

Приложение 1 к промежуточному отчету по проекту РФФИ № 20-08-01109_А «Разработка подхода к выбору оптимальных формаций модульных робототехнических систем исходя из геометрических характеристик внешнего окружения» за 2021 г.

Аннотация

В рамках второго года выполнения работ по проекту был проведен анализ современных методов, подходов и алгоритмов управления механическим движением модульных робототехнических систем (РС). В ходе анализа были выделены достоинства и недостатки различных алгоритмов управления движением модульных РС. Так, в основе централизованных таблиц походки лежит принцип разомкнутого управления, не позволяющий компенсировать ошибки регулирования и внешние возмущения. По результатам проведенного анализа наиболее перспективными представляются алгоритмы управления на основе центральных генераторов моделей походки и передвижения. Данные алгоритмы управления позволяют реализовать адаптивное поведение модульной РС в зависимости от типа поверхности передвижения посредством выбора подходящей модели перемещения или реконфигурации РС. Отдельным достоинством данных алгоритмов является возможность представления наборов движений модульных робототехнических систем с помощью простых математических выражений, что положительно сказывается на качестве управления.

В рамках выполнения работ над проектом также был разработан и апробирован подход к классификации и оценке параметров сложных поверхностей по RGB-D изображениям. Предложенный подход, основан на применении предобученной сегментационной нейросетевой модели HRNet, осуществляющей выделение на изображении целевого участка сложной поверхности, и ряде аналитических алгоритмов, реализующих оценку пространственного положения исследуемого участка поверхности. Согласно результатам проведенных экспериментов, предложенное решение позволяет успешно классифицировать различные поверхности по типу угла наклона и по

типу перепадов высот, а также осуществлять оценку таких геометрических параметров сложных поверхностей по RGB-D изображениям, как величина угла наклона поверхности к горизонтальной плоскости, ориентация аппроксимирующей плоскости поверхности, а также положение краевых точек данной поверхности.

В ходе выполнения проекта были разработаны алгоритмы, позволяющие формировать модели искусственных нейронных сетей, направленных на решение обратной задачи кинематики (ОЗК) различных формаций модульных РС. Анализ результатов проведенных экспериментов показал, что предложенное решение позволяет достичь высокой точности решения ОЗК у различных формаций РС с отличающимися кинематическими структурами. Преимуществом предложенного решения является возможность автоматической генерации обучающих выборок на основе кинематической структуры формации РС и ее дочерних подструктур, что позволяет получить модели искусственных нейронных сетей, направленные на решение обратной задачи кинематики для целой группы формаций модульных робототехнических систем.

В рамках выполнения работ над проектом также были разработаны алгоритмы автоматической генерации элементов внешнего окружения (сложных поверхностей) с заданными параметрами. Данные алгоритмы обеспечивают генерацию таких типов поверхностей, как горизонтальные плоские поверхности, плоские поверхности с произвольным наклоном, дугообразные поверхности, а также прямые лестницы в соответствии с заданными пользователем параметрами. Предложенные алгоритмы в дальнейшем будут использованы при анализе качественных характеристик механического движения модульных РС по различным типам сложных поверхностей в средах виртуального моделирования.

Кроме того, в ходе выполнения проекта был разработан метод оценки оптимальности характеристик механического движения формаций модульных РС по различным участкам рельефа помещений, представленных сложными

поверхностями. Предложенный метод на основе таких параметров, как степень отклонения РС от расчетной траектории движения, степень отклонения скорости движения РС от целевого значения в процессе движения, степень равномерности движения РС, а также общее время движения РС по траектории позволяет осуществлять оценку оптимальности механического движения модульной РС в заданной формации.

Результаты проведенных исследований представлены на 1 международной конференции. Опубликовано 2 научных статьи в изданиях, индексируемых в базах Scopus/WoS и РИНЦ.

Заявленные цели проекта на период, на который предоставлен грант

За второй год реализации проекта было запланировано получение следующих основных результатов:

1. Обзор современных методов, подходов и алгоритмов управления механическим движением модульных робототехнических систем.
2. Разработка подхода к классификации и оценке параметров сложных поверхностей по изображениям.
3. Разработка собственных методов решения ОЗК на основе машинного обучения, которые могут быть применены к различным формациям модульных РС.
4. Разработка алгоритмов автоматической генерации элементов внешнего окружения (сложных поверхностей) с заданными параметрами для анализа качественных характеристик механического движения различных формаций модульных РС.
5. Разработка метода оценки оптимальности характеристик механического движения формаций модульных РС по различным участкам рельефа помещений, представленных сложными поверхностями.
6. Публикация статей в трудах международных конференций и рецензируемых журналах по результатам исследований.

Полученные за период, на который предоставлен грант, результаты с описанием методов и подходов, использованных при реализации проекта

1. Обзор современных методов, подходов и алгоритмов управления механическим движением модульных робототехнических систем

Реконфигурация и самореконфигурация модульных робототехнических систем (РС) позволяет получить определенные формации, отличающиеся степенью подвижности, степенью свободы механизмом, а также способами перемещения всей системы в целом. Кинематическая структура таких систем в одной формации может существенно отличаться от других возможных для данной РС формаций. что требует применения специализированных методов, подходов и алгоритмов управления механическим движением данных систем. Под критериями качества в модульной робототехнике зачастую рассматриваются такие параметры, как устойчивость походки для шагающих формаций системы, скорость реагирования отдельных модулей в задачах синхронизации их работы и др. Динамическая структура модульных РС и большое число степеней свободы, граничащее с гиперизбыточностью [Wu W. et al. Task-oriented inverse kinematics of modular reconfigurable robots //2013 IEEE/ASME International Conference on Advanced Intelligent Mechatronics. – IEEE, 2013. – С. 1187-1192.], привели к разработке множества алгоритмов управления движением для подобных систем. Согласно [A. Sproewitz, R. Moeckel, J. Maye, and a. J. Ijspeert, “Learning to Move in Modular Robots using Central Pattern Generators and Online Optimization,” Int. J. Rob. Res., vol. 27, no. 3–4, pp. 423–443, 2008.], наиболее распространенными на сегодняшний день являются следующие алгоритмы управления модульными РС: централизованные таблицы походки (centralized gait tables), алгоритмы управления на основе ролей (role), алгоритмы управления на основе модели гормона (hormone), алгоритмы управления с ограничениями (constraint), а также алгоритмы, основанные на использовании центрального генератора моделей походки (central pattern generator).

Алгоритмы управления на базе централизованных таблиц походки представляют собой конечные автоматы [Bongard, J., Zykov, V., and Lipson, H. (2006). Resilient machines through continuous self-modeling. *Science*, 314(5802):1118–1121.], в которых заданы дискретные состояния для каждого модуля РС. В качестве состояний зачастую указываются необходимые углы поворота в сочленениях РС. Подобные алгоритмы реализуют негибкое последовательное управление модульными механизмами и не учитывают динамические процессы, возникающие при движении РС. Применение самоорганизующегося конечного автомата было рассмотрено в работе [Манько С. В., Шестаков Е. И. Автоматический синтез сценариев походки реконфигурируемых мехатронно-модульных роботов в модификации шагающей платформы // *Российский технологический журнал*. – 2018. – Т. 6. – №. 4. – С. 26-41. <https://doi.org/10.32362/2500-316X-2018-6-4-26-41>.] для решения задачи поиска оптимальной модели походки шагающих формаций модульной РС. Предложенный подход апробирован на примере формации «квадропод», критерием качества для корректирования запоминаемых автоматом конфигураций сочленений служила оценка устойчивости модульной системы при перемещении. Стоит отметить, что при обучении автомата поддержанию устойчивой походки в реальном времени, время обучения модели существенным образом зависит от ограничений на перемещение каждого звена модульной системы.

Применение нечетких регуляторов для выбора одного варианта из централизованной таблицы походки на базе сигналов с сенсоров предложено в [Basa J., Dasgupta P., Hossain S.G.M., Nelson C. Modular robot locomotion based on a distributed fuzzy controller: The combination of modred's basic module motions // 2013 IEEE/RSJ International Conference on Intelligent Robots and Systems. – IEEE, 2013. – С. 4302-4307. <https://doi.org/10.1109/IROS.2013.6696973>.]. В рамках проведенных в работе экспериментов было рассмотрено перемещение РС, построенной на базе модулей ModRED. Результаты экспериментов показали, что подход

позволяет реализовать адаптивное перемещение модульной системы в цепной конфигурации, состоящей из последовательно соединенных модулей ModRED. Иные формации в рамках данного исследования рассмотрены не были. Централизованные таблицы походки также были применены в [Yim M., Roufas K., Duff D., Zhang Y., Eldershaw C., Nomans S. Modular reconfigurable robots in space applications //Autonomous Robots. – 2003. – Т. 14. – №. 2. – С. 225-237. <https://doi.org/10.1023/A:1022287820808>.] для управления движением модульной системы в различных формациях, полученных посредством реконфигурации модулей PolyBot. Авторы отметили, что использованный вариант управления являлся типом системы с принципом программного (разомкнутого) управления. Данный принцип является жестким и не позволяет компенсировать внешние возмущения, поскольку не использует обратную связь.

Ролевая модель управления, предложенная для модульных систем с цепной структурой в работе [Stoy K., Shen W.M., Will P. Implementing configuration dependent gaits in a self-reconfigurable robot //2003 IEEE International Conference on Robotics and Automation (Cat. No. 03CH37422). – IEEE, 2003. – Т. 3. – С. 3828-3833. <https://doi.org/10.1109/ROBOT.2003.1242184>.], представляет собой модель распределенного управления РС, где каждому модулю назначается своя роль, заключающаяся в изменении углов в сочленениях по заданному набору правил. Распределенная ролевая модель управления также рассмотрена в [Wei H., Chen Y., Tan J., Wang T. Sambot: A self-assembly modular robot system //IEEE/ASME Transactions on Mechatronics. – 2010. – Т. 16. – №. 4. – С. 745-757. <https://doi.org/10.1109/TMECH.2010.2085009>.] для демонстрации возможностей перемещения РС, состоящей из модулей Sambot. Алгоритм является простой последовательностью команд для поворота конкретных модулей на определенный угол с применением задержек. Как отметили авторы, для РС, формируемых на базе Sambot, возможно применение

алгоритмов управления механическим движением, которые позволят адаптировать перемещение под окружающую среду.

Алгоритмы управления на базе модели гормона были разработаны для распределенного управления модульными РС с динамической структурой [Shen, W., Salemi, B., and Will, P. (2002). Hormone-inspired adaptive communication and distributed control for selfreconfigurable robots. *IEEE Transactions on Robotics and Automation*, 18(5):1–12.], [Salemi B., Shen W. M., Will P. Hormone-controlled metamorphic robots // *Proceedings 2001 ICRA. IEEE International Conference on Robotics and Automation* (Cat. No. 01CH37164). – IEEE, 2001. – Т. 4. – С. 4194–4199. <https://doi.org/10.1109/ROBOT.2001.933273>.], [Wei-Min Shen, Maks Krivokon, Harris Chiu, Jacob Everist, Michael Rubenstein, and Jagadesh Venkatesh. Multimode locomotion via superbots. In *Proc. IEEE Int. Conf. Robotics and Automation*, pages 2552–2557, Orlando, Florida, May 2006.]. Модель гормона реализует распространение сообщений, передающихся среди соединенных модулей, которые изменяют свое состояние или режим работы в зависимости от пришедшего сигнала. Таким образом, один и тот же гормон может нести разные задачи для различных модулей. Для синхронизации функционирования модулей в распространяемых по системе сообщениях предусматриваются специальные признаки, при распознавании которых модули выходят из режима ожидания и приступают к выполнению заданных действий. В [Hamann H., Stradner J., Schmickl T., Crailsheim K. A hormone-based controller for evolutionary multi-modular robotics: From single modules to gait learning // *IEEE Congress on Evolutionary Computation*. – IEEE, 2010. – С. 1–8. <https://doi.org/10.1109/CEC.2010.5585994>.] рассмотрено применение эволюционных вычислений для адаптации алгоритма управления двумя конфигурациями модульной РС к решению задач в различных условиях окружающей среды. Главным отличием предложенного алгоритма является применение модели плавной функции стоимости, что позволяет получать высокую вариативность пар гормон-правило.

В [Zhang Y., Fromherz, M. P., Crawford, L. S., & Shang, Y. A general constraint-based control framework with examples in modular self-reconfigurable robots //IEEE/RSJ International Conference on Intelligent Robots and Systems. – IEEE, 2002. – Т. 3. – С. 2163-2168. <https://doi.org/10.1109/IRDS.2002.1041587>.] система управления механическим движением модульной РС на базе алгоритма с ограничениями разделена на два ключевых компонента: регуляторы и поисковая подсистема. Регуляторы выполняют свою классическую функцию, а поисковая подсистема предназначена для оценки состояния системы на основе сигналов со всех сенсоров модульной РС. Оценка состояния включает в себя определение ограничений, которые присутствуют для модульной РС в данном состоянии. Подобные алгоритмы управления на базе ограничений нашли широкое применение в области управления манипуляторами [Aertbeliën E., De Schutter J. eTaSL/eTC: A constraint-based task specification language and robot controller using expression graphs //2014 IEEE/RSJ International Conference on Intelligent Robots and Systems. – IEEE, 2014. – С. 1540-1546. <https://doi.org/10.1109/IROS.2014.6942760>.], [Polverini M.P., Zanchettin A.M., Castello S., Rocco P. Sensorless and constraint based peg-in-hole task execution with a dual-arm robot //2016 IEEE International Conference on Robotics and Automation (ICRA). – IEEE, 2016. – С. 415-420. <https://doi.org/10.1109/ICRA.2016.7487161>.], [Nicolis D., Zanchettin A.M., Rocco P. Constraint-based and sensorless force control with an application to a lightweight dual-arm robot //IEEE Robotics and Automation Letters. – 2016. – Т. 1. – №. 1. – С. 340-347. <https://doi.org/10.1109/LRA.2016.2517206>.] и практически не применяется в модульных робототехнических системах.

