

1. ЭКОНОМИКО-МАТЕМАТИЧЕСКИЕ И СТАТИСТИЧЕСКИЕ МЕТОДЫ И МОДЕЛИ

УДК 330.46

DOI 10.5281/zenodo.12667180

**ПЛЕСКАЧЕВ Юрий Андреевич¹,
РАДЧЕНКО Дарья Максимовна¹,
ЕВДОКИМОВ Дмитрий Юрьевич¹,
ЮЛУСОВ Марк Вадимович¹**

¹ Институт прикладных экономических исследований Российской академии народного хозяйства и государственной службы при Президенте Российской Федерации, просп. Вернадского, 84, Москва, Россия, 119606

ПРИМЕНЕНИЕ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ В АГЕНТНОМ МОДЕЛИРОВАНИИ

Агентное моделирование является мощным инструментом для изучения сложных систем, позволяя анализировать поведение агентов и их взаимодействие на микроуровне. Особую актуальность их применение получает в случаях недостаточных и/или некачественных открытых статистических данных. В статье рассмотрены подходы к классификации методов и примеры их применения для создания агентных моделей, способствующих пониманию и прогнозированию экономических процессов. Представлена систематизация применения современных методов машинного обучения и их элементов для решения отдельных задач по моделированию пространственных взаимосвязей. Рассмотрено, какие роли и функции выполняют алгоритмы машинного обучения на различных этапах разработки агентных моделей, а также приведены примеры их использования в агентном моделировании экономических процессов и выявлен потенциал подобного подхода для улучшения прогностической и объясняющей способности этих моделей. Области применения машинного обучения условно разделены на 4 блока: предварительная обработка данных (которая включает в себя удаление выбросов, заполнение пропусков и нормализацию данных), формирование поведения агентов (в том числе с разной степенью рациональности и обучаемости), построение суррогатных моделей (полностью заменяющих собой исходную модель с целью снижения трудо-, времязатрат и требований к вычислительным мощностям) и постобработка данных (которая включает кластеризацию, разработку форм визуализации и очистку данных). Такие методы, как деревья решений и байесовские сети, играют ключевую роль в извлечении правил из данных и формировании поведенческих стратегий агентов. Работа подчеркивает важность учета шумов и аномалий в данных, а также необходимость адаптации моделей к реальным условиям. По результатам проведенного обзора сформированы рекомендации по применению отдельных методов в зависимости от особенностей моделирования. Результаты исследования имеют практическое значение для разработки более точных и эффективных агентных моделей в различных областях, таких как экономика, экология и социальные науки.

***Ключевые слова:** агентное моделирование, машинное обучение, графовые нейронные сети, нейронные сети, метод опорных векторов, случайный лес, градиентный бустинг, k ближайших соседей, гауссовский процесс, деревья принятия решений.*

Постановка проблемы. В отличие от ряда других стран, где в достаточной степени налажено статистическое обеспечение, позволяющее формировать четкую и

открытую картину межрегиональных взаимодействий на основе собираемых первичных статистических сведений, в России данная сфера не лишена ряда сложностей. Развитие современных методов экономико-математического анализа, методов машинного обучения, которое произошло за последние годы, показывает хорошие результаты в прогнозировании и оценке агентных моделей, в том числе в условиях ограниченности статистической информации.

Анализ последних исследований и публикаций. В последнее время методы машинного обучения получили широкое распространение в исследовательской среде. В литературе представлен широкий спектр подходов, ориентированных на конкретные случаи. К примеру, Alexandridis и Pijanowski [1], Lei и др. [2], Sun и Müller [3] используют байесовские сети для представления процесса принятия решений в качестве инструмента обучения в условиях высокой неопределенности, Laite и др. [4] используют нейронные сети для построения реалистичных симуляций и моделирования конкретных поведенческих характеристик для каждого агента, Chu и др. [5] применяют деревья решений для построения правил, на основе которых агенты в дальнейшем будут принимать решения.

Цель исследования. Цель исследования – обзор и систематизация применения современных методов машинного обучения и их элементов для решения отдельных задач в агентном моделировании.

Изложение основного материала. В общих чертах любая агентная модель состоит из функциональных единиц (агентов), которые образуют микроуровень. Поведение агента определяется факторами микроуровня, взаимодействием с другими агентами и факторами макроуровня. На рисунке 1 изображена взаимосвязь между эмпирическими данными, методами машинного обучения и агентным моделированием относительно этапов их построения, предложенная Turgut и Bozdog [6].

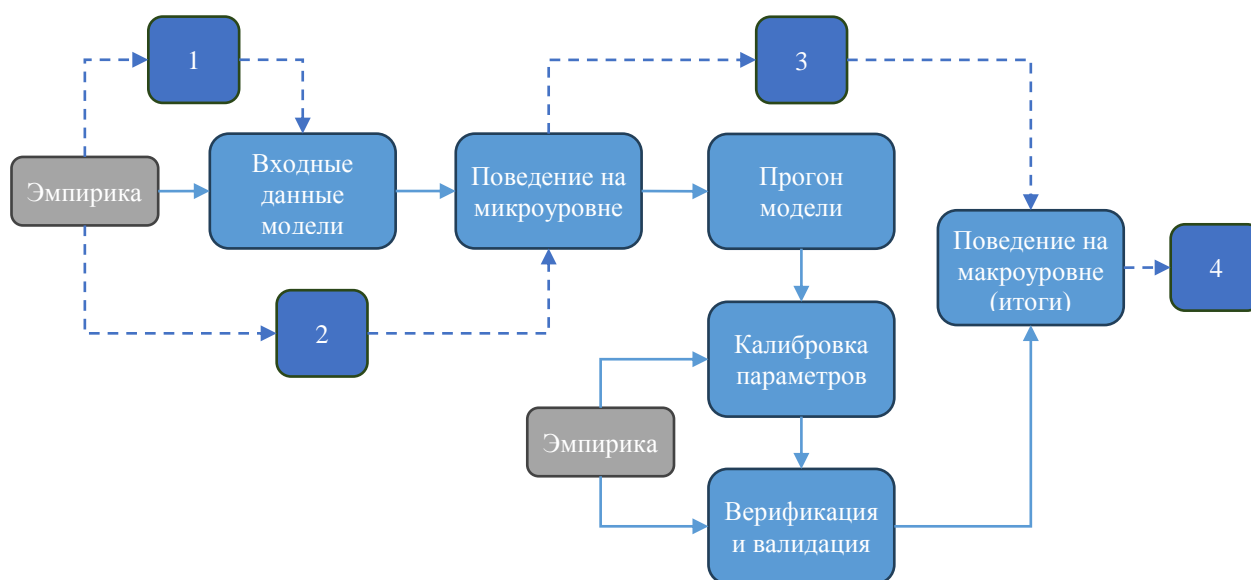


Рис. 1. Взаимосвязь между эмпирическими данными, методами машинного обучения и агентными моделями [6, с. 5]

Блок «1» символизирует использование методов машинного обучения для подготовки входных данных для агентной модели. К блоку «2» относятся методы, используемые для определения поведения агентов в агентной модели. На основе входных данных методы машинного обучения позволяют напрямую определить поведение агентов или конкретные поведенческие правила без необходимости

прописывать их вручную. Блок «3» описывает массив подходов, использующихся для создания статистических моделей, которые с высокой степенью точности воспроизводят поведение исходной агентной модели. Модели блока «4» отвечают за преобразования больших объемов результирующих показателей имитационной модели в формат, полезный для принятия решений.

