

НАУЧНАЯ СТАТЬЯ / RESEARCH PAPER

УДК 69.05

DOI: 10.22227/1997-0935.2024.11.1835-1849

Модель прогнозирования материальных ресурсов и сметной стоимости на ранних этапах жизненного цикла объектов строительства

Михаил Владимирович Гуреев, Александр Николаевич Макаров

Национальный исследовательский Московский государственный строительный университет (НИУ МГСУ); г. Москва, Россия

АННОТАЦИЯ

Введение. Строительная цифровизация предполагает возможность прогнозирования материальных ресурсов (МР) с заданной степенью точности на ранних этапах жизненного цикла (ЖЦ) объекта строительства (ОС), что позволит формировать стоимостные показатели, а также объемы МР и оборудования — одних из ключевых элементов управления и планирования различных стадий ЖЦ объекта. Возможность создания на основе технологий искусственного интеллекта (ИИ) и машинного обучения (МО) инструмента прогнозирования указанных параметров представляется перспективным направлением развития, позволяющим достичь высокого уровня точности планирования бюджета и продолжительности проекта на предпроектной стадии инвестиционно-строительного проекта.

Материалы и методы. Рассмотрена проектная документация для 37 многоквартирных жилых домов с выделенными и нормализованными параметрами: технико-экономические показатели, материально-технические ресурсы, стоимость и др. Для подготовки и обучения моделей ИИ на базе Python выбраны методы библиотеки scikit-learn для сравнения следующих математических моделей: деревья решений, регрессии и алгоритмы, основанные на бустинге.

Результаты. Обучение и исследование проводилось с применением способа автоматизированного машинного обучения (AutoML). На основе сравнения коэффициента детерминации R^2 и среднеквадратичного отклонения (RMSE) выбраны ансамбли моделей, формирующие прогноз для объемов МР и оборудования, а также для сметной стоимости с диапазоном погрешности $\pm 8\%$. Входными значениями моделей являлись 11 количественно-качественных параметров, описывающих характеристики планируемого объекта, формирование которых возможно на ранних этапах ЖЦ объекта без разработки проектной документации.

Выводы. Результаты исследования демонстрируют возможность получения на предпроектной стадии фактически проектных данных с точностью, соответствующей этапу разработки рабочей документации для объекта строительства. Значительно повышается точность прогнозов общей сметной стоимости, а также появляется возможность прогнозирования с заданной точностью объемов материалов и оборудования на ранних этапах ЖЦ ОС для оптимизации всего процесса строительства.

КЛЮЧЕВЫЕ СЛОВА: ранние этапы жизненного цикла объекта, модель прогнозирования сметной стоимости, ансамбли моделей машинного обучения, проектные решения, объекты жилой недвижимости

ДЛЯ ЦИТИРОВАНИЯ: Гуреев М.В., Макаров А.Н. Модель прогнозирования материальных ресурсов и сметной стоимости на ранних этапах жизненного цикла объектов строительства // Вестник МГСУ. 2024. Т. 19. Вып. 11. С. 1835–1849. DOI: 10.22227/1997-0935.2024.11.1835-1849

Автор, ответственный за переписку: Михаил Владимирович Гуреев, mvgureev@gmail.com.

Model of forecasting of material resources and estimated cost at early stages of life cycle of construction objects

Mikhail V. Gureev, Aleksandr N. Makarov

Moscow State University of Civil Engineering (National Research University) (MGSU);
Moscow, Russian Federation

ABSTRACT

Introduction. Digitalization of construction involves the possibility of forecasting material resources with a given degree of accuracy at the early stages of the life cycle of the construction object, which will make it possible to form cost indicators, as well as the volume of material resources and equipment — one of the key elements of management and planning of various stages of the life cycle of the object. The possibility of creating a forecasting tool based on artificial intelligence (AI) and machine learning (ML) technologies for these parameters seems to be a promising development direction, allowing to achieve a high level of accuracy in budget planning and project duration at the pre-project stage of an investment and construction project.

Materials and methods. Design documentation for 37 multi-apartment residential buildings with allocated and normalized parameters: technical and economic indicators, material and technical resources, cost and others. To prepare and train AI

models based on Python, the methods of the scikit-learn library were selected to compare the following mathematical models: decision trees, regressions and algorithms based on boosting.

Results. The training and research were conducted using the automated machine learning (AutoML) method. Based on a comparison of the coefficient of determination R^2 and the standard deviation (RMSE), ensembles of models were selected that form a forecast for the volume of material resources and equipment, as well as for the estimated cost with an error range of $\pm 8\%$. The input values of the models were 11 quantitative and qualitative parameters describing the characteristics of the planned object, the formation of which is possible at the early stages of the life cycle of the object without the development of design documentation.

Conclusions. The results of the study demonstrate the possibility of obtaining actual design data already at the pre-design stage with accuracy corresponding to the stage of development of working documentation for the construction object. Thus, the accuracy of forecasts of the total estimated cost is significantly increased, and it also becomes possible to predict with a given accuracy the volumes of materials and equipment at the early stages of the life cycle of the construction object in order to optimize the entire construction process.

KEYWORDS: early stages of the object's life cycle, an estimated cost forecasting model, ensembles of machine learning models, design solutions, residential real estate objects

FOR CITATION: Gureev M.V., Makarov A.N. Model of forecasting of material resources and estimated cost at early stages of life cycle of construction objects. *Vestnik MGSU* [Monthly Journal on Construction and Architecture]. 2024; 19(11):1835-1849. DOI: 10.22227/1997-0935.2024.11.1835-1849 (rus.).

Corresponding author: Mikhail V. Gureev, mvgureev@gmail.com.

ВВЕДЕНИЕ

Многолетняя сложившаяся практика закрепила в качестве ключевых такие факторы управления инвестиционно-строительным циклом любого объекта, как объемы материальных ресурсов (МР) и оборудования, необходимые для строительства, а также, как производная величина, их стоимостные показатели, формирующие общую смету на строительство.

Вместе с тем точные значения объемов МР и оборудования, а также общая смета на строительство, в зависимости от этапа жизненного цикла (ЖЦ) объекта строительства (ОС), имеют разные допустимые значения точности, увеличивающиеся по мере продвижения от этапа инвестиционной оценки к этапу рабочей документации.

Однако точность, присущая этапу рабочей документации, востребована и на ранних этапах ЖЦ ОС для корректного обоснования инвестиционного проекта, проведения тендеров для выбора участников проекта, контроля разработки проектной документации и т.д.

Проблематика эффективного прогнозирования в строительстве обусловлена необходимостью оптимизации расходов и сокращения сроков строительства. Традиционные подходы, основанные на экспертных оценках и исторических данных, часто не учитывают сложности и динамику современных строительных проектов, что диктует потребность совершенствования нормативно-правового регулирования ценообразования в строительстве с одной стороны, а также формирует запрос на повышение достоверности определения сметной стоимости строительства с другой стороны [1]. В то же время на практике уже применяются методы машинного обучения (МО), решающие задачи прогнозирования с заданными диапазонами точности в короткий срок в различных отраслях, в том числе и в строительстве [2].

