

DOI: 10.34031/article_5db3f6c82c1ea9.69942788

*Ерыгин Е.В., Дуюн Т.А.

Белгородский государственный технологический университет им. В.Г. Шухова

Россия, 308012, Белгород, ул. Костюкова, д. 46

*E-mail: erygin.evgeny@gmail.com

ПРОГНОЗИРОВАНИЕ ШЕРОХОВАТОСТИ ПОВЕРХНОСТИ ПРИ ЧИСТОВОМ ФРЕЗЕРОВАНИИ С ИСПОЛЬЗОВАНИЕМ НЕЙРОННЫХ СЕТЕЙ

Аннотация. В данной статье рассмотрена задача прогнозирования шероховатости при чистовом фрезеровании с помощью нейросетевого моделирования. В качестве базы для создания и обучения искусственной нейронной сети выбрана прогрессивная формула для определения шероховатости при чистовом фрезеровании. В качестве одного из параметров для расчета шероховатости используется термоЭДС обрабатываемого и обрабатываемого материалов. Применение термоЭДС в качестве входного параметра позволяет учитывать материал заготовки и режущего инструмента, что сказывается на точности получаемых результатов. Создана обучающая выборка с данными на пять входов и один выход. Описана архитектура, особенности и алгоритм обучения сети. Создана и настроена нейронная сеть, определяющая шероховатость для чистового фрезерования. Наглядно отображен процесс обучения и отладки нейронной сети посредством выведенных графиков. Произведена проверка работоспособности сети на тестовых данных, позволившая получить хорошие результаты.

Ключевые слова: искусственные нейронные сети (ИНС), шероховатость, чистовое фрезерование, термоЭДС, Байесовская регуляризация.

Введение. Применение искусственных нейронных сетей дает большой скачок к развитию различных областей наук, в том числе и машиностроения. Разработка и использование искусственных нейронных сетей для повышения эффективности процессов механической обработки набирает все большую популярность среди ученых всего мира [1–5]. Использование искусственных нейронных сетей (ИНС) обусловлено их способностью к обучению на основе создания связей между входными и выходными данными. Одним из главных преимуществ является производительность сети, которая характеризуется

временем обучения и отклонением выходного сигнала от эталонного. Основное влияние на производительность оказывает архитектура сети и метод обучения. При грамотной настройке такая сеть дает возможность решать задачи без использования сложного математического аппарата.

Методология. В решении задач интерполяции хорошо себя зарекомендовали ИНС с обратным распространением ошибки [6], архитектура такой сети представлена на рис. 1. Сеть состоит из двух слоев (скрытого и выходного), с сигмоидальной и линейной функциями активации соответственно.

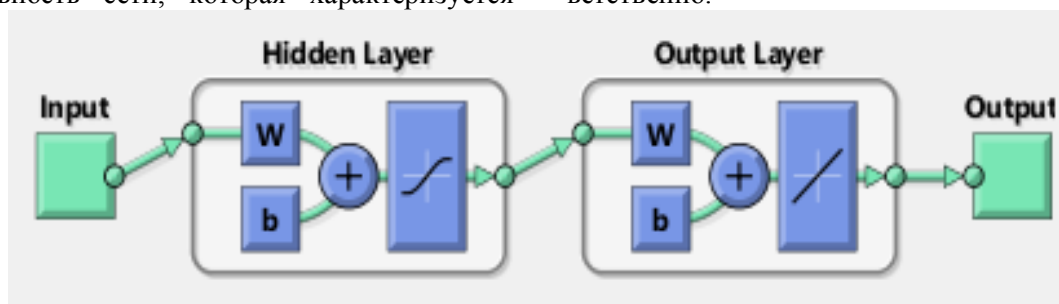


Рис. 1. Схема ИНС с обратным распространением ошибки

Для научного исследования и получения простой математической модели процесса резания была взята работа «Способ определения параметра шероховатости Ra на фрезерных станках с ЧПУ при получистовой и чистовой обработке углеродистых, конструкционных и низколегированных сталей сборным многолезвийным твердосплавным инструментом при торцевом фрезеровании» авторов Плотникова А.Л., Сергеева А.С. и Зайцевой Н.Г. [12].

