

УДК 004.032.26

doi 10.54708/22259309\_2025\_132113

## ПРЕДВАРИТЕЛЬНАЯ ОБРАБОТКА ДАННЫХ: КЛЮЧЕВОЙ ЭТАП РАЗРАБОТКИ ТОЧНЫХ И УСТОЙЧИВЫХ НЕЙРОННЫХ СЕТЕЙ

А. И. ТАТАУРОВ<sup>1</sup>

<sup>1</sup>tataurov.ai@ugatu.su

<sup>1</sup>ФГБОУ ВО «Уфимский университет науки и технологий» (УУНИТ)

**Аннотация.** В работе рассматривается важность предварительной обработки данных на примере применения сверточных нейронных сетей (CNN) к задачам классификации изображений. Приведены ключевые методы обработки данных, включая нормализацию, масштабирование и аугментацию. Для наглядности приведены результаты обучения модели без применения аугментации данных и с её использованием, подтверждающие ключевую роль этого этапа в процессе создания точных и устойчивых моделей.

**Ключевые слова:** предварительная обработка; нейронные сети; методы; аугментация; переобучение.

### ВВЕДЕНИЕ

Современные нейронные сети, такие как сверточные нейронные сети (CNN), достигли значительных успехов в решении задач, связанных с анализом изображений, видео, текста и других типов данных. Однако эффективность и точность этих моделей напрямую зависят не только от их архитектуры, но и от качества данных, на которых они обучаются [1]. Недостаточная проработка данных или их несоответствие требованиям модели может привести к снижению точности, переобучению и невозможности обобщения на новых данных [2, 3].

Предварительная обработка данных – это важнейший этап, который позволяет преобразовать сырой набор данных в форму, наиболее подходящую для обучения нейронной сети. Она включает в себя такие шаги, как нормализация, уменьшение шума, устранение пропусков, аугментация данных и прочие подходы. Для CNN предварительная обработка имеет ключевое значение, так как входные данные (например, изображения) часто имеют высокий уровень вариативности, включая различия в освещении, масштабе, угле наклона и других параметрах.

Основная цель предварительной обработки заключается не только в улучшении качества данных, но и в повышении устойчивости модели к шуму, увеличении разнообразия обучающего набора и снижении риска переобучения. Эти шаги становятся особенно важными, если исходные данные ограничены по объему или содержат артефакты, мешающие модели эффективно извлекать признаки.

Тем не менее предварительная обработка данных – это не универсальный процесс, и её выбор зависит от конкретной задачи. Например, методы, которые эффективны для одной области (например, медицинских изображений), могут быть менее применимы в другой (например, анализе спутниковых снимков). Важно понимать, как разные подходы влияют на качество модели, чтобы обоснованно выбирать их для конкретной задачи.

Рассмотрим некоторые основные методы предварительной обработки, применимые к изображениям, а также оценим влияние аугментации на примере применения CNN к задачам классификации.

### МЕТОДЫ ПРЕДВАРИТЕЛЬНОЙ ОБРАБОТКИ ДАННЫХ

Нормализация – приведение значений сигналов к небольшому фиксированному диапазону (как правило, диапазон имеет вид  $[0,1]$  или  $[-1,1]$ ). Нормализация снижает влияние различий в масштабе данных и ускоряет обучение модели, поскольку значения нейронов становятся более согласованными:

$$I_{norm} = \frac{I}{255}, \quad (1)$$

где  $I$  – интенсивность пикселя в диапазоне  $[0, 255]$ .

В некоторых случаях применяют стандартизацию:

$$I_{std} = \frac{I - \mu}{\sigma}, \quad (2)$$

где  $\mu$  – среднее значение интенсивностей;  $\sigma$  – стандартное отклонение.

Масштабирование – приведение изображений к одному масштабу (например,  $128 \times 128$  или  $224 \times 224$  пикселя), что позволяет избежать ошибок при передаче данных в сеть и уменьшает вычислительные затраты. Применяют методы билинейной интерполяции для увеличения или уменьшения размера изображений, обрезки для выбора центральной или другой наиболее важной части изображения и «padding» для добавления рамок, чтобы сохранить пропорции изображения. Результатом масштабирования является унификация данных.

