

Научная статья
УДК 625.089.2

АВТОМАТИЗИРОВАННОЕ ОБНАРУЖЕНИЕ ДЕФЕКТОВ НА ДОРОЖНОМ ПОЛОТНЕ С ПРИМЕНЕНИЕМ СВЕРТОЧНЫХ НЕЙРОННЫХ СЕТЕЙ

Никита Юрьевич Мокрушин¹, Даниил Владимирович Сперанский²,
Сергей Александрович Чудинов³

^{1, 2, 3} Уральский государственный лесотехнический университет,

Екатеринбург, Россия

¹ mokrushinnikita621@mail.ru

² greatto69@gmail.com

³ chudinovsa@m.usfeu.ru

Аннотация. В работе представлен новый метод, основанный на глубоком обучении для обнаружения повреждений на дорожном полотне по изображениям, сделанным с помощью смартфона, установленного на транспортном средстве. Для решения этой задачи была применена модель сверточной нейронной сети. Степень соответствия, полученная на анализе этих данных, подтверждает результативность модели обнаружения дефектов, а также демонстрирует ее преимущество над другими методами машинного обучения.

Ключевые слова: дорожное полотно, дефекты, сверточные нейронные сети, машинное обучение

Original article

AUTOMATED DETECTION OF ROADWAY DEFECTS USING CONVOLUTIONAL NEURAL NETWORKS

Nikita Yu. Mokrushin¹, Daniil V. Speransky², Sergey A. Chudinov³

^{1, 2, 3} Ural State Forest Engineering University, Yekaterinburg, Russia

¹ mokrushinnikita621@mail.ru

² greatto69@gmail.com

³ chudinovsa@m.usfeu.ru

Abstract. The paper presents a new method based on deep learning to detect damage on the roadway from images taken using a smartphone mounted on a vehicle. To solve this problem, a convolutional neural network model was applied. The degree of compliance obtained from the analysis of these data confirms the effectiveness of the defect detection model, as well as demonstrates its advantage over other machine learning methods.

Keywords: Roadbed, defects, convolutional neural networks, machine learning

Одна из важнейших целей в области технического обслуживания транспорта – автоматическое обнаружение дефектов на дорожном покрытии. Значимость обеспечения безопасности становится вопросом первостепенной важности. Вопреки усилиям и разнообразным методам, проблема обнаружения остается крайне сложной из-за разнообразных и серьезных повреждений, а также из-за высокой степени сложности фона на изображениях. Например, когда контраст между дорожным покрытием и тенями на дороге практически незаметен, это только усиливает сложность ситуации. Вопреки распространенной практике ручного отбора параметров, следует отметить, что существующие процессы обработки недостаточно эффективны для разграничения дефектов дорожного покрытия и сложных фонов на изображениях среднего или низкого разрешения. Существует большой спрос на глубокие сверточные нейронные сети для обучения с учителем. Эти нейронные сети пользуются особым вниманием благодаря их эффективности и эффективности процесса обучения. Подлинное предназначение этих моделей является ключевым стимулом для внедрения глубокого обучения в процессе обнаружения дефектов дорожного покрытия.

Авторитет применения методов глубокого обучения в выявлении повреждений на дорожной поверхности тесно связан со способностью отобранных признаков быть характерными и точными в своем представлении. В процессе проведения исследования был применен инновационный подход к обнаружению дефектов [1]. Использовались сверточные нейронные сети для извлечения основных характеристик из необработанных фрагментов изображения. Этот новый метод позволяет достичь превосходных результатов в выявлении дефектов. Предлагаемый методологический подход находится в центре внимания и отличается наличием четырех основополагающих принципов, которые играют ключевую роль в данном контексте:

- 1) на смену приемникам на основе машинного обучения приходят приемники на основе глубокого использования гибких нейронных сетей;
- 2) при анализе дорожного покрытия не рассматриваются его геометрическая форма и размеры;
- 3) изображения обрабатываются и анализируются автоматически;
- 4) новый метод получает изображения при помощи камеры смартфона, в то время как старые методы используют сложное оптическое оборудование.

С использованием сверточных нейронных сетей, специальной техники обработки информации возможно анализировать изображения дорожного покрытия. Основная цель этой технологии состоит в обнаружении и определении дефектов, которые присутствуют на дорогах, позволяя точно опреде-

лить, является ли каждый пиксель на фотографии поврежденной частью дорожного полотна. Пользуясь базовыми сведениями о поврежденных и целых участках, сеть обучается на квадратных фрагментах изображения, стремясь сформировать уникальный подход к каждому из них. С целью улучшения понимания эти участки текста (с повреждениями и без них) в дальнейшем упоминаются как положительные и отрицательные соответственно. Если в центре и его окрестностях находится поврежденный пиксель, тогда участок признается поврежденным – положительным, в противном случае без повреждений – отрицательным.

