

Применение нейронных сетей для моделирования эксплуатационных характеристик шпиндельного узла

А.Ф. Денисенко^а, Р.В. Ладыгин^б, М.В. Якимов^с

Самарский государственный технический университет, ул. Молодогвардейская, 244, Самара, Россия

^а sammortor@yandex.ru, ^б ladoshman@yandex.ru, ^с mikya@yandex.ru

^а <https://orcid.org/0000-0001-6393-2831>, ^б <https://orcid.org/0000-0002-0260-8032>, ^с <https://orcid.org/0009-0006-5610-4142>

Статья поступила 12.04.2024, принята 14.05.2024

В статье рассматриваются аспекты, связанные с применением нейронной сети для прогнозирования и оценки эксплуатационных характеристик шпиндельного узла металлорежущего станка. Проводится анализ применения нейронных сетей для решения задач прогнозирования состояния и проектирования конструкций сложных технических объектов. Показано планирование эксперимента с использованием языка Python с реализацией применения генератора псевдослучайных чисел Вихря Мерсенна и описан этап сбора экспериментальных данных для обучения нейронной сети. Приводится настройка модуля Neural networks математического пакета Statistica, в котором осуществлялись построение и обучение нейросети. Показан алгоритм выбора наилучшей нейронной сети по критериям ее производительности и ошибки обучения на тестовом множестве. Выбрана сеть со структурой на основе многослойного перцептрона, прогнозирующая работу шпиндельного узла с учетом взаимного влияния факторов — частоты вращения шпинделя (n), времени работы станка (t_m) и нагрузки на передний конец шпинделя (P) на выходные переменные — температуру наружного кольца подшипника (T), радиальное биение (Δ) и упругое смещение переднего конца шпинделя (E). Математическая оценка данной сети показала весьма высокую корреляционную связь для переменных T и E и заметную для Δ . При анализе чувствительности переменных видно высокое влияние переменной n и низкое, почти шумовое, — переменной t_m . Средняя относительная ошибка сети на тестовом множестве не превысила 10,7%. Приведенный пример использования построенной нейронной сети и его анализ доказали высокое качество сети со средней относительной ошибкой по отдельным переменным, не превышающей 9,8%.

Ключевые слова: шпиндельный узел; режимы работы шпинделя; нейросеть; ошибка обучения; многослойный перцептрон.

Application of neural networks to model the performance characteristics of a spindle assembly

A.F. Denisenko^а, R.V. Ladyagin^б, M.V. Yakimov^с

Samara State Technical University; 244, Molodogvardeyskaya St., Samara, Russia

^а sammortor@yandex.ru, ^б ladoshman@yandex.ru, ^с mikya@yandex.ru

^а <https://orcid.org/0000-0001-6393-2831>, ^б <https://orcid.org/0000-0002-0260-8032>, ^с <https://orcid.org/0009-0006-5610-4142>

Received 12.04.2024, accepted 14.05.2024

The article discusses aspects related to the use of a neural network for predicting and assessing the operational characteristics of the spindle assembly of a metal-cutting machine. An analysis is made of the use of neural networks to solve problems of predicting the state and designing structures of complex technical objects. The planning of an experiment using the Python language with the implementation of the Mersenne Twister pseudo-random number generator is shown and the stage of collecting experimental data for training a neural network is described. The setup of the Neural networks module of the Statistica mathematical package, in which the neural network is built and trained, is described. An algorithm for selecting the best neural network based on the criteria of its performance and training error on the test set is shown. A network with a structure based on a multilayer perceptron is selected, predicting the operation of the spindle assembly, taking into account the mutual influence of factors - spindle rotation speed (n), machine operating time (t_m) and load on the front end of the spindle (P) on the output variables: temperature of the outer ring of the bearing (T), radial runout (Δ) and elastic displacement of the front end of the spindle (E). When analyzing the sensitivity of the variables, one can see a high influence of the variable n and a low, almost noise, influence of the variable t_m . The average relative network error on the test set does not exceed 10.7%. The given example of using the constructed neural network and its analysis proved the high quality of the network with an average relative error for individual variables not exceeding 9.8%.

Keywords: spindle assembly; spindle operating modes; neural network; learning error; multilayer perceptron.

Введение. Тенденцией развития современного машиностроения является постоянное повышение производительности и точности обработки. Однако резкое снижение серийности выпускаемых станков, практически переход к их изготовлению по заказам

привели к тому, что существенно возросли требования к этапу проектирования, когда фактически не осталось возможностей для исправления ошибок, допущенных на этом этапе. Кроме того, проектирование оборудования зачастую осуществляется без достаточного обоснования

принятых ранее решений в станках-аналогах. В связи с этим значительно увеличилась потребность в методах, позволяющих оценить качество создаваемого оборудования еще на этапе проектирования.

Все многообразие потребительских свойств станков сводится к четырем обобщающим эксплуатационным показателям, инвариантным для любого производства: производительность, точность, переналаживаемость (технологический диапазон использования), надежность [1].

Шпиндельный узел (ШУ) современных станков представляет из себя сложную многокомпонентную систему, и от его характеристик во многом зависят эксплуатационные характеристики всего станка в целом.

Требования к эксплуатационным характеристикам шпиндельных узлов — точность, жесткость, нагрузочная способность и быстроходность были проанализированы и сформулированы в работе [2].

Достижение значений эксплуатационных характеристик ШУ, отвечающих всем требованиям нормативно-технической документации, как отмечается в работе [3], возможно за счет создания конструкций ШУ, устойчивых к воздействию нагрузок различной физической природы (силовых, тепловых и др.), что закладывается уже при проектировании путем оптимизации основных конструктивных параметров (компоновка, конструкция корпуса, геометрические характеристики), выбора типа, компоновки, способа создания натяга и точностных характеристик шпиндельных опор, анализа условий эксплуатации (нагрузка от резания, частота вращения, способ смазки и охлаждения, температура окружающей среды, теплофизические свойства ШУ), динамических возмущений (погрешности подшипников и элементов привода, неравномерный припуск на обработку и др.) [3].