Для прогнозирования шероховатости при чистовом фрезеровании использованы приведенные в патенте экспериментальные данные, которые были сведены в массив (рис. 2). Авторы патента предлагают формулу расчета шероховатости, используя в качестве одного из входных параметров термо ЭДС:

$$Ra = C_{Ra} \cdot \left[\frac{z \cdot \arccos \left(1 - 2 \cdot \left(\frac{B}{D} \right)^2 \right)}{360} + 1 \right]^{K_1} \cdot \frac{E^{K_2} \cdot t^{K_3} \cdot S^{K_4}}{V^{K_5}} \quad (1)$$

где C_{Ra} – коэффициент, учитывающий вид обработки; V – скорость резания, м/мин; z – количество режущих кромок сборного многолезвийного твердосплавного инструмента; S – подача на зуб сборного многолезвийного твердосплавного инструмента, мм/зуб; t – глубина резания, мм; K_1 – K_5 – показатели степени для определения шероховатости поверхности; E – среднеарифметическое значение термоЭДС, мВ; B – ширина фрезерования, мм; D – диаметр сборного многолезвийного твердосплавного инструмента, мм [12].

В научной работе авторов Плотникова А.Л., Сергеева А.С. и Зайцевой Н.Г. для более точного определения параметра шероховатости Ra при чистовом и получистовом фрезеровании предложено использовать в качестве одного из параметров расчета сигнал термоЭДС E , учитывающий физико-механические свойства контактируемых при обработке пар (тела заготовки и режущей кромки инструмента), полученный в аналогичных условиях пробного прохода по различным сочетаниям контактных пар, среди группы низколегированных, углеродистых и конструкционных сталей при обработке их твердосплавным

инструментом. Учитывать материал заготовки и режущего инструмента при определении параметра шероховатости Ra позволяет применение в качестве одного из входных параметров термоЭДС, что в свою очередь значительно позволяет повысить точность выходных значений.

Основная часть. Для создания и обучения нейронной сети производятся следующие шаги:

- выбор входных и выходных данных
- настройка числа нейронов скрытого слоя
- выбор алгоритма тренировки нейронной сети.

В качестве входных параметров для определения шероховатости поверхности Ra при чистовом фрезеровании были взяты глубина резания t , мм, скорость резания V , м/мин, количество зубьев фрезы n , шт, подача S , мм/зуб, а также термоЭДС, мВ. В качестве выходного параметра получаем шероховатость обработанной поверхности Ra , мкм.

Фрагмент выборки представлен в табл. 1. Полная выборка содержит 108 строк. В табл. 2 представлены диапазоны входных и выходных данных.

Таблица 1

Выборка входных и выходных данных для обучения нейронной сети

Скорость V , м/мин	Подача S , мм/зуб	Глубина t , мм	Режущих кромок n , шт	ТермоЭДС E , мВ	Шероховатость Ra , мкм
159	0,05	1	2	9,3	1,12
159	0,05	1,5	2	9,3	1,37
232	0,05	0,5	2	9,3	0,54
232	0,05	1	2	9,3	0,81
232	0,05	1,5	2	9,3	0,88
159	0,08	0,5	8	13,3	4,55
159	0,08	1	8	13,3	4,89
159	0,08	1,5	8	13,3	5,18

Таблица 2

Диапазоны входных и выходных данных для чистового фрезерования

Скорость V , м/мин	Подача S , мм/зуб	Глубина t , мм	Режущих кромок n , шт	ТермоЭДС E , мВ	Шероховатость Ra , мкм
159–232	0,05–0,08	0,5–1,5	2–8	9,3–17,3	0,8–7,21

В качестве материалов заготовки используются углеродистая, конструкционная и низколегированная стали. Для решения нашей задачи было взято тридцать нейронов скрытого слоя, что вполне достаточно. Для тренировки нейронной сети была выбрана Байесовская регуляризация из соображений, что в этом алгоритме нейронная

сеть проходит полное число итераций, в отличие от алгоритма Левенберга-Марквардта, позволяет получить более точную модель. Использование других алгоритмов дает более искаженные результаты. На рис. 2 приведена схема применяемой сети.

В результате обучения нейронной сети были рассмотрены следующие данные: для обучающих, тестовых и проверочных выборок были получены коэффициент корреляции (R) и среднеквадратическое отклонение (MSE) между целевыми значениями и выходами сети. На основе полученных значений, удалось построить графики, характеризующие качество обучения.

