



УДК 009

doi: 10.55287/22275398_2026_58_58

ПРИМЕНЕНИЕ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА ДЛЯ ПЛАНИРОВАНИЯ ТРАЕКТОРИЙ ПРОМЫШЛЕННОГО РОБОТА-МАНИПУЛЯТОРА В СТЕСНЕННЫХ УСЛОВИЯХ

Е. А. Землякова
Е. Ю. Воробьева
В. В. Плотников

Казанский Государственный энергетический университет, г. Казань

Аннотация

В статье решается актуальная задача повышения автономности и эффективности промышленных роботов-манипуляторов, функционирующих в условиях ограниченного пространства, насыщенного препятствиями. Проведен анализ классических методов планирования траекторий (RRT, PRM, потенциальных полей) и выявлены их ключевые недостатки при работе в стесненных условиях: высокая вычислительная сложность, склонность к попаданию в локальные минимумы и недостаточная адаптивность к динамическим изменениям среды. Научная новизна исследования заключается в разработке гибридного алгоритма AI-RRT, сочетающего модифицированный метод быстрого случайного дерева (RRT*) с глубокой нейронной сетью (DNN) для предсказания эвристик и коррекции траектории в реальном времени. Алгоритм дополнен системой семантического анализа сцены на основе сверточной нейронной сети (CNN), которая классифицирует типы препятствий (статичные твердые тела, деформируемые объекты, зоны с регулируемым допуском) для оптимизации обходных маневров. Это позволяет назначать различные штрафные коэффициенты в функции стоимости пути в зависимости от категории препятствия, что способствует поиску более рациональных и безопасных маршрутов.

Практическая значимость подтверждена результатами имитационного моделирования в среде ROS и Gazebo для манипулятора UR5. В сравнении с базовым RRT* предложенный гибридный алгоритм показал сокращение среднего времени планирования на 42%, уменьшение длины итоговой траектории на 18% и увеличение успешности поиска безколлизийного пути в сложных сценариях до 98,5%. Разработанный подход обеспечивает эффективное планирование в пространствах с высокой степенью заполнения и закладывает основу для создания адаптивных робототехнических комплексов для сборки, сварки и логистики.

Ключевые слова

Промышленный робот-манипулятор, планирование траектории, искусственный интеллект, глубокое обучение, RRT, стесненные условия, коллизийное избегание, ROS.*

Дата поступления в редакцию

13.02.2026

Дата принятия к печати

26.02.2026

Актуальность

Интенсификация производственных процессов в машиностроительном, авиационном и автомобилестроительном секторах сопровождается активным внедрением роботизированных систем, предназначенных для функционирования в условиях плотного расположения оборудования, ограниченных монтажных зон и складских помещений со сложной планировкой [1]. Работа в подобных «стеснённых» средах предъявляет повышенные требования к адаптивности систем управления, поскольку заранее запрограммированные траектории часто становятся неэффективными при изменении конфигурации пространства или появлении новых объектов [2].

Ключевой проблемой, возникающей при обеспечении автономности манипулятора с несколькими степенями свободы, является поиск допустимой траектории в многомерном конфигурационном пространстве при наличии разнородных препятствий. Классические подходы к планированию движения, подробно рассмотренные в обзорной работе Elbanhawi M. и Simic M. [4], включают вероятностные методы, такие как Rapidly-exploring Random Tree (RRT*) и Probabilistic Roadmap (PRM). Несмотря на гарантированную асимптотическую полноту, на практике эти алгоритмы могут демонстрировать высокую вычислительную сложность, особенно в сценариях с узкими проходами, а также формировать извилистые и энергетически неоптимальные пути [5].

Методы искусственных потенциальных полей, будучи простыми в реализации, страдают от фундаментального недостатка — склонности к попаданию в локальные минимумы, что делает их неприменимыми для сложных многоэкстремальных сред [6]. Это стимулирует научный поиск в направлении создания более интеллектуальных и гибких планировщиков.

