

УДК 004.8

## ОПРЕДЕЛЕНИЕ ДЕФЕКТОВ НА СТАЛЬНЫХ ЛИСТАХ С ИСПОЛЬЗОВАНИЕМ СВЕРТОЧНЫХ НЕЙРОННЫХ СЕТЕЙ

Р. Д. Гаскаров<sup>1</sup>, А. М. Бирюков<sup>2</sup>, А. Ф. Никонов<sup>3</sup>, Д. В. Агниашвили<sup>4</sup>,  
Д. А. Хайрисламов<sup>5</sup>

*Институт информационных технологий и интеллектуальных систем,  
Казанский (Приволжский) федеральный университет, Казань*

<sup>1</sup>komnatakita@gmail.com, <sup>2</sup>herou.public@gmail.com, <sup>3</sup>nikonowalex@gmail.com,  
<sup>4</sup>daniilak@gmail.com, <sup>5</sup>danilhayrislamov@gmail.com

### **Аннотация**

Сталь в наши дни является одним из важнейших производственных материалов, который используется повсеместно, от медицины до промышленных отраслей. Своевременное обнаружение и распознавание дефектов на стальных листах после проката – одна из ключевых проблем этого производства с учетом его сложности и необходимости затрат большого количества времени на проведение вручную проверок каждого листа и каждой заготовки. Одними из целей настоящей работы были автоматизация и упрощение данного процесса. Для решения соответствующих задач была использована, в первую очередь, модель сверточной нейронной сети под названием UNet, которая уже зарекомендовала себя как отличный инструмент решения таких задач — при высокой результативности она требует меньшего количества учебных данных. В основе этой модели лежат последовательная, производимая в несколько шагов свертка изображения до приемлемого размера (иными словами, сжатие или кодирование), а затем развертка, восстановление изображения к исходному размеру и соотношению сторон, после чего на выходе будет получена маска изображения с классами элементов, которые необходимо было найти. В дополнение к этой нейронной сети в качестве кодирующего (сворачивающего) слоя была использована другая модель — ResNet34, предварительно обученная на датасете (наборе данных) ImageNet1000. В этой модели также был модифицирован выходной слой — вместо 34 слоев с классами на выходе возвращалось лишь 4, что сокра-

тило время обработки и позволило использовать наиболее удачные определения в результатах. Используя данный подход и проведя все необходимые проверки, при подведении итогов, мы получили результат в 94,8% точности определения дефектов на стальных листах.

**Ключевые слова:** сверточные нейронные сети, нейронные сети, машинное обучение, сталь, искусственный интеллект, UNet, ResNet, определение дефектов, сегментация, классификация.

## **ВВЕДЕНИЕ**

Учитывая высокую конкуренцию в среде производителей стали, фабрикам и производствам просто необходимо выпускать качественный продукт для получения и закрепления хорошей репутации, а также стабильных продаж и обеспечения безопасности конечных потребителей их продукта. Естественно, чтобы можно было гарантировать такое качество продукта, необходимо разработать и внедрить в производство систему контроля качества, иначе говоря, систему мониторинга технологических процессов (далее – СКК). Сама организация этой СКК, говоря конкретно о производстве стали, должна обеспечивать плотное взаимодействие организационных, научных, методологических, технических, информационных и человеко-ресурсных подходов в работе, что не только позволит повысить качество производимой стали, но и уменьшит количество брака, что непосредственным образом благотворно скажется на снижении стоимости производства [1].

Говоря в целом о возможных дефектах и браке стальной продукции, нужно учитывать, что сами свойства материала, процесс проката, а также используемая СКК могут влиять на появление дефектов на листах. В качестве примера можно привести такие повреждения, как царапины, потертости, следы насекомых, сращение листов друг с другом, швы на листах, отслоение частиц с листа, ожоги поверхности листа и прочие [2].

