

## Комплексный анализ и сравнение передовых алгоритмов дефектовки дорожного покрытия с использованием различных систем сбора данных

*С.В. Козырев, К.А. Полянцева*

*Московский Технический Университет Связи и Информатики (МТУСИ)*

**Аннотация:** Рассматривается эффективность использования передовых алгоритмов дефектовки дорожного покрытия в зависимости от применяемых устройств сбора данных, таких как камеры, георадары, LiDAR и IMU-датчики, установленные в смартфонах. Рациональное использование данных программно-аппаратных средств позволит коммунальным службам своевременно выявлять и устранять дефекты дорожного покрытия, тем самым повышая безопасность дорожного движения.

**Ключевые слова:** транспортный сектор, дефектовка дорожного покрытия, передвижные дорожные лаборатории, нейросетевые алгоритмы, компьютерное зрение.

### Введение

Современный научно-технический прогресс в значительной мере способствует существенным изменениям в разнообразных сферах человеческой деятельности, открывая новые горизонты, но, вместе с тем, предоставляя и новые вызовы. Среди этих сфер, которые претерпели изменения за последние годы, выделяется транспортный сектор, который становится все более актуальным в нашей повседневной жизни.

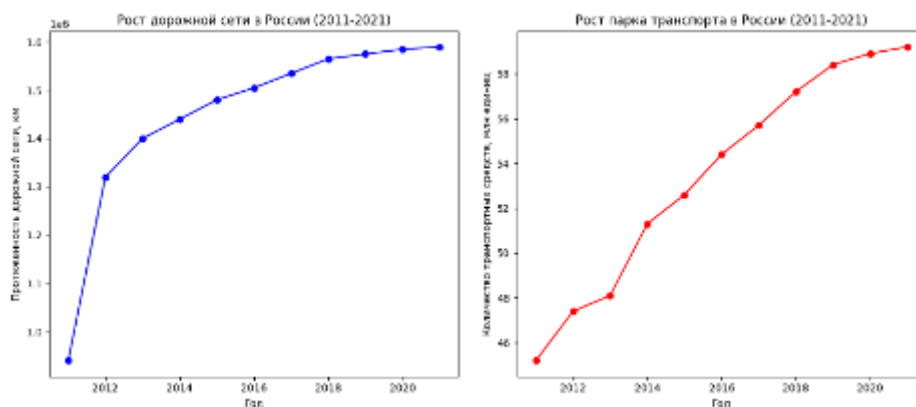


Рис. 1 – Рост транспортной инфраструктуры России

Среди таких изменений в России можно выделить рост парка транспортных средств. По данным на 2021 год он составил 33% и составил 59.2 млн единиц техники [1], в то время как протяженность дорожной сети увеличилась на 11% и составила 1,5 млн. км [2] (рис. 1). В рамках мировой статистики Россия занимает пятое место по протяженности дорог, что свидетельствует о значительном развитии транспортной инфраструктуры в стране.

Однако, наряду с положительными тенденциями, такие изменения также представляют определенные проблемы. В России лишь 52,6% всех дорог отвечает нормативным требованиям по итогам 2022 года [3]. Обусловлено это, как разнообразием климатических и погодных условий в нашем регионе, так и неспособностью своевременно поддерживать надлежащее состояние дорожного покрытия. Наибольший ущерб дорожное полотно получает в межсезонье, когда перепады температур, сопровождаемые осадками, приводят к образованию ям, трещин и деформаций [4]. Более того, согласно статистике, дефекты дорожного покрытия спровоцировали порядка 20% дорожно-транспортных происшествий (ДТП) в 2020 году [5] и порядка 40% в 2021 [6]. Они представляют угрозу для водителей, повышая риск повреждения транспортных средств и, следовательно, возможность потери управления, что, в свою очередь, неизбежно приводит к ДТП.

Исходя из вышеописанных проблем, внедрение передовых технологий компьютерного зрения и машинного обучения в транспортный сектор представляет собой критически важный шаг для решения проблем безопасности на дорогах России. Автоматизированные системы компьютерного зрения могут проводить постоянный мониторинг состояния дорожного покрытия и выявлять дефекты в реальном времени.

Ценность таких систем заключается в возможности предсказывать вероятность возникновения дефектов, основываясь на анализе данных о климатических условиях, транспортном потоке и других факторах, тем самым минимизируя прямое участие человека в сборе и обработке информации. Благодаря такому подходу можно оперативно реагировать на проблемы с дорожным покрытием, устраняя их до того, как они станут причиной аварий. Это не только снизит риск ДТП, но и значительно улучшит общую безопасность дорожного движения.

### **Причины возникновения дефектов дорожного полотна**

Немаловажным элементом большинства дорожных сетей является асфальтобетонное покрытие, на которое в процессе эксплуатации воздействует множество факторов, способствующих его износу и снижению срока службы.

Основная прочность и долговечность дорожного покрытия к внешним факторам закладывается на моменте проверки качества грунта, подготовки основания и выравнивающего слоя. [7] На свойства самой бетонной смеси влияет качество инертных материалов, используемых при производстве (крупные заполнители, песок), чему уделяется отдельное внимание в лабораториях неразрушающего контроля (RMS). Уход за бетоном – важный процесс, влияющий на качество производства готового покрытия. Для этого поверхность бетона обрабатывают специальными составами, исключая появление температурно-усадочных трещин в готовом покрытии. Дополнительно повысить прочность может дисперсное армирование бетона, так как стальные волокна повышают пластичность и энергопоглощение железобетонных элементов, подвергающихся закономерному изгибу под действием статической или динамической нагрузки.

При несоблюдении технологий производства высок риск появления следующих дефектов: волнистость поверхности, разрыв покрытия по всей

ширине, разрывы в середине и по краям, неоднородность текстуры покрытия, некачественные продольные и поперечные швы, продольные и поперечные трещины, недостаточное уплотнение смеси (пустоты).

Продолжительное использование некачественного дорожного покрытия при воздействии экстремальных нагрузок, таких как неблагоприятные погодные и климатические условия, а также интенсивное транспортное движение, ведет к ускоренному износу дорожного полотна и ухудшению его эксплуатационных характеристик. Эти факторы значительно повышают вероятность появления дефектов [8], что, в свою очередь, снижает безопасность и комфорт передвижения.




Рис. 2 – Виды дорожных трещин [8]

Среди таких дефектов можно выделить (рис. 2):

*a) Усталостные трещины:* имеют вид паутины и возникают из-за повторяющихся тяжелых транспортных нагрузок или неправильно распределенной нагрузки на дорожное покрытие. Проникновение воды и плохое подложное покрытие также могут способствовать их появлению.

*b) Отражательные трещины:* напоминают простые хаотичные трещины, развивающиеся из нижележащих трещин и проникающих в верхние слои дорожного полотна.

*c) Поперечные трещины:* являются более ярко выраженными и возникают из-за усадки, вызванной сезонными изменениями температуры, или как продолжение отражательных трещин.

Несвоевременное устранение начальных трещин приводит к возникновению более сложных и опасных дефектов, таких как выбоины. Этот тип дефекта представляет собой углубление в дорожном покрытии, возникающее вследствие прогрессирования усталостных трещин (аллигаторных трещин), при которых части асфальтобетонного покрытия полностью отделяются, обнажая подстилающий бетонный слой (рис. 3). Основными причинами формирования выбоин являются неудовлетворительное основание или земляное полотно, недостаточная толщина дорожного покрытия и неэффективная дренажная система.



Рис. 3 – Виды дорожных выбоин [8]

В случае наезда автомобиля на данный вид дефекта высок риск повреждения колеса, что в большинстве случаев ведет к потере управления транспортным средством и возникновению ДТП.

Также в отдельную группу дефектов можно выделить продавливания и колеи (см. рис. 4), возникающие вследствие интенсивного движения высоконагруженных транспортных средств.

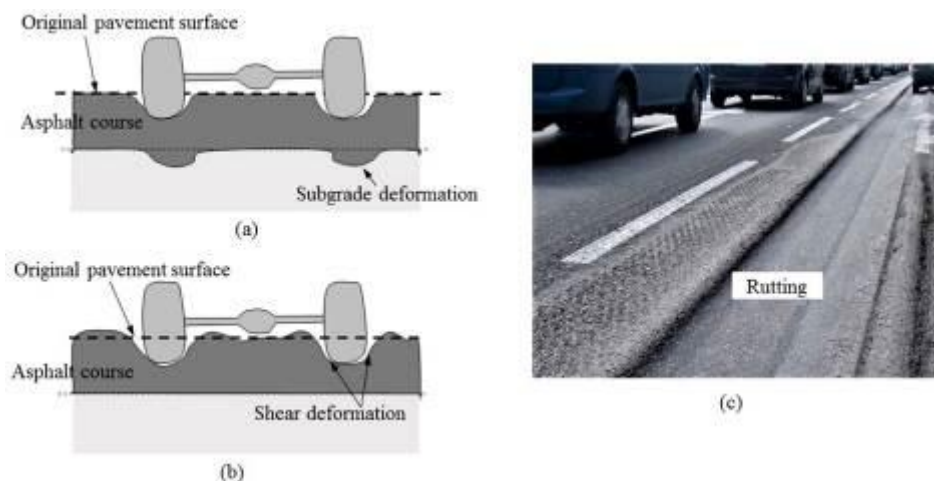


Рис. 4 – Вид дорожной колеи [8]

Данный тип дефекта представляет значительную опасность для водителей, особенно в условиях неблагоприятной погоды, такой как дождь или гололедица. В процессе перестроения транспортного средства передняя или задняя ось может остаться в выбоине, что часто приводит к потере управления автомобилем.

