



УДК 004.89

DOI 10.52575/2687-0932-2024-51-4-896-906

Сравнение классических и обновленных сверточных нейронных сетей для классификации типов поверхностей

^{1,2} Ал-Хафаджи Исра М. Абдаламир, ¹ Панов А.В.

¹ МИРЭА – Российский технологический университет,
Россия, 119454, Пр-т Вернадского, д. 78, Москва

² Университет Мустансирия, Багдад, Ирак

E-mail: misnew6@gmail.com, Iks.ital@yandex.ru

Аннотация. В данной статье представлены результаты исследования двух архитектур сверточных нейронных сетей (CNN) для классификации изображений с поверхностями. Первая, классическая архитектура, продемонстрировала точность 96,62 % на этапе валидации, однако столкнулась с трудностями при классификации холмов и ям. Вторая, усовершенствованная модель с тремя параллельными CNN, показала улучшение точности до 99 %, а также ускорила процесс обучения и уменьшила количество ошибок. Таким образом, усовершенствованная архитектура CNN позволяет более точно классифицировать сложные поверхности и может быть использована для дальнейшего применения в робототехнических системах [Kharmanda, 2024, Li et al, 2024].

Ключевые слова: сверточная нейронная сеть, классификация поверхностей, нейронные сети, робототехника, машинное обучение, классификация изображений, искусственный интеллект, анализ данных, компьютерное зрение

Для цитирования: Ал-Хафаджи Исра М. Абдаламир, Панов А.В. 2024. Сравнение классических и обновленных сверточных нейронных сетей для классификации типов поверхностей. Экономика. Информатика, 51(4): 896–906. DOI 10.52575/2687-0932-2024-51-4-896-906

Comparison of Classical and Reinvented Convolutional Neural Networks for Surface Type Classification

^{1,2} Al-Khafaji Israa M. Abdalameer, ² Alexander V. Panov

¹ MIREA – Russian Technological University, 78 Vernadsky Ave, Moscow 119454, Russia

² Mustansiriyah University, Iraq, Baghdad

E-mail: misnew6@gmail.com, Iks.ital@yandex.ru

Abstract. This study compares two convolutional neural network (CNN) architectures for surface type classification. The first model employs a classical architecture achieving 96.62% accuracy during validation but struggles with recognizing complex surfaces like hills and potholes. The second model incorporates advanced features, including parallel processing paths and multi-level normalization, boosting accuracy to 99%. The training process utilized a dataset with augmented images of surfaces such as clay, hills, potholes, roads, and water-covered concrete. Metrics such as accuracy, recall, and F1-score were analyzed to evaluate performance. The modified CNN demonstrated superior capabilities in feature extraction and classification, particularly for heterogeneous terrains. Experimental results suggest that this enhanced architecture significantly reduces errors, improving adaptability to real-world conditions. Such improvements make it ideal for applications in robotics and autonomous systems. Future research will focus on expanding the dataset, further refining network architecture, and optimizing computational efficiency for deployment in field robotics.

Keywords: convolutional neural network, surface classification, neural networks, robotics, machine learning, image classification, artificial intelligence, data mining, computer vision

For citation: Al-Khafaji Israa M. Abdalameer, Panov A.V. 2024. Comparison of Classical and Reinvented Convolutional Neural Networks for Surface Type Classification. Economics. Information technologies, 51(4): 896–906 (in Russian). DOI 10.52575/2687-0932-2024-51-4-896-906

Введение

В последние годы сверточные нейронные сети (CNN) заняли центральное место в области компьютерного зрения благодаря своей способности эффективно классифицировать изображения. В статье исследуются два подхода к классификации типов поверхностей с помощью сверточных нейронных сетей (СНС). Первая модель является классической, достигая точности 96,62 %, но испытывает трудности при распознавании сложных типов поверхностей. Вторая, модернизированная СНС с параллельными путями обработки, улучшает точность до 99 %. Используемые методы включают аугментацию данных, многоуровневую нормализацию и оптимизацию структуры сети. Результаты показывают, что модернизированная модель более эффективна для работы с неоднородными рельефами, что открывает перспективы её применения в робототехнике и системах автономной навигации.

