

Використання штучного інтелекту в задачах неруйнівного контролю

Д. В. Паренюк¹, О. П. Івко¹, А. В. Паренюк¹

¹*КПІ ім. Ігоря Сікорського, Київ, Україна*

pdv091943-ames@l111.kpi.ua

Анотація

У приведеній роботі показано використання методів штучного інтелекту для задач неруйнівного контролю. На прикладі виявлення та класифікації дефектів у моделі рейки Р50 було використано алгоритм «найближчого сусіда» для навчання нейромережі в середовищі JASP, який показав високу ефективність розпізнавання дефектів. Для оптимізації обробки даних було застосовано вторинні характеристики вибірок. Було проведено верифікацію отриманих результатів шляхом використання статистичних критеріїв, котра підтвердила високу ефективність застосування штучного інтелекту у автоматизації процесу неруйнівного контролю.

Ключові слова: штучний інтелект; неруйнівний контроль; акустика; статистичний аналіз.

Машинне навчання є одним із способів застосування штучного інтелекту у сучасній промисловості, яке базується на виявленні закономірностей у даних, котрі розглядаються. Алгоритми машинного навчання можуть відрізнятися між собою, однак загалом вони навчаються на сотнях та тисячах прикладів. Існує багато моделей штучного інтелекту, що застосовують методику «проб і помилок». Основою машинного навчання є застосування нейронних мереж - комп'ютерних систем, які базуються на використанні математичних моделей. Ці моделі застосовують у своїй роботі велику кількість моделей нейронів, котрі беруть за основу людські. У неруйнівному контролі однією із основних задач є не просто виявлення дефекту, а й його класифікація. Це може виконуватись як людиною оператором, так і спеціально навченим на відповідних даних штучним інтелектом (машиною).

Для того, щоб провести навчання машини (штучного інтелекту) необхідно надати їй для навчання набір даних, що містять у своєму складі характеристики різних груп об'єктів, котрі досліджуються. Для використання підходять як первинні (отримані напряму під час дослідження або вимірювання) так і вторинні (отримані під час обробки масиву даних статистичними або математичними методами).

У наведеній роботі у якості первинного масиву даних використовуються вимірювання, виконані на моделі рейки Р50, що наявна на базі кафедри АМЕС. У

цій моделі розглядалися сигнали від наявних у моделі рейки болтового отвору та пропили біля нього. Отримані результати були зведені у вибірки. Загалом було отримано 30 вибірок. Кожна вибірка являє собою 12 значень глибини (відстані до отвору чи пропили) та встановленого у налаштуваннях приладу підсилення, знятих на кожному міліметрові області вимірювань. Вимірювання виконувались перетворювачем П121-2.5-45-М-003 та дефектоскопом УДЗ-71. Важливою перевагою використання вторинних даних (у розглянутому випадку - мінімальне, максимальне та середнє значення кожної із вибірок) є менший об'єм досліджуваних даних - тобто зменшення вимог до пристроїв, що обробляють отримані дані та спрощення загальної будови приладів, особливо при обробці великих масивів даних для роботи з протяжними дефектами.

Робота із нейромережею була виконана у програмі JASP, де було розглянуто метод «найближчого сусіда» для навчання нейромережі. Цей метод працює порівнюючи нові дані із тим масивом, що вже відомий навченій машині. Були використані вторинні данні для болтового отвору та пропили. У методі використувався параметр $k=2$, тобто алгоритм визначав два найближчих зразки за двома найближчими параметрами. Результат роботи показав стовідсоткову ефективність навчання нейромережі, що показано на Рис 1.

	DepthMEAN	dBMEAN	Results of testing
1	84.858	53.75	Sawed
2	87.12	57.3	Sawed
3	86.63	57.2	Sawed
4	87.58	56.2	Sawed
5	87.04	56	Sawed
6	87.66	57.2	Sawed
7	81.28	54.9	Sawed
8	84.17	56.4	Sawed
9	81.28	56.4	Sawed
10	82.8	56.1	Sawed
11	106.827	56.256	BoltHole
12	107.387	56.254	BoltHole
13	105.498	56.466	BoltHole
14	107.401	56.265	BoltHole
15	105.901	56.321	BoltHole
16	105.458	56.433	BoltHole
17	105.067	56.303	BoltHole
18	104.945	56.237	BoltHole
19	105.661	56.479	BoltHole
20	105.802	56.465	BoltHole
21	105.273	56.419	BoltHole
22	106.482	56.423	BoltHole
23	87.746	54.796	Sawed

Рис. 1: Отримані результати навчання нейромережі.

Також була виконана перевірка отриманих результатів шляхом використання статистичних критеріїв [1]. Було застосовано параметричний критерій Стюдента (Т-тест) із застосуванням формули (1), де

$$t = \frac{\bar{X}_1 - \bar{X}_2}{\sqrt{s_p^2 \left(\frac{1}{n_1} + \frac{1}{n_2} \right)}} \quad (1)$$

- $\bar{X}_1, \bar{X}_2$ — середні значення двох вибірок,
- s_p^2 — зведена оцінка дисперсії, яка обчислюється за формулою (2):

$$s_p^2 = \frac{(n_1 - 1)s_1^2 + (n_2 - 1)s_2^2}{n_1 + n_2 - 2} \quad (2)$$

де:

- s_1^2, s_2^2 — вибіркові дисперсії,
- n_1, n_2 — обсяги вибірок.

що показав наявність статистично значимої різниці між групами результатів для різних дефектів. Можливість використання цього критерію було досліджено шляхом, показаним у роботі [2]. Характер розподілу величин у вибірці при цьому наведено на Рис 2.

Застосування статистичних методів аналізу показало високу точність навчання нейромережі та підтвердило можливість її застосування для ідентифікації дефектів різних типів.




Рис. 2: Характер розподілу даних у вибірці

Перелік посилань

- [1] Orcan F. (2020). Parametric or Non-parametric: Skewness to Test Normality for Mean Comparison. *Int. J. Assess. Tools Educ.*, vol 7, no 2, pp 255–265.
- [2] Паренюк Д. В. (2023). Алгоритм встановлення характеру розподілу значень у вибірці малого розміру. *XIX Міжнародна наукова конференція імені академіка Михайла Кравчука, Тези доповідей*, pp. 182–183.