначеності експерименту, щоб мати можливість навчати модель на власних даних та робити передбачення на даних з принципово іншого експерименту. Для досягнення цієї цілі було виведено алгоритм на основі швидкого перетворення Фур’є, який буде описаний далі.

Збір даних. Дані були отримані з двох джерел: з власного обладнання, деталі експерименту якого описані в [8, 9], та набору даних Мадридського політехнічного університету, що знаходиться у вільному доступі [10]. Сутність експериментів схожа: у одному експерименті досліджуються два підшипники – один новий та незнімний, інший знімний та з різними стадіями дефекту. До підшипників під’єднані акселерометри, що знімають показники віброприскорення.

Обробка даних. Сутність узагальнюючої можливості алгоритмів, яка перевіряється у даній роботі – здатність класифікувати підшипники кочення за сигналами їх віброприскорення, незалежно від окремих конструкційних чи експлуатаційних параметрів підшипників. Але ці параметри значною мірою впливають на класифікацію, оскільки є необхідними для аналізу в усіх класичних підходах до діагностики дефектів.

Попри це, на початку ми мали лише 112 сигналів, отриманих у нашому експерименті, та 45 сигналів, отриманих зі стороннього експерименту. Постає гостра необхідність у генерації більш об’ємної вибірки для навчання класифікатора. Так, у даній роботі ми розглядаємо алгоритм одночасних уніфікації та розбиття сигналів з подальшим використанням оброблених ділянок сигналу як вхідні вектори до моделі класифікації.

Даний алгоритм складається з наступних кроків:

1. Виділення в сигналі проміжку деякої довжини l зі зсувом N . Початкове значення N дорівнює 0, тобто на першій ітерації зразок обирається з проміжку $[0, l]$, з другої $[N, l + N]$, з ітерації з індексом m : $[m \times N, l + m \times N]$, де m змінюється від 0 до необхідної кількості зразків M . Значення M відрізняється для різних сигналів. Важливо, щоб довжина початкового сигналу K була більшою за $l + m \times N$. Виходячи з цього, ми можемо прийняти зсув N за наступною формулою 1:

$$N \leq \frac{(K - l)}{m} \quad (1)$$

2. Перехід до частотного представлення сигналу за допомогою швидкого перетворення Фур’є [11] з відсіченням усіх частот, які перевищують 10-кратну частоту обертання валу;
3. Відновлення сигналу зі збереженням 10 періодів обертання валу;
4. Масштабування амплітуд сигналу за рахунок його поділу на діаметр орбіти обертання тіла кочення;
5. Интерполяція отриманого сигналу на 2048 точок;

Ми можемо проілюструвати роботу алгоритму на прикладі. Нехай ми маємо два сигнали віброприскорення підшипників, які мають різні абсолютні значення частот, хоча відношення цих частот до швидкостей обертання валів є однаковими. Так, на рисунку (рис. 1) показані дві ділянки необроблених сигналів з наступними параметрами:

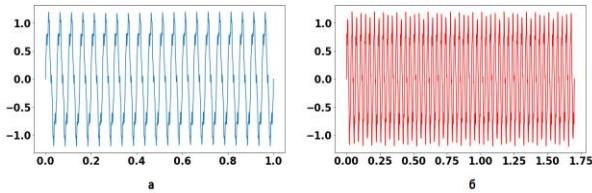


Рис. 1. Приклади сигналів до обробки (а – зі швидкістю ротора 20 Гц, б – зі швидкістю 30 Гц)

- Швидкість валу – 20 Гц, частоти сигналу - 20, 80, 240 Гц, 21 період коливань (рис. 1а);
- Швидкість валу – 30 Гц, частоти сигналу - 30, 120, 390 Гц, 53 періоди коливань. (рис. 1б)

Розділимо операційні частоти на відповідні швидкості обертання валів, отримаємо відносні частоти:

- Для першого валу: 1, 4, 12;
- Для другого валу: 1, 4, 13.

Як можна бачити, перші дві відносні частоти для обох сигналів збігаються, а третя відносна частота вища за 10, тому за алгоритмом вона занулюється. Так, алгоритм повинен перетворити дані сигнали на однакові, що показано на (рис. 2). Також дані сигнали спочатку були представлені у різній кількості періодів обертання валу – 21 проти 53. Алгоритм відновив обидва сигнали на 10 періодах.