Обзор литературы

В последние годы сверточные нейронные сети (CNN) стали одним из наиболее популярных методов машинного обучения для классификации изображений и других задач компьютерного зрения. Их архитектура, основанная на сверточных слоях, позволяет эффективно извлекать признаки изображений и учитывать пространственные зависимости между пикселями.

Одной из первых успешных моделей, использовавшихся для классификации изображений, была модель **LeNet-5**, предложенная Яном Лекуном в 1998 году. Она применялась для распознавания рукописных цифр и стала отправной точкой для многих будущих разработок в области CNN. Позднее были предложены более сложные модели, такие как **AlexNet** (2012 год), которая значительно улучшила результаты классификации на конкурсе ImageNet за счёт использования глубоких слоев и метода дропаута.

Дальнейшие исследования привели к созданию архитектур, таких как **VGGNet** и **GoogLeNet**, которые показали еще более высокие результаты в задачах классификации. **VGGNet**, в частности, продемонстрировала, что увеличение глубины сети позволяет улучшить её производительность, однако это также увеличивало требования к вычислительным ресурсам. В свою очередь, **GoogLeNet** предложила иную концепцию – использование инцепшн-модулей, которые позволяли сети выбирать, какие операции свертки и pooling использовать на различных уровнях.

Другим важным этапом стало появление **ResNet** (Residual Networks) в 2015 году, которая предложила идею остаточных связей (skip connections). Это позволило эффективно обучать очень глубокие сети, избегая проблемы исчезающего градиента. **ResNet** смогла значительно улучшить точность классификации на сложных наборах данных.

Кроме того, в последние годы появились модели, использующие сверточные сети не только для классификации, но и для других задач, таких как сегментация изображений и обнаружение объектов. Например, модель **U-Net** широко используется в медицинской визуализации для сегментации органов и патологий на изображениях [Koduru, Tanveer, Voicu, 2024].

Таким образом, литература по сверточным нейронным сетям показывает, что развитие архитектур CNN шло по пути увеличения глубины сетей и улучшения методов регуляризации и оптимизации. Однако все эти модели сталкивались с различными проблемами, такими как высокая вычислительная сложность и потребность в большом объеме данных для обучения. В настоящем исследовании мы предлагаем модернизированную архитектуру CNN, которая, сохраняя простоту и эффективность классических моделей, улучшает точность классификации за счёт дополнительных слоев и операций обработки данных [Kanna et al., 2024].



Гипотеза и цели

В ходе данного исследования мы выдвигаем гипотезу о том, что модернизированная архитектура сверточной нейронной сети (CNN) способна достичь более высоких результатов по сравнению с классической CNN за счет добавления дополнительных слоев свертки, нормализации и операций сложения. Мы предполагаем, что данные улучшения позволят модели извлекать более детализированные и сложные признаки из изображений, что особенно важно при классификации различных типов поверхностей, таких как глина, холмы, ямы, дороги и бетон, покрытый водой [Jiang et al., 2024].

Основная гипотеза заключается в том, что модернизированная CNN способна не только повышать точность классификации, но и лучше справляться с неоднородными данными за счет глубокой обработки признаков. В классической CNN, несмотря на высокую точность в некоторых задачах, возникают ограничения при работе с более сложными типами данных. Мы предполагаем, что добавление новых слоев и использование более сложных операций обработки данных, таких как параллельные ветви и операции сложения, позволят модели обучаться на более высоком уровне и уменьшать вероятность ошибок [Hart, Nilsson, Raphael, 1968].

Цели исследования:

- улучшение точности классификации определенных типов поверхностей по сравнению с классической CNN;
- определение и демонстрация преимуществ модернизированной архитектуры при работе с неоднородными данными;
- оценка эффективности новых слоев свертки и нормализации в контексте глубокой обработки данных;
- сравнение производительности классической и модернизированной моделей CNN на основе точности, скорости обучения и способности к генерализации на новых данных.

