

РАЗРАБОТКА МОБИЛЬНОГО ПРИЛОЖЕНИЯ ДЛЯ РАСПОЗНАВАНИЯ БОЛЕЗНЕЙ ТОМАТОВН. Д. Никонов¹, Т. В. Никонова²¹НИУ ИТМО, г. Санкт-Петербург, Россия²УО «ВГТУ» г. Витебск, Беларусь

Аннотация. Глубокие нейронные сети успешно используются в агрохозяйстве для борьбы с основными угрозами продовольственной безопасности. Целью данного исследования являлась разработка мобильного приложения для распознавания болезней томатов, изучение точности зарекомендовавших себя архитектур сверточных нейронных сетей в неконтролируемых условиях при решении задач классификации заболеваний сельскохозяйственных культур. Используются архитектуры Inception-v3, VGG16, VGG13 сверточных нейронных сетей (CNN), разработанные для классификации изображений, обнаружения объектов, семантической и интерактивной сегментации. В нашей работе используются несколько наборов данных – PlantVillage-Dataset, PlantDoc и созданный нами Cropped-PlantDoc. Для увеличения набора данных, борьбы с переобучением и улучшения обобщающей способности моделей применили стандартные методы увеличения данных, такие как: вращение, горизонтальный и вертикальный перенос, масштабирование. Использовалось добавление шума, изменение яркости, цвета и контраста, которые могут имитировать различные погодные условия (солнце, ветер, туман) или размытую фотографию, сделанную не профессиональным фотографом. Для решения проблемы классификации заболеваний растений был создан набор данных аналогичный PlantVillage-Dataset, который содержал изображения растений с различными вариантами фона, освещения, видов заболеваний и углами под которыми получен снимок. Так же построив визуализацию промежуточных активаций модели и построение карт внимания (Grad-CAM), мы показали, что при совместном использовании нашей сети и визуальном осмотре специалистом карты внимания, можно добиться высокой точности классификации и решить проблему «черного ящика».

Ключевые слова: сверточные нейронные сети, задача классификации, карта внимания, болезни растений.

I. ВВЕДЕНИЕ

Глубокие нейронные сети успешно используются в агрохозяйстве для борьбы с основными угрозами продовольственной безопасности. Болезни растений уже давно являются одной из важнейших проблем, поскольку они резко снижают урожайность сельскохозяйственных культур и ухудшают их качество.

За последние несколько лет авторы работ посвященных использованию сверточных нейронных сетей для классификации заболеваний растений по изображениям, достигли значительных результатов. Традиционные подходы к классификации болезней с помощью машинного обучения, как правило, сосредоточены на небольшом количестве классов, обычно в рамках одной культуры. Во множестве работ рассматриваются факторы, которые могут оказать влияние на точность диагностической системы. Основываясь на результатах, полученных в этих работах можно сделать вывод, что приложение, использующее глубокое обучение для классификации заболеваний растений, будет более эффективным, если его можно использовать в полевых условиях, где условия можно хотя бы частично корректировать (выведение листа из тени или поворот под нужным углом).

Целью данного исследования являлась разработка мобильного приложения для распознавания болезней томатов, изучение точности зарекомендовавших себя архитектур сверточных нейронных сетей в неконтролируемых условиях при решении задач классификации заболеваний сельскохозяйственных культур. А также изучение факторов среды наиболее значительно влияющих на точность модели. В работе применяется метод построения карт внимания для решения проблемы «черного ящика» и подтверждается, что при совместном использовании разработанной системы классификации и визуальном осмотре специалистом карты внимания (Grad-Cam), можно добиться высокой точности классификации.

II. ПОСТАНОВКА ЗАДАЧИ

Используются архитектуры Inception-v3, VGG16, VGG13 сверточных нейронных сетей (CNN), разработанные для классификации изображений, обнаружения объектов, семантической и интерактивной сегментации.

В нашей работе мы используем несколько наборов данных – PlantVillage-Dataset, PlantDoc и созданный нами Cropped-PlantDoc.

Набор изображений PlantDoc примечателен тем, что содержит снимки растений, максимально приближенные к полевым, в отличие от PlantViLLage, который был создан в контролируемых условиях. В не контролируемых условиях такие факторы как погодные условия (солнечный свет, ветер, туман и дождь), качество фото и фон оказывают сильное влияние на точность диагностической системы. Поэтому для проведения экспериментов мы так же использовали CroppedPlantDoc Dataset. Он был получен путем обрезки изображений, содержащих несколько листовых пластинок набора данных PlantDoc, для получения изображений, содержащих только одну пораженную листовую пластинку. Таким образом, мы получили Cropped-PlantDoc Dataset, содержащий 8468 изображений (13 видов сельскохозяйственных 14 культур и 17 видов заболеваний). Изображения были разделены на обучающие, валидационные наборы данных с соотношением 8:2. PlantVillageDataset – набор данных из 54 306 изображений листьев растений (26 видов заболеваний, 14 видов сельскохозяйственных культур). Изображения были разделены на обучающие, валидационные и тестовые наборы данных с соотношением 8:1,5:0,5.