Таким образом, прогнозирование МР с заданной степенью точности на различных этапах ЖЦ

ОС, в частности на этапе обоснования инвестиций, позволит формировать стоимостные показатели по разделам проектной документации, а также объемам МР и оборудования, которые являются одними из ключевых элементов управления и планирования различных стадий ЖЦ объекта.

На сегодняшний день существующие подходы к расчету стоимости строительства, как правило, разделены на несколько итераций, соответствующих определенному этапу ЖЦ объекта, и имеют установленные допуски по точности.

Структура ЖЦ ОС представляет собой последовательный процесс реализации следующих этапов¹: инициирование проекта (определяет содержание, финансовые ресурсы, а также другие факторы, влияющие на конечный результат); планирование проекта (реализуется план по управлению проектом в строительстве, в том числе планирование бюджета проекта; планирование закупок для проекта; определение ключевых показателей эффективности и результатов проекта в строительстве) и реализация проекта строительства (стадия проектирования и строительства).

Как видно из описания, на различных этапах ЖЦ объекта требуется как оценка стоимости строительства, так и данные по объемам материалов и оборудования для решения различных управленческих задач.

Сегодня имеется несколько подходов к оценке стоимости строительства для жилых зданий. В частности, Минстроем России используются Укрупненные нормативы цены строительства². В общем виде,

¹ ГОСТ Р 57363–2016. Управление проектом в строительстве. Деятельность управляющего проектом (технического заказчика) : утв. Приказом Федерального агентства по техническому регулированию и метрологии от 16.12.2016 № 2043-ст.

² Об утверждении укрупненных нормативов цены строительства. Укрупненные нормативы цены строительства. НЦС 81-02-01–2024. Сборник № 01. Жилые здания : Приказ Минстроя России от 21.02.2024 № 128/пр.




Рис. 1. Существующая точность оценки стоимости строительства на различных этапах жизненного цикла объекта (Минстрой РФ)

Fig. 1. The existing accuracy of estimating the cost of construction at various stages of the life cycle of the facility (Ministry of Construction of the Russian Federation)

основанная на нормативных способах оценка стоимости строительства и ее погрешность, в зависимости от различных этапов ЖЦ (идея проекта, обоснование инвестиций — ОБИН, проект, рабочий проект, исполнительная документация), обобщена Счетной палатой России³ (рис. 1).

В материале Счетной палаты России отмечается значимость приоритета перехода к применению полноценного ресурсного метода определения сметной стоимости строительства. В то же время специалистами устанавливается важность апробации новых подходов в рамках осуществляемой реформы ценообразования и сметного нормирования в строительстве и перехода к ресурсному (ресурсно-индексному) методу расчета сметной стоимости.

Для определения точности оценки стоимости строительства Международная ассоциация развития стоимостного инжиниринга (МАРСИ) рекомендует применять «Систему классификации стоимостных оценок в целях подготовки проектов, организации контрактной стратегии и строительства в обрабатывающих отраслях промышленности» от 02.02.2005 № 18R-97 (далее — система)⁴. В системе определена

точность расчетов [3] на основе обобщенного опыта крупных компаний, инвестиционно-строительные проекты (ИСП) которых обычно проходят через несколько стадий уточнения стоимости (рис. 2).

Как видно, традиционные способы оценки стоимости строительства на ранних этапах ЖЦ здания включают методы, основанные на экспертных оценках, анализе стоимости по аналогии, единичной стоимости и различных параметрических моделях. Эти методы варьируются по степени точности, зависящей от доступности данных, опыта оценщиков и специфики проекта.

Таким образом, можно сделать вывод, что в настоящее время варьирование точности оценки стоимости реализации проекта находится в широких диапазонах на этапах 1–4 ЖЦ объекта. Это обстоятельство повышает риск ошибочной оценки стоимости проекта, что неблагоприятно сказывается на дальнейшем его развитии, так как именно на ранних стадиях ЖЦ формируются ключевые проектные, финансовые и организационно-технические решения, описанные выше.

Оценка стоимости проекта, проводимая на ранних этапах, как правило, на одном базовом параметре — общая площадь объекта, с одной стороны, предполагает уровень неопределенности, описанный в табл. 1, с другой — не дает возможность опираться на объемы МР и оборудования. Тогда как это ключевые параметры, влияющие на процессе управления в инвестиционно-строительном цикле.

Как справедливо указывает автор в работе [3], имеется высокая степень неопределенности ИСП, в особенности стоимости строительства, определяемой при проектировании и проходящей через мно-

³ Бюллетень Счетной палаты Российской Федерации. 2021. № 6. Ценообразование в строительстве.

⁴ AACE International Recommended Practice No. 18R-97 Cost Estimate Classification System — as Applied in Engineering, Procurement, and Construction for the Process Industries (Система классификации стоимостных оценок в целях подготовки проектов, организации контрактной стратегии и строительства в обрабатывающих отраслях промышленности от 02.02.2005 № 18R-97, разработанная Международной ассоциацией развития стоимостного инжиниринга (МАРСИ)).



Рис. 2. Существующая точность оценки стоимости строительства на различных этапах жизненного цикла объекта (МАРСИ)

Fig. 2. The existing accuracy of estimating the cost of construction at various stages of the life cycle of the facility (MARSI)

Табл. 1. Диапазоны точности оценки стоимости реализации проекта на этапах жизненного цикла по различным методикам
Table 1. Ranges of accuracy in estimating the cost of project implementation at the stages of the life cycle using various methods

Этапы жизненного цикла объекта строительства (Минстрой/МАРСИ) Stages of the life cycle of the construction object (Ministry of Construction/MARSI)	Диапазоны точности стоимостных оценок реализации проекта по различным методикам, % Ranges of accuracy of cost estimates of project implementation according to various methods, %		
	МАРСИ MARSI	Минстрой Ministry of Construction	Перспективные методы МО Promising methods of ML
Идея проекта/предварительное ТЭО The idea of the project/preliminary feasibility study	–30...+50	–30...+30	–10...+10
Обоснование инвестиций/ТЭО Justification of investments/feasibility study	–20...+30	–20...+20	–10...+10
Проект/проектная документация Project/project documentation	–15...+20	–10...+10	–10...+10
Рабочий проект/рабочая документация Working draft/working documentation	–10...+15	–2...+2	–10...+10
Исполнительная документация/ рабочая документация Executive documentation/working documentation	–10...+15	–2...+2	–10...+10

жество этапов уточнения и изменения стоимостных показателей в зависимости от стадии проектирования и методов определения стоимости строительства. При этом стоимость строительства является главным фактором, оказывающим влияние на качество и достоверность оценки экономической эффективности ИСП.

