

## Оценка эффективности метода расширения наборов данных на основе глубокого обучения с подкреплением

*Т.С. Евдокимова, М.П. Шлеймович*

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

**Аннотация:** В статье представлены результаты численного эксперимента по сравнению точности нейросетевого распознавания объектов на изображениях с применением различных типов расширения наборов данных. Описывается необходимость в расширении наборов данных с применением адаптивных подходов, с целью минимизации использования преобразований изображений, которые могут снижать точность распознавания объектов. Автор рассматривает такие подходы к расширению наборов данных, как рандомная и автоматическая аугментации, так как они являются распространенными, а также разработанный метод адаптивного расширения наборов данных при помощи алгоритма глубокого обучения с подкреплением. Приведены алгоритмы работы каждого из подходов, их преимущества и недостатки методов. Описывается работа и основные параметры разработанного метода расширения набора данных при помощи алгоритма глубокого обучения с подкреплением (Deep-Q-Network), с точки зрения алгоритма и основного модуля программного комплекса. Уделяется внимание к одному из подходов машинного обучения, а именно обучению с подкреплением. Описывается применение нейронной сети для аппроксимации Q-функции и ее обновления в процессе обучения, в основе которого лежит разрабатываемый метод. Результаты экспериментов показывают преимущество использования расширения наборов данных при помощи алгоритма обучения с подкреплением на примере модели классификации Squeezenet v1.1. Сравнение точности распознавания с использованием методов расширения наборов данных проводилось с применением одинаковых параметров нейросетевого классификатора с применением и без применения предобученных весов. Таким образом, повышение точности в сравнении с другими методами варьируется от 2,91% до 6,635%.

**Ключевые слова:** расширение наборов данных, рандомная аугментация, автоматическая аугментация, преобразования изображений, глубокое обучение с подкреплением, нейросетевой классификатор, распознавание.

### Введение

В настоящее время внедрение глубоких нейросетевых моделей в задачах классификации объектов на изображении встречается во многих сферах. Однако во многих областях осуществление распознавания с высокой точностью является затруднительным. Это может быть по многим причинам, одной из них является недостаточный и однообразный набор данных. На данный момент проблему ограниченности данных решают при помощи аугментации данных. Чаще всего используют отдельно взятые

---

преобразования (расширение, сдвиг, обрезка, поворот, отражение) изображений [1], но и существуют методы комбинирующие эти преобразования, на основе разных алгоритмов (рандомная, автоматическая аугментация и др.). При использовании таких подходов к расширению наборов данных невозможно предугадать какие из преобразований будут положительно сказываться на качество обучения нейросетевого классификатора. Поэтому есть необходимость в применении адаптивного подхода к расширению данных для задач классификации [2]. В данной работе рассматривается расширение набора данных на основе глубокого обучения с подкреплением.

### **Существующие методы расширения набора данных**

В данной работе рассмотрим три вида расширения набора данных в качестве сравнения, а именно рандомную, автоматическую аугментации и на основе глубокого обучения с подкреплением.

Рандомная аугментация относится к автоматическому типу, суть которого заключается в случайном наложении набора преобразований на изображения [3-5]. Работа данного подхода состоит из следующих шагов:

- 1) определение набора преобразований, чаще всего выбирается поворот, сдвиг, отражение, изменение яркости, контрастности, Гауссово размытие и др. При этом каждое из преобразований имеет свой диапазон настраиваемых параметров;
  - 2) настройка параметров рандомной аугментации, а именно настройки количества преобразований, накладываемых на изображения ( $N$ ), и параметр искажения преобразований (магнитуда ( $M$ ));
  - 3) наложение преобразований на изображения;
  - 4) использование преобразованных изображений в процессе обучения. Таким образом, основными параметрами в данном подходе являются  $N$  и  $M$ , которые в свою очередь необходимо подбирать в
-

зависимости от задачи и самого набора изображений. Для некоторых наборов данных стандартные значения параметров могут привести к сильному искажению изображений, что приведет к потере ключевых признаков.

Автоматическая аугментация, в свою очередь, является адаптивным подходом к расширению наборов данных, в основе которого лежит алгоритм обучения с подкреплением [6]. Основной идеей является подбор оптимальных стратегий преобразований изображений для определенного набора данных. Чаще всего используются уже существующие стратегии, которые были получены в процессе обучения на открытых наборах данных [7].

