

ОЦЕНКА ЭФФЕКТИВНОСТИ НЕЙРОСЕТЕВЫХ АЛГОРИТМОВ ПРИ РАБОТЕ С ЦИФРОВЫМИ ИЗОБРАЖЕНИЯМИ

EVALUATION OF THE EFFECTIVENESS OF NEURAL NETWORK ALGORITHMS WHEN WORKING WITH DIGITAL IMAGES

*E. Ryzhkova
D. Titov*

Summary. Modern trends in production modernization are impossible without the use of new technological solutions that allow increasing the speed of defect recognition and, as a result, accelerating decision-making. The study is devoted to a comparative analysis of the effectiveness of neural network algorithms in solving the problem of recognizing defects on a product [1, p. 83]. This paper presents an approach to image classification using a pre-trained model. The main training method is Transfer Learning, which allows you to use a pre-trained model (VGG16) and retrain it on your own data [2, p. 95]. The use of cross-validation increased the ability of the model to correctly classify images with defects, increased confidence in the presence of defects in the obtained images. The experiment includes the use of various algorithms that allow you to analyze their work by analyzing graphs and success rates. The model effectively solves the problem of detecting defects in the form of cracks in images, achieving high accuracy in defect classification.

Keywords: neural network algorithm, trained model, convolutional neural networks, machine vision, defect, quality improvement.

Рыжкова Елена Владимировна

*Ассистент, Сибирский Государственный университет
геосистем и технологий
alena.tarasova.2014@mail.ru*

Титов Дмитрий Николаевич

*к.т.н., Сибирский Государственный университет
геосистем и технологий
titov200708@mail.ru*

Аннотация. Современные тенденции к модернизации производства невозможны без применения новых технологических решений позволяющих повысить скорость распознавания дефектов и как следствие ускорения принятия решений. Исследование посвящено сравнительному анализу эффективности нейросетевых алгоритмов при решении задачи распознавания дефектов на изделии [1, с. 83]. В данной работе был представлен подход к классификации изображений с использованием предварительно обученной модели. Основным методом обучения — Transfer Learning, позволяет использовать предварительно обученную модель (VGG16) и дообучить ее на собственных данных [2, с. 95]. Применение кросс-валидации повысило способность модели правильно классифицировать изображения с дефектами, увеличило уверенность в наличии дефектов в полученных изображениях. Эксперимент, включает использование различных алгоритмов, позволяющих проанализировать их работу с помощью анализа графиков и процентов успеха. Модель эффективно решает задачу обнаружения дефектов в виде трещин на изображениях, достигая высокой точности классификации дефектов.

Ключевые слова: нейросетевой алгоритм, обученная модель, сверточные нейронные сети, машинное зрение, дефект, повышение качества.

В современной промышленности, обработка изображений играет важную роль, особенно в аспектах контроля качества продукции [3, с. 155]. По мере усложнения производственных линий и повышения стандартов качества, возникает необходимость в разработке эффективных методов для автоматического обнаружения дефектов на изделиях [4, с. 245]. Использование нейросетевых алгоритмов открывает новые горизонты в этой области благодаря их способности обучаться на обширных наборах данных и распознавать даже самые сложные дефекты. Настоящее исследование посвящено сравнительному анализу эффективности разнообразных нейросетевых алгоритмов в задачах распознавания дефектов. Основная цель исследования — определить наиболее подходящий алгоритм для распознавания дефектов на производстве с применением нейросетевых технологий.

В данном исследовании применяется метод Transfer Learning [5, с. 136], который включает использование за-

ранее обученной модели VGG16, дополнительно адаптированной под специфику нашего набора данных. Этот метод особенно ценен при ограниченном объеме данных. Обучающий и тестовый наборы данных были сформированы из двух папок, содержащих изображения с дефектами (положительные) и без дефектов (отрицательные). В общей сложности было задействовано 5200 изображений, 60 % из которых были отведены для обучения модели, а оставшиеся 40 % использовались для тестирования. Перед разделением данные подверглись случайной перестановке. Для оценки производительности модели был использован тестовый набор из 100 изображений, каждое из которых было классифицировано как 'POSITIVE' (с трещиной) или 'NEGATIVE' (без трещины). Все изображения были доведены до размера 120x120 пикселей. Модель была скомпилирована с применением оптимизатора Adam и функции потерь бинарной кросс-энтропии. Для предотвращения переобучения была внедрена стратегия ранней остановки.