Далее каждый из этих блоков будет рассмотрен подробнее.

Машинное обучение и качество преобработки данных. С развитием и расширением методов машинного обучения вопросам их интеграции в агентные модели стало уделяться значительное внимание. Входящие данные могут быть связаны с атрибутами, специфичными для агента или среды, определение которых могло бы частично упростить дальнейшее формирование правил и алгоритмов. Также зачастую во входящих данных могут содержаться пропуски, которые необходимо заполнить для корректного проведения оценок.

Случаи применения методов машинного обучения для преобработки данных агентной модели можно классифицировать согласно таблице 1.

Таблица 1. Назначение применяемых на этапе преобработки данных методов машинного обучения [3; 7-14]

Проблемы, возникающие на этапе преобработки данных	Методы	Способ решения проблемы
Отсутствие возможности установить правила, по которым действуют агенты (например, в микромоделях в случаях нерационального поведения агентов)	Деревья решений	Извлечение правил поведения напрямую из данных Гарантия прозрачности и интерпретируемости правил
При использовании данных анкет и опросов: сложности с интерпретируемостью разных типов ответов и их группировкой		Обработка данных анкет/опросов Повышение интерпретируемости ответов с помощью автоматической группировки ответов на основе их сходства Упрощение анализа данных, представление в виде иерархической структуры Анализ больших объемов данных
В исходной выборке присутствуют как количественные, так и качественные данные (опросы, мнения экспертов)	Байесовские сети	Учет неопределенности и возможность делать выводы на основе вероятностных зависимостей между переменными
Неполные данные, недостаточность данных, короткие ряды		Заполнение недостающих данных и возможность делать выводы
Неопределенность в исходных данных при принятии решений		Учет неопределенности и возможность делать выводы на основе вероятностных зависимостей между переменными
Невозможность интерпретации полученных результатов		Позволяет моделировать причинно-следственные связи
Восстановление пропущенных связей внутри графа, генерация графа с требуемыми свойствами	Графовые нейронные сети	Анализ сходства между узлами и на основе него предсказание наличия или отсутствия связи между ними Анализ контекста, в котором находятся узлы, и на основе него предсказание наличия/отсутствия связи между ними

Далее некоторые из представленных работ рассмотрены подробнее. Исследование Dehkordi и др. [8] направлено на устранение разрыва между машинным обучением и имитационным моделированием. Авторы рассматривают различные группы методов машинного обучения, используемые в структурных спецификациях имитационных моделей для принятия решений агентами и моделирования поведения. Представленный авторами обзор показал, что деревья решений и байесовские сети – основные инструменты предварительной обработки данных о поведении агентов.

В работе Herpenstall и др. [9] показано, как методы машинного обучения можно использовать для минимизации воздействия шумов, включая отсутствие или недостаточность данных. Методы фильтрации и нормализации данных, а также использование алгоритмов кластеризации могут быть применены для удаления выбросов и аномалий и учета шумов в данных. Отдельное направление – добавление шума в обучающие данные для повышения устойчивости модели к реальным условиям. Обучение модели на зашумленных данных может способствовать получению более надежных результатов.

Методы машинного обучения можно применять и к необработанным данным для предварительной обработки и калибровки, как было рассмотрено в работах Zhang и др. [10], и Lamperti и др. [11]. Авторы предлагают использовать различные методы машинного обучения для улучшения качества данных и повышения точности моделей. Предварительная обработка данных включает в себя удаление выбросов, заполнение пропусков и нормализацию данных. Методы машинного обучения могут быть использованы для автоматизации этих процессов. Классическая регрессия может быть использована для заполнения пропусков в данных, а кластеризация – для удаления выбросов. Применение методов машинного обучения к предварительной обработке и калибровке данных позволяет автоматизировать эти процессы и повысить точность моделей, что особенно полезно в условиях, когда данные не являются чистыми и структурированными.

Можно выделить три основные причины применения деревьев решений для предварительной обработки данных.

1. Во-первых, этот метод представляется полезным инструментом для извлечения правил из данных, которые затем могут быть реализованы в имитационной модели для принятия решений [15; 16].

2. Во-вторых, деревья решений можно применять к анкетам или результатам опросов, обеспечивая тем самым эмпирическую основу для поведения агентов [12; 17].

3. В-третьих, Sánchez-Marcoño и др. [17] подчеркивают прозрачную структуру и результаты деревьев решений, которые могут интерпретироваться и критиковаться нетехническими экспертами.

Чтобы лучше понять и структурировать причины, по которым байесовские сети часто используются для улучшения предварительной обработки данных для моделирования поведения агентов, выделяются четыре основных блока.

1. Подчеркивается способность байесовских сетей работать как с качественными данными, такими как экспертные знания, так и с количественными данными, например, из опросов, что способствует более эффективному принятию решений [3; 13; 18; 19]. В контексте качественных данных байесовские сети могут служить инструментом для моделирования экспертных знаний о системе. Экспертные знания могут быть формализованы в виде условных вероятностей, отражающих вероятность наступления событий при различных условиях.

2. Kocabas и Dragicevic [18] и Pooyandeh и Marceau [20] подчеркивают способность байесовских сетей обрабатывать неполные или небольшие наборы данных.

Авторы предлагают использовать их для объединения экспертных знаний и результатов опросов, что позволяет получить более полное представление о системе.

3. Они помогают справиться с неопределенностью при принятии решений [3; 13].

4. Они также способны моделировать причинно-следственные связи [3], что лучше отражает процесс принятия решений агентами [21].

Графовые нейронные сети – новый класс моделей машинного обучения, которые объединяют в себе преимущества графовых моделей и нейронных сетей [14]. Графовые нейронные сети используют математические представления графов для моделирования сложных систем и процессов. Они позволяют учитывать структуру и отношения между объектами, что делает их более эффективными для анализа данных, чем традиционные методы машинного обучения.

Обучение графовых нейронных сетей происходит с использованием методов глубокого обучения. Для этого используются различные алгоритмы, такие как метод обратного распространения ошибки или метод стохастического градиентного спуска. Графовые нейронные сети имеют ряд преимуществ перед традиционными методами машинного обучения: они учитывают структуру данных и отношения между объектами, позволяют производить анализ сложных систем и процессов, могут быть обучены на небольших объёмах данных. Однако графовые нейронные сети также имеют некоторые ограничения и проблемы, такие как сложность обучения и необходимость больших объёмов данных. Эти проблемы могут быть решены с помощью современных методов машинного обучения и обработки данных.

