

ПРИМЕНЕНИЕ НЕДООПРЕДЕЛЕННЫХ МОДЕЛЕЙ В ЗАДАЧЕ ГЛОБАЛЬНОЙ ЛОКАЛИЗАЦИИ МОБИЛЬНОГО РОБОТА[#]

А. Д. Московский

Национальный исследовательский центр «Курчатовский институт», г. Москва

✉ moscowskyad@yandex.ru

Аннотация. Рассматривается применение недоопределенных моделей для решения задачи локализации мобильного робота. Предлагается комплексная технология, использующая семантические карты и карты в виде облаков точек. Комплексная технология призвана уменьшить время и увеличить точность глобальной локализации на больших, а также симметричных и периодичных пространствах. Вместо локализации по данным дальномеров, генерирующих облака точек, предлагается сначала определить соответствия между наблюдаемыми роботом объектами и семантической картой (решить задачу распознавания сцены), а далее с использованием недоопределенных вычислений решить задачу локализации по визуальным ориентирам. С помощью недоопределенных вычислений определяются интервальные ограничения на положения робота, представленные несколькими наборами для каждой гипотезы, полученной при решении задачи распознавания сцен. В полученных интервальных ограничениях предлагается выполнить поиск положения робота с использованием данных дальномеров на основе фильтра частиц, который инициализирован в данных ограничениях. Эксперименты, проведенные на открытом наборе данных KITTI-360, показали, что локализация на основе недоопределенных вычислений позволяет уменьшить пространство поиска до 0,2 % от размера исходной карты. Предложенная комплексная технология демонстрирует значительное преимущество в сравнении с подходами, основанными исключительно на облаках точек или исключительно на визуальных ориентирах, особенно в случаях, когда получено несколько гипотез о соответствии наблюдаемых объектов семантической карте.

Ключевые слова: глобальная локализация, недоопределенные модели, программирование в ограничениях, распознавание сцен, семантические карты, мобильный робот.

ВВЕДЕНИЕ

Задача локализации играет одну из ключевых ролей в современной мобильной робототехнике, поскольку подавляющее большинство подходов к управлению движением мобильного робота базируется на знании его текущего положения. В условиях, когда затруднено использование спутниковой навигации, например, в городах или внутри помещений (в комнатной среде), широко применяются методы локализации, строящие трехмерную карту в виде облака точек. Популярность дан

ного подхода определяется в том числе и его универсальностью: не требуется размещение дополнительных меток (устройств) в окружении робота, которые помогали бы в локализации. Подобная подробная карта может применяться и в задаче навигации, поскольку содержит информацию о препятствиях. Она может быть построена с помощью таких распространенных сенсоров, как сканирующие лазерные дальномеры и камеры глубины. Современное развитие методов SLAM (*Simultaneous Localization and Mapping*) [1] позволяет строить достаточно точные карты больших областей, однако при дальнейшем использовании подобных карт возникает задача глобальной локали-

[#] Работа проведена в рамках государственного задания НИЦ «Курчатовский институт».



зации – определения стартового положения робота без знания каких-либо начальных условий. Данная задача решается при инициализации (старте работы) робота и в случаях, если робот «сбился» (положение робота не соответствует ожидаемому) ввиду ошибок в ходе локализации, или, например, был перемещен третьими лицами. Все эти ситуации не позволяют использовать данные о предыдущем положении робота и его смещении для локализации. Поиск положения робота во всем пространстве (обычно ограниченном размером карты) становится сложнее с ростом размера карты, что отмечают авторы обзора [2] подходов, применяемых для решения данной задачи. Помимо увеличения числа требуемых вычислений, проблемой становится то, что упомянутые городские и комнатные среды зачастую содержат области с достаточно схожей геометрией, особенно когда речь идет о типовых постройках. Подобная «периодичность» и «симметричность» окружающей среды приводит к так называемым локальным минимумам на карте, в которых робот может ошибочно глобально локализоваться. И число таких локальных минимумов растет с размером карт.

К решению данной проблемы исследователи подходят с разных сторон. Одно направление использует только облака точек, его задача – построение качественных дескрипторов, связанных с облаками точек, позволяющих выделить и сопоставить геометрические и другие особенности его элементов, в том числе семантические. В целом в рамках данного подхода можно выделить три основные стадии: выделение дескрипторов, сопоставление дескрипторов, уточнение положения. Среди методов выделения дескрипторов можно отметить такие, как FPFH (*Fast Point Feature Histograms*) [3], NDT (*Normal Distribution Transform*) [4], обучаемые подходы NeRF (*Neural Radiance Fields*) [5], Minkloc3d [6] и др. [7]. Для сопоставления дескрипторов применяются разные подходы: распространены методы на основе RANSAC (*RANdom SAmple Consensus*) [8], графовые подходы [9], оптимизационные алгоритмы [10], обучаемые подходы [11]. Метод ICP (*Iterative Closest Point*) [12] и его дальнейшие расширения (см., например, работу [13]), используются для последующего уточнения положения робота. Также используются такие вероятностные подходы, как гистограммный фильтр или фильтр частиц [14], применяемые к облакам точек [15]. Однако, поскольку данные дескрипторы, в первую очередь, базируются на гео-

метрических особенностях взаиморасположения точек, то проблема локальных минимумов ввиду периодичности и симметричности пространств не может быть устранена. Несмотря на то, что построение дескрипторов сужает пространство поиска, они остаются на уровне облаков точек и в какой-то мере сопряжены с перечисленными ранее проблемами, поэтому другие подходы переходят на более «высокий» уровень представления карты, о котором пойдет речь далее.

Подход Place Recognition [16], подобно построению дескрипторов, кодирует сразу все окружение робота в виде вектора чисел. Обычно для этого применяются нейросетевые модели, которые обучаются так, что одно и то же окружение, снятое с разных ракурсов, в разное время суток и т. п., продуцирует близкие друг к другу векторы. Часто такие модели имеют мультимодальный вход и учитывают как облака точек и «сырые» изображения, так и семантику сцены. Таким образом, карта снабжена набором «ключевых кадров», для которых было выполнено построение кодирующих их векторов, а локализация сводится к поиску кадра, наиболее совпадающего с текущим наблюдением робота, полученным по набору сенсоров. Такой подход хорош тем, что использует всю доступную информацию об окружении, однако требует плотного покрытия пространства ключевыми кадрами. Сильное изменение ракурса также может негативно влиять на качество поиска кадра для различных композиций сенсоров, использующихся на работе. Чем более приближена к полному обзору композиция сенсоров, тем лучше для таких методов, однако не для всех роботов это является возможным и целесообразным.