Одна из главных задач СКК — решить, может ли готовая продукция быть выпущенной в продажу, поскольку поставка бракованной партии товара может спровоцировать значительно большие расходы, чем ее утилизация или переработка. Каждый дефект может повлиять на конечное решение о реализации стали

на рынке, например, если на стальном листе будут обнаружены трещины, то данный продукт будет маркирован как брак и не будет допущен к продаже. Если же будет найдено что-то менее существенное, например, небольшие следы шлака или пузырьки воздуха на поверхности листа, то это не будет считаться серьезным недостатком, а сталь пойдет в продажу и дальнейшее производство.

Учитывая все вышесказанное, нами было принято решение разбить работу на две составляющие:

1. Найти и определить дефекты на листах, а также выявить закономерности их появления вкупе с другими дефектами (один дефект может быть причиной появления второго и так далее);
2. Провести эксперимент с использованием нейронных сетей для автоматизации такого рода проверок на качество — смогут ли модель или ансамбль моделей научиться самостоятельно определять дефекты, разбивать их на классы и в дальнейшем, судя по классам, принимать решение о допуске или недопуске стальной продукции к дальнейшей реализации.

### **1. РАБОТЫ, СВЯЗАННЫЕ С ТЕМОЙ ИССЛЕДОВАНИЯ**

Нахождение и определение дефектов на стальных листах с использованием машинного обучения и нейронных сетей далеко продвинулось в последние годы. Некоторые подходы используют модели, которые могут работать в реальном времени, что, однако, требует довольно больших вычислительных мощностей на базе графических процессоров [3], которые позволяют обрабатывать изображения, полученные с видеокамер в большом разрешении. Другой подход, менее требовательный к ресурсам, использует пост-обработку изображений и осуществляется последовательно в три основных этапа:

1. Предварительная обработка изображений;
2. Извлечение классов из объектов на изображении;
3. Классификация полученных артефактов [4].

Один из самых первых методов — RCNN — был исследован и опробован Р. Гиршиком [5], но этот метод не очень хорошо подходил для задач определения объектов на изображении — для его успешной работы требовалась масса времени, поскольку каждое изображение обрабатывалось в исходном разреше-

нии, а каждый найденный объект обрабатывался целиком всей моделью, что сказывалось на производительности не лучшим образом.

Далее, с целью повышения производительности подобных моделей был разработан алгоритм под названием Fast RCNN, который пришел на замену оригинальному RCNN [6]. После него, продолжая наращивать скорость работы, появился Faster RCNN, в основу которого была заложена модель глубокого обучения, работающая с гипотезами о расположении объектов. Эта модель вместо выборочного поиска, использовавшегося в Fast RCNN, строила гипотезы о местонахождении объекта на изображении, а затем извлекала полученные классы и возвращала их.

Учитывая успешность архитектуры RCNN-моделей в задачах определения местонахождения и распознавания объектов на изображениях, нами было принято решение использовать данную архитектуру наряду с UNet, которую также было решено несколько углубить и модифицировать.

### **3. НАБОР ДАННЫХ**

Приступая к практической части работы, в первую очередь необходимо определить, как модели будут взаимодействовать с набором данных (датасетом), то есть какое количество изображений будет достаточным для обучения модели, сколько пикселей потребуется обработать и так далее. Каждое изображение также необходимо разметить — указать в отдельных для каждой фотографии файлах с расширением csv номер дефекта и его маску в формате RLE<sup>1</sup>.

Датасет, который используется для обучения модели, должен также быть подготовлен для большей удобочитаемости компьютером путем замены NaN-значений<sup>2</sup> в колонке EncodePixels в csv-файле (т. е. генерируем HEX-коды каждого пикселя на изображении для увеличения скорости обработки), изменения наименования файлов и добавления колонки classID, чтобы отслеживать информацию о наличии того или иного дефекта было удобнее.