Таким образом, можно сделать вывод, что, несмотря на широкое применение, агентное моделирование сталкивается с проблемами, во-первых, связанными с тем, что такие модели используются для изучения сложных систем, в которых взаимодействует множество агентов, что делает моделирование таких систем очень сложным и трудоёмким процессом. Во-вторых, зачастую агентные модели требуют большого количества данных о поведении агентов в системе, при этом данные часто бывают неполными, неточными или противоречивыми. Также построение корректной модели включает в себя множество параметров, которые определяют поведение агентов в системе.

Применение методов машинного обучения для моделирования поведения агентов на микроуровне. У агентных моделей, использующих методы машинного обучения, есть три преимущества перед традиционными экономическими моделями. Во-первых, возможно имитирование поведения отдельных индивидов, в то время как обычно моделируют поведение репрезентативного агента [22]. Во-вторых, при моделировании существует возможность отказаться от теории рационального выбора в пользу теории ограниченной рациональности. В-третьих, использование методов машинного обучения вместе с агентными моделями предоставляет возможность симитировать взаимодействие между агентами, где индивиды будут эволюционировать. Для этого подойдут методы обучения с учителем или обучения с подкреплением.

Обычно первые два преимущества сразу совмещают в одной модели, и на выходе получаются гетерогенные индивиды с ограниченной рациональностью. Уровень рациональности задаётся авторами модели. На самом базовом уровне агенты не принимают во внимание дополнительную информацию при достижении цели. Например, в работе Gehrke и др. [23] агенты при построении кратчайшего маршрута не учитывают информацию о погоде и загруженности дорог. Однако в большинстве случаев исследователи строят модели с агентами, обладающими каким-то уровнем интеллекта. В той же работе есть агенты, учитывающие информацию в поле своего зрения или способные накапливать опыт и строить прогнозы.

Для моделирования ограниченной рациональности могут использоваться методы обучения с учителем (генетический алгоритм [24], нейронные сети [25]), методы обучения

с подкреплением (rational inattention reinforcement learning, который основывается на теории рационального невнимания [26], алгоритм actor-critic [25], Q-обучение [27]), а также авторские алгоритмы [23]. Разница между ними заключается в способе спецификации поведения индивида. Методы обучения с подкреплением используются гораздо чаще, так как позволяют запрограммировать самообучение агентов: при изменении условий или сложности модели поведение агентов автоматически изменится.

Смоделировать взаимодействие между агентами гораздо сложнее, потому что поведение индивида влияет на всю группу, а действия группы влияют на индивида. В таком случае модель можно представить как стохастическую игру. Shapley [28] приводит описание стохастической игры, в которую играют как минимум два игрока несколько раундов. Участники не знают, когда закончится игра, но понимают, что чем дольше она продолжается, тем выше шанс, что этот раунд может оказаться последним. В каждом раунде игроки имеют на выбор несколько действий, из которых они выбирают только одно. Вознаграждение зависит от действий игрока и текущего состояния игры. При переходе к новому раунду действия всех игроков и текущее состояние игры учитываются для определения новых вознаграждений. Цель игрока – максимизация ожидаемого дисконтированного вознаграждения, где фактор дисконтирования показывает значимость каждого временного периода. Игра может быть полностью состязательной, кооперативной или смешанной.

Для моделирования подобной ситуации лучше всего использовать обучение с подкреплением, а именно Q-обучение. Оно относится к классу model-free методов, где исследователю нужно всего лишь задать функцию, определяющую выигрыш от состояния и действий. Противоположностью model-free метода является model-based метод, распространённый в теории игр, где до начала игры моделируется поведение оппонента и определяется оптимальная стратегия [29]. Работа Fiosins и др. [30] может служить образцом кооперативной стохастической игры, где водителю в дорожном потоке нужно учитывать поведение других участников, чтобы минимизировать время в пути, а Littman [31] приводит пример состязательной игры в футбол.

Подход к построению эмпирических моделей в экономике отличается от подхода в машинном обучении. В экономике принято устанавливать причинно-следственную связь, в то время как в машинном обучении важна способность модели адаптироваться к новым данным. Kleinberg и др. [32] приводят пример для понимания различий между подходами. В одном государстве стоит засуха, и правительство оценивает необходимость инвестирования в обряд вызывания дождя для повышения вероятности осадков. В другой стране стоит пасмурная погода, и чиновник должен определить, нужно ли ему брать с собой зонт. В первом случае нужно установить причинно-следственную связь, во втором важна вероятность осадков, но не их причина. В большинстве случаев концентрируются на задачах первого типа, но и задач второго типа существует очень много, и здесь машинное обучение будет гораздо эффективнее.

Целью стандартных эконометрических методов является минимизация ошибки, рассчитанной на исходных данных (*in sample error*). Однако при построении прогнозов интерес состоит в минимизации ошибки, рассчитанной на новых данных (*out of sample error*). Для оценки качества модели в таком случае используют среднеквадратичную ошибку $MSE(\hat{\theta})$, которую можно разложить на сумму дисперсии $Var(\hat{\theta})$ и квадрата смещения $Bias(\hat{\theta}, \theta)$:

$$MSE(\hat{\theta}) = E \left[(\hat{\theta} - \theta)^2 \right] = Var(\hat{\theta}) + Bias^2(\hat{\theta}, \theta). \quad (1)$$

Когда статистическая оценка $\hat{\theta}$ равна неизвестному параметру θ , то она не смещена. Однако даже она может иметь большую среднеквадратичную ошибку из-за большой дисперсии. Если же $\hat{\theta}$ отличается от θ , то возникает смещение. Было установлено, что снижение дисперсии приводит к росту смещения, и наоборот [33]. Это особенность получила название дилемма смещения-дисперсии. При снижении дисперсии происходит сглаживание функции между наблюдениями, приводящее к росту смещения. При снижении смещения функция лучше подстраивается под данные, но из-за этого происходит рост дисперсии. Наличие смещения указывает на недообучение, т.е. модель слишком простая, в то время как большая дисперсия является сигналом о переобучении. Правильно подобранная модель и большой набор данных являются лекарством от этих двух проблем, минимизирующим среднеквадратичную ошибку.

Суррогатные (прокси) модели. До недавнего времени суррогатные модели в основном применялись в инженерном деле, медицине и биологии, где вычислительные модели обычно чрезвычайно сложны и требуют больших затрат времени [34]. Суррогатные модели позволяют значительно сократить время вычислений и ресурсы, необходимые для проведения моделирования, при этом обеспечивая достаточно точные результаты.

Одним из распространенных применений суррогатов является решение задач оптимизации. Во многих случаях при построении модели необходимо найти значения параметров, которые оптимизируют ту или иную функцию, но выполнение имитационного моделирования для оценки производительности каждой возможной комбинации решений может оказаться непомерно сложным с точки зрения ресурсоемкости. Суррогаты в данном случае представляются достойной альтернативой.

