

DOI: 10.34031/article_5d35d0b62dc823.22670125

^{1,*}Баранов Д.С., ¹Дуюн Т.А.¹Белгородский государственный технологический университет им. В.Г. Шухова
Россия, 308012, Белгород, ул. Костюкова, д. 46.

*E-mail: den-3218@yandex.ru

ПРИМЕНЕНИЕ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ ДЛЯ ПРОГНОЗИРОВАНИЯ ШЕРОХОВАТОСТИ ПРИ ЧИСТОВОМ И ПОЛУЧИСТОВОМ ТОЧЕНИИ

Аннотация. Представлена методика разработки искусственных нейронных сетей для прогнозирования шероховатости обрабатываемой поверхности при чистовом и получистовом точении. Принята архитектура сети с обратным распространением ошибки, имеющая входной, скрытый и выходной слои, сигмоидальную функцию активации для скрытого слоя и линейную – для выходного. Для формирования обучающей выборки использованы эмпирические выражения в виде степенных функций, обучение сетей проводилось по алгоритму Левенберга-Марквардта, имеющего быструю сходимость. В качестве входных переменных для нейросетевых моделей использованы технологические режимы (скорость и глубина резания, подача инструмента), геометрические параметры режущего инструмента (главный и вспомогательный углы в плане резца, радиус при вершине резца, передний угол), физико-механические свойства обрабатываемого материала, каждая обучающая выборка сформирована из тысячи комбинаций исходных данных. Разработаны отдельные сети, прогнозирующие шероховатость при чистовом и получистовом точении, а также комбинированная сеть, учитывающая оба вида обработки. Анализ точности работы сетей показал хорошие результаты, относительная погрешность вычислений не превышает 1 %. Предложенные нейросетевые модели могут быть использованы при технологической подготовке производства, а также в системах адаптивного управления процессом резания.

Ключевые слова: искусственные нейронные сети (ИНС), шероховатость поверхности, чистовое и получистовое точение.

Введение. Современное машиностроение в большей степени базируется на применении многокоординатных станков, обрабатывающих центров и другого высокотехнологического оборудования с числовым программным управлением. Одним из перспективных направлений повышения эффективности работы такого оборудования является адаптивное управление процессом механической обработки с целью достижения заданных значений качественных характеристик обрабатываемой поверхности на основе мониторинга параметров резания в реальном времени. Для решения такого класса задач возникает необходимость не только использования высокоточных датчиков контроля, но и обработка больших массивов информации для формирования цепей обратных связей и реализации управляющих воздействий. В этих случаях традиционные способы назначения режимов резания и прогнозирования качественных характеристик обработанной поверхности не могут быть использованы, так как управляющее воздействие должно формироваться с высоким быстродействием на основе реальных условий процесса. Применение искусственных нейронных сетей (ИНС) может стать приемлемым вариантом для решения таких задач, так как обусловлено способностью нейронных сетей к обучению на основе создания связей между входными и выходными данными. При

должной настройке сети такой подход дает возможность решать трудоемкие задачи с высоким быстродействием без использования сложного математического аппарата.

Разработка и использование ИНС для повышения эффективности процессов механической обработки приобретает все большую популярность среди отечественных и зарубежных ученых [1–10]. Проведем краткий обзор имеющихся разработок в данной области.

В своей работе [2] Шатагин Д.А. предложил автоматизированную систему на основе подходов искусственного интеллекта, позволяющую управлять динамической устойчивостью процесса резания в зависимости от условий обработки с использованием высокопроизводительных вычислений nVidia CUDA и облачных технологий. Показал возможность повышения эффективности механической обработки, за счет определения оптимальных условий резания на основе нейросетевого моделирования. Алтунин К.А. и Соколов М.В. [3] исследовали возможность прогнозирования шероховатости и износа инструмента при различных видах обработки с помощью ИНС, провели сравнительный анализ моделей ИНС и регресса. Модели ИНС обеспечивают лучшие возможности прогнозирования, что связано с возможностью ИНС моделировать более сложную нелинейность и взаимодействия,

чем линейные и показательные модели регресса. Хоанг В.Ч. в своей работе [4] предложил усовершенствованную ИНС вида многослойного персептрона для моделирования температуры резания, описал алгоритм ее обучения с оптимизацией весов скрытого и выходного слоев, сократив время обучения и величину ошибки.