Многообразие входных факторов и выходных параметров, а также множественные связи между ними выявлены не в полной мере и поэтому в предлагаемых частных математических моделях, таких как упруго-деформационная, динамическая, модель трения, тепловая, модель долговечности подшипников [3], учитываются недостаточно.

Таким образом, процесс проектирования ШУ базируется на решении задач анализа и оптимизации многомерных функций, которые успешно могут быть решены с использованием нейронных сетей (НС) [4–7].

В литературе имеются примеры успешного использования НС при проектировании сложных технических систем.

В работе [8] строилась модель станка на основе принципа рационального сочетания математических и информационных компонентов. Математические компоненты, соответствующие элементам модели, описывались уравнениями, как при классическом моделировании, например, нелинейными дифференциальными уравнениями. Информационные компоненты, отражающие связи между характерными параметрами элементов модели, представлялись в форме нейронных сетей, различающихся по типу решаемых задач. К примеру, слоистая сеть использовалась для статической задачи обоснования норм точности при проектировании многоцелевого шлифовального

полуавтомата, а полносвязная — в динамической задаче моделирования конструкций сверхточных направляющих.

В статье [9] рассматривалась и была доказана эффективность применения нейросетей со структурой прямого распространения для прогнозирования температуры в опорах качения узлов станка и других элементов конструкции.

Д.И. Кузнецов [10] использовал нейронные сети кластеризации для решения задач увеличения срока эффективной эксплуатации и управляемости станков, прогнозирования обработки на них новых деталей и создания процессов технологического производства.

Авторы [11] применяли нейронную сеть для решения задачи проектирования технологического процесса обработки типовой детали и небольших подзадач, таких как проектирование обработки отдельных отверстий или других элементов детали.

В работе [12] разработан подход к прогнозированию изменения параметров технологических систем в виде агентной системы с механизмом прогнозирования на основе нейросетей, в котором может быть получена не только информационная система, выполняющая определенные функции, но и динамическая по своей структуре и свойствам «модель реального времени», автоматически совершенствующая механизм своей работы.

В иностранной литературе описана и обоснована структура нейросети для прогнозирования изменения основных параметров торпедного ковша в металлургической промышленности [13].

Зарубежные авторы [14] предлагают оценивать структуру сложного оборудования в виде графика с использованием нейронных сетей (GNNS) для прогнозирования данных временных рядов с несколькими датчиками в процессе сравнительного анализа газотурбинных двигателей, открывающего путь для их эффективной диагностики.

В вышеперечисленных работах методами нейронных сетей производилась комплексная оценка параметров объектов и характеристик протекания процессов с учетом взаимного влияния факторов. Данный аспект является ключевым преимуществом нейросетевого моделирования по сравнению с классическими математическими линейными и нелинейными моделями.

В похожей работе [15] демонстрируется высокая эффективность применения нейронной сети для оценки технического состояния передней опоры шпиндельного узла по частотам вращения шпинделя и соответствующим им температурным показателям наружного кольца подшипника качения. Но эта работа учитывает только температурные зависимости, возникающие при работе ШУ, без учета других факторов, влияющих на процесс теплообразования.

В настоящей же работе авторы ставят своей целью прогнозирование характеристик шпиндельного узла с учетом расширенного количества взаимовлияющих факторов, возникающих в процессе эксплуатации ШУ.

Входными переменными были частота вращения шпинделя (n), время работы (t_m), сила воздействия на передний конец шпинделя (P). Целевыми (выходными)

переменными были температура передней шпиндельной опоры (T), биение шпинделя (Δ — *delta*), упругое смещение переднего конца шпинделя (E).

Применение генератора псевдослучайных чисел на этапе планирования эксперимента. Для качественного построения и обучения нейросети необходимо получить хорошие исходные значения. Ранее для их получения использовали методы полнофакторного (ПФЭ) и дробнофакторного (ДФЭ) эксперимента, которые не лишены недостатков. Так, при планировании по схеме ПФЭ требуется большая трудоемкость проведения такого эксперимента, в котором реализуются все возможные комбинации факторов на всех выбранных для исследования уровнях. А при ДФЭ получается большой объем неучтенных данных, обусловленный применяемой схемой смешивания.

Авторы же предлагают для получения сочетаний факторов и требуемого их количества использовать генератор псевдослучайных чисел (ГПСЧ), поскольку ГПСЧ способен выводить комбинации сочетаний для различного их количества, что, в частности, при обучении нейросетей является неоспоримым преимуществом, поскольку в каждом отдельном случае требуется выводить разный объем сочетаний.

Из современных ГПСЧ наибольшее применение получил Вихрь Мерсенна [16], разработанный в 1997 г. японскими учеными Мамото Мацумото и Такудзи Нисимура. Вихрь Мерсенна основывается на свойствах простых чисел Мерсенна и обеспечивает быструю генерацию высококачественных псевдослучайных чисел. Он лишен многих недостатков, присущих другим ГПСЧ, таких как малый период, предсказуемость, легко выявляемая статистическая зависимость.

ГПСЧ Вихрь Мерсенна и был выбран авторами для получения требуемого количества возможных сочетаний факторов. Алгоритм его применения реализован на языке *Python* [17] и приведен ниже.

Ввод:

```
n = [280,355,450,560,710,900,1120,1400,1800]
t = [15,30,45,60,75,90,105,120,135,150]
p = [500,1000,1500,2000, 2500,3000,3500,4000]
random.sample(set(itertools.product(n,t,p)), 100)
```

Out[1]:

```
[(1120, 75, 500),
 (710, 105, 1000),
 (1400, 15, 3500),
 (1800, 30, 4000),
 .....
 (710, 90, 1000),
 (280, 30, 2500),
 (280, 60, 4000),
 (280, 90, 500)],
```

где n — частоты вращения шпинделя, идущие напрямую, без переборной группы; t_m — значения времени работы станка, принятые через каждые 15 мин до времени выхода на устоявшийся температурный режим 135–150 мин, где изменения температуры минимальны; P — сила воздействия на передний конец

шпинделя, принята с интервалом 500 Н. Для станков нормальной точности установлено наибольшее значение 4 000Н; *random.sample* — вызов генератора для наборов данных и вывод требуемого числа сочетаний — 100. Число 100 сочетаний обусловлено тем, что связей в проводимом эксперименте 9, а для качественного обучения нейросети требуется, как правило в 10 раз больше сочетаний, чем связей в модели [18]; *out* — вывод результатов генерации (представлена часть значений).

