

ИСПОЛЬЗОВАНИЕ НЕЙРОННЫХ СЕТЕЙ U-NET И W-NET В МЕТАЛЛОГРАФИЧЕСКОМ АНАЛИЗЕ ОБРАЗЦОВ СТАЛИ

© 2022 В. А. Ковун, И. Л. Каширина ✉

Воронежский государственный университет
Университетская пл., 1, 394018 Воронеж, Российская Федерация

Аннотация. В статье предлагается подход к металлографическому исследованию образцов стали, основанный на использовании обучаемого нейросетевого классификатора W-Net. Разработан программный подход к обработке данных (микрофотографий срезов металлов), включающий в себя предобработку изображений, нахождение сегментов (зёрен) металла, вычисление их границ, площадей и балла зерна с последующим построением гистограммы распределения площадей зёрен металла на микрофотографии. Проведён анализ эффективности предлагаемого подхода путем сравнения полученных гистограмм распределений с эталонными через вычисление их статистических характеристик. Полученные результаты демонстрируют высокую корреляцию между рассчитанными и эталонными данными.

Ключевые слова: металлография, нейронные сети, анализ изображений.

ВВЕДЕНИЕ

Металлография — важное направление в металлургии, классический метод исследования и контроля качества металлических материалов. Количественная металлография изучает количественные характеристики микроструктуры сталей и сплавов. Важная часть структурного анализа металлического образца заключается в выделении зёрен на микрофотографиях продольных и поперечных шлифов и измерении их абсолютных и относительных размеров с целью определения сортности продукции металлургической промышленности [1]. В последнее время количественная металлография претерпела значительные изменения благодаря появлению автоматических анализаторов изображений (ААИ), но задача полностью автоматизированного определения структуры металла еще не решена. Сложность создаёт наличие на исходном изображении артефактов, вызванных

особенностями технического процесса создания шлифов, а также местами плохо различимые границы зерен. Пример фрагмента исходной микрофотографии шлифа образца стали, полученной с помощью микроскопа, приведён на рис. 1.




Рис. 1. Фрагмент исходной микрофотографии шлифа образца стали
[Fig. 1. Initial slice microphotography fragment]

В данном исследовании предлагается подход к металлографическому анализу, основанный на сегментации с помощью обучаемо-

✉ Каширина Ирина Леонидовна
e-mail: kash.irina@mail.ru



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

го нейросетевого классификатора. Исходные данные были предоставлены лабораторией металловедения и металлофизики компании НЛМК. Для решения задач использовалась открытая библиотека компьютерного зрения OpenCV, а также нейросетевая модель W-Net, разработанная для графической сегментации биомедицинских изображений (таких, как фотографии сетчатки глаза) и хорошо проявившая себя при решении данной задачи [2].

В предыдущих работах [3, 4] был произведён анализ металлографического образца с помощью сети U-Net, однако, несмотря на достаточно хорошие результаты её работы, она не лишена недостатков в рамках рассматриваемой задачи. Среди них можно выделить:

- наличие в результирующих масках большого количества незамкнутых границ зёрен, для компенсации чего в предыдущих работах был разработан алгоритмом постобработки изображения;
- наличие недостаточно чётких границ сегментов на выходной маске сети — как в смысле толщин этих границ, так и в смысле их размытости на изображении, что усложняет постобработку;
- наличие артефактов сегментации на границах результирующих масок.

Для преодоления этих проблем в настоящей работе используется нейронная сеть архитектуры W-Net.

В предлагаемой статье с использованием машинного обучения решаются такие задачи, как:

- выделение замкнутых контуров зёрен металла на исходном изображении;
- вывод обработанного изображения с отмеченными контурами зёрен;
- автоматическое вычисление площадей зёрен;
- построение гистограммы распределения площадей зёрен.
- сравнение полученных результатов с результатами работы сети U-Net.

1. МЕТОДЫ ИССЛЕДОВАНИЯ

Сеть U-Net была предложена в 2015 году для решения задачи обнаружения контуров на микрофотографиях биологических препаратов [5], имеющей определенное сходство с задачей выделения контуров зёрен металла на микрофотографиях шлифов стали. Сеть U-Net не содержит полносвязных слоёв, и, таким образом, является вариантом т.н. полносвёрточной нейронной сети [6].

