

doi: 10.17586/2226-1494-2025-25-6-1160-1167

УДК 004.942

Метод коллективного анализа внешней среды автономными агентами в условиях неполноты данных на основе алгоритма жуков-усачей

Юлия Александровна Павелина¹✉, Илья Юрьевич Попов²

¹ АО «НИИАС», Санкт-Петербург, 196006, Российская Федерация

^{1,2} Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация

¹ lyakhovenko.kam@gmail.com✉, <https://orcid.org/0000-0001-7396-2831>

² ilyapopov27@gmail.com, <https://orcid.org/0000-0002-6407-7934>

Аннотация

Введение. Возрастающая сложность автономных систем и постоянное изменение окружающей среды требуют создания алгоритмов принятия решений, работающих в условиях неполных данных для достижения групповых целей. **Метод.** Для описания группы автономных агентов использован мультиагентный подход, рассматривающий систему как совокупность взаимодействующих интеллектуальных агентов. Для разработки метода коллективного анализа внешней среды агентами использована модель поведения жуков-усачей. **Основные результаты.** Представлен метод, основанный на постоянном обмене информацией между агентами и направленный на минимизацию затрат ресурсов при сборе информации о внешней среде. В ходе проведения эмпирического исследования разработанного метода был получен прирост получаемой группой информации и снижение затрачиваемых ресурсов в сравнении с алгоритмами Model Predictive Control и Cooperative Decision-Making for Mixed Traffic. **Обсуждение.** Предложенный метод позволяет снизить ресурсозатраты группы агентов и повысить производительность системы при достижении групповых целей в условиях неполных данных.

Ключевые слова

автономные агенты, мультиагентные системы, неполнота данных, информационное взаимодействие

Благодарности

Работа выполнена в Университете ИТМО при финансовой поддержке Министерства науки и высшего образования Российской Федерации в рамках проекта № 70-2024-001354 «Разработка технологий и демонстратора комплексной системы группового управления, взаимодействия и организации поведения группы БВС при выполнении целевых задач».

Ссылка для цитирования: Павелина Ю.А., Попов И.Ю. Метод коллективного анализа внешней среды автономными агентами в условиях неполноты данных на основе алгоритма жуков-усачей // Научно-технический вестник информационных технологий, механики и оптики. 2025. Т. 25, № 6. С. 1160–1167. doi: 10.17586/2226-1494-2025-25-6-1160-1167

A method of collective analysis of the external environment by autonomous agents under incomplete data conditions based on the longhorn beetle algorithm

Julia A. Pavelina¹✉, Ilya Yu. Popov²

¹ JSC NIIAS, Saint Petersburg, 196006, Russian Federation

^{1,2} ITMO University, Saint Petersburg, 197101, Russian Federation

¹ lyakhovenko.kam@gmail.com✉, <https://orcid.org/0000-0001-7396-2831>

² ilyapopov27@gmail.com, <https://orcid.org/0000-0002-6407-7934>

Abstract

The increasing complexity of autonomous agents' systems and the constant change of the environment require the development of decision-making algorithms that operate under conditions of incomplete data to achieve group goals. A multi-agent approach is used to describe a group of autonomous agents considering the system as a set of interacting

© Павелина Ю.А., Попов И.Ю., 2025

intelligent agents. A model of the behavior of longhorn beetles is used to develop a method for collective analysis of the external environment by agents. A method based on continuous exchange of information between agents and aimed at minimizing resource costs when collecting information about the external environment is presented. During the empirical study of the developed method, an increase in the information received by the group and a decrease in the resources expended were obtained in comparison with the Model Predictive Control and Cooperative Decision-Making for Mixed Traffic algorithms. The proposed method allows reducing the resource costs of the agent group and increasing the system performance when achieving group goals under conditions of incomplete data.

Keywords

autonomous agents, multi-agent systems, data incompleteness, information interaction

Acknowledgements

This work is partially supported by the Ministry of Science and Higher Education of the Russian Federation, State Assignment No. 70-2024-001354.

For citation: Pavelina Ju.A., Popov I.Yu. A method of collective analysis of the external environment by autonomous agents under incomplete data conditions based on the longhorn beetle algorithm. *Scientific and Technical Journal of Information Technologies, Mechanics and Optics*, 2025, vol. 25, no. 6, pp. 1160–1167 (in Russian). doi: 10.17586/2226-1494-2025-25-6-1160-1167

Введение

В настоящее время интеграция киберфизических устройств в повседневную жизнь становится наиболее популярным направлением в развитии инфраструктуры человека. Одним из приоритетных направлений создания киберфизических систем является интеграция мультиагентных систем.

Мультиагентная система (МАС) — система, образованная несколькими взаимодействующими автономными интеллектуальными агентами. МАС относится к самоорганизующейся системе, так как в ней осуществляется поиск оптимального решения задачи без внешнего вмешательства. Под оптимальным понимается решение, на которое потрачено наименьшее количество энергии в условиях ограниченных ресурсов.

