

УДК 004.896

DOI: [10.26102/2310-6018/2021.35.4.014](https://doi.org/10.26102/2310-6018/2021.35.4.014)

Применение двунаправленных сетей долгой краткосрочной памяти для определения износа режущего инструмента станков с числовым программным управлением в процессе эксплуатации

К.А. Масалимов

*Уфимский государственный авиационный технический университет,
Уфа, Российская Федерация*

Резюме. В процессе эксплуатации станков с числовым программным управлением (ЧПУ) контролируется достаточно большое число параметров, в том числе положение и параметры используемого оборудования, температура узлов станка, показания с датчиков вибрации и силы. Однако есть ряд параметров, значение которых нельзя отследить в ходе процесса производства с использованием станка. Одним из таких параметров является величина износа инструмента резания, которая может быть измерена лишь в периоды простоя станочного оборудования. При этом износ инструмента существенно влияет на качество результирующей поверхности. Эксплуатация инструмента с большим износом приводит к увеличению вибрации, шума, дополнительной нагрузке на другие узлы станка. Для решения проблемы оценки состояния износа инструмента резания имеет смысл использовать доступную оперативную информацию в качестве индикатора величины износа. В статье предложена реализация такого подхода путем оценки величины износа инструмента резания по данным вибрации шпинделя и сил резания. Для фиксации этой зависимости предложено использовать двунаправленные сети долгой краткосрочной памяти, поскольку этот тип нейронных сетей является одним из наиболее эффективных в задаче обработки данных больших временных рядов, проведено обучение и верификация нейронных сетей. Путем проверки на тестовой выборке выяснено, что предложенная модель позволяет определять износ инструмента с точностью 97.5 %, проведено сравнение показателей точности с другими известными в литературе методами оценки износа на основе технологий машинного обучения. Предложенный подход и модель оценки износа инструмента резания могут быть использованы в составе систем управления станков с ЧПУ.

Ключевые слова: станки с ЧПУ, фрезерование, нейронные сети долгой краткосрочной памяти, диагностика в процессе эксплуатации, износ инструмента резания, вибрация, сила резания.

Благодарности: Исследования проведены при финансовой поддержке Министерства науки и высшего образования РФ в рамках проекта 0838-2020-0006 «Фундаментальные исследование новых принципов создания перспективных электромеханических преобразователей энергии с характеристиками выше мирового уровня, с повышенной эффективностью и минимальными удельными показателями, с использованием новых высокоэффективных электротехнических материалов».

Для цитирования: Масалимов К.А. Применение двунаправленных сетей долгой краткосрочной памяти для определения износа режущего инструмента станков с числовым программным управлением в процессе эксплуатации. *Моделирование, оптимизация и информационные технологии.* 2021;9(4). Доступно по: <https://moitvvt.ru/ru/journal/pdf?id=1058> DOI: 10.26102/2310-6018/2021.35.4.014

Application of bidirectional long short-term memory neural networks to determine cutting tool wear for machines with computer numerical control in operation mode

К.А. Масалимов

*Ufa State Aviation Technical University,
Ufa, Russian Federation*

Abstract. During the operation of machines with Computer Numerical Control (CNC), a plenty large enough number of parameters are controlled, including the position and parameters of the equipment used, the temperature of the machine components, readings from vibration, and force sensors. However, several parameters cannot be detected during the manufacturing process using the machine. One of these parameters is the amount of wear on the cutting tool, which can be measured only during periods of idle time of the machine tool. Tool wear significantly affects the quality of the resulting surface. The tool operation with high runout leads to vibration amplification, noise, and additional load of other machine units. To solve the problem of assessing the state of wear of a cutting tool, it makes sense to use the available operational information as the rate of wear indicator. The article proposes the realization of such an approach by assessing the amount of wear of the cutting tool according to the spindle and cutting forces vibration data. It was proposed to use bidirectional networks of long short-term memory to forecast this dependence since this type of neural network is one of the most effective in the problem of processing massive time-series data. By checking the trained model on a test dataset, it was found that the proposed model makes it possible to determine tool wear with an accuracy of 97.5 %. The proposed approach and model for assessing the wear of the cutting tool can be used as part of control systems for CNC machines.