Анализ причин возникновения дефектов дорожного покрытия указывает на необходимость оперативного реагирования и своевременного ремонта дорог. Для эффективного решения этой задачи требуются специализированные устройства, которые могут собирать данные о типе, частоте и местоположении дефектов. Не менее важны алгоритмы, способные эффективно обрабатывать собранную информацию, что позволит быстро и качественно устранять возникающие дефекты.

### **Обзор существующих устройств сбора данных**

В современном научно-инженерном мире ключевым фундаментом эффективного функционирования алгоритмов являются качественные

входные данные. Устройства сбора данных, включающие в себя сенсоры различного типа, играют важную роль в передаче объективной информации об окружающей среде. Разнообразию применяемых технологий позволяет охватить широкий спектр параметров, подлежащих измерению, начиная от визуальных данных, получаемых с помощью камер, и заканчивая бесконтактными замерах с использованием радаров и подобных устройств. Более детально функциональные особенности каждого устройства рассмотрены в таблице 1. Данная таблица включает в себя информацию о принципах работы и ключевых особенностях устройств сбора данных [9, 10].

Таблица № 1

### Обзор существующих устройств

Устройство	Принцип работы	Особенности
1	2	3
Камера	Использование оптических лучей (света) для захвата изображений объектов. Камера работает на принципе пропускания света через оптическую систему и его фиксации на фоточувствительной поверхности (CCD или CMOS), которая регистрирует световые изменения и преобразует их в электрический сигнал.	Плюсы: - Легкость развертывания; - Низкая цена; - Универсальность применения. Минусы: - Зависимость от условий освещения; - Сложность работы с расстоянием.
Радар	Использование электромагнитных волн (радиоволн) для обнаружения, измерения дальности, скорости и направления объектов. Радар работает на принципе излучения радиосигнала в пространство и приема отраженных от объектов сигналов.	Плюсы: - Работа в сложных условиях; - Помехоустойчивость. Минусы: - Узкий спектр задач; - Сложность развертывания; - Относительно высокая цена.

1	2	3
Лидар	Использование лазерных лучей для измерения расстояний, обнаружения объектов и создания трехмерных карт окружающей среды. Лидар работает на принципе излучения лазерного луча в пространство и измерения времени задержки отраженного сигнала, что позволяет определить расстояние до объекта. Также может использоваться для измерения характеристик поверхности объектов и создания точной пространственной модели окружающей обстановки.	Плюсы: - Работа в нормальных условиях; - Высокая точность данных; - Трехмерное пространство. Минусы: - Высокая стоимость; - Ограниченная дальность; - Слабая помехоустойчивость; - Сложность развертывания.
Акустический датчик	Использование звуковых волн для обнаружения, измерения расстояния, скорости и направления объектов. Принцип работы акустических датчиков основан на излучении звукового сигнала в пространство (эхолокации) и приеме отраженных от объектов звуковых волн.	Плюсы: - Низкая стоимость; - Высокая помехоустойчивость; - Простота развертывания. Минусы: - Ограниченная точность; - Влияние окружающей среды;
Пространственный датчик	Пространственные датчики измеряют физические параметры движения и ориентации объектов в пространстве. Общий физический принцип заключается в использовании изменений во внутренних механических или электрических характеристиках датчика, вызванных движением объекта, для выявления и количественного измерения этих изменений.	Плюсы: - Высокая помехоустойчивость; - Пространственное восприятие; - Высокая точность данных. Минусы: - Влияние окружающей среды; - Высокая стоимость; - Сложность настройки;

Проанализировав таблицу, можно прийти к выводу, что каждое устройство сбора данных, исходя из его функциональных особенностей, по-своему уникально и применимо в конкретных сценарных и климатических условиях. Для достижения максимальной эффективности и покрытия большего спектра сценариев, создаются комплексные решения, называемые передвижными лабораториями. Совокупное использование различных



датчиков и устройств в таких лабораториях обеспечивает более полное и точное восприятие окружающей среды, что, в свою очередь, позволяет получать более точные и качественные данные.

### **Передвижные дорожные лаборатории**

Передвижная дорожная лаборатория (ПДЛ) – это специализированное транспортное средство, оборудованное программно-аппаратными устройствами для проведения различных исследований, измерений и анализов в области дорожного строительства, ремонта и обслуживания. Эти лаборатории могут использоваться для проверки качества материалов, дорожных покрытий, асфальтобетонных смесей, а также для мониторинга дорожного движения, безопасности на дорогах и других параметров, связанных с инфраструктурой дорожного хозяйства [11].

Применение таких комплексных решений особенно важно в контексте задач дефектовки дорожного покрытия. В этом случае, появится возможность не только выявить наличие дефектов, но и предоставить дополнительные данные об их характере и особенностях, а также произвести полноценный анализ причин возникновения. Среди существующих комплексных решений можно выделить такие системы как: КПДЛ «Трасса-2»; ПДЛ «АДС-МАДИ»; БПДЛ «РОСДОРНИИ-ЭСКАНДОР». Далее будет произведен более детальный анализ каждой передвижной лаборатории.

1. КПДЛ «Трасса-2» [12] - обеспечивает автоматизированное измерение геометрических параметров дорог (план трассы, продольный и поперечные профили), прочности дорожных одежд, сцепных качеств и ровности покрытия, интенсивности и состава движения, фиксации и анализа дефектов покрытий, определения конструкции и толщины слоев дорожной одежды. КПДЛ «Трасса-2» является аналогом таких лабораторий, как АМАС (Vectra, Франция), ARAN (Fugro, Канада), Hawkeye 2000 Series (ARRB group, Австралия).

---

Среди ее ключевых компонентов можно выделить: лазерные 2d-профилометры (рис. 5); блоки панорамной видеосъемки с углом захвата 180°-360° (рис. 6); георадар-радиолокатор (рис. 7); ПКРС «Метрика» (рис. 8).



Рис. 5 – Модуль 2d-профилометров [12]



Рис. 6 – Модуль панорамной видеосъемки [12]



Рис. 7 - Георадар-радиолокатор [12]




Рис. 8 - ПКРС «Метрика» [12]

2. ПДЛ «АДС-МАДИ» [13] - осуществляет диагностику транспортно-эксплуатационного состояния улиц и дорог столицы. (рис. 9-10). Современное оснащение лаборатории и адаптация под реальные условия позволяют лаборатории полноценно функционировать в круглогодичном и круглосуточном режиме. Ключевой особенностью данной системы является оптимизация работы алгоритмов и программных модулей, что повышает максимальную скорость работы комплекса до 90 км/ч.

Данная лаборатория способна фиксировать: дефекты, дорожную разметку, продольную ровность покрытия, высотные отметки крышек колодцев, линейные элементы обустройства, коэффициент сцепления с дорогой. Вся собранная информация привязывается к глобальной системе координат GPS/ГЛОНАСС.

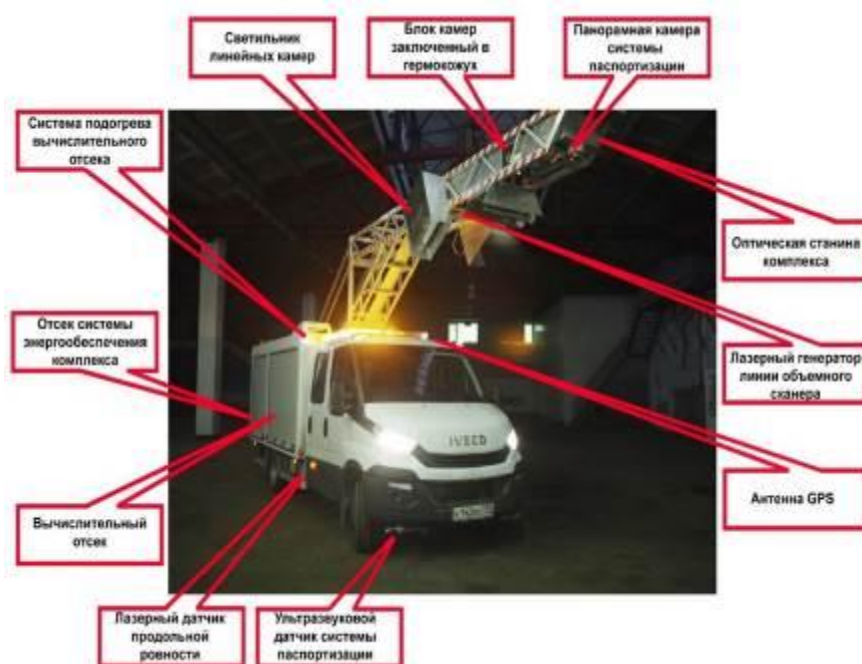


Рис. 9 - «АДС-МАДИ». Вид спереди [13]



Рис. 10 - «АДС-МАДИ». Вид сборку [13]

2. БПДЛ «РОСДОРНИИ-ЭСКАНДОР» [14] - предназначен для выявления участков дорог с ненормативным состоянием, анализа причин возникновения дефектов и оценки остаточного ресурса покрытия. Данные заносятся в специализированную базу данных для управления жизненным циклом дорог и определения объемов и видов ремонтных работ. Основной особенностью такой системы является наличие большого спектра датчиков и

полноценных систем анализа, а также самой большой производительностью – до 400 км. в день со скоростью 70-80 км/ч. (рис. 11-12).



