УДК 004.93

Галанина Ольга Владимировна,
канд. эконом. наук, доцент,
Военный инженерно-технический университет
Galanina Olga Vladimirovna,
Candidate of Economical Sciences, Associate Professor,
Military Engineering and Technical University

Евдущенко Елена Владимировна, канд. техн. Наук,
Военный инженерно-технический университет
Evdushchenko Elena Vladimirovna,
Candidate of Technical Sciences,
Military Engineering and Technical University

РАЗРАБОТКА ДАТАСЕТА ИЗОБРАЖЕНИЙ БПЛА ДЛЯ ПРАКТИЧЕСКОГО ИЗУЧЕНИЯ АЛГОРИТМОВ КЛАССИФИКАЦИИ
DEVELOPMENT OF A DATASET OF UAV IMAGES FOR THE PRACTICAL STUDY OF CLASSIFICATION ALGORITHMS

Аннотация. В статье рассматривается процесс формирования компактного учебного датасета изображений беспилотных летательных аппаратов (БПЛА) и его практическая апробация на модели машинного обучения. Приводятся результаты эксперимента, демонстрирующие эффект переобучения при малом объеме выборки. Выполнен анализ графиков функции потерь и точности, а также рассматриваются методы расширения выборки.

Abstract. The article examines the process of creating a compact training dataset of images of unmanned aerial vehicles (UAVs) and its practical testing on a machine learning model. The results of the experiment are presented, demonstrating the effect of overfitting with a small sample size. The loss and accuracy function graphs are analyzed, and methods for expanding the sample are considered.

Ключевые слова: Датасет, БПЛА, дроны, распознавание образов, машинное обучение, классификация изображений, scikit-learn, переобучение, аугментация данных.

Keywords: Dataset, UAV, drones, image recognition, machine learning, image classification, scikit-learn, overfitting, data augmentation.

Задачи автоматического распознавания беспилотных летательных аппаратов (БПЛА) приобретают все большую актуальность в системах мониторинга, логистики и обеспечения безопасности. Современные исследования в этой области охватывают широкий спектр методов: от классического компьютерного зрения, основанного на анализе видеопотока [1, 2], до акустического анализа звуков дронов, реализованного в программном комплексе XVDetector [3]. Активно развиваются подходы на основе оценки радиочастотной активности [4], а также методы радиочастотных сенсорных технологий [5]. В системах противовоздушной обороны (ПВО) искусственный интеллект применяется для автоматической классификации воздушных целей [6].

Для обучения любых моделей компьютерного зрения, будь то простые классификаторы или глубокие нейронные сети, требуются репрезентативные наборы данных. В настоящее время существуют программные комплексы для формирования специализированных выборок [7, 8], а также решения для сбора, хранения и анализа данных в узких прикладных областях, например, Webiomed.DataSet [9]. Однако крупные публичные датасеты (например, ImageNet) обладают избыточной сложностью и требуют значительных вычислительных ресурсов, что делает их малопригодными для учебных задач.

В связи с этим целью данной работы является разработка компактного учебного датасета БПЛА и его практическая апробация на базовой нейросетевой модели. Задачи работы включают: формирование структуры датасета, его предобработку, обучение классификатора и анализ полученных метрик.

Для формирования выборки было отобрано 9 классов БПЛА (Airborne, Bairaktar, Bober, FP-1, Foxbat, Kosa, Leleka_DS, Lyutyi, Valkiriya). Объем датасета составил от 5 до 7 изображений на каждый класс (61 снимок в общей сложности). Несмотря на небольшой объем, такой набор позволяет отработать базовые навыки работы с изображениями, которые представлены на рисунке 1.

Исходные изображения имеют разрешение 100×75 пикселей. Данные организованы в виде иерархической структуры папок, где имя директории соответствует метке класса (например, папка Airborne содержит только фото этого типа дрона). Подобный подход к структурированию информации для последующего анализа широко применяется в существующих программных решениях [9], так как он позволяет автоматизировать процесс загрузки и маркировки данных.