Keywords: CNC machines, milling, long short-term memory, diagnostic in operation mode, cutting tool wear, vibration, cutting force

Acknowledgments: This work was supported by the Ministry of Education of the Russian Federation, project 0838-2020-0006 «Fundamental study of new principles for the creation of promising electromechanical energy converters with characteristics above the world level, with increased efficiency and minimum specific indicators, using new highly efficient electrotechnical materials».

For citation: Masalimov K.A. Application of Bidirectional Long Short-Term Memory Neural Networks to Determine Cutting Tool Wear for Machines with Computer Numerical Control in Operation Mode. *Modeling, Optimization and Information Technology*. 2021;9(4). Available from: <https://moitvvt.ru/ru/journal/pdf?id=1058> DOI: 10.26102/2310-6018/2021.35.4.014 (In Russ).

Введение

Современному машиностроению и эксплуатации металлорежущего оборудования присуща высокая степень информатизации и автоматизации технологических процессов. Непосредственно в ходе технологической эксплуатации металлорежущего оборудования состояние инструмента резания играет одну из ключевых ролей в получении требуемого качества поверхности детали [1]. Соответственно диагностика и мониторинг состояния инструмента резания позволяют уменьшить число брака при обработке деталей и представляет собой одну из сложных задач в ходе цикла технологической обработки.

Основной величиной, характеризующей состояние инструмента резания, служит его износ [2]. Однако, с точки зрения эксплуатации инструмента резания, не всегда важна абсолютная величина износа, а достаточно определить возможности его дальнейшего использования без возникновения брака и отказов.

На сегодняшний день наиболее распространенными, с точки зрения обслуживания и ремонта металлорежущего оборудования, в том числе и инструмента резания, выступают три подхода [3]:

1. Периодическая плановая проверка состояния деталей металлорежущего оборудования через определенные регламентированные интервалы времени, обычно определяемые по времени среднестатистической наработки на отказ (наиболее распространенный подход).

2. Обслуживание по событию, характеризующемуся эксплуатацией деталей оборудования по времени их максимальной работоспособности, т. е. до достижения факта поломки. Как правило, эксплуатация оборудования по такому принципу подразумевает определенный простой оборудования при его ремонте.

3. Обслуживание оборудования по актуальному состоянию (работоспособности); этот подход связан с оценкой технологического состояния оборудования лицом, его эксплуатирующим, или автоматизированной системой управления в ходе технологического процесса по показаниям с датчиков. Для него характерны минимальные время простоя, затрат на ремонт. Однако по отношению к состоянию инструмента резания данный принцип слабо применим вследствие отсутствия подходящей для оценки сенсорной информации.

Следует также отметить, что переход машиностроительных предприятий к реализации принципов «Industry 4.0» (Четвертой промышленной революции) сопровождается выработкой требований по повышению качества и скорости принимаемых решений [4]. Одну из методик, позволяющих выполнить эти требования, представляет собой концепция так называемых цифровых двойников [5].

Цифровые двойники – достаточно широкое понятие, подразумевающее создание программного аналога физического оборудования для моделирования технических и эксплуатационных характеристик, поведения оборудования в ходе технологического процесса. Это понятие, кроме создания моделей непосредственно оборудования, также означает и частное моделирование определенного числа технологических параметров оборудования. Для реализации подобных моделей используют различные методы, в том числе и методы машинного обучения.

Анализ существующих решений по определению оперативного состояния инструмента резания

Износ инструмента резания характеризует его состояние. Непосредственно величину износа можно оценить визуально с использованием измерительного оборудования, что требует затрат времени, сопровождаемых простоем оборудования.

В последние десять лет получил распространение и другой подход к определению состояния инструмента резания, а именно применение доступной сенсорной информации в качестве побочного признака, позволяющего определить как возможность дальнейшей эксплуатации, так и предполагаемую величину его износа. Ввиду изменчивости технологических требований, условий эксплуатации и параметров окружающей среды, формулировка строгой математической модели определения состояния инструмента резания невозможна. Использование технологии машинного обучения и, в частности, применение глубоких нейронных сетей позволяет выйти из этой ситуации.

