

НЕЙРОСЕТЕВАЯ СИСТЕМА РАСПОЗНАВАНИЯ И КЛАССИФИКАЦИИ ВИДОВОГО СОСТАВА ЛЕСНОГО МАССИВА

Хацкевич М.В., Пархоць А.В.

Брестский государственный технический университет, Брест

Целью настоящей работы является разработка системы распознавания и классификации деревьев в лесном массиве.

Объект исследования – процесс исследования видового состава лесных насаждений.

Предмет исследования – средства реализации нейронной сети, методы классификации и распознавания.

Встречаются следующие основные группы типов леса:

- лиственные леса умеренного пояса;
- мелколиственные леса, в которых преобладающие древесные породы имеют мелкие листовые пластинки. Это берёзовые, осиновые и ольховые леса;
- хвойные леса — леса, состоящие почти исключительно из деревьев хвойных древесных пород;
- смешанные леса — леса, в которых растут как лиственные, так и хвойные деревья.

Исследование лесов – одна из важнейших задач науки на сегодняшний день. В первую очередь это связано с экологией, а именно с сильным изменением климата. При сжигании топлива в атмосферу выделяется углекислый газ, высокая концентрация которого приводит к глобальному потеплению и изменению климата Земли. Деревья и леса помогают смягчить последствия климатических изменений. Именно поэтому ученым в совершенно разных областях иногда просто необходимо проводить анализ леса. И разработка системы, способной на анализ с высоты, позволит сократить затраченное на исследования время в несколько раз.

Определение видового состава леса относится к решению задачи распознавания и классификации.

Для решения задачи распознавания крон деревьев был выбран пакет DeepForest, предназначенный для обучения и прогнозирования отдельных крон деревьев по изображениям. Данная библиотека построена на базе сверточной нейронной сети RetinaNet [1].

Архитектура RetinaNet представлена на рисунке 1 и состоит из 4 основных частей, каждая из которых имеет своё назначение:

1. Backbone – основная (базовая) сеть, служащая для извлечения признаков из поступающего на вход изображения. Данная часть сети является вариативной и в её основу могут входить классификационные нейросети, такие как ResNet, VGG, EfficientNet и другие.

2. Feature Pyramid Net (FPN) – свёрточная нейронная сеть, построенная в виде пирамиды, служащая для объединения достоинств карт признаков нижних и верхних уровней сети, первые имеют высокое разрешение, но низкую семантическую, обобщающую способность, а вторые – наоборот.

3. Classification Subnet – подсеть, извлекающая из FPN информацию о классах объектов, решая задачу классификации.

4. Regression Subnet – подсеть, извлекающая из FPN информацию о координатах объектов на изображении, решая задачу регрессии.

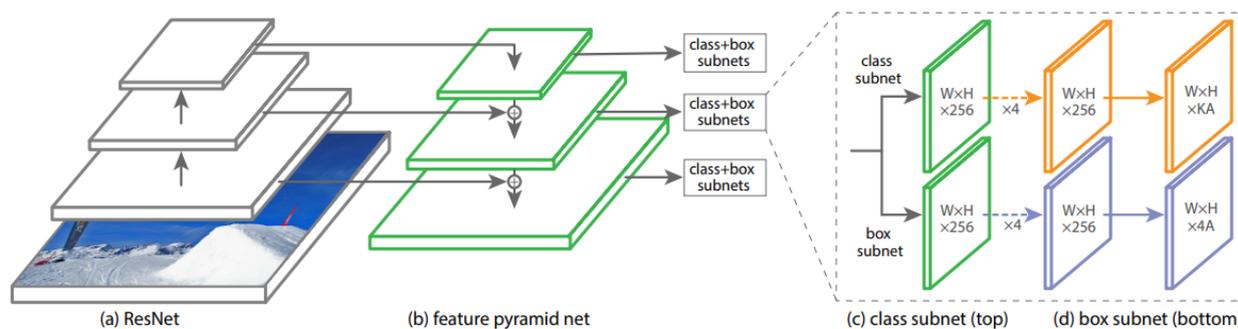


Рисунок 1 – Архитектура RetinaNet

Для решения задачи классификации были выбраны следующие архитектуры:

- VGG16;
- SqueezeNet;
- Inception V3.

Итоговый датасет для классификации включал в себя 10221 изображение, среди которых 980 объектов относились к классу Other. Датасет был разбит на обучающую и тестовую выборку в соотношении 80 % и 20 % соответственно.

На рисунке 2 продемонстрировано сравнение в точности классификации обученных на составленном датасете нейронных сетей по каждому. Самым проблемным классом оказался Other (в который попали все объекты, не относящиеся ни к одному из 4 классов). Лучшим вариантом оказалась архитектура Inception v3 точность которой составила 87 %, на втором месте SqueezeNet с точностью 76%, на третьем – VGG16 с точностью 69 %.

