

С.Н. Кункин¹, А.С. Платонова², Л.Б. Аксенов³

РАЗРАБОТКА ГРУППОВОЙ ТЕХНОЛОГИИ ТОРЦЕВОЙ РАСКАТКИ С ИСПОЛЬЗОВАНИЕМ НЕЙРОСЕТИ



¹Кункин Сергей Николаевич,
Санкт-Петербургский политехнический университет
Петра Великого
Россия, Санкт-Петербург
Тел.: +79043343607, E-mail: kunkin@spbstu.ru



²Платонова Александра Сергеевна
Национальный исследовательский университет ИТМО
Россия, Санкт-Петербург
Тел.: +79213975162, E-mail: asplatonova@itmo.ru



³Аксенов Леонид Борисович,
Санкт-Петербургский политехнический университет
Петра Великого
Россия, Санкт-Петербург
Тел.: +79219316786, E-mail: l_axenov@mail.spbstu.ru

Аннотация

В статье представлен результат использования искусственного интеллекта для распознавания геометрических групп деталей, изготавливаемых обработкой металлов давлением. В качестве объекта исследования выбраны пять групп осесимметричных деталей, производимых с применением холодной торцевой раскатки. Для распознавания принадлежности деталей к этим группам синтезирована сверточная нейронная сеть, построенная на базе TensorFlow и API Keras. После обучения сети степень распознавания для выбранных пяти групп составляла не менее 90%. Предлагаемый подход определения геометрической группы деталей позволяет отойти от субъективной оценки геометрии деталей, и осуществить полную цифровизацию процесса

проектирования с реализацией преимуществ группового метода изготовления.

Ключевые слова: обработка металлов давлением, торцевая раскатка, нейронная сеть, распознавание, групповая технология, группы поковок

Введение

Созданные теоретические основы построения и использования искусственного интеллекта [1-5] в настоящее время активно реализуются в решении многих практических задач, в том числе, в машиностроении [6]. Россия вошла в число мировых лидеров по стандартизации применения технологий искусственного интеллекта – за последние пять лет был создан фонд более чем из 120 ГОСТов [7]. Среди них специальный стандарт, регламентирующий применение искусственного интеллекта в машиностроении [8].

Примеры применения искусственного интеллекта в машиностроении в основном затрагивают проблемы контроля и повышения качества продукции [9]. Это относится и к процессам обработки металлов давлением [10]. Однако искусственный интеллект может сыграть положительную роль в организации производства. Так, использование нейросетей может оказаться весьма эффективным при анализе геометрии изготавливаемых деталей с целью внедрении группового метода обработки, реализуя все преимущества этого метода. Типизация технологических процессов, предложенная А.П. Соколовским [11], и групповой метод обработки, развитый С. П. Митрофановым для механических цехов [12], в заготовительном производстве основаны на классификации геометрически однородных деталей в отдельные группы, для изготовления которых требуется общее оборудование, оснастка, приспособления и т.д. Этот подход, в значительной мере развитый для традиционных процессовковки, объемной и листовой штамповки, еще не охватывает все процессы обработки металлов давлением, в том числе и процессы торцевой раскатки.

Цель работы: определить возможность использования нейросети для определения геометрической группы для деталей изготавливаемых процессом холодной торцевой раскатки.

Метод исследования

Среди многочисленных технологий обработки металлов давлением значительное место занимает процесс торцевой раскатки. Технология торцевой раскатки является разновидностью процессов локального деформирования, со сложным движением инструмента относительно обрабатываемой детали. По сравнению со многими технологиямиковки и

штамповки эта технология, созданная в начале XX века [13, 14], является сравнительно молодой. Теоретические основы этой технология были сформулированы только в конце XX века [15], а технологические возможности еще продолжают исследоваться [16-18]. Для реализации этой технологии создаются новые, оригинальные, инновационные машины, что позволяет реализовать различные технологические приемы раскатки [19]. Применение в процессе торцевой раскатки конических и цилиндрических валков, разнообразного вспомогательного инструмента, активного и пассивного приводов для вращения заготовки обеспечивают широкие возможности этого процесс для получения деталей разнообразной геометрии из полых, прутковых и кольцевых заготовок (рис. 1).