Существующие методы оценки имеют ограниченную точность, особенно на ранних этапах, когда сведения о проекте неполны. Их точность также сильно зависит от качества и актуальности используемых данных, от опыта и субъективных суждений оценщиков. Фактически первые спецификации,

содержащие объемы МР и оборудования, на основе которых производится детальная оценка стоимости реализации проекта, появляются только по завершении стадии проектной документации, и даже в этом случае их точность часто оставляет желать лучшего.

Вместе с тем модели МО (табл. 1) предполагают значительные перспективы для улучшения процесса оценки стоимости строительства на ранних этапах. Алгоритмы машинного обучения могут анализировать большие объемы информации, выявляя сложные нелинейные зависимости между исходными параметрами проекта и объемами МР и оборудования,

а также его стоимостью. В перспективе это позволит делать более точные прогнозы, основанные на объективной информации, а не на субъективном опыте.

Стоит отметить, что внедрение инструментов МО в область строительного проектирования ведется достаточно активно с получением практических результатов. Методы МО дают возможность обрабатывать, систематизировать, прогнозировать и классифицировать огромные массивы информации по определенным признакам и условиям, что в разы сокращает трудозатраты и повышает эффективность работы [4].

В работе [5] автор пришел к выводу о том, что применение моделей машинного обучения приводит в данном случае к улучшению качества прогноза инвестиций в жилищное строительство на основе исследованных параметров.

Как показало исследование [6], система на основе искусственного интеллекта (ИИ) может отслеживать и оценивать сотни тысяч повреждений, генерировать отчеты для различных типов зданий и в конечном итоге прогнозировать сроки износа и повреждения тех или иных объектов с достаточной степенью надежности.

Применение ИИ [7] позволяет значительно снизить издержки в процессе проектирования, строительства и эксплуатации за счет сокращения количества ошибок при проектировании и их своевременного исправления, а также повысить качество прогнозирования, улучшая логику непосредственно на строительной площадке. Технологии МО возможно применять в строительстве на протяжении всего ЖЦ проекта, включая такие начальные этапы, как идея проекта, обоснование инвестиций и проектирование.

Участники процесса проектирования и строительства могут использовать рекомендательный системный подход (контролируемое обучение), который использует МО для определения важных данных, необходимых для выработки управленческих решений. Эти приложения могут рекомендовать инженерам и архитекторам использовать конкретный дизайн, конструктивное решение (например, тип соединений — сварные или болтовые) или архитектурную отделку (например, навесные стены против оконных перегородок) на основе различных критериев (общая стоимость владения, сроки завершения строительства, вероятность дефектных конструкций — ошибки при выполнении). Конечным результатом является то, что участники процесса получают больше информации для принятия обоснованных управленческих решений [8].

Возможность внедрения подходов МО для решения задач прогнозирования МР на ранних этапах ЖЦ объекта описана в труде [9]. В статье раскрыты исходные входные параметры, влияющие на характеристики многоквартирных жилых домов (МКД). Выделены и нормализованы значимые с точки зрения экономических издержек и сроков МР (материалы и оборудование — выходные параметры). На осно-

ве коэффициентов корреляции Пирсона выявлена линейная статистическая взаимосвязь входных и выходных параметров выборки.

В рамках настоящего исследования ставится цель рассмотреть существующие модели МО и произвести на базе сравнения выбор оптимальной модели для прогнозирования выходных параметров объекта строительства (объем материалов и оборудования, необходимых для строительства объектов) с учетом значимых входных параметров (количественно-качественные показатели, описывающие характеристики объекта) для управления проектом строительства МКД на этапе обоснования инвестиций.

Задачи исследования:

- рассмотреть существующие модели, выбрать подходящие исследования;
- описать принципы работы имеющихся моделей;
- провести расчеты по выбранным моделям;
- проанализировать результаты и сделать вывод об оптимальной модели, укладывающейся в цели исследования.

МАТЕРИАЛЫ И МЕТОДЫ

Для решения поставленных задач был выбран язык программирования Python, в частности методы, содержащиеся в библиотеке scikit-learn. В ее состав включены алгоритмы, среди которых и предназначенные для задач классификации, регрессионного и кластерного анализа данных. Кроме того, основываясь на современных подходах МО, выбран способ автоматизированного машинного обучения, а именно Auto-Sklearn — автоматизированный пакет машинного обучения, основанный на scikit-learn и генерирующий признаки на основе неструктурированных данных (далее — AutoML). В его состав входят различные алгоритмы, в том числе предназначенные для задач классификации, регрессионного и кластерного анализа данных, включая метод опорных векторов, метод случайного леса, градиентного бустинга и др. Библиотека разработана для взаимодействия с численными и научными библиотеками языка программирования Python. Данный пакет эффективно работает с небольшими объемами выборок и дает большую (по сравнению с другими подходами МО) точность [10].

Методы МО предполагают возможность обучения за счет использования решений множества сходных задач или существующих верифицированных сведений (в данном случае готовых разделов проектной документации для жилых зданий), что позволяет обучать модель и увеличивать точность прогнозирования, что является одним из ключевых аспектов, определяющих выбор этого метода.

Использование методов МО обусловило следующие последовательные этапы работы.

Подготовка данных

В контексте решения поставленных задач был произведен сбор и анализ 37 комплектов проектной

документации для жилых домов, расположенных в Москве и Московской области, проектирование которых осуществлялось в 2015–2022 гг. Произведено их распознавание в машиночитаемый вид и последующая унификация под единые форматы входных и выходных параметров для каждого из зданий (суммарно более 300 тысяч строк данных, представленных в табличной форме) — создание обучающей и тестовой выборки.

В работе [9] описан подход к формированию выборки для обучения модели. В частности, отобраны количественно-качественные входные параметры, влияющие на характеристики проектируемого объекта (техничко-экономические показатели, отдельные архитектурные, объемно-планировочные и технические решения — входные параметры).

В качестве выходных параметров, значимых в рамках поставленной задачи, первично были выбраны материальные ресурсы, имеющие суммарный стоимостной показатель более 68 % от общей сметной стоимости (что эквивалентно более 93 % от сметной стоимости всех материалов, необходимых для строительства, без учета совокупных затрат непосредственно на монтажные работы и использование механизмов) в общих расходах на строительство МКД. Кроме того, в качестве производного параметра от МР и оборудования в набор данных обучающей выборки был добавлен ключевой параметр для последующей оценки эффективности работы модели — общая сметная стоимость строительства.

Представленные выходные параметры обобщены до предельных классов, к примеру, арматуры

различных диаметров были обобщены до класса «арматура» с единицами измерения в тоннах. Указанное обобщение в рамках одного класса фактически представляло собой первый этап процесса нормализации данных, который предшествует построению моделей на базе МО и обеспечивает корректную и устойчивую работу будущих моделей.

Нормализация — важный этап подготовки МО, призванный привести различные сведения в разных единицах измерения и диапазонах значений к единому виду, что позволит впоследствии сравнивать их между собой или использовать для расчета схожести объектов.

Вторым этапом нормализации данных было устранение выбросов посредством функции линейной регрессии.