Аугментация данных – искусственное увеличение объема тренировочных данных за счет внесения контролируемых изменений в данные, под которыми понимаются вращение, сдвиги, шум, обрезка и масштабирование, инверсия цветов.

Аннотация данных позволяет отметить рабочий режим или состояние каждого примера в обучающем наборе данных для верной интерпретации их нейронной сетью, например, на изображениях может быть приведен процесс «нормальный» или «аномальный». Аннотации должны быть максимально точными и соответствовать реальному состоянию объекта.

### ЭКСПЕРИМЕНТ

Целью эксперимента является оценка различных параметров аугментации изображений на точность сверточной нейронной сети при классификации изображений.

Для обучения CNN используется набор данных из открытого доступа caltech101. Для улучшения качества обучения применяется аугментация данных с использованием класса ImageDataGenerator из библиотеки Keras.

Методология:

Базовая модель. Архитектура CNN фиксирована для всех экспериментов. Гиперпараметры (количество эпох, размер батча) остаются неизменными.

Параметры аугментации. Исследуется влияние следующих параметров аугментации:

- rotation\_range (диапазон случайного поворота);
- width\_shift\_range (горизонтальное смещение);
- height\_shift\_range (вертикальное смещение);
- shear\_range (диапазон сдвига среза);
- zoom\_range (диапазон масштабирования);
- horizontal\_flip (отражение по горизонтали).

Для оценки влияния параметра каждый из них варьируется в определенном диапазоне либо исключается.

Гиперпараметры. Количество эпох выбрано, равное 40, как компромиссное решение между минимизацией времени обучения и точностью базовой модели на обучающей выборке, не менее 94 %.

Этапы моделирования:

- В качестве контрольного варианта модель обучается без аугментации.
- Модель обучается на данных с аугментацией, где фиксируется комбинация параметров.

– Для каждой комбинации проводится независимый запуск с записью значений точности на валидационной выборке.

Метрики:

Для оценки качества модели используется метрика ассурасу на валидационной выборке. Для наиболее значимых комбинаций параметров приведены графики точности и потерь на обучающей и валидационной выборках.

Повторяемость эксперимента:

С целью уменьшения случайных влияний на результат для комбинации параметров с наилучшими показателями точности по результатам первой итерации (отмечены звездочкой \*) эксперимент проводится трижды, фиксируется среднее значение.

Результаты эксперимента приведены в виде сравнительной таблицы, показывающей зависимость точности модели от параметров аугментации (табл. 1).

Таблица 1

**Зависимость точности модели от параметров аугментации**

№	Параметры аугментации	Значение параметров, % (True/False)	Точность модели, %
1	2	3	4
1	Без аугментации	-	45
2	Rotation Range	15	51
3*	Width/Height Shift	0,1; 0,1	62
4	Shear Range	0,1	46
5	Zoom Range	0.15	55
6	Horizontal Flip	True	50
7	Rotation Range	5	49
8	Zoom Range	0,1	54
9*	Zoom Range, Width/Height Shift	0,15; 0,1; 0,1	62
10	Rotation, Shear, Zoom Range, Width/Height Shift, Horizontal Flip	15; 0,1; 0,1; 0,1; 0,1, True	56
11*	Rotation, Shear, Zoom Range, Width/Height Shift, Horizontal Flip	5; 0,1; 0,1; 0,1; 0,1, True	62
12*	Shear, Zoom Range, Width/Height Shift, Horizontal Flip	0,1; 0,1; 0,1; 0,1, True	60
13	Rotation, Shear, Zoom Range, Height Shift, Horizontal Flip	5; 0,1; 0,1; 0,1, True	57
14	Shear, Zoom Range, Width Shift, Horizontal Flip	5; 0,1; 0,1; 0,1, True	57
15	Rotation, Shear, Zoom Range, Width/Height Shift, Horizontal Flip	5; 0,1; 0,1; 0,15; 0,15, True	55
16*	Rotation, Zoom Range, Width/Height Shift, Horizontal Flip	5; 0,1; 0,1; 0,1, True	59
17*	Rotation, Shear Range, Width/Height Shift, Horizontal Flip	5; 0,1; 0,1; 0,1, True	57
18*	Rotation, Shear, Zoom Range, Width/Height Shift, Horizontal Flip	15; 0,1; 0,1; 0,1; 0,1, False	62
19*	Rotation, Shear, Zoom Range, Width/Height Shift, Horizontal Flip	15; 0,1; 0,15; 0,1; 0,1, True	59