---

<sup>1</sup> [https://en.wikipedia.org/wiki/Run-length\\_encoding](https://en.wikipedia.org/wiki/Run-length_encoding)

<sup>2</sup> In computing, NaN, standing for Not a Number, is a member of a numeric data type that can be interpreted as a value that is undefined or unrepresentable, especially in floating-point arithmetic

---

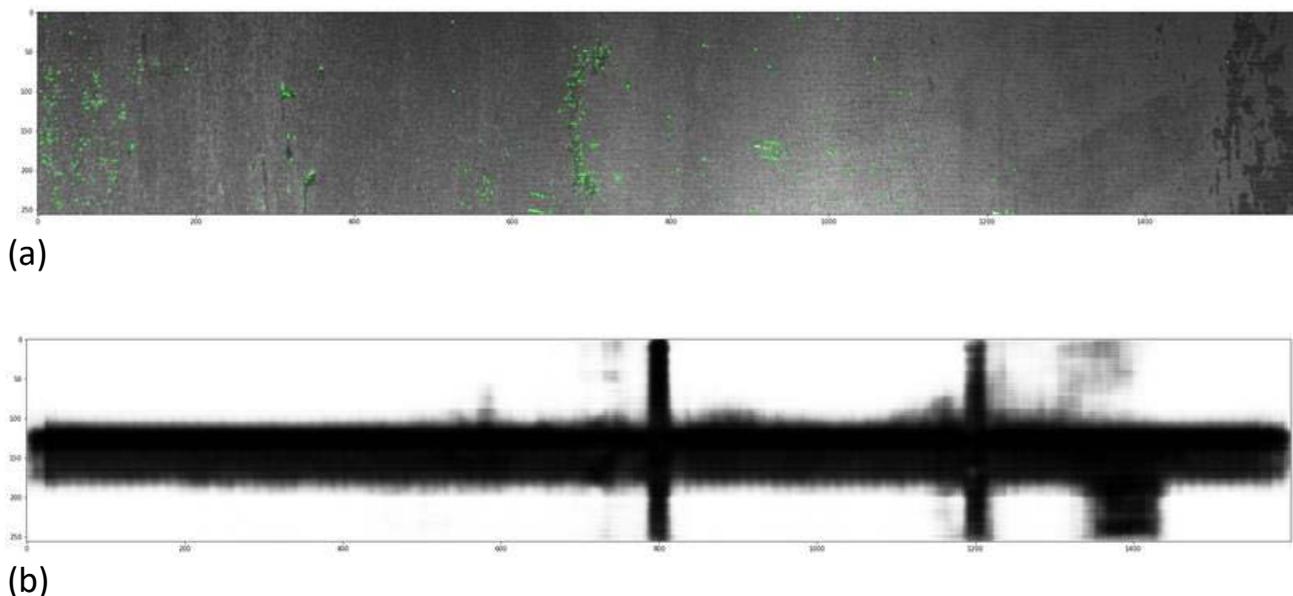


Рисунок 1. Рентгенограмма стального листа с RLE-маской (a) и сама RLE-маска без изображения (b).

Как видно на рис. 1, есть два затруднения в изображениях в датасете:

- на многих изображениях есть довольно большие черные зоны;
- на некоторых изображениях изменена насыщенность цветов.

Однако, учитывая, что на всех фотографиях нет цветов, кроме оттенков черного и серого, их можно проанализировать более простым способом, например, с использованием пиксельной гистограммы.

Как уже упоминалось ранее, если на изображении стального листа есть дефект, то координаты его маски должны быть указаны в строке формата RLE, то есть маска нужного нам дефекта существует с индексацией, наподобие этой: [1234: 1234+3][1239: 1239+16], и так далее. Учитывая это, RLE-строка должна быть декодирована и перенесена на изображения в виде маски<sup>3</sup>.

---

<sup>3</sup>Kaggle: RLE functions – Run Length Encode & Decode. <https://www.kaggle.com/paulorzp/rle-functions-run-lenght-encode-decode>

