

СРАВНЕНИЕ МАТЕМАТИЧЕСКОГО И НЕЙРОСЕТЕВОГО МОДЕЛИРОВАНИЯ
ЭКСПЛУАТАЦИОННЫХ СВОЙСТВ ШПИНДЕЛЬНОГО УЗЛА

© 2025 А.Ф. Денисенко, Р.В. Ладагин

Самарский государственный технический университет, г. Самара, Россия

Статья поступила в редакцию 09.09.2025

В статье проведено сравнительное исследование эффективности классических математических моделей (линейных и нелинейных) и нейронных сетей для прогнозирования эксплуатационных свойств шпиндельных узлов металлорежущих станков. Эксперименты выполнены на данных, полученных с группы токарных станков при различном объеме наблюдений и составе входных переменных, включая частоту вращения шпинделя, нагрузку, время работы и конструктивные параметры шпиндельного узла. Построение моделей осуществлялось в программе Statistica, оценка качества — по коэффициенту детерминации R^2 , средней относительной ошибке и анализу нормальности остатков. Результаты показали, что нейронные сети обеспечивают стабильно низкую ошибку прогнозирования (до 2–5%) независимо от объема данных и числа переменных, а их остатки лучше соответствуют нормальному распределению. Линейные модели демонстрируют низкую точность, особенно для температуры (T), тогда как нелинейные (полиномиальные, логарифмические) конкурируют с нейросетями только при малом числе факторов, с увеличением же состава переменных их качество снижается. Выводы подтверждают преимущество нейросетей в многофакторном прогнозировании, что обусловлено их способностью учитывать скрытые корреляции. Классические модели остаются актуальными для локальных задач с ограниченным числом параметров. Работа подчеркивает необходимость внедрения нейросетевых подходов в проектирование станков для повышения точности прогнозирования эксплуатационных характеристик.

Ключевые слова: шпиндельный узел, эксплуатационные свойства, нейронные сети, математическое моделирование, коэффициент детерминации.

DOI: 10.37313/1990-5378-2025-27-3(2)-221-230

EDN: QJJEPF

ВВЕДЕНИЕ

В последнее десятилетие широкое распространение получили нейронные сети. Они успешно применяются в различных отраслях народного хозяйства и решают самые разнообразные задачи [1, 2]: распознавание фото и речи, прогнозирование и анализ рынков, оптимизация конструкции узлов и деталей, эффективное управление производственными процессами и т.д.

Но, примеров их применения в построении процессов и проектировании изделий машиностроения не так много [3–6]. А их использование в качестве инструмента для проектирования металлорежущих станков и прогнозирования их эксплуатационных свойств – единицы [7–10]. Это является серьезным упущением со стороны научного сообщества и, в частности, конструкторов-технологов. Ведь отдельные узлы станка имеют сложную природу взаимодействия с целым комплексом факторов, влияющих друг на друга, что наряду с действием неучтенных компонентов только увеличивает общую величину погрешности обработки [11, 12].

Проектирование станков и, в частности, шпиндельных узлов (ШУ), вносящих наибольшую погрешность в обрабатываемые детали, зачастую основано на использовании классических линейных и нелинейных моделей. Такие модели не способны на должном уровне реализовать, в частности, зависимости эксплуатационных характеристик ШУ от его конструктивных параметров и режимов эксплуатации, поскольку в этих моделях сложно учесть взаимное влияние факторов и определить тем самым скрытые корреляции. Необходим другой более совершенный механизм, лишенный вышеперечисленных недостатков. Таким механизмом могут служить нейронные сети [13, 14].

Цель настоящей работы заключается в сравнении качества классических моделей прогнозирования и полученных с помощью нейронных сетей при различном объеме экспериментальных данных.

Денисенко Александр Федорович, доктор технических наук, профессор кафедры «Технология машиностроения, станки и инструменты». E-mail: samtortor@yandex.ru

Ладагин Роман Владимирович, аспирант, старший преподаватель кафедры «Технология машиностроения, станки и инструменты». E-mail: ladoshman@yandex.ru

МЕТОДИКА ИССЛЕДОВАНИЯ

Для достижения поставленной цели были собраны экспериментальные установки на базе станков токарной группы: 1А616, 1К62, 16Б16КП, 400ХС «Вектор», 1И250В (аналог 250ИТВМ). Общий вид одной из установок показан на рис. 1.



