

Мишенин Н. А.
асс.,
Кротов К. К.
магистрант,
Гвоздецкий Д. С.
магистрант

Донбасский государственный технический университет, г. Алчевск, ЛНР, Россия

ОЦЕНКА ПРОИЗВОДИТЕЛЬНОСТИ МОДЕЛИ YOLO V5 ПРИ ОБНАРУЖЕНИИ ПОВРЕЖДЕНИЙ ДОРОЖНОГО ПОЛОТНА

Постановка проблемы. Дорожная инфраструктура быстро строится и развивается для удовлетворения транспортных потребностей и улучшения социально-экономического развития. И хотя, можно сказать, что строительство новых дорог является необходимым, быстрое и точное обнаружение повреждений дорог позволяет дорожно-эксплуатационным организациям своевременно производить ремонт дорожного покрытия, поддерживать оптимальное состояние дорог, оптимизировать безопасность перевозок и минимизировать транспортные расходы. Следовательно, возникает потребность в исследовании автоматизированного инструмента проверки, который может помочь в более эффективном выявлении поврежденных участков.

Анализ последних исследований и публикаций. Плохие дорожные условия вызывают множество проблем, в том числе создают проблемы с навигацией по дорогам и повышают риск несчастных случаев для водителей, увеличивают затраты на ремонт транспортных средств, использующих эти дороги, и, в конечном итоге, увеличивают затраты на ремонт дорог из-за необратимого износа дорожных покрытий и оснований. В исследованиях проводимых Оума и Хан и Гавилан, Балконес, Маркос, Льюрка, Сотело, Парра, Оканья, Алиседа, Ярза и Амирола делаются выводы, что своевременное и правильное содержание дорог может на 20 % снизить стоимость проводимого обслуживания дорожного покрытия. Это представляет собой потенциальную значительную экономию расходов.

Изложение основного материала. Существующие методы мониторинга состояния дорожного покрытия подразделяют на три типа в зависимости от регистрирующего оборудования: лазерное 3D-сканирование, вибрационная диагностика и съемка 2D-видео [1]. В последние десятилетия наиболее перспективным и распространенным способом выделения дефектов является подход на основе анализа изображений автомобильных дорог ввиду невысоких затрат по получению таких данных и бурному развитию различных технологий компьютерного зрения [2].

Несмотря на улучшения, обнаружение дефектов дорожного полотна на основе двумерных изображений остается сложной задачей из-за различных проблем, включающих неоднородности и интенсивности повреждений и сложности фона на изображениях, например, из-за слабого контраста дорожного покрытия и возможных теней с аналогичной интенсивностью. Эти трудности могут привести к плохой работе методов, основанных на пороге интенсивности, что приведет к возникновению большого количества ложноотрицательных и ложноположительных результатов. В последнее время усилия по обнаружению локальных границ повреждений были сосредоточены на обнаружении контуров повреждений с использованием преобразования Хаара (FHT), быстрого преобразования Фурье (FFT).

В последнее время наиболее эффективным подходом для обнаружения дефектов дорожного полотна были признаны модели, основанные на глубоком обучении. Более того, алгоритм глубокого обучения (DL), который автоматически и иерархически извлекает репрезентативные и отличительные признаки от нижнего уровня (например, края и текстуры) до верхнего уровня (основного признака), стал основным объектом исследовательского интереса и усилий в данном направлении. Развитие глубоких архитектур сверточных нейронных

сетей, таких как Faster R-CNN, YOLO, SSD, MobileNet, Inception, позволило сократить вычислительные и временные затраты при определении местоположения дефекта на изображении и его классификации одновременно с увеличением точности.

Учитывая, что различные виды дефектов требуют различных видов ремонта, их точная классификация становится решающей для эффективного распределения ресурсов на техническое обслуживание. Набор данных, используемый для оценки производительности модели, должен включать экземпляры каждого дефекта при одинаковых обстоятельствах. Для обучения и проверки восьми моделей обнаружения и Yolo V5 в рамках этого исследования, был использован набор данных, включающий 9053 изображения, полученные из предыдущего исследования Маэды, Секимото, Сето, Касиямы и Оматы [3]. В этом исследовании трещины были разделены на четыре категории. Категория I, включает в себя боковые трещины, вызванные перепадами температур, а также растрескивание асфальтового связующего в результате нижележащих трещин и разрушение строительных швов. Категория II, насчитывающая, включает продольные усталостные трещины (часто возникающие в результате перегрузки от грузовых автомобилей) и некачественными конструктивными швами. Категория III охватывает трещины возникающие в результате различных факторов усталости и нестабильности асфальтового основания. Наконец, категория IV относится к выбоинам, разломам, неровностям и колеям. Они характеризуются глубокими впадинами, возникающими в результате обширного повреждения водой или не устраненных трещин. V категория включает размытие дорожной разметки.

