

Отчет о выполнении проекта РФФИ № 20-08-01109 А «Разработка подхода к выбору оптимальных формаций модульных робототехнических систем исходя из геометрических характеристик внешнего окружения» за 2022 год

Аннотация

Целью проекта является разработка подхода к выбору оптимальных формаций модульных робототехнических систем (РС) в зависимости от геометрических характеристик сложных поверхностей участков пути РС, что позволит добиться повышения эффективности движения РС и проходимости по подобным участкам.

На первом этапе реализации проекта была сформирована методика выбора оптимальных формаций модульных РС исходя из специфики внешнего окружения. Посредством предложенной методики могут быть извлечены пространственные положения точек, принадлежащих исследуемой поверхности, что позволяет однозначно определить классы и иные параметры исследуемой поверхности. Передача полученной информации, а также значений признаков, связанных с требуемыми показателями качества движения РС, в качестве входных данных для предварительно обученной модели выбора оптимальных формаций позволяет реализовать процесс определения оптимальных формаций модульных РС исходя из специфики внешнего окружения.

В соответствии с предложенной методикой в ходе реализации проекта научным коллективом была предложена классификация сложных поверхностей, представляющих отдельные участки рельефа помещений, исходя из их геометрических характеристик. Основываясь на предложенной классификации, впоследствии был разработан специализированный подход к классификации и оценке параметров сложных поверхностей по изображениям, отличающийся возможностью извлечения геометрических характеристик исследуемых поверхностей. 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 проведенного тестирования, усредненные показатели точности (accuracy, recall, precision) классификации по углу наклона и по типу перепадов высот на тестовом наборе данных составили $\{0.74, 0.68, 0.67\}$ и $\{0.76, 0.68,$

0,74} соответственно, при этом усредненная доля корректно классифицированных поверхностей по обоим классификациям составила 62,6%. Таким образом, предложенное решение позволяет успешно классифицировать различные поверхности по типу угла наклона и по типу перепадов высот, и, кроме того, осуществлять извлечение ряда геометрических характеристик сложных поверхностей, включая параметры, описывающие оптимальный вариант плоскостной аппроксимации пространственного распределения точек, принадлежащих сложной поверхности, а также набор параметров, характеризующих протяженность исследуемой поверхности.

На втором этапе реализации проекта рамках решения одной из основных задач проекта были разработаны специализированные алгоритмы, позволяющие формировать модели искусственных нейронных сетей, направленных на решение 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. Ключевым 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 сразу для целого ряда формаций модульной РС.

Также на данном этапе проекта в соответствии с предложенной ранее методикой были разработаны алгоритмы автоматической генерации элементов внешнего окружения (сложных поверхностей) с заданными параметрами. Данные алгоритмы позволяют создавать модели таких типов поверхностей, как горизонтальные плоские поверхности, плоские поверхности с произвольным наклоном, дугообразные поверхности, а также лестницы. При этом в качестве входных данных предложенные алгоритмы запрашивают лишь некоторые ключевые точки генерируемой поверхности относительно базовой системы координат, а также значения параметров, определяющих рельефность генерируемой поверхности. Алгоритмы специально разработаны для применения их выходных результатов в средах робототехнического моделирования и отличаются сравнительно низкой вычислительной сложностью, а также высокой вариативностью конфигураций генерируемых поверхностей.

Кроме того, в ходе выполнения второго этапа проекта, согласно предложенной методике, 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. В рамках экспериментальной оценки предложенного решения были проведены симуляции движения формаций модульной РС по различным типам поверхностей с последующим применением разработанного метода. Также были получены экспертные оценки качества движения данной системы для всех проведенных симуляций. Было установлено, что экспертные оценки в большинстве случаев совпадают с результатами применения предложенного метода, а усредненное по типам поверхностей относительное отклонение между соответствующими оценками, не превышало 0,32 на тестовом наборе симуляций.

На заключительном этапе выполнения проекта в соответствии с ранее предложенной методикой был разработан и успешно протестирован метод, предназначенный для решения задачи определения оптимальной формации модульной РС из конечного множества формаций, исходя из характеристик отдельных участков рельефа помещений, по которым модульной РС предстоит осуществлять движение. Указанный метод, основан на применении модели машинного обучения, осуществляющей прогнозирование оптимальной формации модульной РС на основании входных данных, включающих характеристики сложной поверхности по которой РС предстоит осуществлять движение, а также данных, отражающих уровень приоритета отдельных характеристик механического движения модульной РС при выборе оптимальной формации. В процессе экспериментов, было обучено и протестировано несколько моделей машинного обучения, наилучшие результаты среди которых показала модель на основе метода случайного леса. По результатам тестирования предложенный метод продемонстрировал достаточно высокий уровень качества идентификации оптимальной формации в различных условиях окружения, достигнув точности в 76,3% по метрике (Averaged Accuracy – AAc) на валидационном наборе данных. Полученные результаты позволяют утверждать, что разработанный метод может успешно использоваться при решении широкого круга прикладных задач, предполагающих адаптивное управление формациями модульных РС в зависимости от специфики внешнего окружения.

В рамках заключительных работ над проектом было проведено комплексное тестирование разработанной методики, методов и алгоритмов

посредством симуляции движения модульной РС в различных условиях окружения на отдельных участках смоделированной среды. Данная экспериментальная апробация проводилась с использованием среды виртуального моделирования Gazebo. В качестве исходных данных для моделирования была использована часть набора данных, сформированного для обучения модели машинного обучения, лежащей в основе метода определения оптимальных формаций для модульных РС. Предложенные в рамках проекта решения позволили в ходе тестирования достичь результирующей средней точности определения оптимальной формации модульной РС в 67,8%, что является достаточно высоким уровнем качества решения для столь комплексной задачи.

Таким образом, в ходе исполнения проекта научному коллективу удалось решить основные задачи, поставленные в рамках проекта, а также успешно реализовать и апробировать подход к выбору оптимальных формаций модульных РС в зависимости от геометрических характеристик сложных поверхностей участков пути РС, что в дальнейшем позволит добиться значительного повышения проходимости и эффективности движения модульных РС в подобных условиях.

Результаты проведенных исследований представлены на 4 международных конференциях. Опубликовано 5 статей в научных изданиях, индексируемых в базах Scopus/WoS, RSCI и РИНЦ.

Abstract

The aim of the project is to develop an approach for choosing optimal formation of modular robotic systems (RS) depending on specific geometric characteristics of complex surfaces, what will make it possible to increase the efficiency of the RS movement and the cross-country ability along such surfaces.

At the first stage of the project, a methodology for selecting optimal formations of modular RSs based on the specifics of the external environment was formed. By means of the proposed methodology, the spatial positions of points belonging to the studied surface can be extracted, which allows to unambiguously determine the classes and other parameters of the studied surface. Using the received information, as well as the values of the features associated with the required indicators of the quality of RS movement, as input data for the pre-trained model of optimal formations selection allows to implement the process of determining the optimal formations of modular RS based on the specifics of the external environment.

In accordance with the proposed methodology, during the implementation of the project, the research team proposed a classification of complex surfaces, representing individual sections of the premises, according to their geometric

characteristics. Based on the proposed classification, a specialized approach to the classification and assessment of the parameters of complex surfaces using RGB-D images was developed. This approach is characterized by the possibility to extract the geometric characteristics of the surfaces studied. The proposed approach is based on the use of a pre-trained segmentation neural network model HRNet, which selects a complex surface on the target area, and a number of analytical algorithms that assess the spatial position of the investigated surface area. According to the test results, the average accuracy indices (accuracy, recall, precision) of the classification by inclination angle and height differences on the test data set were $\{0.74, 0.68, 0.67\}$ and $\{0.76, 0.68, 0.74\}$ respectively, the average percentage of correctly classified surfaces for both classifications was 62.6%. Thus, the proposed solution allows to successfully classify different surfaces by the type of inclination angle and by the type of height differences, as well as to extract a number of geometric characteristics of complex surfaces, including parameters describing the optimal option of plane approximation of the spatial distribution of points belonging to the complex surface, as well as a set of parameters characterizing the extent of the studied surface.

At the second stage of the project, specialized algorithms were developed to form artificial neural network models aimed at solving inverse kinematics (IK) problem of various formations of modular RS as one of the main tasks of the project. The analysis of the results of the conducted experiments showed that the proposed solution allows to achieve high accuracy in solving IK problem for different formations of RS with different kinematic structures. A key advantage of the proposed solution is the possibility of automatic generation of training samples based on the kinematic structure of the RS formation and its subsidiary substructures, which makes it possible to obtain artificial neural network models aimed at solving the inverse kinematics problem for a number of formations of modular RS at once.

Also, at this stage of the project, algorithms for automatic generation of external environment elements (complex surfaces) with specified parameters were developed in accordance with the previously proposed methodology. These algorithms allow creating models of such surface types as horizontal flat surfaces, flat surfaces with arbitrary slope arcuate surfaces, and straight stairs. At the same time, as input data, the proposed algorithms request only some key points of the generated surface relative to the base coordinate system, as well as values of parameters that determine the relief of the generated surface. The algorithms are specially designed for the application of their output results to robotic modeling environments and are characterized by relatively low computational complexity and high variability in the configurations of the generated surfaces.

In addition, during the second stage of the project, according to the proposed methodology, a method was developed for assessing the optimality of the characteristics of the mechanical movement of modular RS formations across different sections of the premises, represented by complex surfaces. The proposed method based on such parameters as the degree of RS deviation from the calculated trajectory of movement, the degree of RS speed deviation from the target value during movement, the degree of uniformity of RS movement, as well as the total time of RS movement along the trajectory, allows to assess the optimality of mechanical movement of modular RS in a given formation. As part of the experimental evaluation of the proposed solution, simulations of the motion of various formations of modular RS over different types of surfaces were conducted, followed by application of the developed method. Also, expert evaluations of the quality of motion of this system were obtained for all conducted simulations. It was found that the expert assessments in most cases coincide with the results of the proposed method, and the relative deviation between the corresponding assessments, averaged over the types of surfaces, did not exceed 0.32 on the test set of simulations.

At the final stage of the project, in accordance with the previously proposed methodology, was developed and successfully tested a method designed to solve the problem of determining the optimal formation of modular RS from a finite set of formations, based on the characteristics of different sections of the premises, over which the modular RS is moving. The method is based on application of a machine-learning model which carries out predictions of an optimum formation of modular RS based on the input data including characteristics of a complex surface on which RS is to move, and the data characterizing the level of priority of separate characteristics of mechanical movement of modular RS when choosing the optimum formation. Within the experiments, several machine learning models were trained and tested, the best results among which were shown by the model based on the random forest method. According to the test results, the proposed method showed a fairly high quality of identification of the optimal formation in different environmental conditions, achieving an accuracy of 76.3% by metric (Averaged Accuracy – AAc) on the validation dataset. The obtained results allow to state that the developed method can be successfully used in solving a wide range of applied problems that involve adaptive control of formations of modular RS depending on the specifics of the external environment.

As part of the final work on the project, comprehensive testing of the developed methodology, methods and algorithms was conducted by simulating the movement of a modular RS in different environmental conditions in certain areas of the simulated environment. This experimental testing was conducted using the Gazebo simulation environment. As input data for the simulation, part of the dataset

generated for training the machine learning model underlying the method for determining optimal formations for modular RSs was used. The solutions proposed within the project made it possible to achieve the resulting average accuracy of determining the optimal formation of modular RS of 67.8% during experiment, which is a sufficiently high level of solution quality for such a complex problem.

Thus, the research team managed to solve the main tasks set within the project, as well as to successfully implement and test the approach to the selection of optimal formations of modular RS depending on the geometric characteristics of the complex surfaces of the RS track sections, which in the future will make it possible to significantly improve the permeability and efficiency of movement of modular RS in such conditions.

The results of the research were presented at 4 international conferences. Published 5 scientific articles in the editions indexed in the databases Scopus/WoS and RSCI.

Цель и задачи проекта

Целью проекта является разработка подхода к выбору оптимальных формаций модульных робототехнических систем (РС) в зависимости от геометрических характеристик сложных поверхностей участков пути РС, что в дальнейшем позволит добиться повышения проходимости и эффективности движения РС по подобным участкам. Разработка предлагаемого подхода включает в себя следующие задачи:

- Разработка методики выбора оптимальных формаций модульных РС, с учетом специфики внешнего окружения (типов сложных поверхностей).
- Исследование методов решения задач кинематики и динамики, пригодных для различных формаций модульных РС, с целью обеспечения возможности движения таких формаций по различным типам сложных поверхностей.
- Разработка метода оценки оптимальности характеристик механического движения формации модульной РС по различным типам сложных поверхностей.

Важнейшие результаты, полученные при реализации проекта

В рамках выполнения работ над проектом была предложена методика выбора оптимальных формаций модульных РС исходя из специфики внешнего окружения. Посредством предложенной методики могут быть извлечены пространственные положения точек, принадлежащих исследуемой поверхности, что позволяет однозначно определить классы и иные параметры

исследуемой поверхности. Передача полученной информации, а также значений признаков, связанных с требуемыми показателями качества движения РС, в качестве входных данных для модели выбора оптимальной формации модульной РС позволяет реализовать процесс определения оптимальных формаций, исходя из специфики внешнего окружения.

В ходе реализации проекта была предложена классификация сложных поверхностей, представляющих отдельные участки рельефа помещений, исходя из их геометрических характеристик. Разработанная классификация имеет высокий уровень обобщения, что позволяет унифицировать описание различных типов сложных поверхностей и их признаковое описание с сохранением в каждом конкретном случае данных о специфических особенностях исследуемой поверхности. Кроме того, в ходе реализации проекта был разработан специализированный подход к классификации и оценке параметров сложных поверхностей по изображениям, отличающийся возможностью извлечения геометрических характеристик исследуемых поверхностей. Данный подход основан на применении камеры глубины Intel RealSense D435, реализующей оценку расстояний от объектива камеры до участков сцены в метрических единицах, предобученной сегментационной нейросетевой модели HRNet, осуществляющей выделение на изображении целевого участка сложной поверхности, а также ряде аналитических алгоритмов, реализующих оценку ключевых параметров поверхностей и их классификацию. Согласно результатам проведенного тестирования, предложенное решение позволяет успешно классифицировать различные поверхности по типу угла наклона и по типу перепадов высот в соответствии с предложенной классификацией, и, кроме того, осуществлять извлечение ряда геометрических параметров сложных поверхностей, включая параметры, описывающие оптимальный вариант плоскостной аппроксимации пространственного распределения точек, принадлежащих сложной поверхности, а также набор параметров, характеризующих протяженность исследуемой поверхности.

В рамках проекта также были разработаны специализированные алгоритмы, позволяющие формировать модели искусственных нейронных сетей, направленных на решение 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. Ключевым 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 сразу для целого ряда формаций модульной РС.

