

Метод и программный комплекс расширения графических наборов данных при помощи глубокого обучения с подкреплением

Т.С. Евдокимова

Аннотация—В статье описан метод расширения графических наборов данных при помощи глубокого обучения с подкреплением, позволяющий подбирать наилучшие преобразования, накладываемые на изображения из обучающего набора данных, что позволяет сократить время обучения и повысить точность распознавания классификатора. Описан каждый из этапов метода: формирование состояния – определение описания изображений посредством цветowych, контурных и текстурных свойств, выбор преобразований (действий) на основании эпсилон-жадной стратегии, обучение нейросетевого классификатора, вычисление вознаграждения агента на основании параметров обучения – точность и функция потерь, сохранение результатов обучения в буфер воспроизведения опыта и обновление модели агента. Также в статье описана структура программного комплекса, позволяющая управлять настройками метода и нейросетевого классификатора, состоящий из трех основных модулей – загрузки данных, настройки параметров и отображение результатов обучения моделей.

Ключевые слова—глубокое обучение с подкреплением, нейросетевой классификатор, состояние, агент, вознаграждение, преобразования изображений, программный комплекс, стратегия.

I. ВВЕДЕНИЕ

В настоящее время во многих областях применяются нейросетевые классификаторы. Их применение позволяет снижать ошибки, вызванные человеческим фактором. Однако обучение нейросетевых моделей является сложным и ресурсоёмким процессом. Давно известно, что объем и разнообразие данных в обучающем наборе, напрямую влияет на качество обучения моделей классификатора. Однако не всегда имеется возможность собрать такой набор изображений по различным причинам. Для решения этой проблемы используются подходы, заключающиеся в расширении имеющихся изображений при помощи различного типа преобразований (геометрические, яркостно-цветовые, вырезание фрагментов изображения, смешивание изображений) или алгоритмов, использующие эти преобразования.

Стоит отметить, что существующие подходы

расширения наборов данных мало учитывают особенности влияния отдельно взятых преобразований на качество обучения нейросетевых моделей. В данной работе рассматривается разработанный метод расширения графических наборов данных с использованием глубокого обучения с подкреплением. Этот метод позволяет отбирать из набора преобразований только те, которые будут повышать точность моделей, что приводит к сокращению времени самого обучения.

II. ОПИСАНИЕ МЕТОДА РАСШИРЕНИЯ ГРАФИЧЕСКИХ НАБОРОВ ДАННЫХ

Данный метод заключается в использовании двух нейросетевых моделей, которые взаимосвязаны друг с другом. Одна модель используется для подбора преобразований и анализа их влияния на качество обучения второй модели нейросетевого классификатора. Подбор преобразований, применяемых к изображениям, осуществляется при помощи алгоритма обучения с подкреплением [1].

В общем виде метод расширения графических наборов данных может быть описан следующими этапами:

- 1) формирование состояния. Каждое изображение из обучающего пакета данных описывается определенным набором свойств. Таким образом каждый элемент может быть описан отдельно или совместно цветовым, контурным или текстурным свойствами;
- 2) выбор действия для изображения. В качестве действия выбираются преобразования, которые относятся к геометрическим и яркостно-цветовым, так как они являются самыми распространенными. Однако можно в качестве действий выбирать преобразования, которые основаны на удалении части изображений или их смешивании. Действия выбираются согласно выбранной политики;
- 3) обучение классификатора на обучающем наборе. Каждое изображение из пакета данных поступает на вход нейросетевого классификатора для его дальнейшего обучения. После предсказания метки класса объекта на изображении вычисляется логарифмическая функция потерь;
- 4) вычисление вознаграждения. Так как в основе разработанного метода лежит подход обучения с подкреплением, одним из важных этапов является

вычисление вознаграждения, которое дает оценку за выполненное действие (преобразование) в определенном состоянии (описание изображения). В качестве вознаграждения выбираются параметры точности и функции потерь классификатора;

5) сохранение результатов обучения. В связи с тем, что используется алгоритм глубокого обучения с подкреплением Deep-Q-Network [2,3] накопление опыта сохраняется в буфере воспроизведения опыта;

6) обновление весов модели DQN. В данном подходе используются оценка текущего состояния и целевого;

7) проверка модели классификатора на валидационном наборе. На вход модели классификатора поступают исходные изображения, которые не были подвержены искажениям, посредством геометрических или яркостно-цветовых преобразований. Данный шаг позволяет оценить качество работы модели для исходных данных.

