

Прогнозирование шероховатости поверхности при фрезеровании сфероцилиндрическим инструментом с использованием искусственной нейронной сети

Михаил Гимадеев ^{a, *}, Вадим Стельмаков ^b, Александр Никитенко ^c, Максим Улисков ^d

Тихоокеанский государственный университет, ул. Тихоокеанская, 136, г. Хабаровск, 680035, Россия

^a <https://orcid.org/0000-0001-6685-519X>, 009063@togudv.ru; ^b <https://orcid.org/0000-0003-2763-1956>, 009062@togudv.ru;

^c <https://orcid.org/0000-0003-4729-5558>, 005392@togudv.ru; ^d <https://orcid.org/0009-0001-9858-423X>, 2016104779@togudv.ru

ИНФОРМАЦИЯ О СТАТЬЕ

УДК 621.91:004.89:51-7

История статьи:

Поступила: 30 января 2025

Рецензирование: 01 марта 2025

Принята к печати: 27 марта 2025

Доступно онлайн: 15 июня 2025

Ключевые слова:

Фрезерование
 Шероховатость
 Регрессионный анализ
 Искусственный интеллект
 Нейронная сеть
 Среднеквадратичная ошибка

Финансирование

Работа выполнена при поддержке Министерства науки и высшего образования Российской Федерации (проект № FEME–2024–0010 «Экспериментальная лаборатория мехатронных систем ЧПУ»).

АННОТАЦИЯ

Введение. Фрезерование нержавеющей стали сфероцилиндрическим инструментом представляет собой сложную технологическую операцию, требующую точного контроля параметров обработки для обеспечения высокого качества поверхности. В связи с этим актуальной задачей является разработка методов прогнозирования параметров шероховатости, таких как Rz . **Цель данной работы:** разработка прогностической нейросетевой модели для оценки шероховатости поверхности при фрезеровании нержавеющей стали сфероцилиндрическим инструментом. **Метод и методология.** Основное внимание уделено методам обратного распространения ошибки и градиентного спуска, а также настройке гиперпараметров, что необходимо для предотвращения переобучения и недообучения модели. Экспериментальные исследования включают в себя анализ как контролируемых переменных, таких как подача на зуб, угол наклона и диаметр инструмента, так и неконтролируемых, включая подачу СОЖ и износ инструмента. **Результаты и обсуждения.** Использование СОЖ при фрезеровании стали аустенитного класса позволило снизить параметры шероховатости Rz в среднем на 14 %. Установлена сильная отрицательная корреляционная зависимость между размерным износом инструмента и параметром Rz (–0,95). При этом износ в пределах 2...4 мкм влияет на увеличение параметра Rz на 21 % от минимальных значений. Полученные данные использовались для обучения восьми конфигураций искусственных нейронных сетей, которые применялись для прогнозирования шероховатости по параметру Rz . Результаты показывают, что конфигурация сети 3–16–16–1 показала самую низкую среднеквадратичную ошибку (0,0313), за ней следуют 3–20–14–1 (0,0470) и 3–64–64–1 (0,0481) соответственно. Кроме того, эти конфигурации также продемонстрировали самые низкие средние значения абсолютной погрешности, показывающие среднее значение абсолютных разностей между прогнозируемыми и наблюдаемыми значениями (0,101, 0,1251 и 0,1155 соответственно) и коэффициент детерминации, который является статистической мерой, указывающей долю изменчивости данных, объясняемую моделью (0,9944, 0,9916 и 0,9904 соответственно). Сравнение экспериментальных данных с прогнозами различных моделей позволило установить среднее значение абсолютных разностей для моделей по параметру $Ra \approx 0,074$. В исследовании предлагаются подходы к обучению нейросетевых моделей для точного прогнозирования параметров шероховатости, что вносит значительный вклад в методы моделирования процессов механической обработки.

Для цитирования: Прогнозирование шероховатости поверхности при фрезеровании сфероцилиндрическим инструментом с использованием искусственной нейронной сети / М.Р. Гимадеев, В.А. Стельмаков, А.В. Никитенко, М.В. Улисков // Обработка металлов (технология, оборудование, инструменты). – 2025. – Т. 27, № 2. – С. 126–141. – DOI: 10.17212/1994-6309-2025-27.2-126-141.

Введение

Качество обработанной поверхности играет решающую роль в обеспечении эксплуатационных свойств деталей машин [1]. Шероховатость поверхности (Rz и Ra) часто служит

одной из главных метрик для оценки состояния поверхности после процесса механической обработки [2].

Методы моделирования для прогнозирования Rz можно разделить на три категории: экспериментальные модели, аналитические модели и модели, основанные на искусственном интеллекте (ИИ) [3, 4]. В последние годы модели, управляемые ИИ, стали широко использоваться исследователями для предсказания характеристик, связанных с процессами обработки [5],

*Адрес для переписки

Гимадеев Михаил Радикович, к.т.н., доцент
 Тихоокеанский государственный университет,
 ул. Тихоокеанская, 136,
 680035, г. Хабаровск, Россия
 Тел.: +7 924 216-31-39, e-mail: 009063@togudv.ru

а применение искусственных нейронных сетей (ИНС) рассматривается авторами для прогнозирования шероховатости поверхности, износа инструмента и других параметров при механообработке [6].

Для эффективного функционирования нейронные модели используют обширную сеть простых вычислительных процессоров – «нейронов». Нейронные сети часто служат для решения сложных задач, в которых поведение переменных недостаточно известно. Одной из их фундаментальных характеристик является способность обучаться на примерах и применять эти знания обобщенным образом, что позволяет создавать нелинейные модели. Эта способность делает использование ИНС в многокритериальном анализе весьма эффективным [7, 8].

Конфигурация нейронной сети требует определения нескольких важных параметров: количества узлов во входном слое, количества скрытых слоев, количества нейронов в каждом из них, а также количества нейронов в выходном слое. Состояние нейрона k определяется по формуле

$$S_k = \sum_{i=1}^n (x_i w_{ki}) + b_k,$$

где x_i – выходной сигнал, рассчитанный нейроном i ; w_{ki} – синаптический вес между нейронами i и k ; b_k – вес, связанный с постоянным ненулевым значением, известным как смещение нейрона.

Для использования ИНС необходимо вычислить синаптические веса и смещения. Процесс определения этих параметров называется обучением и происходит итеративно, где начальные параметры актуальны до тех пор, пока процесс не достигнет достаточной сходимости.

Функция активации f описывает, как внутренний вход и текущее состояние активации влияют на определение следующего состояния блока. Можно выделить основные наиболее используемые типы функций активации.

– Пороговая функция:

$$f(S_k) = \begin{cases} 1, & \text{если } S_k \geq 0; \\ 0, & \text{если } S_k < 0. \end{cases}$$

Функция единичного скачка, или пороговая функция, представляет собой математическую функцию, которая принимает значение 1, если ее

аргумент больше или равен некоторому порогу, и значение 0 в противном случае.

– Пример кусочно-линейной функции можно представить в виде

$$f(S_k) = \begin{cases} aS_k + d, & \text{если } S_k \leq c; \\ eS_k + g, & \text{если } S_k > c, \end{cases}$$

где a, c, d, e, g – некоторые константы.

Кусочно-линейная функция состоит из нескольких линейных участков, каждый из которых определен на своем интервале. Линейные участки соединяются так, чтобы образовать непрерывную функцию, хотя производная такой функции может быть разрывной на стыках линейных участков.

– Сигмоидальная функция:

$$f(S_k) = \left(\frac{1}{1 + \exp(-a\mu)} \right),$$

где a – параметр наклона сигмоидальной функции.

Данная функция используется чаще всего и характеризуется тем, что она возрастающая и надлежащим образом уравнивает линейное и нелинейное поведение, сохраняя свой диапазон изменений между 0 и 1.

Выбор функции активации может существенно повлиять на производительность сетей. Выпрямленный линейный блок ($\text{ReLU}(X) = \max\{X, 0\}$) является наиболее часто используемой функцией активации и широко применяется в нейронных сетях из-за своей ненасыщаемости и нелинейности [9]. По сравнению с функциями активации, которые демонстрируют насыщение, такими как сигмоидальная функция, ReLU в сочетании с градиентным спуском имеет более высокую производительность. Градиентный спуск – метод, применяемый для минимизации функции потерь путем коррекции весов. В случае обучения нейронных сетей целевой функцией является функция выходной ошибки сети. Минимумы функции образуют впадины, а максимумы – холмы [10, 11].