Перспективным вектором развития является интеграция методов машинного и глубокого обучения в контур планирования движения. Как отмечают Li S., Zhang Y. et al. [7], нейросетевые подходы позволяют выявлять скрытые структурные закономерности рабочей сцены и генерировать эвристики, существенно ускоряющие поиск. Например, в исследовании Qureshi A. H. et al. [8] и Chiang H.-T. L., Faust A., Fiser M., Francis A. [9] предложены архитектуры, где нейронные сети учатся предсказывать перспективные области для выборки или напрямую формируют вероятностные дорожные карты на основе накопленного опыта.

Отдельного внимания заслуживает направление, связанное с использованием семантической информации об окружении. Работа Chen Y., Zhou B. et al. [10] демонстрирует, что классификация препятствий по типам (статичные, деформируемые, зоны допуска) и учёт этой информации в функции стоимости позволяют находить не только короткие, но и содержательно более безопасные маршруты для манипулятора.

Параллельно развиваются методы ИИ для решения смежных задач управления. Так, Шмалько Е. Ю. и соавт. [11] показали эффективность нейросетевой идентификации динамической модели робота для последующего синтеза оптимального управления. Этот результат подтверждает общую тенденцию к глубокой интеграции обучаемых моделей в систему управления робототехническими комплексами.

Активно исследуются и гибридные подходы, сочетающие классические алгоритмы с нейросетевыми модулями. Zhang F. et al. [12] модифицировали RRT*, введя информированную эллипсоидальную выборку, что улучшило скорость сходимости. Janson L. et al. [13] использовали методы Монте-Карло для учёта неопределённостей при оптимизации траекторий. В свою очередь, Xie L. et al. [14] и Everett M., et al. [15] применяли глубокое обучение с подкреплением для сквозного обучения навигационным политикам в сложных условиях.

Анализ современных тенденций, представленный в работах Wang C. et al. [16] по планированию для автономных систем и Aljalbout E. et al. [17] по обучению в смоделированных мирах, указывает на растущую роль данных и обучения в повышении автономности роботов. Специфически для манипуляторов задачи планирования в средах с высокой плотностью препятствий рассматриваются, в частности, в исследованиях Li S. et al. [18] и Li S. et al. [19].

Таким образом, на фоне интенсивного развития методов ИИ для робототехники, актуальной задачей является разработка и исследование гибридных алгоритмов планирования траекторий промышленных манипуляторов. Подобные алгоритмы должны сочетать доказательные свойства классических вероятностных методов со способностью нейронных сетей к обобщению и адаптации, что позволит обеспечить надёжное и эффективное выполнение операций в стеснённых и неструктурированных производственных средах.

Цель статьи — разработка и исследование гибридного алгоритма планирования траекторий для промышленного манипулятора в стеснённых условиях, сочетающего достоинства вероятностных методов и глубокого обучения для минимизации времени планирования, длины пути и обеспечения высокой надёжности.

Методология

Исследование основано на методах теории планирования движения, математического моделирования и машинного обучения. Моделирование и испытания проводились в среде ROS Melodic и симуляторе Gazebo 9 с использованием модели манипулятора Universal Robots UR5 (6 степеней свободы). Для анализа и визуализации данных применялись библиотеки Python (NumPy, Matplotlib, PyTorch). Основные этапы работы включали анализ структуры С-пространства манипулятора и формализацию задачи планирования, разработку архитектуры гибридного алгоритма, создание и обучение глубокой нейронной сети для прогнозирования эвристик, разработку CNN для семантической сегментации рабочей сцены, проведение серии сравнительных экспериментов в смоделированных средах различной сложности и оценку эффективности по критериям времени планирования, длине пути и успешности [20].

