

УДК 004.852

DOI: 10.22213/2410-9304-2020-3-95-102

### Прогнозирование периода стойкости металлорежущего инструмента на основе нейросети

А. В. Коробейников, кандидат технических наук, доцент, ИжГТУ имени М. Т. Калашникова, Ижевск, Россия

А. Ф. Мкртчян, кандидат технических наук, ИжГТУ имени М. Т. Калашникова, Ижевск, Россия

В. В. Ситников, аспирант, ИжГТУ имени М. Т. Калашникова, Ижевск, Россия

А. В. Наговицын, магистрант, ИжГТУ имени М. Т. Калашникова, Ижевск, Россия

Рассматривается задача прогнозирования периода стойкости металлорежущего инструмента при заданных параметрах режима резания. Для решения поставленной задачи предлагается использовать нейросетевую модель. Предложено использовать в качестве структуры нейронной сети многослойный персептрон. Обучающей выборкой при обучении нейросетевой модели прогнозирования служат накопленные статистические данные системы «Инструментальный шкаф». Входными данными нейронной сети служат значения параметров режима резания (тип материала заготовки, значение глубины резания при технологической операции, значение подачи при технологической операции, значение скорости резания) и значения параметров конструкции металлорежущей пластины, указанных в маркировке пластины согласно ISO 1832-85. Программная реализация предложенной нейронной сети выполнена с использованием библиотеки машинного обучения «DeepLearning4J».

При обучении нейронной сети формировалось 5 обучающих подвыборок, содержащих по 20 % от количества образцов в обучающей выборке. Для решения проблемы переобучения нейронной сети использовался метод перекрестной проверки. Использовалась обучающая выборка общим количеством 500 записей по множеству металлорежущего инструмента, состоящему из 10 пластин. Проведенные эксперименты показали работоспособность предложенного подхода. В работе представлены графики, показывающие зависимость прогнозируемого периода стойкости от одного из параметров режима резания.

Цель работы заключается в повышении эффективности планирования закупок металлорежущего инструмента.

**Ключевые слова:** период стойкости инструмента, нейросетевое прогнозирование, многослойный персептрон.

#### Введение

В настоящее время на машиностроительных предприятиях активно внедряются системы автоматизированного инструментального обеспечения, позволяющие прогнозировать потребность в металлорежущем инструменте и сокращать складские запасы. Но возникает проблема, связанная с трудностью прогнозирования износа инструмента, характеризуемого его периодом стойкости, так как на данный процесс влияет достаточно большое количество факторов [1–5].

В технологии машиностроения известно теоретическое соотношение, определяющее период стойкости металлорежущего инструмента:

$$T = m \sqrt{\frac{C_v K_v}{t^x S^y}}, \quad (1)$$

где  $T$  – период стойкости инструмента (мин);  $C_v$  – коэффициент твердости материала заготовки;  $K_v$  – коэффициент прочности материала заготовки;  $t^x$  – глубина резания (мм);  $S^y$  – подача (мм/об),  $v$  – скорость резания (м/с);  $x$  и  $y$  –

параметры, характеризующие материал инструмента.

Вычислив значение периода стойкости инструмента для заданных параметров технологической операции, можем оценить количество данной технологической операции с использованием одной единицы инструмента, то есть оценку расхода инструмента:

$$N_u = \frac{T}{T_0}, \quad (2)$$

где  $T_0$  – время на выполнение одной технологической операции.

При известном расходе инструмента при выполнении технологических операций появляется возможность более точного планирования количества инструмента для закупки.