При проведении эксперимента установка была собрана на базе 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 смещение опоры ШУ — при помощи индикаторов с ценой деления 1 мкм. Сила на переднем конце шпинделя имитировалась приложением нагрузки на короткую оправку с помощью нагружающего устройства ТЖ-1000.




Рис. 1. Общий вид экспериментальной установки

С целью сокращения времени проведения экспериментов при изменении времени работы станка на фиксированной частоте вращения шпинделя была оценена возможность проводить измерения на каждом следующем отрезке времени без полных циклов 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

Построение и выбор нейронной сети в пакете Statistica. В пакете *Statistica* со встроенным модулем нейронных сетей возможно их получение тремя способами: автоматическое построение, пользовательское построение и метод многократных подвыборок. Каждый из этих способов позволяет

строить нейронные сети двух типов, это многослойные перцептроны и радиальные базисные функции. В каждом случае строилось по 10 нейронных сетей, из которых обучались 5 наилучших сетей и сохранялись в сводной табл. 1. В процессе построения варьировалось число нейронов скрытого слоя от 3 до 20. Обучение происходило по алгоритму 2-го порядка — BFGS и останавливалось, если в течение 20 итераций ошибка не изменялась на величину более 0,0000001. Количество итераций (эпох) обучения задавалось 2 000. Выборка определялась программой случайным образом из следующих пропорций: 70 % — обучающая, 15 % — тестовая и 15 % — контрольная. В качестве функции потерь использовалась квадратичная функция.

В сводной табл. 1 построенных нейронных сетей можно наблюдать архитектуру каждой сети, производительность на обучении, тесте и контроле, ошибку на разных этапах и алгоритм обучения. Производительность характеризуется коэффициентом детерминации, т. е. чем ближе данное значение к единице, тем лучше данная модель приближает данные.

В начале таблицы представлены сети, построенные при помощи автоматического метода, затем идут пользовательские сети и в конце — сети, построенные методом многократных подвыборок. Последний метод построения применительно к данной задаче дал наилучшие результаты.

Особое внимание на данном этапе нужно уделить выбору нейронной сети. Сеть выбирается таким образом, чтобы производительность на этапе обучения, тесте и контроле была максимальной при минимальных ошибках, причем на обучении ошибка должна быть меньше, чем ошибка на тесте, которая, в свою очередь, меньше ошибки на контроле [18–19]. Как показал анализ построенных сетей (табл. 1), этим критериям наилучшим образом отвечает сеть с индексом 58 со структурой многослойного перцептрона MLP 3-7-3 [20], у которой число нейронов на входном и выходном слоях соответствует числу переменных и 7 нейронов на скрытом слое. В отличие от других,

выбранная сеть имеет простую структуру с одной из минимальных ошибок на обучении, вместе с тем она хорошо обобщает данные на тестовом множестве, в то время как другие сети справляются с этим хуже.

Отметим, что сети, построенные с помощью радиальных базисных функций (RBF), дают заметно худший результат, чем сети на основе многослойного перцептрона (MLP).

Структура построенной сети с функциями активации показана на рис. 3.

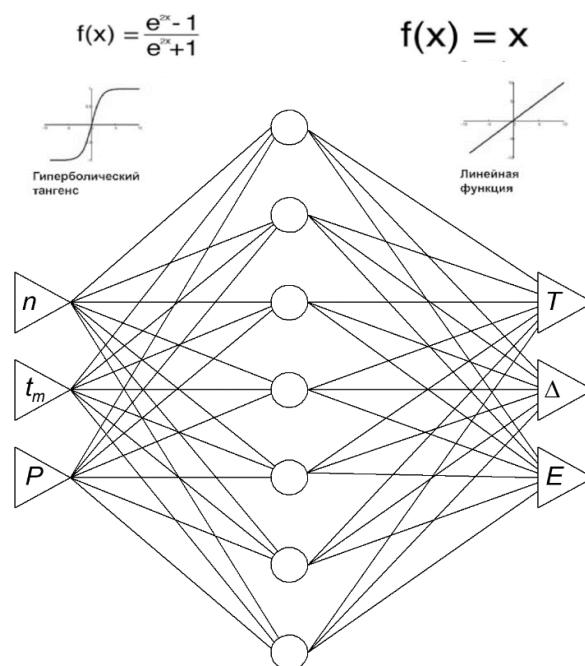


Рис. 3. Вид построенной сети и функции активации на скрытом и выходном слоях: гиперболический тангенс и тождественная (линейная) соответственно

