

УДК: 539.4, 004.85

ПРИМЕНЕНИЕ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ ДЛЯ МОДЕЛИРОВАНИЯ ИСПЫТАНИЙ НА УСТАЛОСТНОЕ РАЗРУШЕНИЕ

Попереков Г.И.

студент

*Московский государственный технический университет имени Н. Э.
Баумана,*

Москва, Россия

Зубарев К.М.

Старший преподаватель кафедры

*Московский государственный технический университет имени Н. Э.
Баумана,*

Москва, Россия

Аннотация. В статье рассматривается применение методов машинного обучения для моделирования усталостного разрушения материалов с целью прогнозирования длины трещины на различных этапах циклических нагрузок. Основное внимание уделено созданию репрезентативного набора данных с использованием модулей Parameter Set и Surface Respond в программном комплексе «Ansys Mechanical», что позволило автоматизировать процесс проектирования экспериментов и анализа чувствительности входных параметров. На основе полученных данных построена полиномиальная регрессионная модель, связывающая механические характеристики материала, параметры нагружения и геометрию образца с длиной образующейся трещины. Показано, что комбинация численного моделирования в Ansys и методов машинного обучения обеспечивает высокую точность прогнозирования развития

усталостных повреждений при сокращении вычислительных ресурсов. Результаты исследования демонстрируют потенциал интеграции инженерного анализа и алгоритмов регрессии для оптимизации испытаний на усталостную долговечность, что актуально для авиационной, автомобильной и строительной отраслей.

Ключевые слова: Усталостное разрушение, Разрушение металлических конструкций, Полиномиальная регрессия, закон Пэриса

APPLICATION OF MACHINE LEARNING METHODS FOR SIMULATION OF FATIGUE FAILURE TESTS

Poperekov G.I.

student

Bauman Moscow state technical University,

Moscow, Russia

Zubarev K. M.

Senior Lecturer

Bauman Moscow state technical University,

Moscow, Russia

Abstract. The article discusses the application of machine learning methods for modeling fatigue failure of materials in order to predict the crack length at different stages of cyclic loading. The main focus is on creating a representative data set using the Parameter Set and Surface Respond modules in the Ansys Mechanical software package, which made it possible to automate the process of designing experiments and analyzing the sensitivity of input parameters. Based on the obtained data, a polynomial regression model was built that relates the mechanical characteristics of the material, loading parameters and sample geometry with the length of the resulting crack. It is shown that the combination of numerical

modeling in Ansys and machine learning methods provides high accuracy in predicting the development of fatigue damage while reducing computing resources. The results of the study demonstrate the potential of integrating engineering analysis and regression algorithms to optimize fatigue life testing, which is relevant for the aviation, automotive and construction industries.

Key words: Fatigue failure, Destruction of metal structures, Polynomial regression, Paris' law

Введение

Современные металлические конструкции, используемые в авиационной, космической, автомобильной и других отраслях промышленности, подвергаются циклическим нагрузкам, которые могут приводить к усталостному разрушению [1,2]. Усталостное разрушение является одним из основных механизмов отказа материалов и конструкций [3,4], что делает его изучение важной задачей для обеспечения безопасности и долговечности инженерных систем [2,3,4].

Традиционные подходы к прогнозированию усталостной долговечности, основанные на эмпирических моделях и детерминистских методах механики разрушения, например, законах Париса для роста трещин, требуют проведения огромного объема дорогостоящих и длительных физических испытаний. Эти испытания, как правило, характеризуются высокой дисперсией результатов, обусловленной стохастической природой инициирования усталостных трещин и влиянием множества факторов: микроструктуры материала, состояния поверхности, остаточных напряжений, сложного спектра нагружения и агрессивности среды.

В последние годы методы машинного обучения демонстрируют беспрецедентный потенциал для преодоления этих ограничений. Обладая способностью выявлять скрытые, нелинейные закономерности и сложные

взаимосвязи в больших массивах данных [5,6], МО предлагает мощный инструментарий для анализа результатов усталостных испытаний, построения прогнозных моделей и ускорения процесса оценки ресурса [7,8]. В данной работе авторы исследуют возможность моделирования усталостных испытаний с помощью регрессионных моделей [9,10]. Полиномиальные регрессионные модели строятся с применением регуляризации [11]. Разработанные алгоритмы могут применяться в задачах механики, в том числе композиционных материалов [12].

