

Методы, технологии и приложения искусственного интеллекта

УДК 004.896

DOI:10.25729/ESI.2025.40.4.002

Система поддержки обучения манипуляционных роботизированных комплексов для технологических операций

Мостаков Николай Алексеевич, Захарова Алёна Александровна

Институт проблем управления им. В.А. Трапезникова РАН,

Россия, Москва, zaawmail@gmail.com

Аннотация. В статье рассматривается работа манипуляционных роботизированных комплексов для наиболее популярных задач в индустрии. В статье приводится реализация классических методов захвата объектов с использованием CAD-модели объекта, отмечены их преимущества и недостатки. В качестве нового решения предложено использовать систему, основанную на применении нейросети архитектуры Action Chunking with Transformers (ACT). Статья детализирует применение нейросетей архитектуры ACT, алгоритм обучения нейросетей и их запуск в рамках технологических операций реальных производств. В работе приводится описание аппаратной части системы, в состав которой входит Коллаборативный манипулятор ARM95, камера глубины RealSense Depth Camera D405 и трекер положения HTC VIVE. В качестве экспериментальной части работы были рассмотрены следующие технологические операции: захват объекта “коробка”, захват объекта “карандаш”, покраска детали и шлифовка поверхности. Разработанная система показывает, что современные технологии, в том числе методов машинного обучения, помогают решать сложные технологические операции с высоким уровнем производительности.

Ключевые слова: робот манипулятор, киберфизические системы, захват объектов, компьютерное зрение

Цитирование: Мостаков Н.А Система поддержки обучения манипуляционных роботизированных комплексов для технологических операций / Н.А. Мостаков, А.А. Захарова // Информационные и математические технологии в науке и управлении, 2025. – № 4(40). – С.17-25. – DOI:10.25729/ESI.2025.40.4.002.

Введение. В работе будут рассмотрены различные варианты использования манипуляционных роботизированных комплексов (МРК), начиная с уже классических задач по движению по точным координатам с использованием систем технического зрения, и заканчивая управлением при помощи нейросети архитектуры Action Chunking with Transformers (ACT), также будет представлена система обучения манипуляционных роботов с использованием нейросети ACT для промышленных задач. ACT – это архитектура нейросети, используемая в робототехнике для обучения манипуляционных роботизированных комплексов сложным технологическим операциям. Она основана на трансформерах и позволяет МРК предсказывать последовательности действий на несколько временных шагов вперед.

МРК становятся всё более востребованными по нескольким ключевым причинам. МРК могут работать без перерывов, в отличие от людей, что значительно увеличивает скорость выполнения процессов окраски и захвата [1]. Это особенно важно в массовом производстве, где требуется высокая частота выполнения однотипных операций. Роботы обеспечивают точность и стабильность в выполнении задач [2, 3].

Роботы часто работают в сложных, динамичных и агрессивных средах, и для успешной навигации или выполнения задач им необходимо уметь принимать решения, основываясь на последовательности действий или событий. Использование ACT позволяет моделям эффективно «запоминать» предыдущие шаги и использовать эту информацию для принятия решений в будущем, что особенно важно в робототехнике.

Преимущество трансформеров в том, что они могут обрабатывать данные, приходящие в виде временных рядов, что идеально подходит для задач, таких, как восприятие окружающего мира роботом и его взаимодействие с этим миром.

МРК используют различные методы и датчики для восприятия окружения [4], что позволяет им эффективно взаимодействовать с объектами и выполнять операции, такие, как захват [5], окраска или сборка продукции.

Существующие решения. Существуют несколько подходов к решению задач с использованием МРК. Наиболее классический подход – это задание человеком-оператором управляющих программ для МРК с заранее известными параметрами. Такой подход используется во всех сферах промышленности, где можно обеспечить неизменность технологического процесса [6]. Данный подход хорошо изучен и описан во многих научных работах [7]. Преимуществом такого подхода является высокая робастность системы, что позволяет обеспечить хорошее качество и высокую производительность в крупно-серийных производствах. Недостатком такого подхода является необходимость переналадки манипуляционного РТК, даже, при небольшом изменении технологического процесса или окружения.

