

# МАШИНОСТРОЕНИЕ И МАШИНОВЕДЕНИЕ

DOI: 10.34031/2071-7318-2025-10-6-116-129

Денисенко А.Ф., \*Ладагин Р.В.

Самарский государственный технический университет

\*E-mail: konferencia-isap@yandex.ru

## НАСТРОЙКИ ПРОЦЕССА ПОСТРОЕНИЯ И ОБУЧЕНИЯ НЕЙРОСЕТЕЙ ПРИ РЕШЕНИИ ЗАДАЧ ПО ПРОГНОЗИРОВАНИЮ ЭКСПЛУАТАЦИОННЫХ ХАРАКТЕРИСТИК ШПИНДЕЛЬНЫХ УЗЛОВ

**Аннотация.** Исследование посвящено разработке нейросетевых методов моделирования эксплуатационных характеристик шпиндельных узлов металлорежущих станков. В работе решены три ключевые задачи: выбор оптимальной архитектуры нейронной сети, минимизация объема обучающих данных и сокращение времени экспериментов при многопараметрическом анализе. Установлено, что многослойный перцептрон с архитектурой  $3 \times 7 \times 3$  показывает наименьшие средние относительные ошибки прогнозирования – 1,87 % для температуры, 7,78 % для биения шпинделя и 10,7 % для упругого смещения переднего конца шпинделя. Эксперименты подтвердили возможность сокращения объема выборки до 50 % без значительной потери точности, а использование генератора псевдослучайных чисел «Вихрь Мерсенна» позволило снизить время генерации данных на 40 %. Анализ чувствительности выявил доминирующее влияние частоты вращения шпинделя ( $n$ ) и силы прикладываемой к переднему концу шпинделя ( $P$ ) на выходные параметры, тогда как время работы ( $t_m$ ) оказалось статистически незначимым. Применение пакета Statistica обеспечило гибкость в настройке моделей, включая выбор функций активации (гиперболический тангенс, сигмоида) и алгоритмов оптимизации (Broyden–Fletcher–Goldfarb–Shanno). Результаты показали превосходство многослойного перцептрона над радиальными базисными сетями по точности на 23–35 %. Практическая значимость работы заключается в создании методики проектирования ШУ, сочетающей нейросетевые технологии с рациональным планированием экспериментов.

**Ключевые слова:** нейросеть, объем выборки, планирование эксперимента, прогнозирование, шпиндельный узел

**Введение.** Современное машиностроение ориентировано на совершенствование технологических процессов, что выражается в росте эффективности и точности обработки материалов. Однако переход к мелкосерийному и индивидуальному производству станков существенно усложнил этап проектирования, где ошибки становятся критичными из-за отсутствия возможностей для их корректировки на последующих стадиях. Кроме того, проектировщики часто игнорируют анализ решений, реализованных в аналогах, что повышает риски неоптимальных конструкторских решений. В таких условиях актуализируется необходимость разработки методов, обеспечивающих оценку качества оборудования на ранних этапах его создания.

Основные эксплуатационные свойства станков, согласно исследованиям [1], можно классифицировать по четырем универсальным критериям: производительность, точность, адаптивность (технологическая гибкость) и устойчивость к отказам.

Важнейшей частью современных станков остается шпиндельный узел (ШУ), который представляет собой многофункциональную систему, определяющую работоспособность всего оборудова-

ния. В работе [2] выделены ключевые требования к ШУ: стабильность геометрических параметров, сопротивляемость деформациям, способность выдерживать эксплуатационные нагрузки и поддерживать высокие скорости вращения шпинделя.

Как показано в [3], достижение требуемых характеристик ШУ возможно только при комплексном подходе к проектированию. Это включает:

- оптимизацию конструктивных параметров (геометрия, компоновка, конструкция корпуса);
- выбор типа подшипников и методов их установки (натяг, точность);
- учет внешних факторов (температурные колебания, динамические нагрузки, режимы смазки);
- анализ динамических воздействий (вибрации, дисбаланс, переменные усилия резания).

Существующие математические модели, описывающие упругие деформации, тепловые процессы или износ подшипников [3], не охватывают всего спектра взаимосвязей между параметрами ШУ. Это ограничивает их применимость для многокритериальной оптимизации, где более эффективными становятся методы машинного

обучения, в частности нейронные сети (НС) [4–7].

Практика применения НС в машиностроении демонстрирует их потенциал. Например, исследование [8] предложило комбинированный подход, где классические дифференциальные уравнения дополняются нейросетевыми моделями для анализа точности и динамики станков. В [9] НС прямого распространения использовали для прогнозирования температурных полей в подшипниках, что повысило точность контроля тепловых деформаций.

Работа Кузнецова Д.И. [10] продемонстрировала использование НС для кластеризации данных с целью прогнозирования износа станков и оптимизации их обслуживания. В [11] нейросети применялись для автоматизации проектирования операций механической обработки, включая формирование переходов для отверстий и пазов.

Авторы [12] разработали адаптивную агентную систему на основе НС, способную динамически корректировать прогнозы параметров технологических процессов в реальном времени. В [13] графовые нейронные сети (GNNS) использовались для анализа данных с датчиков газотурбинных установок, что подтвердило их эффективность для сложных технических систем с нелинейными взаимосвязями.

Эти примеры иллюстрируют, что НС позволяют интегрировать разнородные факторы (механические, тепловые, динамические), обеспечивая превосходство над традиционными моделями.

Имеются отдельные примеры использования нейросетей для исследования ШУ. Так, в [14] предложен метод оценки состояния подшипников по температурным данным и частоте вращения, однако модель не учитывает влияние внешних сил, смазки и вибраций.

Проектирование ШУ требует учета множества переменных: мощность двигателя, кинематические параметры шпинделя, конструкция корпуса, наличие дополнительных модулей (коробки скоростей). Их взаимное влияние формирует итоговые эксплуатационные характеристики, что делает нейросетевые методы перспективными для прогнозных проектных решений.

В настоящей работе ставится цель учета расширенного количества факторов нейросети, влияющих на процесс эксплуатации ШУ и формирующих его характеристики.

**Методика проведения исследований.** Для определения оптимального типа нейронной сети, пригодной для моделирования эксплуатационных параметров шпиндельного узла (ШУ) ме-

таллорежущего оборудования, проведены эксперименты с многослойным перцептроном (MLP). Данная архитектура выбрана как эталонная для задач классификации и регрессии благодаря своей универсальности и прозрачности структуры [15].

MLP относится к сетям прямого распространения информации, где данные последовательно обрабатываются слоями нейронов без обратных связей. Каждый нейрон вычисляет взвешенную сумму входных сигналов, добавляет смещение (bias) и применяет нелинейную активационную функцию, формируя выходное значение. Слоистая организация позволяет наращивать сложность модели: количество слоев и нейронов в них определяет способность сети аппроксимировать нелинейные зависимости между входными и выходными параметрами.

Таким образом, MLP служит базовой платформой для исследования возможностей нейросетевого подхода в проектировании шпиндельных узлов, обеспечивая баланс между простотой интерпретации и функциональной гибкостью.

