

Д. С. Строганов^{1✉}, С. Ю. Кацко¹

Мультиагентная система планирования группы БПЛА с нейросетевой оценкой конфигурации

¹Сибирский государственный университет геосистем и технологий,
г. Новосибирск, Российская Федерация
e-mail: stroganovdanila@outlook.com

Аннотация. В статье рассматривается мультиагентная система планирования полетов группы беспилотных летательных аппаратов (БПЛА), функционирующая на основе сети стационарных док-станций. Предложен подход, в котором агент планирования использует нейросетевую модель для оценки качества конфигурации группы дронов при выполнении задачи покрытия заданной территории. В отличие от классических методов многокритериальной оптимизации с фиксированной целевой функцией, оценка конфигурации осуществляется на основе обучаемой модели, учитывающей параметры зоны, характеристики дронов и контекст выполнения миссии. Описана архитектура системы, включающая агента планирования, агентов станций и агентов дронов, а также механизм распределения задач и формирования маршрутов. Рассмотрен сценарий применения системы для мониторинга аграрных угодий. Полученные результаты моделирования демонстрируют сокращение времени планирования и повышение полноты покрытия по сравнению с базовым подходом с линейной целевой функцией.

Ключевые слова: мультиагентные системы, БПЛА, планирование полетов, распределение задач, оценка конфигурации, многокритериальная оптимизация, нейросетевые модели, док-станции

D. S. Stroganov^{1✉}, S. Yu. Katsko¹

Multi-Agent system for UAV swarm planning with neural network-based configuration evaluation

¹Siberian State University of Geosystems and Technologies, Novosibirsk, Russian Federation
e-mail: stroganovdanila@outlook.com

Abstract. This paper presents a multi-agent system for planning the operation of a group of unmanned aerial vehicles (UAVs) based on a network of stationary docking stations. An approach is proposed in which a planning agent employs a neural network model to evaluate the quality of a UAV swarm configuration for covering a target area. In contrast to classical multi-criteria optimization methods with a fixed objective function, the configuration evaluation is performed using a learned model that takes into account the characteristics of the target area, UAV parameters, and mission context. The system architecture is described, including a planning agent, station agents, and UAV agents, as well as mechanisms for task allocation and route generation. A use case involving agricultural land monitoring is presented. Simulation results demonstrate a reduction in planning time and an improvement in coverage compared to a baseline approach using a linear objective function.

Keywords: multi-agent systems, UAV, flight planning, task allocation, configuration evaluation, multi-criteria optimization, neural network models, docking stations

Введение

В последнее десятилетие беспилотные летательные аппараты (БПЛА) стали одним из ключевых инструментов дистанционного мониторинга территорий.

Широкий спектр применений – от аграрного контроля состояния посевов до инспекции линейной инфраструктуры и экстренного реагирования на чрезвычайные ситуации – предъявляет все более высокие требования к автономности, гибкости и эффективности систем управления группами БПЛА. Традиционный подход, при котором оператор вручную управляет одним или несколькими дронами с мобильного устройства, имеет принципиальные ограничения: необходимость физического присутствия на месте, невозможность одновременного контроля нескольких аппаратов и крайне длительное время реакции при внезапном возникновении нештатной ситуации. Так, при обнаружении очага болезни посевов или начала пожара время развертывания ручной системы может составлять 30–60 минут, тогда как автономная система на основе сети док-станций обеспечивает взлет дрона в течение 15 секунд после поступления сигнала тревоги.

Новый подход предполагает развертывание стационарных доковых станций, оснащенных средствами связи (SIM-карта, спутниковый канал) и системой автоматической зарядки дронов. Каждая станция обслуживает несколько БПЛА, поддерживает их в постоянной готовности и может управлять ими по радиоканалу на расстоянии до 25 км [1]. При объединении нескольких таких станций образуется распределенная система, способная автономно покрывать территории площадью в сотни квадратных километров. Основной нерешенной задачей при таком подходе является эффективное распределение заданий между дронами с учетом их индивидуальных ресурсных ограничений: уровня заряда батарей, угла обзора камер, текущей высоты, а также необходимости избегать пересечений маршрутов между аппаратами разных станций. Ручное решение этой задачи в реальном времени практически невозможно, особенно при числе дронов более десяти.

Целью настоящей работы является разработка интеллектуальной мультиагентной системы, в которой агент планирования автоматически, без вмешательства оператора, определяет оптимальный состав группы БПЛА и строит маршруты для полного покрытия заданной территории с учетом всех ресурсных ограничений.

