

УДК 681.5.015

## МЕТОДИКА МОДЕЛИРОВАНИЯ 3D ДИНАМИЧЕСКОЙ СРЕДЫ НА ОСНОВЕ ТЕОРЕМЫ БАЙЕСА

А.В. ГОСПОД

(Могилёвский государственный университет продовольствия)

*Демонстрируется новый вероятностный подход в изучении пространственных представлений динамической окружающей среды с помощью 3D-лазерных измерений. Показано, что предлагаемый метод может применяться в режиме реального времени даже при наличии большого количества динамических объектов, в отличие от большинства ранее разработанных методик, которые затратны в вычислительном плане при рассмотрении данного вопроса. Существуют способы для изучения активности переднего плана изображения. Однако они, как правило, не учитывают неопределенности, полученные в процессе зондирования. Сделан вывод, что проблема обнаружения динамических объектов может быть решена онлайн при помощи последовательной структуры Байеса. Все параметры, участвующие в процессе обнаружения, подчиняются вероятностной интерпретации. При использовании в реальных условиях, результаты, получаемые предложенным методом, могут применяться для решения различных задач, таких как навигация робота, создание карт, определение локализаций.*

**Введение.** В робототехнике всё более популярной темой исследований становится понимание динамических свойств окружающей среды. Обнаружение движущихся объектов в поле зрения датчиков робота может, например, испортить локализацию или построение карты [1–3]. С другой стороны, новые подходы планирования направлены на навигацию в динамических средах [4; 5], поэтому они сильно полагаются на оценки параметров движения объектов, которые потенциально могут помешать траектории робота. Широко распространенная группа методов, касающихся оценки движения, стремится к тому, чтобы отслеживать перемещение целых точечных скоплений [6]. Благодаря таким подходам удалось получить параметрическое описание движения облака точек, но они обычно принимают допущения относительно размера или формы объектов, что приводит к ограничению числа классов объектов. Необходимо же обнаружить только параметры движения, а не все параметры окружающей среды.

В данной работе мы предлагаем новый подход получения 3D-модели динамической среды. Используя модель компьютерного зрения [7], этот вопрос представляет собой бинарную задачу. То есть для серии наблюдений мы стремимся оценить точечные измерения в зависимости от статического или динамического объекта. Следовательно, моделируем с помощью распределения Гаусса [8; 9].

Известны стандартные методы изучения гауссовых смесей, неуспешные из-за нестационарного характера динамической окружающей среды [10]. Поэтому предлагается решение в режиме реального времени, в котором не делается никаких предположений о количестве гауссианов в модели, но эффективно изменяется с усложнением окружающей среды. Даже при большом количестве настроек предложенный подход способен различать динамические и статические объекты в реальном времени.

**Вероятностные формулировки.** Предлагаемый алгоритм создает 3D-облако точек на основе данных от 2D-датчика [11]. Данные от датчика  $z_t$  представлены в виде функции  $(r_t, \vartheta_t, \phi_t)$ , где  $r_t$  – диапазон измерений;  $\vartheta_t$  и  $\phi_t$  – соответственно тангаж и рыскание лазерного луча в момент времени  $t$ . Предполагая, что  $r_t$  зависит от гауссовых шумов, имеем  $r_t \sim N(\hat{r}_t, \sigma_r)$ , где  $\hat{r}$  – истинное расстояние между лазером и наблюдаемым объектом.

Так как не учитываем неопределенности  $\vartheta$  и  $\phi$ , то представляем данные датчика как матрицу  $N \times M$  с элементами  $c_{ij}$ , являющимися дискретизацией непрерывного пространства  $S = [-\vartheta_{max}, \vartheta_{max}] \times [-\phi_{max}, \phi_{max}]$ , где для тангажа и рыскания границы предопределены. Таким образом, для каждого  $z_t$  можно вычислить вектор в 3D-координатах  $z_t^{[i,j]}$ , где  $i$  и  $j$  индексы элементов  $c_{ij}$ , соответствующие  $r_t$ .

