

Трансферное обучение в задаче классификации летательных аппаратов

Валентин Есилевский
кафедра прикладной математики
Национальный университет радиоэлектроники
г. Харьков, Украина
yes_v_s@ukr.net

Андрей Тевяшев
кафедра прикладной математики
Национальный университет радиоэлектроники
г. Харьков, Украина
andrew.teviashev@nure.ua

Антон Колядин
кафедра прикладной математики
Национальный университет радиоэлектроники
г. Харьков, Украина
anton.koliadin@nure.ua

Transfer Learning In Aircraft Classification

Valentyn Yesilevskiy
Department of Applied Mathematics
National University of Radioelectronics
Kharkiv, Ukraine
yes_v_s@ukr.net

Andrew Teviashev
Department of Applied Mathematics
National University of Radioelectronics
Kharkiv, Ukraine
andrew.teviashev@nure.ua

Anton Koliadin
Department of Applied Mathematics
National University of Radioelectronics
Kharkiv, Ukraine
anton.koliadin@nure.ua

Аннотация—В статье представлен способ решения задачи классификации летательных аппаратов по цифровому изображению с использованием глубоких нейронных сетей, подготовленных на основе трансферного обучения

Abstract— The article presents a method of aircraft classification by digital image using deep neural networks with transfer learning

Ключевые слова—летательные аппараты; классификация изображений; глубокие нейронные сети; трансферное обучение

Keywords— aircrafts; image classification; deep neural networks; transfer learning

I. ВВЕДЕНИЕ

Системы обнаружения и распознавания различных типов летательных аппаратов (ЛА) в последнее время претерпевает сильные изменения. Это связано, во-первых, с применением стелс-технологий, маскирующих характеристики ЛА в радиолокационной области обнаружения. И, во-вторых, в связи с революционными успехами в области применения искусственного интеллекта для обработки изображений и относительной дешевизной необходимых аппаратных средств. Дополнение или даже замена систем радиолокационного обнаружения ЛА системами оптического обнаружения предоставляет новые возможности в определении характера воздушной обстановки. Поэтому задача повышения надежности распознавания типов ЛА по цифровому видеоизображению существенно возрастает.

Обработку видеозображения наземными средствами слежения за воздушной обстановкой можно разбить на ряд задач. Среди них можно выделить следующие задачи: обнаружение подвижного летящего объекта; определение характеристик объекта (дальность, размер, скорость, маневренность и т.п.); определение типа ЛА. Эти задачи могут решаться как поэтапно, так и одновременно. Это может быть обнаружение всех объектов на одном кадре с определением их типа и последующим их сопровождением в последовательности видеок кадров или обнаружение движущихся объектов по видеоряду с последующей идентификацией объектов на каждом кадре. В предлагаемом подходе мы предполагаем, что движущийся объект или объекты сначала будут обнаружены и локализованы на видеозображении, а затем будет решаться задача отнесения каждого объекта к определенному классу.

В области распознавания образов на изображении принята следующая устойчивая терминология для определения задач [1], представленных на рис. 1.




Рис. 1. Различные задачи распознавания образов на изображении: а) классификация, б) классификация с локализацией, в) детектирование

Детектирование – определение класса каждого объекта на изображении. Классификация – определение класса одного объекта на изображении. Классификация с локализацией – классификация одного объекта и указание его места на изображении.

Таким образом, в этой терминологии мы будем обсуждать методы решения задачи классификации ЛА на цифровом изображении.

II. АНАЛИЗ СОСТОЯНИЯ ПРОБЛЕМЫ И ЗАДАЧИ ИССЛЕДОВАНИЯ

Классические методы распознавания ЛА, применяемые до появления глубоких нейронных сетей, были основаны на сравнении неизвестного изображения с библиотекой известных. Сложность решения такой задачи заключается в правильном определении неизвестного ЛА независимо от его ориентации. Для преодоления этой трудности используется подход с вычислением численных значений (моментов), инвариантных к повороту изображения на плоскости. К этим характеристикам относятся моменты Ху, моменты Зернике и Вейвлет-моменты [2,3].

При этом задача классификации решалась методами машинного обучения, как правило, с использованием классических нейронных сетей прямого распространения с небольшим количеством скрытых слоев [2].

