

ПРОГНОЗУВАННЯ ДІАГРАМ ВТОМНОГО РУЙНУВАННЯ АЛЮМІНІЄВОГО СТОПУ Д16Т МЕТОДАМИ МАШИННОГО НАВЧАННЯ

І. С. Дідич, О. А. Пастух, О. П. Ясній, Ю. І. Пиндус, Н. С. Луцик,
В.К. Зеленський

Тернопільський національний технічний університет імені Івана Пулюя, Україна

Abstract. The methods of machine learning (neural networks, boosted trees and random forests) were used to predict the fatigue crack growth diagrams in an aluminium D16T alloy under regular loading at stress ratio $R = 0, 0.2, 0.4, 0.6$. The obtained results are in good agreement with the experimental data. The neural network method gives the least prediction error.

Втому матеріалів необхідно враховувати, для того, щоб правильно оцінити довговічність та залишкову довговічність важливих елементів конструкцій. Особливо актуальною задачею є прогнозування впливу режимів навантаження на поширення втомних тріщин. Одним із підходів до вирішення цього завдання є використання методів машинного навчання, зокрема, нейронних мережі (НМ).

Відомо, що розмах коефіцієнта інтенсивності напруження (КІН) $\Delta K = K_{\max} - K_{\min}$ є одним з основних параметрів, які контролюють швидкість росту втомної тріщини (РВТ) [1 – 3]. Тут K_{\max}, K_{\min} – найбільший та найменший КІН циклу навантаження, відповідно. Швидкість РВТ істотно залежить від коефіцієнта асиметрії циклу навантаження $R = K_{\min} / K_{\max}$ [4].

РВТ на середньоамплітудній ділянці діаграми втомного руйнування (ДВР) можна описати рівнянням Уокера [5]:

$$\frac{da}{dN} = C \left[(1-R)^{m-1} \Delta K \right]^n, R \geq 0, \quad (1)$$

де C, m, n – параметри матеріалу, які визначають з експерименту, N – кількість циклів навантаження; a – довжина тріщини як функція від N .

З літератури відомо велику кількість моделей, які описують всі ділянки ДВР, зокрема рівняння NASGRO [6]:

$$\frac{da}{dN} = C_1 \left[\Delta K_{eff} \right]^{n_1} \frac{\left[1 - \frac{\Delta K_{th}}{\Delta K_{eff}} \right]^p}{\left[1 - \frac{K_{\max}}{K_{Jc}} \right]^q} \quad (2)$$

де C_1, n_1, m, p, q – параметри, які визначають з експерименту; $\Delta K_{eff} = K_{\max} - K_{op}$ – ефективний розмах КІН; K_{op} – КІН розкриття тріщини; ΔK_{th} – пороговий КІН; K_{Jc} – критичний КІН за статичного навантаження, який визначають через критичний J_{Ic} – інтеграл.

Метою даного дослідження є спрогнозувати ДВР в алюмінієвому стопі Д16Т за регулярного навантаження.

Для розв'язування задач механіки, зокрема прогнозування довговічності елементів конструкцій, застосовували найбільш універсальні та ефективні алгоритми навчання з учителем, такі як нейронні мережі (Neural networks), зростаючі дерева (Boosted trees) та випадкові ліси (Random forests). Ідея останніх двох методів полягає у побудові ансамблю з певної кількості дерев прийняття рішень, які навчаються незалежно один від одного. Підсумковий результат приймають голосуванням всіх дерев, що входять до складу ансамблю. Серед переваг цих методів виділяють високу якість прогнозування та здатність ефективно обробляти дані [7]. Натомість, нейронна мережа – це послідовність нейронів, з'єднаних між собою, а нейрон – обчислювальна одиниця, яка отримує інформацію, виконує

над нею прості математичні дії та передає її іншому нейрону. Кожен вхід нейрона, на який надходить деяка кількість сигналів, є виходом іншого. Кожен вхідний сигнал множиться на відповідну вагу, аналогічну синаптичній силі, завдяки якій вхідна інформація змінюється, коли передається від одного нейрона до іншого, і всі результати додаються, після чого визначається рівень активації нейрона [8].

Результати, отримані у працях [4, 9] показують, що методом НМ можна з достатньо точно оцінювати поведінку втомної тріщини.

Швидкість РВТ прогнозували, користуючись експериментальними даними для алюмінієвого ступу Д16Т за коефіцієнта асиметрії циклу навантаження $R = 0; 0,2; 0,4; 0,6$ [10]. Набір даних містить 300 елементів, з яких 225 обрали для навчальної вибірки, а 75 елементів за $R = 0,4$ залишили для перевірки.