Рис. 11 - «РОСДОРНИИ-ЭСКАНДОР». Вид сборки. [14]



Рис. 12 - «РОСДОРНИИ-ЭСКАНДОР». Вид внутри. [14]

Данная лаборатория включает в себя системы: измерения прогиба дорожных одежд; изменения продольной ровности; измерения шероховатости; многоракурсного георадиолокационного зондирования; измерения колейности; измерения геометрических параметров дороги; распознавания дорожных знаков, разметки и дефектов; сбора, обработки и передачи данных. РОСДОРНИИ не предоставляет конкретных данных о

---

расположении систем и принципе их работы, но сам комплекс уже начал эксплуатироваться на дорогах общего пользования.

### **Обзор алгоритмов дефектовки дорожного покрытия**

В современных передвижных лабораториях, неотъемлемой составляющей являются алгоритмы обработки данных, применяемые в сочетании с высокотехнологичным аппаратным обеспечением. Эффективность данных алгоритмов в значительной мере влияет на точность и скорость выявления дефектов, а также на общую производительность таких систем. Каждый алгоритм обработки данных представляет собой уникальное сочетание математических и компьютерных операций, оптимизированных для обработки специфических данных, поступающих от различных устройств.

Важным аспектом разработки алгоритмов обработки данных для передвижных лабораторий является отказоустойчивость и адаптация к разнообразным условиям дорожной среды. Уникальные характеристики дорог, изменяющиеся световые условия и динамическая природа движения лаборатории требуют разработки эффективных алгоритмов, способных обеспечивать стабильную и точную обработку данных в реальном времени. Далее будет произведен анализ существующих алгоритмов, в зависимости от устройства сбора данных, главной целью которых является обнаружение дефектов дорожного покрытия.

### **Алгоритмы компьютерного зрения**

Алгоритмы компьютерного зрения приобрели невероятную популярность, став неотъемлемой частью современных технологических решений в различных областях человеческой жизнедеятельности, в том числе и в области дефектовки дорожного покрытия. Эволюция алгоритмов компьютерного зрения связана с их выдающейся универсальностью,

---

посредством использования камер в качестве устройства ввода данных (рис. 13)




Рис. 13 – Строение камеры. [15]

Камеры предоставляют не только доступный источник получения информации, но и легко настраиваемую платформу для адаптации к различным задачам - от распознавания объектов и лиц, до медицинской диагностики и автоматизации промышленных процессов. Среди архитектурных особенностей таких устройств можно выделить: матрицу светочувствительных элементов, набор фильтров и линз, а также модуль фокусирования.

Наибольшую популярность в области обработки изображений приобрели алгоритмы, основанные на нейронных сетях. Такие алгоритмы нашли широкое применение в области распознавания дефектов дорожного покрытия, что в значительной мере поспособствовало появлению множества научных статей и исследований.

Алгоритм CrackNet [16], основанный на сверточной нейронной сети (CNN) [17], применяется для обнаружения трещин на трёхмерных изображениях асфальтовых поверхностей с пиксельной точностью.

Среди ключевых архитектурных особенностей алгоритма можно выделить отсутствие слоев подвыборки (Pooling layers), что позволяет

сохранить исходные размеры изображения через все слои. CrackNet состоит из пяти слоев, включая слои свертки и полностью связанные слои, а также имеет порядка миллиона параметров. Такая структура обусловлена необходимостью достижения высокой точности на уровне пикселей, что важно для анализа геометрических характеристик трещин.

Алгоритм обучался и тестировался на наборах данных, состоящих из 1800 и 200 изображений соответственно. Данные представляют собой 3D-изображения поверхности дороги размером 1024x512 пикселей, полученные с помощью системы PaveVision3D. Данная методика сбора данных о дефектах основана на использовании двух близко расположенных камер [18]. Полученные данные содержат информацию не только о ширине и длине дефектов, но и об их глубине, что позволяет извлечь более детализированную информацию, применяя стандартные камеры. CrackNet демонстрирует высокие результаты с точностью (Precision) 90.13%, полнотой (Recall) 87.63% и F-мерой 88.86%, значительно превосходя такие алгоритмы, как Pixel-SVM и 3D shadow modeling.

Дальнейшей модификацией данного алгоритма является CrackNet-V [19]. Данный алгоритм все также основан на сверточных нейронных сетях (CNN), но претерпел ряд архитектурных изменений. По сравнению с оригинальной сетью CrackNet, CrackNet-V имеет более глубокую архитектуру (DCNN) [20], посредством использования большого количества фильтров на каждом уровне свертки, при этом имея 64 113 параметров, что в значительной мере превосходит оригинальную модель. Также можно выделить новый блок активации под названием Leaky Rectified Tanh, который может подавлять различия между трещинами разной глубины, позволяя сети сосредоточиться на морфологических особенностях.

Алгоритм тестировался на наборе данных, включающем 2568 обучающих и 500 тестовых трёхмерных изображений дорожных покрытий

---



размером 512x256, содержащих как трещины, так и участки без повреждений. Данные были собраны с различных типов дорог, что обеспечило разнообразие обучающего набора и повысило обобщающую способность модели. CrackNet-V достигает высокой производительности с точностью (Precision) 84,31%, полнотой (Recall) 90,12% и с оценкой F-мерой 87,12%, при этом повысив скорость обработки в 4 раза.

Параллельно с этим начинают становиться все более популярными алгоритмы You Only Look Once (YOLO) [21], которые уже обучены на достаточно больших наборах данных, например, таких как COCO, с возможностью дальнейшего дообучения и корректировки весов под конкретную задачу. Первое упоминание алгоритма YOLOv2, основанного на архитектуре Darknet-19 [22], применительно к данной области, представлено в [23]. Данный алгоритм использует сверточную нейронную сеть (CNN) для одновременной детекции объектов и их классификации на изображении в режиме реального времени.

Ключевой особенностью YOLOv2 является использование ограничивающих рамок (Bounding boxes), с помощью которых обрамляется область, содержащая дорожный дефект. Использование большого количества малоразмерных сверточных слоев и слоев объединения позволяет сократить размер данных до  $13 \times 13 \times 125$  на последнем слое, что в значительной мере повышает производительность алгоритма.

Модель обучалась на наборе данных из 7,240 изображений, полученных с мобильных камер внутри автомобиля, и тестировалась на 1,813 изображениях дорог из семи муниципалитетов Японии. Изображения дорог содержат различные типов трещин, которые были разделены на восемь различных категорий, что позволило алгоритму обучаться на разнообразных данных. YOLOv2 достигает высокой производительности с точностью

---

(Precision) 88,51%, полнотой (Recall) 87,10% и с оценкой F-мерой 87,80%, при этом повысив скорость обработки в 4 раза.

Применение обновленной версии данной модели – YOLOv3 описано в [24]. Среди архитектурных особенностей данной модели можно выделить обновленную архитектуру Darknet-53 [25], наличие остаточных блоков (Residual blocks), которые позволяют сохранять информацию через прямые соединения, минуя несколько слоев и помогая решать проблему затухания градиентов.

В рамках исследования были использованы две камеры с разными углами обзора (30° и 70°) для повышения точности и дальности обнаружения дефектов. Обучение и тестирование проводилось на наборе данных Taiwan Pavement Defect Image Dataset (TPDID), который содержит 62 000 изображений, а дефекты дорожного покрытия в нем разделены на шесть категорий: дорожные выбоины и резкие уклоны (31 708 образцов), крышки люков (9284 образца), продольные трещины (16 810 образцов), поперечные трещины (4761 образец), продольные заплатки (18 023 образца) и поперечные заплатки (10 291 образец). По результатам тестирования YOLOv3 достигает точности (Accuracy) детектирования дефектов, превышающей 71% для такого большого количества классов. Наилучшая средняя точность (Average Precision) была продемонстрирована для первой категории и составила 89%.

Также YOLO интегрируют с другими нейросетевыми алгоритмами [26]. В данном исследовании YOLOv5 (основанный на CSPDarknet53 [27]) используется для обнаружения областей с трещинами, а модифицированный ResU-Net [28] с модулем внимания (Attention gate) выполняет точную попиксельную сегментацию трещин на полученных областях. Это позволяет улучшить обнаружение и измерение трещин на фоне различных объектов и в плохих условиях освещения.

Обучение и тестирование производилось на наборе данных Road Damage Detection (RDD), содержащий изображения дефектов дорожного покрытия, снятых на авторегистратор. Для YOLOv5 изображения имели размер 1280x1280 и были разбиты следующим образом – обучение 2200, валидация 240, тестирование 120. Для ResU-Net размер изображений составил 448x448 и разбит следующим образом - обучение 3800, валидация 360, тестирование 120. Подводя итог, данная комбинация значительно опережает по метрикам алгоритмы YOLACT++ и DeepLabv3+. YOLOv5 демонстрирует среднюю точность (mAP) 91%, а модифицированная ResUNet достигает 87% пересечения над объединением (IoU) при сегментации пикселей с трещинами, что на 6.7% выше оригинального ResU-Net.

Еще одна подобная интеграция описана, где предлагается интеграция между генеративной адверсарной сетью с улучшенным сверхразрешением (ESRGAN [29]) для повышения разрешения низкокачественных изображений и алгоритмом обнаружения объектов YOLOv7 (с добавлением в архитектуру модулей ELAN и EFPN [30]) для обнаружения выбоин на улучшенных изображениях. Данная связка позволяет решить проблему использования бюджетных камер с низким разрешением, при этом сохраняя высокие значения метрик точности модели [31].