А. Формирование состояния

Как говорилось ранее в качестве состояния выбраны свойства, описывающие характеристики изображения. Такое определение состояния позволяет расширить область применения метода в задачах с разными типами изображений.

Цветовое описание изображения заключается в поканальном формировании гистограмм интенсивности [4]:

$$H_R(k) = \sum_{x=0}^{w-1} \sum_{y=0}^{h-1} \delta(I_R(x, y) - k), \quad (1.1)$$

$$H_G(k) = \sum_{x=0}^{w-1} \sum_{y=0}^{h-1} \delta(I_G(x, y) - k), \quad (1.2)$$

$$H_B(k) = \sum_{x=0}^{w-1} \sum_{y=0}^{h-1} \delta(I_B(x, y) - k), \quad (1.3)$$

где k – интенсивность, w, h – ширина и высота изображения, δ – дельта-функция Кронекера.

Также после вычисления гистограммы интенсивности необходимо осуществить нормализацию (2). Данный шаг необходим для увеличения скорости обучения модели.

$$H_{norm}(k) = \frac{H(k) - H_{min}}{H_{max} - H_{min}} \quad (2)$$

Текстурное представление изображения можно представить при помощи улучшенных бинарных локальных шаблонов. В связи с тем, что сам метод расширения графических наборов данных будет увеличивать время обучения за счет применения модели, которая осуществляет подбор наилучших преобразований, свойства изображений должны быть быстройчисляемыми. Улучшенные локальные шаблоны позволяют определить локальные особенности на изображении. Вычисление бинарных локальных шаблонов происходит в несколько этапов:

1) вычисление локальной области для каждого пикселя изображения, центральный пиксель будет иметь координаты (x_c, y_c) , а соседние пиксели (x_i, y_i) ;

2) далее необходимо провести сравнение интенсивности каждого соседнего пикселя $I(x_i, y_i)$ относительно центрального [5]:

$$s(x_i, y_i) = \begin{cases} 1, & I(x_i, y_i) \geq I(x_c, y_c), \\ 0, & I(x_i, y_i) < I(x_c, y_c); \end{cases} \quad (3)$$

3) бинарное число вычисляется на основании объединения бинарного значения $s(x_i, y_i)$:

$$LBP(x_c, y_c) = \sum_{i=0}^n s(x_i, y_i) \cdot 2^i. \quad (4)$$

Еще одним видом представления состояния является информация о границах объекта на изображении.

Информация о контурах может быть представлена при помощи гистограммы ориентированных градиентов [6]:

$$H_c(k) = \sum_{i,j \in c} G(i, j) \cdot I[\theta(i, j)] \in k, \quad (5)$$

где $G(i, j) = \sqrt{(I * S_i)^2 + (I * S_j)^2}$ (I – исходное изображение, S_i, S_j – фильтры Собеля по осям x, y) – величина градиента, $\theta = \arctan(G_j/G_i)$ – направление градиента.

Данный вид контурного представления, выбраны на основании таких преимуществ как компактность представления, простота и скорость вычисления.

Еще одним описанием изображения является метка класса (κ) объекта, которая в данном методе формируется при помощи представления категориальных данных в виде бинарных векторов.

Рассмотренные представления помогут лучше выявлять зависимость состояния и действия. Таким образом полное описание состояния изображения имеет следующий вид:

$$s_t = \{H_{R\ norm}, H_{G\ norm}, H_{B\ norm}, HOG, LBP, \kappa\}. \quad (6)$$

В. Выбор действия (преобразования изображения)

В качестве агента, осуществляющего подбор наиболее подходящих преобразований является сверточная нейронная сеть, на вход которой поступает информация о текущем состоянии, на выходе этой сети дается оценка каждого действия из набора преобразований изображений. Применение действия осуществляется на основании выбранной стратегии - ϵ -жадной [7]. Суть которой заключается в постепенном исследовании и дальнейшей эксплуатации.

$$a_t = \begin{cases} \xi, & \text{с вероятностью } \epsilon \\ \arg \max_a Q(s_t, a), & \text{с вероятностью } 1 - \epsilon \end{cases} \quad (7)$$