Краткий обзор существующих подходов

Задача распределенного планирования маршрутов группы БПЛА относится к классу задач многоагентного распределения ресурсов и является NP-трудной при большом числе аппаратов [2]. В литературе рассматриваются следующие основные классы методов.

Классические алгоритмы маршрутизации (A^* , алгоритм Дейкстры, методы ветвей и границ) гарантируют оптимальность решения, однако требуют полной и заранее известной информации о среде. Они плохо масштабируются с ростом числа агентов и не адаптируются к динамическим изменениям – например, к внезапной разрядке батареи одного из дронов в процессе выполнения миссии.

Эволюционные и роевые методы (генетические алгоритмы, метод роя частиц, алгоритм муравьиных колоний) обеспечивают приемлемое качество решений для задач большой размерности, однако требуют значительного вычисли-

тельного времени и тонкой настройки гиперпараметров для каждого конкретного сценария [3].

Мультиагентные системы (МАС) с фиксированными правилами взаимодействия обеспечивают высокую гибкость и масштабируемость: каждый агент действует автономно и обменивается сообщениями с соседними агентами [4, 5]. Однако фиксированные правила задаются разработчиком вручную и не улучшаются в процессе эксплуатации. Кроме того, в большинстве существующих систем целевая функция оптимизации имеет явный вид с заранее заданными весовыми коэффициентами, что требует ручной настройки под конкретный сценарий [6].

Методы обучения с подкреплением (Reinforcement Learning) позволяют агентам обучаться оптимальной политике управления в ходе взаимодействия со средой [7]. Однако их применение в группах БПЛА осложнено высокой размерностью пространства состояний и необходимостью длительного обучения перед развертыванием. Предлагаемый в настоящей работе подход занимает промежуточное положение: в рамках МАС-архитектуры агент планирования использует нейронную сеть, обученную на исторических данных реальных миссий, для замены ручной целевой функции. Это сочетает гибкость МАС с адаптивностью методов машинного обучения [8].

Постановка задачи

Рассмотрим формальную постановку задачи. Пусть на исследуемой территории расположено n док-станций $S = \{s_1, s_2, \dots, s_n\}$. К каждой станции s_i подключено множество БПЛА $D_i = \{d_{i1}, d_{i2}, \dots, d_{ij}\}$. Каждый дрон d_{ij} характеризуется вектором параметров состояния:

- b_{ij} – уровень заряда батареи (0–100 %);
- h_{ij} – рабочая высота полета;
- φ_{ij} – угол обзора камеры, определяющий ширину полосы покрытия;
- r_{ij} – техническая готовность (доступен / на зарядке / в ремонте).

Оператор задает целевую зону G в виде полигона на карте и, при необходимости, дедлайн выполнения миссии T_{max} . Требуется:

- выбрать подмножество $D^* \subseteq D$ из общего пула доступных дронов;
- построить для каждого дрона из D^* маршрут, обеспечивающий полное покрытие зоны G без слепых зон и без пересечений маршрутов соседних аппаратов;
- обеспечить выполнение ресурсных ограничений: заряд батареи каждого дрона должен быть достаточен для выполнения его подзадачи и возврата на станцию.

Задача является многокритериальной, поскольку оператор может преследовать конкурирующие цели: минимизировать количество задействованных дронов N (экономия ресурса), минимизировать общее время выполнения миссии T и максимизировать полноту покрытия C (долю площади зоны G , охваченной

маршрутами). В классическом подходе эти критерии агрегируются в единую взвешенную целевую функцию вида:

$$F = \min(\alpha \cdot N + \beta \cdot T + \gamma \cdot (1 - C)), \quad \alpha + \beta + \gamma = 1,$$

где α, β, γ – весовые коэффициенты, задаваемые оператором вручную перед каждой миссией. Основным недостатком такого подхода является необходимость экспертной настройки весов: неправильный выбор коэффициентов приводит к неоптимальным решениям. Кроме того, данная функция является линейной и не способна моделировать нелинейные взаимодействия между параметрами.

В предлагаемом подходе весовые коэффициенты и, более широко, оценка качества конфигурации заменяются нейронной сетью, обученной на исторических данных миссий, что устраняет оба указанных недостатка.

Описание предлагаемого подхода

Система построена по трехуровневой иерархической архитектуре МАС и включает три типа агентов (рис. 1) [4].




