

Баженов В.Г.

Національний технічний університет України
«Київський політехнічний інститут імені Ігоря Сікорського»

Калениченко Ю.О.

Національний технічний університет України
«Київський політехнічний інститут імені Ігоря Сікорського»

Рацбарський С.С.

Національний технічний університет України
«Київський політехнічний інститут імені Ігоря Сікорського»

ВИКОРИСТАННЯ НЕЙРОННИХ МЕРЕЖ ДЛЯ ВИЗНАЧЕННЯ ТВЕРДОСТІ СТАЛЕВИХ ЗРАЗКІВ СТРУКТУРОСКОПОМ НА БАЗІ ВИЩИХ ГАРМОНІК

У статті розглянуто можливість використання регресійних штучних нейронних мереж для визначення твердості сталевих зразків вихрострумовим структуроскопом на базі методу вищих гармонік. Обґрунтовано доцільність використання нейронних мереж для обробки результатів вимірювання структуроскопу, проведено аналіз наукових надбань за темою дослідження, визначено задачу дослідження, яка полягає в аналізі таких структурних елементів та характеристик штучних нейронних мереж, як архітектура, функція втрат, оптимізатор.

Описано модель вихрострумового структуроскопа, який використовувався для набору вибірки даних. Визначена проблема використання кутів в якості вхідних параметрів нейронних мереж та запропоновано метод уникнення цієї проблеми. Проаналізовано основні типи штучних нейронних мереж для задач регресії та обґрунтовано вибір фідфорвард типу. Проведено аналіз лосс функцій для нейронної мережі, обґрунтовано вибір середньоквадратичної похибки в якості лосс функції. Проведено аналіз оптимізатора для нейронної мережі, обґрунтовано вибір оптимізатора Adam. Було описано використання вибірки даних та як вона була розбита на тренувальну, тестову та валідаційну множини.

Визначено декілька потенційно робочих варіантів архітектури нейронної мережі. Для кожного з варіантів було створено мережу з відповідною архітектурою та проведено навчання та тестування отриманих мереж на реальних протестованих зразках з відомою твердістю за шкалою С методу Роквеллу. Визначено середньоквадратичну та середню абсолютну похибку регресії для чотирьох варіантів архітектури. Було сформовано рекомендації щодо подальшого використання методу.

Ключові слова: вихрострум, структуроскопія, штучні нейронні мережі, твердість, регресія.

Постановка проблеми. Структуроскопія – це дуже важлива галузь промисловості, яка дозволяє знаходити й попереджувати появу дефектів, прогнозувати ресурс роботи виробів, визначати їх механічні характеристики.

Відомо що найбільш інформативною серед фізичних неруйнівних методів є вихрострумова структуроскопія на базі методу вищих гармонік, яка дозволяє отримати велику кількість інформативних ознак, до яких входять результати вимірювань амплітуди та фази не тільки першої гармоніки, але й вищих, до дев'ятої включно при покроковій зміні сигналу збудження первинної катушки. Подібні системи потребували використання великого парку вимірювальних приладів (включаючи фазометри),

що значно обмежувало, або робило неможливим використання цього методу і також унеможливило його автоматизацію. Проте розвиток мікроелектронних систем за останні роки, таких як ПЛС (FPGA), швидкодіючі аналогово-цифрові та цифроаналогові перетворювачі, зробило їх доступними для масового комерційного використання, що дозволило авторам статі створити автоматичну цифрову систему структуроскопії на базі методу вищих гармонік, яка дозволяє автоматично отримувати цифровий масив даних і будувати графіки змін амплітуд і фаз контролюємих гармонік в залежності від амплітуди збуджуючого сигналу катушки

Проте, аналіз отриманих значень амплітуд та фаз гармонік сигналу відгуку все ще є надзви-

чайно складною проблемою, яка потребує високої кваліфікації оператора та часу на обробку, що унеможливило їх використання в поточному контролі.

