

РАСПОЗНАВАНИЕ ГРУППОВОЙ ПРИНАДЛЕЖНОСТИ ПОКОВОК С ИСПОЛЬЗОВАНИЕМ НЕЙРОННЫХ СЕТЕЙ



¹Аксенов Леонид Борисович,
Санкт-Петербургский политехнический университет
Петра Великого
Россия, Санкт-Петербург
Тел.: +79219316786, E-mail: l_axenov@mail.spbstu.ru



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

Аннотация

В статье представлен результат использования нейронной сети для распознавания типов деталей, изготавливаемых обработкой металлов давлением. В качестве объекта исследования выбраны осесимметричные поковки, производимые на горизонтально-ковочных машинах. После этапа обучения синтезированная нейронная сеть смогла распознать принадлежность геометрии поволоков к определенной группе с достоверностью 90-97%. Предлагаемый подход позволяет отойти от субъективной оценки геометрии деталей, и реализовать полную цифровизацию проектирования технологического процесса.

Ключевые слова: штамповка, геометрия поволоков, распознавание, нейронная сеть

Введение

В последнее время задачам внедрения искусственного интеллекта уделяется большое внимание во всех отраслях науки и техники. Теоретические основы построения и использования искусственного интеллекта [1-5] стали реализовываться в решении многих практических задач. В целях обеспечения ускоренного развития искусственного

интеллекта в Российской Федерации, проведения научных исследований в области искусственного интеллекта, повышения доступности информации и вычислительных ресурсов для пользователей, совершенствования системы подготовки кадров в этой области вышел Указ Президента Российской Федерации [6]. В развитие этого Указа определены задачи развития искусственного интеллекта на машиностроительных предприятиях [7], и, в частности, при создании систем технологической подготовки производства.

Интересные и полезные для практики результаты получены по использованию искусственного интеллекта для совершенствования процессов обработки металлов давлением, и, в частности, процессов листовой и объемной штамповки. Среди проведенных исследований: анализ точности [8-11] и износа инструмента [12], синтез механизмов [13-15], выявление дефектов [16], классификации и выбора технологического оборудования [17].

Этапы технологической подготовки многих процессов обработки металлов давлением достаточно хорошо разработаны, в том числе с использованием компьютерного моделирования. При этом для каждого класса поковок, определяемого геометрией изготавливаемой детали, имеется набор определенных технологических решений, свойственных этому классу. Внедрение в процесс технологической подготовки производства этапа компьютерного распознавания класса поковок, который во многом решается эмпирически, исходя из опыта их разработчиков, позволит реализовать полную цифровизацию проектирования технологического процесса.

Цель работы: Показать возможность использования искусственного интеллекта для распознавания групповой принадлежности поковок, штампуемых на горизонтально-ковочных машинах.

Методы исследования

Среди многочисленных технологий обработки металлов давлением значительное место занимает горячая штамповка на горизонтально-ковочных машинах (ГКМ). Главными особенностями ГКМ являются (рис.1а): наличие разъема полу-матриц (2 и 3) в двух взаимно перпендикулярных плоскостях и передвижение главного высадочного ползуна (4) в горизонтальной плоскости, что позволяет штамповать детали разнообразной конфигурации (рис. 1б) в несколько переходов [18]. В качестве исходной заготовки (5) используется прутки круглого или квадратного сечения, трубный прокат.

Поковки, изготовляемые на ГКМ, в зависимости от их конфигурации подразделяют на шесть основных групп, при этом каждая из групп

разделяется на подгруппы численностью от двух до трех (табл. 1). Принадлежность поковки к одной из подгрупп в значительной мере определяет технологию ее изготовления, то есть использование технологических переходов: наборных, прошивных, формовочных, обрезных, просечных и др. Обычно принадлежность поковки к той или иной группе определяется технологом субъективно, исходя из общих рекомендаций и собственного опыта.