Существует ряд работ, в которых описана методика оценки состояния инструмента резания по сигналам с датчиков вибрации, силы, шума и обработки графической информации. Экспериментальная оценка влияния изменения скорости резания и амплитуды вибрации на интенсивность износа инструмента резания приведена

в статье [6]. В статье [7] описывается реализация оценки остаточного срока эксплуатации инструмента резания на основе фиксируемых в ходе фрезерной обработки данных с использованием дерева решений и гибридного классификатора на основе рекуррентной машины Больцмана.

Определение состояния инструмента резания по графической информации продемонстрировано в работах [8, 9]. Однако такой метод позволяет проводить оценку только в периоды, когда обработку не производят, и требует оснащения станка средствами фиксации визуальной информации.

В работах [10, 11] показано применение нечетких нейронных сетей для оценки величины износа по значениям с датчиков вибрации силы, выполнено сравнение точности моделей на базе нечетких нейронных сетей с моделями RBF (Radial Basis Function), многослойного персептрона, мультирегрессионных моделей. В результате продемонстрировано, что точность оценки износа инструмента резания моделями на базе нечетких нейронных сетей является наиболее высокой и составляет порядка 90 %.

В данной статье предложены варианты реализации модели оценки состояния износа инструмента резания с использованием рекуррентных нейронных сетей долгой краткосрочной памяти (Long Short-Term Memory – LSTM).

Двунаправленная нейронная сеть долгой краткосрочной памяти

Нейронные сети долгой краткосрочной памяти находят применение при реализации функций классификации и прогнозирования временного ряда в случаях, когда границы событий в исследуемой системе не определены строго и зависимость одних событий от других разделена определенным временным промежутком. LSTM сеть способна запоминать зависимости как на коротком промежутке, так и на длительном благодаря включению в свой состав «вентилей забывания». Один узел подобной нейронной сети – блок, включающий в себя несколько вентилях, каждый из которых выполняет свою функцию. Схема соединения вентилях одного элемента LSTM сети и то, как они взаимодействуют, представлено на Рисунке 1.

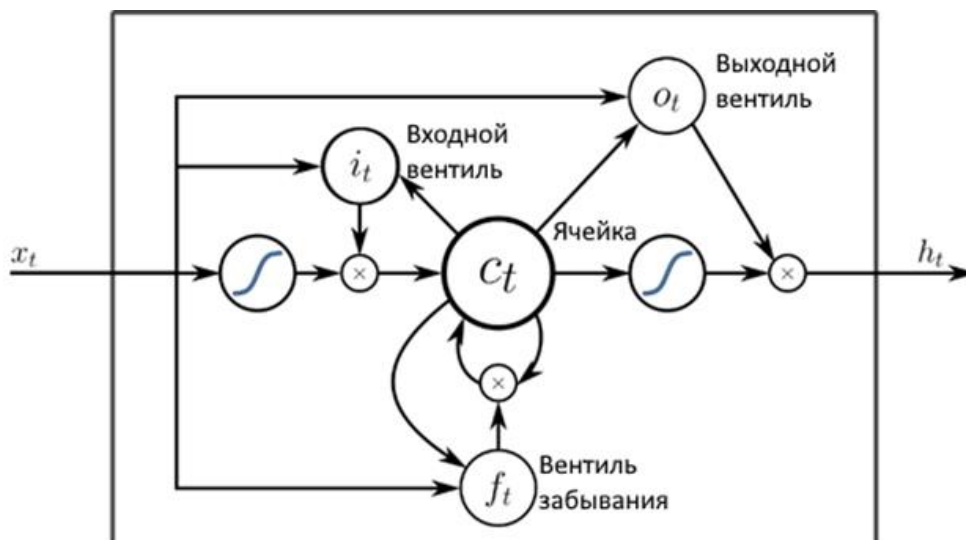


Рисунок 1 – Схема соединения вентилях одного элемента LSTM сети
 Figure 1 – Connection diagram of gates of one element of LSTM network

В ходе своей работы LSTM сеть дискретно выполняет обновление некоторого внутреннего векторного представления h^t , с размерностью, равной количеству элементов сети на базе следующей информации:

- вентиля входных данных i^t ;
- вентиля выходных данных o^t ;
- вентиля забывания (исключения незначимых признаков) f^t ;
- внутренней ячейки (узла) памяти c^t ;
- внутреннего представления h^{t-1} в прошлый дискретный момент времени.