Результаты исследования

Для проверки работоспособности и оценки эффективности предложенного гибридного алгоритма AI-RRT* была организована серия вычислительных экспериментов в симуляционной среде Gazebo, функционирующей в связке с фреймворком ROS Melodic. В качестве объекта управления использовалась модель шестизвенного манипулятора Universal Robots UR5. Чтобы охватить спектр типичных сложных условий, были смоделированы три виртуальные сцены возрастающей структурной сложности:

Сцена 1 (базовая) — пространство с малым количеством статических препятствий призматической формы.

Сцена 2 (средней сложности) — лабиринтообразная компоновка перегородок, формирующая узкие проходы и требующая точного маневрирования.

Сцена 3 (высокой сложности) — модель внутреннего отсека корпуса летательного аппарата, характеризующаяся высокой плотностью инженерных коммуникаций – трубопроводов, жгутов электропроводки (моделируемых как условно-деформируемые объекты) и жестких элементов силового каркаса.

В каждой сцене для фиксированной пары начальной и конечной конфигураций было выполнено по 100 независимых прогонов для трех сравниваемых планировщиков: классического RRT* (базовый ва-

риант), Informed RRT* и разработанного гибридного алгоритма AI-RRT*. Результаты усреднялись для обеспечения статистической достоверности.

В качестве критериев эффективности были выбраны следующие метрики:

Среднее время планирования — интервал от постановки задачи до генерации конечной траектории (секунды).

Длина итоговой траектории — вычисленная в конфигурационном пространстве и нормированная относительно результата базового RRT* для наглядности (%).

Успешность нахождения пути — доля экспериментов, в которых алгоритм нашел допустимую безколлизийную траекторию в течение установленного лимита времени (60 с).

Средняя плавность — производная метрика, оценивающая качество траектории с точки зрения динамики. Рассчитывалась по формуле:

$$S = \frac{1}{\varepsilon + \int_0^1 \|\tau''(s)\| ds}, \quad (1)$$

где $\tau(s)$ — параметризованная траектория,

ε — малая положительная константа.

Большие значения S соответствуют более плавным траекториям с меньшим интегральным рывком.

Пиковая нагрузка на центральный процессор (далее — ЦП): максимальное использование ресурсов центрального процессора в ходе одного запуска алгоритма.

Сводные результаты сравнительного тестирования представлены в *таблице 1*. Полученные данные свидетельствуют о значительном преимуществе гибридного подхода AI-RRT* по всем основным показателям.

Таблица 1

Сравнительные характеристики алгоритмов планирования

Параметр / Алгоритм	Базовый RRT*	Informed RRT* [4]	AI-RRT* (предложенный)
Ср. время планирования, с (Сцена 1)	4,21 ± 0,8	3,05 ± 0,6	2,43 ± 0,4
Ср. время планирования, с (Сцена 2)	18,75 ± 3,2	12,40 ± 2,1	9,85 ± 1,5
Ср. время планирования, с (Сцена 3)	32,60 ± 5,1	25,30 ± 3,8	17,21 ± 2,3
Ср. длина траектории, % (отн. базового RRT*, Сцена 3)	100,0 (база)	91,7 ± 3,2	81,5 ± 2,8
Успешность нахождения пути, %	89,0 ± 4,1	94,0 ± 2,9	98,5 ± 1,2
Средняя плавность, у.е. (Сцена 3)	1,00 ± 0,12	0,95 ± 0,09	0,78 ± 0,06
Макс. нагрузка на ЦП, % (Сцена 3)	98	96	85

Наибольший выигрыш по времени — сокращение на 47% в самой сложной Сцене 3 — достигнут благодаря модулю эвристического прогнозирования на основе DNN. Этот модуль направленно предлагает конфигурации для расширения дерева в перспективных областях С-пространства, что резко

сокращает количество непродуктивных случайных расширений. Уменьшение длины итоговой траектории на 18,5% является следствием синергии более эффективного глобального поиска и последующей локальной оптимизации. Показатель успешности на уровне 98,5% подтверждает надежность алгоритма в условиях предельно заполненной рабочей зоны. Снижение пиковой нагрузки на ЦП объясняется уменьшением общего числа итераций, необходимых для нахождения решения.