Автономные агенты имеют ряд преимуществ: взаимодействие между собой дает возможность корректировки плана и оптимизации маршрута, более эффективное решение задач, выигрыш при выполнении задачи, возможность постановки разных задач для разных участников группы агентов.

Любой агент обладает следующими свойствами:

- активностью — каждый агент может организовывать и реализовывать действия (по заложенному алгоритму функционирования);
- автономностью — относительной независимостью от внешней среды;
- целенаправленностью — наличием своих источников мотивации (каждый агент имеет определенную цель, для достижения которой он функционирует).

В реальных условиях функционирования группы агентов данные могут быть неполными или даже противоречивыми из-за различных факторов, таких как плохая видимость, отсутствие связи или ошибки обслуживания. Проблемой является совокупность издержек в условиях работы по случайному плану, ввиду невозможности создания детерминированного вектора действия.

В средах с неполными данными методы функционирования автономных систем должны иметь возможность адаптироваться к изменяющейся среде и принимать решения, обеспечивающие безопасное и эффективное вождение.

Одним из ключевых компонентов таких методов является машинное обучение. Модели машинного обучения могут анализировать данные с различных датчиков, идентифицировать объекты на дороге, прогнозировать их движение и оценивать риски. Эти модели можно обучать на больших объемах данных, что позволяет им учиться на опыте и со временем улучшать свою производительность.

Однако машинное обучение не является защитным аспектом, и механизмы планирования и координации также необходимы для обеспечения безопасного и эффективного движения группы агентов. Это может включать совместное планирование маршрута, обмен информацией о текущих условиях внешней среды и координацию действий для достижения групповой цели и минимизации задержек.

Предмет исследования

Метаэвристические алгоритмы стали чрезвычайно популярными благодаря своей высокой эффективности при решении оптимизационных задач. В работе [1] для разработки метода коллективного анализа внешней среды автономными агентами была использована модель Beetle Antennae Search (BAS) основанная на поисковом поведении жуков-усачей. Алгоритм BAS имитирует работу антенн и случайное блуждание.

Отметим, что при применении BAS выполняется совместное взаимодействие нескольких типов агентов в единой системе принятия решений. Это создает дополнительные проблемы в области алгоритмов принятия решений и требует разработки эффективных методов координации и коммуникации между всеми участниками группы агентов.

В [2] предложен подход к восприятию динамической среды, который основан на слиянии информации от датчиков и временной фильтрации в сетях занятости с использованием вероятностной структуры. Метод базируется на объединении данных от разных датчиков в вероятностную сетку, в результате чего происходит совместная оценка пространственной занятости и динамики. Он был реализован с использованием парадигмы гибридного байесовского фильтра занятости [3], а затем расширен с помощью условного трека плотности

Монте-Карло [4] для явного представления наблюдаемых регионов и эффективного извлечения признаков с применением облегченных затрат. Такой подход приводит к значительному улучшению качества результатов и резкому снижению вычислительных и аппаратных затрат системы.

Важным направлением исследований является разработка методов оптимизации управления движущимися объектами в условиях неполноты данных. Работа [5] посвящена разработке моделей и информационному обеспечению поиска входных параметров, обеспечивающих эффективное функционирование движущегося объекта в условиях неполноты данных. Задача оптимизации решается с помощью нечетких интервалов и переменных. Параметры объекта и функция оптимизации рассматриваются в виде лингвистических и нечетких переменных [6, 7].

Для мультиагентных систем актуальна задача децентрализованного принятия решений в сложных условиях. В работе [8] представлена децентрализованная система принятия решений по смене направления движения автономных агентов, состоящая из трех модулей: прогнозирования состояния, генерации возможных решений и координации. Каждый агент самостоятельно принимает решение относительно смены траектории движения. Модуль прогнозирования состояния использует существующие модели совместного слежения за агентом для прогнозирования его будущего состояния. В модуле формирования решений агента предлагается модель, основанная на стимулах, для генерации решений кандидатов. Модуль координации принятия решений предлагает алгоритм, позволяющий избежать траектории движения, которая может привести к столкновению движущихся агентов или ухудшению состояния группы.

Особое внимание уделяется кооперативным и смешанным стратегиям управления. В [9] представлен механизм Cooperative Decision-Making for Mixed Traffic (CDMMT), использующий дискретную оптимизацию для улучшения процесса слияния с трафиком и рассмотрены кооперативное и некооперативное поведение в смешанном трафике. CDMMT — кооперативный метод принятия решений для смешанного трафика, ориентированный на эффективное распределение задач и маршрутов между агентами с учетом их взаимодействия и динамики среды. Этот механизм описывается как двухуровневая программа оптимизации, в которой задачи оптимального управления с ограничениями по состоянию встроены в задачу определения последовательности. Эффективность решения достигается за счет разработанного подхода, основанного на двухуровневом динамическом программировании. Однако его эффективность может снижаться при ограничениях на ресурсы или задержках в коммуникации.