В результате сформирован первичный объем выборки, состоящей из нормализованных проектных решений для каждого из выбранных объектов, при этом сформированная выборка МР (выходных параметров) отвечает одновременно двум параметрам:

- 1) каждое выходное значение выборки имеет значимый стоимостной показатель в общих расходах на строительство МКД;
- 2) среди совокупности выходных параметров представлены все основные разделы проектной документации⁵, содержащие материальные ресурсы, необходимые для строительства, а именно — архи-

⁵ О составе разделов проектной документации и требованиях к их содержанию : Постановление Правительства Российской Федерации от 16.02.2008 № 87.

Табл. 2. Значения коэффициента корреляции Пирсона значимых параметров выборки

Table 2. Pearson correlation coefficient values of significant selection parameters

Наименование параметра Name of the parameter	Общая площадь объекта The total area of the object	Строительный объем объекта The building volume of the object	Строительный объем подземной части здания The construction volume of the underground part of the building	Строительный объем надземной части здания The building volume of the aboveground part of the building	Общая площадь квартир объекта The total area of the apartments of the object	Количество подземных этажей Number of underground floors	Среднее значение площади подземного этажа The average value of the underground floor area	Количество жителей объекта The number of residents of the object	Суммарная площадь ветроенных помещений надземной части здания The total area of the built-in premises of the above-ground part of the building	Общее количество машино-мест на подземной стоянке автомобилей The total number of parking spaces in the underground parking lot	Суммарная площадь помещения по всем этажам стоянки автомобилей The total area of the premises on all floors of the parking lot
Наружное остекление Exterior glazing	0,98	0,93	0,81	0,92	0,89	0,68	0,77	0,83	0,72	0,81	0,82

Окончание табл. 2 / End of the Table 2

Наименование параметра Name of the parameter	Общая площадь объекта The total area of the object	Строительный объем объекта The building volume of the object	Строительный объем подземной части здания The construction volume of the underground part of the building	Строительный объем надземной части здания The building volume of the aboveground part of the building	Общая площадь квартир объекта The total area of the apartments of the object	Количество подземных этажей Number of underground floors	Среднее значение площади подземного этажа The average value of the underground floor area	Количество жителей объекта The number of residents of the object	Суммарная площадь встроженных помещений надземной части здания The total area of the built-in premises of the above-ground part of the building	Общее количество машино-мест на подземной стоянке автомобилей The total number of parking spaces in the underground parking lot	Суммарная площадь помещения по всем этажам стоянки автомобилей The total area of the premises on all floors of the parking lot
Арматура Fittings	0,97	0,91	0,80	0,90	0,87	0,66	0,77	0,81	0,69	0,80	0,80
Монолитный железобетон Monolithic reinforced concrete	0,92	0,95	0,82	0,96	0,92	0,62	0,84	0,88	0,68	0,79	0,80
Щит электрический Electric shield	0,89	0,85	0,64	0,90	0,92	0,54	0,70	0,87	0,55	0,62	0,66
Насосная установка Pumping station	0,87	0,92	0,91	0,86	0,72	0,79	0,69	0,62	0,84	0,89	0,91
Прибор отопления Heating device	0,89	0,92	0,77	0,93	0,90	0,65	0,76	0,88	0,65	0,77	0,77
Труба пластиковая Plastic pipe	0,63	0,69	0,47	0,76	0,75	0,37	0,59	0,79	0,44	0,42	0,44
Труба стальная Steel pipe	0,82	0,78	0,75	0,73	0,64	0,64	0,67	0,60	0,66	0,75	0,79
Электрокабель Electric cable	0,89	0,92	0,87	0,93	0,91	0,84	0,76	0,87	0,83	0,88	0,90
Телекоммуникационный шкаф Telecommunication cabinet	0,79	0,73	0,62	0,74	0,75	0,59	0,54	0,68	0,51	0,69	0,69
Извещатель пожарный Fire detector	0,88	0,87	0,72	0,89	0,90	0,72	0,69	0,86	0,60	0,75	0,71
Общая сметная стоимость строительства The total estimated cost of construction	0,94	0,94	0,68	0,92	0,94	0,09	0,85	0,94	0,70	0,77	0,81

тектурные решения (АР), конструктивные и объемно-планировочные решения (КР), сведения об инженерном оборудовании, о сетях и системах инженерно-технического обеспечения (ИОС).

На основании коэффициента корреляции Пирсона по каждому из выбранных параметров подтверждена верность альтернативной гипотезы — значения полученных коэффициентов (табл. 2) демонстрируют значимую линейную взаимосвязь выделенных входных и выходных параметров ОС.

Обучение моделей

Процесс выбора лучшей модели/ансамбля моделей МО для прогнозирования основывался на срав-

нении нескольких типов регрессионных моделей, включая метод опорных векторов (SVM), ARD регрессию (ARDRegression), гауссовский процесс регрессии (GaussianProcessRegressor) и градиентный бустинг регрессор (GradientBoostingRegressor). Модели представляют собой различные подходы в МО, каждый из которых имеет уникальные особенности, делающие подходящими для решения поставленных задач, включая прогнозирование МР и оборудования для строительства.

Процесс обучения разделен на эпохи — полные циклы обучения модели МО на итерации набора данных. По итогу завершения каждой эпохи об-

учения с помощью вычисления корня квадратного из среднеквадратичной ошибки (RMSE) производилась проверка качества работы модели для оценки прогресса модели и принятия решения об окончании обучения для последующей проверки на тестовой выборке. Такой подход обусловлен сложным набором неструктурированных данных и позволял итеративно добиться требуемых диапазонов RMSE, отслеживая при этом прогресс обучения моделей.

После обучения качество обучения полученной модели оценивалось на тестовой выборке. Для каждой модели вычислялся коэффициент детерминации R^2 , который отражает долю вариации зависимой переменной, объясненную независимыми переменными модели. Высокое значение R^2 указывает на лучшее качество прогнозов модели.

Коэффициент детерминации является статистическим показателем, используемым для оценки качества модели в задачах регрессии. Он показывает, какая доля вариации зависимой переменной объясняется независимыми переменными модели:

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2},$$

где n — количество наблюдений; y_i — фактические значения зависимой переменной; $\hat{y}_i$ — предсказанные моделью значения; $\bar{y}$ — среднее значение фактических значений зависимой переменной.

Коэффициент детерминации колеблется от 0 до 1, где 0 указывает на то, что модель не объясняет вариацию зависимой переменной, а 1 — что модель идеально объясняет вариацию. В общем, чем ближе значение R^2 к 1, тем лучше модель «подходит» для данных. Это позволяет оценить, насколько хорошо модель может предсказывать или описывать исходы в рамках данных, на которых она была обучена.

Другой важной метрикой, определяющей эффективность предсказания модели, является RMSE прогноза тестовой выборки. Среднеквадратичная ошибка — метрика, показывающая, насколько далеки в среднем прогнозируемые значения от наблюдаемых (фактических) значений в модели. RMSE рассчитывается по формуле:

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{k=1}^N (\hat{y}_k - y_k)^2},$$

где N — количество наблюдений; $\hat{y}_k$ — предсказанные моделью значения; y_k — фактические значения зависимой переменной.