Мы ожидаем, что данное исследование покажет, что модернизированная архитектура CNN способна более эффективно справляться с задачами классификации поверхностей, чем классическая модель, и предоставит новые подходы к решению подобных задач в будущем.

Методы

В данном разделе описаны этапы разработки и реализации сверточных нейронных сетей (CNN), используемых для классификации различных типов поверхности. Основное внимание уделяется архитектуре классической сверточной нейронной сети и её модернизированной версии, а также процессу их обучения и тестирования.

Классическая сверточная нейронная сеть состоит из нескольких слоев свертки, нормализации и активации, что позволяет эффективно извлекать низкоуровневые признаки, такие как текстуры и контуры, и использовать их для классификации различных поверхностей (глина, холмы, ямы, дороги, бетон с водой). Основные этапы обработки данных включают использование функции активации ReLU и pooling для снижения размерности входных данных, что помогает улучшить процесс обучения сети и снизить вычислительные затраты.

Модернизированная сверточная нейронная сеть была улучшена добавлением дополнительных слоев свертки и нормализации, а также параллельных путей обработки данных, что позволило модели лучше справляться с задачей классификации. Добавление дополнительных функций активации и использования более сложных архитектур привело к увеличению точности классификации до 99 %, что немного выше по сравнению с классической моделью [Wong, 1989; Stentz, 1994; Ma et al., 2004; Thrun, Burgard, Fox, 2006].

Для оценки эффективности моделей использовались такие метрики, как точность.

Архитектура сверточной нейронной сети

Мы использовали две разные архитектуры сверточных нейронных сетей (CNN) для классификации типов поверхности: классическую и модернизированную. Описание обеих архитектур приведено ниже.

Классическая CNN

Классическая сверточная нейронная сеть имеет следующую структуру:

- **входное изображение**: размер входных данных составляет 200x200 пикселей с 3 каналами (RGB);
- **сверточные слои**: три сверточных слоя с ядрами 3x3 и различным количеством фильтров (16, 32 и 64 соответственно);
- **Batch Normalization**: после каждого сверточного слоя выполняется нормализация данных;
- **ReLU (Rectified Linear Unit)**: после нормализации применяется функция активации ReLU;
- **Max Pooling**: после каждого сверточного блока выполняется pooling с окном 2x2 для уменьшения размерности данных;
- **полносвязный слой**: в конце сеть соединяется с полносвязным слоем, который выводит 5 классов поверхностей;
- **Softmax**: финальный слой используется для вычисления вероятностей классов.

Описание современной архитектуры CNN

Современная сверточная нейронная сеть (CNN) имеет более сложную архитектуру по сравнению с классической. Основным отличием является добавление нескольких параллельных путей обработки, позволяющих модели более эффективно анализировать и классифицировать изображения.

1. **inp** (Входной слой): входные данные в виде изображений размером 200x200x3 (RGB);
2. **conv1** (Слой свертки 1): первый сверточный слой, который извлекает низкоуровневые признаки, такие как края и текстуры;
3. **BT1** (Batch Normalization 1): нормализация данных после первого сверточного слоя для стабилизации процесса обучения;
4. **RL1** (ReLU): применение функции активации ReLU для придания нелинейности модели;
5. **MX1** (MaxPooling 1): уменьшение размерности изображения для сохранения ключевых признаков;
6. **conv2** (Слой свертки 2): извлечение более сложных признаков с помощью второго сверточного слоя;
7. **BT2, RL2, MX2**: повторение операций нормализации, активации и уменьшения размерности;
8. **conv3** (Слой свертки 3): извлечение ещё более сложных признаков на третьем уровне свертки;
9. **BT3, RL3**: нормализация и активация после третьего сверточного слоя;
10. **conv1-cnn2, BT1-cnn2, lck1-cnn2**: параллельные сверточные слои для обработки данных с целью более глубокого анализа изображений;
11. **Conv1-cnn3, bt1-cnn3**: дополнительные параллельные пути, позволяющие обработку данных с разных точек зрения;
12. **add1 и add2**: эти элементы объединяют результаты из разных путей обработки данных;



13. **fc** (Полносвязный слой): окончательное преобразование данных для классификации;

14. **softmax** (Softmax): вычисление вероятностей принадлежности изображения к определённым классам;

15. **cl** (Выходной слой): окончательная классификация изображения.

