

УДК 004.65

## МЕТОД РЕКОНФИГУРАЦИИ КИНЕМАТИЧЕСКОЙ СТРУКТУРЫ МЕХАТРОННО-МОДУЛЬНОГО РОБОТА В НЕДЕТЕРМИНИРОВАННЫХ УСЛОВИЯХ

В. И. Петренко<sup>1</sup>, Ф. Б. Тебуева<sup>2</sup>, А. С. Павлов<sup>3</sup>,  
М. М. Гурчинский<sup>4</sup>

<sup>1</sup>vip.petrenko@gmail.com, <sup>2</sup>fariza.teb@gmail.com, <sup>3</sup>losde5530@gmail.com, <sup>4</sup>gurcmikhail@yandex.ru

Институт информационных технологий и телекоммуникаций  
Федеральное государственное автономное образовательное учреждение высшего образования  
«Северо-Кавказский федеральный университет», Ставрополь, Россия

*Поступила в редакцию 22 ноября 2020 г.*

**Аннотация.** Модульные роботы, состоящие из множества однотипных модулей, относятся к одной из самых сложных областей робототехники. Каждый вновь добавленный модуль изменяет форму и возможности конечного устройства, например, добавляет функционал или позволяет роботу перемещаться в новых плоскостях. При этом процесс реконфигурации кинематической структуры представляет собой последовательность перемещений каждого модуля робота из начального положения исходной конфигурации в конечное положение требуемой конфигурации. В работе рассматривается метод реконфигурации кинематической структуры мехатронно-модульного робота с использованием обучения с подкреплением. Предлагаемый метод строится на основе обучающегося алгоритма, где информацией для обучения являются совершаемые действия и «награда», величина, характеризующая качество выполнения целевой задачи роботом. Целью обучения является построение алгоритма управления, максимизирующего суммарную награду за некоторый промежуток времени. Эффективность алгоритма обучения протестирована путем компьютерной симуляции робота, состоящего из 5, 10 и 15 модулей, при формировании целевой конфигурации.

**Ключевые слова:** робототехника, мехатронно-модульный робот, обучение с подкреплением, планирование пути, мультиагентные системы, Q-обучение, автоматизация.

### ВВЕДЕНИЕ

В настоящее время огромный интерес разработчиков робототехнических комплексов привлекают интенсивно развивающиеся беспилотные технологии, концепция использования которых состоит в применении роботов для выполнения рутинных, вредных и опасных видов работ без непосредственного участия человека, что является залогом обеспечения безопасности и высокой эффективности решения поставленных задач [1]. Активные исследования проводятся в области искусственного интеллекта и разработки многофункциональных модульных роботов (ММР) [2-7]. ММР представляют собой робототехнические системы, состоящие из множества гомогенных или гетерогенных

модулей, которые взаимодействуют между собой и обмениваются информацией для выполнения целевой операции. Модули ММР имеют возможность перемещаться относительно друг друга и осуществлять соединение/рассоединение посредством специальных коннекторов, создавая различные конфигурации [2, 3]. Особенность модульной конструкции обеспечивает универсальность и высокую гибкость робота при выполнении поставленной задачи, чем обусловлена обширная область применения ММР. Одной из основных областей применения является эксплуатация ММР при проведении аварийно- и поисково-спасательных работ, спецификой которой являются недетерминированные условия окружающей среды. В данный момент современные ММР не способны полностью заменить человека при выполнении сложных задач в

недетерминированной среде. Неспособность таких роботов полностью заменить человека обусловлена невысокой скоростью выполнения целевых операций в автономном режиме. Причины невысокой скорости выполнения целевой операции ММР заключаются в сложности формализации задачи децентрализованного управления модулями робота при значительном ограничении программных и аппаратных составляющих модулей ММР. Повышение скорости выполнения целевых операций и, как следствие, эффективности функционирования ММР возможно за счет разработки и модификации математических методов и алгоритмов адаптивной реконфигурации кинематической структуры ММР, минимизирующих время выполнения целевой операции. Значительная часть времени при функционировании ММР приходится на выполнение реконфигурации кинематической структуры для преодоления препятствий или ограничений окружающей среды, возникающих при выполнении целевой операции [3]. Уменьшить время, необходимое для изменения конфигурации модулей ММР в соответствии с условиями функционирования, можно путем разработки методов и алгоритмов адаптивной реконфигурации кинематической структуры ММР в недетерминированной среде с препятствиями, что является актуальной задачей в современной прикладной математике и робототехнике.