Для математической формулировки данного вопроса введем бинарную фиксированную переменную  $x_t$ , которая принимает значение true, если наблюдение  $z_t$  соответствует динамическому объекту, в противном случае – false. Нашей целью является оценка  $x_t$  в любой момент времени  $t$ , с учетом погрешностей измерения  $z_t$ . Поэтому формально мы находим  $p(x_t|z_t)$ . Предполагая статистическую независимость между всеми диапазонами изображений элементов, можно оценить апостериорную вероятность для измеренного диапазона динамического объекта  $\bar{x}_t = \{x_t^{[i,j]}\}$  с учетом диапазона изображения  $\bar{z}_t = \{z_t^{[i,j]}\}$ :

$$p(\bar{x}_t|\bar{z}_t) = \prod_{i,j} p(x_t^{[i,j]}|z_t^{[i,j]}) \tag{1}$$

Для лаконичности, далее индексы  $[i, j]$  будут опущены, а все расчеты будут выполнены на уровне ячейки. Следовательно, условный оператор  $p(x_i|z_i)$ , ассоциированный с каждым элементом, теперь должен быть отнесен к апостериорному элементу.

**Разработка модели с помощью гауссовой смеси.** Чтобы определить  $x_i$ , предполагаем, что каждое наблюдение  $z_i$  обусловлено одним из  $K$  объектов, которые могут быть статическими или динамическими. Слепая зона лазера моделируется с помощью нормального распределения  $N(\mu_k, \sigma_k)$ , где  $\mu_k$  – математическое ожидание,  $\sigma_k$  – дисперсия,  $k \in \{1, \dots, K\}$ . Для каждого элемента, таким образом, моделируется свой набор параметров модели, которые в дальнейшем будем обозначать  $\Theta = \{K, \mu_1, \dots, \mu_K, \sigma_1, \dots, \sigma_K\}$ . Для выражения факта соответствия  $z_i$  объекту  $k$  введем бинарную переменную  $g_i^k$ , где только один  $g_i^k$  может быть истинным для любого  $z_i$ .

**Расщепление апостериорного элемента.** Предложенная модель изменяется в режиме реального времени. Следовательно,  $\Theta_i$  представляет собой набор параметров, полученных в каждый момент времени. Параметры модели неизвестны, как и  $x_i$ , и должны быть выведены. То есть в каждый момент времени будет возникать вопрос, как обновить предыдущую оценку параметров  $\Theta_{i-1}$  с учетом последних наблюдений  $z_i$ . Поэтому  $\Theta_i$  и  $\Theta_{i-1}$  должны быть определены в вероятностной интерпретации и должны быть переписаны апостериорные элементы из (1) в виде

$$p(x_i, \Theta_i | z_i, \Theta_{i-1}) = p(x_i | z_i, \Theta_i, \Theta_{i-1}) p(\Theta_i | z_i, \Theta_{i-1}) = p(x_i | z_i, \Theta_i) p(\Theta_i | z_i, \Theta_{i-1}). \quad (2)$$

Таким образом, уравнение (2) описывает модель  $\Theta_i$ , что дает полное описание основного процесса. В этом уравнении имеется два условных оператора, которые необходимы для нахождения апостериорных элементов. Первый условный оператор описывает назначение бинарных состояний  $x_i$ , предполагая, что все параметры  $\Theta_i$  известны. Поэтому должен быть введен второй, определяющий вероятность динамики и включающий в себя искомую модель  $\Theta_i$ , полученную из данных  $z_i$  и  $\Theta_{i-1}$ . Итак, получили алгоритм корректировки.