Следующим этапом развития является интеграция элементов технического зрения в роботизированную ячейку [8]. Такой подход значительно повысил вариативность применения МРК. В используемых системах технического зрения (СТЗ), таковое использовалось в связке с различными классическими алгоритмами, такими, как блок-детектор и распознавание линий [9], также СТЗ активно использует наработки в области машинного обучения [10]. Пример использования систем технического зрения также представлен в работе [11] и на рисунке 1. Рисунок 1 демонстрирует классический подход по определению местоположения объекта на основе алгоритма Iterative Closest Point (ICP).




Рис. 1. Метод оценки местоположения детали при помощи ICP алгоритма

Еще одним вариантом управления МРК является режим телеуправления [12], который используется в медицине (хирургические операции, реабилитация), космических исследованиях (управление аппаратами на орбите) и ликвидации последствий аварий (разбор завалов, обезвреживание опасных веществ). Телеуправление позволяет оператору контролировать МРК на расстоянии, что особенно полезно в условиях, где присутствие человека невозможно или опасно.

Следующий этап развития – это полная интеграция МРК, СТЗ и других датчиков в одну систему при помощи мультимодальных нейросетей. Такие системы используются в задачах, требующих точности и визуальной обратной связи, что позволяет системе адаптироваться к изменениям в технологическом процессе и окружении. В работе нейросеть архитектуры АСТ предсказывает целевые положения для следующих k временных шагов системы. Данный подход называется метод Action Chunking with Transformers (АСТ) [4]. Данная работа представляет новый подход в обучении робототехнических систем сложным технологическим операциям. Недостатком обучения, представленного в статье, является наличие «теневого

клона» для обучения, этот подход не работает с промышленными роботами и большими коллаборативными роботами.

Предложенная в работе архитектура системы позволяет обучать МРК без использования ведущей копии, а также избежать столкновений, благодаря модулю симуляции. Дополненная структура АСТ позволяет системе лучше обобщать полученные данные, что повышает локальную точность траектории во время выполнения технологической операции.

Структура АСТ. В ранее опубликованной статье [14] было представлено бимодальное управление (рис. 2), такой подход работает в случае с небольшими роботами, но не эффективен для применения в промышленных системах.




Рис. 2. Обучение сервисного робота [14]

Разработанная и предлагаемая система подходит для промышленных роботизированных систем из-за возможности обучения робота без использования «двойника». Также неоспоримым преимуществом данной системы является возможность использовать на любых МРК с протоколами связи Ethercat и CAN.

Архитектура системы построена на основе архитектуры трансформера, которая использует изображения с камеры робота вместе с описаниями задач, выраженными на естественном языке, в качестве входных данных и напрямую выводит токенизированные действия. Операция “токенизация” – это процесс преобразования последовательности состояния МРК и данных с сенсоров в дискретные элементы (токены), которые модель может эффективно обрабатывать. Использование операции токенизации вводится в работе [17].

Токенизация изображений: изображения (RGB формат) подаются через модель CNN (ResNet) для извлечения пространственных признаков 300x512.

Токенизация действий: измерения действий робота – это 7 переменных, описывающих МРК (6 положений joint в радианах, 1 параметр, отвечающий за состояние захвата, которое имеет дискретное значение).

Алгоритм обучения выглядит следующим образом:

1. Инициализация параметров
 - a. Датасет (6 положений joint в радианах, 1 параметр – состояние рабочего инструмента, изображение с камер).
 - b. Выбор размерности длины последовательности действий для прогнозирования K и выбор гиперпараметра b .
 - c. Определение переменных (действие на одном шаге времени, наблюдение на шаге, наблюдение без изображений).
2. Создание модели
 - a. Инициализация энкодера $q(z \vee a_{t:t+k}, \sigma_t)$. Кодировать последовательность действий и наблюдения в пространстве z .

- б. Инициализация декодера ($\pi_0|\sigma_t, z$). Декодирует наблюдение и пространство z в последовательность действий.
3. Цикл обучения
 - а. Из датасета выбираются случайное наблюдение и последовательность действий.
 - б. Кодирование последовательности a_t в пространство z и декодирование z в a_t .
 - с. Расчет функции потерь $L = L_{\text{рек}}$, где $L_{\text{рек}}$ MSE между предсказанным a_t и истинными a_t .
 - д. Обновление параметров энкодера и декодера.