Общий вид архитектуры сети U-Net представлен на рис. 2. Каждый синий прямоу-

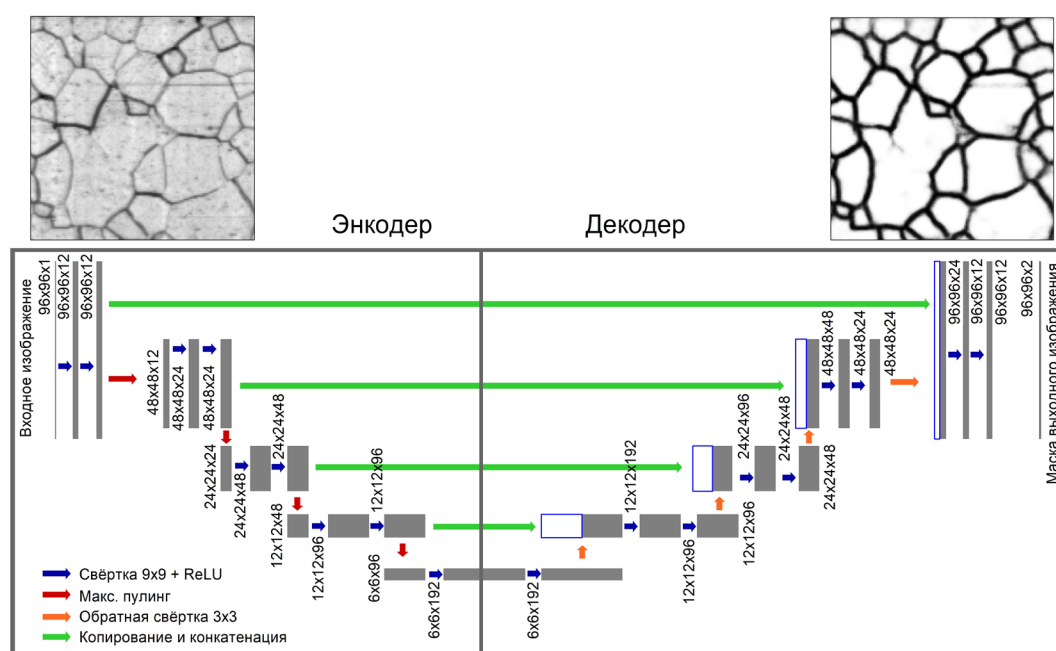


Рис. 2. Общая архитектура сети U-Net, входящей в состав сети W-Net
 [Fig. 2. General architecture of U-Net, which is a part of W-Net]

гольник соответствует многоканальной карте признаков распознаваемых объектов. Размер каждой карты и количество каналов указаны рядом с каждым прямоугольником. Операции над данными обозначены стрелками. Сеть U-Net содержит сжимающий путь (энкодер) и расширяющий путь (декодер), и её архитектура похожа на букву U (что и отражено в названии). Сжимающий путь — свёрточная сеть, в которой последовательно чередуются свёртки и линейные выпрямители (ReLU) с оператором максимизации. Прохождение данных по пути сжатия увеличивает количество информации о признаках, снижая количество пространственной информации. Сжимающий путь похож на типичную свёрточную сеть: он содержит свёрточные слои со свертками 3×3 , после которых результат свертки обрабатывается с помощью функции активации ReLU, а затем поступает на вход объединяющего слоя, на котором вычисляется значение максимума по каждому фрагменту карты размером 2×2 . Расширяющий путь использует серии свёрток и конкатенаций с многомерными признаками сжимающего пути. Каждый блок расширяющего пути содержит слой, обратный объединяющему, с конкатенацией с картой признаков из сжимающего пути и снова два подряд свёрточных слоя со свертками 3×3 , после каждого из которых опять вычисляется функция ReLU. На последнем слое свертка 1×1 используется для формирования из каждого полученного вектора признаков требуемого количества выходных классов.

Сеть U-Net обладает рядом преимуществ, среди которых можно отметить плохую переобучаемость сети. U-Net изначально была разработана для случая, когда обучающая выборка имеет достаточно малый объем, что было важным фактором в пользу выбора именно этой архитектуры.

