

Метод синтеза и автоматической адаптации архитектуры, и организационной структуры многоагентной системы

В.А. Демидов

Кубанский государственный технологический университет, Краснодар, Россия

Аннотация. В работе рассматривается актуальная проблема проектирования многоагентных систем (МАС), требующих высокой адаптивности в условиях динамически изменяющихся параметров окружающей среды, условий задачи, внутренней структуры МАС. Предлагается комплексный метод, объединяющий процессы синтеза исходной архитектуры и последующей автоматической адаптации как архитектуры МАС, определяющей базовые правила ее функционирования, так и организационной структуры, представляющей иерархический атрибутированный ориентированный граф, в котором вершинами являются агенты, а ребра соответствуют связям между ними. Метод основан на разработанной автором «зоосоциальной модели» представления архитектуры МАС, он также характеризуется применением искусственной нейронной сети для предсказания оптимальных действий по модификации архитектуры МАС в случае изменения параметров окружающей среды, условий задачи. При этом для обучения искусственной нейронной сети применяется алгоритм обучения с подкреплением, основанный на методе градиента стратегий (алгоритм «REINFORCE»), а формирование обучающей выборки производится с помощью генетического алгоритма.

Ключевые слова: многоагентная система, архитектура, организационная структура, автоматическая адаптация, синтез, генетический алгоритм, обучение с подкреплением, горизонтальная связь, вертикальная связь.

Введение

Организационная структура многоагентной системы (МАС) представляет собой иерархический атрибутированный ориентированный граф [1], в котором вершинами являются агенты (каждому из которых назначена некоторая роль, определяющая набор выполняемых функций), а ребра соответствуют связям между ними. При этом могут быть выделены два основных типа связи:

– Вертикальная связь – реализует отношение подчинения, агент-менеджер, расположенный на верхнем уровне иерархии координирует действия нижестоящих агентов (агенты-подчиненные), назначая им задачи, оценивая результаты их выполнения, разрешая спорные ситуации (не обязательно, эта функция может быть также реализована на уровне агентов-подчиненных). При этом для получения роли «агент-менеджер» необходимо

выполнение некоторых условий, например, достижение определенного уровня производительности (следовательно, в том случае, если агент-менеджер перестал удовлетворять этим требования, соответствующая роль может быть снят с него). Агенты-подчиненные, имеющие одного агента-менеджера, образуют группу.

– Горизонтальная связь – устанавливается между равнозначными агентами (в плане иерархического положения, т.е. имеющими одну и ту же роль) с целью реализации обмена полученным опытом, информацией о планируемых действиях (включая разрешение спорных ситуаций).

При установлении связей возможны следующие ограничения:

1) Ограничения по группе: возможность установления горизонтальных связей с агентами иных групп (или только в пределах своей группы), число агентов-менеджеров, под руководством которых может находиться один агент-подчиненный.

2) По типу информации для обмена: полученный опыт, информация о планируемых действиях, набор сообщений в рамках разрешения конфликтных ситуаций.

3) По топологии коммуникации: прямая (связь устанавливается непосредственно между двумя агентами), опосредованная (связь устанавливается через агента-посредника).

Очевидно, что для различных пар «окружающая среда-задача» вид организационной структуры, позволяющей максимизировать производительность МАС, будет различен. В процессе работы МАС также возможно изменение параметров окружающей среды, условий задачи, что потребует адаптации организационной структуры с целью поддержания максимального уровня производительности.

Таким образом, имеет место проблема априорной генерации и последующей адаптации (в процессе работы) организационной структуры МАС.

Решению обозначенной проблемы посвящен ряд работ, в частности, в [2] МАС представлена в виде иерархического дерева, где агенты соответствуют узлам, а связи между ними - ребрам; при этом обмен информацией происходит исключительно по вертикали. В работе [3] используется схожий принцип, но дополнительно для выявления потенциальных коалиций применяется операция «сжатия ребер». В [4] для формирования коалиционной структуры предложен гибридный алгоритм, сочетающий древовидный поиск и динамическое программирование. В работе [5] описан подход, основанный на перераспределении задач от «дефектных» (временно неспособных к функционированию) агентов к полнофункциональным.