Работа алгоритма обучения с подкреплением заключается в выполнении следующих шагов:

- 1) создание большого количества случайных стратегий преобразований изображений, которые содержат в себе подстратегии, включающие, чаще всего, 2-3 типа преобразований;
- 2) осуществление оценки стратегий, а именно применение каждой из них к набору данных с последующей оценкой влияния на качество нейросетевого распознавания;
- 3) выбор наилучших стратегий – из всех рассмотренных стратегий выбираются те, что максимизируют точность нейросетевого классификатора;
- 4) применение стратегий ко всему набору данных.

Несмотря на существующие преимущества данного метода, которые заключаются в адаптивном подходе к данным и его универсальности за счет чего он применяется в различных задачах, существуют и недостатки. Для реализации автоматической аугментации необходимо иметь большой набор данных, высокие вычислительные ресурсы, а также необходимо достаточное время для процесса обучения.

## Метод расширения наборов данных на основе глубокого обучения с подкреплением

Рассматриваемый альтернативный метод адаптивного расширения данных на основе глубокого обучения с подкреплением осуществляет подбор наилучших преобразований изображений в процессе обучения нейросетевого классификатора. В качестве алгоритма используется разновидность глубокого обучения с подкреплением Deep-Q-Network (DQN) представленный на рис 1.

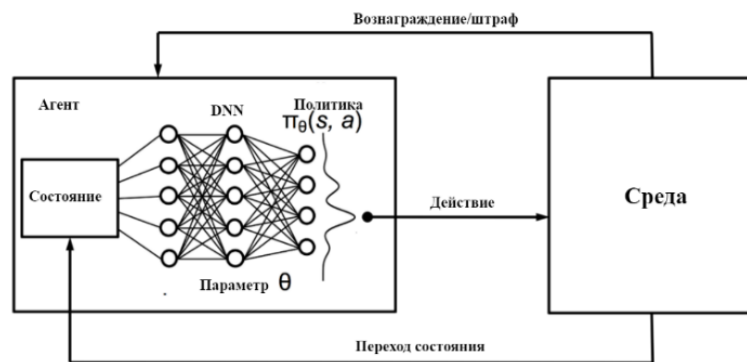


Рис.1 – Схема алгоритма глубокого обучения с подкреплением

В основе лежит классический алгоритм Q-обучения. Особенность (DQN) заключается в применении нейронной сети для аппроксимации значений Q-функции, которая в свою очередь описывает оценку состояний и действий. В процессе обучения происходит обновлений Q-значений [8,9] при помощи уравнения Беллмана:

$$Q(s, a) \leftarrow Q(s, a) + \alpha [R(s, a) + \gamma \max_{a'} (Q(s', a') - Q(s, a)),$$

где R-вознаграждение за действие a в определенном состоянии s,  $\gamma$  – коэффициент дисконтирования (параметр, отвечающий за приоритет долгосрочного или краткосрочного вознаграждения  $0 < \gamma < 1$ ), s'-переход в новое состояние,  $\alpha$ -скорость обучения.

Целью такого алгоритма является максимизация суммарного вознаграждения за полный цикл обучения.

Алгоритм расширения набора данных при помощи глубокого обучения с подкреплением содержит в себе следующую последовательность шагов:

- 1) выбор преобразований изображений в качестве действий;
- 2) определение среды, а именно набора данных и нейросетевой модели;
- 3) определение оценки вознаграждения (можно применять параметр точности классификатора) [1];
- 4) инициализация нейросетевой модели DQN, для аппроксимации Q-значений и буфера воспроизведения для сохранения приобретённого опыта;
- 5) осуществление сбора опыта на каждой итерации; агент на основании текущего состояния выбирает действие (преобразование изображений), на основе эпсилон-жадной стратегии, осуществляется переход в новое состояние и оценку вознаграждения, сохранение опыта в буфере воспроизведения;
- 6) обновление целевых Q-значений.

С точки зрения работы комплекса программ реализация расширения набора данных при помощи глубокого обучения с подкреплением решается при помощи модуля, отвечающего за выбор преобразований, применяемых к изображениям и выбора модели нейросетевой классификации.