В задаче управления модульными роботами с применением генератора моделей походки рассматривается двухуровневая система, состоящая из контроллера походки и отдельных регуляторов, которые управляют каждым модулем РС по отдельности. Генератор моделей походки предложено использовать в работе [A. Sproewitz, R. Moeckel, J. Maye, and a. J. Ijspeert,

“Learning to Move in Modular Robots using Central Pattern Generators and Online Optimization,” *Int. J. Rob. Res.*, vol. 27, no. 3–4, pp. 423–443, 2008.] для решения задачи управления модульными РС с решетчатой и цепной структурой. В работе предложено генерировать модели походки посредством оптимизации методом Пуэла без использования градиента. Целевая функция при этом представляет собой среднюю скорость модульной системы, которая оценивается при помощи изображений с камеры, установленной на РС. Данный метод использовался для оптимизации параметров генератора походки, что позволило обеспечить высокую скорость перемещения системы.

В работе [A. Kamimura, H. Kurokawa, E. Yoshida, S. Murata, K. Tomita, and S. Kokaji, “Automatic Locomotion Pattern Generation for Modular Robots,” in *IEEE International Conference on Robotics & Automation*, 2003, vol. 70, no. 690, pp. 459–466.] предложен метод автоматической генерации моделей передвижения модульных РС. Для получения устойчивой модели походки модульной системы были применены нейронные осцилляторы и генетический алгоритм для поиска субоптимальных параметров данных осцилляторов. В результате применения метода были получены стабильные модели походки для различных конфигураций модульной системы, состоящей из модулей M-TRAN2. Модификация центрального генератора моделей передвижения также предложена в [Spaeth A., Tebyani M., Haussler D., Teodorescu M. *Neuromorphic closed-loop control of a flexible modular robot by a simulated spiking central pattern generator //2020 3rd IEEE International Conference on Soft Robotics (RoboSoft)*. – IEEE, 2020. – С. 46-51. <https://doi.org/10.1109/RoboSoft48309.2020.9116007>.]. В работе рассматривается применение нейронных осцилляторов, которые состоят из двух моделей нейронов Ижикевича [Eugene M. Izhikevich. *Dynamical Systems in Neuroscience*. MIT press, 2007. <https://doi.org/10.7551/mitpress/2526.001.0001>.]. Подход с применением нейронных осцилляторов применен для придания системе управления адаптивных свойств для реализации управления различными формациями модульной РС.

Генератор моделей походки был также использован в [CH S.S.R., Godiyal R., Zodage T., Rane T. 2DxoPod-A Modular Robot for Mimicking Locomotion in Vertebrates //Journal of Intelligent & Robotic Systems. – 2021. – Т. 101. – №. 1. – С. 1-16. <https://doi.org/10.1007/s10846-020-01270-5>.] для управления движением РС, состоящей из модулей 2DxoPod. Алгоритм управления движением модульной системы с применением генератора моделей походки использовался для симуляции перемещения данной системы в формациях «змея» и «квадропод». Как отметили авторы, для каждой конкретной формации та или иная модель походки выбирается в зависимости от окружающей среды и поверхности передвижения модульной системы: например, для формации «змея» авторы выделили гусеничный (caterpillar gait) способ передвижения, горизонтальное волнообразное движение (lateral undulation) и боковое переворачивание (side-winding). В [Hernández H., Moreno R., Faina A., Gomez J. Design of a bio-inspired controller to operate a modular robot autonomously //Ibero-American Conference on Artificial Intelligence. – Springer, Cham, 2018. – С. 314-325. https://doi.org/10.1007/978-3-030-03928-8_26.] рассмотрен генератор моделей передвижения модульной системы, сформированной из модульных роботов EMeRGE. В работе было рассмотрено несколько стохастических алгоритмов оптимизации параметров моделей на основе информации с датчиков. В результате проведенных экспериментов авторы сделали выводы, что применение генетического алгоритма позволило определить наборы движений, с использованием которых модульная система преодолела большее расстояние по сравнению с наборами, созданными посредством алгоритма оптимизации имитации отжига и алгоритмом мутации особи. Комбинирование генератора моделей походки с применением модификации алгоритма оптимизации роем частиц рассмотрено в [Pouya S., Van Den Kieboom J., Spröwitz A., Ijspeert A.J. Automatic gait generation in modular robots: “to oscillate or to rotate; that is the question” //2010 IEEE/RSJ International Conference on Intelligent Robots and Systems. – IEEE, 2010. – С. 514-520. <https://doi.org/10.1109/IROS.2010.5649025>.]. В дальнейших исследованиях

авторы продемонстрировали успешное перемещение модулей нового поколения [Spröwitz A., Moeckel R., Vespignani M., Bonardi S., Ijspeert A.J. Roombots: A hardware perspective on 3D self-reconfiguration and locomotion with a homogeneous modular robot //Robotics and Autonomous Systems. – 2014. – Т. 62. – №. 7. – С. 1016-1033. <https://doi.org/10.1016/j.robot.2013.08.011>.]. Авторы выделили следующие преимущества рассмотренного решения [Pouya S., Van Den Kieboom J., Spröwitz A., Ijspeert A.J. Automatic gait generation in modular robots: “to oscillate or to rotate; that is the question”]: быстрое действие, небольшое количество контролируемых параметров, а также возможность генерации различных моделей походки модульной РС.

Применение генератора моделей походки Мацуоки [Matsuoka K. Sustained oscillations generated by mutually inhibiting neurons with adaptation //Biological cybernetics. – 1985. – Т. 52. – №. 6. – С. 367-376. <https://doi.org/10.1007/BF00449593>.], [Matsuoka K. Mechanisms of frequency and pattern control in the neural rhythm generators //Biological cybernetics. – 1987. – Т. 56. – №. 5. – С. 345-353. <https://doi.org/10.1007/BF00319514>.] для различных кинематических структур модульной РС рассмотрено в [Zhu Y., Zhao J., Cui X., Wang X., Tang S., Zhang X., Yin J. Design and implementation of ubot: A modular self-reconfigurable robot //2013 IEEE International Conference on Mechatronics and Automation. – IEEE, 2013. – С. 1217-1222. <https://doi.org/10.1109/ICMA.2013.6618087>.]. В работе отмечено, что были проведены эксперименты с применением генератора походок для формаций «змея», «квадропад», крестообразной формации со всенаправленными колесами, а также формации «колесо». Рассмотренная модель позволила авторам адаптировать соединения нейронов осцилляторов под различные формации и получить различные режимы работы для модульной РС.

Среди адаптивных подходов к управлению также существуют логико-вероятностные подходы. Так, в работе [Демин А.В. Логико-вероятностный метод управления модульными роботами //Системная информатика. – 2017. – №. 11. – С. 61-80.] рассмотрен логико-вероятностный подход к задаче

адаптивного управления модульными РС. Предложенный подход базируется на использовании логико-вероятностных методов извлечения знаний из данных и обобщении правил на основе знаний исполняемой функции типовых модулей. В системе управления, предназначенной для управления формациями «змея», «манипулятор», «многоножка», используются обучаемые логические нейроны, предназначенные для индивидуального управления модулями РС. Адаптивные свойства системы управления заключались в применении парадигмы обучения с подкреплением при работе системы в реальном времени. Предложенное решение требует дообучения в случае реконфигурации РС. Кроме того, как отметил автор, «эффективность предложенного подхода во многом зависит от количества схожих по функциям модулей в конструкции робота».

На основе модульных РС, состоящих из соединений мобильных платформ, возможно формировать плоские кинематические структуры. Для управления движением подобных РС можно использовать алгоритмы, рассмотренные выше, при этом стоит отметить, что возможно использовать сравнительно простые алгоритмы управления движением в случае, если в состав РС входит небольшое количество модулей. Так, в [Zhang Y., Song G., Liu S., Qiao G., Zhang J., Sun H. A modular self-reconfigurable robot with enhanced locomotion performances: design, modeling, simulations, and experiments //Journal of Intelligent & Robotic Systems. – 2016. – Т. 81. – №. 3-4. – С. 377-393. DOI 10.1007/s10846-015-0228-9.] были рассмотрены алгоритмы управления соединением двух мобильных платформ Trimobot для перемещения по ровной и неоднородной поверхностям. Данные платформы имеют форму шестигранника, три всенаправленных колеса, а также поворотное сочленение в прямоугольном вырезе с одной из сторон платформы с диапазоном поворота $[-90^\circ; 90^\circ]$ для сопряжения модулей, что позволяет приподнимать робота для перемещения системы по неоднородной поверхности. Для перемещения по неоднородным поверхностям в работе рассматривался синусоидальный тип

передвижения модульной РС, при этом, как отметили авторы, период движения настраивается вручную.

Подводя итоги, главный недостаток централизованных таблиц походки является отсутствие обратной связи при управлении движением РС, что не позволяет адаптировать систему под различные типы поверхностей, по которым осуществляется движение. Среди рассмотренных алгоритмов управления механическим движением модульных РС, наиболее распространенным является центральный генератор моделей походки. Алгоритмы, разработанные на базе генератора моделей походки, показали себя адаптивными к различным формациям модульных РС. Кроме того, преимущество центрального генератора моделей походки заключается в простоте создания наборов движений модульных РС произвольных формаций, так как данные движения могут быть представлены простыми математическими выражениями [Li L., Wang C., Xie G. A general CPG network and its implementation on the microcontroller //Neurocomputing. – 2015. – Т. 167. – С. 299-305. <https://doi.org/10.1016/j.neucom.2015.04.066>.], [Zhao W., Hu Y., Zhang L., Wang L. Design and CPG-based control of biomimetic robotic fish //IET control theory & applications. – 2009. – Т. 3. – №. 3. – С. 281-293. <https://doi.org/10.1049/iet-cta:20070204>.], что может положительно сказаться на быстродействии системы управления. Проведенный анализ позволяет сделать вывод, что среди рассмотренных решений наиболее перспективным является направление в области разработки алгоритмов на базе центральных генераторов моделей походки модульной РС. Данный тип алгоритмов потенциально подходит для применения в рамках дальнейших этапов проекта.

2. Разработка подхода к классификации и оценке параметров сложных поверхностей по изображениям

Разработка подхода к классификации и оценке геометрических параметров сложных поверхностей по изображениям предполагает решение следующей группы основных задач: сегментация исследуемого изображения с целью выделения сегментов сложных поверхностей перемещения РС; оценка

пространственного положения исследуемого участка сложной поверхности; классификация и оценка параметров исследуемого участка сложной поверхности.

В настоящее время существует большое количество методов и подходов, направленных на решение задачи сегментации изображений [Grady L. Random walks for image segmentation //IEEE transactions on pattern analysis and machine intelligence. – 2006. – Т. 28. – №. 11. – С. 1768-1783.], [Ohlander R. Picture segmentation using a recursive region splitting method //Computer Graphics and Image Processing. – 1980. – Т. 13. – С. 222-241.], [Wu Z., Leahy R. An optimal graph theoretic approach to data clustering: Theory and its application to image segmentation //IEEE transactions on pattern analysis and machine intelligence. – 1993. – Т. 15. – №. 11. – С. 1101-1113.]. Большинство современных методов сегментации основаны на применении искусственных нейронных сетей [Tao A., Sapra K., Catanzaro B. Hierarchical Multi-Scale Attention for Semantic Segmentation //arXiv preprint arXiv:2005.10821. – 2020.], [Cordts M. et al. The cityscapes dataset for semantic urban scene understanding //Proceedings of the IEEE conference on computer vision and pattern recognition. – 2016. – С. 3213-3223.], [Neuhold G. et al. The mapillary vistas dataset for semantic understanding of street scenes //Proceedings of the IEEE International Conference on Computer Vision. – 2017. – С. 4990-4999.]. Наиболее подходящим решением в контексте разработки подхода к классификации и оценке параметров сложных поверхностей представляется нейросетевая модель HRNet [Tao A., Sapra K., Catanzaro B. Hierarchical Multi-Scale Attention for Semantic Segmentation //arXiv preprint arXiv:2005.10821. – 2020.], характеризующаяся высоким качеством сегментации (значение метрики IoU по данным первоисточника превышало 85%) и способностью функционировать в режиме реального времени. В рамках предыдущих исследований [Rubtsova J. Approach to Image-Based Segmentation of Complex Surfaces Using Machine Learning Tools During Motion of Mobile Robots //Electromechanics and Robotics. – Springer, Singapore, 2022. – С. 191-200.] оригинальная нейросетевая модель была дообучена на наборе

данных, включающем в себя такие типы сцен как сцены с лестницами, сцены с ровными поверхностями, сцены с одиночными препятствиями, а также сцены с наборами препятствий. По результатам проведенных экспериментов дообученная модель HRNet продемонстрировала способность успешно сегментировать участки сложных поверхностей на единичных RGB изображениях – качество сегментации в условиях хорошей освещенности сцены достигло 90,2% по метрике IoU.

