

УДК 004.032.26

EDN: ZTGOBW

**ПРИМЕНЕНИЕ СВЕРТОЧНЫХ НЕЙРОННЫХ СЕТЕЙ  
ДЛЯ ВЫЯВЛЕНИЯ ДЕФЕКТОВ ГРАНУЛ  
ИОНООБМЕННЫХ СОРБЕНТОВ ЯДЕРНОГО КЛАССА**

**П.В. Тряев**

ORCID: 0000-0001-6143-8223 e-mail: [tryaev@okbm.nnov.ru](mailto:tryaev@okbm.nnov.ru)

АО «ОКБМ Африкантов»  
*Нижний Новгород, Россия*

**П.А. Крестьянинов**

ORCID: 0009-0008-5134-2787 e-mail: [pashakr@list.ru](mailto:pashakr@list.ru)

АО «ОКБМ Африкантов»  
*Нижний Новгород, Россия*

**Г.С. Малышев**

ORCID: 0000-0002-8147-988X e-mail: [gsmalyshev@okbm.nnov.ru](mailto:gsmalyshev@okbm.nnov.ru)

АО «ОКБМ Африкантов»  
*Нижний Новгород, Россия*

**А.Е. Наумов**

ORCID: 0009-0003-5993-9928 e-mail: [info@aleksandrnaumov.ru](mailto:info@aleksandrnaumov.ru)

АО «ОКБМ Африкантов»  
*Нижний Новгород, Россия*

**Е.А. Герасимов**

ORCID: 0009-0000-5641-0912 e-mail: [zenyger@rambler.ru](mailto:zenyger@rambler.ru)

АО «ОКБМ Африкантов»  
*Нижний Новгород, Россия*

Исследуются возможности сверточных нейронных сетей в задаче распознавания дефектов гранул ионообменных сорбентов ядерного класса: трещин, сколов. Показано, что использование предобученной нейронной сети позволяет обучить полносвязный классификатор даже для случая критически малого набора обучения. Демонстрируется эффективность обучения нейронной сети при малой обучающей выборке для распознавания дефектов. Предложен вариант объяснения эффективности обучения при малом обучающем наборе данных. Приводятся вероятности, с которыми сеть классифицирует тот или иной дефект, а также указываются предсказательные вероятности, ниже которых результат работы сети можно считать сомнительным. Рассматриваются перспективы использования сверточных нейронных сетей в задаче бинарной классификации дефектов гранул ионообменных сорбентов.

**Ключевые слова:** гранула ионообменного сорбента, сверточные нейронные сети, предобученные нейронные сети, распознавание изображений, дефекты гранулы сорбента, бинарная классификация.

**ДЛЯ ЦИТИРОВАНИЯ:** Тряев, П.В. Применение сверточных нейронных сетей для выявления дефектов гранул ионообменных сорбентов ядерного класса / П.В. Тряев, П.А. Крестьянинов, Г.С. Малышев, А.Е. Наумов, Е.А. Герасимов // Труды НГТУ им. Р.Е. Алексеева. 2024. № 3. С. 25-35. EDN: ZTGOBW

# THE USE OF CONVOLUTIONAL NEURAL NETWORKS TO IDENTIFY DEFECTS IN NUCLEAR CLASS ION-EXCHANGE SORBENT GRANULES

**P.V. Tryaev**

ORCID: **0000-0001-6143-8223** e-mail: **tryaev@okbm.nnov.ru**

JSC «Afrikantov OKBM»

*Nizhny Novgorod, Russia*

**P.A. Krestianinov**

ORCID: **0009-0008-5134-2787** e-mail: **pashakr@list.ru**

JSC «Afrikantov OKBM»

*Nizhny Novgorod, Russia*

**G.S. Malyshev**

ORCID: **0000-0002-8147-988X** e-mail: **gsmalyshev@okbm.nnov.ru**

J JSC «Afrikantov OKBM»