Создание модульного робота с адаптивной (реконфигуративной) кинематической структурой в наше время – это одно из самых многообещающих направлений в робототехнике. Модульных роботов создают, используя однотипные модули, которые объединяются в цельную конструкцию [6]. Соединение однотипных модулей позволяет выстраивать совершенно разные по своей структуре механизмы. Это дает значительные преимущества по сравнению с классическими мобильными роботами: более высокая надежность и преодоление различных по сложности препятствий [7]. Модульная робототехника объединяет в себе все самые новые успехи робототехники, мехатроники и теории управления. Важнейшей областью применения модульных роботов является экстремальная робототехника, основные задачи которой заключаются в создании и внедрении комплексов, используемых в экстремальных ситуациях.

Модульность конструкции ММР и, как следствие, способность к реконфигурации

кинематической структуры является особенностью современных модульных роботов. Модули являются базовыми элементами робота, а образуемая ими конфигурация непосредственно влияет на эффективность выполнения целевых операций. Для формирования конфигурации робота, соответствующей решаемой задаче и условиям окружающей среды, необходим набор правил для планирования наилучшего пути перемещения модулей из начальной конфигурации А в целевую конфигурацию В без коллизий. Реконфигурация структуры робота представляет собой задачу из класса NP, так как сложность решения задачи растет экспоненциально с увеличением количества модулей [4].

Задачи управления модульными роботами, связанные с формированием и реконфигурацией кинематической структуры, отражены в работах [5–20]. В перечисленных работах предложен методологический подход к разработке методов и алгоритмов реконфигурации структуры роботов с мехатронно-модульной конструкцией. В основу разработки положены следующие методы: системный анализ, методы математического анализа, теория эволюционных алгоритмов, теория распределенных вычислительных систем, теория автоматов, исследование операций, теория принятия решений, теория вероятностей, теория множеств, теория построения моделей сложных систем, теория графов и имитационное моделирование. Однако, на текущем этапе развития модульной робототехники применение данной методологии для управления ММР в недетерминированных условиях становится неэффективным. Это можно объяснить возрастающей сложностью задач, которые решаются роботами данного класса, что неизбежно приводит к увеличению числа показателей управления и усложнению задач управления модулями ММР.

Задачу реконфигурации кинематической структуры ММР можно рассматривать как вариант общей проблемы планирования и управления движением робота, которая была исследована в робототехнике на протяжении многих десятилетий [8–11]. Однако, эта проблема отличается от традиционных подходов тем, что связность модулей (или топология кинематической структуры модульного робота) также изменяется при необходимости. При этом задача усложняется наличием неограниченного количества модулей и, соответственно, избыточной степенью подвижности робота, что требует анализа многомерных данных. Стандартные методы планирования движения, которые хорошо работают с несколькими

измерениями и обеспечивают нахождение решения, являются неэффективными при избыточном количестве степеней подвижности ММР, пространство конфигурации которых может быть очень сложным в силу топологии робота. Планирование пути движения модулей ММР при реконфигурации может быть упрощено путем дискретизации состояний агента. Тогда планирование реконфигурации сводится к поиску последовательности дискретных движений, в которых модули выполняют только одно движение в каждый момент времени [12].

В настоящее время определенное распространение при разработке методов и алгоритмов реконфигурации модульных роботов получили методы искусственного интеллекта (ИИ), что отражено в работах многих исследователей [13-19]. В перечисленных работах использованы следующие методы: генетические алгоритмы, искусственные нейронные сети, клеточные автоматы, алгоритм роя частиц. Анализ полученных результатов показал, что применение подобных методов позволяет ММР наиболее гибко подстраиваться под реальные условия среды, образуя модели полностью адекватные поставленной задаче, что выделяет их на фоне полностью формальных систем. Методы реконфигурации, функционирующие с использованием методов ИИ, не только реализуют стандартные адаптивные методы управления, но и предлагают свои алгоритмические подходы к ряду задач, решение которых вызывает затруднение вследствие их неформализованности [20].

В последнее время большую популярность получили системы управления автономными роботами на основе искусственных нейронных сетей (ИНС). Системы управления на основе ИНС обладают следующими преимуществами:

- способность распараллеливания обработки информации;
- возможность самообучаться, т.е. создавать обобщения;
- возможность решать задачи при неизвестных закономерностях;
- устойчивость к шумам во входных данных;
- возможность адаптации к изменениям окружающей среды;
- возможность потенциально сверхвысоких показателей быстродействия и отказоустойчивости при аппаратной реализации нейронной сети.

