

НЕЙРОСЕТЕВАЯ МОДЕЛЬ ДЛЯ ПОДСЧЁТА КОЛИЧЕСТВА ВИШНЁВОЙ МУХИ (RHAGOLETIS CERASI) НА КОНТРОЛЬНЫХ ЛОВЧИХ ЛИСТАХ

Ёвженко Юрий Дмитриевич*

студент 4 года обучения

Гомельский государственный технический университет имени П.О. Сухого,
Республика Беларусь, г. Гомель
E-mail: yuevzhenko@gmail.com

Куручка Константин Сергеевич

кандидат технических наук,

заведующий кафедрой информационных технологий

Гомельский государственный технический университет имени П.О. Сухого,
Республика Беларусь, г. Гомель
E-mail: kurochka@gstu.by

В данной работе предлагается подход к обнаружению и распознаванию насекомых основанный на трансферном обучении модели YOLOv8n. Для переобучения модели используется набор данных, содержащий шесть классов определяемых объектов.

Полученные результаты свидетельствуют о том, что используемая модель достигает средней точности равной 88,89 %. Исследование показало, что предложенная модель может использоваться для выявления вредителей сельскохозяйственных культур на фотографиях контрольных ловчих листов.

Ключевые слова: нейронные сети, обнаружение насекомых, классификация насекомых, компьютерное зрение, машинное обучение

Введение. Защита посевов и урожая – одна из самых дорогостоящих практик в сельском хозяйстве, часто связанная с неправильными стратегиями, а также с невозможностью однозначно распознать и предотвратить серьёзные случаи поражения вредителями. Борьба с вредителями направлена на обеспечение устойчивых и эффективных программ защиты растений, основанных на адекватных стратегиях уничтожения вредителей. Одним из основных компонентов борьбы с вредителями является мониторинг активности и плотности насекомых [1]. Однако операции по мониторингу все ещё основываются на экспертах, которые анализируют ловушки на месте или их цифровые изображения для распознавания и подсчёта вредителей [1]. Такой подход к мониторингу трудоёмок, требует много времени и средств. Кроме того, ловушки также захватывают полезные организмы [2, 3], что оказывает негативное влияние на биоразнообразие и стабильность экосистем, а отсутствие стандартизированного процесса подсчёта часто приводит к ошибкам при проведении мониторинга и сборе статистики [1].

В данной работе представлен подход обнаружения и классификации насекомых при помощи архитектуры *You Only Look Once (YOLO)*. Метод призван упростить работу по мониторингу

численности насекомых и автоматизировать накопление статистики их обнаружений.

Описание используемой нейросетевой модели. *YOLO* – это передовая архитектура нейронной сети для обнаружения объектов в режиме реального времени. В отличие от двухэтапных детекторов [4], *YOLO* анализирует изображение за один проход, что повышает скорость обработки. Ключевой особенностью *YOLO* является её способность одновременно предсказывать ограничивающие рамки и классы объектов для всего изображения, используя единую свёрточную сеть.

Алгоритм работы *YOLO* начинается с разделения входного изображения на сетку, обычно размером 13x13 ячеек. Для каждой ячейки предсказывается несколько ограничивающих рамок, используя предопределённые якорные поля (*anchor boxes*). Затем вычисляются вероятности классов для каждой рамки и значение «*objectness*» – вероятность наличия объекта в рамке. Эти предсказания комбинируются для получения итоговых обнаружений.

В отличии от существующих работ по данной тематике [5, 6], здесь перед сетью стоит две задачи: задача классификации насекомых и задача их обнаружения на изображении; что является

необычным применением алгоритма *YOLO* и повышает сложность обучения сети.

Данные. В работе использовался набор данных *Insect_Detect_detection*, который, в отличие от других наборов созданных для классификации насекомых (такие как *IP102*) сосредотачивающих всё своё внимание исключительно на проблеме классификации и не пригодных для решения проблемы обнаружения объектов на изображении, т.к. на изображении присутствует только насекомое, имеет развёрнутые изображения, включающие в себя фон и несколько насекомых различных видов и позволяет решить обе поставленные задачи. Фрагмент изображения из используемого набора приведён на рисунке 1.