Рис. 1. Экспериментальная установка на базе станка 400ХС «Вектор»

На основе полученных экспериментальных данных строились линейные (ЛМ), нелинейные модели (НМ) в виде регрессионных зависимостей и нейронные сети (НС). Построение математических моделей и нейросетей осуществлялось в программе Statistica на 3-х объемах данных: 108, 232 и 481 наблюдений и различалось составом переменных.

Первый эксперимент проводился на станке мод. 1А616 и содержал 108 наблюдений по 6-ти переменным: частота вращения шпинделя (n); сила (P), имитирующая нагрузку в процессе резания от сил P_z и P_y (приложена статически); время работы (t_m) – входные переменные; температура в зоне наружного кольца подшипника передней опоры (T); биение переднего конца шпинделя (Δ); упругое смещение переднего конца шпинделя (δ) – выходные переменные.

Второй эксперимент также проходил на станке мод. 1А616 и содержал дополнительно к первому 124 наблюдения, что в сумме дало 232. В этом эксперименте к входным переменным добавилась переменная – влияние радиального зазора подшипника передней опоры (S). Изменение S осуществлялась при помощи перемещения положения регулировочной и ограничивающей гаек на шпинделе. Таким образом, были получены дополнительно ещё 3 уровня значений для S .

Третий эксперимент проходил уже на группе станков, что позволило дополнительно к первым двум экспериментам добавить ещё 249 наблюдений. В нём появились дополнительные входные переменные, отражающие влияние конструктивных параметров ШУ на эксплуатационные свойства: максимальный диаметр обрабатываемой детали (D_{max}); динамическая (C) и статическая (C_0) грузоподъемности подшипников передней опоры; номер конуса Морзе (kM); межопорное расстояние (λ) и вылет (α) шпинделя; координата расположения приводного элемента ($L1$), принятая от положения передней опоры.

Выходные переменные во всех экспериментах - согласно первому эксперименту.

РЕЗУЛЬТАТЫ И ИХ ОБСУЖДЕНИЕ

Линейные и нелинейные модели способны реализовать зависимости от множества факторов только для одного отклика, в то время как нейронные сети строят зависимости для множества откликов. Из-за возможностей программы в нелинейных моделях использованы 4 переменные, что полностью соответствует условиям только для 1-го эксперимента, а для 2-го и 3-го был проведен отбор только значимых переменных при помощи корреляции Пирсона. Так, например, для прогнозирования T и Δ использованы входные переменные - S , n , t_m , а для δ – переменные S , n , P (табл. 1). Отмеченные в табл. 1 (полужирным) корреляции значимы при $p < 0,001$.

Таблица 1. Значения корреляций

Переменная	Корреляции		
	T	Δ	δ
S	-0,292	0,107	0,227
n	0,95	0,643	-0,174
t_m	0,394	0,334	-0,087
P	-0,19	-0,037	0,956

В программе Statistica возможно построение нелинейных моделей следующих видов:

- квадратичная функция (x^2);
- кубическая функция (x^3);
- полиномиальная функция 4-й степени (x^4);
- полиномиальная функция 5-й степени (x^5);
- функция квадратного корня ($\sqrt{x}$);
- натуральный логарифм ($\ln x$);
- десятичный логарифм ($\log_{10} x$);
- экспоненциальная функция (e^x , диапазон $-40 \leq x \leq 40$);
- экспоненциальная функция (e^x , диапазон $-18 \leq x \leq 18$);
- обратная (гиперболическая) функция ($1/x$, $x \neq 0$).