Еще одно направление, в рамках которого выполнена данная работа, использует так называемые семантические карты. Это карты, где размечены объекты с их семантическими метками (классами). Методы, позволяющие в автоматическом наборе получать такие карты, активно развиваются [17, 18]. Набор объектов тех же классов выделяется в окружении, которое непосредственно наблюдает робот. Далее возникает задача распознавания сцены, а именно сопоставления объектов карты с объектами в окружении (сцене). Поиск такого соответствия на уровне объектов позволяет сузить пространство поиска по сравнению с поиском в трехмерных картах. Семантика придает дополнительную «уникальность» сценам с однообразной геометрией. После того, как сопоставление найде-

но, можно воспользоваться методами локализации по визуальным ориентирам. Однако одной из проблем данного направления является то, что подобные методы распознавания сцен генерируют целый ряд гипотез о сопоставлении объектов. В результате требуется проводить локализацию для каждой из гипотез и оценивать получившееся качество сопоставления объектов. Направление, использующее семантические карты, имеет ряд преимуществ – применяемые методы менее чувствительны к изменениям ракурса и позволяют вручную редактировать семантические карты. Редактирование карт вручную является достоинством метода, поскольку окружающее пространство способно меняться во времени, а проводить полностью процедуру картирования может быть нецелесообразно.

Учитывая вышеизложенное, целью исследования является ускорение работы и увеличение точности глобальной локализации мобильного робота на картах, представленных в виде облаков точек. Выбрано направление, которое, в дополнение к облакам точек, использует семантические карты и требует решения задачи распознавания сцен. Данная работа сконцентрирована на проблеме локализации мобильного робота по результатам применения методов распознавания сцен с учетом такой специфики задачи, как высокие погрешности определения положения объектов, ошибки в сопоставлении объектов и выбор лучшего результата среди набора гипотез.

1. МЕТОДЫ ЛОКАЛИЗАЦИИ ДЛЯ РЕШЕНИЯ ЗАДАЧИ РАСПОЗНАВАНИЯ СЦЕН

В современных работах по локализации с использованием семантических карт, посвященных решению задачи распознавания сцен, одним из самых распространенных методов является оптимизационный подход сопоставления двух наборов трехмерных точек – SVD (*Singular Value Decomposition*) [19]. Локализация этим методом по результатам распознавания сцен проводится в публикациях [20–22]. Данный подход минимизирует среднеквадратичную ошибку положений точек между двумя наборами, однако требует точного поэлементного соответствия одного набора другому и не учитывает погрешности определения положения в расчетах. В работе [23] используется упомянутый подход ICP, примененный не к облакам точек, а к двум наборам объектов: на карте и на сцене. В ря-

де работ (см., к примеру, публикации [24, 25]) для локализации робота используется технология 2D-3D перепроецирования (*reprojection*), позволяющая сопоставить положения плоских объектов на изображении с их трехмерными положениями. Этот подход позволяет обойтись без трехмерной локализации объектов сцены в пространстве, а следовательно, отчасти нивелировать погрешности в определении этого расстояния, которые могут быть значительными.

Перспективным направлением видится сочетание локализации по облакам точек с данными, полученными в результате применения методов распознавания сцен. Интересный подход был предложен в работе [26]: производилась отдельная трехмерная регистрация облаков точек выделенных объектов, дальнейшее уточнение проводилось с помощью ICP.

Вместе с тем не было обнаружено работ, которые использовали бы поисковые вероятностные подходы на основе гистограммного фильтра или фильтра частиц в задаче локализации по визуальным ориентирам в исследуемой постановке. Это объясняется тем, что для этих методов требуется ограничить область поиска, что проблематично для большинства рассмотренных подходов к локализации, так как они выдают в качестве ответа точку в пространстве, а не область. Использование ограничений на положение робота в виде интервалов позволило бы решить данную проблему. Общий подход программирования в ограничениях (англ. *constraint programming*) [27] позволяет получать данные такого рода. Обобщение этого подхода в виде недоопределенных вычислений (Н-вычислений) [28] было применено к задаче локализации по визуальным ориентирам и последующему использованию гистограммного фильтра внутри полученных ограничений [29]. В данной же работе будет рассмотрен этот подход в применении к локализации робота по ряду гипотез с использованием фильтра частиц (ФЧ), определяющего положение робота с помощью облаков точек в полученных ограничениях.

2. ПРЕДЛАГАЕМАЯ КОМПЛЕКСНАЯ ТЕХНОЛОГИЯ ГЛОБАЛЬНОЙ ЛОКАЛИЗАЦИИ

Комплексная технология глобальной локализации, предлагаемая в настоящей работе, выполнена в рамках направления, использующего семантические карты. Такая комплексная технология лока-



лизации требует использования как слоя карты в виде облака точек, так и семантического слоя, на котором размечены положения объектов и указана некоторая семантическая информация о них. Помимо двух слоев карт, входными данными являются изображения и облака точек от сенсоров робота. Решение задачи локализации в рамках предлагаемой комплексной технологии состоит из следующих этапов:

1. Распознавание и локализация объектов в окружении робота (формирование сцены).
2. Решение задачи распознавания сцены – поиск соответствия между распознанными объектами и семантической картой, получение ряда гипотез.
3. Применение подхода недоопределенной локализации (Н-локализации) к полученным гипотезам: отброс противоречивых гипотез и определение интервальных ограничений на положение робота.
4. Определение положения робота с помощью ФЧ в полученных ограничениях для каждой гипотезы, расчет численных оценок качества.
5. Выбор решения с наибольшей численной оценкой.

Первый этап осуществляется с применением либо классического способа распознавания объектов на изображениях и дальнейшей их локализации с использованием карт глубины или облаков точек [30], либо с применением подходов трехмерного распознавания [31].

Второй этап, включающий в себя решение задачи распознавания сцен, подробно изложен в работе [32]. В ней предлагается использование алгоритмов теории графов, позволяющих выделить геометрические особенности взаиморасположения групп объектов. В работе было описано использование базисных визуально-языковых моделей на примере CLIP (*Contrastive Language-Image Pre-training*) [33] для учета визуального сходства объектов, а не только семантической метки, как это делалось ранее большинством исследователей в области локализации робота по семантическим картам. Использование критерия визуального сходства объектов в дополнение к критерию геометрических особенностей позволило значительно увеличить точность распознавания сцен в сравнении с методами, опирающимися только на один из критериев. Однако ряд проблем, связанных с работой с объектами, включая высокие погрешности их локализации, наличие визуально схожих объектов, ошибки систем распознавания, а также множественность решений приводит к тому, что на выходе таких систем генерируется множество гипо-

тез и верное решение не всегда обладает наивысшей численной оценкой.

На третьем этапе применяется подход Н-локализации, которому посвящена данная работа. Данный подход используется для решения задачи локализации робота по визуальным ориентирам, он формирует интервальные ограничения на положения робота и позволяет определить противоречия во входных данных, которые могут возникнуть из-за перечисленных особенностей результатов решения задачи распознавания сцен.

На четвертом этапе применяется ФЧ для определения положения робота с использованием слоя карты в виде облака точек. Применение ФЧ обосновано тем, что он естественным образом может быть инициализирован в интервальных ограничениях, полученных от Н-локализации. Кроме того, ФЧ способен работать с широким набором входных данных, для которых можно получить численную оценку качества любой из частиц, которая, в свою очередь, в задаче локализации представляет собой гипотезу о положении робота.

На пятом этапе с использованием полученной численной оценки определяется лучшее решение для всех полученных на втором этапе гипотез.

Схема комплексной технологии глобальной локализации приведена на рис. 1.

