

УДК 51–74

DOI: [10.26102/2310-6018/2024.47.4.017](https://doi.org/10.26102/2310-6018/2024.47.4.017)

Построение прогностических агентных моделей на основе включения моделей машинного обучения в определение состояния агентов

А.С. Лисовенко^{1✉}, Д.А. Тарасов¹, А.С. Шишмарева²

¹Уральский федеральный университет имени первого Президента России Б.Н. Ельцина, Екатеринбург, Российская Федерация

²Уральский государственный медицинский университет Министерства здравоохранения Российской Федерации, Екатеринбург, Российская Федерация

Резюме. Сфера агентного моделирования продолжает развиваться в сторону создания более интеллектуальных агентов. В рамках этого возникает концептуальная проблема поиска баланса между детерминированностью поведения агентов и способностью этих агентов к обучению и прогнозированию своего состояния. Одним из потенциальных направлений решения этой проблемы является рассмотрение возможности разработки промежуточного подхода в создании агентов, при котором агенты сохраняют детерминированность своего поведения, но одновременно с этим способны прогнозировать свое состояние и корректировать поведение. В статье представлен новый подход к построению интеллектуальных агентов, который комбинирует классический подход построения агентов, основанный на априорно задаваемых правилах, и применение методов машинного обучения в правилах поведения агентов. Представлено математическое описание предложенной функции расчета состояния агента с использованием моделей машинного обучения, а также алгоритм расчета состояний агентов в модели. Также приведен пример построения агентной модели с применением предложенного подхода. Предложенный подход позволяет разрабатывать агентные модели сложных систем, в которых агенты являются реактивными, но способны спрогнозировать свое состояние и учесть прогноз в определении своего текущего состояния.

Ключевые слова: агентное моделирование, интеллектуальные агенты, подход к построению интеллектуальных агентов, прогнозирование состояния, машинное обучение.

Для цитирования: Лисовенко А.С., Тарасов Д.А., Шишмарева А.С. Построение прогностических агентных моделей на основе включения моделей машинного обучения в определение состояния агентов. *Моделирование, оптимизация и информационные технологии*. 2024;12(4). URL: <https://moitvivr.ru/ru/journal/pdf?id=1728> DOI: 10.26102/2310-6018/2024.47.4.017

Building predictive agent models based on the inclusion of machine learning models in determining the state of agents

A.S. Lisovenko^{1✉}, D.A. Tarasov¹, A.S. Shishmareva²

¹Ural Federal University named after the first President of Russia B.N. Yeltsin, Yekaterinburg, the Russian Federation

²Ural State Medical University of the Ministry of Health of the Russian Federation, Yekaterinburg, the Russian Federation

Abstract. The field of agent modeling continues to evolve towards the creation of more intelligent agents. This raises the conceptual problem of finding a balance between the determinism of agents' behavior and the ability of these agents to learn and predict their condition. One of the potential ways to solve this problem is to consider the possibility of developing an intermediate approach in the creation of agents, in which agents maintain the determinism of their behavior, but at the same time are able to

predict their condition and correct behavior. The article presents a new approach to building intelligent agents, which combines the classical approach of building agents based on a priori set rules and the application of machine learning methods in the rules of agent behavior. A mathematical description of the proposed function for calculating the state of an agent using machine learning models is presented, as well as an algorithm for calculating the states of agents in the model. An example of building an agent model using the proposed approach is also given. The proposed approach makes it possible to develop agent models of complex systems in which agents are reactive but are able to predict their state and take into account the predict in determining their current state.

Keywords: agent modeling, intelligent agents, the approach of building intelligent agents, predicting the state, machine learning.

For citation: Lisovenko A.S., Tarasov D.A., Shishmareva A.S. Building predictive agent models based on the inclusion of machine learning models in determining the state of agents. *Modeling, Optimization and Information Technology*. 2024;12(4). URL: <https://moitvvt.ru/ru/journal/pdf?id=1728> DOI: 10.26102/2310-6018/2024.47.4.017 (In Russ.).

