

УДК 004.932

ВЛИЯНИЕ МЕТОДОВ ПРЕДОБРАБОТКИ ИЗОБРАЖЕНИЙ В ЗАДАЧЕ ОБНАРУЖЕНИЯ И РАСПОЗНАВАНИЯ ОБЪЕКТОВ НА ЦИФРОВЫХ ИЗОБРАЖЕНИЯХ

© Должиков Д.П.

*Самарский национальный исследовательский университет
имени академика С.П. Королева, г. Самара, Российская Федерация*

e-mail: dmdolzhikov@gmail.com

*Научный руководитель: Савельев Д.А., канд. физ.-мат. наук, доцент
Самарский национальный исследовательский университет
имени академика С.П. Королева, г. Самара, Российская Федерация*

Ключевые слова: предобработка изображений, распознавание объектов, обнаружение объектов.

Предобработка изображений является критически важным этапом в процессе обнаружения и распознавания объектов с использованием нейронных сетей. Качественная предобработка может значительно повысить точность распознавания, особенно при неблагоприятных условиях съемки, таких как туман, низкая освещенность, дождь, снег, а также при работе с изображениями низкого качества [1]. Данная работа направлена на исследование влияния различных методов предобработки изображений на точность работы нейронной сети YOLOv1 [2].

В рамках исследования были рассмотрены следующие методы предобработки изображений:

1. Снижение шума – применение фильтров (Гауссово размытие, медианный фильтр) для устранения нежелательных помех [3].
2. Усиление краев – использование фильтров повышения резкости для выделения границ объектов [4–5].
3. Преобразование цветового пространства – перевод изображений из RGB в другие цветовые пространства с применением цветовых преобразований.
4. Выравнивание гистограммы – улучшение контраста изображения путем перераспределения интенсивностей пикселей [6].

Базовая модель YOLOv1 использовала стандартную предобработку: изменение размера до 448×448 пикселей и нормализацию значений пикселей. Данные методы играют первостепенную роль в повышении как скорости, так и точности распознавания [7]. Для оценки эффективности применялась метрика mAP (mean Average Precision). Метрика вычислялась по следующей формуле:

$$mAP = \frac{1}{N} \sum_{n=1}^N AP(n), \quad (1)$$

где N – общее количество классов, $AP(n)$ – Average Precision для класса n .

AP рассчитывается как взвешенная сумма precision на каждом уровне recall:

$$AP_n = \sum_{k=0}^{q-1} (R_k - R_{k+1}) \times P_k, \quad (2)$$

где R_k – значение recall на k -м пороге, P_k – значение precision на k -м пороге, q общее количество порогов.

Обучение моделей проводилось до 170 эпох для каждого метода предобработки. Базовая модель обучалась до 230 эпох и достигла максимального значения mAP 0,0902 на тестовой выборке. Подробнее результаты представлены в таблице.

Таблица – Результаты исследования влияния методов предобработки изображений

Метод предобработки	Максимальное mAP	Эпоха	Изменение относительно базовой модели
Базовая модель	0,0902	160	-
Снижение шума	0,0888	160	-1,55%
Усиление краев	0,0889	150	-1,44%
Преобразование цветового пространства	0,1018	150	+12,86%
Выравнивание гистограммы	0,0414	150	-54,10%

Как видно из таблицы, наилучшие результаты на наборе данных PascalVOC показал метод преобразования цветового пространства, обеспечивающий увеличение метрики mAP на 12,86 %. Методы снижения шума и усиления краев показали незначительное точности (1,55 и 1,44 % соответственно). Метод выравнивания гистограммы показал наихудшие результаты со снижением значения метрики на 54,10%. Это указывает на неприменимость метода выравнивания гистограммы в качестве единственного способа предобработки изображений для архитектуры YOLOv1. На рисунках 1–2 можно наблюдать графики сходимости метрики mAP.



Рисунок 1 – Сходимость метрики mAP у базовой модели




Рисунок 2 – Сходимость метрики mAP с применением предобработки изображений

Исследование продемонстрировало значительное влияние методов предобработки изображений на эффективность нейронной сети YOLOv1. Метод преобразования цветного пространства оказался наиболее эффективным, обеспечив существенное улучшение точности распознавания объектов.

Библиографический список

1. Ogino, Y. ERUP-YOLO: Enhancing Object Detection Robustness for Adverse Weather Condition by Unified Image-Adaptive Processing / Y.Ogino, Y. Shoji, T. Toizumi, A. Ito // ArXiv, Cornell University. – 2024.
2. Redmon, J. You Only Look Once: Unified, Real-Time Object Detection / J. Redmon, S. Divvala, R. Girshick, A. Farhadi // Proceedings of the IEEE conference on computer vision and pattern recognition. – Las Vegas: CVPR, 2016. – P. 779–788.
3. Rodríguez-Rodríguez, J.A. The Impact of Noise and Brightness on Object Detection Methods / J.A. Rodríguez-Rodríguez, E. López-Rubio, J.A. Ángel-Ruiz, M.A. Molina-Cabello // Sensors. – 2024. – Vol. 24 (3). – P. 821.
4. Wang, T.-s Contrast Enhancement-Based Preprocessing Process to Improve Deep Learning Object Task Performance and Results / T.-s Wang, G.T. Kim, M. Kim, J. Jang // Applied Sciences. – 2023. – Vol. 13 (19). – P. 10760.
5. Malche, T. Edge Detection in Image Processing: An Introduction / T. Malche // Roboflow Blog. – 2024.
6. Campos, G. Machine learning hyperparameter selection for Contrast Limited Adaptive Histogram Equalization / G. Campos, S. Mastelini, G. Aguiar [et al.] // EURASIP Journal on Image and Video Processing. – 2019. – Vol. 59.
7. Shahriar, M.T. A Study of Image Pre-processing for Faster Object Recognition / Md Tanzil Shahriar, Huyue Li // ArXiv / Cornell University. – 2020.