Система уравнений (1) отображает, как выполняется обновление состояния векторов LSTM сети, в том числе и значений внутреннего представления h^t :

$$\begin{aligned} i^t &= \text{sigm}(W^i x^t + V^i h^{t-1} + b^i), \\ f^t &= \text{sigm}(W^f x^t + V^f h^{t-1} + b^f), \\ o^t &= \text{sigm}(W^o x^t + V^o h^{t-1} + b^o), \\ c^t &= f^t \odot c^{t-1} + i^t \odot \tanh(W^c x^t + V^c h^{t-1} + b^c), \\ h^t &= o^t \odot \tanh(c^t), \end{aligned} \quad (1)$$

где \odot – произведение Адамара или поэлементное произведение двух матриц, \tanh и sigm – функции активации вентилях, гиперболический тангенс и сигмоидная функция соответственно.

В процессе обучения LSTM сети методом градиентного спуска выполняется подбор значений матриц параметров $W \in \mathbb{R}^{d \times k}$, $V \in \mathbb{R}^{d \times d}$ и вектора параметров $b \in \mathbb{R}^d$.

Недостатком простых LSTM сетей является рассмотрение значений временных рядов лишь в обратном направлении (от текущего состояния к начальному). При диагностике состояния сложных объектов последовательные данные с датчиков имеют устойчивые временные зависимости, и при построении моделей целесообразно учитывать не только прямую зависимость значения, но также и обратную. Решению этой задачи содействует исследование двунаправленной рекуррентной нейронной сети долгой краткосрочной памяти (Bidirectional Long Short-Term Memory – BiLSTM). BiLSTM сети [12] способны обрабатывать данные входного временного ряда в двух направлениях – прямом и обратном (для каждого направления служит свой скрытый слой нейронной сети), а затем передавать их выходной слой линейной регрессии. Следующие уравнения определяют соответствующую функцию скрытого слоя, знаки \rightarrow и \leftarrow обозначают, соответственно, прямой и обратный процессы.

Таким образом, система уравнений характеризует скрытый слой для прямой LSTM сети:

$$\begin{aligned} \vec{i}^t &= \text{sigm}(\vec{W}^i \vec{x}^t + \vec{V}^i \vec{h}^{t-1} + \vec{b}^i), \\ \vec{f}^t &= \text{sigm}(\vec{W}^f \vec{x}^t + \vec{V}^f \vec{h}^{t-1} + \vec{b}^f), \\ \vec{o}^t &= \text{sigm}(\vec{W}^o \vec{x}^t + \vec{V}^o \vec{h}^{t-1} + \vec{b}^o), \\ \vec{c}^t &= \vec{f}^t \odot \vec{c}^{t-1} + \vec{i}^t \odot \tanh(\vec{W}^c \vec{x}^t + \vec{V}^c \vec{h}^{t-1} + \vec{b}^c), \\ \vec{h}^t &= \vec{o}^t \odot \tanh(\vec{c}^t). \end{aligned}$$

Система уравнений характеризует скрытый слой для обратной LSTM сети:

$$\begin{aligned} \tilde{i}^t &= \text{sigm}(\tilde{W}^i \tilde{x}^t + \tilde{V}^i \tilde{h}^{t-1} + \tilde{b}^i), \\ \tilde{f}^t &= \text{sigm}(\tilde{W}^f \tilde{x}^t + \tilde{V}^f \tilde{h}^{t-1} + \tilde{b}^f), \\ \tilde{o}^t &= \text{sigm}(\tilde{W}^o \tilde{x}^t + \tilde{V}^o \tilde{h}^{t-1} + \tilde{b}^o), \\ \tilde{c}^t &= \tilde{f}^t \odot \tilde{c}^{t-1} + \tilde{i}^t \odot \tanh(\tilde{W}^c \tilde{x}^t + \tilde{V}^c \tilde{h}^{t-1} + \tilde{b}^c), \\ \tilde{h}^t &= \tilde{o}^t \odot \tanh(\tilde{c}^t). \end{aligned}$$

Тогда полное представление скрытого слоя BiLSTM сети имеет вид конкатенации векторов прямого и обратного процессов: $h^t = \vec{h}^t \cdot \tilde{h}^t$.