---

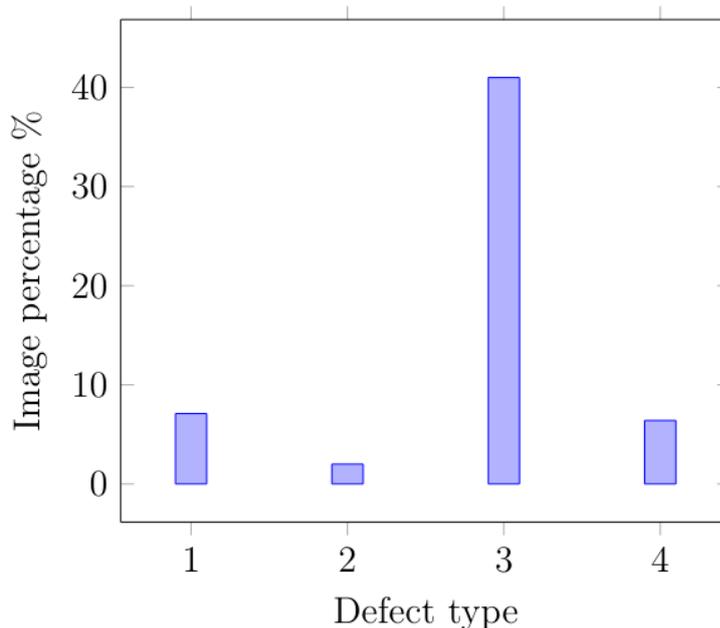


Рисунок 2. Процентаж дефектов по номеру на изображениях в датасете.

Анализ показал, что среди 7095 изображений наибольший процентаж по нахождению имеет дефект №3 (рис. 2). Как видно на рис. 2, распределение дефектов по частоте нахождения неравно. Процент появления дефекта под номером 3 является наивысшим (5150 изображений), в то время как дефект №2 встречается лишь на 2% фотографий во всем наборе данных (247 изображений). Несмотря на это, модель успешно справилась с обучением, поскольку алгоритм работы UNet позволяет точно определять нужные объекты после обучения даже на столь малом наборе изображений.

#### 4. МЕТОДЫ И РЕШЕНИЕ

Основная задача данной работы — избежать возможного человеческого влияния на результат оценки качества стальных листов. Каждый эксперт руководствуется в работе своими собственными принципами и базируется на своем субъективном опыте, поэтому результаты могут отличаться при оценке одного и того же листа разными экспертами. Стоит также учитывать, что люди отличаются от машин и могут сильно нарушить рабочий процесс, если не сорвать его вовсе.

В первую очередь было необходимо автоматизировать процесс обнаружения дефектов. Это было сделано при помощи модели UNet, которая обеспечивает более точную сегментацию при меньшем количестве обучающих данных, что было весьма кстати при очень небольшом количестве изображений в нашем датасете [8].

Модель UNet была представлена в 2015 году Олафом Роннебергером [9] для работ по сегментации биомедицинских изображений и был в дальнейшем модифицирован для использования при поиске дефектов на промышленных производствах. Данная модель использует традиционный подход по свертке, за которым следует так называемое «бутылочное горлышко», а после него — развертка, которая на выходе возвращает маску с сегментированными артефактами. Пропускные соединения между слоями свертки и развертки позволяют восстановить пространственную информацию, которая теряется во время максимального объединения.

Каждый этап развертки состоит из операции увеличения разрешения карты каналов атрибутов, за которой производятся следующие операции:

1. Свертка  $2 \times 2$ , уменьшающая количество атрибутов каналов;
2. Объединение карты атрибутов каналов, которую необходимо в дальнейшем отделить определенным образом от пути сокращения (это продиктовано потерей крайних пикселей на этапе свертки);
3. Двойная свертка  $3 \times 3$ , за которой следует активация с выпрямлением (ReLU).

После этих процессов к работе приступает ResNet34 [10] в качестве кодирующей модели. Этот алгоритм достигает 99% точности при использовании на производствах стали горячего проката. ResNet34 обладает также отличной архитектурой для целей извлечения свойств объектов [11]. В модифицированную модель UNet были внедрены блоки ResNet34 на пути свертки, также они действуют по время извлечения пропускных соединений в конце каждого блока на этапе развертки (рис. 3). Входные данные для нейронной сети были подготовлены посредством генерации мозаики  $512 \times 512$  из входных изображений.

