

**ИНФОРМАЦИОННЫЕ ТЕХНОЛОГИИ,
АВТОМАТИКА И ТЕЛЕКОММУНИКАЦИИ**

УДК 004.89

DOI 10.46973/0201-727X_2025_1_51

*И. М. А. Ал-Хафаджи, А. В. Панов***УЛУЧШЕНИЕ ПЕРЕДВИЖЕНИЯ ШЕСТИКОЛЕСНОГО НАЗЕМНОГО РОБОТА
ПО РАЗЛИЧНЫМ ТИПАМ МЕСТНОСТИ С ИСПОЛЬЗОВАНИЕМ АЛГОРИТМА А*
И НЕЙРОННЫХ СЕТЕЙ**

Аннотация. Рассматривается сверточная нейронная сеть для классификации типов поверхностей, с которыми столкнулись мобильные роботы при выполнении задач навигации. Анализируется классификация из пяти типов поверхностей, на которые можно натолкнуться в Ираке: глина, холмы, ямы, дороги и бетонные покрытия. Архитектура сверточной нейронной сети (CNN) состоит из трех блоков свертки со слоями нормализации и активации ReLU, слоя объединения, полносвязанного классификационного слоя после CNN. Обучение с 96,62 % точностью убедило, что это эффективно. Лучевые графики показывают острый спад потерь и улучшение точности классификации, а кросс-матрица подтверждает успешное распознавание большинства типов поверхностей с недопущением ошибки в классификации холмов. CNN позволяет этим роботам быстрее приспособиться к такой сложной местности, динамически корректируя навигационные пути, что значительно повышает надежность и автономность в реальных операциях.

Ключевые слова: матрица путаницы, типы поверхности, алгоритм А*, навигация мобильного робота, сверточная нейронная сеть (CNN), типы поверхности.

Для цитирования: Ал-Хафаджи, И. М. А. Улучшение передвижения шестиколесного наземного робота по различным типам местности с использованием алгоритма А* и нейронных сетей / И. М. А. Ал-Хафаджи, А. В. Панов // Вестник Ростовского государственного университета путей сообщения. – 2025. – № 1. – С. 51–57. – DOI 10.46973/0201-727X_2025_1_51.

Введение

Шестиколесные роботы играют важную роль в неблагоприятных условиях эксплуатации, таких как зоны препятствий, неровные ландшафты и суровая окружающая среда. Роботы выполняют различные виды деятельности, такие как спасение, разведка и сбор данных, когда люди могут столкнуться с ограничениями доступа или невозможностью безопасного передвижения. Поэтому оптимизация их способности передвижения в различных ландшафтах остается сложной задачей в робототехнике.

Постановка задачи

Исследование направлено на улучшение передвижения шестиколесного наземного робота по различным типам местности с использованием комбинации алгоритма А* и сверточных нейронных сетей (CNN). Основной проблемой является обеспечение классификации поверхности в реальном времени и динамическая корректировка маршрута для оптимизации навигации. Робот должен передвигаться по пяти конкретным типам поверхностей: глина, холмы, ямы, дороги и бетонные покрытия, – каждая из которых предъявляет уникальные требования к мобильности. Использование классификации поверхности на основе CNN в сочетании с алгоритмом А* позволяет улучшить автономную навигацию за счет динамической адаптации к изменениям рельефа, сокращения времени передвижения и повышения надежности работы в сложных условиях.

Целью данного исследования является использование алгоритма А* в сочетании с нейронными сетями для повышения навигационной способности 6-колесного робота на пяти видах поверхностей: глина, холмы, ямы, дороги и бетонные покрытия. Алгоритм А* эффективен при поиске пути и выбран в качестве основного метода, поскольку он может учитывать расстояние до цели и сложность ландшафта, а сверточная нейронная сеть используется для классификации поверхностей, чтобы робот мог справиться с изменяющимися условиями в режиме реального времени.

Обзор предыдущих исследований

В области улучшения передвижения мобильных роботов было проведено множество исследований, основанных на использовании нейронных сетей и алгоритмов планирования маршрута. Ниже представлен краткий обзор некоторых из них:

– Планирование пути с использованием оптимизационных алгоритмов.

Исследование, проведенное на кафедре информатики Технологического университета Ирака, рассматривает улучшение планирования маршрута мобильных роботов в сложных и загруженных средах с помощью оптимизационных алгоритмов. Цель исследования заключалась в разработке алгоритмов, позволяющих строить безопасные и эффективные маршруты с минимальными затратами энергии. Было установлено, что комбинация генетического алгоритма и алгоритма гориллы обеспечивает наилучшее планирование передвижения робота [1].

