


МАШИНОСТРОЕНИЕ И МАШИНОВЕДЕНИЕ MACHINE BUILDING AND MACHINE SCIENCE



УДК 621.9

<https://doi.org/10.23947/1992-5980-2019-19-1-45-55>

Разработка цифрового двойника станка с ЧПУ на основе методов машинного обучения*

Ю. Г. Кабалдин¹, Д. А. Шатагин², М. С. Аносов³, А. М. Кузьмишина^{4**}

^{1, 2, 3, 4} Нижегородский государственный технический университет, г. Нижний Новгород, Российская Федерация

Development of digital twin of CNC unit based on machine learning methods***

Yu. G. Kabaldin¹, D. A. Shatagin², M. S. Anosov³, A. M. Kuzmishina^{4**}

^{1, 2, 3, 4} Nizhny Novgorod State Technical University, Nizhny Novgorod, Russian Federation

Введение. В статье показано, что цифровой двойник (электронный паспорт) станка с ЧПУ разрабатывается как киберфизическая система.

Цель работы — создание нейросетевых моделей, определяющих функционирование станка с ЧПУ, его производительность и динамическую устойчивость при резании.

Материалы и методы. Рассматриваются вопросы создания математических моделей процессов механической обработки с использованием системы сенсоров и промышленного интернета вещей. Оценены методы машинного обучения, подходящие для реализации названных задач. Предложена нейросетевая модель динамической устойчивости процесса резания, позволяющая оптимизировать процесс механической обработки на этапе технологической подготовки производства. На основе подходов нелинейной динамики реконструированы аттракторы динамической системы резания и определены их фрактальные размерности. Выбраны оптимальные характеристики оборудования по входным параметрам и отладке планируемого технологического процесса на основе цифровых двойников.

Результаты исследований. Использование методов машинного обучения позволило создать и исследовать нейросетевые модели технологических систем обработки резанием и программное обеспечение для их реализации. Показана возможность применения деревьев решений для задачи диагностики и классификации неисправностей станков с ЧПУ.

Обсуждение и заключения. В реальном производстве технология цифровых двойников позволяет оптимизировать режимы обработки с учетом технического и динамического состояния станков с ЧПУ. Это обеспечивает высокоточную оценку производственных мощностей предприятия при составлении производственной программы. Кроме того, на основе интеллектуального анализа данных системы распределенных сенсоров можно выявить неисправности оборудования в режиме реального времени.

Introduction. It is shown that the digital twin (electronic passport) of a CNC machine is developed as a cyber-physical system. The work objective is to create neural network models to determine the operation of a CNC machine, its performance and dynamic stability under cutting.

Materials and Methods. The development of mathematical models of machining processes using a sensor system and the Industrial Internet of Things is considered. Machine learning methods valid for the implementation of the above tasks are evaluated. A neural network model of dynamic stability of the cutting process is proposed, which enables to optimize the machining process at the stage of work preparation. On the basis of nonlinear dynamics approaches, the attractors of the dynamic cutting system are reconstructed, and their fractal dimensions are determined. Optimal characteristics of the equipment are selected by input parameters and debugging of the planned process based on digital twins.

Research Results. Using machine learning methods allowed us to create and explore neural network models of technological systems for cutting, and the software for their implementation. The possibility of applying decision trees for the problem of diagnosing and classifying malfunctions of CNC machines is shown.

Discussion and Conclusions. In real production, the technology of digital twins enables to optimize processing conditions considering the technical and dynamic state of CNC machines. This provides a highly accurate assessment of the production capacity of the enterprise under the development of the production program. In addition, equipment failures can be identified in real time on the basis of the intelligent analysis of the distributed sensor system data.



* Работа выполнена в рамках инициативной НИР.

** E-mail: Uru.40@mail.ru, dmitsanych@gmail.com, ansv-maksim@rambler.ru, Foxi-16@mail.ru

*** The research is done within the frame of independent R&D.

Ключевые слова: киберфизическая система, нейросетевая модель, большие данные, интернет вещей, цифровой двойник.

Keywords: cyber-physical system, neural network model, big data, Internet of Things, digital twin.