Многослойные перцептроны (MLP) признаны наиболее распространенными моделями ИНС. MLP включает в себя несколько слоев: входной слой, принимающий исходные данные; один или более скрытых слоев, которые обрабатывают данные с применением весовых коэффициентов и функций активации; выходной

слой, производящий окончательный результат или предсказание на основе обработанных данных. Нейроны каждого слоя соединены только с нейронами следующего слоя, без обратных связей или связей между нейронами внутри одного слоя. Кроме того, типичная особенность MLP – полная связность всех слоев. Пример структуры сети, состоящей из четырех слоев – входного, двух скрытых и выходного, – представлен на рис. 1.

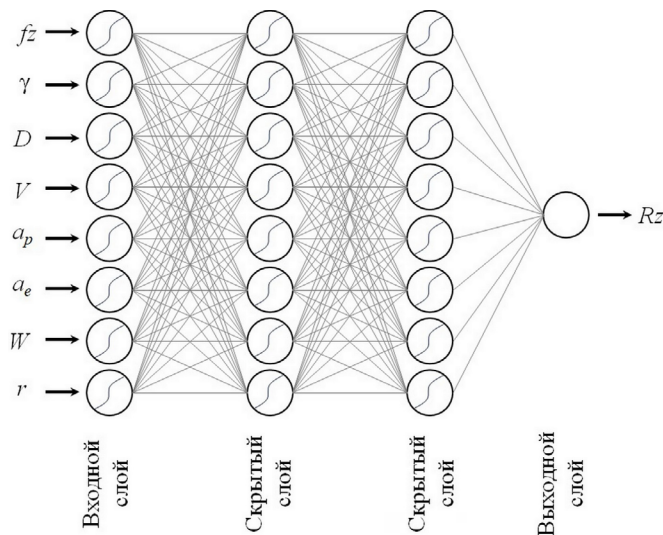


Рис. 1. Структура нейронной сети для прогнозирования параметра шероховатости Rz

Fig. 1. Neural network structure for predicting the roughness parameter Rz

В этой структуре (рис. 1) входной слой имеет 8 узлов, скрытые слои – 8 узлов, а выходной слой имеет один узел. Узлы во входном слое представляют собой следующие факторы: подача на зуб (fz , мм/зуб), угол наклона (γ , град), диаметр инструмента (D , мм), скорость резания (V , мм/мин), глубина резания (a_p , мм), боковой шаг (a_e , мм), подача СОЖ (W , л/мин), износ инструмента (r , мм). Узел в выходном слое представляет прогнозируемое значение шероховатости поверхности по параметру (Rz , мкм).

Представленная сеть полностью связана – это означает, что нейрон любого слоя соединен со всеми нейронами предыдущего слоя. Поток сигналов через сеть направлен слева направо, слой за слоем. При рассмотрении многослойной сети с узлами j и k в каждом скрытом слое пример структуры, представленный на рис. 1, можно описать конфигурацией $8-j-k-1$. В общих

чертах работа этого типа сети описывается двумя основными фазами: прямое распространение и обратное распространение.

Процесс обучения сетей MLP методом обратного распространения ошибки (backpropagation, BP) работает по следующей последовательности: прямое распространение (Forward Propagation), вычисление ошибки (Loss Calculation), обратное распространение (BP), обновление весов (Weight Update). Существенной особенностью сетей MLP является нелинейность выходов нейронов. Эта нелинейность достигается за счет использования функции активации.

Для успешного создания модели ИНС с учетом отклика Rz требуется процесс экспериментирования и настройки, учитывающий множество факторов. Несмотря на то что многие исследователи применяют ИНС для моделирования в различных областях, таких как машинная обработка [12–14], до сих пор отсутствуют четкие рекомендации по созданию прогностической модели. В этом исследовании рассматриваются элементы, которые могут повлиять на эффективность модели и отклик Rz , с использованием возможностей библиотеки TensorFlow языка Python, чтобы уменьшить неопределенность и улучшить качество прогнозов модели.

Для оценки точности моделей предсказания значений шероховатости поверхности выбраны четыре показателя эффективности (метрики) [15]: коэффициент детерминации (R^2), средняя абсолютная ошибка (MAE), средняя квадратичная ошибка (MSE) и квадратный корень из средней квадратичной ошибки (RMSE).

Коэффициент детерминации (R^2) показывает, какая доля дисперсии зависимой переменной объясняется независимыми переменными модели:

$$R^2 = \frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{\sum_{i=1}^n (Y_i - \bar{Y})^2}.$$

Здесь n представляет собой количество данных, Y_i – наблюдаемые значения, \hat{Y}_i – прогнозируемые значения, а \bar{Y} – среднее значение Y .

Несмотря на свою полезность, R^2 имеет некоторые ограничения: он не учитывает количество предикторов и может быть искажен выбросами.

MAE является мерой абсолютной ошибки ($|Y - \hat{Y}|$) между предсказанными и фактическими значениями:

$$\text{MAE} = \frac{1}{n} \sum_{i=0}^{n-1} |Y_i - \hat{Y}_i|.$$

MAE менее чувствительна к большим ошибкам по сравнению с MSE и RMSE, так как использует абсолютные значения ошибок.

MSE и RMSE характеризуются среднеквадратической ошибкой и ее квадратным корнем соответственно:

$$\text{MSE} = \frac{1}{n} \sum_{i=0}^{n-1} |Y_i - \hat{Y}_i|^2;$$

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=0}^{n-1} (Y_i - \hat{Y}_i)^2}.$$

MSE чувствительна к большим ошибкам, так как квадраты разностей увеличиваются при больших отклонениях. Поскольку RMSE измеряется в тех же единицах, что и сами данные, ее легче интерпретировать по сравнению с MSE. Однако, как и MSE, RMSE также чувствительна к большим ошибкам.

Анализ этих метрик имеет решающее значение для комплексной оценки предсказательной эффективности моделей [15, 16]. При сравнении этих метрик особое внимание будет уделено MSE, которая имеет преимущество в выявлении и учете крупных ошибок, что делает ее полезной в задачах машинного обучения, где важно минимизировать большие отклонения от истинных значений. Кроме того, функция MSE гладкая и дифференцируемая, что упрощает вычисление градиентов при использовании методов оптимизации, таких как градиентный спуск. Следовательно, при оценке точности различных моделей MSE является более подходящим выбором из-за простоты расчета и дифференцируемости. Стоит также обратить внимание на коэффициент детерминации R^2 – его значение, близкое к единице, считается наиболее благоприятным.

Вместе с этим перед использованием моделей машинного обучения будет проведен предварительный анализ данных. Важным аспектом этого анализа является проверка на нормальность, а также выявление и устранение выбросов, которые могут существенно повлиять на точность моделей.

Оптимизация моделей – один из важных этапов для достижения эффективных решений. Помимо этого, важной задачей является настройка гиперпараметров, которая направлена на обеспечение наилучшей производительности, оцененной по валидационному набору данных, в рамках выбранного алгоритма. Гиперпараметры играют значительную роль в управлении процессом обучения и существенно влияют на прогностическую точность. Правильная настройка гиперпараметров также способствует уменьшению проблем переобучения и недообучения, тем самым улучшая прогностическую точность. В решении проблемы переобучения может помочь Dropout (исключение). Это метод решения, при котором случайным образом исключаются блоки со связями из нейронной сети во время обучения, что предотвращает коадаптацию [14].

Целью настоящей работы является разработка прогностической нейросетевой модели для оценки шероховатости поверхности при фрезеровании нержавеющей стали сфероцилиндрическим инструментом.

Для достижения данной цели в процессе исследования решались следующие **задачи**:

- исследование процесса прогнозирования параметра шероховатости поверхности Rz при фрезеровании сфероцилиндрическим инструментом, включая оптимизацию архитектуры ИНС, выбор количества слоёв и настройку параметров модели, для повышения точности прогнозов;
- анализ влияния различных входных параметров, включая угол наклона инструмента, на точность прогнозирования шероховатости и разработка подхода к минимизации числа входных данных без потери эффективности модели, а также исследование возможности применения модели при ограниченных обучающих наборах;
- итоговое тестирование разработанной модели, оценка её точности с использованием таких метрик, как MSE, RMSE, MAE и R^2 , а также оценка ее эффективности через сравнительный анализ предсказанных и экспериментальных данных.

