

Научноёмкие технологии в машиностроении. 2026. №1 (175). С.12-18.

Science intensive technologies in mechanical engineering. 2026. №1 (175). P.12-18.

Научная статья

УДК 621.9.014.5/004.891.2

doi: 10.30987/2223-4608-2026-1-12-18

Повышение эффективности экспериментальных исследований режущих инструментов за счет применения машинного обучения

Андрей Владиславович Савилов¹, к.т.н.

Ева Сергеевна Пидгурская², лаборант

Олег Александрович Русинов³, техник

^{1, 2, 3} Иркутский национальный исследовательский технический университет,
Иркутск, Россия

¹ saw@istu.edu, <https://orcid.org/0000-0003-2028-4162>

² eva.pidgurskaya@bk.ru, <https://orcid.org/0000-0000-0000-0000>

³ rusinova@ex.istu.edu, <https://orcid.org/0000-0000-0000-0000>

Аннотация. Представлены результаты исследования возможностей машинного обучения для повышения эффективности экспериментальных исследований режущих инструментов для обработки титана. В статье рассмотрена проблема снижения расходов при испытании режущих инструментов. Исследования включали в себя как реальные тесты на высокопроизводительном оборудовании, так и прогнозирование наиболее эффективных режимов резания с помощью разработанной программы на языке Python. Эксперименты проводились на фрезерном обрабатывающем центре DMG DMU80P duoBlock. В качестве обрабатываемого материала был использован титановый сплав BT23. Обработка выполнялась фрезами со сменными многогранными пластинами из твердого сплава марки HCS35X. В ходе экспериментов измерялся износ инструмента, и определялась производительность процесса обработки. Измерение износа производилось на приборе для измерения инструмента вне станка Zoller Genius III. Полученные в ходе экспериментов данные использованы в разработанной программе для определения наиболее эффективных режимов резания, обеспечивающих максимальную производительность обработки. Для прогнозирования применялась модель регрессии на основе дерева решений. Проверка прогноза, сгенерированного программой, осуществляется проведением дополнительного теста на рекомендованных режимах резания. Расхождение между прогнозом и экспериментальным результатом составило 14 %. В результате выполненной работы показана возможность сократить количество тестов за счет применения методов машинного обучения. Результаты проведенных исследований могут быть использованы для сокращения затрат при испытаниях режущих инструментов как в лабораторных, так и в производственных условиях. Наибольший эффект может быть достигнут при испытаниях инструментов для обработки труднообрабатываемых материалов. Даны рекомендации по продолжению исследований с увеличением количества данных для машинного обучения и анализом дополнительных факторов, таких как характер износа режущей кромки инструмента.

Ключевые слова: фрезерование, титановый сплав, испытания инструмента, стойкость инструмента, машинное обучение, регрессионная модель

Для цитирования: Савилов А.В., Пидгурская Е.С., Русинов О.А. Повышение эффективности экспериментальных исследований режущих инструментов за счет применения машинного обучения // Научноёмкие технологии в машиностроении. 2026. № 1 (175). С. 12–18. doi: 10.30987/2223-4608-2026-1-12-18

Experimental studies upgrading for cutting tools through computer-aided instructions

Andrey V. Savilov¹, PhD. Eng.