Далее выбранное преобразование a_t на основании стратегии накладывается на исходное изображение (x_i) :

$$x'_i = a_t(x_i). \quad (8)$$

С. Обучение модели классификатора

На данном этапе преобразованное изображение поступает на вход нейросетевого классификатора, который в свою очередь предсказывает класс объекта на текущем изображении. После предсказания вычисляется расхождение между вероятностными распределениями при помощи логарифмической функции потерь для многоклассового набора данных [8]:

$$L = -\frac{1}{N} \sum_{i=1}^N \sum_{j=1}^k t_{i,j} \log(p_{i,j}), \quad (9)$$

где N – количество наблюдений, k – количество классов, $t_{i,j}$ – бинарный (0,1) индикатор, отражающий

принадлежность классу, $p_{i,j}$ — предсказанная вероятность.

На следующем шаге этого этапа происходит обновление весов модели при помощи градиентного спуска.

D. Вычисление вознаграждения агента

Так как разработанный метод направлен на подбор наилучших преобразований, применяемых к изображениям из обучающего набора в качестве параметров оценки выбранного действия для вычисления вознаграждения выбраны значения функции потерь и точности:

$$r_i = \omega_1 \cdot \Delta L + \omega_2 \cdot \Delta A, \quad (10)$$

где $\Delta L = L_{i-1} - L_i$ вычисление улучшения функции потерь, $\Delta A = A_i - A_{i+1}$, ω_1 и ω_2 — весовые коэффициенты. Вычисление параметров производится только на результатах, получаемых во время обучения нейросетевого классификатора.

E. Сохранение результатов обучения

Опыт, полученный агентом в результате наложения преобразований на изображения, сохраняется в буфер воспроизведения опыта [9]. В данном случае сохраняется информация о текущем состоянии, действии и вознаграждении, которые представляют собой кортеж этих значений:

$$O = \{(s_1, a_1, r_1), (s_2, a_2, r_2), \dots, (s_n, a_n, r_n)\}. \quad (11)$$

Буфер воспроизведения опыта предназначен для выполнения последующих действий на основании уже приобретенного опыта, это позволит сделать обучение агента более стабильным за счет усреднения распределения прошлых состояний на основании вычисления Q-значений.

В данном методе используется Prioritized Experience Replay Buffer [10], так как он позволяет выбирать приоритетные кортежи. Приоритетность определяется при помощи вычисления ошибки предсказания. Таким образом наибольшую пользу будет иметь кортеж с наибольшим значением ошибки.

F. Обновление модели агента

Обновление модели агента заключается в вычислении разницы между целевыми и текущими оценками, которые зависят от состояния и действия при помощи функции потерь:

$$\delta_i = Q(s_i, a_i) - Q_t, \quad (12)$$

где $Q(s_i, a_i)$ — текущая оценка для состояния и выполненного действия Q_t — целевое значение, которое вычисляется при помощи уравнения Беллмана: $r + \gamma \max_{a'} (Q(s', a'))$. Таким образом целью агента является минимизация этой вычисляемой разницы.

G. Оценка расширения графических наборов данных

Итоговым шагом является проверка работы модели классификатора на валидационных данных. Нужно отметить, что эти данные не подвергаются преобразованиям, для того чтобы провести оценку на реальных данных. Также результаты обучения не

используются для вычисления вознаграждения для агента.

III. Структура программного комплекса расширения графических наборов данных

Программный комплекс разработанного метода заключается в настройке глобальных параметров обучения классификатора и расширения наборов данных. Таким образом он состоит из трех взаимосвязанных модулей:

1) Загрузка данных на данном этапе производится выбор данных для обучения и разбиение их на обучающую и валидационную выборки. Данный модуль является стандартным этапом в процессе обучения моделей для нейросетевого распознавания.

Рис.1. Форма модуля загрузки данных

2) Настройка параметров и запуск обучения моделей. В данном модуле необходимо дать описание исходному набору данных, а точнее определить какими состояниями будут описываться изображения. Гистограммы интенсивности подходят для цветового и яркостного описания изображений, гистограммы ориентированных градиентов лучше подойдут для задач, где важны формы и контуры объектов, локальные бинарные шаблоны позволят дать больше информации об объектах на изображениях, имеющих структуру. Стоит отметить, что описание изображений может содержать несколько свойств.