В контексте разработки подхода к классификации и оценке параметров сложных поверхностей по изображениям необходимо производить оценку пространственного положения исследуемого участка поверхности относительно РС. В случае, если объектив фиксирующей видеокамеры жестко зафиксирован на РС, то возможна оценка пространственного положения участка сцены непосредственно относительно фиксирующей видеокамеры. В общем случае оценка пространственного положения некоторого участка трехмерной сцены относительно объектива видеокамеры может быть реализована на основе данных карты глубины соответствующей сцены. Современные методы построения карт глубины преимущественно могут быть отнесены к двум основным категориям: аппаратные методы [Zhang Z. Microsoft kinect sensor and its effect //IEEE multimedia. – 2012. – Т. 19. – №. 2. – С. 4-10.], [Fernald F. G. Analysis of atmospheric lidar observations: some comments //Applied optics. – 1984. – Т. 23. – №. 5. – С. 652-653.], [Keselman L. et al. Intel realsense stereoscopic depth cameras //Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops. – 2017. – С. 1-10.] и методы, основанные на использовании нейросетевых моделей [Karsch K., Liu C., Kang S.B. Depth extraction from video using non-parametric sampling //European conference on computer vision. – Springer, Berlin, Heidelberg, 2012. – С. 775-788.], [Eigen D., Fergus R. Predicting depth, surface normals and semantic labels with a common multi-scale convolutional architecture //Proceedings of the IEEE international conference on computer vision. – 2015. – С. 2650-2658.], [Laina, I., Rupprecht, C., Belagiannis, V., Tombari, F., Navab, N. Deeper depth prediction

with fully convolutional residual networks //2016 Fourth international conference on 3D vision (3DV). – IEEE, 2016. – С. 239-248.]. К недостатку методов, основанных на использовании нейросетевых моделей, можно отнести меньшую точность работы в задаче построения карт глубины в сравнении с аппаратными методами. Также стоит отметить, что методы построения карт глубины, основанные на использовании нейросетевых моделей, не имеют возможности получать оценку расстояний от объектива камеры до участков сцены в метрических единицах, что исключает возможность использования подобных решений в контексте решения задачи оценки пространственного положения участков исследуемой трехмерной сцены. В рамках проведенного исследования было принято решение использовать камеру глубины RealSense D435 [Keselman L. et al. Intel realsense stereoscopic depth cameras //Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops. – 2017. – С. 1-10.] в связи с тем, что при решении задачи построения карт глубины данное устройство показывает высокую точность работы в сравнении с аналогами [Karsch K., Liu C., Kang S.B. Depth extraction from video using non-parametric sampling //European conference on computer vision. – Springer, Berlin, Heidelberg, 2012. – С. 775-788.], [Eigen D., Fergus R. Predicting depth, surface normals and semantic labels with a common multi-scale convolutional architecture //Proceedings of the IEEE international conference on computer vision. – 2015. – С. 2650-2658.], [Laina, I., Rupprecht, C., Belagiannis, V., Tombari, F., Navab, N. Deeper depth prediction with fully convolutional residual networks //2016 Fourth international conference on 3D vision (3DV). – IEEE, 2016. – С. 239-248.], а также позволяет оценивать расстояния от объектива камеры до исследуемых участков поверхностей на сцене в метрических единицах.

В рамках проведенного исследования был разработан подход к классификации и оценке параметров сложных поверхностей по RGB-D изображениям. Источником изображений служит камера Intel RealSense D435, закрепленная на модульной РС таким образом, чтобы оптическая ось объектива данной камеры располагалась в горизонтальной плоскости.

Предложенный подход к классификации и оценке параметров сложных поверхностей по RGB-D изображениям предполагает реализацию предварительного шага, который выполняется однократно в процессе развертывания соответствующего решения. На данном этапе устраняются эффекты дисторсии, а также перспективные искажения изображений в соответствии с алгоритмом, описанным в работе [Devernay F., Faugeras O.D. Automatic calibration and removal of distortion from scenes of structured environments //Investigative and Trial Image Processing. – International Society for Optics and Photonics, 1995. – Т. 2567. – С. 62-72.].

Разработанный подход к классификации и оценке параметров сложных поверхностей по RGB-D изображениям включает в себя следующие основные этапы:

1. Представление множества точек исследуемого участка сложной поверхности в трехмерном пространстве:
 - a. Определение пространственного расположения областей сцены, соответствующих пикселям исследуемого RGB-D изображения.
 - b. Сегментация сложных поверхностей с использованием дообученной нейросетевой модели HRNet [Rubtsova J. Approach to Image-Based Segmentation of Complex Surfaces Using Machine Learning Tools During Motion of Mobile Robots //Electromechanics and Robotics. – Springer, Singapore, 2022. – С. 191-200.].
2. Оценка геометрических параметров поверхностей.
3. Классификация сложных поверхностей, представляющих отдельные участки рельефа, на основе их геометрических характеристик:
 - a. Классификация поверхностей по углу наклона.
 - b. Классификация поверхностей по степени изменчивости высот.

Каждый из трех ключевых этапов подхода направлен на решение отдельной группы подзадач. Рассмотрим каждый из этапов предложенного подхода более детально.

На первом этапе для представления множества точек исследуемого участка сложной поверхности в трехмерном пространстве необходимо, в первую очередь, определить пространственное расположение областей сцены, которые соответствуют пикселям полученного с камеры Intel RealSense D435 изображения. Рассмотрим алгоритм определения пространственного расположения областей сцены более подробно.

Определим пространственную систему координат, связанную с объективом видеокамеры: ось Z сонаправлена с оптической осью фиксирующей видеокамеры, оси X и Y коллинеарны осям x , y плоскости изображения. В таком случае, пространственные области, связанные с каждым пикселем изображения, отклонены от нормали к плоскости XY на некоторые плоские углы в плоскостях XZ и YZ .

Пусть размер полученного с камеры Intel RealSense D435 изображения в пикселях по горизонтальным и вертикальным осям равен Img_{pixX} и Img_{pixY} соответственно. Для каждого пикселя p_i на данном изображении с индексами по горизонтальной и вертикальной осям i_{pixX} и i_{pixY} соответственно, вычислим угловое отклонение (1):

$$\begin{aligned} ang_{x_{pi}} &= \left(i_{pixX} - \frac{img_{pixX}}{2} \right) \cdot \frac{\alpha}{img_{pixX}} \\ ang_{y_{pi}} &= \left(i_{pixY} - \frac{img_{pixY}}{2} \right) \cdot \frac{\beta}{img_{pixY}} \end{aligned} \quad (1)$$

где $ang_{x_{pi}}$ – угловое отклонение для пикселя p_i по оси x ; $ang_{y_{pi}}$ – угловое отклонение для пикселя p_i по оси y ; α^o – угол обзора камеры по горизонтальной оси изображения (оси x); β^o – угол обзора камеры по вертикальной оси изображения (оси y).

Поскольку для каждого пикселя p_i с использованием камеры RealSense D435 можно получить оценки расстояний D_i до центров фактических пространственных участков сцены, ассоциированных с пикселями p_i , то оценка R_i положения пространственного участка сцены, охватываемого пикселем p_i , относительно системы отсчета, связанной с объективом видеокамеры, может быть произведена посредством (2):

$$\begin{cases} \mathbf{R}_i = \frac{\mathbf{r}_i}{|\mathbf{r}_i|} \cdot D_i \\ \mathbf{r}_i = (\text{tg}(\text{ang_}x_{pi}); \text{tg}(\text{ang_}y_{pi}); 1) \end{cases} \quad (2)$$

где \mathbf{r}_i – направляющий вектор, характеризующий положение пространственного участка сцены, охватываемого пикселем p_i , относительно системы отсчета, связанной с объективом видеокамеры.

Таким образом, пространственные координаты P_i^A участков сцены, связанных с пикселями изображения p_i , в глобальной системе координат A могут быть определены в соответствии со следующим выражением:

$$P_i^A = C^A + \mathbf{R}_i^A,$$

где C^A – вектор, характеризующий пространственное положение фиксирующей видеокамеры, отложенный в глобальной системе отсчета, \mathbf{R}_i^A – вектор, характеризующий положение пространственного участка сцены, охватываемого пикселем p_i в глобальной системе отсчета.

На втором этапе разработанного подхода дообученная модель нейронной сети HRNet выделяет на изображении сегменты, ассоциированные с участками сложных поверхностей. Обработывая изображение, данная нейросетевая модель возвращает количество найденных объектов и набор массивов (классы и маски). Маски представляют собой искомый набор пикселей изображения, принадлежащих исследуемому участку поверхности. Таким образом, зная целевой сегмент изображения, связанный с исследуемой поверхностью, представляется возможным определить множество точек $P_i = (x_i, y_i, z_i)$, принадлежащих исследуемой сложной поверхности.

Таким образом, исследуемый участок сложной поверхности формально может быть представлен в следующем виде:

$$Surf = \{P_i | i = 1, \dots, N\},$$

где N – число точек трехмерного пространства, ассоциированных с исследуемым участком сложной поверхности.

Для отнесения некоторого исследуемого участка поверхности к одной из классификационных групп требуется произвести оценку параметров сложной поверхности. В рамках соответствующей оценки, в первую очередь, необходимо определить уравнение плоскости, наилучшим образом аппроксимирующей исследуемый участок поверхности *Surf*. В качестве такой плоскости примем плоскость *O*, для которой будет минимально усредненное расстояние между точками, принадлежащими участку поверхности *Surf*, и данной плоскостью. Общее уравнение искомой плоскости выглядит следующим образом:

$$Ax + By + Cz + D = 0; x, y, z \in R, \quad (3)$$

где *A*, *B*, *C*, *D* – неизвестные параметры. Поиск значений данных параметров может быть представлен как задача параметрической оптимизации с ограничениями (4):

$$\frac{\sum_{i=1}^N \frac{|A*x_i+B*y_i+C*z_i+D|}{\sqrt{A^2+B^2+C^2}}}{N} \xrightarrow{A,B,C,D \in R} \min. \quad (4)$$

Таким образом, требуется определить такие значения параметров *A*, *B*, *C*, *D*, что при минимизации выражения (4) одновременно будет оставаться справедливым уравнение (3). Для решения оптимизационной задачи подобного рода может быть использован широкий спектр известных методов численной оптимизации [Измаилов А. Ф., Солодов М. В. Численные методы оптимизации. – 2003.], а также методов оптимизации на основе генетических алгоритмов [Гладков Л. А., Курейчик В. В., Курейчик В. М. Генетические алгоритмы. – 2010.].

Полученное уравнение плоскости (3) при известных параметрах будет являться оптимальным вариантом плоскостной аппроксимации пространственного распределения точек, принадлежащих исследуемому участку сложной поверхности *Surf*.

Затем осуществляется поиск 4 крайних точек *P*₁, *P*₂, *P*₃, *P*₄, для которых соответственно справедливы выражения (5)-(8):

$$P_1: \begin{cases} \max(x(P_i) | P_i \in Surf) == x(P_1) \\ \max(y(P_i) | P_i \in Surf) == y(P_1) \end{cases} \quad (5)$$

$$P_2: \begin{cases} \max(x(P_i) | P_i \in Surf) == x(P_2) \\ \min(y(P_i) | P_i \in Surf) == y(P_2) \end{cases} \quad (6)$$

$$P_3: \begin{cases} \min(x(P_i) | P_i \in Surf) == x(P_3) \\ \max(y(P_i) | P_i \in Surf) == y(P_3) \end{cases} \quad (7)$$

$$P_4: \begin{cases} \min(x(P_i) | P_i \in Surf) == x(P_4) \\ \min(y(P_i) | P_i \in Surf) == y(P_4) \end{cases} \quad (8)$$

После получения координат точек P_1, P_2, P_3, P_4 производится определение точки пересечения двух прямых, построенных по точкам P_1, P_3 и P_2, P_4 соответственно. Полученную точку пересечения двух прямых обозначим как P_c .

Далее исследуются 4 отрезка: $L_1 = [P_c; P_1], L_2 = [P_c; P_2], L_3 = [P_c; P_3], L_4 = [P_c; P_4]$. Каждый рассматриваемый отрезок L_j разделяется на K участков равной длины. Затем для каждого участка L_{jk} вычисляется расстояние между ним и плоскостью O . При расчете расстояния d_{jk} до плоскости O каждый участок L_{jk} аппроксимируется некоторой точкой P_{jk} , координаты которой задаются как усредненные координаты концов такого отрезка. Расстояние d_{jk} между некоторой точкой P_{jk} и плоскостью O определяется в соответствии с выражением (9).


$$\frac{|A \cdot x(P_{jk}) + B \cdot y(P_{jk}) + C \cdot z(P_{jk}) + D|}{\sqrt{A^2 + B^2 + C^2}} \quad (9)$$

Таким образом, каждому участку L_{jk} соответствует некоторое расстояние d_{jk} до плоскости O . Полученный набор данных в отношении параметров исследуемой поверхности позволяет провести ее дальнейшую классификацию.