В качестве дополнительного параметра также анализировались значения средней абсолютной ошибки (MAE) для каждой модели.

РЕЗУЛЬТАТЫ ИССЛЕДОВАНИЯ

Благодаря использованию инструмента AutoML удалось получить ансамбли на основе сразу нескольких моделей, что позволило на представленном набо-

ре данных получить достаточно точные предсказания параметров на тестовой выборке.

В общем виде AutoML представляет собой итеративный процесс обучения различных моделей на базе обучающей выборки, содержащий эксперименты с несколькими алгоритмами МО. В действительности предсказать на начальном этапе, какие модели будут давать приемлемые результаты при работе с заданной обучающей выборкой сложно, поэтому AutoML фактически перебирает значительное количество моделей, чтобы сравнить их точность, прежде чем выбрать модель/ансамбль моделей, максимально адаптированный под обучающую выборку. Решение сложной вычислительной задачи предполагает использование ансамблей — сочетания нескольких алгоритмов МО, одновременно обучающихся и исправляющих ошибки друг друга. При этом каждая итерация фактически представляет собой определенную эпоху обучения. При работе с заданной обучающей выборкой для каждого класса было произведено от 25 до 80 эпох обучения (рис. 3).

Последующий выбор ансамбля моделей (в большинстве случаев объединение нескольких моделей в одну и прогноз выходных данных на базе ансамбля моделей превосходит результат одной модели) можно было бы определить по метрике модели. Различные показатели модели возвращаются после обучения регрессионных и классификационных моделей, запускающих инструмент обучения с использованием AutoML.

Результаты, полученные для каждой модели, сравниваются на основе их R^2 и RMSE на тестовой выборке. Модели, обладающие наименьшим значением корня квадратного из среднеквадратичной ошибки и с самым высоким коэффициентом детерминации, выбираются в ансамбль как лучшие, поскольку они демонстрируют наибольшую точность прогнозирования в сравнении с другими моделями. В качестве примера приведен анализ моделей на примере выходного параметра «Арматура» (табл. 3), при этом аналогичное сравнение было проведено для всех выходных параметров. В табл. 4 представлен анализ моделей по определению общей сметной стоимости объекта.

Исследование показало, что для каждого класса ансамбли модели, основанные на методах опорных векторов и градиентного бустинга, показали лучшие результаты и отобраны с целью дальнейшей работы по прогнозированию объемов материалов и оборудования, а также сметной стоимости для ранних этапов ЖЦ ОС.

Метод опорных векторов (SVM) — один из популярных алгоритмов машинного обучения, который используется для задач классификации и регрессии. Он основан на идее поиска оптимальной гиперплоскости, которая разделяет данные разных классов [11].

Отдельно следует обратить внимание, что модели МО, основанные на методе опорных векторов,




Рис. 3. Первые 25 эпох обучения моделей с помощью AutoML для класса «Арматура»

Fig. 3. The first 25 epochs of model training using AutoML for the “Armature” class

Табл. 3. Сравнительный анализ результатов работы моделей для класса «Арматура»

Table 3. Comparative analysis of the results of the models for the “Armature” class

Параметры каждой модели, отобранной в ансамбль Parameters of each model selected in the ensemble				Параметры ансамбля моделей, выполняющего прогноз Parameters of the ensemble of models performing the forecast		
Наименование модели Name of the model	ensemble_R ²	ensemble_MAE	ensemble_RMSE	R ²	MAE	RMSE
Гауссовская регрессия Gaussian_process	0,882677821	226177,6406	111672000000	0,90062	245654,4863	94591846877
АОР регрессия Ard_regression	0,739256749	342365,543	248186000000	0,90062	245654,4863	94591846877
Метод опорных векторов Libsvm_svr	0,657690116	418923,4844	325825E000000	0,90062	245654,4863	94591846877
Градиентный бустинг Gradient_boosting	0,919311528	190765,6953	76802678072	0,90062	245654,4863	94591846877
Метод опорных векторов Libsvm_svr	0,8827941	250391,5391	111562000000	0,90062	245654,4863	94591846877

Табл. 4. Сравнительный анализ результатов работы моделей по определению общей сметной стоимости
Table 4. Comparative analysis of the results of the models to determine the total estimated cost

Параметры каждой модели, отобранной в ансамбль Parameters of each model selected in the ensemble				Параметры ансамбля моделей, выполняющего прогноз Parameters of the ensemble of models performing the forecast		
Наименование модели Name of the model	ensemble_R ²	ensemble_MAE	ensemble_RMSE	R ²	MAE	RMSE
АОР регрессия Ard_regression	0,838993445	1982810,362	5,84055E+12	0,9375	1227033,666	2,26758E+12
Алгоритм усиления классификаторов Adaboost	0,679393077	2128835,404	1,16301E+13	0,9375	1227033,666	2,26758E+12
Метод опорных векторов Libsvm_svr	−0,846241455	7573039,332	6,69729E+13	0,9375	1227033,666	2,26758E+12
АОР регрессия Ard_regression	0,83899669	1982793,837	5,84044E+12	0,9375	1227033,666	2,26758E+12
Метод опорных векторов Liblinear_svr	0,721958326	2820051,539	1,0086E+13	0,9375	1227033,666	2,26758E+12
Многослойный перцептрон Mlp	0,231702029	3811885,179	2,78702E+13	0,9375	1227033,666	2,26758E+12
Алгоритм усиления классификаторов Adaboost	0,172470109	2373370,854	3,00189E+13	0,9375	1227033,666	2,26758E+12
Метод опорных векторов Liblinear_svr	0,542422317	2401944,004	1,65987E+13	0,9375	1227033,666	2,26758E+12

открыли новые возможности для инновационных исследований в области экономики энергетики и финансов [12–21]. В частности, по энергетическому и финансовому применению различных методов МО прогнозирование цен на сырую нефть и электроэнергию [13, 14] является наиболее популярной областью использования, при этом SVM-модели — одни из наиболее актуальных методов МО, применяемых в области экономики энергетики.

Градиентный бустинг (XGBoost) известен своей способностью достигать высоких уровней точности в различных задачах МО. Это достигается через усовершенствованные методы регуляризации, а именно L1 (лассо регрессия) и L2 (ридж-регрессия), которые помогают предотвратить переобучение, что является критически важным во многих реальных приложениях [15]. В целом [16–18] XGBoost (eXtreme Gradient Boosting) представляет собой ансамблевый алгоритм МО, используемый для уменьшения смещения и дисперсии в обучении с учителем.

Этот метод отвечает на вопрос о возможности «слабых» обучающихся алгоритмов с результатами ненамного лучше случайного гадания усовершенствоваться до «сильного» обучающегося алгоритма произвольной точности. Таким образом, основополагающий принцип метода бустинга заключается в последовательном применении слабых алгорит-

мов обучения с каждым последующим уменьшением смещения всей модели. Такой алгоритм позволяет преобразовать слабые модели в мощную ансамблевую [19].