2.1. Локализация по ориентирам на основе недоопределенных моделей

Для применения Н-вычислений требуется создать описание решаемой задачи в виде недоопределенной модели (Н-модели). Такая модель представляет собой описание искомых величин, их области определения и функций интерпретации и присваивания, по которым искомые величины обновляются [28]. Искомые величины, а именно положение робота, задаются в виде так называемых мультиинтервалов – упорядоченному по возрастанию непересекающемуся набору интервалов:

$$*a = \left[\left[a_{\text{low}}^1, a_{\text{high}}^1 \right], \dots, \left[a_{\text{low}}^N, a_{\text{high}}^N \right], \right.$$

$$\left. a_{\text{low} \setminus \text{high}}^i \in R, a_{\text{low}}^i \leq a_{\text{high}}^i, a_{\text{high}}^i < a_{\text{low}}^{i+1} \right],$$

где $*a$ – некая недоопределенная переменная (Н-переменная), заданная мультиинтервалом; a_{low}^i – нижние границы интервалов; a_{high}^i – верхние границы интервалов, образующих мультиинтервал; $i = 1, N - 1$. Мультиинтервалы являются частным случаем Н-переменных, которые здесь и далее будут обозначаться символом «*» слева от имени переменной.




Рис. 1. Схема комплексной технологии решения задачи глобальной локализации

Изначально эти мультиинтервалы инициализированы всеми доступными значениями. Далее определяются так называемые функции интерпретации, применение которых должно уменьшать неопределенность, т. е. сужать границы мультиинтервалов, поскольку новое вычисленное значение на каждом шаге итерации есть пересечение старого значения со значением, полученным в ходе применения функции интерпретации. Если пересечения нет, значит, входные данные содержат противоречия и должны быть исключены из рассмотрения. Функции интерпретации определяются на основе связи между положением робота ($*X$, $*Y$, $*\theta$), положением наблюдаемых ориентиров (X_l , Y_l), и их измерениями, включающими в себя расстояние до объекта r_l и угол на него α_l :

$$*X = \pm \sqrt{(r + \Delta r_l)^2 - (Y - Y_l)^2} + X_l, \quad (1)$$

$$*Y = \pm \sqrt{(r + \Delta r_l)^2 - (X - X_l)^2} + Y_l, \quad (2)$$

$$*X = \frac{Y - Y_l}{\tan(*\theta + *\Delta\alpha_l + \alpha_l)} + X_l, \quad (3)$$

$$*Y = (*X - X_l) \tan(*\theta + *\Delta\alpha_l + \alpha_l) + Y_l, \quad (4)$$

$$*\theta = \arctan\left(\frac{Y_l - *Y}{X_l - *X}\right) - (\alpha_l + *\Delta\alpha_l), \quad (5)$$

где $*\Delta r_l$ и $*\Delta\alpha_l$ – погрешности измерений r_l и α_l , выраженные интервалами, которые могут быть получены из средноквадратичных ошибок по пра-



вилу N сигм: $*\Delta r_l = [-N\sigma r_l, N\sigma r_l]$. В формулах (1)–(5) часть переменных представляется в виде мультиинтервалов и для их вычисления требуется применение интервальной арифметики [34]. Для каждого наблюдаемого ориентира, полученного в ходе решения задачи распознавания сцен, формируется свой набор функций интерпретации (1)–(5). Процедура Н-вычислений сводится к итеративному применению функций к набору Н-переменных. После применения функции она удаляется из списка активных функций, однако если была обновлена переменная (изменилось ее значение), которая является входной для какой-либо функции присваивания вне активного списка, то эта функция возвращается в список активных функций. Вычислительная процедура продолжается до тех пор, пока список активных функций не пуст; также на практике можно ограничить число итераций или установить желаемую точность полученных значений переменных.

В то же время имеется ряд ситуаций, которые не могут быть разрешены методами распознавания сцен. Сюда относятся ситуации симметрии, поскольку алгоритмы на графах неспособны различать порядок появления объектов по мере увеличения угла на них, так как граф содержит информацию только о расстоянии между двумя объектами. Эта ситуация может быть решена на уровне Н-моделей введением дополнительных функций проверки корректности. На основе текущих ограничений ($*X$, $*Y$, $*\theta$) рассчитываются значения углов на самый левый и самый правый объект в сцене и выполняется проверка неотрицательности их разности:

$$-\left(\arctan\left(\frac{*Y - Y_{\text{left}}}{*X - X_{\text{left}}} \right) - \arctan\left(\frac{*Y - Y_{\text{right}}}{*X - X_{\text{right}}} \right) < 0 \right), (6)$$

где индекс left соответствует самому левому (по углу) ориентиру, а индекс right – самому правому. Применять дополнительные функции проверки корректности лучше не к полному набору ($*X$, $*Y$, $*\theta$), а к их декартовому произведению, где каждый элемент – это кортеж из трех интервалов для каждой переменной. Те кортежи, что не прошли проверку (6), исключаются из общего множества.

На выходе получаются значения Н-переменных, представленные набором кортежей интервалов. Такие кортежи описывают объединение пря-

моугольных областей (со сторонами, параллельными осям x и y , иногда именуемых брусами [34]) с указанием ограничения на размер угла. Однако полученный в такой форме ответ может быть несколько избыточным и содержать лишние значения (рис. 2, а).




Рис. 2. Графическое представление избыточного оценивания: а – ситуация избыточного оценивания области положения робота, ограниченного синими штрихпунктирными линиями, где $*X$ – входная Н-переменная, а $*Y$ – рассчитанная; б – пример исчерпывающего оценивания области путем деления по входной переменной

Для таких ситуаций в интервальном анализе [34] применяются алгоритмы исчерпывающего оценивания, заключающегося в итеративном разбиении интервалов, превосходящих заданное ограничение и повторном применении вычислительной процедуры к получившемуся результату. На рис. 2, б показан пример такого разделения после первой итерации алгоритма по переменной $*X$ и вычисление новых значений $*Y_1$ и $*Y_2$. Таким образом, общий алгоритм глобальной локализации на основе Н-вычислений (алгоритм Н-локализации) представим в виде псевдокода.

