

Определение 3. Системы (1) и (2), связанные преобразованием Ляпунова, будем называть *асимптотически эквивалентными (по Богданову)* или *кинематически подобными*.

Результаты и их обсуждение. Нами установлена следующая

Теорема. *Асимптотически эквивалентные (по Богданову) линейные системы в подчиненных производных имеют одну и ту же асимптотику (характер поведения их решений при $t \rightarrow +\infty$).*

Замечание. Именно указанное в теореме свойство дает основание называть асимптотически эквивалентные (по Богданову) системы также и кинематически подобными.

Последняя теорема является распространением свойства, присущего асимптотически эквивалентным линейным нестационарным системам обыкновенных дифференциальных уравнений (см., напр., [2]) на линейные системы в подчиненных дробных производных.

Заключение. Полученная теорема в дальнейшем позволит ввести асимптотические характеристики (инварианты) для линейных систем в подчиненных дробных производных, а также решать задачу управления такими характеристиками, а следовательно, и асимптотикой решений рассматриваемых систем

Благодарности. Работа выполнена в рамках программы ГПНИ "Конвергенция-2025", подпрограмма "Математические методы и модели".

1. Khalil, R. A new definition of fractional derivative / R. Khalil, M. Al Horani, A. Yousef, M. Sababheh // Journ. of Computational and Applied Mathematics. — 2014. — Vol. 264. — Pp. 65-70.

2. Богданов, Ю.С. Об асимптотически эквивалентных линейных дифференциальных системах / Ю.С. Богданов // Дифференц. уравнения. — 1965. — Т.1, No. 6.— С. 707-716.

ИСПОЛЬЗОВАНИЕ СВЕРТОЧНЫХ НЕЙРОННЫХ СЕТЕЙ ДЛЯ РЕШЕНИЯ ЗАДАЧ КЛАССИФИКАЦИИ БОЛЕЗНЕЙ РАСТЕНИЙ

Никонов Н.Д.,

*магистрант НИУ ИТМО, г. Санкт-Петербург, Российская Федерация
Научный руководитель – Никонова Т.В., канд. физ.-мат. наук, доцент*

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

Keywords. Convolutional neural networks, classification task, attention map, plant diseases.

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

Целью данного исследования являлось 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.

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

Результаты и их обсуждение. 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.

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.

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%

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».

МОДЕЛИРОВАНИЕ ЗАДАЧ ПРИНЯТИЯ РЕШЕНИЙ НА БАЗЕ СТАТИСТИЧЕСКИХ ИГР

Савченко И.В.,

студентка 4-го курса БГУ, г. Минск, Республика Беларусь

Научный руководитель – Капусто А.В., канд. физ.-мат. наук, доцент

Ключевые слова. Принятие решений, неопределенность, статистическая игра, стратегия, критерий.

Keywords. Making decisions, uncertainty, statistical game, strategy, criterion.

Задачи по принятию решений в разных сферах жизни, как частных лиц, так и управляющего персонала и руководителей различных предприятий и организаций, сопровождают практически все этапы их активной деятельности и существования. Результатом необдуманно принимаемых решений для задач и вопросов, имеющих экономическую составляющую, могут стать как большие материальные потери, так и негативные последствия для социальной сферы. В рамках руководства предприятием или фирмой это могут быть существенные финансовые издержки, упущенная выгода, производство на склад и т.д., в рамках планирования семейного бюджета – необдуманный кредит, нерациональное распределение средств, участие в заведомо проигрышных вложениях и т.п. Все это может привести к серьезным финансовым потерям как отдельно взятого человека, так и коммерческой структуры [1]. Грамотное и своевременно принятое управленческое решение определяет не только эффективность производственной деятельности предприятия, но и возможность его устойчивого развития.

Принятие управленческого решения требует определенного времени для раздумий и перебора предполагаемых вариантов возможных последствий. Сложность при выборе варианта поведения (стратегии) вызывает недостаточная информированность лица принимающего решение (ЛПР) о будущем – иными словами, неопределенность состояний внешней среды, в которой и предстоит реализовать выбранный вариант действий. Именно эта неопределенность «ответной реакции» внешней среды обуславливает потребность в разработке ЛПР нескольких стратегий, а также ставит его перед выбором окончательного варианта поведения. Вследствие этого процесс принятия обоснованных объективных решений должен опираться на научный подход с использованием моделей и количественных методов анализа данных для обоснования выбора оптимального решения. Теоретико-игровой подход является наиболее распространенным методом принятия решений в условиях неопределенности.

Материал и методы. Математической моделью задачи принятия решений выступает статистическая игра, т.е. игра с природой. В данном случае, в отличие от парных матричных игр, сознательно действует только один из игроков, чаще всего называемый активным, который и выступает в качестве ЛПР. Второй игрок – пассивный игрок или «Природа», который представляет собой внешнюю среду, влияющую на результат принятого ЛПР решения – не принимает решений и, фактически, является абсолютно