

ISSN 1995-2732 (Print), 2412-9003 (Online)

УДК 658.5

DOI: 10.18503/1995-2732-2026-24-3-73-81



ОПРЕДЕЛЕНИЕ НАИМЕНЬШЕГО ЗНАЧЕНИЯ ПАРАМЕТРА ШЕРОХОВАТОСТИ НА ЧЕРТЕЖАХ ДЕТАЛЕЙ СРЕДИ ПОВЕРХНОСТЕЙ, ПОЛУЧЕННЫХ МЕТОДАМИ ТОЧЕНИЯ И ФРЕЗЕРОВАНИЯ, С ИСПОЛЬЗОВАНИЕМ МОДЕЛЕЙ НЕЙРОННЫХ СЕТЕЙ

Кузнецов С.В., Роговик А.А.

Нижегородский государственный технический университет им. Р.Е. Алексеева, Нижний Новгород, Россия

Аннотация. В современном мире все большее распространение и внедрение в различных областях человеческой деятельности получают различные модели нейронных сетей, которые уже активно применяют в технических науках, в частности в машиностроении. В работе описан один из перспективных методов применения моделей нейронных сетей для классификации и обнаружения объектов на изображениях и видео для работы с чертежами деталей. В перспективе описанный метод позволит существенно сократить время подготовки технологической документации при запуске деталей в производство, так как модель сможет выполнять часть функций, ранее осуществляемых человеком. Основная цель работы – это получение метода, функционирующего в автоматизированном режиме, который можно будет применять для работы с чертежами деталей в электронном формате для решения задачи по определению наименьшего значения параметра шероховатости среди поверхностей детали, полученных методами точения и фрезерования. В ходе работы было использовано несколько основных методов и инструментов – это методы обучения моделей нейронных сетей, способных работать с изображениями и видео и решать задачи обнаружения и классификации объектов на них, методы использования данных моделей, методы создания программ для ЭВМ на языке программирования Python. В итоге по результатам работы был получен метод, реализованный при помощи программы для ЭВМ, который позволяет с высокой скоростью обрабатывать чертежи деталей и с высокой точностью определять минимальное значение параметра шероховатости с дальнейшим занесением полученных значений в таблицу. Разработанный метод имеет существенные перспективы практического применения в связи с возможностью его использования как части составного программного комплекса для автоматизированного подбора оборудования.

Ключевые слова: обнаружение объектов на изображениях, нейронные сети, распознавание объектов, компьютерное зрение, “YOLO”, токарная обработка, фрезерная обработка, подбор оборудования, шероховатость поверхности

© Кузнецов С.В., Роговик А.А., 2026

Для цитирования

Кузнецов С.В., Роговик А.А. Определение наименьшего значения параметра шероховатости на чертежах деталей среди поверхностей, полученных методами точения и фрезерования, с использованием моделей нейронных сетей // Вестник Магнитогорского государственного технического университета им. Г.И. Носова. 2026. Т. 24. №3. С. 73-81. <https://doi.org/10.18503/1995-2732-2026-24-3-73-81>



Контент доступен под лицензией Creative Commons Attribution 4.0 License.
The content is available under Creative Commons Attribution 4.0 License.

DETERMINATION OF THE MINIMUM SURFACE ROUGHNESS PARAMETER VALUE IN ENGINEERING DRAWINGS OF PARTS AMONG SURFACES PRODUCED BY TURNING AND MILLING USING NEURAL NETWORK MODELS

Kuznetsov S.V., Rogovik A.A.

Nizhny Novgorod State Technical University named after R.E. Alekseev, Nizhny Novgorod, Russia

Abstract. In the modern world, various neural network models are becoming increasingly widespread and are being implemented in different areas of human activity. They are already actively used in technical sciences, particularly in mechanical engineering. This paper describes one of the promising methods for applying neural network models to image and video object classification and detection for processing engineering drawings of parts. In the future, the described method will make it possible to significantly reduce the time required to prepare technological documentation when launching parts into production, as the model will be able to perform some of the functions previously carried out by humans. The study is aimed at developing an automated method that can be applied to electronic engineering drawings of parts to determine the minimum surface roughness parameter among the surfaces produced by turning and milling operations. Several principal methods and tools have been used in the study, including methods for training neural network models capable of processing images and videos and solving object detection and classification tasks, methods for applying these models, and methods for developing computer programs in the Python programming language. As a result, a method implemented as a computer program has been developed. It enables engineering drawings of parts to be processed at high speed and the minimum surface roughness value to be determined with high accuracy, followed by recording the obtained values in a table. The developed method has significant potential for practical application due to the possibility of incorporating it into an integrated software system for automated equipment selection.