Другое применение суррогатные модели находят в количественной оценке неопределенности. Экзогенно задаваемые параметры подразумевают наличие неопределенности, которая влияет на выходные данные имитационной модели. Обычно в таком случае используется метод Монте-Карло, однако он, опять же, может требовать больших вычислительных затрат.

Ключевым вопросом в исследованиях, посвященных суррогатному моделированию, является оценка и выбор наиболее подходящего алгоритма.

Так, Angione и др. [35] в исследовании 2021 года использовали широкий набор инструментов для агентного моделирования предоставления социальной помощи в Великобритании, включая искусственные нейронные сети, градиентный бустинг и др. Результаты моделирования (время-затраты и СКО по показателю «стоимость оказания социальной помощи за год на душу населения») с использованием различных методов машинного обучения приведены в таблице 2.

Таблица 2. Эффективность разных методов машинного обучения [35, с. 10]

Методы машинного обучения	Время	СКО
Нейронные сети	47,5-695,3	0,188-0,965
Метод опорных векторов (линейный)	1,4-11,2	3,22-7,826
Метод опорных векторов (нелинейный)	1,7-14,2	0,236-5,254
Случайный лес	0,4-2,2	2,656-16,936
Линейная регрессия	1,4-3,9	4,374-24,18
Градиентный бустинг деревьев	1,4-3,8	0,452-3,778
k ближайших соседей	0,33-2,3	12,895
Гауссовский процесс	2,02	0,33-37,02
Деревья принятия решений	0,33	19,734

Авторы отмечают, что однозначный вывод о том, какой из рассмотренных в исследовании методов более предпочтителен для АОМ, сделать достаточно сложно, тем не менее, можно выделить несколько особенностей их применения:

для относительно простых моделей с небольшой выборкой подходит эмуляция гауссовских процессов, нейронные сети и градиентные методы;

для более сложных случаев – градиентный бустинг деревьев;

в случаях дефицита времени и ограниченной вычислительной мощности они также могут стать подходящей альтернативой из-за своей нетребовательности к ресурсам.

Clasay и Peffer в 2022 году также проводили сравнительный анализ эффективности методов машинного обучения в качестве суррогатов на примере агентной модели упрощенного искусственного фондового рынка [34]. В основе – биржа с множеством акций с неограниченным предложением, на котором трейдеры размещают заказы через дискретные интервалы времени, изменяя состав инвестиционных портфелей в соответствии со своими ожиданиями. На каждом этапе все агенты торгуют в случайном порядке, а новая цена устанавливается на основе агрегированных заявок, отправленных трейдерами. В таблице 3 представлены оценки точности использованных авторами методов для разных степеней волатильности цен акций (чем она выше, тем более нестабилен рынок и тем вероятнее он находится в состоянии кризиса).

Таблица 3. Оценки точности методов для разных степеней волатильности цен акций, % [34, с. 12]

Методы	Низкая волатильность	Средняя волатильность	Высокая волатильность
Логистическая регрессия	85	89	89
Байесовские сети	85	88	87
к ближайших соседей	83	82	82
Дерево решений	78	80	82
Случайный лес	85	89	89
Метод опорных векторов	87	91	91
Многослойный перцептрон	87	90	91

Авторы приходят к выводу, что все методы обеспечивают высокую точность результатов даже в условиях высокой волатильности финансового рынка, а их прогностическая способность растет по мере увеличения размера выборки.

Помимо приведенных выше методов в литературе также можно встретить примеры построения суррогатных моделей, построенных с помощью модификаций Q-обучения. Сети Deep Q (Deep Q Network, DQN) и Deep Recurrent Q-Network (DRQN) расширяют базовый метод Q-обучения.

Chen и др. в работе 2020 года [36] используют DRQN, совмещая рекуррентные нейронные сети (RNN) и DQN. В построенной авторами модели существует два типа агентов: банки и фирмы. Фирмы берут кредиты у банков по необходимости. По истечении времени фирме необходимо вернуть банку тело + проценты. Фирмы покупают и продают продукцию друг другу. В результате симуляции модели с использованием трех фирм и трех банков авторы показали, что применение DRQN позволило агентам оптимизировать принимаемые решения по мере накопления опыта. Этот метод машинного обучения применим в моделировании экономических систем также и потому, что допускает нефиксированные стратегии принятия решений, что позволяет моделировать внутренние обратные связи между агентами и окружающей средой.

Визуализация и постобработка данных пространственных агентных моделей.

Агентные модели генерируют большой объем данных в процессе симуляции, что делает возможным применение методов машинного обучения для визуализации и постобработки полученных данных, что может улучшить качество интерпретаций процессов, симулируемых моделью, выводов и рекомендаций, выносимых на ее основе.

В связи с большим количеством данных, генерируемых в ходе симуляции, некоторые методы и модели, связанные с машинным обучением, могут быть применены для пост-обработки полученных данных. Так, для агент-ориентированных моделей часто используется подход, в котором проводится не одна, а серия симуляций (ввиду ограничений вычислительной мощности), из-за чего для некоторых моделей агенты моделируются не индивидуально, а агрегировано, например, один агент представляет 1 000 человек населения. Тогда характеристики агента присваиваются на основе распределения вероятностей появления характеристик среди моделируемой популяции. Множественные симуляции с последующим усреднением их результатов компенсируют ошибки, возникающие при агрегации агентов.

Проблема анализа большого массива данных, получаемого на основе симуляций агентных моделей, актуализирует применение методов сокращения размерности и кластеризации, что продемонстрировано в работе Xie и др. [37]. Применение метода главных компонент – распространённого алгоритма машинного обучения без учителя, позволяет визуализировать полученные наблюдения и подготовить их к дальнейшему анализу.

Метод главных компонент, в упрощенном виде, сводит множество характеристик наблюдений к двум синтетическим, что позволяет отразить схожесть наблюдений в двумерном пространстве, представив их на графике. Чем меньше разница между каждой из оценок для двух наблюдений – тем больше схожести между ними в их изначальном наборе характеристик. Применение данного метода позволяет упростить сравнение и анализ большого количества полученных наблюдений с множественными характеристиками, в т.ч. между различными симуляциями.

После перехода к двумерному пространству могут быть также применены стандартные методы кластеризации моделями машинного обучения, например, метод k-средних, позволяющий выделить схожие группы наблюдений или агентов. Последующий анализ позволяет описывать индивидуальную динамику агентов и групповую (на основе кластеризации), а также проводить межгрупповые сравнения – что определяет принадлежность агентов по кластерам и позволяет оценить межкластерные различия.

Другим примером применения методов машинного обучения в данном направлении может служить модель Luo и др. [38], проводящая очистку данных для визуализации. Модель обнаруживает ошибки, выбросы и шум в данных, которые будут негативно сказываться на восприятии визуализации, построенной на неподготовленных данных. Затем модель очищает данные, взаимодействуя с пользователем в реальном времени, что позволяет получить более качественное представление данных, полученных из моделей.