Введение

Агентное моделирование является мощным инструментом моделирования сложных систем, когда систему затруднительно или невозможно представить в виде описывающих ее уравнений, и широко применяется в различных предметных областях для изучения закономерностей системного уровня, возникающих в результате индивидуального поведения и взаимодействия агентов [1]. Широкая область применения метода агентного моделирования подтверждается большим количеством агентных моделей в области естественных, социальных, физических наук, инженерных систем и сфере бизнеса [2, 3].

Сфера агентного моделирования по-прежнему сталкивается с проблемами моделирования более интеллектуальных агентов, описывающих части или процессы моделируемой системы [4]. Одна из таких концептуальных проблем заключается в том, что классические агентные модели основаны на заранее запрограммированных правилах поведения агентов, что вносит существенные ограничения в возможность обучения агентов на своем прошлом опыте и обеспечения их более интеллектуального поведения [4].

Вариантом решения описанной выше проблемы является применение методов машинного обучения в построении агентных моделей [4, 5], что подтверждается рядом научных работ, где методы машинного обучения в области агентного моделирования уже успешно используются для решения различных задач прогнозирования состояния моделируемой системы [6, 7].

Несмотря на широкое применение методов машинного обучения в агентных моделях для решения задач прогнозирования, у этого метода также есть ограничение – правила поведения агента, заданные с помощью метода машинного обучения, теряют репрезентативность: правила поведения агента выводятся динамически в ходе симуляций. Данный подход хорошо показывает себя в задачах прогнозирования состояния сложной системы, где элементы системы являются динамическими и предполагают изменение своего поведения с течением времени [4, 8–10].

С другой стороны, данный подход является нецелесообразным для задач прогнозирования состояния системы, где поведение элементов системы необходимо задать априорно, но также необходимо провести ряд симуляций с целью определения эффективности внешних воздействий на элементы системы. Задачи такого типа близки к задачам систем автоматического управления [11], однако не ограничиваются этим перечнем и направлены на создание цифровых двойников моделируемых систем,

которые способны спрогнозировать свое состояние на будущее время. Например, к таким задачам относится создание прогностического цифрового двойника состояния воздушной линии электропередачи [12] и прогностического цифрового двойника состояния здоровья пациента [13]. Под цифровым двойником сложной системы при этом подразумевается ее программный аналог, который в виртуальной среде имитирует технические характеристики и поведение своего реального прототипа.

Построение агентных моделей для решения задач описанного выше типа:

1. Не требует динамического определения правил поведения агентов, так как элементы системы являются реактивными (реагируют только на внешние воздействия). Поэтому поведение агентов можно задать априорно.

2. Требует определенной степени интеллектуальности агентов. Агенты должны быть способны спрогнозировать свое состояние при воздействии на них и предпринять априорно заданные им действия с учетом прогнозов.

Классический подход построения агентов модели, основанный на априорно задаваемых правилах поведения агентов, способен учесть первый пункт, но не способен учесть второй, так как агенты не имеют возможности прогнозирования своего состояния. Использование методов машинного обучения в определении правил поведения агентов повышает интеллектуальность агентов к прогнозированию своего состояния, но является нецелесообразным для выполнения первого пункта.

Цель данной работы – предложить подход построения агентов, который способен обеспечить интеллектуальность агента без необходимости отказа от априорно задаваемых правил поведения агентов.

Задачей данной работы является комбинация классического подхода построения агентов модели на основе заданных правил и подхода использования методов машинного обучения в определении поведения агента путем использования предварительно обученных моделей машинного обучения в априорно задаваемых правилах поведения агентов. Математическая постановка описанной выше задачи заключается в разработке функции перехода между состояниями агента, которая включает в себя использование предварительно обученных моделей машинного обучения.

Материалы и методы

Метод агентного моделирования. Метод агентного моделирования заключается в декомпозиции моделируемой системы на ряд взаимосвязанных между собой агентов, каждый из которых характеризует собой часть системы или процесс, происходящий в ней.