На рис. 1 подано прогнозовані та експериментальні дані десятичного логарифма швидкості РВТ da/dN для $R = 0; 0,2; 0,4; 0,6$ методами нейромереж (а), зростаючих дерев (б) та випадкових лісів (в). Як видно з цього рисунку, результати прогнозування добре узгоджуються з експериментом. Метод НМ дає в цьому випадку найбільшу точність з похибкою 2,5 %. Похибка методу зростаючих дерев становить 7,9 %, а похибка методу випадкових лісів складає 12,9 %. Параметри побудованих нейромереж, зростаючих дерев та випадкових лісів наведено у таблицях 1, 2 та 3, відповідно.

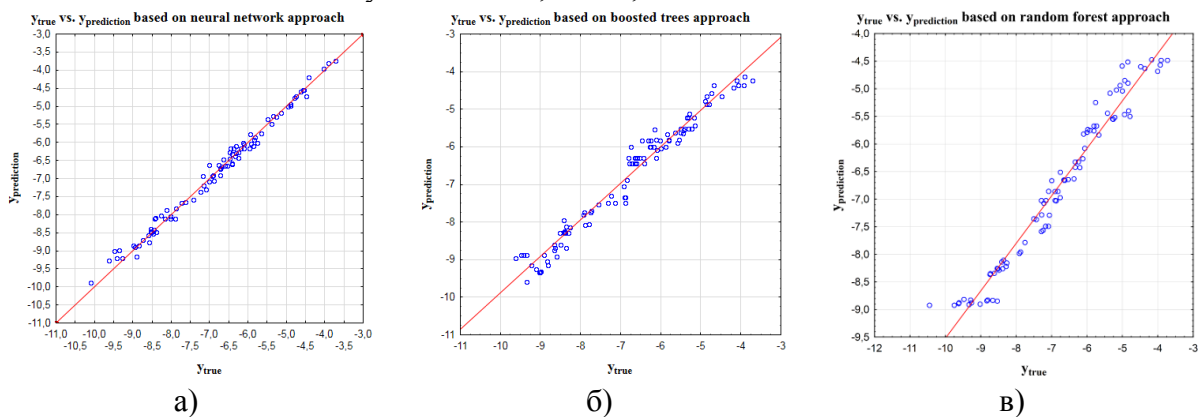


Рис. 1. Прогнозований ($y_{\text{prediction}}$) та експериментальний (y_{true}) десятичний логарифм швидкості РВТ da/dN за $R = 0; 0,2; 0,4; 0,6$ методами а) нейромереж, б) зростаючих дерев, в) випадкових лісів

На рис. 2 подано прогнозовані та експериментальні дані десятичного логарифма швидкості РВТ da/dN від десятичного логарифма ΔK для $R = 0, 0,2, 0,4, 0,6$ методами нейромереж (а), зростаючих дерев (б) та випадкових лісів (в). Як видно з цих рисунків, результати прогнозування візуально добре узгоджуються з експериментом.

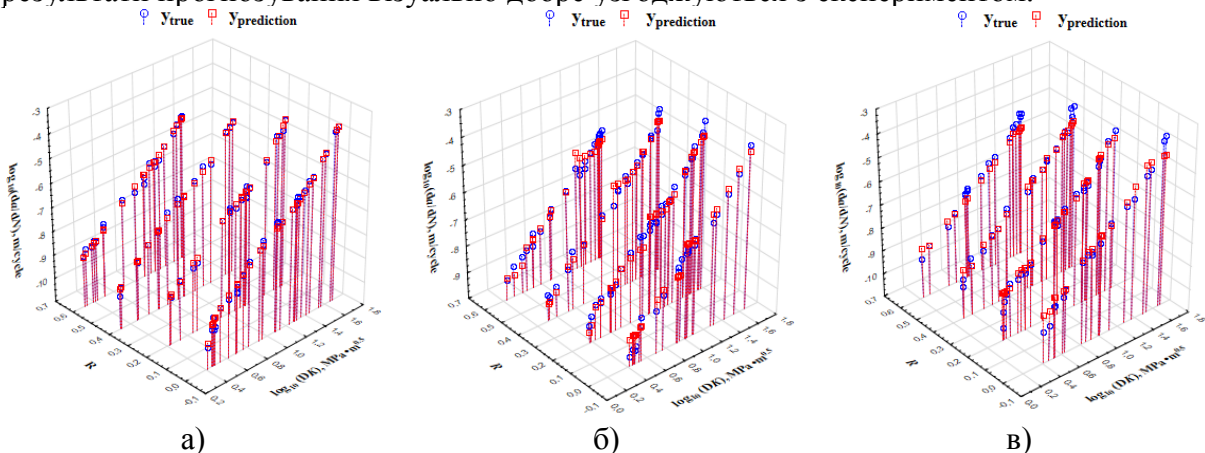


Рис. 2. Прогнозовані ($y_{\text{prediction}}$) та експериментальні (y_{true}) залежності десятичного логарифма швидкості РВТ da/dN від десятичного логарифма ΔK за $R = 0; 0,2; 0,4; 0,6$ методами а) нейромереж; б) зростаючих дерев; в) випадкових лісів

