

Влияние замены и расширения данных с применением преобразований на точность распознавания глубокой нейронной сети ResNet - 50

Т.С. Евдокимова

*Казанский Национальный Исследовательский
Технический Университет им. А. Н. Туполева – КАИ, Казань*

Аннотация: В статье рассматривается, как замена исходных данных преобразованными влияет на качество обучения глубоких нейросетевых моделей. Автор проводит четыре эксперимента с целью оценки влияния замены данных в задачах с малыми наборами данных. Первый эксперимент заключается в обучении модели без внесения изменений в исходный набор данных, второй заключается в замене всех изображений в исходном наборе на преобразованные, третий заключается в сокращении количества исходных изображений и расширения исходного набора данных при помощи преобразований, применяемых к изображениям, а также в четвертом эксперименте осуществляется расширение набора данных с целью уравновесить количество изображений в каждом классе по наибольшему.

Ключевые слова: набор данных, расширение, нейросетевые модели, классификация, преобразование изображений, замена данных.

Введение

В настоящее время внедрение глубоких нейросетевых моделей в задачах классификации объектов на изображении встречается повсеместно. Однако, для осуществления распознавания с высокой точностью, при обучении выбранных моделей классификации необходимо соблюдать ряд критериев, одним из них является подготовка качественного набора данных. Качество набора данных в первую очередь определяется количественной составляющей, которая подразумевает достаточный объем с целью возможности используемой модели обобщать, а также с более высокой точностью распознавать объекты на новых изображениях. Также важна сбалансированность наборов данных, а именно - одинаковое или близкое к нему количество изображений каждого класса, при несоблюдении данного критерия, модель классификации будет качественно распознавать только те классы, которые представляют больший объем.

Важность расширения наборов данных обусловлена следующими причинами: внесение разнообразия в набор обучающих данных за счет создания новых, измененных версий существующих данных, более широкое представление основного распределения данных, позволяя моделям охватывать более широкий спектр закономерностей и вариаций, получение большого набора размеченных данных может оказаться сложной и дорогостоящей задачей, уменьшение систематической ошибки в обучающих данных, за счет расширения выборок для недостаточно представленных классов, сохранение конфиденциальности [1].

Анализ влияния замены и расширения данных

Можно сделать вывод, что в тех сферах, где сбор данных для обучения является затруднительным по ряду причин, необходимо применять подходы к их расширению. Также необходимо рассмотреть возможность замены большей части исходных данных при обучении моделей на расширенный.

В данной работе были проведены следующие эксперименты, в которых исследуется как замена или расширение исходных обучающих данных влияет на модель классификации с точки зрения точности:

- 1) Обучение модели классификации на исходном наборе данных;
- 2) Обучение модели классификации при замене каждого исходного изображения преобразованным;
- 3) Обучение модели классификации при сокращении исходных изображений и компенсирование за счет преобразований;
- 4) Обучение модели классификации со сбалансированным количеством изображений в обучающей выборке по большому классу.

В качестве примера рассматривался многоклассовый набор данных «70 Dog Breeds-Image Data Set», который состоит из 70 классов различных пород собак общее количество изображений составляет 9 346.

как SGD (Stochastic Gradient Descent) [4] или RMSprop [5] имеет следующий ряд преимуществ: быстрая сходимость, нечувствительность к масштабированию, эффективность в задачах с зашумленными данными, автоматическая настройка параметров, в качестве функции потерь была выбрана CrossEntropyLoss так как она позволяет измерять расхождение между двумя распределениями: предсказанным распределением модели и истинным распределением целевых меток, учитывает вероятность всех классов, а не только класса с максимальной вероятностью, функция имеет гладкий градиент, что делает обучение модели более стабильным. А также в качестве опыта проводилось обучение всего на трех эпохах, в которых для оценки градиента ошибки использовался размер пакета равный 64 [6,7].

Во втором опыте все изображения из обучающего набора данных были изменены, посредством применения к каждому изображению набора следующих преобразований RandomBrightnessContrast – функция изменения яркости и контраста изображения [8], HorizontalFlip – функция отражения изображения по горизонтали, Rotate - функция: поворота изображения на случайный угол [9] и RandomRain – функция добавления дождя на изображение [10]. К каждому изображению применялось минимум одно преобразование.