Архитектура W-Net была предложена Adrian Galdran и др. в 2020 году. Фактически, она является концептуально простым расширением нейросетевой архитектуры U-Net. Изначально предложенная область её применения — сегментация кровеносных сосудов на фотографиях глазного дна человека для проведения медицинских исследований. Идея сети заключается в том, чтобы при использовании тонко настроенной и тщательно обученной сети U-Net, при меньшем количестве (на 1–3 порядка) параметров сети, было возможно добиться сравнимых по качеству результатов сегментации с таковыми у других, более сложных широко используемых свёрточных нейронных сетей.

Задача, для которой была использована сеть W-Net, концептуально схожа с задачей, для которой применялась входящая в её состав архитектура U-Net [5]. Как и U-Net [6], сеть W-Net является вариантом архитектуры полносвёрточной нейронной сети, то есть, она не содержит полносвязных слоёв [7]. Входными данными для W-Net являются исходные изображения, выходными данными является бинарная карта сегментации.

Эту сеть можно представить в виде конкатенации двух экземпляров сети U-Net. Общий вид архитектуры сети изображена на рис. 3,

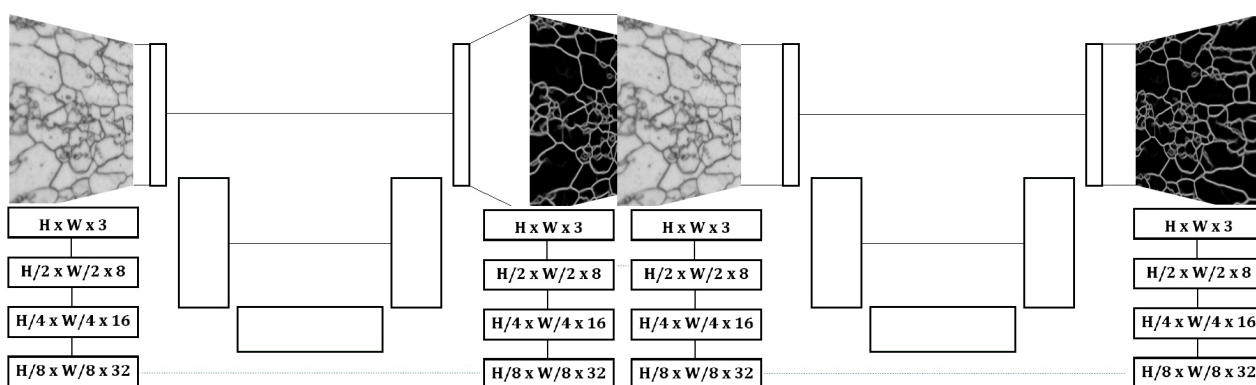


Рис. 3. Общая архитектура сети W-Net
[Fig. 3. General W-Net architecture]

каждому прямоугольнику соответствует блок слоёв сети U-Net. Как и для U-Net, для W-Net справедливо отличие от полносвёрточной сети в виде поддержки сжимающей сети слоями с операторами повышения дискретизации, повышающими разрешение выходов. W-Net содержит два сжимающих и два расширяющих пути, которые последовательно чередуются. W-Net внешне похожа на букву W, что и отражено в названии.

Выходные данные сети W-Net представляют собой изображение в градациях серого, на котором выделены границы сегментов. Преимущества сети W-Net, фактически, унаследованы от используемых в её составе сетей U-Net: концептуальная простота, усложнённое переобучение, и, в силу малого количества параметров, сравнительно небольшое количество данных, требуемых для обучения сети. В своей изначальной задаче сеть W-Net позволила добиться лучших (в терминах статистической значимости) результатов, чем сеть U-Net, тогда как W-Net имела меньше параметров. Меньшее количество параметров сети W-Net также позволило добиться большей производительности (в терминах времени и требуемой аппаратной вычислительной мощности) этой сети, в сравнении с другими используемыми для сегментации архитектурами.

