

ИССЛЕДОВАНИЕ НЕЙРОСЕТЕВЫХ МЕТОДОВ ПЛАНИРОВАНИЯ ТРАЕКТОРИЙ ДВИЖЕНИЯ В ДВУМЕРНОЙ СРЕДЕ

Н. Хамдан

Южный федеральный университет
Россия, 344006, Ростов-на-Дону, ул. Б. Садовая, 105/42
E-mail: dr.nizar.abou.hamdane@gmail.com

М.Ю. Медведев

Южный федеральный университет
Россия, 344006, Ростов-на-Дону, ул. Б. Садовая, 105/42
E-mail: medvmihal@sfedu.ru

В.Х. Пшихопов

Южный федеральный университет
Россия, 344006, Ростов-на-Дону, ул. Б. Садовая, 105/42
E-mail: pshichop@rambler.ru

В.Б. Пархоменко

Южный федеральный университет
Россия, 344006, Ростов-на-Дону, ул. Б. Садовая, 105/42
E-mail: vparhomenko@sfedu.ru

Ключевые слова: планирование траектории, глубокое обучение, векторная карта, обучение с учителем.

Аннотация: В докладе рассматривается проблема планирования движения в двумерной среде на базе нейронной сети глубокого обучения. Исследуется две формы представления карты среды – растровая и векторная. Для каждой формы создана обучающая выборка, на основе которой обучены нейронные сети различной структуры. Показано, что точность обучения слабо зависит от формы представления информации. Однако векторное представление карты среды, включающее информацию о положении робота, цели, препятствий и ближайшую область вокруг робота, позволяет сократить время обучения. Данный эффект достигается за счет снижения объема обрабатываемой нейронной сетью информации. Предложенные решения подтверждаются результатами численного моделирования.

1. Введение

Планирование движения с использованием машинного обучения развивается в связи с успехами глубоких нейронных сетей [1]. При этом, возможно обучение с учителем [2], с подкреплением [3] и гибридные схемы [4]. Обучение с учителем использует имеющийся опыт, например, повторяя удачные действия водителя. Обучение с подкреплением позволяет обучаться путем взаимодействия со средой.

Такой подход применяется в ситуациях, когда нет супервизора, способного решить задачу.

Усилия исследователей в области планирования траекторий направлены на снижение времени планирования и учет различных ограничений [5]. С целью минимизации вычислительных требований существуют исследования, направленные на оптимизацию структуры нейронных сетей и содержания обучающей выборки [6, 7], а также формы представления данных для обучения нейронной сети [8].

В данном докладе исследуются 4 нейронные сети различной структуры. Одна из нейронных сетей взята из работы [9], в которой ставится задача выработки управляющего сигнала, подаваемого на систему управления углом поворота мобильного робота. Нейронная сеть обучается на основе данных с трех видеокамер. В качестве учителя использовался сигнал положения руля автомобиля, который формировался водителем. Обучаемая нейронная сеть включала 5 сверточных слоев и 3 полносвязных слоя. В ходе тестирования для коррекции управляющих действий нейронной сети допускалось вмешательство водителя. При этом был достигнут уровень автономности 90%. Проведен эксперимент, в ходе которого нейронная сеть осуществляла управление направлением движения автомобиля в течении 10 миль. При этом вмешательства водителя не потребовалось. Работа [9] демонстрирует достаточно работоспособное решение, хотя и недостаточно надежное для автономного вождения.

Еще одна исследуемая нейронная сеть взята для исследования из статьи [10], в которой предложено вместе с изображением подавать на нейронную сеть результаты измерения текущей скорости автомобиля и вектор целевой точки. Предложена структура нейронной сети и проведено обучение на основе симулятора и экспериментального образца робота. Полученные результаты показали, что введение дополнительной информации в нейронную сеть позволяет многократно снизить частоту вмешательства и в действия сети и повысить процент успешного достижения цели в городских условиях.