J.F. Briceno, H. El-Mounayri, S. Mukhopadhyay [5] доказали преимущество применения радиально-базисной нейронной сети (RBF) при исследовании силовых характеристик фрезерования, используя в качестве входных данных подачу, частоту вращения шпинделя и глубину резания, получая на выходе – максимальное, среднее и минимальное значение силы резания. Yang H., Ni J. установили зависимость между режимами резания и параметрами процесса резания при высокоскоростной обработке [6]. На вход сети подаются значения скорости резания, машинного времени, величины подачи и давления СОЖ, на выходе формируются тангенциальная и осевая силы, шероховатость обработанной поверхности, фактическая потребляемая мощность электродвигателя станка, средний и максимальный износ по задней поверхности, износ по вершине режущей кромки. H-Y Kim и J-H Ahn решали задачу диагностики процессов механической обработки, а именно мониторинг процесса стружкоудаления при сверлении, оперируя данными фактической потребляемой мощности электродвигателя станка [7]. Kwak J.S., Ha M.K. применили нейросетевой подход для диагностики процесса шлифования и выявления температурных перенапряжений, зависящих от фактической потребляемой мощности электродвигателя и сигналов акустической эмиссии [8]. Bernandos P.G., Mosialos S., Vosniakos G.C. занимались вопросом прогнозирования величины

упругих отжиганий заготовки при точении [9]. Cus F., Zuperl U. использовали ИНС для оптимизации режимов резания при различных видах обработки [10].

Целью настоящей работы являлась разработка методики проектирования ИНС для возможности прогнозирования шероховатости обрабатываемой поверхности при различных видах точения.

Основная часть. В качестве основных математических выражений для определения шероховатости при чистовом и получистовом точении использованы известные эмпирические формулы степенного вида:

$$Ra = 0,85 \frac{t^{0,31} s^{0,58} \phi^{0,4} \phi_1^{0,4}}{v^{0,06} r^{0,65} HB^{0,05}}, \quad (1)$$

$$Ra = k_0 \frac{s^{k_1} (90^\circ + \gamma)^{k_2}}{r^{k_3} v^{k_4}}, \quad (2)$$

где v – скорость резания, м/мин, s – продольная подача, мм/об, t – глубина резания, мм, r – радиус при вершине резца, мм, ϕ , ϕ_1 и γ – величины главного, вспомогательного углов в плане и переднего угла, град, HB – твердость, k_0 , k_1 , k_2 , k_3 , k_4 – показатели степени для определения шероховатости поверхности.

В решении задач аппроксимации хорошо себя зарекомендовали ИНС с обратным распространением ошибки [11], поэтому была принята архитектура сети, представленная на рис. 1. Сеть состоит из входного, скрытого и выходного слоев, имеет сигмоидальную функцию активации для скрытого слоя и линейную – для выходного.




Рис. 1. Схема ИНС с обратным распространением ошибки

В соответствии с принятой архитектурой были разработаны следующие ИНС прогнозирования шероховатости обрабатываемой поверхности: для чистового точения согласно выражению (1), для получистового точения согласно выражению (2), а также комбинированная сеть, учитывающая условия как чистового, так и получистового точения. Архитектура сетей представлена на рис. 2, 3.

Нейронная сеть для условий чистового точения имеет семь нейронов на входном слое, один

скрытый слой с двадцатью восьмью нейронами и один нейрон в выходном слое. Для получистового точения ИНС имеет пять нейронов на входном слое, один скрытый слой с двадцатью тремя нейронами и один нейрон в выходном слое. Количество входных нейронов сетей соответствует количеству исходных данных используемых выражений, количество нейронов скрытого слоя выбрано итерационным приближением для обеспечения требуемой точности работы сети.

