

*Шаповалова Елена Анатольевна,
доцент, кандидат технических наук
доцент кафедры «Техносферная безопасность»
Тюменский индустриальный университет
Россия, г. Тюмень*

*Щербаков Иван Валерьевич,
студент магистратуры,
2 курс, факультет «Безопасность технологических процессов и
производств»*

*Институт сервиса и отраслевого управления
Тюменский индустриальный университет
Россия, г. Тюмень*

*Борисенко Алина Николаевна,
студент магистратуры,
2 курс, факультет «Безопасность технологических
процессов и производств»*

*Институт сервиса и отраслевого управления
Тюменский индустриальный университет
Россия, г. Тюмень*

СРАВНИТЕЛЬНЫЙ АНАЛИЗ МЕТОДОВ АУГМЕНТАЦИИ ДАННЫХ В ЗАДАЧАХ НЕРАЗРУШАЮЩЕГО КОНТРОЛЯ

Аннотация: Аугментация данных – ключевой метод повышения обобщающей способности нейронных сетей при ограниченных датасетах. В статье сравниваются геометрические (повороты, сдвиги, отражения), цветовые (изменения яркости, контрастности) и комбинированные методы аугментации. Эксперимент проведён на датасете радиографических снимков

сварных швов (75 изображений, 2 класса). Показано, что комбинированная аугментация повышает точность классификации с 89% до 94%, снижает переобучение. Рекомендации по выбору методов для задач неразрушающего контроля

Ключевые слова: аугментация данных, свёрточные нейронные сети, радиографический контроль, классификация изображений, неразрушающий контроль.

Abstract: Data augmentation is a key method for improving the generalization ability of neural networks when dealing with limited datasets. This paper compares geometric (rotations, translations, reflections), color-based (changes in brightness and contrast), and combined augmentation methods. The experiment was conducted on a dataset of radiographic images of welds (75 images, 2 classes). It is shown that combined augmentation increases classification accuracy from 89% to 94% and reduces overfitting. Recommendations for selecting methods for non-destructive testing tasks

Keywords: data augmentation, convolutional neural networks, radiographic testing, image classification, non-destructive testing.

Введение

Современные методы неразрушающего контроля все чаще опираются на технологии машинного обучения, в частности на свёрточные нейронные сети (CNN) [1, 3]. Однако успех их применения напрямую зависит от объема и разнообразия имеющихся данных. В промышленных условиях, особенно при радиографическом контроле сварных соединений, создание больших наборов данных представляет собой сложную задачу: сбор и маркировка изображений дефектов требуют привлечения высококвалифицированных специалистов и значительных затрат времени [8]. В результате размер доступной выборки часто не превышает нескольких десятков или сотен изображений, что создает риск переобучения модели и снижения ее способности к обобщению.

Одним из наиболее эффективных способов преодоления этой проблемы является аугментация данных – искусственное расширение обучающей выборки посредством различных преобразований исходных изображений [7]. Классические геометрические преобразования (вращения, сдвиги, отражения, масштабирование), а также изменения цвета и контрастности позволяют синтезировать новые примеры с сохранением семантической метки. Однако влияние различных методов расширения на качество классификации в задачах неразрушающего контроля изучено недостаточно. Как правило, расширение применяется «по умолчанию», без сравнительной оценки эффективности отдельных методов и их комбинаций.

В нашей предыдущей работе мы предложили архитектуру ANN для классификации дефектов сварных швов, которая достигла точности 94% на ограниченном наборе данных (75 изображений) использовалось комбинированное расширение (вращения, сдвиги, отражения). Однако остался открытым вопрос: насколько критичен выбор методов расширения и возможно ли достичь приемлемого качества без расширения или с упрощенными преобразованиями?

Цель данной работы – провести сравнительный анализ влияния различных типов расширения данных на точность классификации дефектов сварных швов с использованием свёрточной нейронной сети. Сравниваются три сценария: обучение без расширения, с использованием только геометрических преобразований и с комбинированным расширением (геометрия + цвет/шум). Полученные результаты позволяют дать практические рекомендации по выбору методов расширения данных для задач неразрушающего контроля с небольшими наборами данных.

Методы аугментации данных

В данном исследовании для расширения обучающей выборки использовались три группы методов аугментации: геометрические преобразования, цветовые и контрастные преобразования, а также их

комбинация. Все преобразования реализованы с помощью класса ImageDataGenerator библиотеки TensorFlow/Keras [1]. На рисунке 1 представлено оригинальное изображение используемого снимка в качестве примера:




Рисунок 1. Оригинальное изображение снимка с дефектом сварного шва

Исходные изображения имели размер 128×128 пикселей, нормализованы в диапазон $[0,1]$. На рисунке 2 показан пример изображения, используемого в качестве обучающего материала для свёрточной нейронной сети:




Рисунок 2. Пример изображения для обучения нейронной сети

Геометрическая аугментация направлена на имитацию различных ракурсов съёмки, смещений и масштабирования сварных швов. В работе использовались следующие параметры:

Повороты – случайный угол в диапазоне от -20 до $+20$ градусов ($\text{rotation_range}=20$). Это позволяет модели распознавать дефекты независимо от ориентации снимка.

Сдвиги – случайное смещение изображения по ширине и высоте до 20% ($\text{width_shift_range}=0.2$, $\text{height_shift_range}=0.2$). Компенсирует возможное несовпадение центровки шва на разных снимках.

Горизонтальное отражение (`horizontal_flip=True`) – зеркальное отображение, актуально для симметричных конструкций.