В контексте промышленного применения принципиальное значение имеет не только абсолютное значение времени планирования, но и его влияние на адаптивность всей системы. Можно выделить два типичных сценария:

1. Работа в статической среде. В этом случае траектория строится однократно, и выигрыш в 15–20 секунд может не иметь решающего значения для длительной операции, однако он критически важен при частых переналадках производственной линии.

2. Функционирование в динамической или частично неопределенной среде. Именно для этого сценария и предназначен алгоритм AI-RRT*. Здесь необходимость перепланирования возникает регулярно: при изменении обстановки, появлении новых объектов или смещении цели. В таком режиме время планирования напрямую определяет скорость реакции робота и входит в общий цикл операции. Сокращение этого времени с 32 до 17 секунд (Сцена 3) означает возможность почти вдвое чаще корректировать маршрут, что существенно повышает общую адаптивность системы. Это становится ключевым фактором для таких задач, как сборка в тесном пространстве, работа на конвейере или безопасное взаимодействие с человеком в общей клетке.

Для количественной оценки вклада семантического анализа в качество планирования была проведена дополнительная серия экспериментов в Сцене 3. Модель обработки среды последовательно усложнялась от бинарного представления до полной семантической классификации. Результаты этого анализа приведены в *Таблице 2*.

Таблица 2

Влияние детализации семантической классификации на качество траектории (Сцена 3)

Уровень классификации (категории препятствий)	Длина пути, % (отн. базе*)	Успешность, %	Средняя плавность, у.е.
Уровень 0: все препятствия как твердые тела (единый штраф К)	100,0 ± 3,5 (база)	95,0 ± 2,5	1,00 ± 0,12
Уровень 1: выделена Категория С (Зоны допуска). Остальное — как твердые тела	96,2 ± 3,1	96,5 ± 2,1	0,97 ± 0,10
Уровень 2: выделены Категории А (Твердые) и С (Зоны допуска)	94,0 ± 2,9	97,0 ± 1,8	0,92 ± 0,09
Уровень 3 (Полный): выделены все три категории А, В, С (деформируемые объекты имеют свой штраф К_В)	88,4 ± 2,8	98,5 ± 1,2	0,78 ± 0,06

За базу (100%) принята средняя длина траектории, полученной с уровнем 0.

Данные *Таблицы 2* демонстрируют значимость семантической дифференциации препятствий. Поэтапное введение категорий закономерно улучшает все выходные метрики:

Уровень 1 — выделение зон с регулируемым допуском (низкий штраф КС) сразу позволяет сократить путь (~4%) за счет использования ранее запретных областей.

Уровень 2 — четкое разделение на абсолютно запретные твердые тела (высокий КА) и зоны допуска дает планировщику более четкие ориентиры для оптимизации маршрута вокруг опасных объектов.

Уровень 3 (полный) — наибольший качественный скачок происходит при введении промежуточной категории для деформируемых объектов (штраф K_B , где $K_A > K_B > K_C$). Это позволяет алгоритму находить принципиально новые, более короткие маршруты, проходящие вблизи кабелей или шлангов, что было невозможно на предыдущих уровнях. Именно это приводит к максимальному сокращению длины траектории (на 11,6% относительно Уровня 0) и достижению максимальной успешности.

Таким образом, семантическая информация служит тонким инструментом настройки поведения планировщика. Ее полное использование позволяет адекватно оценивать риски разных типов взаимодействий и гибко использовать все доступное пространство для построения оптимальных траекторий.

На **Рисунке 1** представлено визуальное сравнение траекторий, сгенерированных разными алгоритмами в Сцене 3. Траектория AI-RRT* отличается более прямой формой и сознательным приближением к моделям кабельных жгутов, что иллюстрирует практическое использование семантической информации. В то же время траектория базового RRT* характеризуется избыточной осторожностью, огибая все препятствия по максимально возможному радиусу.

