



DOI: <https://doi.org/10.30898/1684-1719.2023.7.12>

УДК: 621.396.965.8

АЛГОРИТМ МНОГОЦЕЛЕВОЙ ТРАЕКТОРНОЙ ОБРАБОТКИ ДЛЯ РАСПРЕДЕЛЕННЫХ ДВИЖУЩИХСЯ ЦЕЛЕЙ

Ле Ба Тхань

Московский Физико-Технический Институт
(Национальный исследовательский университет)
141700, Россия, Московской обл., г. Долгопрудный, Институтский пер., 9

Статья поступила в редакцию 5 июля 2023 г.

Аннотация. На основе методов вероятностно–статистического моделирования с применением машинного обучения и теории оптимизации разработан алгоритм автоматического обнаружения и сопровождение распределенных движущихся целей при получении первичных отметок от радаров высокого разрешения, а также информации от других типов датчиков. Используя эти методы и методы ассоциации данных (завязки траектории) были реализованы способы моделирования, прогнозирования и обновления состояния множества распределенных целей при решении задачи траекторной обработки. Для оценки и сравнения производительности алгоритма с другими алгоритмами использован метод имитационного моделирования в среде MATLAB для сценариев сопровождения движущихся распределенных целей разными алгоритмами при разных уровнях помех.

Ключевые слова: траекторная обработка, множество распределенных целей, имитационное моделирование.

Автор для переписки: Ле Ба Тхань, thanhlb@phystech.edu

Введение

С развитием технологий и увеличением потребности в точном отслеживании движущихся объектов появилась необходимость разработки и совершенствования алгоритмов для отслеживания движущихся целей в радиолокационных и сенсорных системах.

В работе [1] разработан алгоритм фильтрации, который решает задачу прогнозирования и обновления состояния индивидуальной цели на основе соответствующего набора измерений. Однако при работе с несколькими целями и их траекториями возникают дополнительные трудности, связанные не только с неопределенностью состояния целей, но и с такими вопросами, как неизвестное количество целей в поле зрения датчиков, их возможное исчезновение и появление, перекрытие другими целями, а также недостатки датчиков, которые могут приводить к ложным обнаружениям и пропуску целей. Кроме того, есть проблема ассоциации данных, включающая определение того, какие измерения относятся к конкретной цели, а какие являются помехами.

Цель данной работы заключается в расширении алгоритма ПМБС (алгоритма пуассоновской мультибернуллиевской смеси), описанного в нашей предыдущей работе [2], для обработки траекторий множества движущихся целей на случай распределенных целей.

Расширенный алгоритм ПМБС (РПМБС) отличается от представленного в работе [2] прежде всего тем, что он учитывает дополнительные параметры состояния цели. В алгоритме ПМБС состояние каждой цели определяется кинематическими параметрами и моделируется гауссовым распределением. В алгоритме РПМБС, помимо кинематических состояний, учитываются размеры и ориентация цели в пространстве, моделируемые с использованием плотности гамма-гауссовского обратного распределения Уишарта (плотность ГГОУ), как это было продемонстрировано в [1].

1. Моделирование множеств распределенных целей для многоцелевой траекторной обработки

Математически задача многоцелевой траекторной обработки ставится следующим образом. Пусть в момент времени k после первичной обработки мы получаем N_k^Z радиолокационных отметок (включая отметки реальных целей и ложных целей), и j -я радиолокационная отметка характеризуется вектором измерений (вектором измеряемых величин) \mathbf{z}_k^j . Множество полученных отметок в момент k описывается множеством измерений $Z_k = \{\mathbf{z}_k^j\}_{j=1}^{N_k^Z}$. Предположим, что количество целей, существующих в зоне наблюдения в момент времени k , равно N_k^x и информация об i -ой цели описывается вектором состояния ξ_k^i . При этом множество целей характеризуется множеством векторов состояния целей $X_k = \{\xi_k^i\}_{i=1}^{N_k^x}$. Из-за ошибок измерений, количество целей и их состояния неизвестны, носят случайный характер и изменяются во времени. Задача состоит в том, чтобы в каждый момент времени k вычислить плотность распределения вероятностей $f_{k|k}(X_k | Z_{1:k})$, где $Z_{1:k} = \{Z_1, \dots, Z_k\}$ – множество измерений, полученных во всех моментах времени от 1 до k . При получении плотности распределения вероятностей $f_{k|k}(X_k | Z_{1:k})$ мы оцениваем количество целей и их состояния в момент времени k .

В многоцелевой обработке траекторий мы сталкиваемся не только с неопределенностью состояния каждой цели, но и с неопределенностью количества целей в поле зрения, а также с проблемой ассоциации данных. Неопределенность количества целей связана с различными факторами, такими как маневрирующие цели, которые могут входить в поле зрения и выходить из него, пропуск целей и ложные обнаружения из-за взаимного перекрытия целей, помех, мешающих отражений, шума радиолокационных систем и т. д.

Для оценки количества целей, присутствующих в поле зрения, необходимо оценить вероятность существования каждой цели.

Проблема ассоциации данных заключается в связывании N_k^z радиолокационных отметок (измерений), полученных в момент времени k , с N_{k-1}^x целями, подтвержденными на момент времени $k-1$. Однако маневрирующие цели постоянно изменяют положение, ориентацию и другие параметры движения с течением времени, поэтому сложно определить, сколько отметок генерируются каждой целью и какие именно. В различные моменты времени цель может соответствовать одной, нескольким или отсутствию отметок. Отметки могут происходить от целей или быть вызваны различными видами помех. Гипотезы ассоциации данных определяют, ассоциирована ли отметка с конкретной целью или она просто является помехой. Поэтому, помимо моделирования состояния распределенной цели с использованием плотности распределения ГГОУ, как было показано в [1], для многоцелевой обработки траекторий необходимо моделировать количество целей в поле зрения, вероятность существования каждой цели и гипотезы ассоциации данных. Для моделирования множества целей и гипотез ассоциации данных используем случайные конечные множества (СКМ). Будем использовать СКМ Бернулли с параметрами $(r^i, p^i(\xi))$ для моделирования распределения обнаруженного объекта, при этом вероятность существования r^i указывает на возможность того существует объект или нет. Если объект существует, то плотность распределения состояния объекта определяется плотностью распределения состояния $p^i(\xi)$:

$$p(X^i) = \begin{cases} 1 - r^i & \text{если } X^i = \emptyset \\ r^i \cdot p^i(\xi) & \text{если } X^i = \{\xi\} \\ 0 & \text{если } |X^i| \geq 2 \end{cases} \quad (1)$$

Как упоминалось в [1], плотность распределения состояний распределенного объекта $p^i(\xi)$ описывается плотностью вероятности распределения ГГОУ. Таким образом, СКМ Бернулли может помочь нам представить неопределенность существования объекта и неопределенность состояния этого объекта.

Предположим, что имеются I независимые случайные конечные множество Бернулли X^1, \dots, X^I с мультиобъектными плотностями вероятности $p^1(\xi), \dots, p^I(\xi)$ соответственно. Объединение случайных конечных множеств X^1, \dots, X^I называется случайным конечным множеством мультибернулли X . Если каждое i -е случайное конечное множество Бернулли имеет параметр $(r^{(i)}, p^{(i)}(\xi))$, то параметры случайных конечных множеств мультибернулли являются набором параметров $\left\{ \left(r^{(i)}, p^{(i)}(\xi) \right) \right\}_{i=1}^I$. Поскольку множества Бернулли X^1, \dots, X^I независимы, в соответствии с формулой свертки СКМ, мультиобъектная плотность вероятность множества мультибернулли (плотность мультибернулли) равна:

$$p(X) = \begin{cases} \sum_{\alpha \in \Phi_i^{|X|}} \prod_{i=1}^I p^i(X^{\alpha(i)}) & \text{если } |X| \leq I \\ 0 & \text{если } |X| > I \end{cases}, \quad (2)$$

$$X^{\alpha(i)} = \begin{cases} \emptyset & \text{if } \alpha(i) = 0 \\ \{\xi\} & \text{if } \alpha(i) > 0 \end{cases}, \quad (3)$$

где $\Phi_i^{|X|}$ – множество отображений $\alpha: \{1, \dots, i\} \rightarrow \{1, \dots, |X|\}$ при условии $\{1, \dots, n\} \subseteq \alpha(\{1, \dots, n\})$ и, если $\alpha(i) > 0, i \neq j \Rightarrow \alpha(i) \neq \alpha(j)$. Множество отображений $\Phi_i^{|X|}$ описывает все возможные способы связывания каждой цели в X_k^d с одной компонентой Бернулли, а все остальные компоненты Бернулли будут связаны с пустым множеством.

Мультиобъектная плотность вероятности множества мультибернулли в (2) также может быть представлена следующим образом:

$$p(X) = p(\{\xi^1, \dots, \xi^n\}) = \sum_{X^1 \uplus \dots \uplus X^I = X} \prod_{i=1}^I p^i(X^i)$$

$$= \begin{cases} \prod_{i=1}^I 1 - r^i & \text{если } n = 0 \\ \prod_{i=1}^I 1 - r^i \sum_{1 \leq i_1 \neq \dots \neq i_n \leq I} \prod_{j=1}^n \frac{r^{i_j} p^{i_j}(\xi^j)}{1 - r^{i_j}} & \text{если } 1 \leq n \leq I \\ 0 & \text{если } n > I \end{cases}.$$

Распределение количества элементов случайного конечного множества имеет вид:

$$\Pr[X = n] = \begin{cases} \prod_{i=1}^I 1 - r^i & \text{если } n = 0 \\ \prod_{i=1}^I 1 - r^i \sum_{1 \leq i_1 \neq \dots \neq i_n \leq I} \prod_{j=1}^n \frac{r^{i_j}}{1 - r^{i_j}} & \text{если } 1 \leq n \leq I \\ 0 & \text{если } n > I \end{cases}.$$

Для моделирования множества, состоящего из I потенциальных объектов, можно использовать случайное конечное множество мультибернулли, которое представляет собой объединение I множеств Бернулли.