Методика исследований

Операции фрезерования были выполнены на обрабатывающем центре DMG MORI DMU 50 мощностью 9 кВт с максимальной частотой вра-

щения (n_{\max}) 8000 мин^{-1} . Деталь, подлежащая обработке, изготовлена из нержавеющей стали аустенитного класса. Химический состав стали 12X18H10T, % по массе: $C \leq 0,12$; $Si \leq 0,8$; $Mn \leq 2,0$; $P \leq 0,035$; $S \leq 0,02$; $Ni \ 9...11$; $Cr \ 17...19$; $Ti < 0,8$; Fe – остальное. В качестве материала режущего инструмента при резании использовался твердый сплав с мультислойным (TiN и TiAlN) PVD-покрытием и мелкозернистой основой диаметром 6, 8, 10 и 12 мм фирмы Sandvik Coromant. В ходе проведения экспериментов данные измерения износа радиуса инструмента (r , мм) по уровням были получены с применением контактного датчика TT140 фирмы Heidenhain.

Измерения шероховатости после фрезерования поверхности проводились при помощи профилометра SURFCOM 1800D, для данного прибора погрешность по эталону составляет 3 %. Фильтр – 50%-й гауссов. Параметр базовой длины (отсечки шага) выбран равным 0,8 мм (ISO 4288:1996) для всех измерений, так как предположительный диапазон должен составить $0,5 < Rz \leq 10$. Трассировка выполнялась три раза в направлении подачи инструмента.

Экспериментальные исследования проводились по плану эксперимента, который включает в себя как контролируемые, так и неконтролируемые факторы. Контролируемыми факторами являются a_p , fz , γ , D и V , неконтролируемыми – W и r . Параметр отклика – шероховатость поверхности Rz .

После проведения экспериментов следующим этапом стало построение моделей ИНС. Все модели были построены с использованием языка Python и библиотек TensorFlow, Keras (в составе TensorFlow) для создания, обучения нейронных сетей и работы с регуляризацией; NumPy для работы с массивами; Scikit-learn для предобработки данных. Экспериментальные данные были разделены на обучающие и тестовые наборы, которые прошли процесс стандартизации и нормализации, составляющие 70 и 30 % от общего числа проведенных экспериментов, что соответствует 28 попыткам обучения и 12 попыткам тестирования.

Алгоритм обучения нейросети – метод обратного распространения ошибки (BP). Метод используется для вычисления градиента функции потерь по отношению к весам нейронной сети.

В результате прямого распространения входные данные проходят через сеть и создают выходное предсказание. Затем вычисляется ошибка предсказания. Эта ошибка распространяется обратно через сеть, начиная с выходного слоя и проходя через все скрытые слои до входного слоя. На каждом слое вычисляется градиент ошибки по отношению к весам.

Значения гиперпараметров были протестированы, и наилучшие значения, найденные для моделей, представлены в табл. 1.

Используемый оптимизатор (в нашем случае Adam) обновляет веса в соответствии с вычисленными градиентами. Эти шаги повторяются для каждой эпохи обучения, что позволяет модели итерационно улучшать свои предсказания.

Результаты и их обсуждение

Одним из важнейших распределений является нормальное, оно описывает типичное поведение различных явлений и имеет большое значение в статистике. Для определения распределения параметра рассмотрены измеренные данные Rz после механической обработки 512 поверхностей с применением СОЖ. Для всех поверхностей технологические параметры составляли $a_p = 0,2 \text{ мм}$, $a_e = 0,4 \text{ мм}$. Результаты распределения параметра шероховатости (Rz) представлены на рис. 2.

Проверка гипотезы по критерию согласия Пирсона показала отсутствие оснований для отклонения гипотезы о нормальном законе распределения при выполнении условий $f > 100$ и $p > 0,05$. Определено, что данные выборки параметра Rz в среднем отклоняются от математического ожидания 5,357 мкм на 0,389 мкм. Установлено, что данные выборки параметра Rz распределяются по нормальному закону согласно правилу двух сигм с вероятностью 0,9873.

Для дальнейшего использования данных в нейросетевом моделировании выбросы удалены, поскольку они могут исказить результаты и снизить способность модели эффективно выявлять закономерности в данных [17]. Кроме того, для последующих экспериментов глубина и боковой шаг были постоянными и составляли $a_p = 0,2 \text{ мм}$, $a_e = 0,4 \text{ мм}$ [18]. В связи с этим количество варьируемых входных параметров для нейросетевой модели уменьшено до трех.

Гиперпараметры для модели нейронной сети BPNN
Hyperparameters for the BPNN neural network model

Model / Модель	Hyperparameters / Гиперпараметры	Indicator / Показатель
Sequential / Последовательная	Activation hidden layers / Функция активации скрытых слоев	<i>Leaky ReLU</i> / Протекающий ReLU
	Kernel_regularizer / Функция регуляризации ядра	$l1 = 0,0001, l2 = 0,0001$
	Dropout / Дропаут	0,01
	Optimizer / Алгоритм оптимизации	Adam / «Адам»
	Learning_rate / Скорость обучения	0,001
	Loss / Функция потерь	mean_squared_error / Среднеквадратичная ошибка
	Metrics / Метрики	mean_squared_error, sqrt(mse), mean_absolute_error / Среднеквадратичная ошибка; корень из среднеквадратичной ошибки; средняя абсолютная ошибка
	Batch size / Размер пакета	16
	Epochs / Эпохи	500





Рис. 2. Распределение параметра шероховатости Rz

Fig. 2. Distribution of surface roughness parameter Rz



Переменную W часто воспринимают как стохастическую и неподконтрольную, вносящую в набор данных необъяснимую дисперсию независимо от объясняющих переменных и самой модели. Чаще всего W и r рассматриваются как неотъемлемый компонент изменчивости, поэтому рассмотрим влияние указанных параметров на отклик по параметру Rz . При $fz = 0,4$ мм/зуб, $\gamma = 50^\circ$, $D = 6$ мм и $z = 2$ получены следующие результаты, представленные на рис. 3.

Рациональное применение СОЖ является важным фактором повышения производитель-

ности обработки металлов. При использовании СОЖ параметр шероховатости Rz в среднем снизился на 14 %.

Скорость диссипации существенно зависит от скорости резания (V_c , м/мин) и объема удаляемого материала (Q , см³/мин). При этом

$$Q = \frac{S_{zj} \cdot fz \cdot n_c \cdot z}{1000},$$

где n_c – частота вращения мин⁻¹; S_{zj} – площадь поперечного сечения при фрезеровании сферическим инструментом, мм²:


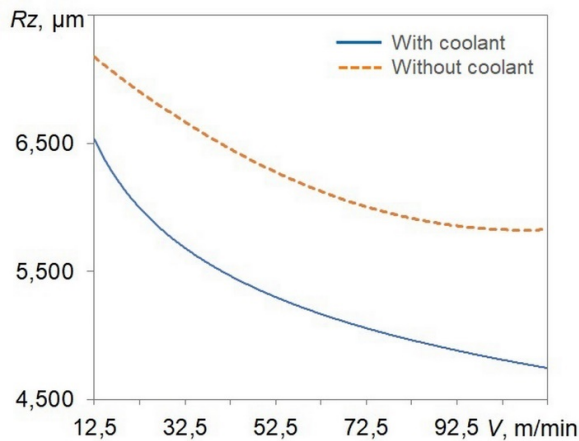


Рис. 3. Зависимость параметра шероховатости Rz от скорости резания, СОЖ и износа инструмента

Fig. 3. Dependence of surface roughness parameter Rz on cutting speed, coolant and tool wear

$$S_{zj} = \left(2 \left(\frac{a_p}{2} \right)^2 + \frac{2 \sin \left(\frac{2 \cos^{-1} \left(1 - 2 \frac{a_p}{2} \frac{R}{2} \right)}{2R} \right) R}{4} \right) \times \left(fz \cdot \sin \tan^{-1} \left(\frac{a_p}{2 \sin \left(\frac{2 \cos^{-1} \left(1 - 2 \frac{a_p}{2} \frac{R}{2} \right)}{2R} \right)} \right) \right) \cdot 2$$

Эффект от действия СОЖ зависит от рационального выбора условий резания, износа инструмента, инструментального и обрабатываемого материала [19]. В данном случае необходимо использовать СОЖ и назначать скорость резания не ниже 75 м/мин для достижения минимально возможного параметра шероховатости Rz , тогда параметр W не будет оказывать существенного влияния на интерпретацию или производительность модели.

