

ПРЕДСКАЗАНИЕ ЭВРИСТИК ДЛЯ ЗАДАЧИ ПЛАНИРОВАНИЯ ПУТИ

Ананикян А. Г.¹, Дроздов Д. П.¹
Научный руководитель – к. ф.-м. н. Яковлев К. С.¹

¹СПбГУ
d.drozdov@spbu.ru

Введение

Планирование пути для мобильного агента (например, робота) часто моделируют как поиск кратчайшего пути в графе, полученном разбиением пространства на сетку. Для таких графов популярным методом является эвристический алгоритм A*. Данный алгоритм итеративно выбирает следующую вершину для рассмотрения по сумме фактической стоимости пути и эвристической оценки оставшегося расстояния к цели. Классические эвристики в этом контексте (Манхэттенское, диагональное или евклидово расстояние) оценивают только геометрическое расстояние до цели и не учитывают препятствия на карте. Из-за этого в средах с множеством стен или барьеров алгоритм может тратить много времени на рассмотрение узлов, находящихся далеко от кратчайшего пути и фактически не даёт значительного прироста к скорости поиска пути по сравнению с алгоритмом Дейкстры, который перебирает вершины, основываясь исключительно на их расстоянии от старта, поскольку данные эвристики не направляют A* в обход препятствий.

Для преодоления этих ограничений активно изучается применение глубокого обучения для построения эвристик, учитывающих расположение препятствий на конкретной карте. Представляя карту сетки как бинарное изображение, сверточные нейронные сети и трансформеры обучаются предсказывать стоимость достижения цели или корректирующие множители для классических эвристик. Так, в методе Neural A* [2] интегрируется дифференцируемый A* в единую обучаемую архитектуру, что улучшает оптимальность и эффективность поиска. Другие подходы, например TransPath [3], обучают множитель между стандартной эвристикой и истинной длиной пути, адаптируя оценку под структуру препятствий. Однако большинство методов машинного обучения предполагают, что обучающие карты и целевые среды имеют одинаковую структуру генерации, что редко выполняется на практике. В реальных условиях планировщики часто сталкиваются с гетерогенными средами без возможности дообучения модели под каждую из них.

Основная часть

В данной работе мы сосредотачиваемся на обучении модели, способной предсказывать эффективные эвристики для множества карт с разнообразной структурой препятствий, которая при этом достаточно легкая для быстрой генерации данных эвристик.

Задача предсказания таких эвристик сводится к выбору компактной и быстрой модели, а также правильному обучению её на небольшом датасете, который бы охватывал большое количество различных топологий, встречающихся при реальном применении данного метода.

Для решения этой проблемы в работе предлагается обучение модели на задачах поиска пути в средах, сгенерированных с использованием зашумления пустых карт с помощью шума, взятого из бета-распределения. Такой метод позволяет с ненулевой вероятностью генерировать любую возможную карту. Кроме того, для того чтобы модель могла увидеть крупные препятствия, часто встречающиеся в задачах поиска

пути, поверх бета-шума случайным образом размещаются простые геометрические фигуры (квадраты, кресты, круги) случайного размера.

В качестве эвристики в работе выбраны корректирующие множители, которые легко использовать в алгоритме A^* и которые имеют небольшой разброс, фиксированный для любой карты, что позволяет избежать значительных отклонений предсказаний.

Для модели выбрана архитектура на основе трансформера со свёрточным энкодером и декодером. Общее количество параметров модели не превышает одного миллиона, что является оптимальным выбором, учитывая успешные результаты подобных архитектур в работах других авторов.

Для тестирования модели был создан специализированный датасет, включающий карты, сгенерированные десятью различными методами, каждый из которых имитирует топологии местности, которые могут встретиться в реальных условиях (например, городские зоны, помещения, береговая линия и другие).

Выводы

Эффективность предложенного подхода была всесторонне подтверждена серией вычислительных экспериментов, включающих 20 000 уникальных тестовых сценариев на специально сгенерированном тестовом датасете. При сравнительном анализе с рядом базовых методов (бэйзлайнов), включая WA^* и TransPath, наш метод продемонстрировал более высокое качество решений. Он позволил существенно снизить среднее относительное отклонение длины найденного пути от истинно кратчайшего: 101.1 % для нашего метода против 103.7 % для WA^* с коэффициентом $w=2$ и 125.9 % для TransPath. Кроме того, доля раскрытых узлов (метрика, линейно коррелированная со временем поиска и независимая от архитектуры вычислительного устройства) уменьшилась с 54.6 % у WA^* $w=2$ и 111.4 % у TransPath до 47.4 % в предложенном методе (эта метрика измерялась относительно A^* с диагональной эвристикой, которая гарантирует нахождение истинно кратчайших путей).

Таким образом, предложенный метод позволяет существенно сокращать вычислительные затраты на поиск пути в картах с разнообразными топологиями, одновременно обеспечивая близость найденных путей к кратчайшим. Полученные результаты подтверждают, что разработанный подход является более эффективным по сравнению с традиционными эвристиками и перспективен для практического применения в задачах поиска пути.

Литература

1. Hart P. E., Nilsson N. J., Raphael B. A formal basis for the heuristic determination of minimum cost paths // IEEE Transactions on Systems Science and Cybernetics. – 1968. – Vol. 4, No. 2. – P. 100–107.
2. Yonetani R., Taniai T., Barekatin M., Nishimura M., Kanazaki A. Path planning using neural A search* / R. Yonetani, T. Taniai, M. Barekatin, M. Nishimura, A. Kanazaki // Proceedings of the 38th International Conference on Machine Learning. – PMLR, 2021. – Vol. 139. – P. 12029–12039.
3. Kirilenko D., Andreychuk A., Panov A., Yakovlev K. Transpath: Learning heuristics for grid-based pathfinding via transformers // Proceedings of the AAAI Conference on Artificial Intelligence. – 2023. – Vol. 37, No. 10. – P. 12436–12443.