В рамках выполнения работ над проектом также были разработаны алгоритмы автоматической генерации элементов внешнего окружения (сложных поверхностей) с заданными параметрами. Данные алгоритмы позволяют создавать модели таких типов поверхностей, как горизонтальные плоские поверхности, плоские поверхности с произвольным наклоном, дугообразные поверхности, а также лестницы. При этом в качестве входных данных предложенные алгоритмы запрашивают лишь некоторые ключевые точки генерируемой поверхности относительно базовой системы координат, а также значения параметров, определяющих рельефность генерируемой поверхности. Алгоритмы специально разработаны для применения их выходных результатов в средах робототехнического моделирования и отличаются сравнительно низкой вычислительной сложностью, а также высокой вариативностью конфигураций генерируемых поверхностей.

В ходе выполнения проекта был также 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. Апробация разработанного метода осуществлялась путем проведения серии симуляций движения различных формаций модульной РС по различным типам сложных поверхностей с последующей оценкой оптимальности характеристик механического движения РС в каждой из симуляций. Полученные результаты были верифицированы путем привлечения экспертной группы, выполнившей независимую оценку в отношении каждой из симуляций. В результате было установлено, что результаты экспертной оценки преимущественно совпадают с результатами оценки оптимальности движения формаций посредством разработанного метода. Относительное отклонение результатов работы предложенного метода от оценок, предоставленных экспертной группой для всех рассмотренных типов поверхностей, не превышает 0,32, что позволяет говорить о высоком прикладном потенциале предложенного метода при решении задач по оценке оптимальности характеристик механического движения формаций модульных РС.

На заключительном этапе выполнения проекта в соответствии с ранее предложенной методикой был разработан и успешно протестирован метод, предназначенный для решения задачи определения оптимальной формации модульной РС из конечного множества формаций, исходя из характеристик отдельных участков рельефа помещений, по которым модульной РС предстоит осуществлять движение. Указанный метод, основан на применении модели машинного обучения, осуществляющей прогнозирование оптимальной формации модульной РС на основании входных данных, включающих характеристики сложной поверхности по которой РС предстоит осуществлять движение, а также данных, отражающих уровень приоритета отдельных характеристик механического движения модульной РС при выборе оптимальной формации. В ходе экспериментальной апробации реализация соответствующей модели машинного обучения на базе случайного леса продемонстрировала достаточно высокий уровень качества идентификации оптимальной формации в различных условиях окружения, достигнув точности в 76,3% по метрике AAc на валидационном наборе данных. Полученные результаты позволяют заключить, что разработанный метод может успешно использоваться при решении широкого круга прикладных задач, предполагающих адаптивное управление формациями модульных РС в зависимости от специфики внешнего окружения.

Сопоставление результатов, полученных при реализации, с мировым уровнем

Одним из наиболее перспективных направлений в современной робототехнике является разработка многофункциональных модульных РС, способных самостоятельно осуществлять реконфигурацию и оперативно изменять положение узлов в процессе работы в зависимости от текущей задачи. Использование модульных РС во многом основывается на построении различных сложноструктурированных формаций из универсальных модульных единиц. Большинство формаций имеют собственную специфику и проектируются индивидуально под решение тех или иных классов практико-ориентированных задач. Однако, в современной литературе недостаточное внимание уделено адаптивной реконфигурации модульных систем в ответ на изменение внешнего окружения, в частности, на изменение рельефа, по которому передвигается РС.

В общем случае классификация и анализ пространственных характеристик участков среды, по которым РС предстоит осуществлять движение, является крайне нетривиальной задачей. На сегодняшний день существует ряд работ, посвященных классификации сложных поверхностей, в

частности, широко представлены исследования, направленные на решение задачи классификации поверхностей на основе данных сенсорных устройств различного типа, таких как: IMU-сенсоры [1], камеры видимого спектра [2], а также тактильные пьезоэлектрические или емкостные датчики [3]. Выделение признаков для классификации поверхностей также рассматривается в работах [4]. Отдельного внимания заслуживает работа [5], авторы которой сделали акцент на анализе indoor сред. Тем не менее, общим недостатком всех представленных выше решений является неполнота признакового описания поверхностей, в частности, практически отсутствуют исследования, реализующие классификацию сложных поверхностей с учетом их геометрических характеристик, которые оказывают значительное влияние на эффективность механического движения РС.

Таким образом, в ходе реализации проекта была предложена классификация сложных поверхностей, представляющих отдельные участки рельефа помещений, исходя из их геометрических характеристик. Разработанная классификация имеет высокий уровень обобщения, что позволяет унифицировать описание различных типов сложных поверхностей и их признаковое описание с сохранением в каждом конкретном случае данных о специфических особенностях исследуемой поверхности. Кроме того, в ходе реализации проекта был разработан специализированный подход к классификации и оценке параметров сложных поверхностей по изображениям, отличающийся возможностью извлечения геометрических характеристик исследуемых поверхностей. Согласно результатам проведенного тестирования, предложенное решение позволяет успешно классифицировать различные поверхности по типу угла наклона и по типу перепадов высот в соответствии с предложенной классификацией, и, кроме того, осуществлять извлечение ряда геометрических параметров сложных поверхностей, включая параметры, описывающие оптимальный вариант плоскостной аппроксимации пространственного распределения точек, принадлежащих сложной поверхности, а также набор параметров, характеризующих протяженность исследуемой поверхности.

Обеспечение возможностей модульных РС к адаптивной реконфигурации в ответ на изменение окружение приводит к возникновению повышенных требований к системам управления модульными РС. Разработка подобных управляющих систем, в свою очередь, требует применения специализированных методов и подходов к решению задач кинематики таких РС. При этом для реализации управления модульными РС с гиперизбыточностью актуальным является решение ОЗК в режиме реального времени. Кроме того, выбранный метод решения ОЗК для модульной РС

должен соответствовать требованиям к эффективности, быстродействию и универсальности для применения к различным формациям такой системы. Таким образом, в ходе выполнения проекта были разработаны специализированные алгоритмы, позволяющие формировать модели искусственных нейронных сетей, направленных на решение 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. В сравнении с рядом современных исследований, посвященных разработке подходов к решению ОЗК с использованием различных методов машинного обучения, представленных в таких работах как [6–9], ключевым 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 сразу для целого ряда формаций модульной РС.

В существующих исследованиях, посвященных проблеме оценки оптимальности механического движения, зачастую рассматривается ограниченный набор возможных формаций мобильных РС, кроме того, практически не учитывается тип поверхности, по которой система осуществляет передвижение. Так, в [10] и [11] рассматривается лишь формация «квадропод», перемещающаяся по плоской поверхности, а в [12] и [13] – лишь шагающие формации и формация «змея» также на плоской поверхности без наклонов. Данные решения не могут гарантировать устойчивое качество работы в тех случаях, когда мобильная РС реконфигурирует в иные формации или осуществляет движение по сложным поверхностям, отличающимся от рассмотренных авторами. Разработанный в рамках проекта метод оценки оптимальности характеристик механического движения формаций модульных РС является расширением над существующими решениями и может быть успешно использован на широком числе формаций модульных РС в процессе их движения по различным типам сложных поверхностей. Помимо формаций модульных РС и типов сложных поверхностей, предложенный метод также инвариантен к задаваемым траекториям движения модульной РС, что позволяет достичь более высокой точности оценки оптимальности характеристик механического движения для широкого класса модульных РС.

Одной из актуальных задач в рамках настоящего проекта являлась разработка алгоритмов автоматической генерации элементов внешнего окружения (сложных поверхностей) с заданными параметрами. Большинство

существующих решений в области генерации поверхностей, характеризуются значительными временными затратами на генерацию моделей, что главным образом обуславливается тем, что данные решения не поддаются полной автоматизации, поскольку требуют предварительного получения цифровых объектов с помощью дополнительного оборудования [14], [15]. Существующие методы автоматической генерации моделей различных поверхностей, как правило, основаны на процедурной генерации [16], [17] и обладают избыточной детализацией с точки зрения применения данных методов для моделирования поверхностей перемещения РС. Кроме того, существует крайне ограниченное число решений, позволяющих настраивать параметры генерируемой поверхности достаточно гибко для применения в области робототехники. Существует также группа методов, способных к автоматической генерации целевой поверхности посредством применения нейросетевых моделей [18], [19]. Однако, при использовании подобных решений существует вероятность появления артефактов на сгенерированной поверхности. В то же время разработанные в рамках проекта алгоритмы автоматической генерации сложных поверхностей позволяют создавать модели таких прикладных типов поверхностей, как горизонтальные плоские поверхности, плоские поверхности с произвольным наклоном, дугообразные поверхности, а также лестницы. При этом в качестве входных данных предложенные алгоритмы запрашивают лишь некоторые ключевые точки генерируемой поверхности относительно базовой системы координат, а также значения параметров, определяющих рельефность генерируемой поверхности. Алгоритмы специально разработаны для применения их выходных результатов в средах робототехнического моделирования и отличаются относительной простотой реализации, а также высокой вариативностью конфигураций генерируемых поверхностей.

Реализация адаптивной реконфигурации модульных систем в ответ на изменение внешнего окружения предполагает разработку методик, методов и подходов, направленных на определение оптимальных формаций РС для перемещения по различным участкам рельефа. Существует значительное количество исследований [20], [21], посвященных определению границ эффективной применимости тех или иных формаций модульных РС с точки зрения их способности к осуществлению механического движения по различным сложным поверхностям. В частности, в работах [22], [23] отмечается, что шагающие формации, такие как «квадропод», «паук» и др., как правило, являются наиболее эффективными при перемещении по участкам местности с большим количеством препятствий, в то время как при движении на ровных поверхностях, характеризуются достаточно низкой скоростью

перемещения. В то время, как катящиеся формации, представленные, например в [24] (Рисунок 6а) и [25], чаще всего демонстрируют наилучшие показатели качества движения при перемещении по открытым и ровным поверхностям. Общий недостаток всех представленных выше работ, посвященных анализу оптимальных условий использования различных формаций модульных РС, заключается в том, что в соответствующих исследованиях зачастую рассматривается задача определения оптимальной области применения некоторой конкретной формации РС, в то время как задача поиска оптимальной формации системы для заданных условий внешнего окружения остается вне рамок работы. Таким образом, предложенные в рамках проекта: методика выбора оптимальных формаций модульных РС исходя из специфики внешнего окружения, а также метод определения оптимальной формации модульной РС из конечного множества формаций, исходя из характеристик отдельных участков рельефа помещений, по которым модульной РС предстоит осуществлять движение, являются передовыми в данной области и практически не имеют прямых аналогов.

1. Методы и подходы, использованные при реализации проекта (описать, уделив особое внимание степени оригинальности и новизны)

1.1. Методика выбора оптимальных формаций модульных РС исходя из специфики внешнего окружения (участка местности, по которому РС предстоит осуществлять движение)

В рамках выполнения работ над проектом научным коллективом была предложена методика выбора оптимальных формаций модульных РС исходя из специфики внешнего окружения. В контексте настоящего проекта в качестве специфики внешнего окружения выступает, в первую очередь, поверхность по которой РС осуществляет движение. Разработанная методика включает в себя две основные фазы: предварительную фазу и фазу исполнения. Предварительная фаза направлена на сбор и анализ данных о характеристиках ожидаемого внешнего окружения РС, а также данных о конструктивных и функциональных особенностях робототехнических средств, выступающих в качестве агентов, с целью разработки и обучения модели выбора оптимальных формаций РС. Предварительная фаза включает в себя следующие основные этапы:

1. Выбор результирующего набора формаций модульной робототехнической системы, доступных для использования с учетом предполагаемой специфики внешнего окружения;

2. Генерация множества синтетических сцен в виртуальной среде с различными параметрами сложных поверхностей рельефа, исходя из предполагаемой специфики внешнего окружения;
3. Моделирование процессов механического движения РС и протоколирование результатов моделирования.
4. Обучение модели выбора оптимальных формаций модульной РС с учетом специфики ожидаемого окружения.

Фаза исполнения также включает в себя несколько основных этапов, представленных ниже:

1. Определение ключевых параметров сложной поверхности, по которой РС предстоит осуществлять движение;
2. Применение модели выбора оптимальной формации модульной РС.

Приведем развернутое описание каждого из этапов входящих в состав, представленных выше фаз. В целом, вся предварительная фаза предложенной методики ориентирована на сбор данных и последующее обучение некоторой модели машинного обучения, которая бы позволила на основе входных данных о характеристиках сложной поверхности, по которой модульной РС предстоит осуществлять движение, а также данных, характеризующих уровень приоритета отдельных характеристик механического движения модульной РС при выборе формации, определить оптимальную формацию модульной РС из доступного перечня формаций.

Результирующий набор формаций модульной РС определяется как доступным для использования числом модульных единиц, входящих в состав РС, так и их функциональным наполнением, обусловленным спецификой поставленных перед РС задач. В общем случае, согласно результатам проведенных исследований, наиболее универсальными формациями модульных РС, обеспечивающими передвижение РС по различным поверхностям с препятствиями, являются «шагающие» формации: «квадропад» и «паук». Однако скорость передвижения при использовании данных формаций остается достаточно низкой. Поэтому, в случае необходимости движения РС по ровной поверхности с большей скоростью, следует использовать формацию «машина», а также формации «колесо» и «сфера». Если же РС необходимо преодолевать труднопроходимый участок местности, такой как труба или узкая траншея или перебраться через широкую яму, лучшим вариантом будет использование формации «змея». Таким образом, в рамках проекта рассматривались следующие формации модульных РС: змея, квадропад, паук, машина, колесо и сфера.

В рамках настоящей методики для формирования обучающего набора данных предлагается использовать набор результатов моделирования движения различных формаций модульной РС в условиях различного окружения. Таким образом, на втором этапе предварительной фазы, согласно методике, должна осуществляться генерация множества синтетических сцен в виртуальной среде с различными параметрами сложных поверхностей рельефа. Генерация синтетических сцен должна выполняться с учетом предполагаемой специфики внешнего окружения, обусловленной решаемой задачей.

Следующий ключевой шаг предварительной фазы направлен на моделирование процессов движения формаций исследуемой модульной РС с учетом специфики ожидаемого окружения. Моделирование осуществляется на всем наборе сгенерированных синтетических сцен при варьировании формаций модульных РС. В результате проведения серии соответствующих экспериментов в виртуальной среде для каждого эксперимента может быть определен набор значений некоторого ряда параметров, включающий: классы сложной поверхности, по которой РС осуществляло движение (в соответствии с предложенной в рамках проекта классификацией); численные характеристики поверхности движения; использованная формация РС; ряд оценочных показателей качества движения текущей формации РС по данной поверхности, полученных в результате анализа данных об устойчивости, скорости и энергоэффективности движения в рамках соответствующего эксперимента.