Однако в реальных производственных условиях добавляются дополнительные факторы, влияющие на период стойкости инструмента, такие как:

– характеристики пластин металлорежущего инструмента (форма, размеры, материал);



Структура входов и выходов ИНС:

- $x[1] = 1$  – константный вход;
- $x[2] \dots x[17]$  – входы позиционного кодирования (one hot encoding) значения типа формы пластины (16 шт), то есть при позиционном кодировании значение  $x[i] = 1$  только для входа соответствующему конкретному типу формы пластины (1...16), а по остальным входам данного подмножества входов присутствует значение  $x[i] = 0$ ;
- $x[18] \dots x[27]$  – входы позиционного кодирования значения заднего угла пластины (10 шт.);
- $x[28] \dots x[39]$  – входы позиционного кодирования значения класса допуска пластины (12 шт.);
- $x[40] \dots x[49]$  – входы позиционного кодирования значения типа формы передней поверхности пластины (10 шт.);
- $x[50]$  – вход вещественного значения длины режущей кромки пластины (мм);
- $x[51]$  – вход вещественного значения толщины пластины (мм);
- $x[52]$  – вход вещественного значения радиуса при вершине режущей кромки пластины (мм);
- $x[53] \dots x[58]$  – входы позиционного кодирования значения типа дополнительных особенностей конструкции пластины (стружколом) (6 шт.);
- $x[59] \dots x[62]$  – входы позиционного кодирования значения типа материала пластины (4 шт.);
- $x[63] \dots x[65]$  – входы позиционного кодирования значения типа материала заготовки (3 шт);
- $x[66]$  – вход вещественного значения глубины резания при технологической операции (мм);
- $x[67]$  – вход вещественного значения подачи при технологической операции (мм/об);
- $x[68]$  – вход вещественного значения скорости резания (м/мин).
- $y[3][1]$  – выход вещественного значения периода стойкости инструмента при технологической операции (мин).

Параметры ИНС при обучении:

- алгоритм обучения (optimization algorithm): стохастический градиентный спуск (stochastic gradient descent);
- скорость обучения (learning rate): 0.02;
- функция ошибки (loss function): средне-квадратическая ошибка (MSE);
- алгоритм инициализации весовых коэффициентов (weight init): Ксавье (Xavier);
- регуляризация весовых коэффициентов (regularization):  $L2(1E-4)$ ;
- алгоритм обновления весовых коэффициентов (updater): Adamax;
- критерий прекращения обучения для устранения переобучения ИНС на обучающей выборке: прекращение обучения при росте сред-

ней ошибки по обучающей и тестовой выборкам;

- нормализация значений вещественных входов: переход из диапазона значений входов в диапазон  $-0,5 \dots +0,5$ .

#### Результаты экспериментов

Для реализации предложенной ИНС была выбрана библиотека машинного обучения «DeepLearning4J» для языка программирования «Java» [10].

Было разработано ПО «ToolLifePeriod», служащее для построения нейросетевой модели прогноза периода стойкости инструмента в составе системы инструментального шкафа («ToolCabinet») компании ООО «Элин» (г. Ижевск) [11].

Функции ПО «ToolLifePeriod»:

- чтение файла статистики по периодам стойкости инструмента из системы инструментального шкафа «ToolCabinet»;
- формирование модели на основе искусственной нейронной сети;
- обучение модели на основе искусственной нейронной сети на основе файла статистики по периодам стойкости инструмента;
- сохранение обученной модели в файл для дальнейшего использования;
- прогноз периодов стойкости инструмента по запросу системы из системы инструментального шкафа «ToolCabinet».

Состав ПО «ToolLifePeriod»:

- 1) ПО «ToolLifePeriodTrain» – обучение модели ИНС на основе статистических данных по периоду стойкости инструмента;
- 2) ПО «ToolLifePeriodPredict» – применение модели ИНС для предсказания периода стойкости инструмента.

При обучении ИНС используется формирование 5 обучающих подвыборок, содержащих по 20 % от количества образцов в обучающей выборке, а затем для решения проблемы переобучения ИНС использовался метод перекрестной проверки (cross validation). Цикл обучения повторяется 5 раз, при этом каждый раз тестовой выборкой служит очередная из подвыборок (20 %), а остальные подвыборки (80 %) составляют обучающую выборку в данном цикле обучения.