Образец для цитирования: Разработка цифрового двойника станка с ЧПУ на основе методов машинного обучения / Ю. Г. Кабалдин [и др.] // Вестник Донского гос. техн. ун-та. — 2019. — Т. 19, № 1. — С. 45–55. <https://doi.org/10.23947/1992-5980-2019-19-1-45-55>

For citation: Yu.G. Kabaldin, et al. Development of digital twin of CNC unit based on machine learning methods. Vestnik of DSTU, 2019, vol. 19, no. 1, pp. 45–55 <https://doi.org/10.23947/1992-5980-2019-19-1-45-55>

Введение. Предложенная в [1] единая базовая управляющая платформа служит основой при разработке нового поколения систем управления технологическим оборудованием, а также позволяет совершенствовать системы числового программного управления (ЧПУ) для цифровых производств. Такой платформой могут быть открытые системы ЧПУ станков с большими вычислительными ресурсами и высоким быстродействием обработки крупной базы данных (БД), встроенными модулями нейропроцессоров и модулями связи с промышленным интернетом. В последнем случае речь идет о возможностях использования облачных технологий обработки больших объемов данных на серверах предприятий (локальные сети) и провайдеров. Все это создаст основу интеллектуального управления для широкой номенклатуры технологического оборудования с ЧПУ.

С девяностых годов XX века [2] авторы представленного исследования разрабатывают программные продукты для интеллектуального управления технологическим оборудованием. В частности, были предложены критерии оценки динамической устойчивости процесса резания, основанные на методах нелинейной динамики и фрактального анализа сигналов виброакустической эмиссии (ВАЭ). Авторы создали единую платформу расширения функциональных возможностей различного технологического оборудования с системами ЧПУ. Она реализуется путем встраивания в системы ЧПУ модулей высокопроизводительных вычислений и глубокого обучения искусственных нейронных сетей с использованием технологий CUDA nVidia. В рамках данной работы изучается технологическое оборудование с ЧПУ, оснащенное датчиками и задействующее облачные технологии для сбора и обработки информации по разработанным методикам. Такие системы будут рассматриваться как киберфизические [3].

Предполагается, что разработанная авторами платформа станет основой цифровизации на всех уровнях предприятия. Для этого она должна не только анализировать данные оборудования, систем, устройств, но и использовать полученную таким образом информацию, чтобы сократить время вывода новых изделий на рынок, повысить гибкость производства, качество продукции и эффективность производственных процессов.

Цифровой двойник (digital twin) — новое слово в моделировании оборудования, техпроцессов и планировании производств [3]. Это совокупность математических моделей, достоверно описывающих процессы и взаимосвязи на отдельном объекте и в рамках целого производственного предприятия с использованием анализа больших данных (big data) и машинного обучения.

Лидер в области использования цифровых двойников — компания Siemens [3]. Согласно ее определению, цифровой двойник — это ансамбль математических моделей. Они характеризуют различные состояния оборудования, технологических и бизнес-процессов во времени, в соответствии с текущими производственными условиями. Среди таких математических моделей особое место занимают нейросетевые схемы, т. е. нейросетевая модель процесса или изделия — это его цифровой двойник [2].

Основной технологической единицей цифрового производства является киберфизическая система (КФС) [1]. Ее высокие адаптивные и интеллектуальные возможности обусловлены следующими особенностями:

- ассоциативное восприятие информации,
- постоянное обучение,
- оценка текущего и прогнозирование будущего состояния.

КФС способна анализировать многомерные данные, учитывая даже скрытые факторы реального производства. Основываясь на этих данных, она может автономно решать задачи оптимизации и принимать правильные решения. Поэтому КФС — главный элемент при создании цифрового двойника. Под цифровым двойником в данном случае подразумевается:

- комплекс математических моделей, характеризующих различные состояния оборудования, технологических процессов во времени, в соответствии с текущими производственными условиями;

— детализированные сборочные 3D-модели объектов, отражающие связи и взаимодействия между узлами.

С этой точки зрения цифровой двойник можно рассматривать как цифровую идентичность КФС, электронный паспорт, в котором фиксируются все данные об обрабатываемых материалах, выполненных технологических операциях и испытаниях.

В настоящее время цифровые двойники в основном создаются для коммерческого использования. Они успешно работают в нефтяной и газовой промышленности. При этом в литературе нет данных о двойниках оборудования механообрабатывающих производств на базе КФС.