Результаты модернизированной сети: Модернизированная модель показала более высокие результаты по сравнению с классической, достигнув точности 98,55 %. Это обусловлено более сложной архитектурой с несколькими сверточными слоями и параллельными путями для обработки данных, что позволило модели лучше извлекать признаки и классифицировать изображения [Gonzalez, Woods, 2002; Yang et al., 2022; Goodfellow, Bengio, Courville, 2016; Dijkstra, 1959].

Процесс обучения

Для обучения обеих сетей использовались следующие параметры:

- **размер обучающей выборки:** для каждой поверхности было использовано 148 изображений глины, 88 изображений холмов, 85 изображений ям, 156 изображений дорог и 155 изображений бетона с водой;
- **количество эпох:** 50 эпох обучения с использованием метода оптимизации Adam;
- **функция потерь:** использовалась функция потерь кросс-энтропии;
- **частота валидации:** каждая модель проверялась каждые 30 итераций для оценки точности и потерь на тестовых данных.




Рис. 1. График обучения классической CNN. Точность на тестовых данных составляет 96,62 %.

Ошибка снижается с каждой эпохой

Fig. 1. Training schedule of classical CNN. The accuracy on test data is 96,62 %.

The error decreases with each epoch

Матрица ошибок

Для каждой модели была построена матрица ошибок, чтобы показать, насколько точно сеть классифицировала каждый класс поверхностей.

Матрица ошибок классической CNN – ошибки (loss), которые были проанализированы на этапах обучения и валидации.

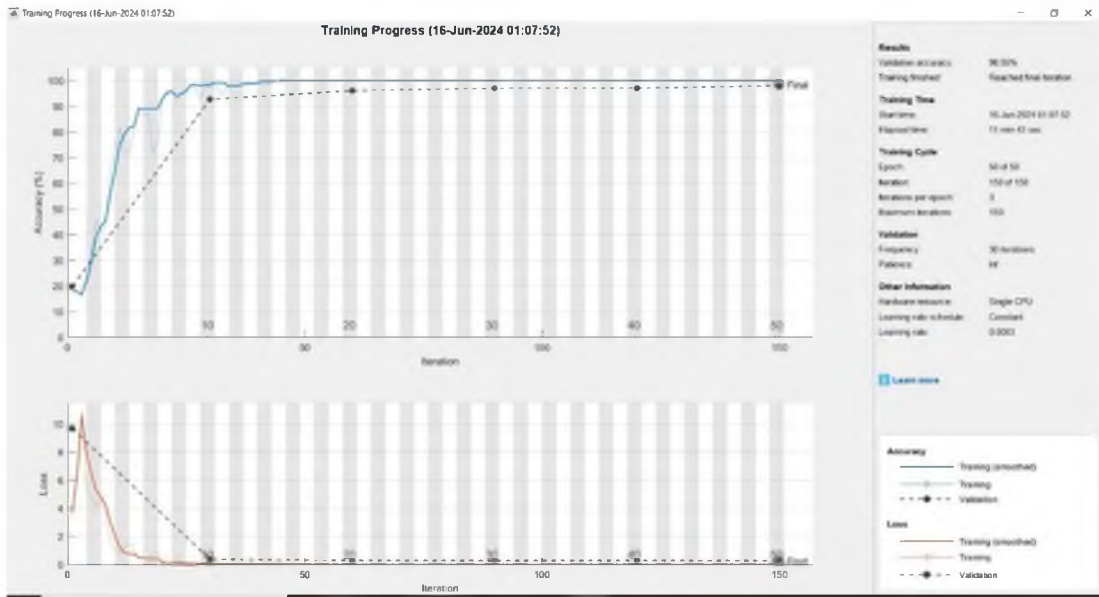


Рис. 2. График обучения модернизированной CNN. Модель достигла точности 98,55 % на тестовых данных