Алгоритм 1. Применения сверточных нейронных сетей для обнаружения дефектов на изображениях [6, с.12]. Применение сверточных нейронных сетей (Convolutional Neural Networks, CNN) CNN [7, с. 3] являются стандартом в области анализа изображений и показывают высокую эффективность при решении задач классификации.

Схема нейронной сети выглядит следующим образом:

1. Входной слой (Input) размером (120,120,3);
2. Сверточный слой (Conv2D) с 16 фильтрами и ядром размером (3,3), функция активации — ReLU;
3. Слой максимального пулинга (MaxPool2D) с размером пула (2,2);
4. Сверточный слой (Conv2D) с 32 фильтрами и ядром размером (3,3), функция активации — ReLU;
5. Слой максимального пулинга (MaxPool2D) с размером пула (2,2);
6. Слой глобального усреднения пулинга (GlobalAveragePooling2D);
7. Выходной слой Dense с одним нейроном и сигмоидной функцией активации.

В результате тестирования модель показала тестовую точность (Test Accuracy) 76,30 %. Отчет о классификации показал следующие результаты:

- для класса «NEGATIVE»: точность (precision) составила 0,83, полнота (recall) — 0,42, F1-мера (гармоническое среднее точности и полноты) — 0,56;
- для класса «POSITIVE»: точность (precision) составила 0,62, полнота (recall) — 0,92, F1-мера (гармоническое среднее точности и полноты) — 0,74. Что такое F1-мера.

Таблица 1.

Результаты первых 10 изображений алгоритма CNN

№	Название файла	Тип файла	Результат	Уверенность в результате
1	0,10 clear	jpg	Negative Not crack	0,627637
2	1,1 craked	jpg	Positive crack	0,813721
3	2,2 clear	jpg	Negative Not crack	0,543231
4	3,3 craked	jpg	Positive crack	0,966885
5	4,4 craked	jpg	Positive crack	0,999512
6	5,5 clear	jpg	Negative Not crack	0,601615
7	6,6 clear	jpg	Negative Not crack	0,586648
8	7,7 clear	jpg	Positive crack	0,852246
9	8,8 clear	jpg	Positive crack	0,963136
10	9,9 craked	jpg	Positive crack	0,964757

Результат указывает на то, что модель лучше справляется с определением класса «POSITIVE», но имеет про-

блемы с определением класса «NEGATIVE». Результаты уверенности наличия трещины модели (в процентах) на тестовом наборе первых 10 изображений показаны в таблице 1.

Можно заметить, что модель часто ошибается, но все же имеется потенциал для улучшения, особенно в части определения отсутствия трещины на изображении.

Алгоритм 2. Использование предварительно обученной модели VGG16 для классификации изображений дефектов [8, с. 40]. Данный алгоритм использует предварительно обученную модель VGG16 для классификации изображений дефектов [9, с. 59]. Из 14(R), 715(G), 201(B) параметра модели, обучаемыми являются только 513 параметров в последних слоях, остальные «заморожены».

Схема нейронной сети включала:

1. Входной слой размером (120,120,3);
2. Слои предварительно обученной VGG16 (с замороженными весами);
3. Слой GlobalAveragePooling2D;
4. Слой Dropout (с вероятностью 0,2);
5. Выходной слой Dense с одним нейроном и сигмоидной функцией.

Модель стала значительно лучше определять класс «NEGATIVE», что было проблемой в предыдущем эксперименте. Также стоит отметить улучшение общей точности модели. Результаты (в процентах), на тестовом наборе первых 10 изображений приведены в таблице 2.

Таблица 2.

Результаты первых 10 изображений алгоритма VGG16 с обучаемым слоем

№	Название файла	Тип файла	Результат	Уверенность в результате
1	0,10 clear	jpg	Negative Not crack	0,367081
2	1,1 craked	jpg	Positive crack	0,920216
3	2,2 clear	jpg	Negative Not crack	0,365792
4	3,3 craked	jpg	Positive crack	0,872709
5	4,4 craked	jpg	Positive crack	0,766673
6	5,5 clear	jpg	Negative Not crack	0,350197
7	6,6 clear	jpg	Negative Not crack	0,297235
8	7,7 clear	jpg	Positive crack	0,310231
9	8,8 clear	jpg	Positive crack	0,352111
10	9,9 craked	jpg	Positive crack	0,938156

Модель показывает высокую уверенность при классификации изображений с дефектами (значения близки к 1), и низкую уверенность при классификации изображений без дефектов (значения близки к 0).