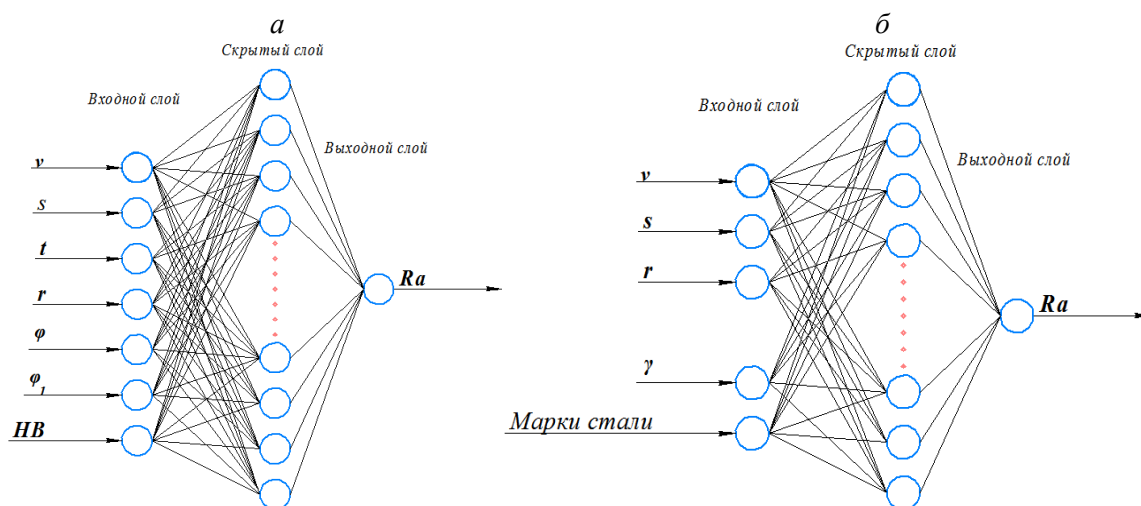


Рис. 2. Архитектура ИНС: а – чистовое точение, б – получистовое точение

Особенностью комбинированной сети, представленной на рис.3, является объединение исходных данных обоих математических выражений при формировании количества нейронов на входном слое. Принято 10 нейронов входного слоя с учетом одного нейрона, определяющего вид обработки, при этом оказалось достаточным 40 нейронов скрытого слоя для требуемой точности сети.

Таблица 1

Диапазоны значений входных данных для чистового и получистового точения

Параметр	Чистовое точение	Получистовое точение
v , м/мин	50÷150	71÷282
s , мм/об	0,08÷0,18	0,05÷0,43
r , мм	0,5÷2	0,5÷2
t , мм	0,5÷1,5	-
φ , градусы	45÷75	-
φ_1 , градусы	25÷35	-
HB	140÷210	-
γ , градусы	-	-40÷4
Марки стали	Среднеуглеродистые стали	Ст3, 20, 45, 70




Рис. 3. Архитектура комбинированной сети

Для обучения ИНС применимы следующие методы: алгоритм Левенберга-Марквардта, Байесовская регуляция или метод масштабируемых сопряженных градиентов [11]. Для решения поставленной задачи использован алгоритм Левенберга-Марквардта ввиду быстрой его сходимости. Подготовка обучающей выборки заключалась в создании массивов входных и выходных данных в пределах интервалов варьирования переменных, соответствующих адекватности используемых выражений (табл. 1).

Массив входных данных для чистового и получистового точения формировался из случайных значений переменных в заданном диапазоне, табл. 1. Третья выборка, представляет собой комбинацию «чистовой» и «получистовой», для ее создания добавлен входной нейрон, характеризующий метод обработки. В зависимости от метода обработки входные и выходные данные формируются согласно заданным диапазонам, а при отсутствии определенного параметра в данном виде обработки, он приравнивается к нулю. Фрагмент комбинированной выборки представлен в табл. 2. Общее количество комбинаций исходных данных для каждой выборки было сгенерировано в количестве 1000 вариантов.

Таблица 2

Фрагмент комбинированной выборки

Метод	v	s	r	t	φ	φ_1	HB	марка	γ	Ra
2	183	0,33	1,4	0	0	0	172	45	-10	0,64839
2	103	0,32	1,1	0	0	0	146	20	2	8,98135
1	89	0,08	1	1,2	54	26	176	0	0	2,22569
2	258	0,05	2	0	0	0	168	3	-22	0,17769
1	131	0,11	0,5	0,8	70	30	175	0	0	4,25357
2	214	0,27	1,3	0	0	0	169	3	-26	0,67384
1	132	0,1	1,6	0,9	58	34	168	0	0	1,91434
2	216	0,31	1,4	0	0	0	166	70	3	4,36725
1	96	0,17	1,4	0,7	51	34	184	0	0	2,53232