III. ТЕОРИЯ

Для обучения сверточных нейронных сетей мы использовали Adam, categorical crossentropy loss и шаг обучения равный 0.001, размер батча 32. Во всех подходах, мы изменяли размер изображений до 150*150 пикселей для увеличения производительности, без особой потери качества изображения. Для оценки производительности моделей были выбраны метрики на основе Confusion matrix (F1-score и Accuracy). Модели, которые были обучены с нуля, показывали значительно более медленный прирост точности, по сравнению с предобученными моделями при одинаковом количестве эпох. Поэтому, для ускорения процесса обучения применялся метод переноса обучения и использовались модели, которые были предварительно обучены на наборе ImageNet. Все рассматриваемые модели CNN, обученные на наборе данных PlantVillage, а так же при последующем тестировании на нем, показали хороший результат (accuracy 95% и выше). Из результатов, полученных при тестировании на наборе данных Cropped-PlantDoc, можно сделать вывод, что сети, обученные только на PlantVillage, в реальных полевых условиях показывают себя значительно хуже. Модель дает не точные результаты из-за фонового шума, не строго ориентированного расположения листа, его деформаций и прочих факторов, вызванных внешними условиями (погода, неравномерная освещенность листа) или низким качеством фото.

IV. РЕЗУЛЬТАТЫ ЭКСПЕРИМЕНТОВ

Для увеличения набора данных, борьбы с переобучением и улучшения обобщающей способности наших моделей мы применили стандартные методы увеличения данных, такие как: вращение, горизонтальный и вертикальный перенос, масштабирование. Кроме этого, использовалось добавление шума, изменение яркости, цвета и контраста, которые могут имитировать различные погодные условия (солнце, ветер, туман) или размытую фотографию, сделанную не профессиональным фотографом. Параметры аугментации – угол поворота – 180°, повышение яркости фото было равномерным и в пределах от 0.9 до 1.1, смещение по горизонтальной и вертикальной оси – 0.2, отдаление – 0.2.

Сети, обученные на наборах PlantVillage и Cropped-PlantDoc (80%), к которым был применен метод увеличения данных, показали значительно лучший результат при тестировании на наборе Cropped-PlantDoc. В наборе с 7 классами шанс «случайно угадать» класс заболевания равен 14.2%. Наилучшую точность в задаче классификации на наборе Cropped-PlantDoc (20%) показала архитектура Inceptionv3 обученная на Cropped-PlantDoc (80%) (accuracy 71.43%), в то время архитектуры VGG13 и VGG16 достигли на этом же наборе данных средней точности равной 56.16% и 54.68%.

V. ОБСУЖДЕНИЕ РЕЗУЛЬТАТОВ

Чтобы увидеть, как работает наша модель и что именно она изучает, мы реализовали 2 метода визуализации на обученной модели VGG13 с использованием набора данных PlantVillage для визуального объяснения

классификационных решений системы: визуализацию промежуточных активаций модели на последнем сверточном слое, состоящую из отображения карт признаков, которые строятся различными слоями свертки и построение карт внимания (Grad-CAM). Выходные данные Grad-CAM – это визуализация тепловой карты для данной метки класса. Эти методы также можно использовать для решения проблемы «черного ящика» и помощи специалистам при визуальной идентификации болезни растений. Карты внимания (Grad-CAM) дают представление о том, какие части фотографии являются определяющими для сети, при классификации заболеваний. Также она может помочь понять, почему диагностическая система ошиблась и какой фактор привел к этой ошибке.

VI. ВЫВОДЫ И ЗАКЛЮЧЕНИЕ

Во многом проблема классификации заболеваний растений была бы решена, если бы был создан набор данных аналогичный PlantVillage-Dataset, который бы содержал изображения растений с различными вариантами фона, освещения, видов заболеваний и углами под которыми получен снимок. Так же построив визуализацию промежуточных активаций модели и построение карт внимания (Grad-CAM), мы показали, что при совместном использовании нашей сети и визуальном осмотре специалистом карты внимания, можно добиться высокой точности классификации и решить проблему «черного ящика».

Болезни томатов группируют по категориям симптомов, чтобы облегчить их идентификацию. После идентификации, поняв причину возникновения болезни и потенциальный ущерб, можно начать надлежащее лечение.

В дальнейшем планируется провести исследование влияния внешних признаков на точность диагностической системы. Например, неоднородной освещенности (наличие бликов, неполная освещенность листа) или фона, для чего будет создан специальный набор данных. Так же планируется отладка мобильного приложения, осуществляющего классификацию заболеваний и его практическое внедрение в сельское хозяйство, занимающееся выращиванием томатов.

СПИСОК ЛИТЕРАТУРЫ

1. Ferentinose K. Deep learning models for plant disease detection and diagnosis // Research Gate, 2018.
2. El-Kereamy A., Kreuze J. F. Deep learning for image-based cassava disease detection // Research Gate, 2017.
3. Fuentes A., Yoon S. A robust deep-learning-based detector for realtime tomato plant diseases and pests recognition // Research Gate, 2017.
4. Wang G., Sun Y. Automatic image-based plant disease severity estimation using deep learning // Research Gate, 2017.

УДК 004.946

ВИРТУАЛЬНЫЕ ИНФЛЮЕНСЕРЫ КАК СРЕДСТВО ПРОДВИЖЕНИЯ FASHION ПРОДУКЦИИ

К. С. Саввинова, А. А. Арбузова

Ивановский государственный политехнический университет, г. Иваново, Россия

Аннотация. В последнее время наблюдается широкое распространение и востребованность виртуальных инфлюенсеров, особенно в индустрии моды и красоты. С использованием цифровых персонажей рекламируются одежда, обувь, аксессуары, косметические средства, другие блогеры и целые торговые марки. Их применение в маркетинговой компании положительно сказывается на продвижении продукции брендов. Несмотря на то, что создание виртуальных инфлюенсеров требует немалых затрат, эффект от их использования приносит существенный доход. Современные пользователи более восприимчивы к информации, которую преподносят виртуальные блогеры, нежели реальные. В данной статье рассмотрен процесс создания и влияние виртуальных инфлюенсеров на рынок fashion-индустрии.

Ключевые слова: виртуальные инфлюенсеры, fashion продукция, блогеры, реклама.