

# МАШИНОСТРОЕНИЕ И МАШИНОВЕДЕНИЕ

DOI: 10.34031/2071-7318-2020-5-11-113-124

\*Ерыгин Е.В., Дуюн Т.А.

Белгородский государственный технологический университет им. В.Г. Шухова

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

## РАЗРАБОТКА НЕЙРОННЫХ СЕТЕЙ ДЛЯ ПРОГНОЗИРОВАНИЯ ШЕРОХОВАТОСТИ ПРИ ФРЕЗЕРОВАНИИ РАЗЛИЧНЫХ МАТЕРИАЛОВ

**Аннотация.** В статье представлена методика разработки и результаты тестирования искусственных нейронных сетей для прогнозирования шероховатости при чистовом фрезеровании. В качестве базы исходных данных для создания и обучения нейронных сетей были использованы экспериментальные данные различных исследователей при обработке материалов с разными физико-механическими свойствами. В качестве основного идентификатора физико-механических свойств принято значение твердости материала. Кроме твердости материала входными параметрами сетей являются также режимы резания: подача инструмента, глубина и скорость резания. Используются данные получаемой шероховатости для нескольких групп материалов: цветных металлов, конструкционных и нержавеющей сталей, жаропрочных сплавов и инструментальной стали. Созданы девять узкоспециализированных нейронных сетей, прогнозирующих шероховатость при фрезеровании определенного материала, ряд комбинированных сетей путем объединения нескольких баз данных, включая широкоуниверсальную нейронную сеть для нескольких групп материалов. Выполнен сравнительный анализ результатов тестирования разработанных нейронных сетей по критерию относительной погрешности. Большинство представленных нейронных сетей имеют удовлетворительную погрешность, не превышающую 10 %. Отдельные нейронные сети имеют более высокую точность, показывающая погрешность в пределах 5 %.

**Ключевые слова:** искусственные нейронные сети (ИНС), объединенные ИНС, шероховатость, чистовое фрезерование.

**Введение.** Шероховатость поверхности является одним из важнейших показателей качества изделий, и в процессе разработки технологических процессов необходимо решать вопросы ее прогнозирования. В настоящее время большинство используемых расчетных моделей шероховатости поверхности при фрезеровании являются эмпирическими. Такие модели, как правило, имеют узкий диапазон применения с точки зрения обрабатываемых материалов и адекватны в заданном интервале изменения технологических режимов. Поэтому вопрос разработки универсальных моделей, применимых для различных материалов и технологических условий обработки является весьма актуальным. Использование нейронных сетей для решения этой задачи перспективно, так как позволяет получить высокую точность модели без проведения трудоемких экспериментов. Однако, это возможно только при наличии достаточно обширной базы исходных данных, связывающих режимы обработки различных материалов с получаемой шероховатостью обрабатываемой поверхности.

**Методология.** Для решения задачи авторами используется искусственная нейронная сеть (ИНС) с обратным распространением ошибки,

аналогичная сеть представлена в работе [1]. Основным результатом работы нейросетевой модели предусматривается возможность прогнозирования значений шероховатости поверхности для различных материалов и режимов обработки. Для идентификации свойств обрабатываемого материала принято использовать значение твердости НВ, так как именно этот параметр по традиционным представлениям оказывает существенное влияние на формирование шероховатости поверхности. В качестве исходных данных для обучения нейронной сети использованы экспериментальные результаты, полученные различными исследователями [2–10]. Для повышения универсальности и гибкости моделей в базу включены данные об обработке материалов различных групп твердости: цветные материалы и сплавы (НВ 80-90), конструкционные и нержавеющей стали (НВ 170230), жаропрочные сплавы (НВ 300) и инструментальная сталь (НВ 373). Условия обработки варьируются также в достаточно широком диапазоне: скорость резания 28-313 м/мин, глубина резания 0,08–2,34 мм, подача 0,002–4,8 мм/об. Подробная информация об используемых экспериментальных данных представлена в табл. 1. Все приведенные материалы

обрабатывались фрезами с твердосплавными пластинами.

**Основная часть.** Для проверки функциональности и сравнительной характеристики точности нейросетевых моделей в зависимости от состава исходных данных ее обучения был разработан ряд нейронных сетей, включающих различные комбинации материалов и технологических режимов. В качестве входных параметров были приняты: скорость резания  $V$  м/мин, подача

$S$  мм/об, глубина резания  $t$  мм, твердость обрабатываемого материала HB, на выходе получаем шероховатость Ra, мкм.

Первоначально были спроектированы отдельные нейронные сети, каждая из которых соответствует определенному материалу и режимам резания. На рис. 1 представлены гистограммы ошибок и графики регрессии этих нейронных сетей: № 1, № 2, № 3, № 4, № 5, № 6, № 7, № 8, № 9. В табл. 2 сведены результаты проверки точности работы сетей по итогам тестирования.

Таблица 1

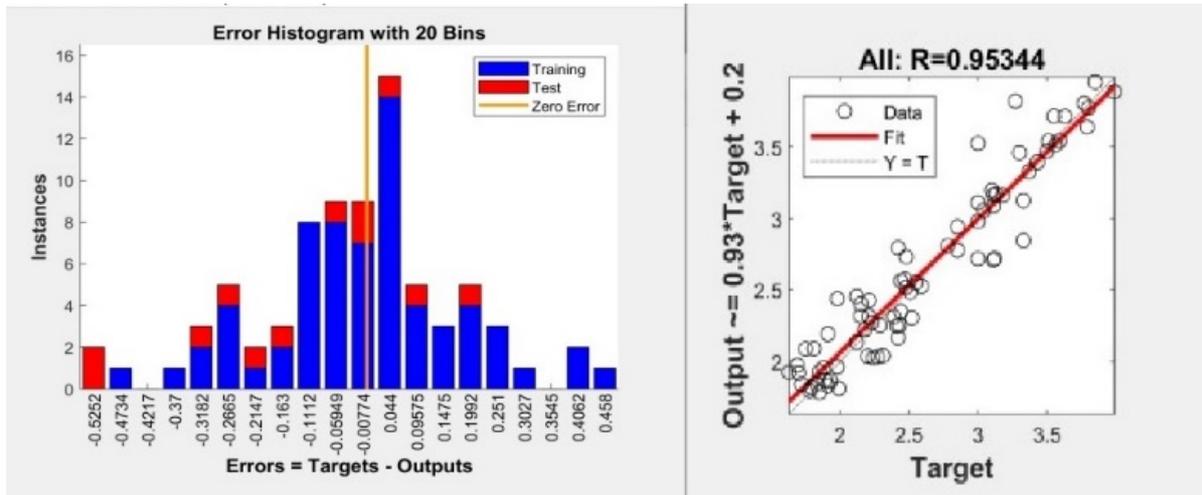
База данных для узкоспециализированных ИНС

