

Полуавтоматическая разметка одноклассовых изображений с применением нейросетевой модели обнаружения объектов

В.Н. Гридин
Центр информационных технологий
в проектировании РАН
Одинцово, Россия
info@ditc.ras.ru

И.А. Новиков
Центр информационных технологий
в проектировании РАН
Одинцово, Россия
i.novikov@niigb.ru

Б.Р. Салем
Центр информационных технологий
в проектировании РАН
Одинцово, Россия
isub97@gmail.com

В.И. Солодовников
Центр информационных технологий
в проектировании РАН
Одинцово, Россия
vovka_online@mail.ru

Аннотация— В результате резкого роста популярности ресурсозатратных методов искусственного интеллекта возникает серьезная проблема предварительной подготовки данных для эффективного обучения моделей на основе сверточных нейронных сетей. Авторами представлен подход, построенный по принципу итеративного обновления обучающей выборки с применением нейросетевой модели YOLO для обнаружения областей интереса, выделения объектов и автоматизации процесса разметки исходных изображений. Предлагаемый подход был апробирован с различными конфигурациями модели для разметки бактерий на изображениях, полученных с помощью сканирующего электронного микроскопа, и в среднем продемонстрировал показатели точности ~90% в процессе обработки набора данных с увеличением исходной обучающей выборки в 1.75 раз.

Ключевые слова— компьютерное зрение, машинное обучение, обнаружение объектов, разметка данных, предобработка данных.

1. ВВЕДЕНИЕ

Разработки и достижения в области компьютерного зрения и машинного обучения позволили создать основу для апробации и внедрения широкого спектра новых алгоритмических и программных средств для решения прикладных задач в различных предметных областях [1][2][3]. В настоящее время создано множество современных методов нахождения объектов на основе нейронных сетей, что позволяет автоматизировать процесс распознавания образов на изображениях и видео. Однако применение нейросетевого подхода осложняется необходимостью решения задачи предварительной разметки исходных изображений для создания обучающей выборки, причем на дальнейший результат влияет, как объем выборки, так и качество выделения областей интереса. Увеличение числа тренировочных примеров положительно сказывается на точности обнаружения и сегментации объектов [4]. Необходимое количество образцов для обучения является субъективным параметром и варьируется в зависимости от решаемой задачи, специфики исходных данных, характеристик используемой нейросетевой модели. С целью исключения ошибок и улучшения

точности выделения границ объектов процесс первоначальной разметки зачастую выполняется вручную специалистом в исследуемой предметной области и требует значительных временных затрат. В данной работе предложен подход, способный повысить производительность процесса разметки изображений с одним классом объектов при создании обучающей выборки.

2. ИСХОДНЫЕ ДАННЫЕ

Для разметки были выбраны 450 изображений, полученных с помощью сканирующего электронного микроскопа, разрешением 1024x768 с микроорганизмами различного рода. Основной целью являлось выделение областей с бактериями на исходном изображении для дальнейшего использования в обучении нейросетевой модели посредством итеративного пополнения набора тренировочных данных. На первом этапе было решено использовать изображения с наличием одного рода бактерий, что позволило создать первоначальную эталонную базу тренировочных данных. Обучающая выборка исходных изображений была сокращена до 10% от исходной с разделением в пропорции 70/30 на тренировочную и валидационную соответственно.

3. ОПИСАНИЕ ПОДХОДА

В рамках предлагаемого подхода была рассмотрена предварительная разметка изображений с минимальным количеством тренировочных изображений. Основной мотивацией работы являлась минимизация времени разметки тренировочных данных с большим количеством объектов на одиночном изображении. Важной особенностью является возможность промежуточного контроля выделенных областей интереса экспертом в предметной области для корректировки возможных ошибок и улучшения точности выделения границ объектов. В процессе предварительного прототипирования метода автоматизированной разметки все обнаруженные микроорганизмы на изображениях были отмечены как

представители одного домена “бактерии”, тогда как всевозможные небактериологические включения, артефакты, элементы слизистой и т.д. относились к элементам внешнего фона подстилающей поверхности.

На первом этапе на вход модели обнаружения объектов подавались размеченные вручную изображения бактерий. Эти входные данные считались эталонными и составляли обучающую выборку. Тренировка модели осуществлялась на представителях различных родов бактерий, что позволяет составить усредненную карту признаков и в дальнейшем дает возможность находить бактерий иных родов без дополнительного обучения на их представителях. Данный подход схематически изображен на рисунке 1.