Рис. 1. Примеры процессов торцевой раскатки при производстве осесимметричных деталей: раскатка внутреннего фланца на трубной заготовке коническим валком (а); раскатка наружного фланца на трубной заготовке цилиндрическим валком (б); раскатка внутреннего фланца из кольцевой заготовки (в)
1 – обойма, 2 – матрица, 3 – заготовка, 4 – оправка, 5 – валок, 6 – деталь

Детали, изготавливаемые торцевой раскаткой, в зависимости от их конфигурации подразделяют на три основные группы, при этом каждая из групп разделяется на подгруппы численностью от трех до шести (Рис. 2). Принадлежность детали к одной из групп в значительной мере определяет технологию ее изготовления: вид и количество раскатных валков, применение оправки. Обычно подгруппа для детали выбирается технологом субъективно, исходя из общих рекомендаций и собственного опыта. Применение нейронных сетей для распознавания групп поковок открывает новые возможности для формализации решения этой проблемы.

Для различных задачи классификации изображений широко используются модели, предобученные на больших наборах данных изображений. В работе для определения принадлежности деталей к одной из технологических групп использовалась предобученная сверточная нейронная сеть ResNet50V2 [20]. Нейросеть была построена на базе TensorFlow [21] и API Keras [22], которые обеспечили возможность работы с моделями типа Sequential [23]. Сеть состояла из 50 слоев, что позволило ей улавливать сложные паттерны [24] и особенности в данных. Нейросеть

этого класса уже была успешно использована для процесса распознавания типа поковок изготавливаемых на горизонтально-ковочных машинах [25].






Рис. 2. Укрупненная классификация деталей, изготавливаемых торцевой раскаткой

Для адаптации ResNet50V2 к решению поставленной задачи определения группы деталей, т.е. реализации трансферного обучения, где модель подстраивается для решения конкретной задачи классификации, нейросеть была дополнена классификатором, состоящим из нескольких слоев: Flatten, Dense, Dropout.

Для создания набора данных для обучения нейронной сети были выбраны пять подгрупп (1.1, 1.3, 1.4, 2.3, 3.2) осесимметричных деталей изготавливаемых их различных видов заготовок (табл. 1).

Таблица 1. Группы раскатанных деталей, выбранные для распознавания

Номер группы	Описание технологической группы	Пример детали
1.1	С формированием наружной фланцевой части у торцевой поверхности трубной заготовки	
1.3	С формированием внутренней фланцевой части на трубной заготовке	
1.4	С формированием внутренней и наружной фланцевой части на трубной заготовке	
2.3	С формированием внутренней фланцевой части кольцевой заготовки	
3.2	С формированием наружной фланцевой части сложной формы на прутковой заготовке	

Детали, изготавливаемые торцевой раскаткой, имеют определенные отличия, которые должна распознать нейросеть. К этим особенностям относится наличие сквозного отверстия на деталях, изготавливаемых из трубных заготовок, или его отсутствие на деталях, изготавливаемых из прутка. Можно предположить, что это различие нейросеть легко распознает. Разница в других геометрических особенностях, таких как вид и профиль раскатываемого фланца, более трудны для распознавания, т.к. локально сосредоточены в торцевых частях деталей, объем (или площадь в сечении) которых много меньше полного объема деталей.

Обучение нейронной сети проводилось с использованием набора данных по структуре похожих на CIFAR-10, в котором представлены

меридиональные, несколько утрированные, сечения выбранных типов деталей (табл. 2).