Таблиця 1. Параметри нейромережі

Ім'я мережі	Алгоритм навчання	Функція помилки	Функція прихованої активації	Функція вихідної активації	Середня квадратична похибка
MLP 2-7-1	BFGS	SOS	Логарифмічна	Логарифмічна	0,025

Таблиця 2. Параметри зростаючих дерев Таблиця 3. Параметри випадкових лісів

Кількість дерев	Середня квадратична похибка	Кількість повторень	Середня квадратична похибка
1000	0,129	200	0,079

Швидкість РВТ за регулярного навантаження при асиметрії циклу навантаження $R = 0,4$, яких не було в навчальній вибірці, прогнозували методами нейромереж, зростаючих дерев та випадкових лісів. Результати прогнозу добре узгоджуються з експериментальними даними.

На рис. 3 зображено прогнозований ($y_{\text{prediction}}$) та експериментальний (y_{true}) десятковий логарифм швидкості РВТ da/dN за $R = 0,4$ методами а) нейромереж; б) зростаючих дерев; в) випадкових лісів. Як і в попередньому випадку, метод НМ дає найменшу похибку, що складає 3,2%. Методи зростаючих дерев на цьому ж наборі даних показали однакову похибку, яка дорівнює 13 %. Параметри отриманих мереж представлено у таблицях 4, 5, 6, відповідно.

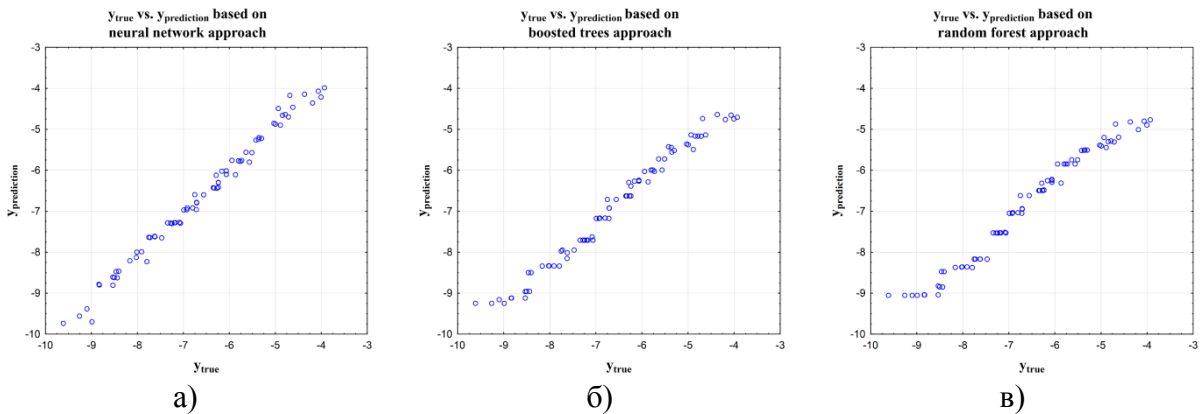


Рис. 3. Прогнозований ($y_{\text{prediction}}$) та експериментальний (y_{true}) десятковий логарифм швидкості РВТ da/dN за $R = 0,4$ методами а) нейромереж; б) зростаючих дерев; в) випадкових лісів