№ ИНС	Обрабатываемый материал	Твердость	Диапазон скорости $V$ м/мин	Диапазон подачи $S$ мм/об	Диапазон глубины резания $t$ мм	Объем данных	Авторы экспериментальных данных
1	Алюминиевый сплав	80	28 - 47	0,002 – 0,047	0,6–1	27	S. Palani, Y. Kesavanarayana [2]
2	Нержавеющая сталь IDM 8365	210	150–313,2	0,096–0,234	0,5–2,34	24	Pavel Kovač, Borislav Savković, Marin Gostimirovic, Dušan Jesic, Ildiko Mankova [3]
3	Латунь	90	29,9–79,8	0,68–4,8	0,2–0,6	78	I. M. Soltan, M. E. H. Eltaib, R. M. El-Zahry [4]
4	Нержавеющая сталь 1Cr18Ni9Ti	210	70–150	0,2–0,6	0,08–0,16	30	Maohua Xiao, Xiaojie Shen, You Ma, Fei Yang, Nong Gao, Weihua Wei, and Dan Wu [5]
5	Низколегированная сталь	200	80–140	0,03–0,06	0,1–0,3	97	Jignesh G. Parmar, Prof. Alpesh Makwana [6]
6	Конструкционная сталь 9SMnPb28K	170	71–283	0,1 – 0,25	0,5–1	27	J. Paulo Davim [7]
7	Конструкционная сталь 50	230	138–243	0,1–0,238	0,54–0,8	18	Y. Sahin, A.R. Motorcu [8]
8	Жаропрочный сплав Inconel 718	300	47,5–185	0,083–0,167	0,1–0,5	20	Bapi Sarkar, Moola Mohan Reddy and Sujan Debnath [9].
9	Инструментальная штамповая сталь 4X5MФ1С	373	100–140	0,4–0,72	0,2–0,5	27	Fu Tao, Liu Weijun, Zhao Jibin [10]

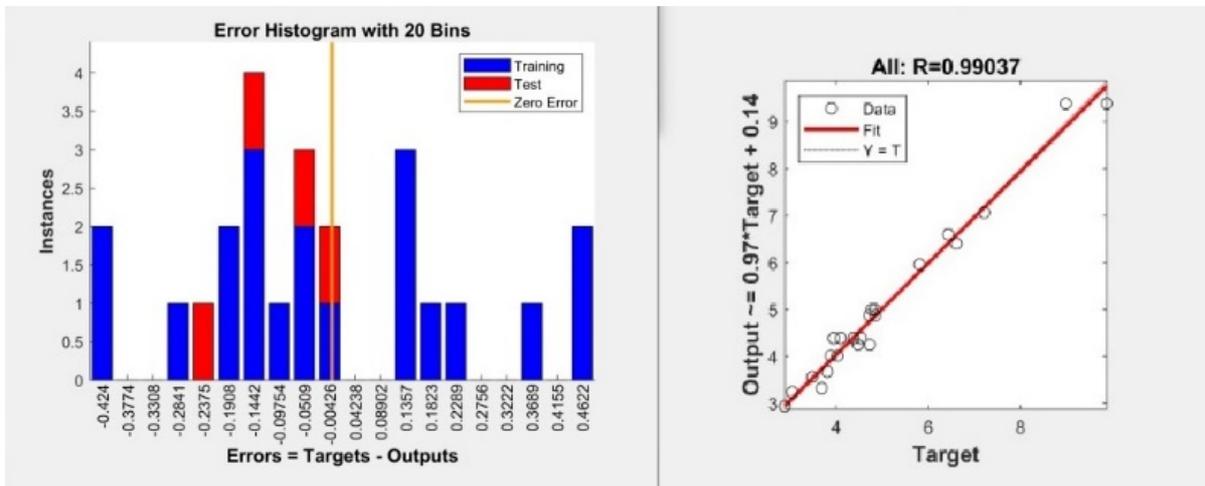
Таблица 2

Погрешность нейронных сетей № 1-9

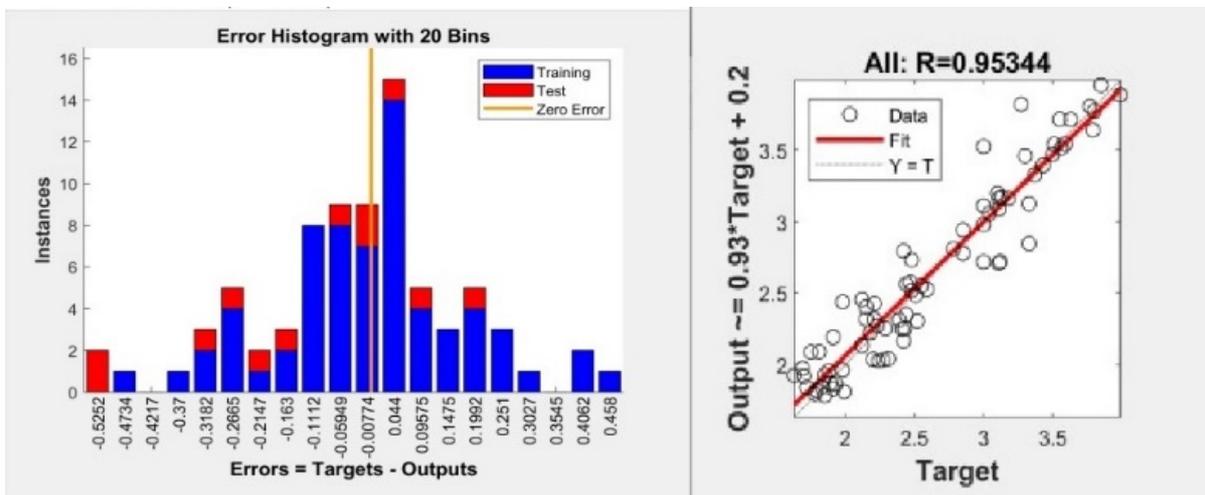
№ ИНС	1	2	3	4	5	6	7	8	9
Относительная погрешность, %	4,18	3,99	5,63	7,26	6,07	8,02	5,13	15,56	1,98