Алгоритм глобальной локализации по визуальным ориентирам с использованием Н-вычислений

```

1.  Algorithm sdm_global_localization( $\{<X_1, Y_1, r_1, \alpha_1, \sigma_r, \sigma_\alpha>\}, N\sigma, xy\_lim$ ):
2.      --  $X_1, Y_1$  – положения объектов на карте
3.      --  $r_1, \alpha_1$  – измерения объектов на сцене
4.      --  $\sigma_r, \sigma_\alpha$  – погрешности измерений объектов
5.      --  $N\sigma$  – множитель для перевода погрешностей в интервал
6.      --  $xy\_lim$  – максимально допустимый размер интервалов по  $x$  и  $y$ 
7.       $V = \emptyset$ 
8.       $*X = *Y = [[-\infty, \infty]]$ 
9.       $*\theta = [[-\pi, \pi]]$ 
10.      $R = \text{init\_R}(\{<X_1, Y_1, r_1, \alpha_1, \sigma_r, \sigma_\alpha>\}, N\sigma)$  -- (1)–(5)
11.      $Status, *X, *Y, *\theta = \text{sdm\_process}(*X, *Y, *\theta, R)$ 
12.     if ! $Status$ 
13.         return  $V$ 
14.      $C = \text{init\_C}(\{<X_1, Y_1, r_1, \alpha_1, \sigma_r, \sigma_\alpha>\}, N\sigma)$  -- (6)
15.     function process_leaf( $*x, *y, *y$ )
16.          $Status, *x, *y, *y = \text{sdm\_process}(*x, *y, *y, R)$ 
17.         if  $Status$ 
18.             if  $|*x| > xy\_lim$ :
19.                  $*x1, *x2 = \text{divide}(*x)$ 
20.                 process_leaf( $*x1, *y, *y$ )
21.                 process_leaf( $*x2, *y, *y$ )
22.             elif  $|*y| > xy\_lim$ :
23.                  $*y1, *y2 = \text{divide}(*y)$ 
24.                 process_leaf( $*x, *y1, *y$ )
25.                 process_leaf( $*x, *y2, *y$ )
26.             else
27.                 add ( $*x, *y, *y$ ) to  $V$ 
28.         for ( $*x, *y, *y$ ) in  $*X \times *Y \times *\theta$  do
29.             if  $C(*x, *y, *y)$  then
30.                 process_leaf( $*x, *y, *y$ )
31.         return  $V$ 

```

Алгоритм **sdm_global_localization** принимает на вход набор положений ориентиров и их измерений, множитель $N\sigma$ для перевода среднеквадратичных ошибок в интервальные, лимит на размер области xy_lim . Вспомогательная функция **init_R** инициализирует параметры функции присваивания (1)–(5) на основе данных об ориентирах. Функция **sdm_process** производит вычисление Н-переменных описанным выше образом, согласно изложенному в работе [28], и возвращает статус (успех либо неуспех) и обновленные значения Н-переменных. Функция **init_C** инициализирует параметры дополнительных функций проверки корректности((6). Функция **divide** разбивает интервал на два путем деления по его центру, и алгоритм возвращает набор кортежей интервалов, не превосходящих по осям x и y заданное ограничение xy_lim и прошедших все дополнительные проверки.

2.2. Локализация с помощью фильтра частиц в ограничениях

Полученные путем применения алгоритма **sdm_global_localization** ограничения описывают область, в которой может находиться робот. Имея такие ограничения, можно выполнить поиск с использованием ФЧ. Каждая частица в данном контексте – это гипотеза о положении робота. Требуется инициализировать начальное распределение в полученных ограничениях равномерным способом. Для работы ФЧ требуется оценивать качество каждой частицы. Предлагается использовать данные плотной карты в виде облака точек и облако точек, полученное с робота. Для сравнения двух облаков точек предлагается рассчитать кратчайшие расстояния от точек облака с робота до точек облака карты. Среднее арифметическое этих рас-



стояний покажет качество наложения облаков друг на друга. Однако для ускорения сходимости ФЧ рекомендуется использовать более «чувствительную» оценку:

$$p(d, \sigma) = \frac{e^{-(d/\sigma)^2}}{\sqrt{2\pi}\sigma}, \quad (7)$$

где p – желаемая оценка частицы; d – среднее кратчайших расстояний; σ – желаемый порог чувствительности. На каждой итерации работы ФЧ происходит расчет весов всех частиц путем переноса облака точек с робота в координаты частицы и расчета оценки (7). Далее происходит процедура перевыборки (*resampling*), цель которой – отсеять частицы с низким весом и размножить частицы с высоким; вероятность, с которой частица попадет в новую выборку, пропорциональна ее весу. Поскольку в процессе перевыборки некоторые части-

цы представлены в нескольких экземплярах, то в начале каждой итерации имеет смысл добавить к каждой частице некоторый случайный шум, чтобы разделить одинаковые гипотезы и плотнее покрыть область поиска. Процедуру, состоящую из указанных шагов, можно проводить либо фиксированное число итераций, либо до достижения целевых значений каких-либо критериев, например, среднего веса частиц, значений матрицы ковариации, построенной по распределению частиц, и т. п. Для выбора искомого положения существуют различные практики: взвешенное среднее всех частиц, максимальная по весу частица, первичная кластеризация частиц и применение указанных способов к локальным кластерам. После расчёта искомого положения робота его качество можно оценить с использованием той же метрики (7). Алгоритм глобальной локализации с помощью ФЧ выглядит следующим образом.

Алгоритм глобальной локализации по облакам точек с помощью фильтра частиц в ограничениях

```

1.  Algorithm pf_global_localization( $V, \sigma, N, iter, \Delta, PCD_{map}, PCD_{robot}$ ):
2.      --  $V$  – ограничения на положение робота
3.      --  $\sigma$  – чувствительность
4.      --  $N$  – число частиц
5.      --  $iter$  – число итераций
6.      --  $\Delta$  – параметры шума
7.      --  $PCD_{map}$  – облако точек карты
8.      --  $PCD_{robot}$  – облако точек с робота
9.       $P = \emptyset$ 
10.     for  $n$  in  $N$  do
11.          $v = \text{sample\_element}(V)$ 
12.          $p = \text{sample\_particle}(v)$ 
13.         add  $p$  to  $P$ 
14.     for  $i$  in  $iter$  do
15.          $W = \emptyset$ 
16.          $P' = \emptyset$ 
17.         for  $p$  in  $P$  do
18.              $p = \text{random\_shift}(p, \Delta)$ 
19.             add  $p$  to  $P'$ 
20.              $PCD = \text{transform\_cloud}(PCD_{robot}, p)$ 
21.              $d = \text{get\_mean\_p2p}(PCD, PCD_{map})$ 
22.              $w = \text{get\_w}(d, \sigma)$  -- (7)
23.             add  $w$  to  $W$ 
24.          $P = \text{resampling}(P', W)$ 
25.          $pose_{final} = \text{get\_pose}(P, W)$ 
26.          $PCD_{final} = \text{transform\_cloud}(PCD_{robot}, pose_{final})$ 
27.          $d_{final} = \text{get\_mean\_p2p}(PCD_{final}, PCD_{map})$ 
28.          $w_{final} = \text{get\_w}(d_{final}, \sigma)$  -- (7)
29.     return  $pose_{final}, w_{final}$ 

```

Алгоритм **pf_global_localization** принимает на вход набор ограничений, полученных от алгоритма **sdm_global_localization**, ряд значений параметров, облака точек с робота и карты. Функция **sample_element** выбирает один из кортежей интервалов случайным образом, но пропорционально общему размеру области, полученному путем произведения размеров всех интервалов. Функция **sample_particle** равновероятностно генерирует частицу, включающую в себя положение по осям x и y и углу так, что все значения принадлежат выбранным интервалам. Функция **random_shift** добавляет к частицам случайный белый шум с указанными параметрами. Функция **transform_cloud** производит геометрический перенос облака точек в координаты частицы. Функция **get_mean_p2p** производит расчет кратчайших расстояний между точками первого облака и точками второго облака. Функция **get_w** рассчитывает вес частицы согласно формуле (7). Функция **resampling** производит пере выборку частиц, функция **get_pose** рассчитывает положение робота одним из предложенных ранее способов, например, взятием взвешенного среднего, путем умножения матрицы частиц на вектор весов. Алгоритм возвращает положение робота и вес этого положения как критерий качества.