В ходе экспериментов с ПО «ToolLifePeriod» использовались обучающая выборка – накопленные статистические данные общим числом 500 записей по множеству металлорежущего инструмента, состоящему из 10 пластин.

При проверке работы ПО «ToolLifePeriod» на первом этапе с помощью ПО «ToolLifePeriodTrain» была получена нейросетевая модель для прогноза периода стойкости металлорежущей

пластины. Изменение среднеарифметической ошибки (СКО) обучающей выборки приведено на рис. 2. Полученные в результате экспериментов значения СКО обучающей и тестовой выборок были в диапазоне 10...20.

На втором этапе с помощью ПО «ToolLife-PeriodPredict» и построенной нейросетевой моделью был выполнен прогноз периода стойкости для одной из металлорежущих пластин (CNMG 120408-PM 4325; материал заготовки: сталь) для различных параметров технологической операции (режима резания), как присутствующих в обучающей выборке, так и не присутствующих.

При выполнении прогноза параметры принимали следующие значения:

– глубина (мм): 0,25, 0,50, 1,00, 1,50, 2,25, 3,00, 3,75, 4,50, 4,75, 5,00, 5,25;

– подача (мм/об.): 0,100, 0,150, 0,200, 0,250, 0,375, 0,500, 0,625;

– скорость (м/мин): 230, 275, 310, 345, 385, 425, 560.

Некоторые результаты, полученные при прогнозе, представлены на рис. 3. Для каждого значения глубины построен график, содержащий как спрогнозированные значения (синие ромбы), так и значения, используемые при обучении (красные квадраты). В табл. 2 приведено соответствие номеров точек и параметров режима резания.

На рис. 4 представлены графики, показывающие зависимость прогнозируемого периода стойкости от одного из параметров режима резания: глубина (мм), подача (мм/об), скорость (м/мин), при фиксированных значениях двух других параметров режима резания.