Построение нейронных сетей может быть выполнено с использованием языков программирования и программ, имеющих интерфейс.

Процесс построения нейросетей с помощью языков программирования (Python, C/C++, Java, R и др.) предполагает обладание навыками программирования, что делает их использование даже для уверенных пользователей ПК весьма затруднительным.

В сравнении с языками программирования программы с интерфейсом гораздо проще в освоении, поскольку весь их функционал (окна, вкладки, кнопки команд) находится на дисплее прямо перед пользователем. К программам подобного вида относятся: Statistica, SPSS (IBM), JMP (SAS), NeuroSolutions, модуль Neural Excel для MSOffice, пакет Matlab и др. Применение этих программ позволяет создавать сети равнозначного качества с сетями, написанными на языках программирования.

Для дальнейшего исследования был выбран пакет Statistica, который качественно выделяется среди этих программ способностью сохранять полученную НС не только в «свой» формат, но и в код на языках программирования C/C++, Java, SAS и др. К тому же в пакете Statistica присутствует самый большой перечень возможных функций активации и более точных алгоритмов обучения, таких как BFGS. Так как модуль НС это лишь часть этого мощного пакета статистического анализа, в нем присутствуют разнообразные инструменты для анализа построенной сети, что делает работу в этом пакете более удобным.

Выходными переменными, вводимыми в программу, были приняты следующие эксплуатационные характеристики:  $T$  – температура,  $\Delta$  – биение шпинделя,  $\delta$  – радиальное смещение переднего конца шпинделя под действием нагрузки. Входными переменными были выбраны:  $n$  – частота вращения шпинделя,  $t_m$  – время работы,  $P$  – радиальная сила воздействия на оправку, установленную в конус шпинделя.

Согласно рекомендациям, приведенным в [6, 16], для обеспечения надежности нейросетевых моделей объем обучающей выборки должен в 10 раз превышать количество связей в эксперименте. В эксперименте анализировались 3 входных –  $n$ ,  $t_m$  и  $P$  и 3 выходных параметра  $T$ ,  $\Delta$  и  $\delta$  –

формирующих 9 внутренних связей. Это определило минимальный требуемый размер данных – 90 наблюдений.

Для проведения экспериментов была собрана установка на базе шпиндельного узла станка мод.1А616 (рис. 1). Температура измерялась пирометром с термопарой К-типа, установленной в отверстие глубиной 10 мм, на расстоянии 20 мм от наружного кольца подшипника, биение и радиальное смещение переднего конца шпинделя контролировалось при помощи индикаторов часового типа с ценой деления 1мкм. Радиальная сила, действующая на оправку, установленную в конус шпинделя, прикладывалась с помощью предварительно протарированного нагружающего устройства ТЖ-1000.

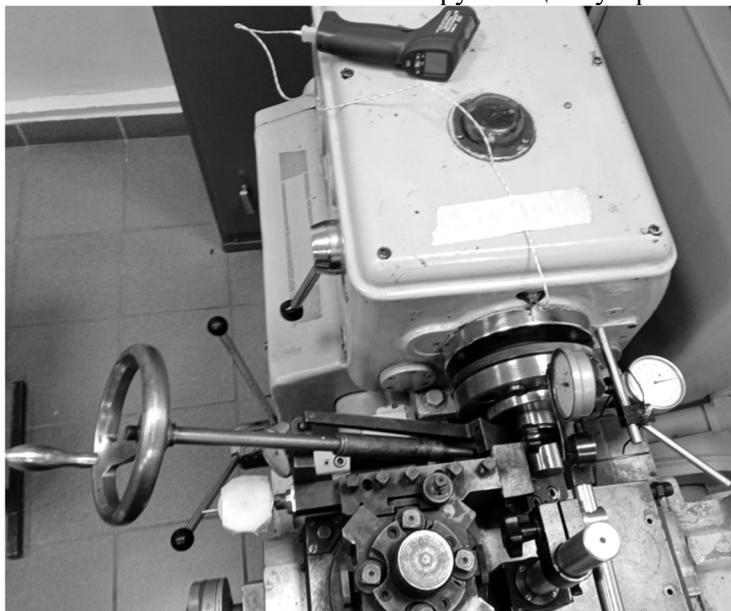


Рис. 1. Общий вид экспериментальной установки

**Результаты.** При реализации поставленной цели по выбору и применению нейронной сети для моделирования эксплуатационных характеристик шпиндельных узлов на основании экспериментально полученных данных, связанных с температурным фактором, возникает проблема значительных временных затрат, связанных с инерционностью температурных процессов в металлорежущих станках.

С целью сокращения времени проведения экспериментов при изменении времени работы

станка на фиксированной частоте вращения шпинделя была оценена возможность проведения измерений на каждом следующем отрезке времени без полного цикла остывания станка. Для этого были выполнены предварительные прогоны работы станка по безостановочной (непрерывной) схеме работы и схеме с перерывами на измерения, подтвердившие практически тождественные значения температуры на конечном временном отрезке (рис. 2).

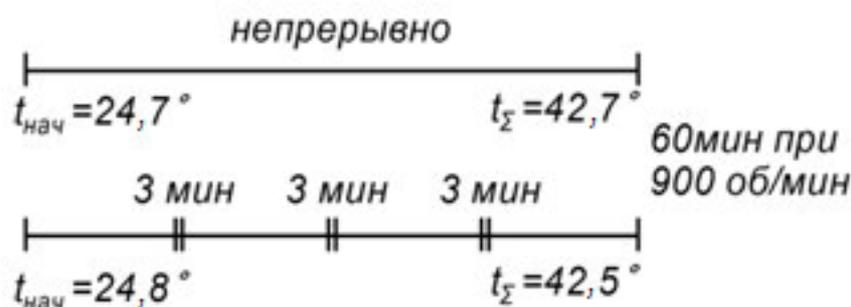


Рис. 2. Схемы предварительных прогонов работы станка

Нейросеть при полном объеме выборки выбиралась из сводного списка построенных нейросетей по критериям производительности на обучающей, тестовой и контрольной выборкам (подмножествам) и соответствующих им ошибках обучения. Для выбора оптимальной сети необходимо придерживаться условий, приведённых в литературе [6, 16, 17] и рассматривать полученные сети по совокупности следующих критериев:

- чем выше производительность, тем лучше сеть предсказывает данные. Наилучшей сетью будет та, у которой эта величина ближе к 1;

- чем меньше ошибка сети, тем будет меньше величина расхождения между наблюдаемыми значениями и спрогнозированными сетью. Наилучшей сетью будет та, у которой эта величина ближе к 0;

- разброс значений производительности и ошибки обучения на подмножествах должен

быть минимален. Наилучшей сетью будет та, у которой эта разница ближе к 0;

- если сети обладают практически одинаковыми ошибками, то наилучшей из них будет сеть с меньшим количеством скрытых элементов – количеством слоев и нейронов, т.е. более простой архитектурой. В этом случае такая сеть будет именно прогнозировать данные, а не запоминать их, кроме того у такой сети меньше вероятность стать переобученной. Сеть же с большим количеством элементов должна использоваться в решении более сложных задач.

