

ОБЛЕГЧЕННАЯ МОДЕЛЬ ПРЕДВАРИТЕЛЬНОЙ ОБРАБОТКИ ИЗОБРАЖЕНИЙ ДЛЯ УЛУЧШЕНИЯ ОБНАРУЖЕНИЯ МАЛЫХ ОБЪЕКТОВ

Назаренко А.А.¹

Научный руководитель – к.ф.-м.н., доцент ВШЦК, Михайлова Е.Г.¹

¹Университет ИТМО

aanazarenko@itmo.ru

Работа выполнена в рамках темы НИР № 640113 «AI Proctor – автоматизированная система прокторинга на основе методов искусственного интеллекта».

Введение

Задача обнаружения малых объектов на изображениях остается одной из наиболее сложных в компьютерном зрении, особенно в условиях неблагоприятной визуальной среды. В микроскопических сценах с живыми, нефиксированными и неокрашенными образцами возникают размытие границ, низкий контраст, шум и нестабильность освещения, что существенно снижает точность детекторов [10, 15]. Большинство существующих подходов к улучшению изображений используют тяжеловесные end-to-end модели [4, 10, 17], которые могут порождать нежелательные искажения и артефакты, что критично при анализе микроскопических данных. Альтернативой являются легковесные и гибридные методы с использованием параметризованных фильтров [3, 8, 16], обеспечивающие контролируемость преобразований и меньшую вычислительную сложность.

Современные детекторы объектов – одноэтапные (YOLOv8, RetinaNet, SSD), двухэтапные (Faster R-CNN, Cascade R-CNN), keypoint-ориентированные (CenterNet, CornerNet) и трансформерные (DETR) – демонстрируют высокую эффективность в общем случае [1, 2, 6, 11, 12, 14, 16], однако испытывают затруднения при обнаружении малых объектов вследствие масштабирования признаков и потери локальных деталей. В условиях промышленного применения дополнительным требованием является вычислительная эффективность и возможность работы на ограниченных ресурсах.

Основная часть

Предложена облегченная комбинированная модель предварительной обработки изображений, предназначенная для повышения качества обнаружения малых объектов в микроскопических сценах. Подход основан на предсказании параметров дифференцируемых фильтров с последующим их применением к исходному изображению без генерации нового изображения нейросетью, что позволяет избежать структурных искажений сцены [8, 12].

Архитектура модуля предварительной обработки включает легковесный сверточный энкодер (3 сверточных слоя и 2 полносвязных слоя) с общим числом обучаемых параметров около 47 тыс. Энкодер предсказывает параметры для набора корректирующих преобразований: экспозиции [5, 8], контраста и резкости. Итоговое изображение формируется путем суммирования исходного изображения и результатов применения фильтров. Такой подход минимизирует появление цветовых и текстурных артефактов по сравнению с генеративными моделями улучшения изображений [4, 7, 11].

Обучение модуля предварительной обработки выполнялось в постановке восстановления исходных кадров из их «мягко деградированных» версий, полученных с использованием контролируемых аугментаций (изменение экспозиции, контраста, размытие, добавление шума и др.).

Для оценки влияния предварительной обработки на задачу обнаружения были использованы восемь детекторов различных типов: YOLOv8 [11], RetinaNet [14], SSD

[16], Faster R-CNN [13], Cascade R-CNN [1], CenterNet [6], CornerNet [12] и DETR [2, 9]. Эксперименты проводились на датасете MMODD [3], содержащем около 2730 микроскопических изображений с объектами размером от 5×5 до 60×60 пикселей.

Результаты показали, что использование предложенного модуля предварительной обработки стабильно повышает качество обнаружения для всех протестированных архитектур. Наилучшие показатели достигнуты при совместном использовании фильтров экспозиции, контраста и резкости: mAP = 0.9245, mIoU = 0.7789, mDice = 0.9034.

По сравнению с моделями без этапа предварительной обработки прирост качества является существенным, что подтверждает эффективность предложенного подхода именно для задачи обнаружения малых объектов.

Выводы

Разработана облегченная модель предварительной обработки изображений, ориентированная на улучшение качества обнаружения малых объектов в сложных микроскопических сценах. Предложенный подход сочетает вычислительную эффективность, отсутствие структурных искажений и стабильный прирост метрик обнаружения. Модель содержит около 47 тыс. обучаемых параметров и может применяться в условиях ограниченных вычислительных ресурсов, что делает её перспективной для промышленного и прикладного использования.

Литература

1. Cai Z., Vasconcelos N. Cascade R-CNN: Delving into high quality object detection // CVPR. 2018.
2. Carion N. et al. End-to-end object detection with transformers // ECCV. 2020.
3. Chai Y., Giryas R., Wolf L. Supervised and unsupervised learning of parameterized color enhancement // WACV. 2020.
4. Chen Y.-S. et al. Deep photo enhancer: Unpaired learning for image enhancement from photographs with GANs // CVPR. 2018.
5. Duan K. et al. CenterNet: Keypoint triplets for object detection // ICCV. 2019.
6. Hu Y. et al. Exposure: A white-box photo post-processing framework // ACM TOG. 2018.
7. Jocher G. et al. Ultralytics YOLOv8. 2023.
8. Law H., Deng J. CornerNet: Detecting objects as paired keypoints // ECCV. 2018.
9. Lin T.-Y. et al. Focal loss for dense object detection // ICCV. 2017.
10. Liu W. et al. SSD: Single shot multibox detector // ECCV. 2016.
11. Nguyen L.D. et al. Deep CNNs for microscopic image classification // ISCAS. 2018.
12. Ren S. et al. Faster R-CNN: Towards real-time object detection // NeurIPS. 2015.
13. Samarin A. et al. Microscopy Microorganisms Object Detection Dataset (MMODD). 2024.
14. Shan C. et al. A coarse-to-fine framework for learned color enhancement with non-local attention // ICIP. 2019.
15. Tatanov O., Samarin A. LFIEM: Lightweight filter-based image enhancement model // ICPR. 2021.
16. Xing F. et al. Deep learning in microscopy image analysis: A survey // IEEE TNNLS. 2018.
17. Zamir S.W. et al. Learning enriched features for fast image restoration and enhancement // TPAMI. 2022.