Нелинейные модели для прогнозирования T строились с использованием натурального логарифма $\ln x$, они имеют вид:

$$y = a + b_1 x_1 + b_2 x_2 + b_3 x_3 + b'_1 \ln(x_1) + b'_2 \ln(x_2) + b'_3 \ln(x_3); \quad (1)$$

а для прогнозирования Δ и δ – с помощью полиномов разной степени $X^2 \dots X^5$, к примеру, для Δ на 108-232 наблюдениях формула такой модели следующая:

$$y = a + b_1 x_1 + b_2 x_2 + b_3 x_3 + b'_1 x_1^2 + b'_2 x_2^2 + b'_3 x_3^2; \quad (2)$$

для переменной δ на 481 наблюдении:

$$y = a + b_1 x_1 + b_2 x_2 + b_3 x_3 + b'_1 x_1^3 + b''_1 x_1^5 + b'_2 x_2^3 + b''_2 x_2^5 + b'_3 x_3^3 + b''_3 x_3^5. \quad (3)$$

Линейные модели строились согласно формуле:

$$y = a + b_1 x_1 + b_2 x_2 + b_3 x_3 + \dots + b_n x_n. \quad (4)$$

В табл. 2...4 представлены формулы полученных моделей для каждого отклика при различном объеме наблюдений и составе входных переменных.

Нейронные сети имеют три нейрона на выходном слое и поэтому прогнозируют сразу три выходных переменных. Для каждой модели в табл. 2...4 также приведен коэффициент детерминации R^2 , характеризующий качество построенных моделей и показывающий насколько они объясняют изменчивость соответствующих переменных. Чем он ближе к 1, тем лучше модель объясняет зависимые переменные. Для нейросетей этим показателем является параметр «производительность» на тестовом множестве, который записывается одним значением сразу для всех выходных переменных.

В нелинейных моделях для прогнозирования T наилучшие результаты показали модели на основе натурального логарифма $\ln x$ (1), а для прогнозирования Δ и δ более подходящими оказались полиномиальные модели разных степеней $x^2 \dots x^5$ (2), (3).

Зависимость, прогнозируемая нейронной сетью, не имеет простой аналитической формулы, как линейные или полиномиальные модели. Вместо этого её запись отражает архитектуру сети и процесс преобразования данных через слои. Например, для многослойного персептрона (MLP) с одним скрытым слоем это можно схематично представить так:

$$y = f_{\text{вых}} [W_2 \cdot f_{\text{скрыт}} (W_1 \cdot \mathbf{X} + \mathbf{B}_1) + \mathbf{B}_2], \quad (5)$$

где $\mathbf{X}$ – входной вектор; W_1, W_2 – матрицы весов; $\mathbf{B}_1, \mathbf{B}_2$ – векторы смещений; $f_{\text{скрыт}}, f_{\text{вых}}$ – функции активации (например: гиперболический тангенс, сигмоидальная, экспоненциальная, линейная).

Значения весов ввиду громоздкости записи приведены только для нейросети MLP 3-7-3 построенной на 108 наблюдениях и имеющей наиболее простую архитектуру из представленных сетей. Значения весов показаны в табл. 5. Сокращения в тексте таблицы: hn – hidden neuron (скрытый нейрон); ib – input bias (нейрон смещения входного слоя); hb – hidden bias (нейрон смещения скрытого слоя).

Таблица 2. Сравнение моделей на 108 наблюдениях

Вид модели	R^2	Формула модели
ЛМ	0,88	$T = 24,72718 + 0,01518n + 0,0465t_m - 0,00029P$
	0,174	$\Delta = 6,18123 + 0,000489n + 0,002362t_m + 0,000045P$
	0,899	$\delta = 0,520701 - 0,000654n - 0,000672t_m + 0,005091P$
НМ	0,992	$T = -27,5236 + 0,0111n - 0,0316t_m - 0,0001P + 5,5623\ln(n) + 6,2082\ln(t_m) - 0,1831\ln(P)$
	0,339	$\Delta = 5,572131 + 0,001968S + 0,007488n + 0,000139t_m - 0,000001S^2 - 0,000041n^2$
	0,989	$\delta = 0,336734 + 0,000029n - 0,024647t_m + 0,003662P - 0,000001n^2 + 0,000314t_m^2 - 0,000001t_m^3 + 0,000001P^2$
НС	0,863	$T\Delta\delta = \text{MLP 3-7-3}; f(x) = \frac{e^{2x} - 1}{e^{2x} + 1}$ (скрытый слой); $f(x) = x$ (выходной слой)