Мультибернуллиевская смесь (МБС) – случайное конечное множество, мультиобъектная плотность вероятности которого представляет собой нормализованную взвешенную сумму мультиобъектных плотностей вероятности множеств мультибернулли $p^j(X)$:

$$p^{mbm}(X) = \sum_j w^j p^j(X) \quad \text{где} \quad \sum_j w^j = 1. \quad (4)$$

Множество векторов измерений (множество отметок) Z_k является объединением двух непересекающихся множеств: множества векторов измерений, генерируемых помехами и множества векторов измерений, генерируемых целями. Предполагается, что эти множества независимы. Помехи моделируются как точечный процесс Пуассона с параметром λ и

пространственным распределением $c(\mathbf{z})$, а $\kappa(\mathbf{z})=\lambda \cdot c(\mathbf{z})$ является его функцией интенсивности:

$$p(X) = e^{-\lambda} \prod_{\mathbf{z} \in Z} \lambda \cdot c(\mathbf{z}). \quad (5)$$

Распределенная цель с состоянием ξ обнаруживается с вероятностью обнаружения, зависящей от состояния $p_D(\xi)$ и, если она обнаруживается, измерения цели моделируются как точечный процесс Пуассона с параметром γ и пространственным распределением $\phi(\mathbf{z}|\xi)=p(\mathbf{z}|\mathbf{x},\mathbf{X})$, где $p(\mathbf{z}|\mathbf{x},\mathbf{X})$ определяется по формуле [1]:

$$p(\mathbf{z}_k | \mathbf{x}_k, \mathbf{X}_k) \approx N(\mathbf{z}_k; h(\mathbf{x}_k), \sigma \mathbf{B}_k \mathbf{X}_k \mathbf{B}_k^T + \mathbf{R}).$$

Предполагаем, что распределенные цели генерируют отметки, независимые друг от друга. Тогда для непустого множества измерений ($|Z|>0$), условное правдоподобие множества измерений, генерируемой данной целью при заданном состоянии распределенной цели определяется по формуле:

$$\ell_Z(\xi_k) = p_D(\xi_k) p(Z_k | \xi_k) = p_D(\xi_k) e^{-\gamma} \prod_{\mathbf{z}_k \in Z_k} \gamma \phi(\mathbf{z}_k | \xi_k). \quad (6)$$

Обратим внимание, что это произведение вероятности обнаружения и плотности распределения вероятности точечного процесса Пуассона, определяется по формуле [1]:

$$\begin{aligned} p(Z_k | \xi_k) &= e^{-\gamma(\mathbf{x}_k)} \gamma(\xi_k)^{|Z|} \prod_{\mathbf{z}_k \in Z_k} p(\mathbf{z}_k | \xi_k) \\ &= e^{-\gamma(\mathbf{x}_k)} \gamma(\xi_k)^{|Z|} \prod_{\mathbf{z}_k \in Z_k} \left(\int p(\mathbf{z}_k | \mathbf{y}_k) p(\mathbf{y}_k | \xi_k) d\mathbf{y}_k \right). \end{aligned} \quad (7)$$

Распределение $p(Z_k | \mathbf{X}_k)$ описывает правдоподобие множества измерений $Z_k = \{Z_k^1, \dots, Z_k^n\}$ при заданном множестве состояний объектов $\mathbf{X}_k = \{\mathbf{X}_k^1, \dots, \mathbf{X}_k^n\}$. Если распределенные цели генерируют отметки, независимые друг от друга, можно написать:

$$p(Z_k | \mathbf{X}_k) = \prod_{i=1}^n p(Z_k^i | \xi_k^i),$$

где Z_k^i – это подмножество измерений, связанное с объектом ξ_k^i . Если соответствие между Z_k^i и ξ_k^i неизвестно, то $p(Z_k | X_k)$ рассчитывается как сумма вероятностей по всем возможным связям:

$$p(Z_k | X_k) = \sum_{A_k} p(Z_k, A_k | X_k),$$

где $p(Z_k, A_k | X_k)$ – вероятность измерений Z_k и связи A_k при заданных состояниях X_k .

Эффективная вероятность обнаружения распределенной цели с состоянием ξ равна $p_D(\xi)(1-e^{-\gamma})$, где $1-e^{-\gamma}$ – пуассоновская вероятность того, что цель генерирует, хотя бы одно измерение. Соответственно, эффективная вероятность пропуска цели, то есть вероятность того, что цель не обнаружена, равна:

$$q_D(\xi) = 1 - p_D(\xi) + p_D(\xi)e^{-\gamma}. \quad (8)$$

Заметим, что $q_D(\xi)$ является условным правдоподобием, определяющимся по формуле (6) для пустого множества измерений, т. е. $\ell_{Z=\emptyset}(\xi) = q_D(\xi)$.

В каждый момент времени, в зависимости от состояния цели ξ (цель может быть скрыта другими объектами или в условиях, когда цель трудно обнаруживается датчиками), вероятность обнаружения цели $p_D(\xi)$ должна быть установлена на более низкое значение.

Допустим, что в момент времени k мы имеем цель, находящуюся в поле зрения. Если цель продолжает находиться в поле зрения в момент времени $k+1$, то говорят, что цель выживает с момента времени k до момента времени $k+1$. Вероятность продолжения существования цели является величиной, зависящей от состояния цели, и называется вероятностью выживания $p_S(\xi_k)$. И наоборот, $1-p_S(\xi_k)$ – это вероятность того, что объект исчезнет, т. е. покинет зону наблюдения. Состояние каждой цели, продолжающей существовать в поле зрения на следующий момент времени $p_{k+1|k}(\xi_{k+1} | \xi_k)$ прогнозируется на основе

модели движения этой цели [1]. Кроме того, считается, что состояние каждой цели изменяется во времени независимо от состояний остальных целей.

Появление новых целей также предполагается независимым от существующих (этот процесс называется рождением цели). Модель рождения цели может быть описана с помощью точечного процесса Пуассона с параметром μ_{k+1}^b , пространственной плотностью $p_{k+1}^b(\xi)$, и интенсивностью $D_{k+1}^b(\xi) = \mu_{k+1}^b p_{k+1}^b(\xi)$.

Таким образом, для эффективного функционирования динамической модели необходимо учитывать следующие факторы: вероятность выживания целей в поле зрения на следующий момент времени и прогнозируемое состояние данных целей, возможность появления новых целей в поле зрения на следующий момент времени и прогнозируемое состояние этих целей.

2. Алгоритм РПМБС для многоцелевой траекторной обработки

Для моделирования плотности распределения множеств целей используем распределение конечных случайных множеств, описанных выше. В алгоритме РПМБС множество целей в момент времени k обозначенных X_k является объединением двух непересекающихся множеств $X_k = X_k^u \cup X_k^d$, где X_k^u – множество необнаруженных целей, X_k^d – множество обнаруженных целей (цели, которые датчики обнаружили хотя бы один раз).

Для представления указанных множеств целей были использованы точечный процесс Пуассона и мультибернуллиевская смесь. Множество необнаруженных целей моделируется с помощью точечного процесса Пуассона:

$$p(X) = e^{-\mu} \prod_{\xi \in X} \mu p(\xi). \quad (9)$$

Количество необнаруженных целей и плотность распределений состояний этих целей характеризуются параметром μ и пространственным распределением $p(\xi)$ как указано в формуле(9). Вероятность существования и состояние i -ой обнаруженной цели описываются СКМ Бернулли с набором параметров

$(r^{(i)}, p^{(i)}(\xi))$. Для описания множества из I обнаруженных целей будем использовать случайное конечное множество мультибернулли (МБ) с набором параметров $\left\{ (r^{(i)}, p^{(i)}(\xi)) \right\}_{i=1}^I$.

Поскольку существует множество гипотез об ассоциации данных между целями и их векторами измерений, имеются различные гипотезы о количестве и состоянии целей при получении множества измерений. Эти гипотезы могут быть представлены с помощью МБС с набором параметров $\left\{ w^j, \left\{ (r^{(i)}, p^{(i)}(\xi)) \right\}_{i=1}^{I_j} \right\}_{j=1}^H$, где H – количество гипотез ассоциации данных, w^j – правдоподобие j -ой гипотезы и $\left\{ (r^{(i)}, p^{(i)}(\xi)) \right\}_{i=1}^{I_j}$ – множество обнаруженных целей, соответствующих этой гипотезе.

Плотность МБС в момент времени k определяется как свёртка плотности точечного процесса Пуассона (ТПП) для необнаруженных целей и плотности мультибернуллиевской смеси для обнаруженных целей, как показано здесь:

$$p_{k|k}(X_k | Z_{1:k}) = \sum_{X_k^d \subseteq X_k} p_{k|k}^u(X_k \setminus X_k^d | Z_{1:k}) p_{k|k}^d(X_k^d | Z_{1:k}). \quad (10)$$

Плотность ТПП для необнаруженных целей:

$$p_{k|k}^u(X_k \setminus X_k^d | Z_{1:k}) = e^{-\mu_{k|k}^u} \prod_{\xi \in X_k \setminus X_k^d} \mu_{k|k}^u p_{k|k}^u(\xi) \quad (11)$$

имеет параметр интенсивности $\mu_{k|k}^u$ и пространственную плотность $p_{k|k}^u(\xi)$.

Плотность МБС для обнаруженных целей:

$$p_{k|k}^d(X_k^d | Z_{1:k}) = \sum_{j=1}^{J_{k|k}} w_{k|k}^j p_{k|k}^{d,j}(X_k^d | Z_{1:k}) \quad (12)$$

имеет $J_{k|k}$ множеств мультибернулли. Плотность j -го множества мультибернулли определяется как:

$$p_{k|k}^{d,j}(X_k^d | Z_{1:k}) = \sum_{\alpha_{k|k}^j \in \Phi_{I_{k|k}^j}^{X_k^d}} \prod_{i=1}^{I_{k|k}^j} p_{k|k}^{j,j}(X_k^{\alpha_{k|k}^j(i)}), \quad (13)$$

где $X_k^{\alpha_{jk}^{(i)}}$ определяется по формуле (3), $p_{k|k}^{j,j}(X_k^{\alpha_{jk}^{(i)}})$ – плотность множества Бернулли, определяемая по формуле (1). Плотность мультибернуллиевской смеси в (12) имеет $J_{k|k}$ компонент мультибернулли, j -ая компонента мультибернулли имеет $I_{k|k}^j$ компонент Бернулли, а правдоподобие j -ой компоненты мультибернулли равно $w_{k|k}^j$.

