

- Директория Computers, компоненты которой отвечают за отображение доступных компьютеров, их аппаратного и программного обеспечения, а также за добавления новых компьютеров.
 - Директория Files, компоненты которой отвечают за отображение файлов, хранящихся на сервере и за добавление новых файлов.
 - Директория Requests, компоненты которой отвечают за отображение запросов, хранящихся на сервере и за добавление новых запросов.
 - Директория Users, компоненты которой отвечают за отображения пользователей, зарегистрировавшихся в системе, а также за регистрация новых пользователей и авторизацию.
 - Директория NavBar, компоненты которой отвечают за навигацию в приложении.
- Сервер для централизованной обработки представляет собой Spring Boot[2] приложение с базой данных, взаимодействующее с веб-клиентом и сервисами на компьютерах.

Архитектура приложения имеет следующие директории:

- controllers – хранит классы обрабатывающие пользовательские запросы.
 - service – основной модуль приложения, обрабатывающий данные в соответствии с бизнес логикой приложения.
 - entity – хранит описание сущностей, хранящихся в базе данных.
 - repository – обеспечивает доступ к базе данных.
- В приложении используются такие расширения как:
- Google Guava – упрощает описание сущностей и имеет большое количество средств для работ с коллекциями
 - Lombok – предоставляет функционал способствующий уменьшению количества и читабельности кода.

Заключение. Была спроектирована, разработана и протестирована система позволяющая упростить отслеживание актуального состояния программного и аппаратного обеспечения. Система является полезным инструментом администрирования большого количества компьютеров.

1. Сервисы Windows [Электронный ресурс] – 2019. – Режим доступа: <https://docs.microsoft.com/en-us/dotnet/framework/windows-services/>. – Дата доступа: 25.02.2019
2. Документация по Spring Boot [Электронный ресурс] – 2019. – Режим доступа: <https://docs.spring.io/spring-boot/docs/current/reference/htmlsingle/>. – Дата доступа: 26.02.2019

ИСПОЛЬЗОВАНИЕ НЕЙРОННЫХ СЕТЕЙ ДЛЯ РАСПОЗНАВАНИЯ РАСТЕНИЙ ПО ФОТОГРАФИЯМ РОСТКОВ

Шульгин И.В.,

студент 4 курса ВГУ имени П.М. Машерова, г. Витебск, Республика Беларусь

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

Необходимость автоматического определения вида растения по фотографиям его ростков возникает в сельском хозяйстве в связи с необходимостью обнаружения сорняков и составления их карт [1].

За последние десятилетия был разработан ряд архитектур глубоких сверточных нейронных сетей, таких как Inception (GoogleNet) и ResNet [2], предназначенных для эффективного распознавания образов.

Цель настоящей работы – установить, какие архитектуры глубоких нейронных сетей пригодны для распознавания растений по фотографиям их ростков и, в частности, для выявления среди них сорняков.

Материал и методы. Для обучения нейронной сети использовался набор данных, размещенный в открытом доступе [3]. Он включает в себя 4750 фотографий ростков 12 видов растений. Примеры изображений показаны на рисунке 1. Для обучений нейронной сети использовалось 70% изображений, оставшаяся часть – для тестирования сети.

Эксперимент проводился для нескольких нейросетевых моделей: ResNet с разным количеством слоёв (18, 34, 50, 101 и 152), AlexNet, VGG19, Densenet121 и Inception-v3.

Обучение нейросетевой модели осуществлялось по методу «переноса обучения» (transfer learning), который заключается в использовании весов нейросетевых моделей, обученных ранее на других изображениях. В нашем случае использовался набор данных ImageNet. В качестве оптимизатора использовался Adagrad с коэффициентом обучения 0,0005.

Результаты и их обсуждение. В таблице 1 приведены значения точности классификации вида растения из тестовой выборки различными нейросетевыми моделями после 20 эпох обучения. В данном случае все модели являлись предобученными на данных ImageNet, а оптимизация проводилась для всех слоёв сети. Наилучший результат показала модель ResNet101 – она дала 97,78% правильных ответов на тестовом наборе.



Рисунок 1 – Примеры изображений из обучающей выборки

Таблица 1 – Точность распознавания на тестовой выборке

Модель нейронной сети	Количество слоёв	Точность классификации, %
AlexNet	8	92,11%
VGG19	19	93,56%
ResNet18	18	96,11%
ResNet34	34	96,46%
ResNet50	50	97,25%
ResNet101	101	97,78%
ResNet152	152	97,01%
DenseNet121	121	97,18%
Inception-V3	48	94,10%

Для демонстрации эффективности применения «переноса обучения» были построены зависимости обучения нейросетевой модели ResNet101 при разных начальных значениях весов слоёв (рисунок 2): линия 1 – использовались предобученные на ImageNet веса, линия 2 – использовались случайно сгенерированные начальные веса.

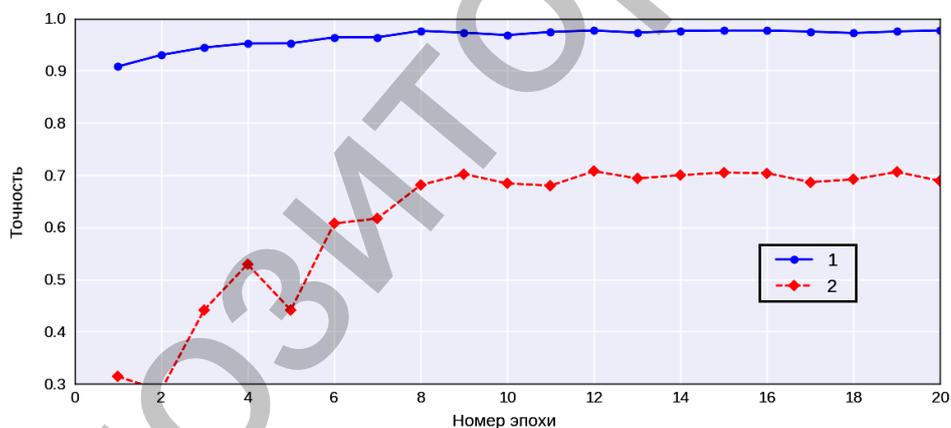


Рисунок 2 – Зависимость точности распознавания от номера эпохи:
1 – предобученная модель, 2 – со случайными начальными весами

Из результатов видно, что использование предобученных моделей даёт выигрыш не только в более быстром обучении, то в итоговой точности распознавания. В нашем случае прирост в точности от использования предобученной модели составил около 27%.

Заключение. Технология переноса обучения, которая заключается в использовании моделей нейронных сетей, обученных ранее на других наборах изображений, даёт существенный прирост в точности распознавания на новых данных. С помощью этого подхода нами была получена точность 97,78% в задаче определения вида растения по фотографиям его ростков.

1. Giselsson, T.M. A Public Image Database for Benchmark of Plant Seedling Classification Algorithms / T.M. Giselsson [et al.] // arXiv.org [Electronic resource]. – Mode of access : <https://arxiv.org/abs/1711.05458>. – Date of access : 26.02.2019.
2. He, K. Deep Residual Learning for Image Recognition / K. He [et al.] // arXiv.org [Electronic resource]. – Mode of access : <https://arxiv.org/abs/1512.03385>. – Date of access : 26.02.2019.
3. Plant Seedlings Dataset // Computer Vision and Biosystems Signal Processing Group [Electronic resource]. – Mode of access : <https://vision.eng.au.dk/plant-seedlings-dataset/>. – Date of access : 26.02.2019.