Eva S. Pidgurskaya², laboratory assistant

Oleg A. Rusinov³, technician

^{1, 2, 3} Irkutsk National Research Technical University, Irkutsk, Russia

¹ saw@istu.edu, <https://orcid.org/0000-0003-2028-4162>

² eva.pidgurskaya@bk.ru, <https://orcid.org/0000-0000-0000-0000>

³ rusinova@ex.istu.edu, <https://orcid.org/0000-0000-0000-0000>

Abstract. Findings of possibilities connected with computer-aided instructions applied for experimental studies upgrading for cutting tools for processing titanium are presented. The article discusses the problem of reducing costs when testing cutting tools. The research included both real-world tests on high-performance equipment and predicting the most efficient cutting modes using a developed Python program. The experiments were carried out at the DMG DMU80P duoBLOCK milling processing center. VT23 titanium alloy was used as the processed material. The machining was carried out with milling cutters using interchangeable polyhedral plates made of HCS35X hard alloy. During the experiments, tool wear was measured and the process performance was determined. Wear measurement was performed on a tool measuring device outside the Zoller Genius III machine. The data obtained within experiments were used in the developed program to determine the most effective cutting modes that ensure maximum process performance. A decision tree regression model was used for forecasting. The forecast generated by the program is checked by performing an additional test on the recommended cutting modes. The discrepancy between the forecast and the experimental result was 14 %. The performed work has resulted in the possibility to reduce the number of tests through computer-aided instructions. The results of the conducted research can be used for cost saving when testing cutting tools both in the laboratory and in working conditions. The greatest effect can be achieved when testing tools for working of difficult-to-process materials. Recommendations are given for continuing research with an increase in the amount of data for machine learning and the analysis of additional factors, such as the nature of wear on the cutting edge of the tool.

Keywords: milling, titanium alloy, tool testing, tool durability, computer-aided instruction, regression model

For citation: Savilov A.V., Pidgurskaya E.S., Rusinov O.A. Experimental studies upgrading for cutting tools through computer-aided instructions / Science intensive technologies in mechanical engineering. 2026. № 1 (175). P. 12–18. doi: 10.30987/2223-4608-2026-1-12-18

Введение

Конкурентоспособность современного машиностроительного производства зависит от эффективности процессов механообработки. Повышение производительности процесса резания в значительной степени влияет на снижение технологической себестоимости обрабатываемых деталей и выпускаемой продукции в целом. В свою очередь производительность процесса обработки определяется выбором оптимального режущего и вспомогательного инструмента и назначением оптимальных режимов резания. Процедура выбора оптимального режущего инструмента в настоящее время затруднена общим характером рекомендаций, предлагаемых его производителями. Указанные рекомендации, как правило, не учитывают особенности конкретной технологической системы, что затрудняет их применение в условиях реального производства [1, 2].

Использование имитационного моделирования для определения наилучших параметров обработки также не дает ожидаемого эффекта ввиду сложности учета большого

количества факторов, влияющих на процесс резания [3]. В такой ситуации важную роль играют испытания режущего инструмента в условиях максимально приближенных к производственным. Однако такие испытания требуют значительных материальных и временных затрат. Причем эти затраты резко возрастают при обработке труднообрабатываемых материалов, таких как титан жаропрочные сплавы, материалы высокой твердости [4].

Существующие методы планирования эксперимента вынуждают исследователей проводить большое количество экспериментов, чтобы получить достоверную информацию о работоспособности и стойкости режущего инструмента. Это характерно не только для широко используемых при испытаниях режущих инструментов композиционных и некомпозиционных планов, но и для статистического метода Тагучи [5, 6].

Задача усложняется, если кроме определения технических выходных параметров обработки, требуется проведение технико-экономического анализа инструмента. В этом случае увеличивается как объём входных данных, так

и в целом трудоёмкость обработки полученных результатов.

Одним из перспективных направлений в поиске сокращения затрат при испытании инструмента является внедрение методов искусственного интеллекта (ИИ). Используя некоторые методы ИИ в производственных задачах, к примеру, такой как машинное обучение (МО), представляется возможным решать задачи классификации, регрессии и сегментации [6, 7]. Следует отметить, что сегодня использование МО при испытаниях режущего инструмента находится в начальной стадии. Научные публикации, подтверждающие успешное ИИ при решении данных задач, практически отсутствуют.

В связи с изложенным, снижение затрат и повышение достоверности результатов

испытаний режущих инструментов можно считать актуальной задачей.