Использование моделей МО существенно повышает качество массовой оценки по сравнению с традиционными статистическими моделями на основе линейной регрессии. При этом все три использованные модели дают одинаковую точность аппроксимации исходных данных.

После выбора базового ансамбля моделей был проведен дополнительный анализ результатов, включая проверку на переобучение и интерпретацию значимости используемых признаков (табл. 5).

Приведенные в табл. 5 данные наглядно демонстрируют прогнозы выбранных ансамблей моделей, в частности, среднее значение отношения фактических к прогнозным значениям для классов, содержащих объемы материалов и оборудования (совокупное среднее значение для всех классов, приведенных в табл. 2), составило 0,813 в меньшую сторону и 1,205 в большую сторону (установлено для класса «Арматура»). Вместе с тем среднее значение отношения фактических к прогнозным значениям для общей сметной стоимости строительства объекта составило 0,927 в меньшую сторону и 1,035 в большую сторону. Таким образом, диапазон по-

Табл. 5. Сравнительный анализ результатов работы ансамбля моделей
Table 5. Comparative analysis of the results of the ensemble of models

Номер объекта тестовой выборки The number of the test selection object	Наименование прогнозируемого класса Name of the predicted class	Тестовая выборка Test selection		Значение точности прогноза The value of forecast accuracy	
		Фактическое значение The actual value	Прогнозное значение The predicted value	Отношение фактического к прогнозному значению по каждому объекту The ratio of the actual to the forecast value for each object	Среднее значение отношения фактического к прогнозному значению по каждому объекту The average value of the ratio of the actual to the forecast value for each object
15	Арматура Fittings	2551856	1923616,3	0,85	0,928
13		591533	581380,59	0,98	0,928
09		1721781	1591521,3	0,92	0,928
03		3134300	3475629,2	1,11	1,205
24		951343	1234753,2	1,3	1,205
21		3373092	3111124,4	0,92	0,928
08		3096100	2815636,3	0,91	0,928
04		2473160	2443746,7	0,99	0,928
15	Общая сметная стоимость (в ценах 2000 г.) Total estimated cost (expressed in 2000 prices)	14862660	14579207	0,98	0,927
28		10350570	10753252	1,04	1,035
09		14710230	12101471	0,82	0,927
14		10658730	9955923	0,93	0,927
24		9996520	8755112	0,88	0,927
6		14862660	14579207	0,98	0,927
31		16941090	17369726	1,03	1,035
34		12664580	12249583	0,97	0,927

грешности при определении сметной стоимости составил $\pm 8\%$, что, в свою очередь, (табл. 1) приближено к точности, соответствующей этапу «Рабочая документация».

На основе полученных результатов исследования можно сделать вывод о значительном потенциале применения методов МО в строительной отрасли не только для предсказания потребностей в ресурсах, но и для оптимизации всего процесса строительства. Прежде всего необходимо отметить, что благодаря использованию ансамбля моделей МО, основанного на методе опорных векторов и градиентного бустинга, точность прогнозирования составила $\pm 8\%$, при этом в качестве входных параметров (или параметров, вводимых пользователем для проведения оценки) использовались 11 количественно-качественных входных параметров, описывающих характеристики проектируемого объекта, формирование которых возможно на ранних этапах ЖЦ объекта без разработки проектной и предпроектной документации. Итак, значительно повышается точность (до диапазонов, соответствующих этапу разработки

рабочей документации для объекта строительства) прогнозов общей сметной стоимости, а также появляется возможность прогнозирования с заданной точностью объемов материалов и оборудования на ранних этапах ЖЦ ОС.

Кроме того, фактически появляется вариативность выявления общей сметной стоимости, которую условно можно разделить на два класса — ресурсный и сметный методы определения общей стоимости строительства. Сметный метод предполагает непосредственный прогноз общей сметной стоимости, тогда как ресурсный метод позволяет определять общую сметную стоимость как производный параметр на базе полученного прогноза по объемам материалов и оборудованию.

Наличие прогноза по материалам и оборудованию с приведенной степенью точности позволит сформировать методику принятия управленческих решений на различных этапах ЖЦ объекта, которая может оптимизировать такие процессы, как выбор генеральной подрядной организации, разработка проекта организации строительства, контроль каче-

ства разработки предпроектной и проектной документации.

На основе полученных результатов исследования для прогнозирования потребностей в строительных материалах и оборудовании можно предположить несколько ключевых направлений для дальнейших исследований в данной области:

1. Расширение исходных данных.

Для улучшения точности и обобщаемости моделей МО в строительстве будущие исследования могут включать, с одной стороны, больший объем данных в виде готовых разделов проектной документации по МКД, с другой — более широкий спектр выходных параметров объекта, формирующих объемлющую матрицу параметров (например, введение дополнительных классов по материалам и оборудованию, определение параметров технических присоединений и т.д.), прогнозирование которых позволит качественно улучшить процесс принятия управленческих решений на различных этапах ЖЦ объекта, таких как климатические условия, экономические индикаторы и данные о поставщиках. Интеграция этих сведений может способствовать разработке более надежных прогностических моделей с более высокими диапазонами точности.

2. Рассмотрение других классов функционального назначения объектов строительства.

В проведенном исследовании авторы ограничили область изучения до МКД, однако очевидно, что предложенный подход релевантен и для других типов объектов строительства — общественных, производственных и складских.

3. Автоматизация процессов принятия решений.

Интеграция моделей МО с системами управления проектами может способствовать автоматизации процессов принятия решений, ускоряя планирование и реализацию строительных проектов.

ЗАКЛЮЧЕНИЕ

Рассмотрены существующие модели МО, на основе сравнения результатов работы моделей выбраны оптимальные для прогнозирования выходных параметров объекта строительства (объем материалов и оборудования, необходимых для строительства объектов, а также общая сметная стоимость) на базе значимых входных параметров (количественно-качественные показатели, описывающие характеристики объекта) — ансамбли модели, основанные на методах опорных векторов и градиентного бустинга. Представлено заключение о точности работы модели, находящейся в диапазоне $\pm 8\%$, что соответствует этапу «Рабочая документация».

Приведен вывод о перспективности применения указанной модели для повышения точности прогнозов и оптимизации принятия управленческих решений на ранних этапах ЖЦ ОС. Кроме того, сделано предположение о возможности формирования методики принятия управленческих решений на различных этапах ЖЦ объекта, оптимизирующей такие процессы, как выбор генеральной подрядной организации, разработка проекта организации строительства, контроль качества разработки предпроектной и проектной документации.

СПИСОК ИСТОЧНИКОВ

1. Секушин С.В., Курбацкая Е.П., Петровский А.И. Актуальные вопросы ценообразования и сметного нормирования в строительной отрасли Российской Федерации // Бюллетень ученого совета АО «ИЭРТ». 2022. № 7. С. 40–45. EDN CFMOZV.