Заключительный шаг предварительной фазы направлен на обучение некоторой модели машинного обучения решению задачи поиска оптимальной формации в зависимости от ряда входных параметров. В общем случае перечень входных параметров может включать в себя экспериментальные данные о классах и параметрах сложной поверхности, а также об уровне приоритета отдельных характеристик механического движения модульной РС при выборе оптимальной формации. В качестве оцениваемого/прогнозируемого показателя при этом выступает непосредственно формация РС. Представленная формулировка задачи поиска оптимальной формации РС поддается интерпретации в терминах задачи много-классовой классификации, где в качестве искомого класса выступает непосредственно формация РС. Таким образом, для решения данной задачи может быть использован широкий класс моделей машинного обучения, направленных на решение задачи много-классовой классификации.

По результатам обучения выбранной модели на сформированном обучающем наборе данных, полученная модель может быть использована в

процессе функционирования модульной РС в реальной среде. В рамках фазы исполнения, согласно методике, ключевой задачей является определение значений входного набора признаков, которые подаются на вход обученной модели. Признаки, связанные с требуемыми показателями качества движения РС, могут быть получены по результатам анализа требований к задаче, поставленной перед РС. Существенно более сложной задачей является извлечение из сцены значений признаков, связанных с данными о классах и параметрах исследуемой сложной поверхности. В рамках выполнения работ над проектом для определения классов и параметров исследуемой поверхности был предложен ряд методов и подходов, направленных на классификацию и оценку геометрических параметров сложных поверхностей по RGB-D изображениям, полученным бортовой сенсорикой модульной РС.

Таким образом, согласно предложенной методике, могут быть извлечены пространственные положения точек, принадлежащих исследуемой поверхности, что позволяет однозначно определить классы и иные параметры исследуемой поверхности. Передача полученной информации, а также значений признаков, связанных с требуемыми показателями качества движения РС, в качестве входных данных для модели выбора оптимальной формации модульной РС позволяет реализовать процесс определения оптимальных формаций исходя из специфики внешнего окружения.

Далее рассмотрим ключевые методы и подходы, которые были разработаны в рамках проекта для реализации основных шагов, представленной выше методики.

1.2 Классификация и анализ геометрических характеристик специфики внешнего окружения (участка местности, по которому РС предстоит осуществлять движение)

Одним ключевых решений в данном направлении выступает разработанный коллективом подход к сегментации сложных поверхностей по изображениям при перемещении модульных РС с использованием средств машинного обучения. В соответствии с результатами проведенного анализа методов и подходов для выделения на изображениях сегментов сложных поверхностей, ассоциированных с участками сложных поверхностей по которым РС потенциально может осуществлять движение, в качестве исходной модели была выбрана нейросетевая модель HRNet [26], отличительными особенностями которой являются наиболее высокая точность сегментации изображений среди рассмотренных решений, а также возможность сегментации изображений в режиме реального времени. Сеть HRNet использует структуру кодер-декодер со сложной отделимой сверткой

для решения задачи захвата более четких границ объектов путем постепенного восстановления пространственной информации. Данная сеть содержит модуль кодера, который постепенно сокращает функциональные возможности и захватывает более высокую семантическую информацию, и модуль декодера для дальнейшего уточнения результатов сегментации, в частности, вдоль границ объектов.

Нейросетевая модель HRNet основана на архитектуре сверточной нейронной сети DeepLab V3+ [27], предназначенной для многомасштабной обработки изображений с целью получения карт сегментации. Данная сеть способна кодировать многомасштабную контекстную информацию, исследуя входящие функции с фильтрами или операциями объединения с множественными скоростями и множеством эффективных полей зрения (ASPP). Помимо обычных сверток, в данной сети применяются разряженные ядра свертки (dilated convolution), позволяющие учитывать больше пространственной информации без увеличения числа параметров. В данной сети такие свертки применяются в модуле пулинга пространственных пирамид. Далее используется билинейная интерполяция, увеличивающая разрешение карты сегментации. Нейронная сеть данной архитектуры способна обрабатывать цветные трехканальные изображения цветового пространства RGB. Обработав изображение, нейронная сеть возвращает количество найденных объектов и набор массивов (классы и маски). Маски представляют собой искомый набор точек на изображении, принадлежащих объекту.

Нейросетевая модель HRNet обучена на крупномасштабном наборе данных Cityscapes [28], который направлен на решение задачи сегментации изображений. Cityscapes содержит набор видеопоследовательностей, включающих в себя уличные сцены (outdoor scenes) 50 различных городов, сделанных во все времена года, при различных погодных условиях. Поскольку нейросетевая модель HRNet изначально обучена на наборе данных, состоящем исключительно из outdoor сцен, в рамках настоящего исследования было принято решение дообучить данную модель на наборе данных, содержащем также indoor сцены с аннотированными сегментационными масками поверхностей пола офисных помещений. Процесс дообучения нейросетевой модели HRNet проводился в соответствии со сформированным и вручную аннотированным набором данных, включающим в себя 15000 цветных трехканальных изображений цветового пространства RGB. Набор данных был сформирован с использованием камеры RealSense D435 [29]. Данный набор включает в себя следующие indoor сцены: сцены с лестницами; сцены с ровными поверхностями; сцены с одиночными препятствиями; сцены с набором препятствий, включая уклоны, выбоины и другие участки местности,

где возможен поворот РС. Полученные изображения были вручную аннотированы при помощи CVAT (Computer Vision Annotation Tool) [30].

Примеры изображений из сформированного набора данных для дообучения нейросетевой модели HRNet, содержащие сцены с лестницами, сцены с ровными поверхностями, сцены с одиночным препятствием и сцены с набором препятствий, а также их сегментационные маски, представлены на рисунке 1.

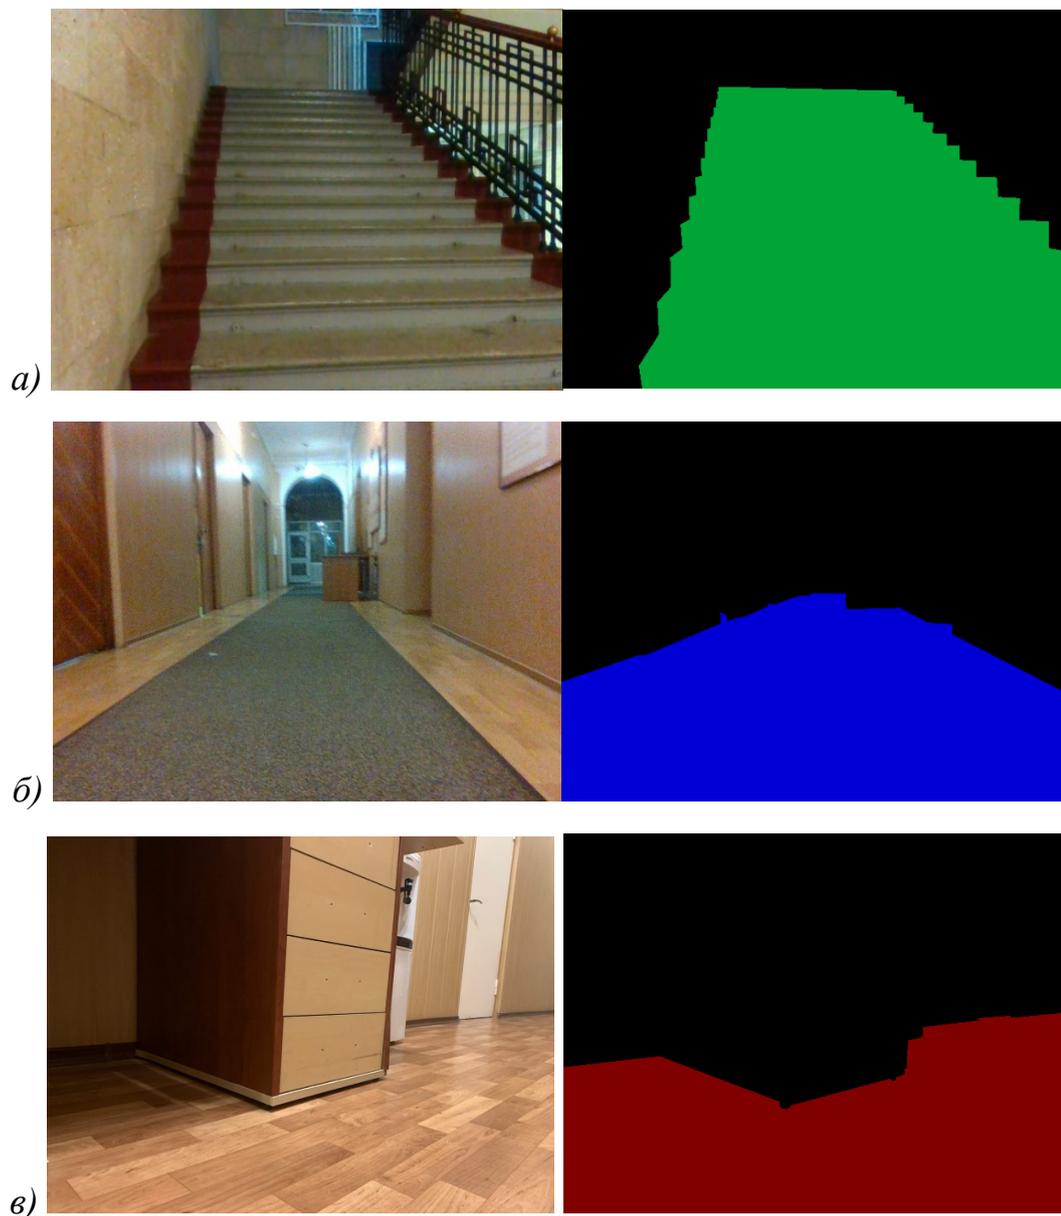




Рисунок 1 – Примеры изображений из сформированного набора данных для дообучения нейросетевой модели HRNet и их сегментационные маски: а) сцены с лестницами; б) сцены с ровными поверхностями; в) сцены с одиночным препятствием; г) сцены с набором препятствий

На рисунке 1.а представлен пример RGB-изображения сцены с лестницей, а также пример изображения, содержащего сегментационную маску лестницы, которая была получена с использованием программного обеспечения CVAT, аналогично для рис. 1.б, 1.в, 1.г. Далее перейдем к оценке реализации предложенного подхода к сегментации сложных поверхностей по изображению при перемещении модульных РС. Апробация и оценка качества работы нейросетевой модели HRNet и дообученной модели нейронной сети HRNet производилась на основании тестового набора данных, включающего в себя 3000 изображений. Данный набор данных был сформирован с использованием камеры глубины RealSense D435. Каждому изображению I_i , входящему в состав тестового набора данных, соответствует некоторый набор значений параметров P_i . Описание данных параметров представлено ниже:

- а. Тип сцены T . Включает в себя 4 различных категории сцен: сцены с лестницами – 1, сцены с ровными поверхностями – 2, сцены с одиночным препятствием – 3 и сцены с набором препятствий – 4.
- б. Уровень освещенности сцены L . Тестовый набор данных включает в себя изображения, сформированные при различных уровнях освещенности сцены: 50%, 70% и 100%, где за 100% взят нормативный уровень освещенности для офисных помещений [31].

Таким образом, тестовый набор данных был разделен на три подгруппы изображений, отличающихся по уровню освещенности сцены: 50%, 70% и 100%. Каждая выделенная подгруппа изображений включает в себя 1000 изображений, содержащих следующее количество сцен: 200 сцен с лестницей; 300 сцен с ровной поверхностью; 300 сцен с одиночным препятствием и 200 сцен с набором препятствий.

Для осуществления непосредственной оценки качества работы разработанного подхода к сегментации сложных поверхностей по изображениям при перемещении модульных РС была выбрана метрика Intersection over Union (IoU), которая определяется в соответствии с выражением:

$$\frac{1}{k} \sum_i^k \frac{i}{t_i} \cdot 100\%, \quad (1)$$

где t_i – число пикселей целевого сегмента i ; n_{ij} – число пикселей, корректно отнесенных нейросетевой моделью к целевому сегменту; k – число сегментируемых классов. Таким образом, чем выше значение метрики IoU, тем выше качество сегментации.

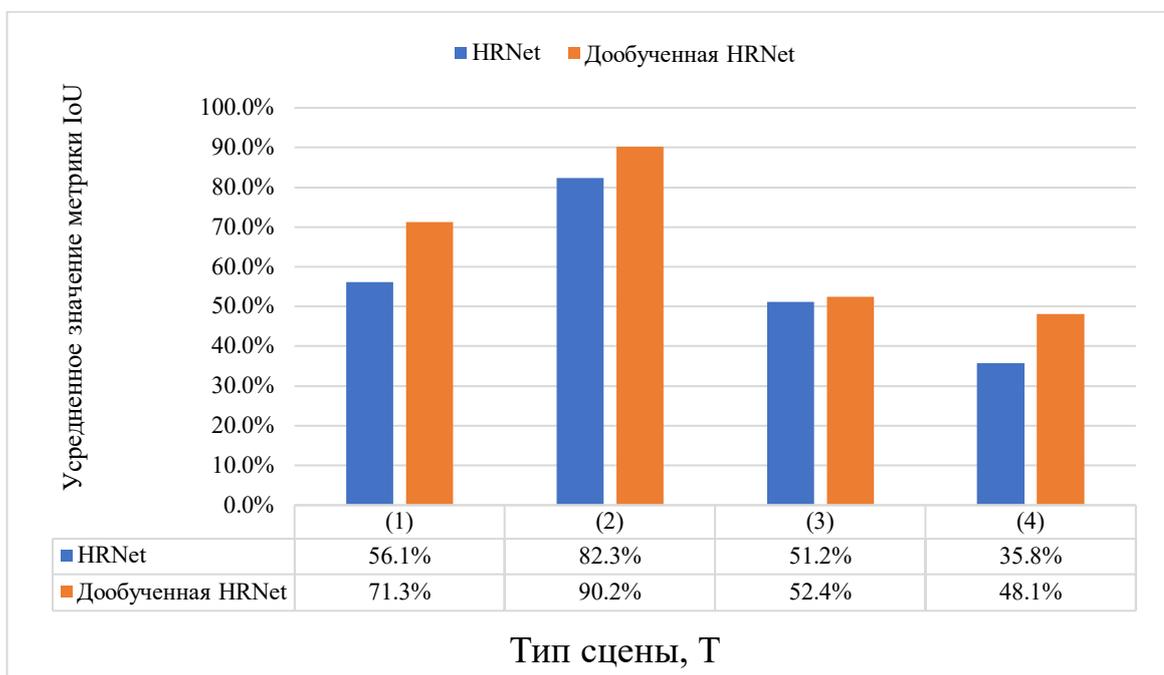


Рисунок 2 – Оценка качества работы нейросетевой модели HRNet и дообученной модели нейронной сети HRNet на подгруппе изображений из тестового набора данных с освещенностью сцены, равной 100%

На рисунке 2 представлена оценка качества работы нейросетевой модели HRNet и дообученной модели нейронной сети HRNet на подгруппе изображений из тестового набора данных с освещенностью сцены, равной 100%. Из данных, представленных на рисунке 2, можно заключить, что качество работы дообученной модели нейронной сети HRNet выше на 15,2% для категории изображений, включающей сцены с лестницами; на 12,3% для категории изображений, включающей сцены с набором препятствий и на 7,9% для категории изображений, включающей сцены с ровными поверхностями, в сравнении с решением, представленным в работе [32]. Для категории изображений, включающей сцены с одиночным препятствием, оба решения

имеют примерно равное значение метрики IoU. Стоит также отметить, что наиболее высокие результаты дообученная нейросетевая модель HRNet показала для категории изображений, включающей сцены с ровными поверхностями (IoU=90,2%), а также для категории изображений, включающей сцены с лестницами (IoU=71,3%). Несколько худшее качество сегментации сложных поверхностей разработанный подход продемонстрировал на изображениях, включающих в себя сцены с одиночным препятствием (IoU=52,4%). Наихудшие результаты сегментации сложных поверхностей в рамках данного эксперимента дообученная нейросетевая модель HRNet продемонстрировала на изображениях, включающих в себя сцены с набором препятствий (48,1%). Предполагается, что подобные результаты связаны с геометрическими особенностями препятствий на данных изображениях. Таким образом, усредненное качество работы исходной модели на данном фрагменте тестового набора данных составило 56,4%, а усредненное качество работы дообученной модели – 65,5%.