Описание исходных данных и постановка задачи оценки износа

В качестве исходных данных при разработке диагностических моделей использованы результаты обработки детали на высокоскоростном станке с ЧПУ модели RödgersTech RFM760 (Рисунок 2).



Рисунок 2 – Общий вид станка модели Rödgers Tech RFM760
Figure 2 – CNC Machine Rödgers Tech RFM760

Станок дополнительно оснащен датчиками вибрации, фиксирующими показания по трем осям, и трехосевым платформенным динамометром, установленным между обрабатывающим столом и заготовкой, для измерения значений сил резания. Схема экспериментальной установки приведена на Рисунке 3.

Инструмент резания – резец из карбида вольфрама с тремя режущими кромками. Для оценки величины износа инструмента применен микроскоп мод. LEICA MZ12. В качестве обрабатываемого материала использована нержавеющую сталь твердости 52HRC.

Параметры процесса фрезерования:

- скорость вращения шпинделя – 10400 мин⁻¹;
- скорость подачи – 1555 мм/мин;
- радиальная глубина резания (ось Y) – 0,125 мм;
- осевая глубина резания (ось Z) – 0,2 мм.

Данные с датчиков вибрации и динамометра получены с частотой дискретизации 50 кГц.

Обработка проведена с использованием шести резцов. В ходе обработки для каждого резца многократно (более 300 раз) зафиксированы показания с датчиков вибрации и силы, и итоговая величина износа каждой режущей кромки после очередного перехода фрезерования. Переходы фрезерования проведены с одинаковой длиной резания, т. е. путь резания был константой.




Рисунок 3 – Схема экспериментальной установки
Figure 3 – Experimental setup elements

На Рисунке 4 показана зависимость величины износа h каждой режущей кромки одного из резцов от увеличения числа переходов фрезерования.




Рисунок 4 – Зависимость износа h каждой (1, 2 и 3) режущей кромки одного из резцов фрезы от увеличения числа переходов фрезерования

Figure 4 – Dependence of the wear h of each (1, 2 and 3) cutting edge of one of the cutter cutters on the increase in the number of milling transitions

Задача оценки износа сформулирована следующим образом: по значениям с датчиков вибрации и силы необходимо оценить, сколько еще переходов обработки возможно провести с использованием резца – остаточный срок эксплуатации. При этом ограничения определены следующим образом – резец считается пригодным для дальнейшей обработки, если износ любой из режущих кромок не превышает значения $165 \cdot 10^{-3}$ мм.

Функция оценки предсказанного значения диагностических моделей:

$$S(d) = \begin{cases} e^{-d/10} - 1, & \text{если } d < 0 \\ e^{d/4.5} - 1, & \text{если } d \geq 0 \end{cases},$$

$$d = c_M - c_F,$$

где c_M – значение остаточного срока эксплуатации, предсказанное моделью, c_F – значение остаточного срока фактическое, d – погрешность предсказания модели. Следует также обратить внимание, что функция оценки задана таким образом, что завышенная оценка остаточного срока эксплуатации имеет большее значение экспоненциального штрафа.

Диагностическая модель для оценки износа инструмента на базе BiLSTM

Результаты экспериментов разбиты на две основные выборки. Данные, полученные в ходе обработки тремя резцами, использованы в процессе обучения диагностической модели. Данные, полученные в ходе обработки другими тремя резцами, применены для тестирования итоговой модели.

В качестве входных данных для нейросетевой модели использованы значения вибрации и силы резания по трем осям; в качестве выходных данных – предполагаемое значение максимального износа любой из кромок резца. Для обеспечения оптимального обучения модели проведена нормализация данных временного ряда значений вибрации и силы:

$$v_{ni} = \frac{v_i}{H_{max} - H_{min}},$$

где v_{ni} – нормализованное значение, v_i – фактическое значение, полученное с датчика, H_{max} и H_{min} – верхний и нижний пределы измерения датчика.