*Nizhny Novgorod, Russia*

**A.Ye. Naumov**

ORCID: **0009-0003-5993-9928** e-mail: **info@aleksandrnaumov.ru**

JSC «Afrikantov OKBM»

*Nizhny Novgorod, Russia*

**Ye.A. Gerasimov**

ORCID: **0009-0000-5641-0912** e-mail: **zenyger@rambler.ru**

JSC «Afrikantov OKBM»

*Nizhny Novgorod, Russia*

**Abstract.** This paper deals with the possibilities of convolutional neural networks in the problem of identifying defects in nuclear class ion-exchange sorbents granules: cracks and chips. It is shown that the use of a pre-trained neural network allows training a fully connected classifier even for the case of a critically small training set. The effectiveness of neural network training with a small training data set for defect identification is demonstrated. An attempt is made to explain the effectiveness of training with a small training data set. The probabilities of classification of a particular defect by the neural network are given, as well as predictive probabilities are indicated below which the result of the network can be considered doubtful. Prospects for the use of convolutional neural networks in the problem of binary classification of defects in ion-exchange sorbent granules are considered.

**Key words:** ion-exchange sorbent granule, convolutional neural networks, pre-trained neural networks, image recognition, sorbent granule defects, binary classification

**FOR CITATION:** P.V. Tryaev, P.A. Krestianinov, G.S. Malyshev, A.Ye. Naumov, Ye.A. Gerasimov. The use of convolutional neural networks to identify defects in nuclear class ion-exchange sorbent granules. Transactions of NNSTU n.a. R.E. Alekseev. 2024. № 3. Pp. 25-35. EDN: ZTGOBW

## Введение

Системы очистки водных теплоносителей вторых контуров АЭС с ВВЭР, плавучих АЭС, судовых ядерных энергетических установок вносят значимый вклад в обеспечение надежной и безопасной эксплуатации. Благодаря их работе водные теплоносители очищаются от широкого спектра загрязнений, показатели качества водно-химических режимов поддерживаются в установленных нормативной документацией диапазонах. Ионообменные фильтры систем очистки вторых контуров загружены ионообменными сорбентами ядерного класса. Они представляют из себя полимерные гранулы сферической формы диаметром от

0,4 до 1,25 мм. В гранулах сорбентов в процессе их изготовления, подготовки к загрузке в систему очистки, эксплуатации в фильтрах возникают дефекты в виде трещин, сколов. При эксплуатации в фильтрах трещины развиваются, что в конечном итоге приводит к фрагментации дефектных гранул. Часть образовавшихся фрагментов гранул будет иметь линейные размеры менее 0,4 мм. Такие частицы не смогут задерживаться фильтрующими устройствами системы очистки и будут выходить в контур, переноситься теплоносителем в полости контура. Под действием рабочих температур они будут подвержены термодеструкции с выделением коррозионно-агрессивных примесей: хлорид-ионов, серной кислоты и др. Это может привести к ухудшению коррозионной обстановки в контуре, протеканию интенсивной общей и локальной коррозии оборудования, трубопроводов [1]. Чтобы исключить загрузку фильтра партией сорбентов с высоким содержанием дефектных гранул, предотвратить эксплуатацию загрузки фильтра, содержащую значительное количество дефектных гранул, следует контролировать наличие дефектов в отобранных представительных пробах гранул сорбентов посредством их визуального осмотра с помощью оптического микроскопа с увеличением не менее  $50\times$ . Данную задачу можно решить, минимизируя человеческий фактор [2] с помощью искусственных нейронных сетей (НС).

В настоящее время практически все системы распознавания изображений строятся на базе сверточных НС [2]. Наиболее широкое применение нейронные сети нашли в задаче распознавания дефектов на поверхностях [3-8]. Однако в этих работах для обучения сети использовались большие наборы данных (не менее 500 изображений на категорию). В то же время особый практический интерес представляют задачи, в которых не требуется крупных наборов обучения. В данной работе показывается, что именно к таким задачам можно отнести распознавание дефектов, т.е. в случае этой задачи не обязательно использовать большие обучающие датасеты. Предпринимается попытка объяснения эффективности обучения сети при малом обучающем наборе данных в случае обнаружения дефектов.