Отримані значення амплітуд та фаз гармонік сигналу відгуку є цифровими значеннями, що дає можливість використання штучних нейронних мереж для їх аналізу. Це дозволить зменшити необхідну кваліфікацію оператора або зовсім його замінити, підвищить швидкість неруйнівного контролю, дозволить проведення поточного контролю замість вибіркового. Все це підвищує надійність продукту та зменшує собівартість виробництва.

Аналіз останніх досліджень та публікацій.

Аналіз наукових надбань за темою дослідження показав, що вихрострумові методи неруйнівного контролю є досить розповсюдженими в задачах контролю стану матеріалів. Багато досліджень [1] [2], використовують вихрострумові методи виключно для знаходження дефектів, що вже утворилися, проте зустрічаються дослідження, які використовують [3] вихрострумові методи для поточного контролю структури та передбачення утворення дефектів, або розглядають [4] можливість використання вихрострумових методів для аналізу процесу термічної обробки сталі.

Дослідження щодо використання нейронних мереж в сукупності з вихрострумовими методами

також існують [5] [6] [7], але вони всі використовують нейронні мережі для характеризування та класифікації дефектів.

В цій статті розглядається можливість використання нейронних мереж в зв'язку з вихрострумовим методом вищих гармонік для визначення механічного параметру твердості сталевих зразків. В літературі на сьогоднішній день не виявлено таких досліджень.

Постановка завдання. Метою статті є аналіз можливості використання нейронних мереж для визначення твердості сталевих зразків під час дослідження них вихрострумовим структуроскопом на базі вищих гармонік. Поставлена мета передбачає необхідність аналізу та обґрунтування вибору архітектури, функції втрат та оптимізатора, практична перевірка роботи моделі нейронної мережі на реальних даних.

Виклад основного матеріалу. В якості структуроскопу, який використовувався для вимірювання сталевих зразків було використано модель, розроблену та запатентовану командою, до якої входять автори статті [8]. Цей структуроскоп дозволяє швидко визначати амплітуди та фази непарних гармонік з першої до дев'ятої з довільно заданою частотою та амплітудою збуджувального сигналу. Вимірювання, що використовувалися для експериментів, було проведено на частоті 5 кГц та амплітудою збуджувального сигналу 23 В.