Однако для указанных работ характерны следующие недостатки:

1) В процессе функционирования агенты могут создавать следующие объединения [6]: коалиция (группа равнозначных агентов, максимизирующих собственные выигрыши), команда (группа равнозначных агентов, максимизирующие коллективный выигрыш), федерация (делегирование группой агентов некоторой своей функции отдельному агенту), конгрегация (объединение агентов, реализованное на долгосрочной основе), матрица (реализация множественного подчинения), иерархия (представление МАС в виде древовидной иерархической структуры). Множество правил создания и ликвидации обозначенных объединений, условия вступления (или выхода) в них агентов, множество ролей, возлагаемых на агентов, а так протоколов их выполнения, образует архитектуру МАС. В процессе работы возможны значительные изменения параметров окружающей среды и условий задачи, что может потребовать

коррекции (адаптации) архитектуры МАС с целью сохранения высокого уровня производительности. При этом в обозначенных работах выполнение коррекции такого рода не предусмотрено.

2) Ограниченное множество моделируемых типов организационных структур (одна или две). Как правило, это децентрализованные структуры, такие как команда и коалиция.

3) В большинстве рассмотренных работ [2-4] адаптация организационной структуры выполняется апостериори, после выполнения поставленной задачи. Подобный подход основан на формировании базы оптимальных организационных структур и может быть применен в процессе обучения в рамках модели мира. При этом алгоритм его применения в реальных ситуациях может быть следующим:

- Классификация окружающей среды, задачи, многоагентной системы (ее состав, аппаратные возможности применяемых агентов), формирование кортежа $\langle E, T, A \rangle$, где E – класс окружающей среды, T – класс задачи, A – класс МАС.

- Поиск в базе знаний организационной структуры:

$$O: \langle E, T, A \rangle \rightarrow \Delta C, \quad (1)$$

при ограничениях $\Delta C > 0$, $\Delta C \rightarrow \max$,

где $\Delta C = C_{\text{после}} - C_{\text{до}}$, $C_{\text{до}}$ – значения показателей эффективности МАС до применения организационной структуры O , $C_{\text{после}}$ – значения показателей эффективности МАС после применения организационной структуры O .

- Имплементация организационной структуры O .

Таким образом, временные затраты t на реализацию вышеуказанных шагов будут складываться из следующих оставляющих:

$$t = t_{\text{классификация}} + t_{\text{поиск}} + t_{\text{имплементация}}.$$

Потенциальная величина параметра t ставит под сомнение возможность применения представленного выше алгоритма в режиме реального времени.

4) В рассмотренных работах не выполняется обучение применяемого алгоритма, т.е. решается исключительно задача оптимизации.

Таким образом, целью данной работы является создание метода, обладающего следующими характеристиками:

1) Возможность априорного определения оптимальной архитектуры/организационной структуры и ее адаптации в процессе функционирования МАС в режиме реального времени.

2) Возможность моделирования следующих типов организационных структур: коалиция, команда, иерархия, федерация, конгрегация.

3) Не только определение оптимальной архитектуры/организационной структуры, а обучение выполнению данной задачи, т.е. с каждой итерацией система учится определять оптимальную архитектуру/организационную структуру МАС.

Материалы и методы

На рисунке 1 представлена диаграмма IDEF0, описывающая разработанный метод.

На рисунке 1 представлены следующие блоки:

1) «Классификация окружающей среды, задачи, многоагентной системы» - формирует кортеж

$$\langle E, T, A \rangle, \quad (2)$$

где E – класс окружающей среды, T – класс задачи, A – класс многоагентной системы (учитывается число, программные и аппаратные характеристики агентов).