Методы и материалы исследования

Для создания и обучения моделей на основе машинного обучения необходимо сформировать набор данных, на основе которых будет проводиться моделирование роста трещины. В качестве признаков будем использовать следующие значения: b – расстояние от начала роста трещины до края образца (мм), t – толщину образца (мм), E – модуль Юнга (Па), μ – коэффициент Пуассона, R – коэффициент асимметрии цикла, C и n – материальные константы, F – силу (Н). В качестве целевого признака будет рассматриваться длина трещины l (мм). На Рисунке 1 представлена геометрическая модели образца, для которого проводятся испытания на усталостное разрушение [7,8]





Рис. 1 – Модель геометрии образца в Ansys. Авторская разработка.

Набор данных был получен с помощью методов параметризации, реализованных в ПК "ANSYS Mechanical", которые применяются для создания и оптимизации моделей, позволяя изменять их параметры для достижения оптимальных результатов. В данной работе использовались инструменты Parameter Set и Surface Response.

С помощью Parameter Set задаётся набор входных параметров, варьируемых в ходе вычислений, а также выходных параметров, используемых для дальнейшего анализа. На рисунке 2 представлено окно Parameter Set, в котором задаются варьируемые параметры для материала



The screenshot shows the 'Parameter Set' window in Ansys Workbench. It contains a table titled 'Outline of All Parameters' with columns A (ID), B (Parameter Name), C (Value), and D (Unit). The table lists various input parameters (P1-P13) and output parameters (P8, P9) for a 'Static Structural (B1)' analysis. Input parameters include geometry dimensions (P1, P2), material properties (P4, P5), and crack growth parameters (P11, P12, P13). Output parameters include crack extension (P8) and total number of cycles (P9).

	A	B	C	D
1	ID	Parameter Name	Value	Unit
2	Input Parameters			
3	Geometry (A1)			
4	P1	(B2_B) B	60	mm
5	P2	(B3_P1) Distance	6,16	mm
6	Static Structural (B1)			
7	P4	Young's Modulus	1,15E+11	Pa
8	P5	Poisson's Ratio	0,34	
9	P11	SMART Crack Growth Stress Ratio	0,1	
10	P12	Material Constant m	2,4498	
11	P13	Force Z Component	6178,2	N
*	New input parameter	New name	New expression	
13	Output Parameters			
14	Static Structural (B1)			
15	P8	Crack Extension Probe Crack Extension	0,031768	m
16	P9	Total Number of Cycles Probe Total Number of Cycles	18064	
*	New output parameter		New expression	
18	Charts			

Рис. 2 – Изменяемые параметры материала при испытании на усталостное разрушение. Авторская разработка.

Эти данные передаются в Surface Response, где формируется таблица значений. В этой таблице столбцы соответствуют изменяемым параметрам, а строки — отдельным наборам данных (комбинациям параметров). На основе этой таблицы вычисляются выходные параметры.

Набор данных был получен при помощи модулей Parameter Set и Surface Respond из ПК «Ansys Mechanical». Области значений упомянутых выше признаков были взяты из общедоступных источников.

Результаты и их обсуждение.

Для моделирования роста трещины была построена полиномиальная регрессионная модель второй степени, точность модели была проверена по следующим метрикам:

- Среднеквадратичная ошибка (MSE, Mean Squared Error) – 0.015;
- Средняя абсолютная ошибка (MAE, Mean Absolute Error) – 0.09;
- Средняя абсолютная процентная ошибка (MAPE, Mean Absolute Percentage Error) – 2.06 %;

Коэффициент детерминации (R^2) – 0.9891.

На рисунке 3 показано соответствие истинных значений и вычисленных по модели. Чем ближе точки к прямой, тем выше точность модели.




Рис. 3 – Точность регрессионной модели. Авторская разработка.

По построенной модели было проведено моделирование испытаний на усталостное разрушение. Для выбранных значений физических характеристик образца (расстояние от начала роста трещины до края образца, толщину образца, модуль Юнга, коэффициент Пуассона, коэффициент асимметрии цикла, материальные константы C и n , прикладываемую силу).




Рис. 4 – Сравнение результатов Ansys и регрессионной модели.

Авторская разработка.

Предсказанные значения длины трещины хорошо согласуются с результатами виртуальных испытаний. Это свидетельствует о том, что предложенный подход может быть использован не только для анализа экспериментальных данных, но и для оптимизации численных расчётов в инженерных системах.