а

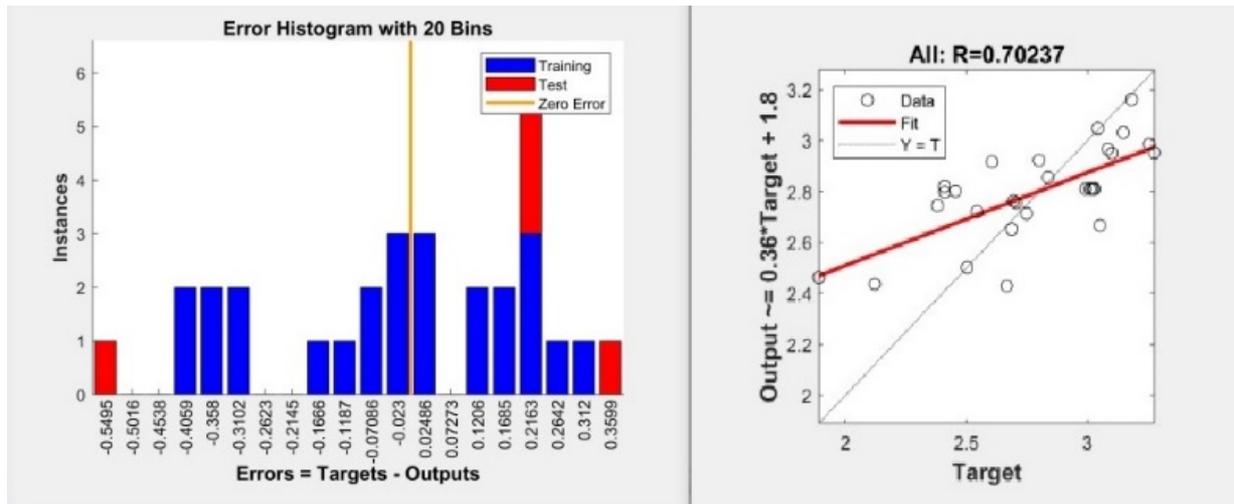


б

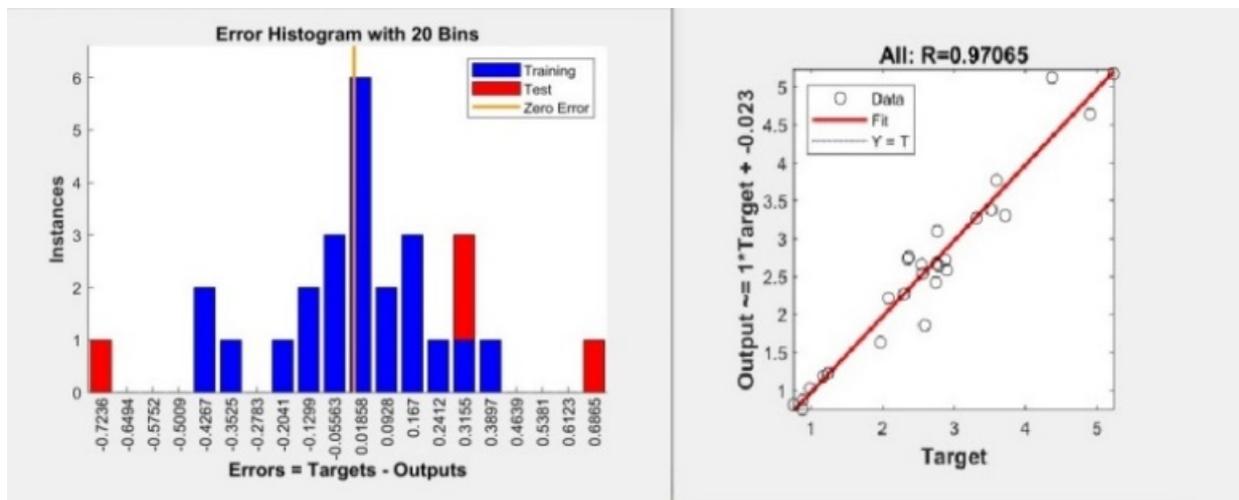


в

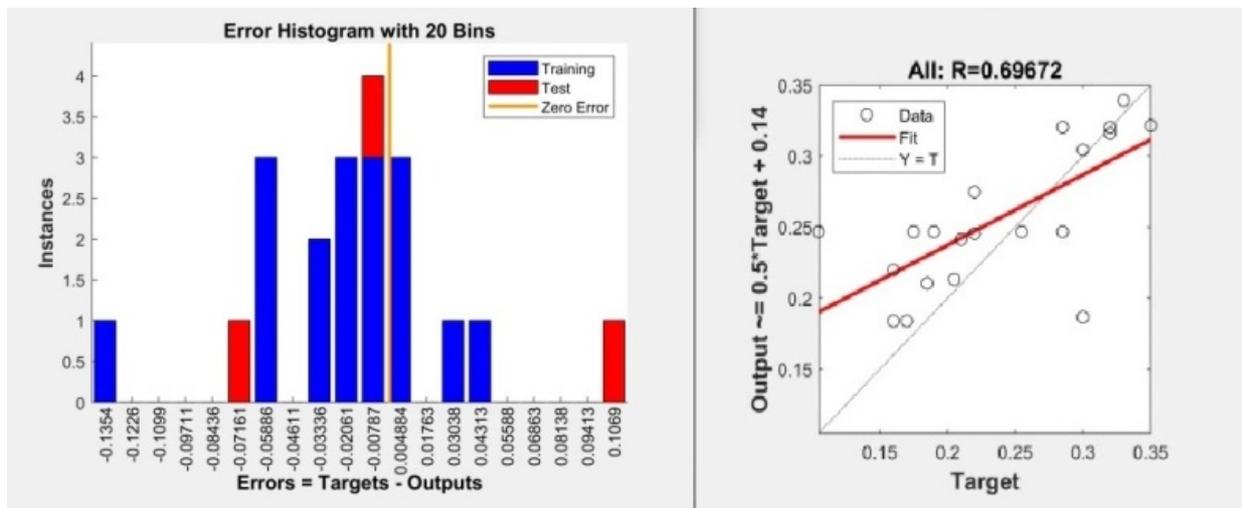
Рис. 1. Гистограмма ошибок и график регрессии (начало):  
а – ИНС № 1; б – ИНС № 2; в – ИНС № 3;