Алгоритм 3. Использование модели VGG16 для классификации изображений с кросс-валидацией [10, с. 41]. В этом алгоритме использовалась 5-кратная кросс-валидация для повышения устойчивости модели. Результаты (в процентах), на тестовом наборе первых 10 изображений приведен в таблице 3.

Таблица 3.

Результаты первых 10 изображений алгоритма VGG16 с обучаемым слоем и кросс-валидацией

№	Название файла	Тип файла	Результат	Уверенность в результате
1	0,10 clear	jpg	Negative Not crack	0,319881
2	1,1cracked	jpg	Positive crack	0,982643
3	2,2 clear	jpg	Negative Not crack	0,378072
4	3,3 cracked	jpg	Positive crack	0,97588
5	4,4 cracked	jpg	Positive crack	0,834913
6	5,5 clear	jpg	Negative Not crack	0,277851
7	6,6 clear	jpg	Negative Not crack	0,251782
8	7,7 clear	jpg	Positive crack	0,193464
9	8,8 clear	jpg	Positive crack	0,274406
10	9,9 cracked	jpg	Positive crack	0,99052

Анализ влияния кросс-валидации на результаты обучения модели для обнаружения дефектов. В ходе сравнительного анализа результатов обучения модели с применением кросс-валидации и без неё были выявлены следующие тенденции:

- повышение уверенности модели в обнаружении дефектов: например, для изображения с наименованием «1cracked.jpg» наблюдается увеличение уверенности в наличии трещин с 92 % (без использования кросс-валидации) до 98 % (с использованием кросс-валидации);
- снижение уверенности модели в отсутствии трещин: в случае изображения «5clear.jpg» процент уверенности в наличии трещины сократился с 37 % (без кросс-валидации) до 26 % (с кросс-валидацией).

Сравнивая результаты обучения модели с использованием кросс-валидации и без нее, можно отметить следующие особенности:

- уверенность в наличии трещин: например, для изображения «1cracked.jpg», увеличивается с 92 % (без кросс-валидации) до 98 % (с кросс-валидацией);
- уверенность в отсутствии трещин: например, в случае изображения «5clear.jpg» уменьшается с 37 % (без кросс-валидации) до 26 % (с кросс-валидацией).

В отчете по классификации были получены следующие результаты:

- для класса «NEGATIVE» точность составила 0,97, полнота — 0,85, а F1-мера — 0,92. Это означает, что модель идеально предсказывает отсутствие трещин, но немного хуже определяет их наличие;
- для класса «POSITIVE» точность составила 0,76, полнота — 0,97, а F1-мера — 0,85. Это означает, что модель идеально определяет наличие трещин, но немного хуже предсказывает их отсутствие;
- общая точность модели на тестовом наборе (accuracy) увеличилась до 91,33 %.

В результате обработки (обучения) были получены данные, которые отображены на графике потерь алгоритма CNN на валидационных и тестовых данных на рис. 1.




Рис. 1. График обучения алгоритма с CNN

График функции потерь при обучении и валидации модели VGG16 показан на рис. 2.

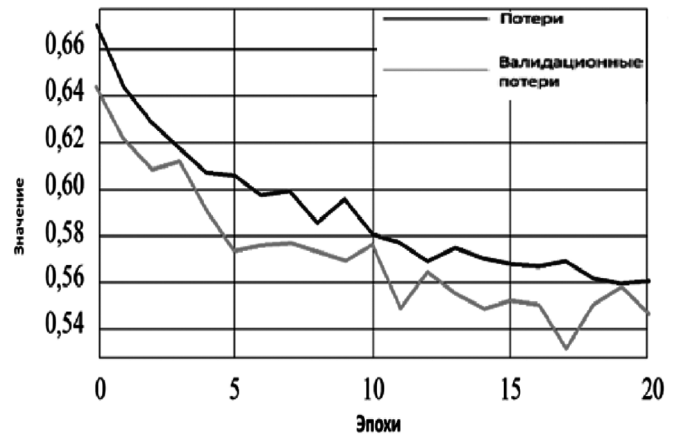


Рис. 2. Функция потерь при обучении и валидации для модели VGG16 с обучаемым слоем

График функции потерь и аккуратности при обучении модели VGG16 с кросс-валидацией для одного фолда показан на рис. 3.