Обучение и тестирование алгоритма происходило на наборе данных, подготовленном электронным факультетом Стелленбосского университета, который содержит 1784 изображения, из которых 1265 обучающих, 401 валидационных и 118 тестовых. Изображения в наборе данных имеют разный размер и разную ориентацию объектов, поэтому их размер был изменен до 1100 × 800р. В результате YOLOv7x + ESRGAN демонстрирует среднюю точность (mAP) 98% и полноту (Recall) 89%.

Наличие подобных исследований позволяет не только комбинировать модели между собой, но и реализовывать собственные полноценные решения

---

на базе новой архитектуры, как например в [32]. В данном исследовании используется модель Mask R-CNN, в архитектурные особенности которой входит наличие модуля RPN (Region Proposal Network)/ ROI Align [33] для извлечения фич из найденных прямоугольных областей и модуля маскирования для пиксельной сегментации каждого обнаруженного объекта в областях ROI.

В качестве начальных весов модели были взяты параметры, полученные из набора данных COCO. После чего, для дообучения и тестирования алгоритма использовались как собственные наборы дорожных дефектов, полученных с помощью БПЛА, так и изображения, найденные в интернете, имеющие размер не менее 560x540. На обучающую выборку было отведено 450 изображений, а на тестовую 50. В конечном итоге Mask R-CNN демонстрирует достаточно высокие результаты по метрике средней точности (mAP) 90%.

### **Алгоритмы вибрационно-гироскопического анализа**

Не менее важной технологией, набирающей популярность в последнее время является использование алгоритмов вибрационно-гироскопического анализа. Примечательным аспектом таких алгоритмов является их универсальность, позволяющая использовать как бюджетные устройства общего назначения (смартфоны), так и готовые аппаратные решения, предназначенные для специализированных задач. Это открывает широкие перспективы внедрения данной технологии в различные сферы, в том числе и в сферу дефектовки дорожного покрытия.

Основными датчиками получения информации в таких алгоритмах являются гироскопы и акселерометры. Гироскоп измеряет угловую скорость вращения объекта вокруг определенной оси. Он предоставляет информацию о том, как быстро объект вращается вокруг каждой из трех осей пространства (обычно X, Y и Z). Акселерометр измеряет ускорение объекта в направлении,

---

в котором он установлен. Это может быть вертикальное (гравитационное ускорение) или любое другое направление, в котором происходит движение. (рис. 14)




Рис. 14 – Устройства гироскопа и акселерометра [34]

Данные сенсоры комплексно используются в инерциальных измерительных устройствах (IMU), которые присутствуют практически во всех современных смартфонах (рис. 15), что позволяет крайне бюджетно реализовывать системы анализа положения объекта в пространстве.




Рис. 15 – Чип IMU внутри смартфона [35]

Полученные данные от чипов IMU, расположенных внутри транспортных средств можно использовать для оценки шероховатости дорожного покрытия, с использованием фильтров Калмана [36], который является широко используемым методом фильтрации данных в системах навигации и оценки состояния.

Прямая интеграция считывающих датчиков в дорожное покрытие описана в [37]. В данном исследовании используется метод мониторинга качества дорожного основания (MRBQ) с использованием пьезоэлектрических датчиков для измерения электрических сигналов с высокой чувствительностью до 2 В/МПа.

В ходе модульного тестирования получены данные о выходном напряжении пьезоэлектрических датчиков, которые затем использовались для обратного расчета модуля упругости основания. Сравнение обратно рассчитанного модуля с результатами измерений методом резонансного колонного теста (RCT) показало точность метода с ошибкой менее 20%. Также выявлено, что точность MRBQ возрастает с увеличением амплитуды и частоты нагрузки, что подтверждает его потенциал для реального времени мониторинга качества дорожного основания и прогнозирования его срока службы.

Развитие данной идеи нашло продолжение в исследовании [38], которое посвящено разработке датчика деформации на основе композита из углеродных нанотрубок и эпоксидной смолы (CNT/EP) для мониторинга асфальтобетонного покрытия.

Датчик был вмонтирован в дно двухслойной асфальтобетонной плиты (размер 300 мм × 300 мм × 100 мм) и демонстрировал хорошую линейную зависимость сопротивления  $\Delta R/R_0$  от деформации, успешно работая при высоких температурах и давлениях. Погрешность измерений составляет около 35% (значение  $\Delta R/R_0$  для встроенного датчика примерно 0,65 от значения до установки). Интеграция и обслуживание подобных устройств в современную дорожную среду требует большого финансирования, в связи с чем появляется необходимость в поиске более бюджетного и легкого в обслуживании датчика.

---

Применения метода обнаружения дефектов на основе анализа акустической сигнатуры описано в [39]. В данном исследовании предлагается использовать алгоритм иерархической кластеризации для оценки структурного состояния дороги (SHS). Этот метод применим для неразрушающего контроля состояния дорожного покрытия, особенно для выявления как видимых, так и скрытых трещин.

Ключевые архитектурные особенности включают использование беспроводной сенсорной сети (WSN) и неразрушающего контроллера (NDT) с микрофонными узлами, которые фиксируют акустическую реакцию покрытия на механическую нагрузку. Это позволяет анализировать сигналы в временной, частотной и временно-частотной областях, извлекая значимые признаки, такие как энергия, энтропия непрерывных вейвлет-коэффициентов, спектральный центроид.

Обучение и тестирование проводилось на наборе данных из 8000 акустических сигналов, по 2000 для каждого уровня SHS. Данные представляли собой акустические сигнатуры, собранные при проезде автомобиля, с использованием частоты дискретизации 1920 Гц. Разработанный алгоритм позволяет правильно классифицировать акустические сигналы с хорошей средней точностью (AP) 86 %.

Похожие исследования также описаны в статье [40]. В данном случае анализ вибро-акустической сигнатуры демонстрируется, как более бюджетный метод дефектовки дорожного покрытия, не уступающий таким технологиям, как георадар (GPR) и дефлектометр с падающим грузом (FWD).

Тестирование алгоритма проводилось на данных, собранных с городских дорог в Катании, Италия. Были отобраны участки с различной толщиной асфальта и наличием трещин, общей длиной около 600 метров. Набор данных включал сигналы, полученные с помощью динамометрической установки (FWD) и виброакустических сенсоров (VAS).

---

Результаты показывают высокую корреляцию между акустическими характеристиками и модулями упругости (например, для F3 и E1: 0.5510,  $p\text{-value} < 0.0001$ ), что подтверждает эффективность подобного подхода и позволяет научному сообществу производить более сложные интеграции, например с нейросетевыми алгоритмами.

В статье [41] к вибро-акустическому анализу применяются алгоритмы машинного обучения, такие как: многослойный перцептрон (MLP), свёрточная нейронная сеть (CNN), классификатор случайного леса (RFC) и классификатор опорных векторов (SVC).

Набор данных состоял из 4000 сигналов виброакустической эмиссии (AE), которые собирались с акустических датчиков, установленных на обочине дороги. Конкретные размерности наборов данных, использованных в различных экспериментах, были 1600, 3200 и 4000 сигналов AE. Результаты исследования показали, что алгоритмы могут ассоциировать определённые вибро-акустические сигнатуры с различными состояниями трещин дорожного покрытия с высокой точностью (Accuracy): MLP - 91.8%, CNN - 95.6%, RFC - 91.0%, SVC - 99.1%.

В [42] используется трехосный акселерометр PCB 356B18, установленный в пяти различных местах шасси автомобиля, датчик GPS и камера, установленная под углом в 45°.

Акселерометр записывал трех осевые данные вибраций (ось z отражала вертикальные ускорения) на скоростях 5, 10, 15 и 20 км/ч, а с помощью GPS и камеры осуществлялась визуальная идентификация и фиксация типов дефектов для дальнейшей разметки. Данные вибраций были записаны с частотой 6000 Гц с использованием программного обеспечения Labview NXG 2020 на участке дороги Spring Street в Мельбурне, Австралия. Для анализа состояния дорожного покрытия использовались модели машинного обучения: Random Forest (RF), Decision Tree (DT) и Support Vector Machine

---



(SVM) [43]. RF показал точность (Accuracy) классификации дефектов покрытия до 93%, DT до 90%, а SVM до 96%.

Доступность современных смартфонов, а также их технологическая оснащенность датчиками IMU позволяет также применять их в области дефектовки дорожного покрытия. В [44] описывается алгоритм кластеризации K-Means, который решает задачу классификации дефектов, таких как выбоины, искажения, колейность и заплатки, без предварительной разметки данных, что экономит ресурсы и время на сбор и анализ данных [45]. Ключевой архитектурной особенностью данного алгоритма является использование оконного анализа данных, что позволяет выделять последовательности точек для более точной характеристики дефектов.

Алгоритм тестировался на 16 наборах данных, собранных независимо на национальной дороге R148 в графстве Килдэр (Ирландия) протяженностью 2,2км. Эти данные представляют собой ускорения, зарегистрированные смартфонами, и классифицируются по различным типам дефектов. Результаты показывают, что максимальная точность (Accuracy) алгоритма составила 87%, средняя — 84%. Средняя полнота (Average Recall) достигла 87% (максимум 98%), указывая на высокую выявляемость дефектов, но средняя точность (Precision) была 46%, что свидетельствует о значительном числе ложных срабатываний.

Наиболее полный анализ популярных алгоритмов машинного обучения применительно к IMU- датчикам смартфона [46] описан в [47].