Таблица 1. Сводная таблица построенных нейронных сетей

Summary of active networks (1 Experiment)								
Index	Net. name	Training perf.	Test perf.	Validation perf.	Training error	Test error	Validation error	Training algorithm
1	MLP 3-6-3	0,868752	0,771035	0,799192	2,41179	4,61836	5,37619	BFGS 67
2	MLP 3-5-3	0,879815	0,744031	0,800608	1,94139	3,50639	3,14534	BFGS 55
3	MLP 3-3-3	0,867959	0,760201	0,802289	2,29632	2,50997	1,79812	BFGS 27
4	MLP 3-9-3	0,908752	0,782638	0,849045	1,58808	1,97825	1,44256	BFGS 108
5	MLP 3-3-3	0,888533	0,780199	0,836448	2,17152	3,14646	2,46S43	BFGS 74
8	MLP 3-4-3	0,895361	0,771663	0,829826	1,25617	1,57267	1,67347	BFGS 84
36	RBF 3-8-3	0,741698	0,610488	0,749069	15,30956	14,56099	11,00919	RBFT
37	RBF 3-8-3	0,822102	0,814571	0,819942	6,76225	5,00853	4,41877	RBFT
38	RBF 3-8-3	0,780199	0,684303	0,766243	11,37219	6,87841	12,00872	RBFT
39	RBF 3-8-3	0,778485	0,647578	0,701063	18,52457	20,86913	19,80158	RBFT
10	RBF 3-8-3	0,762365	0,735835	0,669426	15,55088	9,78293	23,16133	RBFT
41	RBF 3-15-3	0,830380	0,711665	0,781587	8,44133	6,92146	8,30556	RBFT
42	RBF 3-14-3	0,885158	0,714035	0,788036	3,65689	3,39648	4,00471	RBFT
43	RBF 3-19-3	0,885304	0,712880	0,778909	3,34552	7,10913	4,63395	RBFT
44	RBF 3-17-3	0,850995	0,618523	0,837683	8,24080	13,09443	5,61396	RBFT

Summary of active networks (1 Experiment)								
Index	Net. name	Training perf.	Test perf.	Validation perf.	Training error	Test error	Validation error	Training algorithm
45	RBF 3-15-3	0,824192	0,691943	0,781038	6,83186	6,99716	6,18475	RBFT
46	MLP 3-4-3	0,851707	0,908601	0,788142	1,46893	1,19545	2,90275	BFGS 24
47	MLP 3-4-3	0,875721	0,770766	0,803762	1,65825	2,29909	1,76499	BFGS 48
48	MLP 3-4-3	0,865268	0,865185	0,830526	1,27109	1,82013	2,18766	BFGS 88
49	MLP 3-4-3	0,836660	0,804133	0,901422	2,86341	2,08901	3,17122	BFGS 25
50	MLP 3-4-3	0,837872	0,883075	0,872208	3,03319	3,75752	2,59111	BFGS 22
51	MLP 3-9-3	0,848216	0,889393	0,787325	2,84331	1,49339	3,45501	BFGS 20
52	MLP 3-9-3	0,862787	0,759059	0,784233	2,60447	3,13466	3,81621	BFGS 22
53	MLP 3-9-3	0,867972	0,864202	0,812525	0,97007	1,22607	1,24464	BFGS 48
54	MLP 3-9-3	0,869270	0,816995	0,892208	0,94261	0,62398	0,93219	BFGS 66
55	MLP 3-9-3	0,855702	0,855046	0,851509	1,03046	1,98247	0,89355	BFGS 30
56	MLP 3-7-3	0,829810	0,896689	0,717710	2,62488	1,81631	3,13429	BFGS 19
57	MLP 3-7-3	0,862109	0,767962	0,785585	1,84952	2,52291	2,09539	BFGS 23
58	MLP 3-7-3	0,876595	0,863295	0,830870	0,664223	0,989306	1,319104	BFGS 72

Математический анализ выбранной сети. В процессе анализа чувствительности переменных установлено, что наибольшее значение на выходные переменные оказывает N частота вращения, далее идет P сила воздействия на передний конец шпинделя и в

конце t_m время работы, значение которой находится на уровне шума (табл. 2).

На рис. 4 показано распределение остатков по трем переменным, по этим гистограммам видно, что все они соответствуют нормальному закону распределения «тяжелыми хвостами».

Таблица 2. Анализ чувствительности переменных

Networks	Sensitivity analysis (1_Experiment) Samples: Train, Test, Validation		
	n	P	t_m
58.MLP 3-7-3	51,1431111	24,16562	5,498928