– Использование искусственных нейронных сетей для планирования траектории робота.

В другом исследовании рассматривалось применение нейронных сетей для управления движением роботизированной руки с несколькими пальцами. Цель работы состояла в обучении системы всем необходимым движениям, что позволяет прогнозировать и управлять положением суставов руки на основе данных, полученных в процессе обучения нейросети. Результаты показали высокую точность и адаптивность метода [2].

– Применение нейросетевых моделей в навигации мобильных роботов.

В данной работе исследуется планирование маршрута робота на основе нейронных сетей. Авторы разработали модель предсказания маршрута робота, использующую методы искусственного интеллекта, что позволило значительно повысить точность и эффективность передвижения роботов в различных условиях [3].

Описание робота

Это мобильное устройство, выполняющее навигационные задачи и оснащенное камерой для анализа окружающей среды. Робот управляется платой Arduino, которая обрабатывает данные, полученные от датчиков, и преобразует их в алгоритмы для дальнейшего анализа. Фронтальная камера делает снимки местности, которые затем классифицируются с помощью трех сверточных нейронных сетей (CNN), предназначенных для классификации и распознавания поверхностей.

Этот робот разработан для работы в различных условиях местности, включая сложные среды: глина, холмы, ямы, дороги и бетонные покрытия.




Рис. 1. Экспериментальная модель робота, иллюстрирующая включение электроники и сенсорных систем

Применение алгоритма A* для шестиколесного робота

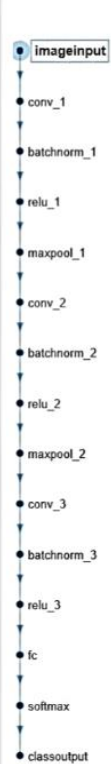
Рельеф, по которому движется робот, моделируется в виде графа, где узлы представляют возможные положения робота, а ребра – пути между ними. Каждый тип поверхности, будь то глина, дороги или холмы, имеет определенную стоимость перемещения. Конструкция должна учитывать сложность рельефа, обеспечивая реалистичное представление условий вождения.

Алгоритм А* использует эвристику для оценки расстояния от текущего положения робота до целевой точки аналогично обработке данных с камеры робота. Например, движение по скользким поверхностям или выбоинам может потребовать больше энергии и времени. Эвристическая оценка позволяет роботу отдавать приоритет наиболее безопасным и энергоэффективным маршрутам.

Для динамической адаптации у робота нет точной информации о типе поверхности, по которой он движется. Характеристики рельефа определяются с помощью камеры и анализируются сверточной нейронной сетью (CNN). Благодаря динамической оценке робот выбирает путь через наиболее безопасную область, например, предпочитая движение по асфальту, даже если он находится дальше от глины. Такой подход формирует структуру CNN, гарантируя ее адаптацию к изменяющимся условиям местности.

Анализ архитектуры сверточной нейронной сети (CNN) для классификации типов поверхности

Для эффективного извлечения признаков из изображений и их последующей классификации использовалась архитектура CNN. Архитектура CNN, используемая для классификации типов поверхности, является самодостаточной и используется вместе с другими слоями для достижения консенсуса. Для начала сеть принимает изображения размером 200×200 пикселей с тремя каналами, которые сначала подлежат нормализации. После нормализации используется первый сверточный слой, содержащий 16 фильтров 3×3 . Однако размеры изображений сохраняются за счёт свойства заполнения. Эти фильтры добавлены к каждой строке изображения или столбцу, позволяя сохранить размер. Эти отрезки изображения или строчки являются признаками. После использования сверточного слоя используется слой нормализации. Этот слой фиксирует ошибки со средним значением и отклонением, что улучшает стабильность работы. Следующим уровнем является слой активации ReLU для введения нелинейности. Максимальный пул используется для выборки информационно богатых областей с помощью окна 2×2 (рис. 2). Второй сверточный подход используется после первого сверточного слоя. Последующий шаг после нормализации – активация maxpool. В этом случае количество фильтров нашего третьего сверточного слоя становится 64. Далее совместно используется сверточная нормализация для уменьшения пространственной размерности функций.



The diagram on the left shows a vertical flow of layers: imageinput, conv_1, batchnorm_1, relu_1, maxpool_1, conv_2, batchnorm_2, relu_2, maxpool_2, conv_3, batchnorm_3, relu_3, fc, softmax, and classoutput.