**Вероятность динамики.** Выражая динамику вероятностью, как в [7], имеем:

$$p(x_i | z_i, \Theta_i) = \frac{p(x_i, z_i | \Theta_i)}{p(z_i | \Theta_i)} = \frac{\sum_{k=1}^K p(x_i, z_i | g_i^k, \Theta_i^k) p(g_i^k | \Theta_i^k)}{\sum_{k=1}^K p(z_i | g_i^k, \Theta_i^k) p(g_i^k | \Theta_i^k)} = \frac{\sum_{k=1}^K p(x_i | g_i^k, \Theta_i^k) p(z_i | g_i^k, \Theta_i^k) p(g_i^k | \Theta_i^k)}{\sum_{k=1}^K p(z_i | g_i^k, \Theta_i^k) p(g_i^k | \Theta_i^k)}. \quad (3)$$

Здесь представлены параметры объекта  $\Theta_i^k = \{\mu_i^k, \sigma_i^k\}$  и переменная состояния  $x_i^k$ , определенная гауссианом, динамическим или статическим. Также предполагаем, что вероятность  $z_i$  одинакова для динамических и статических объектов и обусловлена  $k$ -м объектом. Что приводит к условной независимости отношения  $p(x_i^k, z_i | g_i^k, \Theta_i^k) = p(x_i^k | g_i^k, \Theta_i^k) p(z_i | g_i^k, \Theta_i^k)$ .

Из (3) необходимо определить три слагаемых. Примечательно, что  $p(g_i^k | \Theta_i^k)$  – априорная вероятность для  $z_i$   $k$ -го объекта. Обычно  $p(g_i^k | \Theta_i^k)$  называют весом  $k$ -го гауссиана и обозначают  $w_i^k$ . Второе – вероятность того, что данные  $p(z_i | g_i^k, \Theta_i^k)$  равны  $N(z_i; \mu_i^k, \sigma_i^k)$ . И наконец, вероятность динамики  $k$ -го гауссиана, определенная как  $p(x_i^k | g_i^k, \Theta_i^k)$ .

**Правило корректировки.** Запишем правило корректировки так же, как и вероятность динамики:

$$p(\Theta_i | z_i, \Theta_{i-1}) = \sum_{k=1}^K p(\Theta_i^k | z_i, g_i^k, \Theta_{i-1}^k) p(g_i^k | z_i, \Theta_{i-1}^k). \quad (4)$$

Это дает два дополнительных условия: вероятность  $p(g_i^k | z_i, \Theta_{i-1}^k)$  представляет собой статистический закон для выбора  $k$ -го гауссиана в качестве условного обозначения  $z_i$ ; правило корректировки  $k$ -го гауссиана обозначим через  $p(\Theta_i^k | z_i, g_i^k, \Theta_{i-1}^k)$ .

**Вес смеси.** Предполагается, что каждое наблюдение вызвано только одним объектом. Это связано с жестким присвоением точке данных в кластерах. Значит, можно сказать, что каждая точка данных, полученная в дискретном времени с шагом 1, ...,  $t$ , отнесена к  $k$ -му кластеру, где каждому кластеру соответствует гауссиан.

Выражая количество наблюдений как  $n_t^k$ , которое соответствует  $k$ -му кластеру в момент времени  $t$ , можно оценить априорную вероятность нового наблюдения  $z_t$ :

$$p(g_t^k | \Theta_t^k) = w_t^k = \frac{n_t^k}{t}. \quad (5)$$

Отметим, что, зная  $t$ ,  $n_t^k$  становится эквивалентно представлению веса смеси  $w_t^k$ .

**Онлайн-оценка параметров смеси.** Представлена реализация онлайн-оценки моделируемых параметров. Как было указано выше, можно вычислить апостериорную вероятность наблюдения  $z_t$  от динамического объекта в два этапа: первый – применяется правило корректировки по (4) и переоценка параметров смеси  $\Theta_t$  относительно  $\Theta_{t-1}$ ; второй, используя вероятность динамики из (3) на скорректированных моделях смеси, – выводим новую переменную  $x_t$ .