После обучения модели предлагается следующий алгоритм по ее применению:

1. На вход алгоритма подаются: обученная модель π_0 , T – максимальное количество шагов в эпизоде.
2. Создается очередь для хранения предсказанных действий для шага t .
3. Предсказание действий $a_{t:t+k}$, с помощью модели ($\pi_0|\sigma_t, z$)
4. Добавление предсказанного действия в буфер $B[t + i]$
5. Извлечение из буфера B всех действий, предсказанных для шага t вычисления итогового действия:

$$a_t = \frac{\sum_i w_i \cdot A_t}{\sum_i w_i}, \text{ где } w_i = e^{-mi}.$$

Информационная модель системы. Для сбора данных и управления МТК необходимо предложить способ передачи команд от человека-оператора системе, классические способы управления через задания последовательности точек не подходят для этой операции. Для решения этой проблемы было предложено использовать устройство на базе HTC VIVE (рис. 3). HTC VIVE – это устройство для высокоточного отслеживания положения и ориентации (6 степеней свободы – 6DoF). Высокая точность достигается за счет использования внешних базовых станций (Lighthouse), которые излучают инфракрасные лазеры. Фотодатчики на контроллере регистрируют лазеры, позволяя системе с высокой точностью определять положение в реальном времени.




Рис. 3. Разработанное устройство для записи движений на базе устройства HTC VIVE

К сожалению, в источнике [15] приводится ряд выводов, что для данного датчика характерны выбросы и изменение показаний с течением времени. Часть таких проблем решается правильно подобранными фильтрами, но даже такие фильтры не спасут от коллизии МТК. Для решения этой проблемы предлагается использовать модуль симуляции, который позволит предотвратить коллизию, если во время работы модуля симуляции возникла коллизия, данные на реальный МТК передаваться не будут, что позволит уберечь устройство от поломки. Общая архитектура системы представлена на рис. 4. Архитектура системы состоит из 4 основных частей: Блок сбора данных, Модуль симуляции, Манипулятор, Блок хранения и обработки. Из модуля записи движений на выход подается местоположение и ориентация (кватернион) модуля записи движений ($x, y, z, q1, q2, q3, q4$). Эти данные подаются

в симуляцию, где происходит проверка на корректность выполнения команды “расчет достижимости” и коллизий. Далее проверенные данные переводятся в углы суставов МТК и передаются на реальный МТК с частотой 1 КГц. С реального МТК также снимаются углы суставов и передаются в Блок хранения и обработки.




Рис. 4. Информационная модель системы

Научной новизной предложенного решения является возможность адаптировать робототехнические системы под наиболее популярные операции в манипуляционной робототехнике, не прибегая к программированию системы, оператору необходимо записать около 100 эпизодов в режиме телеуправления для возможности обучения системы.

Экспериментальная часть. Для проверки работоспособности алгоритма был проведен ряд экспериментов с наиболее популярными задачами для манипуляционной робототехники. Для каждого эксперимента был записан ряд эпизодов. Каждый эпизод занимает 8-14 секунд для человека-оператора при выполнении действий в зависимости от сложности операции, что соответствует 400-700 временным шагам при частоте управления 50 Гц. Были записаны около 50 демонстраций для каждой операции. Таким образом, общее количество для демонстраций составляет около 10-20 минут данных для каждой операции. На рисунке 5 показан процесс обучения системы в задаче захвата объектов.




Рис. 5. Снимок процесса сбора данных

Дизайн-эксперимент. Для тестирования и проверки работы предложенного алгоритма предполагается использовать следующие метрики:

- Соотношение успешных действий и общего числа действий (%). Действие считается успешным, если МТК корректно выполнил операцию, ограничений по времени нет.
- Соотношение времени действия при автоматическом выполнении и среднего времени выполнения действия человеком $t_{\text{авт}} - t_{\text{тел}}$.
- Локальная точность траектории во время выполнения действия (мм). Эта метрика описывает отклонение траектории во время автономного режима от средней траектории во время записи операции.

В ходе проведения эксперимента было использовано следующее специализированное оборудование: камера глубины Azure Kinect, манипуляционный робот ARM-IMR-95, веб-камера и устройство для записи движений на базе устройства HTC VIVE. Для реализации телеуправления МТК использовался режим прямого контроля, позволяющий оператору выполнять операции в реальном времени.