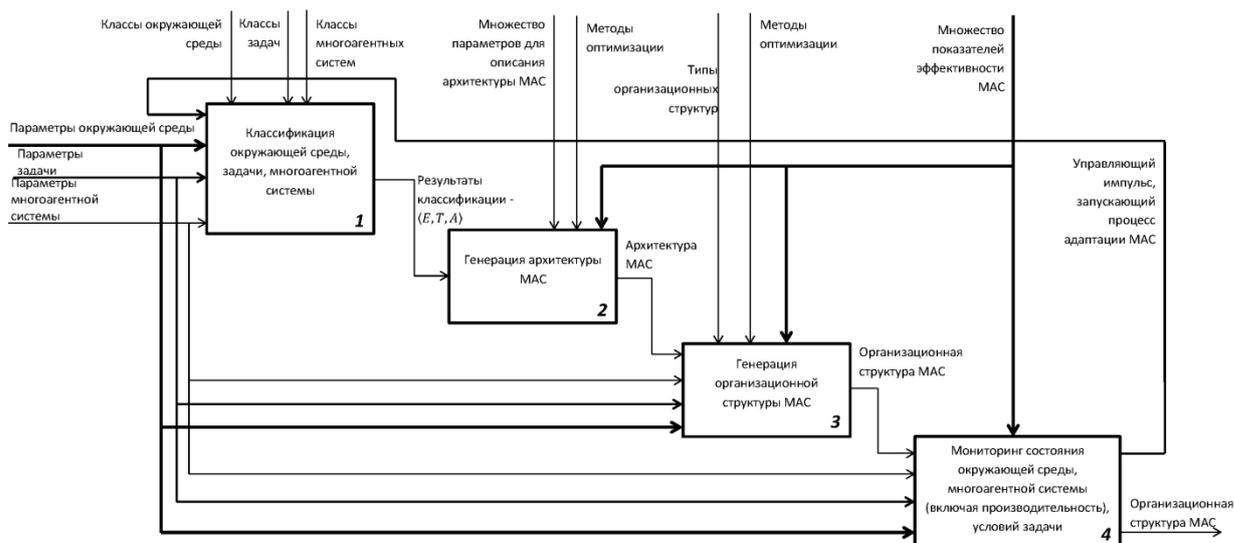


Рис. 1. – Диаграмма IDEF0 предложенного метода синтеза и автоматической адаптации архитектуры и организационной структуры МАС

2) «Генерация архитектуры МАС» - определение на основании кортежа (2) архитектуры (параметрического описания) МАС, применение которой позволит получить оптимальный результат при решении задачи класса T в условиях окружающей среды класса E , располагая многоагентной системой класса A . Рассмотрим данный блок в следующих аспектах:

а) Множество параметров для описания архитектуры МАС - «зоосоциальная модель», подробное описание которой приводится в [7], позволяющая моделировать следующие типы организационных структур: коалиция, команда, иерархия, федерация, конгрегация. «Зоосоциальная модель» предполагает применение параметров, сгруппированных следующим образом [7]: «пищевой инстинкт» (определяет «пищу», в качестве которой может рассматриваться вознаграждение, назначаемое агентам по результатам выполнения поставленной задачи), «инстинкт экономии энергии» (например, «вероятность перехода агента в режим экономии энергии»), «защитный инстинкт» (например, «вероятность выбора действий, приводящих к повреждению или выходу из строя агента»),

описывающая стремление агента к выполнению рискованных действий), «исследовательский инстинкт» (например, «вероятность выбора действия, выполнение которого не ведет, как показывает опыт агента, к оптимальному результату»), «подражательный инстинкт» (например, «вероятность обмена агентами полученным опытом»), «инстинкт коммуникации» (например, «вероятность, с которой агенты будут формировать горизонтальные связи»), «стадный инстинкт» (например, «вероятность установления агентом вертикальных связей»), «территориальный инстинкт» (формализуется с помощью следующих пространственных радиусов: «публичная зона» - область, в которой должны взаимно располагаться агенты для установления вертикальных связей; «социальная зона» - область, в которой должны взаимно располагаться агенты для формирования горизонтальных связей, подробно рассматриваются в [8]), «правила доминирования» (применяются при формировании иерархии, а также при арбитраже конфликтов).