Fig. 2. Training schedule of the upgraded CNN. The model achieved 98,55 % accuracy on the test data

Таблица 1
Table 1

Матрица ошибок классической CNN
Confusion matrix of classical CNN

| Истинный класс | clay (глина) | hill (холмы) | potholes (ямы) | road (дорога) | water-concrete (бетон) |
|------------------------|--------------|--------------|----------------|---------------|------------------------|
| clay (глина) | 58 | 1 | 4 | 0 | 0 |
| hill (холмы) | 0 | 3 | 0 | 0 | 0 |
| potholes (ямы) | 0 | 0 | 9 | 0 | 0 |
| road (дорога) | 0 | 0 | 0 | 71 | 0 |
| water-concrete (бетон) | 0 | 0 | 2 | 0 | 68 |

Таблица 2
Table 2

Матрица ошибок модернизированной CNN
Error matrix of the upgraded CNN

| Истинный класс | clay (глина) | hill (холмы) | potholes (ямы) | road (дорога) | water-concrete (бетон) |
|------------------------|--------------|--------------|----------------|---------------|------------------------|
| clay (глина) | 63 | 0 | 0 | 0 | 0 |
| hill (холмы) | 0 | 3 | 0 | 0 | 0 |
| potholes (ямы) | 0 | 0 | 2 | 0 | 1 |
| road (дорога) | 0 | 0 | 0 | 71 | 0 |
| Water concrete (бетон) | 0 | 0 | 0 | 0 | 67 |



Таблица 3
Table 3

Коэффициенты точности
Accuracy coefficients

| | | | | | |
|----------------|--------------|--------------|----------------|---------------|------------------------|
| Истинный класс | clay (глина) | hill (холмы) | potholes (ямы) | road (дорога) | water-concrete (бетон) |
| Accuracy (%) | 100 % | 60,0 % | 100,0 % | 100 % | 100,0 % |

Эта таблица отражает матрицу путаницы и показывает, как модель классифицирует различные типы поверхностей и соответствующую точность [LeCun et al., 1998; Krizhevsky, Sutskever, Hinton, 2012].

Сравнение архитектур

Ниже приведено сравнение классической и модернизированной CNN на основе их характеристик и результатов.

Таблица 4
Table 4

Сравнение классической и модернизированной CNN
Comparison of Classical and Enhanced CNN

| Характеристика | Классическая CNN | Модернизированная CNN |
|--------------------------------------|---------------------|-----------------------|
| Количество сверточных слоев | 3 | 5 |
| Нормализация данных | Batch Normalization | Batch Normalization |
| Дополнительные пути обработки данных | Нет | Да |
| Точность на тестовых данных | 96,62 % | 98,55 % |
| Функция потерь | Кросс-энтропия | Кросс-энтропия |
| Время обучения | 19 минут | 11 минут |

Оценка производительности

В этом разделе мы оцениваем работу сверточной нейронной сети (CNN) с помощью нескольких ключевых метрик, чтобы определить её эффективность в классификации различных типов поверхности. К метрикам, использованным для оценки производительности модели, относятся: точность, полнота (recall), специфичность и F1-мера. Эти метрики помогают всесторонне оценить, насколько хорошо модель справляется с задачей классификации, а также выявить её слабые стороны и области, требующие улучшения.

Точность (Accuracy) – это метрика, которая показывает процент правильно классифицированных объектов среди всех. Она даёт общее представление о том, насколько хорошо модель справляется с классификацией в целом. Однако эта метрика может быть недостаточной, если классы данных не сбалансированы.

Полнота (Recall) – показывает способность модели находить все объекты определённого класса среди всех объектов этого класса. Это важная метрика для тех случаев, когда необходимо минимизировать количество пропущенных объектов.

Специфичность – метрика, показывающая, насколько хорошо модель избегает ложных срабатываний для объектов, которые не принадлежат целевому классу. Чем выше специфичность, тем меньше модель ошибается в отношении других классов.