Шероховатость поверхности обрабатываемого материала также зависит от степени износа инструмента [20], при этом установлена следующая

корреляционная зависимость: $R = -0,95$ (сильная, отрицательная). При увеличении количества обрабатываемых поверхностей (i , pcs) происходит размерный износ инструмента, в пределах 2...4 мкм, вследствие чего увеличивается параметр Rz на 21 % от минимальных значений.

Рассмотрим эксперимент с тремя факторами, каждый из которых имеет два уровня (табл. 2). Тогда в полном факторном плане восемь комбинаций ($k = 2^3 = 8$).

На основе теоретических данных о факторах, влияющих на шероховатость, была рассмотрена следующая модель: $Y(Rz) = a + b_{fz} X_{fz} + b_{\gamma} X_{\gamma} + b_D X_D$. Здесь рассчитанные естественные коэффициенты регрессии составляют $a = 3,00$; $b_{fz} = 2,77$; $b_{\gamma} = -0,55$; $b_D = -1,08$.

Параметры уравнения регрессии были оценены методом наименьших квадратов (МНК). Стандартизованные β -коэффициенты: $\beta_{fz} = 0,17$; $\beta_{\gamma} = -3,33$; $\beta_D = -1,01$. Сравнение модулей значений стандартизованных коэффициентов регрессии β позволяет заключить, что γ (угол наклона сфероцилиндрического инструмента) – наиболее влиятельный фактор при формировании параметра шероховатости Rz . При фиксации фактора fz остальные факторы показывают отрицательные стандартизованные коэффициенты β ($\beta_{\gamma} = -0,54$; $\beta_D = -1,09$), что указывает на уменьшение значения отклика Rz . Значение $R^2 = 0,14$ указывает на то, что fz играет важную роль в объяснении Rz , и его фиксация значительно снижает объяснительную способность модели.

В случае фиксации фактора γ стандартизованные коэффициенты β ($\beta_{fz} = 2,77$; $\beta_D = -1,09$) показывают, что fz имеет сильный положительный

Таблица 2

Table 2

Значения экспериментальных данных
Experimental data values

№	fz	γ	D	$fz\gamma$	fzD	γD	$fz\gamma D$	Rz
1	0,5	50	12	1	1	1	1	3,05
2	0,1	50	12	-1	-1	1	-1	0,13
3	0,1	10	12	1	-1	-1	1	0,18
4	0,1	10	6	1	1	1	-1	0,37
5	0,5	10	12	-1	1	-1	-1	4,33
6	0,5	50	6	1	-1	-1	-1	6,38
7	0,1	50	6	-1	1	-1	1	0,26
8	0,5	10	6	-1	-1	1	1	9,32

ный вклад, а D – сильный отрицательный. Высокое значение $R^2 = 0,84$ указывает на то, что даже при фиксированном γ факторы fz и D остаются важными для объяснения Rz .

Когда D фиксирован, стандартизованные коэффициенты $\beta_{fz} = 2,76$; $\beta_D = -0,54$. Это означает, что при фиксированном D увеличение fz приводит к увеличению Rz , а увеличение γ – к уменьшению. Значение $R^2 = 0,75$ также указывает на то, что модель с фиксированным D хорошо объясняет вариацию в Rz , а факторы fz и γ остаются важными для объяснения Rz .

Регрессионная модель (RM), полученная после проведения эксперимента по обработке пространственно-сложных поверхностей сфероцилиндрической фрезой и характеризующая взаимосвязь между величиной шероховатости, подачи на зуб, диаметром и углом наклона инструмента, выраженная нормализованной моделью, имеет следующий вид:

$$Rz_{(RM)} = 3 + 2,77_{fz} - 0,55_{\gamma} - 1,08_D - 0,51_{fz\gamma} - 1_{fzD} + 0,22_{\gamma D} + 0,2_{fz\gamma D}.$$

В настоящем исследовании рассмотрим влияние функции активации на производительность восьми моделей нейронных сетей при прогнозировании Rz (рис. 4).

Функция потерь отражает, насколько эффективно модель выполняет задачу во время обучения. Функция активации ReLU с ее нелинейностями, ускоряющими обучение, требует тщательного мониторинга потерь – как Train Loss, так и Validation Loss. Появление низких

потерь на обучающем наборе, но высоких – на валидационном (тестовом) наборе предполагает потенциальное переобучение (overfitting), указывая на то, что модель запоминает обучающие данные вместо того, чтобы изучать общие закономерности. Как видно из рис. 3, модели 3–32–16–1 и 3–6–6–1 слишком хорошо запомнили тренировочные данные, но плохо справляются с новыми.

В соответствии с представленными результатами и с учетом выбора конфигурации сети (табл. 3) на основе MSE, установлено, что лучшими конфигурациями сетей являются 3–64–64–1 (0,0481), 3–20–14–1 (0,0470) и 3–16–16–1 (0,0313). Вместе с этим они характеризуются низкими значениями RMSE, которые составили 0,2174, 0,2135, 0,1770, и MAE с результатами 0,1155, 0,1251, 0,1014 соответственно. RMSE интерпретируется как значение ошибки в той же шкале, что и сами данные.

При проверке моделей с наилучшей прогностической эффективностью использовался план с числом экспериментов $k = 12$ и факторами $fz \in \{0,4, 0,5\}$, $\gamma \in \{10, 15, 20, 30, 40, 50\}$, $D \in \{6\}$, распределенными случайным образом.

В табл. 4 и на рис. 5 представлены данные, показывающие связь между значениями, полученными в ходе проведения эксперимента, рассчитанными на основе разработанной регрессионной модели и предсказанными откликами ИНС (BPNN).

При оценке табл. 4 и рис. 5 можно сделать вывод о том, что рассматриваемые модели показали близкие прогнозируемые значения ($Y(Rz)$)