Keywords: object detection in images, neural networks, object recognition, computer vision, YOLO, turning, milling, equipment selection, surface roughness.

For citation

Kuznetsov S.V., Rogovik A.A. Determination of the Minimum Surface Roughness Parameter Value in Engineering Drawings of Parts Among Surfaces Produced by Turning and Milling Using Neural Network Models. *Vestnik Magnitogorskogo Gosudarstvennogo Tekhnicheskogo Universiteta im. G.I. Nosova* [Vestnik of Nosov Magnitogorsk State Technical University]. 2026, vol. 24, no. 3, pp. 73-81. <https://doi.org/10.18503/1995-2732-2026-24-3-73-81>

Введение

В наши дни все большее распространение получают различные методы, способствующие снижению участия человека при выполнении различных работ и процессов. Данная тенденция также отчетливо просматривается и в машиностроительной области, где с каждым годом разрабатывается все больше средств и методов, способствующих частичной или полной автоматизации производственных процессов и технологической подготовки производства.

Одним из таких методов, получившим повсеместное распространение и внедрение в последние годы, является создание и применение моделей с использованием нейронных сетей. Применение данных моделей во всех сферах человеческой жизнедеятельности способствует существенному повышению эффективности труда человека, а в некоторых случаях даже его практически полному исключению из производственного процесса.

Некоторые возможности применения моделей нейронных сетей в машиностроении уже описаны в ранее опубликованных работах [1-5]. На данный момент модели уже способны эффективно использо-

ваться человеком для выполнения таких машиностроительных задач, как:

- автоматизированный расчет режимов обработки различных материалов;
- решение различных инженерных задач при планировании и подготовке производства;
- управление производственными процессами на предприятиях с возможностью их выполнения в адаптивном режиме;
- мониторинг процесса обработки резанием различных материалов;
- выполнение работ по мониторингу работоспособности оборудования;
- прогнозирование вероятности и времени отказа оборудования.

В представленной работе был реализован один из возможных перспективных методов применения моделей нейронных сетей в машиностроительной области. Были созданы и применены модели для работы с изображениями и видео, а именно для классификации объектов на изображениях. Разработанный метод в перспективе сможет позволить значительно увеличить эффективность труда инженеров при подготовке про-

изводства на предприятиях, занимающихся изготовлением деталей методами обработки резанием.

Цель представленной работы – это разработка метода, который можно будет эффективно применять для работы с чертежами деталей в электронном формате и решения задачи по определению наименьшего значения параметра шероховатости среди поверхностей детали, полученных методами точения и фрезерования, в автоматизированном режиме с использованием моделей нейронных сетей.

При реализации данной цели были созданы две модели: первая – для обнаружения и выделения на чертежах областей, содержащих знаки шероховатости вне зависимости от её значения, и вторая – непосредственно классифицирующая выделенные области по конкретным значениям (например, “12.5”, “6.3”, “3.2”, “1.6” и т.д.). Такое решение было принято по причине того, что данный вариант показал наибольшую точность во время разработки. Далее была создана программа для ЭВМ, которая, используя последовательно эти две полученные модели, выполняет следующие функции: нахождение областей, содержащих знаки шероховатости и выделение их в рамки, вырезание знаков шероховатости по выделенным рамкам, классификация значения шероховатостей для получения конкретного значения из каждой выделенной рамки, корректировка полученных результатов классификации и исключение значений с низкой вероятностью достоверности ответа, выбор наименьшего значения из полученных на предыдущем этапе, занесение значения и номера чертежа в таблицу.

В ходе создания описанной программы было использовано несколько основных инструментов и методов:

- методы обучения моделей нейронных сетей, способных работать с изображениями и видео и решать задачи обнаружения и классификации объектов на них;
- методы использования данных моделей;
- методы создания программ для ЭВМ на языке программирования “Python”.