Эксперимент состоял из нескольких этапов. На подготовительном этапе осуществлялась установка баз и калибровка модуля записи движений. В процессе записи данных фиксировались семь параметров МТК: угловые координаты шести сочленений (в радианах) и дискретный статус захвата. Также производилась запись RGB-изображений с двух камер, что обеспечило мультимодальный характер обучающего датасета. После записи более 50 эпизодов для каждой операции проводилось обучение нейросетевой модели на основе алгоритма, описанного выше, для записи использовались несколько типов технологических операций. Далее выполнялось тестирование системы в автономном режиме.



Рис. 6. Технологическая операция покраска детали

Результаты эксперимента продемонстрировали высокую эффективность системы в операциях захвата и транспортировки объектов, однако в операциях со сложным движением наблюдается снижение точности выполнения операций. Важным аспектом исследования стала демонстрация устойчивости алгоритма к стохастическим вариациям входных данных, обусловленным антропоморфным характером операторских действий в ходе обучения. Полученные данные свидетельствуют о перспективности применения комбинированного подхода, сочетающего телеуправление и машинное обучение, для создания адаптивных робототехнических систем (рис. 7). В ходе проведения эксперимента также был замечен недостаток выбранного оборудования. Устройство для записи движений на базе устройства HTC VIVE требует установки дополнительных датчиков определения местоположения в рабочей зоне, что значительно усложняет применение такого устройства на реальном производстве. Альтернативой модулю записи движений в дальнейшем предполагается использовать 6-осевое устройство, кинематически копирующее манипуляционный робот ARM-IMR-95 в уменьшенном масштабе.




Рис. 7. Автоматический захват коробки и перемещение объекта в другой поддон

В таблице 1 приведены типы технологических операций и оценена успешность действий.

Таблица 1. Типы технологических операций

Наименование технологической операции	Успешные действия, %	$t_{\text{авт}} - t_{\text{тел}}$, сек	Локальная точность траектории, мм
Захват объекта (коробка)	98%	8	11
Захват объекта (карандаш)	93%	9	18
Покраска детали	70%	2	24
Шлифовка поверхности	72%	5	19

Заключение. Разработанная система управления роботизированными комплексами позволяет повысить адаптивность роботизированных комплексов за счет наличия возможности быстрого обучения системы новым навыкам, не требующего от оператора специальной квалификации. Использование телеуправления и АСТ-архитектуры позволяет обучать МТК сложным составным действиям в недетерминированных средах, с вероятностью успеха 60-90%. Разработанная и представленная в статье система позволяет значительно увеличить скорость внедрения роботизированных комплексов на отечественных производствах. Система была обучена для 4 различных операций, для каждой операции были записаны в среднем около 50 эпизодов, каждый длительностью около 8-14 секунд. Такого количества данных достаточно для успешного выполнения задач с вероятностью более 70%. Показатели по метрикам: время выполнения операции и локальная точность траектории – показывают возможность внедрения данной системы на реальных производствах. К недостаткам разработанного решения можно отнести тот факт, что используется метод имитационного обучения, для данного метода характерны недостатки в части того, что метод может не превзойти производительность демонстраций. Еще одним недостатком является ограничение на обобщения новых инструкций комбинациями ранее увиденных.

Для развития системы планируется добавить RL-обучение для минимизации количества данных, необходимых для обучения. Также сейчас разработана VLA-модель, но от оператора все еще требуется задавать правильный порядок действий, в дальнейшем планируется добавить верхнеуровневую сеть VLM, которая будет создавать цепочку действий для VLA модели, что позволит устранить указанные выше недостатки и повысить производительность системы и степень автономности ее работы.