Таблица 3. Сравнение моделей на 232 наблюдениях

Вид модели	R^2	Формула модели
ЛМ	0,884	$T = 28,53123 - 0,90474S + 0,01473n + 0,04476t_m - 0,0003P$
	0,427	$\Delta = 5,722491 + 0,053751S + 0,000895n + 0,003333t_m - 0,000001P$
	0,869	$\delta = -1,78149 + 0,62463S - 0,00012n + 0,00193t_m + 0,00466P$
НМ	0,989	$T = -21,9147 - 0,3218S + 0,0121n - 0,0325t_m - 1,1395\ln(S) + 4,6039\ln(n) + 6,3716\ln(t_m)$
	0,54	$\Delta = 5,539082 - 0,14935S + 0,001768n + 0,010255t_m + 0,036089S^2 - 0,000054t_m^2$
	0,97	$\delta = -2,46489 - 1,71458S + 0,0012n + 0,0043P + 1,40207S^2 - 0,18092S^3$
НС	0,916	$T\Delta\delta = \text{MLP 4-14-3}; f(x) = \frac{1}{1 + e^{-x}}$ (скрытый слой); $f(x) = x$ (выходной слой)

По таблице весов можно определить:

- влияние входных переменных. Так частота вращения шпинделя (n) оказывает разнонаправленное воздействие на скрытые нейроны: от сильного отрицательного (hn2: -1,34376) до положительного (hn3: 1,28531). Это указывает на её комплексную роль в модели;

- вклад скрытых нейронов в выходы. Скрытые нейроны по-разному влияют на выходные переменные. Например: hn4 сильно коррелирует с температурой (T : 1,67895), но подавляет биение (Δ : -0,79161); hn1 и hn6 оказывают противоположное влияние на упругое смещение (δ): -0,38201 и 0,62724 соответственно; нейроны с малыми весами (hn5 -> T : -0,07691) играют второстепенную роль;

- нелинейность модели. Знаки и величины весов (например, hn3 -> Δ : 1,35106 и hn6 -> Δ : -1,40868) подчеркивают способность сети моделировать сложные взаимодействия факторов.

На рис. 2 и рис.3 показаны нормальные вероятностные графики (Q-Q plot). Они используются для проверки соответствия распределения данных нормальному распределению.

Таблица 4. Сравнение моделей на 481 наблюдении

Вид модели	R ²	Формула модели
ЛМ	0,81	$T = 32,56431 + 0,00214D_{\max} - 3,85035K_M - 0,00864C - 0,00104C_0 - 0,00577l_1 + 0,20942\alpha - 0,01054\lambda - 1,0922S + 0,01135n + 0,05204t_m - 0,00019P$
	0,873	$\Delta = -2,11233 - 0,00778D_{\max} + 0,69295K_M - 0,00382C - 0,00279C_0 - 0,00592l_1 + 0,04052\alpha + 0,00881\lambda + 0,09394S + 0,00028n + 0,00235t_m - 0,00003P$
	0,84	$\delta = 11,66764 - 0,0013D_{\max} - 1,94521K_M - 0,00679C - 0,00164C_0 - 0,00309l_1 + 0,02802\alpha - 0,00465\lambda + 0,51119S - 0,00027n - 0,001t_m + 0,00373P$
НМ	0,803	$T = -33,3976 - 2,5415S + 0,0039n - 0,0299t_m + 0,9211\ln(S) + 7,7584\ln(n) + 6,2192\ln(t_m)$
	0,619	$\Delta = 4,83574 - 3,95849S + 0,00171n - 0,00267t_m + 2,28296S^2 - 0,27908S^3 + 0,00009t_m^2$
	0,881	$\delta = -5,31895 + 4,1876S + 0,00004n + 0,00497P - 0,31766S^3 + 0,00718S^5$
НС	0,986	$T\Delta\delta = \text{MLP } 11-22-3; f(x) = \frac{1}{1+e^{-x}}$ (скрытый слой); $f(x) = e^{-ax}$ (выходной слой)