В подходе построения агентных моделей, основанных на правилах, каждый агент описывается совокупностью переменных, возможных состояний агента и априорных правил поведения в виде правил перехода между этими состояниями. При построении интеллектуальных агентов, использующих методы машинного обучения, априорные правила поведения агента определяются динамически. В основном для построения интеллектуальных агентов используется алгоритм обучения с подкреплением Q-learning [8]: алгоритм имитирует обучение агента методом проб и ошибок с получением вознаграждения. На основе получаемого от окружающей агента среды вознаграждения агент формирует функцию полезности Q , которая непосредственно влияет на выбираемые агентом действия.

Независимо от способа построения агентов, построенная агентная модель предназначена для проведения ряда программных симуляций, направленных на изучение поведения агентов в модели, получения результата симуляций в виде набора

данных о состояниях агентов и о наблюдаемых событиях в ходе их взаимодействия между собой и окружающей средой.

Предварительно обученные модели машинного обучения. При рассмотрении агентных моделей сложных систем, выполняющих задачи их прогностических цифровых двойников, у агентов модели не стоит задача динамического получения правил своего поведения путем проб и ошибок. Агенты являются реактивными, их поведение можно описать априорными правилами. Однако у агентов модели также стоит задача прогнозирования своего состояния при внешних воздействиях на них, что требует определенной степени их интеллектуальности. Поэтому вариантом обеспечения интеллектуальности агентов в агентных моделях, выполняющих задачи прогностических цифровых двойников, является использование предварительно обученных моделей машинного обучения в априорно заданных правилах поведения агентов.

Результаты

Построение функции перехода между состояниями агента с использованием моделей машинного обучения. При использовании подхода построения агентов модели, основанного на априорных правилах, структура агента описывается набором переменных P , конечным автоматом $G(V, E)$, где V – состояния агента, а E – правила перехода между состояниями на основе переменных агента. Переход между состояниями при этом задается функцией $f: P_t \rightarrow V_t$, которая на вход получает значения переменных агента P_t , а на выходе – новое состояние агента V_t .

В классическом подходе построения основанной на правилах агентов модели реализация функции f представляет собой набор операций if-else на входном наборе данных P_t в текущий момент времени t симуляции. Набор операций if-else при этом определяется на основе правил перехода между состояниями E и основан только на текущих переменных агента. Обобщенно функцию f в данном подходе можно представить формулой (1):

$$V_t = f(P_t). \quad (1)$$

В предлагаемом авторами работы подходе построения прогностических агентов, основанных на правилах, в реализацию функции перехода между состояниями функции f добавляется возможность включить множество предварительно обученных моделей машинного обучения $M_{it_s}, i \in [1, n]$, n – количество моделей. Модели M_{it_s} используются для прогнозирования переменных агента P_{t_s} на моменты времени $t + t_s$, где t – текущий момент времени симуляции, t_s – шаг прогнозирования во временном интервале. Модели машинного обучения M_{it_s} включаются в набор операций if-else функции расчета состояния агента.

Таким образом, функция f в предлагаемом подходе принимает следующий вид:

$$\begin{aligned} P_{it_s} &= M_{it_s}(P_t), i \in [1, n], \\ P_{it_s} &\in P_{t+t_s}, \\ V_t &= f(P_t, P_{t+t_s}), \end{aligned} \quad (2)$$

где M_{it_s} – предварительно обученная модель машинного обучения для прогнозирования переменной P_i агента для временной отметки $t + t_s$, n – количество прогнозируемых переменных агента, t – текущий момент времени симуляции, t_s – шаг прогнозирования во временном интервале, P_{it_s} – значение прогнозируемой переменной агента P_i на

момент времени $t + t_s$, P_t – множество значений переменных агента на момент времени t , P_{t+t_s} – множество спрогнозированных переменных агента на момент времени $t + t_s$, V_t – состояние агента на момент времени t , f – функция определения состояния V_t агента из множества возможных состояний V .

Алгоритм расчета состояния агентов. Алгоритм расчета состояния агентов расширяет классический алгоритм, основанный на заранее определенных правилах поведения агентов путем включения в расчет функции (2).