Обучение и тестирование диагностических моделей проведено с использованием пакета Keras. Выполнены обучение и сопоставление диагностических моделей с применением следующих архитектур нейронных сетей, к которым относятся: нечеткие нейронные сети (Fuzzy Neural Networks – FNN); сверточные нейронные сети (Convolutional Neural Networks – CNN); LSTM; BiLSTM.

Для LSTM сети в первом скрытом слое использованы 100 нейронов и 1 нейрон в выходном слое. Функция потерь – среднеквадратичная ошибка, алгоритм обучения – оптимизированный алгоритм Адама для стохастического градиентного спуска.

BiLSTM нейронная сеть включает в себя две LSTM сети (по 100 нейронов в скрытом слое и 1 нейрону в выходном), отличающиеся направлением входного временного ряда, и полносвязный слой для объединения результатов с одним выходным нейроном. Результаты обучения и тестирования моделей представлены в Таблице 1.

Таблица 1 – Сравнительная характеристика моделей предсказания износа инструмента резания по показаниям с датчиков вибрации и силы

Table 1 – Comparative characteristics of models for predicting cutting tool wear based on data from vibration and force sensors

Диагностическая модель	Архитектура нейронных сетей			
	FNN	CNN	LSTM	BiLSTM
Коэффициент скорости обучения	0,3	0,3	0,4	0,4
Число эпох обучения	1000	1000	800	800
Среднеквадратичная ошибка (по выходному значению износа резца)	$0,4 \cdot 10^{-4}$	$0,87 \cdot 10^{-5}$	$0,29 \cdot 10^{-5}$	$0,92 \cdot 10^{-6}$
Значение функции оценки на тестовой выборке (итоговое)	1200	420	304	265

На Рисунке 5 показаны результирующие зависимости износа (максимального значения износа любой из кромок) резца от числа переходов фрезерования, полученные по фактическим данным и значениям износа, предсказанным диагностической моделью на базе двунаправленной РНСДКП для одного из тестовых резцов. Отклонения зависимостей находятся в пределах 2,5 %.

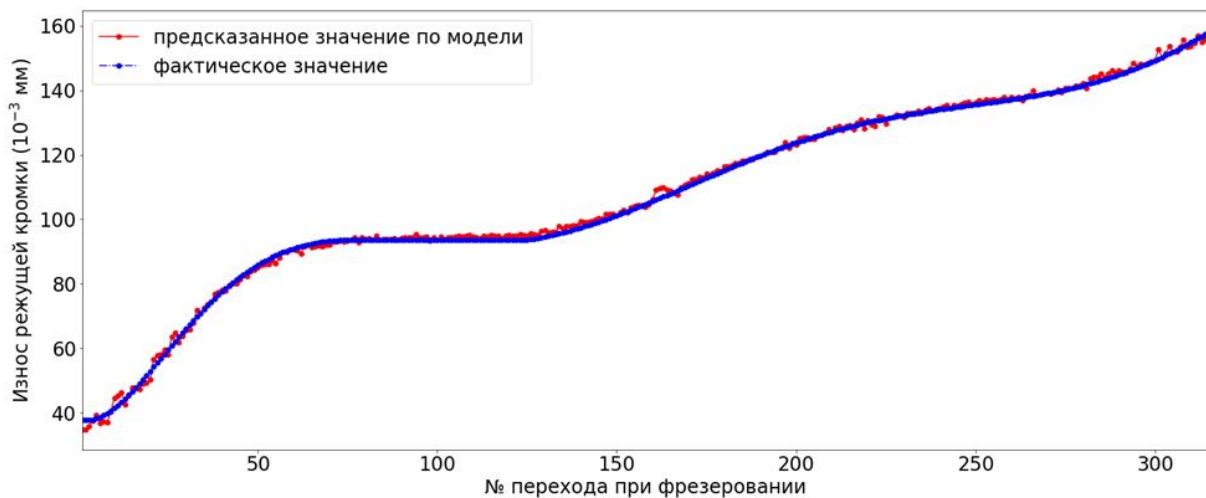


Рисунок 5 – Износ h резца фрезы: фактический и предсказанный диагностической моделью на базе BiLSTM

Figure 5 – Cutting tool wear h : actual and predicted by the BiLSTM diagnostic model

Следовательно, предложенная диагностическая модель на базе BiLSTM нейронной сети достаточно точно определяет значение износа по информации, полученной с датчиков вибрации и силы и может быть использована для оценки износа инструмента резания оперативной эксплуатации станка.