При использовании W-Net для сегментации металлографического образца, её исходная стратегия обучения оставлена без изменений. Фактически, она сводится к минимизации функции потерь между предсказаниями модели и размеченной вручную маской для исходного изображения. В качестве функции потерь используется BCEWithLogitsLoss, или бинарная кросс-энтропия с вектором потерь:

$$L = \{l_1, \dots, l_N\},$$

где

$$l_n = -w_n [y_n \cdot \log \sigma(x_n) + (1 - y_n) \times \log(1 - \sigma(x_n))],$$

здесь x_n — n -е входное значение, y_n — n -е выходное значение, w_n — n -й весовой коэффициент. Эта функция была использована как наиболее подходящая для задачи различения границ и фона, то есть, разделения пикселей изображения на два класса. В каче-

стве метрики использовалась Accurasy (доля правильно классифицированных пикселей). Однако, так как классы являются не сбалансированными (количество белых пикселей существенно превосходит количество черных), в качестве альтернативной метрики была использована Dice score [3], не зависящая от соотношения пикселей границ и фона:

$$DS(Y, \hat{Y}) = \frac{2 \sum_{i,j} y_{ij} \hat{y}_{ij}}{\sum_{i,j} y_{ij}^2 + \sum_{i,j} \hat{y}_{ij}^2},$$

где $Y = (y_{ij})$ — построенная алгоритмом карта сегментации, которая может содержать вещественные значения, $\hat{Y} = (\hat{y}_{ij})$ — эталонный образец (маска), содержащий бинарные значения.

Стоит отметить, что, в случае с W-Net, для первой подсети вычисляется вспомогательная функция потерь, которая затем линейно комбинируется с функцией потерь, вычисленной для второй сети:

$$L(\Phi(x), y) = L(\phi^1(x), y) + L(\phi^2(x), y),$$

где L — функция потерь, Φ — функция выходных данных сети W-Net, ϕ^1 — функция выходных данных первой подсети, ϕ^2 — функция выходных данных второй подсети, x — входные данные, y — размеченная вручную маска.

Значение функции потерь затем используется в обратном распространении ошибки и минимизируется посредством метода адаптивной оценки моментов (Adam).

Исходные изображения перед подачей на вход сети W-Net приводятся к общему разрешению и обрабатываются стандартными техниками аугментации (повороты и отражения). Размер батча составляет четыре изображения.

Для увеличения размера обучающей выборки при обучении W-Net был использован метод эластичной сетки (elastic transform), пример работы которого приведён на рис. 4. Он состоит из следующих шагов.

1. Случайное аффинное преобразование картинки, которое включает в себя случайный сдвиг изображения, поворот изображения на случайный угол и растяжение вдоль осей x и y со случайным коэффициентом (пу-




Рис. 4. Пример аугментации изображения. Слева – исходное изображение, справа – результат аугментации, полученный деформацией исходного изображения по сетке
 [Fig. 4. An example of image augmentation. On the left there is an initial image, and on the right there is an image augmented with grid deformation method]

стые места при этом заполняются отражениями изображения на его границах);

2. Наложение на изображение точек, расположенных в узлах сетки, с последующей эластичной деформацией изображения относительно этих точек по векторам случайных размеров.

Исходный датасет для обучения W-Net был собран из исходных изображений разрешением 2048×1536 точек, и размеченных вручную масок. Сначала каждое из исходных изображений было разделено на батчи разрешением 256×256 точек. С помощью аугментации методом эластичной сетки датасет был расширен до 288 изображений. 231 изображение датасета использовались в качестве обучающей выборки, 57 — в качестве тестовой. Такой малый размер обучающей выборки оправдан тем, что входные данные W-Net при обучении также автоматически подвергаются аугментации. Полученные результаты работы сети W-Net затем подвергаются склеиванию для получения масок сегментации исходных размеров. В отличие от результатов, полученных с помощью сети U-Net, сеть W-Net не создаёт граничные артефакты сегментации на границах полученных масок.

Поскольку границы, определённые нейронной сетью, местами являются нечёткими, а также имеют в качестве цветов разные градации серого, полученная маска нуждается в постобработке: контрастировании и дилатации для повышения чёткости границ зёрен. Было использовано гауссово контрастирование с размером окрестности в 5×5 пикселей:

$$p_{x,y}^n = \begin{cases} 255, & m(x, y, s) \geq T \\ 0, & m(x, y, s) < T \end{cases}$$