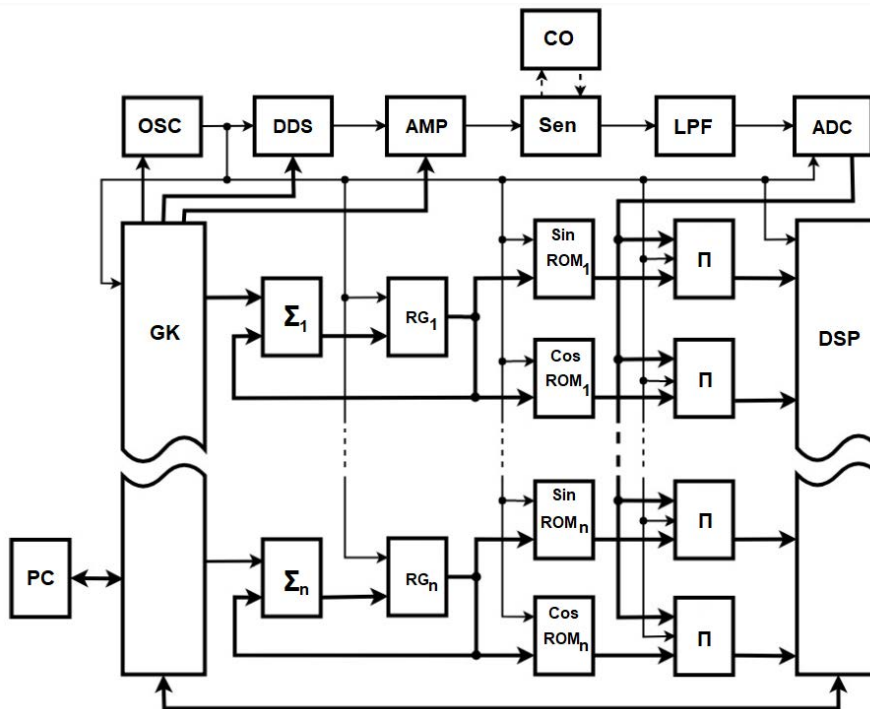


Рис. 1. Функціональна схема системи

На кресленні рис. 1 зображена функціональна схема системи. Схема містить генератор частоти дискретизації OSC, синтезатор тестового сигналу DDS, керований підсилювач потужності AMP, перетворювач тестового сигналу Sen, фільтр нижніх частот LPF, аналогово-цифровий перетворювач ADC, блок керування GK, цифрові суматори сигналів Σ , регістри пам'яті RG, постійні запам'ятовуючі пристрої ROM, помножувачі П, цифровий блок обробки сигналів DSP, персональний комп'ютер PC, об'єкт контролю CO.

В якості даних було використано амплітуди та фази перших п'яти непарних гармонік. Проте, постає проблема використання кута в нейронній мережі, яка полягає в тому, що кут в градусах визначається дійсним числом між 0 та 360, але геометрично 0 та 360 це одне й те саме. Але якщо використовувати кут як стандартне дійсне число то нейронна мережа зробить висновок, що 0 та 360 є дуже різними значеннями, які максимально віддалені одне від одного. Це призведе до того, що передбачення, які використовують ці екстремуми, будуть значно менш точними.

Одним з методів вирішення цієї проблеми є представлення кута φ як пари значень $\sin(\varphi)$, $\cos(\varphi)$. Таке представлення вирішує три проблеми: забезпечує, що значення 0 та 360 є однаковими, нормалізує значення вхідних даних до діапазону $[-1; 1]$, та дозволяє роботу з кутами менше 0 та більше 360 через періодичність функцій представлення. Таким чином представлення кута у вигляді двох змінних збільшує розмір вхідного шару з 10 до 15 нейронів, але вирішує проблеми циклічності, нормалізації та обгортки.

В результаті аналізу було встановлено, що для вирішення задач регресії використовується три основних типи нейронних мереж:

1. Фідфорвард (Feedforward) нейронна мережа – найпростіший тип штучної нейронної мережі, яка передає інформацію лише у одному напрямку, від вхідного шару до вихідного шару, без зворотного зв'язку. Це означає, що дані поширюються через мережу без циклічних залежностей.

2. Згорткова нейронна мережа (Convolutional Neural Network, CNN) – цей тип мережі часто використовується для обробки зображень. Вона має спеціальні шари, в яких здійснюється операція згортки, яка дозволяє виявляти просторові шаблони у вхідних даних. CNN здатна автоматично витягати корисні ознаки з зображень і використовувати їх для нелінійної регресії.

3. Рекурентна нейронна мережа (Recurrent Neural Network, RNN): Цей тип мережі підходить

для роботи з послідовними даними, такими як текст або часові ряди. Вона має зв'язки, які дозволяють інформації передаватися від попередніх кроків до наступних. RNN може запам'ятовувати попередні стани і використовувати їх для моделювання складних залежностей в послідовних даних.

Виходячи з того, що дані, які ми використовуємо, є табличними (tabular data), та не є послідовними, було зроблено висновок, що рекурентна та згорткові моделі нам не підходять. Таким чином, ми використовували фідфорвард модель для проведення аналізу.

В фідфорвард нейронній мережі для задач регресії архітектура може варіюватися в залежності від різних факторів, таких як складність задачі, обсяг даних та складність функції, яку намагається наблизити мережа. Відомо, що підвищення кількостей прихованих прошарків та нейронів в них зазвичай підвищує точність, але їх збільшення не тільки підвищує час на навчання, але й може призвести до перенавчання та погіршення апроксимуючих властивостей мережі. Саме тому остаточна архітектура мережі підбиралась емпірично, виходячи з точності, яку бажано отримати.