Таблица 2. Исходный набор данных для обучения нейронной сети

1.1									
1.3									
1.4									
2.3									
3.2									

Модель ResNet50V2 относится к нейронным сетям, которые используют принцип "обучение с учителем" (supervised learning). Такой метод обучения подразумевает работу с заранее размеченным набором данных, то есть таким, где изображения разделены на группы с соответствующей меткой (в нашем случае это номер группы) и эта метка ожидается как выходной результат. Такие модели обучаются на тренировочном наборе данных, используя различные алгоритмы для определения взаимосвязей между входными признаками и выходными метками. Во время обучения модели делается попытка минимизировать функцию потерь, которая измеряет неточности в предсказаниях сети.

Глубокие нейронные сети обучаются путем подстройки своих связей так, чтобы лучше передавать входные сигналы через множество слоев тем нейронам, которые отвечают за различные способы обработки, и имеют пять основных этапов обучения (рис. 3).




Рис. 3. Этапы обучения нейронной сети ResNet50V2

В отличие от первой версии нейросети ResNet50V1, ResNet50V2 получила изменения в архитектуре (рис. 4), в частности, была добавлена пакетная нормализация (Batch Normalization) [26]. Это позволило сети обучаться быстрее, то есть, потребовалось меньше эпох для достижения нижней границы потерь, что в свою очередь сократило время обучения. Также в сети ResNet50V2 использовалась регуляризация через шум.




Рис. 4. Структура синтезированной нейронной сети ResNet50V2
(в упрощенном виде)

Во время обучения Batch Normalization нормализует выходные данные (активации) после каждого слоя модели по мини-батчам (небольшим группам тренировочных данных). Эта нормализация добавляет некоторый уровень вариации (шума) к активациям модели. Каждый

мини-батч имеет свои собственные параметры (среднее и стандартное отклонение), что приводит к тому, что модель не может слишком сильно подстраиваться под конкретные данные в обучающем наборе. Это помогает снизить возможность переобучения сети на обучающей выборке.

Для предварительной обработки данных используется библиотека PIL (Pillow), позволяющая выполнять базовые операции с растровыми изображениями. Библиотека NumPy применяется для работы с многомерными массивами, она необходима для выполнения вычислений, связанных с вероятностными предсказаниями модели.

Перед началом обучения данные разделяются на три категории: 70% используются для обучения, 15% — для валидации, а оставшиеся 15% — для тестирования. В процессе обучения проведены пять итераций (эпох) (рис. 5).




Рис. 5. Графики точности и потерь для тренировочного и проверочного наборов данных для исходной (а) и оптимизированной модели нейросети (б)

До четвертой эпохи обучения точность для тренировочной и валидационной выборок растет, что указывает на нормальное обучение модели (рис. 5, а). Графики потерь до пятой эпохи соответствуют стандартному процессу обучения, постоянно снижаясь. Небольшой рост потерь на валидационной выборке считается допустимым. Начиная с пятой итерации, на проверочной выборке наблюдается плато, а позже резкий спад, такое поведение графика может говорить о переобучении, то есть модель перестает отличать детали одного типа от другого (рис. 5, а). На это так же указывает рост потерь на тренировочной выборке после 6 эпохи обучения.

Так как для работы была выбрана предобученная модель с большим количеством слоев, изменение ее конфигурации и подбор гиперпараметров

(количество слоев, количество нейронов в каждом слое, скорость обучения и функции активации) для достижения наибольшей точности модели задача достаточно трудоемкая. Для решения этой проблемы была использована библиотека Keras Tuner [27], позволяющая автоматизировать подбор гиперпараметров в моделях глубокого обучения, построенных с использованием Keras, что позволило исследовать различные конфигурации моделей для достижения оптимальной производительности. В результате проведения десяти тестов с помощью Keras Tuner были определены рациональные значения гиперпараметров:

- число нейронов в плотном слое = 192;
- параметр Dropout = 0.4, указывающий, что во время обучения нейронной сети слой Dropout будет случайным образом отключать 40% нейронов в этом слое на каждой итерации обучения; выключая значительное количество нейронов, Dropout заставляет модель учиться более обобщенным паттернам, а не запоминать детали обучающего набора данных; это помогает избежать переобучения;
- коэффициент скорости обучения (learning rate) = 0.0006.