Как показал анализ построенных сетей (табл. 1), этим критериям соответствуют номера сетей 48, 55, 58. Наилучшие же показатели у сети с индексом 58. Она имеет архитектуру многослойного персептрона MLP 3×7×3, у которой число нейронов на входном и выходном слоях соответствует числу переменных, и имеющая 7 нейронов на скрытом слое.

Таблица 1

Сводная таблица построенных нейронных сетей

Индекс	Название сети	Производительность на обучении	Производительность на тесте	Производительность на контроле	Ошибка на обучении	Ошибка на тесте	Ошибка на контроле	Алгоритм обучения
1	MLP 3×6×3	0,8688	0,7710	0,7992	2,4118	4,6184	5,3762	BFGS (67)
2	MLP 3×5×3	0,8798	0,7440	0,8006	1,9414	3,5064	3,1453	BFGS (55)
3	MLP 3×3×3	0,8680	0,7602	0,8023	2,2963	2,5010	1,7981	BFGS (27)
4	MLP 3×9×3	0,9088	0,7826	0,8490	1,5881	1,9782	1,4426	BFGS (108)
5	MLP 3×3×3	0,8885	0,7802	0,8364	2,1715	3,1465	2,4684	BFGS (74)
8	MLP 3×4×3	0,8954	0,7717	0,8298	1,2562	1,5727	1,6735	BFGS (84)
36	RBF 3×8×3	0,7417	0,6105	0,7491	15,3096	14,5610	11,0092	RBFT
37	RBF 3×8×3	0,8221	0,8146	0,8199	6,7622	5,0085	4,4188	RBFT
38	RBF 3×8×3	0,7802	0,6843	0,7662	11,3722	6,8784	12,0087	RBFT
39	RBF 3×8×3	0,7785	0,6476	0,7011	18,5246	20,8691	19,8016	RBFT
10	RBF 3×8×3	0,7624	0,7358	0,6694	15,5509	9,7829	23,1613	RBFT
41	RBF 3×15×3	0,8304	0,7117	0,7816	8,4413	6,9215	8,3056	RBFT
42	RBF 3×14×3	0,8852	0,7140	0,7880	3,6569	3,3965	4,0047	RBFT
43	RBF 3×19×3	0,8853	0,7129	0,7789	3,3455	7,1091	4,6339	RBFT
44	RBF 3×17×3	0,851	0,6185	0,8377	8,2408	13,0944	5,6140	RBFT
45	RBF 3×15×3	0,8242	0,6919	0,7810	6,8319	6,9972	6,1847	RBFT
46	MLP 3×4×3	0,8517	0,9086	0,7881	1,4689	1,1954	2,9027	BFGS (24)
47	MLP 3×4×3	0,8757	0,7708	0,8038	1,6582	2,2991	1,7650	BFGS (48)
48	MLP 3×4×3	0,8653	0,8652	0,8305	1,2711	1,8201	2,1877	BFGS (88)
49	MLP 3×4×3	0,8367	0,8041	0,9014	2,8634	2,0890	3,1712	BFGS (25)
50	MLP 3×4×3	0,8378	0,8831	0,8722	3,0332	3,7575	2,5911	BFGS (22)
51	MLP 3×9×3	0,8482	0,8894	0,7873	2,8433	1,4934	3,4550	BFGS (20)
52	MLP 3×9×3	0,8628	0,7591	0,7842	2,6045	3,1347	3,8162	BFGS (22)
53	MLP 3×9×3	0,8680	0,8642	0,8125	0,970	1,2260	1,2446	BFGS (48)
54	MLP 3×9×3	0,8693	0,8170	0,8922	0,9426	0,6240	0,9322	BFGS (66)
55	MLP 3×9×3	0,8557	0,8551	0,8515	1,0305	1,9825	0,8935	BFGS (30)
56	MLP 3×7×3	0,8298	0,8967	0,7177	2,6249	1,8163	3,1343	BFGS (19)
57	MLP 3×7×3	0,8621	0,7680	0,7856	1,8495	2,5229	2,0954	BFGS (23)
58	MLP 3×7×3	0,8766	0,8633	0,8308	0,6642	0,9893	1,3191	BFGS (72)

Средние относительные ошибки для трех выходных переменных для сети MLP 3×7×3: 1,9 % – для  $T$  (температура); 7,8 % – для  $\Delta$  (биение

шпинделя); 11 % – для  $\delta$  (радиальное смещение переднего конца шпинделя), свидетельствуют,

что построенная нейросеть очень хорошо описывает выбранные эксплуатационные характеристики.

Второй проблемой при использовании нейросетевых моделей для оценки характеристик шпиндельных узлов стала необходимость обработки обширных массивов экспериментальных данных. Для минимизации временных и финансовых затрат на сбор информации проведено исследование по определению минимального объема обучающей выборки, обеспечивающего приемлемую точность прогнозирования.

В связи с этим была поставлена задача определения минимально возможного объема обучающих данных для получения сети равнозначного качества и тем самым снижения трудоемкости и стоимости эксперимента.

С этой целью были сформированы четыре усеченных набора данных – 75 %, 50 %, 25 % и 12 % от полного объема и для каждого варианта созданы MLP-модели с идентичной архитектурой.

Результаты обучения визуализированы через диаграммы распределения погрешностей (рис. 2).