На рис. 3, а представлены графики обучения сети (на тренировочных и тестовых выборках). Данные графики отражают зависимость величины среднеквадратического отклонения от числа эпох (количества раз, когда полученный алгоритм видит полный набор данных). Здесь мы видим, что за 823 эпохи величина среднеквадратической ошибки достигл 0,003673. Процесс обучения был закончен, когда ошибка на проверочных данных перестала уменьшаться на 400-й эпохе.

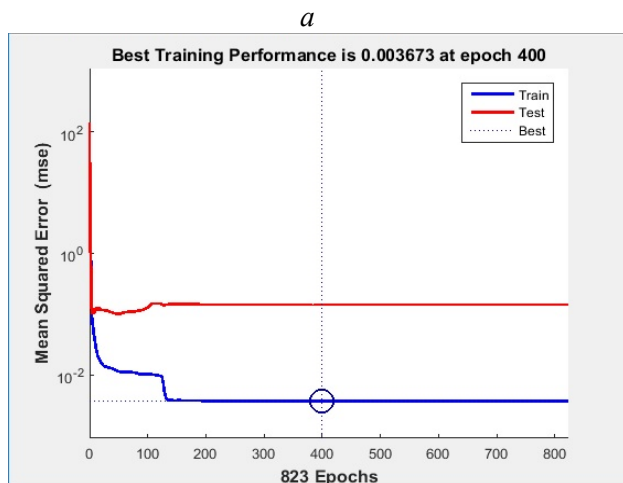


Рис. 3. Процесс тренировки ИНС для чистового фрезерования:
а – графики обучения сети; б – графики состояния обучения

Далее мы видим изменение градиента ошибки обучения по весам сети Gradient и среднеквадратичное отклонение ssX.

Гистограмма ошибок представлена на рис. 4, а. Она показывает зависимость погрешности от числа примеров. Разность между целевыми (target) и выходными (output) значениями сети и есть величина погрешности. Погрешности для обучающего (Training) и тестового (Test) множеств отображены на графике. Из графика следует, что большая часть ошибок лежит в диапазоне от -0,1184 до 0,1264.

На рис. 4, б показаны графики регрессии. На графиках линейная регрессия для обучающего (Training), тестового (Test) и всех вместе множеств. Для каждого результата был рассчитан коэффициент корреляции (R), построен график и выведено уравнение регрессии в виде:

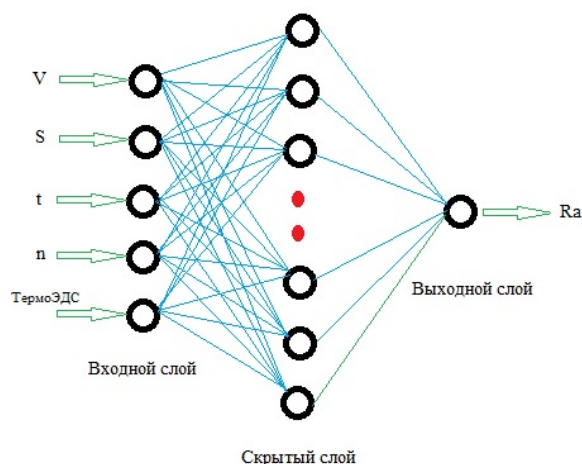
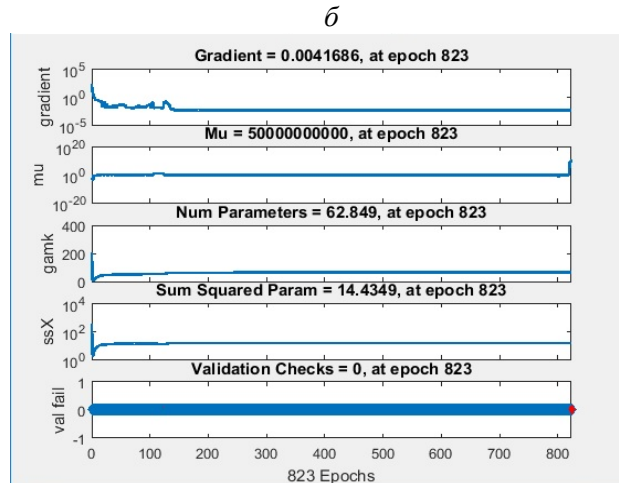


Рис. 2. Архитектура ИНС

Графики состояния обучения представлены на рис. 3, б. Изменение ошибки на контрольном множестве (Val fail) равно нулю. Изменение параметра обучения μ метода Байесовской регуляризации (в альтернативных методах отражаются другие параметры) показано на графике μ .



$$Output = a \times Target + b \quad (2)$$

где *Output* – выходные значения функции; *Target* – целевые значения функции; *a* и *b* – коэффициенты линейной функции активации.