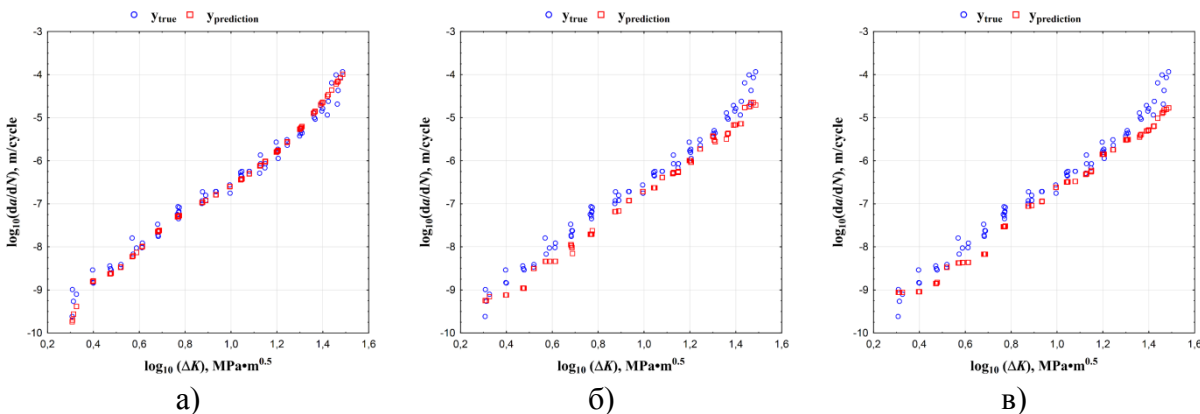


Рис. 4. Прогнозовані ($y_{\text{prediction}}$) та експериментальні (y_{true}) залежності десяткового логарифма швидкості РВТ da/dN від десяткового логарифма розмаху КІН ΔK за $R = 0,4$ методами а) нейромереж; б) зростаючих дерев; в) випадкових лісів

Таблиця 4. Параметри нейромережі

Ім'я мережі	Алгоритм навчання	Функція помилки	Функція прихованої активації	Функція вихідної активації	Середня квадратична похибка
MLP 2-17-1	BFGS	SOS	Логарифмічна	Експоненційна	0.032

Таблиця 5. Параметри зростаючих дерев

Кількість повторень	Середня квадратична похибка
2000	0.13

Таблиця 6. Параметри випадкового лісу

Кількість дерев	Середня квадратична похибка
1000	0.13

Висновки. Досліджено ефективність використання методів нейронних мереж, зростаючих дерев та випадкових лісів для прогнозування впливу асиметрії циклу навантаження на швидкість РВТ у стопі Д16Т за регулярного навантаження. Експериментальними залежностями швидкості РВТ для коефіцієнта асиметрії циклу $R = 0; 0,2; 0,6$ скористалися для побудови навчальної вибірки. Вибірку невідомого для системи набору даних за коефіцієнта асиметрії циклу навантаження $R = 0,4$ взято для перевірки. У всіх випадках найменшу похибку прогнозування отримано при використанні методу нейронних мереж.

Література

1. Paris P. C. Critical Analysis of Crack Propagation Laws / P. C. Paris, F. A. Erdogan // Journal of Basic Engineering. 1963. – Vol. 85(4). – P. 528-534.
2. Трощенко В.Т. Трещиностойкость металлов при циклическом нагружении / В.Т. Трощенко, В.В. Покровский, А.В.Прокопенко. – Киев: Наукова Думка, 1987.
3. Ясній О. Моделювання росту тріщин за змінної амплітуди навантаження в сплаві Д16ЧТ / О. Ясній, Ю. Пиндус. // Вісник Тернопільського державного технічного університету. – 2007. – Т.12, №1. – С. 25-32.
4. Mohanty J. R. Application of artificial neural network for predicting fatigue crack propagation life of aluminum alloys / J. R. Mohanty, B. B. Verma, D. R. K. Parhi, D. R. Ray // Archives of Computational Materials Science and Surface Engineering. – 2009. –Vol. 1(3). – P. 133–138.
5. Walker K. Effects of Environment and Complex Load History on Fatigue Life / K. Walker // American Society for Testing and Materials. – 1970. – P. 1–14.
6. Fatigue crack growth computer program 'NASGRO' version 3.0 – Reference Manual. NASA Technical Report JSC-22267B, 2001. Available from: www.nasgro.swri.org
7. Gorunescu F. Data mining: concepts, models and techniques / F. Gorunescu. – Heidelberg: Springer, 2011.
8. Philip D. Wasserman: Neural Computing: Theory and Practice / D. Philip. – Coriolis Group (Sd), 1989.
9. Pidaparti R. M. V. Neural network approach to fatigue-crack-growth predictions under aircraft spectrum loadings / R. M. V. Pidaparti, M. Palakal. // Journal of Aircraft. – 1995. – №4. – P. 825-831.
10. Ясній П. Вплив асиметрії циклу навантаження на характеристики циклічної тріщиностійкості алюмінієвого сплаву Д16Т / П. Ясній, Ю. Пиндус, В. Фостик // Вісник Тернопільського державного технічного університету. – 2007 – Т.12, №1. – С.7–12.