

5. Guo Y. Fast and Flexible Human Pose Estimation with HyperPose / Y. Guo, J. Liu, G. Li [et al.]. — Text : electronic // MM '21: Proc. of the 29th ACM International Conference on Multimedia. — 2021. — P. 3763-3766. — URL: <https://dl.acm.org/doi/10.1145/3474085.3478325> (date of the application: 26.05.2022).
6. Qi D. YOLO5Face: Why Reinventing a Face Detector / D. Qi, W. Tan, Q. Yao, J. Liu. — Text : electronic // arXiv : [website]. — 2022. — URL: <https://arxiv.org/abs/2105.12931> (date of the application: 26.05.2022).
7. Kolesnikov A. Big Transfer (BiT): General Visual Representation Learning / A. Kolesnikov, L. Beyer, X. Zhai [et al.]. — Text : electronic // arXiv : [website]. — 2019. — URL: <https://arxiv.org/abs/1912.11370> (date of the application: 26.05.2022).
8. cnn-benchmarks. — Text : electronic // Github : [website]. — URL: <https://github.com/jcjohnson/cnn-benchmarks> (date of the application: 26.05.2022).

Д. А. ЗАХАРОВ, И. Г. ЗАХАРОВА

Тюменский государственный университет, г. Тюмень

УДК 004.93

РАЗРАБОТКА СИСТЕМЫ МОНИТОРИНГА СОСТОЯНИЯ ПОКРЫТИЯ ПРОЕЗЖЕЙ ЧАСТИ

***Аннотация.** В статье представлены описание методов обнаружения решения дефектов дорожного покрытия и их программная реализация в рамках системы мониторинга состояния покрытия проезжей части. В качестве основного подхода к решению выбраны создание и применение моделей машинного обучения на базе искусственных нейронных сетей.*

***Ключевые слова:** обнаружение ям, система мониторинга, машинное обучение, нейронные сети, YOLO.*

Введение. С каждым годом растет количество автомобилей и пропорционально этому увеличивается и количество аварий. При этом во многих случаях непосредственной причиной могут послужить серьезные дефекты дорожного покрытия, в частности ямы различных размеров и конфигурации.

Актуальность исследования определяется недостаточной разработкой и практическим применением методов их обнаружения. Идея проекта заключается в применении искусственных нейронных сетей для проведения анализа состояния покрытия проезжей части.

Проблема исследования. Основная цель работы — исследование и программная реализация методов, позволяющих выполнять обнаружение ям на дорогах, с дальнейшим нанесением обнаруженных неровностей на карту для проведения мониторинга состояния дорог.

В рамках проекта были поставлены следующие задачи:

- анализ существующих технических и технологических решений;
- сбор и обработка данных;
- исследование архитектур нейронных сетей для проведения эксперимента;
- разметка данных;
- проведение эксперимента, получение оптимальной модели нейронной сети;
- разработка клиентской и серверной части сервиса для мониторинга ям на карте;
- разработка приложения, которое будет использовать модель нейронной сети, обученную на обнаружение ям на дорогах.

Материалы и методы. Главное преимущество нейронных сетей перед традиционными алгоритмами — они не программируются, а обучаются. В процессе обучения нейронная сеть способна выявлять сложные зависимости между входными данными и выходными, а также выполнять обобщение. Это значит, что в случае успешного обучения сеть сможет вернуть верный результат на основании данных, которые отсутствовали в обучающей выборке, а также неполных или «зашумленных», частично искаженных данных [1].

При помощи методов, основанных на применении технологий компьютерного зрения и машинного обучения, можно получить оптимальный результат при небольших затратах в отличие от применения лазерного сканирования или обработке данных с акселерометра.

В работе использовался набор данных о ямах, составленный на факультете электротехники и электроники Стелленбосского университета. Набор данных состоит из двух разных выборок, одна из которых считается простой, а другая более сложной. Эти выборки могут иметь общие файлы, и есть несколько случаев, когда два разных изображения будут иметь одно и то же имя. Поэтому на этапе обработки исходных данных все изображения были помещены в один каталог, отсортированы по размеру с последующим удалением дубликатов.

Облачный инструмент Roboflow был выбран для разметки данных. Кроме разметки данных, данный инструмент позволяет выполнить предобработку набора данных и процесс его аугментации, за счет применения различных фильтров к изображениям.

В качестве моделей для обучения нейронной сети были выбраны одни из последних моделей с архитектурами Scaled-YOLOv4 [2] (рис. 1) и YOLOv5 [3].