В работе [10] представлена методология создания траектории слияния на основе Model Predictive Control (MPC). MPC — подход к управлению, при котором каждый агент планирует свою траекторию на фиксированном горизонте прогнозирования, оптимизируя целевую функцию с учетом ограничений среды и взаимодействия с другими агентами. MPC оптимизирует

точку слияния и траекторию движения сливающегося агента, одновременно учитывая перемещения агентов по основной траектории. В методологии введена переменная, позволяющая изменять траекторию слияния внутри системы. Следовательно, если необходимы изменения в траектории слияния, например, для поддержания безопасного расстояния, траектория слияния корректируется, оптимизируя точку слияния. Учитывая ограничения на верхние пределы ускорений и нижние пределы замедлений, достижимые реальными автономными агентами, ускорения и замедления обоих связанных агентов заключены в соответствующие интервалы. MPC демонстрирует хорошие результаты при наличии точных моделей среды и прогнозирования, однако уступает по скорости и эффективности группового покрытия области из-за меньшей степени координации между агентами.

Для анализа пропускной способности смешанного трафика используются аналитические модели, основанные на цепях Маркова [11]. Они позволяют учитывать пространственное распределение агентов, различные сценарии их внедрения и параметры управления траекториями движения, что способствует определению оптимальных стратегий достижения групповой цели.

Следует отметить применение поведенческих моделей [12] для определения траекторий и прогнозирования потоков агентов. В работе [12] показано, что при присвоении реалистичных значений параметрам моделирования модель успешно воспроизводит характеристики реального потока.

Постановка задачи коллективного анализа внешней среды автономными агентами

Так как группа автономных агентов является самоорганизующейся, динамической, информационно-коммуникационной системой, состоящей из интеллектуальных элементов, для описания такой системы был использован мультиагентный подход. Рассмотрим группу из n интеллектуальных агентов: $\Lambda = \{A_1, \dots, A_n\}$. Будем считать, что время такой системы дискретно $T = \{0, t_1, \dots, t_0\}$.

Каждый агент A_i группы агентов Λ обладает своей системой управления и физическими устройствами

$$A_i = A_i^{inf} \cup A_i^{phy},$$

где A_i^{inf} — система управления агента; A_i^{phy} — физические устройства агента. При этом система управления A_i^{inf} выполняет функции, связанные с управлением агента (разработка плана действий, взаимодействие с другими агентами), а физические устройства A_i^{phy} выполняют функции, позволяющие осуществить разработанный системой управления план, произвести сбор информации с помощью сенсоров и т. д.

Каждого агента группы определяют его координаты, количество ресурсов и множество знаний о среде:

$$A_i(t) = \{coord_i(t), v_i(t), R_i(t), Inf_i(t), r_inf_i(t), r_sens_i(t)\},$$

где $coord_i(t)$ — набор пространственных характеристик агента A_i в момент времени t ; $v_i(t)$ — скорость

агента в момент времени t ; $R_i(t) = [r_1(t), \dots, r_h(t)]^T$ — вектор-функция, описывающая ресурсы агента в момент времени t ; $Inf_i(t)$ — множество знаний агента в момент времени t , собранные с помощью физических устройств агента A_i^{phy} или полученные в результате информационного взаимодействия системы управления A_i^{inf} с другими агентами; $r_inf_i(t)$ — радиус информационного взаимодействия агента A_i в момент времени t ; $r_sens_i(t)$ — доступный (возможный) радиус сбора информации физическими устройствами A_i^{phy} агента A_i в момент времени t (рис. 1).

Типичная математическая модель исследования операций представлена в следующей формулировке: «Максимизация или минимизация целевой функции при условии выполнения ограничений».

Задачей функционирования группы автономных агентов является выбор такого группового алгоритма действий, который будет максимизировать сумму собранной информации всеми агентами, используя ограниченный объем ресурсов, минимизируя при этом суммарные затраты ресурсов в момент времени t :

$$\max_{\pi} \sum_{t=0}^T \sum_{i=1}^n [\alpha \Delta Inf_i(t) - \beta \Delta R_i(t)],$$

где π — алгоритм управления; $\Delta Inf_i(t)$ — информация, собранная агентом A_i в момент времени t ; $\Delta R_i(t)$ — ресурсы, затраченные агентом A_i в момент времени t ; α, β — коэффициенты весов.

Метод коллективного анализа внешней среды на основе алгоритма поиска жуков-усачей

Исследование окружающей среды жуками-усачами может быть использовано при построении метода ана-