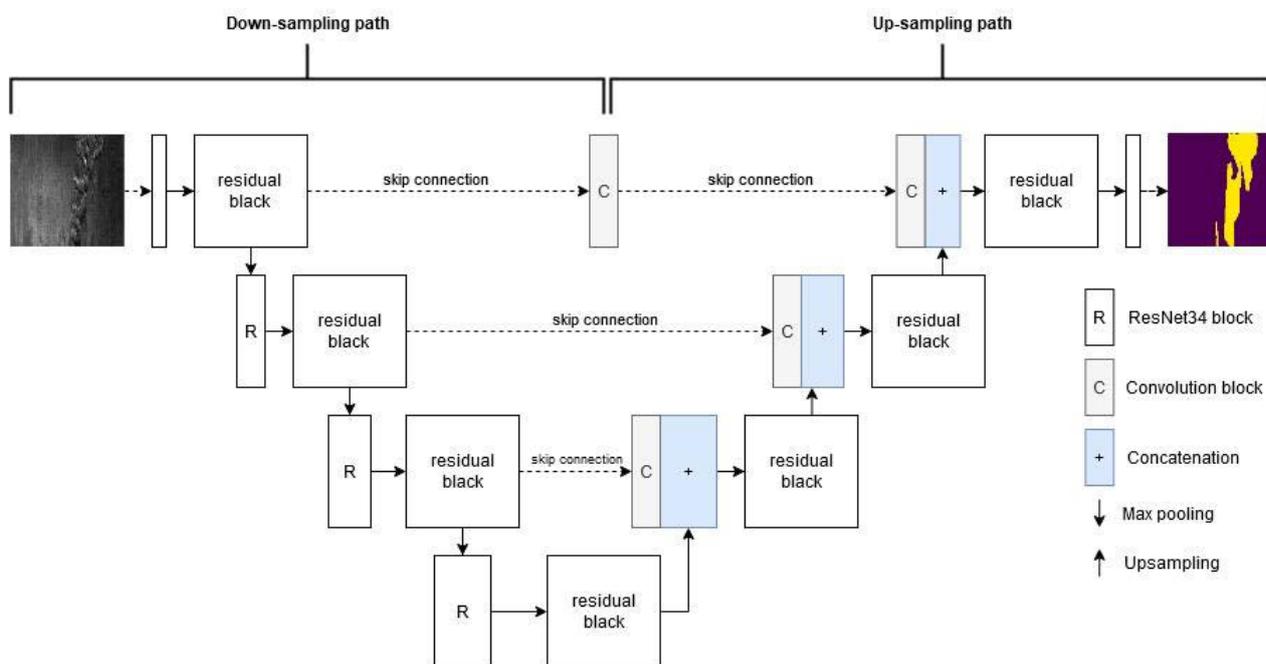


Рисунок 3. Архитектура использованной сверточной нейронной сети. Состоит из двух частей — свёртки и развёртки. Свёртка изображена слева блоками модели ResNet34, а развертка указана справа. Свёртка является стандартным процессом для любой архитектуры сверточных нейронных сетей и состоит из последовательного повторения сжатия 3x3, за которым следуют кодирование длин серий [7] и операция максимального объединения 2x2<sup>2</sup> для сжатия исходного разрешения изображения.

Dice-коэффициент для тестирования этой сборки выводился после каждой «эпохи» обучения. Когда значение функции потерь оставалось стабильным на одном и том же уровне в течение 10-ти эпох, процесс обучения останавливался. Веса для каждой эпохи обучения сохранялись, и эпоха с лучшим результатом на этапе валидации в дальнейшем использовалась для работы.

На этапе прогнозирования X \* X изображений было получено на выходе из модели нейронной сети с определенными отметками надежности прогноза нахождения дефектов (от 0 до 1). Пороговое значение (0,5) было использовано для получения бинарной мозаики предсказания. Мозаичное перекрытие было

использовано для генерации бесшовной сегментации больших зон на изображениях и рентгенограммах [12], а для того, чтобы избежать ненужных артефактов на изображениях и масках, которые часто могут встречаться на краях, использовалась только центральная часть карты предсказаний размером 256x256.