Оценка производительности. В этой работе в качестве основного критерия была принята средняя точность (mAP). Значение mAP — это метрика, используемая для оценки производительности моделей обнаружения объектов

В задаче обнаружения объектов mAP измеряет способность правильно классифицировать и точно определять местоположение объектов. Модель оценивается на основе расчета точности предлагаемых ограничивающих рамок по сравнению с фактическими ограничивающими рамками в наборе тестовых данных. Сравнение значений mAP между моделями позволяет нам определить, какая модель имеет лучшую производительность при обнаружении объектов в наборах тестовых данных.

Делая вывод из полученных в таблицах 1 и 2 данных, можно сделать вывод, что все модели обнаружения, реализующие Faster R-CNN, превосходят модели, использующие детектор SSD, исключая только Yolo V5. Среди перечисленных моделей Faster R-CNN Inception ResNet V2 продемонстрировала наиболее примечательный средний показатель mAP — 27,66 %, за ним следуют Faster R-CNN ResNet 50 и Faster R-CNN Inception V2, которые достигли значений mAP 27,35 % и 26,45 % соответственно. Напротив, модели обнаружения SSD постоянно демонстрировали более низкие показатели mAP (20 %). Модель Yolo V5, дала исключительный показатель mAP — 40,72 % и достигла самого высокого значения AR — 75,61 %.

Таблица 1 — Сравнение показателей средней точности (mAP) для разных моделей

Модель	mAP (%)					
	Малые	Средние	Большие	@.50IoU	@.75IoU	Среднее
YOLO V5	80,26	87,20	89,50	80,19	38,90	40,72
SSD MobileNet-V1	0,00	5,32	18,45	35,81	13,2	16,47
SSD MobileNet-V2	0,00	6,3	21,1	38,7	16,34	18,81
SSD Inception-V2	0,00	6,6	22,25	40,54	16,57	19,45
SSD Lite-MobiNet-V2	0,00	6,57	18,93	36,58	14,43	17,1
Faster R-CNN Inception-V2	3,97	12,08	30,17	51,86	24,18	26,45
Faster R-CNN ResNet-50	10,23	10,56	30,25	51,25	23,73	26,08
Faster R-CNN ResNet-101	4,61	11,73	31,06	52,85	24,15	27,35
Faster R-CNN Inception-Resnet-V2	8,07	14,14	31,26	54,75	24,94	27,66

Таблица 2 — Значения AR сравнительных моделей

Модель	AR@1 (%)	AR@10 (%)	AR@100 mAP (%)			
			Малые	Средние	Большие	Среднее
YOLO V5	73,20	75,61	75,50	80,21	83,87	74,52
SSD MobileNet-V1	22,82	34,90	0,00	20,24	42,30	37,31
SSD MobileNet-V2	25,04	37,81	0,00	23,56	44,17	40,51
SSD Inception-V2	26,01	38,66	0,00	23,40	46,61	41,44
SSD Lite-MobiNet-V2	23,29	35,82	0,00	26,25	41,15	38,91
Faster R-CNN Inception-V2	33,61	49,82	16,00	41,10	58,05	53,06
Faster R-CNN ResNet-50	32,88	47,98	11,00	36,62	57,15	51,33
Faster R-CNN ResNet-101	33,78	48,82	19,00	41,15	56,99	52,06
Faster R-CNN Inception-Resnet-V2	34,41	49,27	23,67	38,14	56,73	51,45

Выводы. На этапе эксплуатации и использования качество дороги имеет важное значение не только для обеспечения эффективной транспортировки и бесперебойного потока грузов, но и для безопасности всех участников дорожного движения. Даже небольшие признаки повреждений, какими бы незначительными они ни были, потенциально могут привести к серьезным авариям. Быстрое обнаружение этих повреждений имеет жизненно важное значение, поскольку оно обеспечивает как безопасность участников дорожного движения, так и помогает более эффективно распределять бюджеты на техническое обслуживание и ремонт.

Делая вывод из проведенного сравнительного анализа, можно сделать вывод, что Yolo V5 является лучшей версией модели с точки зрения точности при обнаружении поврежденных участков дорожной инфраструктуры.

Список источников

1. Azimi M., Eslamlou A., Pekcan G. Data-driven structural health monitoring and damage detection through deep learning: State-of-the-art review // *Sensors*. 2020. Vol. 20. Iss. 10. P. 2778.
2. Канаева И. А., Иванова Ю. А., Спицын В. Г. Сегментация дефектов дорожного покрытия на основе формирования синтетических выборок с помощью глубоких генеративно-сопоставительных сверточных сетей // *Компьютерная оптика*. 2021. № 6. С. 907–916.
3. Road damage detection and classification using deep neural networks with smartphone images / H. Maeda [et al.] // *Computer-Aided Civil and Infrastructure Engineering*. 2018. Vol. 33. Iss. 12. P. 1127–1141.