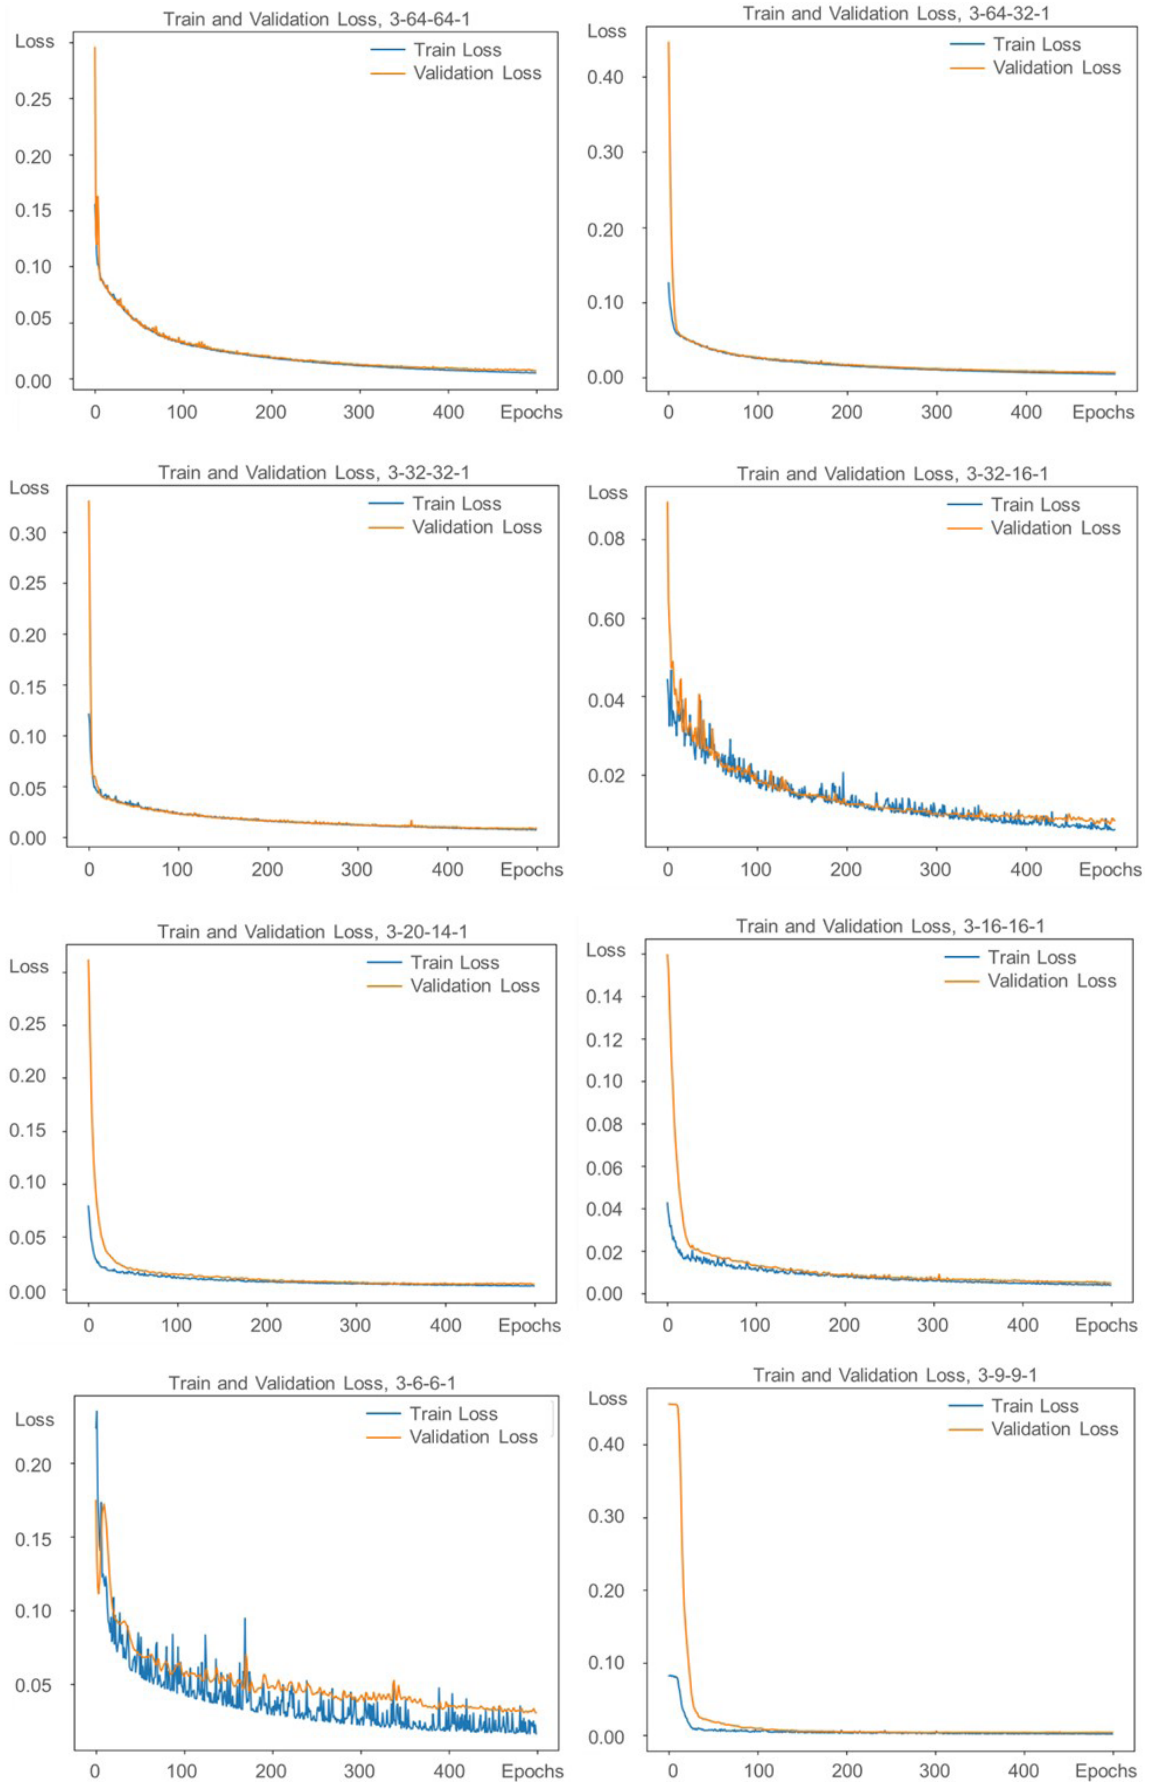


Рис. 4. Скорость обучения различных конфигураций

Fig. 4. Learning rates of various configurations

Таблица 3

Table 3

Прогностическая эффективность нейронной сети
Predictive performance of the neural network

Метрики / Metrics	3-64-64-1	3-64-32-1	3-32-32-1	3-32-16-1	3-20-14-1	3-16-16-1	3-6-6-1	3-9-9-1
Среднеквадратичная ошибка / <i>MSE</i>	0,0481	0,0621	0,0572	0,0685	0,0470	0,0313	0,0415	0,0603
Квадратный корень из <i>MSE</i> / <i>RMSE</i>	0,2174	0,2492	0,2391	0,2617	0,2135	0,1770	0,2037	0,2456
Средняя абсолютная ошибка / <i>MAE</i>	0,1155	0,1228	0,1656	0,1361	0,1251	0,1014	0,1306	0,1447
Коэффициент детерминации R^2 / R^2	0,9904	0,9889	0,9898	0,9878	0,9916	0,9944	0,9926	0,9862

Таблица 4

Table 4

Прогнозируемые ($Y(R_z)$) и экспериментальные (R_z) значения для выбранных конфигураций при $k = 12$

Predicted ($Y(R_z)$) and experimental (R_z) values for selected configurations at $k = 12$

fz	γ	D	R_z	$R_{z(RM)}$	$Y(R_z)$		
					3-64-64-1	3-20-14-1	3-16-16-1
0,4	10	6	6,945	7,090	6,680	6,277	6,491
0,4	50		4,610	4,840	4,938	5,025	5,116
0,4	20		6,108	6,528	6,037	6,469	6,303
0,4	40		5,400	5,403	5,357	5,503	5,261
0,5	20		8,341	8,590	7,923	8,372	7,875
0,4	15		6,614	6,809	6,426	6,495	6,330
0,5	10		9,163	9,330	8,272	8,402	8,925
0,4	30		5,826	5,965	6,067	5,987	6,307
0,5	15		8,786	8,960	8,463	8,590	8,072
0,5	40		6,992	7,110	7,035	6,977	7,407
0,5	30		7,694	7,850	7,792	7,443	7,896
0,5	50		6,024	6,370	6,548	6,745	6,541
MSE				0,049	0,136	0,167	0,175
RMSE				0,221	0,369	0,408	0,418
MAE(R_z)				0,195	0,286	0,317	0,384
MAE(R_a)				0,049	0,072	0,081	0,095
R^2				0,973	0,924	0,907	0,903