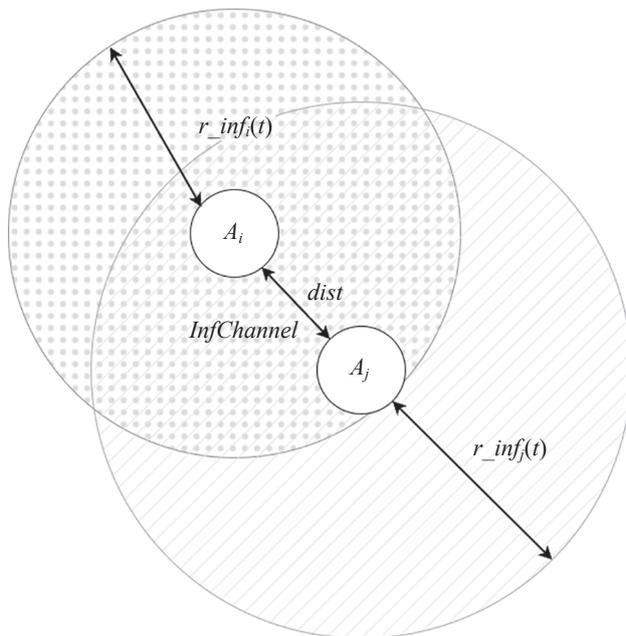


Рис. 1. Возможный информационный канал $InfChannel$ между агентами A_i и A_j

Fig. 1. Possible information channel $InfChannel$ between agents A_i and A_j

лиза внешней среды и достижения некоторых целей группы автономных агентов. Действительно, агенты должны иметь эффективные алгоритмы маршрутизации и планирования, чтобы выбирать оптимальный путь и исследовать внешнюю среду. Это включает распределение и координацию агентов, оптимизацию времени в пути.

Важным аспектом оптимизации работы автономных агентов является связность и коммуникация. Агенты должны иметь надежные и быстрые средства связи для обмена информацией, обновления маршрутов, обнаружения препятствий и координации с другими агентами группы.

Строение антенн жуков-усачей, которые обычно состоят из множества типов обонятельных рецепторных клеток, часто уникально для конкретных видов, и функции таких сенсорных систем до сих пор являются предметом споров. Однако две основные функции таких больших антенн — улавливание запахов добычи и половых феромонов потенциально подходящего партнера. Также длинные антенны действуют как защитный механизм оповещения для жуков-усачей.

Благодаря своим большим размерам антенны могут увеличивать радиус обследования области окружающей среды вокруг себя. Такой механизм можно сравнить с механизмом, с помощью которого автономный агент исследует быстро меняющуюся среду с помощью датчиков и информационного взаимодействия внутри группы.

Жук вращает каждую антенну на одной стороне своего тела, чтобы обнаружить запах, когда он охотится или находит партнера, жук исследует окружающую область случайным образом, используя обе антенны. Когда антенны на одной стороне обнаруживают более высокую концентрацию запаха, жук поворачивается в эту сторону, в противном случае он поворачивается в другую сторону.

Для выполнения задачи коллективного анализа внешней среды агентами определим метод коллективного анализа внешней среды и построения матрицы-карты параметров группой агентов.

Метод состоит из 8 основных этапов, построенных на сборе информации агентами группы, оптимизации потребления ресурсов каждым агентом, а также повышении качества и объема собираемой информации о внешней среде.

Ниже подробно описан каждый этап метода, а также методы оптимизации на основе алгоритма поиска жуков-усачей.

Этап 0. Инициализация системы: определение скорости v и радиуса определения информации агентов $r_sens_i(t)$ для всех агентов группы Λ (рис. 2). При этом $r_sens_i(t) \geq v_i(t)\Delta t$, где Δt — принятая единица времени.

Этап 1. Сбор информации в точке $coord_i(t)$ на расстоянии $r_sens_i(t)$, построение матрицы $Inf_i(t)$.

Агент с помощью сенсоров и приборов восприятия окружающей среды A_i^{phy} собирает требуемые для анализа окружающей среды параметры.

Этап 2. Проведение информационного обмена A_i с каждого агента в радиусе $Inf_i(t)$, сопоставление и дополнение полученных множеств друг с другом:

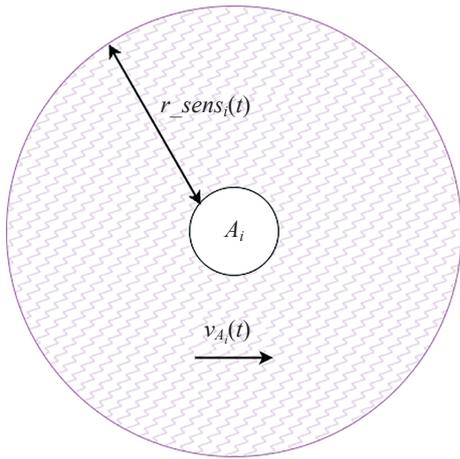


Рис. 2. Инициализация скорости и радиуса анализа области агентом A_i

Fig. 2. Initialization of the speed and radius of the agent's A_i area analysis

$Inf_i(t) = Inf_i(t-1) \cup Inf_{\Lambda_i}(t)$, где $\Lambda_i(t)$ — множество агентов в радиусе $r_inf_i(t)$ от агента A_i . На этапе 2 метода агенты, способные к взаимодействию друг с другом, на основе полученной информации дополняют карту внешней среды (рис. 3). Такой подход позволяет оптимизировать сбор данных о параметрах и объектах внешней среды.

Этап 3. Определим множество $D_{A_i} \setminus DN_{A_i} = \{d_1, \dots, d_w\}$, где D_{A_i} — множество всех возможных направлений агента A_i ; DN_{A_i} — множество направлений до ближайших агентов, с которыми произошел информационный обмен.