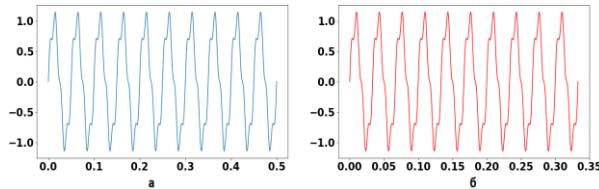


Рис. 2. Ділянки перетворених сигналів

За допомогою даного алгоритму ми отримали для кожного окремого початкового сигналу окремий набір зразків сигналів однакової довжини. Зсув N для сигналів обирається таким чином, щоб збалансувати вибірку – для позитивних прикладів було створено більше зразків, аніж для негативних прикладів, оскільки вибірка була початково незбалансованою – негативні приклади складали 90% від загального об'єму вибірки.

У даній роботі розглядаються сигнали з двох датчиків – той, що встановлений безпосередньо на підшипнику з потенційним дефектом, та той, що встановлений на цілому підшипнику. Так, кожен зразок для навчання мережі буде мати 2 канали, а загальна розмірність вибірки є $1996 \times 2048 \times 2$, де 2048×2 – розмірність вхідного сигналу.

Архітектура нейронної мережі. Даний етап роботи полягає у розгляді можливості застосування штучних нейронних мереж для бінарної класифікації сигналів віброприскорення підшипників кочення за їх робочим станом. Штучні нейронні мережі – це окремий вид алгоритмів створення математичних моделей, який використовується для обробки даних з великою кількістю параметрів – зображень, звуку, та ін. Штучні нейронні мережі мають набагато більше параметрів за класичні моделі та здатні автоматично знаходити складні патерни у комплексних даних [12]. Даний принцип застосовується у нейронній мережі для генерації звуку WaveNet, яка через свої узагальнюючі можливості найкращим чином зарекомендувала себе у даному типі задач.

Головна перевага даних алгоритмів полягає у тому, що вони здатні автоматично знаходити патерни у складних даних. Математична модель нейронних мереж передбачає використання на вході “сиріх даних” – тобто без попереднього створення простору ознак, які б описували об’єкт дослідження. Натомість модель отримує на вхід повне чисельне представлення об’єкта – сигналу, зображення, тощо – та нелінійно

перетворює ці чисельні значення до вихідного простору цільової функції.

Мотивацію до розгляду нейронних мереж є те, що у даній роботі ми можемо використовувати чистий або оброблений сигнал як вхідний вектор у математичну модель, не використовуючи евристичні підходи для створення простору ознак. Але вектор параметрів нейронних мереж є набагато більшим за вектори параметрів класичних алгоритмів, тому даний підхід має певні обмеження для використання через значну ресурсоємність алгоритмів оптимізації вектору параметрів моделі. Так, пошук оптимальної архітектури нейронних мереж виходить за рамки даної роботи і основна мета цього дослідження полягає у загальній оцінці застосовності даного підходу до класифікації стану підшипників за сигналами їх віброприскорення.

У даній роботі було досліджено можливість бінарної класифікації обробленого сигналу за допомогою архітектури нейронної мережі, близької до архітектури WaveNET, що початково була створена для генерації звуку. Це згорткова нейронна мережа, де шари мають різні фактори дилатації [13, 14] та дозволяють її рецептивному полю зростати експоненціально з переходом до більш глибоких шарів та покривати тисячі часових відрізків.

У даній роботі використовувались 6 слоїв згортки, відповідно до 6 факторів дилатації: 1, 2, 4, 8, 16, 32. Архітектура даної мережі представлена на (рис. 3). Хоча ця мережа є згортковою, фактично згортки сигналів до меншої розмірності не відбувається – розмір ковзного вікна підібраний так, щоб довжина сигналу не змінювалась при проході через шари. Таким чином, усі згорткові шари приймають сигнали розмірності 2×2048 . Загальна кількість параметрів моделі: 31094.

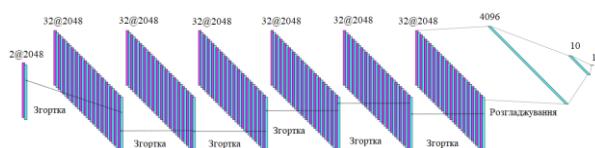


Рис. 3. Архітектура нейронної мережі.