Цифровые двойники на базе КФС можно получить, используя:

- традиционные аналитические подходы, основанные на математическом описании физических процессов;
- современные статистические методы, в том числе машинное обучение.

Материалы и методы. Методы машинного обучения, применяемые для построения статистических моделей, можно разбить на три группы: модели регрессионного анализа, модели классификации и модели выявления аномалий [4–6] (табл. 1).

Таблица 1

Основные методы машинного обучения

Регрессионный анализ	Классификация	Выявление аномалий
Линейная регрессия	Логистическая регрессия	Метод опорных векторов
Байесовская регрессия	Лес деревьев решений	Анализ главных компонент
Лес деревьев решений	Джунгли решений	К-средние
Деревья решений	Деревья решений	Нейронные сети
Квантильная регрессия быстрого леса	Метод опорных векторов	Самоорганизующиеся карты Кохонена
Нейронные сети	Точечная машина Байеса	
Регрессия Пуассона	One-vs-All	
Порядковая регрессия	Нейронные сети	

Выбор метода машинного обучения зависит от размера, качества и природы данных, а также от типа решаемых задач. Существующие методы требуют различных вычислительных мощностей и обладают различной степенью точности. Как правило, их оценивают по возможности достичь точной аппроксимации данных и выявить границы в пространстве данных. Метод искусственных нейронных сетей (ИНС) является наиболее универсальным и точным, он позволяет работать с большим количеством данных и строить нелинейные зависимости. Нейронные сети задействуют большое количество параметров настройки, что открывает возможности для создания высокоточных моделей процессов, работающих в режимах регрессионного анализа, классификации и выявления аномалий.

Основной метод анализа качества моделей — перекрестная проверка. Она позволяет оценить статистическое качество исходных данных за счет построения и сравнения нескольких моделей, полученных на различных обучающих и проверочных выборках. При построении моделей сложных объектов и систем требуется снижение размерности данных и устранение эффекта мультиколлинеарности переменных. Решение таких задач возможно за счет применения метода главных компонент, позволяющего представить многомерные данные в виде ограниченного числа составляющих (компонент). Такой обобщающий подход может применяться и для устранения переобучения моделей. Основные методы машинного обучения представлены в табл. 1.

Для повышения качества модели используют бэггинг и бустинг. Суть данных алгоритмов заключается в построении не одной модели, а их комплекса, работающего над той же задачей. Результатом такой работы является некая интегральная оценка вероятности какого-либо события. Данная оценка может быть представлена как синергетический эффект действия группы моделей, каждая из которых по отдельности работает неудовлетворительно. Таким образом, цифровым двойником может быть комплекс статистических моделей, исполь-

зующих различные комбинации методов машинного обучения и прошедших различные стадии верификации и улучшения.

Итак, в общем случае цифровой двойник на базе КФС — это многофакторная модель оборудования [1], включающая ансамбль электронных (т. е. нейронсетевых) моделей. В данном случае определяющими будут следующие нейронные сети: динамической устойчивости процесса резания, сил резания и шероховатости обработанной поверхности. Силы резания вызывают упругие отжатия в системе «инструмент — деталь», что обуславливает погрешности формы и размеров.

Для решения данной задачи был разработан комплекс статистических моделей, использующих методы машинного обучения. Полученные модели являются основой для цифрового двойника токарного станка с ЧПУ. Они позволяют решать задачи регрессионного анализа для прогнозирования динамики процесса резания при различных условиях обработки, шероховатости обработанной поверхности и сил резания. Кроме того, с помощью этих моделей решаются задачи классификации для оценки текущего состояния станка. Схема процесса создания цифрового двойника представлен на рис. 1.




Рис. 1. Схема процесса создания цифрового двойника станка с ЧПУ

Рассмотрим более подробно нейросетевую модель динамики процесса резания. Обучающая выборка была получена на основе телеметрических данных, собранных в процессе механической обработки с использованием распределенной системы датчиков сигнала ВАЭ, динамометра и технологии промышленного интернета вещей (industrial internet of things, IIoT). Количество датчиков, их тип и пространственная ориентация определялись в соответствии с компоновкой оборудования. Наличие в системе большого числа датчиков с различной пространственной ориентацией объясняется неоднородностью материалов и конструкций, особенностями распространения сигналов, а также возможностью перестройки колебательной системы в процессе эксплуатации. Таким образом, использование гетерогенной системы сенсоров позволило получить наиболее полную динамическую картину процессов в n -мерном пространстве «состояние — время». В качестве протокола приема-передачи данных в рамках сети IIoT был использован стандартный протокол TCP/IP, а также текстовый формат обмена данными JSON (JavaScript Object Notation).