Набор данных для сравнения алгоритмов классификации дефектов содержал около 1540 образцов (1080 размеченных без дефектов и 460 размеченных с выбоинами). Каждый образец дороги соответствовал примерно одной секунде записи, что отражает временную детализацию наших сегментов дороги. По результатам исследования был составлен топ алгоритмов по метрикам:

---

1. *Accuracy* - ANN (Artificial Neural Networks) 86.88 ( $\pm 1.14$ ); SVM (Support Vector Machines) 88.05 ( $\pm 1.81$ ); Random Forest: 87.79 ( $\pm 1.31$ ); Extra Trees: 87.34 ( $\pm 2.07$ ); Bagging: 86.75 ( $\pm 0.80$ ); Gradient Boosting: 87.14 ( $\pm 0.54$ ); Stacking: 86.95 ( $\pm 0.43$ )

2. *F-Score* - ANN 86.74 ( $\pm 1.13$ ); SVM 87.87 ( $\pm 1.97$ ); Random Forest 87.43 ( $\pm 1.30$ ); Extra Trees 86.65 ( $\pm 2.37$ ); Bagging 86.29 ( $\pm 0.99$ ); Gradient Boosting 86.69 ( $\pm 0.49$ ); Stacking 86.25 ( $\pm 0.53$ )

3. *AUC* - ANN 91.44 ( $\pm 1.93$ ); SVM 91.83 ( $\pm 1.60$ ); Random Forest: 93.89 ( $\pm 0.22$ ); Extra Trees 94.94 ( $\pm 1.21$ ); Bagging 92.13 ( $\pm 1.21$ ); Gradient Boosting: 92.43 ( $\pm 0.78$ ); Stacking: 93.12 ( $\pm 0.49$ )

### **Алгоритмы лазерного и радиоволнового анализа**

Алгоритмы лазерного и радиоволнового анализа представляют собой категорию методов, требующих значительных вычислительных ресурсов. Тем не менее, существенной особенностью данных алгоритмов является их способность предоставлять наиболее полное описание окружающего пространства. Основным устройством сбора данных в этих системах являются лидары и радары.

LIDAR (Light Detection and Ranging) - технология дистанционного зондирования, которая использует лазерный свет для измерения расстояний и создания точной трехмерной карты окружающей среды. Среди основных компонентов лидаров можно выделить: лазерный источник, отражатель, фотодетектор, временной измеритель, систему ориентации (рис. 16). Результатом работы данного модуля будет облако точек в трехмерном пространстве, описывающее геометрическую структуру объектов вокруг себя (рис. 17). Каждая точка в этом облаке представляет конкретную координату в пространстве, определенную на основе времени задержки возвращенного отраженного лазерного излучения [48].

---



Рис. 16. – Устройство модуля LIDAR [49]



Рис. 17. – Облако точек, полученных с помощью LIDAR [50]

RADAR (от англ. Radio Detection and Ranging) – более доступная технология, используемая для обнаружения и определения положения объектов. Он работает по принципу излучения электромагнитных волн и считывании их отражений от различных объектов [51]. Большинство радаров состоит из передатчика, антенны, приемника, временной измерителя, системы ориентации.

В рамках исследования [52] было проведено сравнение технологии GPR с методом ударного эха (IE), методом ультразвуковых волн (USW) и методом спектрального анализа поверхностных волн (SASW) для задач

дефектовки дорожного покрытия. Данные георадара позволяют оценить глубину трещины, если гиперболическое отражение, возникающее на дне трещины, обнаружено с погрешностью 5,5%. Отклонение результатов GPR от измерений ядерным плотномером не превышало 3%. В качестве рекомендации было предложено использовать антенны, работающие на более высоких частотах, таких как 2,3 ГГц, для обеспечения большей точности оценки глубины трещины.

Более наглядное использование технологии GPR для измерения толщины асфальтового покрытия и обнаружения дефектов описано в [53]. Среди архитектурных особенностей можно выделить использование горизонтального фильтра высокого пропускания и модифицированного метода локализации слоев.

Представленная система монтирована на транспортное средство и включает в себя: два георадара с воздушной связью, четыре георадара с наземной связью 300 М, частоты которых составляют 1 ГГц, 2 ГГц и 300 МГц соответственно, а также модуль GPS и две камеры. Максимальной скоростью обнаружения дефектов для такой системы составляет 80 км/ч. Для подавления шумов радарной системы применялись методы: удаления постоянного тока (DC), калибровки системы, фильтрации и компенсации амплитуды.

В рамках тестирования было собрано 22 000 георадарных данных о новом дорожном покрытии. В результате тестирования прогнозируемые ошибки для поверхностного слоя и верхнего слоя покрытия составляют менее 3% и 5%, соответственно, что удовлетворяет требованиям к точности обнаружения асфальтового покрытия.

Методология анализа данных георадара (GPR) для выявления и характеристики трещин в дорожном покрытии [54]. В качестве анализируемых данных представлены радарограммы различных моделей

---

трещин в слоистых однородных средах, собранных на одном из участков шоссе на дороге G20 в Китае с использованием системы LTD-2600 GPR с 400 МГц антенной. Для моделирования георадара были использованы поглощающие граничные условия в виде конволюционного идеально согласованного слоя (CPML), что позволило снизить ошибки отражения и достичь более высокой точности. При сборе данных применялся коэффициент усиления с разнесением и экспоненциальной компенсацией (SEC) для компенсации амплитуды. По результатам исследования амплитудные вариации дифрагированных волн позволяют точно определить тип и местоположение трещин, в качестве примера усталостные трещины генерируют более высокую амплитуду дифрагированных волн, чем отражающие трещины на интерфейсе между асфальтом и полужестким базовым слоем.

Наличие подобных исследований позволяет производить интеграцию технологии GPR с нейросетевыми алгоритмами, например, в [55] предлагается использовать нейросеть YOLO в связке с GPR.

В рамках исследования сбор данных осуществлялся с помощью радарного комплекса GeoScope™ MKIV и антенной решетки DXGT™ 1820, с возможностью сканирования до 3м глубины в высоком разрешении (41 линия за один проход в непрерывном диапазоне частот от 200 МГц до 3 ГГц). В качестве классифицируемых дефектов были выбраны - трещины, пустоты и проседания. Конечный набор данных представлял собой изображения размером 320x320 пикселей, разделенных на тренировочную (263 изображения и 1134 трещины), валидационную (44 изображения и 135 трещин) и тестовую (43 изображения и 131 трещина) выборки. Для обработки данных использовались - обратное дискретное преобразование Фурье (ISDFT), автомасштабирование данных и удаление фона (BGR).

---

По итогам тестирования наилучшие результаты продемонстрировала модель YOLOv5m, исходя из следующих метрик точности: Precision – 76%; Recall - 94%; F1 - 82%; mAP - 91.61%; FPS - 1.36. Это говорит о высокой эффективности использования нейросетевых алгоритмов в связке с GPR.

Возможна также интеграция более сложных технологий трехмерного лазерного сканирования (LIDAR) в мобильные системы картографирования [56]. Транспортное средство, оснащенное панорамной камерой, GNSS+INS устройством, лидаром и оборудованием для захвата данных способно моделировать подробную карту дефектов и классифицировать их по 10 классам: трещины в швах (узкие, широкие), продольные трещины (узкие, широкие), поперечные трещины, трещины "аллигатор", рейвлинг, разрыв кромки, ямочный ремонт, выбоины. Получаемая информация передается на сервер и визуализируется в облачном сервисе.

В ходе проекта по инвентаризации было нанесено на карту 7570,063 км дорог с твердым покрытием. В период с 2016 по 2020 год было проанализировано около 35,000 км государственных дорог и около 25,000 км муниципальных и лесных дорог. Данные включают информацию о различных типах дорожных покрытий, от велосипедных дорожек до многополосных автомагистралей. Конкретных алгоритмов и метрик точности в статье не указано, но говорится о высокой эффективности системы с использованием данных устройств.

Наглядное использование трехмерного лазерного сканирования для задач обнаружения и классификации дефектов дорожного покрытия описано в [57]. Среди ключевых архитектурных особенностей можно выделить: использование метода мэшинга (meshing) для объединения облака точек в единую поверхность, а также метода анализа главных компонент (PCA [58]) для нахождения наилучшей поверхности в облаке точек.

Набор данных для тестирования предоставлял собой цифровые изображения и облака точек, полученные с помощью наземного лазерного сканера Leica P40 из пяти разных мест в городе Порт-Саид. Размеры данных варьировались от 480x648 до 1920x1080 пикселей, а облака точек содержали различные объемы данных, соответствующие сканируемым зонам.

Метрики, по которым оценивалась точность, включают количество обнаруженных пикселей, горизонтальное и вертикальное стандартные отклонения (Std.H и Std.V). По результатам тестирования трещины типа «аллигатор» успешно классифицировались при значениях метрик Std.H/Std.V – (9.94/ 6.79), горизонтальные трещины – (6.21/0.49), вертикальные трещины – (0.71/4.46), прочие трещины – (0.67/0.80), а отсутствие трещин при нулевых значениях.

Высокие метрики точности позволяют производить интеграцию технологии LIDAR с нейросетевыми алгоритмами, например, [59]. В данном исследовании представлен метод реконструкции дорожного полотна, называемый NeRO (Neural Road Surface Reconstruction) на основе MLP.