Одна из целей настоящей работы – оценка той предсказательной вероятности сети, ниже которой результат работы сети можно считать сомнительным. Если при классификации неоднородности сеть вынесла вердикт с вероятностью меньшей указанной оценки, то классифицированную неоднородность необходимо будет направить на дополнительное исследование, которое будет проводиться сотрудником лаборатории. Если сеть классифицировала неоднородность с вероятностью, превышающей указанную оценку, вердикт нейронной сети можно считать достоверным.

## 1. Подготовка обучающего набора и набора валидации


Функционирование обученной НС зависит от значительного числа факторов [2]: архитектуры сети, начальной инициализации весов и порогов сети, способа нормировки обучающих данных, подаваемых на вход сети, размера обучающего набора, выбранного алгоритма градиентного спуска, начальной скорости обучения (параметр, учитываемый в алгоритме градиентного спуска), числа эпох обучения. К настоящему времени не существует универсальных рекомендаций по подбору указанных параметров. Самые успешные НС, нашедшие коммерческое применение, были получены путем продолжительных вычислительных экспериментов.

В настоящее время основная проблема, препятствующая повсеместному внедрению сетей – малый объем обучающих изображений. Для каждой из двух классифицируемых категорий имелось только 40 изображений, т.е. весь обучающий набор состоял всего из 80 изображений. На рис. 1 представлены изображения типичных образцов из тренировочного набора. 14 изображений (по 7 изображений на категорию) было использовано для проверки сети на этапе обучения (валидации). Для обучения коммерческих сетей используют не менее тысячи изображений на категорию, то есть имеющийся в наличии обучающий набор на порядок меньше, чем при обучении коммерческих сетей. Поэтому на текущем этапе ис-

следований ставится задача продемонстрировать принципиальную возможность использования нейронных сетей для задач распознавания дефектов на гранулах сорбентов, а также подобрать архитектуру нейронной сети, которая бы позволила удачно решить задачу распознавания дефектов. Кроме того, ставилась задача продемонстрировать, что даже для случая малого набора обучения можно получить сеть, не делающую грубых ошибок, когда гранула сорбента с дефектом классифицируется сетью как бездефектный образец.



а)



б)

**Рис. 1. Изображения типичных образцов из тренировочного набора:**  
*а – гранулы сорбента с дефектами, б – гранулы сорбента без дефектов*

**Fig. 1. Images of typical samples from the training set:**  
*a – sorbent granules with defects; b – sorbent granules without defects*

Корректное обучение сети невозможно осуществить без набора валидации, который на этапе обучения позволяет отследить эпоху, с которой начинается переобучение сети. Пе-

реобучение НС – это фундаментальная проблема, решить которую удалось только в последние десятилетия. Дело в том, что в процессе обучения сеть научится классифицировать изображения из обучающего набора с высокой точностью (даже при малом наборе обучения эта точность может быть близка к 100 %). Но любая обученная сеть будет работать с данными, которых не было в обучающем наборе. Если НС переобучена, то на любых данных, даже несущественно отличающихся от тренировочных, работа сети будет непредсказуемой. Поэтому после каждой обучающей итерации необходимо вычислять перекрестную энтропию именно для набора валидации, который не пересекается с обучающим набором. До тех пор, пока потери падают, пусть даже неравномерно, на валидационном наборе, процесс обучения сети можно считать корректным. Как только будет отмечен рост перекрестной энтропии, необходимо остановить обучение, так как рост потерь на наборе валидации свидетельствует о переобучении сети.