Необработанные изображения не могут быть напрямую поданы в классификатор машинного обучения. Перед обучением данные проходят следующие этапы предобработки:

1. Приведение к градациям серого. Цветные изображения переводятся в одноканальный формат. Это снижает размерность признакового пространства (с трех каналов RGB до одного) и уменьшает вычислительную нагрузку, что особенно важно при работе на CPU.

2. Нормализация. Значения яркости пикселей изначально лежат в диапазоне [0; 255]. Они масштабируются в диапазон [0; 1] путем деления на 255.0. Это способствует более стабильной и быстрой сходимости градиентных алгоритмов оптимизации, так как предотвращает резкие скачки весов.

3. Векторизация (Flattening). Двумерные матрицы изображений (100×75) разворачиваются в одномерные векторы признаков длиной 7500 элементов.



Рисунок 1. Учебный датасет drones

Разбиение выборки. Данные разделяются на обучающую и тестовую подвыборки в пропорции 80/20. Для предотвращения дисбаланса классов применяется стратификация, обеспечивающая равное долевое представительство каждого типа дрона в обеих частях.

Для классификации использовался многослойный перцептрон (MLP) из библиотеки scikit-learn. Выбор данной архитектуры обусловлен её простотой и наглядностью, что идеально подходит для учебных целей.

Модель MLPClassifier была настроена следующим образом:

1. Скрытые слои: два слоя с 128 и 64 нейронами. Такая конфигурация позволяет сети выделять как простые, так и более сложные признаки.

2. Функция активации: ReLU (Rectified Linear Unit), которая решает проблему затухания градиента.

3. Оптимизатор: Adam – адаптивный метод оптимизации, хорошо работающий «из коробки» без необходимости тонкой ручной настройки скорости обучения.

4. Количество итераций: до 300.

5. Результаты апробации и анализ графиков

В ходе эксперимента на каждой итерации фиксировались метрики функции потерь (Loss) и точности (Accuracy). Построенные графики позволили наглядно оценить процесс обучения (рис. 2, 3).