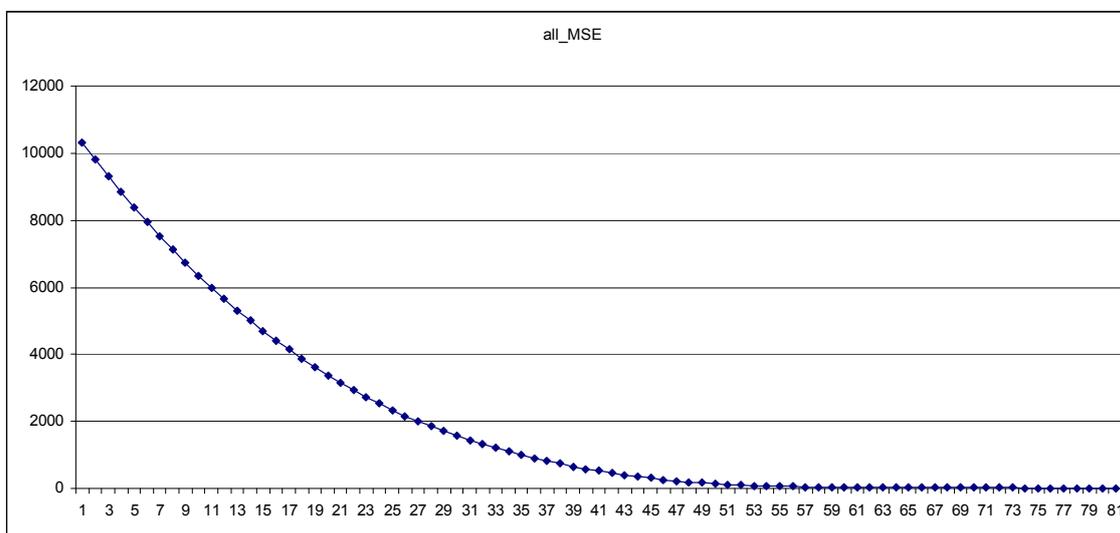


Рис. 2. Изменение ошибки при обучении

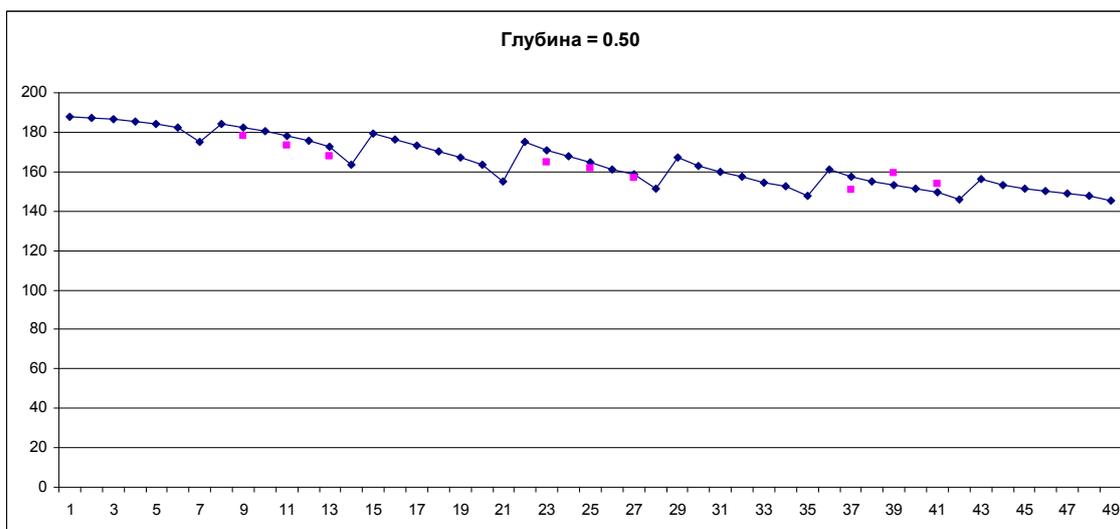


Рис. 3. Результаты прогноза при различных значениях параметров режима резания (окончание на с. 99)