Еще одним из параметров является набор действий, который будет применяться к изображениям из обучающего набора. Данный шаг необходим для отсеивания преобразований, которые объективно могут изменить ключевые признаки или значения объектов.

Также в этом модуле производится загрузка нейросетевых моделей разных архитектур, данный функционал обусловлен задачей и условиями использования. А также можно выбрать свойство предобученности этих моделей, это необходимо в задачах, где данные специфичны и выгоднее обучить

модель с нуля. После настройки параметров происходит запуск обучения моделей.

Основные свойства данных	Выбор преобразований	Параметры классификатора
☐ Цвет ☒ Контурсы ☐ Текстура	☒ Горизонтальный отрез ☒ Вертикальный отрез ☒ Сдвиг ☐ Поворот ☐ Обрезка ☒ Наложение Гауссова ☒ Размытие ☒ Джиттер	Выбор модели классификатора ResNet-18 Использовать предобученные веса ☐ Нет ☒ Да Введите количество эпох обучения 18

Рис.2. Форма модуля настройки параметров для обучения моделей

3) Контроль обучения моделей. По завершению обучения в данном модуле (рис.3) реализована возможность просмотра информации о полученных результатах нейросетевого классификатора в виде численного (табличное) и графического представления (рис.4) с возможностью загрузки. Также для оценки наилучших преобразований, которые применялись к исходному обучающему набору данных выводится информация о типе преобразования и среднего вознаграждения для каждого из классов набора данных, которое было получено агентом в процессе полного цикла обучения.

C:\Users\Desktop\358361-blackangel.jpg

Выберите файл для распознавания

Распознать

Класс объекта

daisy

Просмотр лучших преобразований

Просмотр графиков обучения модели классификатора

Рис.3. Форма контроля обучения моделей




Рис.4. Форма графического представления результатов обучения нейросетевого классификатора

<i>Наилучшие преобразования</i>		
Класс	Награда	Преобразование
1) daisy	1,4523	Растяжение
2) dandelion	1,6740	Горизонтальное отражение
3) rose	1,3801	Сдвиг
4) sunflower	1,7091	Джиттер
5) tulip	1,4488	Горизонтальное отражение

[Скачать](#)

Рис.5. Форма с представлением наилучших преобразований для каждого класса из обучающего набора

IV. ЗАКЛЮЧЕНИЕ

Описанный в статье метод может применяться, как один из способов повышения точности распознавания при помощи нейросетевых моделей. Разработанный метод целесообразнее использовать в задачах с малым набором исходных данных.

В зависимости от набора данных метод расширения графических наборов данных позволяет сократить время обучения от 6% до 30% относительно времени обучения нейросетевого классификатора без применения расширения данных. Сравнивая значения одинакового количества эпох повышение точности за счет разработанного метода позволяют получить преимущество от 2% до 11%. Разброс показателей зависит от набора данных, используемых архитектур моделей и их настройки. Программный комплекс в свою очередь позволяет пользователю реализовать первичную настройку и запуск обучения нейросетевых моделей.

БИБЛИОГРАФИЯ

- [1] Т. С. Евдокимова. Влияние методов расширения наборов данных на качество обучения нейросетевых моделей. Адаптивный подход расширения наборов данных // Инженерный вестник Дона. 2024. № 8(116). С. 282-290.
- [2] Nakamura T., Kobayashi M., Motoi N. Path Planning for Mobile Robot Considering Turnabouts on Narrow Road by Deep Q-Network // IEEE Access. 2023. Vol. 11. pp. 19111-19121. – DOI 10.1109/access.2023.3247730.
- [3] M. Sewak, Deep q network (dqn), double dqn, and dueling dqn, in DeepReinforcement Learning. Springer, 2019, pp. 95–108.
- [4] Черешнев В.О., Фролов С.В., Проскурин С.Г. Построение структурных ОКТ изображений на основе гистограммы распределения интенсивности пикселей// IX Международная конференция по фотонике и информационной оптике: Сборник научных трудов, Москва, 29–31 января 2020 года. Москва: Национальный исследовательский ядерный университет "МИФИ", 2020. С. 631-632.
- [5] Голиков Н.С. Применение локальных бинарных шаблонов в задаче распознавания эмоций // Вестник науки №5 (62) том 4. С. 1191 - 1199. 2023 г.
- [6] Ярошевич П.В., Богуш П.Р. Алгоритм классификации изображений парковочных мест автостоянки на основе гистограмм ориентированных