Далее перейдем к оценке влияния уровня освещенности сцены на качество работы разработанного решения.

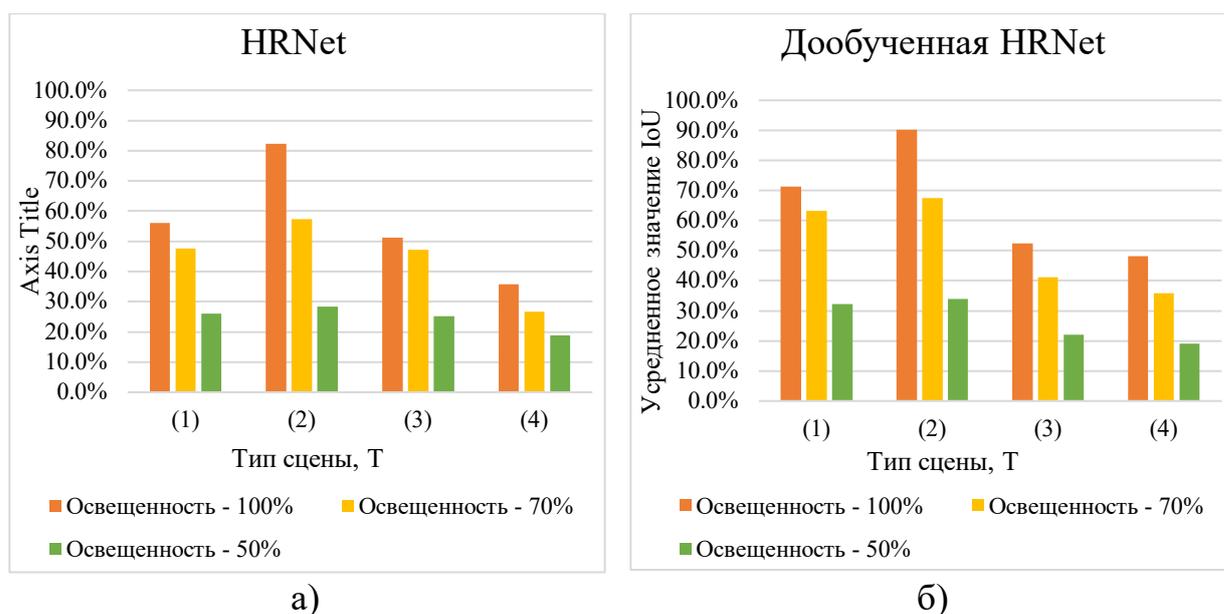


Рисунок 3 – Оценка влияния уровня освещенности сцены L на качество работы на тестовом наборе данных, включающем в себя изображения, сформированные при различных уровнях освещенности: а) нейросетевой модели HRNet б) дообученной модели нейронной сети HRNet

На рисунке 3 представлена оценка качества работы нейросетевой модели HRNet (рисунок 3.а) и дообученной модели нейронной сети HRNet (рисунок 3.б) на тестовом наборе данных, включающем в себя изображения, сформированные при различных уровнях освещенности. Из данных графиков можно сделать вывод о том, что независимо от типа исследуемой сцены и

уровня ее освещенности, наилучшие усредненные результаты демонстрирует дообученная модель нейронной сети HRNet. Усредненные по типам сцен значения метрики IoU на изображениях с уровнями освещенности 100% и 70% для нейросетевой модели HRNet равны 56,4% и 44,7% соответственно. Для дообученной модели нейронной сети HRNet усредненные по типам сцен значения метрики IoU на изображениях с уровнями освещенности 100% и 70% составили 65,5% и 52% соответственно. Дообученная нейросетевая модель HRNet показывает существенно более высокие результаты в условиях хорошей освещенности, однако этот эффект становится слабее при низкой освещенности сцен. Для нейросетевой модели HRNet усредненное по типам сцен значение метрики IoU для изображений с уровнем освещенности 50% равно 24,6%, а для дообученной модели нейронной сети HRNet – 26,8%.

Таким образом, разработанный подход к сегментации сложных поверхностей по изображению, основанный на дообучении нейросетевой модели HRNet, позволило существенно повысить качество решения задачи сегментации сложных поверхностей и тем самым, обеспечить получение качественных входных данных для анализа характеристик сегментированных поверхностей.

В рамках дальнейших исследований по данному направлению научным коллективом был разработан подход к классификации и оценке параметров сложных поверхностей по RGB-D изображениям. Предложенный подход 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 ранее разработанного подхода, основанного на использовании дообученной нейросетевой модели HRNet;
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.

Как можно заметить, предлагаемый подход содержит три ключевых этапа, каждый из которых направлен на решение отдельной группы подзадач. Рассмотрим каждый из этапов предложенного подхода более детально.

Описание первого этапа. 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 со направлена 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_{pix_x} и Img_{pix_y} соответственно. Для каждого пикселя p_i на данном изображении с индексами по горизонтальной и вертикальной осям i_{pix_x} и i_{pix_y} соответственно вычислим угловое отклонение:

$$ang_{x_{p_i}} = \left(i_{pix_x} - \frac{img_{pix_x}}{2} \right) \cdot \frac{Alpha}{img_{pix_x}}, \quad (2)$$

где $ang_{x_{p_i}}$ – угловое отклонение для пикселя p_i по оси x ; $ang_{y_{p_i}}$ – угловое отклонение для пикселя p_i по оси y ; $Alpha^\circ$ – угол обзора камеры по горизонтальной оси изображения (оси x); $Beta^\circ$ – 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 следующим образом:

$$\left\{ \begin{array}{l} R_i = \frac{\mathbf{r}_i}{|\mathbf{r}_i|} \cdot D_i \\ r = \left(\text{tg}(ang_{x_{p_i}}); \text{tg}(ang_{y_{p_i}}); 1 \right) \end{array} \right., \quad (3)$$

где \mathbf{r} – 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:

$$P_i^A = C^A + R_i^A \quad (4)$$

где C^A – вектор, характеризующий пространственное положение фиксирующей видеокамеры, отложенный в глобальной системе отсчета, R_i^A – вектор, характеризующий положение пространственного участка сцены, охватываемого пикселем p_i в глобальной системе отсчета.

На следующем этапе 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 искомым набор пикселей изображения, принадлежащих исследуемому участку поверхности. Таким образом, зная целевой сегмент изображения, связанный с исследуемой поверхностью, представляется возможным определить множество точек P_i , принадлежащих исследуемой сложной поверхности:

$$P_i = (x_i, y_i, z_i). \quad (5)$$

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

$$Surf = \{P_i | i = 1, \dots, N\}, \quad (6)$$

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

Описание второго этапа. 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:

$$Ax + By + Cz + D = 0; x, y, z \in R, \quad (7)$$

где A, B, C, D – неизвестные параметры. Поиск значений данных параметров

может быть представлен как задача параметрической оптимизации с ограничениями:

$$\frac{\sum_{i=1}^N \frac{|A^* x_i + B^* y_i + C^* z_i + D|}{\sqrt{A^2 + B^2 + C^2}}}{N} \xrightarrow{A, B, C, D \in R} \min (2). \quad (8)$$

Таким образом, требуется определить такие значения параметров A, B, C, D , что при минимизации выражения (8) одновременно будет оставаться справедливым уравнение (7). Для решения оптимизационной задачи подобного рода может быть использован широкий спектр известных методов численной оптимизации, а также методов оптимизации на основе генетических алгоритмов. Полученное уравнение плоскости (7) 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 следующие выражения:

$$\begin{aligned} P_1 : & \begin{cases} \max(x(P_i) | P_i \in Surf) = x(P_1) \\ \max(y(P_i) | P_i \in Surf) = y(P_1) \end{cases} \\ P_2 : & \begin{cases} \max(x(P_i) | P_i \in Surf) = x(P_2) \\ \min(y(P_i) | P_i \in Surf) = y(P_2) \end{cases} \\ P_3 : & \begin{cases} \min(x(P_i) | P_i \in Surf) = x(P_3) \\ \max(y(P_i) | P_i \in Surf) = y(P_3) \end{cases} \\ P_4 : & \begin{cases} \min(x(P_i) | P_i \in Surf) = x(P_4) \\ \min(y(P_i) | P_i \in Surf) = y(P_4) \end{cases} \end{aligned} \quad (9)$$

После того, как были определены точки P_1, P_2, P_3, P_4 . Осуществляется 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 осуществляется исследование четырех отрезков: $L_1 = [P_c; P_1]$, $L_2 = [P_c; P_2]$, $L_3 = [P_c; P_3]$, $L_4 = [P_c; P_4]$. Каждый рассматриваемый отрезок L_j разделяется на K участков равной длины. После чего для каждого участка L_{jk} осуществляется расчет расстояния 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 О определяется в соответствии со следующим выражением:

$$\frac{|A * x(P_{jk}) + B * y(P_{jk}) + C * z(P_{jk}) + D|}{\sqrt{A^2 + B^2 + C^2}} \quad (10)$$

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

Описание третьего этапа. При оценке типов поверхностей с точки зрения их геометрических характеристик может быть предложено множество вариантов классификации типов поверхностей по различным наборам критериев. В рамках данного проекта было принято решение использовать фасетный метод классификации. По результатам предварительного анализа были выделены следующие ключевые классификации сложных поверхностей: по углу наклона поверхности, по степени изменчивости высот. Рассмотрим каждый вариант классификации более подробно.

С точки зрения угла наклона исследуемого участка поверхности для формирования непересекающихся классификационных группировок была предложена следующая иерархическая классификация:

1. Поверхности с условно постоянным наклоном;
 - а. Горизонтальные поверхности;
 - б. Наклонные поверхности;
2. Поверхности с переменным наклоном;

На основании полученных на предыдущем этапе наборов дискретных данных могут быть построены зависимости между расстояниями от точки P_c в направлениях P_1, P_2, P_3, P_4 и соответствующими расстояниями до плоскости О. Полученные зависимости могут быть представлены в следующем виде:

$$d_{jk} = f_j(|P_{jk} - P_c|), P_{jk} \in L_j \quad (11)$$

Каждая полученная зависимость f_j ($j=1, \dots, 4$) может быть аппроксимирована линейной функцией вида:

$$d_{jk} = a_j \cdot |P_{jk} - P_c| + b_j \quad (12)$$

Коэффициенты a_j, b_j при аппроксимирующих функциях могут быть найдены с использованием метода наименьших квадратов. На основе значений

данных коэффициентов может быть сделан однозначный вывод о классификационной подгруппе, к которой относится исследуемый участок сложной поверхности:

1. Если для всех зависимостей f_j коэффициент a_j линейной аппроксимирующей функции по модулю меньше, чем некоторый ε_1 , то исследуемый участок сложной поверхности относится к типу поверхностей с условно постоянным наклоном.
 - a. Если при этом параметры A , в плоскости O по модулю меньше, чем некоторый ε_2 , то исследуемый участок сложной поверхности может быть отнесен к классу горизонтальных;
 - b. В противном случае исследуемый участок сложной поверхности относится к классу наклонных.
2. В случае, если хотя бы для одной зависимости f_j коэффициент a_j соответствующей линейной аппроксимирующей функции по модулю превосходит некоторый ε_1 , то исследуемый участок сложной поверхности однозначно может быть отнесен к классу поверхностей с переменным наклоном.

При оценке типов сложных поверхностей с точки зрения изменчивости высот для формирования непересекающихся классификационных группировок была предложена следующая классификация:

1. Ровная поверхность;
2. Поверхность с малыми перепадами высот;
3. Поверхность со значительными перепадами высот.

Для отнесения некоторого исследуемого участка поверхности к одной из представленных выше классификационных групп могут быть использованы результаты, полученные в процессе анализа наклона исследуемого участка поверхности.

Значение выражения (2), полученное в процессе оценки параметров A , B , C , D аппроксимирующей плоскости O , характеризует усредненное расстояние между точками, принадлежащими исследуемому участку поверхности **Surf**, и данной плоскостью. На основе значений данного выражения (2) может быть сделан однозначный вывод о классификационной подгруппе, к которой относится исследуемый участок сложной поверхности:

1. В случае, если результирующее значение выражения (2) меньше, чем некоторый α_1 , то исследуемый участок сложной поверхности может быть отнесен к классу ровных;
2. В случае, если результирующее значение выражения (2) больше, чем

некоторый α_1 , но не превосходит некоторый α_2 , то исследуемый участок сложной поверхности может быть отнесен к классу поверхностей с малыми перепадами высот;

3. В случае, если результирующее значение выражения (2) превосходит α_2 , то исследуемый участок сложной поверхности может однозначно быть отнесен к классу поверхностей со значительными перепадами высот;

Предложенная классификация сложных поверхностей, по которым РС предстоит осуществлять движение, нацелена на обеспечение максимального уровня обобщения и универсальности. Посредством данной классификации могут быть описаны различные типы сложных поверхностей, такие как: лестницы, труднопроходимые местности, поверхности предполагаемого движения РС со значительным количеством препятствий и др. При этом предложенная классификация позволяет унифицировать признаковое описание сложных поверхностей с сохранением в каждом конкретном случае данных о специфических особенностях исследуемой поверхности. В частности, в рамках предложенной классификации лестничный марш будет классифицирован как наклонная поверхность со значительными перепадами высот. Дополняя классификацию данными о протяженности поверхности, об ориентации аппроксимирующей плоскости, а также о средней глубине перепадов высот, можно сохранить большую часть информации о структуре сложной поверхности, без введения для каждой семантической категории поверхностей специфических характеристик и параметров.