б) Определение оптимальной архитектуры МАС (подробно рассматривается в [8]). Осуществляется в рамках модели мира (удовлетворяющей E) с помощью генетического алгоритма, принимающего в качестве «хромосомы» набор параметров «зоосоциальной модели» архитектуры МАС. Полученные кортежи $\langle H, C \rangle$ (H - «хромосома», C - полученные значения показателей эффективности) далее применяются для обучения модели, основанной на применении искусственных нейронных сетей, методов парадигмы обучения с подкреплением [9]. При этом для описания состояния МАС применяется следующая структура:

$$S = \{E, T, A, H\},$$

где H - «хромосома», описывающая архитектуру МАС. Для изменения состояния S (а именно, множества H) могут применяться примитивные действия следующих видов (точнее - они применяются для практической реализации генетических операторов, таких, как «мутация», «скрещивание»):

$a_{H_i} \uparrow$ – увеличить значение показателя («гена») H_i на величину Δ_{H_i} , $a_{H_i} \downarrow$ – уменьшить значение показателя H_i на величину Δ_{H_i} , $i = 1, 2, \dots, N_H$, N_H – число генов в «хромосоме». Для расчёта подкреплений R применяется следующая функция:

$$R(C_T): R(C_T) \in [-1, 1] \wedge R(C_T \leq C_{T_{min}}) = -1 \wedge R(C_{T_{max}}) = 1,$$

где $C_{T_{min}}$, $C_{T_{max}}$ – минимально и максимально допустимое время выполнения задачи T . Соответственно, подкрепление назначается на основании полученного эффекта от применения генетических операторов (т.е. привело ли это к повышению эффективности МАС). Аппроксимация функции стратегии ($\pi_{E,T}(S) \rightarrow \text{prob}(a)$, a – примитивное действие) осуществляется с помощью искусственной нейронной сети (ИНС) с применением алгоритма «REINFORCE» (алгоритм обучения с подкреплением, основанный на методе градиента стратегий [10]). Таким образом, в случае изменения кортежа $\langle E, T, A \rangle$ (и снижения эффективности МАС, т.е. $C \downarrow$) значения его элементов, а также описание текущей архитектуры МАС (H) подаются на вход ИНС, выходным значением которой является множество корректирующих воздействий (примитивных действий) a_{H_i} (H_i – i -й «ген» «хромосомы»), применение которых позволит получить новую «хромосому» $H': C \rightarrow \text{max}$.

3) Генерация организационной структуры МАС. На основании архитектуры $H: C \rightarrow \text{max}$ формируется организационная структура МАС, при этом она является гибкой и не задается априори. Для применения предлагается модифицированная версия метода, предложенного в [11], основанного на «биогеографическом алгоритме», суть которого состоит в моделировании процесса заселения животными неосвоенных территорий (например, вулканический остров) с учетом таких факторов, как объем ресурсов и населенность территории. Суть предлагаемого метода

описывается далее. Пусть P_{subor} – базовая вероятность формирования агентами вертикальных связей («заселение острова»), R_{public} – радиус «публичной зоны» (агенты, взаимно расположенные в «публичных зонах» друг друга могут формировать вертикальные связи, т.е. радиус, в пределах которого агенты осуществляют поиск агента-менеджера, к которому могут присоединиться). Каждый агент-менеджер $A^{manager}$ получает для выполнения некоторую задачу T , которую он разбивает на подзадачи T_j , назначаемые его агентам-подчиненным A_i^{subor} , $j = 1, 2, \dots, N_T$, N_T – количество подзадач, на которые была разбита задача T , $i = 1, 2, \dots, N_{A^{manager}}$, $N_{A^{manager}}$ – число агентов, подчиненных $A^{manager}$. Цель любого агента A_k (вне зависимости от его роли) состоит в следующем:

$$F_t^{A_k} \rightarrow \max,$$

где $F_t^{A_k}$ – показатель «пищи», добываемой агентом A_k в момент времени t , определяемой по формуле:

$$F_t^{A_k} = \frac{\sum_{t=1}^{t_{end}} R_{T_t}^{A_k} o(t)}{t},$$

где $R_{T_t}^{A_k}$ – вознаграждение, полученное агентом A_k за решение подзадачи (или задачи, если $A_k = A^{manager}$) T_t , $R_{T_t}^{A_k} \in [0, 1]$, o – функция, монотонно убывающая на интервале $[t, 1]$, $o \in [0, 1]$, $o(t) = 1$, $o(1) = 0$, $k = 1, 2, \dots, N_A$, N_A – общее число агентов МАС.