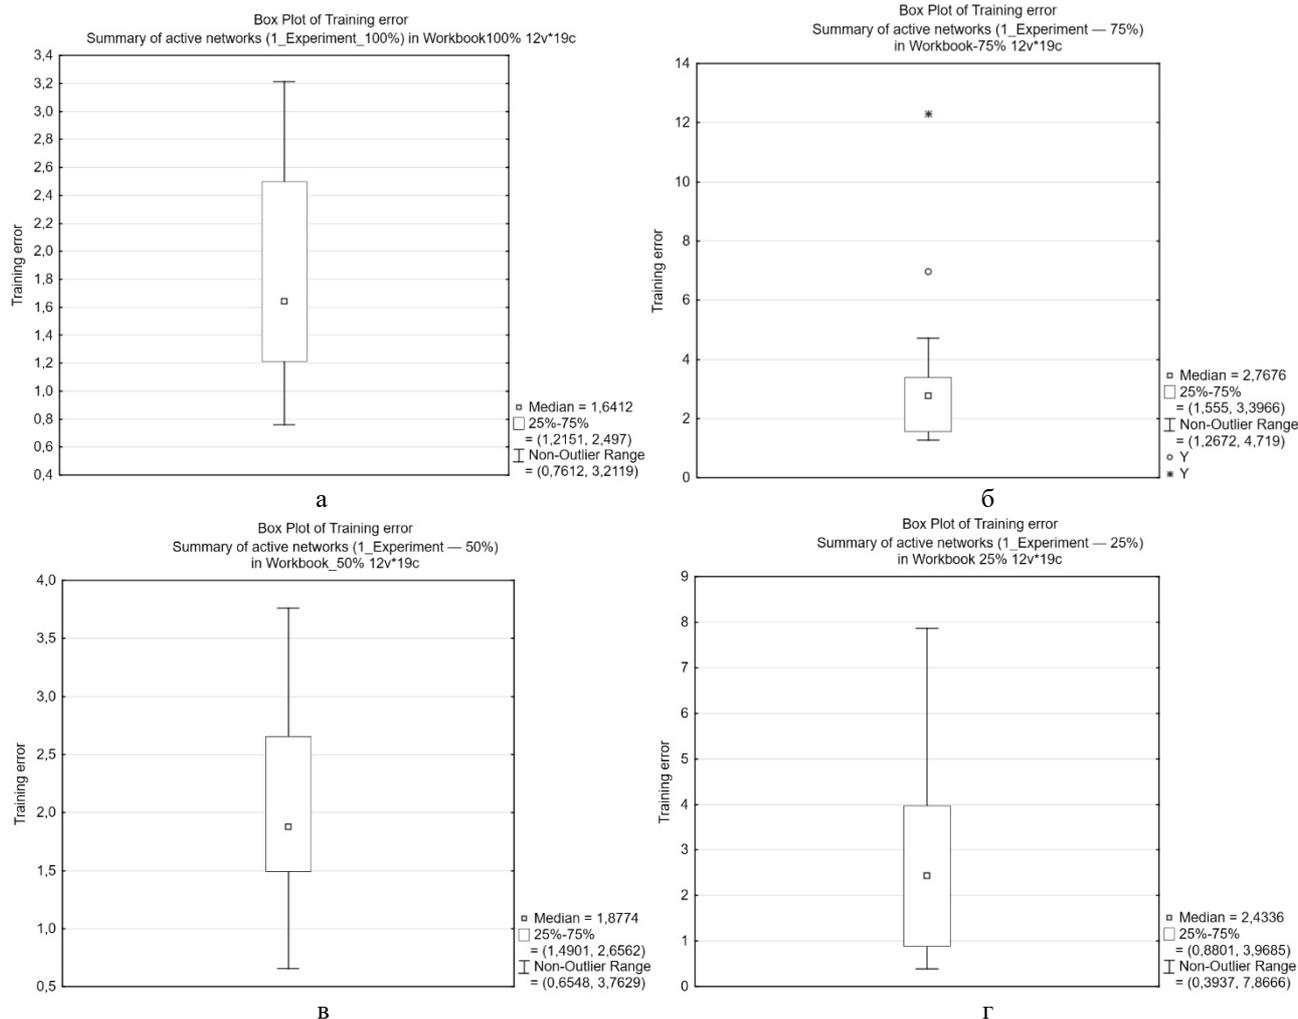
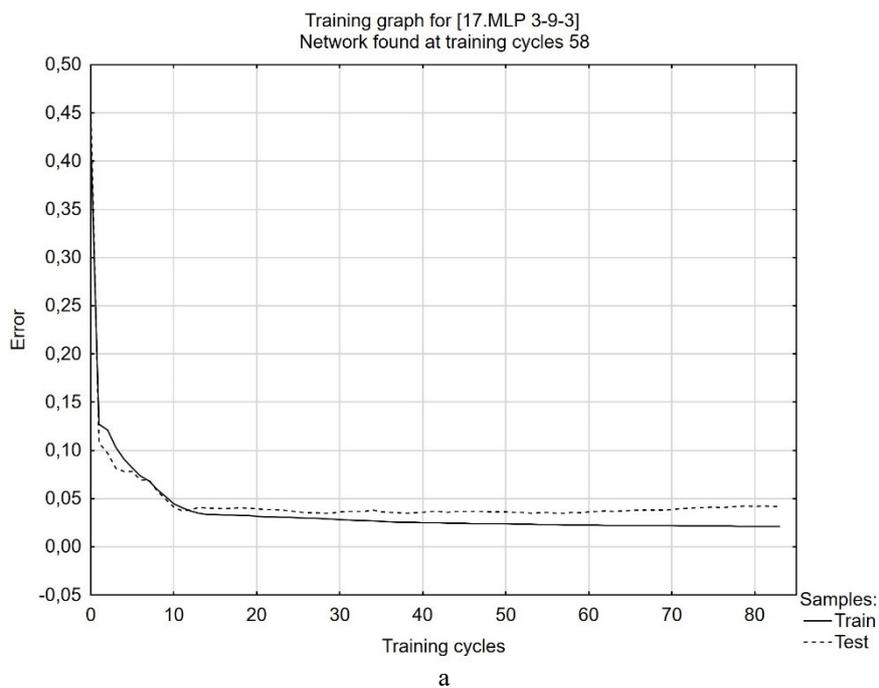


Рис. 2. Диаграммы размаха построенных сетей на размере выборок:  
а – 100 %; б – 75 %; в – 50 %; г – 25 %

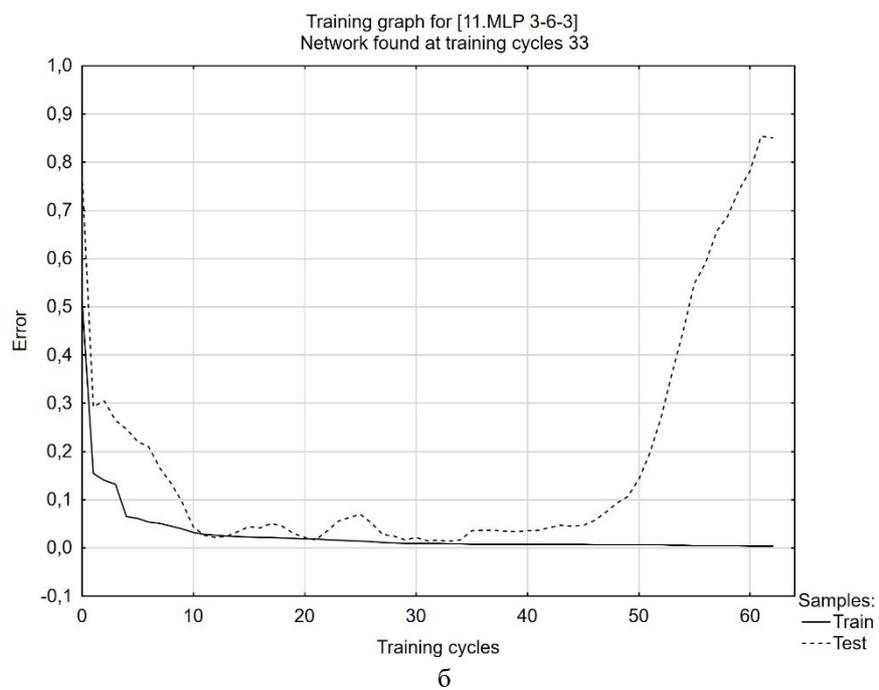
**Анализ результатов показал, что:**

- при 100 % данных разброс ошибок не превышал 3,2, демонстрируя стабильность моделей;
- сокращение выборки до 75 % и 50 % увеличило вариативность ошибок до 3,7...4,7;
- на 25 % данных отклонения достигли 7,9 при расширении квартильного размаха с 1,2...2,5 до 0,9...3,9.