## **5. ИТОГИ**

Основная задача настоящего исследования заключается в создании сверточной нейронной сети, которая сможет на практике подтвердить возможность автоматизации проверок качества стальных листов горячего проката без участия человека в этом процессе. Подводя итог, отметим, эта задача была выполнена в три этапа:

1. Изучение релевантных этой теме нейронных сетей, которые могут потенциально подходить для успешного завершения исследования.
2. Анализ последних научных статей и исследований, а также практических подходов к решению подобных задач с целью определения наиболее эффективных подходов и архитектур нейронных сетей.
3. Разрешение распространенной проблемы с вычислительными мощностями, чтобы сделать возможной обучение и работу модели на доступном оборудовании.

В результате сборки двух моделей — UNet и ResNet34, предобученной на датасете ImageNet1000, были получены следующие результаты:

- 94,8% точность анализа дефектов стальных листов горячего проката.
- Отличные показатели модели на этапе валидации и обучения.

Для оценки полученных результатов была использована метрика Dice-коэффициента. Она демонстрирует сходство или различие между результатом работы нейронной сети и реальными показателями. Чем выше сходство, тем выше коэффициент, также он используется в целях формализации функции потерь в изучении проблем семантической сегментации [13–16]. Как показано на рис. 4, в течение 20 эпох обучения Dice-коэффициент плавно достигает значения около 0,95 и остается на том же уровне.



Рисунок 4. Результаты dice-коэффициента. Эпохи — итерации обучения нейронной сети, Dice score — статистические показатели оценки работы модели, которые определяют, велико ли различие между реальными дефектами на листе стали и теми, которая обнаружила нейронная сеть.

## 6. ЗАКЛЮЧЕНИЕ

Популярность глубокого обучения в области классификации и обнаружения дефектов с учетом преломления рентгеновских лучей обусловлена высокой результативностью такого подхода [17]. Данный метод был с успехом использован на рентгенограммах и продемонстрировал более высокие результаты, нежели ручная обработка снимков. Учитывая все вышеописанное, внедрение подобных технологий в металлургическую промышленность может существенно снизить расходы на производство, повысить качество продукции и сократить время, требуемое для оценки качества.

В настоящей работе мы предлагаем простой, эффективный и недорогой способ обнаружения и анализа дефектов на листах стали горячего проката, высокая точность работы которого с успехом демонстрирует возможность замены ручного труда при оценке качества продукции на производстве стали.

## СПИСОК ЛИТЕРАТУРЫ

1. *Stavropoulos P. et al.* Monitoring and control of manufacturing processes: A review // *Procedia CIRP*. 2013. V. 8. P. 421–425.
2. *Chao W. and al.* Research on Classification of Surface Defects of Hot-rolled Steel Strip Based on Deep Learning // *DEStech Transactions on Computer Science and Engineering*. 2019. 2nd International Conference on Informatics, Control and Automation (ICA 2019). 2019. P. 362–366.
3. *Li J. and al.* Real-time detection of steel strip surface defects based on improved yolo detection network // *IFAC-PapersOnLine*. 2018. V. 51, No. 21. P. 76–81.
4. *Zhang Z., Zhang S., Li Q.* Online Surface Defects Detection System for Cold-rolled Steel Strip // *Recent Patents on Engineering*. 2017. V. 11, No. 1. P. 62–67.
5. *He K. and al.* Mask r-cnn // *Proceedings of the IEEE international conference on computer vision*, 2017. P. 2961–2969.
6. *Ren S. and al.* Faster r-cnn: Towards real-time object detection with region proposal networks // *Advances in Neural Information Processing Systems*, 2015. P. 91–99.
7. *Shang W. and al.* Understanding and improving convolutional neural networks via concatenated rectified linear units // *International Conference on Machine Learning*, 2016. P. 2217–2225.
8. *Ferguson M.K. and al.* Detection and segmentation of manufacturing defects with convolutional neural networks and transfer learning // *Smart and Sustainable Manufacturing Systems*. 2018. V. 2. arXiv:1808.02518 [cs.CV]
9. *Ronneberger O., Fischer P., Brox T.* U-net: Convolutional networks for biomedical image segmentation // *International Conference on Medical Image Computing and Computer-Assisted Intervention*. Springer, Cham, 2015. P. 234–241.
10. *Wu Z., Shen C., Van Den Hengel A.* Wider or deeper: Revisiting the resnet model for visual recognition // *Pattern Recognition*. 2019. V. 90. P. 119–133.
11. *He K. and al.* Deep residual learning for image recognition // *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 2016. P. 770–778.
12. *Ronneberger O., Fischer P., Brox T.* U-net: Convolutional networks for biomedical image segmentation // *International Conference on Medical Image Computing and Computer-Assisted Intervention*. Springer, Cham, 2015. P. 234–241.