На первом этапе работы был проведён поиск и анализ имеющейся информации по использованию нейронных сетей, а именно по их обучению и работе с ними. Было рассмотрено несколько публикаций по данной тематике [6-8]. Особый интерес представляла работа с моделями, способными обрабатывать изображения и решать задачи по поиску и классификации объектов. Причиной этого является тот факт, что успех реализации поставленной задачи напрямую зависит от правильности выбора базовой модели, из имеющихся в открытом доступе.

Основными требованиями при выборе модели являлись высокая точность и скорость обработки, открытый исходный код, возможность обучения и работы со своим набором данных.

Было рассмотрено несколько различных моделей, которые отвечают данным требованиям: “SSD (Single Shot Detector)”, “YOLO (You Only Look

Once)”, “Mask R-CNN” и “Faster R-CNN”. После анализа имеющейся информации по данным моделям в качестве основного варианта была выбрана модель “YOLO”, так как данный алгоритм обеспечивает одну из самых высоких скоростей работы и точность обнаружения и классификации объектов. Данная модель активно применяется для решения задач обнаружения в различных областях. “YOLO” основана на архитектуре “DarkNet”, которая разрабатывалась для решения задач с применением компьютерного зрения. Преимущества работы с данной моделью ранее были представлены во многих публикациях [9-11].

Новизна описанной в статье работы обуславливается тем, что отсутствуют публикации, содержащие подобные изыскания, и нет описанных аналогов, способных выполнять возложенные на разработку функции.

Полученный метод имеет хорошие перспективы применения на практике, так как его можно использовать как составную часть метода для автоматизированного подбора оборудования для выполнения операций механической обработки вместе с другими частями разрабатываемого программного комплекса. Перспективы применения данного программного комплекса и некоторых его составляющих уже ранее были описаны и представлены [12, 13]. Основным эффектом от внедрения разработанного метода – увеличение эффективности труда инженеров-технологов за счет его способности автоматизировать часть их работы по выбору необходимых металлорежущих станков.

Также описываемый в работе метод может быть использован при сортировке и группировании деталей, так как значение параметров шероховатости поверхности является одной из основных характеристик детали. Преимущества данного подхода при планировании производства были описаны ранее в работах [14, 15].

Таким образом, можно отметить, что данная статья может стать интересна специалистам в области машиностроения, представляющим предприятия, которые занимаются изготовлением деталей с использованием токарной и фрезерной обработки, таких как валы, корпуса, опоры, рычаги, оси, фланцы, втулки, диски и др.

Основные этапы проведения работы

Первый этап – создание наборов данных для машинного обучения моделей. Создание любой модели нейронной сети для классификации и обнаружения объектов начинается именно с этого шага. Данный этап является одним из самых основных в достижении поставленной задачи, так как от качества собранных данных напрямую будет зависеть качество полученных моделей.

Для обучения необходимых для работы моделей было собрано 2000 изображений в формате “JPEG” различных чертежей или их фрагментов, оформленных согласно требованиям «Единой системы конструкторской документации». Данный набор был со-

бран так, чтобы он включал в себя достаточное для обучения разнообразие данных, с которыми впоследствии предстоит работать моделям: чертежи различных форматов листа (А4, А3, А2, А1) и изображения различного качества и разрешения.

Далее необходимо выбрать, какие классы будут обучаться распознавать создаваемую модель. В качестве параметра, определяющего классы, была выбрана шероховатость Ra – среднее арифметическое абсолютных значений отклонений профиля в пределах базовой длины, так как данный параметр является предпочтительным согласно ГОСТ Р 70117–2022. Используемые значения данного параметра были взяты согласно ГОСТ 2789–73 из таблицы 2. После этого был выбран рабочий диапазон значений. Начальным значением диапазона было выбрано $Ra_{12,5}$, так как это значение, для получения которого однозначно необходимо применение механической обработки, в том числе токарными и фрезерными методами. Конечным значением диапазона выбрано значение $Ra_{0,4}$, так как на данный момент это наилучший показатель, который можно получить при обработке на токарных и фрезерных станках твердосплавным инструментом в идеальных условиях. Таким образом, имеем рабочий диапазон $Ra_{12,5} - Ra_{0,4}$, который разграничен красной линией на рис. 1. Далее из этого диапазона были выбраны те значения, которые являются предпочтительными согласно ГОСТ 2789–73. После анализа подготовленного набора чертежей бы-

ло получено, что также большое распространение имеют значения $Ra_{2,5}$ и $Ra_{1,25}$, поэтому их также было решено добавить к обучению моделей.