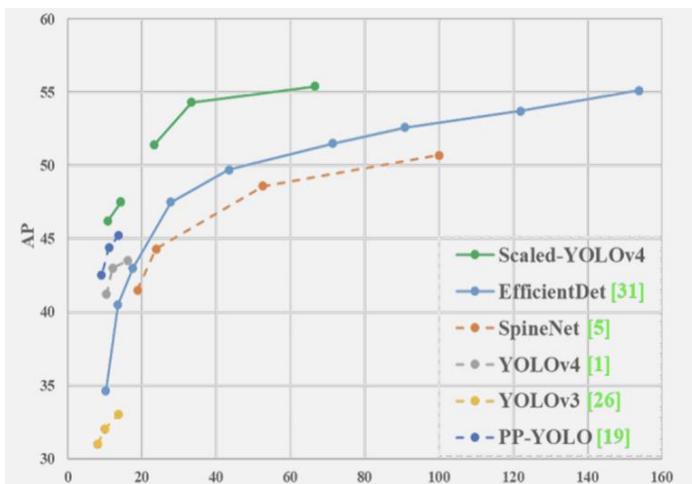


Рис. 1. Средняя точность модели Scaled-YOLOv4 на наборе данных MS COCO

YOLOv5 — это новейшая модель обнаружения объектов, разработанная ultralytics той же компанией, которая разработала PyTorch

версию YOLOv3 и была выпущена в июне 2020 г. [4]. Модель YOLOv5 доступна в четырех вариациях — small, medium, large, x-large, каждая из которых показывает свою точность при фиксированной производительности (рис. 2).

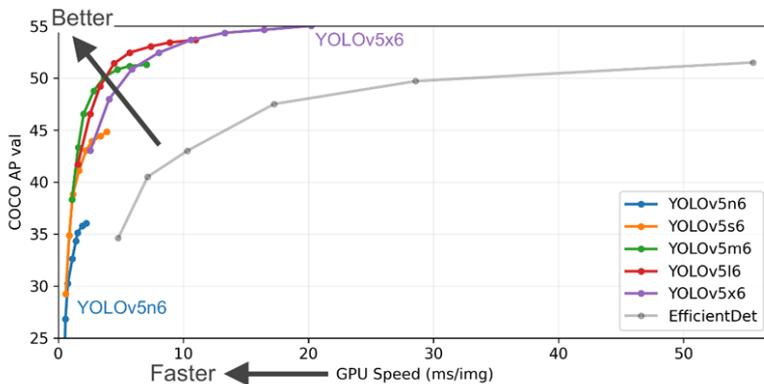


Рис. 2. Средняя точность модели YOLOv5 на наборе данных MS COCO

Ввиду того, что процесс обучения ограничивался определенными техническими ресурсами, модели обучались с различными обучающими параметрами: чем больше параметров в модели нейронной сети, тем меньше размер обучающей выборки, поскольку тяжелые модели при большей обучающей выборке требуют большей вычислительной мощности. В табл. 1 представлен список моделей и параметров, которые использовались при их обучении.

Таблица 1

Список моделей и параметров их обучения

| Модель | Размер изображений (image size) | Размер партий (batch size) | Количество эпох |
|----------|---------------------------------|----------------------------|-----------------|
| 1 | 2 | 3 | 4 |
| YOLOv5n6 | 1280px | 64 | 300 |
| YOLOv5s | 640px | 128 | |
| YOLOv5s6 | 1280px | 32 | |
| YOLOv5m | 640px | 64 | |

| 1 | 2 | 3 | 4 |
|------------------|--------|----|-----|
| YOLOv5l | 640px | 64 | 300 |
| YOLOv5l6 | 1280px | 16 | |
| YOLOv5x | 640px | 64 | |
| YOLOv5x6 | 1280px | 16 | |
| Scaled-YOLOv4-P6 | 1280px | 16 | |

Результаты. По результатам тестирования наибольшую точность показала модель YOLOv5l6. Результаты обучения моделей YOLOv5 представлены на рис. 3 и 4. Модель Scaled-YOLOv4 продемонстрировала точность ниже 0.6.

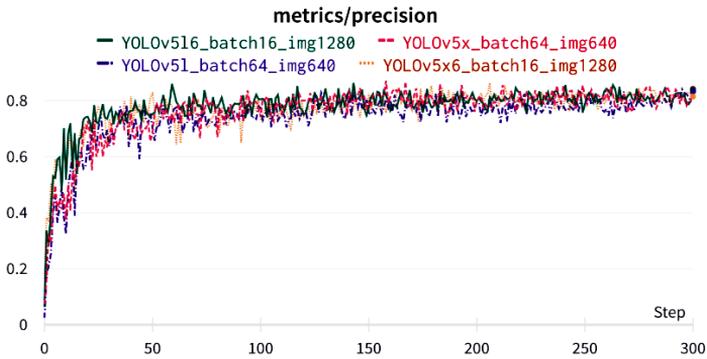


Рис. 3. Результаты обучения моделей YOLOv5

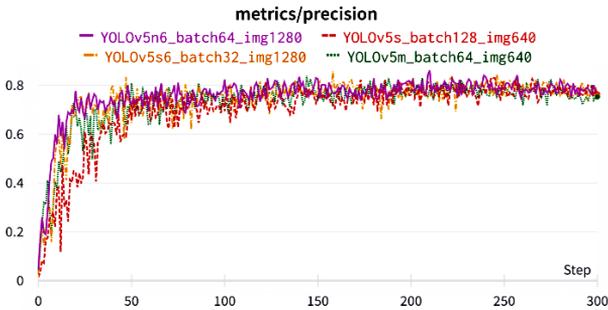


Рис. 4. Результаты обучения моделей YOLOv5

На рис. 5 представлены результаты обработки снимка моделью YOLOv516.