Третий этап разработанного подхода к классификации сложных поверхностей направлен на определение классов исследуемой поверхности в соответствии с классификацией, предложенной на предыдущем этапе выполнения проекта. Принадлежность исследуемой поверхности к тому или иному классу определяется исходя из результатов оценки геометрических

параметров данной поверхности (этап 2 предложенного подхода) в соответствии с решающими правилами, приведенными в рамках разработанной ранее классификации.


Апробация разработанного подхода к классификации и оценке параметров сложных поверхностей производилась на базе тестового набора данных, включающего в себя 4500 изображений, на которых представлено 6000 различных поверхностей. Тестовый набор данных был сформирован с использованием камеры глубины RealSense D435. Данный набор данных включает в себя изображения сцен – помещений, содержащих как минимум одну поверхность, по которой РС предстоит передвигаться. Примеры изображений из тестового набора данных представлены на рисунке 1.



а)



б)



в)

Рисунок 1 – Примеры RGB изображений и соответствующих им карт глубины из тестового набора данных для оценки качества разработанного подхода: а) сцены с ровной поверхностью; б) сцены с поверхностью с малыми перепадами высот; в) сцены с поверхностью со значительными перепадами высот

На рисунке 1 представлены примеры RGB изображений из тестового набора данных и соответствующих данным изображениям карт глубины, полученных с использованием камеры глубины Intel Real Sense D435: сцен с ровной поверхностью (рисунок 1а), где в качестве такой поверхности выступает ровный пол; сцен с поверхностью с малыми перепадами высот (рисунок 1б), где в качестве такой поверхности выступает пол с малыми перепадами высот; сцен с поверхностью со значительными перепадами высот (рисунок 1в), где в качестве поверхности со значительными перепадами высот выступает лестница.

Каждому участку сложной поверхности $Surf_i$ на каждом изображении I_i , входящему в состав тестового набора данных, соответствует некоторый набор значений параметров P_i . Описание данных параметров представлено ниже:

1. Тип поверхности с точки зрения угла наклона U . Включает в себя 3 различных типа угла наклона поверхности: горизонтальные поверхности; наклонные поверхности; поверхности с переменным наклоном.
2. Тип поверхности с точки зрения изменчивости высот V : ровная поверхность; поверхность с малыми перепадами высот; поверхность со значительными перепадами высот.

Для оценки качества разработанного подхода были сформированы различные количественные оценки точности работы предложенного решения на тестовом наборе данных. Соответствующие показатели были определены следующим образом:

1. Для тестового набора данных *Surf* на основе анализа результатов применения разработанного подхода к классификации сложных поверхностей были сформированы матрицы ошибок классификации M_{Ui} и M_{Vj} , где i ($i = 1..3$) и j ($j = 1..2$) – число классов поверхностей с точки зрения угла наклона U и перепадов высот V соответственно. Данные матрицы формировались независимо для каждого типа поверхностей по каждой из классификационных группировок (см. таблицу 1).

Таблица 1 – Матрицы ошибок классификации

	Поверхность относится к данному типу поверхности	Поверхность не относится к данному типу поверхности
Алгоритм указал на принадлежность к данному типу поверхности	TP	FP
Алгоритм не указал на принадлежность к данному типу поверхности	FN	TN

В матрицах M_{Ui} ячейки TP_i отражают число поверхностей класса i , которые были корректно классифицированы алгоритмом и отнесены к соответствующему классу i ; ячейки FP_i отображают число экземпляров данных, которые были ложно отнесены алгоритмом к рассматриваемому классу i ; FN_i показывает количество случаев, когда алгоритм ложно показал отсутствие принадлежности исследуемых поверхностей к типу поверхности i ; ячейки TN_i отражают число верно определенных случаев отсутствия принадлежности исследуемых поверхностей к классу i . Аналогично для матриц M_{Vj} и ячеек TP_j , FP_j , FN_j и TN_j соответственно.

Далее для каждой матрицы вида M были определены показатели качества классификации A (accuracy), R (recall) и Pr (precision) в соответствии со следующими выражениями:

$$A = \frac{TP+TN}{TP+FP+FN+TN}, \quad (10)$$

$$R_{ij} = \frac{TP}{TP+FN}, \quad (11)$$

$$Pr_{ij} = \frac{TP}{TP+FP}. \quad (12)$$

На рисунке 2 представлены диаграммы полученных значений показателей A , R , Pr для каждого варианта классификации сложных поверхностей: по типу угла наклона U поверхности и по типу перепадов высот V .

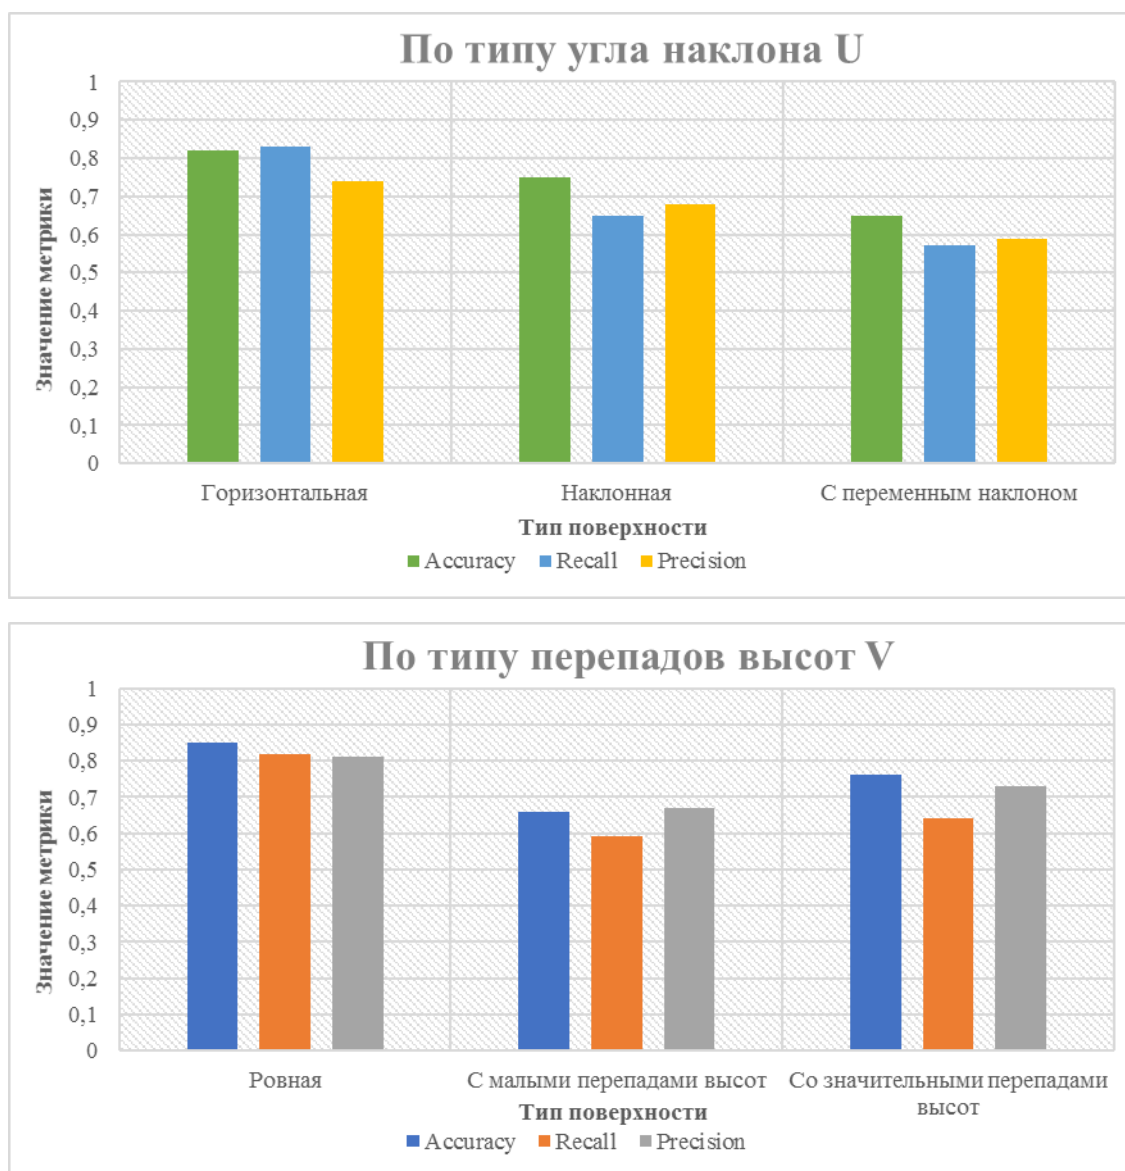


Рисунок 2 – Диаграммы полученных значений показателей A , R , Pr для каждого варианта классификации сложных поверхностей: по типу угла наклона U и по типу перепадов высот V

Основываясь на представленных выше результатах, можно заключить, что тип поверхности влияет на качество классификации сложных поверхностей, в частности, рассчитанные показатели A , R , Pr имеют более низкие значения для следующих типов поверхностей: поверхности с переменным наклоном; поверхности с малыми перепадами высот. Предполагается, что подобные результаты могут быть связаны с возникающими погрешностями при построении карт глубины, а также с возможными погрешностями при сегментации сложных поверхностей по изображениям. Наиболее высокие значения рассчитанных показателей имеют горизонтальные поверхности, а также ровные поверхности. Усредненные значения показателей A , R , Pr при классификации поверхностей по типу угла наклона составили $\{0,74; 0,68; 0,67\}$, а значения данных показателей в отношении классификации поверхностей по типу перепадов высот составили $\{0,76; 0,68; 0,74\}$.

На основании полученных данных были определены результирующие оценки качества классификации поверхностей из тестового набора данных (см. таблицу 2). Классификация поверхности считалось успешной в том случае, если поверхность была корректно классифицирована в рамках обеих классификационных групп.

Таблица 2 – Результирующие оценки качества классификации поверхностей из тестового набора данных

Оценки	Количество поверхностей	Средняя доля
Поверхность верно классифицирована как по типу угла наклона, так и по типу перепадов высот	3755	62,6%
Поверхность верно классифицирована по углу наклона, но неверно классифицирована по типу перепадов высот	561	9,4%
Поверхность верно классифицирована по типу перепадов высот, но неверно классифицирована по углу наклона	768	12,8%
Класс поверхности определен неверно в обоих случаях	916	15,2%

Как видно из представленных выше данных, результирующая доля корректно классифицированных поверхностей из тестового набора данных составила 62,6%; поверхности были верно классифицированы по углу наклона, но неверно классифицированы по типу перепадов высот в 9,4% случаев; доля поверхностей верно классифицированных по типу перепадов высот, но неверно классифицированных по углу наклона составила 12,8%; поверхности были неверно классифицированы по обоим вариантам классификации в 15,2% случаев. Исходя из полученных результатов можно заключить, что предложенное решение демонстрирует довольно высокое качество классификации сложных поверхностей по изображениям. Стоит также отметить, что данное решение позволяет не только определить классы поверхности, но и определить значения численных характеристик данных поверхностей, включая такие параметры как: величина угла наклона поверхности к горизонтальной плоскости, ориентация аппроксимирующей плоскости, положение краевых точек. Таким образом, предложенное решение позволяет успешно классифицировать различные поверхности по типу угла наклона и по типу перепадов высот, а также получать оценку параметров данных поверхностей по RGB-D изображениям.

3. Разработка собственных методов решения ОЗК на основе машинного обучения, которые могут быть применены к различным формациям модульных РС

Решение ОЗК многозвенных модульных систем заключается в поиске таких положений n сочленений-модулей $(\varphi_1, \varphi_2, \dots, \varphi_n)$, которые обеспечивают требуемое положение рабочего органа или отдельных элементов модульного робота (x_c, y_c, z_c) . Кроме того, решение ОЗК модульной РС осложняется большим разнообразием формаций, которые данная система может образовать посредством реконфигурации, с разным числом степеней свободы. Наиболее существенным образом в контексте решения ОЗК данное разнообразие

сказывается на формациях с цепными и смешанными структурами. Схемы различных формаций цепной структуры представлены на рисунке 3.

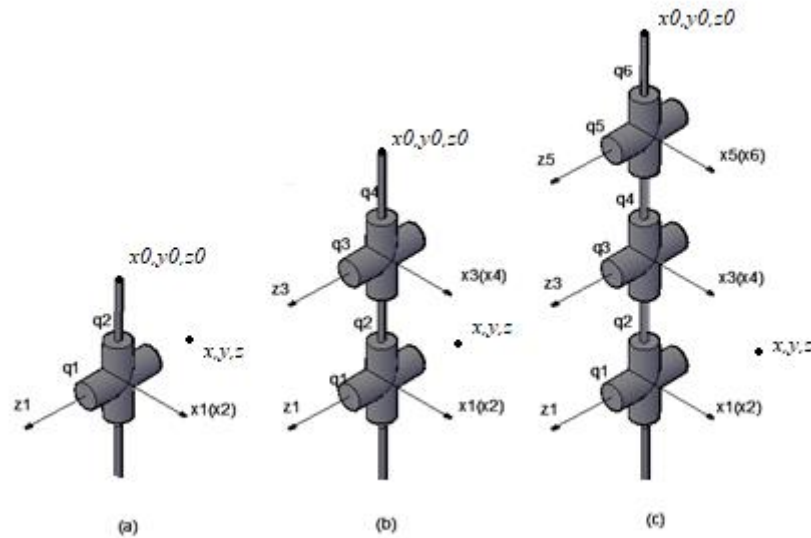


Рисунок 3 – Схемы цепных формаций модульных робототехнических систем, состоящие из: (а) одного модуля; (b) двух модулей; (c) трех модулей

На рисунке выше приведены соединения модулей исследуемой модульной РС. Исходное положение рабочих органов находится в точке с координатами (x_0, y_0, z_0) .