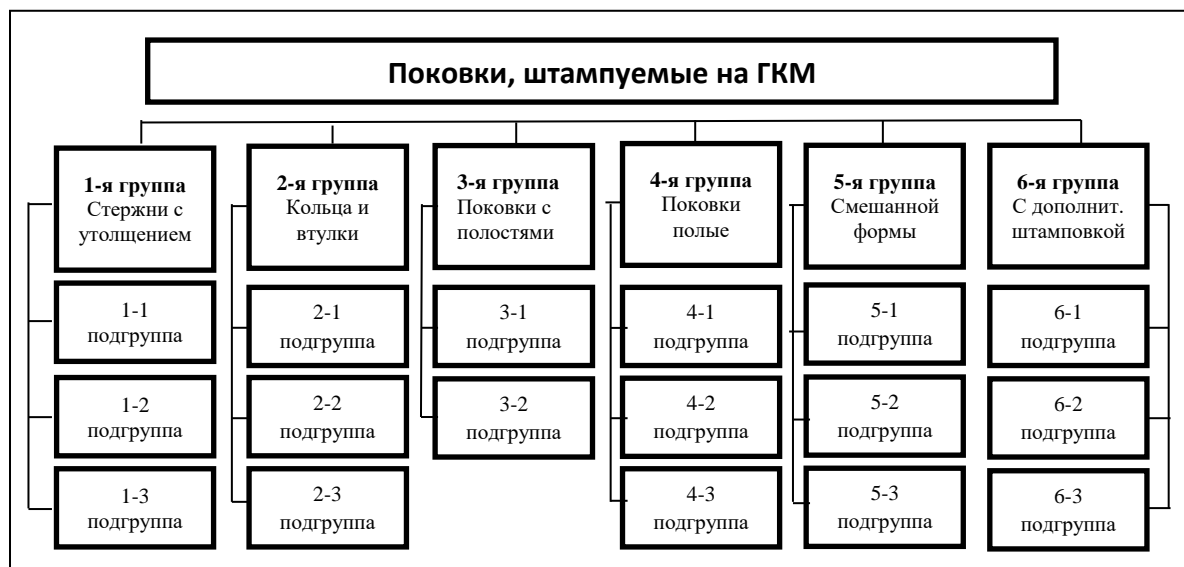


Рис. 1. Схема штамповки на горизонтально—ковочной машине: *а* – подача заготовки до упора (1), *б* – зажим заготовки полу матрицами, *в* – штамповка (высадка) поковки, *г* – удаление поковки (6) и примеры штампуемых поковок

Таблица 1. Классификация поковок, штампуемых на ГКМ

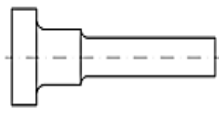
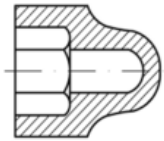
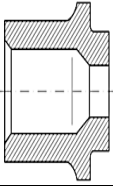
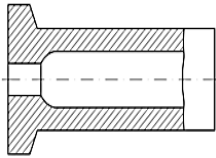
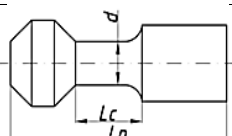


Для формализации отнесения поковок к определенному типу предпринимались несколько попыток, не получивших широкого

распространения, и прежде всего, использование анализа экстремальных вершин контура поковок [19]. Однако для этой операции необходимо специальное кодирование чертежа поковки, что не является обязательной процедурой проектирования технологического процесса, а также создание специальной компьютерной программы. В дальнейшем для этих целей были апробированы методы многомерного статистического анализа, и проверки статистических гипотез [20], которые требовали от пользователей глубокой математической и подготовки и знаний программирования. Применение нейронных сетей для распознавания групп поковок открывает новые возможности для формализации решения этой проблемы. Оно предусматривает следующие этапы: создание исходного банка данных для обучения нейронной сети, выбор структуры сети (построение модели), первичный этап обучения, изменение исходного набора данных, второй этап обучения, изменение параметров обучения, тестирование.


Для создания набора данных для обучения нейронной сети были выбраны пять подгрупп (А, В, С, D, E) осесимметричных поковок из различных групп (табл. 2).

Таблица 2. Типы поковок тел вращения, выбранные для распознавания

Код	Типы поковок	Эскизы
А	Стержень, с одним утолщением на конце	
В	С глухой полостью	
С	Кольца и втулки	
Д	Полые	
Е	С утолщениями на обоих концах	

На основе геометрии выбранных поковок был разработан банк данных, в котором отражались основные особенности подгрупп поковок. Эти данные представляли меридиональные сечения поковок, т.к. именно такие сечения отражают наиболее полно геометрию поковок и дают возможность представить внутреннюю их часть (отверстие или углубление). Таким образом, был построен исходный набор данных для распознавания пяти типов поковок, по структуре похожий на CIFAR-10, в котором представлены меридиональные сечения поковок разных типов (табл. 3).