В современной робототехнике широко применяются методы декомпозиции, основной идеей которых является разбиение глобальной задачи на группу подзадач. В работе [21] предложен алгоритм планирования движения робота, основан-

ный на декомпозиции целевой задачи на последовательность подзадач. Авторами работы [22] разработан алгоритм распределения задач между контроллерами глобального и локального уровня при управлении роботом. В работе [23] ИНС применяются при реализации обучения с подкреплением для снижения размерности пространства состояний, за счет чего повышается скорость и эффективность обучения группы роботов. Однако к недостаткам ИНС следует отнести высокую вычислительную сложность и низкую скорость обучения в целом, так как наибольшая эффективность достигается за счет увеличения количества слоев нейронов (так называемые глубокие нейронные сети), что также обуславливает специфические требования к вычислительному устройству [16].

Задача повышения эффективности функционирования ММР, в частности, скорости выполнения целевых операций, в недетерминированной среде является весьма острой и до сих пор не нашла своего окончательного решения в большинстве прикладных задач. Очевидно, что дальнейшее развитие модульной робототехники возможно только на основе комплексного подхода, который будет использовать все многообразие существующих методов и средств управления модульной робототехникой. Таким образом, будущее интеллектуального управления модульной робототехникой лежит в сочетании традиционного управления с потенциальными возможностями и перспективами применения систем, основанных на использовании методов ИИ.

## ПОСТАНОВКА ЗАДАЧИ

Целью данной работы является повышение уровня автоматизации интеллектуальных агентов мехатронно-модульного робота при реконфигурации кинематической структуры в недетерминированных условиях за счет применения обучения с подкреплением. Уровень автоматизации интеллектуальных агентов ММР в данной работе измеряется количеством автоматизируемых действий, обеспечивающих функционирование робота при минимальном участии оператора. В обучении с подкреплением существует агент (agent), который взаимодействует с окружающей средой (environment), предпринимая действия (actions). Окружающая среда дает награду (reward) за эти действия, а агент продолжает их предпринимать. На рисунке 1 представлено схематическое представление алгоритма обучения с подкреплением.

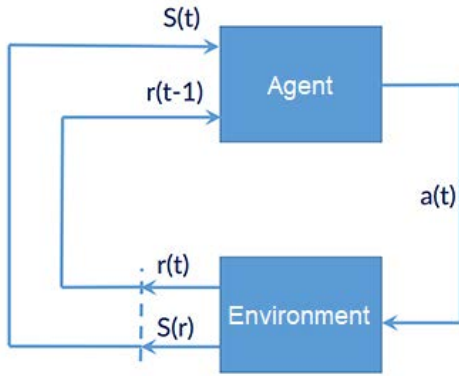


Рис. 1. Схема алгоритма обучения с подкреплением

С помощью использования алгоритмов обучения с подкреплением разработчики могут найти стратегию, приписывающую состояниям (states) окружающей среды действия, одно из которых может выбрать агент в этих состояниях. Среда обычно формулируется как Марковский процесс принятия решений (МППР) с конечным множеством состояний, и в этом смысле алгоритмы обучения с подкреплением тесно связаны с динамическим программированием. Вероятности выигрышей и переходов в новое состояние в МППР обычно являются величинами случайными, но стационарными в рамках задачи.

Формально простейшая модель обучения с подкреплением состоит из:

- множества состояний окружения (states)  $S$ ;
- множества действий (actions)  $A$ ;
- множества вещественнозначных скалярных «выигрышей» (rewards)  $R$ .

В произвольный момент времени  $t$  агент характеризуется состоянием  $s \in S$  и множеством возможных действий  $A(s_t)$ . Выбирая действие  $a \in A(s_t)$ , он переходит в состояние  $s_{t+1}$  и получает выигрыш  $r_t$ . Основываясь на таком взаимодействии с окружающей средой, агент, обучающийся с подкреплением, должен выработать стратегию  $\pi: S \rightarrow A$ , которая максимизирует выигрыш  $R = r_0 + r_1 + \dots + r_n$  в случае МППР, имеющего терминальное состояние, или величину:

$$R = \sum \gamma^t r_t, \quad (1)$$

где  $0 \leq \gamma^t \leq 1$  – дисконтирующий множитель для предстоящего выигрыша.

Таким образом, задачу реконфигурации кинематической структуры ММР можно представить, как последовательность действий, приводящих каждый модуль ММР из текущего положения в целевое положение. Тогда постановка

задачи выглядит следующим образом: необходимо определить множество действий  $a_1, a_2, \dots, a_n$  для каждого модуля ММР для формирования требуемой конфигурации при известных собственном положении  $q_i(x_i, y_i)$  и заданной конфигурации  $P$  с максимально возможным вознаграждением  $R$ .