Алгоритм вводит иерархическую структуру агентов, при которой у каждого агента A есть множество агентов нижнего уровня $\{A_k\}$ и агентов верхнего уровня $\{A_m\}$. В данной иерархии исключаются циклические зависимости, т. е. структура агентов имеет вид дерева.

В ходе симуляции при необходимости прогнозирования состояния агентов в момент времени t на момент времени $t + t_s$ выполняется следующий алгоритм для каждого агента A модели:

1. Агент запрашивает данные P_t для расчета своего состояния, исходя из тех переменных, которые участвуют в функции перехода между состояниями f . В том числе запрашиваются данные, необходимые в качестве входных параметров для модели машинного обучения M_{it_s} . В случае, если запрошенные данные ожидаются от агентов нижнего уровня $\{A_k\}$, агент ожидает их.

2. Рассчитываются переменные агента P_{it_s} с использованием моделей машинного обучения M_{it_s} .

3. Агент информирует связанных с ним агентов $\{A_m\}$ о рассчитанных переменных P_{it_s} .

4. Вычисляется состояние агента V_t по формуле (2).

5. Если агент получает уведомление об обновлении переменных агентов нижнего уровня $\{A_k\}$, повторяются шаги 1–4.

Алгоритм завершает свою работу, когда у всех агентов проставлена отметка о том, что рассчитаны соответствующие состояния V_t для агентов.

Апробация

В качестве примера использования предложенного подхода построения прогностических агентов на основе априорно задаваемых правил поведения была рассмотрена следующая задача: выявление детей от 3 до 17 лет с высоким риском развития тяжелых нарушений зубочелюстной системы (ЗЧС). Решение данной задачи с помощью агентного моделирования мотивировано внедрением в медицинские учреждения информационных технологий, направленных на индивидуализацию подхода к пациенту [13]. Составленная агентная модель при этом – инструмент для помощи врачу в определении нуждаемости в раннем ортодонтическом лечении конкретного ребенка для обеспечения максимального эффекта восстановления физиологического развития ЗЧС.

В рамках примера в агентной модели 1 тип агента – «ЗЧС». У данного агента не стоит задача динамического получения правил своего поведения, так как сам по себе агент является реактивным. Задачей агента является отслеживание текущего состояния ЗЧС ребенка, а также прогнозирование, как могут развиваться нарушения ЗЧС при его взрослении и при лечении или его отсутствии. Поэтому для построения агента «ЗЧС» был применен предложенный в данной работе прогностический подход построения агентов, основанный на априорно задаваемых правилах с применением в них предварительно обученных моделей машинного обучения.

В агенте «ЗЧС» выделены следующие переменные P :

- 1) Age – возраст ребенка (лет);
- 2) $Balls$ – сумма баллов, характеризующих степень нарушения ЗЧС;
- 3) S – числовая характеристика степени нарушения ЗЧС в отрезке от 0 до 4 в зависимости от тяжести нарушений;
- 4) S_{pred} – прогнозируемые числовые характеристики степени нарушения ЗЧС на более старший возраст;
- 5) Показатели нарушений зубочелюстной системы [14]: обратная саггитальная щель (мм), саггитальная щель (мм), вертикальная дизокклюзия во фронтальном или боковом участке (мм), глубокое резцовое перекрытие более 3,5 мм (мм), глубокое резцовое перекрытие до контакта с десной / небом, без травмы (мм), глубокое резцовое перекрытие с травмой десны / неба (мм), смещение нижней челюсти назад, смещение нижней челюсти в сторону, смещение нижней челюсти вперед (мм), уменьшение общей длины зубного ряда на 1 зуб (да / нет), общей длины зубного ряда на 2 зуба и более (да / нет), сужение верхнего зубного ряда в области первых моляров (мм).

Для прогнозирования степеней тяжести нарушений ЗЧС S_{pred} были разработаны 9 моделей машинного обучения M в зависимости от возраста ребенка и применения к ребенку ортодонтического лечения (ОЛ) [14]. В Таблице 1 представлены обозначения этих моделей, их точность и описание. Описание строится по принципу принадлежности модели прогнозирования степени нарушения ЗЧС для детей текущего возраста на более старший возраст с использованием или отсутствием ОЛ.