По сравнению с рандомной и автоматической аугментациями данный метод является более адаптивным за счет получения обратной связи от нейросетевого классификатора в виде вознаграждения. С точки зрения вычислительной сложности имеет преимущество по сравнению с автоматической аугментацией, но уступает рандомной так как она не имеет адаптивного характера подбора преобразований изображений. Также из важных преимуществ это возможность динамического обучения для задач с изменяющимися условиями.

---

## Результаты численного эксперимента оценки точности с применением расширений набора данных

Для корректного сравнения рассмотренных методов необходимо провести оценку точности распознавания объектов на изображениях. В качестве модели классификации была выбрана Squeezenet v1.1, которая является легкой моделью за счет малого количества слоев, данную модель целесообразно использовать в условиях ограниченных ресурсов без глобальной потери качества распознавания модели классификатора. Эксперимент проводился на открытом многоклассовом наборе данных, а именно 5 классов при этом набор изображений в каждом классе неравный, а общее количество изображений составляет 2746 в обучающей выборке и 924 в тестовой.

Для объективной оценки будут взяты одинаковые значения параметров выбранного нейросетевого классификатора, а именно оптимизатор – Adam, функция потерь – CrossEntropyLoss [10], размер батча – 64, количество эпох – 15.

В таблице приведены результаты точности распознавания нейросетевого классификатора без применения расширения данных, автоматической аугментацией и рандомной.

Таблица

Сравнительная точность распознавания объектов на изображениях

Метод преобразования	Предобучение	Точность
Без расширения наборов данных	нет	51,97%
Рандомная аугментация	нет	57,83%
Автоматическая аугментация	нет	58,31%
Расширение наборов данных при помощи глубокого обучения с подкреплением	нет	61,74%
Без расширения наборов данных	да	79,63%
Рандомная аугментация	да	81,21%
Автоматическая аугментация	да	79,32%
Расширение наборов данных при помощи глубокого обучения с подкреплением	да	83,13%

Для рандомной аугментации наилучшие результаты были получены при использовании количества преобразований  $N=4$ , интенсивность преобразований  $M=5$ . В свою очередь, среди существующих стратегий автоматической аугментации наилучшие результаты показаны на стратегии, полученной на открытом наборе данных CIFAR [11]. Для метода расширения набора данных на основе глубокого обучения с подкреплением было выбрано 6 преобразований изображений: горизонтальное отражение, вертикальное отражение, джиттер, сдвиг, растяжение и поворот.

### **Заключение**

При сравнении трех рассмотренных методов можно сделать вывод, что применение адаптивного расширения набора данных с применением глубокого обучения с подкреплением позволяет увеличить точность по сравнению с другими методами. В сравнении с нейросетевым классификатором без расширения набора данных, повышение точности для предобученных и непредобученных весов для набора данных составляет в среднем 6,635% (3,5% и 9,77% соответственно). В сравнении с рандомной аугментацией в среднем на 2,91% (1,92% и 3,91%, соответственно). Относительно автономной аугментации повышение точности на обучающей выборке составило в среднем 3,62% (3,81% и 3,43% соответственно). Результаты показывают, что применение адаптивного подхода гарантированно повышает точность в сравнении с другими методами расширения набора данных. Однако стоит отметить, что данный подход может уступать в скорости обучения, в сравнении с рандомной аугментацией и быть менее эффективным в сравнении с автономной на открытых наборах данных, которые лежат в основе ее стратегий.

### **Литература**

1. Балеев И. А., Земцов А. Н., Зыбин М. И., Смирнов В. А. Распознавание дефектов на металлических сплавах с помощью алгоритмов компьютерного



зрения OpenCV // Инженерный вестник Дона. 2021. № 3. URL: [ivdon.ru/ru/magazine/archive/n3y2021/6874](http://ivdon.ru/ru/magazine/archive/n3y2021/6874)

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](http://ivdon.ru/ru/magazine/archive/n8y2024/9439).

3. Xiao A., Shen B., Tian J., Hu Z. Differentiable RandAugment: Learning Selecting Weights and Magnitude Distributions of Image Transformations // IEEE Transactions on Image Processing, 2023, Vol. 32, pp. 2413-2427.