Далее перейдем к оценке реализации предложенного подхода к классификации и оценке параметров сложных поверхностей по RGB-D изображениям. Оценка качества разработанного подхода к классификации и оценке параметров сложных поверхностей производилась на основании 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 осуществлять движение. Примеры изображений из тестового набора данных представлены на рисунке 4.

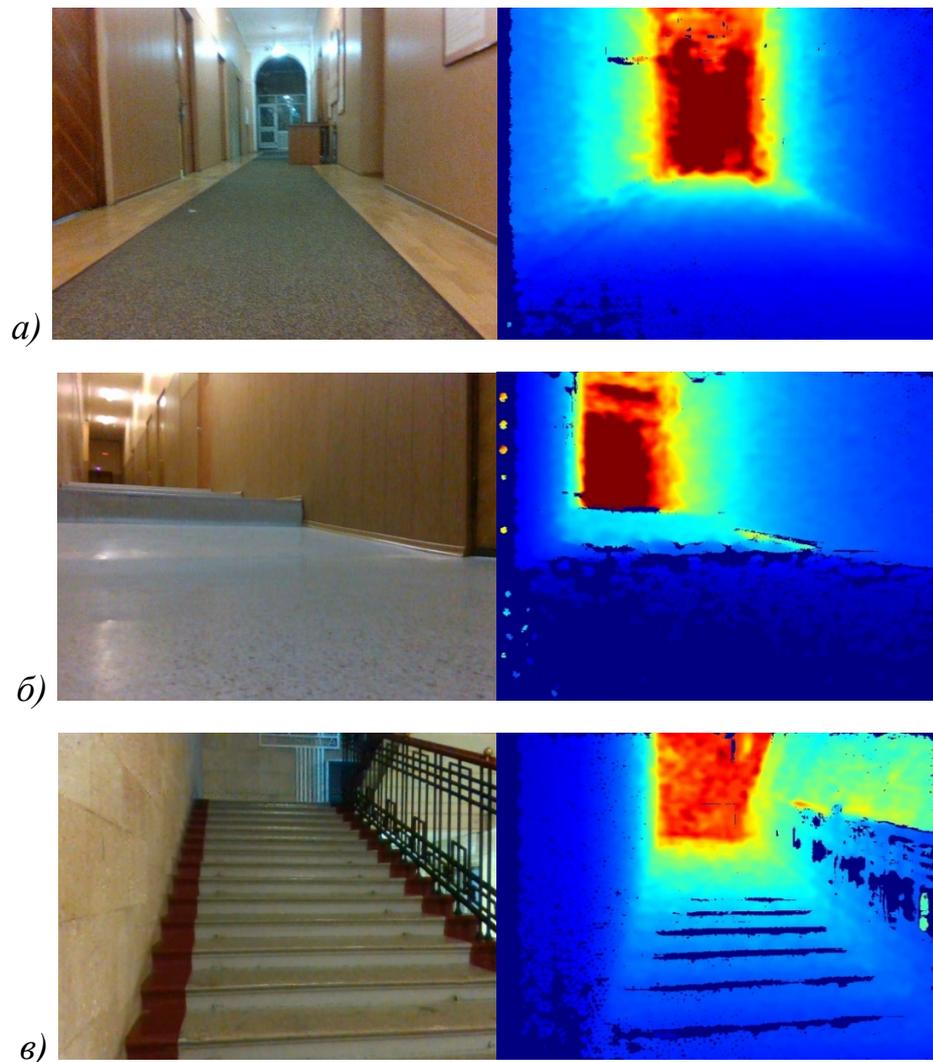


Рисунок 4 – Примеры RGB изображений и соответствующих им карт глубины из тестового набора данных для оценки качества разработанного подхода: а) сцены с ровной поверхностью; б) сцены с поверхностью с малыми перепадами высот; в) сцены с поверхностью со значительными перепадами высот

На рисунке 4 представлены примеры RGB изображений из тестового набора данных и соответствующих данным изображениям карт глубины, полученных с использованием камеры глубины Intel Real Sense D435.

Каждому участку сложной поверхности \mathbf{Surf}_i на каждом изображении \mathbf{I}_i , входящему в состав тестового набора данных, соответствует некоторый набор значений параметров \mathbf{P}_i . Описание данных параметров представлено ниже:

- а. 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.
- б. 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:

Для тестового набора данных **Surf** на основе анализа результатов применения разработанного подхода к классификации сложных поверхностей были сформированы матрицы ошибок классификации M_{U_i} и M_{V_j} , 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 (табл. 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_{U_i} 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_{V_j} и ячеек TP_j , FP_j , FN_j и TN_j соответственно.

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

$$A = \frac{TP + TN}{TP + FP + FN + TN}; \quad (13)$$

$$R_{ij} = \frac{TP}{TP + FN}; \quad (14)$$

$$Pr_{ij} = \frac{TP}{TP + FP}. \quad (15)$$

На рисунке 5 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 .

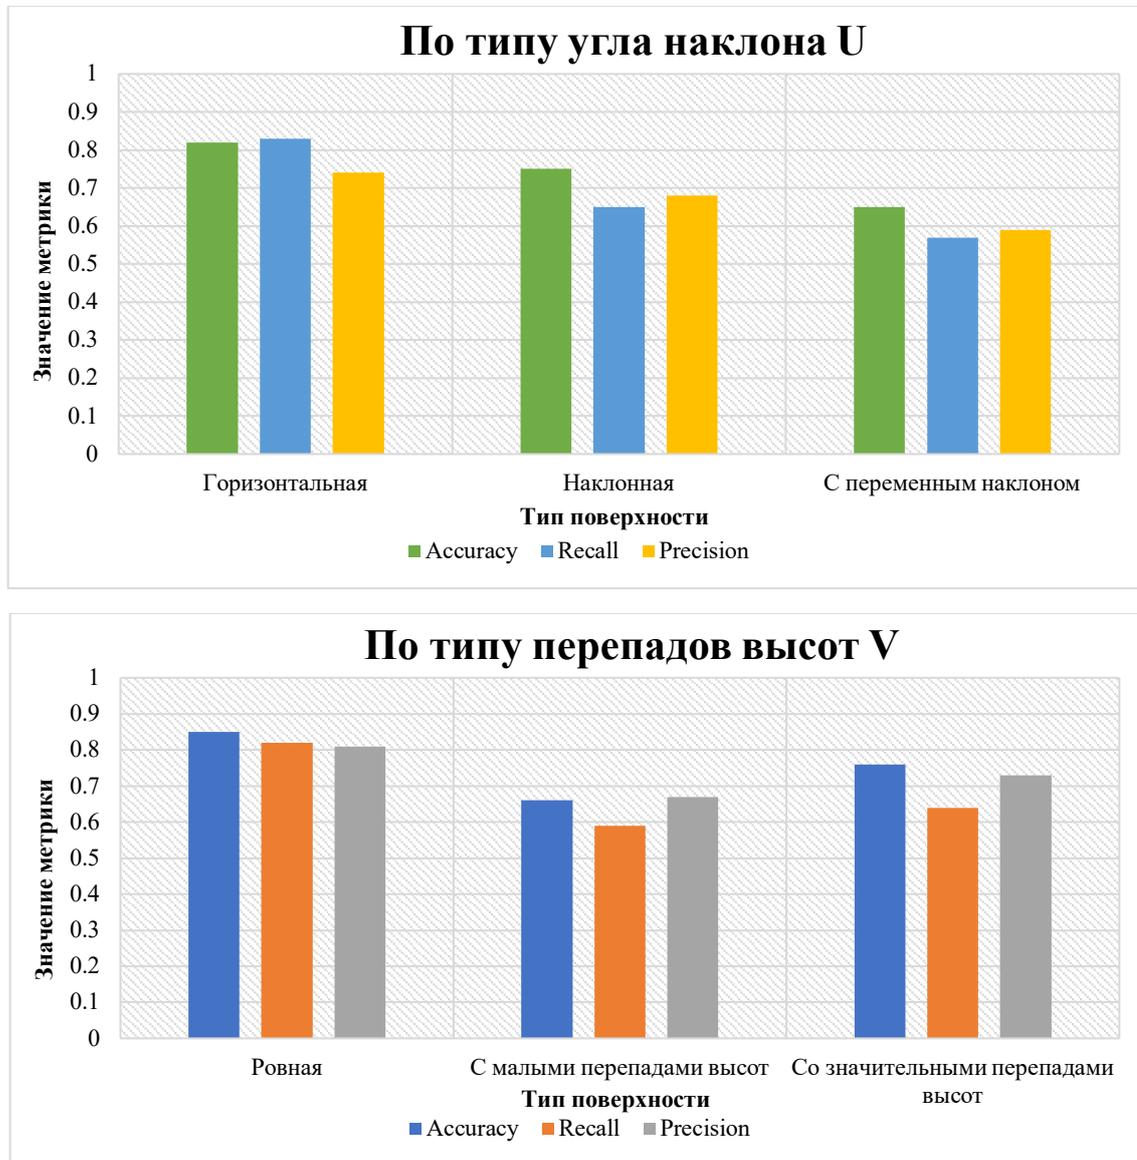


Рисунок 5 – Диаграммы полученных значений показателей A, R, Pr для каждого варианта классификации сложных поверхностей: по типу угла наклона U и по типу перепадов высот V

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 (табл. 2). Классификация поверхности считалось успешной в случае, если поверхность была корректно классифицирована в рамках обеих классификационных групп.

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

	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 в таблице 2 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 научным коллективом решение позволяет успешно классифицировать различные поверхности по типу угла наклона и по типу перепадов высот, а также осуществлять оценку геометрических параметров данных поверхностей по RGB-D изображениям.

1.3 Генерация элементов внешнего окружения (участков местности, по которым РС предстоит осуществлять движение) с заданными параметрами в виртуальной среде

Следующее ключевое решение, необходимое для реализации предложенной коллективом методики выбора оптимальных формаций модульных РС, исходя из специфики внешнего окружения, посвящено генерации в виртуальной среде множества синтетических сцен, включающих сложные поверхности с заданными параметрами. В данном направлении научным коллективом была разработана группа алгоритмов автоматической генерации элементов внешнего окружения (сложных поверхностей) с заданными характеристическими параметрами. Соответствующие алгоритмы автоматической генерации поверхностей были разработаны в соответствии с выделенными в ходе выполнения проекта «прикладными» типами поверхностей. В перечень прикладных типов поверхностей в рамках проекта были включены: горизонтальные плоские поверхности; плоские поверхности с произвольным наклоном; дугообразные поверхности; лестницы. Ниже представлена матрица соответствия между прикладными типами поверхностей и классификационными группами, к которым данные поверхности потенциально могут быть отнесены в зависимости от значений параметров конкретной поверхности (таблица 3). 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 3 – Матрица 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. Рассмотренные 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, 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 . Численный параметр, характеризующий степень изменчивости высот в рамках генерируемой поверхности.

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

1. В рамках используемой среды виртуального моделирование 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:

$$D = -AP_{1x} - BP_{1y} - CP_{1z}. \quad (16)$$

3. Определим дополнительную систему отсчета, связанную с генерируемой поверхностью следующим образом: начало системы отсчета 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:

$$P_i^0 = T_{Surf}^0 * P_i^{Surf}. \quad (17)$$

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 $n \times m$. 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 данной точки смещается в СО поверхности на величину, определяемую в соответствии со следующим выражением:

$$offset(P_{ki}) = Rand(N(\mu = 0; \sigma^2 = 1 + V)) * D(P_{ki}), \quad (18)$$

Первый компонент 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. Требуемый тип поверхности;
2. Классификационные группы генерируемой поверхности;
3. Базовые параметры поверхности: a , b . Параметры a , b – параметры цилиндрической поверхности с образующими, параллельными оси OZ , описываемой уравнением:

$$\frac{x^2}{a^2} + \frac{y^2}{b^2} = 1. \quad (19)$$

4. Параметр протяженности поверхности – l . Характеризует протяженность цилиндра вдоль оси OZ .
5. Уровень отсечения поверхности – Cut . Принимает значения в диапазоне от 0 до a и определяет какая доля исходной фигуры будет использована в процессе генерации поверхности.

6. Ориентация генерируемой поверхности относительно базовой системы отсчета – rot . Задаёт матрицу вращения (в CO , связанной с исходной фигурой), применение которой к исходной поверхности, позволяет достичь нужной ориентации поверхности в базовой CO .
7. Коэффициент перепада высот – V . Численный параметр, характеризующий степень изменчивости высот в рамках генерируемой поверхности.

Алгоритм генерации поверхностей №2 включается 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 следующем 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 CO , связанной с прообразом поверхности). Таким образом, достигается корректная ориентация прообраза поверхности в рамках базовой CO .
5. Далее из набора точек $Surf_P$ исключаются такие точки P_i , для которых в базовой системе отсчета справедливо выражение: $P_{iz} < 0$. Таким образом, 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: направление лестницы d – принимает значение 1 для лестницы, направленной вверх, и -1 для лестницы, направленной вниз; ширина лестницы – w ; число степеней – n ; высота ступеней – h ; глубина ступеней – D ; ориентация генерируемой поверхности относительно базовой системы отсчета (rot) – задает матрицу вращения (в CO , связанной с исходной фигурой), применение которой к исходной поверхности, позволяет достичь нужной 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 в дальнейшем были использованы сбора данных в отношении качественных характеристик механического движения формаций модульных РС по сложным поверхностям различного типа.

1.4 Метод оценки оптимальности характеристик механического движения формаций модульных РС по различным участкам рельефа помещений, представленным сложными поверхностями

В соответствии с предложенной в рамках проекта методикой, для формирования обучающего набора данных для целевой модели машинного обучения необходимо на базе набора сцен, полученных с применением разработанных алгоритмов автоматической генерации сложных поверхностей различного типа, провести моделирование процессов движения различных формаций исследуемой модульной РС с параллельной оценкой оптимальности характеристик механического движения соответствующих формаций по сгенерированным участкам местности. Для реализации данного шага в ходе выполнения работ над проектом, научным коллективом был предложен метод оценки оптимальности характеристик механического движения формаций модульных РС по различным участкам рельефа помещений, представленным сложными поверхностями. Разработанный метод ориентирован на использование в рамках сред виртуального моделирования, которые позволяют получить большой объем сопутствующей информации о фактических характеристиках движения РС в процессе симуляции.