Таблица 1 – Модели машинного обучения для прогнозирования степени нарушения ЗЧС у детей в возрасте 3–17 лет

Table 1 – Machine learning models for predicting the degree of impairment of the dental system in children aged 3–17 years

Обозначение модели	Описание	Точность
$M_{from_3_5_to_6_9_no}$	для детей 3–5 лет на возраст 6–9 лет без ОЛ	82–86 %
$M_{from_3_5_to_10_12_no}$	для детей 3–5 лет на возраст 10–12 лет без ОЛ	
$M_{from_3_5_to_13_17_no}$	для детей 3–5 лет на возраст 13–17 лет без ОЛ	
$M_{from_6_9_to_10_12_no}$	для детей 6–9 лет на возраст 10–12 лет без ОЛ	92–97 %
$M_{from_6_9_to_13_17_no}$	для детей 6–9 лет на возраст 13–17 лет без ОЛ	
$M_{from_10_12_to_13_17_no}$	для детей 10–12 лет на возраст 13–17 лет без ОЛ	94 %
$M_{from_3_5_to_6_9_yes}$	для детей 3–5 лет на возраст 6–9 лет с ОЛ	82–90 %
$M_{from_6_9_to_10_12_yes}$	для детей 6–9 лет на возраст 10–12 лет с ОЛ	
$M_{from_10_12_to_13_17_yes}$	для детей 10–12 лет на возраст 13–17 лет без ОЛ	

В зависимости от текущего возраста ребенка к расчету множества S_{pred} применяется только часть этих моделей. Например, если возраст ребенка Age равен 10, то для прогнозирования степени тяжести будут использоваться модели $M_{from_10_12_to_13_17_no}$ и $M_{from_10_12_to_13_17_yes}$.

Состояния V агента «ЗЧС» основываются на значениях переменных S и переменных из множества S_{pred} . В Таблице 2 представлены наименования состояний агента «ЗЧС» и правила перехода в эти состояния. При составлении списка возможных состояний исключаются варианты, когда при лечении происходит ухудшение состояния ЗЧС. В таблице под S_{yes} подразумевается спрогнозированная степень нарушения ЗЧС с учетом применения ОЛ.

Таблица 2 – Состояния и правила перехода в них для агента «ЗЧС»
Table 2 – States and rules of transition to them for the agent «ЗЧС»

Состояние	Описание	Правило перехода
Ранг 0	Прогнозируемое изменение состояния ЗЧС – без изменений	$\forall s, s \in S_{pred}, s = S$
Ранг 1	Без лечения – прогнозируется ухудшение состояния ЗЧС, с лечением – без изменений	$s_{yes} = S$ и $\exists s, s \in S_{pred}, s > S$
Ранг 2	Без лечения – прогнозируется ухудшение состояния ЗЧС, с лечением – прогнозируется улучшение состояния ЗЧС	$s_{yes} < S$ и $\exists s, s \in S_{pred}, s > S$
Ранг 3	Без лечения – без изменений, с лечением – прогнозируется улучшение состояния ЗЧС	$s_{yes} < S$ и $\forall s, s \in S_{pred}, s = S$
Ранг 4	И с лечением, и без лечения прогнозируется улучшение состояния ЗЧС	$s_{yes} < S$ и $\forall s, s \in S_{pred}, s < S$

Функция f определения текущего состояния V_{cur} представлена далее (3).

Обозначения:

1. sum – функция подсчета баллов на основе текущих нарушений ЗЧС. Чем тяжелее нарушение, тем больше баллов суммируется в итоговое значение $Balls$.

2. $Disorders$ – множество численных значений нарушений ЗЧС. Большее значение характеризует более тяжелое нарушение. Все значения масштабируются в отрезок от $[0, 1]$ на основе минимального и максимального возможного значения конкретного нарушения.

3. S_{balls} – функция определения степени тяжести нарушений ЗЧС S на основе суммы баллов нарушений ЗЧС $Balls$. Перечень возможных значений представлен в Таблице 3.