ANALYSIS RESULT				
Name	Type	Activations	Learnables	
1 imageinput 200x200x3 images with 'zerocenter' normalization	Image Input	200x200x3	-	
2 conv_1 16 3x3x3 convolutions with stride [1 1] and padding 'same'	Convolution	200x200x16	Weights 3x3x3x16	Bias 1x1x16
3 batchnorm_1 Batch normalization with 16 channels	Batch Normalization	200x200x16	Offset 1x1x16	Scale 1x1x16
4 relu_1 ReLU	ReLU	200x200x16	-	
5 maxpool_1 2x2 max pooling with stride [2 2] and padding [0 0 0 0]	Max Pooling	100x100x16	-	
6 conv_2 32 3x3x16 convolutions with stride [1 1] and padding 'same'	Convolution	100x100x32	Weights 3x3x16x32	Bias 1x1x32
7 batchnorm_2 Batch normalization with 32 channels	Batch Normalization	100x100x32	Offset 1x1x32	Scale 1x1x32
8 relu_2 ReLU	ReLU	100x100x32	-	
9 maxpool_2 2x2 max pooling with stride [2 2] and padding [0 0 0 0]	Max Pooling	50x50x32	-	
10 conv_3 64 3x3x32 convolutions with stride [1 1] and padding 'same'	Convolution	50x50x64	Weights 3x3x32x64	Bias 1x1x64
11 batchnorm_3 Batch normalization with 64 channels	Batch Normalization	50x50x64	Offset 1x1x64	Scale 1x1x64
12 relu_3 ReLU	ReLU	50x50x64	-	
13 fc 5 fully connected layer	Fully Connected	1x1x5	Weights 5x160000	Bias 5x1
14 softmax softmax	Softmax	1x1x5	-	
15 classoutput crossentropyex with 'clay' and 4 other classes	Classification Output	-	-	

Рис. 2. Анализ структуры сверточной нейронной сети (CNN), используемой для классификации типов поверхностей

На рис. 2 представлена архитектура сверточной нейронной сети (CNN), используемой для классификации изображений на основе типа поверхности, например, «глина» и других категорий. Модель состоит из нескольких слоев, включая сверточные слои, пакетную нормализацию, функции активации (ReLU), пулирование максимальных значений, полностью связанный слой и окончательный слой классификации (Softmax).

Из таблицы видно, что данная сверточная нейронная сеть состоит из операторов свертки, операторов нормализации, активационных функций, операций объединения, полносвязного слоя и классифицирующего слоя Softmax. CNN анализирует входные данные и относит их к одному из пяти типов поверхностей.

Архитектура сверточной нейронной сети (CNN) для классификации типов поверхностей

№ п/п	Название слоя	Тип слоя	Активации	Параметры (обучаемые)
1	imageinput	Входное изображение	200×200×3	Нормализация («zerocenter»)
2	conv_1	Сверточный слой	200×200×16	16 фильтров 3×3, шаг 1, padding 'same'
3	batchnorm_1	Нормализация пакета	200×200×16	16 каналов
4	relu_1	Функция активации ReLU	200×200×16	—
5	maxpool_1	Максимальное объединение	100×100×16	2×2, шаг 2, padding [0 0 0 0]
6	conv_2	Сверточный слой	100×100×32	32 фильтра 3×3, шаг 1, padding 'same'
7	batchnorm_2	Нормализация пакета	100×100×32	32 канала
8	relu_2	Функция активации ReLU	100×100×32	—
9	maxpool_2	Максимальное объединение	50×50×32	2×2, шаг 2, padding [0 0 0 0]
10	conv_3	Сверточный слой	50×50×64	64 фильтра 3×3, шаг 1, padding 'same'
11	batchnorm_3	Нормализация пакета	50×50×64	64 канала
12	relu_3	Функция активации ReLU	50×50×64	—
13	fc	Полносвязный слой	1×1×5	5 нейронов, веса 5×160000
14	softmax	Softmax-активация	1×1×5	—
15	classoutput	Выход классификации	—	Классификация на глину, холмы, ямы, дороги и бетонные покрытия

Таким образом, данная архитектура решает задачу классификации изображения одной из пяти категорий поверхностей. Также отметим, что фильтрации тех или иных признаков способствует применение операторов свертки. Слой нормализации данных предварительно обрабатывает данные и упрощает процесс обучения. Полносвязный слой на последнем этапе объединяет полученные признаки, а Softmax присваивает вероятности принадлежность к классу.

Работа состоит из более чем 5000 изображений, позволяющих классифицировать тип поверхности, с которой сталкивается робот перед своей камерой. Полный набор включал в себя в общей сложности 500 изображений, которые были разделены на категории: глина, холмы, ямы, дороги и бетонные покрытия. Каждый показанный тип был точно определен с помощью обученного оператора CNN, что позволило роботу правильно адаптировать навигацию к каждому свойству поверхности. Эти изображения были полезны для повышения точности классификации и предоставления роботу наилучшего маршрута с учетом текстуры, влажности и других характеристик поверхности (рис. 3).