Таким образом, если агент A_i^{subor} присоединился к группе, находящейся под руководством $A^{manager}$, и не получает подзадач, то его показатель «пищи» будет уменьшаться. Вероятность выхода агента из группы может определяться как функция от расстояния между агентами $s(A^{manager}, A_i^{subor})$, а также от «пищи» $F_t^{A_i^{subor}}$, добываемой агентом-подчиненным A_i^{subor} :

$$\begin{cases} P_{free} = 0 \text{ при } \mathbf{s}(A^{manager}, A_i^{subor}) < R_{public} \wedge F_t^{A_i^{subor}} > F_{sat}, \\ P_{free} = |\varepsilon_{dist} - 1| \varepsilon_{food} \end{cases}$$

где F_{sat} – минимальное значение получаемой «пищи», при котором агент-подчиненный A_i^{subor} не испытывает желания покинуть группу; ε_{dist} , ε_{food} – функции следующего вида:

$$\varepsilon_{dist}(p) = \frac{1}{1+e^{-\beta p}}, \quad (3)$$

где $p \in \{\mathbf{s}(A^{manager}, A_i^{subor}), F_t^{A_i^{subor}}\}$, $\beta \leq 0$ – скорость убывания.

При этом в качестве начального времени фиксации показателя $F_t^{A_i^{subor}}$ может быть использован показатель t_0 – время запуска процесса выполнения задачи T . Данный подход вполне эффективен при обеспечении мобильности агентов между группами, однако при принятии в группу свободного агента A_k (не входящего в группу), имеющего $F_t^{A_i^{subor}} \gg 0$ (эта «пища» была им ранее «добыта» при работе в качестве свободного агента), даже в случае назначения ему подзадач для исполнения, он длительное время будет сохранять высокий уровень $F_t^{A_i^{subor}}$. Таким образом, агент A_k будет формально числиться в группе, не выполняя никакой работы, пока вероятность разрыва вертикальной связи (P_{free}) не достигнет необходимых значений для его выхода. При этом в то же время другая группа может испытывать недостаток агентов и агент A_k мог бы ее усилить. Для устранения данного недостатка мы предлагаем обнулять значение показателя $F_t^{A_k}$ при вступлении агента в группу, а также ввести показатель t_{load} , запрещающий агенту менять группу в течении некоторого времени (чтобы устранить эффект «скачков» агентов между разными группами, возникающий при $F_t^{A_k} = 0$).

4) Мониторинг состояния окружающей среды, многоагентной системы (включая производительность), условий задачи. Данный блок предназначен для отслеживания ситуаций, являющихся триггерами к запуску процесса адаптации МАС к текущим условиям – изменение параметров окружающей среды, условий задачи, состава множества агентов. При этом необходимо учитывать следующее:

- неполная наблюдаемость, динамический характер окружающей среды и, как следствие, сложность формализации ее параметров;

- производительность МАС сохранилась на том же уровне, несмотря на изменения параметров окружающей среды, условий задачи, состава множества агентов;

- в данном случае адаптация организационной структуры осуществляется автоматически на уровне агентов (модифицированный метод [11]).

Таким образом, в качестве триггера к адаптации архитектуры может быть использован показатель текущей производительности МАС, например, усредненное вознаграждение агентов по всем траекториям (при этом в качестве траекторий τ рассматриваются последовательности кортежи $\langle S_{\text{до } A}, a, S_{\text{после } A}, r \rangle$, где $S_{\text{до } A}$ – состояние агента до выполнения примитивного действия a , $S_{\text{после } A}$ – состояние агента после применения примитивного действия A):

$$R_{\tau} = \frac{\sum_{i=1}^{N_A} \left(\sum_{k=1}^{N_{\tau A_k}} \gamma_{\tau}(k) r_k \right)}{N_A},$$

где N_A – общее число агентов МАС, $N_{\tau A_k}$ – число кортежей в траектории агента A_k , γ_{τ} – «коэффициент обесценивания» (позволяет снижать веса подкреплений, содержащихся в кортежах опыта, полученного достаточно давно), определяемый по формуле (3), при этом $\beta \geq 0$.