Выводы

В данной работе исследованы возможности применения методов машинного обучения для моделирования роста усталостных трещин в металлических конструкциях. Основу исследования составили данные, полученные с помощью ПК «Ansys Mechanical», что позволило воспроизвести условия реальных испытаний на трещиностойкость с высокой точностью. Полиномиальная регрессия второй степени показала высокую эффективность в прогнозировании длины трещины, демонстрируя значительное превосходство над линейной моделью. Значения метрик ($R^2 = 0.9891$, $MSE = 0.015$, $MAPE = 2.06\%$) подтверждают правильность модели и

её способность учитывать сложные нелинейные зависимости между параметрами. Финальная проверка на цифровом двойнике подтвердила корректность модели: предсказанные значения длины трещины хорошо согласуются с результатами виртуальных испытаний. Это свидетельствует о том, что предложенный подход может быть использован не только для анализа экспериментальных данных, но и для оптимизации численных расчётов в инженерных системах. Таким образом, работа демонстрирует перспективность сочетания методов машинного обучения и компьютерного моделирования для прогнозирования усталостных разрушений. Полученные результаты могут быть применены для повышения точности расчётов долговечности конструкций, что особенно актуально в авиационной, космической и других отраслях, где критически важна надёжность материалов.

Библиографический список

1. Определение критической плоскости и оценка усталостной долговечности при различных режимах циклического нагружения / И. С. Никитин, Н. Г. Бураго, А. Д. Никитин, В. Л. Якушев // Вестник Пермского национального исследовательского политехнического университета. Механика. – 2017. – № 4. – С. 238-252. – DOI 10.15593/perm.mech/2017.4.15.
2. Маньшин, Ю. П. Численное моделирование и экспериментальные оценки характеристик выносливости элементов конструкций / Ю. П. Маньшин, Е. Ю. Маньшина // Вестник Донского государственного технического университета. – 2020. – Т. 20, № 1. – С. 79-86. – DOI 10.23947/1992-5980-2020-20-1-79-86.
3. Швечков, Е. И. Исследование циклической трещиностойкости поковок из сплавов 193ЗТЗН, ВТ6ч и стали 08Х15Н5Д2ТУ-Ш / Е. И. Швечков, А. В. Сыров // Технология легких сплавов. – 2013. – № 1. – С. 67-75.
4. Исследование усталостного разрушения конструкционной стали в условиях циклического сжатия / М. Р. Орлов, Л. В. Морозова, С. А. Наприенко [и др.] // Электрометаллургия. – 2017. – № 3. – С. 32-48.

5. Puttegowda M., Nagaraju S. B. Artificial intelligence and machine learning in mechanical engineering: Current trends and future prospects //Engineering Applications of Artificial Intelligence. – 2025. – Т. 142. – С. 109910.
6. Kollmannsberger S. et al. Deep learning in computational mechanics. – Springer International Publishing, 2021. – С. 55-84.
7. Шапошников, Д. М. А. Фиксирование усталостного разрушения металлических материалов методом компьютерного зрения / Д. М. А. Шапошников, В. В. Автаев, К. М. Зубарев // Дневник науки. – 2024. – № 6(90).
8. Применение метода корреляции цифровых изображений для построения диаграмм деформирования в истинных координатах / А. Д. Монахов, М. М. Гуляев, Н. Е. Гладышева [и др.] // Известия высших учебных заведений. Цветная металлургия. – 2023. – Т. 29, № 3. – С. 79-88. – DOI 10.17073/0021-3438-2023-3-79-88.
9. Носков, С. И. Построение регрессионных моделей с использованием аппарата линейно-булевого программирования / С. И. Носков, М. П. Базилевский. – Иркутск : Иркутский государственный университет путей сообщения, 2018. – 176 с. – ISBN 978-5-98710-354-8.
10. Базилевский, М. П. Сведение задачи отбора информативных регрессоров при оценивании линейной регрессионной модели по методу наименьших квадратов к задаче частично-булевого линейного программирования / М. П. Базилевский // Моделирование, оптимизация и информационные технологии. – 2018. – Т. 6, № 1(20). – С. 108-117.
11. Облакова, Т. В. Применение регуляризации при построении полиномиальных регрессионных моделей на примере прогнозирования стоимости бриллиантов / Т. В. Облакова, В. М. Григорян, К. М. Зубарев // Научное обозрение. Технические науки. – 2024. – № 5. – С. 31-36. – DOI 10.17513/srts.1485.
12. Димитриенко, Ю. И. Моделирование нелинейных диэлектрических свойств композитов на основе метода асимптотической гомогенизации / Ю. И. Димитриенко, Е. А. Губарева, К. М. Зубарев // Математическое моделирование и численные методы. – 2020. – № 2(26). – С. 26-45. – DOI 10.18698/2309-3684-2020-2-2645.

Оригинальность 81%