В отличие от алгоритма ПМБС для сопровождения точечных целей [2], где состояние каждой цели моделируется с использованием распределения Гаусса, в алгоритме РПМБС все плотности вероятности состояния каждой распределенной цели ($p(\xi)$ в (1), $p(\xi)$ в (9) и $p_{k|k}^b(\xi)$) являются плотностями ГГОУ. Следовательно, плотность ПМБС для моделирования состояний множества целей $p_{k|k}(X_k | Z_{1:k})$ в уравнении (10) можно назвать плотностью ГГОУ–ПМБС. Отметим, что в [1] был представлен расчет параметра плотности ГГОУ после выполнения прогнозирования и обновления.

Для простоты и удобства, алгоритм сопровождения распределенных целей, основанный на рекурсивном обновлении и прогнозировании плотности ГГОУ–ПМБС $p_{k|k}(X_k | Z_{1:k})$, будет называться расширенным алгоритмом ПМБС (или алгоритмом РПМБС). Для работы алгоритма необходимо выполнить некоторые предположения, которые приведены в таблице 1.

Таблица 1. Предположения

<p>Интенсивность рождения новых целей представляет собой смесь плотностей ГГОУ с известными параметрами:</p> $D_{k+1}^b = u_{k+1}^b \sum_{j=1}^{N_{k+1}^b} w_{k+1}^{(b,j)} GGI W(\xi_{k+1}; \zeta_{k+1}^{(b,j)}). \quad (14)$ <p>Начальная необнаруженная интенсивность точечного процесса Пуассона представляет собой смесь плотностей ГГОУ с известными параметрами:</p> $D_0^u = u_0^u \sum_{j=1}^{N_0^u} w_0^{(u,j)} GGI W(\xi_0; \zeta_0^{(b,j)}). \quad (15)$ <p>Вероятности обнаружения и выживания могут быть аппроксимированы как:</p> $p_D(\xi) \approx p_D(\hat{\xi}) \quad ; \quad p_S(\xi) \approx p_S(\hat{\xi}), \quad (16)$ <p>где $\xi = E[\xi] = \int \xi \cdot p(\xi) d\xi$.</p>
--

Параметр Пуассона для распределения помех известен, и пространственное распределение является однородным, $s(\mathbf{z}) = A^{-1}$, где A – объем зоны наблюдения.

Мультиобъектная плотность ГГОУ–ПМБС прогнозируется с использованием уравнения Чепмена–Колмогорова:

$$p_{k|k-1}(\mathbf{X}_k | \mathbf{Z}_{1:k-1}) = \int p_{k,k-1}(\mathbf{X}_k | \mathbf{X}_{k-1}) p_{k-1|k-1}(\mathbf{X}_k | \mathbf{Z}_{1:k-1}) \delta \mathbf{X}_{k-1}. \quad (17)$$

Прогнозируемая плотность ГГОУ–ПМБС обновляется множеством измерений Z_k по теореме Байеса для случайных конечных множеств:

$$p_{k|k}(\mathbf{X}_k | \mathbf{Z}_{1:k}) = \frac{p_k(Z_k | \mathbf{X}_k) \cdot p_{k|k-1}(\mathbf{X}_k | \mathbf{Z}_{1:k-1})}{\int p_k(Z_k | \mathbf{X}_k) \cdot p_{k|k-1}(\mathbf{X}_k | \mathbf{Z}_{1:k-1}) \delta \mathbf{X}_k}, \quad (18)$$

где $p_{k,k-1}(\mathbf{X}_k | \mathbf{X}_{k-1})$ – плотность перехода множества целей, а $p_k(Z_k | \mathbf{X}_k)$ – плотность множества измерений.

Благодаря свойству сопряженности плотности ПМБС вместо расчета прогнозируемой и обновленной плотностей ПМБС в (17) и (18) мы сможем рекурсивно прогнозировать и обновлять их параметры.

2.1. Обновление плотности ПМБС

При предположении, что прогнозируемая плотность множества объектов в момент времени k представляет собой плотность ГГОУ–ПМБС, как описано в формулах(10)–(13), обновленная плотность также будет представлена в виде плотности ГГОУ–ПМБС.

Обновленная плотность МБС приведённая в (19), (20) содержит обновленную компоненту мультибернулли для каждой прогнозируемой компоненты мультибернулли и каждой возможной ассоциации данных:

$$p_{k|k}^d(\mathbf{X}_k^d | \mathbf{Z}^k) = \sum_{j=1}^{J_{k|k-1}} \sum_{Y \subseteq Z} \sum_{P \subseteq Y} \sum_{\substack{\{\mathbf{V}_{j,i}\}_i \\ \mathbb{M}\{\mathbf{V}_{j,i}\}_i = (Z \setminus Y)}} w_{k|k}^{j,P,\{\mathbf{V}_{j,i}\}_i} p_{k|k}^{d,j,P,\{\mathbf{V}_{j,i}\}_i}(\mathbf{X}_k^d | \mathbf{Z}^k), \quad (19)$$

$$w_{k|k}^{j,P,\{\mathbf{V}_{j,i}\}_i} = \frac{w_{k|k-1}^j L_P L_{\{\mathbf{V}_{j,i}\}_i}}{\sum_{j=1}^{J_{k|k-1}} \sum_{Y \subseteq Z} \sum_{P \subseteq Y} \sum_{\substack{\{\mathbf{V}_{j,i}\}_i \\ \mathbb{M}\{\mathbf{V}_{j,i}\}_i = (Z \setminus Y)}} w_{k|k-1}^j L_P L_{\{\mathbf{V}_{j,i}\}_i}}, \quad (20)$$

где $P \angle Z$ – означает, что P разбивает множество Z на непустые подмножества C (называемые блоками), так что:

$$\bigcup_{C \in P} C = Z ;$$

$$C_a \cap C_b = \emptyset, \forall C_a, C_b \in P : C_a \neq C_b,$$

$\{V_i\}_{i=1}^I : \biguplus_{i=1}^I V_i = Z$ – обозначает что Z является объединением непересекающихся подмножеств V_i (V_i может быть пустым для некоторых значений). То есть:

$$\bigcup_{i=1}^I V_i = Z$$

$$V_{i_1} \cap V_{i_2} = \emptyset, \text{ для } \forall i_1 \neq i_2.$$

В (19), (20) для j -ой компоненты мультибернулли, ассоциация данных разбивается на три части:

- 1) Множество измерений Z делится на подмножество Y , включающее измерения от помех или ранее не обнаруженных целей, и подмножество $Z \setminus Y$, содержащее измерения от целей, которые были обнаружены ранее.
- 2) При заданном множестве Y , его разбиение P на непустые блоки C , где каждый блок включает измерения от единого источника (либо помехи, либо индивидуальной цели).
- 3) Для $Z \setminus Y$ определено множество подмножеств $\{V_{j,i}\}_i$, где каждое подмножество $V_{j,i}$ включает в себя измерения, связанные с i -й оценкой Бернулли в j -ой компоненте МБ.

Обновление фильтра РПМБС выполняется следующим образом. Обновление параметров точечного процесса Пуассона для необнаруженного объекта, которые продолжают оставаться необнаруженными:

$$\mu_{k|k}^u = \mu_{k|k-1}^u \langle p_{k|k-1}^u ; q_D \rangle = \mu_{k|k-1}^u \sum_{j=1}^{N_{k|k-1}^u} q_D^{u,j}, \quad (21)$$

где $q_D(\cdot)$ определяется по формуле (8):

$$q_D^{u,j} = 1 - p_D(\hat{\xi}_{k|k-1}^{(u,j)}) + p_D(\hat{\xi}_{k|k-1}^{(u,j)}) \left(\frac{\beta_{k|k-1}^{(u,j)}}{\beta_{k|k-1}^{(u,j)} + 1} \right)^{\alpha_{k|k-1}^{(u,j)}} \quad (22)$$

и является эффективной вероятностью пропуска цели.

Обновленная пространственная плотность:

$$\begin{aligned}
 p_{k|k}^u = & \frac{\sum_{j=1}^{N_{k|k-1}^u} (1 - p_D(\hat{\xi}_{k|k-1}^{(u,j)})) w_{k|k-1}^{u,j}}{\sum_{j=1}^{N_{k|k-1}^u} q_D^{u,j} w_{k|k-1}^{u,j}} G G / W(\xi_k; \zeta_{k|k-1}^{(u,j)}) \\
 & + \frac{\sum_{j=1}^{N_{k|k-1}^u} p_D(\hat{\xi}_{k|k-1}^{(u,j)}) \left(\frac{\beta_{k|k-1}^{(u,j)}}{\beta_{k|k-1}^{(u,j)} + 1} \right)^{\alpha_{k|k-1}^{(u,j)}} w_{k|k-1}^{u,j}}{\sum_{j=1}^{N_{k|k-1}^u} q_D^{u,j} w_{k|k-1}^{u,j}} \\
 & \times G(\gamma_k; \alpha_{k|k-1}^{(u,j)}, \beta_{k|k-1}^{(u,j)} + 1) \times N(\mathbf{x}_k; m_{k|k-1}^{(u,i)}, \mathbf{P}_{k|k-1}^{(u,i)}) \\
 & \times I W(\mathbf{X}_k; \nu_{k|k-1}^{(u,j)}, \mathbf{V}_{k|k-1}^{(u,j)})
 \end{aligned} \tag{23}$$

В формуле (23) сумма обновленных весов равна единице, т. е. обновленная плотность действительно является правильной плотностью. Мы видим, что для каждого компонента ГГОУ в плотности распределения состояния необнаруженных целей, представленной формулой (11), мы получаем два обновленных компонента ГГОУ. Это связано с тем, что цель может генерировать пустое множество измерений двумя способами. Первый способ связан с процессом обнаружения, моделируемым величиной $p_D(\cdot)$, что может привести к пропуску цели. Второй способ связан с числом измерений, которое подчиняется закону Пуассона, определённым параметром γ , при этом число измерений может принимать значение равное нулю. Заметим, что параметры Гауссова распределения и параметры обратного распределения Уишарта идентичны в обоих случаях, а отличаются только параметры гамма-распределения. Применяя метод сокращения гамма-смеси, можно свести бимодальное распределение величины γ_k к унимодальному, так что $p_{k|k}^u(\cdot)$ имеет $N_{k|k-1}^u$ компонент ГГОУ вместо $2N_{k|k-1}^u$ компонент [3].

