

ЛОКАЛИЗАЦИЯ ВРЕДНОСНЫХ НАСЕКОМЫХ СЕМЕЙСТВА TERPHRITIDAE НА ИЗОБРАЖЕНИЯХ С ИСПОЛЬЗОВАНИЕМ НЕЙРОННЫХ СЕТЕЙ FAST R-CNN И INCEPTION V3

Курочка К. С., Карпенко Д. Е.
Кафедра «Информационные технологии»,

УО «Гомельский государственный технический университет имени П. О. Сухого»

Гомель, Республика Беларусь

E-mail: {kurochka, protankist343}@gmail.com

В работе предлагается нейросетевая модель и соответствующее программное обеспечение для обнаружения вредоносных насекомых на контрольных ловчих листах, используемых в сельском хозяйстве. Основной акцент сделан на применении модели Fast R-CNN с архитектурой Feature Pyramid Network (FPN) и Inception V3 в качестве классификационной «головы». Разработанный подход позволяет автоматизировать процесс мониторинга количества насекомых семейства terphritidae, являющихся вредителями косточковых культур. Применение созданного программного обеспечения позволит увеличить скорость определения уровня вредителей, накоплению статистики и позволит даже непрофильным специалистам оценивать степень поражения садов.

ВВЕДЕНИЕ

Вредоносные насекомые представляют серьёзную угрозу для сельского хозяйства, вызывая значительные потери урожая. Традиционные методы обнаружения насекомых требуют значительных затрат времени и ресурсов, что делает необходимым разработку автоматизированных систем мониторинга. Современные достижения в области машинного обучения и компьютерного зрения позволяют решать такие задачи с использованием нейронных сетей. В данной работе рассматривается применение R-CNN с Feature Pyramid Network (FPN) и Inception V3 для задачи обнаружения вредоносных насекомых.

I. ПРОБЛЕМАТИКА И ПРИЧИНЫ

Традиционные методы борьбы с насекомыми, такие как химические пестициды, сталкиваются с рядом серьёзных проблем. Во-первых, чрезмерное использование пестицидов вызывает устойчивость насекомых, что требует постоянного увеличения дозировок или смены действующего вещества. Во-вторых, химикаты часто негативно влияют на окружающую среду, загрязняя почву и водные ресурсы. Кроме того, они могут наносить ущерб полезным насекомым, нарушая экосистему. Также наблюдаются проблемы с возрождением популяций вредителей после обработки и возникновением новых вредителей, устойчивых к химическим средствам. Это показывает необходимость внедрения более устойчивых методов, таких как биологический контроль и интегрированные системы управления [1]. Для повышения эффективности борьбы и уменьшения финансовых затрат на обработку и профилактику сельскохозяйственных угодий разрабатываются и интегрируются автоматизированные системы учета и контроля за насекомыми, что позволяет снизить количество необходимых обработок сельскохозяй-

ственных угодий. Данные системы повышают эффективность использования пестицидов, рабочей силы, что уменьшает конечную стоимость продукта. Кроме того, применение таких автоматизированных систем позволяет минимизировать негативное воздействие на окружающую среду за счет более точного и целенаправленного применения средств защиты растений.

II. ТЕХНИЧЕСКИЕ ХАРАКТЕРИСТИКИ FAST RCNN+FPN И INCEPTION V3

Задача Fast R-CNN – быстрое детектирование объектов. Модель решает проблему производительности RCNN, где отдельные региональные предложения классифицируются напрямую на уровне изображения, вместо раздельной обработки. Поэтому данная сетевая топология является популярной при обработке различных изображений [4]. В Fast R-CNN сеть одновременно предсказывает классы объектов и координаты ограничивающих рамок (bounding boxes), что значительно ускоряет процесс. RoI Pooling важная часть Fast RCNN, которая извлекает фиксированные по размеру регионы интереса (RoI) из карты признаков, что позволяет применять классификатор к предложенным регионам.

Feature Pyramid Networks (FPN) данная сеть строит пирамиды признаков, извлекая информацию на разных уровнях свёрточной сети, что позволяет учитывать как низкоуровневые, так и высокоуровневые признаки. FPN особенно эффективен при работе с многообразием масштабов объектов.

Inception V3 имеет 48 слоев, включая свёрточные слои, слои объединения. Inception использует модульную архитектуру, состоящую из так называемых «Inception модулей». Эти модули позволяют сети захватывать различные уровни абстракции и комбинации признаков. Данная мо-

дель имеет Global Average Pooling. Этот подход позволяет сделать модель более устойчивой к различным преобразованиям изображения, так как он фокусируется на глобальных признаках, а не на локальных. Так же этот метод помогает предотвратить ситуацию «исчезающего градинта».

