

Обработка металлов давлением. Технологии и машины обработки давлением Metal forming. Technology and equipment of metal forming

Научная статья
УДК 621.735.34.041
DOI: 10.14529/met240303

ПРИМЕНЕНИЕ НЕЙРОННОЙ СЕТИ YOLO ДЛЯ ОПРЕДЕЛЕНИЯ ДЕФЕКТОВ НА БЕСШОВНЫХ КОЛЬЦАХ

И.К. Фарукшин, *ilya.farukshin@mail.ru*

В.В. Широков, *shirokovvv@susu.ru*

Д.Ю. Звонарев, *zvonarevdi@susu.ru*

О.О. Сиверин, *siverinoo@susu.ru*

Б.А. Чаплыгин, *chaplyginba@susu.ru*

Южно-Уральский государственный университет, Челябинск, Россия

Аннотация. В настоящее время контроль качества изделий является основным направлением для отечественных предприятий. Своевременный контроль продукции позволяет предотвращать потенциальные потери, а также уменьшает риск возникновения претензий со стороны потребителей. К сожалению, из-за больших объемов производства и нехватки квалифицированных сотрудников не все отечественные предприятия могут обеспечить стопроцентный контроль продукции. Зарубежные компании давно нашли выход из этой ситуации. Крупные предприятия, такие как Porsche и BMW, используют системы на основе искусственного интеллекта для контроля продукции. Для российских предприятий введение искусственного интеллекта является относительно новым, но популярным направлением. Цель исследования – изучить возможности применения нейронных сетей для определения дефектной продукции. В ходе исследования была изучена технология AI.SEE, проанализирована технология производства бесшовных колец (выделены недостатки производства), а также методика обучения нейронной сети YOLO. Также была поставлена и решена следующая задача: разработать модель (на основе компьютерного зрения), которая будет определять и визуализировать наличие дефекта на бесшовных кольцах. Проведенное исследование показало, что модель, обученная на готовых весах YOLO, может с высокой точностью 80...90 % определить наличие дефектов на кольцевых поковках. Но стоит отметить, что, несмотря на высокую точность определения дефектов, модель требует ряд доработок для более стабильной и качественной работы. Использование подобной модели может значительно улучшить процессы контроля на производстве. Стоит отметить, что полученные результаты могут быть полезны для компаний, занимающихся производством колец, и способствовать повышению эффективности и надежности производственных процессов для дальнейшего внедрения подобной системы.

Ключевые слова: раскатка колец, свёрточная нейронная сеть, YOLO, машинное зрение, распознавание дефектов

Для цитирования: Применение нейронной сети YOLO для определения дефектов на бесшовных кольцах / И.К. Фарукшин, В.В. Широков, Д.Ю. Звонарев и др. // Вестник ЮУрГУ. Серия «Металлургия». 2024. Т. 24, № 3. С. 26–33. DOI: 10.14529/met240303

Original article
DOI: 10.14529/met240303

NEURAL APPLICATION YOLO NETWORK FOR DEFECT DETECTION ON SEAMLESS RINGS

I.K. Farukshin, ilya.farukshin@mail.ru

V.V. Shirokov, shirokovvv@susu.ru

D.Yu. Zvonarev, zvonarevdi@susu.ru

O.O. Siverin, siverinoo@susu.ru

B.A. Chaplygin, chaplyginba@susu.ru

South Ural State University, Chelyabinsk, Russia

Abstract. Currently, product quality control is the main focus for domestic enterprises. Timely product control allows to prevent potential losses, and also reduces the risk of claims from consumers. Unfortunately, due to the large volume of production and lack of qualified employees, not all domestic enterprises can provide one hundred percent product control. Foreign companies have long ago found a way out of this situation. Large enterprises such as “Porsche” and “BMW” use systems based on artificial intelligence to control products. For Russian enterprises, the introduction of artificial intelligence is relatively new, but popular direction. The purpose of the research is to study the possibilities of using neural networks to identify defective products. In the course of the study was studied AI.SEE technology, analyzed the production technology of seamless rings (highlighted the shortcomings of production), as well as the method of training neural network YOLO. Also, the following task was set and solved: to develop a model (based on computer vision) that will detect, and visualize the presence of a defect on seamless rings. The conducted research showed that the model trained on off-the-shelf YOLO scales can determine the presence of defects on ring forgings with a high accuracy of 80...90 %. But, it should be noted that, despite the high accuracy of defect detection, the model requires a number of modifications for more stable and qualitative work. The use of such a model can significantly improve the control processes in production. It is worth noting that the results obtained can be useful for companies engaged in the production of rings, and contribute to improving the efficiency and reliability of production processes, for further implementation of such a system.