4. Петрин Д. А., Гришунов С. С., Белов Ю. С. Улучшение качества моделей машинного обучения в задачах классификации изображений на основе метода аугментации данных // Известия Института инженерной физики. 2021. № 1(59). С. 56-60.

5. Евдокимова Т. С., Андреев Н. В., Фаткуллина Л. Ф. Методы расширения наборов данных на основе обучения с подкреплением // Научно-технический вестник Поволжья. 2023. № 11. С. 59-62.

6. Хакимов Р. С., Павленко Б. В., Пикалев Я. С. Обзор расширенных техник аугментации для набора данных изображений // Донецкие чтения 2024: образование, наука, инновации, культура и вызовы современности: материалы IX Международной научной конференции, 2024. С. 272-275.

7. Momeny M., Neshat A. A., Gholizadeh A. [et al.] Greedy Autoaugment for classification of mycobacterium tuberculosis image via generalized deep CNN using mixed pooling based on minimum square rough entropy // Computers in Biology and Medicine. 2022. Vol. 141. P. 105175.

8. Беляев, С. А., Коробов Д. А. Современные подходы к обучению интеллектуальных агентов в среде Atari // Программные продукты и системы. 2018. № 2. С. 284-290.



9. Жиленков А.А., Силкин А. А., Серебряков М. Ю., Колесова С. В. Сравнительный анализ систем глубокого обучения с подкреплением и систем обучения с учителем // Известия ТулГУ. Технические науки. 2022. №10. С. 109-112.

10. Апарнев А. Н., Бартенев О. В. Анализ функций потерь при обучении сверточных нейронных сетей с оптимизатором Adam для классификации изображений // Вестник Московского энергетического института. Вестник МЭИ. 2020. № 2. С. 90-105.

11. Вершков Н.А., Бабенко М.Г., Кучуков В.А., Кучукова Н.Н. Обучение многослойного перцептрона с учителем в задаче распознавания с помощью корреляционного показателя // Труды Института системного программирования РАН. 2021. №33(1). С. 33-46.

#### References

1. Baleev I. A., Zemcov A. N., Zybin M. I., Smirnov V. A. Inzhenernyj vestnik Dona. 2021. № 3. URL: [ivdon.ru/ru/magazine/archive/n3y2021/6874](http://ivdon.ru/ru/magazine/archive/n3y2021/6874)

2. Evdokimova T.S. Inzhenernyj vestnik Dona. 2024. № 8. URL: [ivdon.ru/ru/magazine/archive/n8y2024/9439](http://ivdon.ru/ru/magazine/archive/n8y2024/9439).

3. Xiao A., Shen B., Tian J., Hu Z. IEEE Transactions on Image Processing, 2023, Vol. 32, pp. 2413-2427.

4. Petrin D. A., Grishunov S. S., Belov Ju. S. Izvestija Instituta inzhenernoj fiziki. 2021. № 1(59). pp. 56-60.

5. Evdokimova T. S., Andrejanov N. V, Fatkullina L. F. Nauchno-tehnicheskij vestnik Povolzh'ja. 2023. № 11. pp. 59-62.

6. Hakimov R. S., Pavlenko B. V., Pikalev Ja. S. Doneckie chtenija 2024: obrazovanie, nauka, innovacii, kul'tura i vyzovy sovremennosti: materialy IX Mezhdunarodnoj nauchnoj konferencii, 2024. pp. 272-275.

7. Momeny M., Neshat A. A., Gholizadeh A. [et al.] Computers in Biology and Medicine. 2022. Vol. 141. p. 105175.



8. Beljaev, S. A., Korobov D. A. Programmnye produkty i sistemy. 2018. № 2. pp. 284-290.
9. Zhilenkov A.A., Silkin A. A., Serebrjakov M. Ju., Kolesova S. V. Izvestija TulGU. Tehnicheskie nauki. 2022. №10. pp. 109-112.
10. Aparnev A. N., Barten'ev O. V. Vestnik Moskovskogo jenergeticheskogo instituta. Vestnik MJeI. 2020. № 2. pp. 90-105.
11. Vershkov N.A., Babenko M.G., Kuchukov V.A., Kuchukova N.N. Trudy Instituta sistemnogo programmirovaniya RAN. 2021. №33(1). pp. 33-46.

**Дата поступления: 17.12.2024**

**Дата публикации: 27.01.2025**