

УДК 539.42, 004.032.26

ПРОГНОЗУВАННЯ ДІАГРАМ ВТОМНОГО РУЙНУВАННЯ АЛЮМІНІЄВОГО СПЛАВУ Д16Т МЕТОДАМИ МАШИННОГО НАВЧАННЯ

О. П. ЯСНІЙ, О. А. ПАСТУХ, Ю. І. ПИНДУС, Н. С. ЛУЦИК, І. С. ДІДИЧ

Тернопільський національний технічний університет ім. Івана Пулюя

Методами машинного навчання (нейронні мережі, підсилені дерева, випадкові ліси, опорно-векторні машини та k -найближчих сусідів) побудовано діаграми втомного руйнування алюмінієвого сплаву Д16Т за регулярного навантаження і асиметрії циклу навантаження $R = 0; 0,2; 0,4; 0,6$. Отримані результати добре узгоджуються з експериментальними. Виявлено, що метод нейронних мереж дає найменшу похибку прогнозування – 3,2 і 2,5% у тестових вибірках.

Ключові слова: *ріст втомної тріщини, коефіцієнт інтенсивності напружень, асиметрія циклу навантаження, довговічність, нейронна мережа, машинне навчання.*

Задачі механіки руйнування можна розв'язувати як детерміновано, так і ймовірно [1]. Зокрема, ймовірність руйнування пароперегрівника теплової електростанції оцінено за процедурою R6, яка ґрунтується на двопараметричному критерії руйнування тіл із тріщинами [2]. Дослідити вплив режимів навантаження на ріст втомних тріщин – важливий аспект механіки втомного руйнування. Найчастіше одержані експериментальні дані мають певний розкид, який необхідно враховувати. Так отримуємо задачу регресії, яку можна розв'язувати методами машинного навчання, зокрема, використовуючи нейронні мережі, підсилені дерева, випадкові ліси, опорно-векторні машини та k -найближчі сусіди [3]. Відомо [4, 5], що з допомогою нейронних мереж (НМ) з великою точністю розв'язують задачі механіки, зокрема, прогнозують швидкість росту втомних тріщин (РВТ), яку описують як функцію розмаху коефіцієнта інтенсивності напружень (КІН) $\Delta K = K_{\max} - K_{\min}$ [6–8]. Тут K_{\max} , K_{\min} – найбільший та найменший КІН циклу навантаження, при цьому асиметрія циклу $R = K_{\min} / K_{\max}$ суттєво впливає на РВТ [4]. Тому показник R часто вводять у моделі РВТ, зокрема, закриття тріщини [9, 10], залишкового напруження стиску [11, 12], двопараметричної рушійної сили [13, 14].

Експериментальна методика досліджень доволі складна та затратна. Тому важливо замість експерименту виконувати числове моделювання методами машинного навчання. Мета цього дослідження – спрогнозувати кінетичну діаграму втомного руйнування (КДВР) алюмінієвого сплаву Д16Т під час регулярного навантаження за асиметрії циклу навантаження $R = 0; 0,2; 0,4; 0,6$ різнорізними методами машинного навчання, не задаючи явно аналітичних моделей РВТ, та порівняти одержані результати.

Науково-методичні основи методів машинного навчання. Для прогнозування швидкості РВТ у матеріалі елементів конструкцій застосовують такі найбільш універсальні та ефективні алгоритми навчання з учителем, як нейронні мережі (neural networks), підсилені дерева (boosted trees), випадкові ліси (random forests), опорно-векторні машини (support vector machines) та метод k -найближчих

сусідів (*k*-nearest neighbors). Під участю вчителя розуміють знання, подані у вигляді пар вхід-вихід. Учитель формулює і передає навчальній мережі бажаний відгук, що є результатом оптимальних дій, які вона повинна виконати. Параметри мережі коригують з урахуванням навчального вектора і сигналу помилки – різниці між бажаним і вихідним сигналами мережі.

Алгоритм підсилених дерев ґрунтується на рекурсивному розбитті вхідної множини на підмножини, асоційовані із класами. Алгоритм конструювання підсилених дерев складається з етапів побудови і скорочення дерев. Створюючи дерева, вибирають критерій розщеплення та зупинки навчання. Тоді як під час їх скорочення відсікають деякі гілки. Ідея методу випадкових лісів полягає у побудові ансамбля з певної кількості дерев прийняття рішень, які навчаються незалежно одне від одного. Підсумковий результат приймають після голосування всіх дерев ансамбля. Перевагами цього методу є висока точність прогнозування та здатність ефективно обробляти дані [15]. Методи опорно-векторних машин та *k*-найближчих сусідів найпростіші. Перший подає дані точками у просторі. Для навчальних даних, що відносяться до однієї з двох категорій, алгоритм навчання будує модель, яка зараховує нові дані до однієї чи іншої категорії. Тут основними є параметр регуляризації, функція втрат, яка визначає як помилки лише ті прогнозовані значення, що віддалені від навчальних на відстань, більшу за ϵ , та параметр ядра γ . За функцію ядра вибрано радіальну базисну (RBF). Методом *k*-найближчих сусідів новий об'єкт відносять до класу, що домінує серед *k*-найближчих об'єктів навчальної вибірки. Зазвичай відстань між *k*-найближчими сусідами евклідова.