Полученное множество определяет список направлений, которые предотвращают повторный сбор агентом параметров, собранных другими агентами на этапе 2. Это позволяет снизить количество затрачиваемых группой агентов ресурсов.

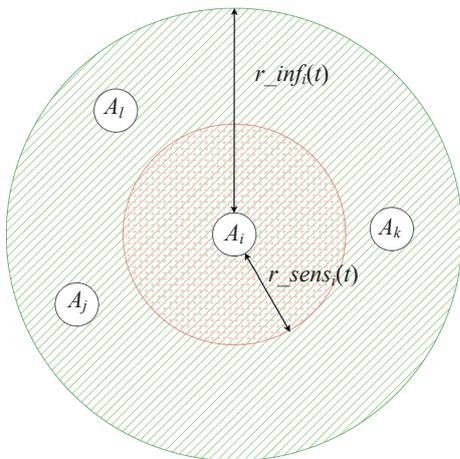


Рис. 3. Графическое отображение области информационного взаимодействия агента A_i с агентами A_j, A_l, A_k и области определения информации

Fig. 3. Graphical display of the area of information interaction of the agents A_i, A_j, A_l, A_k and the area of information definition

Этап 4. Определение вектора направления агента A_i на основе алгоритма поиска жуков-усачей:

$$coord_i(t+1) = coord_i(t) + dir(r_{sens_i}(t), coord_i(t), step(v), D_{A_i} \setminus DN_{A_i}, \min\{M[Sp(coord_i(t+1))]\}),$$

где dir — функция, определяющая направление по некоторой координате $coord_i(t)$; $step(v)$ — шаг агента за единицу времени; Sp — функция минимизации, определяющая количества издержек на основе количества полученной информации $\Delta Inf_i(t+1)$ и затраченных на этот поиск ресурсов агента $\Delta R_i(t+1)$ при переходе из точки $coord_i(t)$ в точку $coord_i(t+1)$; M — математическое ожидание.

Тогда получим

$$\min\{M[Sp(coord_i(t+1))]\} = \frac{\min\{M[Sp(coord_i(t+1), \Delta R_i(t+1))]\}}{\max\{M[Sp(coord_i(t+1), \Delta Inf_i(t+1))]\}}$$

т. е. для минимизации издержек при выборе определенного направления требуется минимизация затраченных ресурсов $\Delta R_i(t+1)$ и максимизация обнаруженной новой информации об окружающей среде $\Delta Inf_i(t+1)$.

Этап 5. Информационный обмен A_i с агентами в радиусе $r_inf_i(t)$ о полученных на этапе 4 направлениях векторов для момента времени $t+1$.

Этап 5 требуется для определения совпадения полученных агентами направлений, что может повысить издержки на ресурсы группы агентов, а также снизить объем полученной информации для следующего момента времени.

Этап 6. Если направления на этапе 4 совпали: — корректировка направления при совпадении $coord_i(t+1)$ и $coord_j(t+1)$, на основе сравнения функций минимизации издержек для агента A_i и агента A_j соответственно:

$$dir(r_{sens_i}(t), coord_i(t), step(v), D_{A_i} \setminus DN_{A_i})$$

и

$$dir(r_{sens_j}(t), coord_j(t), step(v), D_{A_j} \setminus DN_{A_j});$$

— если направления не совпали, перейти к этапу 8.

Этап 7. Для агента чье значение функции издержек оказалось больше:

$$coord(t+1) = coord(t) + rnd(D_A \setminus DN_A),$$

где rnd — означает случайную функцию. Вернуться к этапу 5.

Этап 8. Переход агента в точку $coord(t+1)$, сбор информации ΔInf .

Далее этапы метода повторяются с этапа 2, пока групповая цель группы агентов не будет достигнута.

Эмпирическое исследование

Для оценки эффективности предлагаемого метода был разработан собственный программный симулятор, имитирующий перемещение группы агентов по опреде-

ленной местности. В качестве программной платформы для реализации разработанного метода использовался язык программирования Python 3. Python 3 позволяет работать с библиотекой NumPy, которая предоставляет эффективные структуры данных и операции для работы с многомерными массивами, что обеспечивает быстрые вычисления и обработку данных.

Все агенты $\Lambda = \{A_1, \dots, A_n\}$ в симуляторе объединены в систему, где каждый элемент может взаимодействовать друг с другом для организации сбора информации.

Приведем описание области моделирования:

- область моделирования представлена в виде матрицы и разделена на квадратные элементарные сектора;
- агент может перемещаться только на одну ячейку за единицу времени: по вертикали, горизонтали и диагонали.

Для моделирования и сравнения результатов представленного метода было разработано программное обеспечение с использованием языка программирования Python 3.9, имитирующее движение агентов и обследование ими области с помощью алгоритмов MPC и CDMMT. Алгоритм MPC использует прогнозирование для оптимизации траектории движения. Алгоритм CDMMT основан на кооперативном принятии решений и использует централизованную координацию для распределения зон поиска между агентами. В эмпирическом исследовании оба алгоритма реализованы с возможностью обмена знаниями между агентами и учетом ограничений на ресурсы, что позволяет объективно сравнить их с предложенным методом на основе алгоритма BAS в условиях неполноты данных.