Таблица 5. Значения весов для сети MLP 3-7-3

Связи	Значение весов	Связи	Значение весов	Связи	Значение весов	Связи	Значение весов	Связи	Значение весов
n --> hn1	0,23784	ib--> hn1	0,32890	hn1 --> T	0,00971	hn1 --> Δ	-1,31359	hn1 --> δ	-0,38201
tm --> hn1	0,10080								
P --> hn1	0,35114								
n --> hn2	-1,34376	ib--> hn2	0,01625	hn2 --> T	-0,92766	hn2 --> Δ	-1,08496	hn2 --> δ	0,06401
tm --> hn2	0,60475								
P --> hn2	-0,06139								
n --> hn3	1,28531	ib--> hn3	-0,90055	hn3 --> T	-0,11004	hn3 -->Δ	1,35106	hn3 --> δ	-0,11755
tm --> hn3	1,11338								
P --> hn3	0,58180								
n --> hn4	0,58374	ib--> hn4	-0,58432	hn4 --> T	1,67895	hn4 --> Δ	-0,79161	hn4 --> δ	-0,06893
tm --> hn4	0,90695								
P --> hn4	-0,23921								
n --> hn5	0,64690	ib--> hn5	0,01002	hn5 --> T	-0,07691	hn5 --> Δ	-0,80781	hn5 --> δ	-1,00621
tm --> hn5	0,08484								
P --> hn5	-0,94126								
n --> hn6	0,49330	ib--> hn6	-0,45540	hn6 --> T	-0,17483	hn6 --> Δ	-1,40868	hn6 --> δ	0,62724
tm --> hn6	-0,42124								
P --> hn6	0,97281								
n --> hn7	-0,53247	ib--> hn7	0,32983	hn7 --> T	1,54999	hn7 --> Δ	0,47961	hn7 --> δ	-1,03069
tm --> hn7	-0,48720								
P --> hn7	0,30893								
				hb--> T	0,21669	hb--> Δ	0,34349	hb--> δ	0,65678

Обозначения на графиках:

Ось X: Наблюдаемые значения переменной («Observed Value»).

Ось Y: Ожидаемые значения (квантили) нормального распределения («Expected Normal Value»).

Если точки на графике близки к прямой линии, то это свидетельствует о нормальном распределении данных. Отклонения от линии указывают на отклонение от нормального распределения.

В данной работе график анализирует остатки модели (разницу между прогнозируемыми и наблюдаемыми значениями), чтобы проверить их нормальность — важное условие для многих статистических моделей.




Рис. 2. Графики нормального вероятностного распределения для переменной T на 481 наблюдении, спрогнозированные: а – нейросетью; б – нелинейной моделью




Рис. 3. График нормального вероятностного распределения для переменной Δ на 108 наблюдениях, спрогнозированный линейной моделью

У нейросетей на графике нормального вероятностного распределения прогнозные значения во многом совпадают с наблюдаемыми на всех размерах наблюдений 108-481 и по всем переменным. Данную качественную картину можно наблюдать в частности на рис. 2, а, в то время как у других моделей этот показатель хуже (рис. 2, б) либо прогнозные значения сильно отличаются (рис. 3), но при этом остатки модели соответствуют нормальному распределению.

Качество полученных математических моделей и нейронных сетей дополнительно оценено по критерию средней относительной ошибки. Результаты представлены в табл. 6.

Таблица 6. Качество полученных математических моделей и нейронных сетей

Число набл.	Средняя относительная ошибка прогнозируемых переменных								
	$T, \%$			$\Delta, \%$			$\delta, \%$		
	ЛМ	НМ	НС	ЛМ	НМ	НС	ЛМ	НМ	НС
108	3,97	1,51	1,67	7,71	6,35	6,25	12,74	7,7	9,72
232	4,69	1,78	1,69	7,27	6,69	6,34	19,4	17,94	13,02
481	7,16	8,29	1,8	13,59	31,79	7,91	29,22	34,08	10,88

Для удобства восприятия по данным табл. 6 построены гистограммы (рис. 4) параллельного сравнения моделей по выходным переменным для разного числа наблюдений.

