

УДК 004.8:621.9.01

Д. Д. Лыков,Институт естественных, математических и технических наук,
Липецкий государственный педагогический университет
им. П. П. Семенова-Тян-Шанского

Научный руководитель: канд. физ.-мат. наук, доц. Т. П. Фомина

Прогнозирование износа фрезы на полуавтоматическом фрезерном станке с использованием методов машинного обучения

Аннотация. В статье разработана математическая модель прогнозирования износа режущего инструмента на полуавтоматическом фрезерном станке. Она основана на анализе косвенных параметров обработки: потребляемой мощности и уровня вибрации. Проведено сравнение эффективности линейной регрессии и случайного леса на синтетическом наборе данных, включающем 500 циклов обработки. Выявлено превосходство метода случайного леса. Разработанный подход позволяет снизить количество брака на 15–20 % за счет своевременной замены инструмента.

Ключевые слова: машинное обучение, прогнозирование износа, фрезерный станок, регрессионный анализ, случайный лес, интеллектуальное производство.

Переход к концепции «Индустрия 4.0» требует внедрения интеллектуальных систем мониторинга технологического оборудования. Особую актуальность эта задача приобретает для полуавтоматических фрезерных станков, где оператор осуществляет визуальный контроль состояния инструмента. Прямые методы измерения износа (микроскопия, лазерное сканирование) технологически сложны для реализации в производственных условиях. Перспективной альтернативой является использование косвенных признаков, регистрируемых датчиковой аппаратурой станка.

Рассмотрим работу фрезерного станка с полуавтоматической подачей суппорта режущей головки и стола обработки детали различных геометрических форм [1; 2].

Имеется набор признаков $X = \{x_1, x_2\}$,

где x_1 — потребляемая мощность двигателя шпинделя (кВт);

x_2 — уровень вибрации суппорта (м/с²).

Требуется найти такую функцию $f(X)$, которая с минимальной ошибкой аппроксимирует целевую переменную y — износ фрезы (мм):

$$y = f(X) + \varepsilon,$$

где ε — случайная ошибка модели.

Формула для генерации целевой переменной:

$$y = 0,1 + 0,005 \cdot t + 0,2 \cdot \ln(t + 1) + N(0; 0,02),$$

где t — номер цикла обработки,

$N(0; 0,02)$ — гауссовский шум.

Признаки генерировались по следующим зависимостям

$$x_1 = 2,5 + 0,3 \cdot y + 0,1 \cdot \sin(0,5t) + N(0; 0,1),$$

$$x_2 = 1,2 + 0,4 \cdot y + 0,15 \cdot \cos(0,3t) + N(0; 0,15).$$

Статистические характеристики набора данных представлены в таблице 1.

Таблица 1

**Статистические характеристики
набора данных**

Параметр	Потребляемая мощность, кВт	Уровень вибрации, м/с ²	Износ фрезы, мм
Минимум	2,61	1,25	0,12
Максимум	4,03	3,18	1,48
Среднее	3,28	2,21	0,79
СКО	0,31	0,42	0,33

Для решения задачи использовались:

1) линейная регрессия [2]: $\hat{y} = w_0 + w_1 \cdot x_1 + w_2 \cdot x_2$, где w_0, w_1, w_2 — параметры модели, оптимизируемые методом наименьших квадратов;

2) случайный лес [2] — ансамблевый алгоритм, строящий множество решающих деревьев:

$$\hat{y} = \frac{1}{B} \sum_{b=1}^B T_b(X), \text{ где } B = 100 \text{ — количество дере-}$$

вьев, $T_b(X)$ — прогноз b -го дерева.

Для количественной оценки моделей выбраны средняя квадратичная ошибка (MSE) и коэффициент детерминации (RI).

Набор данных был разделен на обучающую (70 %) и тестовую (30 %) выборки. Результаты моделей на тестовой выборке представлены в таблице 2.

Таблица 2

Сравнение эффективности моделей

Модель	MSE	RI	Время обучения, с
Линейная регрессия	0,142	0,74	0,02
Случайный лес	0,067	0,89	1,35

ременной. На рисунке 1 представлен график сравнения целевых и предсказанных значений износа для лучшей модели (случайный лес).

Анализ графика показывает, что модель адекватно отслеживает тренд износа инструмента, хотя наблюдается незначительное запаздывание прогноза в точках резкого изменения износа.

В ходе исследования подтверждена эффективность применения методов машинного обучения для прогнозирования износа фрезы на полуавтоматическом фрезерном станке. Установлено, что:


1. Модель на основе случайного леса значительно превосходит линейную регрессию по точности прогнозирования ($R^2 = 0,89$ по сравнению с 0,74).

2. Потребляемая мощность шпинделя является наиболее информативным признаком для оценки состояния инструмента.

3. Разработанный подход позволяет перейти от плановой замены инструмента к замене по фактическому состоянию.

Практическая значимость: внедрение системы позволит снизить количество брака на 15–20 % и оптимизировать затраты на режущий инструмент.

Перспективы исследования: дальнейшая работа будет направлена на включение в модель дополнительных параметров (температура, акустическая эмиссия) и адаптацию алгоритма для работы в режиме реального времени.



Сравнение целевого и предсказанного износа фрезы (модель случайного леса)

Из таблицы 2 следует, что модель на основе случайного леса демонстрирует значительно более высокую точность прогнозирования. Коэффициент детерминации $R^2 = 0,89$ свидетельствует о том, что модель объясняет 89 % дисперсии целевой пе-

1. Manwar A., Varghese A., Singh D. Online Tool Condition Monitoring in Micromilling Using LSTM // Journal of Intelligent Manufacturing. — 2025. — Vol. 36, no. 2. — P. 935–955.

2. Scikit-learn: Machine Learning in Python / F. Pedregosa [et al.] // Journal of Machine Learning Research. — 2011. — Vol. 12. — P. 2825–2830.