Результаты

Цель эксперимента заключается в доказательстве эффективности предложенного метода в результате компьютерного моделирования.

Основные параметры эксперимента:

1) Окружающая среда представляет виртуальный лабиринт (150x150 клеток) с автоматическим изменением структуры (одна клетка с периодичностью в 10 с. изменяет свое состояние с проходимой на непроходимую), при этом 1 раз в 100 итераций возможно случайное одновременное изменение состояний до 25% клеток лабиринта.

2) Поставленная задача заключается в поиске агентами целевых состояний (100 шт.), выводимых по 5 шт. одновременно (начальное положение агентов, а также координаты целевых состояний определяются случайным образом). При этом карта окружающей среды со всеми изменениями, параметры агентов и целевых состояний повторяются для всех тестируемых методов.

3) Число агентов – 40 шт., из них:

- 5 шт. – агенты, имеющие вычислительную систему с высоким уровнем производительности;

- 5 шт. – агенты, имеющие вычислительную систему среднего уровня;

- 30 шт. – агенты, имеющие низкопроизводительную вычислительную систему.

4) Число итераций – 300, при этом итерация представляет попытку решения задачи и считается выполненной в случае обнаружения всех целевых состояний.

5) Показатель эффективности метода: время выполнения одной итерации (t).

Результаты проведенного эксперимента представлены на рисунке 2.

На рисунке 2 приняты следующие условные обозначения: Method – предложенный метод синтеза и автоматической адаптации архитектуры и организационной структуры МАС; Method [2] – метод, описанный в [2]; Method [8] – метод, описанный в [8] (без автоматической адаптации организационной структуры МАС).