В третьем опыте из каждого класса было взято 10 случайных изображений, к которым были применены различного типа преобразования, таким образом было получено 100 изображений каждого класса. В данном опыте были выполнены сразу две задачи, а именно - сокращение исходных данных для процесса обучения и замена их преобразованными, а также соблюдение баланса в данных в каждом классе.

В четвертом опыте главной задачей было сбалансировать все классы по количеству изображений. Алгоритм состоял из поиска класса с наибольшим количеством изображений, нахождение разницы между значением

количества изображений в наибольшем и текущем классах, далее выбирались случайные изображения, к которым применялись преобразования и сохранялись в исходный набор.

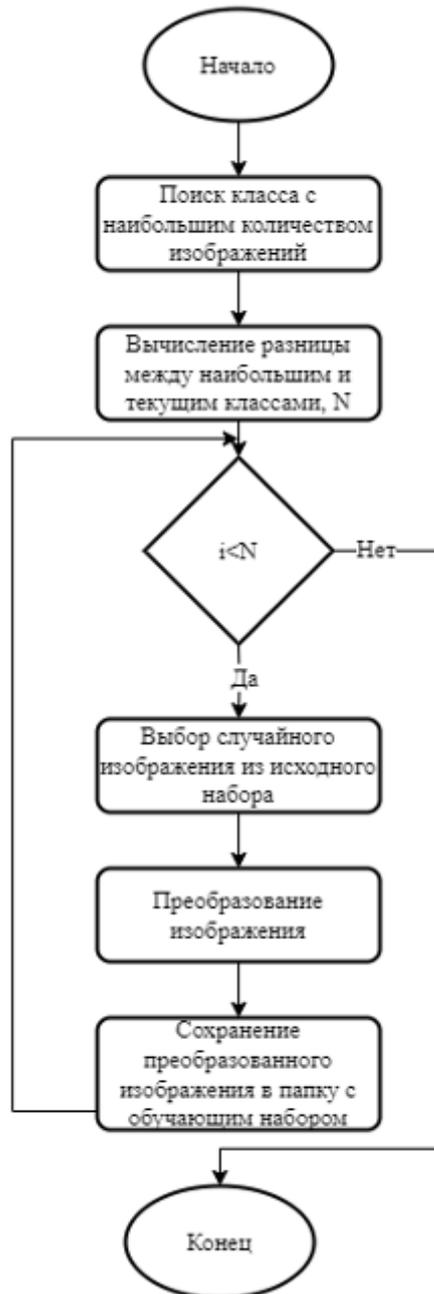


Рис. 3. – Блок-схема увеличения набора изображений каждого класса по наибольшему

По результатам четырех экспериментов были получены следующие результаты, представленные в таблице. Данные из таблицы показывают, что обучение модели с применением преобразований всех данных в исходном наборе не уступает в точности при обучении на исходных данных. В свою очередь, сокращение количества исходных данных с последующим их расширением показало, что модель обучается хуже всего на 2,43 %, что показывает, что в условиях ограниченных ресурсов такой подход может быть применим. Наилучшие результаты показал подход, заключающийся в расширении классов и их сбалансировании по наибольшему.

Таблица

Результаты четырех экспериментов влияния замены и расширения данных на качество обучения глубоких нейросетевых моделей

Тип данных для обучения	Метрика обучения	Номер эпохи		
		№1	№2	№3
На исходных данных	Точность	0,8843	0,9114	0,9200
	Функция потерь	0,6479	0,5488	0,5483
На измененных данных	Точность	0,8814	0,9129	0,9271
	Функция потерь	0,6799	0,5385	0,5277
Сокращение исходных данных	Точность	0,8700	0,8743	0,8957
	Функция потерь	0,6888	0,6316	0,6234
Сбалансирование классов	Точность	0,9229	0,9300	0,9314
	Функция потерь	0,5457	0,5504	0,5767

Таким образом можно сказать, что в тех задачах, где существует ограничение в количестве собранных данных можно осуществлять замену данных преобразованными. Особое внимание стоит уделить вопросу

сбалансированности данных, а также подбору преобразований, применяемых к изображениям.