## 2. Выбор архитектуры нейронной сети для решения задачи классификации дефектов

Начальные слои сверточной НС выделяют на изображении наиболее обобщенные (низкоуровневые) признаки (например, границы и текстуры), в то время как более глубокие слои выделяют абстрактные понятия, то есть признаки высокого уровня (такие, как «нос кошки» или «перо птицы») [8]. Когда речь заходит о дефектах, говорить о каких бы то ни было их абстрактных признаках достаточно сложно, т.е. основная информация должна быть заложена в низкоуровневых признаках, самыми сложными из которых могут быть, например, ломанные линии – признак трещин на грануле сорбента. На основании данных положений авторы статей [9-11] заключают, что для распознавания дефектов можно использовать сравнительно неглубокие сети достаточно простой архитектуры, например, VGG16.

В настоящей работе архитектура сети VGG16 также была выбрана в качестве базовой при решении задачи распознавания дефектов. Сеть VGG16 состоит из пяти базовых блоков: первые два блока содержат по два, а последние три блока – по три слоя свертки. После указанных блоков добавляется полносвязный классификатор. Простая архитектура сети позволяет не только ускорить процесс обучения, но и дает возможность использовать сравнительно малый набор обучения. При различной начальной инициализации весов и порогов сети результат обучения может кардинально отличаться, а для критически малых наборов обучения случайная инициализация весов и порогов не позволит обучить сеть до приемлемых значений точности распознавания. Во избежание трудностей, связанных с начальной инициализацией весов и порогов сети, было решено использовать сеть VGG16, уже обученную на миллионе изображений (1000 изображений на категорию) из тренировочного набора ImageNet [12]. Данная сеть была разработана Кареном Симоньяном и Эндрю Циссерманом в 2014 г. [13]. Модель VGG16 входит в состав фреймворка Keras, а возможности данной библиотеки позволяют модернизировать сеть под свои задачи. В частности, пользователь может удалить полносвязный классификатор на 1000 категорий и добавить классификатор с нужной ему архитектурой. Сеть VGG16, представленная в Keras, обучалась распознавать объекты, которые не имеют никакого отношения к дефектам, поэтому изначально не совсем очевидна обоснованность использования предобученной сети. Однако карты признаков сверточной сети определяют присутствие на объекте универсальных обобщенных признаков, которые, как правило, не зависят от конкретики решаемой задачи. Поэтому сверточная основа сети всегда может быть использована для решения задач классификации. Иными словами, для выявления универсальных признаков сеть можно обучать абсолютно на любом наборе данных, так как все исследуемые объекты всегда несут определенные низкоуровневые признаки. Сложные абстрактные признаки (которые в задаче с распознаванием дефектов нам не интересны), характерные для конкретных классов, «зашиты» в глубоких слоях. Задача распознавания дефектов интересна как раз тем, что для них нет необходимости выделять высокоуровневые абстрактные признаки (о чем уже говорилось выше), в то время как более универ-

сальные (низкоуровневые) признаки, характерные для всех объектов, независимо от их природы, хорошо выявляются даже посредством малого числа слоев.

Сверточная основа сети VGG16 не дообучалась. Обучался только полносвязный классификатор, имеющий один скрытый слой из 64 нейронов с функцией активации ReLU. Далее взвешенная сумма выходов данных нейронов подавалась на один выходной нейрон с функцией активации сигмоида. В качестве метода оптимизации (метода градиентного спуска) был выбран метод RMSprop [2], впервые предложенный Джеффом Хинтоном. При обучении сети с помощью функций библиотеки Keras начальная скорость обучения [2] в алгоритме RMSprop устанавливалась в  $2 \cdot 10^{-5}$ , а остальные параметры алгоритма RMSprop были оставлены по умолчанию. Данные параметры можно посмотреть в описании функций библиотеки Keras [14]. Каждую итерацию на вход сети подавалось по пять изображений (минибатч) из обучающего набора. Дело в том, что начальным этапом оценки антиградиента функции потерь является вычисление перекрестной энтропии для обучающего набора. Однако использование всего обучающего набора на каждой итерации обучения приводит к существенным временным затратам, а также повышается вероятность переобучения сети. Поэтому общепризнанным подходом является вычисление перекрестной энтропии не на всем обучающем наборе, а только на небольшой партии из обучающего набора (такая партия называется минибатчем [12]). Естественно, что в данном случае могут быть получены только оценочные значения для компонентов антиградиента функции ошибки. Тем не менее, практика показала высокую эффективность такого подхода. Так как размер обучающего пакета составлял 80 изображений, а размер одного минибатча был равен пяти, то за одну эпоху выполнялось 16 обучающих итераций. Кроме того, на каждой новой эпохе минибатчи формируются заново, причем, случайным образом.