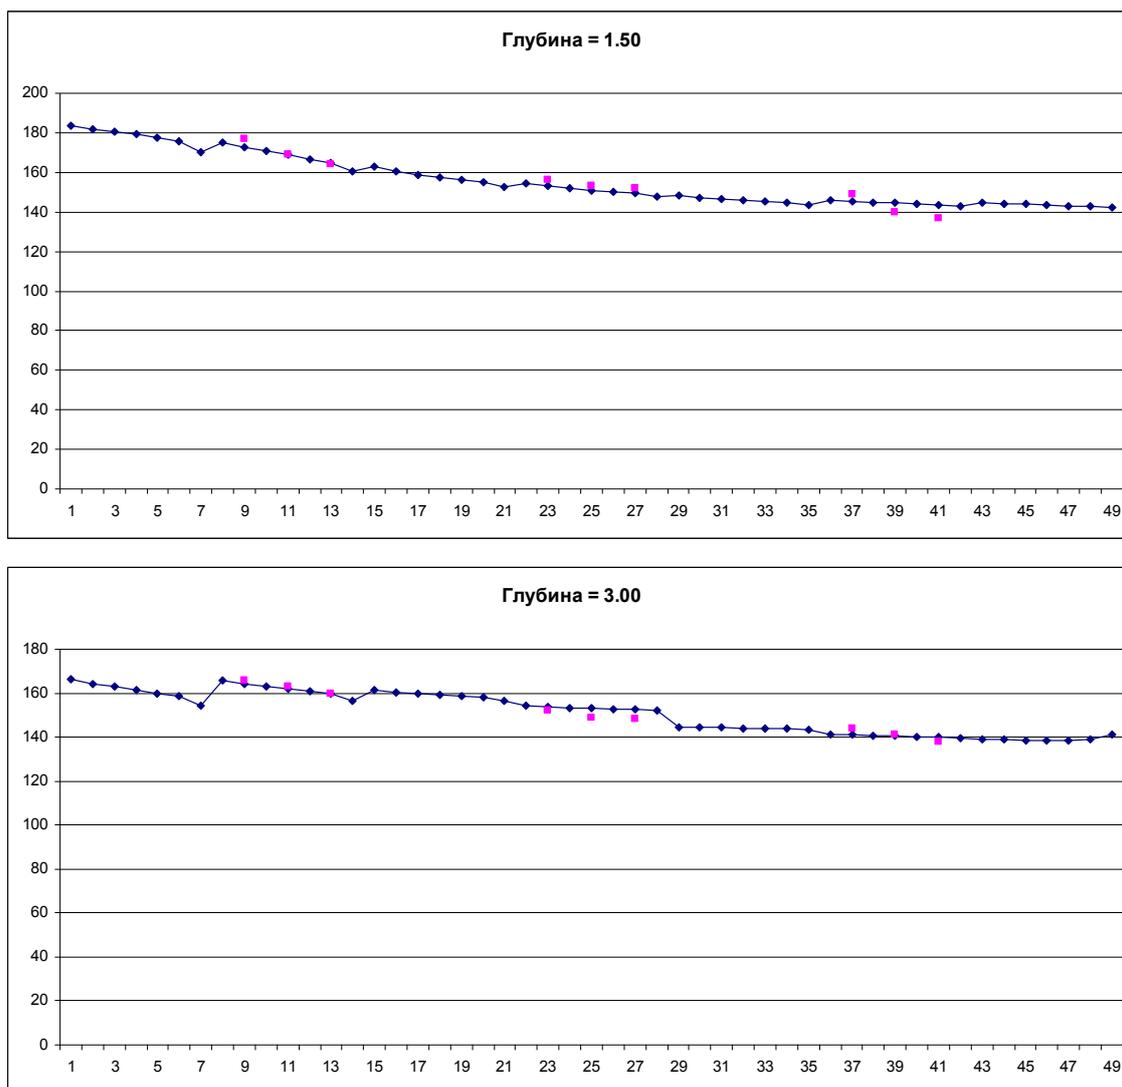


Рис. 3. Окончание (начало на с. 98)

Таблица 2. Соответствие параметров при построении графиков

№	Подача (мм/об.)	Скорость (м/мин)
1	0,100	230
2	0,100	275
3	0,100	310
4	0,100	345
5	0,100	385
6	0,100	425
7	0,100	560
8	0,150	230
9	0,150	275
10	0,150	310
11	0,150	345
12	0,150	385
13	0,150	425
14	0,150	560
15	0,200	230
16	0,200	275
17	0,200	310
18	0,200	345
19	0,200	385

Окончание табл. 2

№	Подача (мм/об.)	Скорость (м/мин)
20	0,200	425
21	0,200	560
22	0,250	230
23	0,250	275
24	0,250	310
25	0,250	345
26	0,250	385
27	0,250	425
28	0,250	560
29	0,375	230
30	0,375	275
31	0,375	310
32	0,375	345
33	0,375	385
34	0,375	425
35	0,375	560
36	0,500	230
37	0,500	275
38	0,500	310
39	0,500	345
40	0,500	385
41	0,500	425
42	0,500	560
43	0,625	230
44	0,625	275
45	0,625	310
46	0,625	345
47	0,625	385
48	0,625	425
49	0,625	560