Рис. 3. График прогресса обучения модели сверточной нейронной сети с использованием алгоритма A^*

На рис. 4 изображена траектория робота, нанесенная с использованием алгоритма A^* , которая отражает перемещение от точки выхода к рабочему назначению. Оригинальная точка старта изображена синим маркером в круглом поле, в то время как желаемая точка цели обозначена круглым знаком зеленого цвета. Красные объекты с кругом указывают на препятствия, которые становятся в пути. Алгоритм A^* , показывающий движение, представляет собой подход поиска динамической точности маршрута к пути робота, что делает его кратким, с учетом всех признаков внешней среды. На рис. 4 можно увидеть, как алгоритм успешно проходит через все препятствия, чтобы достичь заданного пункта назначения по кратчайшему пути. Как описано выше, алгоритм A^* визуализирует, насколько эффективно он работает в процессе навигации. В большинстве случаев также можно увидеть, насколько уникален и адаптивен алгоритм A^* в реальных условиях.

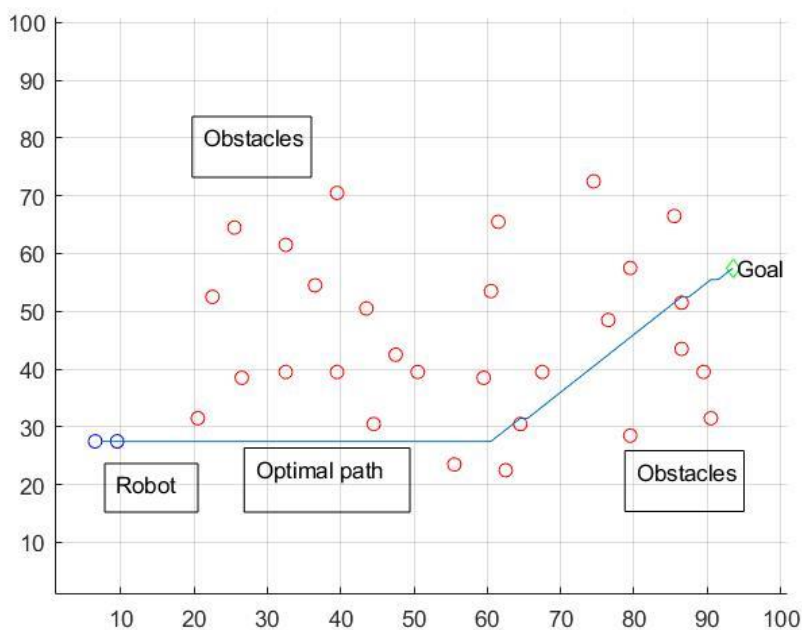


Рис. 4. Маршрут робота, найденный с использованием алгоритма A^*

Заключение

Результаты исследования подтверждают великолепные возможности использования алгоритмического комбинирования A* со сверточными нейронными сетями в решении проблем сложнейшей навигации: 96,62 % точности предполагают существенный прогресс не только в выборе лучшего маршрута, но и в классификации ландшафтов. A* с CNN позволяют роботам овладевать динамическими поворотными движениями вокруг артефактов и адаптироваться к различным оборачивающим слоям. Эти результаты делают эту разработку перспективной для ежедневного использования в критических задачах, таких как аварийные процессы схождения группы либо агентов или рекогносцировочные операции, когда быстрота и точность перемещения необходимы как никогда. Исследователи продолжают совершенствование навигационных систем за счёт использования более сложных алгоритмов машинного обучения. Для этого планируется разработка трёх уникальных CNN: каждая оптимизирована по-разному в плане конкретных параметров и архитектуры для улучшения качества критеризации и классификации. Их относительная производительность, а в дальнейшем, возможно, и универсальность, будет детально изучена в контексте эксперимента.