Для предварительной обработки сигналов применялись аналоговые и цифровые полосовые фильтры, а также вейвлет-фильтры. Использование вейвлет-фильтров позволило:

- исключить влияние шумовой составляющей в сигналах ВАЭ;
- выделить периодическую и хаотическую составляющие на основе энтропийных показателей.


Предварительная обработка данных проводилась на «пограничном» устройстве (Edge), которое вычисляет значения параметров сигнала ВАЭ и формирует пакеты данных для отправки в виртуальное облачное хранилище. Построение математических моделей на основе методов машинного обучения требует структурирования и разметки данных. Однако учитывая особенности технологии работы IIoT, построение реляционных БД не всегда возможно, поэтому был применен подход на основе технологий NoSQL. Для этого хранение и обработка данных были реализованы на виртуальном сервере, имитирующем работу вычислительного кластера. На этом сервере была развернута специальная распределенная, масштабируемая файловая система.

В качестве основы использовались свободно распространяемые утилиты, библиотеки и фреймворки проекта Hadoop (это одна из наиболее успешных и распространенных технологий больших данных). В частности, программная оболочка Hadoop Common управляет распределенной файловой системой HDFS и базой данных HBase [4]. Для выполнения распределенных вычислений и обработки больших объемов данных использовалась система MapReduce, обеспечивающая автоматическое распараллеливание и распределение задач на кластере. Для ускорения обучения нейросетевых моделей были задействованы графические процессоры nVidia CUDA.

Результаты исследования. Для создания статистической модели динамического состояния процесса резания выбрана рекуррентная ИНС с сигмоидальной функцией активации нейронов. В качестве обучающей выборки использованы данные, полученные в процессе работы промышленного оборудования. При обучении использовался алгоритм обратного распространения ошибки. По окончании процесса обучения проводилась верификация полученной модели на основе значений средней квадратичной ошибки. На рис. 2, а видно монотонное убывание ошибки. При этом ее распределение является нормальным и сосредоточено вблизи нулевого значения, что свидетельствует о хорошем качестве полученной модели.



а)



б)

Рис. 2. Оценка качества полученной модели: диаграмма распределения ошибки обучения (а); зависимость среднеквадратичной ошибки от итерации обучения (б)

Полученная ИНС (рис. 3) состоит из 17 входных нейронов, воспринимающих информацию об условиях обработки и предыдущем динамическом состоянии.





Рис. 3. Нейросетевая модель динамической устойчивости процесса резания

Выходной слой нейронов отражает информацию о динамическом состоянии системы резания. Скрытый слой образован 38 нейронами. Данная ИНС способна моделировать динамику динамической системы резания для различных условий обработки в заданные моменты.

Для оценки адекватности нейросетевой модели было проведено моделирование процесса механической обработки на токарном обрабатывающем центре с ЧПУ. В качестве обрабатываемой заготовки использовался вал из нержавеющей стали 12Х18Н10Т, закрепленный с двух сторон по центру, как показано на рис. 4, а.






Рис. 4. Результаты нейросетевого моделирования: схема обработки (а), моделируемый процесс резания (б), реальный процесс резания (в), процесс резания после оптимизации (г)


Режимы определены в соответствии с производственными нормами для обработки деталей данного типа на токарном станке с ЧПУ. Симуляцию перемещения инструмента относительно заготовки обеспечила переменная на входном слое ИНС, отвечающая за положение суппорта станка по оси Z . Шаг изменения данной переменной составлял 0,01 мм на расстоянии от 0 до 350 мм. Так было получено динамическое состояние системы резания для 35 тыс. положений инструмента на оси Z . Зафиксированные динамические состояния отражены на соответствующей спектрограмме (рис. 4, б): заметны две доминирующие частоты автоколебаний (3,5 кГц и 6,5 кГц) и два фазовых перехода.