Результаты обработки изображений с помощью всех алгоритмов приведены в таблице 4.




Рис. 3. Функция потерь и точности при обучении кросс-валидацией для модели VGG16 с обучаемым слоем для одного фолда

Таблица 4.

Сравнение результатов алгоритмов

Название способа	Test Accuracy	Precision «NEGA-TIVE»	Recall «NEGA-TIVE»	F1-score «NEGA-TIVE»	Precision «POSITI-VE»	Recall «POSITI-VE»	F1-score «POSITI-VE»
Convolutional Neural Networks, CNN	76,30 %	0,83	0,42	0,56	0,62	0,92	0,74
VGG16 with Transfer Learning	90,00 %	0,96	0,86	0,92	0,75	0,96	0,86
VGG16 with Transfer Learning and Cross-Validation	91,33 %	0,97	0,85	0,91	0,76	0,97	0,85

Использование VGG16 с Transfer Learning и совместно с кросс-валидацией приводит к высокой точности классификации, достигающей 91,33 %. Оба подхода демонстрируют высокую точность как для «NEGATIVE» класса (до 0,97 и 0,86), так и для «POSITIVE» класса (до 0,76 и 0,97). Выбор между этими двумя подходами может варьироваться в зависимости от конкретных требований к поставленной задаче.

Применение Transfer Learning с VGG16 и кросс-валидацией показало значительное улучшение точности классификации, достигая 91,33 %. Эти методы подтвердили свою эффективность и показывают потенциал для дальнейшего улучшения качества моделей распознавания дефектов.

ЛИТЕРАТУРА

1. Скороход А.В., Гордиенко М.В., Семенкин Е.С. Введение в глубинные нейронные сети // Актуальные проблемы авиации и космонавтики, 2020. — №3 — С. 83–85.
2. Чернышев Ю.О., Венцов Н.Н., Пшеничный И.С. Использование технологии Transfer Learning для интеллектуального формирования стартовых популяций при решении задач транспортного типа // Известия Южного федерального университета, 2018. — №3. Т. 233. — С. 90–98.
3. Wei. W., Xu. X. Application of crack detection algorithm using convolutional neural network in concrete pavement construction // International Journal of Grid and Utility Computing, 2022. — №13. Т 2-3. — P. 154–163.
4. Бьенвеню М.М. Использование предобученной нейросети (VGG16) для решения задачи переноса стиля изображения // Известия тульского государственного университета. Технические науки 2021. — №18. Т. 2. — С. 243–248.
5. Федотов И.С. Трансферное обучение в компьютерном зрении: применение и перспективы // Вестник науки, 2023. — №9. Т. 66. — С. 135–137.
6. Маршалко Д.А., Кубанских О.В. Архитектура свёрточных нейронных сетей // Ученые записки Брянского государственного университета, 2019. — №2. Т. 30. — С. 10–13.
7. Xu Z., Qian S., Ran X., Zhou J. Application of Deep Convolution Neural Network in Crack Identification // Applied Artificial Intelligence 2022. — №36. Т. 1. — pp. 1–22.
8. Камалова Ю.Б., Андриянов Н.А. Распознавание микроскопических изображений пылевых зерен с помощью сверточной нейронной сети VGG-16 // Вестник Южно-Уральского государственного университета, 2022. — №22. Т. 3. — С. 39–46.
9. Ломовцева Н.А., Кувайскова Ю.Е. Использование модуля нейронных сетей в системе Statistica для решения задачи классификации // Известия Южного федерального университета. Вестник Ульяновского государственного технического университета, 2021. — №4(104) — С. 59–61.
10. Pak V., Ugli A.S. Application of transfer learning for medical image classification // Science, technology and education, 2020. — №4. Т. 92. — P. 39–42.

© Рыжкова Елена Владимировна (alena.tarasova.2014@mail.ru); Титов Дмитрий Николаевич (titov200708@mail.ru)

Журнал «Современная наука: актуальные проблемы теории и практики»