Таким образом, к каждой выбранной гипотезе о сопоставлении объектов сцены объектам карты последовательно применяются алгоритмы **sdm_global_localization** и **pf_global_localization**, в результате чего определяется набор решений с рассчитанными критериями качества, из которых выбирается лучшее по введенной метрике.

3. ЭКСПЕРИМЕНТАЛЬНОЕ ИССЛЕДОВАНИЕ

Экспериментальное исследование предложенной технологии было проведено на адаптированном открытом наборе данных KITTI-360 [35] для задачи распознавания сцен, предложенной в работе [32]. Подготовленные данные¹ содержат описания семантических карт и сцен в виде наборов объектов с указанием соответствий между этими множествами. В качестве входных данных для алгоритма **sdm_global_localization** были выбраны результаты работы метода распознавания сцен на основе поиска изоморфного подграфа *sig_lite_clip* [32] как показавшего лучшие результаты по метрике нахождения полностью верного ответа. Ответ для задачи распознавания сцен представляет собой соответствие между наблюдаемыми объектами и

объектами на карте, это соответствие используется для формирования задачи локализации по данным об ориентирах. Тем не менее, значительная часть ответов не содержала правильного ответа (когда все объекты сопоставлены корректно) на первом месте в упорядоченном по коэффициенту уверенности (численная оценка результатов распознавания сцен) списке гипотез. Чтобы проверить эффективность указанной технологии в работе с такими входными данными, были выбраны максимальные по коэффициенту уверенности десять ответов для каждой входной сцены.

Выбранные сцены были разбиты на несколько групп: *super_true*, *has_true* и *wrong*. Группа *super_true* соответствует тем результатам распознавания сцен, в которых правильный ответ сопоставления объектов сцены объектам карты присутствует и имеет самый высокий коэффициент уверенности среди выбранных десяти ответов. Группа *has_true* содержит ответы, среди которых есть правильный, но он имеет не самый высокий коэффициент уверенности среди остальных гипотез. Группа *wrong* содержит результаты, в которых нет полностью верных ответов. Размер групп соотносится как 68 % – 27% – 4 % к общему числу сцен, оставшееся число не было обработано методами распознавания. Все эксперименты были выполнены на компьютере с процессором AMD Ryzen7 2700X Eight-Core 3.70GHz и ОЗУ 32ГБ, графические ускорители не использовались.

Для полученных десяти гипотез для каждой сцены была проведена процедура Н-локализации (SDM, *Sub Definite Models*) с $N\sigma = 4$ в варианте с дополнительным разделением интервалов с $xy_lim = 10$ м, и без него (см. рис. 2). В варианте без дополнительного деления переменных оценивался результат, полученный на десятой строчке алгоритма **sdm_global_localization**. Полученные интервальные ограничения на положение робота для всех гипотез одной сцены оценивались на предмет точности интервалов и охвата интервалов (табл. 1). Точность интервалов рассчитывалась путем определения, принадлежит ли истинное положение робота, известное в используемом наборе данных, рассчитанным интервальным ограничениям (чем больше значение, тем лучше). Охват интервалов отражает сокращение области поиска. Он оценивался путем равномерного распределения миллиона частиц (положений робота) по площади всей карты, определения числа частиц, принадлежащих любому из полученных наборов ограничений, и взятию отношения полученного числа ко всему набору (чем меньше его значение, тем лучше).

¹ URL: https://github.com/MoscowskyAnton/scene_recognition_kitti_360



Таблица 1

Результаты тестирования подхода Н-локализации

Метод	Точность интервалов, %, ↑			Охват интервалов, %, ↓			t , с
	Группа			Группа			Все группы
	super_true	has_true	wrong	super_true	has_true	wrong	
SDM с делением	97,1	98	17,6	0,23	0,41	0,65	0,69
SDM без деления	99,8	100	37	3,22	4,44	0,37	0,03

Из табл. 1 видно, что группа *wrong*, в которой нет верного ответа, сильно отстает по точности интервалов. Также видна разница на порядок в охвате интервалов для варианта алгоритма с делением при небольшой потере точности интервалов относительно варианта без деления. Однако уменьшение охвата интервалов на порядок приводит к увеличению времени выполнения алгоритма на тот же порядок.

Для оценки точности определения положения робота предлагаемая технология сравнивалась с другими методами глобальной локализации. Все исследуемые подходы были реализованы автором лично либо взяты из открытых библиотек. Методы, работающие с результатом распознавания сцен, получали для каждой сцены на вход все десять вариантов и по численной оценке выбирали наилучший, для этого лучшего решения рассчитывались ошибки по положению и по углу и время исполнения. Ошибки оценивались при помощи математического ожидания ($\cdot$) медианы (M). Время работы метода распознавания сцен не учитывалось, однако для выбранного метода и выбранной последовательности составило $41,55 \pm 46,5$ с [32] на том же вычислительном оборудовании. Стоит отметить, что в наборе KITTI-360 облака точек для карты представлены не в монолитном варианте, а в виде нескольких пересекающихся областей (подкарт); там, где это возможно, выбиралась одна из подкарт, наиболее подходящая к области поиска. В исследовании были рассмотрены следующие подходы:

– **RANSAC+ICP** – классический подход к локализации исключительно по облакам точек с расчетом FPFH-дескрипторов [3], поиском их соответствий методом RANSAC [8] и дальнейшим уточнением с помощью ICP [12]. Данный подход был выбран для рассмотрения ввиду доступных открытых реализаций. Поиск соответствий методом RANSAC проводился для каждой подкарты, а уточнение ICP – для той позиции, которой соответствовало наибольшее значение меры *fitness*.

– **SVD** – метод локализации по данным распознавания сцен [19]. Качество решения для разных результатов распознавания сцен определялось средней ошибкой положения каждого объекта между сценой и картой.

– **SVD+ICP** – локализация по данным распознавания сцен методом SVD и дальнейшее уточнение полученного положения с помощью ICP по облакам точек. В качестве численной оценки использовался параметр *fitness* метода ICP.

– **SDM+PF** – предлагаемая в работе технология Н-локализации по ориентирам алгоритмом **sdm_global_localization** ($N\sigma = 4$, $x_{y_lim} = 10$ м) и использование ФЧ в ограничениях алгоритмом **pf_global_localization** ($N = 150$; $\sigma = 0,1$; $iter = 5$; $\Delta = (0,5; 0,1)$). В качестве решения выбиралась частица с наибольшим весом, который также служил критерием отбора решений для разных результатов распознавания сцен.

– **SDM+RANSAC+ICP** – подход **RANSAC+ICP**, который применялся к облаку точек, полученному на основе ограничений, рассчитанных алгоритмом **sdm_global_localization**. Рассчитанные ограничения были расширены на дальность работы дальности. В качестве меры оценки решений также бралось значение *fitness* метода ICP. Использовался вариант метода SDM без деления, остальные параметры соответствовали параметрам в **SDM+PF**.