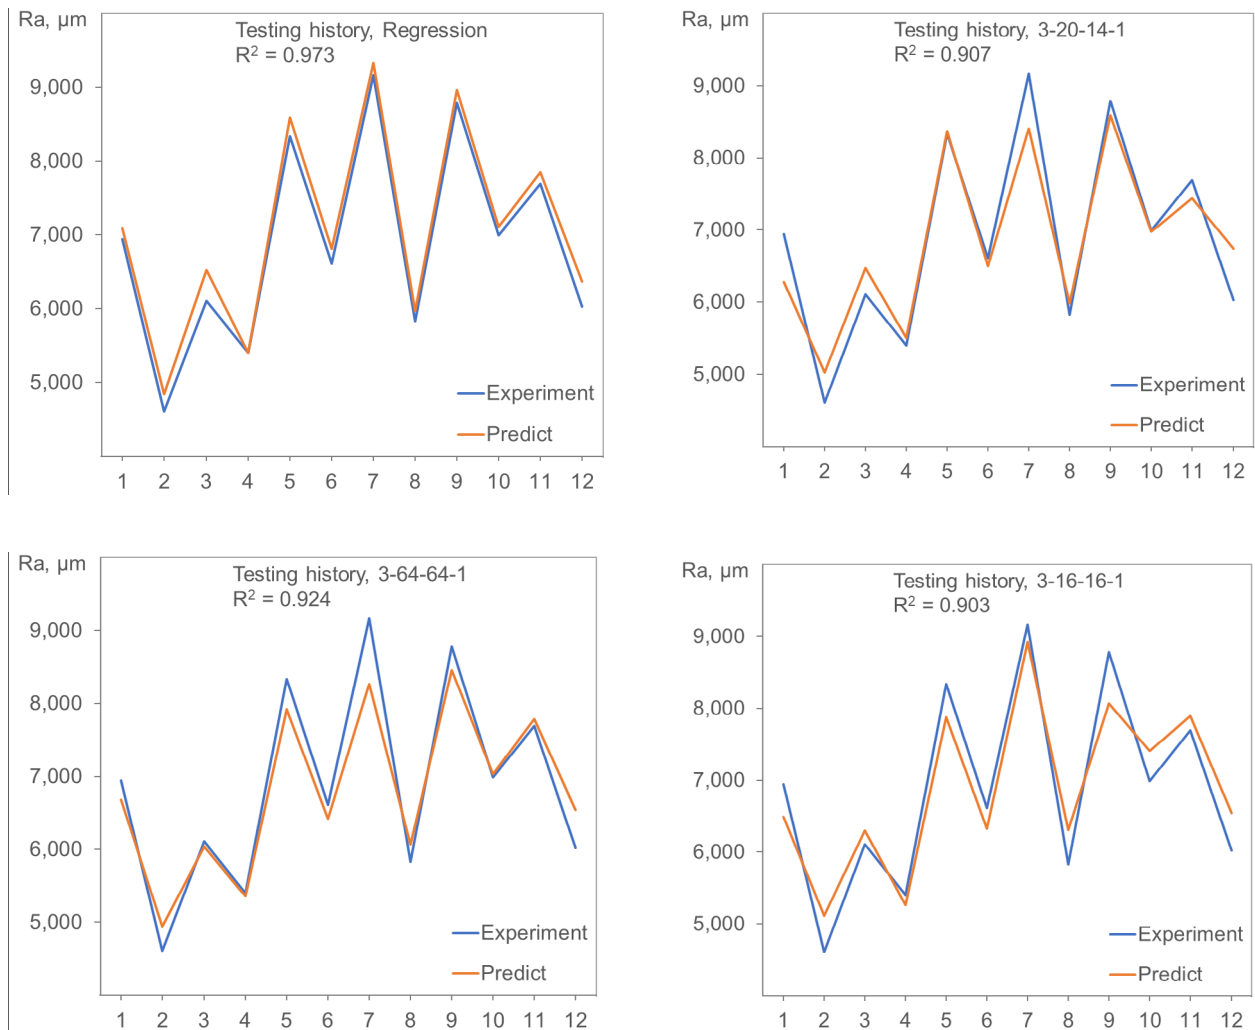


Рис. 5. Предсказанные значения (Predict) и экспериментальные (Experiment) для выбранных классификаций

Fig. 5. Predicted and Experimental values for selected classifications

к фактическим (R_z). Коэффициент детерминации R^2 составил для регрессионной модели 0,973, 0,924, 0,907 и 0,903 соответственно для рассматриваемых конфигураций. По всем конфигурациям $MAE \approx 0,2955$ мкм, это означает, что в среднем предсказания моделей отклоняются от фактических значений R_z на 0,2955 мкм.

Параметр R_z находится в корреляционной зависимости с параметром Ra [21–23], имея коэффициент корреляции 0,91, что указывает на сильную положительную связь между ними. Этот параметр был получен в ходе статистической обработки экспериментальных данных и демонстрирует значительную степень зависимости Ra и R_z в соотношении $Ra = (R_z - 0,391) / 4,022$.

Сравнение экспериментальных данных с предсказаниями различных моделей позволило установить MAE для параметра $Ra \approx 0,049$ мкм.

Такое значение можно считать пренебрежимо малым в контексте шероховатости поверхности, указывая на то, что наблюдаемые значения чрезвычайно близки к фактическому среднему значению. Таким образом, можно сделать вывод, что для анализа шероховатости найденная погрешность незначительна и не оказывает существенного влияния на точность результатов, тем самым подтверждая соответствие наблюдаемых данных фактическому среднему значению.

Заклучение

В данной статье рассмотрена искусственная нейронная сеть в качестве способа прогнозирования шероховатости поверхности при фрезеровании сфероцилиндрическим инструментом. Описаны этапы настройки архитектуры ИНС,



в частности подбор количества слоев и нейронов в скрытых слоях, для повышения точности прогнозов.

Рассмотрена концепция выбора параметров на основе значимости вклада в точность предсказания шероховатости поверхности R_z для сокращения входных факторов до возможно минимального. Результаты показывают, что получить точные прогнозы шероховатости поверхности возможно даже при учете небольшого количества входных параметров с относительно небольшими обучающими наборами.

Выбор правильной конфигурации сети и входных параметров имеет большое значение для обеспечения точности прогнозов. Кроме того, в исследовании подчеркивается важность учета угла наклона сфероцилиндрического инструмента от 10 до 50 градусов в обучении моделей ИНС, при этом увеличение угла влияет на уменьшение величины параметров шероховатости.

Итоговые тестирования, проведенные для проверки адекватности предложенной модели, показали, что модель хорошо работает с разумной точностью при заданном наборе параметров. В завершение можно сказать, что это исследование вносит значительный вклад в моделирование процессов механической обработки фрезерованием.

Список литературы

1. Система автоматизированного технологического управления износостойкостью деталей машин при обработке резанием / А.Г. Суслов, Д.М. Медведев, Д.И. Петрешин, О.Н. Федонин // *Научное издание технологии в машиностроении*. – 2018. – № 5 (83). – С. 40–44. – DOI: 10.30987/article_5ad8d291cddcd8.06334386.
2. Sensor data and information fusion to construct digital-twins virtual machine tools for cyber-physical manufacturing / Y. Cai, B. Starly, P. Cohen, Y.-S. Lee // *Procedia Manufacturing*. – 2017. – Vol. 10. – P. 1031–1042. – DOI: 10.1016/j.promfg.2017.07.094.
3. Zain A.M., Haron H., Sharif S. Prediction of surface roughness in the end milling machining using artificial neural network // *Expert Systems with Applications*. – 2010. – Vol. 37 (2). – P. 1755–1768. – DOI: 10.1016/j.eswa.2009.07.033.
4. Convolutional neural network-based tool condition monitoring in vertical milling operations using acoustic signals / C. Cooper, P. Wang, J. Zhang, R.X. Gao, T. Roney, I. Ragai, D. Shaffer // *Procedia Manufacturing*.

ing. – 2020. – Vol. 49. – P. 105–111. – DOI: 10.1016/j.promfg.2020.07.004.

5. Application of measurement systems in tool condition monitoring of milling: a review of measurement science approach / D.Yu. Pimenov, M. Kumar Gupta, L.R.R. da Silva, M. Kiran, N. Khanna, G.M. Krolczyk // *Measurement*. – 2022. – Vol. 199. – P. 111503. – DOI: 10.1016/j.measurement.2022.111503.

6. A surface quality prediction model considering the machine-tool-material interactions / M. Guo, W. Xia, C. Wu, C. Luo, Z. Lin // *The International Journal of Advanced Manufacturing Technology*. – 2024. – Vol. 131 (7–8). – P. 1–19. – DOI: 10.1007/s00170-024-13072-2.

7. Chen C.H., Jeng S.Y., Lin C.J. Prediction and analysis of the Surface roughness in CNC end milling using neural networks // *Application Science*. – 2022. – Vol. 12 (1). – P. 393. – DOI: 10.3390/app12010393.

8. Oktem H., Erzurumlu T., Erzincanli F. Prediction of minimum surface roughness in end milling mold parts using neural network and genetic algorithm // *Materials & Design*. – 2006. – Vol. 27 (9). – P. 735–744. – DOI: 10.1016/j.matdes.2005.01.010.

9. Bingham G., Miikkulainen R. Discovering parametric activation functions // *Neural Networks*. – 2022. – Vol. 148. – P. 48–65. – DOI: 10.1016/j.neunet.2022.01.001.

10. Галушкин А.И. Нейронные сети: основы теории – М.: Горячая линия – Телеком, 2017. – 496 с. – ISBN 978-5-9912-0082-0. – URL: <https://asu.tusur.ru/learning/010402/d15a/010402-d15a-book1.pdf> (дата обращения: 02.04.2025).

11. Анцев А.В., Янов Е.С., Данг Ч.Х. Оптимизация режимов резания с учетом уровня вибрации на основе применения методов искусственного интеллекта // *Вестник Воронежского государственного технического университета*. – 2020. – Т. 16., № 3. – С. 101–109. – DOI: 10.25987/VSTU.2020.16.3.014.