Таким образом, были приняты классы для обучения модели, а именно значения Ra : 12,5; 6,3; 3,2; 2,5; 1,6; 1,25; 0,8; 0,4, которые выделены желтым цветом на рис. 1.

После того как были определены классы для обучения, были созданы два набора данных для двух моделей: первой – для обнаружения и выделения на чертежах областей, содержащих знаки шероховатости вне зависимости от их значений, и второй – для непосредственной классификации выделенных областей по конкретным значениям.

Набор данных для обучения первой модели был создан из подготовленных ранее 2000 изображений чертежей в формате “JPEG”, с которым работает модель “YOLO”, который далее был разделен на две части: тренировочную и проверочную. Тренировочная часть составила 1600 изображений (80%), проверочная – остальные 400 изображений (20%). Далее для всех этих изображений была выполнена «разметка» (подготовка текстовых файлов с координатами искомого объектов на изображении), суть которой состояла в выделении всех возможных знаков шероховатости на чертежах. Пример того, как это было выполнено на одном из изображений из обучающего набора, представлен на рис. 2.

ГОСТ 2789–73 С. 3

8.1. Среднеарифметическое отклонение профиля Ra

Таблица 2

МКМ				
100	10,0	1,00	0,100	0,010
80	8,0	0,80	0,080	0,008
63	6,3	0,63	0,063	—
50	5,0	0,50	0,050	—
40	4,0	0,40	0,040	—
32	3,2	0,32	0,032	—
25	2,5	0,25	0,025	—
20	2,0	0,20	0,020	—
16,0	1,60	0,160	0,016	—
12,5	1,25	0,125	0,012	—

Примечание. Предпочтительные значения параметров подчеркнуты.

Рис. 1. Выбор значения классов для обучения модели из значений по ГОСТ 2789–73

Fig. 1. Selection of class values for model training based on the values specified in GOST 2789–73




Рис. 2. Пример размеченного изображения из обучающего набора данных

Fig. 2. Example of an annotated image from the training dataset

После подготовки обучающего набора для модели для обнаружения объектов на изображении был подготовлен набор данных для обучения модели для классификации объектов. Подготовка данного “DataSet” для такой модели не требует разметки и она состоит в том, чтобы распределить классифицируемые объекты по папкам. Для этого было подготовлено 2000 изображений тех знаков шероховатости, которые были определены ранее, с дальнейшим разделением их на два набора: тренировочный и проверочный в соотношении 85 и 15%. В итоге имеем 8 папок в каждом наборе: 12,5; 6,3; 3,2; 2,5; 1,6; 1,25; 0,8; 0,4. Кроме того, необходимо отметить, что все изображения были получены обрезкой по координатам с тех чертежей, которые были использованы для обучения первой модели. Пример изображений из обучающего набора данных для модели для классификации представлен на рис. 3.




Рис. 3. Примеры изображений из набора данных для обучения модели для классификации
Fig. 3. Examples of images from the dataset used to train the classification model

Второй этап – обучение двух необходимых моделей. Первой была обучена модель для обнаружения знаков шероховатости на чертежах. Как было сказано ранее, в качестве базовой модели были взята модель “YOLO”, которая уже предварительно обучена распознавать некоторые типы объектов на изображениях и видео и которая была переобучена для выполнения поиска необходимых нам объектов на наборе данных,


описанном на предыдущем этапе. Исходные данные для обучения модели имели следующие значения:

- приводимое разрешение изображений по большей стороне – 1280;
- количество шагов – 16;
- количество эпох обучения – 30.

Пример того, как модель во время обучения выделяла знаки шероховатости на изображениях из проверочного набора, представлен на рис. 4. Данный пример был получен в результате обработки моделью набора данных на эпохе с наибольшей полученной точностью. На рис. 4 видно, что модель смогла найти и выделить в рамки все имеющиеся знаки шероховатости на представленных изображениях.