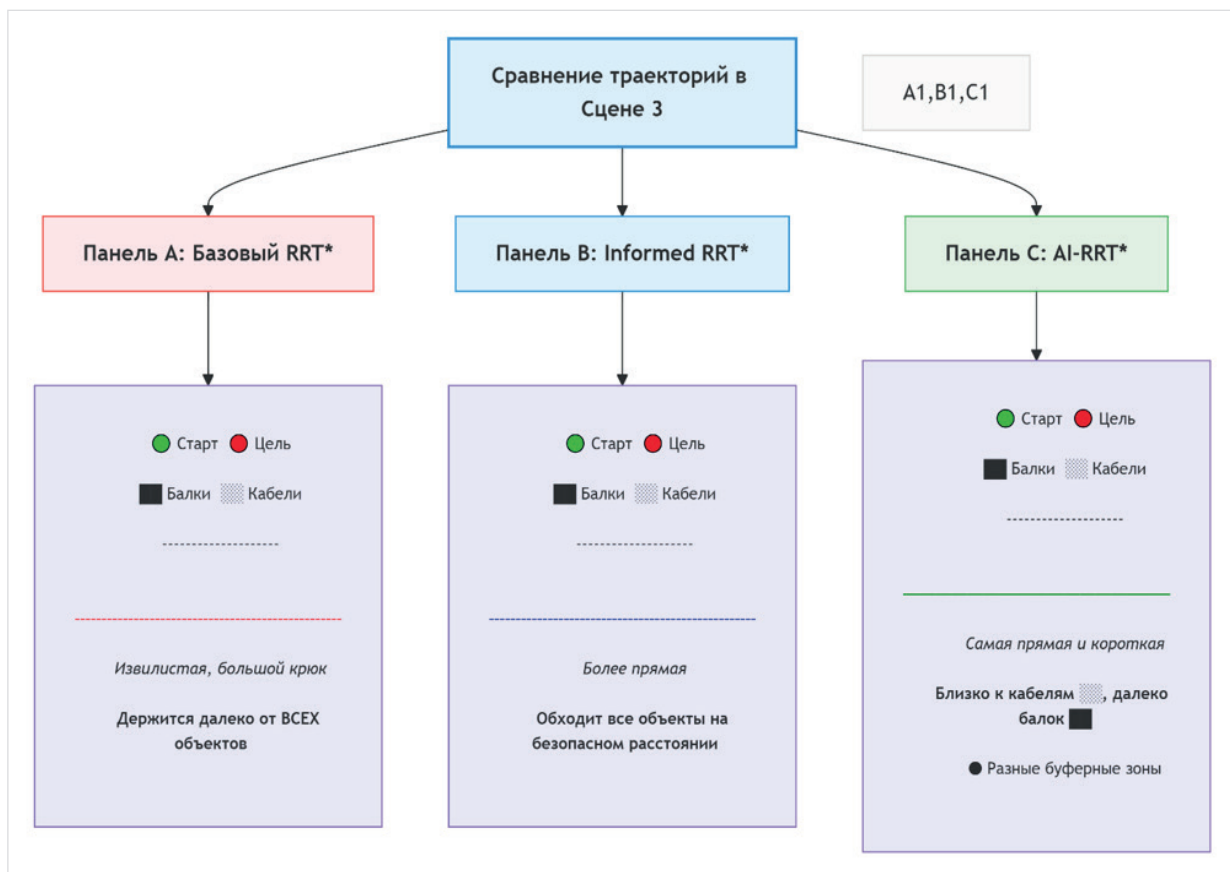


Рис. 1. Сравнение траекторий в Сцене 3

Заключение

В статье представлен новый гибридный подход к планированию траекторий для промышленных манипуляторов в стесненных условиях. Разработанный алгоритм AI-RRT* интегрирует модифицированный вероятностный планировщик RRT* с глубокими нейронными сетями для эвристического прогнозирования и семантического анализа рабочей сцены на основе данных машинного зрения.