Обновление цели, обнаруженной впервые

Цель, которая обнаружена впервые, что приводит к множеству измерений C , имеет вероятность существования:

$$r_c = \begin{cases} 1 & \text{если } |C| > 1 \\ \frac{L_C}{\kappa^C + L_C} & \text{если } |C| = 1 \end{cases} \quad (24)$$

Пространственное распределение:

$$p_C(\xi) = \frac{\sum_{j=1}^{N_{k|k-1}^u} w_{k|k-1}^{u,j} L_k^{(u,j,C)} G G I W(\xi; \zeta_{k|k}^{u,j,C})}{\sum_{j=1}^{N_{k|k-1}^u} w_{k|k-1}^{u,j} L_k^{(u,j,C)}} \quad (25)$$

является мультимодальным, где каждый из компонентов ГГОУ в прогнозируемой плотности распределения необнаруженной цели соответствует отдельной моде $p_{k|k-1}^u$. Обновленные параметры $\zeta_{k|k}^{u,j,C}$ и прогнозируемые правдоподобия $L_k^{(u,j,C)}$ рассчитываются, как указано в [1]. Сокращение смеси может быть применено для того, чтобы преобразовать данное распределение к унимодальной плотности [3]. Прогнозируемое правдоподобие представляет собой взвешенную сумму прогнозируемых правдоподобий, соответствующих каждому из компонентов ГГОУ в прогнозируемой плотности распределения необнаруженной цели:

$$L_C = \mu_{k|k-1}^u \sum_{j=1}^{N_{k|k-1}^u} w_{k|k-1}^{u,j} L_k^{(u,j,C)} \quad (26)$$

*Обновление для СКМ мультибернулли
(обновление состояния обнаруженных цели)*

i -ая компонента Бернулли в j -ой компоненте мультибернулли (МБ), обновленная непустым множеством $V_{j,i} \neq \emptyset$, имеет вероятность существования:

$$r_{k|k}^{i,j,V_{j,i}} = 1. \quad (27)$$

Значение $r_{k|k}^{j,i,V_{j,i}} = 1$ указывает на то, что нет возможности установить связь между измерениями и несуществующей целью. Однако это утверждение верно лишь в рамках данной гипотезы ассоциации данных. Важно отметить, что нельзя однозначно заключить о существовании цели исключительно на основании одной гипотезы.

Обновленная пространственная плотность и прогнозируемое правдоподобие:

$$p_{k|k}^{j,i,V_{j,i}}(\xi) = GG / W(\xi; \zeta_{k|k}^{u,j,V_{j,i}}), \quad (28)$$

$$L_{V_{j,i}} = r_{k|k-1}^{j,i} L_{k|k}^{j,i,V_{j,i}}, \quad (29)$$

рассчитываются, как указано в [1].

Если вместо этого i -я оценка Бернулли в j -м компоненте МБ была обновлена пустым множеством $V_{j,i} = \emptyset$, то вероятность существования равна:

$$r_{k|k}^{j,i,V_{j,i}} = \frac{r_{k|k-1}^{j,i} q_D^{j,i}}{1 - r_{k|k-1}^{j,i} + r_{k|k-1}^{j,i} q_D^{j,i}}, \quad (30)$$

где

$$q_D^{j,i} = 1 - p_D(\hat{\xi}_{k|k-1}^{(j,i)}) + p_D(\hat{\xi}_{k|k-1}^{(j,i)}) \left(\frac{\beta_{k|k-1}^{(j,i)}}{\beta_{k|k-1}^{(j,i)} + 1} \right)^{\alpha_{k|k-1}^{(j,i)}}. \quad (31)$$

В этом случае вероятность существования вычисляется как относительная вероятность того, что цель либо существует, но не была обнаружена с вероятностью $r_{k|k-1}^{j,i} q_D^{j,i}$, либо не существует с вероятностью $1 - r_{k|k-1}^{j,i}$.

Обновленное распределение состояний является бимодальным:

$$\begin{aligned}
 p_{k|k}^{j,i,\mathbf{v}_{j,i}}(\xi) = & \frac{1 - p_D(\hat{\xi}_{k|k-1}^{(j,i)})}{q_D^{j,i}} GGI W(\xi_k; \zeta_{k|k-1}^{(j,i)}) \\
 & + \frac{p_D(\xi_{k|k-1}^{(j,i)}) \left(\frac{\beta_{k|k-1}^{(u,j)}}{\beta_{k|k-1}^{(u,j)} + 1} \right)^{\alpha_{k|k-1}^{(u,j)}}}{q_D^{j,i}}, \quad (32) \\
 & \times G(\gamma_k; \alpha_{k|k-1}^{(u,j)}, \beta_{k|k-1}^{(u,j)} + 1) \times N(\mathbf{x}_k; \mathbf{m}_{k|k-1}^{(u,i)}, \mathbf{P}_{k|k-1}^{(u,i)}) \\
 & \times I W(\mathbf{X}_k; \nu_{k|k-1}^{(u,j)}, \mathbf{V}_{k|k-1}^{(u,j)})
 \end{aligned}$$

где первая мода соответствует случаю, когда цель не была обнаружена, вторая мода соответствует случаю, когда цель сгенерировала пустой набор измерений. Используя метод сокращения гамма-смеси, описанный в [3], бимодальное распределение ГГОУ может быть преобразовано в унимодальное распределение ГГОУ. Прогнозируемое правдоподобие:

$$L_{\mathbf{v}_{j,i}} = 1 - r_{k|k+1}^{j,i} p_D(\hat{\xi}_{k|k-1}^{(j,i)}) + r_{k|k+1}^{j,i} p_D(\hat{\xi}_{k|k-1}^{(j,i)}) \left(\frac{\beta_{k|k-1}^{(j,i)}}{\beta_{k|k-1}^{(j,i)} + 1} \right)^{\alpha_{k|k-1}^{(j,i)}}. \quad (33)$$

Прогнозируемые правдоподобия

Прогнозируемое правдоподобие разбиения и прогнозируемое правдоподобие мультибернулли для вычисления весов компонентов МБС в (20) выражены следующим образом:

$$L_P = \prod_{\substack{C \in \mathcal{P} \\ |C| > 1}} L_C \times \prod_{\substack{C \in \mathcal{P} \\ |C| = 1}} (\kappa^C + L_C), \quad (34)$$

$$L_{\{\mathbf{v}_{j,i}\}_i} = \sum_i L_{\mathbf{v}_{j,i}}. \quad (35)$$

2.2. Прогнозирование плотности ПМБС

Пусть апостериорная мультиобъектная плотность в момент времени k представляет собой ПМБС как в формулах (10)–(13). Тогда прогнозируемая мультиобъектная плотность в момент времени $k+1$ также является плотностью ПМБС.

Необнаруженные цели

Прогнозируемый точечный процесс Пуассона для необнаруженных целей имеет параметр Пуассона:

$$\mu_{k+1|k}^u = \mu_{k+1}^b + \langle f_{k|k}^u; p_S \rangle \mu_{k|k}^u = \mu_{k+1}^b + \mu_{k|k}^u P_S^u, \quad (36)$$

где

$$P_S^u = \sum_{j=1}^{N_{k|k}^u} w_{k|k}^{(u,j)} p_S(\hat{\xi}_{k|k}^{u,j}). \quad (37)$$

Прогнозируемое пространственное распределение:

$$\begin{aligned} p_{k|k}^u(\xi_{k+1}) = & \frac{\mu_{k+1}^b}{\mu_{k+1}^b + P_S^u \mu_{k|k}^u} \sum_{j=1}^{N_{k+1}^b} w_{k+1}^{(b,j)} GGI W(\xi_{k+1}; \zeta_{k+1}^{(b,j)}) \\ & + \frac{\mu_{k|k}^u}{\mu_{k+1}^b + P_S^u \mu_{k|k}^u} \sum_{j=1}^{N_{k|k}^u} w_{k+1}^{(u,j)} p_S(\hat{\xi}_{k|k}^{u,j}) GGI W(\xi; \zeta_{k+1|k}^{(u,j)}) \end{aligned}, \quad (38)$$

где прогнозируемые параметры $\zeta_{k+1|k}^{(u,j)}$ вычисляются, как указано в [1].

Прогнозируемое пространственное распределение имеет $N_{k+1}^u + N_{k+1}^b$ компонент ГГОУ.

Обнаруженные цели

Прогнозируемый МБС в формулах (12), (13) для обнаруженных целей имеет веса и количество компонент $w_{k+1|k}^j = w_{k|k}^j$, $J_{k+1|k} = J_k$ и $I_{k+1|k}^j = I_{k|k}^j$. Вероятность существования и пространственное распределение:

$$r_{k+1|k}^{j,i} = p_S(\hat{\xi}_{k|k}^{j,i}) r_{k|k}^{j,i}, \quad (39)$$

$$p_{k+1|k}^{j,i}(\xi_{k+1}) = GGI W(\xi; \zeta_{k+1|k}^{(j,i)}), \quad (40)$$

где прогнозируемые параметры $\zeta_{k+1|k}^{(j,i)}$ вычисляются по формулам в [1].