Оцінки якості. Якість алгоритмів оцінювалась за допомогою точності [15]. Ця метрика використовується для оцінки якості алгоритму класифікації, який побудований на наборі даних без дисбалансом класів. Вона має гарну здатність до інтерпретації як доля вірно розпізнаних прикладів. Вимірюється від 0 до 1, де 1 – найкращий результат. 0.5 – середнє значення – якість, яку має алгоритм з довільно заданими параметрами, тобто непридатний до класифікації. Точність розраховується за формулою 2:

$$\text{Точність} = \frac{TP + TN}{TP + TN + FP + FN} \quad (2)$$

де TP – правильно розпізнані позитивні приклади (підшипники без дефектів);

TN – правильно розпізнані негативні приклади (підшипники з дефектами);

FP — кількість хибно-позитивних помилок;
FN — кількість хибно-негативних помилок.

Оскільки ми маємо занадто малу кількість прикладів для навчання та тестування моделі, конкретні показники якості будуть залежати від того, як ми розіб'ємо вибірку на навчальну та тестову підвибірки. Тому ми використовували валідацію методом бутстропу [16]. Цей метод полягає в багатократному стохастичному відборі з поверненням елементів для навчання з початкової вибірки. Так, для 100 ітерацій відбору ми будемо мати 100 різних пар підвибірок, де навчальна вибірка буде містити 63% елементів з початкової вибірки, а тестова — відповідно, 37%. Цей метод розрахунку називається "Out-of-bag error" [17]. Цей метод також застосовується у методі машинного навчання "випадковий ліс". Необхідно зазначити, що ми окремо розбиваємо позитивні і негативні приклади, щоб зберегти розподіл класів та не отримати елементи лише одного класу у навчальній або тестовій підвибірках.

Якщо для кожної ітерації бутстропованого відбору ми можемо навчити математичну модель на 63% даних та обчислити метрики на відкладених 37%, ми отримаємо розподіл значень метрики. Так, маючи середнє значення з розподілу, ми можемо зробити стійкий кількісний висновок про якість моделі.

Результати. Першим етапом цієї роботи є створення математичної моделі для розпізнавання підшипників з дефектом у рамках одного експерименту. На рисунку (рис. 4) зображений розподіл точності для 100 бутстропованих підвибірок з нашого набору даних. Результати на цьому рисунку та далі приведені для оцінки якості алгоритму на валідаційній виборці — тобто на тих даних, які модель не бачила під час навчання.

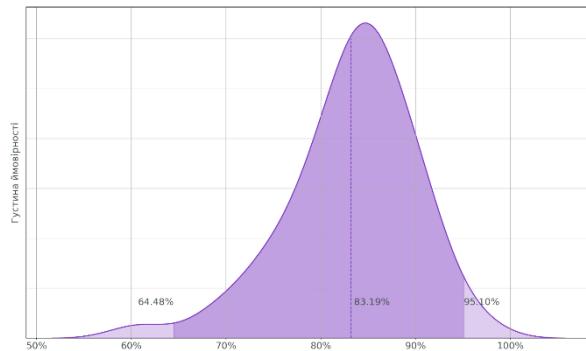


Рис. 4. Розподіл точності для класифікації у рамках одного експерименту

Як можна побачити з результатами цього етапу — модель дійсно здатна розпізнавати сигнали, які отримані з того ж експерименту, що й навчальні дані.

Другий етап — застосування моделі для класифікації сигналів, отриманих з інших експериментів. Тут перевірялося, чи може дана математична модель правильно класифікувати підшипники інших розмірів, які були встановлені на інших машинах обертання. На рисунку (рис. 5) зображений розподіл точності для навчання на 100 бутстропованих підвибірках з нашого набору даних та

тестуванні алгоритму на 100 бутстропованих підвибірках з іншого набору даних.