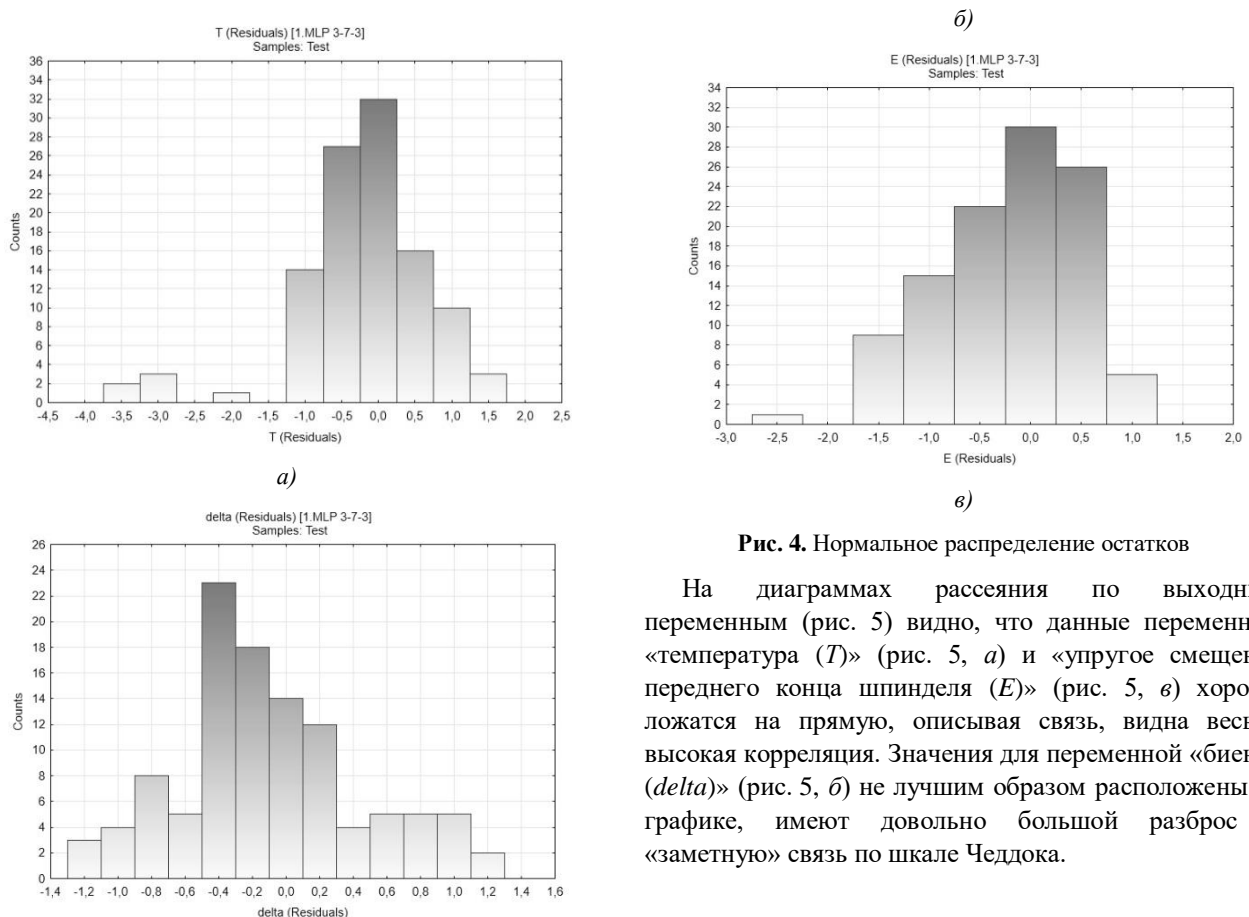
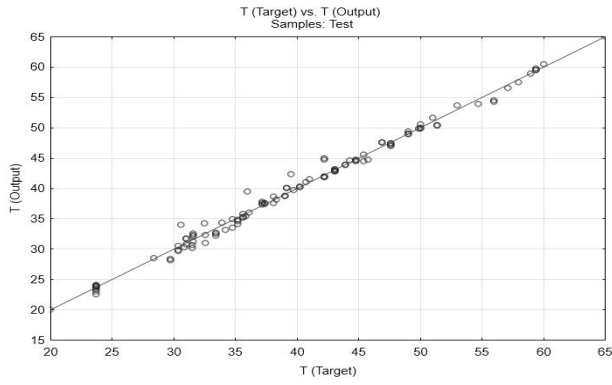
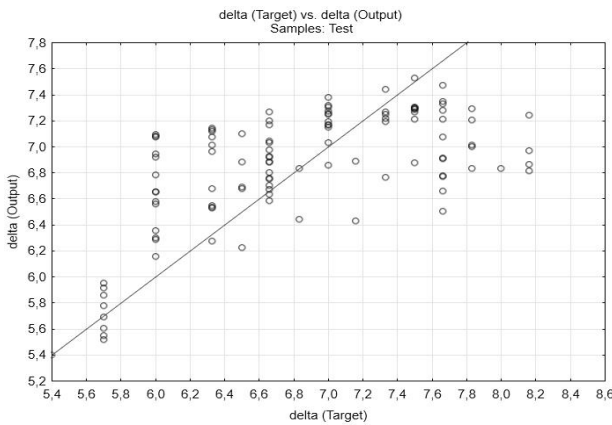


Рис. 4. Нормальное распределение остатков

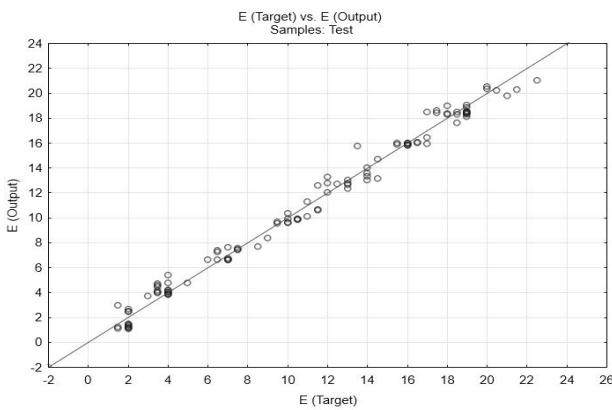
На диаграммах рассеяния по выходным переменным (рис. 5) видно, что данные переменных «температура (T)» (рис. 5, а) и «упругое смещение переднего конца шпинделя (E)» (рис. 5, в) хорошо ложатся на прямую, описывая связь, видна весьма высокая корреляция. Значения для переменной «биение ($delta$)» (рис. 5, б) не лучшим образом расположены на графике, имеют довольно большой разброс и «заметную» связь по шкале Чеддока.



а)



б)



в)

Рис. 5. Графики корреляции для выходных переменных

Полученные значения на графике поверхности зависимости температуры от частоты шпинделя и времени работы лежат, точно описывая поверхность (рис. 6).

На графике (рис. 7) значения зависимости температуры от частоты и силы воздействия на передний конец шпинделя также лежат весьма хорошо, поверхность описана достаточно точно.

График зависимости температуры от силы на переднем конце шпинделя и времени работы описывается посредственно, значения лежат не лучшим образом (рис. 8).




Рис. 6. График поверхности зависимости T от tm и n

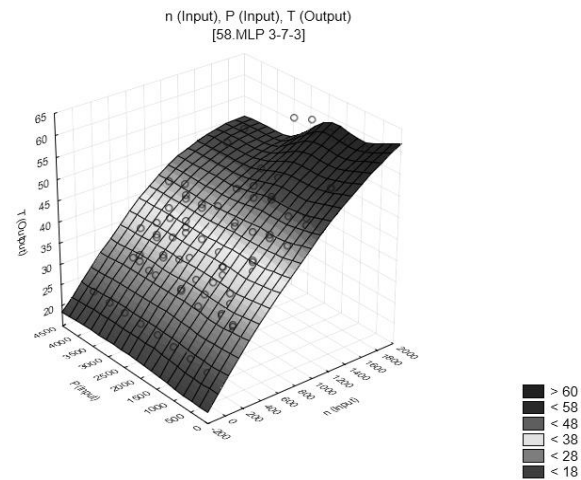


Рис. 7. График поверхности зависимости температуры от частоты и силы воздействия на передний конец шпинделя