3. Ассоциация данных при траекторной обработке распределенных целей

3.1. Проблема ассоциации данных при обработке траектории распределенных целей

В контексте обработки данных с множественными целями важно уметь определить происхождение отметок или измерений, устанавливая, от какой цели они исходят, или они являются результатом помех.

Согласно формулам (19), (20), процесс ассоциации данных для распределенных целей состоит из двух частей.

Разделение множества измерений: все измерения, происходящие от одного и того же источника (то есть относящиеся к одной и той же цели или помехе) группируются вместе. Этот процесс приводит к разделению полного набора измерений на непересекающиеся подмножества, именуемые блоками, так что каждое измерение принадлежит строго одному блоку.

Ассоциация блоков с целями: каждый блок измерений затем может быть ассоциирован с потенциальным источником, т. е. отдельной целью или помехой. Этот процесс ассоциации аналогичен тому, который применяется для точечных целей, как описано в работах [2], [4], предполагая, что каждая цель может быть связана максимум с одним блоком измерений.

3.2. Сложность ассоциации данных

Количество разбиений множеств

Пусть множество измерений содержит всего m измерений. Количество всех неупорядоченных разбиений множества из m измерений задаётся числом Белла $B(m)$, определенным формулой:

$$B(m) = \sum_{p=0}^m S(m, p),$$

где $S(m, p) = p \sum_{j=0}^p (-1)^{p+j} C_p^j j^m$ — чисел Стирлинга второго рода,

C_p^j — число сочетаний из p по j .

Число Белла также можно вычислить по рекуррентной форме:

$$B(m+1) = \sum_{k=0}^m C_m^k B(k)$$

Таблица 2. Значения некоторых чисел Белла

m	0	1	2	3	4	5	6	7	8	...	90
$B(m)$	1	1	2	5	15	52	203	877	4240		$>10^{100}$

В таблице 2 приведены некоторые значения числа Белла. Мы видим, что значение числа Белла $B(m)$ очень быстро возрастает с ростом значения m . Это означает, что по мере увеличения количества измерений, множество измерений имеет большое число разбиений.

Количество способов назначений блоки измерений целям

Предположим, что имеется p блоков измерений и n целей. Количество возможных вариантов ассоциации данных для p блоков измерений и n целей определяется следующим образом:

$$N(p, n) = \sum_{k=0}^{\min(p, n)} C_p^k C_n^k k!$$

Как указано в таблице 3, при наличии только всего 8 блоков измерений и 8 целей, существует 1441729 гипотез ассоциации данных. В связи с комбинаторным характером, количество гипотез ассоциации данных растет быстро с увеличением количества блоков измерения и целей.

Таблица 3. Количество ассоциаций данных для p ячеек измерений и n целей

$N(p, n)$	0	1	2	3	4	5	6	7	8
0	1	1	1	1	1	1	1	1	1
1	1	2	3	4	5	6	7	8	9
2	1	3	7	13	21	31	43	57	73
3	1	4	13	34	73	136	229	358	529
4	1	5	21	73	209	501	1045	1961	3393
5	1	6	31	136	501	1546	4051	9276	19081
6	1	7	43	229	1045	4051	13327	37633	93289
7	1	8	57	358	1961	9276	37633	130922	394353
8	1	9	73	529	3393	19081	93289	394353	1441729

Допустим, у нас есть n целей и m измерений. Количество гипотез, связывающих эти m измерений и n целей, равно:

$$N_A(m, n) = \sum_{p=1}^m S(m, p) \sum_{k=0}^{\min(n, p)} C_p^k C_n^k k!$$

Когда и количество целей n , и количество измерений m становятся большими, число возможных ассоциаций данных быстро возрастает.

Далее, предположим, что на временном шаге k мы имеем N_A способов связать m измерений и n целей. Тогда общее количество ассоциации данных с начального момента времени до момента времени k равно:

$$N_{\text{л:к}}^{\text{общ}} = \prod_{i=1}^k N_A(m_i, n_i).$$

Комбинаторный характер этих процессов приводит к быстрому увеличению числа гипотез ассоциации данных с увеличением числа целей и измерений. Общее количество последовательностей ассоциации данных также возрастает с течением времени. Это становится особо заметным в сложных условиях, например, при мониторинге транспортных средств вокруг автомобиля, когда количество целей в поле зрения датчика большое, а высокоразрешающие датчики, такие как лидар или автомобильный радар, на каждом временном этапе генерируют значительное количество измерений.

С другой стороны, избыточное количество ассоциаций данных требует существенных вычислительных ресурсов, которые могут превышать доступные аппаратные способности. Более того, многие приложения требуют обработки данных в реальном времени. В связи с этим, для уменьшения вычислительной нагрузки и обеспечения необходимой точности работы алгоритма обработки траекторий, целесообразно применять методы, упрощающие задачу ассоциации данных. В разделе 3.3 мы обсудим методы снижения сложности ассоциации данных, применяемые в алгоритмах обработки траекторий.

3.3. Методы уменьшения сложности ассоциации данных

Общая цель методов ассоциации данных состоит в том, чтобы сохранить гипотезы ассоциации данных с высокой вероятностью и исключить гипотезы ассоциации данных с низкой вероятностью при сохранении требуемой точности алгоритма.

Стробирование

Стробирование – это метод уменьшения гипотез ассоциаций данных путем устранения измерений, которые с большой вероятностью не принадлежат реальной цели.

Как для точечной, так и для распределенной цели, вероятность гипотезы ассоциации данных, связывающей измерение \mathbf{z} с распределенной целью ξ , пропорциональна функции правдоподобия:

$$\ell_{\mathbf{z}_k}(\xi_{k|k-1}) \sim p(\mathbf{z}_k | \xi_{k-1})$$

В отличие от стробирования для точечной цели, стробирование для расширенной цели учитывает форму и размер цели. Согласно формуле $p(\mathbf{z}_k | \mathbf{x}_k, \mathbf{X}_k) \approx N(\mathbf{z}_k; h(\mathbf{x}_k), \sigma \mathbf{B}_k \mathbf{X}_k \mathbf{B}_k^T + \mathbf{R})$, которая была представлена в [1]:

$$\begin{aligned} p(\mathbf{z}_k | \xi_{k|k-1}) &= p(\mathbf{z}_k | \mathbf{x}_{k|k-1}, \mathbf{X}_{k|k-1}) \\ &= N(\mathbf{z}_k; h(\mathbf{x}_{k|k-1}), \sigma \mathbf{B}_k \mathbf{X}_{k|k-1} \mathbf{B}_k^T + \mathbf{R}_k) \\ &= N(\mathbf{z}_k; \bar{\mathbf{z}}_k, \mathbf{S}_k) \\ &= \frac{\exp\left(-\frac{1}{2}(\mathbf{z}_k - \bar{\mathbf{z}}_k)^T \mathbf{S}_k^{-1}(\mathbf{z}_k - \bar{\mathbf{z}}_k)\right)}{|2\pi \mathbf{S}_k|^{\frac{1}{2}}} \end{aligned} \quad (41)$$

где $\bar{\mathbf{z}}_k = h(\mathbf{x}_{k|k-1})$ – предсказанное измерение цели, $\mathbf{S}_k = \sigma \mathbf{B}_k \mathbf{X}_{k|k-1} \mathbf{B}_k^T + \mathbf{R}_k$ – инновационная ковариация.

Из выражения (41) мы видим, что правдоподобие того, что измерение \mathbf{z}_k связано с целью ξ_k , обратно пропорциональна величине:

$$d^2 = (\mathbf{z}_k - \bar{\mathbf{z}}_k)^T \mathbf{S}_k^{-1}(\mathbf{z}_k - \bar{\mathbf{z}}_k),$$

где d – расстояние Махаланобиса от многомерного вектора \mathbf{z}_k до множества со средним значением $\bar{\mathbf{z}}_k$ и матрицей ковариации \mathbf{S}_k . Вероятность гипотезы, связывающей измерение с целью, будет очень мала, если расстояние d велико. Другими словами, измерение не может быть получено от цели, если расстояние между измерением и прогнозируемым измерением слишком велико.

Квадрат расстояния Махаланобиса d^2 подчиняется распределению $d^2 \sim \chi^2(n_z)$, где n_z – размерность вектора измерения \mathbf{z} .

Предположим, P_G – вероятность того, что измерение не связано с целью при условии $d > G$. Затем порог G определяется с использованием обратной кумулятивной функции распределения хи-квадрат.

Если расстояние d от измерения \mathbf{z} до множества прогнозируемых измерений цели больше, чем пороговое значение G , то гипотеза о том, что измерение связано \mathbf{z} с целью, исключается. В случае $d < G$, мы говорим, что измерение находится в пределах строба захвата цели. Если $d > G$, то измерение находится вне этих стробов захвата.

В данной работе на каждом временном шаге измерения каждого датчика разбиты на три группы: первая группа включает измерения, находящиеся в пределах стробов захвата обнаруженных целей; вторая группа – измерения, не попадающие в стробы захвата обнаруженных целей, но находящиеся в пределах стробов захвата необнаруженных целей; третья группа – измерения, не находящиеся в пределах стробов захвата обнаруженных или необнаруженных целей, исключаются. Применяя метод стробирования, можно сократить количество гипотез ассоциации данных.

Кластеризация для разбиения множества измерения

Как было указано выше, для множества измерений существует множество способов разбиения. Однако измерения, происходящие от одной и той же цели, обычно близки в пространстве. Соответственно, если два измерения находятся на значительном расстоянии друг от друга, вероятно, они не могут быть отнесены к одной цели. Чтобы сохранить лишь наиболее вероятные разбиения, можно использовать алгоритмы кластеризации из области машинного обучения.

Кластеризация – это процесс группировки объектов в подмножества или кластеры, при этом объекты внутри одного кластера наиболее похожи друг на друга по определенным критериям в сравнении с объектами из других кластеров.