Входные данные моделирования следующие: область тестирования: 50×50 элементарных секторов; количество агентов — 10; скорость агентов постоянна и равна 1; пространственно моделирование ограничено; количество ресурсов у каждого агента в начальный

момент времени одинаково и равно 100; радиус сбора информации — 5 элементарных секторов; радиус информационного взаимодействия — 10 элементарных секторов; каждый агент выполняет 20 шагов в каждом эксперименте; обмен информацией агентами происходит в радиусе — 10 элементарных секторов.

Для сравнения эффективности различных подходов анализа внешней среды группой агентов были использованы следующие метрики: суммарный объем собранной информации группой агентов за один эксперимент; суммарный объем затраченных ресурсов всеми агентами группы за один эксперимент.

В начальный момент времени агенты инициализируются в случайном месте, при этом агенты не могут появляться в одном и том же секторе. После заполнения тестовой области агентами начинается обследование этой области.

Проверка результатов:

- для оценки результатов были рассчитаны параметры объема полученной информации, собранной всей группой агентов, а также объем затраченных ресурсов;
- для каждого подхода было проведено 100 экспериментов — BAS, MPC, CDMMT;
- на каждой итерации эксперимента входные данные были одинаковыми для каждого подхода.

Основной целью моделирования была проверка возможности предложенного метода увеличить объем информации, минимизировав при этом объем затраченных ресурсов.

На рис. 4 представлены результаты эксперимента.

Как видно из рис. 4, разработанный метод позволяет повысить общую осведомленность группы агентов об анализируемой территории, а также снизить объем затраченных ресурсов. Стоит уточнить, что алгоритм CDMMT показал похожие результаты полученного объема информации, но из-за того, что агенты при обследо-

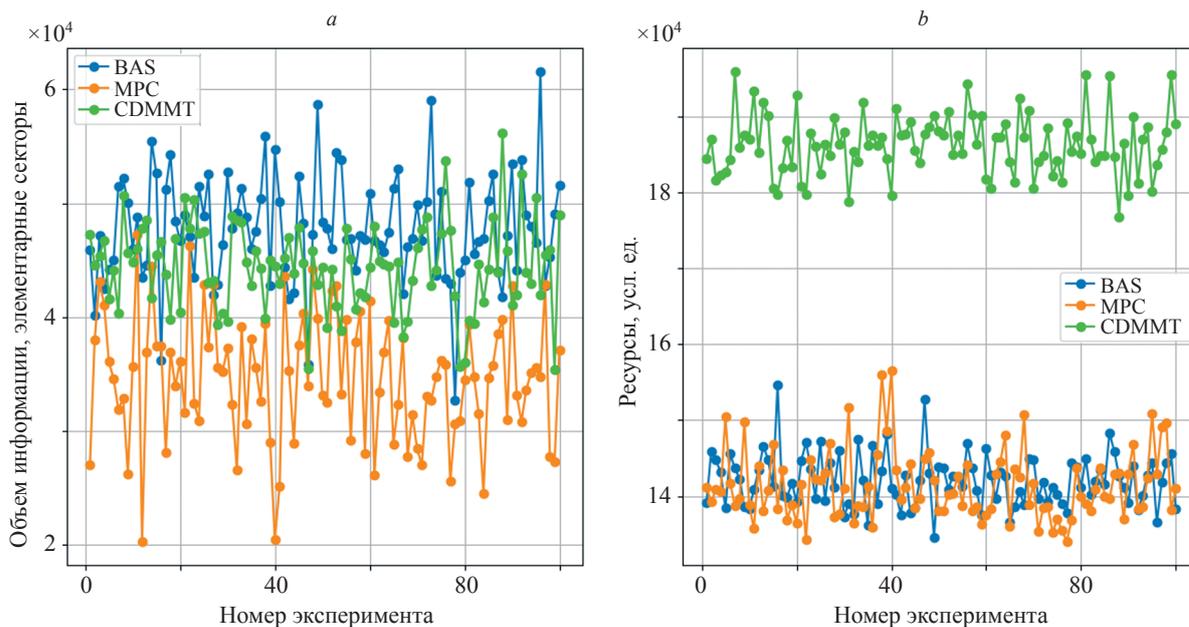


Рис. 4. Графики значений объемов полученной информации (а) и затраченных ресурсов (б) группой агентов
Fig. 4. Graphs of the values of the volumes of information received (a) and resources expended (b) by a group of agents

вании области с помощью CDMMT затрачивают большой объем ресурсов из-за работы в кооперации друг с другом. Это не соответствует постановке задачи группового управления автономных агентов, которая основывается на максимизации полученного объема информации, минимизируя при этом затраченные ресурсы.