В итоге после обучения была получена модель объемом 13,9 МБ, взятая с одной из тридцати эпох обучения с наибольшей точностью, со следующими характеристиками, которые используют для оценки качества подобных моделей:

- “P” (точность модели, показывающая долю правильных ответов из всех, которые предоставила модель) – 0,926;
- “R” (полнота охвата моделью, показывает долю найденных объектов из тех, которые были на изображениях) – 0,931;
- “mAP50” (среднее значение средней точности AP, рассчитываемой из показателей P и R, по всем классам при перекрытии размеченной рамки и рамки определенной модели 50%) – 0,967;
- “mAP50-95” (среднее арифметическое значение средней точности AP по всем классам, рассчитываемое при различном проценте перекрытия от 50 до 95%) – 0,612.



Приемлемые значения данных показателей, которые определены как приемлемые разработчиками базовой модели для большинства случаев, составляют: “P” – 0,7; “R” – 0,7; “mAP50” – 0,6, “mAP50-95” – 0,5. Полученные значения являются весьма высокими и превышают уровень, считающийся приемлемым.

На графиках, представленных на **рис. 5**, можно видеть, как изменялись данные четыре показателя в течение тридцати эпох обучения.




Рис. 5. Графики изменения показателей P, R, mAP50, mAP50-95 во время тридцати эпох обучения
Fig. 5. Graphs of changes in indicators P, R, mAP50, mAP50-95 during thirty training epochs

После обучения был проведен тест полученной модели на случайных изображениях чертежей в количестве 35 шт. На 34-х из 35-ти изображений модель не допустила ни одной ошибки. На одном изображении модель дополнительно выделила области, не содержащие знаки шероховатости.

Далее была обучена вторая модель для классификации знаков шероховатости по 8-ми классам: 12,5; 6,3; 3,2; 2,5; 1,6; 1,25; 0,8; 0,4. За базу также была принята предварительно обученная модель “YOLO”. Исходные данные для обучения модели:

- приводимое разрешение изображений по большей стороне – 224 (низкое значение, так как изображения из набора данных имеют низкое разрешение);

- количество шагов – 32;

- количество эпох обучения – 100.

Для оценки модели для классификации объектов основным является показатель “top1_acc”, который показывает долю правильных ответов среди ответов с самой высокой вероятностью для изображений из проверочной части обучающего набора. В итоге имеем значение 0,972 для всех классов, на эпохе с наивысшей точностью. То есть модель правильно определила 97% изображений, что является очень

высоким показателем. График изменения данного показателя в течение 100 эпох обучения представлен на **рис. 6**.

После обучения для полученной модели был проведен тест на 50-ти изображениях различных шероховатостей. В результате было правильно определено значение шероховатости на 48-ми изображениях из тестового набора.




Рис. 6. График изменения показателя “top1_acc” во время ста эпох обучения

Fig. 6. Graph of changes in the “top1_acc” indicator during one hundred training epochs

Таким образом, были получены две модели нейронных сетей для работы с изображениями, в нашем случае с чертежами, которые были испытаны на случайных изображениях и показали очень высокие показатели точности. Исходя из этого, было принято решение о возможности их применения для дальнейшей работы и использования в разрабатываемой программе для ЭВМ.

Третий этап – создание программы для ЭВМ.

После получения двух работоспособных моделей с удовлетворяющими нас показателями точности была разработана программа для ЭВМ, которая при помощи этих двух моделей может определять значение параметра наименьшей шероховатости поверхностей, полученных методами точения и фрезерования, на чертежах деталей в автоматизированном режиме. Данная программа была написана на языке программирования “Python”, так как используемая версия модели “YOLO” работает с кодом, написанным на данном языке. Основные функции полученной программы:

- при помощи первой модели для обнаружения объектов находить на чертежах области, содержащие знаки шероховатости и выделять их в рамки;

- вырезать с чертежей найденные знаки шероховатости по выделенным рамкам;

- при помощи второй модели классифицировать значения шероховатостей для получения конкретного значения из каждой выделенной первой моделью рамки;

- корректировать полученные результаты классификации и исключать значения с низкой вероятностью достоверности ответа;

– выбирать наименьшее значение из тех, которые были получены после обработки второй моделью на предыдущем этапе;

– заносить полученные значения и номера чертежа в таблицу в редактируемом формате.