- Из графиков обучения (рис. 3) видно, что
- для выборок 25–100 % кривые стабилизируются после 20 итераций;
- на 12 % данных наблюдались хаотичные колебания ошибок, что свидетельствует о невозможности построения работоспособной модели.



а



б

Рис. 3. Графики обучаемости нейросетей при различных размерах выборки:  
а – 25...100 %, б – 12 %

Из табл. 2, где представлены лучшие конфигурации сетей для каждого объема данных, следует, что:

- число нейронов скрытого слоя: 7...9 для всех рабочих моделей;
- при 50 % данных точность прогнозов соответствовала результатам полной выборки;
- модель на 25 % данных сохранила функциональность, но с погрешностью, превышающей базовый уровень на 18...27 %.

Результаты табл. 3 показывают, что

- допустимый минимум обучающих данных – 25 % от исходного объема;

- критический порог (12 %) делает модели непригодными для практического использования;

- оптимальный баланс между затратами и точностью достигается при 50 % выборки.

Третьей проблемой при моделировании характеристик шпиндельных узлов с помощью нейросетей стала оптимизация времени экспериментов при множестве комбинаций входных параметров. Рост числа факторов экспоненциально увеличивает сложность расчетов, что требует применения специализированных методов генерации данных.

Таблица 2

**Сводная таблица построенных нейронных сетей с наилучшими показателями по критериям ошибки и производительности**

Размер выборки, %	Название сети	Производительность на обучении	Производительность на тесте	Производительность на контроле	Ошибка на обучении	Ошибка на тесте	Ошибка на контроле	Алгоритм обучения
100	MLP 3×7×3	0,8766	0,8633	0,8309	0,6642	0,9893	1,3191	BFGS (72)
75	MLP 3×8×3	0,8831	0,8424	0,7892	1,2916	0,9741	1,3519	BFGS (34)
50	MLP 3×9×3	0,8943	0,8550	0,8692	0,7878	1,6255	0,5634	BFGS (58)
25	MLP 3×7×3	0,9631	0,9839	0,7175	0,6081	2,0013	3,0350	BFGS (67)
12	MLP 3×6×3	0,9701	0,0000	0,0000	1,3270	1,9358	1,8068	BFGS (33)

Таблица 3

**Средняя относительная ошибка переменных для разного размера выборки**

Размер выборки, %	Название сети	MAPE (T)	MAPE (Δ)	MAPE (δ)
100	MLP 3×7×3	0,01672	0,06250	0,09722
75	MLP 3×8×3	0,02597	0,06442	0,07792
50	MLP 3×9×3	0,02342	0,06723	0,10156
25	MLP 3×7×3	0,03020	0,07691	0,16193

Для этой цели могут использоваться методы планирования экспериментов [18]: полно-факторный эксперимент (ПФЭ) и дробно-факторный эксперимент (ДФЭ). Однако, хотя ПФЭ обеспечивает полноту данных, но требует реализации всех комбинаций факторов, что ресурсоемко. ДФЭ сокращает объем работ, но приводит к потере части информации из-за эффектов смешивания.

В связи с указанным предлагается использовать генератор псевдослучайных чисел (ГПСЧ) для формирования комбинаций факторов. Преимущество такого подхода – гибкость в управлении объемом данных, что критично для обучения нейросетей.

Из современных ГПСЧ выбран «Вихрь Мерсенна» – алгоритм, разработанный Мамото и Такудзи Нисимура в 1997 г. [19]. Его основные преимущества: длинный период повторения (на основе чисел Мерсенна) и отсутствие статистических аномалий (предсказуемость, корреляции).

Код генератора интегрирован в Python-среду [20, 21], что обеспечило адаптивность под задачи исследования.

Настройка нейросетевых моделей в пакете Statistica содержала следующие ключевые моменты:

- построение сетей осуществлялось автоматическим (в начале табл. 1), пользовательским методом (в середине табл. 1) и методом многократных подвыборок (в конце табл. 1), с помощью последнего получены сети наилучшего качества применительно к решаемым в данной работе задачам;

- строились два типа сетей: радиальные базисные функции (RBF) и многослойный персептрон (MLP).

Из табл. 1 видно, что сеть MLP показала на 23–35 % меньшую погрешность.

**Параметры обучения и разделения данных:**

- число нейронов скрытого слоя: 3...20 (оптимум – 7–9);
- функции активации:
  - скрытый слой: гиперболический тангенс (для всех выборок), сигмоида, экспонента;
  - выходной слой: линейная функция;
- алгоритм оптимизации: квазиньютоновский метод BFGS с критерием остановки при изменении ошибки  $< 1 \cdot 10^{-7}$  за 20 итераций.
- максимальное число итераций: 2000 (фактически достаточно 200);
- 70 % – обучение, 15 % – тест, 15 % – контроль (сохранено для всех вариантов выборки: 12–100 %);
- функция потерь: среднеквадратичная ошибка (MSE).

Из данных, приведенных в табл. 1, следует, что наилучшие результаты показали сети, построенные методом многократных подвыборок.

**Использование ГПСЧ «Вихрь Мерсенна» сократило время генерации данных на 40 % по сравнению с ПФЭ, сохранив репрезентативность выборки.**

Из сводной таблицы построенных нейросетей (табл. 1) выбрана сеть с индексом 58 MLP 3×7×3.

В процессе анализа чувствительности входных переменных сети № 58, приведенных в табл. 1, установлено, что наибольшее влияние на выходные переменные оказывает частота вращения

шпинделя  $n$ , далее идёт – радиальная сила воздействия на оправку, установленную в конус шпинделя  $P$ , имитирующая силу резания, и

наименьшее влияние оказывает время работы станка  $t_m$ , значение которого находится на уровне шума (табл. 4).

Таблица 4

#### Анализ чувствительности входных переменных

Сеть	$n$	$P$	$t_m$
58.MLP 3×7×3	51,1431	24,1656	5,4989

В табл. 5 показаны коэффициенты корреляции для трёх переменных на обучении, тесте и контроле. Видно, что у переменных «температура» и «смещение переднего конца шпинделя» корреляционная связь «весьма высокая» близкая к единице, а у переменной «биение» «заметная»

около 0,6, т.е. изменение величин входных переменных оказывает более сильное влияние на «температура» и «смещение переднего конца шпинделя», в то время как на «биение» такое изменение входных переменных оказывает влияние сравнительно ниже.