где $p_{x,y}^n$ — новое значение пикселя по координатам (x, y) на изображении, $p_{x,y}$ — старое значение пикселя по координатам (x, y) на изображении, T — порог яркости, $m(x, y, s)$ — значение суммы яркостей соседей пикселя по координатам (x, y) в окрестности размером $t = 2s + 1$, а 0 и 255 соответствуют чёрный и белый цвет (в однобайтовых градациях серого) соответственно, а

$$m(x, y, s) = \sum_{i=x-s}^{x+s} \sum_{j=y-s}^{y+s} (p_{x,y}).$$

Результирующие изображения затем проходят постобработку с помощью библиотеки OpenCV по алгоритму, включающему следующие шаги:

- контрастирование пикселей, эрозия и дилатация изображения;
- поиск сегментов на изображении;
- поиск замкнутых контуров зёрен на обработанном изображении, подсчёт площадей, ограниченных найденными контурами, а также вывод гистограмм распределения площадей зёрен.

Таким образом, общий алгоритм обработки данных в рассматриваемой задаче имеет следующий вид.

1. Предобработка исходных изображений.
 - 1.1. Аугментация.
 - 1.2. Разрезание.
2. Обучение сети W-Net.
3. Постобработка изображений.

3.1. Инверсия.

3.2. Контрастирование.

4. Поиск контуров на результирующем изображении.

5. Вычисление размеров зерна и построение гистограммы распределения размеров.

3. РЕЗУЛЬТАТЫ И ИХ ОБСУЖДЕНИЕ

По окончании процесса обучения были достигнуты следующие значения метрик: val_auc: 0.9237, val_dice: 0.52, val_loss: 0.5004.

В качестве примера полученных результатов использован образец, представленный на рис. 1.

Пример результирующей маски сегментации (до постобработки), полученный на выходе сети W-Net для одного из фрагментов исходного изображения, представлен на рис. 5.

На рис. 6 приведён фрагмент изображения найденных контуров зёрен.

Согласно ГОСТ-5639-82, сравнение размеров зерна должно осуществляться в терминах т.н. балла зерна. Балл зерна G определяется по соотношению $m = 8 \times 2^G$, где m — среднее количество зёрен с баллом G на 1 мм^2 площади шлифа.

По вычисленным границам сегментов были найдены их площади. Поскольку предоставленные образцы микрофотографий сталей имеют фиксированный масштаб, значения площадей сегментов, вычисляемые в пикселях, могут быть по пропорции приведены к квадратным микрометрам, что и было

проделано. Далее вычислялось значение балла зерна для каждого найденного контура.

На рис. 7 представлены сегменты, окрашенные в соответствии с их баллом.

По найденным баллам была построена гистограмма распределения площадей зёрен. На рис. 8 приведены итоговые гистограммы распределения баллов площадей сегментов для результата работы сети W-Net и гистограммы эталонной (размеченной экспертами НЛМК) маски соответственно.

На рис. 9 приведены аналогичные гистограммы распределения баллов площадей сегментов для результата работы сети U-Net и эталонной маски.

Для сравнения эталонных и полученных гистограмм были использованы функции сравнения гистограмм из пакета NumPy.

В качестве основной метрики качества использовалась величина корреляции, позволяющая оценить, насколько хорошо две гистограммы совпадают друг с другом:

$$d_1(H_1, H_2) = \frac{\sum_I (H_1(I) - \bar{H}_1)(H_2(I) - \bar{H}_2)}{\sqrt{\sum_I (H_1(I) - \bar{H}_1)^2 \sum_I (H_2(I) - \bar{H}_2)^2}}$$

Здесь H_1 — гистограмма эталонного образца, H_2 — гистограмма восстановленного изображения, а $H_1(I)$, $H_2(I)$ — частоты соответствующих интервалов гистограмм, и

$$\bar{H}_k = \frac{1}{N} \sum_{j=1}^N H_k(J).$$

В качестве еще одной метрики качества использовалась также величина Хи-квадрат,




Рис. 5. Фрагмент исходного изображения (слева) и маска сегментации этого фрагмента, полученная в ходе работы сети W-Net (справа)

[Fig. 5. Initial image fragment (on the left), and the resulting image segmentation mask (on the right) generated by W-Net]




Рис. 6. Аппроксимированные границы зёрен, найденные сетью W-Net (фрагмент)
[Fig. 6. A fragment of approximated grain borders, found by W-Net]




Рис. 7. Аппроксимированные границы зёрен, закрасенные в соответствии с их площадью
[Fig. 7. Approximated grain borders, colored according to their area sizes]