Другое направление, связанное с обработкой данных для визуализации – кластеризация данных, учитывающая свойства человеческого восприятия при подборе количества кластеров для визуализации, предложенная в работе Wang и др. [39]. Модель позволяет выделять кластеры в данных, не только исходя из статистических критериев, применяемых в наиболее распространенных методах, но и учитывать при определении количества кластеров в данных свойства и склонности человеческого восприятия. Поэтому данная модель машинного обучения, позволяет максимизировать не только статистическую точность, но и эффективность коммуникации получаемых результатов конечному пользователю.

Другой кластер моделей машинного обучения – способные на основе набора данных предложить и создать наиболее подходящие формы визуализации. Например, модель DeepEye [40], получая набор данных, использует классификацию на основе бинарного дерева решений, чтобы проранжировать все возможные виды визуализаций относительно имеющегося набора данных от «плохих» к «хорошим». Модель также использует набор экспертных правил для улучшения качества оценки визуализаций. VizML [41] использует натренированную нейронную сеть, способную предположить 5 наиболее удачных визуализаций для заданного набора данных. Как и ряд других ML-моделей, их общая идея – наличие модели, натренированной на наборах данных, отражающих разные их типы и подходящие к ним визуализации. В этом случае модели предсказывают оптимальные визуализации для новых наборов данных, исходя из своего прошлого «опыта». GenerativeMap [42] позволяет создавать динамическую визуализацию, создавая промежуточные графики между двумя наблюдениями, что позволяет рассматривать динамику исследуемого, визуализируемого процесса. TSR-TVD [43] предполагает глубокий анализ данных для визуализации процесса с пространственно-временной динамикой. Так модель изучает динамику процесса в пространстве-времени, на основе чего позволяет сгенерировать визуализацию для процесса в состояниях между заданными наблюдениями. Generative Adversarial Network [44] и InsituNet [45] на основе анализа набора данных позволяют пользователям изменять некоторые из параметров набора данных и визуализируют изменения, ассоциирующие с изменениями данных параметров. Описанные модели могут быть использованы как один из этапов работы с моделью для сокращения издержек на анализ промежуточных результатов симуляций.

Таким образом, существует широкий спектр методов машинного обучения, оптимизирующих различные элементы постобработки и визуализации данных агентных моделей. Большинство моделей, однако, в большей степени релевантны для ситуаций, при которых требуется регулярная, потоковая визуализация и обработка больших данных, в противном случае наличие отдельной модели для визуализации – избыточно.

Выводы и перспективы дальнейших исследований. Применение машинного обучения позволяет повысить точность и скорость принятия решений, оценивать адекватность и устойчивость экономических решений, а также формировать методический инструментарий для более эффективного процесса выработки мер и политик развития.

Выбор оптимальных параметров для интеграции методов машинного обучения в агентную модель может быть сложной задачей, требующей глубокого понимания системы. Как показал обзор международного опыта, применение рассмотренных выше методов может в значительной степени решить или сократить масштаб проблем, с которыми сталкивается исследователь на разных этапах построения агентных моделей.

Список литературы

1. Alexandridis K., Pijanowski B.C. Assessing multiagent parcelization performance in the MABEL simulation model using Monte Carlo replication experiments // *Environment and Planning B: Planning and Design*, Vol. 34, No. 2, 2007. pp. 223-244.
2. Lei Z., Pijanowski B.C., Alexandridis K.T., Olson J. Distributed modeling architecture of a multi-Agent-Based behavioral economic landscape (MABEL) model // *Simulation*, Vol. 81, No. 7, 2005. pp. 503-515.
3. Sun Z., Müller D. A framework for modeling payments for ecosystem services with agent-based models, Bayesian belief networks and opinion dynamics models // *Environmental Modelling & Software*. 2013. No. 45. pp. 15–28.

4. Laite R., Portman N., Sankaranarayanan K. Behavioral analysis of agent based service channel design using neural networks, 2016.
5. Chu T.Q., Drogoul A., Boucher A., and Zucker J.D. Interactive learning of independent experts' criteria for rescue simulations // Journal of Universal Computer Science, Vol. 15, No. 13, 2009. pp. 2719-2743.
6. 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. T. 123.
7. Taghikhah F., Voinov A., Filatova T., and Polhill J.G. Machine-assisted agent-based modeling: Opening the black box // Journal of Computational Science, No. 64, 2022.
8. Dehkordi M., Lechner J., Ghorbani A., Nikolic I., Chappin E., and 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, Vol. 1, No. 26, Sep 2023.
9. Heppenstall A.J., Crooks A.T., See, L.M., Batty, M. Agent-based models of geographical systems // Springer Science & Business Media, 2011.
10. Zhang H., Vorobeychik Y., Letchford J., Lakkaraju K. Data-driven agent-based modeling, with application to rooftop solar adoption // Autonomous Agents and Multi-Agent Systems, Vol. 30, 2016. pp. 1023-1049.
11. Lamperti F., Roventini A., and Sani A. Agent-based model calibration using machine learning surrogates // Journal of Economic Dynamics and Control, Vol. 90, 2018. pp. 366-389.
12. Gaube V., Kaiser C., Wildenberg M., Adensam H., Fleissner P., Kobler J., Lutz J., Schaumberger A., Schaumberger J., Smetschka B. Combining agent-based and stock-flow modelling approaches in a participative analysis of the integrated land system in Reichraming // Austria. Landscape Ecology, Vol. 9, No. 24, 2009. pp. 1149-1165.
13. Abdulkareem S., Augustijn E.W., Mustafa Y., and Filatova T. Intelligent judgements over health risks in a spatial agent-based model // International Journal of Health Geographics, Vol. 1, No. 17, Aug 2018.
14. Кузнецов М. Графовые нейронные сети : учебник по машинному обучению. 2024. – URL: <https://education.yandex.ru/handbook/ml/article/grafovye-nejronnye-seti> (дата обращения: 04.04.2024).
15. Sengupta R., Chapman C., Sarkar D., and Bortolamiol S. Automated extraction of movement rationales for building agent-based models: Example of a Red Colobus Monkey group. In L. Perez, E.K. Kim & R. Sengupta (Eds.), Agent-Based in the Age of Complexity Science Models and Geospatial Big Data, Berlin Heidelberg: Springer, 2018. pp. 59-71.
16. Rosés R., Kadar C., and Malleson N. A data-driven agent-based simulation to predict crime patterns in an urban environment // Computers, Environment and Urban Systems, Vol. 89, No. 101660, 2021.
17. Sánchez-Marroño N., Alonso-Betanzos A., Fontenla-Romero O., Polhill J.G., and Craig T. Empirically-derived behavioral rules in agent-based models using decision trees learned from questionnaire data // Agent-Based Modeling of Sustainable Behaviors. 2017. pp. 53-76.
18. Kocabas V., Dragicevic S. Bayesian networks and agent-based modeling approach for urban land-use and population density change: A BNAS model // Journal of Geographical Systems. 2013. Vol. 4. No. 15. pp. 403-426.
19. Tian F., Li M., Han X., Liu H., and Mo B. A production-living-ecological space model for land-use optimisation: A case study of the core Tumen River region in China // Ecological Modelling. 2020. Vol. 437. No. 109310.
20. Pooyandeh M., Marceau D. Incorporating Bayesian learning in agent-based simulation of stakeholders' negotiation // Computers, Environment and Urban Systems, No. 48, 2014. pp. 73-85.