Базовый сценарий применения данного решения предполагает, что некоторая модель модульной РС в заданной формации с числом модулей N осуществляет движение по некоторому участку рельефа, представленному сложной поверхностью. 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. При этом скорость, а также ускорение РС определяются относительно центра тяжести формации.

В качестве основных факторов, характеризующих оптимальность механического движения РС, в рамках предложенного метода рассматриваются параметры, используемые при управлении движением РС с целью поддержания заданной траектории, а именно: 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; средняя скорость

движения по маршруту. Рассмотрим алгоритмы оценки влияния приведенных выше факторов более подробно.

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_{t_1} становится больше некоторого порогового значения D_{\max} , то считается, что имеет место факт отклонения РС 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 завершении процесса движения РС, итоговый вклад рассматриваемого фактора в результирующую оценку оптимальности движения РС может быть определен в соответствии со следующим выражением:

$$Tr = \frac{\sum_{i=1}^n (L_{ti} + |R_{ti} - L_{ti}|)}{L_{base}} \cdot \frac{\sum_{i=1}^n D_{ti}}{n}, \quad (20)$$

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. Соответствующий 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 в отношении 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 считается, что на данном участке траектории имело место существенное отклонение скорости движения РС от заданного целевого значения.
4. Итоговый вклад рассматриваемого фактора в результирующую оценку оптимальности движения РС может быть определен в соответствии со следующим выражением:

$$V_{tr} = \frac{\sum_{i=1}^m |V - v_i|}{m} \quad ||V - v_i| > v_{\max}, \quad (21)$$

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 большее 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 относительно центра тяжести, 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 могут быть определены в соответствии со следующим выражением:

$$T_j = t_0 + \frac{T}{m} \cdot j, \quad (22)$$

где T – общее время движения РС по заданной траектории; t_0 – момент начала движения РС; 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 следующему выражению:

$$A_j = \frac{\sum_{k=1}^K |a_k| : T_j \leq t_k \leq T_j + \frac{T}{m}}{K}, \quad (23)$$

где K – число значений мгновенного ускорения РС, полученных в промежутке между моментами времени T_j и $\left(T_j + \frac{T}{m}\right)$ 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 имели место 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 со следующим выражением:

$$A_r = \frac{\sum_{j=1}^J A_j}{J} | A_j > A_{\max}. \quad (24)$$

Согласно представленным выше алгоритмам, результирующая оценка оптимальности движения РС может быть получена следующим образом:

$$Val = \frac{s \cdot Tr + v \cdot V_r + a \cdot A_r}{t \cdot V}, \quad (25)$$

где s , v , a , t – вещественные коэффициенты, характеризующие уровень приоритета отдельных характеристик механического движения модульной РС в процессе проведения оценки. Соответственно, чем меньше значение полученной величины, 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. Далее перейдем к экспериментальному тестированию предложенного метода оценки

оптимальности характеристик механического движения формаций модульных РС по различным участкам рельефа помещений, представленным сложными поверхностями.

Тестирование разработанного метода оценки оптимальности характеристик механического движения формаций модульных РС по различным поверхностям проводилось в среде виртуального моделирования Gazebo. В рамках проекта в перечень рассматриваемых типов поверхностей были включены: горизонтальные плоские поверхности; плоские поверхности с произвольным наклоном; дугообразные поверхности; лестницы. В рамках выбранной виртуальной среды моделирования осуществлялась генерация поверхностей указанных типов с отличающимися значениями таких параметров как протяженность, ширина, наклон и степень перепада высот. Всего для целей настоящего эксперимента был подготовлен набор *Surf*, включающий 590 экземпляров поверхностей, распределение поверхностей по прикладным типам приведено в таблице 4.

Таблица 4 – Распределение поверхностей из набора *Surf* по прикладным типам

Тип поверхности	Количество, шт.
Горизонтальные плоские поверхности	150
Плоские поверхности с произвольным наклоном	170
Дугообразные поверхности	170
Лестницы	100
Всего	590

В качестве формаций модульных РС в рамках эксперимента были задействованы следующие формации с различным числом модулей: квадропод (6, 10), паук (11, 15), змея (6, 9, 15). Указанный набор формаций был смоделирован в виртуальной среде, а соответствующие модели осуществляли независимое прохождение маршрутов по сгенерированным сложным поверхностям. В рамках каждой из симуляций указывались начальная и конечная точка маршрута движения РС, а также целевая траектория движения РС. Таким образом, всего было проведено 4130 симуляций движения модульных РС в различных формациях по сгенерированным поверхностям, в рамках каждой из которых с использованием разработанного метода производилась оценка оптимальности характеристик механического движения заданной формации f_j по i -й моделируемой поверхности из набора *Surf*.

По результатам выполнения соответствующей группы симуляций, в отношении каждой поверхности *Surf_i* из набора *Surf* на основании полученных оценок оптимальности механического движения, была определена оптимальная формация РС для движения по данной поверхности, прочие

формации также были проранжированы, исходя из полученных ими оценок. Ранги задействованных формаций, усредненные по типам сгенерированных поверхностей, представлены ниже в таблице 5.

Таблица 5 – Ранги рассматриваемых формаций РС, усредненные по типам сгенерированных поверхностей

Тип поверхности	Формация РС						
	f_1	f_2	f_3	f_4	f_5	f_6	f_7
	Квадропод (6)	Квадропод (10)	Паук (11)	Паук (15)	Змея (6)	Змея (9)	Змея (15)
Горизонтальные плоские поверхности	4,43	2,39	2,87	1,81	6,91	5,84	3,74
Плоские поверхности с произвольным наклоном	2,32	3,15	2,13	2,49	6,78	6,17	4,95
Дугообразные поверхности	4,82	1,73	4,1	1,96	6,74	5,36	3,27
Лестницы	5,12	2,17	5,78	3,74	6,56	2,98	1,63

Согласно представленным в таблице 5 результатам, можно заключить, что для большинства типов поверхностей с использованием предложенного метода удалось обеспечить однозначное ранжирование формаций РС с точки зрения качественных характеристик их механического движения по соответствующим типам поверхностей. Так при использовании разработанного метода в случае горизонтальных плоских поверхностей, в качестве оптимальной чаще всего выделялась формация паук (15), в случае дугообразных – формация квадропод (10), а в случае поверхностей лестничного типа оптимальной наиболее часто оказывалась формация змея (15). В то же время для поверхностей с произвольным наклоном однозначного фаворита с использованием разработанного метода выявить не удалось. В зависимости от конкретных параметров поверхности оптимальной формацией, согласно оценкам оптимальности, полученным с использованием предложенного решения, становились следующие: паук (11, 15) и квадропод (6).

В рамках следующего этапа эксперимента была произведена верификация оценок оптимальности, полученных с использованием разработанного метода, за счет привлечения экспертной группы. В целях проведения экспертной оценки результатов, полученных с использованием разработанного решения, был определен ряд порядковых критериев для реализации процедуры оценки:

1. Точность соблюдения траектории при движении формации по маршруту;
2. Устойчивость и плавность движения формации по маршруту;
3. Скорость движения по маршруту;

Для каждого из представленных выше критериев была задана порядковая шкала следующего вида: 1 – крайне низкое; 2 – низкое; 3 – среднее; 4 – высокое; 5 – крайне высокое. В совокупности данные критерии позволяют сделать однозначный вывод о качестве механического движения формации модульного РС по заданной поверхности.

В проведении экспертной оценки принимало участие 5 независимых отраслевых экспертов, имеющих прикладной опыт в области модульной робототехники и алгоритмов управления движением РС. Каждый из экспертов проводил независимую оценку полного набора симуляций по представленным выше критериям с последующим ранжированием формаций с точки зрения оптимальности характеристик их механического движения на конкретной поверхности. Далее, ранг каждой из формаций на данной поверхности подвергался усреднению в разрезе экспертов. Таким образом, были сформированы результирующие экспертные оценки качества механического движения формаций РС по каждой поверхности $Surf_i$ из набора $Surf$. Ранги задействованных формаций, усредненные по типам сгенерированных поверхностей, представлены ниже в таблице 6.

Таблица 6 – Ранги рассматриваемых формаций РС, усредненные по типам сгенерированных поверхностей

Тип поверхности	Формация РС						
	f1	f2	f3	f4	f5	f6	f7
	Квадропод (5)	Квадропод (9)	Паук (10)	Паук (18)	Змея (6)	Змея (9)	Змея (15)
Горизонтальные плоские поверхности	4,22	2,47	3,03	1,76	6,8	6,01	3,71
Плоские поверхности с произвольным наклоном	2,54	2,98	2,49	2,35	6,48	6,53	4,62
Дугообразные поверхности	4,66	1,85	4,62	1,77	6,04	5,66	3,39
Лестницы	5,42	1,95	6,07	3,39	6,03	3,31	1,83

Данные, представленные в таблице 6, позволяют заключить, что в целом результаты экспертной оценки совпадают с результатами оценки оптимальности движения формаций посредством разработанного метода. В

ряде случаев наблюдаются отклонения итоговых рангов формаций в случае тех или иных типов поверхностей, тем не менее, указанные различия в рангах в большинстве своем ограничиваются сменой позиций между формациями, находившимися на смежных рангах в таблице 5, в частности, в случае дугообразных поверхностей сменился взаимный приоритет двух наиболее оптимальных формаций, а в случае поверхностей типа лестница – двух наименее оптимальных. В целом, во всех случаях формации, получившие высокий ранг при применении предложенного метода, также были высоко оценены экспертной группой и наоборот, что позволяет говорить о достаточно высокой эффективности предложенного решения.

На заключительном этапе эксперимента для всех поверхностей $Surf_i$ было определено относительное отклонение результатов ранжирования с использованием разработанного решения (R) и с использованием экспертной группы (E), полученное в соответствии со следующим выражением:

$$\sigma_i = \frac{\sum_{j=1}^{J=7} |R(f_j, Surf_i) - E(f_j, Surf_i)|}{J}. \quad (26)$$

Полученные результаты были усреднены по типам поверхностей и представлены ниже в таблице 7.

Таблица 7 – Усредненное по типам поверхностей относительное отклонение рангов рассматриваемых формаций РС, полученных с использованием разработанного решения и в рамках экспертной оценки

Тип поверхности	Отклонение
Горизонтальные плоские поверхности	0,116
Плоские поверхности с произвольным наклоном	0,269
Дугообразные поверхности	0,301
Лестницы	0,317

Результаты, представленные в таблице 7, демонстрируют, что относительное отклонение результатов работы предложенного метода от оценок, предоставленных экспертной группой, имеет достаточно низкое значение для всех типов поверхностей. При этом значение отклонения у горизонтальных поверхностей существенно ниже, чем для других типов поверхностей, что можно объяснить более простой структурой данных поверхностей. Уровень отклонения для прочих типов поверхностей не превышает 0,32, что позволяет говорить о высоком прикладном потенциале предложенного метода при решении задач по оценке оптимальности характеристик механического движения формаций модульных РС.

Таким образом, в рамках данной проекта был предложен и успешно апробирован метод оценки оптимальности характеристик механического движения формаций модульных РС по различным участкам рельефа помещений, представленным сложными поверхностями.

1.5 Метод определения оптимальной формации модульной РС из конечного множества формаций, исходя из характеристик отдельных участков рельефа помещений, по которым модульной РС предстоит осуществлять движение

В соответствии с предложенной на предыдущих этапах проекта методикой была разработана модель машинного обучения, осуществляющая определение оптимальной формации для заданной модульной РС, исходя из характеристик участка помещения, по которому данной РС предстоит осуществлять движение. Предложенная модель выступает реализацией для соответствующего метода определения оптимальной формации модульных РС. Рассмотрим разработанную модель более подробно. В процессе исследований был определен фиксированный набор признаков, выступающих в качестве входных данных для разработанной модели определения оптимальной формации модульных РС. Указанный набор включает в себя следующие основные признаки:

- Число модульных единиц n , входящих в состав рассматриваемой РС;
- Активная формация модульной РС – m (интерпретируется как признак целочисленного типа);
- Сложность реконфигурации в прочие доступные формации для рассматриваемой модульной РС;
- Набор параметров A, B, C, D , описывающих оптимальный вариант плоскостной аппроксимации пространственного распределения точек, принадлежащих участку помещения, по которому РС предстоит осуществлять движение;
- Набор вещественных параметров $d1$ и $d2$, характеризующих протяженность участка помещения, по которому РС предстоит осуществлять движение;
- Результаты классификации участка помещения, по которому РС предстоит осуществлять движение с точки зрения угла наклона (интерпретируется как признак целочисленного типа);
- Результаты классификации участка помещения, по которому РС предстоит осуществлять движение с точки зрения степени изменчивости высот (интерпретируется как признак целочисленного типа);

- Набор признаков s, v, a, t , характеризующий уровень приоритета отдельных характеристик механического движения модульной РС при выборе оптимальной формации (интерпретируется как набор показателей вещественного типа в диапазоне $[0; 1)$).

Дадим более развернутую характеристику каждому из приведенных выше признаков. Первый признак является показателем целочисленного типа и отражает число модульных единиц, входящих в состав рассматриваемой РС. Предполагается, что при осуществлении движения по участкам местности, представленным сложными поверхностями, по результатам реконфигурации РС должны быть задействованы все доступные для системы модульные единицы. В то же время необходимо учитывать, что каждая из формаций РС имеет собственные ограничения на число модульных единиц, которые могут быть включены в ее состав. В таблице 8 представлены данные, отражающие доступные для РС формации, исходя из числа задействованных модульных единиц. Таким образом, данный показатель в определенной степени ограничивает конечное пространство решений для разрабатываемой модели поиска оптимальной формации модульной РС.

Следующим входным параметром является целочисленный показатель, отражающий текущую активную формацию модульной РС. По результатам ранее проведенного в рамках проекта анализа наиболее универсальными формациями, обеспечивающей передвижение модульной РС по различным поверхностям с препятствиями, являются шагающие формации: «квадропад» и «паук». Однако скорость передвижения при использовании данных формаций остается достаточно низкой. Поэтому, в случае необходимости движения РС по ровной поверхности с большой скоростью, следует использовать формацию «машина», а также формации «колесо» и «сфера». Если же РС необходимо преодолевать труднопроходимый участок местности, такой как труба или узкая траншея или перебраться через широкую яму, лучшим вариантом будет использование формации «змея». Таким образом, в процессе разработки модели определения оптимальной формации, был сформирован конечный набор доступных формаций РС, с каждой из которых было ассоциировано некоторое целочисленное значение: квадропад – 1; паук – 2; машина – 3; колесо – 4; сфера – 5; змея – 6.