Дополнительно для рассматриваемых результатов была рассчитана часто встречающаяся в задачах глобальной локализации метрика *recall@k* ($R@k$), показывающая процент попадания ответа в некоторую доверительную область для k ответов. В литературе [36, 37] для задачи глобальной локализации доверительная область выбирается, как правило, равной 20 м, исходя из соображения, что для решения данной задачи с практической точки зрения уже неважно, насколько сильно ошибка превышает это значение.

Численные результаты применения исследуемых методов для группы *super_true* приведены в табл. 2.

Таблица 2

Численные результаты экспериментов для группы решений *super_true*

Метод	$ r $, м	$M(r)$, м	$ \alpha $, рад	$M(\alpha)$, рад	$ t $, с	$M(t)$, с	$R@1$, %	$R@5$, %
RANSAC+ICP	233,3	190,1	0,71	0,12	4418,1	4171,5	37	—
SVD	4,7	2,3	0,26	0,06	0,005	0,004	94,4	95,6
SVD+ICP	39,5	1,6	0,29	0,06	18,6	17,7	94,9	96,1
SDM+PF	83,7	2,1	0,39	0,06	95,1	97,1	98,4	99,3
SDM+RANSAC+ICP	100,6	1,4	0,28	0,05	1009	976	69,4	83,7

По результатам, представленным в табл. 2, можно сделать вывод, что распространенный подход SVD без привязки к облакам точек значительно превосходит остальные методы практически по всем параметрам. Связано это с тем, что коэффициент уверенности, используемый для нормирования ответов в методах распознавания сцен, идеологически совпадает с метрикой оценки метода SVD, поэтому для группы *super_true* этот метод практически не ошибается с выбором гипотезы, выбирая самую высокую по коэффициенту уверенности, которая и является правильной. Это же видно в сравнении с расширением этого метода SVD + ICP, где значительно выросла средняя ошибка, так как появились сцены, где была предпочтена другая гипотеза, однако медианная ошибка в сравнении с SVD была уменьшена, что говорит о том, что более чем в половине случаев ICP смог улучшить положение по данным с облаков точек. Другие методы, использующие результаты распознавания сцен, показывают сравнимую медиану, но сильно увеличенное математическое ожидание из-за неверно выбранных гипотез, которые могут находиться на других концах карты, тем самым значительно повлияв на среднее значение. Влияние «удаленных» от верного ответа ошибок также косвенно подтверждается и превосходящими значениями $R@k$ для метода SDM + PF, поскольку метрика $R@k$ описывает пороговую оценку.

Результаты для группы *has_true* представляют больший интерес в рамках исследования, поскольку отражают возможность методов находить верный ответ в наборе близких гипотез. Численные результаты для данной группы приведены в табл. 3.

В табл. 3 в сравнении с табл. 2 метод SVD, который показывал лучшие результаты, значительно потерял в точности и демонстрирует одни из худших значений показателей. Это происходит ввиду того, что он не использует дополнительные данные в виде облаков точек, как это делают осталь-

ные методы, что подтверждает важность предлагаемого комбинированного подхода. Однако добавление коррекции с помощью ICP позволило значительно повысить точность и получить практически лучшие результаты по всем параметрам и хорошие временные показатели работы алгоритма. Показатели точности методов, основанных на результатах распознавания сцен и уточнения положения по облакам точек, в целом не сильно отличаются от группы *super_true* (см. табл. 2), что говорит о возможности нахождения решения среди множества близких гипотез. Сильное снижение значения метрики $R@1$ обусловлено неправильностью лучшего ответа в группе *has_true*, снижение значения метрики $R@5$ также происходит потому, что правильный ответ мог не попасть в пять лучших решений.

Группа решений, отнесенных к категории *wrong*, которая не содержит полностью верного ответа, тоже представляет интерес в задаче локализации по визуальным ориентирам, поскольку постановка содержит заведомо ложные данные. Численные результаты представлены в табл. 4.

По результатам экспериментов, представленным в табл. 4, можно сделать вывод о том, что отсутствие верного ответа от системы распознавания сцен отрицательно влияет на результаты (все показатели точности значительно снижаются в сравнении с табл. 2 и табл. 3), что свидетельствует о важности разработки робастных методов распознавания сцен. Предложенный подход Н-локализации на основе функций проверки корректности позволяет отбрасывать некоторые из гипотез, в среднем было отброшено 17,5 % всех обработанных гипотез и эта величина не сильно варьируется в пределах исследуемых групп (16,6; 20,1 и 18,5 % соответственно).

На рис. 3 представлены значения рассчитанных показателей $recall@1$ и $recall@5$ без деления на группы.

Предложенные методы на основе сокращения области поиска (SDM+PF и SDM+RANSAC+ICP) показывают сравнимые по точности результаты



Таблица 3


Численные результаты экспериментов для группы решений *has_true*

Метод	$ r $, м	$M(r)$, м	$ \alpha $, рад	$M(\alpha)$, рад	$ t $, с	$M(t)$, с	$R@1$, %	$R@5$, %
RANSAC+ICP	207,5	158,9	1	0,46	4038,3	4002	27,7	–
SVD	191,1	28,9	1,15	0,83	0,005	0,004	44,3	85,8
SVD+ICP	38,4	2	0,35	0,04	19,6	19,6	44,5	85,9
SDM+PF	80,4	1,5	0,29	0,05	94,8	95,6	62,2	63,9
SDM+RANSAC+ICP	71,5	6,7	0,22	0,03	911,2	878,3	61,5	84,6

Таблица 4

Численные результаты экспериментов для группы решений *wrong*

Метод	$ r $, м	$M(r)$, м	$ \alpha $, рад	$M(\alpha)$, рад	$ t $, с	$M(t)$, с	$R@1$, %	$R@5$, %
RANSAC+ICP	289	262,3	0,87	0,06	4501	4255	33,3	–
SVD	351	298,3	1,22	0,92	0,004	0,004	24,3	30,7
SVD+ICP	206,7	95,2	1,13	0,86	17,8	17,2	24,5	30,7
SDM+PF	203,4	150,8	1,34	1	79,1	83,4	25,7	25,7
SDM+RANSAC+ICP	210,5	285,5	0,59	0,07	1076,6	1030,9	13,3	20

Рис. 3. Распределения и средние значения $recall@k$ для исследованных методов: а – $recall@1$; б – $recall@5$

с подходом на основе SVD, в некоторых случаях превосходя их (см. рис. 3), что говорит о перспективности данного направления для решения задач глобальной локализации. Значения временных параметров работы алгоритмов, приведенные в исследовании, носят скорее ознакомительный характер, поскольку при реализации методов не возникали вопросы, связанные с программной оптимизацией. Подход на основе ФЧ с использованием

поточечного расстояния для сравнения облаков обладает ограничением: он показывает хорошие результаты только вблизи верного ответа и с небольшими отклонениями по углу. Исследование и применение более чувствительных метрик сравнения облаков точек, в том числе с учетом их цветовых характеристик, также потенциально улучшит результат. Отдельно стоит отметить, что метод SDM+RANSAC+ICP показал как значительное

увеличение точности, так и уменьшение времени вычисления в сравнении с классическим подходом RANSAC+ICP, что говорит о возможности использования технологии сокращения пространства поиска на основе Н-локализации и для других методов глобальной локализации по облакам точек.