Материалы и методы

Экспериментальные исследования проводились в два этапа. На первом этапе были проведены эксперименты на фрезерном обрабатывающем центре DMU80P duoBlock. В качестве обрабатываемого материала был использован титановый сплав VT23. Химический состав материала приведен в табл. 1, а его механические свойства в табл. 2. Заготовки для испытаний представляли собой плиты размером 300×200×100 мм. Установка заготовок осуществлялась непосредственно на столе станка с последующей фиксацией с помощью прихватов.

1. Химический состав в % титанового сплава VT23

1. Chemical formula in percentage term % of VT23 titanium alloy

Fe	C	Si	Cr	Mo	V	N	Ti	Al	Zr	O	H	При- меси
0,4...1	до 0,1	до 0,15	0,8...1,4	1,5...2,5	4,0...5,0	0,05	84,1...9,3	4,0...6,3	0,3	0,15	0,015	0,03

2. Механические свойства титанового сплава VT23

2. Mechanical properties of VT23 titanium alloy

Сортамент	σ_b , МПа	$\sigma_{0,2}$, МПа	δ_5 , %	ψ , %	Твердость, НВ
Лист	1100...1200	1000...1100	7...10	25...30	320...350

Режущий инструмент был представлен фрезами со сменными многогранными пластинами СКИФ-М MT190-025G12R05BD10-ИК с хвостовиком G25-QCH-M12-148C 4470017249. На фрезы были установлены пластины BDMT10T330ER из твердого сплава марки HCS35X. Установка фрезы в шпиндель станка осуществлялась с использованием гидропластового патрона CoroChuck 930-150-HD-32-077. Рабочая зона станка с установленными заготовками и режущим инструментом в шпинделе показана на рис. 1.

Режимы резания для фрезы MT190-025G12R05BD10-ИК приведены в табл. 3.



Рис. 1. Рабочая зона станка DMU80P duoBlock

Fig. 1. Working area of the DMU80P duoBlock machine

3. Режимы резания для фрезы MT190-025G12R05BD10-1K

3. Cutting modes for MT190-025G12R05BD10-1K milling cutter

№ опыта	Скорость резания v , м/мин	Глубина резания t , мм	Ширина резания B , мм	Подача на зуб S_z , мм/зуб
1	30	9	0,5	0,05
2	30			0,095
3	30			0,14
4	45			0,05
5	45			0,095
6	45			0,14
7	60			0,05
8	60			0,095
9	60			0,14

Для определения стойкости производились измерения износа пластин по передней и задней поверхности с использованием прибора для измерения инструмента вне станка Zoller Genius III. Испытания прекращались при достижении величины износа до 0,1 мм по задней поверхности.

Для каждого из 9-ти опытов была рассчитана производительность обработки Q , см³/мин, по формуле

$$Q = \frac{B \cdot t \cdot S_M}{1000}, \quad (1)$$

где B – ширина резания, мм; t – глубина резания, мм; S_M – минутная подача, мм/мин.

Следующим этапом было прогнозирование наиболее эффективных режимов резания, обеспечивающих максимальную производительность обработки. Для реализации данной задачи была разработана программа на языке Python с графическим интерфейсом для работы с данными, полученными во время эксперимента. Блок-схема программы и ее общий вид представлены на рис. 2. Программа представляет собой приложение для работы с Excel и CSV файлами, предварительно заполненными данными в табличном виде.