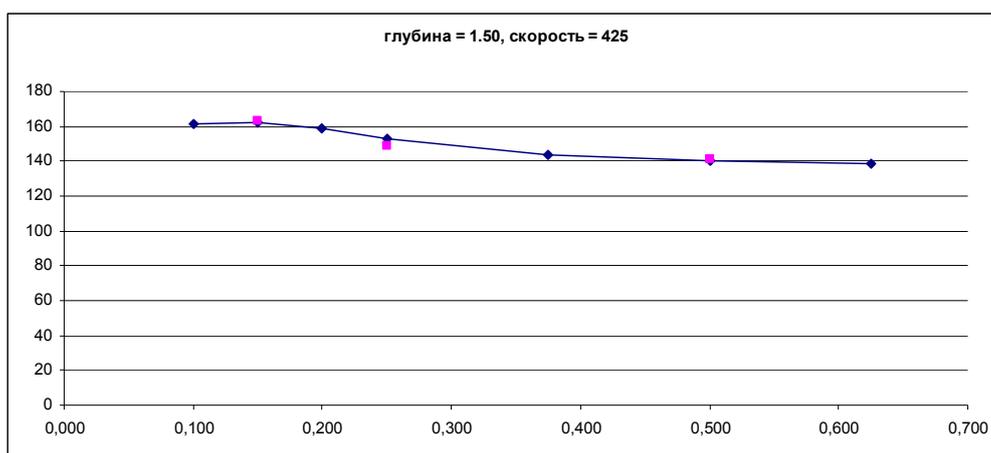


Рис. 4. Зависимость периода стойкости от отдельных параметров режима резания (окончание на с. 101)

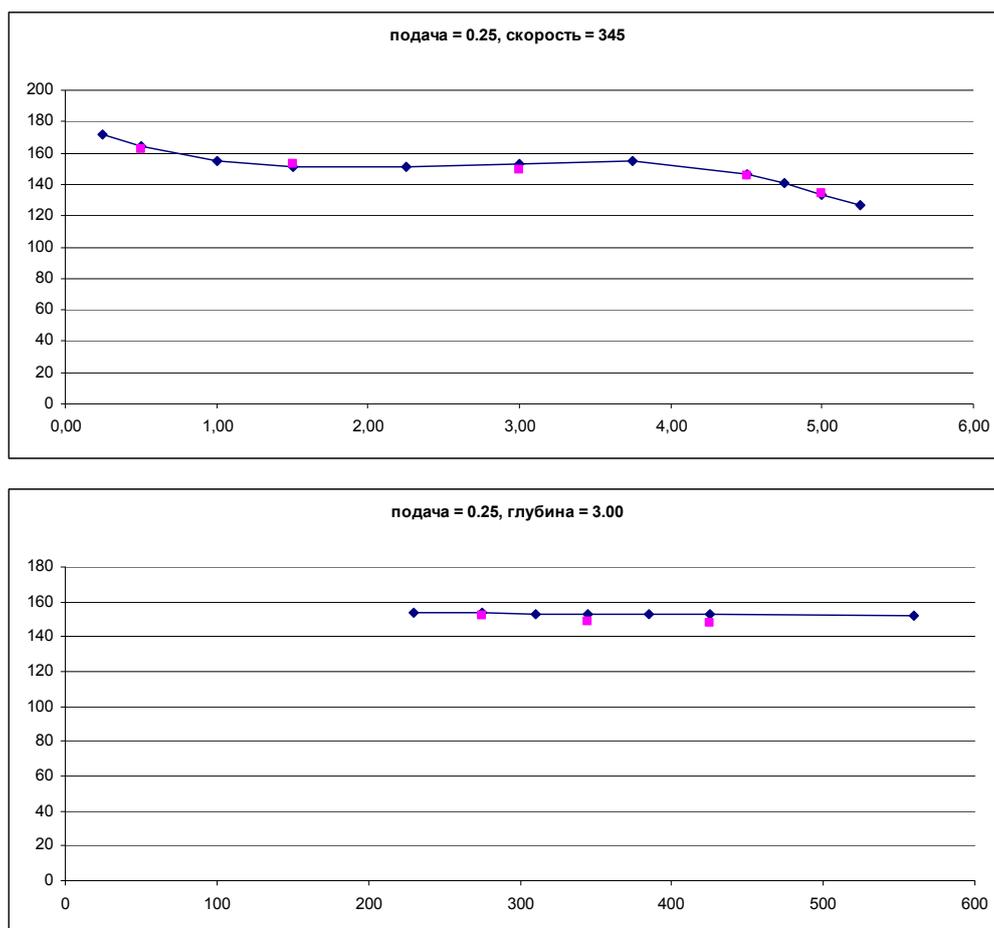


Рис. 4. Окончание (начало на с. 100)

### Выводы

Полученные результаты показывают соответствие фактических статистических значений и спрогнозированных значений периода стойкости данной пластины. На графиках присутствуют дополнительные точки, в которых проверяется экстраполяция и интерполяция по значениям параметров режимов резания.