## МЕТОДЫ

В работе рассматривается один из подходов в обучении с подкреплением, использующий непосредственную параметризацию  $\pi(s, a)$ . Существуют и другие подходы [24], использующие функции качества состояния и действия. Рассматриваемый подход характеризуется простотой в разработке при дискретных пространствах состояний и действий. Рассмотрим один из алгоритмов данного класса – Q-обучение (Q-learning). Данный алгоритм для определения оптимальной политики использует Q-функцию, аргументами которой являются состояние наблюдаемой среды и выбранное действие. Это позволяет итерационным способом построить Q-функцию и тем самым найти оптимальную политику управления. Выражение для обновления Q-функции имеет следующий вид:

$$Q(s_t, a_t) \leftarrow r_t + \alpha[r_{t+1} + \gamma \max_a Q(s_{t+1}, a)], \quad (2)$$

где  $a$  – действие, выбранное в момент времени  $t$  из множества всех возможных действий  $A$ ,  $\alpha$  – коэффициент, определяющий скорость обучения агента.

Оценки Q-функции хранятся в 2-х мерной таблице, входами которой являются состояние и действие. В системах, использующих Q-Learning, выражение (2) обычно комбинируется с методом временной разности (temporal difference, TD( $\lambda$ )), который был предложен в работе [25]. При параметре метода временной разности  $\lambda$ , равном нулю, в обновлении участвуют только текущее и последующее значение прогнозных Q-значений, поэтому в данном случае метод называется одношаговым Q-обучением. Выражение для одношагового Q-обучения имеет следующий вид:

$$Q(s_t, a_t) \leftarrow Q(s_t, a_t) + \alpha[r_{t+1} + \gamma \max_a Q(s_t, a) - Q(s_t, a_t)]. \quad (3)$$

В этом случае искомая функция ценности действия  $Q$ , непосредственно приближается к оптимальной функции ценности действия  $Q^*$ , независимо от применяющейся стратегии. Стратегия определяет, какие пары состояние-действие кор-

ректируются и посещаются, однако для обеспечения сходимости необходимо лишь, чтобы все пары продолжали корректироваться в ходе работы алгоритма. Алгоритм Q-обучения представлен на рис. 2.

```

Инициализировать  $Q(s, a)$  произвольно
Повторять (для каждого эпизода):
    Инициализировать  $s$ 
    Повторять (для каждого эпизода):
        Найти  $a$  по  $s$ , используя стратегию, полученную из  $Q$ 
        Выполнять действие  $a$ , найти  $r, s'$ 
         $Q(s_t, a_t) \leftarrow Q(s_t, a_t) + \alpha[r_{t+1} + \gamma \max_a Q(s_t, a) - Q(s_t, a_t)]$ 
         $s \leftarrow s'$ 
    Пока  $s$  не перейдет в терминальное состояние
    
```

**Рис. 2.** Алгоритм Q-обучения

Для проверки алгоритма на практическом примере в качестве упрощенной модели ММР была выбрана регулярная решетка, в которой один модуль робота (агент) занимает одну клетку. Каждый агент в момент времени  $t$  имеет 5 вариантов действий: шаг вверх, шаг вправо, шаг вниз, шаг влево, остаться на месте.

Для того чтобы уменьшить размер Q-таблицы, наблюдения агента были представлены в векторной форме. Так, текущее положение агента относительно целевой клетки представлено в векторном виде  $q_i'$ , рассчитываемому по формуле (4):

$$V = q_i - q_{Target},$$

$$\begin{cases} x'_i = 1, \text{ if } x_V > 0, \\ x'_i = -1, \text{ if } x_V < 0, \\ x'_i = 0, \text{ if } x_V = 0, \\ y'_i = 1, \text{ if } y_V > 0, \\ y'_i = -1, \text{ if } y_V < 0, \\ y'_i = 0, \text{ if } y_V = 0, \end{cases} \quad (4)$$

где  $x'_i, y'_i$  – координаты позиции агента на следующем шаге,  $x_V, y_V$  – координаты вектора, описывающего положение агента относительно целевой клетки  $q_{Target}$ .

Наблюдениями агента являются данные о собственном положении на регулярной решетке и наличии других агентов в окрестности первого порядка. Наличие одного или нескольких соседних агентов кодируется значением  $n = (0, 1, \dots, 15)$ . Таким образом наблюдения агента можно описать кортежем  $\langle q_i', n \rangle$ . Данные преобразования позволяют агенту четко определить направление, в котором необходимо

двигаться для достижения цели с учетом наличия препятствий (других агентов) в соседних клетках. При этом размер Q-таблицы составил 144 строки и 720 возможных значений оценки Q-функции.