Таблица 3. Типы поковок тел вращения, выбранные для распознавания



Для решения задач классификации изображений из множества подвидов нейронных сетей чаще всего используются сверточные нейронные сети - Convolutional Neural Network [21]. В работе была выбрана сеть с высоким уровнем абстракции TensorFlow [22], разработанная компанией Google, в связке с API Keras [23] для работы с

моделями типа Sequential, которая позволяет добавлять слои последовательно.

Модель синтезированной нейронной сети состояла из следующих слоев: нормализация данных, сверточный слой, пулинг, полносвязный слой. Для визуализации результатов процесса обучения были использованы: библиотека Matplotlib, компонент pyplot для построения графиков, библиотека PIL для обработки растровых изображений на языке python, и numpy - библиотека для работы с многомерными массивами на этапе тестирования для расчета точности распознавания модели.

Классическая структура обучения нейронной сети подразумевает разделение исходного массива данных на две категории: 80% - на обучение, 20% - на тестирование. В процессе исследования было проведено 10 итераций процесса обучения. Первоначально для обучения была использована модель сети с четырьмя сверточными слоями, что не дало желаемых значений точности модели.

Значение точности на тренировочном наборе (train_acc), начиная с шестой итерации обучения, имело несколько минимумов и опускалось до отметки 0.77 к концу обучения (рис. 2а), что не является удовлетворительным результатом.

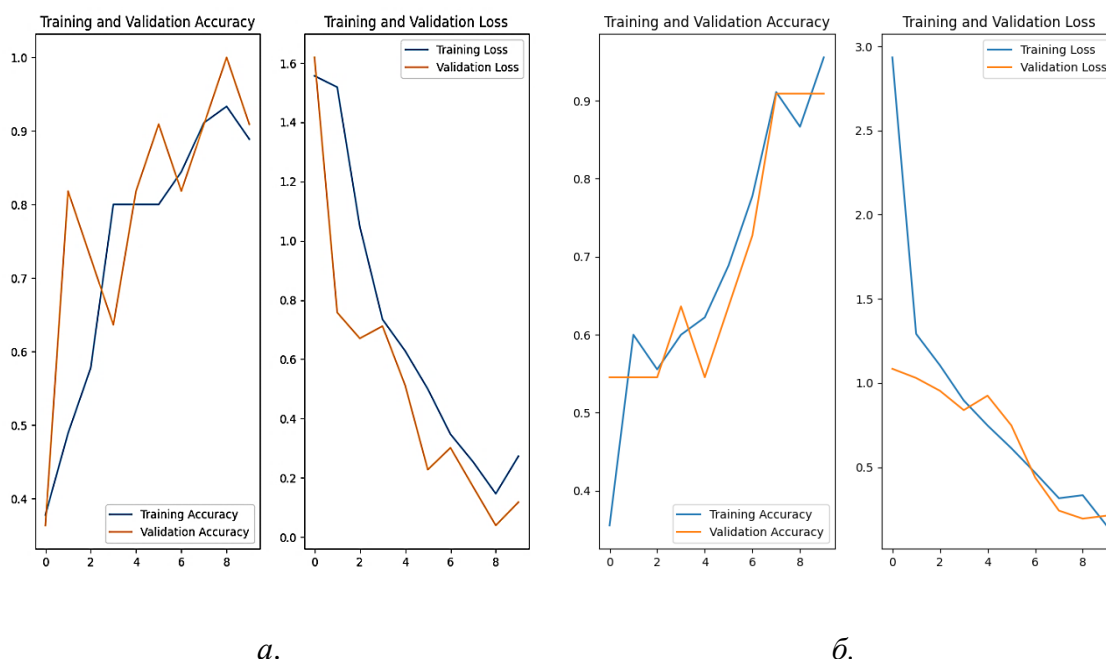


Рис. 2. Графики точности и потерь для тренировочного и проверочного исходного наборов данных для первичного обучения модели (а) и повторного обучения со скорректированной архитектурой (б)


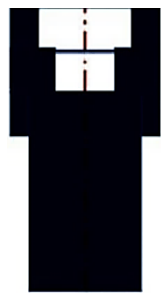
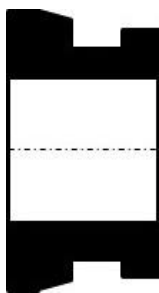
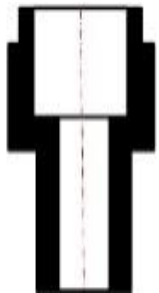

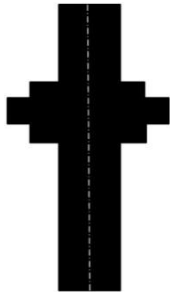
Так как тренировочный набор составляет 80% от всех исходных изображений, это означает, что большая часть геометрий будет распознаваться с низкой точностью. Снижение величины потерь на

тренировочном наборе (train_loss) происходило к десятой итерации обучения, на этом же этапе точность приобретала стабильное высокое значение.