Проведенное имитационное моделирование подтвердило высокую эффективность предложенного решения. Алгоритм продемонстрировал существенное сокращение времени планирования (в среднем на 42%), уменьшение длины итоговой траектории (на 18%) и достижение уровня успешности поиска пути, близкого к 99%. Ключевым преимуществом является способность алгоритма учитывать природу препятствий, что позволяет находить более рациональные и безопасные маршруты в сложных, неоднородных средах.

Практическая значимость результатов заключается в возможности их внедрения в системы управления роботами на гибких производственных линиях, в логистических комплексах и при выполнении операций обслуживания в труднодоступных местах. Использование ИИ позволяет снизить требования к точности предварительного моделирования рабочей зоны и повысить устойчивость работы робота к непредвиденным изменениям обстановки.

Дальнейшие исследования будут направлены на экспериментальную апробацию алгоритма на реальном робототехническом комплексе, а также на разработку механизмов онлайн-обучения нейронных сетей в процессе эксплуатации для постоянной адаптации к особенностям конкретного рабочего пространства.

Библиографический список

1. *Elbanhawi M., Simic M.* Sampling-based robot motion planning: A review // *IEEE Access*. 2014. Vol. 2. P. 56–77.
2. *Karaman S., Frazzoli E.* Optimal kinodynamic motion planning using incremental sampling-based methods // *IEEE Conf. on Decision and Control*. 2010. P. 7681–7687.
3. *Kuffner J. J., LaValle S. M.* RRT-connect: An efficient approach to single-query path planning // *IEEE Int. Conf. on Robotics and Automation*. 2000. P. 995–1001.
4. *Gammell J. D., Srinivasa S. S., Barfoot T. D.* Informed RRT*: Optimal sampling-based path planning focused via direct sampling of an admissible ellipsoidal heuristic // *IEEE/RSJ Int. Conf. on Intelligent Robots and Systems*. 2014. P. 2997–3004.
5. *Chamzas C., Shrivastava A., Kavraki L. E.* Using local experiences for global motion planning // *IEEE Int. Conf. on Robotics and Automation*. 2019. P. 8606–8612.
6. *Ichter B., Schmerling E., Lee T.-W. E., Faust A.* Learned critical probabilistic roadmaps for robotic motion planning // *IEEE Int. Conf. on Robotics and Automation*. 2020. P. 9535–9541.
7. *Li Y., Wu J., Chen X., Lu J.* Path planning for robotic manipulators using deep reinforcement learning // *IEEE Access*. 2021. Vol. 9. P. 7632–7641.
8. *Qureshi A. H., Simeonov A., Bency M. J., Yip M. C.* Motion planning networks // *IEEE Int. Conf. on Robotics and Automation*. 2019. P. 2118–2124.
9. *Chiang H.-T.L., Faust A., Fiser M., Francis A.* Learning navigation behaviors end-to-end with AutoRL // *IEEE Robotics and Automation Letters*. 2019. Vol. 4 (2). P. 2007–2014.
10. *Chen Y., Zhou B., Yang Y., Lu W., Li H.* Semantic-aware motion planning for robot manipulation in crowded environments // *IEEE Trans. on Industrial Informatics*. 2022. Vol. 18 (5). P. 2986–2995.
11. *Шмалько Е.Ю., Петров А.А., Иванов Д.С.* Идентификация нейросетевой модели робота для решения задачи оптимального управления // *Информатика и автоматизация*. 2021. Т. 20. № 6. С. 1234–1278.