Модель была обучена повторно, исходя из найденных значений гиперпараметров. В результате точность на графиках достигла значения 0.9 ко второй эпохе обучения, а после фазы плато снова начинает расти (рис. 5, б). Резкий скачок графика потерь для валидационной выборке свидетельствует об изменении гиперпараметров модели. Но так как далее наблюдается быстрый спад, то можно сделать вывод, что параметры подобраны достаточно правильно, и обучение модели проходит в нормальном режиме, без явного переобучения.





Обсуждение результатов

После обучения сеть загружались изображения деталей различных групп, но не входящие в исходный обучающий набор данных, а от нейросети требовалось определить тип, к которому относится изображение и достоверность совпадения. Для итогового тестирования использовалась модель, обученная с гиперпараметрами, подобранными с помощью Keras Tuner. Результаты распознавания групп анализируемых деталей приведены в таблице 3. Нейросеть успешно определила принадлежность деталей к исследуемым пяти группам с достоверностью 91-99%.

Далее в нейросеть были загружены для распознавания сечения контрольных деталей, не принадлежащих ни к одной из перечисленных пяти групп, использованных при обучении нейросети. Созданная сеть определила для этих деталей группу с набором признаков, которая имеет наибольшее число совпадений с исходной геометрией детали. Так, одна из деталей была отнесена к группе 1.1 - полых деталей с наружным фланцем

(табл. 3). Однако фланец на контрольной детали заметно отличался от фланцев деталей группы 1, так как высота фланца значительно превосходила его ширину. Поэтому вероятность отнесения этой детали к группе 1 составила только 42,08%.

Таблица 3. Результаты распознавания типа поковок нейронной сетью

1.1	1.3	1.4	2.3	3.2	Неизвестный тип	
						
94,64%	96,32%	95,1%	99,1%	91,23%	1.1 40,46%	3.2 42,08%

Другая контрольная деталь была отнесена к группе 3.2. Нейросеть распознала, что деталь изготавливается из прутковой заготовки, но ее фланцевая часть характерна скорее для операции высадки, чем для торцевой раскатки. Как результат, достоверность отнесения этой контрольной детали к группе 3.2 была определена в 40,46%.

Следует отметить, что распределение деталей по группам, изготавливаемых торцевой раскаткой, были созданы специалистами, исследовавшими этот процесс. Важно было бы проанализировать, как определит эти группы нейросеть, если представить ей всю совокупность деталей, изготавливаемых этой технологией. Такие попытки уже были сделаны [28], получены интересные результаты, но требующие еще дополнительного анализа.

Заключение

- Синтезированная нейронная сеть после обучения оказалась способной распознавать пять групп осесимметричных деталей изготавливаемых торцевой раскаткой с достоверностью не менее 90%, что дает основание для практического использования нейросети в процессе создания групповых технологий торцевой раскатки.
- При анализе сечений деталей, не принадлежащих ни к одной из перечисленных трех групп, созданная нейросеть относила деталь к группе, для которой набор признаков имел наибольшее число совпадений с эскизом детали.