2

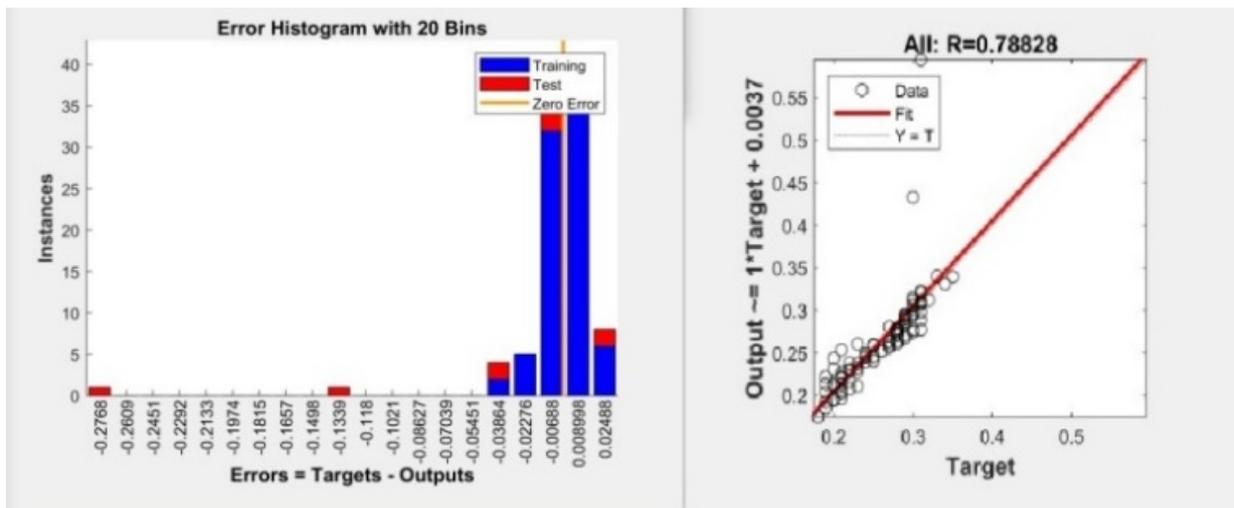


д

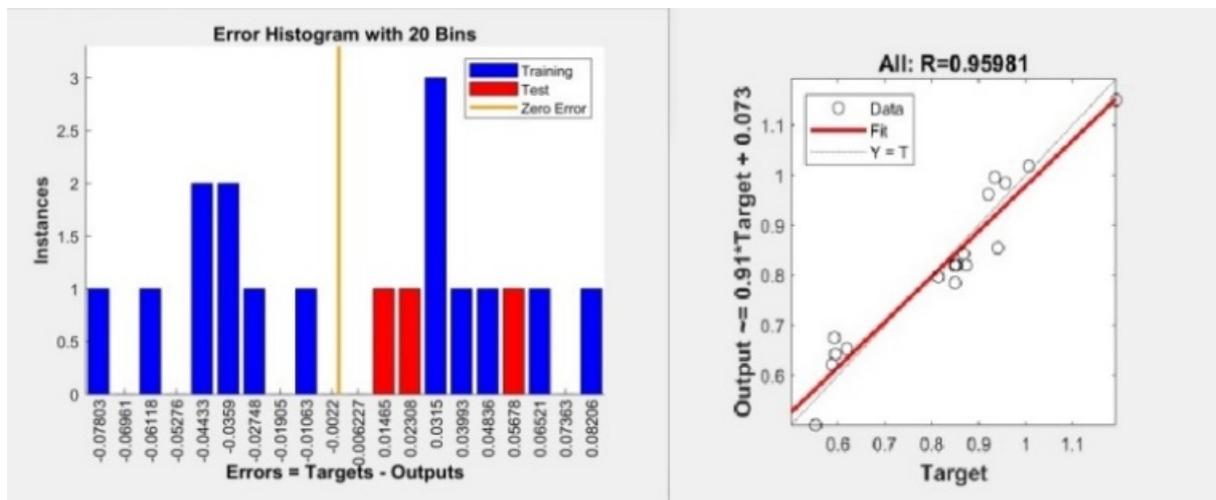


е

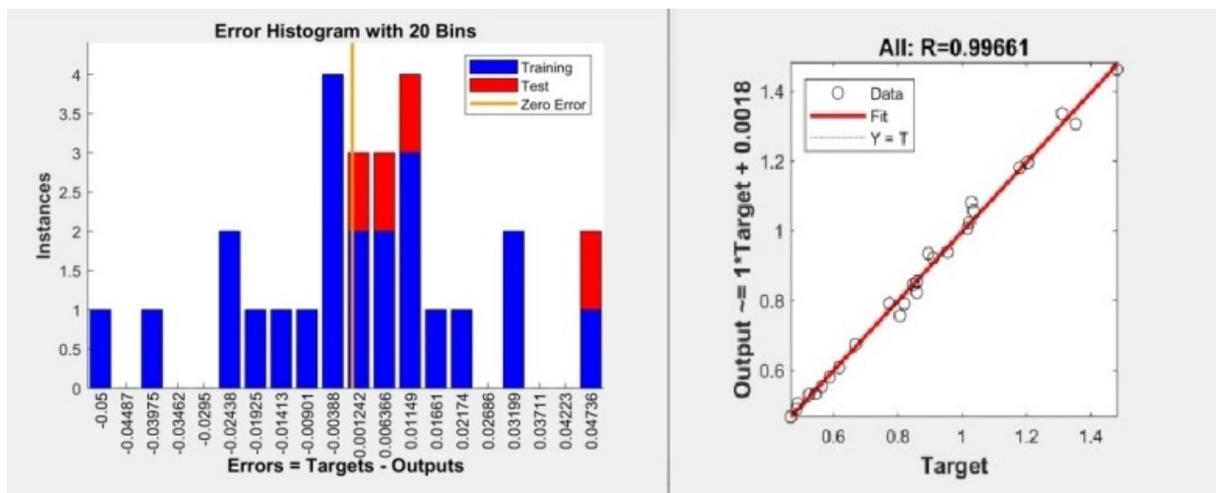
Рис. 1. Гистограмма ошибок и график регрессии (продолжение):  
 г – ИНС №4; д – ИНС №5; е – ИНС № 6



ж



з



и

Рис. 1. Гистограмма ошибок и график регрессии (окончание):  
 г – ИНС №4; д – ИНС №5; е – ИНС № 6

Как видно из таблицы, построенные нейронные сети обладают хорошей точностью, для большинства из них относительная погрешность не превышает 10 %, за исключением сети № 8,

погрешность которой составляет 15 %, что связано с особенностями исходных данных. Несмотря на приемлемую точность представленные модели узконаправлены и могут использоваться

только для одного конкретного материала. Поэтому на следующем этапе исследования принято решение объединить отдельные исходные данные в определенные группы, тем самым усовершенствовать и расширить универсальность нейронных сетей. Для более корректной работы объединенных нейронных сетей, рационально начать объединение по признаку близости значений исходных данных. Таким образом, сформированы следующие нейросетевые модели:

1. Объединенная нейронная сеть 1\_3 (данные сетей № 1 и № 3) для мягких материалов – цветных металлов и сплавов, включающая данные по обработке алюминия и латуни.

2. Объединенная нейронная сеть 2\_4 (данные сетей № 2 и № 4) по обработке нержавеющей стали.

3. Объединенная нейронная сеть 6\_7 (данные сетей № 6 и № 7) по обработке конструкционных сталей.

4. Объединенная нейронная сеть 8\_9 (данные сетей № 8 и № 9) по обработке высокопрочных материалов: жаропрочного сплава и инструментальной штамповой стали.

В табл. 3 представлены объединенные данные условий обработки указанных групп материалов и полученная точность нейросетевых моделей, а на рис. 2 – гистограммы ошибок и графики регрессии, указанных нейронных сетей.