Все указанные функции программа выполняет автоматически, от пользователя необходима лишь корректировка значений в случае обнаружения ошибок.

После того как разработка была завершена, был проведен тест полученной программы, который был проведен на тестовом наборе данных, состоящем из 35-ти случайных изображений чертежей деталей. В результате, разработанная программа смогла успешно выполнить все перечисленные ранее функции. Правильно было определено 34 из 35-ти значения параметра минимальной шероховатости для деталей. Кроме того, все полученные значения были занесены в таблицу в редактируемом формате. Среднее время обработки одного изображения составило примерно 5 с. На рис. 7 в качестве примера представлен один чертеж из тестового набора, который был успешно обработан, и результат был выведен пользователю.

Исходя из вышесказанного, можно утверждать, что разработанная программа смогла выполнить возлагаемые на неё функции, определить подавляющее большинство искомых значений и вывести их пользователю в виде документа в редактируемом формате.

Заключение

Обе разработанные модели на основе нейронной сети для обнаружения объектов на изображениях и видео “YOLO” показали высокие показатели качества

после их обучения и тестирования. Первая модель для обнаружения знаков шероховатости на чертежах смогла показать хорошие результаты, что можно подтвердить значениями характеристик точности моделей для обнаружения объектов “P, R, mAP50, mAP50-95”, которые оказались значительно выше рекомендуемых разработчиками базовой модели для большинства случаев как приемлемые. Также работоспособность данной модели была подтверждена результатами проведенного тестирования на 35-ти случайных изображениях чертежей деталей, по результатам которого модель смогла обработать без ошибок 34 изображения из 35-ти. На одном изображении также были правильно выделены все области, содержащие значения шероховатости, но на нем были выделены и области, которые её не содержат.

Вторая модель для классификации знаков шероховатости по восьми видам (12,5; 6,3; 3,2; 2,5; 1,6; 1,25; 0,8; 0,4) также показала весьма высокий результат. Основным показателем точности для таких моделей, показывающий долю правильных ответов, составил 0,972, то есть 97% правильных ответов, полученных во время обучения модели на эпохе с самой высокой точностью. По результатам теста также был получен хороший результат – модель смогла правильно определить 48 из 50-ти объектов на тестовых изображениях правильно. Исходя из этого, можно сказать, что полученные модели показали высокую эффективность при обнаружении и классификации знаков шероховатости при обнаружении их на чертежах деталей в формате изображения “JPEG”.




Рис. 7. Пример одного из обработанных чертежей во время тестирования

Fig. 7. Example of an engineering drawing processed during testing

Разработанная программа для ЭВМ, использующая разработанные модели, также показала весьма высокие результаты своей работы. По результатам проведенного теста программа смогла правильно обработать 34 из 35-ти случайных изображений чертежей деталей и вывести пользователю их минимальные значения параметра шероховатости поверхностей, полученных методами точения и фрезерования. Программа выполнила все описанные ранее функции и смогла создать таблицу в редактируемом формате, содержащую названия чертежей и полученные значения шероховатости в автоматическом режиме. Среднее время обработки одного изображения составило примерно 5 с.

Полученные в ходе работы результаты имеют значительные перспективы для их применения в практической деятельности, так как обе разработанные модели и программа для ЭВМ могут быть использованы как составная часть метода для автоматизированного подбора оборудования для выполнения операции механической обработки вместе с другими частями разрабатываемого программного комплекса. Это, в свою очередь, может способствовать частичной автоматизации работы технологов при выполнении подбора металлорежущего оборудования, а именно токарных и фрезерных станков. Также полученные результаты могут быть использованы для сортировки и группирования деталей.

Подводя итоги, можно сказать, что разработанная программа для ЭВМ имеет хорошие перспективы её применения и может быть интересна представителям предприятий единичного и серийного производства, которые имеют большую производственную номенклатуру и занимаются изготовлением деталей на токарных и фрезерных станках.