2. Сорокин И.В., Настычук А.В. Анализ опыта применения методов машинного обучения в строительной отрасли России // Строительство и архитектура. 2023. Т. 11. № 1. С. 18. DOI: 10.29039/2308-0191-2022-11-1-18-18. EDN WEOBBP.

3. Петровский А.И., Капустина Н.В. Взаимосвязь точности оценки стоимости строительства и экономической эффективности инвестиционно-строительных проектов // Государственное и муниципальное управление. Ученые записки. 2021. № 1. С. 165–169. DOI: 10.22394/2079-1690-2021-1-1-165-169. EDN FVZTTT.

4. Петроченко М.В., Недвига П.Н., Кукина А.А., Шерстюк В.В. Классификация строительной информации в BIM с использованием алгоритмов искусственного интеллекта // Вестник МГСУ. 2022.

Т. 17. № 11. С. 1537–1550. DOI: 10.22227/1997-0935.2022.11.1537-1550. EDN JFYSSO.

5. Кирьянова Л.В., Сулейманов Н.Ф. Сравнение регрессионных моделей стоимости жилищного строительства в Венгрии, полученных методами машинного обучения // Экономика и предпринимательство. 2023. № 5 (154). С. 636–641. DOI: 10.34925/EIP.2023.154.5.123. EDN HSQACR.

6. Михайлова Е.В., Савина В.В., Савин И.М. Искусственный интеллект как инструмент оптимизации ресурсных графиков // Строительное производство. 2022. № 2. С. 52–56. DOI: 10.54950/26585340_2022_2_52. EDN AODBGs.

7. Колчин В.Н. Специфика применения технологии «искусственного интеллекта» в строительстве // Инновации и инвестиции. 2022. № 3. С. 250–253. EDN JJLECU. EDN JJLECU.

8. Blanco J.L., Fuchs S., Parsons M., Ribeirinho M.J. Artificial intelligence: Construction technology's next frontier // Capital projects & infrastructure. April 2018.

9. Макаров А.Н., Гуреев М.В. Определение параметров модели прогнозирования материальных ресур-

сов для строительства жилых зданий на этапе обоснования инвестиций // Строительное производство. 2023. № 4. С. 97–104. DOI: 10.54950/26585340_2023_4_97. EDN XELYIL.

10. Низамов И.В., Еловенко Д.А. Обзор технологий AutoML, имеющихся инструментов, пример применения и сравнительный анализ с классическим решением // Молодежный вестник ИрГТУ. 2022. Т. 12. № 3. С. 468–475. EDN TMBATS.

11. Добашин А.С., Степанов Г.С., Гоголин И.А., Гаджиев Д.М. Использование математической статистики и программирования для решения практических задач машинного обучения // Актуальные исследования высшей школы 2023 : сб. ст. Междунар. науч.-практ. конф. 2023. С. 229–242. DOI: 10.46916/03052023-2-978-5-00174-965-3. EDN NKBEGI.

12. Саранин З.А. Обзор практики применения методов машинного обучения в экономике энергетики // Молодежная неделя науки Института промышленного менеджмента, экономики и торговли : сб. тр. Всеросс. студ. науч.-учеб. конф. 2023. С. 256–258. EDN OHSVAR.

13. Entezari A., Aslani A., Zahedi R., Noorollahi Y. Artificial intelligence and machine learning in energy systems : a bibliographic perspective // Energy Strategy Reviews. 2023. Vol. 45. P. 101017. DOI: 10.1016/j.esr.2022.101017

14. Ahmad T., Zhu H., Zhang D., Tariq R., Basam A., Ullah F. et al. Energetics Systems and artificial intelligence: applications of industry 4.0 // Energy Reports. 2022. Vol. 8. Pp. 334–361. DOI: 10.1016/j.egy.2021.11.256

15. Сухов А.А., Суханкин А.А. Сравнительный анализ лучших алгоритмов градиентного бустинга:

CATBOOST, XGBOOST, LIGHT GBM. Рекомендации к их применению // Вызовы современности и стратегии развития общества в условиях новой реальности : сб. мат. XXIII Междунар. науч.-практ. конф. 2024. С. 287–293. EDN AKOAVR.

16. Machado M.R., Karray S., de Sousa I.T. Light-GBM: an effective decision tree gradient boosting method to predict customer loyalty in the finance industry // 2019 14th International Conference on Computer Science & Education (ICCSE). 2019. Pp. 1111–1116. DOI: 10.1109/ICCSE.2019.8845529

17. Chen T., Guestrin C. XGBoost // Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. 2016. Pp. 785–794. DOI: 10.1145/2939672.2939785

18. Liu X., Wang T. Application of XGBOOST model on potential 5G mobile users forecast // Lecture Notes in Electrical Engineering. 2023. Pp. 1492–1500. DOI: 10.1007/978-981-19-3387-5_177

19. Острикова А.Л., Селютин В.В. Инновационные технологии массовой оценки жилой недвижимости // Экология. Экономика. Информатика. Серия: Системный анализ и моделирование экономических и экологических систем. 2023. Т. 1. № 8. С. 147–154. DOI: 10.23885/2500-395X-2023-1-8-147-154. EDN PYQMGE.

20. Faisal A., Yigitcanlar T., Kamruzzaman M., Paz A. Mapping two decades of autonomous vehicle research : a systematic scientometric analysis // Journal of Urban Technology. 2020. Vol. 28. Issue 3–4. Pp. 45–74. DOI: 10.1080/10630732.2020.1780868

21. Sari R., Voyvoda E., Lacey-Barnacle M., Karababa E., Topal C., Islambay D. Energy justice: a social sciences and humanities cross-cutting theme report. Cambridge, 2017. DOI: 10.13140/RG.2.2.33861.35043

Поступила в редакцию 19 июня 2024 г.

Принята в доработанном виде 21 июня 2024 г.

Одобрена для публикации 25 сентября 2024 г.

ОБ АВТОРАХ: Михаил Владимирович Гуреев — аспирант кафедры технологий и организации строительного производства; Национальный исследовательский Московский государственный строительный университет (НИУ МГСУ); 129337, г. Москва, Ярославское шоссе, д. 26; SPIN-код: 6188-6750, ORCID: 0009-0002-3069-7614; mvgureev@gmail.com;

Александр Николаевич Макаров — кандидат технических наук, доцент кафедры технологий и организации строительного производства; Национальный исследовательский Московский государственный строительный университет (НИУ МГСУ); 129337, г. Москва, Ярославское шоссе, д. 26; SPIN-код: 2460-1473, ORCID: 0000-0001-8421-1013; anmakarov@yandex.ru.

Вклад авторов:

Гуреев М.В. — концепция исследования, разработка методологии, написание исходного текста и итоговые выводы.

Макаров А.Н. — научное руководство, доработка концепции исследования, развитие методологии, доработка текста и итоговых выводов.

Авторы заявляют об отсутствии конфликта интересов.