Время обучения заняло порядка минуты на CPU Intel Xeon W-2145 с тактовой частотой 3,7 ГГц, объем оперативной памяти – 32 Гб. Полносвязный классификатор обучался в течение 50 эпох, после чего было принято остановить обучение, так как значения точности распознавания (процент правильно распознанных изображений из набора валидации) от эпохи к эпохе существенно не изменялось (рис. 2). После окончания восьмой эпохи обучения процент правильно распознанных валидационных изображений скачкообразно изменялся от 78,57 % до 85,71 %. Это соответствует одиннадцати и двенадцати правильно распознанным изображениям из четырнадцати валидационных, т.е. на протяжении более сорока эпох обучаемая нейросеть делала от двух до трех ошибочных вердиктов из четырнадцати возможных. Сами скачкообразные изменения в графике точности распознавания связаны только с малым количеством валидационных изображений.

График потерь (перекрестной энтропии) представлен на рис. 2. Необходимо отметить, что, несмотря на малость обучающего набора, эффект переобучения не проявился, так как потери снижались практически на каждой эпохе обучения. Поведение графика точности распознавания (рис. 2) свидетельствует о корректности процесса обучения: действительно, до восьмой эпохи включительно наблюдается монотонный рост точности распознавания на наборе валидации, после чего точность распознавания стабилизировалась, о чем уже было сказано выше. Для графика точности распознавания на тренировочном наборе наблюдается немонотонное возрастание процента правильно распознанных изображений. Вероятно, дальнейшее обучение полносвязного классификатора позволило еще больше увеличить точность распознавания на тренировочном наборе, но с практической точки зрения точность обучения корректнее оценивать по набору валидации.

Еще одним подтверждением корректности процесса обучения являются стартовые значения точности распознавания для тренировочного и валидационного наборов: эти значения близки к 50 %, что является ожидаемым значением для случая бинарной классификации. Из графика на рис. 3 видно, что после обучения сети точность классификации изображений на наборе валидации достигает 85,71 % (12 изображений из 14 валидационных). Естественно, что на данном этапе обученная сеть не найдет коммерческого применения. Тем не менее,

продемонстрирована принципиальная возможность использования предобученных нейронных сетей простой архитектуры для задач распознавания дефектов на гранулах сорбента. Расширенное на порядок количество обучающих изображений позволит существенно повысить точность распознавания.




Рис. 2. Процесс изменения доли правильно распознанных изображений в процессе обучения  
Fig. 2. The process of changing the proportion of correctly recognized images in the learning process






Рис. 3. Процесс изменения перекрестной энтропии в процессе обучения  
Fig. 3. The process of changing cross-entropy in the learning process

### 3. Анализ результатов работы обученной сети

Рассмотрим результаты работы сети. Пример правильно распознанного сорбента с дефектами из валидационного набора представлен на рис. 4.



а)



б)

**Рис. 4. Пример правильно распознанного сорбента с дефектами:**

*а – изображение, поданное на нейронную сеть,*

*б – исходное изображение, из которого был получен рис. 4а*

**Fig. 4. Example of a properly recognized sorbent with defects:**


*a – image submitted to a neural network; b – original image used for Figure 4a*

В круглых скобках на рис. 4 а указана истинная категория (метка класса), без скобок указана метка, предсказанная сетью. Процент на рисунке – это предсказательная вероятность принадлежности к классу. На рис. 4 а показано черно-белое изображение с 256 уровнями яр-