Среди архитектурных особенностей можно выделить использование Positional Encoding (PE) для реконструкции высоты дорожного покрытия, Mask2Former с Swin-L backbone для предсказания семантической информации, такой как дороги, дорожные линии, люки и дефекты, а также COLMAP для получения точек Structure from Motion (SfM [60]). Тестирование производилось на наборе данных Kitti Odometry Dataset с размером изображений 1241 x 376. В конечном итоге при использовании LiDAR данных с Hash PE удалось достичь высокой точности по метрикам PSNR - 29.20 и mIoU - 0.994. Высокотехнологичные устройства, подобные технологии LIDAR, начинают все больше интегрироваться в современные смартфоны, что делает их более доступными. Например, в [61] рассматривается использование LiDAR-

---

сенсоров в смартфонах линейки iPhone для обнаружения дорожных дефектов.

В рамках анализа данных применялись алгоритмы на основе методов роста регионов (Region Growing), используемые для задач кластеризации точек на основе их свойств и близости, а также методов подгонки плоскости (Plane Fitting) с целью оценки отклонений от модели. Данные представляли облака точек, полученные с помощью LiDAR-сенсора и изображения, обработанные методом Structure from Motion (SfM). По результатам исследования облака точек, полученные с помощью SfM, оказались более точными по сравнению с данными LiDAR-сенсора, благодаря их высокому разрешению.

### Заключение

После проведения обширного анализа научных исследований была сформирована сравнительная таблица 2 рассмотренных алгоритмов. Сравнение производится по таким критериям, как: стоимость устройства сбора данных, решаемые (в рамках дефектовки дорожного покрытия) задачи, средняя точность алгоритма.

Таблица № 2

Сравнение алгоритмов компьютерного зрения.

Устройства сбора данных	Применяемые алгоритмы	Стоимость устройств	Решаемые задачи	Средняя точность, %
1	2	3	4	5
CV Algorithm	CrackNet, CrackNet-V, YOLO, ResU-Net, SegNet, Mask R-CNN.	Низкая (камера)	Обнаружение дефектов/ Классификация/ Сегментация, анализ качества	~90-95% Accuracy



1	2	3	4	5
IMU Algorithm	MRBQ, CNT/EP, CNN, RFC, SVC, MLP, RF, DT, SVM, K-Means.	Низкая (датчики)	Обнаружение дефектов, анализ качества	~70-80% Accuracy
GPR Algorithm	IE, USW, SASW, CPML, YOLO	Средне-высокая (GPR)	Обнаружение дефектов/ Классификация	~95+% Accuracy
LiDAR Algorithm	MA, MLP, PCA, SfM, etc	Высокая (LiDAR)	Обнаружение дефектов/ Классификация/ Сегментация, анализ качества	~95+% Accuracy

На основании составленной таблицы можно сделать вывод, что алгоритмы компьютерного зрения являются наиболее оптимальным решением. Это обусловлено несколькими ключевыми факторами:

1. *Высокая точность:* Алгоритмы компьютерного зрения в среднем демонстрируют высокие показатели точности 90-95% (Accuracy).

2. *Большой спектр решаемых задач:* Алгоритмы компьютерного зрения способны обнаруживать, классифицировать и сегментировать дорожные дефекты разных типов и классов, что говорит об их универсальности.

3. *Низкая стоимость устройств сбора данных:* Камеры являются одним из самых распространенных устройств бюджетного сегмента, доступность которых значительно выше георадаров (GPR) и лидаров (LiDAR)

## Литература

1. Инфографика: как изменился парк транспортных средств в России за 10 лет? // Автостат URL: [autostat.ru/infographics/46087/](https://autostat.ru/infographics/46087/) (дата обращения: 21.12.23).
2. Появился рейтинг стран по длине дорог. Мы в пятерке! // За Рулем URL: [zr.ru/content/news/916887-rejting-stran-podline-avtomob/](https://zr.ru/content/news/916887-rejting-stran-podline-avtomob/) (дата обращения: 20.12.23).
3. Инфографика: Рейтинг российских регионов по качеству дорог // РИА Новости. URL: [ria.ru/20230703/dorogi-1881060572.html](https://ria.ru/20230703/dorogi-1881060572.html) (дата обращения: 23.12.2023).
4. Факторы, влияющие на сроки службы автомобильных дорог // Репозиторий Белорусского национального технического университета. URL: [rep.bntu.by/bitstream/handle/data/62974/187-192.pdf?sequence=1&isAllowed=y](https://rep.bntu.by/bitstream/handle/data/62974/187-192.pdf?sequence=1&isAllowed=y) (дата обращения: 17.12.23).
5. Основные причины ДТП // Автошкола177 URL: [avtoshkola177.ru/article/osnovnyye-prichiny-dtp](https://avtoshkola177.ru/article/osnovnyye-prichiny-dtp) (дата обращения: 12.11.2023).
6. Госавтоинспекция. Показатели состояния безопасности дорожного движения // Официальный сайт ГИБДД URL: [stat.gibdd.ru](https://stat.gibdd.ru) (дата обращения: 28.12.2023)
7. Sazonova S. A., Nikolenko S. D., Akamsina N. V. Monitoring concrete road pavement damages // IOP Conference Series: Earth and Environmental Science. IOP Publishing, 2022. V. 988. №5. P. 052054.
8. Wang H. P., Guo Y. X., Wu M. Y., Xiang K., Sun S. R. Review on structural damage rehabilitation and performance assessment of asphalt pavements // Reviews on Advanced Materials Science. 2021. V. 60. №1. pp. 438-449.
9. Zhou Y., Guo X., Hou F., Wu J. Review of intelligent road defects detection technology // Sustainability. 2022. V. 14. №10. P. 6306.

10. Vargas J., Alsweiss S., Toker O., Razdan R., Santos J. An overview of autonomous vehicles sensors and their vulnerability to weather conditions // Sensors. 2021. V. 21. №16. P. 5397.

11. Дорожные лаборатории и измерительное оборудование // Лаборатория Микроприборов URL: [mp-lab.ru/application/road-laboratories/](http://mp-lab.ru/application/road-laboratories/) (дата обращения: 08.01.2024).

12. Комплексная передвижная дорожная лаборатория «Трасса» // Спецдортехника URL: [sdtech.ru/paper/trassa\\_stat/](http://sdtech.ru/paper/trassa_stat/) (дата обращения: 09.01.2024).

13. ПДЛ «АДС-МАДИ» // МАДИДТ URL: [madidt.ru/7-produkty.html](http://madidt.ru/7-produkty.html) (дата обращения: 11.01.2024).

14. РОСДОРНИИ представил инновационную лабораторию «Эскандор» для непрерывной диагностики автодорог // ФАУ РОСДОРНИИ URL: [rosdornii.ru/press-center/news/novosti-bkd/rosdornii-predstavil-innovatsionnuyu-laboratoriyu-eskandor-dlya-nepreryvnoy-diagnostikiavtodorog/?sphrase\\_id=32009](http://rosdornii.ru/press-center/news/novosti-bkd/rosdornii-predstavil-innovatsionnuyu-laboratoriyu-eskandor-dlya-nepreryvnoy-diagnostikiavtodorog/?sphrase_id=32009) (дата обращения: 12.01.2024).

15. Учебный центр. Как работают камеры? // Everpresent. URL: [everpresent.com/how-do-cameras-work/](http://everpresent.com/how-do-cameras-work/) (дата обращения: 13.02.2024)

16. Zhang A., Wang K. C., Li B., Yang E., Dai X., Peng Y., Chen C., Fei Y., Liu Y., Li Q. Automated pixel-level pavement crack detection on 3D asphalt surfaces using a deep-learning network // Computer-Aided Civil and Infrastructure Engineering. 2017. V. 32. №10. pp. 805-819.

17. Yamashita R., Nishio M., Do R. K. G., Togashi K. Convolutional neural networks: an overview and application in radiology // Insights into imaging. 2018. V. 9. pp. 611-629.

18. Hu Y., Furukawa T. Degenerate near-planar 3D reconstruction from two overlapped images for road defects detection // Sensors. 2020. V. 20. №6. P. 1640.

19. Fei Y., Wang K. C., Zhang A., Chen C., Li J., Li Q., Liu Y., Li B. Pixel-level cracking detection on 3D asphalt pavement images through deep-learning-based CrackNet-V // IEEE Transactions on Intelligent Transportation Systems. IEEE, 2019. V. 21. №1. pp. 273-284.

20. Simonyan K., Zisserman A. Very deep convolutional networks for large-scale image recognition // arXiv preprint arXiv: 1409.1556. 2014.

21. Redmon J., Divvala S, Grishick R, Farhadi A. You only look once: Unified, real-time object detection // Proceedings of the IEEE conference on computer vision and pattern recognition. IEEE, 2016. pp. 779-788.

22. Redmon J., Farhadi A. YOLO9000: better, faster, stronger // Proceedings of the IEEE conference on computer vision and pattern recognition. IEEE, 2017. pp. 7263-7271.

23. Mandal V., Uong L., Adu-Gyamfi Y. Automated road crack detection using deep convolutional neural networks // 2018 IEEE International Conference on Big Data (Big Data). IEEE, 2018. pp. 5212-5215.

24. Lin Y. C., Chen W. H., Kuo C. H. Implementation of pavement defect detection system on edge computing platform // Applied Sciences. 2021. V. 11. №8. P. 3725.

25. Redmon J., Farhadi A. Yolov3: An incremental improvement // arXiv preprint arXiv: 1804.02767. 2018.

26. Deng L., Zhang A., Guo J., Liu Y. An integrated method for road crack segmentation and surface feature quantification under complex backgrounds // Remote Sensing. 2023. V. 15. №6. P. 1530.