## РЕЗУЛЬТАТЫ


В целях апробации предложенного метода была произведена программная реализация алгоритма на языке программирования Python. При проведении симуляции был использован компьютер со следующими характеристиками: процессор Intel Core i7-8550U 1.8GHz, 8Gb RAM. Параметры алгоритма обучения с подкреплением для реконфигурации ММР представлены в таб. 1.

**Таблица 1.** Параметры алгоритма обучения с подкреплением

Параметр	Значение
Размер поля	10
Количество агентов	5/10/15
Количество эпизодов	50000
Количество шагов в каждом эпизоде	200
Эпсилон (epsilon)	0,99
Скорость обучения (learning rate)	0,3
Фактор дисконтирования	0,95
Вознаграждение за достижение цели одним агентом	10000
Штраф за столкновение с другими агентами	-10000
Штраф за перемещение	-40

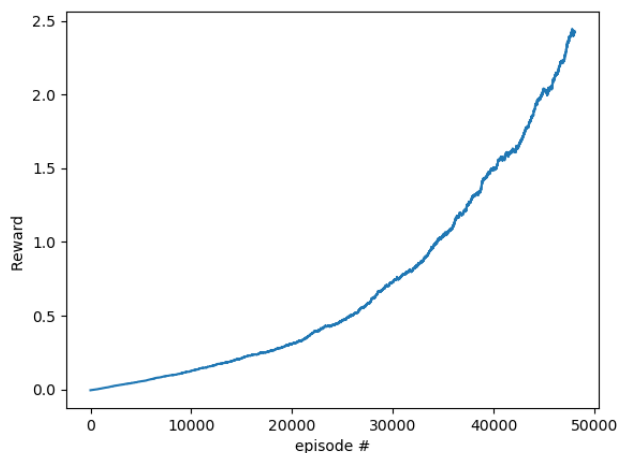
Эпсилон представляет собой коэффициент, определяющий вероятность выбора действия, которое ранее не было исследовано. Фактор обучения – коэффициент, определяющий насколько сильно агент доверяет новой информации. Значение фактора дисконтирования определяет, насколько быстро агент получит вознаграждение за выполняемые действия.

Целевая конфигурация задается набором координат каждого модуля случайно на каждой итерации. Пример начального положения модулей целевой конфигурации для ММР, состоящего из 5 модулей, представлен на рис. 3.




**Рис. 3.** Пример начального положения модулей ММР (клетки, закрашенные серым цветом, означают позиции целевой конфигурации; цветные клетки - агенты)

В ходе обучения 5 агентов среднее значение вознаграждения составило 2103232,2. При этом среднее количество эпизодов, в которых агенты успешно заняли позиции согласно целевой конфигурации, составило 641, что можно считать приемлемым показателем функционирования ММР по сравнению с результатами, полученными при увеличении количества агентов. Результат обучения представлен на рис. 4.




**Рис. 4.** График результата обучения 5 агентов

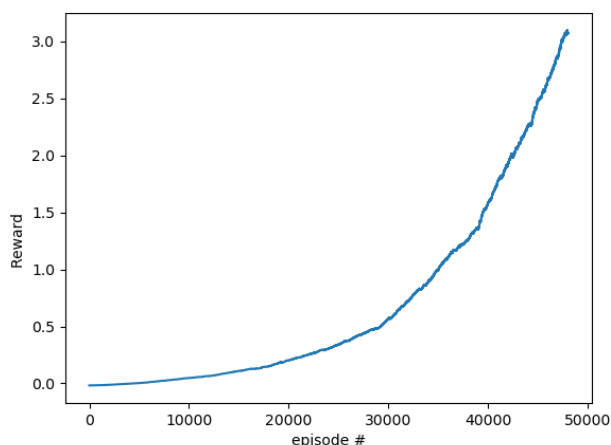
Для проверки масштабируемости алгоритма Q-обучения был проведен эксперимент с 10 и 15 агентами, соответствующие примеры представлены на рис. 5, 6.