Обучающий набор данных состоит из 1335 изображений насекомых с шестью классами определяемых объектов: мухи (лат. *rhagoletis cerasi*), журчалки (лат. *syrrhidae*), осы (лат. *vespae*), пчёлы (лат. *anthophila*), мелкие насекомые (мошки, комары) и тени насекомых. На каждом изображении находится от одного до нескольких классов



Рисунок 1 – Фрагмент изображения из набора данных

Выбранные параметры обеспечивают эффективное обнаружение и классификацию объектов на изображениях, о чём свидетельствует метрика *mAP50-95* равная 75,5 %, и минимизируют возможность обнаружения и, как следствие,

объектов. Изображения были разделены в соотношении 80 % для обучения, 10 % для валидации и 10 % для тестирования.

В датасете имеются сильно схожие классы объектов, что усложняет их классификацию. Такими классами являются осы, пчёлы и журчалки. Также проблемным классом являются тени, имеющие очертания и форму насекомых, но ими не являющиеся, поэтому тени выделены в отдельный класс для уменьшения ложноположительных определений объектов.

Результаты обучения сети. В ходе исследования модели при помощи *Ray Tune*, что является аналогом *Grid Search* для *YOLO*, были определены следующие параметры обучения модели:

- количество эпох обучения равное 500;
- коэффициент ошибки определения *bounding box* равный 7,5;
- коэффициент ошибки классификации объекта равный 0,7;
- пороговое значение *IoU* равное 0,7.

классификации одного объекта дважды. Также после каждой эпохи обучения модель прогоняется по валидационному набору данных и сохраняет полученные значения метрик. Метрики обучения сети показаны на рисунке 2.

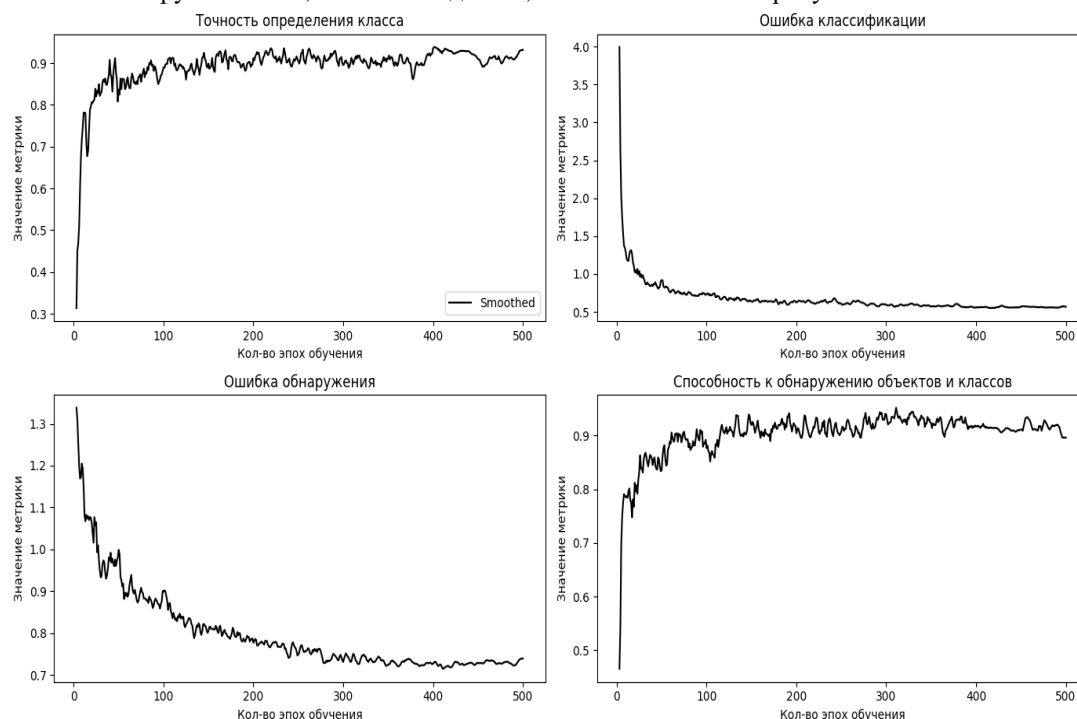


Рисунок 2 – Метрики обучения сети

Среди метрик можно увидеть общее падение ошибки на валидационных данных, рост точности определения классов объектов до 93,25 % и способности обнаруживать объекты насекомых на

изображении до 89,6 % с ростом числа эпох обучения.