Этот подход давал неплохие результаты для распознавания самолетов на аэрокосмических снимках аэродромов, где вариации положения объекта относились к повороту на плоскости. Для распознавания летящего самолета эти методы менее приспособлены. Для такого рода задач используются различные методы распознавания трехмерных объектов [4,5].

Революционные успехи в области анализа изображений были достигнуты после применения глубоких сверточных нейронных сетей обученных на тестовом наборе изображений ImageNet [6]. Модификации подходов, связанных с глубокими нейронными сетями, были использованы и для решения задачи идентификации типов самолетов [7].

При обучении глубоких нейронных сетей решению задачи классификации с нуля возникает ряд проблем. Прежде всего - необходимость создания большого обучающего набора размеченных изображений, включающего миллионы изображений как в ImageNet. И сложной технической проблемой является подключение больших вычислительных ресурсов, включающих в себя кластеры графических видеокарт, чтобы закончить обучение в приемлемое время.

Решением описанных проблем определения типа летательного аппарата является трансферное обучение глубоких нейронных сетей, позволяющий использовать предварительно обученную (даже для других классов объектов) сеть для построения классификаторов изображений ЛА.

Исследованию этого подхода посвящена данная работа. В разделе 3 предложено решение для задачи создания обучающего набора изображений. В разделе 4 описана процедура обучения предварительно подготовленной модели для классификации нескольких типов ЛА. В разделе 6 обсуждаются полученные результаты.

III. ТЕОРЕТИЧЕСКИЕ ПРЕДПОСЫЛКИ ТРАНСФЕРНОГО ОБУЧЕНИЯ

Существуют в открытом доступе как модули для встраивания в собственное программное обеспечение версии глубоких нейронных сетей, хорошо себя зарекомендовавших для решения задач искусственного интеллекта от распознавания изображений до обработки естественной речи. Эти модели предлагают не только готовую архитектуру сети, но и это очень важно – весовые коэффициенты предварительно натренированной сети. Используемая в данной работе сеть Inception v3 [9] натренирована на одной из крупнейших баз данных изображений ImageNet с более чем 10 миллионами изображений, аннотированных для 1000 классов объектов.

Современные модели распознавания изображений – это глубокие сверточные нейронные сети (Convolutional Neural Network, CNN) с многочисленными слоями. Нижние слои такой CNN-сети отвечают за распознавание низкоуровневых элементарных признаков, таких как края, контуры и части изображения. Средние слои обеспечивают распознавание групп низкоуровневых

признаков, которые в свою очередь являются элементарными признаками для последующих слоев. Последний слой определяет категорию изображения.

Трансферное обучение в случае классифицирования изображений ЛА позволяет повторно натренировать последний слой такой CNN-сети с помощью собственного набора изображений в приемлемое время, не изменяя веса других слоев и достигая необходимую точность.

Еще одно преимущество трансферного обучения – это то, что для дополнительной тренировки последнего слоя CNN-сети необходимо не такое большое количество данных, как при тренировке с нуля, так как требуется настроить меньшее количество весов.

IV. ГЕНЕРАЦИЯ ИЗОБРАЖЕНИЙ ДЛЯ ОБУЧЕНИЯ

Для генерации исходных изображений ЛА были использованы сеточные трехмерные модели ЛА как на рис. 2.




Рис. 2. Сеточная трехмерная модель самолетам

Для данной задачи использовались модели для определения одного из классов: самолет, БПЛА, вертолет, квадрокоптер (Рис. 3). Были использованы различные виды ЛА для каждого класса.



Рис. 3. Трехмерные модели основных типов ЛА для классификации

Эти модели для анимации были включены в проект для Unity — среды разработки компьютерных игр. Программное управление положением ЛА в игровой среде позволило подготовить несколько сотен изображений под разными углами. Эти наборы были

дополнены реалистическими изображениями из Интернета.

V. ОБУЧЕНИЕ НЕРОСЕТЕВОГО КЛАССИФИКАТОРА

Решением описанных проблем определения типа летательного аппарата является трансферное обучение глубоких нейронных сетей, позволяющий использовать предварительно обученную (даже для других классов объектов) сеть для построения классификаторов изображений ЛА. В качестве базовой предобученной сети использовалась сеть Inception v3.