Таблица 5

#### Коэффициенты корреляции

	$T$			$\Delta$			$\delta$		
	Обучение	Тест	Контроль	Обучение	Тест	Контроль	Обучение	Тест	Контроль
58.MLP 3×7×3	0.9964	0.9957	0.9893	0.6397	0.5986	0.5070	0.9937	0.9956	0.9962

В табл. 6 показана ошибка для переменной «температура  $T$ » относительно исходных значений на тестовой выборке (подмножестве) и введена новая переменная – относительная ошибка (MAPE), определяемая как отношение третьей переменной в таблице к абсолютному значению первой переменной (исходные данные):

$$MAPE = \frac{v3}{abs(v1)},$$

где  $v3$  и  $v1$  – переменные из третьего и первого столбцов в таблице 5, т.е. из столбцов с заголовками  $T$ -Abs. Res. 58.MLP3×7×3 и  $T$  Target.

Аналогично посчитаны ошибки по переменным биения и смещения переднего конца шпинделя (табл. 7 и 8).

Таблица 6

#### Определение ошибки для переменной $T$

Номер наблюдения	Таблица прогнозов для $T$ (тестовое подмножество)			
	$T$ Target	$T$ - Output 58.MLP 3×7×3	$T$ -Abs. Res. 58.MLP 3×7×3	MAPE = $v3/abs(v1)$
1	23,700	22,538	1,1617	0,04902
8	23,700	24,025	0,3249	0,01370
13	30,400	29,673	0,7271	0,02392
23	31,500	30,204	1,2958	0,04114
26	33,400	32,550	0,8496	0,02544
30	34,200	33,131	1,0689	0,03125
33	35,200	34,616	0,5842	0,01660
35	35,800	35,439	0,3608	0,01008
43	36,100	35,973	0,1271	0,00352
45	37,400	37,507	0,1070	0,00286
50	37,200	37,349	0,1491	0,00401
70	43,900	43,923	0,0232	0,00053
81	47,600	47,308	0,2917	0,00613
88	42,200	44,723	2,5227	0,05978
91	50,000	49,918	0,0816	0,00163
102	57,100	56,508	0,5918	0,01036

Таблица 7

Определение ошибки для переменной « $\Delta$ »

Номер наблюдения	Таблица прогнозов для $\Delta$ (тестовое подмножество)			
	$\Delta$ (Target)	$\Delta$ – Output (58.MLP 3×7×3)	$\Delta$ – Abs. Res. (58.MLP 3×7×3)	MAPE
1	5,700	5,951	0,251	0,04403
8	5,700	5,517	0,183	0,03205
13	6,000	6,655	0,655	0,10912
23	6,000	6,655	0,655	0,10912
26	6,660	6,701	0,041	0,00623
30	7,660	6,768	0,892	0,11650
33	7,660	6,657	1,003	0,13097
35	8,160	6,812	1,348	0,16517
43	8,160	6,972	1,188	0,14560
45	7,000	6,856	0,144	0,02060
50	6,000	7,078	1,078	0,17963
70	7,000	7,166	0,166	0,02378
81	7,500	7,306	0,194	0,02591
88	7,660	7,209	0,451	0,05891
91	7,000	7,257	0,257	0,03666
102	7,660	7,349	0,311	0,04063

Таблица 8

Определение ошибки для переменной  $\delta$ 

Номер наблюдения	Таблица прогнозов для $\delta$ (тестовое подмножество)			
	$\delta$ (Target)	$\delta$ – Output (58.MLP 3×7×3)	$\delta$ – Abs. Res. (58.MLP 3×7×3)	MAPE
1	2,000	2,502	0,502	0,25078
8	21,500	20,289	1,211	0,05632
13	12,000	13,290	1,290	0,10752
23	17,000	15,966	1,034	0,06082
26	19,000	18,495	0,505	0,02656
30	10,000	10,340	0,340	0,03398
33	3,5000	4,730	1,230	0,35149
35	14,000	13,311	0,689	0,04922
43	19,000	18,489	0,511	0,02689
45	6,5000	7,360	0,860	0,13234
50	16,000	15,826	0,174	0,01090
70	22,500	21,017	1,483	0,06591
81	3,0000	3,688	0,688	0,22938
88	13,000	12,362	0,638	0,04910
91	9,5000	9,525	0,025	0,00262
102	2,0000	1,471	0,529	0,26443

Средние относительные ошибки для трёх выходных переменных составили: 1,87 % – для  $T$  (температура); 7,78 % – для  $\Delta$  (биение шпинделя); 10,7 % – для  $\delta$  (радиальное смещение переднего конца шпинделя). Из приведенных значений видно, что рассматриваемая нейросеть очень хорошо описывает зависимости даже для переменной  $\Delta$  с заметной корреляционной связью.

**Выводы.**

1. Для построения нейросетей, используемых для проектирования подсистем металлорежущих станков, может успешно использоваться

математический пакет Statistica, обладающий удобным и широкоуниверсальным интерфейсом.

2. Анализ, проведенный с использованием математического пакета Statistica, показал, что для моделирования эксплуатационных характеристик шпиндельного узла может успешно использоваться нейросеть на основе многослойного персептрона. Сети, построенные с помощью радиальных базисных функций (RBF) дают заметно худший результат, чем сети на основе многослойного персептрона (MLP).

3. При трех входных и трех выходных переменных наилучшие результаты по критериям

производительности и минимизации ошибки при обучении и при тестировании показала сеть с архитектурой многослойного перцептрона MLP  $3 \times 7 \times 3$ , которая имеет 7 нейронов на скрытом слое. Для указанной нейросети средние относительные ошибки для выходных переменных составили: для температуры – 1,87 %; для биения шпинделя – 7,78 %; для радиального смещения переднего конца шпинделя под действием нагрузки – 10,7 %.

4. При условии многовариантности комбинаций переменных, учитывающих действующие факторы, для получения обучающих данных предложено использовать генератор псевдослучайных чисел «Вихрь Мерсенна».

5. Исследования по сокращению трудоемкости сбора экспериментальных обучающих данных, число которых рекомендуется как 10-тикратно увеличенное число связей в модели, показали, что данные, сокращенные на 25 % и даже на 50 %, позволяют построить качественные нейросети.

6. Анализ, проведенный с использованием сети MLP  $3 \times 7 \times 3$ , показал, что при прогнозировании выбранных эксплуатационных характеристик шпиндельного узла наибольшее влияние на выходные переменные оказывает частота вращения шпинделя и сила, имитирующая силу резания.

## БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Проектирование металлорежущих станков и станочных систем: Справочник-учебник. В 3 т. Т.1. Проектирование станков / А.С. Проников, О.И. Аверьянов, Ю.С. Аполлонов и др.; Под общ. ред. А.С. Проникова. М.: Изд-во МГТУ им. Н.Э. Баумана: Машиностроение, 1994. 444 с.
2. Пуш А.В., Зверев И.А. Шпиндельные узлы: качество и надежность при проектировании. М.: СТАНКИН, 2000. 132 с.
3. Зверев И.А., Данильченко Ю.М. Комплексное моделирование при проектировании шпиндельных узлов на опорах качения // Вестник СевНТУ. 2014. № 150. С. 75–80.
4. Уоссерман Ф. Нейрокомпьютерная техника: теория и практика. М.: Мир, 1990. 320 с.
5. Круглов В.В., Борисов В.В. Искусственные нейронные сети. Теория и практика. М.: Горячая линия-Телеком, 2002. 382 с.
6. Боровиков В.П. Нейронные сети. STATISTICA Neural Networks: Методология и технологии современного анализа данных. М.: Горячая линия – Телеком, 2008. 392 с.
7. Скуратов М.И., Пугач Н.Г., Екомасов Е.Г., Львов Б.Г. Искусственные нейронные сети: базовые принципы и возможные реализации // Известия Уфимского научного центра РАН. 2022. № 4. С. 5–11.
8. Кудинов А.В. Особенности нейросетевого моделирования станков // СТИН. 2001. № 1. С. 13–18.
9. Позевалкин В.В., Поляков А.Н. Исследование эффективности тепловых моделей станка на основе нейронных сетей прямого распространения // СТИН. 2021. № 10. С. 29–32.
10. Кузнецов Д.И. Обоснование технических характеристик гибких производственных модулей нейросетевыми методами : специальность 05.03.01 : автореферат диссертации на соискание ученой степени кандидата технических наук / Кузнецов Дмитрий Иванович. – Комсомольск-на-Амуре, 2004. 21 с.
11. Михалёв О.Н., Янюшкин А.С. Применение нейронной сети для автоматизации проектирования // Высокие технологии в машиностроении. Материалы XVIII всероссийской научно-технической конференции с международным участием. Отв. редактор Р.Г. Гришин. Самара, 2021. С. 93–96.
12. Богатиков В.Н., Кириллов И.Е., Морозов И.Н. Распределенная адаптивная модель прогнозирования изменения параметров технологических систем // Труды Кольского научного центра РАН. 2012. № 6 (13). С. 158–168.
13. Graph Neural Networks for Leveraging Industrial Equipment Structure: An application to Remaining Useful Life Estimation. Jyoti Narwariya, Pankaj Malhotra, Vishnu TV, Lovekesh Vig, Gautam Shroff. arXiv:2006.16556 [cs.LG]. [Электронный ресурс]. Систем. требования: AdobeAcrobatReader. URL: <https://arxiv.org/pdf/2006.16556>
14. Рожков С.В., Шадский Г.В., Шадский В.Г. Оценка технического состояния передней опоры шпиндельного узла металлорежущего станка // Известия ТулГУ. Технические науки. 2017. Вып. 8. Ч. 2. С. 251–257.
15. Хайкин С. Нейронные сети: полный курс, 2-е издание.: Пер. с англ. М.: Издательский дом «Вильямс», 2006. 1104 с.
16. StatSoft, Inc. 2012. Электронный учебник по статистике Москва, StatSoft. WEB: <http://www.statsoft.ru/home/textbook/default.htm>. [Электронный ресурс]. Систем. требования: Интернет браузер URL: <https://web.archive.org/web/20131213145139/http://statsoft.ru/home/textbook/default.htm>
17. Рашид Т. Создаем нейронную сеть. : Пер. с англ. СПб. : ООО «Альфа-книга», 2017. 272 с.
18. Гришелёнок Д.А., Ковель А.А. Использование результатов математического планирования эксперимента при формировании обучающей выборки нейросети // Известия высших

учебных заведений. Приборостроение. 2011. Т. 54. № 4. С. 51–54.

19. Matsumoto M., Nishimura T. Mersenne twister: A 623-dimensionally equidistributed uniform pseudorandom number generator // ACM Transactions on Modeling and Computer Simulations. 1998. Vol. 8 (1). Pp. 3–30.

20. Задка М., Уильямс М., Бенфилд К., Уорнер Б., Митчелл Д., Сэмюэл К., Тарди П. Twisted

из первых рук / пер. с англ. А.Н. Киселева. М.: ДМК Пресс, 2020. 338 с.

21. Денисенко А.Ф., Ладыгин Р.В., Якимов М.В. Применение нейронных сетей для моделирования эксплуатационных характеристик шпиндельного узла // Системы. Методы. Технологии. № 2 (62). 2024. С. 78–86.

#### Информация об авторах

**Денисенко Александр Федорович**, доктор технических наук, профессор кафедры «Технология машиностроения, станки и инструменты». E-mail: sammortor@yandex.ru. Самарский государственный технический университет. Россия, 443100, Самара, ул. Молодогвардейская, 244.

**Ладыгин Роман Владимирович**, аспирант кафедры «Технология машиностроения, станки и инструменты». E-mail: konferencia-isap@yandex.ru. Самарский государственный технический университет. Россия, 443100, Самара, ул. Молодогвардейская, 244.

Поступила 08.02.2025 г.

© Денисенко А.Ф., Ладыгин Р.В., 2025

**Denisenko A.F., \*Ladyagin R.V.**  
Samara State Technical University  
\*E-mail: konferencia-isap@yandex.ru

## SETTINGS FOR THE PROCESS OF CONSTRUCTING AND TRAINING NEURAL NETWORKS WHEN SOLVING PROBLEMS OF PREDICTING THE OPERATIONAL CHARACTERISTICS OF SPINDLE UNITS

**Abstract.** The study is devoted to the development of neural network methods for modeling the operational characteristics of spindle units of metal-cutting machines. The paper solves three key problems: selecting the optimal neural network architecture, minimizing the volume of training data and reducing the time of experiments in multiparameter analysis. It was found that a multilayer perceptron with the  $3 \times 7 \times 3$  architecture shows the smallest average relative prediction errors – 1.87% for temperature, 7.78% for spindle runout and 10.7% for elastic displacement of the spindle front end. The experiments confirmed the possibility of reducing the sample size to 50% without significant loss of accuracy, and the use of the Mersenne Twister pseudorandom number generator made it possible to reduce the data generation time by 40%. Sensitivity analysis revealed the dominant effect of the spindle speed ( $n$ ) and the force applied to the spindle front end ( $P$ ) on the output parameters, while the operating time ( $t_m$ ) was statistically insignificant. The use of the Statistica package provided flexibility in model configuration, including the choice of activation functions (hyperbolic tangent, sigmoid) and optimization algorithms (Broyden–Fletcher–Goldfarb–Shanno). The results showed the superiority of the multilayer perceptron over radial basis networks in accuracy by 23–35%. The practical significance of the work lies in the creation of a methodology for designing a control system that combines neural network technologies with rational planning of experiments.