Заключение

Представленный в статье способ диагностики состояния режущего инструмента металлорежущего станка позволяет определить износ по косвенным признакам, получаемым на основе информации с датчиков вибрации и силы.

В статье описана архитектура предлагаемой диагностической модели на базе нейронных сетей типа LSTM, проведена сравнительная характеристика с диагностическими моделями на основе других классов нейронных сетей. Подтверждено, что BiLSTM сети достаточно точно позволяют оценить предполагаемый износ режущего инструмента. Использование подобных диагностических систем в составе систем управления и контроля станков обеспечивает оптимизацию технологических процессов обработки и уменьшение длительности вынужденных простоев.

СПИСОК ИСТОЧНИКОВ

1. Ивашенко А.П. Методы и средства контроля состояния режущего инструмента. *Международный журнал прикладных и фундаментальных исследований*. 2015;12(3):393–396.
2. Масалимов К.А., Мунасыпов Р.А., Фецак С.И., Кудояров Р.Г. Диагностика состояния режущего инструмента металлорежущих станков с использованием двунаправленных рекуррентных нейронных сетей с долгой краткосрочной памятью. *Научно-технический журнал СТИН*. 2020;12:12–16.
3. Иванов В.А., Фещенко А.А. Особенности подходов к техническому обслуживанию и ремонту оборудования в непрерывном производстве. *Вестник Пермского национального исследовательского политехнического университета. Машиностроение, материаловедение*. 2018;20(3):82–89.
4. Фомина А.В., Мухин К.Ю. Индустрия 4.0. Основные понятия, преимущества и проблемы. *Экономический вектор*. 2018;3(14):33–38.
5. Кокорев Д.С., Юрин А.А. Цифровые двойники: понятие, типы и преимущества для бизнеса. *Colloquium-journal*. 2019;10(34):31–35. DOI: <https://www.doi.org/10.24411/2520-6990-2019-10264>
6. Omelchak A., Fecak S.I., Idrisova U.V. Dynamic Processes in a Machine-Tool at High-Speed. *DAAAM International Scientific Book*. 2016:175–182.
7. Li Guofa et al. Tool wear state recognition based on gradient boosting decision tree and hybrid classification RBM. *The International Journal of Advanced Manufacturing Technology*. 2020;110:511–533. DOI: <https://doi.org/10.1007/s00170-020-05890-x>
8. Bergs Thomas et al. Digital image processing with deep learning for automated cutting tool wear detection. *Procedia Manufacturing*. 2020;48:947–958. DOI: <https://doi.org/10.1016/j.promfg.2020.05.134>
9. Oo HtunHtun et al. Tool wear monitoring system in belt grinding based on image-processing techniques. *The International Journal of Advanced Manufacturing Technology*. 2020;111:2215-2229. DOI: <https://doi.org/10.1007/s00170-020-06254-1>
10. Lin Cheng-Jian et al. Using an Interval Type-2 Fuzzy Neural Network and Tool Chips for Flank Wear Prediction. *IEEE Access*. 2020;8:122626–122640. DOI: <https://doi.org/10.1109/ACCESS.2020.3006849>
11. Gajewski Jakub et al. Classification of wear level of mining tools with the use of fuzzy neural network. *Tunnelling and Underground Space Technology*. 2013;35:30–36. DOI: <https://doi.org/10.1016/J.TUST.2012.12.002>
12. Siami-Namini Sima et al. The Performance of LSTM and BiLSTM in Forecasting Time Series. *2019 IEEE International Conference on Big Data (Big Data)*. 2019:3285–3292. DOI: <https://doi.org/10.1109/BigData47090.2019.9005997>