Список источников

1. Сверточные нейронные сети для выявления дефектов и повреждений конструкций / Степанов Д.В., Макаров А.В., Молотов А.М., Облетов Е.Н. // Промышленное и гражданское строительство. 2024. № 9. С. 52-58.
2. Алтунина К.А., Соколова М.В. Применение нейронных сетей для моделирования процесса токарной обработки // Вестник ТГТУ. 2016. Т. 22. № 1. С. 122-133.
3. Суздалева Н.Н. Потенциал использования нейросетей промышленными предприятиями в условиях российской действительности // Региональная и отраслевая экономика. 2022. №11 (173). С. 91-94.
4. Веретельников А. С., Гавлицкий А. И. Применение искусственного интеллекта в металлообрабатывающей промышленности // Электронный научный журнал «Дневник науки». 2022. №12.
5. Алханов А.А. Машинное обучение и его применение в современном мире // Проблемы науки. 2021. №7 (66). С. 25-27.
6. Redmon J., Farhadi A. YOLO9000: Better, Faster, Stronger // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2017, pp. 7263–7271.

7. Redmon J., Shooji F., Farhadi A. YOLOv5 Training and Improving Object Detectors and Segmentation Models with One Click. // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2022, pp. 962–972.
8. Lin T.-Y., Dollár P., Girshick R., He, K., Hariharan, B., Belongie, S. Feature Pyramid Networks for Object Detection. // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2017, pp. 936–944.
9. Кузнецов С.В., Роговик А.А., Кузнецова Е.С. Детекция деталей, получаемых методами токарной обработки, с использованием модели для распознавания объектов YOLOv5 // Вестник Магнитогорского государственного технического университета им. Г.И. Носова. 2025. Т. 23. №3. С. 122-128. <https://doi.org/10.18503/1995-2732-2025-23-3-122-128>
10. Bochkovskiy A., Wang, C. YOLOv5: Creating State-of-the-Art Object Detectors in Real Time. [S. l.] // ArXiv, 2021, pp. 214–219.
11. Bochkovskiy A. YOLOv7: Trainable Boosted Data-Driven Layer for Real-Time Object Detection. [S. l.] // ArXiv, 2023, pp. 5147–5155.
12. Кузнецов С.В., Роговик А.А. Определение максимального диаметра деталей типа тел вращения на чертежах в автоматизированном режиме // Вестник ИжГТУ имени М.Т. Калашникова. 2025. Т. 28, № 4. С. 29–35. DOI: 10.22213/2413-1172-2025-4-29-35
13. Кузнецов С.В., Роговик А.А. Автоматизированное нахождение и распознавание длин деталей типа тела вращения на чертежах с использованием инструментов компьютерного зрения // Вестник Магнитогорского государственного технического университета им. Г.И. Носова. 2026. Т. 24. №1. С. 133-141. <https://doi.org/10.18503/1995-2732-2026-24-1-133-141>
14. Митрофанов С.П. Научная организация машиностроительного производства. Л.: Машиностроение, 1976. 712 с.
15. Кузнецов С. В., Роговик А.А. Группирование деталей тел вращения типа диск и ему подобных при планировании их изготовления с целью увеличения серийности производства // Вестник ИжГТУ имени М.Т. Калашникова. 2025. Т. 28, № 1. С. 24–32. DOI: 10.22213/2413-1172-2025-1-24-32.

References

1. Stepanov D.V., Makarov A.V., Molotov A.M., Obletov E.N. Convolutional neural networks for detecting defects and damage in structures. *Promyshlennoe i grazhdanskoe stroitel'stvo* [Industrial and Civil Engineering]. 2024;(9):52-58. (In Russ.)
2. Altunina K.A., Sokolova M.V. Application of neural networks for modeling the turning process. *Vestnik TGTU* [Vestnik of TSTU]. 2016;22(1):122-133. (In Russ.)
3. Suzdaleva N.N. Potential for the use of neural networks by industrial enterprises under Russian conditions. *Regionalnaya i otraslevaya ekonomika* [Regional and sectoral economics]. 2022;(11(173)):91-94. (In Russ.)
4. Veretelnikov A.S., Gavlit'skiy A.I. Application of artificial intelligence in the metalworking industry. *Elektronnyy nauchnyy zhurnal «Dnevnik nauki»* [Electronic scientific journal "Diary of Science"]. 2022;(12). (In Russ.)