ЗАКЛЮЧЕНИЕ

В работе описан подход недоопределенной локализации, предложенный в рамках комплексной технологии глобальной локализации робота на трехмерных картах, снабженных семантическим слоем. Распознавая и локализуя объекты, находящиеся в поле зрения робота, можно решить задачу распознавания сцен, сопоставив их с объектами карты. По полученным данным с помощью подхода недоопределенной локализации определяются ограничения на положение робота, которые, в свою очередь, могут быть использованы для сокращения области поиска методом локализации на основе данных дальномеров.

Проведенные эксперименты показывают, что методы локализации по облакам точек, примененные в ограничениях, полученных предлагаемой комплексной технологией, значительно повышают точность и быстродействие алгоритма в сравнении с базовым подходом глобальной локализации без учета семантики. Сокращение зоны поиска до 0,2 % от размера карты позволяет говорить о применимости авторской технологии для любых методов локализации по данным дальномеров. Также эксперименты показали, что комбинирование методов локализации по ориентирам с методами локализации по облакам точек позволяет работать в ситуации, когда верный ответ распознавания сцен «затерян» среди нескольких близких друг к другу гипотез. Таким образом, результаты, полученные по итогам проведенных экспериментов, позволяют считать, что цель исследования, определенная как улучшение качества глобальной локализации, достигнута. Повышение качества работы алгоритма происходит благодаря применению недоопределенных вычислений, которые используются в рамках комплексной технологии локализации с использованием семантических карт.

Дальнейшим направлением работ предполагается исследование и применение более чувствительных методов регистрации облаков точек для увеличения точности определения положения робота и оценки гипотез. В дополнение целесообразно рассмотреть предлагаемый подход во взаимодействии с методами Place Recognition для сокращения пространства поиска среди имеющихся

ключевых кадров, которые зачастую снабжаются координатной меткой, по которой можно определить соответствие полученным в ходе Н-локализации ограничениям. Стоит отметить, что перспективной задачей является многокритериальная оптимизация параметров используемых методов, требующая значительных вычислительных ресурсов, однако она выходит за рамки данной работы, в которой параметры были выбраны эмпирическим путем.

ЛИТЕРАТУРА

1. Chen, P., Zhao, X., Zeng, L., et al. A Review of Research on SLAM Technology Based on the Fusion of LiDAR and Vision // *Sensors*. – 2025. – Vol. 25, no. 5. – Art. no. 1447.
2. Yin, H., Xu, X., Lu, S., et al. A Survey on Global LiDAR Localization: Challenges, Advances and Open Problems // *Int. J. Comput. Vis.* – 2024. – Vol. 132, no. 8. – P. 3139–3171.
3. Rusu, R.B., Blodow, N., Beetz, M. Fast Point Feature Histograms (FPFH) for 3D Registration // *Proceedings of 2009 IEEE International Conference on Robotics and Automation*. – Kobe, Japan, 2009. – P. 3212–3217.
4. Saarinen, J., Andreasson, H., Stoyanov, T., et al. Normal Distributions Transform Monte-Carlo Localization (NDT-MCL) // *proceedings of 2013 IEEE/RSJ International Conference on Intelligent Robots and Systems*. – Tokyo, Japan, 2013. – P. 382–389.
5. Mildenhall, B., Srinivasan, P.P., Tancik, M., et al. NeRF: Representing Scenes as Neural Radiance Fields for View Synthesis // *Commun. ACM*. – 2022. – Vol. 65, no 1. – P. 99–106.
6. Komorowski, J. MinkLoc3D: Point Cloud Based Large-Scale Place Recognition // *Proceedings of 2021 IEEE Winter Conference on Applications of Computer Vision (WACV)*. – Waikoloa, HI, USA, 2021. – P. 1789–1798.
7. Rosen, D.M., Doherty, K.J., Terán Espinoza, A., et al. Advances in Inference and Representation for Simultaneous Localization and Mapping // *Annu. Rev. Control. Robot. Auton. Syst.* – 2021. – Vol. 4, no. 1. – P. 215–242.
8. Fishler, M., Bolles, R. Random Sample Consensus: A Paradigm for Model Fitting Applications to Image Analysis and Automated Aartography // *Communication of the ACM*. – 1981. – Vol. 24. – P. 381–395.
9. Yang, H., Shi, J., Carlone, L. TEASER: Fast and Certifiable Point Cloud Registration // *IEEE Trans. Robot.* – 2021. – Vol. 37, no. 2. – P. 314–333.
10. Lusk, P.C., How, J.P. CLIPPER: Robust Data Association Without an Initial Guess // *IEEE Robot. Autom. Lett.* – 2024. – Vol. 9, no. 4. – P. 3092–3099.
11. Choy, C., Dong, W., Koltun, V. Deep Global Registration // *Proceedings of 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. – Seattle, WA, USA, 2020. – P. 2511–2520.
12. Rusinkiewicz, S., Levoy, M. Efficient Variants of the ICP Algorithm // *Proceedings of 3rd International Conference on 3-D Digital Imaging and Modeling*. – Quebec City, Canada, 2001. – P. 145–152.
13. Vizzo, I., Guadagnino, T., Mersch, B., et al. KISS-ICP: In Defense of Point-to-Point ICP – Simple, Accurate, and Robust