Для повышения конечной точности модели было сокращено количество сверточных слоев с четырех до двух и оставлено десять итераций обучения. После повторного обучения с новыми параметрами наблюдалось резкое увеличение потерь на проверочном наборе данных (val_loss) и уменьшение точности (val_acc) в начале обучения (рис. 2б), что свидетельствует, о пересчете весов признаков изображений. Далее значения обоих параметров на графиках монотонно растут, что является показателем хорошей обучаемости модели. Поэтому для дальнейшего распознавания геометрических образов была использована именно эта архитектура обученной модели.

После обучения сети для распознавания типа поковок в сеть загружались несколько сечений поковок из рассматриваемых трех групп, а от нейросети требовалось определить тип, к которому относится изображение и достоверность совпадения. Результаты распознавания приведены в таблице 4.

Таблица 4. Результаты распознавания типа поковок нейронной сетью

А	В	С	Д	Е	Неизвестный тип
					
Относится к группе А 99,78%	Относится к группе В 91,74%	Относится к группе С 87,40%	Относится к группе D 99,92%	Относится к группе Е 93,49%	Относится к группе А 32,98%

На последнем этапе исследования нейронной сети для анализа предлагалась геометрия поковки, не принадлежащая ни к одной из пяти групп (неизвестная группа) исходного обучающего набора данных. В этом случае нейронная сеть определяла группу поковок с набором признаков, который имеет наибольшее число совпадений с заданной геометрией поковки. Так, сеть определила, что представленная поковка нового типа (табл. 4) с 32,98% достоверности относится к типу А. Это кажется вполне

убедительным, так как у этой детали есть утолщение, как и всех деталей типа А, но не на торце детали, а в центральной части.

Заключение

- Синтезированная нейронная сеть с двумя сверточными слоями после 10 итераций обучения оказалась способной распознавать принадлежность геометрии осесимметричных поковок к одной из пяти групп с достоверностью 90-97%, что на уровне очень опытного технолога. Это дает основание для практического использования нейронной сети в проектировании технологического процесса штамповки на ГКМ.
- При анализе сечений деталей, не принадлежащих ни к одной из групп поковок, использованных для обучения сети, созданная сеть определяла тип поковки, набор признаков которого имеет наибольшее число совпадений с исходным чертежом.
- Внедрение компьютерного распознавания типа штампуемых деталей позволяет исключить субъективизм на этом этапе проектирования и реализовать полную цифровизацию процесса проектирования технологического процесса штамповки.

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] Галушкин, А.И. Нейронные сети: основы теории. /А.И. Галушкин. - М.: Р и С, 2015. - 496 с.
- [4] Prateek Joshi. Artificial Intelligence with Python. Packt Publishing Ltd, 2017, 446p.
- [5] Хайкин, С. Нейронные сети: полный курс / С. Хайкин. - М.: Диалектика, 2019. - 1104 с.
- [6] Указ Президента Российской Федерации № 490 от 10.10.2019 года. О развитии искусственного интеллекта в Российской Федерации. Электронный ресурс: <http://government.ru/docs/all/124098/> .Дата обращения 28.01.2024.
- [7] Черепанов Н.В., Буслаев С.П. Проблемы и задачи развития искусственного интеллекта на машиностроительном предприятии. «Инновации и инвестиции». № 7. 2021, с.175-179.
- [8] Lee, S.; Quagliato, L.; Park, D.; Berti, G.A.; Kim, N. A Buckling Instability Prediction Model for the Reliable Design of Sheet Metal Panels Based on an Artificial Intelligent Self-Learning Algorithm. Metals 2021, 11, 1533.