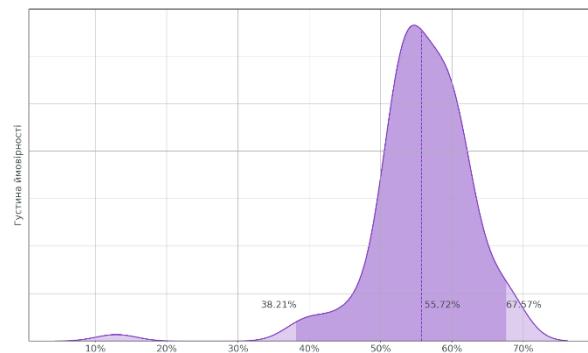


Рис. 5. Розподіл точності для класифікації з прогнозуванням робочого стану підшипників з іншого експерименту

Як можна побачити з результатами цього етапу — модель має здатність до генералізації, хоча кількісна міра якості не є задовільною для використання даної моделі у промисловості. На рисунку 6 показані значення точності та функції втрат при навчанні моделі на одній з підвиборок. На рисунку вказані як навчальна вибірка — набір прикладів, які нейронна мережа використовує для навчання, так і валідаційна вибірка. Так, ми можемо бачити, що модель перенавчається на навчальній вибірці, рішенням цьому може бути зменшення кількості параметрів моделі або збільшення набору даних.

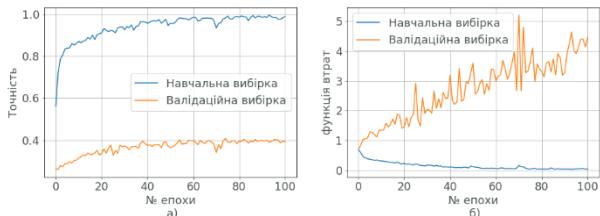


Рис. 6. Приклад графіків навчання моделей (а — навчальна та валідаційна точність, б — навчальне та валідаційне значення втрат)

Висновки. У даній роботі розглянуто побудову згорткової нейронної мережі для бінарної класифікації робочого стану підшипників кочення за кумулятивними ознаками сигналів їх віброприскорення. Даний тип архітектур нейронних мереж добре зарекомендував себе у задачах класифікації комплексних даних, таких як сигнали та зображення. Використання даних алгоритмів дає можливість уникнути етапу попереднього вибору простору ознак, який б найкращим чином відображав інформацію, яка міститься у сигналах віброприскорення підшипників, щодо їх робочого стану. Окремим приводом до використання даного типу архітектур є їх стійкість до зсуву фази сигналів, тобто побудовані за даним принципом архітектури є інваріантні до часу початку зняття вимірювань.

Ключовою особливістю даної роботи є використання згорткової нейронної мережі зі змінною дилатацією. Даний підхід використовується у випадках, коли очікувані ключові ознаки певного

об'єкту можуть мати значно різний розмір, тобто модель стає інваріантною до довжини ключових проміжків сигналу, за якими можна зробити висновок про робочий стан підшипників. На цьому етапі були використані сигнали у двох каналах - для вісі У підшипника з потенційним дефектом та вісі У підшипника без дефекту.

Так, оцінюючи здатність моделі до класифікації сигналів у рамках одного експерименту, отримана точність складає 83%. Аналіз генералізації показав точність 56%, що на 6% вище точності випадкового вгадування для двокласової збалансованої вибірки.

У ході дослідження був розроблений алгоритм масштабування сигналів віброприскорень для їх використання у згорткових нейронних мережах. Даний алгоритм передбачає масштабування амплітуд сигналів за орбітами елементів кочення підшипників, очищення спектрів від вищих частот та відновлення очищених сигналів на певній кількості періодів обертання валу. Даний підхід також дає можливість збалансувати вибірку даних, адже розбиття сирого сигналу може бути зроблено з перекриттям без проблеми повного копіювання певних ділянок сигналів.