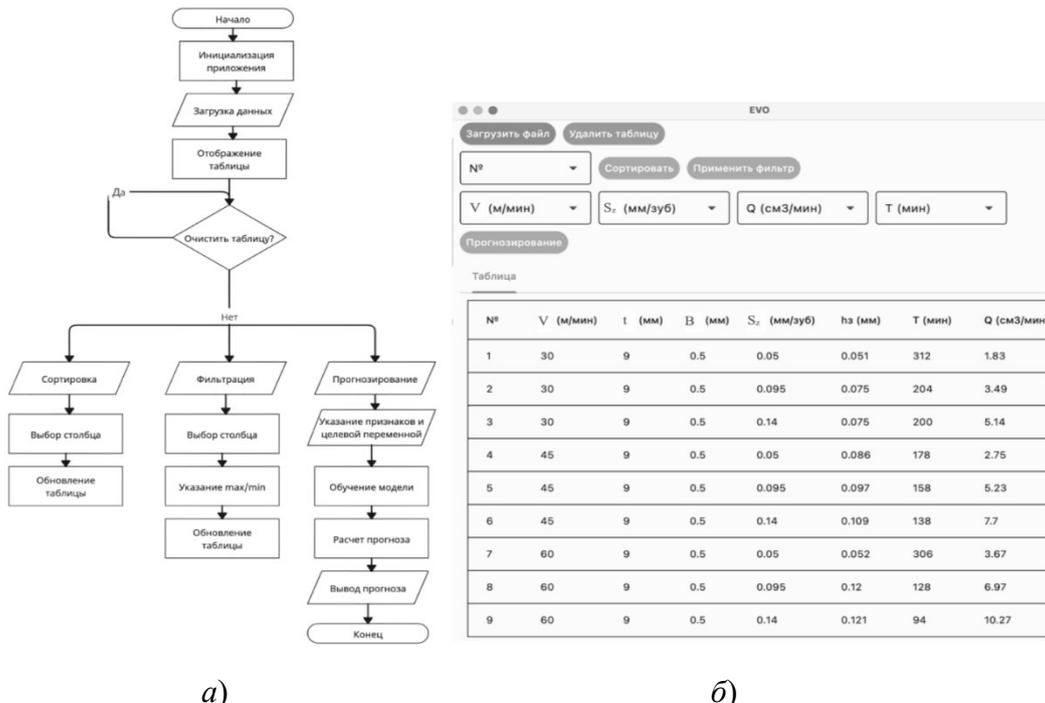


Рис. 2. Программа прогнозирования наиболее эффективных режимов резания: а – блок-схема; б – интерфейс приложения

Fig. 2. The program of forecasting the most effective cutting modes: а – block diagram; б – application interface

Графический интерфейс программы основан на библиотеке Flet. Данный выбор обусловлен перспективой создания веб-версии программы, простотой разработки и возможностью работы программы под управлением различных операционных систем. Для подгрузки данных используется библиотека Pandas. Прогноз осуществляется с использованием библиотеки машинного обучения Scikit-learn, она предоставляет простые и эффективные инструменты для анализа данных, построения моделей машинного обучения и выполнения задач, связанных с прогнозированием и классификацией. В данном случае применяется модель регрессии на основе дерева решений, связано это с малым объемом данных, работой с нелинейными зависимостями и отсутствием необходимости их нормализации [8, 9].

Проверка прогноза, сгенерированного программой, осуществляется проведением дополнительного теста на рекомендованных режимах резания.

Результаты и обсуждение

Зависимость производительности фрезы от стойкости, при работе на режимах резания указанных в табл. 3, приведена на рис. 3. Исходя из полученных данных, установлен наиболее производительный режим обработки № 1.

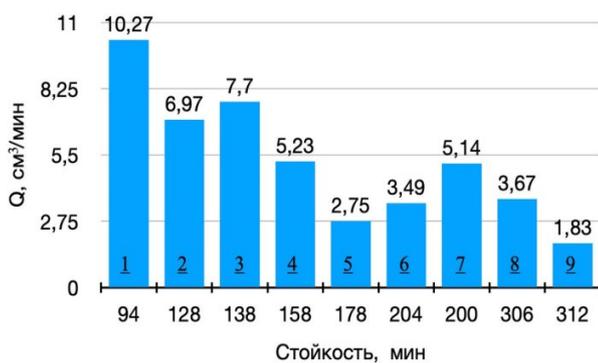


Рис. 3. Диаграмма зависимости производительности фрезы от стойкости

Fig. 3. Diagram of the dependence of milling cutter performance on durability

Данные, полученные в результате проведения испытаний, были обработаны аналитической программой, которая в процессе работы рассчитала следующие режимы резания и стойкость: $v = 60$ мм/мин; $S_z = 0,19$ мм/зуб; $Q = 13,57$ см³/мин; прогнозируемое значение $T = 156,43$ мин.