При полном совпадении выходных значений (*Output*) с целевыми (*Target*) $R=1$, $a=1$, $b=0$ – это идеальный вариант, в нашем же случае имеются небольшие отклонения коэффициента *b*.

Для проверки работоспособности сети были использованы данные контрольной выборки (табл. 3).

На выходе нейронная сеть выдала значение шероховатости $Ra = 0,8886$, при целевом $Ra = 0,82$.

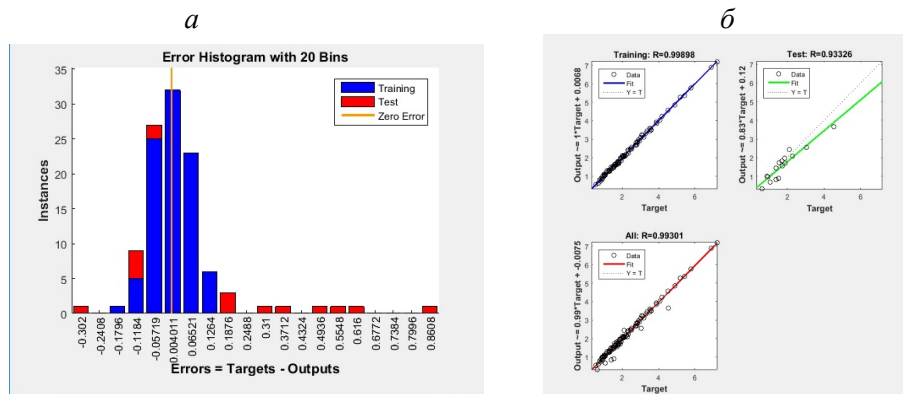


Рис. 4. Результаты тренировки ИНС для чистового фрезерования:
 а – гистограмма ошибок обучения сети; б – графики регрессии