REFERENCES

1. Ivashchenko A.P. Metody i sredstva kontrolya sostoyaniya rezhushchego instrumenta. *Mezhdunarodnyj zhurnal prikladnyh i fundamental'nyh issledovaniy*. 2015;12(3):393–396. (In Russ.)
2. Masalimov K.A., Munasyrov R.A., Fecak S.I., Kudoyarov R.G. Diagnostika sostoyaniya rezhushchego instrumenta metallorezhushchih stankov s ispol'zovaniem dvunapravlennyh rekurrentnyh nejronnyh setej s dolgoj kratkosrochnoj pamyat'yu. *Nauchno-tehnicheskij zhurnal STIN*. 2020;12:12–16. (In Russ.)
3. Ivanov V.A., Feshchenko A.A. Osobennosti podhodov k tekhnicheskomu obsluzhivaniyu i remontu oborudovaniya v nepreryvnom proizvodstve. *Vestnik Permskogo nacional'nogo issledovatel'skogo politekhnicheskogo universiteta. Mashinostroenie, materialovedenie*. 2018;20(3):82–89. (In Russ.)
4. Fomina A.V., Muhin K.Yu. Industriya 4.0. Osnovnye ponyatiya, preimushchestva i problemy. *Ekonomicheskij vektor*. 2018;3(14):33–38. (In Russ.)
5. Kokorev D.S., Yurin A.A. Cifrovye dvojniki: ponyatie, tipy i preimushchestva dlya biznesa. *Colloquium-journal*. 2019;10(34):31–35. DOI: <https://www.doi.org/10.24411/2520-6990-2019-10264>. (In Russ.)
6. Omelchak A., Fecak S.I., Idrisova U.V. Dynamic Processes in a Machine-Tool at High-Speed. *DAAAM International Scientific Book*. 2016:175–182.
7. Li, Guofa et al. Tool wear state recognition based on gradient boosting decision tree and hybrid classification RBM. *The International Journal of Advanced Manufacturing Technology*. 2020;110:511–533. DOI: <https://doi.org/10.1007/s00170-020-05890-x>
8. Bergs, Thomas et al. Digital image processing with deep learning for automated cutting tool wear detection. *Procedia Manufacturing*. 2020;48:947–958. DOI: <https://doi.org/10.1016/j.promfg.2020.05.134>
9. Oo, HtunHtun et al. Tool wear monitoring system in belt grinding based on image-processing techniques. *The International Journal of Advanced Manufacturing Technology*. 2020;111:2215–2229. DOI: <https://doi.org/10.1007/s00170-020-06254-1>
10. Lin, Cheng-Jian et al. Using an Interval Type-2 Fuzzy Neural Network and Tool Chips for Flank Wear Prediction. *IEEE Access*. 2020;8:122626–122640. DOI: <https://doi.org/10.1109/ACCESS.2020.3006849>
11. Gajewski, Jakub et al. Classification of wear level of mining tools with the use of fuzzy neural network. *Tunnelling and Underground Space Technology*. 2013;35:30–36. DOI: <https://doi.org/10.1016/J.TUST.2012.12.002>
12. iami-Namini, Sima et al. The Performance of LSTM and BiLSTM in Forecasting Time Series. *2019 IEEE International Conference on Big Data (Big Data)*. 2019:3285–3292. DOI: <https://doi.org/10.1109/BigData47090.2019.9005997>

ИНФОРМАЦИЯ ОБ АВТОРАХ / INFORMATION ABOUT THE AUTHORS

Масалимов Камил Адипович, младший научный сотрудник, Уфимский государственный авиационный технический университет, Уфа, Российская Федерация.
e-mail: masalimov.ka@gmail.com
ORCID: [0000-0001-8123-7963](https://orcid.org/0000-0001-8123-7963)

Kamil A. Masalimov, Junior Researcher, Ufa State Aviation Technical University, Ufa, Russian Federation.

*Статья поступила в редакцию 10.06.2021; одобрена после рецензирования 19.10.2021;
принята к публикации 25.11.2021.
The article was submitted 10.06.2021; approved after reviewing 19.10.2021;
accepted for publication 25.11.2021.*