Список источников

1. Ji W., Wang L. Industrial robotic machining: a review. The international journal of advanced manufacturing technology, 2019, vol. 103, pp. 1239–1255.
2. Zhang Y., Li X., Wang J. A Review of paint robots: technologies, applications, and challenges. International Journal of advanced robotic systems, 2020, vol. 17, no. 4.
3. Kingsley K., Stanley O. Design of robotic manipulator for painting purposes in automotive industry. Global Journal of engineering and technology advances, 2022, vol. 13, no. 2, pp. 054–059.
4. Vaswani A., Shazeer N.M., Parmar N., et al. Attention is all you need. Advances in neural information processing systems, 2017, vol. 30, pp. 5998–6008.
5. Bicchi A., Kumar V. Robotic Grasping and Manipulation. In: Siciliano B., Valavanis K.P. (eds) Control Problems in Robotics and Automation, Lecture notes in control and information sciences, 1998, vol. 230. Springer, London. DOI: 10.1007/BFb0015076.
6. Karabegović I. The Role of industrial robots in the development of automotive industry in China. Journal of Intelligent Manufacturing, 2016, vol. 27, pp. 1–12.
7. Беклемишев Н.Д. Алгоритмы управления движением схвата манипулятора. – М.: ИПМ им. М.В. Келдыша, 2017. – 47 с.
8. Inish T., Shaan U. Integration of vision system onto robotic arm. International Research Journal of Modernization in Engineering Technology and Science (IRJMETS), 2024.
9. Kaur U., Narula R. Vision-based control of robotic manipulator. Journal of Advanced Research in Automotive Engineering (JAAE), 2016, pp. 205–212.
10. Quillen D., Jang E., Nachum O. Deep Reinforcement Learning for Vision-Based Robotic Grasping: A Simulated Comparative Evaluation of Off-Policy Methods. Machines, 2023, pp. 11–16.
11. Захарова А.А. Автоматизация процесса покраски металлических деталей со сложной геометрической формой / А.А. Захарова, Н.А. Мостаков, А.О. Винокуров // Материалы Международной конференции молодых ученых [МКПУ-2023]. – 2023.
12. Wu P., Shentu Y. GELLO: A General, Low-Cost, and Intuitive Teleoperation Framework for Robot Manipulators. IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), 2024.
13. Lai L., Huang A.Z., Gershman S.J. Action chunking as policy compression. 2022. DOI: 10.31234/osf.io/z8yrv_v2.
14. Zhao T.Z., Kumar V., Levine S., Finn C. Learning Fine-Grained Bimanual Manipulation with Low-Cost Hardware. Robotics: Science and Systems (RSS), 2023, DOI: 10.48550/arXiv.2304.13705.
15. Kulozik J., Jarrassé N. Evaluating the precision of the HTC VIVE Ultimate Tracker. 2024, DOI: 0.48550/arXiv.2409.01947.
16. Shahria M.T., Sunny M.S.H. A Comprehensive Review of Vision-Based Robotic Applications. Robotics, 2022, DOI: 10.3390/robotics11060139.
17. Chau G., An Y., Iqbal A.R. Generalizability Under Sensor Failure: Tokenization + Transformers Enable More Robust Latent Spaces. Computer Science, 2024, DOI: 10.48550/arXiv.2402.18546.

Захарова Алёна Александровна. Докт. техн. наук, главный научный сотрудник, лаборатория Киберфизических систем, Институт проблем управления им. В.А. Трапезникова РАН. AuthorID: 101862, SPIN: 2683-7199, ORCID: 0000-0003-4221-7710, Researcher ID: F-8209-2017, 117997, Россия, Москва.

Мостаков Николай Алексеевич. аспирант, лаборатория Киберфизических систем, Институт проблем управления им. В.А. Трапезникова РАН. AuthorID: 1086261, SPIN: 5393-7773, ORCID: 0000-0002-3746-3493, 117997, Россия, Москва.

UDC 004.896

DOI:10.25729/ESI.2025.40.4.002

System for training manipulation RTK for technological operations

Nikolay A. Mostakov, Alena A. Zakharova

Trapeznikov Institute of Control Sciences of the Russian Academy of Sciences,
Russia, Moscow, zaawmail@gmail.com

Abstract. The article discusses the operation of robotic manipulation systems for the most popular tasks in the industry. The article provides an implementation of classical methods for grasping objects using a CAD model of

the object, highlights their advantages and disadvantages. As a new solution, it is proposed to use a system based on the Action Chunking with Transformers (ACT) neural network architecture. The article details the use of ACT neural networks, the algorithm for training neural networks and launching them within the framework of technological operations of real production. The paper describes the hardware of the system, which includes the ARM95 Collaborative Manipulator, the RealSense Depth Camera D405 depth camera and the HTC VIVE position tracker. The following technological operations were considered as an experimental part of the work: grasping a box object, grasping a pencil object, painting a part and grinding a surface. The developed system shows that modern technologies, including machine learning methods, help to solve complex technological operations with a high level of productivity.