Список літератури

- Sloukia F., Aroussi M. E., Medromi H., M. Wahbi. Bearings prognostic using Mixture of Gaussians Hidden Markov Model and Support Vector Machine. *2013 International Conference on Computer Systems and Applications (AICCSA)*. 2013, T. 1, C. 1-4, doi: 10.1109/AICCSA.2013.6616438.
- Magar R., Ghule L., Li J., Zhao Y., Farimani A. FaultNet: A Deep Convolutional Neural Network for Bearing Fault Classification. *2021 IEEE Access*. T. 9. C. 25189-25199. doi: 10.1109/ACCESS.2021.3056944.
- Shi X., Cheng Y., Zhang B., Zhang H. Intelligent fault diagnosis of bearings based on feature model and Alexnet neural network. *2020 IEEE International Conference on Prognostics and Health Management (ICPHM)*. T. 1. C. 1-6. doi: 10.1109/ICPHM49022.2020.9187051.
- Oord A., Dieleman S., Zen H., Simonyan K., Vinyals O., Graves A., Kalchbrenner N., Senior A., Kavukcuoglu K. WaveNet: A Generative Model for Raw Audio. *CoRR* 2016. C. 1-6. URL: arxiv:1609.03499 (дата звернення 21.12.2021)
- Mera-Gaona, M.; López, D.M.; Vargas-Canas, R. An Ensemble Feature Selection Approach to Identify Relevant Features from EEG Signals. *Appl. Sci.* 2021. T. 11. C. 1-17. doi: 10.3390/app11156983.
- El Mountassir M., Yaacoubi S., Ragot J., Mourot G., Maquin D. Feature selection techniques for identifying the most relevant damage indices in SHM using Guided Waves. *8th EWSHM jointly with the European Conference of the Prognostics and Health Management Society (PHME)*. м. Bilbao, Spain. 2016. C. 1-8
- Boonyakanont P., Lekuthai A., Chomtho K., Songsiri J. A review of feature extraction and performance evaluation in epileptic seizure detection using EEG. *Biomedical Signal Processing and Control*. 2020. T. 57. C. 1-28. doi: 10.1016/j.bspc.2019.101702
- Isaienkov K. *Bearing classification*. Kaggle. URL: <https://www.kaggle.com/isaienkov/bearing-classification> (дата звернення: 22.09.2021)
- Babudzhan, R., Isaienkov, K., Krasii, D., Melkonian, R., Vodka, O., Zadorozhniy, I., & Yushchuk, M. Collection and processing of bearing vibration data for their technical condition classification by machine learning methods. *Modeling Control and Information Technologies*. 2021. T. 5, C. 10–15. doi: 10.31713/mcit.2021.02
- R. Soto-Ocampo, J. Cano-Moreno, J. Mera, J. Maroto. Bearing severity fault evaluation using contour maps—case study / *C. Applied sciences*. 2021. T. 11, № 14. C. 2–30. doi: 10.3390/app11146452
- Oberst U. The Fast Fourier Transform. *SIAM Journal on Control and Optimization*. 2007. T. 46. №2. C. 496-540
- Lazli L., Boukadoum M. Hidden Neural Network for Complex Pattern Recognition: A Comparison Study with Multi- Neural Network Based Approach. *International Journal of Life Science and Medical Research*. (2013). No. 3. pp. 234-245. doi: 10.5963/LSMR0306003
- Hamaguchi R., Fujita A., Nemoto K., Imaizumi T., Hikosaka S. Effective Use of Dilated Convolutions for Segmenting Small Object Instances in Remote Sensing Imagery. *Computer Vision and Pattern Recognition. 2018 IEEE Winter Conference on Applications of Computer Vision (WACV)*. 2018. C. 1442-1450. doi:10.1109/wacv.2018.00162
- Wang, Z., & Ji, S. Smoothed Dilated Convolutions for Improved Dense Prediction. *Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*. 2018. C. 2486-2495. doi:10.1145/3219819.3219944
- Sulaiman M. Hossin M., A Review on Evaluation Metrics for Data Classification Evaluations. *International Journal of Data Mining & Knowledge Management Process*. T. 5. C. 1-11. doi: 10.5121/ijdkp.2015.5201.
- Janitz S., Hornung R. On the overestimation of random forest's out-of-bag error. *PLoS ONE*. T. 13. C. 2-19. doi: 10.1371/journal.pone.0201904
- Bruce P. and Bruce A. *Practical Statistics for Data Scientists: 50 Essential Concepts*. O'Reilly Media, 2017. 318 c.

References (transliterated)