Важливим кроком під час синтезу моделі є вибір лосс функції, також відомої як функції втрат. Ця функція вимірює рівень помилки, під якою розуміється різниця між прогнозованими значеннями моделі та справжніми значеннями цільової змінної. В контексті машинного навчання вона використовується як квантифікатор того, наскільки модель добре виконує свою задачу та її мінімізація є основною метою тренування моделі. Відомо, що в задачах регресії є три найбільш популярних лосс функції:

1. Mean squared error (MSE) – середньоквадратична похибка.

2. Mean absolute error (MAE) – середня абсолютна похибка.

3. Huber loss – лосс функція, яка поєднує між собою переваги MSE та MAE. Вона розраховує MSE за замовчуванням, проте має параметр границі, і якщо MSE перевищує цю границю то значення функції втрат натомість розраховується через MAE.

Середньоквадратична функція втрат має перевагу в тому, що зі збільшенням абсолютної помилки визначення параметру лосс функція збільшується експоненційно, що призводить до значного більшого впливу окремих великих неточностей або викидів на результат тренування. В задачі визначення твердості викиди є досить

небажаним феноменом, отже видається доцільним вибір середньоквадратичної функції втрат. Під час тренування також була використана метрика середньої абсолютної похибки для оцінки розподілу похибок нейронної мережі.

Вибір оптимізатора також є дуже важливим кроком під час синтезу моделі. Відомо, що оптимізатор – це алгоритм, за яким ваги та зсуви моделі змінюються для зменшення лосс функції під час тренування. В результаті аналізу, виходячи з поставленої задачі, було визначено декілька оптимізаторів, що можуть використовуватися під час задач регресії:

1. Gradient Descent (Градiєнтний спуск): Це один з найпростіших та базових методів оптимізації. Градiєнтний спуск оновлює параметри моделі в напрямку, протилежному градiєнту лосс функції. Існує кілька варіантів градiєнтного спуску, таких як стохастичний градiєнтний спуск (SGD) та міні-пакетний градiєнтний спуск (Mini-batch GD).

2. RMSprop (Root Mean Square Propagation): RMSprop використовує експоненційно згладжений середньоквадратичний градiєнт для оновлення параметрів. Він відповідає на проблему градiєнтного спуску, де великі градiєнти можуть призводити до малих оновлень параметрів.

3. Adam (Adaptive Moment Estimation): Adam є популярним методом оптимізації, який комбiнує ідеї з методів градiєнтного спуску та RMSprop. Він використовує зважену комбiнацію моменту градiєнту та квадратів градiєнту для оновлення параметрів моделі.

4. Adagrad (Adaptive Gradient Algorithm): Adagrad адаптивно налаштовує швидкість навчання для кожного параметра залежно від його історичного градiєнту. Він добре підходить для розріджених даних, де навчання може бути сконцентроване на рідкісних ознаках.

Проаналізувавши наведені оптимізатори, видається доцільним використання оптимізатора Adam[9] через його поєднання переваг методів градiєнтного спуску та RMSProp. Adagrad було відкинуто через те, що наші дані не є розрідженими, а отже його основна перевага не є актуальною для нашої проблеми.

Дані для навчання було набрано на наборі з 9 сталевих зразків, зображених на рис. 2, які було досліджено на твердість за Роквеллом за шкалою C. Вони мали твердість між 250 та 560 одиниць.

Кожен зі зразків було виміряно 400 разів, що дає нам вибірку даних в 3600 точок. Така вибірка відповідає принципу різноманітності, який потребує щоб різні значення передбачуваної величини

були представлені в виборці приблизно в однакових пропорціях.




Рис. 2. Сталеві зразки

Відомо, що важливою складовою під час навчання нейронних мереж є перенавчання, яке пов'язане з занадто точним відтворенням тренувальних даних [10]. Це призводить до збільшення помилки та втрати узагальнюючих можливостей. З метою вирішення цієї проблеми вибірку було розбито на дві множини: навчальну та тестову. Навчання проводиться лише на навчальній множині, а тестова використовується для перевірки узагальнюючих можливостей мережі. Дані цих множин не перетинаються. Також під час навчання на кожному з кроків виділяється так звана валідаційна множина. На кожному з етапів навчання вона автоматично та випадковим чином відкидається з тренувальної множини з метою запобігання перенавчанню та поточної перевірки роботи мережі.