Из результатов обучения сетей можно сделать вывод, что для достижения приемлемой среднеквадратической ошибки не более 10^{-2} для различных исходных структур потребовалось 341-999 циклов (эпох) обучения. В процессе обучения сетей варьировалось количество нейронов скрытого слоя в зависимости от получаемой среднеквадратической ошибки с целью ее снижения до заданного уровня. Таким образом, полу-

чены следующие значения среднеквадратической ошибки: для чистового точения – $2,34 \cdot 10^{-4}$ при 28 нейронах скрытого слоя, для получистового точения – $2,46 \cdot 10^{-4}$ при 23 нейронах скрытого слоя и для комбинированной сети – $2,92 \cdot 10^{-4}$ при 40 нейронах скрытого слоя. На рис. 4–6 представлено графическое отображение результатов обучения ИНС прогнозирования шероховатости обрабатываемой поверхности при различных видах обработки.

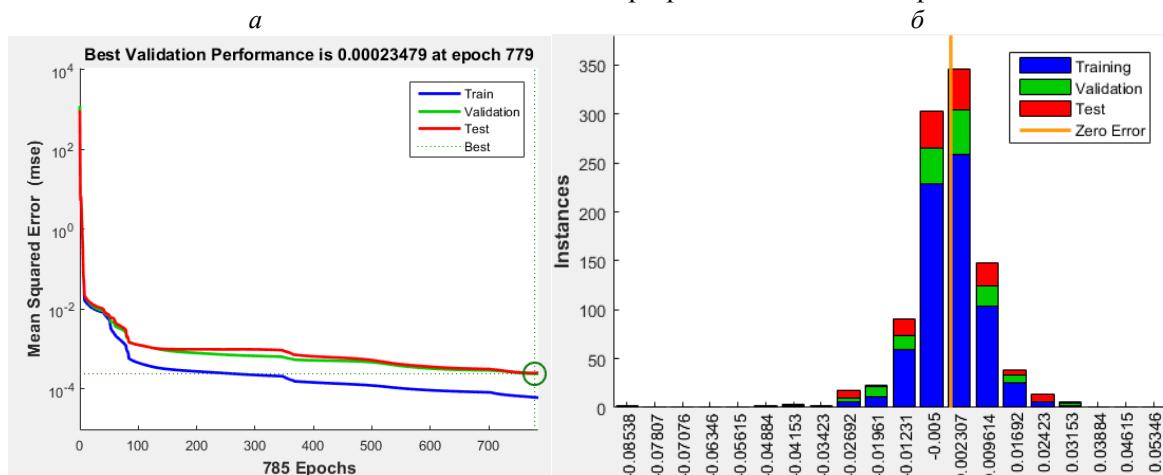


Рис. 4. Результаты работы ИНС для чистового точения: а – график обучения сети; б – гистограмма ошибки

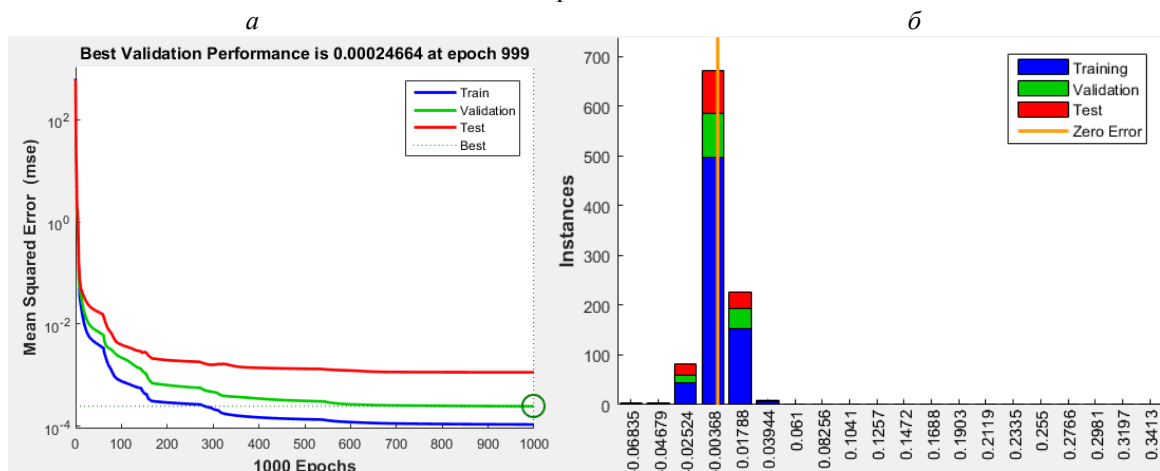


Рис. 5. Результаты работы ИНС для получистового точения: а – график обучения сети; б – гистограмма ошибки