- Sloukia F., Aroussi M. E., Medromi H., M. Wahbi. Bearings prognostic using Mixture of Gaussians Hidden Markov Model and Support Vector Machine. *2013 International Conference on Computer Systems and Applications (AICCSA)*. 2013, Vol. 1, pp. 1-4, doi: 10.1109/AICCSA.2013.6616438.
- Magar R., Ghule L., Li J., Zhao Y., Farimani A. FaultNet: A Deep Convolutional Neural Network for Bearing Fault Classification. *2021 IEEE Access*. Vol. 9. pp. 25189-25199. doi: 10.1109/ACCESS.2021.3056944.
- Shi X., Cheng Y., Zhang B., Zhang H. Intelligent fault diagnosis of bearings based on feature model and Alexnet neural network. *2020 IEEE International Conference on Prognostics and Health Management (ICPHM)*. Vol. 1. pp. 1-6. doi: 10.1109/ICPHM49022.2020.9187051.
- Oord A., Dieleman S., Zen H., Simonyan K., Vinyals O., Graves A., Kalchbrenner N., Senior A., Kavukcuoglu K. WaveNet: A Generative Model for Raw Audio. *CoRR* 2016. pp. 1-6. URL: arxiv:1609.03499 (accessed 21.12.2021)
- Mera-Gaona, M.; López, D.M.; Vargas-Canas, R. An Ensemble Feature Selection Approach to Identify Relevant Features from EEG Signals. *Appl. Sci.* 2021. Vol. 11. pp. 1-17. doi: 10.3390/app11156983.
- El Mountassir M., Yaacoubi S., Ragot J., Mourot G., Maquin D. Feature selection techniques for identifying the most relevant damage indices in SHM using Guided Waves. *8th EWSHM jointly with the European Conference of the Prognostics and Health Management Society (PHME)*. Bilbao, Spain. 2016. pp. 1-8.
- Boonyakanont P., Lekuthai A., Chomtho K., Songsiri J. A review of feature extraction and performance evaluation in epileptic seizure detection using EEG. *Biomedical Signal Processing and Control*. 2020. Vol. 57. pp. 1-28. doi: 10.1016/j.bspc.2019.101702
- Isaienkov K. *Bearing classification*. Kaggle. URL: <https://www.kaggle.com/isaienkov/bearing-classification> (accessed: 22.09.2021)
- Babudzhan, R., Isaienkov, K., Krasii, D., Melkonian, R., Vodka, O., Zadorozhniy, I., & Yushchuk, M. Collection and processing of bearing vibration data for their technical condition classification by machine learning methods. *Modeling Control and Information Technologies*. 2021. Vol. 5, P. 10–15. doi: 10.31713/mcit.2021.02
- R. Soto-Ocampo, J. Cano-Moreno, J. Mera, J. Maroto. Bearing severity fault evaluation using contour maps—case study / *C. Applied sciences*. 2021. Vol. 11, no. 14. P. 2–30. doi: 10.3390/app11146452
- Oberst U. The Fast Fourier Transform. *SIAM Journal on Control and Optimization*. 2007. Vol. 46. №2. C. 496-540
- Lazli L., Boukadoum M. Hidden Neural Network for Complex Pattern Recognition: A Comparison Study with Multi- Neural Network Based Approach. *International Journal of Life Science and Medical Research*. (2013). No. 3. pp. 234-245. doi: 10.5963/LSMR0306003

13. Hamaguchi R., Fujita A., Nemoto K., Imaizumi T., Hikosaka S. Effective Use of Dilated Convolutions for Segmenting Small Object Instances in Remote Sensing Imagery. Computer Vision and Pattern Recognition. *2018 IEEE Winter Conference on Applications of Computer Vision (WACV)*. 2018. pp. 1442-1450. doi:10.1109/wacv.2018.00162
14. Wang, Z., & Ji, S. Smoothed Dilated Convolutions for Improved Dense Prediction. *Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*. 2018. pp. 2486-2495. doi:10.1145/3219819.3219944
15. Sulaiman M. Hossin M. A Review on Evaluation Metrics for Data Classification Evaluations. *International Journal of Data Mining & Knowledge Management Process*. Vol. 5. P. 1-11. doi: 10.5121/ijdkp.2015.5201.
16. Janitz S., Hornung R. On the overestimation of random forest's out-of-bag error. *PLoS ONE*. Vol. 13. P. 2-19. doi: 10.1371/journal.pone.0201904
17. Bruce P. and Bruce A. *Practical Statistics for Data Scientists: 50 Essential Concepts*. O'Reilly Media, 2017. 318 p.