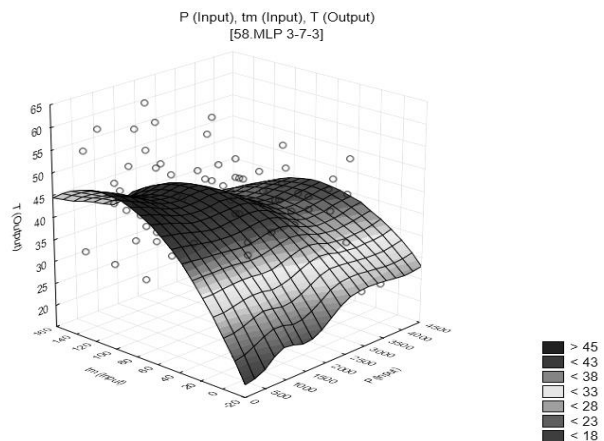


Рис. 8. График поверхности зависимости температуры от силы на переднем конце шпинделя и времени работы

В табл. 3 показаны коэффициенты корреляции для трех переменных на обучении, тесте и контроле. Видно, что у переменных «температура» и «упругое смещение переднего конца шпинделя» корреляционная связь «весьма высокая», близкая к единице, а у переменной «биение» — «заметная», около 0,6.

В табл. 4 показан анализ чувствительности по функциям для трех переменных. По точкам, здесь можно наблюдать, как изменяется

Таблица 3. Коэффициенты корреляции

	Correlation coefficients (1_Experiment)								
	T	T	T	delta	delta	delta	E	E	E
	Train	Test	Validation	Train	Test	Validation	Train	Test	Validation
58.MLP 3-7-3	0,996379	0,995658	0,989347	0,639717	0,598606	0,507081	0,993690	0,995621	0,996182

Таблица 4. Анализ чувствительности по точкам

Grid points	Pointwise sensitivity analysis for T (1 Experiment) Network: 58.MLP 3-7-3			Pointwise sensitivity analysis for delta (1_Experiment) Network: 58.MLP 3-7-3			Pointwise sensitivity analysis for E (1 Experiment) Network: 58.MLP 3-7-3		
	n Sensitivity (true positives)	tm Sensitivity (true positives)	P Sensitivity (true positives)	n Sensitivity (true positives)	tm Sensitivity (true positives)	P Sensitivity (true positives)	n Sensitivity (true positives)	tm Sensitivity (true positives)	P Sensitivity (true positives)
Minimum	0,020596	0,030992	-0,000089	0,001411	0,010415	0,000199	-0,000895	-0,005352	0,004871
2	0,022093	0,042665	-0,000123	0,001463	0,009172	0,000159	-0,001030	-0,004814	0,005371
3	0,022856	0,052072	-0,000149	0,001389	0,007459	0,000121	-0,001087	-0,003959	0,005768
4	0,022781	0,058302	-0,000163	0,001193	0,005387	0,000086	-0,001064	-0,002829	0,006037
5	0,021878	0,060619	-0,000163	0,000896	0,003104	0,000057	-0,000971	-0,001497	0,006161
6	0,020274	0,058572	-0,000146	0,000531	0,000765	0,000036	-0,000824	-0,000055	0,006134
7	0,018167	0,052073	-0,000113	0,000133	-0,001485	0,000023	-0,000641	0,001404	0,005957
8	0,015785	0,041417	-0,000066	-0,000261	-0,003528	0,000017	-0,000439	0,002790	0,005647
9	0,013337	0,027243	-0,000006	-0,000625	-0,005284	0,000020	-0,000234	0,004031	0,005226
Maximum	0,010984	0,010446	0,000062	-0,000941	-0,006713	0,000028	-0,000035	0,005071	0,004721

В табл. 5, показана ошибка для переменной температуры относительно исходных значений на тестовой выборке. Введена новая переменная — относительная ошибка (MAPE), определяемая как отношение третьей переменной в таблице к абсолютному значению первой переменной (исходные данные) (1):

$$MAPE = \frac{V3}{abs(V1)} \quad (1)$$

Таблица 5. Определение ошибки для переменной T

Case name	Predictions spreadsheet for T (1_Experiment) Network: 58.MLP 3-7-3 Samples: Test			
	T Target	T - Output 58.MLP 3-7-3	T - Abs. Res. 58. MLP 3-7-3	MAPE = v3/abs(v1)
1	23,70000	22,53832	1,161675	0,049015831
8	23,70000	24,02490	0,324905	0,01370906
13	30,40000	29,67285	0,727147	0,02391931
23	31,50000	30,20416	1,295841	0,04113781
26	33,40000	32,55037	0,849630	0,02543803
30	34,20000	33,13113	1,068872	0,03125357
33	35,20000	34,61582	0,584178	0,01659596
35	35,80000	35,43916	0,360837	0,01007924
43	36,10000	35,97291	0,127087	0,00352042
45	37,40000	37,50699	0,106993	0,00286076
50	37,20000	37,34908	0,149077	0,00400744

70	43,90000	43,92323	0,023233	0,00052923
81	47,60000	47,30835	0,291651	0,00612713
88	42,20000	44,72270	2,522702	0,05977967
91	50,00000	49,91837	0,081633	0,00163266
102	57,10000	56,50823	0,591774	0,01036382

Аналогично посчитаны ошибки по переменным биения и упругого смещения переднего конца шпинделя, расчет которых не приводится.

В табл. 6 показаны средние относительные ошибки для трех выходных переменных. По ним видно, что нейросеть очень хорошо описывает зависимости даже у переменной биения с заметной корреляционной связью, ошибка которой не превышает 11 %.

Таблица 6. Средние относительные ошибки для переменных

Case name	Predictions spreadsheet (1 Experiment) Network: 58.MLP 3-7-3 Samples: Test Subset of Predictions spreadsheet for (1_Experiment) Variables: 4 Include condition: v0 = 1		
	MAPE (T)	MAPE (delta)	MAPE (E)
MEAN case 1-16	0,01874812211	0,0778062939	0,1073914

Далее для проверки работоспособности и достоверности прогноза готовой нейросетью новых данных в нее был загружен тот же самый файл примера, который использовался при обучении.