СПИСОК ЛИТЕРАТУРЫ

- [1] Горбань А. Н. Обучение нейронных сетей. М.: ParaGraph, 1990. 160 с.
- [2] Wasserman, Philip D., Advanced methods in neural computing. 1993 New York : Van Nostrand Reinhold, 255 p.
- [3] Prateek Joshi. Artificial Intelligence with Python. Packt Publishing Ltd, 2017, 446p.
- [4] Хайкин, С. Нейронные сети: полный курс / С. Хайкин. - М.: Диалектика, 2019. - 1104 с.
- [5] Дэвид Фостер. Генеративное глубокое обучение. Творческий потенциал нейронных сетей. Изд-во Питер, 2020, 336 с.
- [6] Yue LIU. The Review of Intelligent Mechanical Engineering Based on Artificial Neural Network. Электронный ресурс: <https://www.researchgate.net/publication/300620879> . Дата обращения: 02.02.2025
- [7] Научно-практический семинар «Развитие систем искусственного интеллекта в странах СНГ». МОСКВА, 18 ноября 2024 г. Электронный ресурс: <https://www.rst.gov.ru/newsRST/redirect/news/1/9619> . Дата обращения 05.02.2025
- [8] Национальный стандарт ПНСТ 955-2024. Искусственный интеллект в машиностроении. Варианты использования. Электронный ресурс: <https://protect.gost.ru/default.aspx/document1.aspx?control=31&baseC=6&page=9&month=11&year=2024&search=&id=263494> . Дата обращения: 15.01.2025.
- [9] Черепанов Н.В., Буслаев С.П. Проблемы и задачи развития искусственного интеллекта на машиностроительном предприятии. «Инновации и инвестиции». № 7. 2021, с.175-179.
- [10] S.Gondo, H.Arai. Data-driven metal spinning using neural network for obtaining desired dimensions of formed cup. CIRP Annals. Volume 71, Issue 1, 2022, Pages 229-232
- [11] Курс технологии машиностроения: Допущ. М-вом высш. образования СССР в качестве учебника для втузов / Проф. А. П. Соколовский, д-р техн. наук. - Москва ; Ленинград : [Ленингр. отд-ние] и 1-я тип. Машгиза в Л., 1947-1949. - 2 т.
- [12] Митрофанов С.П. Научные основы организации группового производства — М;Л.: Машгиз, 1963. — 308 с.
- [13] Slick E. E. The Slick Wheel Mill // The Iron Age. 1918. Vol. 102, N 9. P. 491–498.
- [14] Massey H. F. British Patent Specification. 1929. N 319065.

- [15] Standring P. M. The significance of nutation angle in rotary forging // Advanced Technology of Plasticity, Proceeding of the 6th ICTP. 1999. Vol. III. P. 1739–1744.
- [16] Агеев Н. П. Технологические возможности объемной штамповки обкатыванием на сферодвижном прессователе. Классификация процессов // Металлообработка. 2001. № 5. С. 36–44.
- [17] Recent development in orbital forging technology / J. Nowak, L. Madej, S. Ziolkiewicz, [et al.]. International Journ. Material Forming. 2008. Supp. 1. P. 387–390.
- [18] Аксенов Л.Б., Кункин С.Н. Машины и технологии торцевого локального деформирования (к 100-летию первой раскатной машины). Металлообработка. 2018. № 3 (105). С. 25-33.
- [19] MJC Engineering & Technology. Rotary Forging Brochure. [Электронный ресурс]. Режим доступа: <https://mjcengineering.com/machines/additional-equipment/%20rotary-forging-equipment/> Дата обращения 05.02.2025).
- [20] ResNet50v2 architecture. Электронный ресурс: https://www.researchgate.net/figure/ResNet50v2-architecture_fig1_359153551 . Дата обращения 11.01.2025
- [21] Create production-grade machine learning models with TensorFlow. Электронный ресурс: <https://www.tensorflow.org/?hl=en>. Дата обращения: 14.01.2024.
- [22] Keras 3 API documentation. Электронный ресурс: <https://keras.io/api/>. Дата обращения: 14.01.2024.
- [23] What are convolutional neural networks? Электронный ресурс: <https://www.ibm.com/topics/convolutional-neural-networks>. Дата обращения: 14.01.2024.
- [24] Dima Torius. Мозг изнутри (Визуализация прохождения паттерна через модель искусственной нейронной сети). Электронный ресурс: <https://habr.com/ru/articles/438972/> . Дата обращения 11.01.2025.
- [25] Аксенов Л.Б., Платонова А.С. Распознавание групповой принадлежности поковок с использованием нейронных сетей. Современное машиностроение: Наука и образование 2024: материалы 13-й Международной научной конференции, 20 июня 2024 года / Под ред. А.Н. Евграфова и А.А. Поповича. - СПб.: ПОЛИТЕХ-ПРЕСС, 2024, с. 625-638.
- [26] Martin Riva, Batch Normalization in Convolutional Neural Networks. Электронный ресурс: <https://www.baeldung.com/cs/batch-normalization-cnn>. Дата обращения: 11.01.2025.
- [27] KerasTuner. Электронный ресурс: https://keras.io/keras_tuner/ . Дата обращения: 13.03.2025
- [28] Elia Hamouche & Evripides G. Loukaides (2018) Classification and selection of sheet forming processes with machine learning, International