Применение искусственных нейронных сетей (ИНС) для решения ОЗК относится к методам контролируемого машинного обучения, в ходе которого модель искусственной нейронной сети получает связанные между собой данные и выводит между ними зависимости [Kriegeskorte N., Golan T. Neural network models and deep learning //Current Biology. – 2019. – Т. 29. – №. 7. – С. R231-R236. <https://doi.org/10.1016/j.cub.2019.02.034>.]. При решении ОЗК входными данными являются матрица положения рабочего органа, а выходными – состояния сочленений.

Для точного решения ОЗК при использовании глубоких нейронных сетей необходимо выполнить три основных задачи: получить наиболее репрезентативную выборку данных, выбрать наиболее подходящую архитектуру нейронной сети и гиперпараметры обучения. Первая и третья задачи решаются в рамках разработанного алгоритма обучения ИНС для решения ОЗК модульной РС, приведенного на рисунке 4.

Входными данными этого алгоритма являются: модели прямой кинематики – математические описания моделей для симуляции; размер обучающей выборки; параметры ИНС для каждой из формаций; имена или номера сочленений на стыках модулей; параметры для подключения к симуляции; макропараметры ИНС.

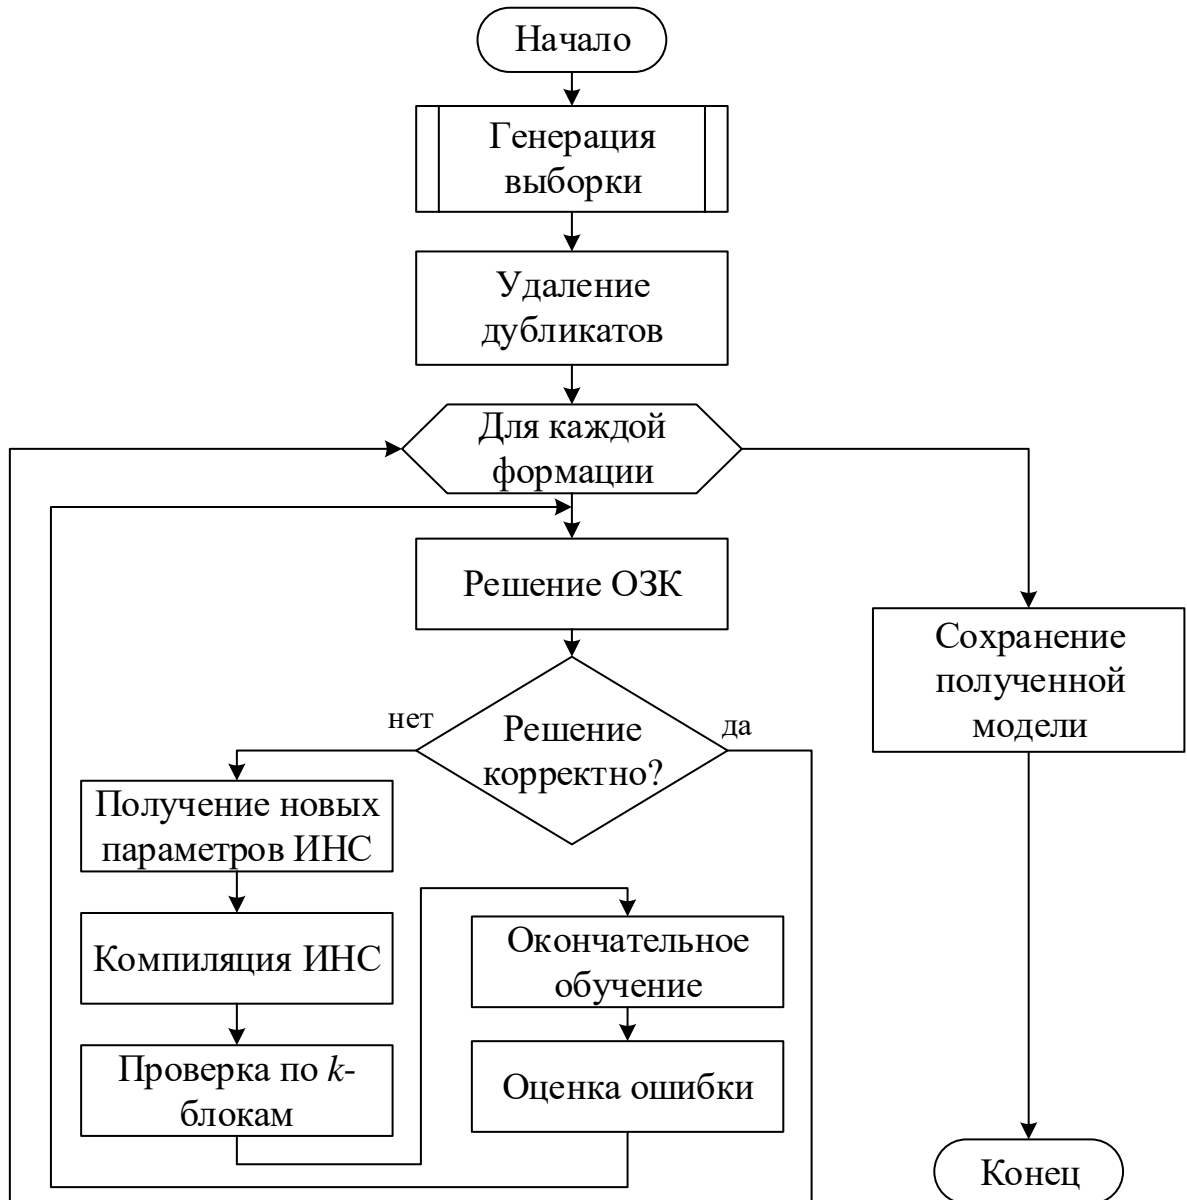


Рисунок 4 – Блок-схема алгоритма обучения ИНС для решения ОЗК модульной РС

На первом этапе работы алгоритма происходит формирование репрезентативной выборки для «родительской» и «дочерних» формаций, то есть подразумевается, что «дочерние» формации – это кинематические

структуры (подмножества), содержащиеся в общей структуре модульной РС. Данная общая структура, как было отмечено выше, задается пользователем. Генерация выборки происходит с помощью отдельного алгоритма, который далее рассматривается более подробно (см. рисунок 5). В результате выполнения алгоритма «Генерация выборки» сформированные случайные выборки записываются в файлы для возможности повторного использования полученных данных.

Далее из сформированной выборки в блоке «Удаление дубликатов» исключаются все повторяющиеся пары данных. Это необходимо для повышения репрезентативности выборок. Данный механизм отсеивания заключается в том, что полученные координаты округляются до двух знаков после запятой, после чего попарно сравниваются, в случае повторения какого-либо результата одна из пар удаляется из выборки.

Следующим этапом алгоритма является процесс обучения ИНС. На первом этапе обучения пользователем указываются параметры скрытых слоев нейронной сети. Из-за возрастания вычислительных затрат при удалении дубликатов и увеличения времени обучения нет возможности получить большую обучающую выборку, в связи с чем на этапе проверки получаемые оценки могут сильно меняться в зависимости от того, попадут данные оценки в проверочный или обучающий наборы. Это повлияет на оценку качества модели. Поэтому в данном алгоритме используется перекрестная проверка по k -блокам [Carmesin J. Diestel R., Hamann M., Hundertmark F. k -Blocks: a connectivity invariant for graphs //SIAM Journal on Discrete Mathematics. – 2014. – Т. 28. – №. 4. – С. 1876-1891. <https://doi.org/10.1137/130923646>.], чтобы установить оптимальное количество эпох обучения. В данном алгоритме реализовано разбиение полученного массива данных на 5 блоков, при этом создается 5 копий моделей нейронных сетей и осуществляется обучение каждой ИНС на 4 блоках с оценкой по оставшимся блокам. После этого по полученным оценкам вычисляется среднее значение, которое принимается в качестве общего критерия проверки. Наконец, находится наилучшая оценка

ошибки обучения и проводится повторное обучение на полном наборе данных. Если полученные результаты удовлетворяют требуемой точности, то алгоритм переходит к решению ОЗК следующей формации, иначе у пользователя запрашивается внесение изменений в параметры ИНС. В качестве меры точности в данном алгоритме используется среднее абсолютное отклонение между предсказанными ИНС углами и действительными значениями углов при сочленениях, полученных при генерации выборки.

После успешного обучения решению ОЗК всех формаций сохраняются веса и модели ИНС для дальнейшего использования.

В разработанном алгоритме формирования выборки возможно два способа получения выборки:

1. Аналитический – с помощью параметров Денавита-Хартенберга.
2. С использованием симуляции.

Аналитический способ требует знания параметров Денавита-Хартенберга для построения результирующих матриц. Второй способ, использующий симуляцию, требует модель робота (например, в формате Universal Robot Description Format – URDF). Однако использование каждого из данных способов формирования выборки параметров модульной системы сопровождается следующими проблемами. В случае с аналитическим способом из-за большого количества матричных вычислений требуется большая вычислительная мощность, а при использовании способа с симуляцией требуется модель для каждой формации модульной РС. Кроме того, при отсеивании повторяющихся пар параметров приходится в отдельности перебирать наборы углов для каждой формации.

Для решения описанных выше проблем был разработан алгоритм получения репрезентативной выборки пар «состояния сочленений-координаты рабочих органов». Блок-схема данного алгоритма представлена на рисунке 5. Приведенный алгоритм основан на принципе повторяемости кинематических схем модуля в многозвенных модульных системах. Алгоритм позволяет одновременно получать наборы данных о нескольких формациях с

цепной либо смешанной структурой, состоящих из модулей со схожей геометрией. Для работы данного алгоритма требуется указать параметры или модель только одной «родительской» формации, а также число сочленений в одном модуле. На основании данных «родительского» формации будут извлечены ее потомки – «дочерние» формации. Так, при аналитическом способе получения выборки в качестве потомков будут использованы промежуточные результирующие матрицы, а при использовании симуляции будут извлекаться положения промежуточных звеньев модульной РС.

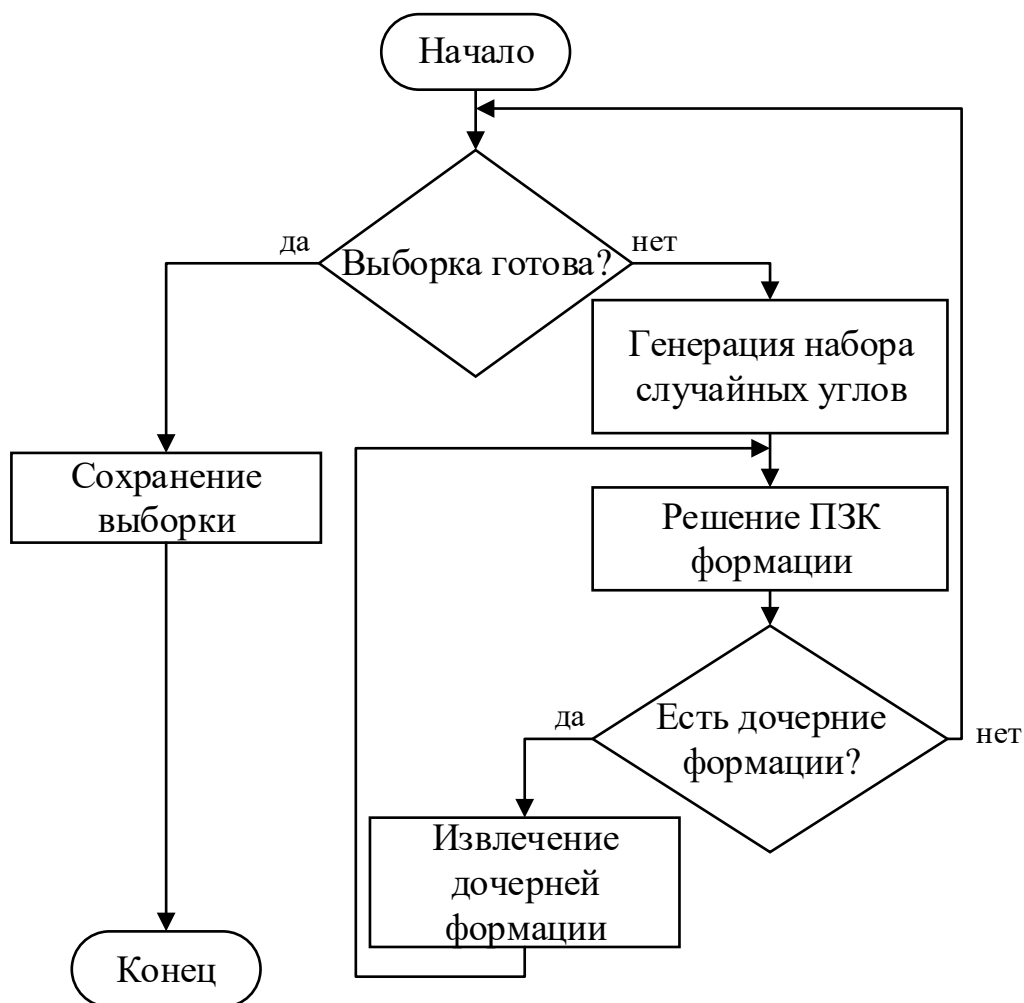


Рисунок 5 – Блок-схема алгоритма получения репрезентативной выборки

На вход данного алгоритма подается число «дочерних» формаций, а также необходимый размер массива данных для обучения ИНС. Разработанный алгоритм циклически пополняет набор данных для обучения до тех пор, пока не будет достигнут желаемый размер выборки. Соответствующая проверка осуществляется в блоке «Выборка готова?». Если

желаемый размер выборки не достигнут, продолжается генерация случайных наборов значений углов в сочленениях РС, которые затем используются для решения ПЗК. После получения решения проверяется, остались ли «дочерние» формации, если дочерние кинематические структуры остались, то далее выполняется извлечение данной формации и решение ПЗК до тех пор, пока не закончатся «дочерние» формации. В случае, если «дочерние» кинематические структуры закончились, то для всей кинематической структуры РС повторно выполняются шаги с получением данных для обучения. При окончании процесса получения данных для обучения выполняется сохранение выборки, которая используется в последующих шагах основного алгоритма, приведенного на рисунке 4.

