

МАШИННОЕ ОБУЧЕНИЕ И ВОПРОСЫ ПРОЧНОСТИ

Аскарлов Б.Б.

АФ НИТУ МИСиС ассистент кафедры «ИТ и АТПП»

Аннотация

В статье рассматриваются возможности применения методов машинного обучения для решения задач прочности материалов и конструкций. Анализируются современные подходы к прогнозированию разрушений, оценке остаточного ресурса и оптимизации конструкций. Показано, что интеграция алгоритмов машинного обучения с классическими методами механики сплошных сред позволяет существенно повысить точность и скорость инженерных расчётов.

Ключевые слова: машинное обучение, прочность, разрушение, прогнозирование, нейронные сети, регрессия, надёжность, инженерные системы.

ВВЕДЕНИЕ

Вопросы прочности являются фундаментальными в инженерии, особенно в таких областях, как машиностроение, строительство, авиация и горная промышленность. Традиционные методы анализа прочности базируются на решении дифференциальных уравнений, использовании метода конечных элементов (МКЭ) и экспериментальных исследованиях.

Однако с ростом сложности конструкций и увеличением объёма данных возникает необходимость применения новых подходов. Машинное обучение (ML) становится эффективным инструментом, позволяющим выявлять скрытые закономерности в данных и строить точные прогнозные модели.

1. Классические подходы к анализу прочности

Традиционно задачи прочности решаются на основе:

- теории упругости и пластичности;
- метода конечных элементов (FEM);
- экспериментальных испытаний материалов;
- эмпирических зависимостей.

Основной задачей является определение напряжённо-деформированного состояния (НДС) и предсказание момента разрушения.

Недостатки классических методов:

- высокая вычислительная сложность;
- зависимость от точности исходных моделей;
- необходимость упрощений;
- длительное время расчётов.

2. Машинное обучение в задачах прочности

Машинное обучение позволяет строить модели вида:

$$\sigma = f(x_1, x_2, \dots, x_n) \text{ где:}$$

- σ — напряжение или критерий разрушения,
- x_i — параметры материала и нагрузки. Основные методы:
- Линейная и нелинейная регрессия
- Нейронные сети (ANN)
- Метод опорных векторов (SVM)
- Деревья решений и ансамбли (Random Forest, Gradient Boosting)

Преимущества:

- высокая скорость вычислений после обучения;
- способность работать с шумными данными;
- выявление нелинейных зависимостей;
- автоматизация анализа.

3. Применение ML в задачах прочности

3.1. Прогнозирование разрушений

Модели машинного обучения используются для:

- определения предельных нагрузок;
- классификации состояний (разрушено / не разрушено);
- анализа трещинообразования.

Пример: нейронная сеть прогнозирует вероятность разрушения балки по параметрам нагрузки и геометрии.

3.2. Оценка остаточного ресурса

ML применяется для прогнозирования срока службы конструкций:

$$R = f(\sigma, T, N, \text{дефекты}) \text{ где:}$$

- R — остаточный ресурс,
- T — температура,
- N — число циклов нагружения. Это особенно важно для:
- авиации,
- нефтегазовой отрасли,

- горной промышленности.

3.3. Интеллектуальная диагностика

Системы на базе ML позволяют:

- анализировать данные датчиков;
- выявлять дефекты;
- предсказывать аварийные ситуации. Используются:
- временные ряды,
- спектральный анализ,
- методы глубинного обучения.

3.4. Оптимизация конструкций

ML применяется для:

- подбора материалов;
- минимизации массы конструкции;
- повышения прочности. Алгоритмы:
- генетические алгоритмы;
- reinforcement learning;
- Bayesian optimization.

4. Гибридные методы

Наиболее перспективным направлением является объединение:

- физических моделей (FEM),
- и машинного обучения.

Такие модели называются **Physics-Informed Machine Learning (PIML)**. Преимущества:

- учитываются физические законы;
- уменьшается потребность в данных;
- повышается интерпретируемость.

5. Ограничения и проблемы

Несмотря на преимущества, существуют проблемы:

- необходимость больших обучающих выборок;
- переобучение моделей;
- слабая интерпретируемость нейросетей;
- зависимость от качества данных.

Также важно учитывать, что ML не заменяет полностью классическую механику, а дополняет её.

6. Перспективы развития

Основные направления:

- цифровые двойники конструкций;
- интеграция с IoT и сенсорными системами;
- применение глубокого обучения;
- использование нейросетей в реальном времени.

7. Математическая модель прогнозирования прочности

Для решения задачи прогнозирования прочности материала рассмотрим регрессионную модель, основанную на **методе наименьших квадратов (МНК)**.

7.1. Постановка задачи

Пусть имеется выборка наблюдений:

$$\{x^{(1)}, x^{(2)} \dots x^{(m)}, y\}$$

$12 \qquad \qquad \qquad n(i) \qquad \qquad \qquad i-1$

где:

- x_j — входные параметры (нагрузка, температура, дефекты и т.д.),
- y — выходная величина (предел прочности). Требуется найти функцию:

$$y = f(x)$$

7.2. Линейная модель (МНК)

Предположим линейную зависимость:

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n$$

Коэффициенты β определяются минимизацией функционала ошибки:

$$J(\beta) = \sum_{i=1}^m (y^{(i)} - \hat{y}^{(i)})^2$$

Решение в матричной форме:

$$B = (X^T X)^{-1} X^T y$$

7.3. Квадратичная модель (расширение МНК)

Для учёта нелинейности (что актуально в задачах прочности):

$$y = \beta_0 + \sum_i \beta_i x_i + \sum_{ii} \beta_{ii} x_i^2 + \sum_{ij} \beta_{ij} x_i x_j$$

Такая модель хорошо описывает:

- нелинейную деформацию,
- взаимодействие факторов,
- эффекты накопления повреждений.

7.4. Нейросетевая модель

Для более сложных зависимостей используется многослойная нейронная сеть:

$$y = f(W_2 \cdot \sigma(W_1 x + b_1) + b_2) \text{ где:}$$

- W — веса,
- b — смещения,
- σ — функция активации (ReLU, sigmoid). Преимущество:
- аппроксимация сложных нелинейных зависимостей,
- высокая точность.

ЗАКЛЮЧЕНИЕ

Машинное обучение открывает новые возможности в области анализа прочности. Оно позволяет значительно ускорить расчёты, повысить точность прогнозов и автоматизировать процессы диагностики. Наиболее эффективным является комбинированный подход, объединяющий классические методы механики и современные алгоритмы искусственного интеллекта.

СПИСОК ЛИТЕРАТУРЫ

- [1]. Bishop C. *Pattern Recognition and Machine Learning*
- [2]. Goodfellow I. *Deep Learning*
- [3]. Zienkiewicz O. *The Finite Element Method*
- [4]. Liu Y. *Machine Learning in Structural Engineering*
- [5]. Hastie T. *The Elements of Statistical Learning*