- [9] Shamsuzzohaa, A.; Kankaanpaa, T.; Nguyen, H.; Nguyen, H. Application of machine learning algorithm in the sheet metal industry: An exploratory case study. *Int. J. Comp. Integr. Manuf.* 2022, 35, 145–164
- [10] Cruz, D.J.; Barbosa, M.R.; Santos, A.D.; Miranda, S.S.; Amaral, R.L. Application of Machine Learning to Bending Processes and Material Identification. *Metals* 2021, 11, 1418.
- [11] 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
- [12] Quiza, R.; Figueira, L.; Davim, J.P. Comparing statistical models and artificial neural networks on predicting the tool wear in hard machining D2 AISI steel. *Int. J. Adv. Manuf. Technol.* 2008, 37, 641–648.
- [13] П.А. Андриенко, В.И. Каразин, Д.П. Козликин, В.А. Терешин, А.В. Хисамов, И.О. Хлебосолов. Применение нейронных сетей для решения задач теории механизмов и машин: Современное машиностроение: наука и образование 2023: материалы 12-й Международной научной конференции, 22 июня 2023 г. / под ред. А. Н. Евграфова, А. А. Поповича. – СПб. : ПОЛИТЕХ-ПРЕСС, 2023. С. 175 – 188.
- [14] Mirandola, I.; Berti, G.A.; Caracciolo, R.; Lee, S.; Kim, N.; Quagliato, L. Machine Learning-Based Models for the Estimation of the Energy Consumption in Metal Forming Processes. *Metals*, 2021, 11(5), 833; <https://doi.org/10.3390/met11050833>
- [15] Alexander N. Evgrafov (as Editor). *Advances in Mechanical Engineering. Selected Contributions from the Conference “Modern Engineering: Science and Education”*, Saint Petersburg, Russia, June 2022. Springer, <https://doi.org/10.1007/978-3-031-30027-1>
- [16] Essid O, Laga H, Samir C (2018) Automatic detection and classification of manufacturing defects in metal boxes using deep neural networks. *PLoS ONE* 13(11): e0203192. <https://doi.org/10.1371/journal.pone.0203192>
- [17] 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>
- [18] Ковка и штамповка: справочник. В 4 т. Т. 2. Горячая объемная штамповка. 2-е изд., перераб. и доп. / Под общ. ред. Е.И.Семенова. М.: Машиностроение, 2010. 720 с.: ил.
- [19] Л.Н.Голубков, Б.Г.Богомолов, Г.П.Тетерин, А.В.Ткаченко. Разработка методов проектирования на ЭВМ технологического процесса штамповки поковок типа тел вращения на ГКМ. Кузнечно-штамповочное производство. Обработка металлов давлением, №11, 1971, с.36-39.

- [20] Алиев Ч.А., Тетерин Г.П. Система автоматизированного проектирования технологии горячей объемной штамповки.- Машиностроение, 1987. 224 с.:ил.
- [21] What are convolutional neural networks? Электронный ресурс: <https://www.ibm.com/topics/convolutional-neural-networks>. Дата обращения: 14.01.2024.
- [22] Create production-grade machine learning models with TensorFlow. Электронный ресурс: <https://www.tensorflow.org/?hl=en>. Дата обращения: 14.01.2024.
- [23] Keras 3 API documentation. Электронный ресурс: <https://keras.io/api/>. Дата обращения: 14.01.2024.

L.B. Aksenov¹, A.S. Platonova²

RECOGNITION OF THE GROUP AFFILIATION OF FORGED PARTS USING NEURAL NETWORKS

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

²ITMO University, St. Petersburg, Russia

Abstract

The article presents the result of using a neural network to recognize the types of forging parts manufactured by metal forming. Axisymmetric forgings produced on upset forging machines were selected as the object of research. After the training stage, the synthesized neural network was able to recognize that the geometry of forged parts affiliation to a certain group with a confidence of 90-97%.The proposed approach makes it possible to move away from the subjective assessment of the geometry of forging parts, and to realize the complete digitalization of the design of the technological process.

Keywords: upset forging, forging part groups, recognition, neural network

REFERENCES

- [1] Gorban A. N. Obuchenie nejronnykh setej. M.: Paragraph, 1990. 160 p.
- [2] Wasserman, Philip D., Advanced methods in neural computing. 1993 New York : Van Nostrand Reinhold, 255 p.
- [3] Galushkin, A.I. Nejronnye seti: osnovy teorii. /A.I. Galushkin. - M.: R i S, 2015. - 496 p.
- [4] Prateek Joshi. Artificial Intelligence with Python. Packt Publishing Ltd, 2017, 446 p.