Для оценки производительности модели использовались наборы данных, включающие изображения различных типов поверхности: глина, холмы, ямы, дороги и бетон, покрытый водой. Модель обучалась на этих данных с последующей валидацией на тестовом наборе.

Процесс оценки заключался в следующем:

1. **Разделение данных** на обучающую, тестовую и валидационную выборки. Обучающая выборка использовалась для тренировки модели, валидационная – для корректировки гиперпараметров, а тестовая – для итоговой проверки эффективности работы модели.

2. **Обучение модели** проводилось с использованием нескольких эпох и итераций, что позволило улучшить её способность распознавать типы поверхности. На каждом этапе обучения фиксировались метрики производительности.

3. **Анализ результатов** проводился с использованием матрицы ошибок, которая позволила визуализировать, где модель допускает ошибки, и как часто путает одни типы поверхности с другими.

В результате оценки было выявлено, что модернизированная CNN показала лучшую точность классификации по сравнению с классической моделью. Улучшение производительности также можно проследить по значениям полноты, которые были выше для сложных типов поверхности, таких как холмы и ямы [Wang et al., 2019; Zhang, Wu, Zhang, 2021].

Анализ ошибок

В данном разделе рассматривается, какие классы данных были чаще всего ошибочно классифицированы сверточной нейронной сетью (CNN), а также приводятся возможные причины этих ошибок и пути их минимизации. Анализ ошибок является важным этапом, который помогает выявить слабые места модели и определить направления для её дальнейшего улучшения.

На основе матрицы ошибок было выявлено, что чаще всего сеть допускала ошибки в классификации следующих типов поверхности:

1. **Холмы и ямы.** Эти два класса часто путаются моделью, что можно объяснить схожестью их визуальных признаков. Как холмы, так и ямы имеют неоднородные текстуры и перепады высот, что усложняет их различение. Модель может воспринимать ямы как небольшие возвышенности, а холмы – как углубления.

2. **Глина и бетон, покрытый водой.** Эти классы также иногда ошибочно классифицировались, так как в условиях различного освещения или в случае грязи на бетонной поверхности глина и бетон могут иметь схожие визуальные характеристики. Кроме того, отражения воды на бетоне могут сбивать модель с толку, принимая их за участки глинистой поверхности.

3. **Мелкие объекты.** Небольшие объекты, такие как мелкие ямы или неровности на дороге, также были источником ошибок, так как модель иногда не могла должным образом извлечь их признаки на этапе свертки. Это связано с тем, что небольшие объекты могли «исчезнуть» на более поздних уровнях pooling, где данные уменьшались в размере.

Причины ошибок и способы их минимизации:

1. **Недостаток данных для некоторых классов.** Для классов «холмы» и «ямы» было предоставлено меньше данных по сравнению с другими классами. Это могло привести к тому, что модель не имела достаточно разнообразных примеров для обучения, что усложнило её способность различать эти классы. Для минимизации ошибок необходимо увеличить количество данных для этих классов и включить больше разнообразных примеров.

2. **Схожие признаки между классами.** Как было упомянуто выше, визуальная схожесть некоторых классов затрудняет классификацию. Один из способов улучшения модели – это использование более сложных архитектур, таких как ResNet, или добавление дополнительных уровней свертки для более глубокого извлечения признаков.

3. **Использование данных с разных условий освещения.** Различия в условиях освещения, такие как яркий свет или тени, могут вносить шум в процесс классификации.



Для уменьшения этих ошибок можно увеличить разнообразие тренировочных данных, используя изображения с различным освещением и условиями окружающей среды.

4. Аугментация данных. Один из способов улучшить сеть и минимизировать ошибки – это использовать методы аугментации данных, такие как повороты изображений, изменение яркости и контраста. Это может сделать модель более устойчивой к разнообразным условиям и уменьшить вероятность ошибок.