В отличие от [8], здесь строго регулируется последовательная корректировка моделей смеси статистическими плотностями и законами вероятности. Таким образом, ключевым вкладом является интеграция новых наблюдений в существующую смесь.

Поиск оптимального значения параметров для  $\Theta_t$ , обусловленных  $\Theta_{t-1}$  и  $z_t$ , соответствует максимизации скорректированной вероятности  $p(\Theta_t | z_t, \Theta_{t-1})$ . В связи с этим необходимо пересмотреть вероятностное правило корректировки (4). Это предполагает в целях максимизации  $p(\Theta_t | z_t, \Theta_{t-1})$  в первую очередь восстановить оптимальное назначение для отображения соответствия переменных  $g_t^k$ .

Так как каждое наблюдение  $z_t$  соответствует только одному объекту, то необходимо определить, есть ли уже в смеси данные от датчика  $z_t$  объекта  $k \in \{1, \dots, K\}$ . Исходя из [12] введем вероятность и оценку соответствия относительно двух различных случаев.

*Возможное:* наблюдение  $z_t$  можно объяснить  $k$ -м гауссианом в текущей модели смеси. Рассмотрим диапазон измерений  $r_t$ , обусловленный  $z_t$  и помехами  $\sigma_r$ . Кроме того, пусть  $\theta_{t-1}^k$  параметр  $k$ -го гауссиана распределения смеси, который объясняет  $z_t$ . Тогда наша модель предполагает, что  $p(z_t | g_t^k) \sim N(\mu_{t-1}^k, \sigma_{t-1}^k + \sigma_r)$ . Отметим, что суммирование дисперсий  $\sigma_r$  и объекта  $\sigma_{t-1}^k$  позволяет определить шум в обеих моделях.

*Невозможное:* наблюдение не может быть объяснено с помощью любого из  $k$  гауссианов в текущей модели смеси. Не делая допущение о том, как незаметно появляются объекты в диапазоне сенсора, предполагаем равномерное распределение по всей длине луча. Следовательно, мы определяем  $p(z_t | g^{new}) \sim U(0, r_{max})$ , где  $U$  – равномерное распределение в пределах  $[0, r_{max}]$ , а  $g^{new}$  – новый гауссиан для  $z_t$ .

Определим  $p_{new} = p(g^{new})$  и применим теорему Байеса относительно  $p(g^{new} | z_t)$  для вероятности генерируемых непредставленных объектов:

$$p(g^{new} | z_t) = \frac{p(z_t | g^{new}) \cdot p_{new}}{p(z_t | g^{new}) \cdot p_{new} + p(z_t | g_t^k) \cdot (1 - p_{new})}. \quad (6)$$

Тогда, предполагая, что  $p(z_t | g^{new})$  мало, можно аппроксимировать логарифм этого выражения:

$$\log p(g^{new} | z_t) \approx \log \frac{p(z_t | g^{new}) \cdot p_{new}}{p(z_t | g_t^k) \cdot (1 - p_{new})} = \log p(z_t | g^{new}) + \log p_{new} - \log p(z_t | g_t^k) - \log(1 - p_{new}). \quad (7)$$

Используя предположения модели из описанных выше случаев, имеем

$$\log p(g^{new} | z_t) \approx -\log r_{max} + \log p_{new} - \log(1 - p_{new}) + \frac{1}{2} \log 2\pi(\sigma_{t-1}^k + \sigma_r) + \frac{1}{2} \frac{(r_t - \mu_{t-1}^k)^2}{(\sigma_{t-1}^k + \sigma_r)}. \quad (8)$$

Объединив все выражения относительно диапазона измерений  $r_t$ , получим простое квадратичное отклонение

$$d_k(r_t) = (r_t - \mu_{t-1}^k)^T (\sigma_{t-1}^k + \sigma_r)^{-1} (r_t - \mu_{t-1}^k). \quad (9)$$

Если предполагать, что необъяснимые наблюдения с вероятностью  $p(g^{new}|z_t) > 0,5$  значительны, то отклонение

$$d_k^{min} = 2 \log 0,5 + 2 \log r_{max} - 2 \log p_{new} + 2 \log(1 - p_{new}) - \log 2\pi(\sigma_{t-1}^k + \sigma_r). \quad (10)$$

В итоге имеем, что при  $d_k(r) < d_k^{min}$   $k$ -й гауссиан объясняет наблюдение  $z_t$ .