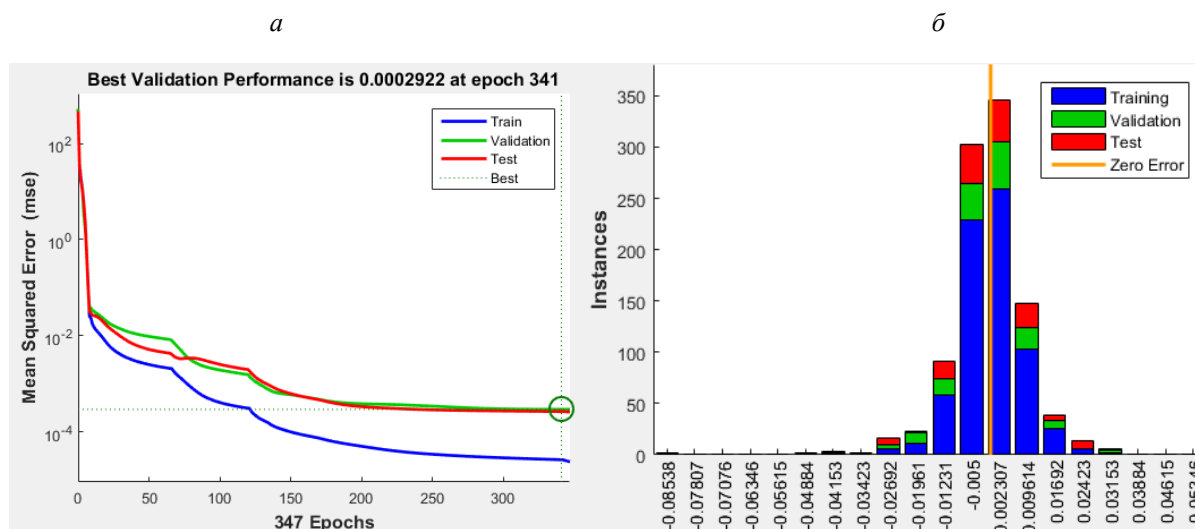


Рис. 6. Результаты работы ИНС для комбинированного точения: *a* – график обучения сети; *б* – гистограмма ошибки

Во всех случаях подавляющее число ошибок находится в непосредственной близости к нулевой линии, а величина ошибки не превышает 0,1 мкм, табл. 3.

Таблица 3

Разброс ошибки при работе ИНС

Сеть для чистового точения			Сеть для получистового точения			Комбинированная сеть для чистового и получистового точения		
Величина ошибки	Кол-во значений	%	Величина ошибки	Кол-во значений	%	Величина ошибки	Кол-во значений	%
$2,3 \cdot 10^{-3}$	346	34,6	$-3,6 \cdot 10^{-3}$	671	67,1	$1,0 \cdot 10^{-3}$	486	48,6
$-5 \cdot 10^{-3}$	303	30,3	$17,8 \cdot 10^{-3}$	226	22,6	$-6,6 \cdot 10^{-3}$	235	23,5
$9,6 \cdot 10^{-3}$	148	14,8	$-25,2 \cdot 10^{-3}$	82	8,2	$8,7 \cdot 10^{-3}$	157	15,7
$-12,3 \cdot 10^{-3}$	91	9,1	$39,4 \cdot 10^{-3}$	10	1,0	$-14,3 \cdot 10^{-3}$	35	3,5
$16,9 \cdot 10^{-3}$	39	3,9	$-46,7 \cdot 10^{-3}$	5	0,5	$16,4 \cdot 10^{-3}$	29	2,9
$-19,6 \cdot 10^{-3}$	23	2,3	$-68,3 \cdot 10^{-3}$	3	0,3	$-22,0 \cdot 10^{-3}$	15	1,5
$-26,9 \cdot 10^{-3}$	17	1,7				$24,0 \cdot 10^{-3}$	14	1,4
$24,2 \cdot 10^{-3}$	14	1,4				$31,7 \cdot 10^{-3}$	8	0,8
$31,5 \cdot 10^{-3}$	6	0,6				$-37,4 \cdot 10^{-3}$	7	0,7
$41,5 \cdot 10^{-3}$	3	0,3				$39,4 \cdot 10^{-3}$	4	0,4
остальные	10	1,0				остальные	10	1,0
Относительная погрешность, %								
0,76			0,94			0,62		