В данной работе, с целью группировки измерений, относящихся к одному объекту, применяется алгоритм DBSCAN (Density-Based Spatial Clustering of Applications with Noise), который является плотностным алгоритмом кластеризации пространственных данных с учетом наличия шума [5].

С применением алгоритма кластеризации, измерения, наиболее вероятно исходящие от одного и того же объекта, объединяются в единый блок. Для определения наиболее вероятных гипотез, связывающих блоки с конкретными целями или помехами, использовались алгоритмы оптимального присваивания, изложенные в работе [4].

Кроме того, были применены следующие методы для снижения количества гипотез ассоциации данных: удаляются гипотезы с низкой вероятностью и малым весом, после чего происходит нормализация весов оставшихся гипотез; осуществляется объединение подобных распределений; удаляются гипотезы с низким весом до тех пор, пока не останется N_{\max} наиболее вероятных гипотез; производится преобразование компонент Бернулли с низкой вероятностью существования в точечный процесс Пуассона.

Использование этих стратегий снижает потребности в вычислительных ресурсах и ускоряет процесс вычислений, что важно для обработки траекторий в реальном времени и удовлетворения требований современных приложений.

4. Методика извлечение оценок состояния множество целей. Метод для оценки производительности алгоритма обработки траекторий распределенных целей

4.1. Извлечения оценки

Как уже отмечалось, развитый алгоритм является рекурсивным и включает этапы прогнозирования и обновления распределения состояний объектов. После каждого этапа обновления мы получаем апостериорную плотность,

представленную в форме плотности ПМБС. Оценка информации об объектах проводится на основе компоненты МБС, формируемой из множества обнаруженных объектов.

Извлечение оценок из плотности МБС производится следующим образом.

В компоненте МБС отбирается компонента МБ с наибольшим весом, соответствующая гипотезе ассоциации данных с наивысшей вероятностью.

В компоненте МБ с наибольшим весом, количество компонент Бернулли с вероятностью существования выше определенного порога оценивается как количество объектов. Распределение состояний для каждого объекта представлено соответствующей компонентой Бернулли.

Как описано в работе [1], оценки параметров каждого объекта вычисляются с применением метода среднего значения апостериорной плотности или метода максимального апостериорного значения. При определении распределенных состояний, таких как размер и ориентация объекта, оценки получаются путём разложения матрицы расширенного состояния X .

4.2. Оценка производительности алгоритма

Для оценки производительности алгоритма сопровождения точечных целей используем метрику GOSPA (generalized optimal sub-pattern assignment). Метрика GOSPA вычисляет единственное скалярное значение, которое объединяет ошибки локализации (расстояние между истинными и оценочными позициями целей) и ошибки мощности (пропущенные или ложные цели).

$$d_p^{(c,\alpha)}(X, \hat{X}) = \left[\min_{\theta \in \Theta} \left(\underbrace{\sum_{(i,j) \in \theta} d(\mathbf{x}^i, \hat{\mathbf{x}}^j)}_{\text{ошибки локализации}} + \underbrace{\frac{c^p}{\alpha} (|\mathbf{x}| - |\theta|)}_{\text{ошибки пропуска целей}} + \underbrace{\frac{c^p}{\alpha} (|\hat{\mathbf{x}}| - |\theta|)}_{\text{ошибки ложных целей}} \right) \right]^{\frac{1}{p}},$$

где X и \hat{X} – множества истинных и оценочных позиций целей, соответственно.

$\mathbf{x}^i, \hat{\mathbf{x}}^i$ – элементы (позиции объектов) в множествах X и \hat{X} соответственно.

P – показатель ($1 \leq p < \infty$), определяющий степень, в которой большие ошибки выделяются перед меньшими.

c – предельное расстояние ($c > 0$), соответствующее максимальной допустимой ошибке локализации цели.

α – коэффициент штрафа за мощность ($0 < \alpha \leq 2$), определяющий вес ошибок мощности (пропущенных или ложных обнаружений целей) в метрике GOSPA.

Θ – множество возможных способов назначений оценочных позиций целей их истинным позициям. Оценочная позиция назначается истинной позиции цели при условии, что расстояние между ними меньше c . Для оптимизации назначения можно применить венгерский алгоритм или алгоритм аукциона [6].

В случае отслеживания точечных целей ошибка локализации оценивается как евклидово расстояние между реальной и оцененной позициями целей. Для распределенных целей ошибки локализации также включают ошибки в оценке размера и ориентации цели в пространстве. Предположим, что реальная цель аппроксимируется эллипсом, центр и форма которого определяются вектором \mathbf{c} и матрицей \mathbf{X} . Алгоритм предполагает, что цель аппроксимируется эллипсом, центр и форма которого определяются вектором $\hat{\mathbf{c}}$ и матрицей $\hat{\mathbf{X}}$. Различие между двумя эллипсами оценивается по расстоянию Гаусса–Вассерштейна (расстояние PГВ), который определяется по формуле:

$$d(\mathbf{c}, \mathbf{X}, \hat{\mathbf{c}}, \hat{\mathbf{X}}) = \|\mathbf{c} - \hat{\mathbf{c}}\|^2 + \text{Tr}(\mathbf{X} + \hat{\mathbf{X}} - 2(\mathbf{X}^{\frac{1}{2}} \hat{\mathbf{X}} \mathbf{X}^{\frac{1}{2}})^{\frac{1}{2}}),$$

где квадратный корень матрицы \mathbf{X} – это матрица, причем $(\mathbf{X}^{\frac{1}{2}})^T (\mathbf{X}^{\frac{1}{2}}) = \mathbf{X}$.

Для оценки эффективности алгоритма отслеживания множества распределенных целей, расстояние PГВ интегрируется в метрику GOSPA.

5. Имитационное моделирование

В данном разделе оценивается производительность предложенного алгоритма (алгоритм РПМБС). Производительность этого алгоритма сравнивается с двумя другими алгоритмами: первым, основанным на комбинированном подходе, включающем обработку траекторий точечных целей

(в рамках данного исследования применяется многогипотезный алгоритм сопровождения) и алгоритм кластеризации DBSCAN [2], [7-9] и вторым, основанном на алгоритме плотности вероятности гипотез и методе моделирования формы и размера цели с использованием эллипса [10]. Для упрощения обозначений, первый алгоритм мы называем многогипотезным алгоритмом сопровождения (алгоритм МГС), второй – расширенным алгоритмом плотности вероятности гипотез (алгоритм РПВГ).

Обобщенная схема алгоритма РПМБС для многоцелевой обработки траекторий с использованием данных от различных датчиков представлена на рис. 1. Блоки этой схемы реализованы на основе описанных выше разделов и предыдущих исследований [1], [2].