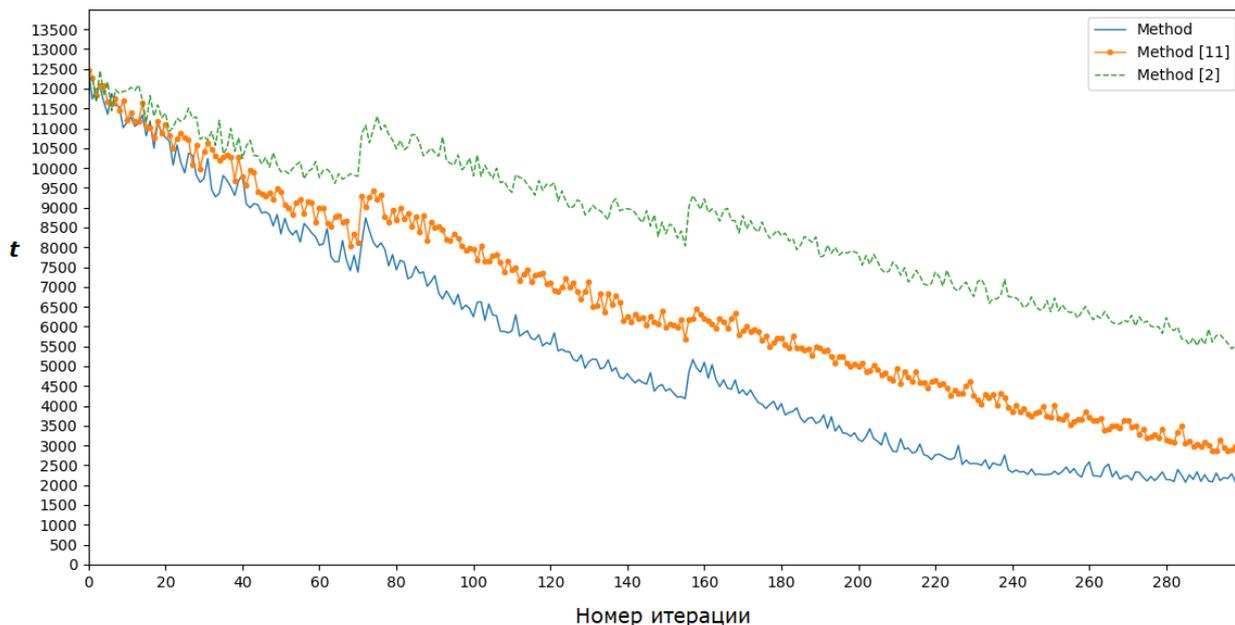


Рис. 2 - Результаты эксперимента

Обсуждение

Как видно на рисунке 2, предложенный метод позволил получить к 300-й итерации лучшие результаты, чем аналогичные решения (в сравнении с [8] преимущество по показателю эффективности в 30%, с [2] – 60%). Разработанный метод показал лучшую устойчивость к резкому изменению структуры лабиринта (см. резкий рост показателя t между следующими итерациями: 60-80, 140-160).

Предложенный метод синтеза и автоматической адаптации архитектуры и организационной структуры МАС удовлетворяет критериям, приводимым в начале статьи, а именно:

1) Возможность априорного определения оптимальной архитектуры МАС, а также последовательности действий для ее адаптации, реализованная

с помощью искусственной нейронной сети. Для оптимизации организационной структуры МАС применяется модифицированный метод (в случае вступления агентов в группу выполняется обнуление «пищи», полученной ими ранее), основанный на применении биогеографического алгоритма.

2) Разработанная «зоосоциальная модель» архитектуры МАС позволяет моделировать следующие типы организационных структур: коалиция, команда, иерархия, федерация, конгрегация (подробнее см. в [7]).

3) Для обучения искусственной нейронной сети, позволяющей получить оптимальную архитектуру МАС, применяется гибридный метод, основанный на применении генетического алгоритма, методов обучения с подкреплением, алгоритма «REINFORCE».

Выводы

В результате был разработан метод синтеза и автоматической адаптации архитектуры и организационной структуры МАС, характеризующийся применением искусственной нейронной сети для предсказания оптимальных действий по модификации архитектуры МАС в случае изменения параметров окружающей среды, условий задачи. Для обучения ИНС применяется алгоритм «REINFORCE», при этом формирование обучающей выборки производится с помощью генетического алгоритма.

Разработанный метод может найти свое практическое применение при выполнении обследования мобильными роботами инфраструктурных объектов; доставке грузов; реализации искусственного интеллекта в компьютерных играх.

Литература

1. Касьянов В.Н. Методы и средства визуализации информации на основе атрибутированных иерархических графов с портами / Сибирский аэрокосмический журнал. 2023. Т. 24. № 1. С. 8-17.
 2. Ling Yu, Zhiqi Shen, Chunyan Miao, Lesser V. Genetic Algorithm Aided Optimization of Hierarchical Multi-Agent System Organization // The Tenth International Conference on Autonomous Agents and Multiagent Systems. Taipei. 2011. URL: researchgate.net/publication/221456103_Genetic_algorithm_aided_optimization_of_hierarchical_multiagent_system_organization
 3. Bistaffa F., Farinelli F., Cerquides J., Rodríguez-Aguilar J., Ramchurn S.D. Anytime Coalition Structure Generation on Synergy Graphs // 2014 international conference on Autonomous agents and multi-agent systems. 2014. URL: researchgate.net/publication/269092245_Anytime_coalition_structure_generation_on_synergy_graphs
 4. Rahwan T., Michalak T.P. Coalition Structure Generation on Graphs // Artificial Intelligence. 2014. URL: researchgate.net/publication/267396027_Coalition_Structure_Generation_on_Graphs
 5. Ghrieb N., Mokhati F., Tahar G. Maintaining Organizational Multi-agent Systems: A Reorganization-based Preventive Approach // 13th International Conference on Agents and Artificial Intelligence. 2021. URL: researchgate.net/publication/349209965_Maintaining_Organizational_Multi-agent_Systems_A_Reorganization-based_Preventive_Approach
 6. Horling B., Lesser V. A Survey of Multi-Agent Organizational Paradigms // A The Knowledge Engineering Review. 2005. № 19(04). Pp. 281 – 316.
-

7. Дубенко Ю.В., Подгорный С.А., Дышкант Е.Е., Демидов В.А. «Зоосоциальная модель» представления архитектуры многоагентной системы // Инженерный вестник Дона. 2025. № 7. URL: ivdon.ru/uploads/article/pdf/IVD_87N6y25_Dubenko.pdf_0e5120ea36.pdf

8. Дубенко Ю.В., Подгорный С.А., Дышкант Е.Е., Демидов В.А. Алгоритм определения оптимальной архитектуры многоагентной системы // Вестник Адыгейского государственного университета. Серия: Естественно-математические и технические науки. 2025. № 1 (356). С. 26-37.