Для проверки разработанных решений были проведены эксперименты, которые были разделены на два этапа. Первым этапом являлось обучение моделей ИНС, вторым – проверка решения ОЗК по случайным значениям.

На первом этапе экспериментов разработанные алгоритмы были применены для обучения ИНС, при этом данные для ее обучения генерировались с использованием моделей мобильной автономной робототехнической системы (МАРС). Из данных модулей были составлены два типа формаций: «манипулятор» и «змея». Первая формация имела разбиение на три (рисунок 6а), два (рисунок 6б) и один подвижный модуль (рисунок 6в). Формация «змея» имела аналогичное разбиение: три (рисунок 6г), два (рисунок 6д) и один подвижный модуль (рисунок 6е).

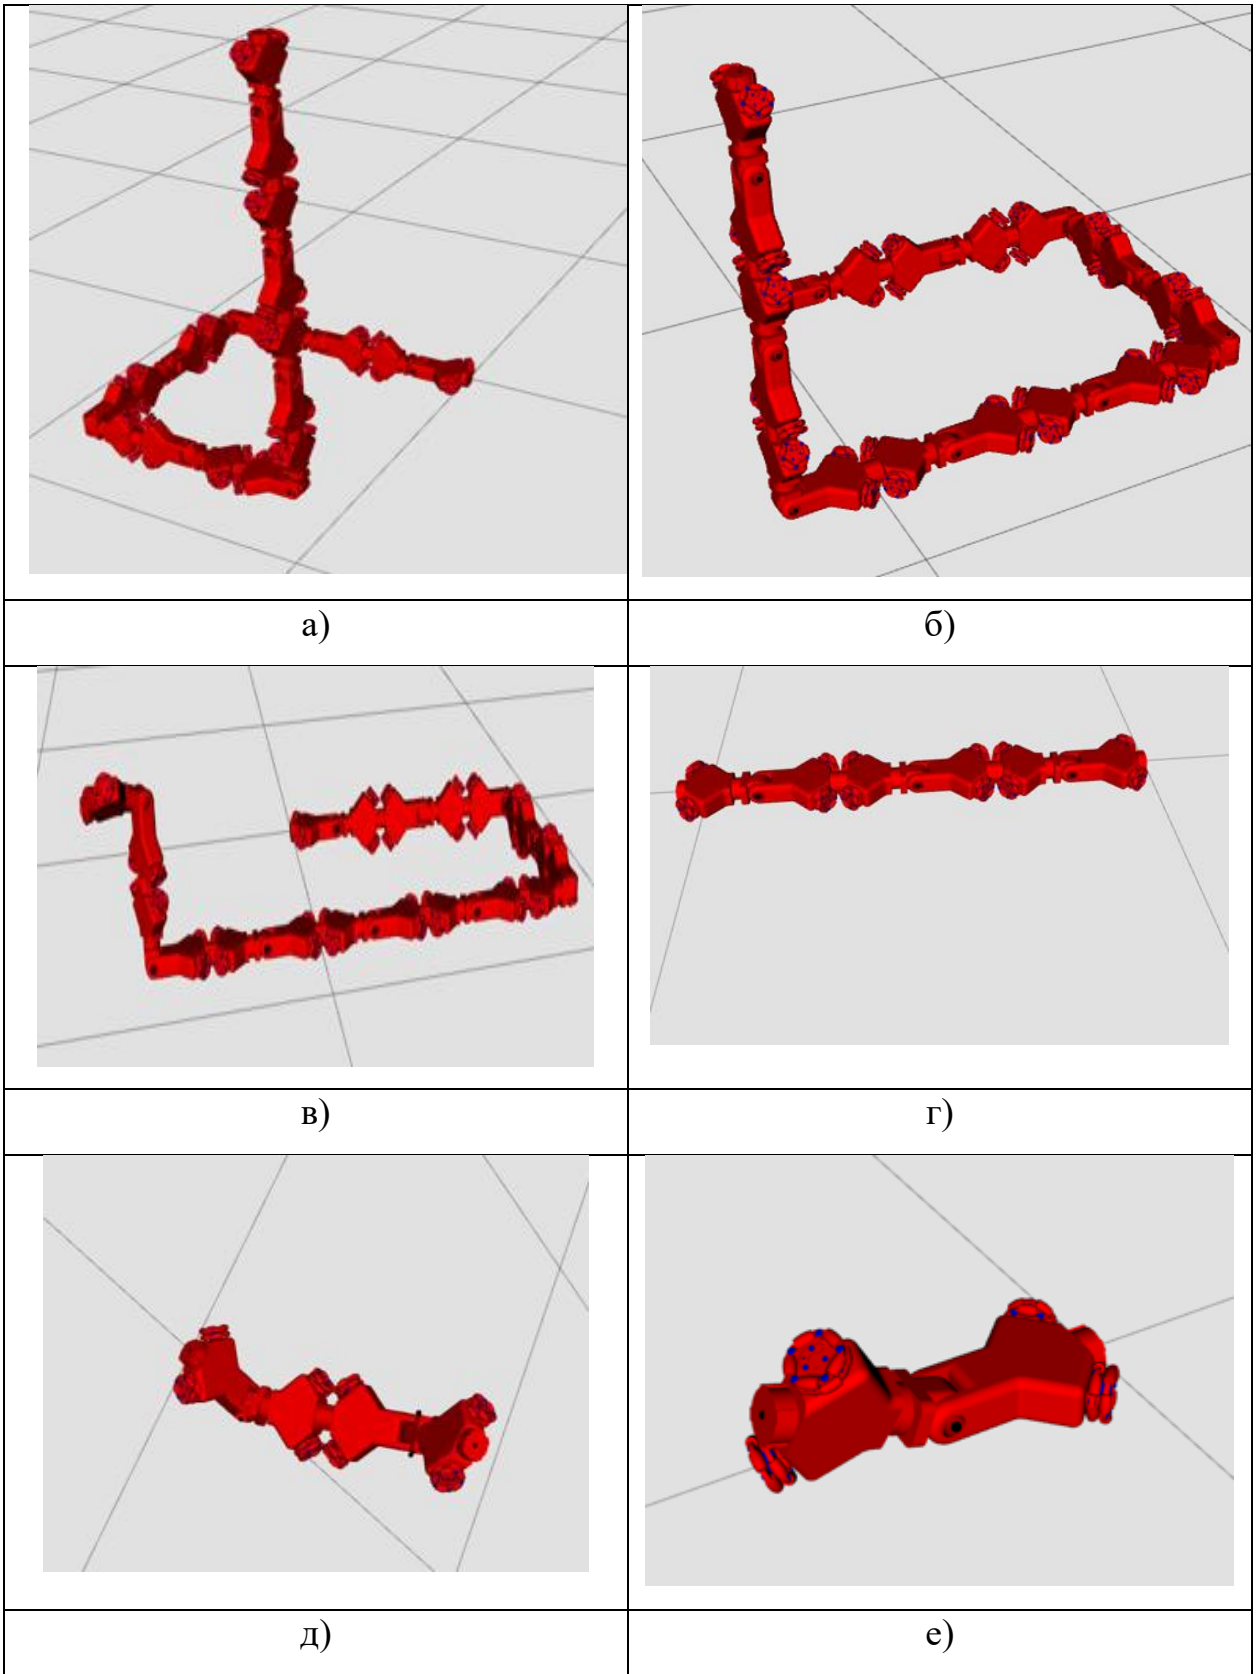


Рисунок 6 – Исследуемые формации модульной робототехнической системы
МАРС

Данные формации РС, составленной из модулей МАРС, имеют цепную кинематическую схему, при этом все модули имеют схожую геометрию и кинематическую структуру.

Для начала обучения необходимо указать размер обучающей выборки и сочленения, которые будут выступать в качестве рабочего органа. В экспериментах размер обучающей выборки составил 5000 элементов, отражающих возможные состояния исследуемой модульной РС (см. рисунок 7). В качестве рабочего органа выбрано сочленение, находящееся на окончании формации.

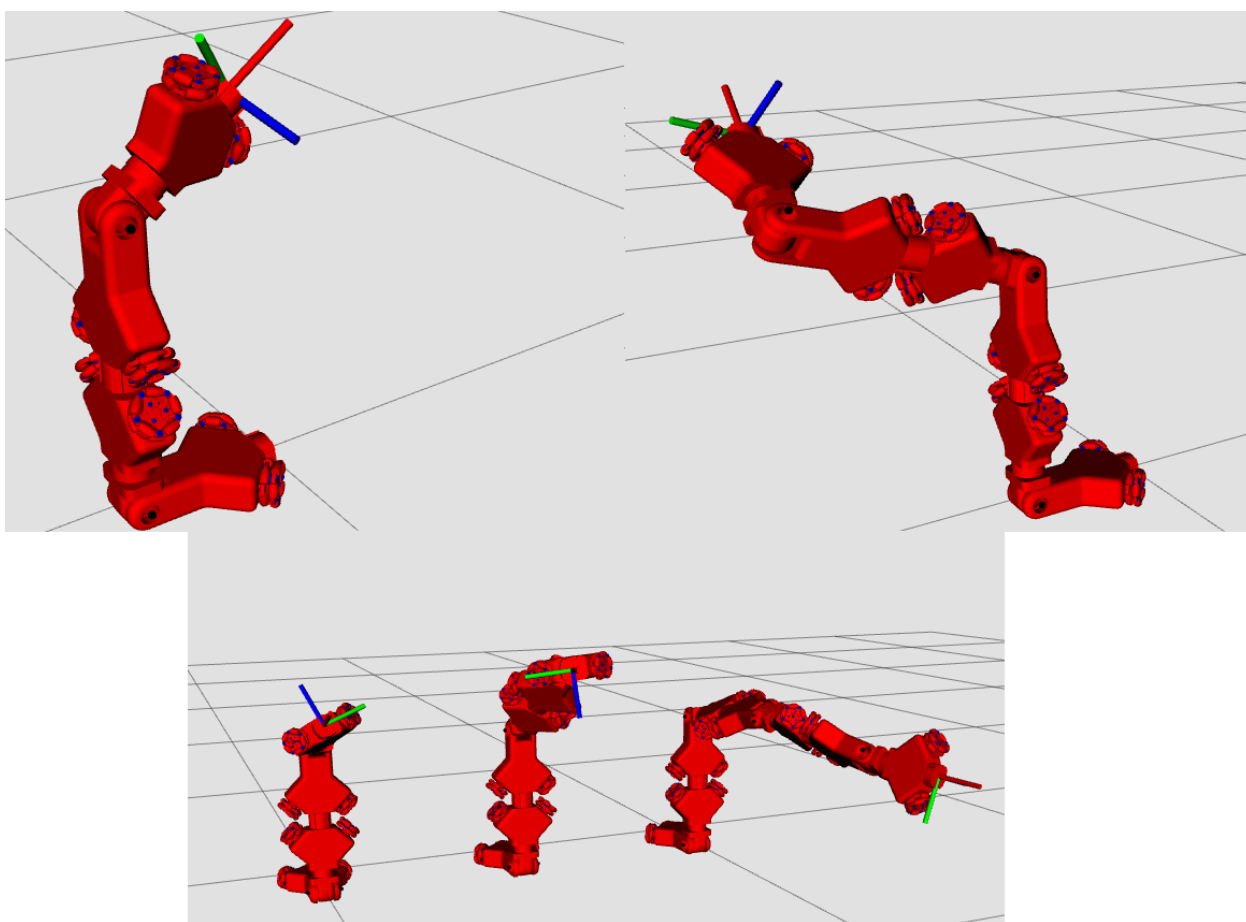


Рисунок 7 – Визуализация процесса получения обучающей выборки

В основе обучаемой ИНС была использована нейронная сеть с множественными скрытыми слоями, в качестве функции потерь – среднеквадратическая ошибка, при этом был использован оптимизатор, реализующий алгоритм Adam (метод стохастического градиентного спуска, основанный на адаптивной оценке моментов первого и второго порядка)

[Kingma D.P., Ba J. Adam. A method for stochastic optimization //arXiv preprint arXiv:1412.6980. – 2014.]. Использованное в экспериментах аппаратное обеспечение включало в себя процессор Intel Core i5-4690К 3,5 Гц, 16 ГБ ОЗУ, видеокарту NVIDIA GeForce GTX 970 4 ГБ.