Обсуждение

Оптимизация производительности группы автономных агентов является сложной задачей, требующей учета множества факторов, таких как эффективность маршрута, управление энергопотреблением, связность и безопасность. Разработка технологий и исследования в этой области направлены на решение этих проблем для обеспечения эффективного и безопасного использования автономных агентов и их интеграции в различные сферы жизни человека.

Эффективность и целесообразность метода были проверены с использованием как программного моделирования, результаты которого показывают возможность применения метода на практике. Результаты проведенных экспериментов демонстрируют, что предложенный метод анализа внешней среды на основе поведения жуков-усачей обеспечивает более высокую эффективность сбора информации по сравнению с Model Predictive Control и Cooperative Decision-Making for Mixed Traffic в условиях неполноты данных. Метод анализа внешней среды на основе поведения жуков-усачей достигает этого за счет самоорганизации, постоянного обмена знаниями между агентами и адаптивного поиска.

Заключение

В настоящей работе предлагается метод коллективного анализа внешней среды группой автономных агентов в условиях неполных данных. Модель группы автономных агентов построена на основе мультиагентного подхода. Метод коллективного анализа внешней среды разработан на основе алгоритма поиска жуков-усачей, основанного на поиске пищи жуками с помощью своих антенн. Представленный метод направлен на минимизацию затрат при достижении агентами групповых целей, т. е. минимизацию ресурсов, затрачиваемых на следующем этапе метода, и максимизацию получаемой информации. Кроме того, после каждого этапа и в начале инициализации системы агенты на определенном расстоянии от них обмениваются сообщениями для сравнения наборов информации.

Интеграция предлагаемого метода в процесс взаимодействия автономных агентов позволит повысить производительность такой системы, снизить уровень затрачиваемых ресурсов по сравнению со случайным выбором маршрута, а также автоматизировать работу системы в условиях неполных данных.

В качестве плана дальнейших исследований определено снижение количества допущений при моделировании и приближении условий функционирования системы к реальным, повышения нагрузки на систему за счет увеличения количества агентов.

В качестве еще одной задачи для изучения рассматривается возможность применения метода в группах беспилотных летательных аппаратов.

Литература

1. Wang J., Chen H. BSAS: Beetle swarm antennae search algorithm for optimization problems // arXiv. 2018. arXiv:1807.10470. <https://doi.org/10.48550/arXiv.1807.10470>
2. Laugier C., Chartre J. Intelligent perception and situation awareness for automated vehicles // Proc. of the Conference GTC Europe. 2016. hal-01428547.
3. Nègre A., Rummelhard L., Laugier C. Hybrid sampling bayesian occupancy filter // Proc. of the IEEE Intelligent Vehicles Symposium Proceedings. 2014. P. 1307–1312. <https://doi.org/10.1109/ivs.2014.6856554>
4. Rummelhard L., Nègre A., Laugier C. Conditional monte carlo dense occupancy tracker // Proc. of the IEEE 18th International Conference on Intelligent Transportation Systems. 2015. P. 2485–2490. <https://doi.org/10.1109/itsc.2015.400>
5. Finaev V.I., Ignatyev V.V., Shestova E.A., Spiridonov O.B., Zargaryan J.A., Zargaryan E.V. Optimum nominal method modification at the management of moving objects under uncertainty // ARPN Journal of Engineering and Applied Sciences. 2015. V. 10. N 16. P. 6837–6844.
6. Shapovalov I., Soloviev V., Finaev V., Beloglazov D., Zargaryan J., Kosenko E. Research of the controlled flight dynamics based on the full and simplified quadrotor models // Advances in Engineering Mechanics and Materials. 2014. P. 17–22.
7. Mamdani E.H. Application of fuzzy logic to approximate reasoning using linguistic synthesis // IEEE Transactions on Computers. 1977. V. C-26. N 12. P. 1182–1191. <https://doi.org/10.1109/tc.1977.1674779>
8. Nie J., Zhang J., Ding W., Wan X., Chen X., Ran B. Decentralized cooperative lane-changing decision-making for connected autonomous vehicles // IEEE Access. 2016. V. 4. P. 9413–9420. <https://doi.org/10.1109/access.2017.2649567>