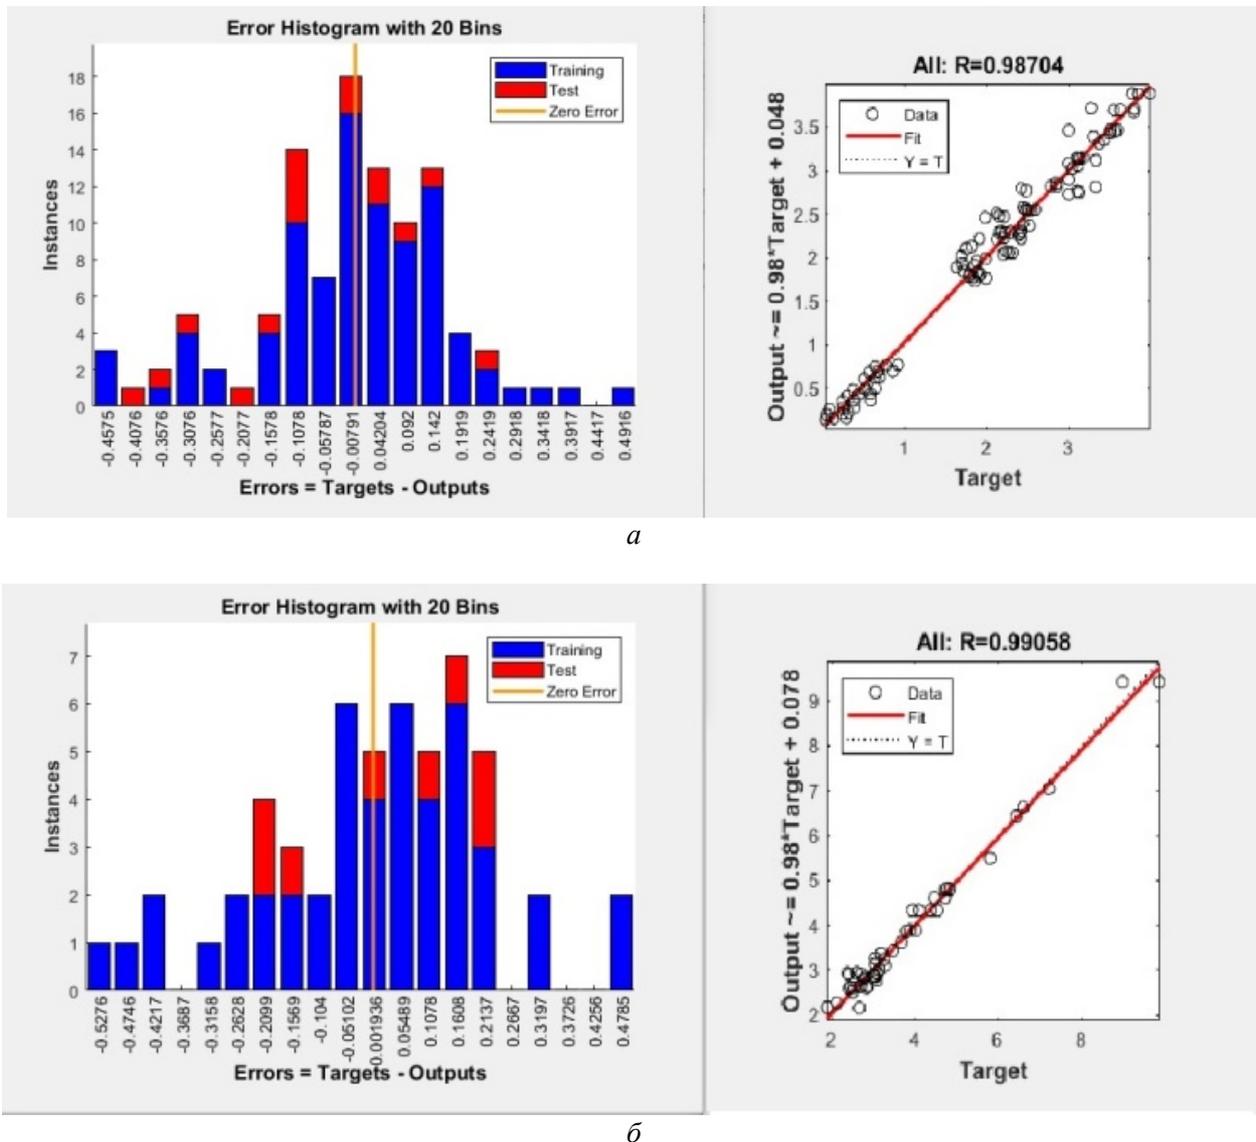
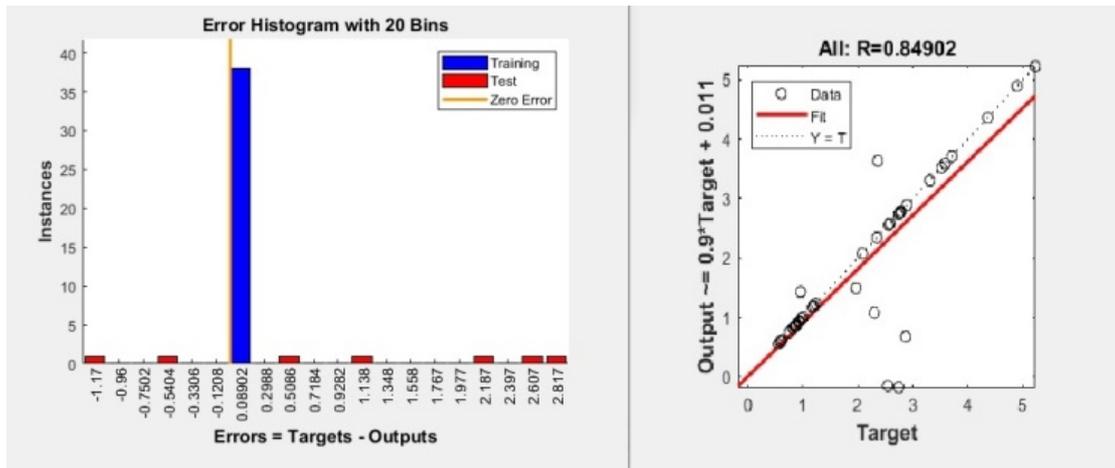
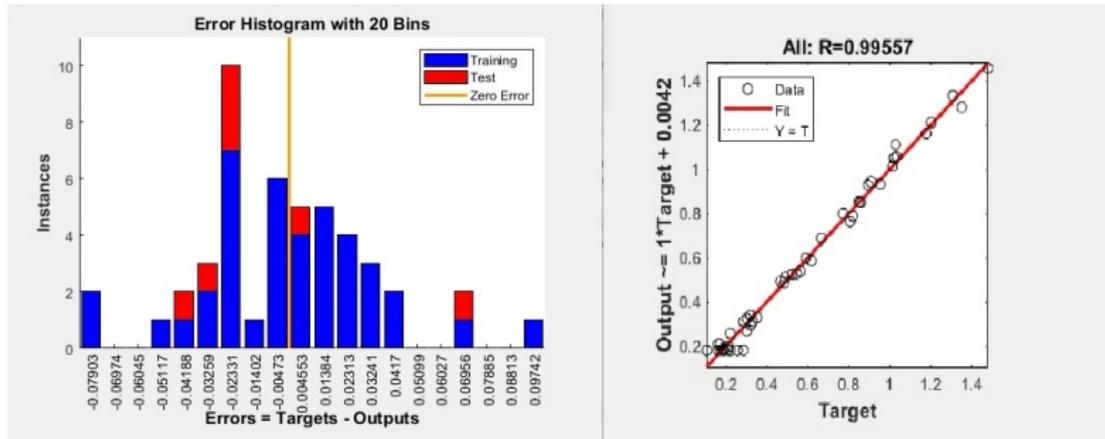