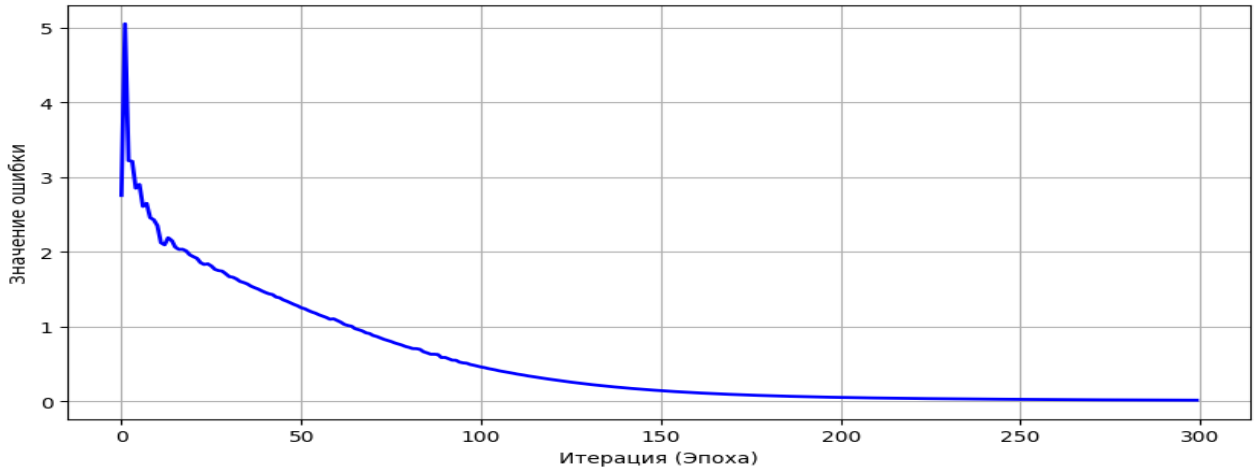

Рисунок 2. График ошибки (Loss) в процессе обучения

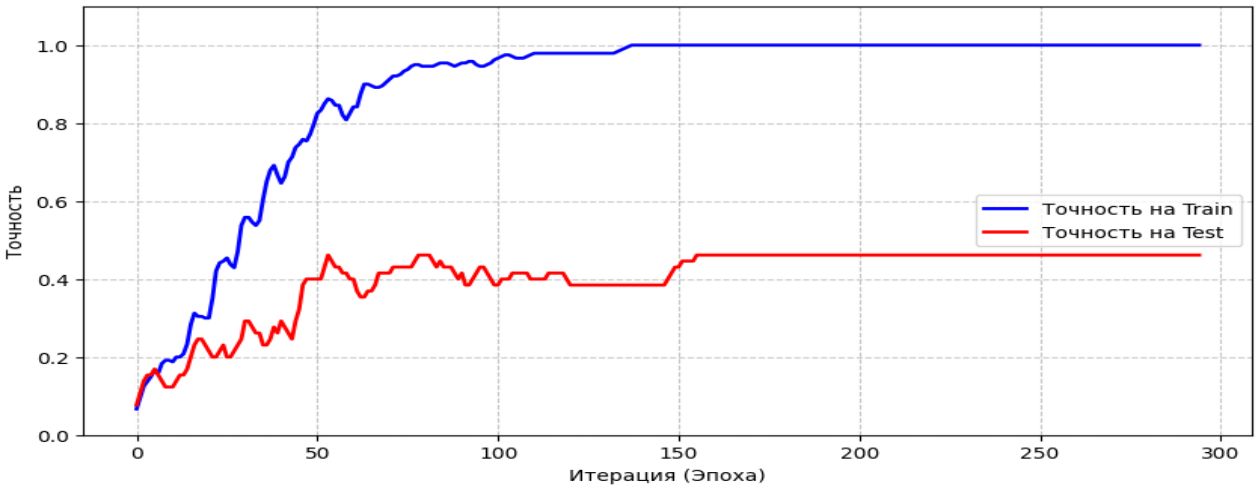

Рисунок 3. График точности (Accuracy) в процессе обучения

График функции потерь (рис. 2) демонстрирует стремительное падение почти до нуля уже на первых 200-итерациях. Это означает, что модель успешно минимизировала ошибку на тренировочных данных. Однако график точности (рис. 3) показал иную картину: если точность на обучающей выборке выросла практически до 100%, то точность на тестовой выборке стабилизировалась на уровне около 46% и перестала расти.

Полученные результаты (Loss → 0 при Accuracy 46%) демонстрируют классический эффект переобучения (overfitting). Из-за крайне малого объема выборки (5-7 изображений на класс) модель адаптируется к конкретным тренировочным примерам, «запоминая» их, но не способна обобщить признаки на новые данные.

Для повышения качества распознавания в таких условиях исследователи применяют более сложные архитектуры глубокого обучения [2], либо используют дополнительные каналы информации: акустические [3] или радиочастотные [4, 10].

Однако наиболее доступным и математически обоснованным способом борьбы с переобучением является *искусственное расширение выборки* (аугментация). Для генерации новых данных с заданными свойствами успешно применяются методы статистического моделирования, в частности, метод Монте-Карло [11]. Путем случайных поворотов, сдвигов и изменения яркости исходных изображений можно увеличить объем обучающей выборки в десятки раз, что позволит модели выделять общие признаки, а не запоминать конкретные пиксели.

В ходе работы был создан и апробирован учебный датасет изображений БПЛА. Несмотря на низкую итоговую точность на тестовых данных, обусловленную дефицитом исходных изображений, датасет позволяет отработать полный цикл работы с данными: от их сбора и предобработки до обучения модели и анализа метрик.

Дальнейшее развитие работы предполагает расширение выборки с использованием методов аугментации на основе статистического моделирования [11], а также переход к сверточным нейронным сетям (CNN), которые обладают большей устойчивостью к переобучению и лучше подходят для задач распознавания образов.

Список литературы:

1. Бахвалов, И. М. Распознавание БПЛА различных классов средствами компьютерного зрения / И. М. Бахвалов, С. В. Старцев // Искусственный интеллект в промышленных, коммерческих, медицинских и финансовых приложениях: сборник статей научно-технического семинара студентов кафедры "Инженерной кибернетики", Москва, 26–27 декабря 2024 года. – Москва: Национальный исследовательский технологический университет "МИСИС", 2024. – С. 34-40.