5. Alkhanov A.A. Machine learning and its application in the modern world. *Problemy nauki* [Problems of science]. 2021;(7(66)):25-27. (In Russ.)
6. Redmon J., Farhadi A. YOLO9000: Better, Faster, Stronger. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). 2017, pp. 7263-7271.
7. Redmon J., Shooji F., Farhadi A. YOLOv5 Training and Improving Object Detectors and Segmentation Models with One Click. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). 2022, pp. 962-972.
8. Lin T.-Y., Dollár P., Girshick R., He K., Hariharan B., Belongie S. Feature Pyramid Networks for Object Detection. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). 2017, pp. 936-944.
9. Kuznetsov S.V., Rogovik A.A., Kuznetsova E.S. Detection of parts produced by turning using the YOLOv5 object recognition model. *Vestnik Magnitogorskogo gosudarstvennogo tekhnicheskogo universiteta im. G.I. Nosova* [Vestnik of Nosov Magnitogorsk State Technical University]. 2025;23(3):122-128. (In Russ.) DOI: 10.18503/1995-2732-2025-23-3-122-128.
10. Bochkovskiy A., Wang C. YOLOv5: Creating State-of-the-Art Object Detectors in Real Time. [S. l.]. ArXiv. 2021;214-219.
11. Bochkovskiy A. YOLOv7: Trainable Boosted Data-Driven Layer for Real-Time Object Detection. [S. l.]. ArXiv. 2023;5147-5155.
12. Kuznetsov S.V., Rogovik A.A. Automated determination of the maximum diameter of rotational parts in engineering drawings. *Vestnik IzhGTU imeni M.T. Kalashnikova* [Bulletin of Kalashnikov Izhevsk State Technical University]. 2025;28(4):29-35. (In Russ.) DOI: 10.22213/2413-1172-2025-4-29-35.
13. Kuznetsov S.V., Rogovik A.A. Automated detection and recognition of the lengths of rotational parts in engineering drawings using computer vision tools. *Vestnik Magnitogorskogo gosudarstvennogo tekhnicheskogo universiteta im. G.I. Nosova* [Vestnik of Nosov Magnitogorsk State Technical University]. 2026;24(1):133-141. (In Russ.) DOI: 10.18503/1995-2732-2026-24-1-133-141.
14. Mitrofanov S.P. *Nauchnaya organizatsiya mashinostroitel'nogo proizvodstva* [Scientific organization of machine-building production]. Leningrad: Mashinostroenie, 1976, 712 p. (In Russ.)
15. Kuznetsov S.V., Rogovik A.A. Grouping of disk-type rotational parts and similar parts when planning their manufacture in order to increase production series. *Vestnik IzhGTU imeni M.T. Kalashnikova* [Bulletin of Kalashnikov Izhevsk State Technical University]. 2025;28(1):24-32. (In Russ.) DOI: 10.22213/2413-1172-2025-1-24-32.

Поступила 29.01.2026; принята к публикации 20.02.2026; опубликована 30.09.2026
Submitted 29/01/2026; revised 20/02/2026; published 30/09/2026

Кузнецов Сергей Викторович – кандидат технических наук, доцент,
заведующий кафедрой «Машиностроительные технологические комплексы»,
Нижегородский государственный технический университет им. Р.Е. Алексеева, Нижний Новгород, Россия.
Email: ks251072@yandex.ru. ORCID 0009-0004-9532-1671

Роговик Артем Алексеевич – аспирант,
Нижегородский государственный технический университет им. Р.Е. Алексеева, Нижний Новгород, Россия.
Email: artem-rogovik@mail.ru. ORCID 0009-0004-4099-7324

Sergey V. Kuznetsov – PhD (Eng.), Associate Professor,
Head of the Department of Machine-Building Technological Complexes,
Nizhny Novgorod State Technical University named after R.E. Alekseev, Nizhny Novgorod, Russia.
Email: ks251072@yandex.ru . ORCID 0009-0004-9532-1671

Artem A. Rogovik – Postgraduate Student,
Nizhny Novgorod State Technical University named after R.E. Alekseev, Nizhny Novgorod, Russia.
Email: artem-rogovik@mail.ru . ORCID 0009-0004-4099-7324