13. *Salehi S.S.M., Erdogmus D., Gholipour A.* Tversky loss function for image segmentation using 3D fully convolutional deep networks // International Workshop on Machine Learning in Medical Imaging. Springer, Cham, 2017. P. 379–387.

14. *Milletari F., Navab N., Ahmadi S.A.* V-net: Fully convolutional neural networks for volumetric medical image segmentation // 2016 Fourth International Conference on 3D Vision (3DV). IEEE, 2016. P. 565–571.

15. *Wang P., Chung A.C.S.* Focal dice loss and image dilation for brain tumor segmentation // Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support. Springer, Cham, 2018. P. 119–127.

16. *Sudre C.H. and al.* Generalised dice overlap as a deep learning loss function for highly unbalanced segmentations // Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support. Springer, Cham, 2017. P. 240–248.

17. *Sitdikov V.D. and al.* Application of X-ray Technique to Study the Structure of Ultrafine-Grained Ferritic/Martensitic Steel // J. of Materials Engineering and Performance. 2019. V. 28, No. 11. P. 7109–7118.

## Steel Defects Analysis Using Cnn (Convolutional Neural Networks)

R. D. Gaskarov<sup>1</sup>, A. M. Biryukov<sup>2</sup>, A. F. Nikonov<sup>3</sup>, D. V. Agniashvili<sup>4</sup>,  
D. A. Khayrislamov<sup>5</sup>

<sup>1-5</sup> Higher Institute of Information Technology and Intelligent Systems

<sup>1</sup> komnatakita@gmail.com, <sup>2</sup> herou.public@gmail.com, <sup>3</sup> nikonowalex@gmail.com,  
<sup>4</sup> daniilak@gmail.com, <sup>5</sup> danilhayrislamov@gmail.com

### Abstract

Steel is one of the most important bulk materials these days. It is used almost everywhere - from medicine to industry. Detecting this material's defects is one of the most challenging problems for industries worldwide. This process is also manual and time-consuming. Through this study we tried to automate this process. A convolutional neural network model UNet was used for this task for more accurate segmentation with less training image data set for our model. The essence of this NN (neural network) is in step-by-step convolution of every image (encoding) and then stretching them to initial resolution, consequently getting a mask of an image with various classes on it. The foremost modification is changing an input image's size to 128x800 px resolution (original images in dataset are 256x1600 px) because of GPU memory size's limitation. Secondly, we used ResNet34 CNN (convolutional neural network) as encoder, which was pre-trained on ImageNet1000 dataset with modified output layer - it shows 4 layers instead of 34. After running tests of this model, we obtained 92.7% accuracy using images of hot-rolled steel sheets.

**Keywords:** CNN, neural networks, steel, machine learning, AI, Unet, ResNet, defects detection, segmentation, classification

### REFERENCES

1. Stavropoulos P. et al. Monitoring and control of manufacturing processes: A review // Procedia CIRP. 2013. V. 8. P. 421–425.
2. Chao W. and al. Research on Classification of Surface Defects of Hot-rolled Steel Strip Based on Deep Learning // DEStech Transactions on Computer Science and Engineering. 2019. 2nd International Conference on Informatics, Control and Automation (ICA 2019). 2019. P. 362–366.