ВЫВОДЫ

Из анализа таблиц 2...4, 6 и гистограмм рис. 4 можно сделать несколько выводов:

- линейные модели имеют стабильно невысокое качество. Особенно это наглядно видно при прогнозировании T ;
- нелинейные модели, полученные на малом объеме экспериментальных данных, для отдельных переменных дают точность даже выше чем у нейронных сетей и могут с ними конкурировать. При большем составе переменных их качество заметно снижается, что, возможно, обусловлено отсутствием сведений от неучтенных переменных;




Рис. 4. Сравнение средней относительной ошибки моделей по переменным:
а – T ; б – Δ ; в – δ

- модели на основе нейронных сетей отличаются стабильно низкой ошибкой, которая не зависит ни от размеров наблюдений, ни от состава переменных. Причем низкую ошибку они способны давать и при малом числе переменных, где они уязвимы ввиду отсутствия или ограниченного количества возникающих скрытых корреляций, в учете которых заключается одно из главных их преимуществ.

Проведенный сравнительный математический анализ показывает, что нейронные сети качественно отличаются от линейных и нелинейных моделей, обеспечивая большую независимость от условия получения значений входных переменных. Это подтверждается тем, что у нейросетей меньше средняя относительная ошибка, преимущественно больше коэффициент детерминации, который лишь увеличивается с ростом количества наблюдений и расширением состава переменных, лучшее соответствие спрогнозированных значений выходных переменных нормальному закону распределения. Все это свидетельствует, что применение нейросетей в качестве инструмента для комплексного (многофакторного) прогнозирования эксплуатационных свойств ШУ предпочтительнее. Линейные и нелинейные же модели могут применяться для решения локальных задач с малым количеством факторов.

СПИСОК ЛИТЕРАТУРЫ

1. Горобченко, С.Л. Современное состояние применения и развития методов искусственного интеллекта в промышленных регуляторах и интеллектуальных системах управления / С. Л. Горобченко, Б. М. Шифрин, С. В. Алексеева [и др.] // Известия Тульского государственного университета. Технические науки. – 2023. – № 3. – С. 106-112. – DOI 10.24412/2071-6168-2023-3-106-112.
2. Ладыгин, Р.В. Анализ нейронных сетей для решения задач отраслей промышленности // Высокие технологии в машиностроении: Материалы XX всероссийской научно-технической конференции с международным участием, Самара, 09–10 ноября 2023 года. – Самара: Самарский государственный технический университет, 2023. – С. 140-141.
3. Михалёв, О.Н. Применение нейронной сети для автоматизации проектирования / О.Н. Михалёв, А.С. Янюшкин // В сборнике: Высокие технологии в машиностроении. Материалы XVIII всероссийской научно-технической конференции с международным участием. Отв. редактор Р.Г. Гришин. Самара, 2021. С. 93-96.
4. Богатилов, В.Н. Распределенная адаптивная модель прогнозирования изменения параметров технологических систем / В.Н. Богатилов, И.Е. Кириллов, И.Н. Морозов // Труды Кольского научного центра РАН. – 2012. – № 6 (13). – С. 158-168.
5. Сердюков, В.И. Повышение безотказной работы изделий с использованием элементов искусственного интеллекта / В. И. Сердюков, Н. А. Сердюкова, С. И. Шишкина // Вестник Московского государственного технического университета им. Н.Э. Баумана. Серия Машиностроение. – 2017. – № 1(112). – С. 62-72.
6. Доц, М.В. Проектирование технологических операций обработки композиционных материалов на основе искусственных нейронных сетей / М. В. Доц, Е. Б. Бондарь, А. М. Марков, В. Б. Маркин // Ползуновский вестник. – 2012. – № 1-1. – С. 81-84.
7. Кудинов, А.В. Особенности нейросетевого моделирования станков / А.В. Кудинов // СТИН. – 2001. – №1. – С. 13-18.
8. Позевалкин, В.В. Исследование эффективности тепловых моделей станка на основе нейронных сетей прямого распространения / В.В. Позевалкин, А.Н. Поляков // СТИН. – 2021. – № 10. – С. 29-32.
9. Кузнецов, Д.И. Обоснование технических характеристик гибких производственных модулей нейросетевыми методами: автореф. дисс. ... канд. техн. наук: 02.03.01 / Д.И. Кузнецов. – Комсомольский-на-Амуре государственный технический университет. – Комсомольск-на-Амуре, 2004. – 316 с.
10. Рожков, С.В. Оценка технического состояния передней опоры шпиндельного узла металлорежущего станка / С.В. Рожков, Г.В. Шадский, В.Г. Шадский // Известия ТулГУ. Технические науки. – 2017. – Вып. 8. – Ч. 2. – С. 251-257.
11. Пуш, А.В. Шпиндельные узлы: качество и надежность при проектировании / А.В. Пуш, И.А. Зверев. – М.: СТАНКИН, 2000. – 132 с.
12. Зверев, И.А. Комплексное моделирование при проектировании шпиндельных узлов на опорах качения / И.А. Зверев, Ю.М. Данильченко // Вісник СевНТУ. – 2014. – № 150. – С. 75-80.
13. Скуратов, М.И. Искусственные нейронные сети: базовые принципы и возможные реализации / М.И. Скуратов, Н.Г. Пугач, Е.Г. Екомасов, Б.Г. Львов // Известия Уфимского научного центра РАН. – 2022. – № 4. – С. 5-11.
14. Денисенко, А.Ф. Применение нейронных сетей для моделирования эксплуатационных характеристик шпиндельного узла / А.Ф. Денисенко, Р.В. Ладыгин, М.В. Якимов // Системы. Методы. Технологии. – 2024. – №2 (62). – С.78-86.