Таблица 8 – Доступные формации для модульной РС, исходя из числа задействованных модульных единиц

Число модульных единиц (n)	Квадропад	Паук	Машина	Колесо	Сфера	Змея
3	-	-	-	-	-	+
4	-	-	-	-	-	+

5	-	-	+	-	-	+
6	+	-	-	-	-	+
7	+	-	+	+	-	+
8	+	-	-	+	+	+
9	-	-	+	+	-	+
10	+	-	-	+	+	+
11	+	+	+	+	-	+
12	+	-	-	+	-	+
13	-	-	+	+	-	+
14	+	-	-	+	-	+
15	+	+	+	+	-	+
16	+	-	-	+	+	+
17	-	-	+	+	-	+

Следующий параметр отражает сложность реконфигурации РС из текущего состояния в прочие доступные формации рассматриваемой модульной системы. Как было указано ранее, каждая из формаций РС имеет собственные ограничения на число модульных единиц, которые могут быть включены в ее состав. Кроме того, важно отметить, что процесс реконфигурации между различными формациями может существенно отличаться по числу фактических манипуляций на уровне модульных агентов и быть достаточно ресурсоемким с точки зрения временных затрат. В то же время оптимальной для перехода следует считать ту формацию, для которой достигается не только оптимизация характеристик механического движения модульной РС по заданному участку местности, но и обеспечивается минимизация совокупного времени исполнения данной миссии. Таким образом, для корректной интерпретации входных данных, в процессе разработки модели определения оптимальной формации, данный параметр интерпретируется в набор признаков следующего вида: бинарный признак, отражающий возможность реконфигурации РС в i -ю формацию; целочисленный признак, отражающий сложность реконфигурации между текущей и i -й формацией РС. В таблице 9 представлены данные в отношении сложности реконфигурации между рассматриваемыми формациями модульной РС, взятые как обратное от средней длительности процесса реконфигурации с последующим шкалированием на вещественную область $[0;1]$ с шагом 0,05.

Таблица 9 – Шкалированные оценки сложности реконфигурации между рассматриваемыми формациями модульной РС

	Квадропод	Паук	Машина	Колесо	Сфера	Змея
Квадропод	0	0,75	0,45	0,5	0,65	0,4
Паук	0,75	0	0,35	0,6	1	0,55
Машина	0,45	0,35	0	0,7	1	0,45
Колесо	0,5	0,6	0,7	0	0,4	0,15

Сфера	0,65	1	1	0,4	0	0,4
Змея	0,4	0,55	0,45	0,15	0,4	0

Далее в качестве входных данных для предлагаемой модели выступает набор параметров, характеризующих геометрические особенности сложных поверхностей, представляющих собой участки местности, по которым РС предстоит осуществлять движение. Вещественные показатели A, B, C, D , описывают оптимальный вариант плоскостной аппроксимации пространственного распределения точек такой поверхности, а параметры $d1$ и $d2$ характеризуют соответственно продольную и поперечную протяженность данного участка местности.

Следующие два признака отражают результаты классификации поверхности, по которой модульной РС предстоит осуществлять движение. В рамках предыдущих исследований было принято решение использовать фасетный метод классификации, в результате чего были выделены следующие ключевые классификации сложных поверхностей: по углу наклона поверхности, а также по степени изменчивости высот. Таким образом, каждый из указанных признаков имеет целочисленный тип и характеризует класс, присвоенный исследуемой поверхности по соответствующей классификации.

Заключительный набор признаков s, v, a, t характеризует уровень приоритета отдельных характеристик механического движения модульной РС при выборе оптимальной формации системы. В качестве таких признаков в рамках предложенной модели рассматривались: уровень приоритета минимизации отклонения РС от расчетной траектории движения – s ; уровень приоритета минимизации отклонения скорости движения РС от целевого значения в процессе движения по траектории – v ; уровень приоритета стабильности и равномерности движения РС по заданной траектории – a ; уровень приоритета минимизации общего времени движения по расчетной траектории. Указанные показатели приводятся в вещественном виде в диапазоне $[0; 1)$.

В качестве выходных данных разработанная модель машинного обучения должна возвращать идентификатор доступной формации, которая, согласно модели, является оптимальной для движения РС по рассматриваемому участку местности. Таким образом, выходные данные модели представляют собой вектор размерности $(1, M)$, где M – число рассматриваемых формаций модульных РС.

Представленная формулировка задачи поиска оптимальной формации РС поддается интерпретации в терминах задачи много-классовой классификации, где в качестве искомого класса выступает непосредственно искомая формация РС. В рамках настоящего исследования было принято решение апробировать

ряд актуальных моделей машинного обучения, ориентированных оперирование векторными данными без временной связности. В частности, были апробированы: наивный байесовский классификатор, метод ближайших соседей, классификатор на основе композиции деревьев решений с применением метода случайных подпространств, классификатор на основе случайного леса, а также многослойный перцептрон Румельхарта.

Подготовка обучающего набора данных осуществлялась на основе среды виртуального моделирования Gazebo, где с использованием разработанных на предыдущем этапе проекта алгоритмов автоматической генерации элементов внешнего окружения осуществлялась генерация различных участков местности, по которым модульная РС впоследствии выполняла движение в различных доступных ей формациях. Согласно принятой стратегии подготовки обучающего набора данных всего был сгенерирован 1 027 000 отличающихся участков местности с известными параметрами A , B , C , D , $d1$, $d2$, а также известными классами как с точки зрения угла наклона, так и с точки зрения степени изменчивости высот. Для каждого из сгенерированных участков местности была инициирована независимая симуляция, в рамках каждой из которых в качестве варьируемых параметров выступали: число модульных единиц (n), входящих в состав рассматриваемой РС; группа показателей s , v , a , t , характеризующих уровень приоритета отдельных характеристик механического движения модульной РС при выборе оптимальной формации. При этом по каждой из симуляций выполнялось от 3 до 10 итераций с различными набором значений варьируемых параметров.

На каждой из итераций в рамках заданного моделируемого окружения модульная РС последовательно осуществляла движение во всех доступных ей формациях по заданному участку местности, представленному сложной поверхностью известного вида. В процессе движения РС, с использованием разработанного ранее метода, производилась оценка оптимальности характеристик механического движения всех доступных формаций данной РС по заданному участку рельефа помещений, при этом показатели s , v , a , t использовались в качестве весовых коэффициентов при соответствующих компонентах результирующего оценочного выражения. На основании оценок, полученных по всем доступным формациям модульной РС, на каждой из итераций определялась «оптимальная» формация, продемонстрировавшая наиболее высокие показатели качества механического движения. После чего на основании полного набора параметров моделирования, а также данных в отношении оптимальной формации осуществлялось формирование новой записи в обучающем наборе данных. По завершении симуляций для всех

сгенерированных участков местности, конечный размер обучающего набора данных составил 6 353 817 записей.

Обучение указанных ранее моделей машинного обучения осуществлялось с применением стратегии кросс-валидации для дополнительной минимизации рисков переобучения моделей. Для проведения базового тестирования моделей была сформирована валидационная выборка объемом в 30% от исходного полного набора данных. Итоговый размер валидационной выборки составил 1 906 145 записей.

Наивный байесовский классификатор был выбран в качестве базовой эталонной модели, в частности, в ходе эксперимента была использована адаптация стандартного полиномиального наивного байесовского алгоритма – байесовский алгоритм дополнения (CNB).

Метод ближайших соседей был опробован с различным числом соседей (от 5 до 12) с равномерным распределением весов, в качестве метрики использовалось стандартное евклидово расстояние, для решения задачи ассоциативного поиска с учетом размера обучающей выборки был использован алгоритм бинарных деревьев поиска (K-D trees). В ряде экспериментов был дополнительно использован алгоритм жадного добавления-удаления признаков (Add-Del).

В случае модели многослойного перцептрона было использовано два дополнительных полносвязных слоя с Dropout слоем между ними с целью борьбы с переобучением модели, с этой же целью была использована функция L2-регуляризации. В качестве функции активации была выбрана функция Softmax, а оптимизация весов осуществлялась с использованием вариации оптимизационного алгоритма на основе градиентного спуска (Adam).

Для модели, полученной на основе композиции решающих деревьев, было задействовано 100 отдельных деревьев при этом апробировались различные варианты ограничений на глубину дерева, а также на допустимое число объектов в листьях. В процессе обучения использовался критерий информативности Джинни, а обучающие выборки для базовых решающих деревьев формировались с использованием метода случайных подпространств.

Заключительной моделью машинного обучения, рассмотренной в рамках данного исследования, была модель случайного леса. Данная композиция строилась на основе 1000 базовых деревьев с ограничением на допустимое число объектов в листьях. В процессе экспериментов рассматривались вариации как с использованием критерия информативности Джинни, так и на основе энтропийного критерия, которые рассматривались в качестве гиперпараметров модели.

Таким образом, выбранные модели машинного обучения были обучены и первично оценены на отдельных подмножествах исходного набора данных в соответствии с принятой стратегией кросс-валидации. Реализации указанных моделей, продемонстрировавшие наиболее высокое качество классификации в рамках данного процесса, были затем протестированы на валидационной части исходного полного набора данных, полученные результаты для каждой из апробированных моделей представлены в таблице 10.

Таблица 10 – Усредненная по классам точность (Averaged Accuracy – ААс) определения оптимальной формации модульной РС для каждой из рассматриваемых моделей машинного обучения

Модель	ААс по результатам кросс-валидации	ААс на валидационной части полного набора данных
Наивный байесовский классификатор (СNB)	58,8%	54,6%
Метод ближайших соседей	73,7%	73,2%
Многослойный перцептрон Румельхарта	74,8%	71,9%
Композиция решающих деревьев	65,6%	61,7%
Случайный лес	78,2%	76,3%

Согласно представленным в таблице 3 результатам, можно заключить, что все рассматриваемые модели машинного обучения продемонстрировали на валидационной выборке точность классификации схожую с результатами, полученными для них ранее в процессе кросс-валидации. При этом базовая модель на основе байесовского классификатора, а также модель на основе композиции решающих деревьев продемонстрировали в рамках обоих экспериментов наиболее низкое качество классификации. Наивысшую точность продемонстрировала модель на основе случайного леса, достигнув по метрике ААс точности классификации в 76,3% на валидационной части набора данных. Также стоит выделить результаты, полученные для метода ближайших соседей, точность классификации которого практически не изменилась при его тестировании на валидационной выборке, составив 73,2% по метрике ААс.

На следующем шаге эксперимента для двух моделей, продемонстрировавших лучшее качество классификации на валидационной части набора данных, были определены значения метрик точности (Accuracy – Ас), точности (Precision – Pr) и полноты (Recall – R) отдельно по каждому из классов. Полученные результаты представлены на рисунках 6 и 7 соответственно.

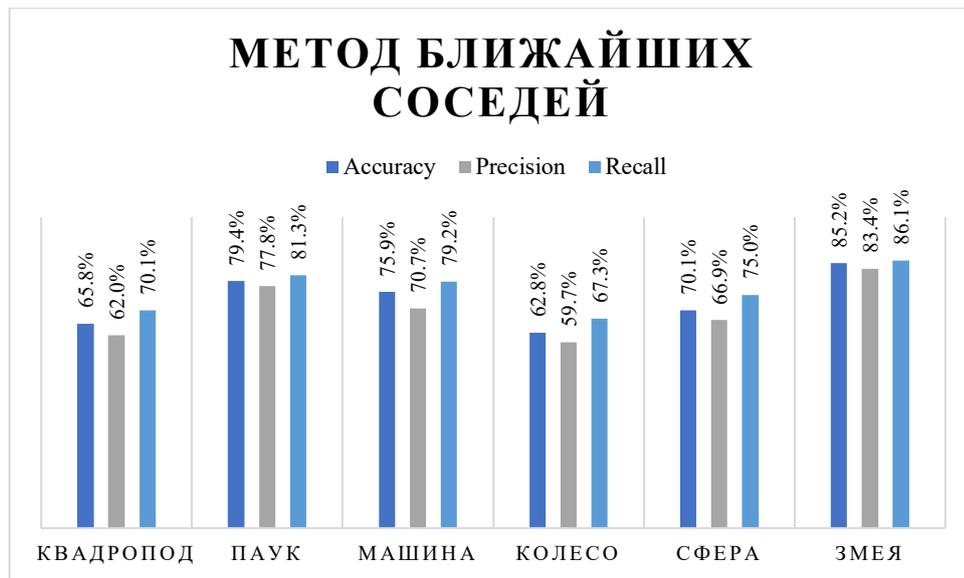


Рисунок 6 – Полученные значения метрик качества классификации для модели на основе метода ближайших соседей в разрезе каждого из классов

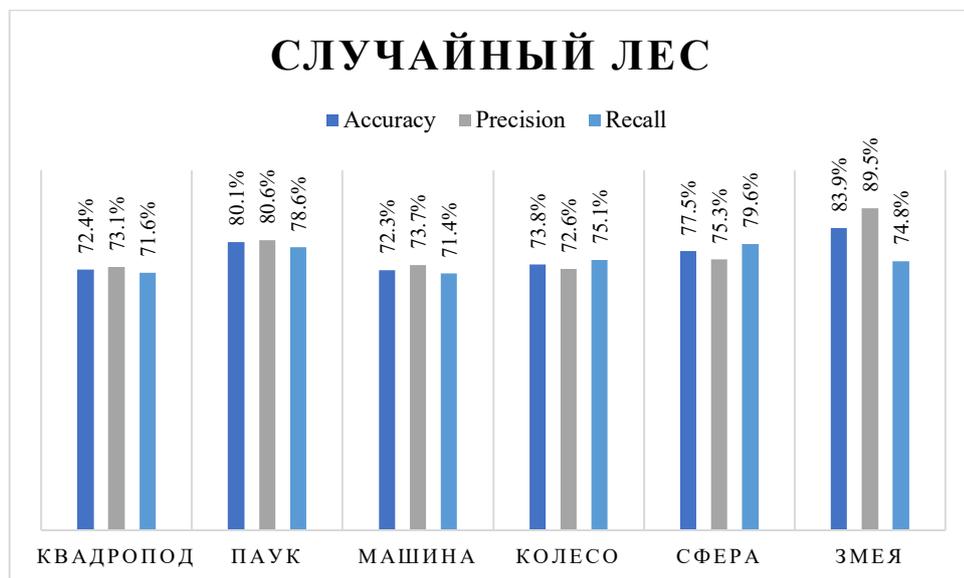


Рисунок 7 – Полученные значения метрик качества классификации для модели на основе случайного леса в разрезе каждого из классов

Согласно результатам, представленным на рисунках 6 и 7, можно отметить, что модель классификации на основе метода ближайших соседей показывает большой разброс в точности распознавания для различных классов. Так для формаций квадропод и колесо точность классификации по метрике Ac составляет немногим более 60%, в то время как для классов змея и паук достигает порядка 80%. Данный факт может объясняться тем, что модели данного класса склоны демонстрировать менее устойчивые результаты в случае сильно пересекающихся классов и наоборот. В частности, классы змея и паук характеризуются более специфическими условиями потенциально оптимального применения, что согласуется с более высокими показателями

точности для данных классов, полученными рассматриваемой моделью. В то же время модель классификации на основе случайного леса демонстрирует в значительной степени более равные показатели точности классификации между классами, при этом для большинства классов не наблюдается значительных отклонений в значениях метрик P_r и R , полученных для отдельных классов, что дополнительно сигнализирует о более высокой устойчивости полученного решения. Таким образом, по результатам сравнения полученных классификаторов именно модель классификации на основе случайного леса следует рассматривать в качестве наилучшего решения задачи определения оптимальной формации модульной РС.