Таблица 3 – Перечень возможных значений степени тяжести нарушений ЗЧС в соответствии с количеством баллов

Table 3 – List of possible values of severity of the dental system violations in accordance with the number of points

Степень тяжести S	Сумма баллов нарушений $Balls$
0	$Balls < 2$
1	$Balls \in [2, 6]$
2	$Balls \in [7, 13]$
3	$Balls \in [14, 20]$
4	$Balls \geq 21$

4. $Pred_{age}$ – функция прогноза числовых характеристик степени нарушения ЗЧС на более старший возраст. На основе текущего возраста Age происходит определение множества моделей машинного обучения, участвующих в прогнозе, и расчет с их помощью числовых характеристик (Таблица 4) на основе переменных P_{cur} .

Таблица 4 – Правила расчета числовых характеристик степени нарушения ЗЧС на более старший возраст

Table 4 – Rules for calculating the numerical characteristics of the degree of violation of the dental system at an older age

Возраст (лет)	Рассчитанные значения числовых характеристик
От 3 до 5	$S_{pred_{6_9_no}} = M_{from_3_5_to_6_9_no}(P_{cur});$ $S_{pred_{10_12_no}} = M_{from_3_5_to_10_12_no}(P_{cur});$ $S_{pred_{13_17_no}} = M_{from_3_5_to_13_17_no}(P_{cur});$ $S_{pred_{6_9_yes}} = M_{from_3_5_to_6_9_yes}(P_{cur});$ $S_{pred} =$ $\{S_{pred_{6_9_no}}, S_{pred_{10_12_no}}, S_{pred_{13_17_no}}, S_{pred_{6_9_yes}}\};$
От 6 до 9	$S_{pred_{10_12_no}} = M_{from_6_9_to_10_12_no}(P_{cur});$ $S_{pred_{13_17_no}} = M_{from_6_9_to_13_17_no}(P_{cur});$ $S_{pred_{10_12_yes}} = M_{from_6_9_to_10_12_yes}(P_{cur});$ $S_{pred} = \{S_{pred_{10_12_no}}, S_{pred_{13_17_no}}, S_{pred_{10_12_yes}}\};$
От 10	$S_{pred_{13_17_no}} = M_{from_10_12_to_13_17_no}(P_{cur});$ $S_{pred_{13_17_yes}} = M_{from_10_12_to_13_17_yes}(P_{cur});$ $S_{pred} = \{S_{pred_{13_17_no}}, S_{pred_{13_17_yes}}\};$

$$\begin{aligned}
 Balls &= sum(Disorders), \\
 S &= S_{balls}(Balls), \\
 S_{pred} &= Pred_{age}(Age, P_{cur}), \\
 V_t &= state(S, S_{pred}),
 \end{aligned}
 \tag{3}$$

где *state* – функция определения состояния по Таблице 1.

Заключение

В данной работе предложен новый подход построения интеллектуальных агентов системы, который базируется на классическом подходе, основанный на априорно задаваемых правилах поведения агентов. Путем включения в правила поведения агента предварительно обученных моделей машинного обучения агент становится способен спрогнозировать свои переменные и учесть эти прогнозы в расчете текущего состояния без необходимости отказа от априорно задаваемых правил поведения.

Предложенный подход построения интеллектуальных агентов требует предоставления разработчикам моделей функционала для хранения и использования моделей машинного обучения в правилах поведения агента, программную реализацию логики применения моделей машинного обучения в коде расчета состояния агентов. На данный момент времени ни одна представленная в научном поле платформа для агентного моделирования не позволяет реализовать предложенный подход построения агентов.

Также условием применения предложенного подхода для построения агентных моделей является необходимость предварительной разработки моделей машинного обучения для прогнозирования целевых переменных агента в ходе моделирования.

Помимо этого, данные модели машинного обучения должны быть высокой точности для обеспечения адекватности результатов прогнозирования.

Предложенный подход построения интеллектуальных агентов может быть применен для построения агентных моделей сложных систем, направленных на прогнозирование их общего состояния, и их составных частей при оказываемых на них внешних воздействиях.