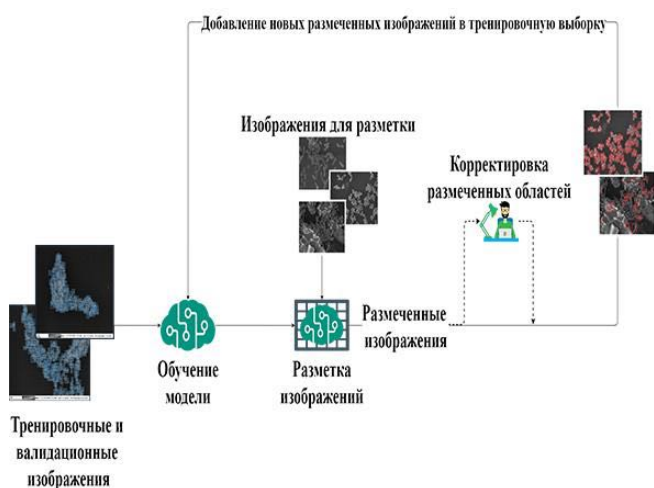


Рис. 1. Общая схема авторазметки одноклассовых изображений

4. ТЕСТИРОВАНИЕ ПОДХОДА

Предлагаемый подход был апробирован с использованием 3 различных сценариев работы модели Yolo:

- модель 1 (M1) обучена на основе Yolov5l с 50 вручную размеченными изображениями;
- модель 2 (M2) обучена на основе Yolov5l с 87 изображениями, размеченными, как вручную – 50, так и автоматически моделью M1 – 37,
- модель 3 (M3) дообучена на основе модели M1 с 87 изображениями (50 размечены вручную, 37 размечены предыдущей моделью M1).

5. ЗАКЛЮЧЕНИЕ

Анализ работы предлагаемого подхода автоматизированной разметки и сравнение результатов обучения нейросетевых моделей на вновь полученной расширенной выборке с исходной моделью, обученной на основе вручную размеченных примеров,

продемонстрировал схожие результаты по метрикам оценки качества нахождения объектов, но позволил увеличить объем данных, доступных для последующего использования. В качестве инструментария для обнаружения микробиологических объектов была выбрана модель YOLO v5, однако стоит отметить, что данный подход может быть применен в рамках большинства сверточных нейронных сетей. Осуществлена оценка различных конфигураций выбранной нейросетевой модели, что позволило подобрать наиболее подходящий инструментарий для рассматриваемого подхода. Впоследствии полученные размеченные изображения будут являться входными данными для обучения моделей классификаторов микробиологических объектов. Более того, полученный в ходе исследований подход может быть использован в широком спектре задач, включающих в себя разметку одноклассовых изображений.

Полученные модели были оценены на основе метрик Точность, Полнота, mAP (mean average precision)[4] с областью пересечения 0.5 и [0.5-0.95].

Результаты сравнения трёх вышеуказанных моделей представлены в таблице 1.

Таблица 1. СРАВНЕНИЕ МОДЕЛЕЙ

| Метрики качества модели | Модели | | |
|-------------------------|---------------|---------------|---------------|
| | Модель 1 (M1) | Модель 2 (M2) | Модель 3 (M3) |
| Точность | 0.883 | 0.909 | 0.911 |
| Полнота | 0.869 | 0.809 | 0.817 |
| mAP 0.5 | 0.896 | 0.889 | 0.888 |
| mAP_0.5:0.95 | 0.542 | 0.555 | 0.552 |

БЛАГОДАРНОСТИ

Работа выполняется в рамках темы № FFSM-2019-0001.

ЛИТЕРАТУРА

- [1] Andriyanov, N.A. Detection of objects in the images: From likelihood relationships towards scalable and efficient neural networks / N.A. Andriyanov, V.E. Dementiev, A.G. Tashlinskiy // Computer Optics. – 2022. – Vol. 46(1). – P. 139-159. DOI: 10.18287/2412-6179-CO-922.
- [2] Kalinina, M.O. Book spine recognition with the use of deep neural networks / M.O. Kalinina, P.L. Nikolaev // Computer Optics. – 2020. – Vol. 44(6). – P. 968-977. DOI: 10.18287/2412-6179-CO-731.
- [3] Gridin, V.N. Predictive data analysis subsystem for patients with subjective and subtle cognitive impairment / V.N. Gridin, B.R. Salem, V.I. Solodovnikov // International Conference on Information Technology and Nanotechnology (ITNT). – 2021. – P. 1-4. DOI: 10.1109/ITNT52450.2021.9649288.
- [4] Liu, L. Mean Average Precision / L. Liu, M.T. Özsu // Encyclopedia of Database Systems. – Boston, MA: Springer US, 2009. – P. 1703-1703.