Результаты:

Модели с номерами 3, 9, 11, 18 показали наилучшую точность при выбранных параметрах, составляющую 62 %. На рис. 1–2 приведены графики точности и потерь для тренировочного и валидационных наборов данных для базовой модели и модели с аугментацией.

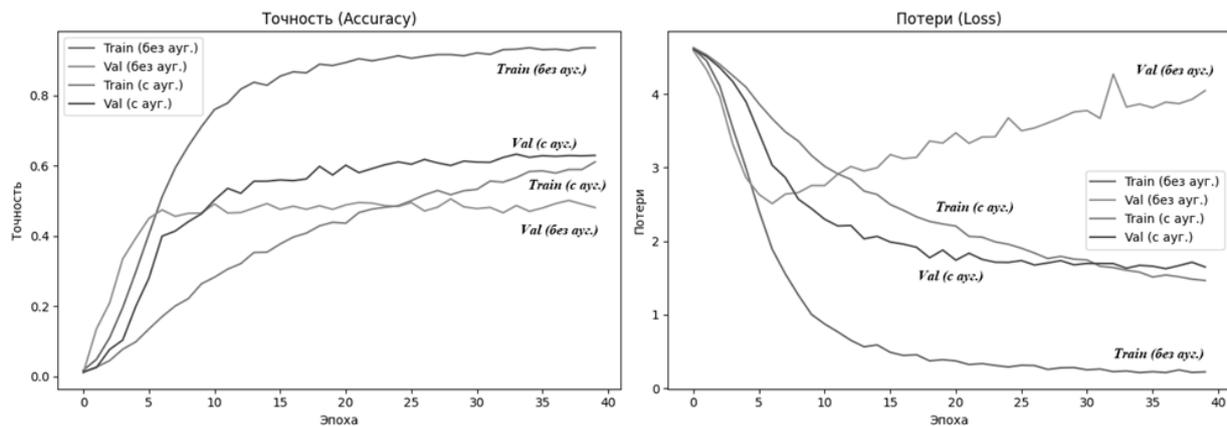


Рис. 1. Обучение модели № 9

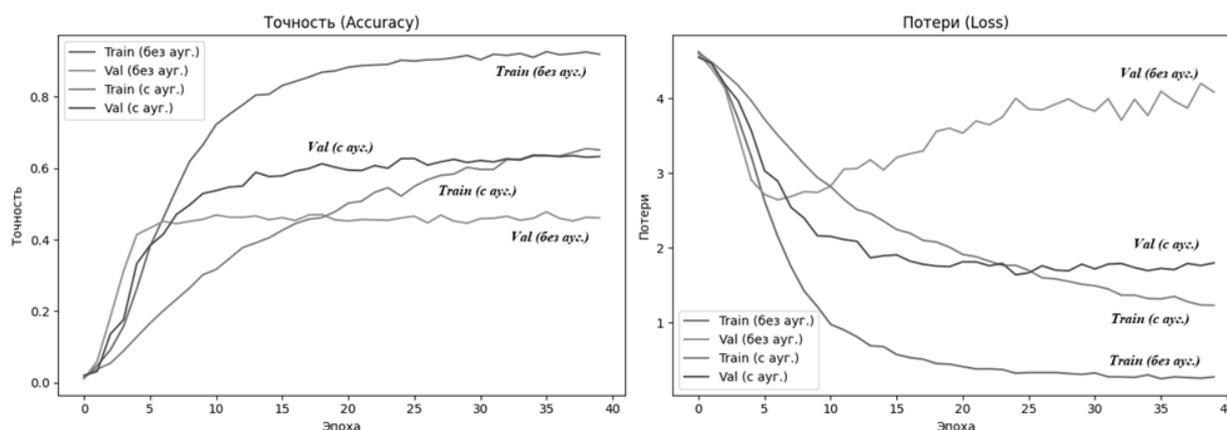


Рис. 2. Обучение модели № 3

По графикам заметно, что базовая модель без аугментации имеет хорошие показатели обучения на тестовом наборе данных (91–94 %), в отличие от модели с аугментацией (63–66 %), однако на валидационном наборе точность базовой модели (45–47 %) ниже, чем у модели с аугментацией (63–65 %), что говорит о вероятном переобучении базовой модели, начало которого можно отметить на 5–10 эпохах.

Приведенные модели с аугментацией, напротив, имеют очень схожую точность как на тренировочном наборе данных, так и на валидационном, что говорит о возможности их дальнейшего дообучения с целью повышения общей точности.

### ЗАКЛЮЧЕНИЕ

Данная работа наглядно демонстрирует значимость предварительной обработки данных на примере задачи классификации изображений с использованием сверточных нейронных сетей (CNN). Методы обработки данных, такие как нормализация, масштабирование и аугментация, оказывают прямое влияние на качество и устойчивость моделей.

Было показано, что модель без аугментации данных склонна к переобучению: высокая точность на тренировочном наборе данных (91–94 %) сопровождается существенным снижением точности на валидационном наборе (45–47 %). Напротив, модели с аугментацией демонстрируют сбалансированную производительность, обеспечивая близкую точность на тренировочных (63–66 %) и валидационных (63–65 %) данных, что свидетельствует о лучшем обобщении.