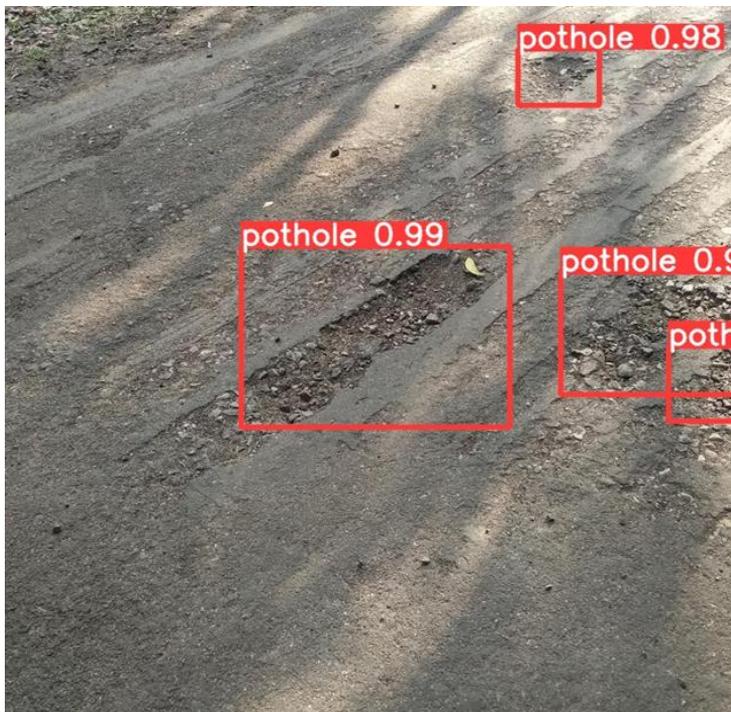


Рис. 5. Результаты работы модели YOLOv516

Для мониторинга неровностей на карте был разработан сервис, архитектура которого представлена на рис. 6.

Устройство обнаружения, которое использует полученную в результате эксперимента модель нейронной сети, отправляет на серверную часть приложения снимки всех обнаруженных ям, с их местоположением и описанием (обнаруженные области на снимках, точность). Клиентская часть приложения при помощи использования сервиса Mapbox [5] наносит ямы на карту (рис. 7).

СПИСОК ЛИТЕРАТУРЫ

1. Реализация искусственных нейронных сетей в Линукс: научный журнал Novainfo : [сайт]. — URL: <https://novainfo.ru/article/2010>. — Текст : электронный.
2. Scaled-YOLOv4 : [сайт]. — URL: <https://github.com/WongKinYiu/ScaledYOLOv4> (дата обращения: 16.05.2022). — Текст : электронный.
3. YOLOv5 : [сайт]. — URL: <https://github.com/ultralytics/yolov5> (дата обращения: 16.05.2022). — Текст : электронный.
4. D. Cochard. YOLOv5: The Latest Model for Object Detection : [сайт]. — URL: <https://medium.com/axincai/yolov5-the-latest-model-for-object-detection-b13320ec516b>. — Текст : электронный.
5. Documentation Mapbox : [сайт]. — URL: <https://docs.mapbox.com/> (дата обращения: 16.05.2022). — Текст : электронный.

А. И. СТРЕЛЬНИКОВ, М. С. ВОРОБЬЕВА

Тюменский государственный университет, г. Тюмень

УДК 004.912

ИССЛЕДОВАНИЕ МЕТОДОВ АНАЛИЗА ИНФОРМАЦИОННОЙ И ЛЕКСИЧЕСКОЙ НАСЫЩЕННОСТИ НАУЧНЫХ ТЕКСТОВ

***Аннотация.** В статье представлен обзор существующих методов анализа информационной и лексической насыщенности. Выдвинута гипотеза корреляции критериев лексической и информационной насыщенности. Гипотеза проверена на основе результатов анализа 752 ВКР студентов ИМиКН за 6 лет обучения.*

***Ключевые слова:** информационная насыщенность, информативность, абстрактность, водность, плотность ключевых слов, лексическая насыщенность, лексическое многообразие, лексическая сложность.*

Введение. При написании текстов научного стиля авторы заинтересованы в повышении информационной насыщенности своих работ при сохранении понятности для читателя. Необходимо провести исследование методов определения информационной насыщенности и факторов, влияющих на насыщенность. Авторы Ю. В. Морозова и И. А. Уртамова в статье [1] и Н. К. Криони и др. в статье [2]