DEVELOPMENT OF A GROUP TECHNOLOGY FOR AXIAL ROTARY FORGING USING A NEURAL NETWORK

¹Peter the Great St. Petersburg Polytechnic University, Russia;

²ITMO University, St. Petersburg, Russia

Abstract

The paper presents the result of using artificial intelligence to recognize geometric groups of parts made by metal forming. Five groups of axisymmetric parts produced using cold axial rotary forging have been selected as the object of research. To recognize the details belonging to these groups, a convolutional neural network based on TensorFlow and the Keras API was synthesized. After training the network, the recognition rate for the selected groups was at least 90%. The proposed approach to determining the geometric group of parts allows us to move away from the subjective assessment of the geometry of parts, and to fully digitalize the design process with the implementation of the advantages of the group manufacturing method.

Keywords: metal forming, axial rotary forging, neural network, part groups, recognition, group technology

REFERENCES

- [1] Gorban' A. N. Obuchenie nejronnykh setej. M.: ParaGraph, 1990. 160 s.
- [2] Wasserman, Philip D., Advanced methods in neural computing. 1993 New York : Van Nostrand Reinhold, 255 p.
- [3] [Prateek Joshi](#). Artificial Intelligence with Python. Packt Publishing Ltd, 2017, 446p.
- [4] Khajkin, S. Nejronnye seti: polnyj kurs / S. Khajkin. - M.: Dialektika, 2019. - 1104 c.
- [5] Djevid Foster. Generativnoe glubokoe obuchenie. Tvorcheskij potentsial nejronnykh setej. Izd-vo Piter, 2020, 336 s.
- [6] Yue LIU. The Review of Intelligent Mechanical Engineering Based on Artificial Neural Network. Information on URL: <https://www.researchgate.net/publication/300620879> Accessed: 02.02.2025