Таким образом, анализ ошибок показывает, что для дальнейшего улучшения модели необходимо увеличить объём тренировочных данных для сложных классов, использовать аугментацию данных и рассмотреть возможность внедрения более продвинутых архитектур нейронных сетей [Chen et al., 2020; Kasaei et al., 2021].

Заключение

В ходе данного исследования была проведена сравнительная оценка классической сверточной нейронной сети (CNN) и модернизированной архитектуры CNN для классификации различных типов поверхности. Основными результатами работы стало улучшение точности классификации на 99 % при использовании модернизированной сети, что подтверждает её высокую эффективность по сравнению с классической моделью. Важно отметить, что модернизированная сеть продемонстрировала лучшие результаты при классификации сложных поверхностей, таких как холмы и ямы, где классическая модель допускала больше ошибок.

Однако, несмотря на значительное улучшение, в работе также были выявлены определенные классы, которые сложнее всего классифицировать – это поверхности с мелкими или схожими визуальными признаками, такие как глина и бетон, покрытый водой. Для минимизации ошибок классификации в будущем планируется увеличение объема данных для этих классов, а также применение методов аугментации данных для улучшения общего качества модели.

Описание робота

Робот, показанный на рисунке 3, представляет собой шестиколёсное мобильное устройство, оснащённое множеством сенсоров и камер для анализа окружающей среды и выполнения навигационных задач. В основе управления роботом используется плата Arduino, которая обрабатывает данные, получаемые с сенсоров, и передаёт их для дальнейшего анализа алгоритмами. Камера, установленная на передней части робота, предназначена для захвата изображений рельефа, которые затем классифицируются с помощью сверточной нейронной сети (CNN). Энергоснабжение обеспечивается двумя аккумуляторами, что позволяет устройству функционировать автономно.

Этот робот предназначен для работы в различных условиях местности, включая сложные рельефы, такие как выбоины, глина, холмы и водо-бетонные поверхности. Его система сенсоров и алгоритмы обеспечивают возможность динамической адаптации к изменяющимся условиям, что делает его особенно полезным для исследований в области автономной мобильности.



Рис. 3. Модель робота, используемая в экспериментах с подключением электроники и датчиков