Значения входных переменных из примера были скопированы и вставлены во вкладку «пользовательские наблюдения». По ним программа предсказала выходные значения переменных, представленные на рис. 9 в ячейках таблицы с приставкой «1».

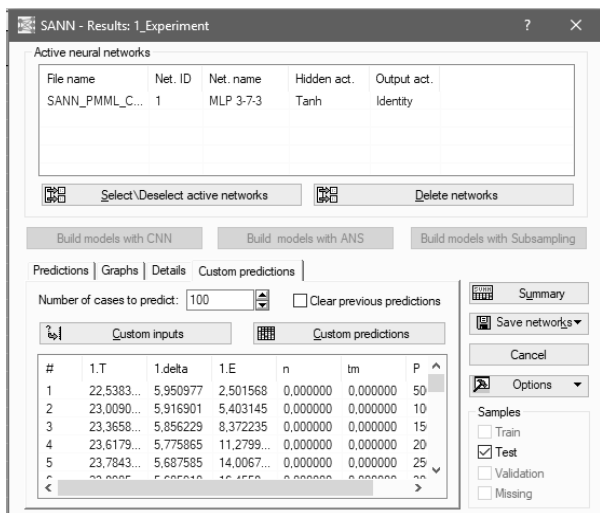


Рис. 9. Предсказанные значения переменных

Далее была посчитана относительная ошибка для предсказанных значений трех переменных аналогично тому, как это делалось ранее, после обучения сети (1). В табл. 7 приведены данные для переменной E.

Таблица 7. Относительная ошибка для предсказанных значений

Case name	Predictions spreadsheet for E (1 Experiment) Network: 1.MLP 3-7-3. Samples: Test			
	E	E – Output	E – Abs. Res.	MAPE E
	Target	1.MLP 3-7-3		= v3/abs(v1)
1	2,00000	2,50157	0,501568	0,25078399
2	4,00000	5,40314	1,403145	0,35078618
3	9,00000	8,37223	0,627765	0,06975169
4	11,00000	11,27991	0,279907	0,02544613
5	14,00000	14,00679	0,006786	0,0004847
6	17,00000	16,45586	0,544138	0,03200811
7	19,00000	18,56088	0,439123	0,02311173
8	21,50000	20,28906	1,210936	0,05632261
9	14,00000	13,57058	0,429418	0,03067271
10	18,00000	18,28031	0,280307	0,01557262
11	20,50000	20,22919	0,270806	0,01321006
12	2,00000	2,45745	0,457452	0,22872609
13	12,00000	13,29027	1,290274	0,10752287
14	8,50000	7,71543	0,784568	0,09230213

Литература

1. Проников А.С., Аверьянов О.И., Аполлонов Ю.С. Проектирование металлорежущих станков и станочных систем: справ. В 3 т. Проектирование станков. М.: Изд-во МГТУ им. Н.Э. Баумана, 1994. Т. 1. 444 с.
2. Пуш А.В., Зверев И.А. Шпиндельные узлы: качество и надежность при проектировании. М.: Станкин, 2000. 132 с.

15	2,00000	2,67322	0,673220	0,33660999
16	11,50000	10,57312	0,926880	0,08059826
17	16,50000	16,01411	0,485889	0,02944781
18	1,50000	2,95583	1,455827	0,97055139
19	11,50000	10,65296	0,847039	0,07365553
20	17,50000	18,61230	1,112297	0,06355985
21	5,00000	4,77314	0,226860	0,04537197
22	4,00000	4,77380	0,773796	0,19344888
23	17,00000	15,96605	1,033945	0,06082032
24	19,00000	18,34743	0,652569	0,03434575
25	7,00000	7,62409	0,624086	0,08915512
26	19,00000	18,49537	0,504634	0,02655969

И в завершение была посчитана средняя относительная ошибка так же, как это было сделано после процесса обучения, но только теперь уже на новых данных и готовой нейросетью (табл. 8). Максимальная ошибка не превысила 10 %.

Таблица 8. Средние относительные ошибки для переменных на контрольном примере

Case name	Predictions spreadsheet (1 Experiment) Network: 1.MLP 3-7-3 Samples: Test Subset of Predictions spreadsheet for (1_Experiment) Variables: 4 Include condition: v0 = 1		
	MAPE (T)	MAPE (delta)	MAPE (E)
MEAN case 1–16	0,0167199531	0,0625048404	0,0972225184

Заключение. Для моделирования эксплуатационных характеристик шпиндельного узла с использованием математического пакета *Statistica* выбрана сеть на основе многослойного перцептрона со структурой MLP 3-7-3, показывающая наилучшие результаты по производительности и ошибкам обучения.

Математический анализ данной сети показал, что наибольшее влияние на выходные переменные оказывает частота вращения шпинделя и сила, прикладываемая к переднему концу шпинделя, время же работы находится в диапазоне шума и в расчетах может не учитываться.

Построенная нейросетевая модель очень хорошо описывает зависимости как на тестовом множестве (ошибка не превышает 10.7 %), так и для предсказанных данных на контрольном примере (ошибка не превышает 9.8 %) и может быть использована на этапах проектирования и прогнозирования эксплуатационных характеристик шпиндельного узла металлорежущего станка.