СПИСОК ИСТОЧНИКОВ / REFERENCES

1. Macal C., North M. Introductory tutorial: Agent-based modeling and simulation. In: *Proceedings of the Winter Simulation Conference 2014, 7–10 December 2014, Savannah, USA*. IEEE; 2014. pp. 6–20. <https://doi.org/10.1109/WSC.2014.7019874>
2. Кузнецов А.В. Краткий обзор многоагентных моделей. *Управление большими системами*. 2018;(71):6–44.
 Kuznetsov A.V. The short review of multi-agent models. *Large-Scale Systems Control*. 2018;(71):6–44. (In Russ.).
3. Mehdizadeh M., Nordfjaern T., Klöckner C.A. A systematic review of the agent-based modelling/simulation paradigm in mobility transition. *Technological Forecasting and Social Change*. 2022;184. <https://doi.org/10.1016/j.techfore.2022.122011>
4. Ale Ebrahim Dehkordi M., Lechner J., Ghorbani A., Nikolic I., Chappin É., Herder P. Using Machine Learning for Agent Specifications in Agent-Based Models and Simulations: A Critical Review and Guidelines. *Journal of Artificial Societies and Social Simulation*. 2023;26(1). <https://doi.org/10.18564/jasss.5016>
5. Lorscheid I. Learning Agents for Human Complex Systems. In: *2014 IEEE 38th International Computer Software and Applications Conference Workshops, 21–25 July 2014, Vasteras, Sweden*. IEEE; 2014. pp. 432–437. <https://doi.org/10.1109/COMPSACW.2014.73>
6. Bashardoust A., Safaei D., Haki K., Shrestha Y.R. Employing Machine Learning to Advance Agent-based Modeling in Information Systems Research. In: *Forty-Fourth International Conference on Information Systems, ICIS 2023, 10–13 December 2023, Hyderabad, India*. URL: https://aisel.aisnet.org/icis2023/adv_theory/adv_theory/3/
7. Turgut Y., Bozdogan C.E. A framework proposal for machine learning-driven agent-based models through a case study analysis. *Simulation Modelling Practice and Theory*. 2023;123. <https://doi.org/10.1016/j.simpat.2022.102707>
8. Brearcliffe D.K., Crooks A. Creating Intelligent Agents: Combining Agent-Based Modeling with Machine Learning. In: *Proceedings of the 2020 Conference of The Computational Social Science Society of the Americas, 8–11 October 2020, Online*. Cham: Springer; 2021. pp. 31–58. https://doi.org/10.1007/978-3-030-83418-0_3
9. Kavak H., Padilla J.J., Lynch C.J., Diallo S.Y. Big data, agents, and machine learning: towards a data-driven agent-based modeling approach. In: *ANSS '18: Proceedings of the Annual Simulation Symposium: SpringSim '18: 2018 Spring Simulation Multiconference, 15–18 April 2018, Baltimore, USA*. San Diego: Society for Computer Simulation International; 2018. pp. 1–12. <https://dl.acm.org/doi/10.5555/3213032.3213044>
10. Ramchandani P., Paich M., Rao A. Incorporating Learning into Decision Making in Agent Based Models. In: *Progress in Artificial Intelligence: 18th EPIA Conference on Artificial Intelligence, EPIA 2017, 5–8 September 2017, Porto, Portugal*. Cham: Springer; 2017. pp. 789–800. https://doi.org/10.1007/978-3-319-65340-2_64
11. Adenuga O.T., Mpofu K., Kanisuru A.M. Agent-based Control System: A Review and Platform for Reconfigurable Bending Press Machine. *Procedia Manufacturing*. 2019;35:50–55. <https://doi.org/10.1016/j.promfg.2019.05.007>