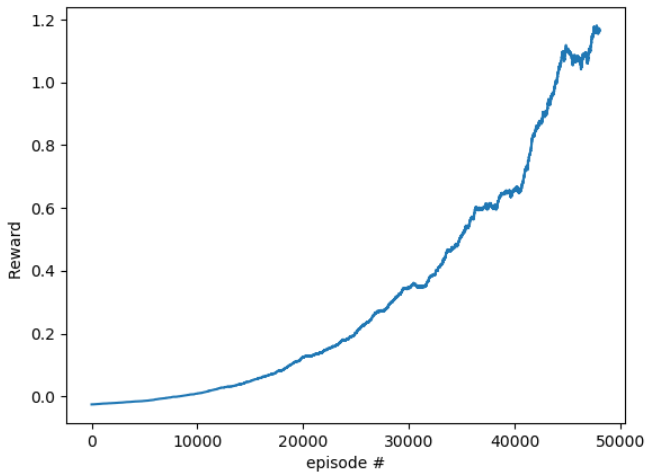
**Рис. 5.** Пример эпизода обучения с подкреплением при масштабировании до 10 агентов



**Рис. 6.** Пример эпизода обучения с подкреплением при масштабировании до 15 агентов  
Результат обучения агентов представлен на рис.7, 8.



**Рис. 7.** Результат обучения с подкреплением при масштабировании 10 агентов



**Рис. 8.** Результат обучения с подкреплением при масштабировании 15 агентов

Для наглядности полученные результаты по обучению 5, 10 и 15 агентов сведены в таблицу 2.

**Таблица 2.** Результаты обучения агентов

Параметр	Количество агентов		
	5	10	15
Среднее вознаграждение	$2.1 * 10^7$	$2.7 * 10^7$	$1.1 * 10^7$
Количество успешно завершённых эпизодов	704	32	0
Количество эпизодов без найденного решения	395	119	6
Количество эпизодов, завершённых коллизиями агентов	901	1849	1994

Согласно данным, представленным в таблице 2, при увеличении количества агентов резко уменьшается количество успешных эпизодов обучения из-за увеличения количества столкновений между агентами. Помимо этого, в процессе обучения были обнаружены проблемные случаи, например, когда целевая конфигурация расположена в углах поля, и первые агенты, достигшие целевые позиции могут блокировать путь остальным агентам. Исходя из вышесказанного, можно сделать вывод о том, что Q-обучение эффективно для малой группы робототехнических объектов без возможности масштабирования.

## ВЫВОДЫ

Несмотря на противоречивость полученных результатов, Q-обучение доказало свою эффек-

тивность при обучении одного агента. Предполагается, что значения Q-таблицы в процессе обучения несколькими агентами многократно переписываются и могут отклоняться от оптимальных значений из-за отсутствия функции аппроксимации. Проверка данного предположения может быть осуществлена путем использования искусственных нейронных сетей вместо Q-таблицы для формирования оптимальной политики агента, на что и будет направлено исследование в дальнейших работах.

Таким образом, в данной статье представлен метод реконфигурации кинематической структуры мехатронно-модульного робота в недетерминированных условиях на основе обучения с подкреплением. В основу метода был положен алгоритм Q-обучения, позволяющий эффективно обучать агента при дискретных пространствах состояний и действий. Представлены результаты моделирования разработанного метода для робота, состоящего из 5, 10 и 15 модулей. Полученные результаты свидетельствуют о необходимости модификации алгоритма Q-обучения для возможности масштабирования системы и повышения уровня автоматизации действий интеллектуальных агентов мехатронно-модульного робота при реконфигурации кинематической структуры в недетерминированных условиях.

## СПИСОК ЛИТЕРАТУРЫ

1. Указ Президента Российской Федерации «О Стратегии научно-технологического развития Российской Федерации» от 01.12.2016 № 642 // Собрание законодательства Российской Федерации. – п.20.
2. M. Yim, W.-M. Shen, B. Salemi, D. Rus, M. Moll, H. Lipson, E. Klavins, and G. Chirikjian, «Modular self-reconfigurable robot systems [grand challenges of robotics]», *Robotics Automation Magazine, IEEE*, vol. 14, no. 1, pp. 43-52, March 2007.
3. Stoy K., Brandt D., & Christensen D. J. (2010). *Self-reconfigurable robots: an introduction*. Cambridge, MA: MIT Press.
4. Gorbenko A.A., Popov V.Y. Programming for modular reconfigurable robots. *Programming and Computer Software*, 2012; 38: 13-23. DOI: 10.1134/S0361768812010033.
5. Petrenko V.I., Tebueva F.B., Pavlov A.S., Antonov V.O., Kochanov M.S. Path Planning Method in the Formation of the Configuration of a Multifunctional Modular Robot Using a Swarm Control Strategy // 7th Scientific Conference on Information Technologies for Intelligent Decision Making Support (ITIDS 2019), *Advances in Intelligent Systems Research*. 2019. Vol-166. P. 165-170. DOI: <https://doi.org/10.2991/itids-19.2019.30>.
6. Mezenceva O.S., Petrenko V.I., Zhilina E., Pavlov A.S., Apurin A.A. Developing a concept of available multi-functional modular robot for education and research // *CEUR Workshop*

Proceedings SLET 2019 - Proceedings of the International Scientific Conference Innovative Approaches to the Application of Digital Technologies in Education and Research. 2019.