References

1. Wang J., Chen H. BSAS: Beetle swarm antennae search algorithm for optimization problems. *arXiv*, 2018, arXiv:1807.10470. <https://doi.org/10.48550/arXiv.1807.10470>
2. Laugier C., Chartre J. Intelligent perception and situation awareness for automated vehicles. *Proc. of the Conference GTC Europe*, 2016, hal-01428547.
3. Nègre A., Rummelhard L., Laugier C. Hybrid sampling bayesian occupancy filter. *IEEE Intelligent Vehicles Symposium Proceedings*, 2014, pp. 1307–1312. <https://doi.org/10.1109/ivs.2014.6856554>
4. Rummelhard L., Nègre A., Laugier C. Conditional monte carlo dense occupancy tracker. *Proc. of the IEEE 18th International Conference on Intelligent Transportation Systems*, 2015, pp. 2485–2490. <https://doi.org/10.1109/itsc.2015.400>
5. Finaev V.I., Ignatyev V.V., Shestova E.A., Spiridonov O.B., Zargaryan J.A., Zargaryan E.V. Optimum nominal method modification at the management of moving objects under uncertainty. *ARPN Journal of Engineering and Applied Sciences*, 2015, vol. 10, no. 16, pp. 6837–6844.
6. Shapovalov I., Soloviev V., Finaev V., Beloglazov D., Zargaryan J., Kosenko E. Research of the controlled flight dynamics based on the full and simplified quadrotor models. *Advances in Engineering Mechanics and Materials*, 2014, pp. 17–22.
7. Mamdani E.H. Application of fuzzy logic to approximate reasoning using linguistic synthesis. *IEEE Transactions on Computers*, 1977, vol. C-26, no. 12, pp. 1182–1191. <https://doi.org/10.1109/tc.1977.1674779>
8. Nie J., Zhang J., Ding W., Wan X., Chen X., Ran B. Decentralized cooperative lane-changing decision-making for connected autonomous vehicles. *IEEE Access*, 2016, vol. 4, pp. 9413–9420. <https://doi.org/10.1109/access.2017.2649567>

9. Sun Z., Huang T., Zhang P. Cooperative decision-making for mixed traffic: A ramp merging example // *Transportation Research Part C: Emerging Technologies*. 2020. V. 120. P. 102764. <https://doi.org/10.1016/j.trc.2020.102764>
10. Cao W., Mukai M., Kawabe T., Nishira H., Fujiki N. Mild merging path generation method with optimal merging point based on MPC // *IFAC Proceedings Volumes*. 2013. V. 46. N 21. P. 756–761. <https://doi.org/10.3182/20130904-4-jp-2042.00109>
11. Ghiasi A., Hussain O., Qian Z.S., Li X. A mixed traffic capacity analysis and lane management model for connected automated vehicles: A Markov chain method // *Transportation Research Part B: Methodological*. 2017. V. 106. P. 266–292. <https://doi.org/10.1016/j.trb.2017.09.022>
12. Gipps P.G. A behavioural car-following model for computer simulation // *Transportation Research Part B: Methodological*. 1981. V. 15. N 2. P. 105–111. [https://doi.org/10.1016/0191-2615\(81\)90037-0](https://doi.org/10.1016/0191-2615(81)90037-0)
9. Sun Z., Huang T., Zhang P. Cooperative decision-making for mixed traffic: A ramp merging example. *Transportation Research Part C: Emerging Technologies*, 2020, vol. 120, pp. 102764. <https://doi.org/10.1016/j.trc.2020.102764>
10. Cao W., Mukai M., Kawabe T., Nishira H., Fujiki N. Mild merging path generation method with optimal merging point based on MPC. *IFAC Proceedings Volumes*, 2013, vol. 46, no. 21, pp. 756–761. <https://doi.org/10.3182/20130904-4-jp-2042.00109>
11. Ghiasi A., Hussain O., Qian Z.S., Li X. A mixed traffic capacity analysis and lane management model for connected automated vehicles: A Markov chain method. *Transportation Research Part B: Methodological*, 2017, vol. 106, pp. 266–292. <https://doi.org/10.1016/j.trb.2017.09.022>
12. Gipps P.G. A behavioural car-following model for computer simulation. *Transportation Research Part B: Methodological*, 1981, vol. 15, no. 2, pp. 105–111. [https://doi.org/10.1016/0191-2615\(81\)90037-0](https://doi.org/10.1016/0191-2615(81)90037-0)

Авторы

Павелина Юлия Александровна — аспирант, ведущий специалист, АО «НИИАС», Санкт-Петербург, 196006, Российская Федерация; инженер-исследователь, Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация, [sc 57216353188](https://orcid.org/0000-0001-7396-2831), <https://orcid.org/0000-0001-7396-2831>, lyakhovenko.kam@gmail.com

Попов Илья Юрьевич — кандидат технических наук, доцент, Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация, [sc 57202195632](https://orcid.org/0000-0002-6407-7934), <https://orcid.org/0000-0002-6407-7934>, ilyapopov27@gmail.com

Authors

Julia A. Pavelina — PhD Student, Leading Specialist, JSC NIIAS, Saint Petersburg, 196006, Russian Federation; Engineer-Researcher, ITMO University, Saint Petersburg, 197101, Russian Federation, [sc 57216353188](https://orcid.org/0000-0001-7396-2831), <https://orcid.org/0000-0001-7396-2831>, lyakhovenko.kam@gmail.com

Ilya Yu. Popov — PhD, Associate Professor, ITMO University, Saint Petersburg, 197101, Russian Federation, [sc 57202195632](https://orcid.org/0000-0002-6407-7934), <https://orcid.org/0000-0002-6407-7934>, ilyapopov27@gmail.com

Статья поступила в редакцию 03.04.2025
Одобрена после рецензирования 12.10.2025
Принята к печати 23.11.2025

Received 03.04.2025
Approved after reviewing 12.10.2025
Accepted 23.11.2025



Работа доступна по лицензии
Creative Commons
«Attribution-NonCommercial»