COMPARISON OF MATHEMATICAL AND NEURAL NETWORK MODELING OF SPINDLE UNIT PERFORMANCE PROPERTIES

© 2025 A.F. Denisenko, R.V. Ladyagin

Samara State Technical University, Samara, Russia

The article presents a comparative study of the effectiveness of classical mathematical models (linear and nonlinear) and neural networks for predicting the performance properties of spindle units of metal-cutting machines. The experiments were performed on data obtained from a group of lathes with different volumes of observations and composition of input variables, including spindle speed, load, operating time and design parameters of the spindle unit. The models were built in the Statistica program, quality assessment was carried out by the determination coefficient R^2 , average relative error and analysis of the normality of the residuals. The results showed that neural networks provide a consistently low forecast error (up to 2-5%) regardless of the data volume and the number of variables, and their residuals better correspond to the normal distribution. Linear models demonstrate low accuracy, especially for temperature (T), while nonlinear (polynomial, logarithmic) models compete with neural networks only with a small number of factors, and with an increase in the composition of variables, their quality decreases. The findings confirm the advantage of neural networks in multifactor forecasting, which is due to their ability to take into account hidden correlations. Classical models remain relevant for local problems with a limited number of parameters. The work emphasizes the need to implement neural network approaches in machine tool design to improve the accuracy of forecasting performance characteristics.

Keywords: spindle unit, performance properties, neural networks, mathematical modeling, determination coefficient.