Для подтверждения результатов моделирования проводился натурный эксперимент с аналогичными условиями обработки и регистрацией сигнала ВАЭ. По полученным экспериментальным данным была также построена спектрограмма процесса механической обработки (рис. 4, в). На ней тоже видны две доминирующие частоты в областях 3,5 кГц и 6,5 кГц и два фазовых перехода. В итоге погрешность моделирования на различных участках обработки составила от 3 % до 7 %. Как видно из рис. 4, предложенные производственные нормы не позволяют получить изделие заданного качества. Это может быть причиной брака, а учитывая биения заготовки, и поломки инструмента.


Использование названных выше норм ведет к неадекватной оценке производственных мощностей предприятия и, соответственно, к некачественному формированию производственной программы. Устранение данного недостатка на этапе конструкторско-технологической подготовки чревато дополнительными временными и финансовыми затратами. Поэтому выполняется корректировка режимов, заложенных в нормах производства. Для этого рассчитываются оптимальные значения вектора технологических условий с использованием ИНС и метода градиентного спуска. Целевыми функциями оптимизации были значения амплитуды сигнала ВАЭ, фрактальной размерности и информационной энтропии, которые должны стремиться к минимуму. В качестве параметров оптимизации выбраны скорость обработки и значение фаски на передней поверхности. По завершении процесса оптимизации были получены новые режимы обработки: $V = 90$ м/мин; $S = 0,1$ мм/об; $f\gamma = 0,2$ мм.

Эти режимы оценивались также по результатам натурального эксперимента с регистрацией и обработкой сигнала ВАЭ. Как видно из рис. 4, г, оптимизация условий обработки позволила повысить динамическую устойчивость процесса резания за счет снижения амплитуды автоколебаний в 2 раза и фрактальной размерности $Df = 1,1$. Таким образом, повышалось динамическое качество механической обработки без потери производительности.


Аналогичным путем были получены модели для прогнозирования значений шероховатости обработанной поверхности и сил при резании. Силы резания определяют точность обработки, вызывая упругое отжатие детали и инструмента, а, следовательно, и погрешность формы детали. Данные нейросетевые модели представляют собой многослойные искусственные нейронные сети прямого распространения (рис. 5).



а)



б)



в)

Рис. 5. Распределение значений амплитуды сигнала датчиков: As_1 (а), As_2 (б), As_3 (в)

Нейросетевые модели в составе цифрового двойника применимы не только в реальных производственных условиях, но и при выборе и обосновании закупки оборудования. На этом этапе возможен подбор оптимальных характеристик оборудования и отладка планируемого технологического процесса на цифровых двойниках.

Для оценки текущего состояния оборудования была разработана модель классификации с использованием деревьев решений [5]. В качестве признаков, на основе которых принималось решение, были выбраны значения амплитуды сигнала ВАЭ в различные моменты времени с трех датчиков, расположенных на инструменте (As_1), у передней опоры шпинделя (As_3) и у заднего центра (As_2). В качестве классов использовались три состояния: нормальное (Normal), износ инструмента (Tool wear) и аномальное (Abnormal). Под аномальным подразумевается любое состояние, при котором качество обработанной поверхности и работа оборудования будут неудовлетворительными. Критерием износа инструмента считалась фаска на задней поверхности $h = 0,15$ мм. После получения обучающей выборки выполнялся разведочный анализ данных.

Из рис. 5 видно соответствие распределения значений амплитуды сигнала ВАЭ датчика As_1 трем группам состояний. Информация, полученная с этого датчика, хорошо дифференцирует нормальное состояние и износ инструмента. Однако значения, соответствующие аномальному состоянию, имеют пересечения с данными из других групп, поэтому информация с датчика As_1 не может быть использована с высокой точностью для классификации состояний.

Рис. 5, б характеризует распределение значений амплитуды сигнала с датчика As_2 . Полученные данные имеют низкую информационную ценность из-за двух недостатков:

- пересечения значений группы аномального состояния с другими классами;
- слабая дифференциация нормального состояния и износа инструмента (об этом свидетельствует их близкое расположение).