7. **Petrenko V., Tebueva F., Pavlov A., Gurchinsky M.** The method of the kinematic structure reconfiguration of a multi-functional modular robot based on the greedy algorithm // 12th International Conference on Developments in eSystems Engineering (DeSE), Kazan, Russia, 2019, pp. 42-47, doi: 10.1109/DeSE.2019.00018.

8. **Kovács G., Yusupova N., Smetanina O., Rassadnikova E.** Methods and algorithms to solve the vehicle routing problem with time windows and further conditions (2018) Pollack Periodica, 13 (1), pp. 65-76. DOI: 10.1556/606.2018.13.1.6.

9. **Kutlubaev I.M., Zhydenko, I.G., Bogdanov, A.A.** Basic concepts of power anthropomorphic grippers construction and calculation (2016) 2016 2nd International Conference on Industrial Engineering, Applications and Manufacturing, ICIEAM 2016 - Proceedings, №7910963. DOI: 10.1109/ICIEAM.2016.7910963.

10. **Petrenko V.I., Tebueva F.B., Gurchinsky M.M., Antonov V.O., Pavlov A.S.** Predictive assessment of operator's hand trajectory with the copying type of control for solution of the inverse dynamic problem. SPIIRAS Proc. 18, 123-147 (2019). DOI: 10.15622/sp.18.1.123-147.

11. **Lynch K.M., Park F.C.** 2017. Modern Robotics. Cambridge, UK: Cambridge Univ. Press.

12. **Liu J., Zhang X., & Hao G.** (2016). Survey on research and development of reconfigurable modular robots. Advances in Mechanical Engineering. DOI: <https://doi.org/10.1177/1687814016659597>.

13. **Ababsa Tarek & DJEDI, NourEddine & Duthen, Yves.** (2017). Genetic Programming-based Self-Reconfiguration Planning for Metamorphic Robot. International Journal of Automation and Computing. DOI: 10.1007/s11633-016-1049-4.

14. **Baca José & Dasgupta Raj & Hossain S.G.M. & Nelson Carl** (2013). Modular robot locomotion based on a distributed fuzzy controller: The combination of modred's basic module motions. Proceedings of the IEEE/RSJ International Conference on Intelligent Robots and Systems. IEEE/RSJ International Conference on Intelligent Robots and Systems. 4302-4307. DOI: 10.1109/IROS.2013.6696973.

15. **Dong Bo & Zhou Fan & Liu Keping & Li Yuanchun.** (2017). Torque sensorless decentralized neuro-optimal control for modular and reconfigurable robots with uncertain environments. Neurocomputing. DOI: 282. 10.1016/j.neucom.2017.12.012.

16. **Guettas Chourouk & Foudil Cherif & , Thomas Breton & Duthen Yves.** (2014). Cooperative Co-evolution of Configuration and Control for Modular Robots. International Conference on Multimedia Computing and Systems - Proceedings. DOI: 10.1109/ICMCS.2014.6911138.

17. **Li Yan & Lu, Zengpeng & Zhou, Fan & Dong, Bo & Liu Keping & Li Yuanchun.** (2019). Decentralized Trajectory Tracking Control for Modular and Reconfigurable Robots With Torque Sensor: Adaptive Terminal Sliding Control-Based Approach. Journal of Dynamic Systems, Measurement, and Control. 141. DOI: 10.1115/1.4042550.

18. **Yeom Kiwon.** (2015). Morphological approach for autonomous and adaptive system: The construction of three-dimensional artificial model based on self-reconfigurable modular agents. Neurocomputing. 148. 100-111. DOI: 10.1016/j.neucom.2012.12.082.

19. **Brunete, A. Ranganath, A. Segovia, S. de Frutos, J. P., Hernando M., & Gambao E.** (2017). Current trends in reconfigurable modular robots design. International Journal of Advanced Robotic Systems. DOI: <https://doi.org/10.1177/1729881417710457>.

20. **Zhu Yanhe & Dongyang Bie & Wang Xiaolu & Zhang, Yu & Jin Hongzhe & Zhao Jie.** (2016). A distributed and parallel control mechanism for self-reconfiguration of modular robots using L-systems and cellular automata. Journal of Parallel and Distributed Computing. 102. DOI: 10.1016/j.jpdc.2016.11.016.