кости размером 150 на 150 пикселей. Именно такую размерность имеют изображения, подаваемые на сеть VGG16, т.е. перед обучением сети необходимо было произвести трансформацию исходного цветного изображения (рис. 4б) к черно-белому изображению размера 150 на 150 [12]. Кроме того, яркость каждого пикселя полученного изображения была нормирована на 255 (максимальный уровень яркости для восьмибитной яркости), так как эффективное обучение сети невозможно без предварительной нормировки обучающих и валидационных данных. Изображение на рис. 4 а тяжело воспринимается человеческим глазом (возникают трудности с определением трещин и сколов на гранулах сорбента), в то время как для нейронной сети такие входные изображения являются естественными.

Пример правильно распознанного сорбента без дефектов из валидационного набора представлен на рис. 5.



**Рис. 5. Пример правильно распознанного сорбента без дефектов:**

*а – изображение, поданное на нейронную сеть,*

*б – исходное изображение, из которого был получен рис. 5а.*

*В круглых скобках на рис. 5а указана истинная категория (метка класса), без скобок указана метка, предсказанная сетью. % на рис. 5а – предсказательная вероятность принадлежности к классу*


**Fig. 5. Example of a properly recognized sorbent without defects:**

*a – image submitted to a neural network; b – original image used for Figure 5a.*

*In parentheses in Figure. 5a is the true category (class label), without parentheses is the predicted label.*

*The percentage in Figure 5a is the predictive probability of belonging to a class by the network. The percentage in Figure 5a is the predictive probability of belonging to a class*

Особый интерес представляют ошибочные вердикты, вынесенные сетью. В валидационном наборе из 14 изображений были неправильно идентифицированы только 2 (на момент окончания обучения). На рис. 6 показан пример изображения бездефектного образца, ошибочно идентифицированного сетью как гранула сорбента с дефектом. Тем не менее, предсказательная вероятность для него близка к 50 % (как и для других ошибочно распознанных образцов), т.е. обученная сеть «сомневается» в вынесенном вердикте. Кроме того, грубых ошибок, когда изображение гранулы сорбента с дефектом было классифицировано как бездефектная гранула, допущено не было.



**Рис. 6. Два бездефектных образца, неправильно классифицируемые сетью как гранула сорбента с дефектом**

**Fig. 6. Two samples without defect incorrectly classified by the network as a defective sorbent**

#### **4. Рекомендации по использованию обученной нейронной сети**

Для формирования рекомендаций по использованию сети необходимо, в первую очередь, исходить из анализа ошибок, допущенных сетью. Из всех тренировочных и валидационных изображений (всего 94) 12 были классифицированы неверно. Для всех этих изображений предсказательная вероятность составила менее 60 %, поэтому можно заключить, что все те, для которых сеть вынесла вердикт с предсказательной вероятностью менее 60 %, должны направляться опытному специалисту для дополнительного исследования. Помимо указанных 12, в тренировочном и валидационном наборах нашлось еще 5 изображений, для которых сеть вынесла правильный вердикт с предсказательной вероятностью, меньшей 60 %. Таким образом, если исследователя интересует только факт наличия дефектов в пробах гранул сорбентов, обученная сеть экономит 82 % времени на исследование образцов (77 изображений из 94).

#### **Заключение**

В результате работы показано, что при малом обучающем наборе (40 изображений на категорию) использование предобученной сети позволяет получить достаточно высокий процент правильно распознанных изображений: 85,71 % на наборе валидации при том, что обучался только полносвязный классификатор, а сверточная основа сети оставалась без изменений.

Предложено объяснение высокого процента правильно распознанных дефектов при условии малости выборки, использованной для обучения сети: данный эффект, скорее всего, связан с тем, что для дефектов не требуется выявление каких бы то ни было абстрактных

признаков. В то же время наиболее обобщенные признаки, характерные, в том числе, и для дефектов, должны выявляться уже первыми сверточными слоям предобученной сети.