27. Bochkovskiy A., Wang C. Y., Liao H. Y. M. Yolov4: Optimal speed and accuracy of object detection // arXiv preprint arXiv: 2004.10934. 2020.

28. Diakogiannis F. I., Waldner F., Caccetta P., Wu C. ResUNet-a: A deep learning framework for semantic segmentation of remotely sensed data // ISPRS Journal of Photogrammetry and Remote Sensing. 2020. V. 162. pp. 94-114.

---



29. Wang X., Yu K., Wu S., Gu J., Liu Y., Dong C., Qiao Y., Change Loy C. Esrgan: Enhanced super-resolution generative adversarial networks // Proceedings of the European conference on computer vision (ECCV) workshops. 2018. pp. 0-2.

30. Wang C. Y., Bochkovskiy A., Liao H. Y. M. YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors // Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. IEEE, 2023. pp. 7464-7475.

31. Rout N. K., Dutta G., Sinha V., Dey A., Mukherjee S., Gupta G. Improved Pothole Detection Using YOLOv7 and ESRGAN // arXiv preprint arXiv:2401.08588. 2023.

32. Wang P., Wang C., Liu H., Liang M., Zheng W., Wang H., Liu S., Zhong G., Zhu S. Research on automatic pavement crack recognition based on the mask R-CNN model // Coatings. 2023. V. 13. №2. P. 430.

33. He K., Gkioxari G., Dollár P., Girshick R. Mask R-CNN // Proceedings of the IEEE international conference on computer vision. IEEE, 2017. pp. 2961-2969.

34. Хочу все знать. История автопилота // LiveJournal URL: [masterok.livejournal.com/440501.html](https://masterok.livejournal.com/440501.html) (дата обращения: 13.02.24).

35. Инерциальные измерительные единицы (ИИУ): краткий обзор основных понятий // Medium URL: [nyahmet.medium.com/inertial-measurement-units-imus-a-brief-summary-of-key-concepts-b86e6dbf6458](https://nyahmet.medium.com/inertial-measurement-units-imus-a-brief-summary-of-key-concepts-b86e6dbf6458) (дата обращения: 14.02.24).

36. Pei Y., Biswas S., Fussell S., Pingali K. An elementary introduction to Kalman filtering // Communications of the ACM. 2019. V. 62. №11. pp. 122-133.

37. Cai Y., Ma L., Cao Z., Zhang C., Ding G., Dong Q., Yue T., Geng X. Real-time monitoring for road-base quality with the aid of buried piezoelectric

sensors //Journal of Intelligent Material Systems and Structures. 2021. V. 32. №18-19. pp. 2231-2243.

38. Ma C., Xin X., Zhang N., Wang J., Wang C., Liang M., Yao Z., Zhang Y. Encapsulation for sensing element and its application in asphalt road monitoring // Coatings. 2023. V. 13. №2. P. 390.

39. Fedele R., Praticò F. G. Detecting Road Pavement Cracks Based on Acoustic Signature Analyses // European Workshop on Structural Health Monitoring. Cham: Springer International Publishing, 2020. pp. 437-446.

40. Cafiso S., Di Graziano A., Fedele R., Marchetta V., Praticò F. Sensor-based pavement diagnostic using acoustic signature for moduli estimation // International Journal of Pavement Research and Technology. 2020. V. 13. pp. 573-580.

41. Praticò F. G., Fedele R., Naumov V., Sauer T. Detection and monitoring of bottom-up cracks in road pavement using a machine-learning approach // Algorithms. 2020. V. 13. №4. P. 81.

42. Shtayat A., Moridpour S., Best B., Abuhassan M. Using supervised machine learning algorithms in pavement degradation monitoring // International Journal of Transportation Science and Technology. 2023. V. 12. №2. pp. 628-639.

43. Kavzoglu T., Bilucan F., Teke A. Comparison of support vector machines, random forest and decision tree methods for classification of sentinel-2A image using different band combinations // 41st Asian Conference on Remote Sensing. ACRS, 2020. V. 41. pp. 1-8.

44. Ikotun A. M., Ezugwu A. E., Abualigah L., Abuhaija B., Heming, J. K-means clustering algorithms: A comprehensive review, variants analysis, and advances in the era of big data // Information Sciences. 2023. V. 622. P. 178-210.

45. Dong D., Li Z. Smartphone sensing of road surface condition and defect detection // Sensors. 2021. V. 21. №16. p. 5433.

46. Cafiso S., Di Graziano A., Marchetta V., Pappalardo G. Urban road pavements monitoring and assessment using bike and e-scooter as probe vehicles // Case Studies in Construction Materials. 2022. V. 16. P. e00889.

47. Mihoub A., Krichen M., Alswailim M., Mahfoudhi S., Bel Hadj Salah R. Road scanner: A road state scanning approach based on machine learning techniques // Applied Sciences. 2023. V. 13. №2. P. 683.

48. Mehendale N., Neoge S. Review on lidar technology // Available at SSRN 3604309. 2020.

49. Raj T., Hanim Hashim F., Baseri Huddin A., Ibrahim M. F., Hussain A. A survey on LiDAR scanning mechanisms // Electronics. 2020. V. 9. №. 5. P. 741.

50. Лидары в беспилотном транспорте. Как с помощью лидаров беспилотные автомобили выстраивают траекторию движения? // Orient Systems URL: [orsyst.ru/blog/lidar/](https://orsyst.ru/blog/lidar/) (дата обращения: 23.04.2024)

51. Bhatta N., Priya G. M. RADAR and its applications // ИЖТА. 2017. V. 10. №3. pp. 1-9.

52. Plati C., Loizos A., Gkyrtis K. Assessment of modern roadways using non-destructive geophysical surveying techniques // Surveys in Geophysics. 2020. V. 41. №3. pp. 395-430.

53. Dong Z., Ye S., Gao Y., Fang G., Zhang X., Xue Z., Zhang T. Rapid detection methods for asphalt pavement thicknesses and defects by a vehicle-mounted ground penetrating radar (GPR) system // Sensors. 2016. V. 16. №12. p. 2067.

54. Guo S., Xu Z., Li X., Zhu P. Detection and characterization of cracks in highway pavement with the amplitude variation of GPR Diffracted waves: Insights from forward modeling and field data // Remote Sensing. 2022. V. 14. №4. P. 976.

55. Liu Z., Wu W., Gu X., Li S., Wang L., Zhang T. Application of combining YOLO models and 3D GPR images in road detection and maintenance // Remote Sensing. 2021. V. 13. №6. P. 1081.

---



56. Truu M., Raun R., Jentson M. Utilizing Effective Technology In High-Standard Road Defects Inventory System In Estonia // IOP Conference Series: Materials Science and Engineering. IOP Publishing, 2021. V. 1202. №1. P. 012009.

57. Hassan E. S., El-Hattab A. I., Ismail M., Elsharkawy A. Detection of Road Surface Damage by Using Terrestrial Laser Scanner // Port-Said Engineering Research Journal. 2020. V. 24. №1. pp. 35-43.

58. Karamizadeh S., Abdullah S., Manaf A., Zamani M., Hooman A. An overview of principal component analysis // Journal of signal and information processing. 2020. V. 4.

59. Wang R., Zhang S., Huang P., Zhang D., Chen H. NeRO: Neural Road Surface Reconstruction // arXiv preprint arXiv:2405.10554. 2024.

60. Eltner A., Sofia G. Structure from motion photogrammetric technique // Developments in Earth surface processes. Elsevier, 2020. V. 23. pp. 1-24.

61. Zeybek M., Ediz D. Detection of road distress with mobile phone LiDAR sensors // Advanced LiDAR. 2022. V. 2. №2. pp. 48-53.

### References

1. Infografika: kak izmenilsja park transportnyh sredstv v Rossii za 10 let? [Infographics: how has the vehicle fleet in Russia changed over 10 years?]. URL: [autostat.ru/infographics/46087/](http://autostat.ru/infographics/46087/) (accessed 21/12/23)

2. Pojavilsja rejting stran po dline dorog. My v pjaterke! [A ranking of countries by road length has appeared. We're in the top five!]. URL: [zr.ru/content/news/916887-rejting-stran-podline-avtomob/](http://zr.ru/content/news/916887-rejting-stran-podline-avtomob/) (accessed 20/12/23)

3. Infografika: Rejting rossijskih regionov po kachestvu dorog [Infographics: Rating of Russian regions by road quality]. URL: [ria.ru/20230703/dorogi-1881060572.html](http://ria.ru/20230703/dorogi-1881060572.html) (accessed 23/12/2023)

4. Faktory, vlijajushhie na sroki sluzhby avtomobil'nyh dorog [Factors influencing the service life of highways]. URL: [\[URL\]](#)



rep.bntu.by/bitstream/handle/data/62974/187-192.pdf?sequence=1&isAllowed=y  
(accessed 17/12/23)

5. Osnovnye prichiny DTP [Main causes of road accidents]. URL: avtoshkola177.ru /article/osnovnye-prichiny-dtp (accessed 12/11/2023)

6. Gosavtoinspekcija. Pokazateli sostojanija bezopasnosti dorozhnogo dvizhenija [State traffic inspectorate. Road safety indicators]. URL: stat.gibdd.ru (accessed 28/12/2023)

7. Sazonova S. A., Nikolenko S. D., Akamsina N. V. IOP Conference Series: Earth and Environmental Science. IOP Publishing, 2022. Vol. 988. №5. 052054 p.