21. **Zhang Q., Fan C.X.** Motion planning of robot on the basis of task decomposition and speed distribution // Huanan Li-gong Daxue Xuebao/Journal South China Univ. Technol. (Natural Sci. South China University of Technology, 2016. T. 44, № 3. C. 44-50. DOI: 10.3969/j.issn.1000-565X.2016.03.007.

22. **Yasuda G.** Distributed Controller Design for Cooperative Robot Systems Based on Hierarchical Task Decomposition // Int. J. Humanoid Robot. World Scientific Publishing Co. Pte Ltd, 2017. T. 14, № 2. DOI: 10.1142/S0219843617500177.

23. **Kawano H.** Hierarchical sub-task decomposition for reinforcement learning of multi-robot delivery mission // Proceedings - IEEE International Conference on Robotics and Automation. 2013. C. 828-835. DOI: 10.1109/ICRA.2013.6630669.

24. **Sutton R., Barto A.** Reinforcement learning: An Introduction. Cambridge, MA: MIT Press, 1998. 322 pp.

25. R.S. Learning to predict by the methods of temporal differences. Mach Learn 3, 9-44 (1988). <https://doi.org/10.1007/BF00115009>.

#### ОБ АВТОРАХ

**ПЕТРЕНКО Владимир Иванович**, заведующий каф. организации и технологии защиты информации, кандидат технических наук, доцент. Иссл.в обл защиты информации, системы связи, конечные поля, сигнальные конструкции, дискретные последовательности, робототехнические системы. **ТЕБУЕВА Фариза**, заведующий каф. прикладной математики и компьютерной безопасности. Д-р физ.-мат. заведующий каф. наук, доцент. Иссл. в обл. моделирования процессов защиты информации в информационно-телекоммуникационных системах, управления робототехническими системами.

**ПАВЛОВ Андрей Сергеевич**, инженер-лаборант, преподаватель кафедры прикладной математики и компьютерной безопасности, аспирант. Исследователь в области искусственного интеллекта, управления робототехническими системами.

**ГУРЧИНСКИЙ Михаил Михайлович**, программист учебно-научной лаборатории робототехнических систем, аспирант. Исследователь в области искусственного интеллекта, управления робототехническими системами.

#### METADATA

**Title:** The method for reconfiguration of the kinematic structure of a mechatronic-modular robot in non-determined conditions

**Authors:** Petrenko V. I. <sup>1</sup>, Tebueva F. B. <sup>2</sup>, Pavlov A. S. <sup>3</sup> Gurchinsky M. M. <sup>4</sup>

**Affiliation:** Institute of Information Technologies and Telecommunications Federal State Autonomous Educational Institution of Higher Education "North Caucasus Federal University", Stavropol, Russia



**Email:** <sup>1</sup> vip.petrenko@gmail.com,  
<sup>2</sup> fariza.teb@gmail.com, <sup>3</sup> losde5530@gmail.com,  
<sup>4</sup> gurcmikhail@yandex.ru

**Language:** Russian.

**Source:** SIIT, no. 2 (4). pp. 57-65, 2020. ISSN 2686-7044 (Online), ISSN 2658-5014 (Print).

**Abstract:** Fuzzy Cognitive Maps (FCMs) are a very simple, useful and powerful tool for modeling and analyzing dynamic complex systems. FCMs can structure virtual worlds that dynamically change with time. Mathematical models of FCMs are reviewed and a number of problems which emerged with them are briefly analyzed. In order to address some of these drawbacks a revised approach is proposed. This approach is being used to analyze the behavior and control the Building Energy Management System of a building. Simulation results of the new method are presented and discussed.

**Key words:** Building energy management system, energy efficiency, fuzzy cognitive maps.

**About authors:**

**PETRENKO Vyacheslav Ivanovich**, Acting Director of the Institute of Mathematics and Information Technologies named Professor N. I. Chervyakov, Head of the Department of Organization and Technology of Information Protection, Candidate of Technical Sciences, Associate Professor. Researcher in the field of information security, communication systems, finite fields, signal structures, discrete sequences, artificial intelligence, control of robotic systems.

**TEBUEVA Fariza Bilyalovna**, Head of the Department of Applied Mathematics and Computer Security, Doctor of Physics and Mathematics, Associate Professor. Researcher in the field of modeling information security processes in information and telecommunication systems, artificial intelligence, control of robotic systems.

**PAVLOV Andrey Sergeevich**, laboratory engineer, lecturer at the Department of Applied Mathematics and Computer Security, postgraduate student. Researcher in the field of artificial intelligence, control of robotic systems.

**GURCHINSKY Mikhail Mikhailovich**, programmer of the educational and scientific laboratory of robotic systems, postgraduate student. Researcher in the field of artificial intelligence, control of robotic systems.