При помощи смартфона полученные 500 изображений дорожного покрытия с разрешением 3264×2448 формируют в коллекцию. С целью достижения баланса между расчетной мощностью и степенью соответствия обнаружения дефектов. Информация о каждой выборке передается в трех цветовых каналах (красный, зеленый и синий) с размером 99×99 пикселей [2]. Эти фрагменты изображений, созданные по определенному алгоритму, играют ключевую роль в процессе обработки:

1. Фрагмент считается положительным в том случае, если центр дефекта существует в границах пяти пикселей от центра фрагмента, положительный фрагмент считается отрицательным, если не выполняется первое условие.

2. Небольшое перекрытие между двумя положительными участками $P1$ и $P2$ исключает шанс совпадения обучающих выборок. Такое перекрытие можно определить через соотношение:

$$O = \frac{S_{(P1 \cap P2)}}{S_{(P1 \cup P2)}}, \quad (1)$$

где $S_{(P1 \cap P2)}$ – площадь пересечения двух участков $P1$ (первого участка) и $P2$ (второго участка);

$S_{(P1 \cup P2)}$ – площадь $P1$ (первого участка) и $P2$ (второго участка) вместе.

Для этого была принята стратегия размещения соседних участков, основанная на выборе расстояния между их центрами, которое равно $d = 0,75w$, где w представляет собой ширину каждого участка. В отношении отрицательных участков необходимо обеспечить их неперекрывающееся расположение.

3. Каждый из фрагментов-кандидатов вращается вокруг центра фрагмента в случае, если таковой имеется на случайный угол $\alpha \in [0^\circ; 360^\circ]$. Это существенно влияет на увеличение числа случаев повреждений, так как отклонения составляют всего ничтожную долю от всего собранного материала. Для обучения сети было выбрано 640 000 экземпляров, в то время как

160 000 использовались для кросс-проверки. Оставшиеся 200 000 экземпляров были выделены для тестирования. Набор данных в трех пакетах составлял одинаковое количество изображений.

Основная цель обучения сверточной нейронной сети заключается в достижении двух важных результатов: увеличение разнообразия данных в обучающей выборке и предотвращение переобучения. Обработка тестовых фото сети присваивает части фото вероятность одного из двух событий: первое – повреждение на дорожном полотне, второе – повреждение отсутствует, эта операция называется картой вероятности [3, 4]. Сверточная нейросеть обладает более обширным набором параметров, что позволяет ей проявлять большую вариативность и минимальные ошибки в своей работе. Количество повреждений на дорожном покрытии значительно меньше, чем на фоновом фото. Этот факт приводит к тому, что сеть переоценивает вероятность повреждения. Таким образом, необходимо установить подходящий предел. На рис. 1 и 2 новый метод с использованием сверточной нейронной сети распределяет отобранные изображения с высшей степенью соответствия. Такие заключения демонстрируют особенности нового способа, а также его превосходство над машинными методами в целом.




Рис. 1. Сверточная нейронная сеть определяет повреждения на дорожном покрытии и присваивает соответствующую вероятность




Рис. 2. Сверточная нейронная сеть определяет повреждения на дорожном покрытии и присваивает соответствующую вероятность

Повреждения дорожных покрытий обнаруживаются в скользящем окне с шагом в один пиксель. Если окно частично выходит за пределы изображения, то отсутствующие пиксели будут автоматически воссозданы путем зеркального отражения [5].

Данный автоматический метод выявления дефектов на дорогах, с использованием глубоких сверточных нейронных сетей, может быть в дальнейшем усовершенствован путем замены камеры смартфонов на интегрированную систему, предназначенную для обнаружения дефектов в режиме реального времени [6, 7].

Список источников

1. Oliveira H., Correia P. L. Automatic Road crack detection and characterization // IEEE Transactions on Intelligent Transportation Systems. 2013. Vol. 14, № 1. P. 155–168.
2. Road damage detection and classification using deep neural networks with smartphone images / H. Maeda [et al.] // Computer-Aided Civil and Infrastructure Engineering. 2018. № 33 (2). P. 1–15.

3. Oliveira H., Correia P. L. Crackit-an image processing toolbox for crack detection and characterization // IEEE International Conference on Image Processing. 2014. P. 798–802.

4. Deep residual learning for image recognition / K. He, X. Zhang, S. Ren, J. Sun // IEEE Conference on Computer Vision and Pattern Recognition. 2016. P. 770–778.

5. Кравцов С. С., Чантиева М. Э. Автоматическое обнаружение дефектов дорожного полотна при помощи сверточных нейронных сетей // Technical science. 2022. № 3 (126). С. 42–47.

6. Уроков А. Х., Соаталиев Р. Р. Обнаружение дефектов дорожного покрытия с помощью модели машинного обучения / редкол.: С. Е. Кравченко (гл. ред.) [и др.] ; сост. В. А. Ходяков // Дорожное строительство и его инженерное обеспечение : материалы Международной научно-технической конференции. Минск : БНТУ, 2021. С. 158–161.

7. Road marking blur detection with drive recorder / M. Kawano [et al.] // International Conference on Big Data. 2017. P. 4092–4097.