Рис. 2. Гистограмма ошибок и график регрессии (начало):  
а – ИНС 1\_3; б – ИНС 2\_4;



6



2

Рис. 2. Гистограмма ошибок и график регрессии (окончание):  
в – ИНС 6\_7; г – ИНС 8\_9

Таблица 3

**Результаты первично объединенных нейронных сетей**

№ ИНС	Обрабатываемый материал	Твердость	Диапазон скорости V, м/мин	Диапазон подачи S, мм/об	Диапазон глубины резания t, мм	Объем данных	Относительная погрешность, %
1_3	Алюминиевый сплав, латунь	80–90	28–79,8	0,002–4,8	0,2–1	105	6,44
2_4	Нержавеющие стали IDM 8365 и 1Cr18Ni9Ti	210	70–313,2	0,096–0,6	0,08–2,34	54	4,55
6_7	Конструкционные стали 9SMnPb28K и сталь 50	170–230	71–283	0,1–0,25	0,5–1	45	9,08
8_9	Жаропрочный сплав Inconel 718 и инструментальная штамповая сталь 4X5MФ1С	300 – 373	47,5–185	0,083–0,72	0,1–0,5	47	4,52

Как видно из графиков, объединенные нейронные сети показывают гораздо лучшие результаты, чем отдельные. Распределение погрешностей более приближено к нормальному распределению Гаусса, большинство отклонений группируется вблизи золотого сечения. Однако некоторые тестовые данные имеют существенное от-

клонение, наиболее ярко это выражено у нейронной сети 6\_7. Такой результат получен, видимо вследствие недостаточного перекрытия значений скорости резания и малого объема данных.

На основании положительного результата объединения данных отдельных нейронных сетей был предпринят следующий шаг объедине-

ния сетей по признаку укрупнения групп обрабатываемых материалов и расширения диапазонов режимов резания. В отличие от предыдущего объединения в данном случае отдельные исходные данные вошли в состав нескольких нейронных сетей. Это было выполнено с целью выявления влияния диапазонов изменения входных параметров на точность выходного параметра. Таким образом, были созданы три укрупненные нейронные сети, данные в которых частично перекрываются:

1. Комбинированная нейронная сеть 2\_4\_5\_6\_7 (данные сетей № 2, № 4, № 5-7), включающая условия обработки нержавеющей, низколегированных и конструкционных сталей.

2. Комбинированная нейронная сеть 1\_2\_3\_4\_5\_6\_7 (данные сетей № 1-7), включающая условия обработки цветных металлов, нержавеющей, низколегированных и конструкционных сталей.

3. Комбинированная нейронная сеть 2\_4\_5\_6\_7\_8\_9 (данные сетей № 2, № 4-9), включающая условия обработки нержавеющей, низколегированных, конструкционных сталей и высокопрочных материалов (жаропрочного сплава и инструментальной стали).

На рис. 3 представлены гистограммы ошибок и графики регрессии, указанных нейронных сетей, а в табл. 3 сведены данные условий обработки указанных групп материалов и полученная точность нейросетевых моделей.

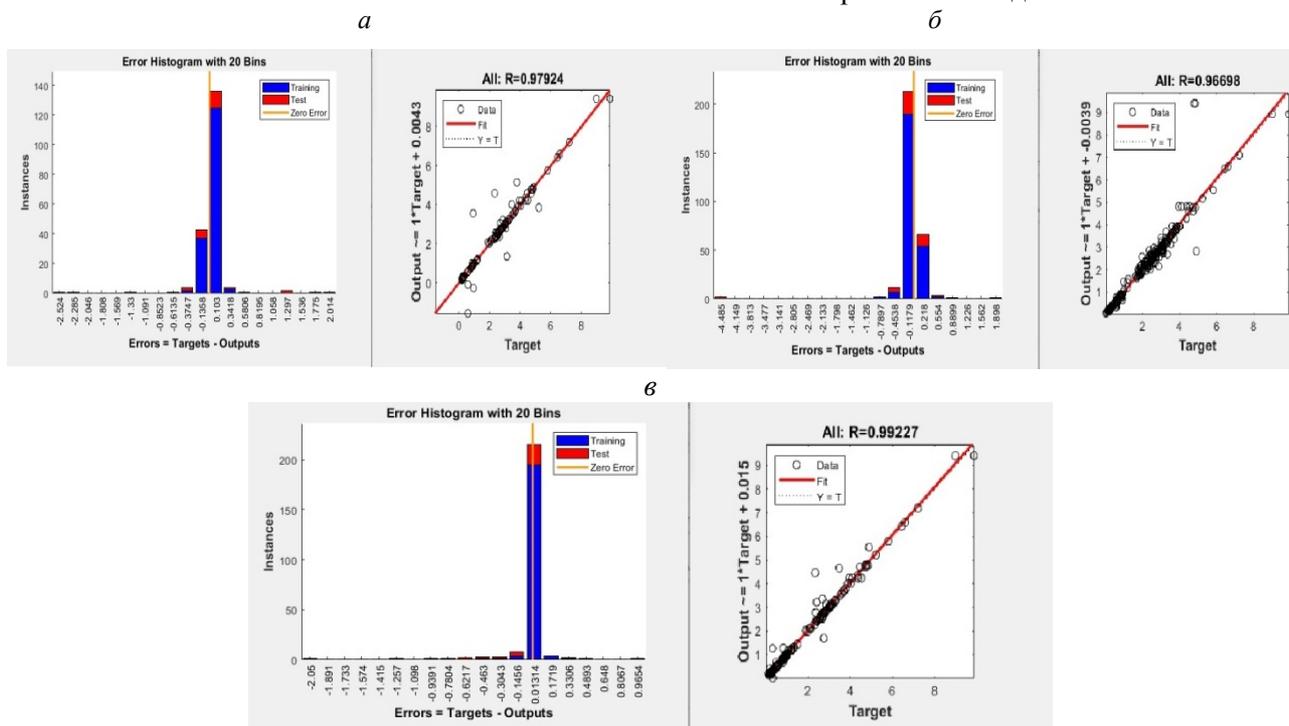


Рис. 3. Гистограмма ошибок и график регрессии: а – ИНС 2\_4\_5\_6\_7; б – ИНС 1\_3\_2\_4\_5\_6\_7; в – ИНС 2\_4\_5\_6\_7\_8\_9