Третья нейронная сеть сконструирована на основе работ [7, 11], в которых используется специальная процедура создания обучающей выборки, позволяющая повысить точность функционирования работы обученной сети.

Также для сравнения используется нейронная сеть, использующая только полносвязные слои и не использующая сверточные слои.

Во многих работах используются специальные формы представления информации о среде. В статье [12] вместо полной карты на вход нейронной сети подается локальный участок карты и глобальный путь на этом участке. В работе [13] на нейронную сеть также подается локальный участок среды, непосредственно примыкающий к роботу. Это позволяет более эффективно функционировать нейросетевому планировщику в непосредственной близости от препятствий.

В данном докладе исследуются две формы представления карты среды. Одна форма – растровая карта, а вторая – комбинированная, в которой присутствует информация о положении робота, цели и препятствий, и растровая карта ближнего окружения робота.

2. Формулировка задачи

Рассматривается прямоугольная среда, представленная на рис. 1. Среда имеет размеры $N_x = 65 \times N_y = 65$ ячеек. Каждое препятствие описывается координатами левого нижнего угла, высотой и шириной, т.е. вектором, содержащим 4 параметра:

$$(1) \quad p_{obs} = [x_{obs}, y_{obs}, r_{obs}, b_{obs}],$$

где x_{obs}, y_{obs} – координаты левого нижнего угла препятствия; r_{obs} – высота препятствия; b_{obs} – ширина препятствия.

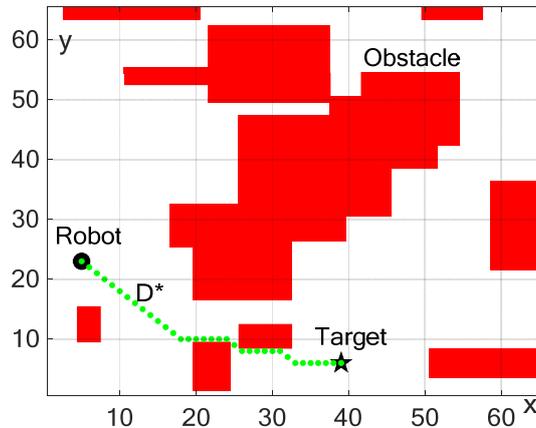


Рис. 1. Среда функционирования робота

Положение робота и целевой точки описывается векторами

$$(2) \quad p_r = [x_r, y_r],$$

$$(3) \quad p_t = [x_t, y_t].$$

Задача указанной нейронной сети выбрать одно из восьми направлений движения, представленные на рис. 2.

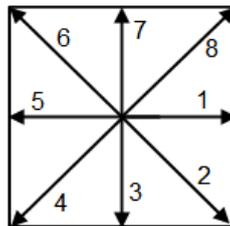


Рис. 2. Направления движения робота

Таким образом, ставится задача обучить нейронную сеть классифицировать среду, представленную на рис. 1, на 8 классов, имитируя алгоритм планирования учителя.

2. Результаты решения задачи

Кроме растрового изображения, представленного на рис. 1, в данной работе используется описание среды, представленное в виде матрицы, содержащей вектора (1)-(3). Такая матрица имеет вид:

$$(4) \quad M_{env} = \begin{bmatrix} x_{obs1} & y_{obs1} & r_{obs1} & b_{obs1} \\ \dots & \dots & \dots & \dots \\ x_{obs,Nobs} & y_{obs,Nobs} & r_{obs,Nobs} & b_{obs,Nobs} \\ x_r & y_r & x_r & y_r \\ x_t & y_t & x_t & y_t \\ p_{xr-1,yr+1} & p_{xr,yr+1} & p_{xr+1,yr+1} & 0 \\ p_{xr-1,yr} & 65 & p_{xr+1,yr} & 0 \\ p_{xr-1,yr-1} & p_{xr,yr-1} & p_{xr+1,yr-1} & 0 \\ q_{xt-1,yt+1} & q_{xt,yt+1} & q_{xt+1,yt+1} & 0 \\ q_{xt-1,yt} & 65 & q_{xt+1,yt} & 0 \\ q_{xt-1,yt-1} & q_{xt,yt-1} & q_{xt+1,yt-1} & 0 \end{bmatrix},$$