- [7] Nauchno-prakticheskij seminar «Razvitie sistem iskusstvennogo intellekta v stranakh SNG». MOSKVA, 18 noyabrya 2024 g. Information on URL: <https://www.rst.gov.ru/newsRST/redirect/news/1/9619> . Accessed: 05.02.2025
- [8] Natsional'nyj standart PNST 955-2024. Iskusstvennyj intellekt v mashinostroenii. Varianty ispol'zovaniya. Information on URL: <https://protect.gost.ru/default.aspx/document1.aspx?control=31&baseC=6&page=9&month=11&year=2024&search=&id=263494>. Accessed: 15.01.2025.
- [9] Cherepanov N.V., Buslaev S.P. Problemy i zadachi razvitiya iskusstvennogo intellekta na mashinostroitel'nom predpriyatii. «Innovatsii i investitsii». № 7. 2021, c.175-179.
- [10] S.Gondo, H.Arai. Data-driven metal spinning using neural network for obtaining desired dimensions of formed cup. CIRP Annals. Volume 71, Issue 1, 2022, Pages 229-232
- [11] Kurs tekhnologii mashinostroeniya: Dopushch. M-vom vyssh. obrazovaniya SSSR v kachestve uchebnika dlya vtuzov / Prof. A. P. Sokolovskij, d-r tekhn. nauk. - Moskva ; Leningrad : [Leningr. otd-nie] i 1-ya tip. Mashgiza v L., 1947-1949. - 2 t.
- [12] Mitrofanov S.P. Nauchnye osnovy organizatsii gruppovogo proizvodstva - M;L.: Mashgiz, 1963. - 308 s.
- [13] Slick E. E. The Slick Wheel Mill // The Iron Age. 1918. Vol. 102, N 9. P. 491–498.
- [14] Massey H. F. British Patent Specification. 1929. N 319065.
- [15] Standring P. M. The significance of nutation angle in rotary forging // Advanced Technology of Plasticity, Proceeding of the 6th ICTP. 1999. Vol. III. P. 1739–1744.
- [16] Ageev N. P. Tekhnologicheskie vozmozhnosti ob'emnoj shtampovki obkatyvaniem na sferodvizhnom pressovatele. Klassifikatsiya protsessov // Metalloobrabotka. 2001. № 5. S. 36-44.
- [17] Recent development in orbital forging technology / J. Nowak, L. Madej, S. Ziolkiewicz, [et al.]. International Journ. Material Forming. 2008. Supp. 1. P. 387–390.
- [18] Aksenov L.B., Kunkin S.N. Mashiny i tekhnologii tortsevogo lokal'nogo deformirovaniya (k 100-letiyu pervoj raskatnoj mashiny). Metalloobrabotka >. 2018. № 3 (105). S. 25-33.
- [19] MJC Engineering & Technology. Rotary Forging Brochure. Information on URL: <https://mjcengineering.com/machines/additional-equipment/%20rotary-forging-equipment/> . Accessed: 05.02.2025).
- [20] ResNet50v2 architecture. Information on URL: https://www.researchgate.net/figure/ResNet50v2-architecture_fig1_359153551 . Accessed 11.01.2025

- [21] Create production-grade machine learning models with TensorFlow. Information on URL: <https://www.tensorflow.org/?hl=en>. Accessed: 14.01.2024.
- [22] Keras 3 API documentation. Information on URL: <https://keras.io/api/>. Accessed: 14.01.2024.
- [23] What are convolutional neural networks? Information on URL: <https://www.ibm.com/topics/convolutional-neural-networks>. Accessed: 14.01.2024.
- [24] Dima Topius. Mozg iznutri (Vizualizatsiya prokhozhdeniya patterna cherez model' iskusstvennoj neyronnoj seti). Information on URL: <https://habr.com/ru/articles/438972/>. Accessed: 11.01.2025.
- [25] Aksenov, L.B., Platonova, A.S. Raspoznavanie gruppovoj prinadlezhnosti pokovok s ispol'zovaniem neyronnykh setej. Sovremennoe mashinostroenie: Nauka i obrazovanie 2024: materialy 13-j Mezhdunarodnoj nauchnoj konferentsii, 20 iyunya 2024 goda / Pod red. A.N. Evgrafova i A.A. Popovicha. - SPb.: POLITEKhp-PRESS, 2024, s. 625-638.
- [26] Martin Riva, Batch Normalization in Convolutional Neural Networks. Information on URL: <https://www.baeldung.com/cs/batch-normalization-cnn>. Accessed: 11.01.2025.
- [27] KerasTuner. Information on URL: https://keras.io/keras_tuner/. Accessed: 13.03.2025
- [28] Elia Hamouche & Evripides G. Loukaides (2018) Classification and selection of sheet forming processes with machine learning, International Journal of Computer Integrated Manufacturing, 31:9, 921-932, <https://doi.org/10.1080/0951192X.2018.1429668>