21. Ma L., Arentze T., Borgers A., and Timmermans H. Modelling land-use decisions under conditions of uncertainty // *Computers, Environment and Urban Systems*. 2007. Vol. 4. No. 31. pp. 461–476.
22. Axtell R.L., Farmer J.D. Agent-Based Modeling in Economics and Finance: Past, Present, and Future // *Journal of Economic Literature*.
23. Gehrke J.D., Wojtusiak J. Traffic Prediction for Agent Route Planning // *Computational Science – ICCS 2008*. Germany. – 2008. – Т. 5103. – С. 692-701.
24. Rand W. Machine Learning Meets Agent-Based Modeling: When not to go to a Bar // *Conference on Social Agents: Results and Prospects*. 2006.
25. Osoba O.A., Vardavas R., Grana J., Zutshi R., Jaycocks A. Policy-focused Agent-based Modeling using RL Behavioral Models // *19th IEEE International Conference On Machine Learning And Applications*. USA. 2020.
26. Mu T., Zheng S., Trott A.R. Modeling Bounded Rationality in Multi-Agent Simulations Using Rationally Inattentive Reinforcement Learning // *Transactions on Machine Learning Research*. – 2022. – Т. 12. – С. 1-12.
27. Dahlke J., Bogner K., Mueller M., Berger T., Pyka A., Ebersberger B. Is the Juice Worth the Squeeze? Machine Learning (ML) In and For Agent-Based Modelling (ABM) // *arXiv*. 2020. – URL: <https://doi.org/10.48550/arXiv.2003.11985>.
28. Shapley L.S. Stochastic games // *Proceedings of the national academy of sciences*. – 1953. – Т. 39. – № 10. – С. 1095-1100.
29. Shoham Y., Powers R., Grenager T. If multi-agent learning is the answer, what is the question? // *Artificial Intelligence*. – 2007. – Т. 171. – № 7. – С. 365-377.
30. Fiosins M., Fiosina J., Müller J., Görmer J. Reconciling Strategic and Tactical Decision Making in Agent-Oriented Simulation of Vehicles in Urban Traffic // *Proceedings of the 4th International ICST Conference on Simulation Tools and Techniques*. Spain. 2012.
31. Littman M.L. Markov games as a framework for multi-agent reinforcement learning // *Machine Learning Proceedings*. USA. – 1994. – С. 157-163.
32. Kleinberg J., Ludwig J., Mullainathan S., Obermeyer Z. Prediction Policy Problems // *American Economic Review*. – 2015. – Т. 105. – № 5. – С. 491-495.
33. Geman S., Bienenstock E., Doursat R. Neural Networks and the Bias/Variance Dilemma // *Neural Computation*. – 1992. – Т. 4. – № 1. – С. 1-58.
34. Llacay B., Peffer G. Categorical surrogation of agent-based models: A comparative study of machine learning classifiers // *Expert Systems*. 2022. pp. 1-40.
35. Angione C., Silverman E., Yaneske E. Using Machine Learning to Emulate Agent-Based Simulations // *arXiv*, 2021.
36. Chen B., Li W., and Pei H. IEEE 5th Information Technology and Mechatronics Engineering Conference (ITOEC) // *Deep Recurrent Q-Learning for Research on Complex Economic System*. Chongqing, China. 2020. pp. 583–588.
37. Xie S., Lawniczak A. & Gan C. Optimal number of clusters in explainable data analysis of agent-based simulation experiments // *Journal of Computational Science*. 2022. Vol. 62.
38. Luo Y., Chai C., Qin X., Tang N. & Li G. Interactive cleaning for progressive visualization through composite questions // *Proceedings of the IEEE International Conference on Data Engineering*. 2020.
39. Wang Y., Feng K., Chu X., Zhang J., Fu C.W., Sedlmair M., Yu X., & Chen B. A perception-driven approach to supervised dimensionality reduction for visualization // *IEEE Transactions on Visualization and Computer Graphics*. 2017. Vol. 24. No. 5. pp. 1828–1840.
40. Luo Y., Qin X., Tang & Li. DeepEye: towards automatic data visualization // *Proceedings of the IEEE International Conference on Data Engineering*. 2018. pp. 101–112.

41. Hu K., Bakker M.A., Li S., Kraska T. & Hidalgo C. VizML: A machine learning approach to visualization recommendation // Proceedings of the ACM Conference on Human Factors in Computing Systems. 2019.
 42. Chen C., Wang C., Bai X., Zhang P. & Li C. Generativemap: Visualization and exploration of dynamic density maps via generative learning model // IEEE Transactions on Visualization and Computer Graphics. 2019. Vol. 26. No. 1. pp. 216–226.
 43. Han J., Wang C. TSR-TVD: Temporal super-resolution for time-varying data analysis and visualization // IEEE Transactions on Visualization and Computer Graphics. 2019. Vol. 1. No. 26. pp. 216–226.
 44. Berger M., Li J. & Levine J.A. A generative model for volume rendering // IEEE Transactions on Visualization and Computer Graphics. 2019. Vol. 4. No. 25. pp. 1636–1650.
 45. He W., Wang J., Guo H., Wang K.C., Shen H.W., Raj M., Nashed Y.S. & Peterka T. InSituNet: Deep image synthesis for parameter space exploration of ensemble simulations // IEEE Transactions on Visualization and Computer Graphics. 2019. Vol. 1. No. 26. pp. 23–33.
-

Плескачев Юрий Андреевич, старший научный сотрудник лаборатории инфраструктурных и пространственных исследований, Институт прикладных экономических исследований Российской академии народного хозяйства и государственной службы при Президенте Российской Федерации, Москва, Россия
E-mail: pleskachyev-ya@ranepa.ru

Радченко Дарья Максимовна, научный сотрудник лаборатории инфраструктурных и пространственных исследований, Институт прикладных экономических исследований Российской академии народного хозяйства и государственной службы при Президенте Российской Федерации, Москва, Россия
E-mail: radchenko-dm@ranepa.ru

Евдокимов Дмитрий Юрьевич, младший научный сотрудник лаборатории инфраструктурных и пространственных исследований, Институт прикладных экономических исследований Российской академии народного хозяйства и государственной службы при Президенте Российской Федерации, Москва, Россия
E-mail: evdokimov-dy@ranepa.ru

Юлусов Марк Вадимович, младший научный сотрудник лаборатории инфраструктурных и пространственных исследований, Институт прикладных экономических исследований Российской академии народного хозяйства и государственной службы при Президенте Российской Федерации, Москва, Россия
E-mail: yulusov-mv@ranepa.ru

Поступила в редакцию 31.05.2024 г.