где $p_{i,j}$, $i = xr - 1, xr, xr + 1, j = yr - 1, yr, yr + 1$, равняется 65, если ячейка возле робота занята препятствием. Иначе ячейка $p_{i,j}$ равна 0. Строки матрицы M_{env} (7) с номерами $Nobs + 2, Nobs + 3, Nobs + 4$ содержат карту ближайшей к роботу области, 8 соседних ячеек. Последние три строки матрицы M_{env} (7) содержат ближайшие 8 ячеек к целевой точке. При этом $q_{i,j}$, $i = xt - 1, xt, xt + 1, j = yt - 1, yt, yt + 1$ равняется 65, если соответствующая ячейка занята роботом или препятствием. В противном случае ячейка $q_{i,j}$ равна 0.

Таким образом, матрица M_{env} (4) содержит 4 столбца и $Nobs + 8$ строк.

Вектор параметров препятствий p_{obs} (1) задается в соответствии с выражениями:

$$(5) \quad x_{obs} = rand(1, 65), y_{obs} = rand(1, 65),$$

$$(6) \quad r_{obs} = rand(1, 20), b_{obs} = rand(1, 20),$$

где $rand(c_1, c_2)$ – генератор равномерно распределенного случайного числа в диапазоне $[c_1, c_2]$.

Начальное положение робота и положение целевой точки также задаются случайным образом в диапазоне $[1, 65]$.

Матрица (4) преобразуется в картинку в виде оттенков серого с разрешением 16 бит. Внешний вид картинки, которая подается на вход нейронной сети, представлен на рис. 3.

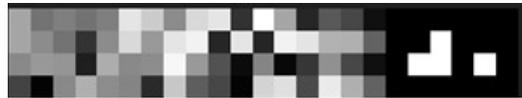


Рис. 3. Матрица признаков в виде изображения, подаваемого на вход нейронной сети

В ходе исследования рассмотрены 4 нейронных сети. Сеть NN1 включает входной слой, 9 сверточных слоев, 4 полносвязных слоя и выходной слой. Каждый сверточный слой включает 128 фильтров размером 3×3 . Число нейронов в полносвязных слоях 512, 128, 32 и 8. Сеть NN2 взята из работы [10], а сеть NN3 из работы [9]. Сеть NN4

содержит 9 полносвязных слоев с числом нейронов 1024, 1024, 512, 512, 256, 128, 64, 32, 8.

Вначале рассмотрена задача обучения сетей на основе растровой карты. Созданы 3 обучающие выборки объемом 240 000, 400 000 и 560 000 изображений. Качество обучения контролируется частотой успешного достижения цели ω_s . Данный параметр вычисляется в процессе моделирования в соответствии с выражением:

$$(7) \quad \omega_s = N_s / N_m,$$

где N_s – число экспериментов, в которых успешно достигнута цель; N_m – общее число экспериментов.

Результаты обучения рассмотренных нейронных сетей представлены в табл. 1. Частота успешного достижения цели в табл. 1 получена при $N_m = 300$.

Таблица 1. Оценки точности для растровой картинки.

Объем выборки	240 000	400 000	560 000
Сеть NN1	71,4	73,2	74,0
Сеть NN2	63,4	79,2	80,0
Сеть NN3	56,2	65,0	67,6
Сеть NN4	46,0	45,7	48,3

Аналогичные результаты для обучения нейронных сетей на основе входной матрицы, представленной на рис. 3, показаны на рис. 4.

Таблица 2. Оценки точности для векторного представления.