В результате проведения дополнительного теста на рекомендуемых программой режимах резания была достигнута стойкость фрезы 135 мин, что почти на 22 мин или на 14 % ниже прогноза [10]. Данный результат можно считать удовлетворительным. Для повышения точности прогноза требуется больше данных для анализа. Также следует ожидать повышение точности за счет учета дополнительных факторов [11, 12]. Например, важным показателем работоспособности инструмента кроме величины износа является его характер [13, 14]. Информация о характере износа может быть введена в программу в виде файла, содержащего изображение, полученное с помощью прибора для измерения инструмента вне станка.

Заключение

Разработано программное обеспечение, которое используя метод машинного обучения, анализирует результаты испытаний режущих инструментов и прогнозирует наиболее эффективные режимы резания, позволяющие достичь максимальной производительности для рассматриваемой технологической системы. Погрешность прогноза составила 14 %. Результаты проведенных исследований могут быть использованы для сокращения затрат при испытаниях режущих инструментов как в лабораторных, так и в производственных условиях. Наибольший эффект может быть достигнут при испытаниях инструментов для обработки труднообрабатываемых материалов. Рекомендуется проведение дополнительных исследований с увеличением количества данных для машинного обучения и анализом дополнительных факторов, таких как характер износа режущей кромки инструмента.

СПИСОК ИСТОЧНИКОВ

1. Xi L., Li L., Li L., Zhao J., Sutherland J.W. Parameter optimization of titanium alloy considering energy efficiency and tool wear based on RBFNN-MOPSO algorithm in milling // *Journal of Manufacturing Processes*. 2024. Vol. 122. P. 97–111. DOI: 10.1016/j.jmapro.2024.05.070.

2. Серебренникова А.Г., Гурылев В.Б. Титановый сплав VT22: исследование зависимости выходных параметров токарной обработки от геометрии режущего инструмента // *Вестник Иркутского государственного технического университета*. 2020. Т. 24, № 3 (152). С. 548–560. DOI 10.21285/1814-3520-2020-3-548-560.

3. Бондаренко И.Р., Гринёк А.В., Ковалев Л.А. Имитационное моделирование как эффективное средство исследования силовых характеристик резания при высокопроизводительном фрезеровании // *Вестник БГТУ им. В.Г. Шухова*. 2018. № 6. С. 90. DOI: 10.12737/article_5b115a6e582483.82239040.

4. Козлов С.В. Теоретические основы повышения эффективности механической обработки титановых сплавов // *Интернаука*. 2021. № 20 (196). С. 60–64. EDN OSDINE.

5. Матлыгин Г.В., Савилов А.В., Николаев А.Ю., Тимофеев С.А. Исследование отклонений формы изделий из быстрорежущей стали при точении фрезерованием на станках с ЧПУ Тимофеев // *Наукоемкие технологии в машиностроении*. 2023. № 7 (145). С. 15–23. DOI: 10.30987/2223-4608-2023-7-15-23. EDN: EVCANO.

6. Saeed M.A., Junejo F., Amin I., Tanoli I.K., Algarni A.D., Ahmad S., Ateya A.A. A hybrid two stage Taguchi-regression-NSGA II-AHP-GRA, multi-objective optimization framework for sustainable straight slot milling of AZ31 magnesium alloy // *Results in Engineering*. 2025. Vol. 25. Art. 104451. DOI: 10.1016/j.rineng.2025.104451.

7. Karim K.A., Rashid A.B., Baki R.F., Maktum M.J. Machine Learning Algorithms for Manufacturing Quality Assurance: A Systematic Review of Performance Metrics and Applications // *Array*. 2025. Art. 100393. DOI: 10.1016/j.array.2025.100393.