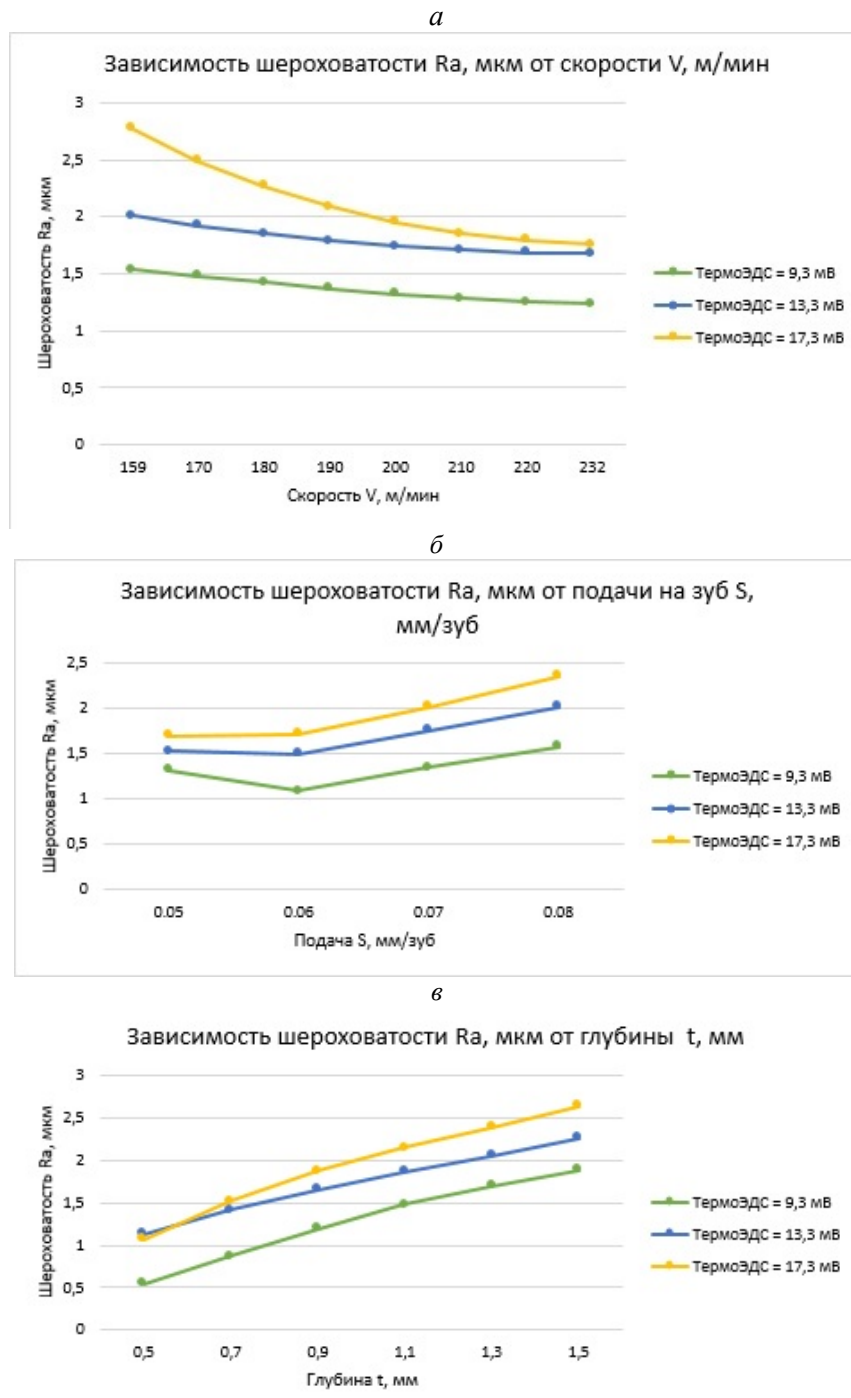


Рис. 5. Графики зависимости шероховатости R_a , мкм при различных термоЭДС E , мВ от:
 а – скорости V , м/мин; б – подачи S , мм/зуб; в – глубины фрезерования t , мм

Таблица 3

Контрольная выборка для проверки работоспособности нейронной сети

Скорость V, м/мин	Подача S, мм/зуб	Глубина t, мм	Режущих кромок n, шт	ТермоЭДС E, мВ
232	0.08	0.5	2	13.3