Путем анализа количества ошибок, допущенных сетью, были даны рекомендации по практическому использованию сети. Если исследователя интересует наличие дефектных гранул сорбентов в пробе, то обученная нейронная сеть позволит сэкономить до 82 % времени на ее исследование.

### Библиографический список

1. **Кочеткова, А.В.** Влияние на работоспособность оборудования второго контура судовых ядерных энергетических установок попадания в контур сорбентов из фильтров / А.В. Кочеткова, Н.Г. Сандлер, П.В. Тряев, П.А. Крестьянинов, К.Г. Соломаха. // Взгляд в будущее – 2017. Материалы XV молодежной научно-технической конференции. – СПб: АО «Ц», 2017. – 844 с.
2. **Архангельская, Е.В.** Глубокое обучение. Погружение в мир нейронных сетей / Е.В. Архангельская, А.А. Кадуринов, С.И. Николенко. – СПб.: Питер, 2020. – 481 с.
3. **Siyu, Zhang.** Visual inspection of steel surface defects based on domain adaptation and adaptive convolutional neural network / Siyu Zhang, Qiju Zhang, Jiefei Gu, Lei Su // 15 May 2021, Mechanical Systems and Signal Processing 153(3):107541.
5. **Zijian, Kuang.** Computer Vision and Normalizing Flow-Based Defect Detection / Zijian Kuang, Xinran Tie, Lihang Ying, Shi Jin // <https://arxiv.org/abs/2012.06737>.
6. **Desai, K. A.** Swarit Anand Singh, Automated surface defect detection framework using machine vision and convolutional neural networks // Journal of Intelligent Manufacturing. 2022. Vol. 34. P. 1995-2011, (2023) <https://link.springer.com/article/10.1007/s10845-021-01878-w>.
7. **Xu, L.** A Weakly Supervised Surface Defect Detection Based on Convolutional Neural Network / L. Xu, Sh. Lv, Y. Deng, X. Li. IEEE Access PP(99):1-1 March 2020.
8. **Perez, H.** Learning for Detecting Building Defects Using Convolutional Neural Networks / H. Perez, Joseph H., M. Tah, A. Mosavi. <https://arxiv.org/abs/1908.04392>, [Submitted on 6 Aug 2019].
9. **Шолле, Ф.** Глубокое обучение на Python/ Ф. Шолле. – СПб.: Питер, 2020. – 400 с.
10. **Малышев, Г.С.** Использование предобученной нейронной сети для выявления дефектов на изделиях из силицированного графита в АО «ОКБМ Африкантов» / Г.С. Малышев, И.В. Друмов, И.А. Иляхинский, М.А. Камнев, О.В. Андреев, А.А. Абрамов // Научно-технический вестник Поволжья. 2021. № 2. С. 17-20.
11. **Друмов, И.В.** Выявление дефектов на изделиях из силицированного графита с помощью нейронных сетей / И.В. Друмов, М.А. Камнев, Г.С. Малышев, Г.В. Терехин // Автоматизация в промышленности. 2022. № 01. DOI: 10.25728/avtprom.2022.01.05
12. **Ak, R.** Detection and Segmentation of Manufacturing Defects with Convolutional Neural Networks and Transfer Learning Max Ferguson / R. Ak, Y.-T. T. Lee, K. H. Law // Submitted on 7 Aug 2018 (v1), last revised 3 Sep 2018 (this version, v2) <https://arxiv.org/abs/1808.02518>.
13. **Malyshev, G.S.** Choice of neural network architecture when recognizing objects that do not have high-level features / G.S. Malyshev, V.V. Andreev, O.V. Andreeva, O.A. Chistyakov, D.N. Sveshnikov // CEUR Workshop Proceedings, Vol-3027. 2021. С. 1073-1081
14. **Simonyan, K.** Very Deep Convolutional Networks for Large-Scale Image Recognition / K. Simonyan, A. Zisserman // arXiv:1409.1556v6 [cs. CV], 10 April – 2015.

*Дата поступления  
в редакцию: 25.05.2024*

*Дата принятия  
к публикации: 10.07.2024*