8. Mohanraj T., Shankar S., Rajasekar R., Sakthivel N.R., Pramanik A. Tool condition monitoring techniques in milling process // *Journal of Materials Research and Technology*. 2020. Vol. 9, no. 1. P. 1032–1042. DOI: 10.1016/j.jmrt.2019.10.031.

9. Balasuadhakar A., Kumaran S.T., Uthayakumar M. Machine learning prediction of surface roughness in sustainable machining of AISI H11 tool steel // *Smart Materials in Manufacturing*. 2025. Vol. 3. Art. 100075. DOI: 10.1016/j.smmf.2025.100075.

10. Domínguez-Monferrer C., Ramajo-Ballester A., Armingol J.M., Cantero J.L. Spot-checking machine learning algorithms for tool wear monitoring in automatic drilling operations in CFRP/Ti6Al4V/Al stacks in the aircraft industry // *Journal of Manufacturing*

Systems. 2024. Vol. 77. P. 96–111. DOI: 10.1016/j.jmsy.2024.08.023.

11. Салихов М.Р., Юрьева Р.А. Алгоритм прогнозирования состояния оборудования на основе машинного обучения // *Приборостроение*. 2022. № 9. URL: <https://cyberleninka.ru/article/n/algorithm-prognozirovaniya-sostoyaniya-oborudovaniya-na-osnove-mashinnogo-obucheniya>

12. Панин Е.П. Прогнозирование технического состояния оборудования на основе ансамблевых методов машинного обучения // *Вестник науки*. 2025. № 6 (87). URL: <https://cyberleninka.ru/article/n/prognozirovanie-tehnicheskogo-sostoyaniya-oborudovaniya-na-osnove-ansamblevyh-metodov-mashinnogo-obucheniya>

13. Бондаренко И.Р., Гринёк А.В., Ковалев Л.А. Имитационное моделирование как эффективное средство исследования силовых характеристик резания при высокопроизводительном фрезеровании // *Вестник БГТУ имени В. Г. Шухова*. 2018. № 6. URL: <https://cyberleninka.ru/article/n/imitatsionnoe-modelirovanie-kak-effektivnoe-sredstvo-issledovaniya-silovyh-harakteristik-rezaniya-pri-vysokoproizvoditelnom>

14. Шишков Н.Г., Астапов В.С., Муртазов А.К. Применение методов машинного обучения для прогнозирования износа инструмента фрезерования в условиях автоматизированного производства // *Вестник Тихоокеанского государственного университета (Вестник ТОГУ)*. 2025. № 2 (77). С. 47–58. DOI: <https://doi.org/10.38161/1996-3440-2025-2-47-58>.

REFERENCES

1. Xi L., Li L., Zhao J., Sutherland J.W. Parameter optimization of titanium alloy considering energy efficiency and tool wear based on RBFNN-MOPSO algorithm in milling // *Journal of Manufacturing Processes*. 2024. Vol. 122. P. 97–111. DOI: 10.1016/j.jmapro.2024.05.070.

2. Serebrennikova A.G., Gurylev V.B. Titanium alloy VT22: a study of the dependence of turning output parameters on the geometry of the cutting tool // *Bulletin of Irkutsk State Technical University*. 2020, vol. 24, no. 3 (152). pp. 548–560. DOI 10.21285/1814-3520-2020-3-548-560.

3. Bondarenko I.R., Grinek A.V., Kovalev L.A. Simulation modeling as an effective means of studying cutting power characteristics in high-performance milling // *Bulletin of the BSTU named after V.G. Shukhov*. 2018, no. 6, p. 90. DOI: 10.12737/article_5b115a6e582483.82239040.

4. Kozlov S.V. Theoretical foundations of increasing the efficiency of mechanical processing of titanium alloys // *Internauka*. 2021, no. 20 (196), pp. 60–64. EDN OSDINE.