8. Wang H. P., Guo Y. X., Wu M. Y., Xiang K., Sun S. R. Reviews on Advanced Materials Science. 2021. Vol. 60. №1. pp. 438-449.

9. Zhou Y., Guo X., Hou F., Wu J. Sustainability. 2022. Vol. 14. №10. 6306 p.

10. Vargas J., Alsweiss S., Toker O., Razdan R., Santos J. Sensors. 2021. Vol. 21. №16. 5397 p.

11. Dorozhnye laboratorii i izmeritel'noe oborudovanie [Road laboratories and measuring equipment]. URL: mp-lab.ru/application/road-laboratories/ (accessed 08/01/2024)

12. Kompleksnaja predvizhnaja dorozhnaja laboratorija «Trassa» [Complex mobile road laboratory "Track"]. URL: sdtech.ru/paper/trassa\_stat/ (accessed 09/01/2024)

13. PDL «ADS-MADI» [Mobile road laboratory "ADS-MADI"]. URL: madidt.ru/7-produkty.html (accessed 11/01/2024)

14. ROSDORNII predstavil innovacionnuju laboratoriju «Jeskandor» dlja nepreryvnoj diagnostiki avtodorog [RUSDORNII presented the innovative laboratory "Eskandor" for continuous diagnostics of highways]. URL: rosdornii.ru/press-center/news/novosti-bkd/rosdornii-predstavil-innovatsionnuju-

---

laboratoriyu-eskandor-dlya-nepreryvnoy-diagnostikiavtodorog/?sphrase\_id=32009  
(accessed 12/01/2024)

15. Uchebnyj centr. Kak rabotajut kamery? [Training center. How do cameras work?]. URL: [everpresent.com/how-do-cameras-work/](https://everpresent.com/how-do-cameras-work/) (accessed 13.02.2024)

16. Zhang A., Wang K. C., Li B., Yang E., Dai X., Peng Y., Chen C., Fei Y., Liu Y., Li Q. Computer- Aided Civil and Infrastructure Engineering. 2017. Vol. 32. №10. pp. 805-819.

17. Yamashita R., Nishio M., Do R. K. G., Togashi K. Insights into imaging. 2018. Vol. 9. pp. 611-629.

18. Hu Y., Furukawa T. Sensors. 2020. Vol. 20. №6. pp. 1640.

19. Fei Y., Wang K. C., Zhang A., Chen C., Li J., Li Q., Liu Y., Li B. IEEE Transactions on Intelligent Transportation Systems. IEEE, 2019. Vol. 21. №1. pp. 273-284.

20. Simonyan K., Zisserman A. arXiv preprint arXiv:1409.1556. 2014.

21. Redmon J., Divvala S, Grishick R, Farhadi A. Proceedings of the IEEE conference on computer vision and pattern recognition. IEEE, 2016. pp. 779-788.

22. Redmon J., Farhadi A. Proceedings of the IEEE conference on computer vision and pattern recognition. IEEE, 2017. pp. 7263-7271.

23. Mandal V., Uong L., Adu-Gyamfi Y. 2018 IEEE International Conference on Big Data. IEEE, 2018. pp. 5212-5215.

24. Lin Y. C., Chen W. H., Kuo C. H. Applied Sciences. 2021. Vol. 11. №8. 3725 p.

25. Redmon J., Farhadi A. arXiv preprint arXiv:1804.02767. 2018.

26. Deng L., Zhang A., Guo J., Liu Y. Remote Sensing. 2023. Vol. 15. №6. 1530 p.

27. Bochkovskiy A., Wang C. Y., Liao H. Y. M. arXiv preprint arXiv:2004.10934. 2020.

28. Diakogiannis F. I., Waldner F., Caccetta P., Wu C. ISPRS Journal of Photogrammetry and Remote Sensing. 2020. Vol. 162. pp. 94-114.
29. Wang X., Yu K., Wu S., Gu J., Liu Y., Dong C., Qiao Y., Change Loy C. Proceedings of the European conference on computer vision (ECCV) workshops. 2018. pp. 0-2.
30. Wang C. Y., Bochkovskiy A., Liao H. Y. M. Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. IEEE, 2023. pp. 7464-7475.
31. Rout N. K., Dutta G., Sinha V., Dey A., Mukherjee S., Gupta G. arXiv preprint arXiv:2401.08588. 2023.
32. Wang P., Wang C., Liu H., Liang M., Zheng W., Wang H., Liu S., Zhong G., Zhu S. Coatings. 2023. Vol. 13. №2. 430 p.
33. He K., Gkioxari G., Dollár P., Girshick R. IEEE, 2017. pp. 2961-2969.
34. Hochu vse znat'. Istorija avtopilota [I want to know everything. Autopilot history] URL: [masterok.livejournal.com/440501.html](http://masterok.livejournal.com/440501.html) (accessed 14.02.24).
35. Inercial'nye izmeritel'nye edinicy (IIU): kratkij obzor osnovnyh ponjatij [Inertial Measurement Units (IMUs): A Brief Summary of Key Concepts] URL: [nyahmet.medium.com/inertial-measurement-units-imus-a-brief-summary-of-key-concepts-b86e6dbf6458](https://nyahmet.medium.com/inertial-measurement-units-imus-a-brief-summary-of-key-concepts-b86e6dbf6458) (accessed 14.02.24).
36. Pei Y., Biswas S., Fussell S., Pingali K. Communications of the ACM. 2019. Vol. 62. №11. pp. 122-133.
37. Cai Y., Ma L., Cao Z., Zhang C., Ding G., Dong Q., Yue T., Geng X. Journal of Intelligent Material Systems and Structures. 2021. Vol. 32. №18-19. pp. 2231-2243.
38. Ma C., Xin X., Zhang N., Wang J., Wang C., Liang M., Yao Z., Zhang Y. Coatings. 2023. Vol. 13. №2. 390 p.
-

39. Fedele R., Praticò F. G. European Workshop on Structural Health Monitoring. Cham: Springer International Publishing, 2020. pp. 437-446.

40. Cafiso S., Di Graziano A., Fedele R., Marchetta V., Praticò F. International Journal of Pavement Research and Technology. 2020. Vol. 13. pp. 573-580.

41. Praticò F. G., Fedele R., Naumov V., Sauer T. Algorithms. 2020. Vol. 13. №4. 81 p.

42. Shtayat A., Moridpour S., Best B., Abuhassan M. International Journal of Transportation Science and Technology. 2023. Vol. 12. №2. pp. 628-639.

43. Kavzoglu T., Bilucan F., Teke A. 41st Asian Conference on Remote Sensing. ACRS, 2020. Vol. 41. pp. 1-8.

44. Ikotun A. M., Ezugwu A. E., Abualigah L., Abuhaija B., Heming, J. Information Sciences. 2023. Vol. 622. pp. 178-210.

45. Dong D., Li Z. Sensors. 2021. Vol. 21. №16. pp. 5433.

46. Cafiso S., Di Graziano A., Marchetta V., Pappalardo G. Case Studies in Construction Materials. 2022. Vol. 16. e00889 p.

47. Mihoub A., Krichen M., Alswailim M., Mahfoudhi S., Bel Hadj Salah R. Applied Sciences. 2023. Vol. 13. №2. 683 p.

48. Mehendale N., Neoge S. Available at SSRN 3604309. 2020.

49. Raj T., Hanim Hashim F., Baseri Huddin A., Ibrahim M. F., Hussain A. Electronics. 2020. Vol. 9. №. 5. 741 p.

50. Lidary v bespilotnom transporte. Kak s pomoshh'ju lidarov bespilotnye avtomobili vystraivajut traektoriju dvizhenija? [Lidars in unmanned vehicles. How do self-driving cars build a trajectory using lidars?] URL: [orsyst.ru/blog/lidar/](https://orsyst.ru/blog/lidar/) (accessed 23.04.2024)

51. Bhatta N., Priya G.M. IJCTA. 2017. Vol. 10. №3. pp. 1-9.

52. Plati C., Loizos A., Gkyrtis K. Surveys in Geophysics. 2020. Vol. 41. №3. pp. 395-430.

---



53. Dong Z., Ye S., Gao Y., Fang G., Zhang X., Xue Z., Zhang T. Sensors. 2016. Vol. 16. №12. 2067 p.
54. Guo S., Xu Z., Li X., Zhu P. Remote Sensing. 2022. Vol. 14. №4. 976 p.
55. Liu Z., Wu W., Gu X., Li S., Wang L., Zhang T. Remote Sensing. 2021. Vol. 13. №6. 1081 p.
56. Truu M., Raun R., Jentson M. IOP Conference Series: Materials Science and Engineering. IOP Publishing, 2021. Vol. 1202. №1. 012009 p.
57. Hassan E. S., El-Hattab A. I., Ismail M., Elsharkawy A. Port-Said Engineering Research Journal. 2020. Vol. 24. №1. pp. 35-43.
58. Karamizadeh S., Abdullah S., Manaf A., Zamani M., Hooman A. Journal of signal and information processing. 2020. Vol. 4.
59. Wang R., Zhang S., Huang P., Zhang D., Chen H. arXiv preprint arXiv:2405.10554. 2024.
60. Eltner A., Sofia G. Elsevier, 2020. Vol. 23. pp. 1-24.
61. Zeybek M., Ediz D. Advanced LiDAR. 2022. Vol. 2. №2. pp. 48-53.

**Дата поступления: 8.08.2024**

**Дата публикации: 24.11.2024**