Литература

1. Сорокина В. В., Абламейко С.В. Метод аугментации данных для улучшения качества распознавания изображений электронной коммерции // Вестник Полоцкого государственного университета. Серия С. Фундаментальные науки. 2023. № 2(41). С. 29-34.

2. Евдокимова Т. С. Влияние методов расширения наборов данных на качество обучения нейросетевых моделей. Адаптивный подход расширения наборов данных // Инженерный вестник Дона. 2024. № 8. URL: ivdon.ru/ru/magazine/archive/n8y2024/9439.

3. Okewu E., Misra S., Lius F. S. Parameter Tuning Using Adaptive Moment Estimation in Deep Learning Neural Networks // Lecture Notes in Computer Science. 2020. Vol. 12254 LNCS. pp. 261-272.

4. De S., Maute K., Doostan A. Bi-fidelity stochastic gradient descent for structural optimization under uncertainty // Computational Mechanics. 2020. Vol. 66, No. 4. pp. 745-771.

5. Yue X., Liu Q. Improved FunkSVD Algorithm Based on RMSProp // Journal of Circuits, Systems, and Computers. 2022. Vol. 31, No. 08.

6. Загидуллин А. Р. Исследование методов обучения нейронной сети для задачи сегментации // Инновации. Наука. Образование. 2021. № 31. С. 343-352.

7. Пучков Е.В. Сравнительный анализ алгоритмов обучения искусственной нейронной сети // Инженерный вестник Дона, 2013, № 4. URL: ivdon.ru/ru/magazine/archive/n4y2013/2135.

8. Коссов Г.А., Селезнев И.А. Влияние настраиваемых параметров полносвязной нейронной сети на качество предсказания для задачи классификации литотипов // Проблемы информатики. 2023. № 1(58). С. 48-59.

9. Кравченко С.В., Алексеев А. В., Орлова Ю. А. Проблемы детектирования объекта на изображении в задачах глубокого обучения в области компьютерного зрения на основе свёрточных нейронных сетей // Инновации и инвестиции. 2020. № 6. С. 194-197.

10. Ojala T, Pietikainen M, Maenpaa T (2002) Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. // IEEE Trans Pattern Anal Mach Intell. 24(7). pp. 971–987.

References

1. Sorokina V.V., Ablamejko S.V. Vestnik Poloczkiego gosudarstvennogo universiteta. Seriya S. Fundamental`ny`e nauki. 2023. № 2(41).pp. 29-34.

2. Evdokimova T. S. Inzhenernyj vestnik Dona. 2024, № 8. URL: ivdon.ru/ru/magazine/archive/n8y2024/9439.

3. Okewu E., Misra S., Lius F. S. Lecture Notes in Computer Science. 2020. Vol. 12254 LNCS. pp. 261-272.

4. De S., Maute K., Doostan A. Computational Mechanics. 2020. Vol. 66, No. 4. pp. 745-771.

5. Yue X., Liu Q. Journal of Circuits, Systems, and Computers. 2022. Vol. 31, No. 08.

6. Zagidullin A. R. Innovacii. Nauka. Obrazovanie. 2021. № 31. pp. 343-352.

7. Puchkov E. V. Inzhenernyj vestnik Dona, 2013, № 4. URL: ivdon.ru/ru/magazine/archive/n4y2013/2135.

8. Kossov G. A., Seleznev I.A. Problemy` informatiki. 2023. № 1(58). pp. 48-59.

9. Kravchenko S. V., Alekseev A. V., Orlova Yu. A. Innovacii i investicii. 2020. № 6. pp. 194-197.

10. Ojala T, Pietikainen M, Maenpaa T (2002) IEEE Trans Pattern Anal Mach Intell. 24(7). pp 971–987.

Дата поступления: 18.11.2024

Дата публикации: 1.01.2025