НМ – послідовність з'єднаних між собою нейронів, 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 множать на відповідну вагу, аналогічну синаптичній силі, через що вхідна інформація змінюється під час передавання від одного нейрона до іншого. Далі всі результати додають і визначають рівень активації нейрона [16]. НМ не запрограмовують, а навчають на даних.

Важливими параметрами НМ є її топологія, алгоритм навчання та функції активації прихованого та вихідного шарів. У цьому дослідженні застосовували алгоритм навчання Бройдена–Флетчера–Гольдфарба–Шанно (Broyden–Fletcher–Goldfarb–Shanno) (BFGS) та вибрали суму квадратів помилок (SOS) як функцію помилки.

Результати та їх обговорення. Розроблення певної моделі машинного навчання складається із таких етапів: підготовка даних; конструювання алгоритму; його тренування на навчальних даних та перевірка на тестових. Швидкість РВТ прогнозували за експериментальними даними, одержаними для сплаву Д16Т за асиметрії циклу навантаження $R = 0; 0,2; 0,4; 0,6$ [17]. Під час навчання набір даних розділили на дві нерівні частини – навчальну та тестову вибірки.

Дослідження розділили на два етапи. На першому навчальна вибірка містила експериментальні залежності швидкості РВТ від КІН за значень $R = 0; 0,2; 0,6$, а вибірку невідомого для системи набору даних за $R = 0,4$ обрали, щоб перевірити якість прогнозування. А на другому тестову вибірку навчання вибрав комп'ютер із всіх експериментальних даних за різних асиметрій циклу навантаження.

Навчальна вибірка містила 225 елементів, що характеризують КІН ΔK , якщо $R = 0; 0,2; 0,6$. Швидкість РВТ da/dN під час регулярного навантаження за асиметрії циклу $R = 0,4$ прогнозували методами машинного навчання і вибрали за вихідний параметр. За експериментальними результатами РВТ при $R = 0,4$ сфор-

мували тестову вибірку з 75 елементів, щоб оцінити якість прогнозування. Виявили, що побудовані моделі можуть здійснювати прогноз за даними, які не використовували в навчальній вибірці. Тому такі результати є інформативними для дослідження їх якості. Методами машинного навчання побудували (рис. 1 і 2) залежності експериментальних швидкостей РВТ (da/dN_{true}) від прогнозованих da/dN (da/dN_{pred}), а також $da/dN-\Delta K$ за $R = 0,4$. Метод НМ дає похибку 3,2%, підсилених дерев та випадкових лісів – 13%, тоді як похибка методів опорно-векторних машин та k -найближчих сусідів становить 6%.