- Registration If Done the Right Way // IEEE Robot. Autom. Lett. – 2023. – Vol. 8, no. 2. – P. 1029–1036.
14. Barfoot, T.D. State Estimation for Robotics. – Cambridge: Cambridge University Press, 2017.
 15. Chen, R., Yin, H., Jiao, Y., et al. Deep Samplable Observation Model for Global Localization and Kidnapping // IEEE Robot. Autom. Lett. – 2021. – Vol. 6, no. 2. – P. 2296–2303.
 16. Zhang, X., Wang, L., Su, Y. Visual Place Recognition: A Survey from Deep Learning Perspective // Pattern Recognit. – 2021. – Vol. 113. – Art. no. 107760.
 17. Xia, L., Cui, J., Shen, R., et al. A Survey of Image Semantics-Based Visual Simultaneous Localization and Mapping: Application-Oriented Solutions to Autonomous Navigation of Mobile Robots // Int. J. Adv. Robot. Syst. – 2020. – Vol. 17, no. 3. – Art. no. 172988142091918.
 18. Jin, X., Li, X., Zhu, Y., et al. A Survey of Visual Semantic Mapping // Proceedings of 2022 3rd Asia-Pacific Conference on Image Processing, Electronics and Computers. – New York, NY, USA, 2022. – P. 295–301.
 19. Arun, K.S., Huang, T.S., Blostein, S.D. Least-Squares Fitting of Two 3-D Point Sets // IEEE Trans. Pattern Anal. Mach. Intell. – 1987. – Vol. PAMI-9, no. 5. – P. 698–700.
 20. Pramatarov, G., De Martini, D., Gadd, M., et al. BoxGraph: Semantic Place Recognition and Pose Estimation from 3D LiDAR // arXiv:2206.15154v1. – 2022. – DOI: 10.48550/arXiv.2206.15154
 21. Wu, Y., Zhang, Y., Zhu, D., et al. An Object SLAM Framework for Association, Mapping, and High-Level Tasks // arXiv:2305.07299. – 2023. – DOI: <https://doi.org/10.48550/arXiv.2305.07299>
 22. Ankenbauer, J., Lusk, P.C., Thomas, A., et al. Global Localization in Unstructured Environments Using Semantic Object Maps Built from Various Viewpoints // Proceedings of 2023 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). – Detroit, MI, USA, 2023. – P. 1358–1365.
 23. Guo, X., Hu, J., Chen, J., et al. Semantic Histogram Based Graph Matching for Real-Time Multi-Robot Global Localization in Large Scale Environment // IEEE Robot. Autom. Lett. – 2021. – Vol. 6, no. 4. – P. 8349–8356.
 24. Wang, Y., Jiang, C., Chen, X. GOREloc: Graph-Based Object-Level Relocalization for Visual SLAM // IEEE Robot. Autom. Lett. – 2024. – Vol. 9, no. 10. – P. 8234–8241.
 25. Matsuzaki, S., Sugino, T., Tanaka, K., et al. CLIP-Loc: Multimodal Landmark Association for Global Localization in Object-based Maps // Proceedings of 2024 IEEE International Conference on Robotics and Automation (ICRA). – Yokohama, Japan, 2024. – P. 13673–13679.
 26. Liu, Y., Petillot, Y., Lane, D., et al. Global Localization with Object-Level Semantics and Topology // Proceedings of 2019 International Conference on Robotics and Automation (ICRA). – Montreal, Canada, 2019. – P. 4909–4915.
 27. Handbook of Constraint Programming / Ed. by Rossi F., van Beek P., Walsh T. – Amsterdam: Elsevier, 2006. – 978 p.
 28. Нариньяни А.С. Введение в недоопределенность // Информационные технологии. – 2007. – № 4. – С. 1–32. [Nariniany, A.S. Introduction to Subdefinitions // Informational Technologies. – 2007. – No. 4. – P. 1–32. (In Russian)]
 29. Moscovsky, A. Subdefinite Computations for Reducing the Search Space in Mobile Robot Localization Task / In: Artificial Intelligence. RCAI 2021. Ed. by S.M. Kovalev, S.O. Kuznetsov, and A.I. Panov. – Lecture Notes in Computer Science. – Cham: Springer, 2021. – Vol. 12948.
 30. Moscovsky, A.D. Extended Object Detection: Flexible Object Description System for Detection in Robotic Tasks / In: Smart Electromechanical Systems. Ed. by A.E. Gorodetskiy, and I.L. Tarasova. – Studies in Systems, Decision and Control. – Cham: Springer, 2022. – Vol. 419. – P. 27–43.
 31. Contreras, M., Jain, A., Bhatt, N.P., et al. A survey on 3D Object Detection in Real Time for Autonomous Driving // Front. Robot. AI. – 2024. – Vol. 6, no. 11. – Art. no. 1212070
 32. Московский А.Д. Распознавание сцен в задаче глобальной локализации мобильного робота с использованием моделей векторных представлений изображений и графовых подходов // Управление большими системами. – 2025. – № 114. – С. 307–344. [Moscowsky, A.D. Scene Recognition for the Mobile Robot Global Localization Problem Based on Image Vectorization and Graphs Approaches // Large-Scale Systems Control. – 2025. – No. 114. – P. 307–344. (In Russian)]
 33. Radford, A., Kim, J.W., Hallacy, C., et al. Learning Transferable Visual Models from Natural Language Supervision // Proceedings of International Conference on Machine Learning. – Vienna, Austria, 2021. – P. 8748–8763.
 34. Баженов А.Н., Жилин С.И., Кумков С.И., и др. Обработка и анализ интервальных данных. – Москва, Ижевск: Институт компьютерных исследований, 2024. – 356 с. [Bazhenov, A.N., Zhilin, S.I., Kumkov, S.I., et al. Processing and Analysis of Interval Data. – Moscow, Izhevsk: Institute of computer researches, 2024. – 356 p. (In Russian)]
 35. Liao, Y., Xie, J., Geiger, A. KITTI-360: A Novel Dataset and Benchmarks for Urban Scene Understanding in 2D and 3D // IEEE Trans. Pattern Anal. Mach. Intell. – 2023. – Vol. 45, no. 3. – P. 3292–3310.
 36. Keetha, N., Mishra, A., Karhade, J., et al. Anyloc: Towards Universal Visual Place Recognition // arXiv:2308.00688. – 2023. – DOI: <https://doi.org/10.48550/arXiv.2308.00688>
 37. Puligilla, S., Omata, M., Zaidi, H., et al. LIP-Loc: LiDAR Image Pretraining for Cross-Modal Localization // Proceedings of 2024 IEEE/CVF Winter Conference on Applications of Computer Vision Workshops (WACVW). – Waikoloa, HI, USA, 2024. – P. 939–948.

*Статья представлена к публикации членом редколлегии
Р. В. Мецержковым.*

*Поступила в редакцию 05.05.2025,
после доработки 12.05.2025.
Принята к публикации 16.07.2025.*

Московский Антон Дмитриевич – начальник группы, Национальный исследовательский центр «Курчатовский институт», г. Москва

✉ moscovskyad@yandex.ru

ORCID iD: <https://orcid.org/0000-0002-6546-8697>

© 2025 г. Московский А. Д.



Эта статья доступна по лицензии Creative Commons «Attribution» («Атрибуция») 4.0 Всемирная.

APPLICATION OF SUBDEFINITE MODELS IN THE GLOBAL LOCALIZATION OF A MOBILE ROBOT

A. D. Moscovsky

National Research Center "Kurchatov Institute," Moscow, Russia

✉ moscovskyad@yandex.ru

Abstract. This paper considers the application of subdefinite (SD) models, a variation of constraint programming, to the localization problem of a mobile robot. A complex technology with semantic maps and point cloud maps is proposed. The technology is intended to accelerate and increase the accuracy of global localization in large, symmetric, and periodic environments. The conventional localization approach is based on data from rangefinders generating point clouds; the idea proposed instead is, first, to match the objects observed by the robot to those on the semantic map (recognize the scene), and then apply SD computations to perform localization via visual landmarks. SD computations are used to determine interval constraints on the robot's positions, represented by several sets for each hypothesis obtained during the scene recognition. Within the interval constraints, the robot is localized using rangefinder data based on a particle filter initialized within these constraints. According to the experiments conducted on the open KITTI-360 dataset, localization based on SD computations can reduce the search space to 0.2% of the original map size. The complex technology shows a significant advantage compared to approaches involving point clouds or visual landmarks only, especially in scenarios with multiple hypotheses about the matches of observed objects and those on the semantic map.

Keywords: global localization, subdefinite models, constraint programming, scene recognition, semantic maps, mobile robot.

Acknowledgments. This work was carried out under the state assignment of the National Research Center "Kurchatov Institute."