12. Ерыгин Е.В., Дуюн Т.А. Прогнозирование шероховатости поверхности при чистовом фрезеровании с использованием нейронных сетей // *Вестник Белгородского государственного технологического университета им. В.Г. Шухова*. – 2019. – № 10. – С. 135–141. – DOI: 10.34031/article_5db3f6c82c1ea9.69942788.

13. Некоторые вопросы совместного применения детерминированных математических моделей и нейронных сетей в цифровых двойниках процесса обработки металлов резанием на металлорежущих станках / В.П. Лапшин, И.А. Туркин, В.И. Гвинджилия, И.О. Дудинов, Д.О. Гамалеев // *СТИН*. – 2024. – № 10. – С. 6–11.

14. Dropout: a simple way to prevent neural networks from overfitting / N. Srivastava, G. Hinton,

A. Krizhevsky, I. Sutskever, R. Salakhutdinov // *Journal of Machine Learning Research*. – 2014. – Vol. 15 (56). – P. 1929–1958.

15. Machine learning models for prediction and classification of tool wear in sustainable milling of additively manufactured 316 stainless steel / M. Danish, M.K. Gupta, S.A. Irfan, S.M. Ghazali, M.F. Rathore, G.M. Krolczyk, A. Alsaady // *Results in Engineering*. – 2024. – Vol. 22. – P. 102015. – DOI: 10.1016/j.rineng.2024.102015.

16. *Chai T., Draxler R.R.* Root mean square error (RMSE) or mean absolute error (MAE) arguments against avoiding RMSE in the literature // *Geoscientific Model Development*. – 2014. – Vol. 7 (3). – P. 1247–1250. – DOI: 10.5194/gmd-7-1247-2014.

17. A survey on data preprocessing for data stream mining: current status and future directions / S. Ramírez-Gallego, B. Krawczyk, S. García, M. Woźniak, F. Herrera // *Neurocomputing*. – 2017. – Vol. 239. – P. 39–57. – DOI: 10.1016/j.neucom.2017.01.078.

18. Modeling of cutter displacements during ball end milling of inclined surfaces / S. Wojciechowski, T. Chwalczuk, P. Twardowski, G.M. Krolczyk // *Archives of Civil and Mechanical Engineering*. – 2015. – Vol. 15. – P. 798–805. – DOI: 10.1016/j.acme.2015.06.008.

19. *Куцева М.Е., Клауч Д.Н., Кобелев О.А.* Принципы выбора смазочно-охлаждающих технологических сред для обработки металлов резанием //

Известия МГТУ «МАМИ». – 2014. – Т. 8, № 1–2. – С. 73–76. – DOI: 10.17816/2074-0530-67737.

20. Tool wear prediction through AI-assisted digital shadow using industrial edge device / M. Chehreghad, G. Kecibas, C. Besirova, U. Uresin, M. Irican, I. Lazoglu // *Journal of Manufacturing Processes*. – 2024. – Vol. 113. – P. 117–130. – DOI: 10.1016/j.jmapro.2024.01.052.

21. Формирование параметров шероховатости на основе корреляционных связей при чистовом фрезеровании пространственно-сложных поверхностей / М.Р. Гимадеев, В.М. Давыдов, А.В. Никитенко, А.В. Сарыгин // *Упрочняющие технологии и покрытия*. – 2019. – № 15 (6). – С. 243–249.

22. *Gimadeev M.R., Li A.A.* Analysis of systems for automated provision of surface roughness parameters based on dynamic monitoring // *Advanced Engineering Research (Rostov-on-Don)*. – 2022. – Vol. 22 (2). – P. 116–129. – DOI: 10.23947/2687-1653-2022-22-2-116-129.

23. Экспериментальное исследование динамики процесса механообработки концевыми сфероцилиндрическими фрезами / М.Р. Гимадеев, А.А. Ли, В.О. Беркун, В.А. Стельмаков // *Обработка металлов (технология, оборудование, инструменты)*. – 2023. – Т. 25, № 1. – С. 44–56. – DOI: 10.17212/1994-6309-2023-25.1-44-56.

Конфликт интересов


Авторы заявляют об отсутствии конфликта интересов.

© 2025 Авторы. Издательство Новосибирского государственного технического университета. Эта статья доступна по лицензии Creative Commons «Attribution» («Атрибуция») 4.0 Всемирная (<https://creativecommons.org/licenses/by/4.0>).



Obrabotka metallov - Metal Working and Material Science





Journal homepage: http://journals.nstu.ru/obrabotka_metallov



Prediction of surface roughness in milling with a ball end tool using an artificial neural network

Mikhail Gimadeev^{a,*}, Vadim Stelmakov^b, Aleksandr Nikitenko^c, Maksim Uliskov^d

Pacific National University, 136 Tihookeanskaya St., Khabarovsk, 680035, Russian Federation

^a  <https://orcid.org/0000-0001-6685-519X>,  009063@togudv.ru; ^b  <https://orcid.org/0000-0003-2763-1956>,  009062@togudv.ru;

^c  <https://orcid.org/0000-0003-4729-5558>,  005392@togudv.ru; ^d  <https://orcid.org/0009-0001-9858-423X>,  2016104779@togudv.ru

ARTICLE INFO

Article history:

Received: 30 January 2025

Revised: 01 March 2025

Accepted: 27 March 2025

Available online: 15 June 2025

Keywords:

Milling

Roughness

Regression analysis

Artificial intelligence

Neural network

Standard error

Funding

This work has funded by the Ministry of science and higher education of Russian Federation (project № FEME–2024–0010).

ABSTRACT

Introduction. Milling stainless steel with a ball-end tool is a complex technological process that requires precise control of processing parameters to ensure high surface quality. In this regard, it is an urgent task to develop methods for predicting roughness parameters, such as R_z . **The aim of this work** is to develop a predictive neural network model that can estimate surface roughness when milling stainless steel using a ball-end tool. **Method and methodology.** The main focus is on error backpropagation and gradient descent methods, as well as hyperparameter tuning, which are necessary to prevent overfitting and underfitting of the model. Experimental studies include the analysis of both controlled variables, such as feed per tooth, angle of inclination and diameter of the tool, and uncontrolled, including coolant supply and tool wear. **Results and discussions.** The use of coolant for milling austenitic steel has reduced the roughness parameters R_z by an average of 14%. A strong negative correlation has been established between the dimensional wear of the tool and the parameter R_z (–0.95). At the same time, wear in the range of 2...4 μm affects an increase in the R_z parameter by 21% compared to the minimum values. The data obtained were used to train eight configurations of artificial neural networks, which were used to predict roughness using the R_z parameter. The results show that the 3-16-16-1 network configuration showed the lowest MSE (0.0313), followed by 3-20-14-1 (0.0470) and 3-64-64-1 (0.0481), respectively. In addition, these configurations also demonstrated the lowest average absolute error values, which demonstrate the average of the absolute differences between predicted and observed values (0.1014; 0.1251 and 0.1155, respectively), and the coefficient of determination, which is a statistical measure indicating the proportion of data variability explained by the model (0.9944; 0.9916; 0.9904). A comparison of the experimental data with the predictions of various models allowed us to determine the average value of the absolute differences for the models according to the parameter $R_a \approx 0.074$. The study suggests approaches to training neural network models for accurate prediction of roughness parameters, which makes a significant contribution to the methods of modeling machining processes.

For citation: Gimadeev M.R., Stelmakov V.A., Nikitenko A.V., Uliskov M.V. Prediction of surface roughness in milling with a ball end tool using an artificial neural network. *Obrabotka metallov (tehnologiya, oborudovanie, instrumenty) = Metal Working and Material Science*, 2025, vol. 27, no. 2, pp. 126–141. DOI: 10.17212/1994-6309-2025-27.2-126-141. (In Russian).

References

1. Suslov A.G., Medvedev D.M., Petreshin D.I., Fedonin O.N. Sistema avtomatizirovannogo tekhnologicheskogo upravleniya iznosostoikost'yu detalei mashin pri obrabotke rezaniem [System for automated wear-resistance technological control of machinery at cutting]. *Naukoemkie tekhnologii v mashinostroenii = Science intensive technologies in mechanical engineering*, 2018, no. 5 (83), pp. 40–44. DOI: 10.30987/article_5ad8d291cddcd8.06334386.
2. Cai Y., Starly B., Cohen P., Lee Y.S. Sensor data and information fusion to construct digital-twins virtual machine tools for cyber-physical manufacturing. *Procedia Manufacturing*, 2017, vol. 10, pp. 1031–1042. DOI: 10.1016/j.promfg.2017.07.094.