III. АРХИТЕКТУРА СОЗДАННОЙ МОДЕЛИ

Структура модели состоит из модулей FPN, RPN, ROI Align и классификационной «головы» Inception V3, которая в свою очередь выступает для создания карт признаков в Fast RCNN, на рисунке изображена общая структура модели (см. рис. 1). Inception V3 был модифицирован для работы с Fast RCNN + FPN. Из классификатора был удален выходной слой, который классифицировал принадлежность к классу. Так же что бы сформировать пирамиду признаков были выбраны 5 сверточных слоев из последнего блока в модели Inception V3. Для обучения использовались уже предобученные модели Inception V3 и Fast RCNN FPN, классификатор InceptionV3 был обучен на датасете ImageNet.

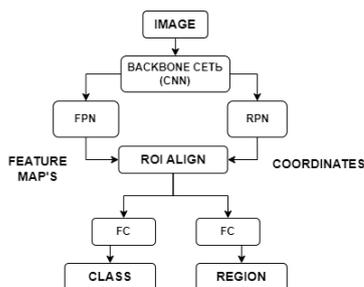


Рис. 1 – Общая топология сети

IV. ВЫБОР ПРИЗНАКОВ ДЛЯ СОЗДАНИЯ НАБОРА ДАННЫХ ДЛЯ ОБУЧЕНИЯ

Основная проблематика в машинном обучении – обучение, разработка новых топологий модели и создание датасетов. Система не будет хорошо работать, если обучающий набор слишком мал или данные нерепрезентативны, зашумлены либо загрязнены несущественными признаками (мусор на входе - мусор на выходе)[2]. Данный аспект является одним из самых важных. От качества обучающей выборки зависит конечный результат. Выбор данных и их признаков в машинном обучении является достаточно творческим, т.е. он не детерминирован. Что важнее, на пчёл изначально был датасет, а на вишнёвую муху – нет. Время для создания полноценного набора данных с вишневыми мухами не было, т.к. период размножения приходится на начало мая и начало июня. Поэтому было принято решение использовать перенос обучения и синтезировать дата сет.

Для генерации данных используются различные способы, на изображения добавляют различные шумы, эффекты. Такие операции, как

сдвиг обучающих изображений на несколько пикселей в каждом направлении, могут значительно улучшить обобщаемость, даже если при проектировании модели уже была заложена частичная инвариантность относительно параллельных переносов путем применения методов свертки и пулинга[3]. Многие другие операции, например поворот или масштабирование изображения, также оказались весьма эффективными[3]. Такой подход называется аугментация данных. Большая часть выборки была сформирована именно этим способом. Так же имеет место быть генерация новых объектов при помощи генеративных моделей и трансформеров.

После первичного обучения проведен анализ паразитов, которые как и вишневая муха нападают косточковые культуры. Датасет для классификатора был дополнен этими паразитами и классификатор был до обучен. Все эти манипуляции с данными дали неплохие показатели классификации(см рис. 2). Statistic classes определяет количество объектов классифицированных, Statistic pred определяет количество определенных классов. Процент правильно определенных классов около 0,95.

```

statistic_classes
[17840. 17820.  0.  0.]
statistic_pred
[16866. 17628.  0.  0.]
train loss 0.0667583669647682
    
```

Рис. 2 – Матрица ошибок

V. ЗАКЛЮЧЕНИЕ

На рисунке изображены маркированные объекты, обведенные моделью(см. рис. 3). Предложенная модель и программные средства могут быть использованы в практической деятельности небольшими сельхоз предприятиями и фермерскими хозяйствами.

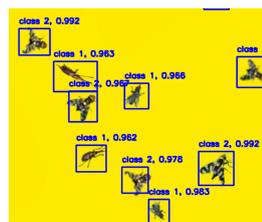


Рис. 3 – Пример маркированных объектов

1. Finstein, J. Advances in Pest Management Strategies: A Review / J. Finstein// Int. Res. J. Agric. Sci. Soil Sci. – 2023. – Vol. 12, № 4. – P. 1–3.
2. Прикладное машинное обучение с помощью Scikit-Learn и TensorFlow: концепции, инструменты и техники для создания интеллектуальных систем / Жерон О. – СПб.: Диалектика, 2018. – 688 с.
3. Глубокое обучение / Гудфеллоу Я., Бенджио И., Курвилль А. – М.: ДМК Пресс, 2018. – 652 с.
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 / Kurochka K.S., Panarin K.A.// ICEST 2021-Proceedings – 2021. – ISBN:978-1-6654-2888-0, – P.55–58.