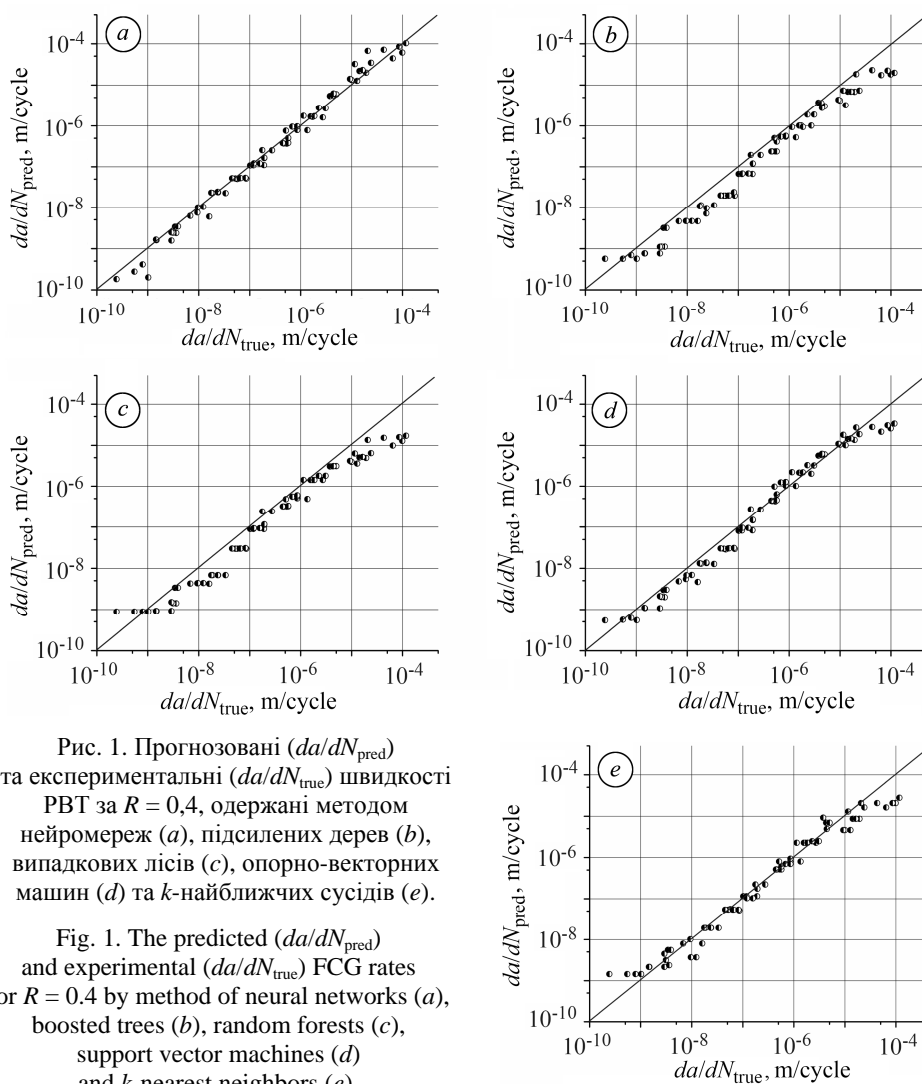


Рис. 1. Прогнозовані (da/dN_{pred}) та експериментальні (da/dN_{true}) швидкості РВТ за $R = 0,4$, одержані методом нейромереж (a), підсилених дерев (b), випадкових лісів (c), опорно-векторних машин (d) та k -найближчих сусідів (e).

Fig. 1. The predicted (da/dN_{pred}) and experimental (da/dN_{true}) FCG rates for $R = 0.4$ by method of neural networks (a), boosted trees (b), random forests (c), support vector machines (d) and k -nearest neighbors (e).

Швидкість РВТ прогнозували за коефіцієнта асиметрії циклу навантаження $R = 0; 0,2; 0,4; 0,6$. Вибірка містила 300 елементів, з яких 70% вибрали випадково для навчальної вибірки, а 30% залишили, щоб оцінити якість прогнозування. Виявили, що результати прогнозування добре узгоджуються з експериментальними. Як і в попередньому випадку, метод НМ найточніший (похибка 2,5%). Похибка методу підсилених дерев 7,9%, випадкових лісів 12,9%, опорно-векторних машин 6,7%, k -найближчих сусідів 5%. Важливо, що на рис. 1 і 2 точки розташовані досить близько до бісектриси першого координатного кута, що свідчить про узгодженість прогнозованих та експериментальних даних [18]. Параметри

побудованих нейромереж, підсиленних дерев, випадкових лісів, опорно-векторних машин та k -найближчих сусідів наведено у табл. 1–4.