DOI: 10.37313/1990-5378-2025-27-3(2)-221-230

EDN: QJJEPP

REFERENCES

1. *Gorobchenko, S.L.* Sovremennoe sostoyanie primeneniya i razvitiya metodov iskusstvennogo intellekta v promyshlennyyh regul'yatorah i intellektual'nykh sistemah upravleniya / S. L. Gorobchenko, B. M. Shifrin, S. V. Alekseeva [i dr.] // *Izvestiya Tul'skogo gosudarstvennogo universiteta. Tekhnicheskie nauki.* – 2023. – № 3. – S. 106-112. – DOI 10.24412/2071-6168-2023-3-106-112.
2. *Ladyagin, R.V.* Analiz neyronnykh setey dlya resheniya zadach otraslej promyshlennosti // *Vysokie tekhnologii v mashinostroenii* : Materialy XX vserossiyskoy nauchno-tekhnicheskoy konferencii s mezhdunarodnym uchastiem, Samara, 09–10 noyabrya 2023 goda. – Samara: Samarskiy gosudarstvennyy tekhnicheskij universitet, 2023. – S. 140-141.
3. *Mihalyov, O.N.* Primenenie neyronnoy seti dlya avtomatizatsii proektirovaniya / Mihalyov O.N., Yanyushkin A.S. V sbornike: *Vysokie tekhnologii v mashinostroenii. Materialy XVIII vserossiyskoy nauchno-tekhnicheskoy konferencii s mezhdunarodnym uchastiem.* Otv. redaktor R.G. Grishin. Samara, 2021. S. 93-96.
4. *Bogatikov, V.N.* Raspredeleonnaya adaptivnaya model' prognozirovaniya izmeneniya parametrov tekhnologicheskikh sistem / V.N. Bogatikov, I.E. Kirillov, I.N. Morozov. – *Trudy Kol'skogo nauchnogo centra RAN.* – 2012. – № 6 (13). – S. 158-168.
5. *Serdyukov, V.I.* Povyshenie bezotkaznoy raboty izdeliy s ispol'zovaniem elementov iskusstvennogo intellekta / V. I. Serdyukov, N. A. Serdyukova, S. I. Shishkina // *Vestnik Moskovskogo gosudarstvennogo tekhnicheskogo universiteta im. N.E. Bauman.* Seriya Mashinostroenie. – 2017. – № 1(112). – S. 62-72.
6. *Doc, M.V.* Proektirovaniye tekhnologicheskikh operatsiy obrabotki kompozitsionnykh materialov na osnove iskusstvennykh neyronnykh setey / M. V. Doc, E. B. Bondar', A. M. Markov, V. B. Markin // *Polzunovskiy vestnik.* – 2012. – № 1-1. – S. 81-84.
7. *Kudinov, A.V.* Osobennosti nejrosetevogo modelirovaniya stankov / A.V. Kudinov // *STIN.* – 2001. – №1. – S. 13-18.
8. *Pozevalkin, V.V.* Issledovanie effektivnosti teplovykh modeley stanka na osnove neyronnykh setey pryamogo rasprostraneniya / V.V. Pozevalkin, A.N. Polyakov // *STIN.* – 2021. – № 10. – S. 29-32.
9. *Kuznecov, D.I.* Obosnovanie tekhnicheskikh harakteristik gibkikh proizvodstvennykh moduley nejrosetevymi metodami: avtoref. diss....kand.tekhn.nauk: 02.03.01 / D.I. Kuznecov. – Komsomol'skiy-na-Amure gosudarstvennyy tekhnicheskij universitet. – Komsomol'sk-na-Amure, 2004. – 316 s.
10. *Rozhkov, S.V.* Ocenka tekhnicheskogo sostoyaniya peredney opory shpindel'nogo uzla metallovezhushchego stanka / S.V. Rozhkov, G.V. Shadskiy, V.G. Shadskiy, // *Izvestiya TulGU. Tekhnicheskie nauki.* – 2017. – Vyp. 8. – Ch. 2. – S. 251-257.
11. *Push, A.V.* Shpindel'nye uzly: kachestvo i nadezhnost' pri proektirovanii / A.V. Push, I.A. Zverev. – M.: STANKIN, 2000. – 132 s.
12. *Zverev, I.A.* Kompleksnoye modelirovaniye pri proektirovanii shpindel'nykh uzlov na oporah kacheniya / I.A. Zverev, Yu.M. Danil'chenko // *Visnik SevNTU.* – 2014. – № 150. – S. 75-80.
13. *Skuratov, M.I.* Iskusstvennyye neyronnyye seti: bazovyye principy i vozmozhnyye realizatsii / M.I. Skuratov, N.G. Pugach, E.G. Ekomasov, B.G. L'vov // *Izvestiya Ufimskogo nauchnogo centra RAN.* – 2022. – № 4. – S. 5-11.
14. *Denisenko, A.F.* Primenenie neyronnykh setey dlya modelirovaniya ekspluatatsionnykh harakteristik shpindel'nogo uzla / A.F. Denisenko, R.V. Ladyagin, M.V. Yakimov // *Sistemy. Metody. Tekhnologii.* – 2024. – №2 (62). – S. 78-86.

Alexander Denisenko, DSc, Professor, Professor of Department of «Technology of Mechanical Engineering, Machines and Tools». E-mail: sammortor@yandex.ru

Roman Ladyagin, Postgraduate Student, Senior Lecturer of the Department of «Technology of Mechanical Engineering, Machines and Tools». E-mail: ladoshman@yandex.ru