Построенные по результатам прогноза графики показывают работоспособность построенной нейросетевой модели. Полученная модель прогноза может быть использована при планировании расхода инструмента при заданных параметрах технологических операций.

Для обучения предложенной нейросетевой модели прогноза периода стойкости инструмента необходимо наличие статистических (фактических) данных по периоду стойкости инструмента из системы инструментального шкафа «ToolCabinet». Чем больше объем статистических данных будет накоплен, тем точнее будет выполнен прогноз на основе модели.

Результаты прогноза периода стойкости инструмента могут быть использованы системой инструментального шкафа «ToolCabinet» для

планирования закупок инструмента в соответствии с планом производства продукции, параметрами технологических операций, параметрами металлорежущего инструмента.

### Библиографические ссылки

1. Райхельсон В. А. Обработка резанием сталей, жаропрочных и титановых сплавов с учетом их физико-механических свойств : монография. М. : Техносфера, 2018. 508 с.
2. Бибик В. Л. Методы прогнозирования стойкости режущих инструментов // *Фундаментальные исследования*. 2011. № 12-1. С. 81–84.
3. Сидорова Е. В. Прогнозирование стойкости твердосплавной режущей пластины с PVD-покрытием // *Прогрессивные технологии и системы машиностроения*. 2016. № 4 (55). С. 80–85.
4. Дядюра К. А., Нагорный В. В. Прогнозирование фактического ресурса режущего инструмента // *Вибрация машин: измерение, снижение, защита*. 2011. № 2. С. 20–25.
5. Абдурахманов М. Р., Шанарев А. В. Некоторые вопросы планирования операций обработки резанием // *Современные исследования в сфере естественных, технических и физико-математических наук : сборник трудов конференции*. Киров, 2018. С. 554–558.

6. Николенко С., Кадури А., Архангельская Е. Глубокое обучение. СПб. : Питер, 2018. 480 с.

7. Goodfellow I., Bengio Y., Courville A. Deep learning. Cambridge, USA: MIT Press, 2016. URL: <http://www.deeplearningbook.org> (дата обращения: 01.06.2020).

8. Хайкин С. Нейронные сети: полный курс. М. : Вильямс, 2006. 1104 с.

9. Чуранкин В. Г., Медведев И. Д., Малахов И. И. Перспективы применения электронных инструментальных шкафов в ОАО «Омском моторостроительном КБ» // Информационные технологии в науке и производстве : сборник трудов конференции. Омск, 2015. С. 191–196.

10. Deep Learning for Java. URL: <http://www.DeepLearning4j.org> (дата обращения: 01.06.2020).

11. ООО «Элин». URL: <https://elin.tiu.ru> (дата обращения: 01.06.2020).

### References

1. Raikhelson V.A. *Obrabotka rezaniem stalei, zharoprochnykh i titanovykh splavov s uchetom ikh fiziko-mekhanicheskikh svoystv* [Cutting of steels, heat-resistant and titanium alloys, taking into account their physical and mechanical properties]. Moscow: Tekhnosfera Publ., 2018, 508 p. (in Russ.).

2. Bibik V.L. [Metall-cutting tool life forecasting methods]. *Fundamental'nye issledovaniya*. 2011, no. 12-1, pp. 81-84 (in Russ.).

3. Sydorova E.V. [Prediction of tool life of the carbide cutting insert with PVD-coating]. *Progressivnye tekhnologii i sistemy mashinostroeniya*. Donetsk, 2016, no. 4 (55), pp. 80-85 (in Russ.).