Таким образом, в ходе выполнения завершающего этапа проекта в соответствии с ранее разработанной методикой был разработан и успешно протестирован метод, предназначенная для решения задачи определения оптимальной формации модульной РС из конечного множества формаций, исходя из характеристик отдельных участков рельефа помещений, по которым модульной РС предстоит осуществлять движение. Указанный метод, основан на применении разработанной модели машинного обучения, продемонстрировавшей достаточно высокий уровень качества идентификации оптимальной формации в различных условиях окружения, достигнув точности в 76,3% по метрике AAc на валидационном наборе данных.

1.6 Тестирование разработанной методики, методов и алгоритмов посредством симуляции движения различных формаций модульной РС на отдельных участках смоделированной среды

В рамках заключительных работ над проектом было проведено комплексное тестирование разработанной методики, методов и алгоритмов посредством симуляции движения модульной РС в различных условиях окружения на отдельных участках смоделированной среды. Данная экспериментальная апробация также проводилась с использованием среды виртуального моделирования Gazebo. В качестве исходных данных для моделирования была использована часть валидационного набора данных, сформированного при проведении тестирования метода определения оптимальных формаций для модульных РС, представленного выше. Исходный объем соответствующего набора данных составляет 1 906 145 записей. Поскольку при реализации данного эксперимента требовалось не только осуществлять моделирование окружения и движений РС, но и одновременно использовать большинство разработанных ранее в рамках проекта методов и алгоритмов анализа внешнего окружения, было принято решение осуществить прореживание данного набор данных с сохранением исходной балансировки

классов (фактически оптимальных формаций модульной РС). Конечный объем полученного в результате прореживания набора данных Data составил 19 061 запись.

Таким образом, на основании каждой записи, представленной в полученном наборе данных, с использованием разработанных в рамках проекта алгоритмов автоматической генерации элементов внешнего окружения (сложных поверхностей) осуществлялась симуляция определенных участков местности, по которым модульной РС предстояло осуществлять движение. В рамках каждой из полученных симуляций модульная РС размещалась перед заданным участком местности в формации, соответствующей записи в наборе Data. На следующем шаге запускалась эмуляция функционирования внутренних подсистем модульной РС, а также инициировались программные реализации разработанных в рамках проекта методов и моделей, направленных на анализ внешнего окружения (заданного участка местности, по которому РС предстояло осуществлять движение). В частности, инициировался программный модуль, реализующий представленный выше подход к классификации и оценке геометрических параметров сложных поверхностей по RGB-D изображениям. Далее, с использованием полученных данных в отношении исследуемого участка местности, осуществлялось применение представленного выше метода определения оптимальной формации модульной РС из конечного множества формаций, исходя из характеристик отдельных участков рельефа помещений, по которым модульной РС предстоит осуществлять движение. После чего, на основании результатов использования данного метода модульная РС осуществляла реконфигурацию в предполагаемую оптимальную формацию и выполняла перемещение по заданному участку местности.

Для каждой симуляции оценивалось фактическое прохождение участка местности, а также соответствие выбранной средствами РС формации – фактически оптимальной формации, которая была определена ранее для данного случая в процессе разработки метода определения оптимальной формации. Также для каждой симуляции дополнительно протоколировались результаты оценки параметров исследуемого участка местности средствами РС. Результаты, полученные путем усреднения данных по всем проведенным симуляциям, представлены в таблице 11.

Таблица 11 – Результирующие показатели качества определения оптимальной формации модульной РС в условиях моделируемой среды

Показатель	Усредненная доля
------------	------------------

Заданный участок местности пройден модульной РС в принятой формации успешно	98,1%
Выбранная средствами РС формация соответствует реально оптимальной формации для заданного участка местности	67,8%
Классы, а также геометрические характеристики исследуемого участка местности определены корректно (уровень отклонения меньше допустимого)	62,2%
Участок местности корректно классифицирован как по типу угла наклона, так и по типу перепадов высот	65,6%
Участок местности корректно классифицирован по углу наклона, но некорректно по типу перепадов высот	7,7%
Участок местности корректно классифицирован по типу перепадов высот, но некорректно по углу наклона	9,1%
Класс участка местности определен неверно в обоих случаях	17,6%
Набор параметров А, В, С, D (описывающих оптимальный вариант плоскостной аппроксимации пространственного распределения точек, принадлежащих исследуемому участку местности) определен в процессе симуляции таким образом, что отклонение между нормальными реальной и определенной средствами РС аппроксимирующими плоскостями составляет более 20 градусов	18,3%
Параметры d1 и d2, характеризующие протяженность исследуемого участка местности, определены с относительным отклонением в более чем 25%	21,6%

По результатам эксперимента можно сделать вывод, что результирующий уровень точности определения оптимальной формации модульной РС в рамках эксперимента в моделируемой среде дополнительно снизился в среднем на 8,5%. Данное снижение качества определения оптимальной формации в значительной степени может быть объяснено возникающими в процессе анализа внешнего окружения погрешностями в оценке параметров исследуемого участка местности. Средний уровень корреляции между случаями ошибочной оценки параметров участка местности и случаями ошибочного выбора оптимальной формации составляет порядка 64,4%. Тем не менее, предложенные в рамках проекта решения позволили достичь результирующей средней точности определения оптимальной формации модульной РС на основе характеристик исследуемых участков местности в 67,8%, что по-прежнему является достаточно высоким уровнем качества решения для столь комплексной задачи. Также важно отметить, что в ряде случаев разработанное решение продемонстрировало достаточно высокий уровень устойчивости и частично скомпенсировало погрешности в оценке параметров окружения, поскольку в 78,6%, когда один из параметров исследуемого участка местности был определен неверно, предложенный метод определения оптимальной формации модульной РС продолжал сходиться к корректному результату.

Таким образом, в ходе исполнения проекта научному коллективу удалось решить основные задачи, поставленные в рамках проекта, и успешно реализовать подход к выбору оптимальных формаций модульных робототехнических систем (РС) в зависимости от геометрических характеристик сложных поверхностей участков пути РС, что в дальнейшем позволит добиться значительного повышения проходимости и эффективности движения модульных РС в подобных условиях.

Апробация результатов реализации Проекта на научных мероприятиях (участие в научных мероприятиях по тематике Проекта за период, на который был предоставлен грант) (каждое мероприятие с новой строки, указать название мероприятия, ФИО члена коллектива и тип доклада)

15th International Conference on Electromechanics and Robotics “Zavalishin’s Readings” (ER(ZR) 2020) - Савельев А.И., очный доклад

23rd issue of the International Conference Series on Climbing and Walking Robots and the Support Technologies for Mobile Machines CLAWAR 2020 - Павлюк Н.А., очный доклад

16th International Conference on Electromechanics and Robotics “Zavalishin’s Readings” (ER(ZR) 2021) - Яковлев Р.Н., очный доклад

6th Computational Methods in Systems and Software 2022 (CoMeSySo 2022) – Ерашов А.А., очный доклад.

Краткое назначение конечной продукции, технологии или услуг, которые будут производиться с применением полученных результатов

Технология.

Технология адаптивного управления формациями модульных РС в зависимости от специфики внешнего окружения. Указанная технология может быть использована в составе промышленных модульных РС с целью повышения эффективности их перемещения в условиях динамических сред.

Литература

1. Hashmi, M. Z. What Lies Beneath One’s Feet? Terrain Classification Using Inertial Data of Human Walk / M. Z. U. H. Hashmi, Q. Riaz, M. Hussain, M. Shahzad // Applied Sciences. – 2019. – Т. 9. – №. 15. – С. 3099, DOI: 10.3390/app9153099.
2. Ebadi F., Road Terrain detection and Classification algorithm based on the Color Feature ex-traction / F. Ebadi, M. Norouzi // 2017 Artificial Intelligence

- and Robotics (IRANOPEN). – IEEE, 2017. – С. 139-146, doi: 10.1109/RIOS.2017.7956457
3. Shill J. J. Tactile surface classification for limbed robots using a pressure sensitive robot skin / J. J. Shill, Jr, E. G., Collins, E. Coyle, J. Clark // *Bioinspiration & biomimetics*. – 2015. – Т. 10. – №. 1. – С. 016012
 4. Mrva J., Faigl J. Feature Extraction for Terrain Classification with Crawling Robots // *ITAT*. – 2015. – С. 179-185., Walas K. Terrain classification and negotiation with a walking robot // *Journal of Intelligent & Robotic Systems*. – 2015. – Т. 78. – №. 3-4. – С. 401-423.
 5. Yuan Q., Design and Experiment of the NAO Humanoid Robot's Plantar Tactile Sensor for Surface Classification / Yuan Q., Wang J. // *2017 4th International Conference on Information Science and Control Engineering (ICISCE)*. – IEEE, 2017. – С. 931-935, DOI: 10.1109/ICISCE.2017.197
 6. Phaniteja S. et al. A deep reinforcement learning approach for dynamically stable inverse kinematics of humanoid robots // *2017 IEEE International Conference on Robotics and Biomimetics (ROBIO)*. – IEEE, 2017. – С. 1818-1823.
 7. Momani S., Abo-Hammour Z. S., Alsmadi O. M. K. Solution of inverse kinematics problem using genetic algorithms // *Applied Mathematics & Information Sciences*. – 2016. – Т. 10. – №. 1. – С. 225.
 8. Starke S. A hybrid genetic swarm algorithm for interactive inverse kinematics: дис. – Universität Hamburg, Fachbereich Informatik, 2016.
 9. Almusawi A. R. J., Dülger L. C., Kapucu S. A new artificial neural network approach in solving inverse kinematics of robotic arm (denso vp6242) // *Computational intelligence and neuroscience*. – 2016. – Т. 2016.
 10. 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. DOI: 10.32362/2500-316X-2018-6-4-26-41.
 11. Брискин, Е. С., Калинин, Я. В., Малолетов, А. В., Шурыгин, В. А. (2017). Об оценке эффективности шагающих роботов на основе многокритериальной оптимизации их параметров и алгоритмов движения // *Известия Российской академии наук. Теория и системы управления*. – 2017. – №. 2. – С. 168-176. DOI: 10.7868/S0002338817020056.
 12. Sproewitz A. et al. Learning to move in modular robots using central pattern generators and online optimization // *The International Journal of Robotics Research*. – 2008. – Т. 27. – №. 3-4. – С. 423-443. DOI: 10.1177/0278364907088401.
 13. Kamimura A. et al. Automatic locomotion pattern generation for modular robots // *2003 IEEE International Conference on Robotics and Automation (Cat. No. 03CH37422)*. – IEEE, 2003. – Т. 1. – С. 714-720. DOI:10.1109/robot.2003.1241678.
 14. Санжаров В. В. и др. Система генерации наборов изображений для задач компьютерного зрения на основе фотореалистичного рендеринга

- //Препринты Института прикладной математики им. МВ Келдыша РАН. – 2020. – №. 0. – С. 80-29. DOI: 10.20948/prepr-2020-80.
15. Williams R. D. et al. Hyperscale terrain modelling of braided rivers: fusing mobile terrestrial laser scanning and optical bathymetric mapping //Earth Surface Processes and Landforms. – 2014. – Т. 39. – №. 2. – С. 167-183. DOI: 10.1002/esp.3437.
 16. Ebert, D. S., Musgrave, F. K., Peachey, D., Perlin, K., Worley, S. Texturing & modeling: a procedural approach. Morgan Kaufmann. 2003.
 17. Kelvin L. Z., Bhojan A. Procedural generation of roads with conditional generative adversarial networks //ACM SIGGRAPH 2020 Posters. – 2020. – С. 1-2. DOI: 10.1145/3388770.3407422.
 18. Beckham C., Pal C. A step towards procedural terrain generation with gans //arXiv preprint arXiv:1707.03383. – 2017. DOI: 10.48550/arXiv.1707.03383.
 19. Panagiotou E., Charou E. Procedural 3D terrain generation using Generative Adversarial Networks //arXiv preprint arXiv:2010.06411. – 2020. DOI: 10.48550/arXiv.2010.06411.
 20. Liu C., Whitzer M., Yim M. A distributed reconfiguration planning algorithm for modular robots //IEEE Robotics and Automation Letters. – 2019. – Т. 4. – №. 4. – С. 4231-4238.
 21. Daudelin J. et al. An integrated system for perception-driven autonomy with modular robots //Science Robotics. – 2018. – Т. 3. – №. 23. – С. eaat4983.
 22. Pacheco M. et al. Fable II: Design of a modular robot for creative learning //2015 IEEE International Conference on Robotics and Automation (ICRA). – IEEE, 2015. – С. 6134-6139.
 23. CH S. S. R. et al. HexaMob—a hybrid modular robotic design for implementing biomimetic structures //Robotics. – 2017. – Т. 6. – №. 4. – С. 27.
 24. Sastra J., Chitta S., Yim M. Dynamic rolling for a modular loop robot //The International Journal of Robotics Research. – 2009. – Т. 28. – №. 6. – С. 758-773.
 25. Wei X., Tian Y., Wen S. Design and locomotion analysis of a novel modular rolling robot //Mechanism and Machine Theory. – 2019. – Т. 133. – С. 23-43.
 26. Tao A., Sapra K., Catanzaro B. Hierarchical Multi-Scale Attention for Semantic Segmentation //arXiv preprint arXiv:2005.10821. – 2020.
 27. Chen L. C. et al. Encoder-decoder with atrous separable convolution for semantic image segmentation //Proceedings of the European conference on computer vision (ECCV). – 2018. – С. 801-818.
 28. 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.
 29. 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.
 30. McLure C. E. Implementing subnational value added taxes on internal trade: the compensating VAT (CVAT) //International Tax and Public Finance. – 2000. – Т. 7. – №. 6. – С. 723-740.

31. ГОСТ Р. 55710-2013 Освещение рабочих мест внутри зданий // Нормы и методы измерений. 2013.
32. Tao A., Sapa K., Catanzaro B. Hierarchical Multi-Scale Attention for Semantic Segmentation //arXiv preprint arXiv:2005.10821. – 2020.