Представленный метод пока что позволяет только выбрать множество гауссианов из смеси. Поэтому далее, если найдем любой гауссиан для  $z_t$ , жестко определим  $z_t$  к  $k$ -му кандидату гауссиана с минимальным отклонением  $d_k(r)$ , что равносильно выбору объекта с максимальной вероятностью  $p(g_i^k|z_t) = 1 - p(g^{new}|z_t)$ . Тогда максимизируем (4), вычисляя онлайн-оценки максимальной вероятности для  $k$ -го гауссиана. Последовательный подход необходим, чтобы найти максимальную вероятность для параметров гауссового распределения, что позволяет обрабатывать наблюдения  $z_t$  по очереди [13].

В случаях если нет ни одного кандидата гауссиана, наблюдаемый объект представляют вводом нового гауссиана  $K+1$  в смесь. Этот гауссиан определяется средними  $r_t$  и  $\sigma_r$ .

В качестве исходных данных алгоритм для последовательной корректировки параметров принимает диапазон измерений  $r_t$  и соответствующее распределение смеси клеток  $M_{t-1}$ , а взамен выдает скорректированную плотность  $M_t$ .

**А л г о р и т м .** Корректировка смеси ( $M_{t-1}, r_t$ )

**Ввод:** Гауссова смесь  $M_{t-1} = \{n_{t-1}^1, \theta_{t-1}^1, \dots, n_{t-1}^K, \theta_{t-1}^K\}$

**Ввод:** Показания датчика  $r_t$

**Вывод:** Скорректированная гауссовая смесь  $M_t$

$M_{cand} \leftarrow \emptyset$

**for each**  $n_{t-1}^k, \theta_{t-1}^k \in M_{t-1}$  **do**

    вычислить  $d_k(r_t)$  и  $d_k^{min}$  согласно (9) и (10)

**if**  $d_k(r_t) < d_k^{min}$  **then**

$M_{cand} \leftarrow M_{cand} \cup \{n_{t-1}^k, \theta_{t-1}^k\}$

**end if**

**next**

**if**  $M_{cand} \neq \emptyset$  **then**

$n_{t-1}^k, \theta_{t-1}^k \leftarrow$  минимальный аргумент  $d_k(r_t)$

$n_{t-1}^l, \theta_{t-1}^l \in M_{cand}$

$M_t \leftarrow M_{t-1} \setminus \{n_{t-1}^k, \theta_{t-1}^k\}$

$n_t^k \leftarrow n_{t-1}^k + 1$

$\theta_t^k \leftarrow$  скорректированный гауссиан ( $\theta_{t-1}^k, r_t$ )

$M_t \leftarrow M_t \cup \{n_t^k, \theta_t^k\}$

**else**

$n_t^{K+1} \leftarrow 1$

$\theta_t^{K+1} \leftarrow \{\mu_t^{K+1} \leftarrow r_t, \sigma_t^{K+1} \leftarrow \sigma_r\}$

$M_t \leftarrow M_{t-1} \cup \{n_t^{K+1}, \theta_t^{K+1}\}$

**End if**

Коллапс смеси ( $M_t$ )

Предложенный алгоритм использует две вспомогательные функции. Первая корректирует гауссиан, последовательно определяя среднее арифметическое и дисперсию из лучших кандидатов гауссианов относительно  $r_t$ . Вторая функция следит за устойчивостью смеси – это абстрактный механизм присоединения гауссианов, которые разделяют значительную долю фиксированного пространства. Это следует из природы плотности смеси  $p(z_t|\Theta_t)$ , которая фактически является шумом модели среды, обусловленным

несовершенством датчика, отображенным в новых гауссианах исключительно априорно. Фактически дисперсия каждого гауссиана может выйти за пределы начальной неопределенности, например, при определении прерывистой поверхности.