Keywords: ring rolling, convolutional neural network, YOLO, machine vision, defect recognition

For citation: Farukshin I.K., Shirokov V.V., Zvonarev D.Yu., Siverin O.O., Chaplygin B.A. Neural application YOLO network for defect detection on seamless rings. *Bulletin of the South Ural State University. Ser. Metallurgy*. 2024;24(3):26–33. (In Russ.) DOI: 10.14529/met240303

В настоящее время нейронные сети пользуются большой популярностью в различных сферах: машиностроении, металлургии, медицине и др.

Свёрточные нейронные сети бывают сегментированные, разметочные и классификационные.

Классификационные сети – выполняют задачу классификации изображений, а именно, извлечения классов информации из многоканального растрового изображения [1]. К таким нейросетям относятся AlexNet, ZFNet и др.

Разметочные сети – выполняют задачу обнаружения объектов, то есть определение местоположения и класса объектов в изображении или видеопотоке [2]. К разметочным сетям относятся следующие архитектуры: R-CNN, Fast R-CNN и др.

Сегментационные сети – разбивают изображение на области, соответствующие раз-

личным объектам [3]. Сегментационные сети выполняют одну из ключевых задач в компьютерном зрении, они позволяют машине точно понимать где находится объект, чем просто классификация или обнаружение объектов. Виды нейронных сетей: U-Net, FCN, DeepLab.

Зарубежные компании, такие как Porsche и BMW, применяют нейронные сети для анализа качества продукции. Например: в компании Porsche используется система AI.SEE [4].

Принцип работы системы AI.SEE следующий: изделие сканируется роботом (который оснащен специальной оптической системой), робот передает информацию нейронной сети, она сопоставляет полученное изображение со специальной базой данных и делает вывод о качестве продукции. Использование такой системы позволяет существенно повысить эффективность визуального осмотра,

а именно обеспечить 100%-ный контроль продукции.

К сожалению, не все отечественные предприятия в данный момент могут позволить себе подобные системы контроля, так как это направление достаточно новое в России и возникает недостаток квалифицированных специалистов. Поэтому на отечественных предприятиях визуальный осмотр производят специально обученные люди, контролёры ОТК (отдел технического контроля), который не могут обеспечить 100%-ный контроль продукции.

Если заказчик получит негодное изделие и на этапе сборки не заметит дефект, то это может привести к преждевременному выходу из строя механизма или даже к аварийной ситуации. Поэтому определение дефекта на этапе производства – это важная задача.

Рассмотрим в качестве примера производство бесшовных колец. Эти кольца используются в авиационных двигателях, поэтому качественное изготовление детали является ключом к надёжной эксплуатации машины [5].

Бесшовные кольца получают с помощью двух формообразующих операций штамповки и раскатки. Обычно на этапе штамповки получают полупродукт (поковку), которую в дальнейшем обрабатывают на раскатной машине. Принцип раскатки (рис. 1) следующий: исходную заготовку 3 устанавливают на раскатной валок 4, затем нажимной валок 1 нажимает на заготовку и, вращая, обжимает ее. Направляющий ролик 2 служит для формирования правильного круга, а контрольный ро-

лик 5 фиксирует достижение заданного размера [6].




Рис. 1. Раскатка кольца
Fig. 1. Ring rolling

Одним из наиболее частых дефектов при производстве бесшовных колец является «след от заусенца». Заусенец (рис. 2) – это остаток металла, который возникает в результате неправильной конструкции штампа, некачественной наладки оборудования или износа штамповой оснастки [7].

Из-за длинного заусенца происходит следующее: в момент соприкосновения кольца и упорного ролика происходит срезание заусенца и последующее его наматывание на центральный валок, вследствие чего по внутреннему диаметру возникают глубокие следы, которые представлены на рис. 3.

Применение нейронной сети позволит организовать работу персонала таким образом,



Рис. 2. Дефект «заусенец»
Fig. 2. The “burr” defect




Рис. 3. Дефект «след от заусенца»
Fig. 3. Defect “debur mark”

что при появлении дефекта персонал сможет устранить причину появления дефектов.