3. *Li J. and al.* Real-time detection of steel strip surface defects based on improved yolo detection network // IFAC-PapersOnLine. 2018. V. 51, No. 21. P. 76–81.
4. *Zhang Z., Zhang S., Li Q.* Online Surface Defects Detection System for Cold-rolled Steel Strip // Recent Patents on Engineering. 2017. V. 11, No. 1. P. 62–67.
5. *He K. and al.* Mask r-cnn // Proceedings of the IEEE international conference on computer vision, 2017. P. 2961–2969.
6. *Ren S. and al.* Faster r-cnn: Towards real-time object detection with region proposal networks // Advances in Neural Information Processing Systems, 2015. P. 91–99.
7. *Shang W. and al.* Understanding and improving convolutional neural networks via concatenated rectified linear units // International Conference on Machine Learning, 2016. P. 2217–2225.
8. *Ferguson M.K. and al.* Detection and segmentation of manufacturing defects with convolutional neural networks and transfer learning // Smart and Sustainable Manufacturing Systems. 2018. V. 2. arXiv:1808.02518 [cs.CV]
9. *Ronneberger O., Fischer P., Brox T.* U-net: Convolutional networks for biomedical image segmentation // International Conference on Medical Image Computing and Computer-Assisted Intervention. Springer, Cham, 2015. P. 234–241.
10. *Wu Z., Shen C., Van Den Hengel A.* Wider or deeper: Revisiting the resnet model for visual recognition // Pattern Recognition. 2019. V. 90. P. 119–133.
11. *He K. and al.* Deep residual learning for image recognition // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2016. P. 770–778.
12. *Ronneberger O., Fischer P., Brox T.* U-net: Convolutional networks for biomedical image segmentation // International Conference on Medical Image Computing and Computer-Assisted Intervention. Springer, Cham, 2015. P. 234–241.
13. *Salehi S.S.M., Erdogmus D., Gholipour A.* Tversky loss function for image segmentation using 3D fully convolutional deep networks // International Workshop on Machine Learning in Medical Imaging. Springer, Cham, 2017. P. 379–387.
14. *Milletari F., Navab N., Ahmadi S.A.* V-net: Fully convolutional neural networks for volumetric medical image segmentation // 2016 Fourth International Conference on 3D Vision (3DV). IEEE, 2016. P. 565–571.

15. *Wang P., Chung A.C.S.* Focal dice loss and image dilation for brain tumor segmentation // *Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support*. Springer, Cham, 2018. P. 119–127.

16. *Sudre C.H. and al.* Generalised dice overlap as a deep learning loss function for highly unbalanced segmentations // *Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support*. Springer, Cham, 2017. P. 240–248.

17. *Sitdikov V.D. and al.* Application of X-ray Technique to Study the Structure of Ultrafine-Grained Ferritic/Martensitic Steel // *J. of Materials Engineering and Performance*. 2019. V. 28, No. 11. P. 7109–7118.

## СВЕДЕНИЯ ОБ АВТОРАХ



**Гаскаров Родион Дмитриевич** - магистрант, Казанский (Приволжский) Федеральный Университет, г. Казань;

**Rodion Dmitrievich Gaskarov** — graduate student of Kazan Federal University.

Email: komnatakita@gmail.com



**Бирюков Алексей Михайлович** – магистрант, Казанский (Приволжский) Федеральный Университет, г. Казань;

**Alexey Mikhailovich Biryukov** — graduate student of Kazan Federal University.

Email: herou.public@gmail.com



**Никонов Алексей Федорович** – магистрант, Казанский (Приволжский) Федеральный Университет, г. Казань;

**Alexey Fedorovich Nikonov** — graduate student of Kazan Federal University.

Email: nikonowalex@gmail.com



**Агниашвили Даниил Владиславович** – магистрант, Казанский (Приволжский) Федеральный Университет, г. Казань;

**Daniil Vladislavovich Agniashvili** — graduate student of Kazan Federal University.

Email: [daniilak@gmail.com](mailto:daniilak@gmail.com)



**Хайрисламов Данил Айдарович** – магистрант, Казанский (Приволжский) Федеральный Университет, г. Казань;

**Danil Aydarovich Khayrislamov** — graduate student of Kazan Federal University;

Email: [danilhayrislamov@gmail.com](mailto:danilhayrislamov@gmail.com)

*Материал поступил в редакцию 4 августа 2020 года*