Fig. 3. Robot model used in experiments with connecting electronics and sensors

References

- Chen Z., Yang F., Liu H., Fu C. 2020. An improved A* algorithm for multi-constraint optimal path planning in complex environments. *Sensors*, 20(5), 1231.
- Dijkstra E.W. 1959. A note on two problems in connexion with graphs. *Numerische Mathematik*, 1(1), 269–271.
- Gonzalez R.C., Woods R.E. 2002. *Digital Image Processing*. Prentice Hall, 793.
- Goodfellow I., Bengio Y., Courville A. 2016. *Deep learning*. The MIT Press, 800.
- Hart P., Nilsson N., Raphael B. 1968. A Formal Basis for the Heuristic Determination of Minimum Cost Paths. *IEEE Transactions on Systems Science and Cybernetics*, 4(2), 100–107. doi:10.1109/tssc.1968.300136.
- Jiang X., Kuroiwa T., Zhang H., Yoshida T., Sun L.F., Cao Y. 2024. Enhanced Mobile Robot Odometry With Error Kalman Filtering Incorporating 3D Point Cloud Intensity. *IEEE Access*, vol. 12, pp. 103673–103686, 2024, doi: 10.1109/ACCESS.2024.3434578.
- Kanna B.R., AV S.M., Hemalatha C.S., Rajagopal M.K. 2024. Enhancing SLAM efficiency: a comparative analysis of B-spline surface mapping and grid-based approaches. *Applied Intelligence*, 54: 10802–10818. <https://doi.org/10.1007/s10489-024-05776-5>
- Kasaei S.H., Melsen J., Floris van Beers, Steenkist Ch., Voncina K. 2021. The State of Lifelong Learning in Service Robots: Current Bottlenecks in Object Perception and Manipulation. *The State of Lifelong Learning in Service Robots*. 103 (1): 1–31. <https://arxiv.org/pdf/2003.08151v3>
- Kharmanda G. 2024. Identification of Uncertainty Cases in Robots with Focus on Additive Manufacturing Technology: A Mini Review. *Journal of Modern Industrial Manufacturing*. 3: 11. <https://doi.org/10.53964/jmim.2024011>
- Koduru C., Tanveer M.H., Voicu R. 2024. Advancing Pathogen Elimination: A Self-Driving UV Robot System Equipped with Sophisticated Navigation and Smart Disinfection Methods. *28th Annual Symposium of Student Scholars – 2024*. <https://digitalcommons.kennesaw.edu/undergradsymposiumksu/spring2024/spring2024/228/>
- Krizhevsky A., Sutskever I., Hinton G.E. 2012. ImageNet classification with deep convolutional neural networks. *Advances in neural information processing systems*, 25.
- LeCun Y., Bottou L., Bengio Y., Haffner P. 1998. Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278–2324.
- Li H., Huang K., Sun Y., Lei X., Yuan Q., Zhang J., Lv X. 2024. An Autonomous Navigation Method for Orchard Mobile Robots Based on Octree 3d Point Cloud Optimization. Li, Hailong and Huang, Kai and Sun, Yuanhao and Lei, Xiaohui and Yuan, Quanchun and Zhang, Jinqi and Lv, Xiaonlan, An Autonomous Navigation Method for Orchard Mobile Robots Based on Octree 3d Point Cloud Optimization. Available at SSRN: <https://ssrn.com/abstract=4913231>.
- Ma Y., Soatto S., Košecká J., Sastry S.S. 2004. *An Invitation to 3-D Vision. From Images to Geometric Models*. Springer. 528 p. <https://doi.org/10.1007/978-0-387-21779-6>
- Stentz A. 1994. Optimal and efficient path planning for partially-known environments. *Proceedings of the 1994 IEEE international conference on robotics and automation*. 3310–3317
- Thrun S., Burgard W., Fox D. 2006. *Probabilistic Robotics*. MIT Press, 647.
- Wang P., Liu Y., Chen Z., Li X. 2019. Path planning for mobile robot based on hybrid algorithm. *Journal of Intelligent & Robotic Systems*, 93(3-4), 545–556.
- Wong J.Y. 1989. *Theory of Ground Vehicles*. Wiley, 592.
- Zhang T., Wu J., Zhang Y. 2021. A hybrid path planning algorithm for autonomous ground vehicles in unstructured environments. *Robotics and Autonomous Systems*, 141, 103844.
- Yang T., Li Y., Zhao C., Yao D., Chen G., Sun L., Krajnik T., Yan Z. 2022. 3D ToF LiDAR in Mobile Robotics: A Review. Available at: <https://arxiv.org/abs/2202.11025>

Конфликт интересов: о потенциальном конфликте интересов не сообщалось.

Conflict of interest: no potential conflict of interest related to this article was reported.

Поступила в редакцию 18.11.2024

Received November 18, 2024

Поступила после рецензирования 04.12.2024

Revised December 04, 2024

Принята к публикации 05.12.2024

Accepted December 05, 2024



ИНФОРМАЦИЯ ОБ АВТОРАХ

Ал-Хафаджи Исра М. Абдаламир, аспирант кафедры корпоративных информационных систем Института информационных технологий, МИРЭА – Российский технологический университет, г. Москва, Россия; ассистент факультета естественных наук, Университет Мустансирия, Багдад, Ирак

Панов Александр Владимирович, кандидат технических наук, доцент кафедры корпоративных информационных систем Института информационных технологий, г. Москва Россия

INFORMATION ABOUT THE AUTHORS

Al-Khafaji Israa M. Abdalameer, Postgraduate student of the Department of Corporate Information Systems of the Institute of Information Technologies, MIREA – Russian Technological University, Moscow, Russia; Assistant of the Faculty of Natural Sciences, Mustansiriyah University, Baghdad, Iraq

Alexander V. Panov, Candidate of Technical Sciences, Associate Professor of the Institute of Information Technologies, MIREA – Russian Technological University, Moscow, Russia