Эти результаты подтверждают, что предварительная обработка данных играет ключевую роль на этапе подготовки моделей. Аугментация данных не только снижает вероятность переобучения, но и способствует созданию моделей, которые могут эффективно работать в условиях реальных данных. Таким образом, использование методов предварительной обработки является необходимым условием для построения точных, надежных и устойчивых моделей.

## СПИСОК ЛИТЕРАТУРЫ

1. Krizhevsky A., Sutskever I., & Hinton, G. E. ImageNet classification with deep convolutional neural networks. Communications of the ACM. 2012. 60(6). P. 84–90.
2. Goodfellow I., Bengio Y., & Courville A. Deep Learning. MIT Press. 2016.
3. Simard P. Y., Steinkraus D., & Platt J. C. Best practices for convolutional neural networks applied to visual document analysis. International Conference on Document Analysis and Recognition. 2003.

## ОБ АВТОРАХ

Татауров Александр Игоревич, аспирант каф. ПИШ «Моторы будущего»

## METADATA

**Title:** DATA PREPROCESSING: A KEY STAGE IN DEVELOPING ACCURATE AND ROBUST NEURAL NETWORKS

**Author:** A. I. Tataurov<sup>1</sup>

**Affiliation:**

<sup>1</sup>Ufa University of Science and Technology (UUST), Russia.

**Email:** <sup>1</sup>[tataurov.ai@ugatu.su](mailto:tataurov.ai@ugatu.su)

**Language:** Russian.

**Source:** Molodezhnyj Vestnik UGATU (scientific journal of Ufa University of Science and Technology), no. 1 (32), pp. 113-117, 2025. ISSN 2225-9309 (Print).

**Abstract:** This paper examines the importance of data preprocessing using convolutional neural networks (CNNs) for image classification tasks. Key data processing methods, including normalization, scaling, and augmentation, are discussed. To illustrate the significance of this stage, the study presents training results of a model without data augmentation and with its application, confirming the critical role of this step in creating accurate and robust models.

**Keywords:** preprocessing, neural networks, methods, augmentation, overfitting.

**About authors:**

**TATAUROV ALEXANDR IGOREVICH**, graduate student, Dept. "Motors of the Future" (UUST).