Выводы. Разработанные нейросетевые модели принятой архитектуры показали хороший результат обучения, относительная погрешность вычислений не превышает 1 %. Наиболее высокую точность показала комбинированная сеть прогнозирования шероховатости поверхности при двух видах обработки: чистовом и получистовом, относительная погрешность которой составила 0,62 %. Сеть имеет десять нейронов входного слоя и сорок нейронов скрытого, обучена по алгоритму Левенберга-Марквардта. Предложенные нейросетевые модели могут быть использованы при технологической подготовке производства, а также в системах адаптивного управления процессом резания.

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. P. 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. P. 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. P. 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. P. 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. P. 281–290.

11. Бураков М.В. Нейронные сети и нейроконтролеры: учеб. Пособие. СПб.: ГУАП, 2013. 284 с.

Информация об авторах

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.

Баранов Денис Сергеевич, аспирант кафедры технология машиностроения. E-mail: den-3218@yandex.ru. Белгородский государственный технологический университет им. В.Г. Шухова. Россия, 308012, Белгород, ул. Костюкова, д. 46.

Поступила в апреле 2019 г.

© Баранов Д.С., Дуюн Т.А., 2019

^{1,*}*Baranov D.S., ¹Dujun T.A.*

¹*Belgorod State Technological University named after V.G. Shukhova
Russia, 308012, Belgorod, st. Kostyukova, 46
E-mail: den-3218@yandex.ru*

APPLICATION OF ARTIFICIAL NEURAL NETWORKS FOR PREDICTING ROUGHNESS AT CLEANING AND GETTING POINT

Abstract. A technique for the development of artificial neural networks to predict the roughness of the treated surface during finishing and semi-finishing turning is presented. The back-propagation network architecture was adopted, having an input, hidden and output layers, a sigmoidal activation function for the hidden layer and a linear one for the output layer. To form a training sample, empirical expressions in the form of power functions were used, training of networks was carried out according to the Levenberg-Marquardt algorithm, which has fast convergence. Technological modes (cutting speed and depth of cut, tool feed), cutting tool geometrical parameters (main and auxiliary angles in terms of the tool, radius at the tip of the tool, rake angle), physicomechanical properties of the material being processed, each the training sample is formed from thousands of source data combinations. Separate networks have been developed that predict roughness during finishing and semi-turning turning, as well as a combined network that takes into account both types of processing. Analysis of the accuracy of the networks showed good results, the relative error of calculations does not exceed 1 %. The proposed neural network models can be used in technological preparation of production, as well as in systems of adaptive control of the cutting process.

Keywords: artificial neural networks (INS), surface roughness, fine and semi-turning.

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 nechetkih modelей*]. 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 veyvletanalizaov s ispol'zovaniem programmno-aparatnykh 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 usloviyakh 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 under 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 neurocontrollers [*Nejronnye seti i nejrokontrolery*]: ucheb. Posobie. SPb.: GUAP, 2013, 284 p. (rus)

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.

Baranov, Denis S. Postgraduate student. E-mail: den-3218@yandex.ru. Belgorod State Technological University named after V.G. Shukhov. Russia, 308012, Belgorod, st. Kostyukova, 46.

Received in April 2019

Для цитирования:

Баранов Д.С., Дуюн Т.А. Применение искусственных нейронных сетей для прогнозирования шероховатости при чистовом и получистовом точении // Вестник БГТУ им. В.Г. Шухова. 2019. № 7. С. 128–134. DOI: 10.34031/article_5d35d0b62dc823.22670125

For citation:

Baranov D.S., Dujun T.A. Application of artificial neural networks for predicting roughness at cleaning and getting point. Bulletin of BSTU named after V.G. Shukhov. 2019. No. 7. Pp. 128–134. DOI: 10.34031/article_5d35d0b62dc823.22670125