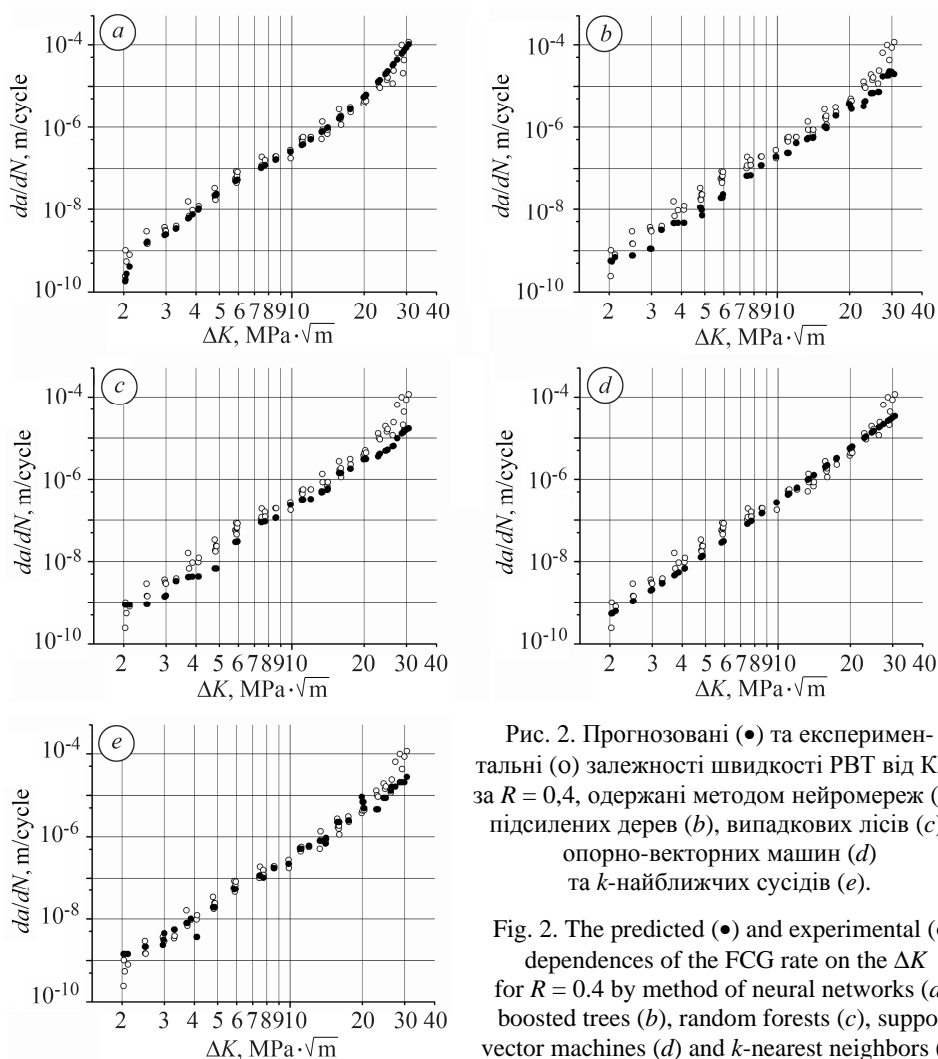


Рис. 2. Прогнозовані (●) та експериментальні (○) залежності швидкості РВТ від КІН за $R = 0,4$, одержані методом нейромереж (а), підсиленних дерев (b), випадкових лісів (c), опорно-векторних машин (d) та k -найближчих сусідів (e).

Fig. 2. The predicted (●) and experimental (○) dependences of the FCG rate on the ΔK for $R = 0.4$ by method of neural networks (a), boosted trees (b), random forests (c), support vector machines (d) and k -nearest neighbors (e).

Таблиця 1. Параметри нейромереж

Асиметрія циклу навантаження	Ім'я мережі	Алгоритм навчання	Функція помилки	Функція прихованої активації	Функція вихідної активації
$R = 0,4$	MLP 2-17-1	BFGS	SOS	Логарифмічна	Експоненційна
$R = 0; 0,2; 0,4; 0,6$	MLP 2-7-1	BFGS	SOS	Логарифмічна	Логарифмічна

Таблиця 2. Параметри підсиленних дерев та випадкових лісів

Асиметрія циклу навантаження	Кількість повторень	Кількість дерев
$R = 0,4$	2000	1000
$R = 0; 0,2; 0,4; 0,6$	200	

Таблиця 3. Параметри опорно-векторних машин

Асиметрія циклу навантаження	Параметр регуляризації	Нечутлива функція втрат ϵ	Параметр ядра γ	Кількість опорних векторів
$R = 0,4$ $R = 0; 0,2; 0,4; 0,6$	10	0,1	0,5	24 (обмежено 14)

Таблиця 4. Параметри k -найближчих сусідів

Асиметрія циклу навантаження	Кількість найближчих сусідів	Відстань
$R = 0,4$ $R = 0; 0,2; 0,4; 0,6$	1	Евклідова

ВИСНОВКИ

Методами машинного навчання досліджено вплив асиметрії циклу навантаження на швидкість РВТ у сплаві Д16Т за регулярного навантаження (нейронні мережі, підсилені дерева, випадкові ліси, опорно-векторні машини та k -найближчих сусідів). Виявлено, що незалежно від типу дослідження (самостійно вибрана тестова вибірка чи навчання комп'ютером) результати прогнозування добре узгоджуються з експериментальними. Найменшу похибку (3,2 і 2,5%) отримано методом нейронних мереж у всіх тестових вибірках.