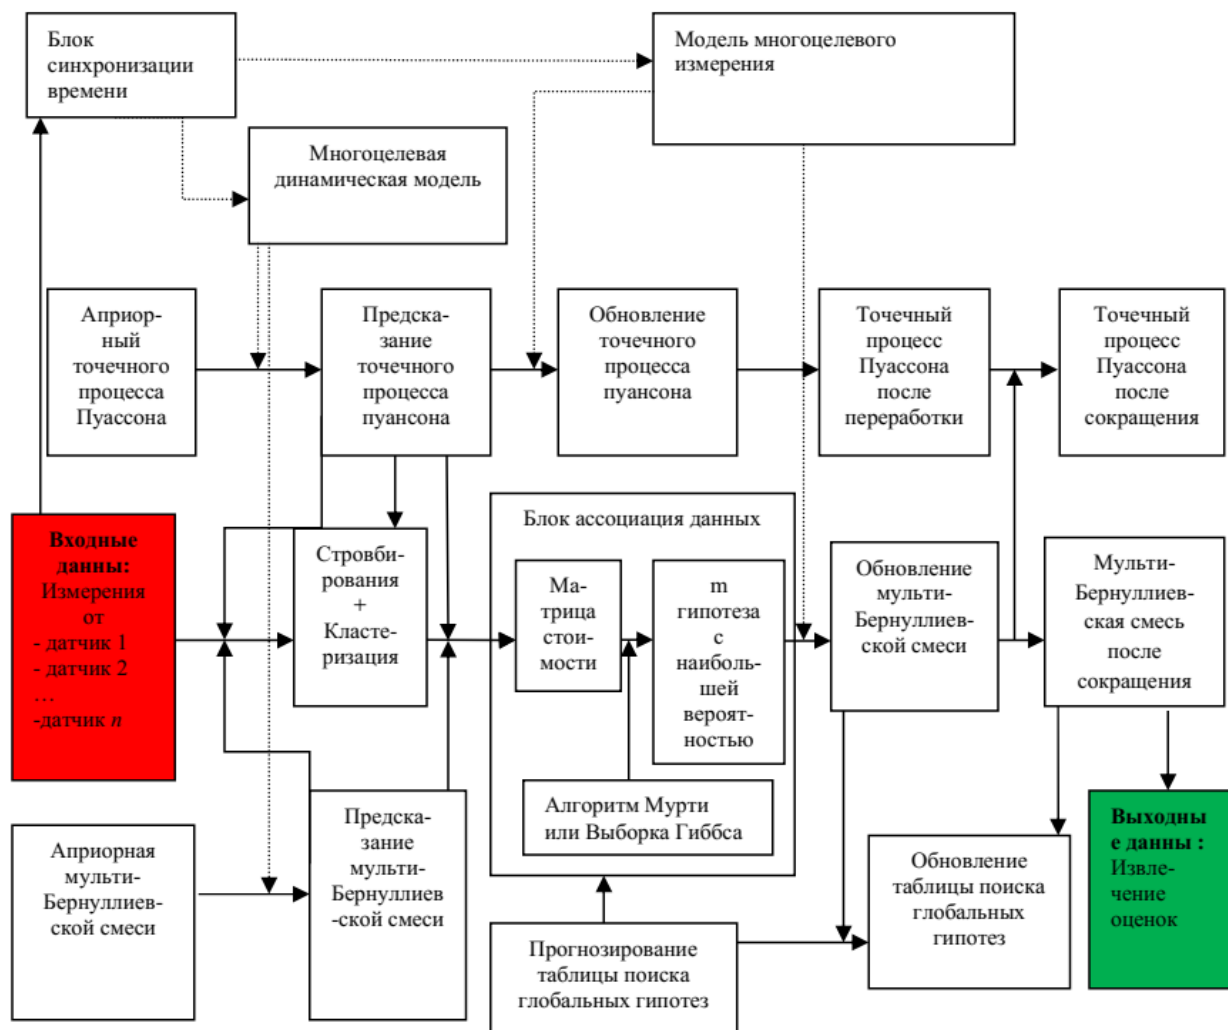


Рис. 1. Обобщенная схема алгоритма РПМБС

Для сравнения производительности алгоритмов было проведено имитационное моделирование сценария обработки траекторий движущихся целей вокруг автономного транспортного средства с использованием MATLAB при двух различных уровнях помех ($\lambda = 10^{-7}$ и $\lambda = 10^{-4}$). Автономное транспортное средство было оснащено комплектом датчиков, включающим шесть радаров и две камеры, параметры которых были настроены для соответствия реальным характеристикам каждого типа датчика. В каждый момент времени радары генерировали множество радиолокационных отметок, соответствующих нелинейным измерениям (расстояние, азимут и доплеровская скорость) возможно присутствующих объектов в зоне обнаружения радара. Камеры, в свою очередь, предоставляли наборы линейных измерений, содержащих информацию о положениях потенциальных объектов в декартовой системе координат. Полученная информация использовалась в качестве входных данных для алгоритмов траекторной обработки. В результате работы алгоритмов получалась оценка количества и состояния движущихся целей в поле зрения датчиков автономного автомобиля. Отклонение этих оценок от истинных значений оценивалось с помощью метрики GOSPA (параметры метрики GOSPA: $\alpha=2$, $c=20$, $p=1$).

Сначала сравнивалась эффективность предложенного алгоритма РПМБС и алгоритма МГС. В условиях низкой интенсивности помех и небольшого количества целей, оба алгоритма демонстрируют хорошую эффективность, как отображено на рис. 2. Как видно на рис. 3, с увеличением интенсивности помех, число ложных обнаружений и пропусков целей при использовании МГС в отличие от РПМБС возрастает. Таким образом, алгоритм РПМБС, в дополнение к возможности оценивания размеров цели, показывает более высокую точность обработки траекторий точечных объектов.







Рис. 2. Метрики GOSPA и составляющие ошибки при использовании алгоритма РПМБС (синие кривые) и алгоритма МГС (оранжевые кривые) в условии низкой интенсивность помех ($\lambda = 10^{-7}$): а) метрики GOSPA, б) ошибки локализации, в) ошибки пропуска целей, г) ошибки ложных целей







Рис. 3. Метрики GOSPA и составляющие ошибки при использовании алгоритма РПМБС (синие кривые) и алгоритма МГС (оранжевые кривые) в условии высокой интенсивности помех ($\lambda = 10^{-4}$): а) метрики GOSPA, б) ошибки локализации, в) ошибки пропуска целей, г) ошибки ложных целей

Результаты моделирования демонстрируют несколько ключевых преимуществ алгоритма РПМБС по сравнению с алгоритмом МГС.

Во-первых, алгоритм МГС использует критерий N/M для подтверждения существования цели. Это значит, что цель подтверждается, если за M последовательных наблюдений получено не менее N отметок от цели. Однако, при подтверждении существования или исчезновения цели критерий N/M учитывает только наличие отметок внутри строба захвата, но не учитывает расстояние от этих отметок до центра строба захвата (то есть, до среднего значения прогнозируемого вектора измерения). В отличие от этого, алгоритм РПМБС использует расстояние от отметок до центра строба захвата (это расстояние пропорционально вероятности того, что данная отметка является

отметкой цели) для расчёта вероятности существования цели на каждом временном шаге, что обеспечивает более быструю и точную оценку присутствия цели. Когда обнаруженная цель имеет очень низкую вероятность существования, алгоритм РПМБС не прекращает отслеживание полностью, а переносит состояние этой цели в группу необнаруженных целей. Такой подход позволяет более быстро реагировать на возможное повторное появление цели в поле зрения при получении новых измерений в будущем.

Во-вторых, модель рождения учитывает вероятность появления новых целей в поле зрения, что позволяет алгоритму РПМБС оперативно идентифицировать новые цели. Одновременно вероятность обнаружения и вероятность выживания цели могут быть корректно изменены в случаях скрытых или сложных условий. Корректировка вероятности обнаружения и вероятности выживания цели в алгоритме РПМБС способствует получению более точной оценки количества целей, особенно при выходе цели из поля зрения.

Третьим преимуществом алгоритма РПМБС является ранний учет размера цели при обработке данных, что позволяет более точно связывать измерения и цели на последующих временных шагах. Это приводит к уменьшению зависимости эффективности алгоритма от точности использования алгоритма кластеризации измерений. В совокупности все это делает алгоритм РПМБС более эффективным в обработке траекторий целей, особенно в условиях высокого уровня помех.

Сравним модифицированные алгоритмы РПМБС и РПВГ.

Производительность: в условиях низкой интенсивности помех и небольшого количества целей, оба алгоритма демонстрируют хорошую эффективность, как отображено на рис. 4. Однако с повышением интенсивности шума РПВГ сталкивается с увеличением ложных обнаружений и пропусков, что видно на рис. 5. Это может быть связано с основной концепцией фильтра РПВГ, которая заключается в аппроксимации апостериорной плотности состояния целей с использованием точечного процесса Пуассона, что подразумевает одинаковое среднее значение и дисперсию распределения. Параллельно,

алгоритм РПМБС показывает стабильность при различных уровнях шума, обеспечивая точные оценки числа, состояния и размера целей.

С точки зрения требуемых вычислительных ресурсов, алгоритм РПВГ обладает преимуществом перед РПМБС, что может быть решающим при реализации в реальном времени или в системах с ограниченными вычислительными ресурсами. Вместе с тем, несмотря на высокую производительность РПМБС, особенно в условиях высокого уровня шума, этот алгоритм обладает высокой вычислительной сложностью и требует тщательной настройки большого количества параметров.

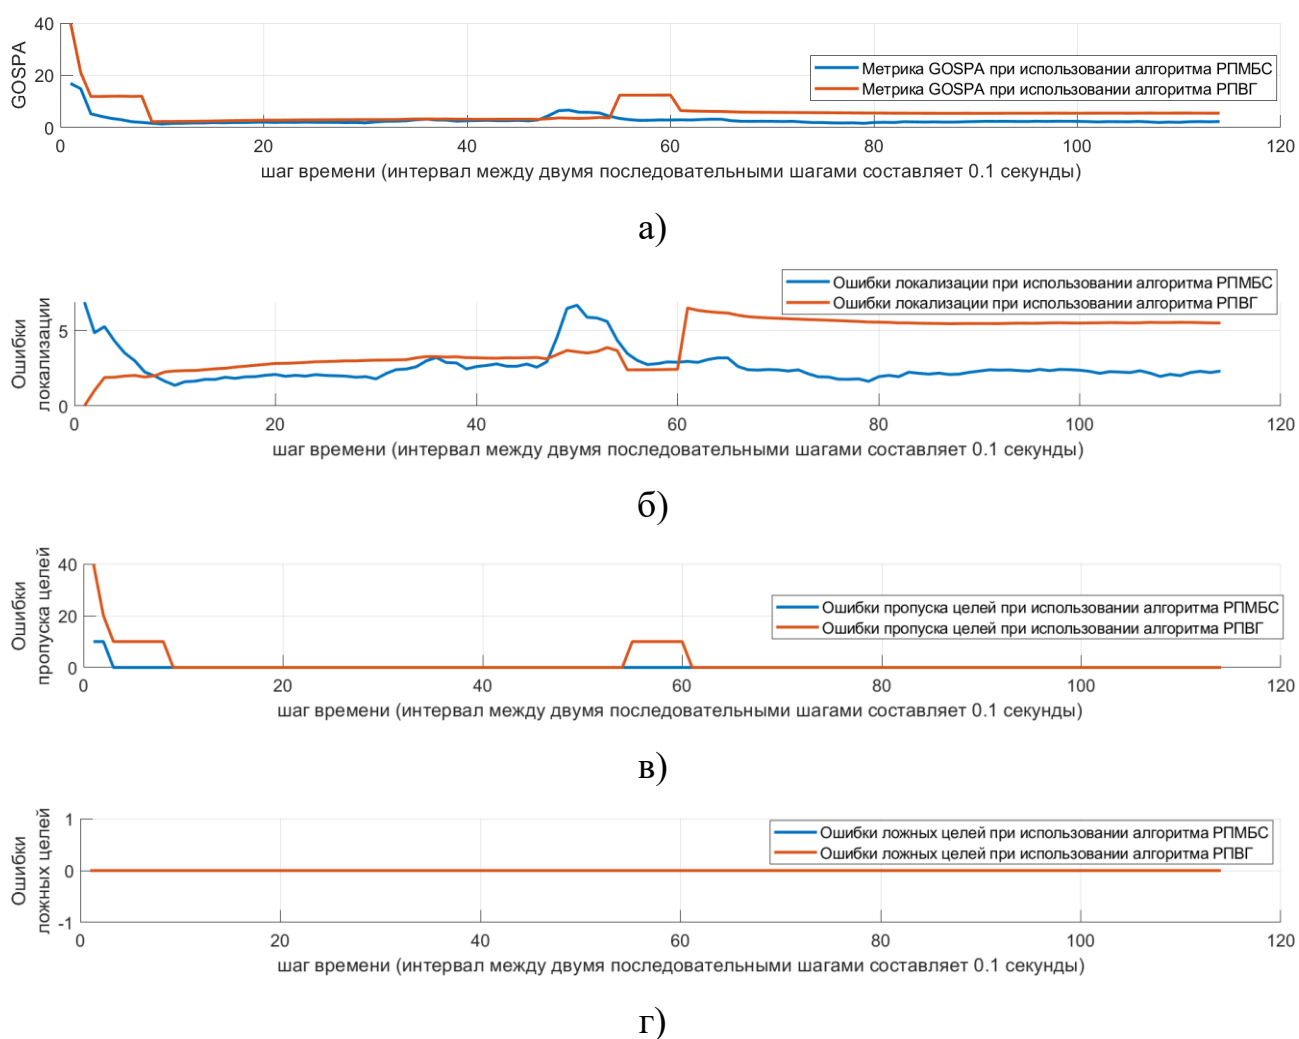


Рис. 4. Метрики GOSPA и составляющие ошибки при использовании алгоритма РПМБС (синие кривые) и алгоритма РПВГ (оранжевые кривые) в условии низкой интенсивности помех ($\lambda = 10^{-7}$): а) метрики GOSPA, б) ошибки локализации, в) ошибки пропуска целей, г) ошибки ложных целей