Трансферное обучение предполагает решение двух задач: изменение архитектуры НС и обучение измененной сети. Изменение архитектуры заключалось в замене последнего классифицирующего слоя на слой с 4 элементами (по числу типов ЛА). Числовое значение выходов последнего слоя определяет вероятность отнесения входного изображения соответствующему классу.

В процессе обучения были «заморожены» веса всех нейронов предварительно обученной на изображениях ImageNet модели кроме нейронов последнего, слоя. 4000 эпох обучения позволили получить решение задачи классификации. Процесс оценки качества классификации и ошибки в ходе обучения приведены на рис. 4.

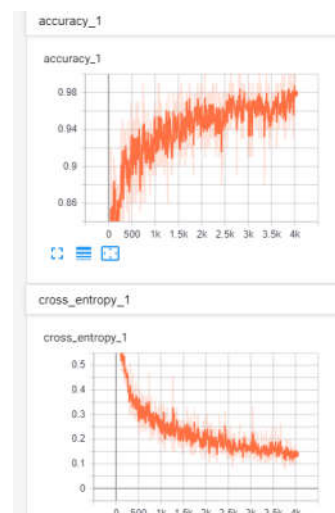


Рис. 4. График оценки качества классификации и ошибки в процессе обучения

Результаты работы классификатора на реальных изображениях на рис 5.



Рис. 5. Результаты работы классификатора на реальных изображениях

Программное обеспечение для проекта разработано в части трехмерного моделирования на C# в Unity. Программы обучения сети и ее использования для классификации написаны на Python с использованием библиотеки TensorFlow.

VI. ВЫВОДЫ

Предложенный подход позволяет получить решение поставленной задачи с достаточно высокой степенью точности на модельных данных. Для решения задачи в реальных условиях этот способ может быть предложен как один из методов, который вместе с другими методами (например, определения динамических характеристик

полета по видеоряду изображений) позволит получить правильное решение поставленной задачи.

ЛИТЕРАТУРА REFERENCES

- [1] Dharti Dhami «Object Detection/Localization Algorithms» Nov 25, 2018 [Online]. Available: <https://medium.com/@dhartidhami/object-detection-localization-algorithms-e55b19259cbf>
- [2] Huihui Li, Xing Jin, Ning Yang, Zhe Yang The recognition of landed aircrafts based on PCNN model and affine moment invariants/ Pattern Recognition Letters 2015 / 01 Vol. 51
- [3] Rong, Hai-Jun, Jia, Ya-Xin, Zhao, Guang-She “Aircraft recognition using modular extreme learning machine” Neurocomputing 2014 / 03 Vol. 128
- [4] Li W, Bebis G, Bourbakis NG. “3D object recognition using 2D Views”./ IEEE Trans Image Process 2008;17(11):2236–54.
- [5] Wei, Zhenzhong, Liu, Chang, Li, Nan “Weighted Marginal Fisher Analysis with Spatially Smooth for aircraft recognition”/ Volume: 27 Journal: Chinese Journal of Aeronautics, February, 2014
- [6] Krizhevsky, Alex & Sutskever, Ilya & E. Hinton, Geoffrey. (2012).” ImageNet Classification with Deep Convolutional Neural Networks.”/ Neural Information Processing Systems. 25. 10.1145/3065386.
- [7] Mash, Robert, Becherer, Nicholas, Woolley, Brian, Pecarina, John ” Toward aircraft recognition with convolutional neural networks”/ [IEEE 2016 IEEE National Aerospace and Electronics Conference (NAECON) and Ohio Innovation Summit (OIS) - Dayton, OH, USA (2016.7.25-2016.7.29)]
- [8] “How to Retrain an Image Classifier for New Categories” 2018 [Online]. Available: https://www.tensorflow.org/hub/tutorials/image_retraining
- [9] Szegedy, Christian, Vanhoucke, Vincent, Ioffe, Sergey, Shlens, Jon, Wojna, Zbigniew ” Rethinking the Inception Architecture for Computer Vision”/ [IEEE 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR) - Las Vegas, NV, USA (2016.6.27-2016.6.30)] 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)