**Keywords:** neural network, sample size, experimental design, forecasting, spindle unit

### REFERENCES

1. Design of metal-cutting machine tools and machine tool systems: Handbook-textbook. In 3 volumes. Volume 1. Design of machine tools. A.S. Pronikov, O.I. Averyanov, Yu.S. Apollonov, et al.; Under the general editorship of A.S. Pronikov [Proektirovanie metallorzhushhix stankov i stanochny'x sistem]. Moscow: Publishing house of Bauman Moscow State Technical University: Mechanical Engineering, 1994. 444 p. (rus)

2. Push A.V., Zverev I.A. Spindle units: quality and reliability in design. [Shpindel'ny'e uzly': kachestvo i nadezhnost' pri proektirovanii]. Moscow: STANKIN, 2000. 132 p. (rus)

3. Zverev I.A., Danilchenko Yu.M. Integrated modeling in the design of spindle units on rolling bearings [Kompleksnoe modelirovanie pri proektirovanii shpindel'ny'x uzlov na oporax kacheniya]. Visnik SevNTU. 2014. No. 150. Pp. 75–80. (rus)

4. Wasserman F. Neurocomputer technology: theory and practice. [Nejrokomp'yuternaya tekhnika: teoriya i praktika]. M.: Mir, 1990. 320 p. (rus)

5. Kruglov V.V., Borisov V.V. Artificial neural networks. Theory and practice. [Iskusstvenny`e nejronny`e seti. Teoriya i praktika]. M.: Goryachaya Liniya-Telecom, 2002. 382 p. (rus)
6. Borovikov V.P. Neural networks. STATISTICA Neural Networks: Methodology and technologies of modern data analysis. [Metodologiya i texnologii sovremennogo analiza danny`x]. M.: Goryachaya Liniya - Telecom, 2008. 392 p. (rus)
7. Skuratov M.I., Pugach N.G., Ekomasov E.G., Lvov B.G. Artificial neural networks: basic principles and possible implementations [Iskusstvenny`e nejronny`e seti: bazovy`e principy` i vozmozhny`e realizacii]. Bulletin of the Ufa Scientific Center of the Russian Academy of Sciences. 2022. No. 4. P. 5–11. (rus)
8. Kudinov A.V. Features of neural network modeling of machine tools, [Osobnosti nejrosetevogo modelirovaniya stankov]. STIN. 2001. No. 1. Pp. 13–18. (rus)
9. Pozevalkin V.V., Polyakov A.N. Study of the efficiency of thermal models of a machine tool based on direct propagation neural networks [Issledovanie e`ffektivnosti teplovy`x modelej stanka na osnove nejronny`x setej pryamogo rasprostraneniya] STIN. 2021. No. 10. Pp. 29–32. (rus)
10. Kuznetsov D.I. Justification of technical characteristics of flexible manufacturing modules using neural network methods [Obosnovanie texnicheskix xarakteristik gibkix proizvodstvenny`x modulej nejrosetevy`mi metodami]. Abstract of a dissertation for the degree of candidate of technical sciences. Komsomolsk-on-Amur State Technical University. Komsomolsk-on-Amur, 2004. 21 p. (rus)
11. Mikhalev O.N., Yanyushkin A.S. Application of neural networks for design automation [Primenenie nejronnoj seti dlya avtomatizacii proektirovaniya]. High technologies in mechanical engineering. Proceedings of the XVIII All-Russian scientific and technical conference with international participation Responsible. editor R.G. Grishin. Samara, 2021. Pp. 93–96. (rus)
12. Bogatkov V.N., Kirillov I.E., Morozov I.N. Distributed adaptive model for forecasting changes in the parameters of technological systems [Raspredeleonnaya adaptivnaya model` prognozirovaniya izmeneniya parametrov texnologicheskix sistem]. Proceedings of the Kola Science Center of the Russian Academy of Sciences. 2012. No. 6 (13). Pp. 158–168. (rus)
13. Graph Neural Networks for Leveraging Industrial Equipment Structure: An application to Remaining Useful Life Estimation. Jyoti Narwariya, Pankaj Malhotra, Vishnu TV, Lovekesh Vig, Gautam Shroff. arXiv:2006.16556 [cs.LG]. [electronic resource]. Systems requirements: Adobe AcrobatReader, URL: <https://arxiv.org/pdf/2006.16556> (rus)
14. Rozhkov S.V., Shadsky G.V., Shadsky V.G. Assessment of the technical condition of the front support of the spindle unit of a metal-cutting machine [Ocenka texnicheskogo sostoyaniya perednej opory` shpindel`nogo uzla metallovezhushhego stanka]. Izvestiya Tula State University. Technical sciences. 2017. Issue 8. Part 2. Pp. 251–257. (rus)
15. Khaikin S. Neural networks: a complete course, 2nd edition: Trans. from English. [Nejronny`e seti: polny`j kurs]. M.: Williams Publishing House, 2006. 1104 p. (rus)
16. StatSoft, Inc. 2012. Electronic textbook on statistics. [E`lektronny`j uchebnik po statistike] Moscow, StatSoft. WEB: <http://www.statsoft.ru/home/textbook/default.htm> (rus)
17. Rashid T. Creating a neural network. [Sozdaem nejronnyuy set`]. Trans. from English - St. Petersburg: OOO «Alfa-book», 2017. 272 p. (rus)
18. Grishelenok D.A., Kovel A.A. Using the results of mathematical planning of the experiment in forming the training sample of the neural network [Ispol`zovanie rezul`tatov matematicheskogo planirovaniya e`ksperimenta pri formirovanii obuchayushhej vy`borki nejroseti]. News of higher educational institutions. Instrument engineering. 2011. Vol. 54. No. 4. Pp. 51–54. (rus)
19. Matsumoto M., Nishimura T. Mersenne twister: A 623-dimensionally equidistributed uniform pseudorandom number generator. ACM Trans. on Modeling and Computer Simulations. 1998. Vol. 8(1). Pp. 3–30.
20. Zadka M., Williams M., Benfield K., Warner B., Mitchell D., Samuel K., Tardy P. Twisted first-hand. Trans. from English by A. N. Kiseleva. [Twisted iz pervy`x ruk]. Moscow: DMK Press, 2020. 338 p. (rus)
21. Denisenko A.F., Ladyagin R.V., Yakimov M.V. Application of neural networks for modeling the operational characteristics of the spindle unit [Primenenie nejronny`x setej dlya modelirovaniya e`ksploatatsionny`x xarakteristik shpindel`nogo uzla] Systems. Methods. Technologies. No. 2 (62). 2024. Pp. 78–86. (rus)

*Information about the authors*

**Denisenko, Alexander F.** DSc, Professor. E-mail: sammortor@yandex.ru. Samara State Technical University, Russia, 443100, Samara, St. Molodogvardeyskaya, 244.

---

**Ladyagin, Roman V.** Postgraduate Student. E-mail: konferencia-isap@yandex.ru. Samara State Technical University. Russia, 443100, Samara, St. Molodogvardeyskaya, 244.

---

*Received 08.02.2025*

**Для цитирования:**

Денисенко А.Ф., Ладягин Р.В. Настройки процесса построения и обучения нейросетей при решении задач по прогнозированию эксплуатационных характеристик шпиндельных узлов // Вестник БГТУ им. В.Г. Шухова. 2025. № 6. С. 116–128. DOI: 10.34031/2071-7318-2025-10-6-116-128

**For citation:**

Denisenko A.F., Ladyagin R.V. Settings for the process of constructing and training neural networks when solving problems of pre-dicting the operational characteristics of spindle units. Bulletin of BSTU named after V.G. Shukhov. 2025. No. 6. Pp. 116–128. DOI: 10.34031/2071-7318-2025-10-6-116-128