Масштабирование (`zoom_range=0.2`) – случайное увеличение или уменьшение изображения, имитирует разное расстояние от источника излучения.

Цветовые и контрастные преобразования

Радиографические снимки могут различаться по яркости и контрастности из-за условий экспонирования. Для имитации этих вариаций применялись:

изменение яркости – добавление случайного сдвига в значениях пикселей (в пределах $\pm 10\%$ от исходного диапазона);

изменение контрастности – масштабирование интенсивности пикселей с коэффициентом от 0,8 до 1,2;

добавление гауссовского шума – среднеквадратическое отклонение 0,01 от нормализованного диапазона. Это повышает устойчивость модели к случайным помехам, характерным для рентгеновских детекторов.

Комбинированная аугментация

В третьем сценарии последовательно применялись все вышеперечисленные преобразования. Порядок операций: сначала геометрические изменения (повороты, сдвиги, отражение), затем цветовые и контрастные модификации. Такой подход позволяет синтезировать максимальное разнообразие примеров, сохраняя при этом принадлежность к исходному классу (дефект/годный).

Все преобразования выполнялись онлайн во время обучения, то есть каждый снимок предъявлялся модели в случайно изменённом виде на каждой эпохе. Валидационная выборка не подвергалась аугментации.

Результаты

Сценарий 1 (без аугментации). Обучение на исходных 57 изображениях без каких-либо преобразований. Точность на валидационной выборке (18

снимков) составила 89%. При этом наблюдались явные признаки переобучения: точность на обучающей выборке достигла 99%, тогда как на валидационной – не превышала 89%, разрыв составил 10%. Модель запомнила конкретные снимки, но не научилась обобщать признаки дефектов.

Сценарий 2 (только геометрическая аугментация). Применялись повороты ($\pm 20^\circ$), сдвиги (20%), горизонтальное отражение и масштабирование. Валидационная точность повысилась до 92%. Разрыв между обучающей и валидационной точностью сократился до 5%, что свидетельствует об улучшении обобщающей способности. Однако при оценке на реальных снимках (без аугментации) модель иногда ошибалась на снимках с нестандартной яркостью.

Сценарий 3 (комбинированная аугментация). К геометрическим преобразованиям добавлены цветовые и контрастные модификации (изменение яркости, контрастности, гауссовский шум). Валидационная точность достигла **94%** (максимальное значение). Разрыв между обучающей и валидационной точностью составил менее 3%, что говорит о хорошей обобщающей способности. Чувствительность (выявление дефектов) осталась на уровне 100%, специфичность – 87,5%. В таблице 1 указаны сценарии использования всех видов аугментации данной работы:

Таблица 1.

Влияние аугментации на точность классификации

Сценарий аугментации	Точность на валидации	Признаки переобучения
Без аугментации	89%	Разрыв train/val >10%
Только геометрическая	92%	Разрыв ~5%
Комбинированная	94%	Разрыв <3%

Заключение

В работе проведён сравнительный анализ влияния различных методов

аугментации данных на точность классификации дефектов сварных швов с помощью сверточной нейронной сети. Эксперименты на ограниченном датасете (75 радиографических снимков) показали, что:

отсутствие аугментации приводит к переобучению и снижению точности (89%);

применение только геометрических преобразований повышает точность до 92% и уменьшает переобучение;

комбинированная аугментация (геометрия + цветовые/контрастные модификации) обеспечивает максимальную точность – 94% – и минимальный разрыв между обучающей и валидационной выборками.

Для задач неразрушающего контроля с малыми датасетами комбинированная аугментация является обязательным элементом предобработки. Рекомендуется включать повороты, сдвиги, отражения, масштабирование, а также незначительные изменения яркости и контрастности. Дальнейшие исследования могут быть направлены на применение более сложных методов (CutMix, MixUp) и автоматический подбор параметров аугментации.

Список литературы:

1. Денисенко А. А. Решение задачи бинарной классификации при помощи сверточных нейронных сетей с использованием фреймворка Tensorflow // Технические науки: проблемы и решения: сборник статей по материалам XX международной научно–практической конференции. СПб.: Свое издательство, 2019. С. 1–4.

2. Клехо Д. Ю., Карелина Е. Б., Батырев Ю. П. Использование технологии сверточных нейронных сетей в сегментации объектов изображения // Лесной вестник / Forestry Bulletin, 2021. Т. 25. № 1. С. 140–145. DOI: 10.18698/2542–1468–2021–1–140–145

3. Ле Мань Х. Сверточная нейронная сеть для решения задачи

классификации // Труды МФТИ, 2016. Т. 8. № 3. С. 91–97.

4. Рысьмятова А. А. Использование сверточных нейронных сетей. М.: МГУ, 2016. 34 с.

5. Сикорский О. С. О влиянии цветового пространства изображения на обучение сверточной нейронной сети в задаче классификации изображений // Новые информационные технологии в автоматизированных системах, 2018. № 21. С. 340–343.

6. Жданов А. Д., Жданов Д. Д., Хилик Е. Д. Автоматическое создание и разметка RGB–D изображений для обучения систем машинного зрения // Графикон–конференции по компьютерной графике и зрению. – 2023. – Т. 33. – С. 25–32.

7. Shorten C., Khoshgoftaar T. M. A survey on Image Data Augmentation for Deep Learning // Journal of Big Data. – 2019. – Vol. 6. – Article 60. – DOI: 10.1186/s40537-019-0197-0.

8. ГОСТ 30242–97 «Дефекты соединений при сварке металлов плавлением. Классификация, обозначение и определения». – М.: ИПК Издательство стандартов, 1998. – 22 с.