Задачей работы являлась разработка модели (на основе компьютерного зрения), способной определять и визуализировать наличие дефекта на бесшовных кольцах.

Для оценки возможности применения компьютерного зрения для распознавания дефекта «след от заусенца» было проведено обучение нейронной сети при помощи выборки изображений с дефектами, состоящей из 100 фотографий. Для расширения датасета была проведена аугментация (искусственное расширение датасета). Были выполнены следующие преобразования: вертикальный и горизонтальный повороты, а также расширение изображений. В конечном итоге для обучения нейронной сети использовался датасет из 400 фотографий.

В качестве нейронной сети использовалась архитектура YOLO (you-only-look-once), а именно YOLOv8. Данная нейросеть представляет собой двухуровневую нейронную сеть преимущественно со свёрточными слоями. По сравнению с предыдущими версиями, модель YOLOv8 работает быстрее и точнее, восьмая версия позволяет не только обнаруживать объекты, но и сегментировать и классифицировать их [8].

Также модель YOLO в каждой категории (сегментация, обнаружение и классификация) имеет по пять предварительно обученных моделей, а использование предварительно обученной модели значительно экономит время и вычислительные ресурсы.

На рис. 4 представлены предварительно обученные модели Segment. Из приведенных моделей видно, что модель YOLOv8x-seg де-

Модель	Размер (пикселей)	mAPbox 50-95	mAPmask 50-95	Скорость CPU ONNX (мс)	Скорость A100 TensorRT (мс)	params (М)	FLOPs (Б)
YOLOv8n-seg	640	36.7	30.5	96.1	1.21	3.4	12.6
YOLOv8s-seg	640	44.6	36.8	155.7	1.47	11.8	42.6
YOLOv8m-seg	640	49.9	40.8	317.0	2.18	27.3	110.2
YOLOv8l-seg	640	52.3	42.6	572.4	2.79	46.0	220.5
YOLOv8x-seg	640	53.4	43.4	712.1	4.02	71.8	344.1

Рис. 4. Характеристики предварительно обученных моделей
Fig. 4. Characteristics of pre-trained models

монстрирует лучшие показатели точности. Однако она наиболее требовательна с точки зрения вычислительных ресурсов и работает медленнее других моделей.

Наиболее подходящим вариантом служит YOLOv8m-seg, у нее высокая скорость обработки, меньшие требования к вычислительным ресурсам и по сравнению с YOLOv8x-seg – незначительная разница в точности распознавания. Поэтому модель YOLOv8m-seg является предпочтительнее.

Обучение проводилось на языке Python, обучающие параметры представлены на рис. 5.

Показатели обученной модели представлены на рис. 6. Анализ результатов – это важный этап, именно с помощью анализа можно понять насколько хорошо модель справляется с поставленной задачей, особенно в наборах данных с разнообразными категориями объектов.

После процесса обучения получились следующие результаты (см. рис. 6).

Box (P, R, mAP50, mAP50-95) – эта метрика используется для анализа производительности модели в обнаружении объектов [9], где:

mAP50-95 – значение точности, которое

рассчитывается при различных значениях IoU (от 0,5 до 0,95). С помощью этого параметра можно понять, как будет работать модель на разных уровнях сложности обнаружения.

P(Precision) – точность обнаружения.

R(Recall) – способность модели идентифицировать объекты на изображении.

mAP50 – показатель, который определяет производительность модели на «лёгких» уровнях сложности обнаружения.

Из полученных результатов следует, что модель YOLOv8m-seg имеет высокую точностью (P) и способность идентификации (R), что указывает на ее способность качественно определять объекты. Такие результаты являются приемлемыми, однако для определения дефектов с более высокой точностью модель потребует дальнейшей настройки, а также обучения на более объемном датасете.