В ходе работы алгоритма обучения были определены параметры скрытых слоев, дающие наименьшую среднюю ошибку отклонения между значениями углов в сочленениях. Так, для формаций, состоящих из трех модулей, – это три скрытых слоя по 256 нейрона с прореживанием в 20%. Для формаций, состоящих из двух модулей, – три скрытых слоя по 64 нейрона без прореживания, а для единичного модуля – три скрытых слоя по 32 нейрона без прореживания. В процессе обучения ИНС вычислялась средняя абсолютная ошибка после эпохи обучения по обеим формациям. Были получены графики изменения данного параметра. График изменения средней ошибки обучения ИНС для решения ОЗК модульной РС, состоящей из одного модуля, приведена на рисунке 8. Величины по осям ординат всех последующих графиков являются результатом нормализации значений средней ошибки с учетом среднеквадратического отклонения и среднего значения, полученные после обучения моделей ИНС. Каждое нормализованное значение представляет собой разность средней ошибки и среднего значения ошибок по модулю, деленная на среднеквадратическое отклонение.




Рисунок 8 – Кривая изменения средней абсолютной ошибки определения угла в сочленении модульной РС, состоящей из одного модуля

С помощью проверки по k -блокам было определено, что для системы из одного подвижного модуля МАРС наименьшая ошибка достигается на 79 эпохе обучения. Как видно по представленному графику, в течение первых эпох обучения средняя абсолютная ошибка значительно уменьшилась, но уже после 10 эпохи скорость изменения ошибки стала значительно меньше. Денормализованное значение отклонения между значениями углов соответствует в среднем $0,4^\circ$. На рисунке 9 показана кривая изменения средней абсолютной ошибки при обучении ИНС решению ОЗК системы, состоящей из двух модулей.




Рисунок 9 – Изменение средней абсолютной ошибки определения углов в сочленениях модульной РС, состоящей из двух модулей

Посредством проверки по k -блокам было выявлено, что для системы из двух модулей МАРС наименьшая ошибка получается на 89 эпохе обучения. При этом в течение первых эпох обучения средняя абсолютная ошибка значительно уменьшилась. Расчетное денормализованное отклонение между значениями углов соответствует в среднем $0,4815^\circ$. Полученная кривая изменения средней абсолютной ошибки для системы из трех модулей МАРС приведена на рисунке 10.




Рисунок 10 – Кривая изменения средней абсолютной ошибки определения углов в сочленениях модульной РС, состоящей из трех модулей

С применением проверки по k -блокам было определено, что число эпох, необходимых для получения наименьшей ошибки, составляет 78 эпох. При этом результирующая денормализованная средняя ошибка составила $2,925^\circ$.

Второй этап апробации предложенных методов заключался в проверке точности решения ОЗК посредством полученных моделей ИНС. Для этого был сгенерирован тестовый набор T_φ из 1000 кортежей $t_{\varphi i} = (\varphi_0, \dots, \varphi_W)_i \mid i = 1..1000$, W – число обобщенных координат модульной системы. В данных кортежах $t_{\varphi i} \in T_\varphi$ записывались случайные значения углов в сочленениях каждой кинематической структуры. Далее для каждого кортежа углов через аналитическое решение ПЗК были найдены координаты целевой точки $t_{ci} = (x_i, y_i, z_i)$. Для определения аналитического решения была использована модифицированная методика Денавита-Хартенберга [Craig J. J. Introduction to robotics: mechanics and control, 3/Е. – Pearson Education India, 2009. – 408 с.]. Затем данные координаты (x_i, y_i, z_i) были поданы на вход моделям ИНС, для

решения ОЗК, то есть для нахождения значений углов ($\varphi_{E0}, \dots, \varphi_{EW}$), где φ_{Ej} – прогноз величины угла, полученный с помощью ИНС, $j = 1 \dots W$. Наконец, была вычислена точность решения ОЗК, которая вычислялась как абсолютное отклонение между заданными и полученными с помощью ИНС значениями углов. Полученные результаты приведены в таблице 3 (см. Этап II).

Таблица 3 – Средние абсолютные отклонения по двум группам экспериментов

Состав системы \ Параметр	Один модуль	Два модуля	Три модуля
Этап I. Обучение			
Среднее отклонение, град	0,4	0,4815	2,925
Этап II. Проверка по случайно заданным углам			
Среднее отклонение, град	0,20	0,39	1,98
Среднее отклонение, м	0,0005	0,0015	0,0080

Результаты экспериментов показали, что среднее абсолютное отклонение для формаций РС с различным числом модулей составило $0,20^\circ$, $0,39^\circ$ и $1,98^\circ$ соответственно. При выражении через координаты с помощью решения ПЗК среднее отклонение составило 0,0005 м, 0,0015 м и 0,0080 м соответственно.

Таким образом, особенностью предложенного решения является возможность автоматического получения нейросетевых моделей, которые позволят решать ОЗК для отдельных формаций модульных РС. В качестве недостатка предложенного алгоритма обучения можно отметить ручной подбор гиперпараметров ИНС в процессе обучения. Разработанный алгоритм генерации выборки позволяет получить обучающую выборку для различных «дочерних» формаций модульной РС, что позволит решать ОЗК для управления модульной системой при сохранении конкретного типа формации в случае, если произошло изменение количества модулей. Кроме того, разработанный алгоритм опционально позволяет получить выборку для одной конкретной формации без учета кинематических подструктур и обучить модель ИНС решению ОЗК для управления данной формацией РС. В целом

предложенные алгоритмы имеют потенциал для применения в целях обучения моделей ИНС, которые позволят решать ОЗК модульной РС в различных формациях.

4. Разработка алгоритмов автоматической генерации элементов внешнего окружения (сложных поверхностей) с заданными параметрами для анализа качественных характеристик механического движения различных формаций модульных РС

Ранее, в ходе выполнения работ над проектом, была предложена классификация сложных поверхностей, представляющих отдельные участки рельефа помещений, на основе их геометрических характеристик. Предложенная классификация имеет высокий уровень обобщения и ориентирована на унификацию описания различных типов сложных поверхностей. В то же время следует отметить, что при разработке алгоритмов генерации сложных поверхностей отталкиваться следует от интуитивно понятных «прикладных» типов поверхностей. В ходе выполнения проекта были выделены «прикладные» типы поверхностей, в отношении которых были разработаны соответствующие алгоритмы автоматической генерации поверхностей с заданными параметрами. В перечень прикладных типов поверхностей в рамках настоящего исследования были включены: горизонтальные плоские поверхности; плоские поверхности с произвольным наклоном; дугообразные поверхности; лестницы. В таблице 4 представлены соответствия между прикладными типами поверхностей и классификационными группами, к которым данные поверхности потенциально могут быть отнесены в зависимости от значений параметров конкретной поверхности. Введем краткие обозначения для классификационных групп сложных поверхностей в соответствии с предложенной ранее классификацией:

- Поверхности с условно постоянным наклоном и отсутствием перепадов высот: (1;1).

- Поверхности с условно постоянным наклоном и малыми перепадами высот: (1;2).
- Поверхности с условно постоянным наклоном и значительными перепадами высот: (1;3).
- Поверхности с переменным наклоном и отсутствием перепадов высот: (2;1).
- Поверхности с переменным наклоном и малыми перепадами высот: (2;2).
- Поверхности с переменным наклоном и значительными перепадами высот: (2;3).

Таблица 4 – соответствия прикладных типов поверхностей и классификационных групп сложных поверхностей согласно предложенной классификации

Алгоритм генерации	Тип поверхности	(1;1)	(1;2)	(1;3)	(2;1)	(2;2)	(2;3)
№1	Горизонтальные плоские поверхности	+	+	+	–	–	–
№1	Плоские поверхности с произвольным наклоном	+	+	+	–	–	–
№2	Дугообразные поверхности	–	–	–	–	+	+
№3	Лестницы	–	+	+	–	–	–

Таким образом, для решения задачи по автоматической генерации сложных поверхностей были разработаны три алгоритма, каждый из которых обеспечивает генерацию определенных типов поверхностей. Рассмотрим разработанные алгоритмы подробнее. Алгоритм генерации поверхностей №1 ориентирован на генерацию горизонтальных плоских поверхностей и плоских поверхностей с произвольным наклоном. В качестве входных данных алгоритм принимает на вход следующий набор параметров:

1. Требуемый тип поверхности.
2. Классификационные группы генерируемой поверхности.
3. Ориентация поверхности относительно базовой системы отсчета (СО).
Определяется значениями параметров A , B , C уравнения плоскости (3), аппроксимирующей данную поверхность.
4. Положение двух краевых точек P_1 и P_2 генерируемой поверхности относительно базовой СО.
5. Положение прочих краевых точек поверхности P_i ($i = 3 \dots N$) относительно точки P_1 в системе отсчета, связанной с генерируемой поверхностью.
6. Коэффициент перепада высот – V . Это численный параметр, характеризующий степень изменчивости высот в рамках генерируемой поверхности.

Алгоритм генерации поверхностей №1 включает в себя несколько основных этапов и функционирует следующим образом:

1. В рамках используемой среды виртуального моделирования задается базовая система отсчета.
2. На основе значений параметров A , B , C , уравнения аппроксимирующей плоскости поверхности и пространственного положения краевой точки поверхности P_1 , определенных относительно базовой СО, осуществляется определение параметра D аппроксимирующей плоскости поверхности в соответствии со следующим выражением:

$$D = -AP_{1x} - BP_{1y} - CP_{1z}.$$

3. Определим дополнительную систему отсчета, связанную с генерируемой поверхностью следующим образом: начало СО совпадает с положением краевой точки поверхности P_1 ; оси x и y лежат в аппроксимирующей плоскости, при этом ось x сонаправлена с вектором между краевыми точками P_1 и P_2 ; ось z лежит перпендикулярно аппроксимирующей плоскости и сонаправлена с нормалью к ней; направление оси y определяется по правилу правой руки так, чтобы

получилась правосторонняя система координат. Матрицу перехода из базовой системы отчета в систему отсчета, связанную с поверхностью, обозначим как T_0^{Surf} .

4. На следующем шаге определим положение прочих краевых точек поверхности P_i в базовой системе отсчета следующим образом (13):

$$P_i^0 = T_{Surf}^0 \cdot P_i = (T_0^{Surf})^{-1} \cdot P_i. \quad (13)$$

5. Сегмент аппроксимирующей плоскости Seg , ограниченный отрезками S_j , последовательно соединяющими краевые точки поверхности P_i ($i = 1 \dots N$), будет представлять прообраз генерируемой поверхности.
6. Далее необходимо определить точки пересечения in_P_k отрезков S_j с плоскостью XOY базовой системы отсчета (если такие имеются). В случае, если соответствующие точки пересечения существуют, необходимо из общего набора краевых точек поверхности исключить те точки P_i , для которых в базовой системе отсчета справедливо выражение: $P_{iz} < 0$.
7. Переопределим набор краевых точек поверхности, включив в него точки in_P_k . Сегмент аппроксимирующей плоскости, ограниченный отрезками, последовательно соединяющими краевые точки поверхности (из обновленного набора краевых точек), будет представлять конечный прообраз генерируемой поверхности.
8. Для перехода к заключительному этапу разработанного алгоритма необходимо осуществить дискретизацию прообраза генерируемой поверхности. Таким образом, прообраз генерируемой поверхности $Surf_P$ представляется конечным набором точек вида P_s ($s = 1 \dots S$), каждая из которых входит в область, ограниченную отрезками, последовательно соединяющими краевые точки поверхности.
9. Заключительным этапом является внесение перепадов высот в прообраз генерируемой поверхности. С данной целью случайным образом выбираются прямоугольные сектора случайного размера вида $n \cdot m$. Каждый такой сектор Sec_k представляет собой некоторое подмножество

точек из набора $Surf_P$. Далее, для каждой точки P_{ki} , принадлежащей данному сектору ($P_{ki} \in Sec_k$), пространственное положение смещается в СО поверхности на величину, определяемую в соответствии с выражением (14):

$$offset(P_{ki}) = Rand(N(\mu = 0; \sigma^2 = 1 + V)) \cdot D(P_{ki}), \quad (14)$$

Первый множитель данного выражения соответствует псевдослучайной величине из нормального распределения с указанными параметрами, а второй – пропорционален расстоянию между точкой P_{ki} и центром сектора Sec_k . По результатам применения данных преобразований формируется обновленный набор точек $Surf_P_fin$, который и является конечным представлением генерируемой поверхности.