На рис. 5, в показано распределение значений амплитуды сигнала с датчика As_3 . Информация с этого датчика хорошо выделяет значения аномального состояния, при этом отсутствуют пересечения значений всех классов состояний. Таким образом, разведочный анализ данных позволяет сделать заключение о возможности получения статистической модели классификации состояния станка с ЧПУ.

Для обучения модели был использован алгоритм CART [3]. Он делит полученные данные на определенные подмножества на разных уровнях. В качестве критерия разделения используется целевая функция минимизации информационной энтропии. Таким образом, каждый новый уровень имеет более определенное содержание признаков. Совокупность всех полученных уровней представляется в виде иерархической древовидной структуры, состоящей из узлов и ветвей, при этом ветвление следует стандартным логическим правилам.

Из всей выборки признаков выбирается такое значение условия деления для корневого узла, которое лучше минимизирует значения информационной энтропии. Затем от каждого полученного узла строятся ветви и происходит аналогичное деление на новые узлы. Подобное ветвление может продолжаться, пока не будут классифицированы все значения обучающей выборки. В общем случае такое дерево будет представлять сложную ветвистую структуру, идеально классифицирующую текущую выборку. Однако оно может показывать очень низкую точность при работе с новыми данными. Поэтому необходима оптимизация размера дерева. Она может проводиться с использованием перекрестной проверки, на основе которой строится несколько деревьев-претендентов, а в итоге выбирается дерево, показавшее лучший результат. Кроме того, выполняется отсечение ветвей, пока данная процедура не приведет к резкому возрастанию ошибки.

На рис. 6 представлена полученная модель классификации состояния оборудования на основе показаний датчиков ВАЭ с использованием дерева принятия решений.




Рис. 6. Дерево решений для классификации состояния оборудования

Первое выбранное условие — показания амплитуды сигнала ВАЭ с датчика As_3 . Если амплитуда ВАЭ больше или равна 2,3, то состояние однозначно аномальное. Это суждение подтверждается разведочным анализом данных. В противном случае происходит следующее разбиение, и классификацию определяют данные с датчика As_1 . Если амплитуда ВАЭ датчика As_1 меньше 2,1, состояние считается нормальным; если больше, то речь идет об износе инструмента.

Как видно из рис. 6, принятие решений не учитывает показания датчика As_2 . Низкая информативность сигнала с этого датчика была выявлена и в ходе разведочного анализа.

Высокая точность определения аномального режима работы на основе анализа сигнала датчика As_3 может быть связана с местом его установки (передняя опора шпинделя). Вероятнее всего, динамические процессы в шпиндельном узле обусловили это состояние, которое отразилось и на качестве механической обработки. Учитывая нелинейные процессы рассеивания колебаний в упругой системе станка, данная информация доходила до других датчиков уже сильно искаженной.

При этом датчик As_1 , установленный на инструменте, позволяет выделять его износ с высокой точностью. Это можно объяснить доминирующей ролью резца в общей колебательной системе.

Датчик As_2 , установленный на заднем центре, с наименьшей эффективностью регистрирует информацию для классификации состояния. Это можно объяснить удаленностью As_2 от основных динамических процессов.

Таким образом, описанный метод можно применить не только для задачи классификации состояния оборудования, но и для определения оптимального числа датчиков и мест их размещения. Однако стоит учитывать возможность перестройки динамических процессов в системе резания при изменении условий обработки и естественного износа деталей станка.

Обсуждение и заключения. Использование цифровых двойников оборудования при планировании производства позволяет выявить узкие места в технологических операциях, повысить качество продукции, снизить риски поломки инструмента и нештатной работы оборудования. С помощью цифровых двойников можно оптимизировать режимы обработки с учетом технического и динамического состояния каждой производственной единицы. Такой подход обеспечивает высокоточную оценку производственных мощностей предприятия при составлении производственной программы. Кроме того, на основе интеллектуального анализа данных системы распределенных сенсоров в режиме реального времени выявляются неисправности оборудования.

Библиографический список

1. Искусственный интеллект и киберфизические механообрабатывающие системы в цифровом производстве / Ю. Г. Кабалдин [и др.]. — Нижний Новгород : Изд-во Нижегород. гос. техн. ун-та им. П. Е. Алексеева, 2018. — 271 с.
2. Организация и управление механообрабатывающим цифровым производством / Ю. Г. Кабалдин [и др.] // Вестник машиностроения. — 2018. — № 11. — С. 19–27.