Для парной идентификации гауссианов используется отклонение из (10), как и для ассоциирования зашумленных наблюдений с более подходящими кандидатами. Преимущество такой реализации состоит в том, что вместо введения нового параметра на каждом шаге корректировки можно повторно использовать априорную вероятность  $p_{new}$  при возникновении неопределенных объектов. Следовательно, общее количество  $K$  гауссианов, содержащееся в смеси, связано с предположениями модели и не требует искусственной фиксации, как в [14].

**Вычисление вероятности динамики.** Как скорректировать параметры распределения гауссовой смеси, которая способна представлять наблюдения в статистически независимом диапазоне изображения элементов, рассмотрено выше. Но представленная модель пока что не имеет оценку бинарных состояний переменной  $x_t^k$ .

Из вероятности динамики, согласно (3), известно, что условная плотность  $p(x_t^k | g_t^k, \Theta_t^k)$  определяет методику, которая основана на весовом коэффициенте  $k$ -го гауссиана в распределении смеси.

Чтобы вычислить вероятность динамики  $k$ -го гауссиана, используется метод, описанный в [8]. Он основан на том, что большинство наблюдаемых объектов обычно статические. Это означает, что точки данных, чаще всего наблюдаемые, скорее, принадлежат статическому объекту. При моделировании каждого гипотетически возникшего объекта  $k$ -м гауссианом, согласно (5), количество наблюдений от  $k$ -го объекта кодируется в весовую смесь  $w_k$ , которую можно оценить с помощью вероятности  $p(x_t^k | g_t^k, \Theta_t^k)$  следующим образом: во-первых, сортируем все веса  $w_k$  в порядке убывания, затем вычисляем количество гауссианов  $K_s$ , которое, скорее всего, равно количеству статических объектов:

$$K_s = \arg \min_l \left\{ \sum_{k=1}^l w_{s(k)} > \rho \right\}, \quad (11)$$

где  $s(k)$  – индекс веса  $w_k$  после сортировки;  $\rho \in [0, 1]$  – параметр, зависящий от статической части окружающей среды;  $(K - K_s)$  гауссианов в отсортированной смеси соответствуют динамическим объектам.

Таким образом, чем меньше  $\rho$ , тем больше вероятность того, что гауссиан динамический.

Используя (11), аппроксимируем вероятность динамики:

$$p(x_t^k | g_t^k, \Theta_t^k) = \begin{cases} 1, & \text{если } s(k) > K_s; \\ 0, & \text{иначе.} \end{cases} \quad (12)$$

**Сложность вычислений.** Рассмотрим вычислительные затраты предложенного метода. Анализ шагов, предпринятых для корректировки параметров модели  $\Theta_t$ , дает новое наблюдение  $z_t$  для перерасчета переменной  $x_t$ .

Повторный расчет элементов смеси в основном зависит от поиска лучшего кандидата и от парного коллапса гауссианов. Как и среднее число  $\hat{K}$  гауссианов изменяется в зависимости от выбора  $p_{new}$ , так и сложность вычислений сильно зависит от предшествующего математического ожидания возникновения динамики. Но затраты на корректировку связаны с рекурсивным коллапсом всей смеси в единственную гауссову плотность. Следовательно, в худшем случае представленный алгоритм запускается  $O(\hat{K}^2 \log \hat{K})$  раз.

Оценка состояний требует дополнительной сортировки скорректированной смеси, что добавляет еще  $O(\hat{K} \log \hat{K})$  итераций.