Рис. 1. Концептуальная модель системы

Агент планирования (Coordinator Agent) – единственный агент верхнего уровня. Он получает от оператора описание зоны G и вычисляет ее геометрические параметры (площадь, форму, протяженность). Затем рассылает запросы агентам всех станций, собирает информацию о доступных дронах и их параметрах, после чего с помощью нейронной сети формирует оптимальный план: выбирает состав группы D^* и назначает каждому дрону его подзону.

Агент станции (Station Agent) – по одному на каждую док-станцию. Агент станции непрерывно опрашивает подключенные к ней дроны, актуализирует их параметры состояния и отвечает на запросы агента планирования. При получении

нии задания от координатора агент станции транслирует его соответствующему агенту дрона.

Агент дрона (UAV Agent) – по одному на каждый БПЛА. Отвечает за автономное выполнение назначенного маршрута: удерживает заданную высоту и курс, непрерывно передает телеметрию и снимки на свою станцию, а при критическом снижении уровня заряда самостоятельно прерывает выполнение задания и возвращается на зарядку.

Ключевым элементом предлагаемого подхода является замена классической взвешенной целевой функции нейронной сетью (НС), обученной предсказывать качество произвольной конфигурации роя для заданной миссии. Входом НС служит вектор признаков, включающий:

- параметры зоны G : площадь, периметр, расстояние до ближайших станций;
- параметры предложенной конфигурации D^* : количество дронов N , их индивидуальные заряды $\{b_{ij}\}$, высоты $\{h_{ij}\}$ и углы обзора $\{\varphi_{ij}\}$;
- контекстные параметры: время суток, наличие дедлайна T_{max} .

Выходом НС является оценка качества конфигурации – скалярное значение в диапазоне $[0, 1]$, отражающее ожидаемую эффективность данного плана относительно всех трех критериев одновременно. Агент планирования перебирает несколько кандидатных конфигураций и выбирает ту, для которой НС предсказывает наибольшее качество. Существенным преимуществом такого подхода является способность НС улавливать нелинейные зависимости, недоступные линейной целевой функции. Например, в процессе обучения сеть может выявить, что при площади зоны свыше 50 га и наличии дедлайна конфигурация из двух дронов с зарядом 60 % статистически превосходит конфигурацию из одного дрона с зарядом 90 %, поскольку параллельное покрытие двух подзон оказывается быстрее и надежнее. Обучение НС осуществляется в два этапа. На первом этапе используются синтетические данные, генерируемые в среде симуляции: для случайных зон и случайных конфигураций дронов запускается физическая модель полета, по результатам которой вычисляются фактические значения N , T и C . На втором этапе сеть дообучается на реальных данных эксплуатации системы по мере накопления истории миссий.

После того как агент планирования определил состав группы D^* и назначил каждому дрону подзону, выполняется построение маршрутов внутри каждой подзоны. Используется модифицированный метод параллельных полос (lawnmower pattern): ширина полосы определяется индивидуально для каждого дрона исходя из его высоты и угла обзора камеры, что обеспечивает точное покрытие без перекрытий между соседними полосами. Для предотвращения пересечений маршрутов дронов разных станций применяется временная координация: агент планирования назначает каждому дрону временной слот начала работы в зоне пересечения подзон таким образом, чтобы аппараты находились в этой зоне в разное время.

Пример применения: мониторинг аграрных угодий

Рассмотрим следующий сценарий. Агрохозяйство площадью 320 га разделено на три участка неправильной формы. На территории расположены три док-станции: S1 (северо-запад), S2 (центр), S3 (юго-восток). К каждой станции подключены по четыре дрона с параметрами, представленными в таблице 1.

Таблица 1. Параметры дронов на момент начала миссии

Дрон	Станция	Заряд, %	Высота, м	Угол камеры, °	Статус
D1-1	S1	87	50	60	Готов
D1-2	S1	23	50	60	Зарядка
D1-3	S1	65	60	70	Готов
D2-1	S2	91	50	60	Готов
D2-2	S2	58	50	60	Готов
D3-1	S3	74	55	65	Готов
D3-2	S3	82	50	60	Готов