3. Кабалдин, Ю. Г. Управление динамическими процессами в технологических системах механообработки на основе искусственного интеллекта / Ю. Г. Кабалдин, С. В. Биленко, С. В. Серый. — Комсомольск-на-Амуре : Изд-во Комсомольского-на-Амуре гос. техн. ун-та, 2003. — 201 с.
4. Frankel, A. Есть способ лучше: цифровой двойник повысит эффективность процессов конструкторско-технологического проектирования и производства / A. Frankel, J. Larsson // CAD/CAM/CAE Observer. — 2016. — № 3. — С. 36–40.
5. Шитиков, В. К. Классификация, регрессия и другие алгоритмы Data Mining с использованием R [Электронный ресурс] / В. К. Шитиков, С. Э. Мاستицкий. — Режим доступа: http://www.ievbras.ru/ecostat/Kiril/R/DM/DM_R.pdf (дата обращения: 14.02.19).
6. Уайт, Т. Nadoor. Подробное руководство / Т. Уайт. — Санкт-Петербург : Питер, 2013. — 672 с.

Поступила в редакцию 21.01.2019
Сдана в редакцию 22.01.2019
Запланирована в номер 15.02.2019

Received 21.01.2019
Submitted 22.01.2019
Scheduled in the issue 15.02.2019

Об авторах:

Кабалдин Юрий Георгиевич,

профессор кафедры «Технология и оборудование машиностроения» Нижегородского государственного технического университета им. Р. Е. Алексеева (РФ, 603950, г. Нижний Новгород, ул. Минина, 24), доктор технических наук, профессор, ORCID: <https://orcid.org/0000-0003-4300-6659>
Uru.40@mail.ru

Шатагин Дмитрий Александрович,

старший преподаватель кафедры «Технология и оборудование машиностроения» Нижегородского государственного технического университета им. Р. Е. Алексеева (РФ, 603950, г. Нижний Новгород, ул. Минина, 24), ORCID: <http://orcid.org/0000-0003-1293-4487>
dmitsanych@gmail.com

Аносов Максим Сергеевич,

старший преподаватель кафедры «Технология и оборудование машиностроения» Нижегородского государственного технического университета им. Р. Е. Алексеева (РФ, 603950, г. Нижний Новгород, ул. Минина, 24), ORCID: <http://orcid.org/0000-0001-8150-9332>
ansv-maksim@rambler.ru

Кузьмишина Анастасия Михайловна,

старший преподаватель кафедры «Технология и оборудование машиностроения» Нижегородского государственного технического университета им. Р. Е. Алексеева (РФ, 603950, г. Нижний Новгород, ул. Минина, 24), ORCID: <https://orcid.org/0000-0001-6966-3417>
Foxi-16@mail.ru

Authors:

Kabaldin, Yury G.,

professor of the Technology and Equipment of Mechanical Engineering Department, Nizhny Novgorod State Technical University n.a. R.E. Alekseev, (24, ul. Minina, Nizhny Novgorod, 603950, RF), Dr.Sci. (Eng.), professor, ORCID: <https://orcid.org/0000-0003-4300-6659>
Uru.40@mail.ru

Shatagin, Dmitry A.,

senior lecturer of the Technology and Equipment of Mechanical Engineering Department, Nizhny Novgorod State Technical University n.a. R.E. Alekseev, (24, ul. Minina, Nizhny Novgorod, 603950, RF), ORCID: <http://orcid.org/0000-0003-1293-4487>,
dmitsanych@gmail.com

Anosov, Maxim S.,

senior lecturer of the Technology and Equipment of Mechanical Engineering Department, Nizhny Novgorod State Technical University n.a. R.E. Alekseev, (24, ul. Minina, Nizhny Novgorod, 603950, RF), ORCID: <http://orcid.org/0000-0001-8150-9332>
ansv-maksim@rambler.ru

Kuzmishina, Anastasia M.,

senior lecturer of the Technology and Equipment of Mechanical Engineering Department, Nizhny Novgorod State Technical University n.a. R.E. Alekseev, (24, ul. Minina, Nizhny Novgorod, 603950, RF), ORCID: <https://orcid.org/0000-0001-6966-3417>,
Foxi-16@mail.ru