Архітектура нейронної мережі визначається емпірично. Виходячи з складності задачі, було запропоновано такі характеристики:

- Кількість прихованих прошарків N_l – 2 або 3.
- Кількість нейронів в кожному прихованому прошарку N_p – 64 або 128.

Експерименти, проведені з цими архітектурами, дозволять більш точно визначити напрямок подальших досліджень архітектури. Навчання кожної з архітектур було проведено на однаковій кількості в 400 епох.

Для кожної архітектури було навчено по п'ять мереж, з яких обрано найкращі за показником середньоквадратичної помилки. Результати навчання мереж різних архітектур наведено в таблиці 1.

Таблиця 1
Ефективність навчених моделей в залежності від архітектури

Архітектура	$N_i=2$	$N_i=2$	$N_i=3$	$N_i=3$
	$N_p=64$	$N_p=128$	$N_p=64$	$N_p=128$
MSE	185,32	62,487	46,774	14,476
MAE	10,306	5,208	5,884	2,807

Як видно з табл. 1 найменшу похибку має найбільш складна архітектура. Використання тестового та валідаційного масивів даних значно зменшує можливість перетренування. Менш складні архітектури мають занадто велику похибку щоб їх використовувати. Це дозволяє дати рекомендацію використовувати щонайменше 3 прихованих прошарки з щонайменше 128 нейронами в кожному. Збільшення цих характеристик може призвести до підвищення точності, але тоді перетренування стане більш актуальною проблемою, яка буде потребувати окремих кроків для вирішення.

Висновки. У роботі досліджена можливість реалізації визначення твердості сталевих зразків на результатах вихрострумовею контролю методом вищих гармонік за допомогою штучних нейронних мереж. Було проаналізовано та запропоновані найбільш оптимальні архітектури, лосс-функцію та оптимізатор для проведення регресії, навчено моделі. Вперше запропонована модель яка досягла середньоквадратичної похибки в 14,476 одиниць та середньої абсолютної в 2,807 одиниць за Роквеллом за шкалою С. Враховуючи, що використані для тренування зразки мали діапазон між 250 та 560 одиниць твердості, отриманий результат є дуже гарним та доводить можли-

вість використання штучних нейронних мереж для аналізу твердості за результатами вихрострумовею структуроскопії на базі методу вищих гармонік. Враховуючи, що людина-оператор може визначати твердість лише наближено та потребує величезного досвіду роботи та часу на аналіз інформації, регресійна нейронна мережа визначає твердість дуже точно та швидко. Результати експерименту дають можливість сформулювати рекомендації щодо архітектур нейронних мереж для подальшого розвитку методу. Натренована модель машинного навчання інтегрована в систему запропонованого авторами цифрового структуроскопа на базі вищих гармонік та використовується для визначення твердості за період часу, що не перевищує 5–10 секунд. Перспективи подальших досліджень ґрунтуються на збільшенні виборки інформації, збільшенні кількості зразків з різними твердостями для розширення шкали, збільшення точності та покращення узагальнюючих властивостей нейронних мереж. Також розглядається можливість використання аналогічного методу регресії за допомогою штучних нейронних мереж для визначення інших механічних, структурно-хімічних та електромагнітних характеристик сталі. На сьогоднішній день в світі відсутні аналоги подібних систем. Частина досліджень по впровадженню штучного інтелекту в систему виконується за рахунок європейського гранту за Рамковою програмою досліджень та інновацій Horizon 2020 Європейської комісії, другого відкритого конкурсу «DII-World — Прискорення розгортання та зрілості DII на користь оцифрування європейських МСП», Grant Agreement № 952176, отриманого авторами проекту

Список літератури:

1. Janovec, M., Bugaj, M., & Smetana, M. Eddy current array inspection of riveted joints. *Transportation Research Procedia*, №43, pp. 48-56, 2019.
2. Krysztofik, J., & Malicki, M. Detection of Sub-Surface Defects in Semi-Finished Products from Aluminum Alloys by the Eddy Current Method. *Fatigue of Aircraft Structures*, 2021(13), pp. 31-39, 2021.
3. Butusova, Y. N., Mishakin, V. V., & Kachanov, M. On monitoring the incubation stage of stress corrosion cracking in steel by the eddy current method. *International Journal of Engineering Science*, №148, 103212, 2020
4. Beneš, P., Průcha, V., Hájek, J., & Vítovec, V. Possibility of Using Eddy Current Evaluation of the Heat Treatment of Steel. 2019
5. Kuzmin, E. V., Gorbunov, O. E., Plotnikov, P. O., Tyukin, V. A., & Bashkin, V. A. Application of neural networks for recognizing rail structural elements in magnetic and eddy current defectograms. *Automatic Control and Computer Sciences*, №53, pp 628-637, 2019.
6. Rosado, L. S., Janeiro, F. M., Ramos, P. M., & Piedade, M. Defect characterization with eddy current testing using nonlinear-regression feature extraction and artificial neural networks. *IEEE Transactions on Instrumentation and Measurement*, №62(5), pp. 1207-1214, 2013.
7. Alvarenga, T. A., Carvalho, A. L., Honorio, L. M., Cerqueira, A. S., Filho, L. M., & Nobrega, R. A. Detection and classification system for rail surface defects based on Eddy current. *Sensors*, №21(23), 7937, 2021.
8. Патент України на винахід №125416 UA МПК (2022.01) G01N27/72 (2006.01) G01N27/90(2021.01), G01R33/12(2006.01), G01N27/00, G01R33/00 Цифровий спосіб і система визначення структури матеріалу об'єкта / Баженов В.Г., Калениченко Ю.О., Калениченко О.Г., Баженов В.В./ від 03.03.2023, Бюл. №9 від 02.03.2023, Номер заявки а2020 02552 від 23.04.2020.

9. Kingma, D. P., & Ba, J. Adam: A method for stochastic optimization. arXiv preprint arXiv:1412.6980, 2014.
10. Hawkins, D. M. The problem of overfitting. Journal of chemical information and computer sciences, № 44(1), pp. 1-12, 2004.

Bazhenov V.G., Kalenychenko Y.O., Ratsebarskyi S.S. USING NEURAL NETWORKS FOR DETERMINATION OF HARDNESS OF STEEL SAMPLES WITH A STRUCTUROSCOPE BASED ON HIGHER HARMONICS

The article considers the possibility of using regression artificial neural networks to determine the hardness of steel samples by using an eddy current structuroscope based on the method of higher harmonics. The expediency of using neural networks for processing the measurement results of the structuroscope is substantiated, the analysis of scientific assets on the topic of the study is carried out, the research task is defined, which consists in the analysis of such structural elements and characteristics of artificial neural networks as architecture, loss function, optimizer.

The model of the eddy current structuroscope, which was used for data collection, is described. The problem of using angles as input parameters of neural networks is defined and a method of avoiding this problem is proposed. The main types of artificial neural networks for regression problems were analyzed and the choice of the feedforward type was justified. The analysis of loss functions for the neural network was carried out, the selection of the root mean square error as the loss function was justified. The analysis of the optimizer for the neural network was carried out, the choice of the Adam optimizer was justified. The data set used and how it was split into training, test, and validation sets were described.

Several potentially working variants of neural network architecture have been identified. For each of the options, a network with the appropriate architecture was created, and the resulting networks were trained and tested on real tested samples with known hardness according to the C scale of the Rockwell method. The root mean square and mean absolute error of the regression were determined for four architecture options. Recommendations for further use of the method were formed.

Key words: eddy current, structuroscopy, artificial neural networks, hardness, regression.