Надійшла (received) 25.12.2021

Відомості про авторів / Сведения об авторах / About the Authors

Бабуджан Руслан Андрійович — Національний Технічний Університет «Харківський Політехнічний Інститут», студент кафедри динаміки та міцності машин; м. Харків, Україна; ORCID: <https://orcid.org/0000-0001-5765-9234>, e-mail: ruslanbabudzhan@gmail.com

Ісаєнков Константин Олександрович — інженер, Quantum Inc.; м. Харків, Україна; ORCID: <https://orcid.org/0000-0001-5266-7040>; e-mail: k.isaienkov@quantummobile.com

Красій Данило Максимович — Національний технічний університет «Харківський політехнічний інститут», студент; м. Харків, Україна; ORCID: <https://orcid.org/0000-0003-1599-2295>, e-mail: krasiydm@gmail.com

Водка Олексій Олександрович — кандидат технічних наук, доцент, Національний технічний університет «Харківський політехнічний інститут»; м. Харків, Україна; ORCID: <https://orcid.org/0000-0002-4462-9869>; e-mail: Oleksi.vodka@gmail.com

Задорожний Іван В'ячеславович — Національний Технічний Університет «Харківський Політехнічний Інститут», аспірант кафедри динаміки та міцності машин; м. Харків, Україна; ORCID: <https://orcid.org/0000-0002-6952-3024>, e-mail: Ivan.Zadorozhniy@khpi.edu.ua

Ющук Михайло Вікторович — інженер, Quantum Inc; м. Харків, Україна.; ORCID: <https://orcid.org/0000-0002-2618-0893>, e-mail: m.yushchuk@quantummobile.com

Бабуджан Руслан Андрійович — Национальный технический университет «Харьковский политехнический институт», студент кафедры динамики и прочности машин; г. Харьков, Украина; ORCID: <https://orcid.org/0000-0001-5765-9234>, e-mail: ruslanbabudzhan@gmail.com

Исаенков Константин Александрович — Quantum Inc., инженер; г. Харьков, Украина; ORCID: <https://orcid.org/0000-0001-5266-7040> e-mail: k.isaienkov@quantummobile.com

Красій Данил Максимович — Национальный технический университет «Харьковский политехнический институт», студент кафедры динамики и прочности машин; г. Харьков, Украина; ORCID: <https://orcid.org/0000-0003-1599-2295>, e-mail: krasiydm@gmail.com

Водка Алексей Александрович — кандидат технических наук, доцент, Национальный технический университет «Харьковский политехнический институт»; г. Харьков, Украина; ORCID: <https://orcid.org/0000-0002-4462-9869>; e-mail: Oleksi.vodka@gmail.com

Задорожный Иван Вячеславович — Национальный Технический Университет "Харьковский Политехнический Институт", аспирант кафедры динамики и прочности машин; г. Харьков, Украина; ORCID: <https://orcid.org/0000-0002-6952-3024>, e-mail: Ivan.Zadorozhniy@khpi.edu.ua

Ющук Михаил Викторович — Quantum Inc., инженер; г. Харьков, Украина; ORCID: <https://orcid.org/0000-0002-2618-0893>, e-mail: m.yushchuk@quantummobile.com

Babudzhan Ruslan Andriovich — National Technical University "Kharkiv Polytechnic Institute", student of the Department of Dynamics and Strength of Machines; Kharkiv, Ukraine; ORCID: <https://orcid.org/0000-0001-5765-9234>, e-mail: ruslanbabudzhan@gmail.com

Isaienkov Konstantyn Oleksandrovich — Quantum Inc., engineer; Kharkiv, Ukraine; ORCID: <https://orcid.org/0000-0001-5266-7040>; e-mail: k.isaienkov@quantummobile.com

Krasiy Danilo Maksimovich — National Technical University "Kharkov Polytechnic Institute", student of the Department of Dynamics and Strength of Machines; Kharkiv, Ukraine; ORCID: <https://orcid.org/0000-0003-1599-2295>, e-mail: krasiydm@gmail.com

Vodka Oleksi Oleksandrovich — Candidate of Technical Sciences, Associate Professor, National Technical University "Kharkiv Polytechnic Institute"; Kharkiv, Ukraine; ORCID: <https://orcid.org/0000-0002-4462-9869>; e-mail: Oleksi.vodka@gmail.com

Zadorozhny Ivan Vyacheslavovich — National Technical University "Kharkov Polytechnic Institute", post-graduate student of the Department of Dynamics and Strength of Machines; Kharkiv, Ukraine; ORCID: <https://orcid.org/0000-0002-6952-3024>, e-mail: Ivan.Zadorozhniy@khpi.edu.ua

Yushchuk Michael Viktorovich — Quantum Inc., engineer; Kharkiv, Ukraine; ORCID: <https://orcid.org/0000-0002-2618-0893>, e-mail: m.yushchuk@quantummobile.com