Таблица 4

**Результаты вторично объединенных нейронных сетей**

№	Твердость материала	Диапазон скорости $V$ , м/мин	Диапазон подачи $S$ , мм/об	Диапазон глубины резания $t$ , мм	Объем данных	Относительная погрешность, %
1	Нейронная сеть 2_4_5_6_7 для обработки материалов: нержавеющей стали IDM 8365 и 1Cr18Ni9Ti, низколегированная сталь, конструкционные стали 9SMnPb28K и сталь 50					
	170–230	70–313,2	0,03–0,6	0,08–2,34	196	6,74
2	Нейронная сеть 1_3_2_4_5_6_7 для обработки материалов: алюминиевый сплав, латунь, нержавеющей стали IDM 8365 и 1Cr18Ni9Ti, низколегированная сталь, конструкционные стали 9SMnPb28K и сталь 50					
	80–230	28–313,2	0,002–4,8	0,08–2,34	301	11,47
3	Нейронная сеть 2_4_5_6_7_8_9 по обработке материалов: нержавеющей стали IDM 8365 и 1Cr18Ni9Ti, низколегированная сталь, конструкционные стали 9SMnPb28K и сталь 50, жаропрочный сплав Inconel718 и инструментальная штамповая сталь 4X5MФ1С					
	170–373	47,5–313,2	0,03–0,72	0,08–2,34	243	4,50

Полученные результаты объединения являются вполне удовлетворительными. Наименьшую точность с погрешностью 11 % имеет 2 сеть, в состав которой вошли как мягкие материалы (алюминий и латунь), так и более твердые (конструкционные и нержавеющие стали) с разностью твердости в 150 единиц НВ. При этом 3 сеть имеет разницу в твердости включенных материалов 200 единиц НВ, но существенно меньшую погрешность 4,5 %. Это связано с условиями формирования шероховатости поверхности для отдельных материалов. Закономерности формирования шероховатости при обработке различных типов сталей являются более близкими, в отличие от обработки алюминия и латуни, имеющих существенно более высокую теплопроводность и склонных к наростообразованию.

На последнем этапе исследования выполнено объединение всех имеющихся экспериментальных данных в одну нейронную сеть. Нейронная сеть 1\_2\_3\_4\_5\_6\_7\_8\_9 предусматривает

возможность прогнозирования шероховатости поверхности для широкого диапазона обрабатываемых материалов и режимов резания: от самых мягких (алюминий, латунь) до наиболее твердых (жаропрочный сплав, инструментальная сталь), включая материалы средней твердости (нержавеющие, конструкционные и низколегированные стали). Такой охват даст более широкую применимость проектируемой нейронной сети. Для ее создания были использованы выборки всех предыдущих нейронных сетей, обучение производилось по алгоритму Байесовской регуляризации при созданных 300 скрытых слоях.

В результате была получена рабочая нейронная сеть, обладающая наибольшей универсальностью по сравнению с ранее представленными. На рис. 4 изображены гистограмма ошибок и график регрессии. После тестирования сеть показывает среднюю относительную погрешность результата в 7,64 %. Итоговые характеристики данной сети сведены в табл. 5.

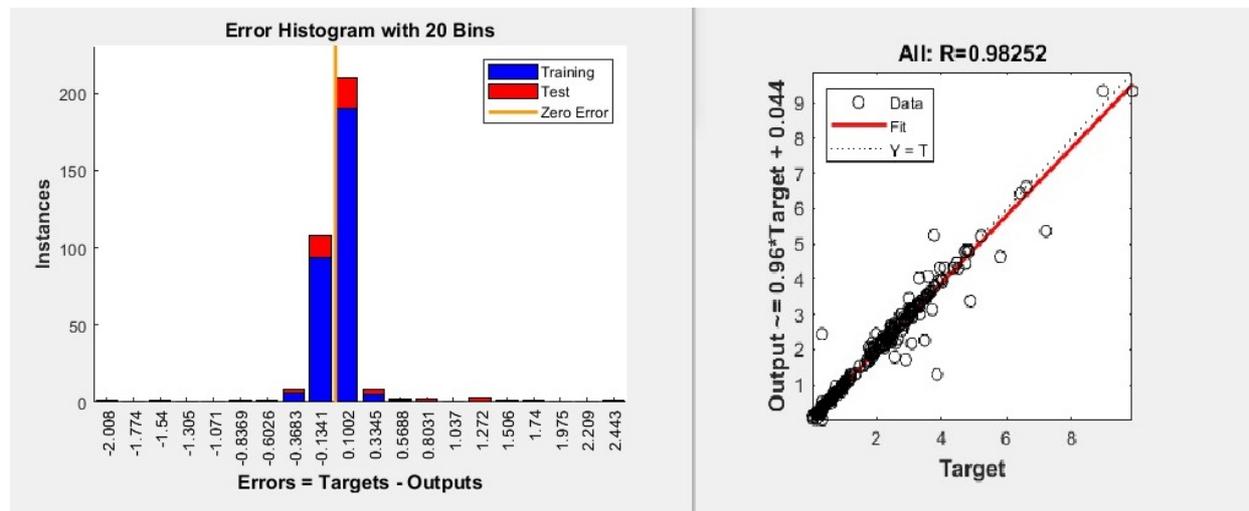


Рис. 4. Графики процесса обучения нейронной сети 1\_2\_3\_4\_5\_6\_7\_8\_9

Таблица 5

**Погрешности проверочных выборок**

№ ИНС	1 2 3 4 5 6 7 8 9
Обрабатываемый материал	Алюминиевый сплав, латунь, нержавеющие стали IDM 8365 и 1Cr18Ni9Ti, низколегированная сталь, конструкционные стали 9SMnPb28K и сталь 50, жаропрочный сплав Inconel 718 и инструментальная штамповая сталь 4X5MФ1С
Твердость	80–373
Диапазон скорости V, м/мин	28–313,2
Диапазон подач S, мм/об	0,002–4,8
Диапазон глубины резания t, мм	0,08–2,34
Объем данных	348
Относительная погрешность, %	7,64

**Выводы.** Использование искусственных нейронных сетей для прогнозирования шероховатости обрабатываемой поверхности при механической обработке позволяет создавать как узкоспециализированные модели для определенных материалов, так и широкоуниверсальные модели для групп материалов с различными физико-механическими свойствами при наличии достаточной базы данных для обучения сети. В зависимости от объема исходных данных и диапазонов их изменения представленные нейросетевые модели показали относительную погрешность в пределах от 2 % до 15 %. Хорошие результаты получены при объединении отдельных баз данных в укрупненные группы по признаку физико-механических свойств и создании на их основе комбинированных нейросетевых моделей. Так, получена широкоуниверсальная модель прогнозирования шероховатости при фрезеровании различных материалов: от наиболее мягких цветных металлов до высокотвердых жаропрочных сплавов, относительная погрешность которой составляет 8 %. Для дальнейшего совершенствования данной нейронной сети требуется увеличение объема базы данных по обработке различных материалов, исключение некорректных данных, а так же возможное добавление новых входных параметров и их комбинирование при широком диапазоне обрабатываемых материалов.

#### БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Ерыгин Е.В., Дуюн Т.А. Прогнозирование шероховатости при чистовом фрезеровании с использованием нейронных сетей // Вестник БГТУ им. В.Г. Шухова. 2019. Том 4, №10. С. 135–141.
2. Palani S., Kesavanarayana Y. Prediction of Surface Roughness in End Milling Process by Machine Vision Using Neuro Fuzzy Network // International Conference on Science, Engineering and Management Research (ICSEMR). 2014. P. 1–5.
3. Kovač P., Savković B., Gostimirovic M., Jesic D., Mankova I. Modeling of the Machining Surface Roughness Parameters for Steel Difficult to Machining // ANALELE UNIVERSITĂȚII “EFTIMIE MURGU” REȘIȚA ANUL XXIV. 2017. Vol. 1. Pp. 1453–7397.
4. Soltan I.M., Eltaib M. E. H., El-Zahry R.M. Surface roughness prediction in end milling using multiple regression and adaptive neuro-fuzzy inference system // Fourth Assiut University Int. Conf. on Mech. Eng. Advanced Tech. For Indus. Prod., 2006. Pp. 614–620.
5. Xiao M., Shen X., Ma Y., Yang F., Gao N., Wei W., Wu D. Prediction of surface roughness and optimization of cutting parameters of stainless steel turning based on RSM // Hindawi Mathematical Problems in Engineering. 2018. Pp. 1–16.
6. Parmar J.G., Makwana A. Prediction of surface roughness for end milling process using Artificial Neural Network // International Journal of Modern Engineering Research (IJMER). 2012 Vol. 2. Pp. 1006–1013.
7. Davim J.P. A note on the determination of optimal cutting conditions for surface finish obtained in turning using design of experiments // Journal of materials processing technology. 2001. Vol. 116. Pp. 305–308.
8. Sahin Y., Motorcu A.R. Surface roughness model in machining hardened steel with cubic boron nitride cutting tool // International Journal of Refractory Metals & Hard Materials. 2008. Vol. 26. Pp. 84–90.
9. Sarkar B., Reddy M.M., Debnath S. Effect of machining parameters on surface finish of Inconel 718 in end milling // MATEC Web of Conferences 95. 2017. P. 1-6.
10. Tao F., Weijun L., Jibin Z. Optimization of cutting parameters using multiobjective evolutionary algorithm based on decomposition // Journal of Vibroengineering. 2013. Vol. 15. Pp. 833–844.

#### Информация об авторах

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

Поступила 24.10.2020 г.

© Ерыгин Е.В., Дуюн Т.А., 2020

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

Belgorod State Technological University named after V.G. Shukhova

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

## DEVELOPMENT OF NEURAL NETWORKS FOR FORECASTING ROUGHNESS WHEN MILLING VARIOUS MATERIALS

**Abstract.** The article presents a methodology for the development and testing results of artificial neural networks for predicting roughness in finishing milling. Experimental data of various researchers in the processing of materials with different physical and mechanical properties are used as the initial data base for the creation and training of neural networks. The value of material hardness is taken as the main identifier of physical and mechanical properties. In addition to the hardness of the material, the input parameters of the nets are also the cutting modes: tool feed, depth and cutting speed. The data of the obtained roughness are used for several groups of materials: non-ferrous metals, structural and stainless steels, heat-resistant alloys and tool steel. Nine highly specialized neural networks have been created that predict roughness when milling a certain material, a number of combined networks by combining several databases, including a broad-based neural network for several groups of materials. A comparative analysis of the results of testing the developed neural networks by the criterion of relative error is carried out. Most of the presented neural networks have a satisfactory error not exceeding 10%. Individual neural networks have higher accuracy, showing an error within 5 %.

**Keywords:** artificial neural networks (ANN), combined ANN, roughness, finish milling.

### REFERENCES

1. Erygin E.V., Dujun T.A. Prediction of roughness in finishing milling using neural networks [Prognostirovanie sherohovatosti pri chistovom frezerovanii s ispol'zovaniem nejronnyh setej]. Bulletin of BSTU named after V.G. Shukhov. 2019. No. 10. Pp. 135–141.
2. Palani S., Kesavanarayana Y. Prediction of Surface Roughness in End Milling Process by Machine Vision Using Neuro Fuzzy Network. International Conference on Science, Engineering and Management Research (ICSEMR). 2014. Pp. 1–5.
3. Kovač P., Savković B., Gostimirović M., Jesić D., Mankova I. Modeling of the Machining Surface Roughness Parameters for Steel Difficult to Machining. ANALELE UNIVERSITĂȚII “EFTIMIE MURGU” REȘIȚA ANUL XXIV. 2017. Vol. 1. Pp. 1453–7397.
4. Soltan I. M., Eltaib M. E. H., El-Zahry R. M. Surface roughness prediction in end milling using multiple regression and adaptive neuro-fuzzy inference system. Fourth Assiut University Int. Conf. on Mech. Eng. Advanced Tech. For Indus. Prod., 2006. Pp. 614–620.
5. Xiao M., Shen X., Ma Y., Yang F., Gao N., Wei W., Wu D. Prediction of surface roughness and optimization of cutting parameters of stainless steel turning based on RSM. Hindawi Mathematical Problems in Engineering. 2018. Pp. 1–16.
6. Parmar J. G., Makwana A. Prediction of surface roughness for end milling process using Artificial Neural Network. International Journal of Modern Engineering Research (IJMER). 2012 Vol. 2. Pp. 1006–1013.
7. Davim J. P. A note on the determination of optimal cutting conditions for surface finish obtained in turning using design of experiments. Journal of materials processing technology. 2001. Vol. 116. Pp. 305–308.
8. Sahin Y., Motorcu A.R. Surface roughness model in machining hardened steel with cubic boron nitride cutting tool. International Journal of Refractory Metals & Hard Materials. 2008. Vol. 26. Pp. 84–90.
9. Sarkar B., Reddy M. M., Debnath S. Effect of machining parameters on surface finish of Inconel 718 in end milling. MATEC Web of Conferences 95. 2017. Pp. 1–6.
10. Tao F., Weijun L., Jibin Z. Optimization of cutting parameters using multiobjective evolutionary algorithm based on decomposition. Journal of Vibroengineering. 2013. Vol. 15. Pp. 833–844.

### Information about the authors

**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.

**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.

Received 24.10.2020

**Для цитирования:**

Ерыгин Е.В., Дуюн Т.А. Разработка нейронных сетей для прогнозирования шероховатости при фрезеровании различных материалов // Вестник БГТУ им. В.Г. Шухова. 2020. № 11. С. 113–124. DOI: 10.34031/2071-7318-2020-5-11-113-124

**For citation:**

Erygin E.V., Dujun T.A. Development of neural networks for forecasting roughness when milling various materials. Bulletin of BSTU named after V.G. Shukhov. 2020. No. 11. Pp. 113–124. DOI: 10.34031/2071-7318-2020-5-11-113-124