12. Лисовенко А.С., Лимановская О.В. Моделирование состояния воздушной линии электропередачи на основе учета дефектности проводов и условий окружающей среды. В сборнике: *Физика. Технологии. Инновации: Сборник статей VIII Международной молодежной научной конференции, 17–21 мая 2021 года, Екатеринбург, Россия*. Екатеринбург: Уральский федеральный университет; 2021. С. 157–168.
13. Лисовенко А.С., Лимановская О.В., Гаврилов И.В., Мещанинов В.Н. Агентная система прогнозирования состояния пациента в персонализированной геронтологии. В сборнике: *Имитационное моделирование: теория и практика (ИММОД-2023): Сборник трудов одиннадцатой всероссийской научно-практической конференции по имитационному моделированию и его применению в науке и промышленности, 18–20 октября 2023 года, Казань, Россия*. Казань: Издательство АН РТ; 2023. С. 121–129.
Lisovenko A.S., Limanovskaya O.V., Gavrilov I.V., Meshchaninov V.N. Agent-based system for predicting the patient's condition in personalized gerontology. In: *Imitatsionnoe modelirovanie: teoriya i praktika (IMMOD-2023): Sbornik trudov odinnadtsatoi vserossiiskoi nauchno-prakticheskoi konferentsii po imitatsionnomu modelirovaniyu i ego primeneniyu v nauke i promyshlennosti, 18–20 October 2023, Kazan, Russia*. Kazan: Izdatel'stvo AN RT; 2023. pp. 121–129. (In Russ.).
14. Шишмарева А.С., Бимбас Е.С., Лимановская О.В. Прогнозирование результатов раннего ортодонтического лечения и развития зубочелюстной системы при его отсутствии у детей 3–12 лет. *Стоматология детского возраста и профилактика*. 2023;23(3):243–254. <https://doi.org/10.33925/1683-3031-2023-660>
Shishmareva A.S., Bimbass E.S., Limanovskaya O.V. Predicting early orthodontic treatment results and development of the dentofacial system without orthodontic treatment in 3–12-year-old children. *Pediatric dentistry and dental prophylaxis*. 2023;23(3):243–254. (In Russ.). <https://doi.org/10.33925/1683-3031-2023-660>

ИНФОРМАЦИЯ ОБ АВТОРАХ / INFORMATION ABOUT THE AUTHOR

Лисовенко Антон Сергеевич, аспирант, Уральский федеральный университет имени первого Президента России Б.Н. Ельцина, Екатеринбург, Российская Федерация.
e-mail: anton.lisovenko.researcher@mail.ru
ORCID: [0000-0001-9127-0820](https://orcid.org/0000-0001-9127-0820)

Anton S. Lisovenko, postgraduate Student, Ural Federal University named after the first President of Russia B.N. Yeltsin, Yekaterinburg, the Russian Federation.

Тарасов Дмитрий Александрович, кандидат физико-математических наук, доцент департамента информационных технологий и автоматизации Института радиоэлектроники и информационных технологий Уральского федерального университета имени первого Президента России Б.Н. Ельцина, Екатеринбург, Российская Федерация.
e-mail: datarasov@yandex.ru
ORCID: [0000-0001-6911-8371](https://orcid.org/0000-0001-6911-8371)

Dmitry A. Tarasov, Candidate of Physical and Mathematical Sciences, Associate Professor of the Department of Information Technology and Automation of the Institute of Radio Electronics and Information Technologies, Ural Federal University named after the first President of Russia B.N. Yeltsin, Yekaterinburg, the Russian Federation.

Шишмарева Анастасия Сергеевна, кандидат медицинских наук, доцент кафедры стоматологии детского возраста и ортодонтии

Anastasia S. Shishmareva, Candidate of Medical Sciences, Associate Professor of the Department of Pediatric Dentistry and

Уральского государственного медицинского университета Министерства здравоохранения Российской Федерации, Екатеринбург, Российская Федерация.

e-mail: dolphy2007@yandex.ru

ORCID: [0000-0001-8641-9088](https://orcid.org/0000-0001-8641-9088)

Orthodontics of the Ural State Medical University of the Ministry of Health of the Russian Federation, Yekaterinburg, the Russian Federation.

Статья поступила в редакцию 24.10.2024; одобрена после рецензирования 08.11.2024; принята к публикации 13.11.2024.

The article was submitted 24.10.2024; approved after reviewing 08.11.2024; accepted for publication 13.11.2024.