Список литературы/References

- 1 **Krizhevsky, A.** ImageNet Classification Using Deep Convolutional Neural Networks / A. Krizhevsky, I. Sutskever, G. E. Hinton // *Advances in Neural Information Processing Systems*. – 2012. – DOI 10.1145/3065386.
- 2 **He, Q.** Deep residual learning for image recognition / Q. He, S. Zhang, S. Ren, Q. Sun // *IEEE Conference on Computer Vision and Pattern Recognition*. – 2016. – DOI 10.1109/CVPR.2016.90.
- 3 **Simonyan, K.** Very deep convolutional networks for image recognition at large scales / K. Simonyan, A. Zisserman // *arXiv preprint arXiv:1409.1556*. – 2014. – URL: <https://arxiv.org/abs/1409.1556> (date of access: 15.10.2024).
- 4 **Long, J.** Fully convolutional networks for semantic segmentation / J. Long, E. Shelhamer, T. Darrell // *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. – 2015. – DOI 10.1109/CVPR.2015.7298965.
- 5 **Deep feature learning for discriminative localization** / B. Zhou, A. Khosla, A. Lapedriza [et al.] // *IEEE Conference on Computer Vision and Pattern Recognition*. – 2016. – DOI 10.1109/CVPR.2016.319.
- 6 **Hart, P. E.** Formal Basis for Heuristic Determination of Minimum Cost Paths / P. E. Hart, N. J. Nilsson, B. Raphael // *IEEE Transactions on Systems Science and Cybernetics*. – 1968. – DOI 10.1109/TSSC.1968.300136.
- 7 **Stentz, A.** Optimal and efficient path planning for partially-known environments // *Proceedings of the IEEE International Conference on Robotics and Automation*. – 1994. – DOI 10.1109/ROBOT.1994.351061.
- 8 **Thrun, S.** *Probabilistic Robotics* / S. Thrun, W. Burgard, D. Fox // Cambridge, Massachusetts : MIT Press. – 2005. – 647 p. – ISBN 978-0-262-20162-9.
- 9 **Invitation to 3D Vision : From Images to Geometric Models** / Y. Ma, S. Soatto, J. Kosechka, S. S. Sastry // New York. – USA : Springer. – 2004. – 528 p. – ISBN 978-0-387-00893-6.
- 10 **Wong, J. Y.** *Theory of ground vehicles*. 3rd ed. – New York, NY : Wiley, 1989. – 528 p. – ISBN 978-0-471-35461-3.

I. M. A. Al-Khafaji, A. V. Panov

IMPROVING THE LOCOMOTION OF A SIX-WHEELED GROUND ROBOT ON DIFFERENT TYPES OF TERRAIN USING A* ALGORITHM AND NEURAL NETWORKS

Abstract. A convolutional neural network is considered for classifying surface types encountered by mobile robots during navigation tasks. The classification of five surface types encountered in Iraq is analyzed: clay, hills, potholes, asphalt roads, and concrete pavements. The architecture of the convolutional neural network (CNN) consists of three convolution blocks with normalization and ReLU activation layers, a pooling layer, a fully connected classification layer after the CNN. The training with 96.62 % accuracy convinced that it is effective. The ray plots show a sharp decrease in loss and improvement in classification accuracy,

and the cross matrix confirms successful recognition of most surface types with no misclassification of hills. CNN allows these robots to adapt faster to such complex terrain by dynamically adjusting navigation paths, which significantly improves reliability and autonomy in real-world operations.

Keywords: confusion matrix, surface types, A* algorithm, mobile robot navigation, convolutional neural network (CNN), surface types.

For citation: Al-Khafaji, I. M. A. Improving the locomotion of a six-wheeled ground robot on different types of terrain using A* algorithm and neural networks / I. M. A. Al-Khafaji, A. V. Panov // Vestnik Rostovskogo Gosudarstvennogo Universiteta Putey Soobshcheniya. – 2025. – No. 1. – P. 51–57. – DOI 10.46973/0201–727X_2025_1_51.

Сведения об авторах

Ал-Хафаджи Исра М. Абдаламир

Институт информационных технологий (МИРЭА) – Российский технологический университет,
кафедра корпоративных информационных систем,
аспирант,

Университет Мустансирия,
(Багдад, Ирак),
факультет естественных наук,
ассистент,
e-mail: misnew6@gmail.com

Панов Александр Владимирович

Институт информационных технологий (МИРЭА) – Российский технологический университет,
кафедра корпоративных информационных систем,
кандидат технических наук, доцент,
e-mail: Iks.ital@yandex.ru.

Information about the authors

Al-Khafaji Israa M. Abdalameer

Institute of Information Technologies (MIREA) –
Russian Technological University,
Chair of Information Information Systems,
Postgraduate Student,

Mustansiriyah University,
(Baghdad, Iraq),
Department of Natural Sciences,
Assistant,
e-mail: misnew6@gmail.com

Panov Alexander Vladimirovich

Institute of Information Technologies (MIREA) –
Russian Technological University,
Chair of Information Information Systems,
Candidate of Engineering Sciences,
Associate Professor,
e-mail: Iks.ital@yandex.ru.