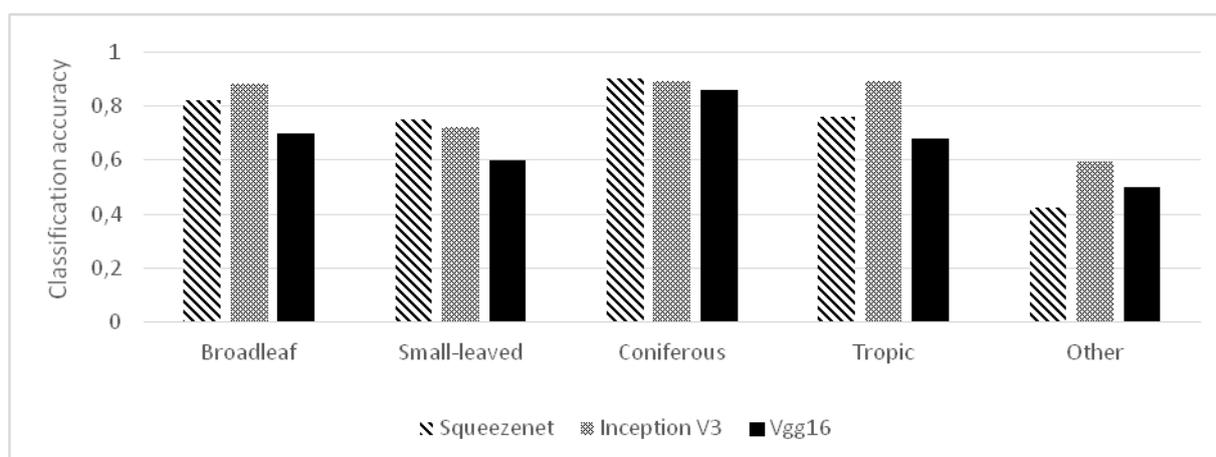


Рисунок 2 – Сравнение обученных нейронных сетей по точности

Основное преимущество данного метода заключается в том, что он повышает качество классификации, т.к. появляется возможность сбора большего количества данных для обучения. Для обучения классификатора не требуется

ручной разметки объектов на изображении. Для обучения классификатора необходимо только наличие самих изображений объектов.

Основным недостатком метода является то, что он так и не решает проблему с ложными срабатываниями. Это связано с тем, что класс Other получился слишком разнообразным и найти общие признаки среди экземпляров данного класса для нейронных сетей не предоставляется возможным.

Для тестирования была составлена тестовая выборка из 20 изображений и использовался лучший из рассмотренных классификаторов.

При использовании изображения леса в основном из широколиственных пород, а также мелколиственных пород в меньшей степени (см. рис. 3), были получены: точность детектирования 94 %, а классификации – 90 %. Система правильно распознала типы деревьев.

При использовании изображения леса, состоящего в основном из хвойных деревьев (см. рис. 4), были получены: точность детектирования 90 %, а классификации – 88 %. Система правильно распознала преобладающий тип деревьев.



Рисунок 3 – Результат работы программы на изображении леса, состоящего в основном из широколиственных пород и мелколиственных пород в меньшей степени



Рисунок 4 – Результат работы программы на изображении леса, состоящего в основном из хвойных деревьев

Список цитированных источников

1. Deepforest [Электронный ресурс]. – Режим доступа: – <https://deepforest.readthedocs.io/en/latest/landing.html> – Дата доступа: 16.05.2021
2. Machinelearningmastery [Электронный ресурс]. – Режим доступа: – <https://www.machinelearningmastery.ru/object-detection-on-aerial-imagery-using-retinanet-626130ba2203/> – Дата доступа: 16.05.2021
3. Towardsdatascience [Электронный ресурс]. – Режим доступа: – <https://towardsdatascience.com/review-squeezenet-image-classification-e7414825581a> – Дата доступа: 20.05.2021
4. Arxiv [Электронный ресурс]. – Режим доступа: – <https://arxiv.org/pdf/1810.00736.pdf> - Дата доступа: 21.05.2021

УДК 656.13

ОБРАБОТКА ДАННЫХ В ГОРОДСКОЙ ПАССАЖИРСКОЙ ИНФОРМАЦИОННО-ТРАНСПОРТНОЙ СИСТЕМЕ НА БАЗЕ БЕСПИЛОТНЫХ ЭЛЕКТРОКАРОВ

Е.В. Швецова,

Брестский государственный технический университет, г. Брест

Научный руководитель: В. Н. Шуть, к. т. н., доцент

Для современные городских пассажирских перевозок характерен такой существенный недостаток, как неэффективное принятие решений диспетчеризации вследствие отсутствия своевременной и адекватной информации либо использования ограниченной выборки исторических данных о пассажиропотоках на маршрутах. Данный недостаток может быть эффективно нивелирован с помощью внедрения информационно-транспортных систем (ИТС)[1], способных осуществлять сбор и анализ данных о пассажиропотоке в режиме реального времени, а также осуществлять диспетчеризацию при минимальном участии человека. В данной работе предлагаются основные принципы построения сбора и анализа данных в таких транспортных системах.

При осуществлении перевозок в предлагаемой информационно-транспортной системе все время последовательно протекают процессы *сбора заявок, составления плана перевозки и выполнения плана перевозки* [2], образующие цикл функционирования ИТС. Поступающие заявки на перевозку передаются в единый информационный сервер ИТС (ИС ИТС), являющийся программно-аппаратным комплексом, отвечающим за сбор, анализ заявок и управление перевозкой в режиме реального времени.

Структурно ИС ИТС состоит из систем: сбора заявок (ССЗ), анализа данных (САД) и организации перевозок (СОП), рис.1.



Рисунок 1 – Структура ИС ИТС