Полученный с применением разработанного алгоритма набор $Surf_P_fin$ за счет применения средств трехмерного моделирования может быть использован для построения конечной визуализации генерируемой поверхности. В рамках данного процесса на поверхность могут быть дополнительно наложены различные текстуры с целью учета специфических свойств различных материалов, которые могут влиять на характеристики механического движения робототехнических систем.

Далее рассмотрим алгоритм генерации поверхностей №2, ориентированный на построение дугообразных поверхностей. В качестве прообраза дугообразных поверхностей в рамках данного алгоритма используются поверхности цилиндрической формы. На вход данный алгоритм принимает следующий набор параметров:

1. Классификационные группы генерируемой поверхности.
2. Базовые параметры поверхности a , b , являющиеся параметрами цилиндрической поверхности с образующими, параллельными оси OZ , и описываемой уравнением (15):

$$\frac{x^2}{a^2} + \frac{y^2}{b^2} = 1. \quad (15)$$

где x и y – координаты вдоль осей x и y СО, связанной с цилиндрической поверхностью.

3. Параметр протяженности поверхности – l . Характеризует протяженность цилиндра вдоль оси OZ .
4. Уровень отсечения поверхности – Cut . Принимает значения в диапазоне от 0 до a и определяет какая доля исходной фигуры будет использована в процессе генерации поверхности.
5. Ориентация генерируемой поверхности относительно базовой СО – rot . Задаёт матрицу вращения (в СО, связанной с исходной фигурой), применение которой к исходной поверхности позволяет достичь нужной ориентации поверхности в базовой СО.
6. Коэффициент перепада высот – V . Численный параметр, характеризующий степень изменчивости высот в рамках генерируемой поверхности.

Алгоритм генерации поверхностей №2 включает в себя несколько основных этапов и функционирует следующим образом:

1. На первом этапе в соответствии с заданными параметрами a , b и l осуществляется генерация прообраза генерируемой поверхности требуемой формы, размера и протяженности.
2. На втором шаге алгоритма осуществляется дискретизация полученного прообраза поверхности. Таким образом, прообраз генерируемой поверхности $Surf_P$ представляется набором точек вида P_i ($i = 1 \dots N$).
3. Далее из набора точек $Surf_P$ исключаются все точки, для которых $P_{ix} < Cut$. Результат данной операции можно интерпретировать как отсечение некоторой части от исходного прообраза поверхности посредством плоскости YOZ , смещенной на величину Cut в направлении оси OX .
4. На следующем шаге ко всем точкам P_i , входящим в обновленный набор $Surf_P$ применяется матрица вращения rot (в СО, связанной с прообразом поверхности). Таким образом достигается корректная ориентация прообраза поверхности в рамках базовой СО.

5. Далее из набора точек $Surf_P$ исключаются такие точки P_i , для которых в базовой СО справедливо выражение: $P_{iz} < 0$. В результате формируется конечный прообраз генерируемой поверхности $Surf_P_rez$.
6. Заключительный шаг данного алгоритма в полной мере аналогичен шагу 9 алгоритма №1 и обеспечивает внесение перепадов высот в прообраз генерируемой поверхности. По результатам выполнения соответствующих преобразований формируется обновленный набор точек $Surf_P_fin$, который и является конечным представлением генерируемой поверхности.

По аналогии с алгоритмом №1, полученный с применением данного алгоритма набор $Surf_P_fin$ за счет применения средств трехмерного моделирования может быть использован для построения конечной визуализации генерируемой поверхности, к которой также могут быть применены различные текстуры.

В заключении кратко рассмотрим алгоритм генерации поверхностей №3. Данный алгоритм направлен на построение поверхностей типа лестница. Данный алгоритм опирается на базовый функционал распространенных сред трехмерного моделирования и не предполагает комплексных последовательных преобразований исходных прообразов поверхностей для получения их конечного представления. В данном случае поверхность типа лестница рассматривается как многокомпонентная поверхность, состоящая из двух групп идентичных элементов. На вход данный алгоритм принимает следующий набор параметров:

1. Направление лестницы d – принимает значение 1 для лестницы, направленной вверх, и -1 для лестницы, направленной вниз.
2. Ширина лестницы – w .
3. Число ступеней – n .
4. Высота ступеней – h .
5. Глубина ступеней – D .

6. Ориентация генерируемой поверхности относительно базовой системы отсчета – задает матрицу вращения rot (в CO , связанной с исходной фигурой), применение которой к исходной поверхности позволяет достичь необходимой ориентации поверхности в базовой CO .

Предложенный алгоритм состоит из следующих ключевых шагов:

1. На первом шаге осуществляется генерация n прямоугольных поверхностей шириной w и длиной D , расположенных в плоскости XOY , первая из которых не имеет смещения по осям y и z , а каждая следующая смещается относительно предыдущей по оси y на величину D , а по оси z – на величину h .
2. На следующем шаге осуществляется генерация n прямоугольных поверхностей шириной w и высотой h , расположенных в плоскости XOZ , первая из которых смещена по оси y на величину D и не имеет смещения по оси z , а каждая следующая смещается относительно предыдущей по оси y на величину D , а по оси z – на величину h .
3. На заключительном шаге ко всем сгенерированным прямоугольным поверхностям применяется матрица вращения rot (в CO , связанной с прообразом поверхности). В результате данного шага формируется конечное представление генерируемой поверхности в рамках базовой CO .

По аналогии с представленными выше алгоритмами, в процессе визуализации сгенерированной поверхности к ней могут быть применены различные текстуры.

Таким образом, в рамках выполнения работ над проектом были разработаны алгоритмы автоматической генерации сложных поверхностей различного типа с заданными параметрами. Предложенные алгоритмы планируется в дальнейшем использовать для анализа качественных характеристик механического движения формаций модульных РС по сложным поверхностям различного типа.

5. Разработка метода оценки оптимальности характеристик механического движения формаций модульных РС по различным участкам рельефа помещений, представленных сложными поверхностями

В рамках выполнения работ над проектом был разработан метод оценки оптимальности характеристик механического движения формаций модульных РС по различным участкам рельефа, представленным сложными поверхностями. Разработанный метод ориентирован на использование в средах виртуального моделирования, которые позволяют получить большой объем сопутствующей информации о фактических характеристиках движения РС в процессе симуляции.

Базовый сценарий применения данного метода предполагает, что некоторая модель модульной РС в заданной формации осуществляет движение по некоторому участку рельефа, представленному конечным набором сложных поверхностей. Для РС определена расчетная траектория движения по заданному участку рельефа, а также требуемая скорость движения по маршруту – V . Целевая скорость движения РС задается на всю длину пути и составляет не более 80% от предельной скорости движения РС в данной формации.

В качестве основных факторов, характеризующих оптимальность механического движения РС, в рамках предложенного метода рассматривались степень отклонения РС от расчетной траектории движения, степень отклонения скорости движения РС от целевого значения в процессе движения по траектории, степень равномерности движения РС по заданной траектории, а также общее время движения по траектории. В разработанный метод включены алгоритмы оценки данных факторов для получения комплексной результирующей оценки оптимальности механического движения модульной РС. Рассматриваемые факторы оцениваются в соответствии с алгоритмами, описанными ниже.

Алгоритм численной оценки влияния отклонений РС от расчетной траектории движения включает в себя следующие основные шаги:

1. В процессе движения РС по заданной траектории периодически с некоторой частотой осуществляется оценка расстояния d_t между фактическим положением РС и ближайшей точкой расчетной траектории.
2. В случае, если в некоторый момент времени t_1 расстояние d_{t1} становится больше некоторого порогового значения D_{max} , то считается, что РС отклоняется от заданной траектории. Точку выхода с заданной траектории обозначим как P_1 .
3. Далее, до тех пор, пока расстояние между фактическим положением РС и ближайшей точкой расчетной траектории вновь не станет меньше, чем D_{max} , РС считается в состоянии отклонения от целевой траектории. Точку возврата на целевую траекторию обозначим как P_2 , длину участка целевой траектории между точками P_1 и P_2 обозначим как L_{t1} , а фактическую длину пути между точками целевой траектории P_1 и P_2 как R_{t1} . Определим среднюю величину отклонения РС от целевой траектории в процессе движения между точками P_1 и P_2 как D_{t1} .
4. По завершению процесса движения РС итоговый вклад рассматриваемого фактора в результирующую оценку оптимальности движения РС может быть определен в соответствии с выражением (16):

$$Tr = \frac{\sum_{i=1}^n (L_{ti} + |R_{ti} - L_{ti}|)}{L_{base}} \cdot \frac{\sum_{i=1}^n D_{ti}}{n}, \quad (16)$$

где n – число зафиксированных отклонений от целевой траектории в процессе движения РС; L_{base} – протяженность целевой траектории движения РС.

Таким образом, чем чаще фактическая траектория РС отклонялась от расчетной и чем значительней были соответствующие отклонения, тем

большее значение будет иметь величина Tr , характеризующая влияние данного фактора на итоговую оценку оптимальности движения РС.

Далее рассмотрим алгоритм численной оценки влияния отклонений скорости движения РС от целевого значения в процессе движения РС на итоговую оценку оптимальности движения РС. Разработанный алгоритм включает в себя следующие основные этапы:

1. На первом этапе фактическая траектория движения РС разбивается на множество участков вида L_i таким образом, что время прохождения данных участков траектории остается равным некоторому промежутку времени t .
2. Далее для каждого из полученных участков траектории L_i осуществляется расчет средней скорости движения РС v_i на данном участке.
3. В случае, если на некотором из участков фактической траектории L_i средняя скорость движения РС v_i отличается от целевого значения V более, чем на величину v_{max} , то есть если $|V - v_i| > v_{max}$, то считается, что на данном участке траектории имеется отклонение скорости движения РС от заданного целевого значения.
4. Итоговый вклад рассматриваемого фактора в результирующую оценку оптимальности движения РС может быть определен в соответствии с выражением (17):

$$V_{tr} = \sum_{i=1}^m |V - v_i| \mid |V - v_i| > v_{max}, \quad (17)$$

где m – полученное число участков траектории вида L_i .

Таким образом, с ростом числа участков траектории, на которых наблюдалось существенное отклонение между средней скоростью движения РС и ее целевым значением, тем более значение будет иметь величина V_{tr} .

Далее рассмотрим алгоритм численной оценки влияния равномерности движения РС по заданной траектории на итоговую оценку оптимальности движения РС. В общем случае возникновение существенных мгновенных

ускорений в процессе механического движения РС снижает стабильность и устойчивость движения такой системы. В контексте рассматриваемого алгоритма под ускорением РС понимается ускорение всей связанной системы твердых тел, а не отдельных модулей системы. Учитывая требования к передвижению по всему маршруту с постоянной целевой скоростью, появление значимых ускорений РС однозначно свидетельствует о нарушениях стабильности процесса движения системы. Рассмотрим основные шаги соответствующего алгоритма:

1. В процессе движения РС по заданной траектории периодически с некоторой частотой осуществляется определение модулей значений мгновенного ускорения РС. Таким образом, формируется набор значений мгновенного ускорения РС $\{a_i \mid i = 1 \dots n\}$, каждый элемент которого ассоциирован с некоторым моментом времени t_i .
2. На следующем шаге задается набор T_set промежутков времени ΔT_j , каждый из которых имеет длительность t_{min} . Начала соответствующих временных отрезков определяются в соответствии с выражением (18):

$$T_j = t_0 + \frac{T}{m} \cdot j, \quad (18)$$

где t_0 – момент начала движения РС; T – общее время движения РС по заданной траектории; m – численная переменная, при этом $m \ll n$.

3. Далее осуществляется оценка модулей среднего ускорения РС A_j на каждом из полученных промежутков времени ΔT_j согласно выражению (19):

$$A_j = \frac{\sum_{k=1}^K |a_k| : T_j \leq t_k \leq T_j + \frac{T}{m}}{K}, \quad (19)$$

где K – число значений мгновенного ускорения РС, полученных в промежутке между моментами времени T_j и $(T_j + T/m)$ соответственно.

4. В случае, если на некотором промежутке времени ΔT_j модуль среднего ускорения РС A_j больше некоторой пороговой величины

A_{max} , то считается, что на данном временном отрезке есть значительные ускорения РС, что свидетельствует о существенных нарушениях стабильности процесса движения РС по целевой траектории.

5. Итоговый вклад рассматриваемого фактора в результирующую оценку оптимальности движения РС может быть определен в соответствии с выражением (20):

$$A_{tr} = \sum_{j=1}^J A_j | A_j > A_{max}. \quad (20)$$

Получаемые с помощью представленных выше алгоритмов результаты оценки факторов применяются для определения результирующей оценки оптимальности движения РС в соответствии с формулой (21):

$$Val = Tr + V_{tr} + A_{tr} + T. \quad (21)$$

Данная результирующая оценка является целевым результатом применения разработанного метода. Получаемое значение означает, что чем меньше величина Val , тем меньше возникло нарушений в процессе механического движения модульной РС по заданной траектории и тем более оптимальным следует считать механическое движение модульной РС по данному участку рельефа в заданной формации.

Таким образом, в рамках выполнения работ над проектом был предложен метод оценки оптимальности характеристик механического движения формаций модульных РС по различным участкам рельефа помещений, представленных сложными поверхностями. Практическую апробацию разработанного метода планируется провести в дальнейшем в рамках выбранной виртуальной среды с целью оценки качества механического движения формаций модульных РС по сложным поверхностям различного типа.