- градиентов и метода опорных векторов // Компьютерная оптика. 2017. Т. 41, № 1. С. 110-117. – DOI 10.18287/2412-6179-2017-41-1-110-117.
- [7] Чесноков С.Е. Эволюционные стратегии в машинном обучении // Труды Поволжского государственного технологического университета. Серия: Технологическая. 2024. № 12. С. 42-51
- [8] Mao A, Mohri M, Zhong Y Cross-entropy loss functions: Theoretical analysis and applications. arXiv preprint arXiv:2304.07288.<https://doi.org/10.48550/arXiv.2304.07288>
- [9] Дубенко, Ю.В. (2022) Метод повторного использования и обмена опытом при коллективном взаимодействии интеллектуальных агентов // Вестник Воронежского государственного технического университета, 1, 62–72, <https://doi.org/10.36622/vstu.2022.18.1.007>
- [10] Schaul T, Quan J, Antonoglou I, Silver D. 2015. Prioritized experience replay. ArXiv DOI 10.48550/arXiv.1511.05952

A method and software package for expanding graphical datasets using deep reinforcement learning

T.S. Evdokimova

Abstract—the article describes a method for expanding graphical datasets using deep reinforcement learning, which allows selecting the best transformations applied to images from the training dataset, which reduces training time and improves the accuracy of classifier recognition. Each of the stages of the method is described: state formation – definition of image descriptions through color, contour and texture properties, selection of transformations (actions) based on an epsilon-greedy strategy, training of a neural network classifier, calculation of agent remuneration based on learning parameters-accuracy and loss function, saving learning results to an experience buffer and updating the agent model. The article also describes the structure of the software package that allows you to manage the settings of the method and the neural network classifier, consisting of three main modules – data loading, parameter settings and displaying the results of model training.

Keywords—deep reinforcement learning, neural network classifier, state, agent, reward, image transformations, software package, strategy.

REFERENCES

- [1] T. S. Evdokimova The influence of data set expansion methods on the quality of training neural network models. An adaptive approach to expanding data sets // Engineering Bulletin of the Don. 2024. No. 8(116). pp. 282-290.
- [2] Nakamura T., Kobayashi M., Motoi N. planificarea căii pentru robotul mobil luând în considerare virajele pe drumul îngust prin rețeaua Q profundă // accesul IEEE. 2023. Vol. 11. 19111-19121. - DOI 10.1109 / acces.2023.3247730
- [3] M. Sewak, Deep Q network (dqn), double dqn ai dueling dqn, în învățarea DeepReinforcement. Springer, 2019, p.95-108.
- [4] Chereshevnev V.O., Frolov S.V., Proskurin S.G. Constructing structural OCT images based on a histogram of pixel intensity distribution// IX International Conference on Photonics and Information Optics: Collection of Scientific Papers, Moscow, January 29-31, 2020. Moscow: National Research Nuclear University "MEPhI", 2020. pp. 631-632.
- [5] Golikov N.S. Application of local binary patterns in the problem of emotion recognition // Bulletin of Science No. 5 (62) volume 4. pp. 1191 - 1199. 2023
- [6] Yaroshevich P.V., Bogush P.R. An algorithm for classifying images of parking spaces based on histograms of oriented gradients and the method of support vectors // Computer Optics. 2017. Vol. 41, No. 1. pp. 110-117. - DOI 10.18287 / 2412-6179-2017-41-1-110-117.
- [7] Chesnokov S.E. Evolutionary strategies in machine learning // Proceedings of the Volga State Technological University. Series: Technological. 2024. No. 12. pp. 42-51
- [8] Mao a, Mohri M, Zhong y funcții de pierdere a entropiei încrucișate: analiză teoretică și aplicații. arXiv preimprimare arXiv: 2304.07288. <https://doi.org/10.48550/arXiv.2304.07288>
- [9] Dubenko, Yu.V. (2022) Regatul Unit // Regatul Unit, 1, 62-72, <https://doi.org/10.36622/vstu.2022.18.1.007>
- [10] Schaul T, Quan J, Antonoglou I, Argint D. 2015. Reluarea experienței prioritare. ArXiv DOI 10.48550 / arXiv.1511.05952