В качестве проверки работоспособности модели использовался полученный в результате обучения файл best.pt, с помощью которого проводилась разметка входящих изображений. Результаты разметки представлены на рис. 7 и 8. Нейросеть распознает объекты, для

```
!pip install ultralytics
from ultralytics import YOLO
model = YOLO('/content/yolov8m-seg.pt')
results = model.train(data='/content/Defects-9/data.yaml', epochs=100, imgsz=640, device=device, model='/content/yolov8m-seg.pt')
```

Рис. 5. Код для обучения нейронной сети
Fig. 5. Code for neural network training

```
Validating runs/segment/train/weights/best.pt...
Ultralytics YOLOv8.1.9 Python-3.10.12 torch-2.1.0+cu121 CUDA:0 (Tesla T4, 15102MiB)
YOLOv8m-seg summary (fused): 245 layers, 27222963 parameters, 0 gradients, 110.0 GFLOPs
```

Class	Images	Instances	Box(P)	R	mAP50	mAP50-95)	Mask(P	R	mAP50	mAP50-95):
all	6	10	1	0.749	0.853	0.48	0.953	0.6	0.676	0.27

Speed: 0.3ms preprocess, 18.7ms inference, 0.0ms loss, 1.2ms postprocess per image
Results saved to runs/segment/train

Рис. 6. Результаты обучения модели
Fig. 6. Results of model training




Рис. 7. Распознавание дефектов с помощью нейросети № 1
Fig. 7. Defect recognition using neural network No. 1



Рис. 8. Распознавание дефектов с помощью нейросети № 2
Fig. 8. Defect recognition with the help of neural network No. 2

Количество красных пикселей: 52524, что составляет 17.10% от общего числа пикселей. БРАК!!!

Рис. 9. Оценка качества изделия
Fig. 9. Product quality assessment

которых была обучена, с высокой точностью 80...90 %.

Далее следовал подсчет количества пикселей дефекта относительно общего количества пикселей поковки, если значение пикселей превышало 10 %, то модель определяла поковку как брак и на панели появлялась предупредительная фраза (рис. 9).

Заключение

В ходе работы было выявлено следующее: на основе полученных данных, а именно

точности нейронной сети, следует вывод, что модель можно применять для организации работы персонала. Точность обученной модели составляет 80...90 %, это очень высокие показатели. Использование данной системы может своевременно информировать персонал о появлении дефектной продукции.

Несмотря на все вышесказанное, модель требует ряд доработок. Необходимо провести эксперименты с использованием других нейронных сетей, также стоит расширить датасет и применить больше аугментационных функций.

Список литературы

1. Васкан В.Д. Обзор архитектур сверточных нейронных сетей для задачи классификации изображений // ИТ-стандарт. 2021. № 3 (28). С. 34–39.
2. Тисецкий А.П., Ковалев Д.И., Мансурова Т.П. Обзор методов сегментации и обнаружения объектов на изображении в реальном времени для предотвращения аварийных ситуаций РЖД // Современные инновации, системы и технологии. 2022. Т. 2, № 3. С. 0101–0116. DOI: 10.47813/2782-2818-2022-2-3-0101-0116
3. Годунов А. И., Балаян С. Т., Егоров П. С. Сегментация изображений и распознавание объектов на основе технологии сверточных нейронных сетей // Надежность и качество сложных систем. 2021. № 3. С. 62–73. DOI: 10.21685/2307-4205-2021-3-8
4. AI.SEE – Automated Visual Inspection using AI: [сайт]. URL: <https://www.elunic.com/> (дата обращения: 06.04.2024).
5. Костышев В.А., Шитарев И.Л. Анализ технологических схем изготовления кольцевых профилей авиационных двигателей // Актуальные проблемы производства. Технология, органи-

зация, управление: сб. науч. тр. Самара: Самар. гос. аэрокосм. ун-т им. С.П. Королева, 1996. С. 48–58.

6. Раскатка колец: метод. указания / авт.-сост. В.А. Костышев, Б.В. Каргин. Самара: Самар. гос. аэрокосм. ун-т им. С.П. Королева (нац. исслед. ун-т), 2011. 109 с.

7. Контроль качества поковок: методические указания / сост. В.С. Люкшин, Д.Б. Шатько. Юрга: Изд-во Юргинского технологического института (филиала) Томского политехнического университета, 2014. 27 с.

8. Ultralytics Revolutionizing the World of Vision AI: [сайт]. URL: <https://www.ultralytics.com/> (дата обращения: 06.04.2024).

9. Mean Average Precision (mAP) in Object Detection: [сайт]. URL: <https://learnopencv.com/> (дата обращения: 06.04.2024).

References

1. Vaskan V.D. Overview of convolutional neural network architectures for the image classification problem. *IT-standard*. 2021;3(28):34–39. (In Russ.)