Рис. 8. Сравнение гистограммы W-Net
[Fig. 8. W-Net histograms comparison]




Рис. 9. Сравнение гистограммы U-Net
[Fig. 9. U-Net histograms comparison]

оценивающая согласованность полученного и эталонного распределений:

$$d_2(H_1, H_2) = \sum_I \frac{(H_1(I) - H_2(I))^2}{H_1(I)}$$

И наконец, в качестве третьей (дополнительной) метрики использовалась реализованная в методе compareHist() величина пересечения — суммы отношений меньшей из частот на каждом интервале к большей, по всем интервалам, где хотя бы одна из частот отлична от нуля (если все частоты совпадут, то пересечение будет равно числу интервалов с ненулевыми частотами на каждой из сравниваемых гистограмм; предполагается, что гистограммы построены по одним и тем же интервалам). Пересечение также может быть

вычислено в процентах (по отношению к исходному числу интервалов):

$$d_3(H_1, H_2) = \sum_I \frac{\min(H_1(I), H_2(I))}{\max(H_1(I), H_2(I))}$$

Усредненные результаты сравнения гистограмм, построенных для границ зёрен, найденных с помощью сетей U-Net, W-Net и эталонных (предоставленных лабораторией металловедения и металлофизики компании НЛМК) гистограмм на тестовой выборке представлены в табл. 1. По этим результатам можно сделать вывод о согласованности получаемых распределений друг с другом.

Полученные значения свидетельствуют о высокой согласованности эталонного и полученных распределений для обоих нейросе-

тевых классификаторов, однако корреляция, как основная метрика качества, выше у сети W-net. Кроме того, в контурах зерен, найденных W-Net отсутствуют артефакты сегментации на границах результирующих масок, что говорит о более высоком качестве работы этой сети.

Таблица 1. Значения статистических метрик
[Table 1. Statistics values]

Метрика	Значение для W-Net	Значение для U-Net
Корреляция	0.999	0.986
Хи-квадрат	0.712 ($p \approx 0.003$)	0.724 ($p \approx 0.003$)
Пересечение	0.874	0.891

ЗАКЛЮЧЕНИЕ

В настоящей статье была сформулирована задача количественного металлографического анализа, а также приведён пример использования нейронной сети W-Net для автоматического определения границ зёрен на микрофотографии образца стали. Полученное изображение было подвергнуто постобработке, после чего на нём были выделены и аппроксимированы контуры границ зерен металла. По полученной маске была построена гистограмма распределения площадей зёрен. Результаты сегментации сравнены с таковыми для нейронной сети U-Net. Приведённые методы и средства могут быть использованы для упрощения процесса металлографического исследования при производстве стали.

КОНФЛИКТ ИНТЕРЕСОВ

Авторы декларируют отсутствие явных и потенциальных конфликтов интересов, связанных с публикацией настоящей статьи.

СПИСОК ЛИТЕРАТУРЫ

1. ГОСТ 5639-82 Стали и сплавы. Методы выявления и определения величины зерна (с Изменением N 1) [Текст]. – Взамен ГОСТ 5639-65; Введ. с 01.01.1983. – Москва : Изд-во стандартов, 1988. – 16 с.

2. Galdran A., Anjos A. The Little W-Net That Could: State-of-the-Art Retinal Vessel Segmentation with Minimalistic Models: база данных. – Режим доступа: <https://arxiv.org/abs/2009.01907>, Sep. 2020

3. Ковун В. А. Разработка моделей и алгоритмов машинного обучения для автоматического металлографического определения наблюдаемых размеров зерен стали / В. А. Ковун, И. Л. Каширина // Актуальные проблемы прикладной математики, информатики и механики: сб. тр. науч.-практич. конф. – Воронеж : Научно-исследовательские публикации, 2020. – С. 249–255.

4. Kovun V. A. On development of models and algorithms for automated metallographic measurement of visible metal slice grain sizes / V. A. Kovun, I. L. Kashirina // Journal of physics: conference series: Applied Mathematics, Computational Science and Mechanics: Current Problems, 2020.