РЕЗЮМЕ. Методами машинного обучения (нейронные сети, усиленные деревья, случайные леса, опорно-векторные машины и k -ближайших соседей) построены диаграммы усталостного разрушения алюминиевого сплава Д16Т при регулярном нагружении с асимметрией цикла $R = 0; 0,2; 0,4; 0,6$. Полученные результаты хорошо согласуются с экспериментальными. Выведено, что метод нейронных сетей дает наименьшую погрешность прогнозирования (3,2 и 2,5%) в тестовых выборках.

SUMMARY. The methods of machine learning (neural networks, boosted trees, random forests, support vector machines and k -nearest neighbors) were used to constructed the fatigue crack growth diagrams in an D16T aluminium 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. It was revealed that the method of neural networks gives the least prediction error of 3.2 and 2.5% in the test samples.

1. Варфоломеев І. В., Ясній О. П. Моделивання руйнування імовірнісними методами елементів конструкцій з тріщинами // Фіз.-хім. механіка матеріалів. – 2008. – **44**, № 1. – С. 76–83.
(Varfolomeev I. V. and Yasniy O. P. Modeling of fracture of cracked structural elements with the use of probabilistic methods // Materials Science. – 2008. – **44**, № 1. – P. 87–96.)
2. Ясній О. П., Собчак А. Р., Ясній В. П. Оцінювання ймовірності руйнування колектора пароперегрівника // Фіз.-хім. механіка матеріалів. – 2014. – **50**, № 3. – С. 63–68.
(Yasniy O. P., Sobchak A. R., and Yasniy V. P. Estimation of the probability of fracture of the superheater collector of a thermal power plant // Materials Science. – 2014. – **50**, № 3. – P. 381–387.)
3. Hastie T., Tibshirani R., and Friedman J. The Elements of Statistical Learning: Data Mining, Inference, and Prediction. – New York: Springer, 2009. – 730 p.
4. 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 Mat. Sci. and Surf. Eng. – 2009. – **1**, № 3. – P. 133–138.
5. Pidaparti R. M. V. and Palakal M. Neural network approach to fatigue-crack-growth predictions under aircraft spectrum loadings // J. of Aircraft. – 1995. – № 4. – P. 825–831.
6. Paris P. C. and Erdogan F. A. Critical Analysis of Crack Propagation Laws // J. of Basic Eng. – 1963. – **85**, № 4. – P. 528–534.

7. Троценко В. Т., Покровский В. В., Прокопенко А. В. Трещиностойкость металлов при циклическом нагружении. – К.: Наук. думка, 1987. – 256 с.
8. Ясній О. П., Пиндус Ю. І. Моделювання росту тріщин за змінної амплітуди навантаження в сплаві Д16ЧТ // Вісник Тернопільськ. держ. техн. ун-ту. – 2007. – **12**, № 1. – С. 25–32.
9. Elber W. Fatigue crack closure under cyclic tension // Eng. Fract. Mech. – 1970. – **2**, № 1. – P. 37–45.
10. Elber W. The significance of fatigue crack closure // Damage tolerance in aircraft struct. – 1971. – **486**. – P. 230–242.
11. Klesnil M. and Lukas P. Effect of stress cycle asymmetry on fatigue crack growth // Mat. Sci. Eng. – 1972. – **9**. – P. 231–240.
12. Kujawski D. and Ellyin F. A fatigue crack growth model with load ratio effects // Eng. Fract. Mech. – 1987. – **28**. – P. 367–378.
13. Dinda S. and Kujawski D. Correlation and prediction of fatigue crack growth for different R-ratios using K_{\max} and ΔK^+ parameters // Eng. Fract. Mech. – 2004. – **71**. – P. 1779–1790.
14. Kujawski D. A new $(\Delta K + K_{\max})$ 0.5 driving force parameter for crack growth in aluminum alloys // Int. J. of Fatigue. – 2001. – **23**. – P. 733–740.
15. Gorunescu F. Data mining: concepts, models and techniques. – Heidelberg: Springer, 2011. – 360 p.
16. Philip D. Wasserman. Neural Computing: Theory and Practice. – New York: Coriolis Group (Sd), 1989. – 230 p.
17. Ясній П., Пиндус Ю., Фостик В. Вплив асиметрії циклу навантаження на характеристики циклічної тріщиностійкості алюмінієвого сплаву Д16Т // Вісник Тернопільськ. держ. техн. ун-ту. – 2007. – **12**, № 1. – С. 7–12.
18. Describing fatigue crack growth and load ratio effects in Al 2524 T3 alloy with an enhanced exponential model / C. A. R. P. Baptista, A. M. L. Adib, M. A. S. Torres, V. A. Pastoukhov // Mech. of Mat. – 2012. – **51**. – P. 66–73.

Одержано 09.08.2018