- [5] Khajkin, S. Nejronnye seti: polnyj kurs / S. Khajkin. - M.: Dialektika, 2019. - 1104 p.
- [6] Ukaz Prezidenta Rossijskoj Federatsii № 490 ot 10.10.2019 goda. O razvitii iskusstvennogo intellekta v Rossijskoj Federatsii. Jelektronnyj resurs: <http://government.ru/docs/all/124098/> .Data obrashcheniya 28.01.2024.
- [7] Cherepanov N.V., Buslaev S.P. Problemy i zadachi razvitiya iskusstvennogo intellekta na mashinostroitel'nom predpriyatii. «Innovatsii i investitsii». № 7. 2021, pp.175-179.
- [8] Lee, S.; Quagliato, L.; Park, D.; Berti, G.A.; Kim, N. A Buckling Instability Prediction Model for the Reliable Design of Sheet Metal Panels Based on an Artificial Intelligent Self-Learning Algorithm. *Metals* 2021, 11, 1533.
- [9] Shamsuzzohaa, A.; Kankaanpaa, T.; Nguyen, H.; Nguyen, H. Application of machine learning algorithm in the sheet metal industry: An exploratory case study. *Int. J. Comp. Integr. Manuf.* 2022, 35, 145–164
- [10] Cruz, D.J.; Barbosa, M.R.; Santos, A.D.; Miranda, S.S.; Amaral, R.L. Application of Machine Learning to Bending Processes and Material Identification. *Metals* 2021, 11, 1418.
- [11] 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, Pp. 229-232*
- [12] Quiza, R.; Figueira, L.; Davim, J.P. Comparing statistical models and artificial neural networks on predicting the tool wear in hard machining D2 AISI steel. *Int. J. Adv. Manuf. Technol.* 2008, 37, 641–648.
- [13] P.A. Andrienko, V.I. Karazin, D.P. Kozlikin, V.A. Tereshin, A.V. Khisamov, I.O. Khlebosolov. *Primenenie nejronnykh setej dlya resheniya zadach teorii mekhanizmov i mashin: Sovremennoe mashinostroenie: nauka i obrazovanie 2023: materialy 12-j Mezhdunarodnoj nauchnoj konferentsii, 22 iyunya 2023 g. / pod red. A. N. Evgrafova, A. A. Popovicha. - SPb. : POLITEKKh-PRESS, 2023. pp. 175 - 188.*
- [14] Mirandola, I.; Berti, G.A.; Caracciolo, R.; Lee, S.; Kim, N.; Quagliato, L. Machine Learning-Based Models for the Estimation of the Energy Consumption in Metal Forming Processes. *Metals*, 2021, 11(5), 833; <https://doi.org/10.3390/met11050833>
- [15] Alexander N. Evgrafov (as Editor). *Advances in Mechanical Engineering. Selected Contributions from the Conference “Modern Engineering: Science and Education”*, Saint Petersburg, Russia, June 2022. Springer, <https://doi.org/10.1007/978-3-031-30027-1>
- [16] Essid O, Laga H, Samir C (2018) Automatic detection and classification of manufacturing defects in metal boxes using deep neural networks. *PLoS ONE* 13(11): e0203192. <https://doi.org/10.1371/journal.pone.0203192>

- [17] 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>
- [18] Kovka i shtampovka: spravochnik. V 4 t. T. 2. Goryachaya ob"emnaya shtampovka. 2-e izd., pererab. i dop. / Pod obshch. red. E.I.Semenova. M.: Mashinostroenie, 2010. 720 p.: il.
- [19] L.N.Golubkov, B.G.Bogomolov, G.P.Teterin, A.V.Tkachenko. Razrabotka metodov proektirovaniya na JeVM tekhnologicheskogo protsessa shtampovki pokovok tipa tel vrashcheniya na GKM. Kuznechno-shtampovnoe proizvodstvo. Obrabotka metallov davleniem, №11, 1971, pp.36-39.
- [20] Aliev Ch.A., Teterin G.P. Sistema avtomatizirovannogo proektirovaniya tekhnologii goryachej ob"emnoj shtampovki.- Mashinostroenie, 1987. 224 p.: il.
- [21] What are convolutional neural networks? Information on URL: <https://www.ibm.com/topics/convolutional-neural-networks>. Accessed 3.02.2024
- [22] Create production-grade machine learning models with TensorFlow. Information on URL: <https://www.tensorflow.org/?hl=en>. Accessed 13.02.2024
- [23] Keras 3 API documentation. Information on URL: <https://keras.io/api/>. Accessed 13.02.2024.