5. Matlygin G.V., Savilov A.V., Nikolaev A.Yu., Timofeev S.A. Investigation of form deviations of high-speed steel (HSS) products under turning milling operation using automatically programmed tools // *Science-intensive technologies in mechanical engineering*. 2023, no. 7 (145),

pp. 15–23. DOI: 10.30987/2223-4608-2023-7-15-23. EDN: EVCANO.

6. Saeed M.A., Junejo F., Amin I., Tanoli I.K., Algarni A.D., Ahmad S., Ateya A.A. A hybrid two stage Taguchi-regression-NSGA II-AHP-GRA, multi-objective optimization framework for sustainable straight slot milling of AZ31 magnesium alloy // Results in Engineering. 2025. Vol. 25. Art. 104451. DOI: 10.1016/j.rineng.2025.104451.

7. Karim K.A., Rashid A.B., Baki R.F., Maktum M.J. Machine Learning Algorithms for Manufacturing Quality Assurance: A Systematic Review of Performance Metrics and Applications // Array. 2025. Art. 100393. DOI: 10.1016/j.array.2025.100393.

8. Mohanraj T., Shankar S., Rajasekar R., Sakthivel N.R., Pramanik A. Tool condition monitoring techniques in milling process // Journal of Materials Research and Technology. 2020. Vol. 9, no. 1. P. 1032–1042. DOI: 10.1016/j.jmrt.2019.10.031.

9. Balasuadhakar A., Kumaran S.T., Uthayakumar M. Machine learning prediction of surface roughness in sustainable machining of AISI H11 tool steel // Smart Materials in Manufacturing. 2025. Vol. 3. Art. 100075. DOI: 10.1016/j.smmf.2025.100075.

10. Domínguez-Monferrer C., Ramajo-Ballester A., Armingol J.M., Cantero J.L. Spot-checking machine learning algorithms for tool wear monitoring in automatic drilling operations in CFRP/Ti6Al4V/Al stacks in the aircraft

industry // Journal of Manufacturing Systems. 2024. Vol. 77. P. 96–111. DOI: 10.1016/j.jmsy.2024.08.023.

11. Salikhov M.R., Yuryeva R.A. Algorithm for predicting the state of equipment based on machine learning // Instrument engineering. 2022, no. 9. URL: <https://cyberleninka.ru/article/n/algorithm-prognozirovaniya-sostoyaniya-oborudovaniya-na-osnove-mashinnogo-obucheniya>

12. Panin Ye.P. Forecasting the technical condition equipment based on ensembles machine learning methods // Bulletin of Science. 2025, no. (87). URL: <https://cyberleninka.ru/article/n/prognozirovanie-tehnicheskogo-sostoyaniya-oborudovaniya-na-osnove-ansamblevyh-metodov-mashinnogo-obucheniya>

13. Bondarenko I.R., Grinek A.V., Kovalev L.A. Simulation modeling as an effective means of studying cutting power characteristics in high-performance milling // Bulletin of the BSTU named after V. G. Shukhov. 2018, no. 6. URL: <https://cyberleninka.ru/article/n/imitatsionnoe-modelirovanie-kak-effektivnoe-sredstvo-issledovaniya-silovyh-harakteristik-rezaniya-pri-vysokoproizvoditelnom>

14. Shishkov N.G., Astapov V.S., Murtazov A.K. Application of machine learning methods to predict the runout of milling tools in automated production // Bulletin of the Pacific State University (Bulletin of the TOGU). 2025, no. 2 (77), pp. 47–58. DOI: <https://doi.org/10.38161/1996-3440-2025-2-47-58>.

Вклад авторов: все авторы сделали эквивалентный вклад в подготовку публикации. Авторы заявляют об отсутствии конфликта интересов.

Contribution of the authors: the authors contributed equally to this article. The authors declare no conflicts of interests.

Статья поступила в редакцию 03.04.2025; одобрена после рецензирования 17.06.2025; принята к публикации 30.06.2025.

The article was submitted 03.04.2025; approved after reviewing 17.06.2025; assepted for publication 30.06.2025.