UDC 330.46

DOI 10.5281/zenodo.12667180

PLESKACHYEV Yuri¹,
RADCHENKO Daria¹,
EVDOKIMOV Dmitrii¹,
YULUSOV Mark¹

¹Institute of Applied Economic Research, Russian Presidential Academy of National Economy and Public Administration (RANEPA), Vernadsky av., 84, Moscow, Russia, 119571

APPLICATION OF MACHINE LEARNING METHODS IN AGENT-BASED MODELING

Agent-based modeling is a powerful tool for studying complex systems, allowing one to analyze the behavior of agents and their interaction at the micro level. Their application is particularly relevant in cases of insufficient and/or low-quality open statistical data. The article discusses approaches to the classification of methods and provide examples of their application in creating agent-based models that contribute to understanding of and forecasting economic processes. It presents a systematization of modern machine learning techniques and their components used solve specific problems in the modeling of spatial relationships. The article considers the roles and functions of machine learning algorithms in various stages of development of agent-based models, as well as provides examples of applying machine learning methods such modeling in economics and identifies the potential of this approach to enhance the predictive and explanatory power of these models. The application field of machine learning is conditionally divided into 4 blocks: data preprocessing (which includes removing outliers, filling in gaps and normalizing data), shaping agent behavior (accounting for varying degrees of rationality and learning abilities), surrogate models (completely replacing the original model in order to reduce labor, time, and computing power requirements) and data postprocessing (which includes clustering, developing visualization forms, and data cleanup). Methods such as decision trees and Bayesian networks play a key role in extracting rules from data and shaping agents' behavioral strategies. The work highlights the importance of taking noise and anomalies in the data into account as well as the need to adapt models to real conditions. Based on the review findings, recommendations are made for selecting individual methods based on the specific features of the modeling task. The results of the study are of practical importance for the development of more accurate and effective agent models in various fields such as economics, ecology and social sciences.

Key words: *agent based modeling, machine learning, graph neural networks, neural networks, support vector machine, random forest, gradient boosting, k nearest neighbors, Gaussian process, decision trees.*

References

1. Alexandridis K., Pijanowski B.C. (2007) Assessing multiagent parcelization performance in the MABEL simulation model using Monte Carlo replication experiments. *Environment and Planning B: Planning and Design*. Vol. 34, No. 2. pp. 223-244. (In English).
2. Lei Z., Pijanowski B.C., Alexandridis K.T., Olson J. (2005) Distributed modeling architecture of a multi-Agent-Based behavioral economic landscape (MABEL) model. *Simulation*. Vol. 81, No. 7. pp. 503-515. (In English).
3. Sun Z., Müller D. (2013) A framework for modeling payments for ecosystem services with agent-based models, Bayesian belief networks and opinion dynamics models.

Environmental Modelling & Software. No. 45. pp. 15–28. (In English).

4. Laite R., Portman N., Sankaranarayanan K. (2016) Behavioral analysis of agent based service channel design using neural networks. (In English).
5. Chu T.Q., Drogoul A., Boucher A., and Zucker J.D. (2009) Interactive learning of independent experts' criteria for rescue simulations. *Journal of Universal Computer Science*. Vol. 15, No. 13. pp. 2719-2743. (In English).
6. Turgut Y., Bozdog C.E. (2023) A framework proposal for machine learning-driven agent-based models through a case study analysis. *Simulation Modelling Practice and Theory*. 123. (In English).
7. Taghikhah F., Voinov A., Filatova T., & Polhill J.G. (2022) Machine-assisted agent-based modeling: Opening the black box. *Journal of Computational Science*. No. 64. (In English).
8. Dehkordi M., Lechner J., Ghorbani A., Nikolic I., Chappin E., & Herder P. (2023) Using Machine Learning for Agent Specifications in Agent-Based Models and Simulations: A Critical Review and Guidelines. *Journal of Artificial Societies and Social Simulation*. Vol. 1, No. 26, Sep 2023. (In English).
9. Heppenstall A.J., Crooks A.T., See, L.M., Batty, M. (2011) Agent-based models of geographical systems. *Springer Science & Business Media*. (In English).
10. Zhang H., Vorobeychik Y., Letchford J., Lakkaraju K. (2016) Data-driven agent-based modeling, with application to rooftop solar adoption. *Autonomous Agents and Multi-Agent Systems*. Vol. 30. pp. 1023-1049. (In English).
11. Lamperti F., Roventini A., & Sani A. (2018) Agent-based model calibration using machine learning surrogates. *Journal of Economic Dynamics and Control*. Vol. 90. pp. 366-389. (In English).
12. Gaube V., Kaiser C., Wildenberg M., Adensam H., Fleissner P., Kobler J., Lutz J., Schaumberger A., Schaumberger J., Smetschka B. (2009) Combining agent-based and stock-flow modelling approaches in a participative analysis of the integrated land system in Reichraming, Austria. *Landscape Ecology*. Vol. 9, No. 24. pp. 1149–1165. (In English).
13. Abdulkareem S., Augustijn E.W., Mustafa Y., & Filatova T. (2018) Intelligent judgements over health risks in a spatial agent-based model. *International Journal of Health Geographics*. Vol. 1, No. 17, Aug 2018. (In English).
14. Kuznetsov M. (2024) Graph neural networks : a textbook on machine learning. URL: <https://education.yandex.ru/handbook/ml/article/grafovye-nejronnye-seti> (date of application: 04.04.2024). (In Russian).
15. Sengupta R., Chapman C., Sarkar D., & Bortolamiol S. (2018) Automated extraction of movement rationales for building agent-based models: Example of a Red Colobus Monkey group. In L. Perez, E.K. Kim & R. Sengupta (Eds.), *Agent-Based in the Age of Complexity Science Models and Geospatial Big Data*, Berlin Heidelberg: Springer. pp. 59–71. (In English).
16. Rosés R., Kadar C., & Malleson N. (2021) A data-driven agent-based simulation to predict crime patterns in an urban environment. *Computers, Environment and Urban Systems*. Vol. 89, No. 101660. (In English).
17. Sánchez-Marroño N., Alonso-Betanzos A., Fontenla-Romero O., Polhill J.G., & Craig T. (2017) Empirically-derived behavioral rules in agent-based models using decision trees learned from questionnaire data. *Agent-Based Modeling of Sustainable Behaviors*. pp. 53-76. (In English).
18. Kocabas V., Dragicevic S. (2013) Bayesian networks and agent-based modeling approach for urban land-use and population density change: A BNAS model. *Journal of Geographical Systems*. Vol. 4. No. 15. pp. 403–426. (In English).
19. Tian F., Li M., Han X., Liu H., & Mo B. (2020) A production-living-ecological space model for land-use optimisation: A case study of the core Tumen River region in China. *Ecological Modelling*. Vol. 437. No. 109310. (In English).