3. Зверев И.А., Данильченко Ю.М. Комплексное моделирование при проектировании шпиндельных узлов на опорах качения // Вісник СевНТУ. 2014. № 150. С. 75-80.
4. Уоссерман Ф. Нейрокомпьютерная техника: теория и практика / пер. с англ. Ю.А. Зуева, В.А. Точенова. М.: Мир, 1992. 326 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 // Изв. Уфимского науч. 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: автореф. дис. ... на соиск. учен. степ. канд. техн. наук. Комсомольск-на-Амуре, 2004. 24 с.
11. Михалёв О.Н., Янюшкин А.С. Применение нейронной сети для автоматизации проектирования // Высокие технологии в машиностроении: материалы XVIII Всерос. науч.-технической конф. с междунар. участием (24-25 нояб. 2021 г.). 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 науч. центра РАН. 2012. № 6 (13). С. 158-168.
13. Yemelyanov V., Chernyi S., Yemelyanova N., Varadarajan V. Application of neural networks to forecast changes in the technical condition of critical production facilities. Computers & Electrical Engineering. 2021. V. 93. 107225.
14. Jyoti Narwariya, Pankaj Malhotra, Vishnu T.V., Lovekesh Vig, Gautam Shroff. Graph Neural Networks for Leveraging Industrial Equipment Structure: An application to Remaining Useful Life Estimation.
15. Рожков С.В., Шадский Г.В., Шадский В.Г. Оценка технического состояния передней опоры шпиндельного узла металлорежущего станка // Изв. ТулГУ. Технические науки. 2017. Вып. 8, Ч. 2. С. 251-257.
16. Matsumoto M., Nishimura T. Mersenne twister: A 623-dimensionally equidistributed uniform pseudorandom number generator // ACM Trans. on Modeling and Computer Simulations: journal. 1998. V. 8, № 1. P. 3-30.
17. 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.
18. Галушкин А.И. Нейронные сети: основы теории. М.: Горячая линия - Телеком, 2014. 496 с.
19. Рашид Тарик. Создаем нейронную сеть: пер. с англ. А.Г. Гузикевича. СПб.: ООО «Альфа-книга», 2017. 272 с.
20. Хайкин С. Нейронные сети: полный курс: пер. с англ. Н.Н. Кузусул, А.Ю. Шелестова. 2-е изд., испр. М.: Вильямс, 2008. 1103 с.
2. Push A.V., Zverev I.A. Spindle assemblies: quality and reliability in design. М.: Stankin, 2000. 132 p.
3. Zverev I.A., Danil'chenko Yu.M. Complex modeling in the design of spindle assemblies on rolling supports // Visnik SevNTU. 2014. № 150. P. 75-80.
4. Uosserman F. Neurocomputer technology: theory and practice / per. s angl. Yu.A. Zueva, V.A. Tochenova. М.: Mir, 1992. 326 p.
5. Kruglov V.V., Borisov V.V. Artificial neural networks. Theory and practice. М.: Goryachaya liniya - Telekom, 2002. 382 p.
6. Borovikov V.P. Neural networks. STATISTICA Neural Networks: Methodology and technologies of modern data analysis. М.: Goryachaya liniya - Telekom, 2008. 392 p.
7. Skuratov M.I., Pugach N.G., Ekomasov E.G., L'vov B.G. Artificial neural networks: basic principles and possible implementations // Proceedings of the RAS Ufa Scientific centre. 2022. № 4. P. 5-11.
8. Kudinov A.V. Features of neural network modeling of machine tools // STIN. 2001. № 1. P. 13-18.
9. Pozevalkin V.V., Polyakov A.N. Investigation of the effectiveness of thermal machine models based on neural networks of direct propagation // STIN. 2021. № 10. P. 29-32.
10. Kuznecov D.I. Substantiation of the technical characteristics of flexible production modules by neural network methods: avtoref. dis. ... na soisk. uchen. step. kand. tekhn. nauk. Komsomol'sk-na-Amure, 2004. 24 p.
11. Mihalyov O.N., Yanyushkin A.S. Application of a neural network for design automation // Vysokie tekhnologii v mashinostroenii: materialy XVIII Vseros. nauch.-tekhnicheskoy konf. s mezhdunar. uchastiem (24-25 noyab. 2021 g.). Samara, 2021. P. 93-96.
12. Bogatikov V.N., Kirillov I.E., Morozov I.N. A distributed adaptive model for predicting changes in the parameters of technological systems // Transactions Kola Science Centre of the Russian Academy of Sciences. 2012. № 6 (13). P. 158-168.
13. Yemelyanov V., Chernyi S., Yemelyanova N., Varadarajan V. Application of neural networks to forecast changes in the technical condition of critical production facilities. Computers & Electrical Engineering. 2021. V. 93. 107225.
14. Jyoti Narwariya, Pankaj Malhotra, Vishnu T.V., Lovekesh Vig, Gautam Shroff. Graph Neural Networks for Leveraging Industrial Equipment Structure: An application to Remaining Useful Life Estimation.
15. Rozhkov S.V., Shadskij G.V., Shadskij V.G. Assessment of the technical condition of the front support of the spindle assembly of a metal-cutting machine // News of the Tula State University (Izvestija TulGU). Technical sciences. 2017. Vyp. 8, Ch. 2. P. 251-257.
16. Matsumoto M., Nishimura T. Mersenne twister: A 623-dimensionally equidistributed uniform pseudorandom number generator // ACM Trans. on Modeling and Computer Simulations: journal. 1998. V. 8, № 1. P. 3-30.
17. Zadka M., Uil'yams M., Benfield K., Uorner B., Mitchell D., Semyuel K., Tardi P. Twisted from the first hand / per. s angl. A.N. Kiseleva. М.: ДМК Пресс, 2020. 338 p.
18. Galushkin A.I. Neural networks: basic theory. М.: Goryachaya liniya - Telekom, 2014. 496 p.
19. Rashid Tarik. Creating a neural network: per. s angl. A.G. Guzikevicha. SPb.: ООО «Al'fa-kniga», 2017. 272 p.
20. Hajkin S. Neural networks: a complete course: per. s angl. N.N. Kusul', A.Yu. Shelestova. 2-e izd., ispr. М.: Vil'yams, 2008. 1103 p.

References

1. Pronikov A.S., Aver'yanov O.I., Apollonov Yu.S. Design of metal-cutting machines and stationary systems: sprav. V 3 t. Designing machine tools. М.: Izd-vo MGTU im. N.E. Baumana, 1994. V. 1. 444 p.