Keywords: robot manipulator, cyber-physical systems, grasping objects, computer vision

References

1. Ji W., Wang L. Industrial robotic machining: a review. The international journal of advanced manufacturing technology, 2019, vol. 103, pp. 1239–1255.
2. Zhang Y., Li X., Wang J. A Review of paint robots: technologies, applications, and challenges. International Journal of advanced robotic systems, 2020, vol. 17, no. 4.
3. Kingsley K., Stanley O. Design of robotic manipulator for painting purposes in automotive industry. Global Journal of engineering and technology advances, 2022, vol. 13, no. 2, pp. 054–059.
4. Vaswani A., Shazeer N.M., Parmar N., et al. Attention is all you need. Advances in neural information processing systems, 2017, vol. 30, pp. 5998–6008.
5. Bicchi A., Kumar V. Robotic Grasping and Manipulation. In: Siciliano B., Valavanis K.P. (eds) Control Problems in Robotics and Automation, Lecture notes in control and information sciences, 1998, vol. 230. Springer, London. DOI: 10.1007/BFb0015076.
6. Karabegović I. The Role of industrial robots in the development of automotive industry in China. Journal of Intelligent Manufacturing, 2016, vol. 27, pp. 1–12.
7. Beklemishev N.D. Algoritmy upravleniya dvizheniem skhvata manipulyatora [Algorithms for controlling the movement of a manipulator gripper]. Moscow, IPM im. M.V. Keldysha [Keldysh Institute of Applied Mathematics] Publ., 2017, 47 p.
8. Inish T., Shaan U. Integration of vision system onto robotic arm. International Research Journal of Modernization in Engineering Technology and Science (IRJMETS), 2024.
9. Kaur U., Narula R. Vision-based control of robotic manipulator. Journal of Advanced Research in Automotive Engineering (JAAE), 2016, pp. 205–212.
10. Quillen D., Jang E., Nachum O. Deep Reinforcement Learning for Vision-Based Robotic Grasping: A Simulated Comparative Evaluation of Off-Policy Methods. Machines, 2023, pp. 11–16.
11. Zakharova A.A., Mostakov N.A., Vinokurov A.O. Avtomatizatsiya protsessa pokraski metallicheskih detaley so slozhnoy geometricheskoy formoy [Automation of the painting process for metal parts with complex geometric shapes]. Materialy Mezhdunarodnoy konferentsii molodykh uchenykh [Proceedings of the International Conference of Young Scientists (MKPU-2023)], 2023.
12. Wu P., Shentu Y. GELLO: A General, Low-Cost, and Intuitive Teleoperation Framework for Robot Manipulators. IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), 2024.
13. Lai L., Huang A.Z., Gershman S.J. Action chunking as policy compression. 2022. DOI: 10.31234/osf.io/z8yrv_v2.
14. Zhao T.Z., Kumar V., Levine S., Finn C. Learning Fine-Grained Bimanual Manipulation with Low-Cost Hardware. Robotics: Science and Systems (RSS), 2023, DOI: 10.48550/arXiv.2304.13705.
15. Kulozik J., Jarrassé N. Evaluating the precision of the HTC VIVE Ultimate Tracker. 2024, DOI: 0.48550/arXiv.2409.01947.
16. Shahria M.T., Sunny M.S.H. A Comprehensive Review of Vision-Based Robotic Applications. Robotics, 2022, DOI: 10.3390/robotics11060139.
17. Chau G., An Y., Iqbal A.R. Generalizability Under Sensor Failure: Tokenization + Transformers Enable More Robust Latent Spaces. Computer Science, 2024, DOI: 10.48550/arXiv.2402.18546.

Zakharova Alena Alexandrovna. Dr. Sci. (Tech.), chief Scientific Officer, Laboratory of Cybernetic Systems, V.A. Trapeznikov Institute of Control Sciences of RAS. AuthorID: 101862, SPIN: 2683-7199, ORCID: 0000-0003-4221-7710, Researcher ID: F-8209-2017, Moscow, Russia.

Mostakov Nikolay Alexeyevich. graduate student, Laboratory of Cybernetic Systems, V.A. Trapeznikov Institute of Control Sciences of RAS. AuthorID: 1086261, SPIN: 5393-7773, ORCID: 0000-0002-3746-3493, Moscow, Russia.

Статья поступила в редакцию 06.08.2025; одобрена после рецензирования 01.10.2025; принята к публикации 03.10.2025.

The article was submitted 08/06/2025; approved after reviewing 10/01/2025; accepted for publication 10/03/2025