2. Tisetsky A., Kovalev D., Mansurova T. Study of methods of segmentation and detection of objects in the image in real time to prevent accidents of Russian Railways. *Modern Innovations, Systems and Technologies*. 2022;2(3):0101–0116. (In Russ.) DOI: 10.47813/2782-2818-2022-2-3-0101-0116

3. Godunov A.I., Balanyan S.T., Egorov P.S. Image segmentation and object recognition based on convolutional neural network technology. *Nadezhnost' i kachestvo slozhnykh sistem = Reliability and quality of complex systems*. 2021;3(3):62–73. (In Russ.) DOI: 10.21685/2307-4205-2021-3-8

4. AI.SEE – Automated Visual Inspection using AI: website. Available at: <https://www.elunic.com/> (accessed 06 April 2024).

5. Kostyshev V.A., Shitarev I.L. [Analysis of technological schemes of manufacturing ring profiles of aircraft engines]. In: *Aktual'nye problemy proizvodstva. Tekhnologiya, organizatsiya, upravlenie: sb. nauch. tr.* [Current issues of production. Technology, organization, management: collection of scientific papers]. Samara: Samara State Aerospace University named after S.P. Korolev; 1996. P. 48–58. (In Russ.)

6. Kostyshev V.A., Kargin B.V. (authors-compilers). *Raskatka kolets: metodicheskie ukazaniya* [Rolling of rings: methodical instructions]. Samara: Samara State Aerospace University named after S.P. Korolev (National Research University); 2011. 109 p. (In Russ.)

7. Lyukshin V.S., Shatko D.B. (compilers). *Kontrol' kachestva pokovok: metodicheskie ukazaniya* [Quality control of forgings: methodical instructions]. Yurga: Yurga Technological Institute (branch) of Tomsk Polytechnic University; 2014. 27 p. (In Russ.)

8. Ultralytics Revolutionizing the World of Vision AI: website. Available at: <https://www.ultralytics.com/> (accessed 06 April 2024).

9. Mean Average Precision (mAP) in Object Detection: website. Available at: <https://learnopencv.com/> (accessed 06 April 2024).

Информация об авторах

Фарукшин Илья Камильевич, магистрант кафедры процессов и машин обработки металлов давлением, Южно-Уральский государственный университет, Челябинск, Россия; ilya.farukshin@mail.ru.

Широков Вячеслав Вячеславович, канд. техн. наук, старший научный сотрудник, доц. кафедры процессов и машин обработки металлов давлением, Южно-Уральский государственный университет, Челябинск, Россия; shirokovvv@susu.ru.

Звонарев Дмитрий Юрьевич, канд. техн. наук, старший преподаватель кафедры процессов и машин обработки металлов давлением, Южно-Уральский государственный университет, Челябинск, Россия; zvonairevdi@susu.ru.

Сиверин Олег Олегович, старший преподаватель кафедры процессов и машин обработки металлов давлением, Южно-Уральский государственный университет, Челябинск, Россия; siverinoo@susu.ru.

Чаплыгин Борис Александрович, д-р техн. наук., проф., проф. кафедры процессов и машин обработки металлов давлением, Южно-Уральский государственный университет, Челябинск, Россия; chaplyginba@susu.ru.

Information about the authors

Илья К. Фарукшин, Master's Student, Department of the Department of Processes and Machines for Metal Forming, South Ural State University, Chelyabinsk, Russia; ilya.farukshin@mail.ru.

Vyacheslav V. Shirokov, Cand. Sci. (Eng.), Senior Researcher, Ass. Prof. of the Department of Processes and Machines for Metal Forming, South Ural State University, Chelyabinsk, Russia; shirokovvv@susu.ru.

Dmitriy Yu. Zvonarev, Cand. Sci. (Eng.), Senior Lecturer of the Department of Processes and Machines for Metal Forming, South Ural State University, Chelyabinsk, Russia; zvonarevdi@susu.ru.

Oleg O. Siverin, Senior Lecturer of the Department of Processes and Machines for Metal Forming, South Ural State University, Chelyabinsk, Russia; siverinoo@susu.ru.

Boris A. Chaplygin, Dr. Sci. (Eng.), Prof., Prof. of the Department of Processes and Machines for Metal Forming, South Ural State University, Chelyabinsk, Russia; chaplyginba@susu.ru.

Статья поступила в редакцию 06.04.2024

The article was submitted 06.04.2024