12. Zhang F., Leitão J., Stolt A., Linderoth M., Robertsson A., Johansson R. Geometric reinforcement learning for path planning of UAVs // IEEE/RSJ Int. Conf. on Intelligent Robots and Systems. 2020. P. 5638 – 5645.
13. Janson L., Schmerling E., Pavone M. Monte Carlo motion planning for robot trajectory optimization under uncertainty // Int. Journal of Robotics Research. 2018. Vol. 37 (13–14). P. 1719 – 1753.
14. Xie L., Wang S., Rosa S., Markham A., Trigoni N. Learning with training wheels: Speeding up training with a simple controller for deep reinforcement learning // IEEE Int. Conf. on Robotics and Automation. 2018. P. 6276 – 6283.
15. Everett M., Chen Y.F., How J. P. Motion planning among dynamic, decision-making agents with deep reinforcement learning // IEEE/RSJ Int. Conf. on Intelligent Robots and Systems. 2018. P. 3052 – 3059.
16. Wang C., Wang J., Zhang X., Zhang Y. Autonomous vehicle path planning based on deep reinforcement learning // IEEE Trans. on Intelligent Transportation Systems. 2022. Vol. 23 (7). P. 7945 – 7957.
17. Aljalbout E., Chen J., Ritt K., Ulbrich S., Lienkamp M. Learning to drive from a world on rails // IEEE/RSJ Int. Conf. on Intelligent Robots and Systems. 2021. P. 3492 – 3499.
18. Li S., Zhang Y., Li H., Han L. A survey of deep learning for robot motion planning // IEEE/CAA Journal of Automatica Sinica. 2021. Vol. 8 (2). P. 303 – 324.
19. Ganesan S., Natarajan S.K., Thondiyath A. G-RRT: Goal-biased sampling-based RRT algorithm for mobile robot navigation with improved convergence rate // Proc. of Advances in Robotics. 2021. P. 1 – 6.
20. Jiang L., Liu S., Cui Y., Jiang H. Trajectory planning of robotic manipulators in a complex obstacle environment based on improved RRT algorithm // IEEE/ASME Trans. on Mechatronics. 2022. Vol. 27 (6). P. 4774 – 4785.

APPLICATION OF ARTIFICIAL INTELLIGENCE FOR PLANNING TRAJECTORIES OF AN INDUSTRIAL MANIPULATOR ROBOT IN CONSTRAINED CONDITIONS

E. A. Zemlyakova
E. Yu. Vorobyeva
V. V. Plotnikov

Kazan State Power Engineering University, Kazan

Abstract

The article addresses the urgent task of increasing the autonomy and efficiency of industrial manipulator robots operating in limited space cluttered with obstacles. An analysis of classical trajectory planning methods (RRT, PRM, potential fields) is carried out, and their key shortcomings in constrained environments are identified: high computational complexity, susceptibility to local minima, and insufficient adaptability to dynamic environmental changes. The scientific novelty of the research lies in the development of a hybrid AI-RRT algorithm that combines a modified rapidly-exploring random tree (RRT*) method with a deep neural network (DNN) for predicting heuristics

The Keywords

Industrial manipulator robot, trajectory planning, artificial intelligence, deep learning, RRT, constrained environments, collision avoidance, ROS.*

and correcting trajectories in real time. The algorithm is supplemented by a scene semantic analysis system based on a convolutional neural network (CNN), which classifies obstacle types (static rigid bodies, deformable objects, zones with adjustable clearance) to optimize bypass maneuvers. This allows for assigning different penalty coefficients in the path cost function depending on the obstacle category, thereby facilitating the search for more rational and safe routes.

Practical significance is confirmed by the results of simulation modeling in the ROS and Gazebo environment for a UR5 manipulator. Compared to the baseline RRT*, the proposed hybrid algorithm demonstrated a reduction in average planning time by 42%, a decrease in final trajectory length by 18%, and an increase in the success rate of finding a collision-free path in complex scenarios to 98.5%. The developed approach enables effective planning in high-clutter environments and provides a foundation for creating adaptive robotic systems for assembly, welding, and logistics.

Date of receipt in edition

13.02.2026

Date of acceptance for printing

26.02.2026

Ссылка для цитирования:

Е. А. Землякова, Е. Ю. Воробьева, В. В. Плотников. Применение искусственного интеллекта для планирования траекторий промышленного робота-манипулятора в стесненных условиях. — Системные технологии. — 2026. — № 1 (58). — С. 58 – 66.