**Заключение.** Предложена новая методика идентификации динамических объектов, которая в отличие от других использует намного меньше предположений о внешней среде. Разработанный алгоритм определяется статическими моделями и законами вероятности. Предложенная модель служит для построения карт движения робота и слежения за препятствиями в его рабочей зоне.

#### ЛИТЕРАТУРА

1. Biber, P. Dynamic maps for long-term operation of mobile service robots / P. Biber, T. Duckett // In: Proc. of Robotics: Science and Systems, RSS (2005).

2. Burgard, W. Mobile robot map learning from range data in dynamic environments / W. Burgard, C. Stachniss, D. Hahnel // STAR, vol. 35 (2007).
3. Schulz, D. Probabilistic state estimation of dynamic objects with a moving mobile robot / D. Schulz, W. Burgard // Robotics and Autonomous Systems 34(2–3), 107–115 (2001).
4. Coastal navigation: Mobile robot navigation with uncertainty in dynamic environments / N. Roy [et al.] // In: IEEE International Conference on Robotics and Automation, pp. 35–40. Citeseer (1999).
5. Jensen, B. Motion detection and path planning in dynamic environments / B. Jensen, R. Philippsen, R. Siegwart // In: Workshop Proceedings Reasoning with Uncertainty in Robotics, International Joint Conference on Artificial Intelligence, IJCAI (2003).
6. Classifying dynamic objects: An unsupervised learning approach / M. Luber [et al.] // In: Robotics: Science and Systems IV, p. 270 (2009).
7. Lee, D. A Bayesian framework for Gaussian mixture background modeling / D. Lee, J. Hull, B. Erol // In: Proc. of The IEEE International Conference on Image Processing, vol. 3, pp. 973–976 (2003).
8. Stauffer, C. Learning patterns of activity using real-time tracking / C. Stauffer, W. Grimson // IEEE Transactions on Pattern Analysis and Machine Intelligence 22(8), 747–757 (2000).
9. Sheikh, Y. Bayesian object detection in dynamic scenes / Y. Sheikh, M. Shah // In: Proc. of The IEEE Computer Society Conference on Computer Vision and Pattern Recognition, vol. 1, p. 74 (2005).
10. Hou, S. Robust estimation of Gaussian mixtures from noisy input data / S. Hou, A. Galata // In: Proc. of The IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp. 1–8 (2008).
11. Surmann, H. An autonomous mobile robot with a 3D laser range finder for 3D exploration and digitalization of indoor environments / H. Surmann, A. Nuchter, J. Hertzberg // Journal of Robotics and Autonomous Systems (JRAS) 45(3–4) (2003).
12. A non-rigid approach to scan alignment and change detection using range sensor data / R. Kaestner [et al.] // In: Field and Service Robotics. STAR, 25th edn., pp. 179–194. Springer (2006).
13. Bishop, C. [et al.] // Pattern Recognition and Machine Learning, pp. 94–97. Springer, New York (2006).
14. Lerner, U. Hybrid Bayesian Networks for Reasoning about Complex Systems / U. Lerner // PhD thesis, Stanford University (2002).

Поступила 11.03.2015

## METHODS OF MODELING 3D OF DYNAMIC MEDIA BASED ON BAYES' THEOREM

A. HOSPAD

*We propose a new probabilistic approach to the study of spatial representations of of dynamic environment using the 3D-laser measurements. Most of the previous developed techniques computationally costly when considering this issue, and the new method can be applied in real time, even in the presence of a large number of dynamic objects. There are ways for studying activity of the foreground image. However, they generally do not take into account the uncertainty generated during sensing. In this paper we consider the problem of detection of dynamic objects can be solved by means of sequential online structure Bayes. All the parameters involved in the detection process are subject to a probabilistic interpretation. When used in real-world conditions, the results obtained by the proposed method can be used for various tasks: navigation robot creation of maps, localization.*