5. Ronneberger O., Fischer P., Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation // Medical Image Computing and Computer-Assisted Intervention, New York: Springer, Cham, 2015. – Vol. 9351. – P. 234–241. Режим доступа: <https://arxiv.org/abs/1505.04597>

6. Jonathan Long, Evan Shelhamer, Trevor Darrell. Fully Convolutional Networks for Semantic Segmentation // The IEEE Conference on Computer Vision and Pattern Recognition (CVPR). 2015. – P. 3431–3440.

7. Beucher S., Meyer F. The Morphological Approach to Segmentation: The Watershed Transformation // Mathematical Morphology in Image Processing, New York : Marcel Dekker Inc., 1993. – P. 433–481.

Ковун Владислав Анатольевич — аспирант кафедры математических методов исследования операций факультета прикладной математики, информатики и механики Воронежского государственного университета.

E-mail: sidav94@gmail.com

ORCID: <https://orcid.org/0000-0001-7055-8614>

Каширина Ирина Леонидовна — д-р техн. наук, профессор кафедры математических методов исследования операций факультета прикладной математики, информатики и механики Воронежского государственного университета.

E-mail: kash.irina@mail.ru

ORCID: <https://orcid.org/0000-0002-8664-9817>

DOI: <https://doi.org/>

Received 15.01.2022

Accepted 22.04.2022

ISSN 1995-5499

USAGE OF U-NET AND W-NET NEURAL NETWORK ARCHITECTURES FOR STEEL SAMPLES METALLOGRAPHIC ANALYSIS

© 2022 V. A. Kovun, I. L. Kashirina ✉

Voronezh State University

1, Universitetskaya Square, 394018 Voronezh, Russian Federation

Annotation. The article proposes an approach to the metallographic study of steel images based on the use of the W-Net neural network classifier. A software approach to data processing (micrographs of metal slices) has been developed, which includes image preprocessing, finding metal segments (grains), calculating their boundaries, areas and grain score, followed by constructing a histogram of the distribution of metal grain areas on micrographs. The efficiency of the proposed approach is analyzed by comparing the obtained histograms of distributions with the reference ones by calculating their statistical characteristics. The results show a good correlation between calculated and reference data.

Keywords: neural networks, metallographic analysis, computer vision.

CONFLICT OF INTEREST

The authors declare the absence of obvious and potential conflicts of interest related to the publication of this article.

REFERENCES

1. GOST 5639-82 Stali I splavy. Metody vyyavleniya i opredeleniya velichiny zerna (s Izmeneniyem N 1) [Steels and alloys. Methods for detecting and determining grain size (with Change No. 1)] (1988). Moscow publishing house of standards.

2. Galdran A. and Anjos A. (2020) The Little W-Net That Could: State-of-the-Art Retinal Vessel Segmentation with Minimalistic Models. arXiv:2009.01907 [online] Available at: <https://arxiv.org/abs/2009.01907>, Sep. 2020.

3. Kovun V. and Kashirina I. (2020) Development of machine learning models and algorithms for automatic metallographic determination of observed steel grain sizes (in Russian). Applied Mathematics, Computational Science and Mechanics: Current Problems.

4. Kovun V. and Kashirina I. (2020). On development of models and algorithms for automated metallographic measurement of visible metal slice grain sizes. Journal of Physics: Conference Series. doi:10.1088/1742-6596/1479/1/012033.

✉ Kashirina Irina L.
e-mail: kash.irina@mail.ru

5. *Ronneberger O., Fischer P. and Brox T.* U-Net: Convolutional Networks for Biomedical Image Segmentation. arXiv:1505.04597v1 [online] Available at: <https://arxiv.org/abs/1505.04597>
6. *Long J., Shelhamer E. and Darrell T.* Fully Convolutional Networks for Semantic Segmentation. 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). P. 3431–3440
7. *Beucher S. and Meyer F.* (1993) The Morphological Approach to Segmentation: The Watershed Transformation. *Mathematical Morphology in Image Processing*. P. 433–481.

Kovun Vladislav A. — post-graduate student at Applied Mathematics and Mechanics faculty, Voronezh State University.

E-mail: sidav94@gmail.com

ORCID: <https://orcid.org/0000-0001-7055-8614>

Kashirina Irina L. — DSc in Technical Sciences, Professor of the Department of Mathematical Methods of Operations Research at Applied Mathematics and Mechanics faculty, Voronezh State University

E-mail: kash.irina@mail.ru

ORCID: <https://orcid.org/0000-0002-8664-9817>