9. Привалов К.С. Обучение с подкреплением в адаптивном управлении параметрами генетического алгоритма // Инженерный вестник Дона. 2025. № 8. URL: ivdon.ru/uploads/article/pdf/IVD_30N9y25_privalov.pdf_c62fb1a5cd.pdf

10. Грессер Л., Кенг Ван Лун Глубокое обучение с подкреплением: теория и практика на языке Python. СПб: Питер, 2022. 416 с.

11. Дубенко Ю.В., Дышкант Е.Е., Обозовский А.А. Метод синтеза организационной структуры централизованных многоагентных систем с возможностью ее автоматической адаптации в случае изменения параметров окружающей среды или поставленной задачи // Известия высших учебных заведений. Поволжский регион. Технические науки. 2023. № 3 (67). С. 18-30.

References

1. Kas'yanov V.N. Sibirskij aerokosmicheskij zhurnal. 2023. Т. 24. № 1. Pp. 8-17.

2. Ling Yu, Zhiqi Shen, Chunyan Miao, Lesser V. The Tenth International Conference on Autonomous Agents and Multiagent Systems. Taipei. 2011. URL: researchgate.net/publication/221456103_Genetic_algorithm_aided_optimization_of_hierarchical_multiagent_system_organization

3. Bistaffa F., Farinelli F., Cerquides J., Rodríguez-Aguilar J., Ramchurn S.D. 2014 international conference on Autonomous agents and multi-agent systems. 2014. URL: [_____](#)



researchgate.net/publication/269092245_Anytime_coalition_structure_generation_on_synergy_graphs

4. Rahwan T., Michalak T.P. Artificial Intelligence. 2014. URL: researchgate.net/publication/267396027_Coalition_Structure_Generation_on_Graphs

5. Ghrieb N., Mokhati F., Tahar G. 13th International Conference on Agents and Artificial Intelligence. 2021. URL: researchgate.net/publication/349209965_Maintaining_Organizational_Multi-agent_Systems_A_Reorganization-based_Preventive_Approach

6. Horling B., Lesser V. A. The Knowledge Engineering Review. 2005. № 19(04). Pp. 281 – 316.

7. Dubenko YU.V., Podgornyy S.A., Dyshkant E.E., Demidov V.A. Inzhenernyy vestnik Dona. 2025. № 7. URL: ivdon.ru/uploads/article/pdf/IVD_87N6y25_Dubenko.pdf_0e5120ea36.pdf

8. Dubenko YU.V., Podgornyy S.A., Dyshkant E.E., Demidov V.A. Vestnik Adygejskogo gosudarstvennogo universiteta. Seriya: Estestvenno-matematicheskie i tekhnicheskie nauki. 2025. № 1 (356). Pp. 26-37.

9. Privalov K.S. Inzhenernyy vestnik Dona. 2025. № 8. URL: ivdon.ru/uploads/article/pdf/IVD_30N9y25_privalov.pdf_c62fb1a5cd.pdf

10. Gresser L., Keng Van Lun Glubokoe obuchenie s podkrepleniem: teoriya i praktika na yazyke Python [Deep Reinforcement Learning: Theory and Practice in Python]. SPb.: Piter, 2022. 416 p.

11. Dubenko YU.V., Dyshkant E.E., Obozovskij A.A. Izvestiya vysshih uchebnyh zavedenij. Povolzhskij region. Tekhnicheskie nauki. 2023. № 3 (67). Pp. 18-30.

Авторы согласен на обработку и хранение персональных данных.

Дата поступления: 24.12.2025

Дата публикации: 28.02.2026