REFERENCES

1. Sekushin S.V., Kurbatskaya E.P., Petrovsky A.I. Current issues of price formation and cost estimating in Russian construction industry. *Bulletin of the Scientific Council of JSC "IERT"*. 2022; 7:40-45. EDN CFMOZV. (rus.).
2. Sorokin I., Nastychuk A. Analysis of the experience of applying machine learning methods in the Russian construction industry. *Construction and Architecture*. 2023; 11(1):18. DOI: 10.29039/2308-0191-2022-11-1-18-18. EDN WEOBBP. (rus.).
3. Petrovskiy A.I., Kapustina N.V. Relationship between construction cost estimation accuracy and cost effectiveness of investment and construction projects. *State and Municipal Management. Scholar Notes*. 2021; 1:165-169. DOI: 10.22394/2079-1690-2021-1-1-165-169. EDN FVZTTT. (rus.).
4. Petrochenko M.V., Nedviga P.N., Kukina A.A., Sherstyuk V.V. Classification of information models in BIM using artificial intelligence algorithms. *Vestnik MGSU [Monthly Journal on Construction and Architecture]*. 2022; 17(11):1537-1550. DOI: 10.22227/1997-0935. 2022.11.1537-1550. EDN JFYSSO. (rus.).
5. Kirianova L.V., Suleimanov N.F. Comparison of machine learning regression models of housing costs in Hungary. *Journal of Economy and Entrepreneurship*. 2023; 5(154):636-641. DOI: 10.34925/EIP.2023.154.5.123. EDN HSQACR. (rus.).
6. Mikhailova E.V., Savina V.V., Savin I.M. Artificial intelligence as a tool for optimizing resource schedules. *Construction Production*. 2022; 2:52-56. DOI: 10.54950/26585340_2022_2_52. EDN AODBGS. (rus.).
7. Kolchin V.N. The specifics of the use of "artificial intelligence" technology in construction. *Innovations and Investments*. 2022; 3:250-253. EDN JJLECU. (rus.).
8. Blanco J.L., Fuchs S., Parsons M., Ribeirinho M.J. Artificial intelligence: Construction technology's next frontier. *Capital projects & infrastructure*. April 2018.
9. Makarov A.N., Gureev M.V. Determining the parameters of a model for forecasting material resources for the construction of residential buildings at the investment feasibility assessment stage. *Construction Production*. 2023; 4:97-104. DOI: 10.54950/26585340_2023_4_97. EDN XELYIL. (rus.).
10. Nizamov I.V., Elovenko D.A. Overview of AutoML technology, available tools, application example and comparative analysis with the classic solution. *Young Researchers' Journal of ISTU*. 2022; 12(3):468-475. EDN TMBATS. (rus.).
11. Dobashin A.S., Stepanov G.S., Gogolin I.A., Gadzhiev D.M. Using mathematical statistics and programming to solve practical machine learning problems. *Actual Studies of Higher Education 2023: collection of articles of the International Scientific and Practical Conference*. 2023; 229-242. DOI: 10.46916/03052023-2-978-5-00174-965-3. EDN NKBEGI. (rus.).
12. Saranin Z.A. Review of the practice of applying machine learning methods in energy economics. *Youth Science Week of the Institute of Industrial Management, Economics and Trade : proceedings of the All-Russian Student Scientific and educational conference*. 2023; 256-258. EDN OHSVAR. (rus.).
13. Entezari A., Aslani A., Zahedi R., Noorollahi Y. Artificial intelligence and machine learning in energy systems : a bibliographic perspective. *Energy Strategy Reviews*. 2023; 45:101017. DOI: 10.1016/j.esr.2022.101017
14. Ahmad T., Zhu H., Zhang D., Tariq R., Basam A., Ullah F. et al. *Energetics Systems and artificial intelligence: applications of industry 4.0. Energy Reports*. 2022; 8:334-361. DOI: 10.1016/j.egyr.2021.11.256
15. Sukhov A.A., Sukhankin A.A. Comparative analysis of the best gradient boosting algorithms: CATBOOST, XGBOOST, LIGHT GBM. Recommendations for their application. *Challenges of modernity and strategies for the development of society in a new reality : collection of materials of the XXIII International Scientific and Practical Conference*. 2024; 287-293. EDN AKOAVR. (rus.).
16. Machado M.R., Karray S., de Sousa I.T. Light-GBM: an effective decision tree gradient boosting method to predict customer loyalty in the finance industry. *2019 14th International Conference on Computer Science & Education (ICCSE)*. 2019; 1111-1116. DOI: 10.1109/ICCSE.2019.8845529
17. Chen T., Guestrin C. XGBoost. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. 2016; 785-794. DOI: 10.1145/2939672.2939785
18. Liu X., Wang T. Application of XGBOOST model on potential 5G mobile users forecast. *Lecture Notes in Electrical Engineering*. 2023; 1492-1500. DOI: 10.1007/978-981-19-3387-5_177
19. Ostrikova A.L., Selyutin V.V. Innovative technologies for mass valuation of residential real estate. *Ecology. Economy. Informatics. System Analysis and Mathematical Modeling of Ecological and Economic Systems*. 2023; 1(8):147-154. DOI: 10.23885/2500-395X-2023-1-8-147-154. EDN PYQMGE. (rus.).
20. Faisal A., Yigitcanlar T., Kamruzzaman M., Paz A. Mapping two decades of autonomous vehicle research : a systematic scientometric analysis. *Journal of Urban Technology*. 2020; 28(3-4):45-74. DOI: 10.1080/10630732.2020.1780868
21. Sari R., Voyvoda E., Lacey-Barnacle M., Karababa E., Topal C., Islambay D. *Energy Justice: A Social Sciences and Humanities Cross-Cutting Theme Report*. Cambridge, 2017. DOI: 10.13140/RG.2.2.33861.35043

Received June 19, 2024.

Adopted in revised form on June 21, 2024.

Approved for publication on September 25, 2024.

B I O N O T E S: **Mikhail V. Gureev** — postgraduate student of the Department of Technologies and Organization of Construction Production; **Moscow State University of Civil Engineering (National Research University) (MGSU)**; 26 Yaroslavskoe shosse, Moscow, 129337, Russian Federation; SPIN-code: 6188-6750, ORCID: 0009-0002-3069-7614; mvgureev@gmail.com;

Aleksandr N. Makarov — Candidate of Technical Sciences, Associate Professor of the Department of Technologies and Organization of Construction Production; **Moscow State University of Civil Engineering (National Research University) (MGSU)**; 26 Yaroslavskoe shosse, Moscow, 129337, Russian Federation; SPIN-code: 2460-1473, ORCID: 0000-0001-8421-1013; anmakarof@yandex.ru.

Contribution of the authors:

Mikhail V. Gureev — research concept, methodology development, writing the source text and final conclusions.

Aleksandr N. Makarov — scientific guidance, revision of the research concept, development of methodology, revision of the text and final conclusions.

The authors declare that there is no conflict of interest.