Далее, оператор рисует на карте интерфейса целевую зону, охватывающую все три участка хозяйства (суммарная площадь 320 га), и запускает планирование. Дедлайн не задается – система работает в режиме качественного покрытия. Агент планирования запрашивает агентов трех станций. Те опрашивают своих дронов и возвращают параметры состояния. Агент планирования исключает дрон D1-2 как недоступный (на зарядке) и формирует набор кандидатных конфигураций из оставшихся шести дронов. Нейронная сеть оценивает несколько конфигураций. Конфигурация из трех дронов {D1-1, D2-1, D3-2} с высоким зарядом получает оценку 0,71, однако НС, обученная на исторических данных, предсказывает более высокую эффективность (0,84) для конфигурации из четырех дронов {D1-3, D2-1, D2-2, D3-1}: несмотря на меньший средний заряд, они обеспечивают более равномерное географическое распределение покрытия и сокращают общее время миссии благодаря параллельной работе. Агент планирования принимает четырехдронную конфигурацию, разбивает зону на четыре подзоны с учетом ширины полосы каждого дрона (определяемой высотой и углом камеры) и назначает маршруты. Для участка пересечения подзон дронов D2-1 и D3-1 применяется временная координация: D3-1 начинает работу в зоне пересечения на 4 минуты позже D2-1.

Система завершает планирование за 2,3 секунды с момента запроса оператора. Дроны одновременно взлетают со своих станций и выполняют маршруты. Итоговые показатели миссии приведены в таблице 2.

Таблица 2. Сравнение подходов к планированию

Показатель	Ручное управление	МАС (линейная функция)	МАС (нейросеть)
Время планирования, с	~1200	4,1	2,3
Покрытие территории, %	~70	96	99
Время миссии, мин.	~180	52	41
Задействовано дронов, шт.	1	3	4
Участие оператора	Постоянное	Настройка весов	Только задание зоны

Полученные результаты демонстрируют, что предложенный подход обеспечивает высокую полноту покрытия территории (99 %) при сокращении времени выполнения миссии на 21 % по сравнению с линейной многокритериальной функцией и без какой-либо ручной настройки весовых коэффициентов.

Заключение

В работе представлена мультиагентная система распределенного планирования полетов группы БПЛА, функционирующая на основе сети стационарных док-станций. Предложена трехуровневая архитектура МАС (агент планирования – агент станции – агент дрона), в которой ключевым элементом является нейросетевой модуль агента планирования. Основной вклад работы состоит в применении нейросетевой модели для оценки конфигурации роя, позволяющей учитывать нелинейные взаимодействия между параметрами дронов, которые не моделируются линейной функцией. Проведенный вычислительный эксперимент на сценарии мониторинга аграрных угодий площадью 320 га подтвердил работоспособность предложенного подхода: покрытие территории составило 99 %, время выполнения миссии сократилось на 21 % по сравнению с базовым вариантом МАС, а участие оператора сведено к минимуму – указанию зоны мониторинга на карте. Направлениями дальнейших исследований являются интеграция модуля обнаружения препятствий в реальном времени, разработка механизма динамического перепланирования маршрутов при выходе одного из дронов из строя в процессе миссии, а также апробация системы на реальном аппаратном стенде.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. DJI Enterprise. DJI Dock 3 Product Specifications. – 2024. URL: <https://enterprise.dji.com/dock-3> (дата обращения: 15.04.2025).
2. Agatz N., Bouman P., Schmidt M. Optimization Approaches for the Traveling Salesman Problem with Drone // Transportation Science. – 2018. – Vol. 52. – №. 4. – P. 965–981.
3. Курейчик В. М., Кажаров А. А. Использование роевого интеллекта в решении NP-трудных задач // Известия ЮФУ. Технические науки. 2011. № 7 (120). С. 30-37.

4. Городецкий В. И. Самоорганизация и многоагентные системы. I. Модели многоагентной самоорганизации / В. И. Городецкий // Известия Российской академии наук. Теория и системы управления. - 2012. - № 2. - С. 92-120.
5. Dorri A., Kanhere S.S., Jurdak R. Multi-Agent Systems: A Survey // IEEE Access. – 2018. – Vol. 6. – P. 28573–28593.
6. Queralta J.P. et al. Collaborative Multi-Robot Search and Rescue: Planning, Coordination and Communication // Proceedings of the IEEE. – 2020. – Vol. 108. – №. 10. – P. 1572–1597.
7. Mnih V. et al. Human-level control through deep reinforcement learning // Nature. – 2015. – Vol. 518. – P. 529–533.
8. Кольчерин Д.В., Печеркин С.А. Применение мультиагентных систем, основанных на нейронных сетях // Проблемы современной науки и образования. 2017. № 23. С. 6-10.

© Д. С. Строганов, С. Ю. Кацко, 2026