Выводы. ИНС принятой архитектуры показала хороший результат. Сеть имеет пять нейронов входного слоя и тридцать нейронов скрытого, обучена по алгоритму Байесовской регуляризации. Относительная погрешность составила 8,32 %. Подобные расхождения связаны с недостаточным количеством входных данных, а также погрешностями при их измерении в ходе эксперимента. Повысить точность данной сети возможно, применив более крупную выборку. Входные данные для обучения ИНС позволили построить графики зависимости величины шероховатости Ra, мкм, от термоЭДС E, мВ при определенных значениях остальных параметров (рис. 5). Можно сделать вывод, что величина шероховатости существенно зависит от величины термоЭДС.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Дуюн Т.А., Гринек А.В. Математическое моделирование процессов механической обработки как средство управления технологическими параметрами на основе нейросетевых и нечетких моделей // Труды международной конференции «Современные направления и перспективы развития технологий обработки и оборудования в машиностроении», Севастополь – 2016, №3 (3). С. 28–33.
2. Кабалдин Ю.Г., Лаптев И.Л., Шатагин С.В., Серый С.В. Диагностика выходных параметров процесса резания в режиме реального времени на основе фрактального и вейвлетанализа с использованием программно-аппаратных средств National Instruments и Nvidia CUDA // Вестник машиностроения. 2014. № 8. С. 80–82.
3. Алтунин К.А., Соколов М.В. Применение нейронных сетей для моделирования процесса токарной обработки // Вестник ТГТУ. 2016. Том 22. №1. С. 122–133.
4. Хоанг В.Ч., Сальников В.С. Моделирование температуры резания в условиях неопределенности с применением искусственной нейронной сети // В сб. Известия ТулГУ. Технические науки. 2014. Вып. 11. Ч. 2. С. 386–395.
5. Briceno J.F., El-Mounayri H., Mukhopadhyay S. Selecting an artificial neural network for efficient modeling and accurate simulation of the milling process // International Journal of Machine Tools and Manufacture. 2002. Vol. 42, №6. Pp. 663–674.
6. Yang H., Ni J. Dynamic neural network modeling for nonlinear, nonstationary machine tool thermally induced error // International Journal of Machine Tools and Manufacture. 2005. Vol. 45 № 4–5. Pp. 455–465.
7. Kim H.Y., Ahn J.H. Chip disposal state monitoring in drilling using neural network based spindle motor power sensing // International Journal of Machine Tools and Manufacture. 2002. Vol. 42 № 10. Pp. 1113–1119.
8. Kwak J.S., Ha M.K. Neural network approach for diagnosis of grinding operation by acoustic emission and power signals // Journal of Materials Processing Technology. 2004. Vol. 147, № 1. Pp. 65–71.
9. Bernandos P.G., Mosialos S., Vosniakos G.C. Prediction of work piece elastic deflections under cutting forces in turning // Robotics and Computer-Integrated Manufacturing. 2006. Vol. 22, № 5–6. Pp. 505–514.
10. Cus F., Zuperl U. Approach to optimization of cutting conditions by using artificial neural networks // Journal of Materials Processing Technology. 2006. Vol. 173, № 3. Pp. 281–290.
11. Бураков М.В. Нейронные сети и нейроконтролеры: учеб. Пособие. СПб.: ГУАП, 2013. 284 с.
12. Пат. 2509633, Российская Федерация, МПК В23С3/00. Способ определения параметра шероховатости Ra на фрезерных станках с ЧПУ при получистовой и чистовой обработке углеродистых, конструкционных и низколегированных сталей сборным многолезвийным твердосплавным инструментом при торцевом фрезеровании / А.Л. Плотников, А.С. Сергеев, Н.Г. Зайцева; заявитель и правообладатель Федеральное государственное бюджетное образовательное учреждение высшего профессионального образования "Волгоградский государственный технический университет" (ВолГТУ), №2012129424; заявл. 11.07.2012; опубл. 20.03.2014.

Информация об авторах

Ерыгин Евгений Вячеславович, аспирант кафедры технология машиностроения. E-mail: erygin.evgeny@gmail.com. Белгородский государственный технологический университет им. В.Г. Шухова. Россия, 308012, Белгород, ул. Костюкова, д. 46.

Дуюн Татьяна Александровна, доктор технических наук, профессор кафедры технология машиностроения. E-mail: tanduun@mail.ru. Белгородский государственный технологический университет им. В.Г. Шухова. Россия, 308012, Белгород, ул. Костюкова, д. 46.

Поступила в июне 2019 г.

© Ерыгин Е.В., Дуюн Т.А., 2019

**Erygin E.V., Dujun T.A.*

Belgorod State Technological University named after V.G. Shukhova

Russia, 308012, Belgorod, st. Kostyukova, 46

**E-mail: erygin.evgeny@gmail.com*

FORECASTING OF THE SURFACE ROUGHNESS IN FINISHING MILLING USING NEURAL NETWORKS

Abstract. *This article describes the task of predicting roughness when finishing milling using neural network modeling. As a basis for the creation and training of an artificial neural network, a progressive formula for determining the roughness during finishing milling is chosen. The thermoEMF of the processing and processed materials is used as one of the parameters for calculating the roughness. The use of thermoEMF allows to take into account the material of the workpiece and the cutting tool, which affects the accuracy of the results. A training sample is created with data for five inputs and one output. The architecture, features and network learning algorithm are described. A neural network that determines the roughness for finishing milling has been created and configured. The process of learning and debugging of the neural network by means of graphs is clearly displayed. The network operability is checked on the test data, which allows obtaining positive results.*

Keywords: *artificial neural networks (INS), roughness, finishing milling, thermoEMF, Bayesian regularization.*