Наряду с метриками обучения модель также позволяет построить матрицу ошибок, продемонстрированную на рисунке 3.

Матрица ошибок сообщает, сколько объектов было опознано верно (главная диагональ матрицы) и сколько не верно (пересечение строки и столбца сообщает сколько объектов «строки» было классифицировано как «столбец»). Матрица ошибок также содержит дополнительный класс *background*, под которым подразумеваются объекты, которые

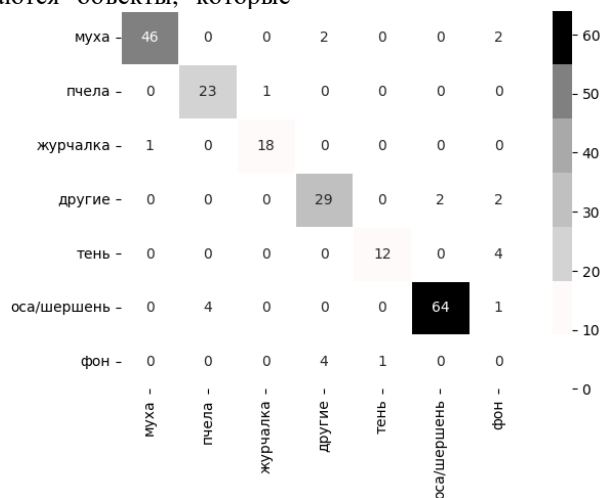


Рисунок 3 – Матрица ошибок



Рисунок 4 – Результат предсказания модели

Заключение. Итоговый результат работы модели показал, что несмотря на наличие в наборе данных похожих видов насекомых точность обнаружения и классификации достигает 88,89 %. Анализ включал в себя исследование результатов детектирования, выявление ошибок, визуализацию предсказаний и общую оценку эффективности модели. Это позволило определить, насколько

успешно модель обнаруживает и классифицирует насекомых. Также полученная модель может быть дообучена для обнаружения большего количества видов насекомых.

Модель *YOLOv8* показала свою эффективность в решении задач обнаружения и классификации насекомых, что позволяет рекомендовать её для практического использования.

Список используемой литературы

- 1 Савчук, И. В. Мониторинг численности и вида насекомых-вредителей для обеспечения безопасности сельскохозяйственной продукции : монография / И. В. Савчук. – Тюмень : ФГБОУ ВО ГАУ Северного Зауралья, 2023. – 154 с., С. 10-26.
- 2 Suckling D. M. Pheromone trap colour determines catch of nontarget insects / Suckling D. M.; Bradley S. J.; Walker J. T. S. – New Zealand Plant Prot, 2000. – С. 216–220.
- 3 Wallis, D. R. Evaluation of coloured sticky traps for monitoring beneficial insects in apple orchards / Wallis, D. R.; Shaw, P.W. – New Zealand Plant Prot, 2008. – С. 328–332.

- 4 Kurochka K. S., Panarin K. A. An algorithm of segmentation of a human spine X-ray image with the help of Mask R-CNN neural network for the purpose of vertebrae localization / 2021 56th International Scientific Conference on Information, Communication and Energy Systems and Technologies, ICEST 2021-Proceedings. – 2021. – С. 55-58.
- 5 Kundur, N. C., Mallikarjuna, P. B. Insect pest image detection and classification using deep learning / International Journal of Advanced Computer Science and Applications, 13(9) – 2022.
- 6 Cao X., Wei Z., Gao Y. Recognition of Common Insect in Field Based on Deep Learning / J. Phys. Conf – 2020.