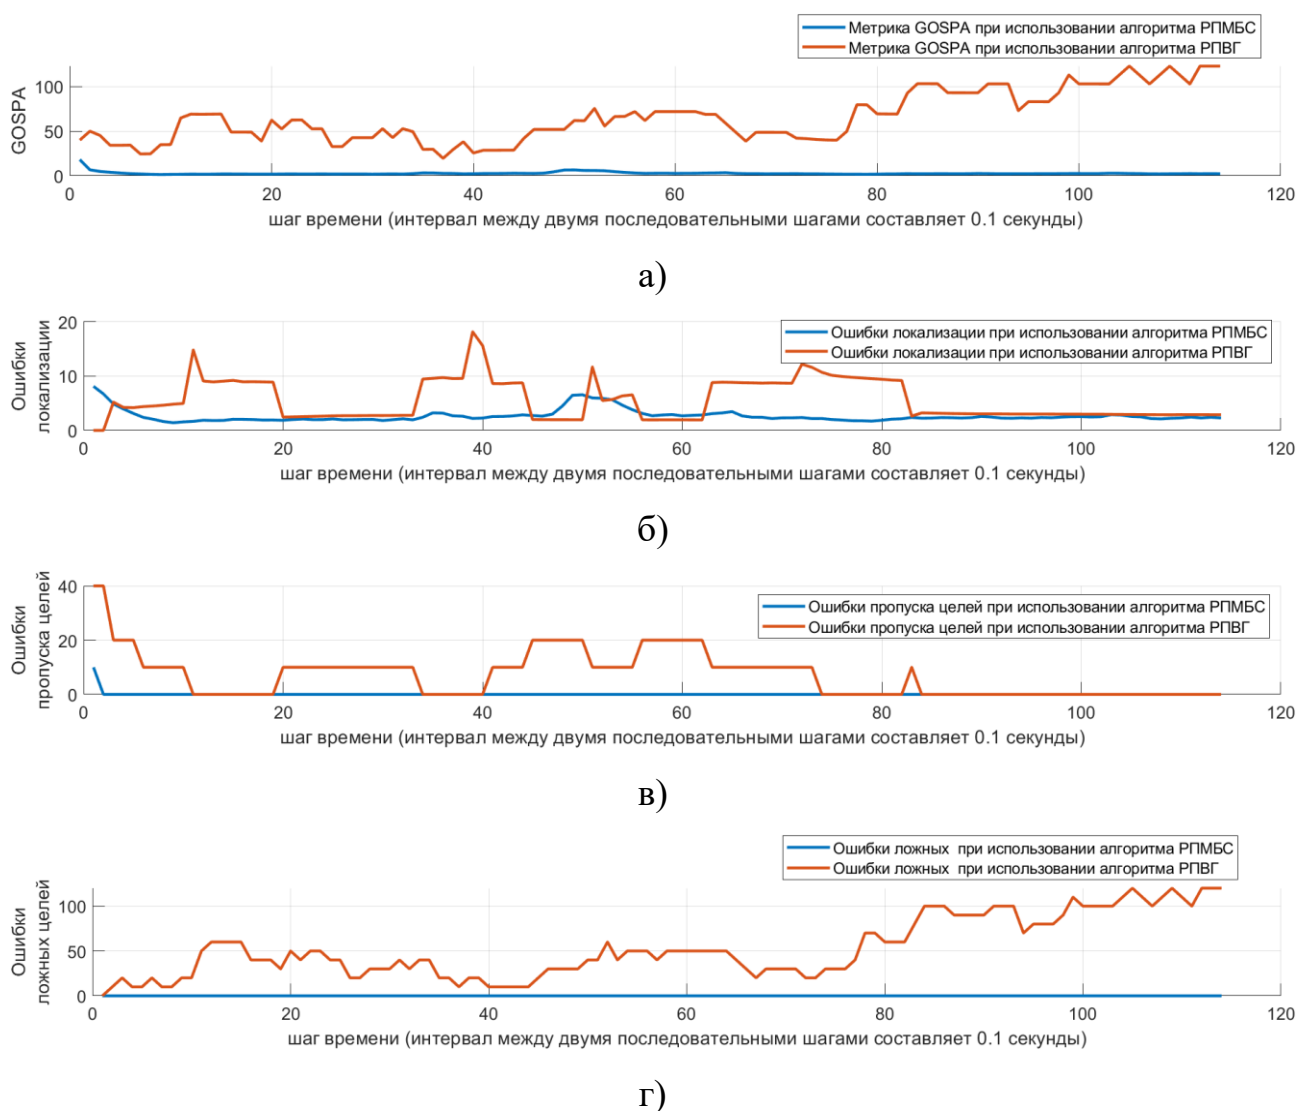


Рис. 5. Метрики GOSPA и составляющие ошибки при использовании алгоритма РПМБС (синие кривые) и алгоритма РПВГ (оранжевые кривые) в условии высокой интенсивности помех ($\lambda = 10^{-4}$): а) метрики GOSPA, б) ошибки локализации, в) ошибки пропуска целей, г) ошибки ложных целей

Таким образом, выбор алгоритма будет зависеть от конкретных требований приложения и контекста отслеживания целей. При этом нужно учитывать баланс между производительностью алгоритма, доступными вычислительными ресурсами и сложностью настройки и реализации алгоритма.

Заключение

Результаты имитационного моделирования показывают, что, помимо хорошей оценки информации о количестве и кинетическом состоянии цели, алгоритм позволяет приблизительно определять размеры цели по первичным

радиолокационным отметкам, которые несут информацию о расстоянии до целей, азимута и доплеровской скорости.

Сравнительная оценка производительности показала, что предложенный алгоритм превосходит другие известные алгоритмы, особенно при высокой интенсивности помех. Такая производительность делает его применимым в области отслеживания движущихся распределенных целей, что может быть полезно в системах помощи водителю, управления автономными транспортными средствами и в других сферах.

Литература

1. Ле Ба Тхань. Нелинейная фильтрация сигналов распределенной движущейся цели при траекторной обработке. Журнал радиоэлектроники [электронный журнал]. 2023. <https://doi.org/10.30898/1684-1719.2023.7.8>
2. Thanh L. B., Alexandrovich P. D., Ruben P. Multi-object multi-sensor tracking simulation using poisson multi-bernoulli mixture filter //2021 23rd International Conference on Digital Signal Processing and its Applications (DSPA). – IEEE, 2021. – С. 1-6. <https://doi.org/10.1109/DSPA51283.2021.9535849>
3. Granström K., Orguner U. Estimation and maintenance of measurement rates for multiple extended target tracking //2012 15th International Conference on Information Fusion. – IEEE, 2012. – С. 2170-2176. <https://ieeexplore.ieee.org/document/6290567>
4. Thanh L. B. Data Association for Multi-Object Tracking Using Assignment Algorithms //2021 International Conference Engineering and Telecommunication (En&T). – IEEE, 2021. – С. 1-5. <https://doi.org/10.1109/EnT50460.2021.9681742>
5. Dietmayer K., Kellner D., Klappstein J. Grid-based dbscan for clustering extended objects in radar data //IEEE intelligent vehicles symposium, Alcala de Henares, Spain. – 2012. <https://doi.org/10.1109/IVS.2012.6232167>
6. Rahmathullah A. S., García-Fernández Á. F., Svensson L. Generalized optimal sub-pattern assignment metric //2017 20th International Conference on Information

Fusion (Fusion). – IEEE, 2017. – С. 1-8.
<https://doi.org/10.23919/ICIF.2017.8009645>

7. Коновалов А. А. Основы траекторной обработки радиолокационной информации //СПб.: Изд-во СПбГЭТУ" ЛЭТИ. – 2013.
<https://etu.ru/assets/files/nauka/nii/2013---Kononov.-Osnovi-traektornoj-obrabotki.-Chast-1.pdf> , <https://etu.ru/assets/files/nauka/nii/2014---Kononov.-Osnovi-traektornoj-obrabotki.-Chast-2.pdf>
8. Буренева О. И. и др. Макет автомобильного радара диапазона 77 ГГц //Известия высших учебных заведений России. Радиоэлектроника. – 2021. – Т. 24. – №. 3. – С. 22-38. <https://doi.org/10.32603/1993-8985-2021-24-3-22-38>
9. Кичерова А. Д., Медведев Е. Р. Программная реализация вторичной обработки сигналов в автомобильном радаре //Навигация и управление движением. – 2021. – С. 277-279.
http://www.elektropribor.spb.ru/upload/medialibrary/361/KMU-2021-ALL_2211.pdf
10. Granström K. et al. Gamma Gaussian inverse Wishart probability hypothesis density for extended target tracking using X-band marine radar data //IEEE Transactions on Geoscience and Remote Sensing. – 2015. – Т. 53. – №. 12. – С. 6617-6631. <https://doi.org/10.1109/TGRS.2015.2444794>

Для цитирования:

Ле Ба Тхань. Алгоритм многоцелевой траекторной обработки для распределенных движущихся целей. *Журнал радиоэлектроники* [электронный журнал]. 2023. №7. <https://doi.org/10.30898/1684-1719.2023.7.12>