REFERENCES

1. Dujun T.A., Grinek A.V. Mathematical modeling of machining as control system instrument of technological parameters based on the fuzzy logic and neural networks [Matematicheskoe modelirovanie processov mekhanicheskoy obrabotki kak sredstvo upravleniya tekhnologicheskimi parametrami na osnove nejrosetevykh i nechetkiykh modelej]. Trudi mezhdunarodnoy konferencii «Sovremennye napravleniya i perspektivi razvitiya tekhnologii obrabotki i oborudovaniya v mashinostroenii», Sevastopol. 2016, No. 3. Pp. 28–33. (rus)
2. Kabaldin U.G., Laptev I.L., Shatahin S.V., Seriy S.V. Diagnostics of the output parameters of the cutting process in real time based on fractal and wavelet analyzes using software and hardware National Instruments and Nvidia CUDA [Diagnostika vyhodnykh parametrov processa rezaniya v rezhime real'nogo vremeni na osnove fraktal'nogo i vevvletanalizaov s ispol'zovaniem programmno-apparatnykh sredstv National Instruments i Nvidia CUDA]. Bulletin of engineering. 2014. No. 8. Pp. 80–82. (rus)
3. Altunin K.A., Sokolov M.V. Application of Neural Networks to Modeling of the Turning Process [Primenenie nejronnykh setey dlya modelirovaniya processa tokarnoy obrabotki]. Transactions of the TSTU. 2016. No. 1. Pp. 122–133. (rus)
4. Hoang V.C., Salnikov V.S. Modelling of temperature of cutting in the conditions of uncertainty with application of the artificial neural network [Modelirovanie temperatury rezaniya v usloviyah neopredelennosti s primeneniem iskusstvennoy nejronnoy seti]. V sb. Izvestia TulGU. Tekhnicheskie nauki. 2014. No. 11. P. 2. Pp. 386–395. (rus)
5. Briceno J.F., El-Mounayri H., Mukhopadhyay S. Selecting an artificial neural network for efficient modeling and accurate simulation of the milling process. International Journal of Machine Tools and Manufacture. 2002. Vol. 42, No. 6. Pp. 663–674.
6. Yang H., Ni J. Dynamic neural network modeling for nonlinear, nonstationary machine tool thermally induced error. International Journal of Machine Tools and Manufacture. 2005. Vol. 45. No 4–5. Pp. 455–465.
7. Kim H.Y., Ahn J.H. Chip disposal state monitoring in drilling using neural network based spindle motor power sensing. International Journal of Machine Tools and Manufacture. 2002. Vol. 42. No.10. Pp. 1113–1119.
8. Kwak J.S., Ha M.K. Neural network approach for diagnosis of grinding operation by acoustic emission and power signals. Journal of Materials Processing Technology. 2004. Vol. 147. No. 1. Pp. 65–71.
9. Bernandos P.G., Mosialos S., Vosniakos G.C. Prediction of work piece elastic deflections un-

der cutting forces in turning. Robotics and Computer-Integrated Manufacturing. 2006. Vol. 22. No. 5–6. Pp. 505–514.

10. Cus F., Zuperl U. Approach to optimization of cutting conditions by using artificial neural networks. Journal of Materials Processing Technology. 2006. Vol. 173. No. 3. Pp. 281–290.

11. Burakov M.V. Neural networks and neuro-controllers [Нейронные сети и нейроконтроль]: учеб. Posobie. SPb.: GUAP, 2013, 284 p. (rus)

12. Plotnikov A.L., Sergeev A.S., Zaitsev N.G. The method of determining the roughness parameter Ra on milling machines with CNC in the semi-finishing and finishing of carbon, structural and low-alloy steels with multi-blade assembled carbide tools for face milling. Patent RF, no. 2509633, 2014.

Information about the authors

Dujun, Tatiana A. DSc, Professor. E-mail: tanduun@mail.ru. Belgorod State Technological University named after V.G. Shukhov. Russia, 308012, Belgorod, st. Kostyukova, 46.

Erygin, Evgeny V. Postgraduate student. E-mail: erygin.evgeny@gmail.com. Belgorod State Technological University named after V.G. Shukhov. Russia, 308012, Belgorod, st. Kostyukova, 46.

Received in June 2019

Для цитирования:

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

For citation:

Erygin E.V., Dujun T.A. Forecasting of the surface roughness in finishing milling using neural networks. Bulletin of BSTU named after V.G. Shukhov. 2019. No. 10. Pp. 135–141. DOI: 10.34031/article_5db3f6c82c1ea9.69942788