20. Pooyandeh M., Marceau D. (2014) Incorporating Bayesian learning in agent-based simulation of stakeholders' negotiation. *Computers, Environment and Urban Systems*. No. 48. pp. 73–85. (In English).
21. Ma L., Arentze T., Borgers A., & Timmermans H. (2007) Modelling land-use decisions under conditions of uncertainty. *Computers, Environment and Urban Systems*. Vol. 4. No. 31. pp. 461–476. (In English).
22. Axtell R.L., Farmer J.D. Agent-Based Modeling in Economics and Finance: Past, Present, and Future. *Journal of Economic Literature*. (In English).
23. Gehrke J.D., Wojtusiak J. (2008) Traffic Prediction for Agent Route Planning. *Computational Science – ICCS 2008*. Germany. Vol. 5103. pp. 692-701. (In English).
24. Rand W. (2006) Machine Learning Meets Agent-Based Modeling: When not to go to a Bar. *Conference on Social Agents: Results and Prospects*. (In English).
25. Osoba O.A., Vardavas R., Grana J., Zutshi R., Jaycocks A. (2020) Policy-focused Agent-based Modeling using RL Behavioral Models. 19th IEEE International Conference On Machine Learning And Applications, 2020, USA. (In English).
26. Mu T., Zheng S., Trott A.R. (2022) Modeling Bounded Rationality in Multi-Agent Simulations Using Rationally Inattentive Reinforcement Learning. *Transactions on Machine Learning Research*. Vol. 12. pp. 1-12. (In English).
27. Dahlke J., Bogner K., Mueller M., Berger T., Pyka A., Ebersberger B. (2020) Is the Juice Worth the Squeeze? Machine Learning (ML) In and For Agent-Based Modelling (ABM). *arXiv*. URL: <https://doi.org/10.48550/arXiv.2003.11985>. (In English).
28. Shapley L.S. (1953) Stochastic games. *Proceedings of the national academy of sciences*. Vol. 39. No. 10. Pp. 1095-1100. (In English).
29. Shoham Y., Powers R., Grenager T. (2007) If multi-agent learning is the answer, what is the question? *Artificial Intelligence*. Vol. 171. No. 7. pp. 365-377. (In English).
30. Fiosins M., Fiosina J., Müller J., Görmer J. (2012) Reconciling Strategic and Tactical Decision Making in Agent-Oriented Simulation of Vehicles in Urban Traffic. Proceedings of the 4th International ICST Conference on Simulation Tools and Techniques, Spain, 2012. (In English).
31. Littman M.L. (1994) Markov games as a framework for multi-agent reinforcement learning. *Machine Learning Proceedings, USA, 1994*. pp. 157-163. (In English).
32. Kleinberg J., Ludwig J., Mullainathan S., Obermeyer Z. (2015) Prediction Policy Problems. *American Economic Review*. Vol. 105. No. 5. pp. 491-495. (In English).
33. Geman S., Bienenstock E., Doursat R. (1992) Neural Networks and the Bias/Variance Dilemma. *Neural Computation*. Vol. 4. No. 1. pp. 1-58. (In English).
34. Llacay B., Peffer G. (2022) Categorical surrogation of agent-based models: A comparative study of machine learning classifiers. *Expert Systems*. pp. 1-40. (In English).
35. Angione C., Silverman E., Yaneske E. (2021) Using Machine Learning to Emulate Agent-Based Simulations. *arXiv*. (In English).
36. Chen B., Li W., and Pei H. (2020) Deep Recurrent Q-Learning for Research on Complex Economic System. IEEE 5th Information Technology and Mechatronics Engineering Conference (ITOEC). Chongqing, China. 2020. pp. 583–588. (In English).
37. Xie S., Lawniczak A. & Gan C. (2022) Optimal number of clusters in explainable data analysis of agent-based simulation experiments. *Journal of Computational Science*. Vol. 62. (In English).
38. Luo Y., Chai C., Qin X., Tang N. & Li G. (2020) Interactive cleaning for progressive visualization through composite questions. Proceedings of the IEEE International Conference on Data Engineering. 2020. (In English).
39. Wang Y., Feng K., Chu X., Zhang J., Fu C.W., Sedlmair M., Yu X., & Chen B. (2017) A perception-driven approach to supervised dimensionality reduction for visualization.

IEEE Transactions on Visualization and Computer Graphics. Vol. 24. No. 5. pp. 1828–1840. (In English).

40. Luo Y., Qin X., Tang & Li. (2018) Deepeye: towards automatic data visualization. Proceedings of the IEEE International Conference on Data Engineering. 2018. pp. 101–112. (In English).

41. Hu K., Bakker M.A., Li S., Kraska T. & Hidalgo C. (2019) VizML: A machine learning approach to visualization recommendation. Proceedings of the ACM Conference on Human Factors in Computing Systems. 2019. (In English).

42. Chen C., Wang C., Bai X., Zhang P. & Li C. (2019) Generativemap: Visualization and exploration of dynamic density maps via generative learning model. *IEEE Transactions on Visualization and Computer Graphics*. Vol. 26. No. 1. pp. 216–226. (In English).

43. Han J., Wang C. (2019) TSR-TVD: Temporal super-resolution for time-varying data analysis and visualization. *IEEE Transactions on Visualization and Computer Graphics*. Vol. 1. No. 26. pp. 216–226. (In English).

44. Berger M., Li J. & Levine J.A. (2019) A generative model for volume rendering. *IEEE Transactions on Visualization and Computer Graphics*. Vol. 4. No. 25. pp. 1636–1650. (In English).

45. He W., Wang J., Guo H., Wang K.C., Shen H.W., Raj M., Nashed Y.S. & Peterka T. (2019) InSituNet: Deep image synthesis for parameter space exploration of ensemble simulations. *IEEE Transactions on Visualization and Computer Graphics*. Vol. 1. No. 26. pp. 23–33. (In English).

Pleskachyev Yuri, Senior Researcher, Laboratory of Infrastructure and Spatial Research, Institute of Applied Economic Research, Russian Presidential Academy of National Economy and Public Administration (RANEPA), Moscow, Russia

E-mail: pleskachyev-ya@ranepa.ru

Radchenko Daria, Researcher, Laboratory of Infrastructure and Spatial Research, Institute of Applied Economic Research, Russian Presidential Academy of National Economy and Public Administration (RANEPA), Moscow, Russia

E-mail: radchenko-dm@ranepa.ru

Evdokimov Dmitrii, Junior Researcher, Laboratory of Infrastructure and Spatial Research, Institute of Applied Economic Research, Russian Presidential Academy of National Economy and Public Administration (RANEPA), Moscow, Russia

E-mail: evdokimov-dy@ranepa.ru

Yulusov Mark, Junior Researcher, Laboratory of Infrastructure and Spatial Research Institute of Applied Economic Research, Russian Presidential Academy of National Economy and Public Administration (RANEPA), Moscow, Russia

E-mail: yulusov-mv@ranepa.ru

Received 31.05.2024