* Corresponding author

Gimadeev Mikhail R., Ph.D. (Engineering), Associate Professor
 Pacific National University,
 136 Tihookeanskaya st.,
 680035, Khabarovsk, Russian Federation
 Tel.: +7 924 216-31-39, e-mail: 009063@togudv.ru

3. Zain A.M., Haron H., Sharif S. Prediction of surface roughness in the end milling machining using artificial neural network. *Expert Systems with Applications*, 2010, vol. 37 (2), pp. 1755–1768. DOI: 10.1016/j.eswa.2009.07.033.
4. Cooper C., Wang P., Zhang J., Gao R.X., Roney T., Ragai I., Shaffer D. Convolutional neural network-based tool condition monitoring in vertical milling operations using acoustic signals. *Procedia Manufacturing*, 2020, vol. 49, pp. 105–111. DOI: 10.1016/j.promfg.2020.07.004.
5. Pimenov D.Y., Kumar Gupta M., da Silva L.R.R., Kiran M., Khanna N., Krolczyk G.M. Application of measurement systems in tool condition monitoring of milling: a review of measurement science approach. *Measurement*, 2022, vol. 199, p. 111503. DOI: 10.1016/j.measurement.2022.111503.
6. Guo M., Xia W., Wu C., Luo C., Lin Z. A surface quality prediction model considering the machine-tool-material interactions. *The International Journal of Advanced Manufacturing Technology*, 2024, vol. 131 (7–8), pp. 1–19. DOI: 10.1007/s00170-024-13072-2.
7. Chen C.H., Jeng S.Y., Lin C.J. Prediction and analysis of the Surface roughness in CNC end milling using neural networks. *Application Science*, 2022, vol. 12 (1), p. 393. DOI: 10.3390/app12010393.
8. Oktem H., Erzurumlu T., Erzincanli F. Prediction of minimum surface roughness in end milling mold parts using neural network and genetic algorithm. *Materials & Design*, 2006, vol. 27 (9), pp. 735–744. DOI: 10.1016/j.matdes.2005.01.010.
9. Bingham G., Miikkulainen R. Discovering parametric activation functions. *Neural Networks*, 2022, vol. 148, pp. 48–65. DOI: 10.1016/j.neunet.2022.01.001.
10. Galushkin A.I. *Neironnyye seti: osnovy teorii* [Neural networks: fundamentals of theory]. Moscow, Goryachaya liniya – Telekom Publ., 2010. 496 p. ISBN 978-5-9912-0082-0. Available at: <https://asu.tusur.ru/learning/010402/d15a/010402-d15a-book1.pdf> (accessed 02.04.2025).
11. Antsev A.V., Yanov E.S., Dang Ch.Kh. Optimizatsiya rezhimov rezaniya s uchetom urovnya vibratsii na osnove primeneniya metodov iskusstvennogo intellekta [Cutting modes optimization taking into account vibration level based on application of artificial intelligence methods]. *Vestnik Voronezhskogo gosudarstvennogo tekhnicheskogo universiteta = Bulletin of Voronezh state technical university*, 2020, vol. 16 (3), pp. 101–109. DOI: 10.25987/VSTU.2020.16.3.014.
12. Erygin E.V., Duyun T.A. Prognozirovanie sherokhovatosti poverkhnosti pri chistovom frezerovanii s ispol'zovaniem neironnykh setei [Forecasting of the surface roughness in finishing milling using neural networks]. *Vestnik Belgorodskogo gosudarstvennogo tekhnologicheskogo universiteta im. V.G. Shukhova = Bulletin of Belgorod state technological university named after V.G. Shukhov*, 2019, no. 10, pp. 135–141. DOI: 10.34031/article_5db3f6c82c1ea9.69942788.
13. Lapshin V.P., Turkin I.A., Gvindzhilia V.I., Dudinov I.O., Gamaleev D.O. Nekotorye voprosy sovместnogo primeneniya determinirovannykh matematicheskikh modelei i neironnykh setei v tsifrovyykh dvoynikakh protsessa obrabotki metallov rezaniem na metallovezhushchikh stankakh [Using deterministic models and neural networks in digital twins of metal cutting processes]. *STIN = Russian Engineering Research*, 2024, no. 10, pp. 6–11. (In Russian).
14. Srivastava N., Hinton G., Krizhevsky A., Sutskever I., Salakhutdinov R. Dropout: a simple way to prevent neural networks from overfitting. *Journal of Machine Learning Research*, 2014, vol. 15 (56), pp. 1929–1958.
15. Danish M., Gupta M.K., Irfan S.A., Ghazali S.M., Rathore M.F., Krolczyk G.M., Alsaady A. Machine learning models for prediction and classification of tool wear in sustainable milling of additively manufactured 316 stainless steel. *Results in Engineering*, 2024, vol. 22, p. 102015. DOI: 10.1016/j.rineng.2024.102015.
16. Chai T., Draxler R.R. Root mean square error (RMSE) or mean absolute error (MAE)? – Arguments against avoiding RMSE in the literature. *Geoscientific Model Development*, 2014, vol. 7 (3), pp. 1247–1250. DOI: 10.5194/gmd-7-1247-2014.
17. Ramírez-Gallego S., Krawczyk B., García S., Wozniak M., Herrera F. A survey on data preprocessing for data stream mining: current status and future directions. *Neurocomputing*, 2017, vol. 239, pp. 39–57. DOI: 10.1016/j.neucom.2017.01.078.
18. Wojciechowski S., Chwalczuk T., Twardowski P., Krolczyk G.M. Modeling of cutter displacements during ball end milling of inclined surfaces. *Archives of Civil and Mechanical Engineering*, 2015, vol. 15, pp. 798–805. DOI: 10.1016/j.acme.2015.06.008.
19. Kuscheva M.E., Klauch D.N., Kobelev O.A. Printsipy vybora smazочно-okhlazhdayushchikh tekhnologicheskikh sred dlya obrabotki metallov rezaniem [Principles of selection of cutting technological mediums for metal cutting]. *Izvestiya MGTU MAMI*, 2014, vol. 8, no. 1–2, pp. 73–76. DOI: 10.17816/2074-0530-67737. (In Russian).



20. Chehrehzad M., Kecibas G., Besirova C., Uresin U., Irican M., Lazoglu I. Tool wear prediction through AI-assisted digital shadow using industrial edge device. *Journal of Manufacturing Processes*, 2024, vol. 113, pp. 117–130. DOI: 10.1016/j.jmapro.2024.01.052.

21. Gimadeev M.R., Davydov V.M., Nikitenko A.V., Sarygin A.V. Formirovanie parametrov sherokhovatosti na osnove korrelyatsionnykh svyazei pri chistovom frezerovanii prostranstvenno-slozhnykh poverkhnostei [Formation of roughness parameters based on correlation relations during finishing milling of spatially complex surfaces]. *Uprochnyayushchie tekhnologii i pokrytiya = Strengthening Technologies and Coatings*, 2019, vol. 15, no. 6 (174), pp. 243–248.

22. Gimadeev M.R., Li A.A. Analysis of automated surface roughness parameter support systems based on dynamic monitoring. *Advanced Engineering Research (Rostov-on-Don)*, 2022, vol. 22 (2), pp. 116–129. DOI: 10.23947/2687-1653-2022-22-2-116-129.

23. Gimadeev M.R., Li A.A., Berkun V.O., Stelmakov V.A. Eksperimental'noe issledovanie dinamiki protsessa mekhanoobrabotki kontsevymi sferotsilindricheskimi frezami [Experimental study of the dynamics of the machining process by ball-end mills]. *Obrabotka metallov (tekhnologiya, oborudovanie, instrumenty) = Metal Working and Material Science*, 2023, vol. 25, no. 1, pp. 44–56. DOI: 10.17212/1994-6309-2023-25.1-44-56.

Conflicts of Interest

The authors declare no conflict of interest.

© 2025 The Authors. Published by Novosibirsk State Technical University. This is an open access article under the CC BY license (<http://creativecommons.org/licenses/by/4.0>).