Объем выборки	240 000	400 000	560 000
Сеть NN1	79,33	80,67	80,5
Сеть NN2	76,25	78,04	78,32
Сеть NN3	68,46	72,65	73,25
Сеть NN4	72,67	73,33	75,0

6. Заключение

Анализ результатов, представленных в табл. 1 и табл. 2 позволяет сделать следующие выводы:

- векторное представление информации для нейронной сети дает повышение точности работы нейронной сети на 6 – 7 %;
- ни одна из проанализированных нейронных сетей не обеспечивает достаточно надежного решения, позволяющего ей самостоятельно решать задачу автовождения.

Кроме того, следует отметить, что использование векторного представления за счет уменьшения объема входных данных, позволяет снизить время обучения в 10 – 15 раз.

Исследование выполнено за счет поддержки Передовой школы ЮФУ «Инженерия киберплатформ».

Список литературы

1. LeCun Y., Bengio Y., Hinton G. Deep learning // Nature. 2015. Vol. 521. P. 436-444.

2. Hawke J., Shen R., Gurau C., Sharma S., Reda D., Nikolov N., Mazur P., Micklethwaite S., Griffiths N., Shah A., and Kendall A. Urban driving with conditional imitation learning // 2020 IEEE International Conference on Robotics and Automation (ICRA). 2020. P. 251-257.
3. Kickia P., Gawrona T., Ćwiana K., Ozay M., Skrzypczyńska P. Learning from experience for rapid generation of local car maneuvers // Engineering Applications of Artificial Intelligence. 2021. Vol. 105. 104399.
4. Chiang H.-T.L., Hsu J., Fiser M., Tapia L., and Faust A. RL-rrt: Kinodynamic motion planning via learning reachability estimators from RL policies // IEEE Robotics and Automation Letters. 2019. Vol. 4, No. 4. P. 4298-4305.
5. Пшихопов В.Х., Медведев М.Ю., Костюков В.А., Хуссейн Ф., Кадим А. Алгоритмы планирования траекторий в двумерной среде с препятствиями // Информатика и автоматизация. 2022. Т. 21, № 3, С. 459-492.
6. Wang J., Perez L. The effectiveness of data augmentation in image classification using deep learning // ArXiv. 2017.
7. Гайдук А.Р., Мартянов О.В., Медведев М.Ю., Пшихопов В.Х., Хамдан Н., Фархунд А. Нейросетевая система управления группой роботов в неопределенной двумерной среде // Мехатроника, автоматизация, управление. 2020. Т. 21, № 8. С. 470-479.
8. Berner C., Brockman G., et. al. Dota 2 with Large Scale Deep Reinforcement Learning // ArXiv. 2019.
9. Bojarski M., Testa D.D., Dworakowski D., Firner B., Flepp B., Goyal P., Jackel L.D., Monfort M., Muller U., Zhang J., Zhang X., Zhao J., Zieba K. End to end learning for self-driving cars. ArXiv, 2016.
10. Codevilla F., Mueller M., López Аю, Koltun V., Dosovitskiy A. End-to-end driving via conditional imitation learning // In 2018 IEEE International Conference on Robotics and Automation (ICRA). 2018. P. 4693-4700.
11. Medvedev M., Kadhim A., Brosalin D. Development of the Neural-Based Navigation System for a Ground-Based Mobile Robot // 2021 7th International Conference on Mechatronics and Robotics Engineering. 2021. P. 35-40.
12. Wang B., Liu Z., Li Q., Prorok A. Mobile Robot Path Planning in Dynamic Environments Through Globally Guided Reinforcement Learning // IEEE Robotics and Automation Letters. 2020. Vo;. 5, No. 4. P. 6932-6939.
13. Liangheng L.H., Zhang S.J.; Ding D.R.; Wang Y.X. Path Planning via an Improved DQN-Based Learning Policy // IEEE Access. 2019. Vol. 7. P. 67319-67330.