2. Ашманова, Е. А. Нейросетевые методы для распознавания дронов и птиц в воздушном пространстве / Е. А. Ашманова, С. В. Старцев // Искусственный интеллект в промышленных, коммерческих, медицинских и финансовых приложениях: Сборник статей научно-технического семинара студентов кафедры "Инженерной кибернетики", Москва, 30 мая 2025 года. – Москва: Национальный исследовательский технологический университет "МИСИС", 2025. – С. 17-23.

3. Свидетельство о государственной регистрации программы для ЭВМ № 2024619525 Российская Федерация. XVDetector – программный комплекс автоматизированного распознавания и анализа звуков дронов: № 2024618648: заявл. 19.04.2024: опубл. 24.04.2024 / М. Г. Городничев, Г. М. Мкртчян, С. Е. Симонов, М. С. Мосева; заявитель ОБЩЕСТВО С ОГРАНИЧЕННОЙ ОТВЕТСТВЕННОСТЬЮ "КИБЕР АЙ КЬЮ".

4. Оценка методов искусственного интеллекта для детектирования дронов на основе радиочастотной активности / Н. Н. Мудрук, М. Д. Трегубенко, Е. С. Басан, Е. С. Абрамов // Системный синтез и прикладная синергетика: сборник научных работ X Всероссийской научной конференции, пос. Нижний Архыз, 28 сентября – 02 2021 года. – Ростов-на-Дону, Таганрог: Южный федеральный университет, 2021. – С. 179-185. – DOI 10.18522/syssyn-2021-31. – EDN JTIKVZ.

5. Бонджулич, Б. П. Распознавание беспилотников на основе радиочастотных сенсорных технологий / Б. П. Бонджулич // Сенсорное Слияние – 2023: доклады IV Всесоюзного Конгресса по сенсорике и экономике, Санкт-Петербург – Кронштадт, 30–31 мая 2023 года. – Санкт-Петербург: Б. и., 2023. – С. 201-204.

6. Барышников, Д. Ю. Использование искусственного интеллекта в системах ПВО для автоматического распознавания и классификации дронов / Д. Ю. Барышников, А. В. Степанов // Теория и практика военного образования в гражданских вузах: педагогический поиск: Сборник материалов VIII Всероссийской научно-практической конференции с международным участием, Екатеринбург, 20–21 ноября 2025 года. – Екатеринбург: УМЦ УПИ, 2025. – С. 165-167.

7. Свидетельство о государственной регистрации программы для ЭВМ № 2024667680 Российская Федерация. вИИзуал: № 2024666696: заявл. 17.07.2024: опубл. 26.07.2024 / К. В. Скобельцын.

8. Свидетельство о государственной регистрации программы для ЭВМ № 2025665756 Российская Федерация. «Программа формирования дата сетов для прогнозирования курсов валют с помощью нейронной сети»: заявл. 19.03.2025: опубл. 19.06.2025 / А. М. Андриянов, О. В. Баюк, Л. Б. Сенкевич [и др.].

9. Свидетельство о государственной регистрации программы для ЭВМ № 2020616925 Российская Федерация. Программа для сбора, хранения и анализа медицинских данных Webiomed.DataSet: № 2020615907: заявл. 17.06.2020: опубл. 25.06.2020; заявитель Общество с ограниченной ответственностью «К-Скай».

10. Оценка методов искусственного интеллекта для детектирования дронов на основе радиочастотной активности / Н. Н. Мудрук, М. Д. Трегубенко, Е. С. Басан, Е. С. Абрамов // Системный синтез и прикладная синергетика: сборник научных работ X Всероссийской научной конференции, пос. Нижний Архыз, 28 сентября – 02 2021 года. – Ростов-на-Дону, Таганрог: Южный федеральный университет, 2021. – С. 179-185. – DOI 10.18522/syssyn-2021-31.

11. Галанина, О. В. Моделирование выборок с заданными свойствами методом Монте-Карло для обучения и исследования нейронных сетей прямого распространения / О. В. Галанина, А. М. Голубев // Мягкие измерения и вычисления. – 2023. – Т. 70, № 9-1. – С. 21-27. – DOI 10.36871/2618-9976.2023.09.002.