4. Dyadyura K.A., Nagornyi V.V. *Prognozirovanie fakticheskogo resursa rezhushchego instrumenta* [Pre-

dicting the actual life of the cutting tool]. *Vibratsiya mashin: izmerenie, snizhenie, zashchita*. Donetsk, 2011, no. 2, pp. 20-25 (in Russ.).

5. Abdurakhmanov M.R., Shaparev A.V. *Nekotorye voprosy planirovaniya operatsii obrabotki rezaniem* [Some questions about planning cutting operations]. *Sovremennye issledovaniya v sfere estestvennykh, tekhnicheskikh i fiziko-matematicheskikh nauk: sbornik trudov konferentsii* [Proc. Modern research in the field of natural, technical and physical and mathematical sciences: the conference proceedings]. Kirov, 2018, pp. 554-558 (in Russ.).

6. Nikolenko S., Kadurin A., Arkhangel'skaya E. *Glubokoe obuchenie* [Deep learning]. Saint Petersburg: Piter Publ., 2018. 480 p. (in Russ.).

7. Goodfellow I., Bengio Y., Courville A. *Deep learning*. Cambridge, USA: MIT Press, 2016. Available at: <http://www.deeplearningbook.org> (accessed 01.06.2020).

8. Haykin S. *Neironnye seti: polnyi kurs* [Neural Networks: A Comprehensive Foundation]. Moscow: Vil'yams Publ., 2006. 1104 p. (in Russ.).

9. Churankin V.G., Medvedev I.D., Malakhov I.I. *Perspektivy primeneniya elektronnykh instrumental'nykh shkafov v OAO "Omskom motorostroitel'nom KB"* [Prospects for the use of electronic tool cabinets in JSC "Omsk engine-building design bureau"]. *Informatsionnye tekhnologii v nauke i proizvodstve: sbornik trudov konferentsii* [Proc. Information technologies in science and production: the conference proceedings]. Omsk, 2015, pp. 191-196 (in Russ.).

10. Deep Learning for Java. Available at: <http://www.DeepLearning4j.org> (accessed 01.06.2020).

11. Elin Ltd. Available at: <https://elin.tiu.ru> (accessed 01.06.2020).

\*\*\*

### Predicting the Durability Period of a Metal Cutting Tool Based on a Neural Network

A.V. Korobeynikov, PhD in Engineering, Associate Professor, Kalashnikov ISTU, Izhevsk, Russia

A.F. Mkrtchyan, PhD in Engineering, Kalashnikov ISTU, Izhevsk, Russia

V.V. Sitnikov, Post-graduate, Kalashnikov ISTU, Izhevsk, Russia

A.V. Nagovitsyn, Master's Degree Student, Kalashnikov ISTU, Izhevsk, Russia

The work is aimed at forecasting the period of metal cutting tool durability at specified parameters of the cutting mode. To solve the task, it is proposed to use a neural network model. A multilayer perceptron is suggested to be used as a neural network structure. The accumulated statistical data of the "ToolCabinet" system serve as a training sample when teaching the neural network model of forecasting. Input data of the neural network are the values of the cutting mode parameters (the type of the workpiece material, the value of the cutting depth during the technological operation, the value of feed during the technological operation, the value of the cutting speed) and values of the metal cutting insert design parameters specified on the insert marking according to ISO 1832-85. Software implementation of the proposed neural network is performed using the machine learning library "DeepLearning4J".

At training of a neural network 5 training sub-samples were formed, each containing 20 % of the quantity of samples in the training set. The method of cross-checking was used to solve the problem of neural network retraining. We used a training sample with the total number of 500 records for a set of metal cutting tools consisting of 10 inserts. The experiments have shown the operability of the proposed approach. The work presents graphs showing the dependence of the predicted durability period on one of the cutting mode parameters.

The aim of the work is to increase the efficiency of metal cutting tool procurement planning.

**Keywords:** tool durability period, neural network forecasting, multi-layer perceptron.

Получено 03.09.2020