

exchange of the neck of an underground reservoir with the surrounding soil mass [K opredeleniyu koefficienta teploperedachi pri teploobmene gorlovinny podzemnogo rezervuara s okruzhayushchim gruntovym massivom]. Resource and Energy Efficient Technologies in the Building Complex of the Region. Saratov. 2018. No. 9. Pp. 282–288. (rus)

21. Cristescu T. On a Class of Thermodynamic Process Involved in the Transport and Storage of Liquefied Petroleum Gas. Oil & Gas University of Ploiesti Bulletin. Technical Series. 2010. Vol. 62. No. 3B. Pp. 162–168.

22. Osipova N.N., Grishin B.M. Modeling of operating modes gas composite cylinders. Russian Journal of Building Construction and Architecture. 2021. No. 3 (51). Pp. 63–74. DOI:10.36622/VSTU.2021.51.3.005

23. Osipova N.N., Kulyaev S.G., Orlova U.A. Evaporation capacity of liquefied petroleum gas composite vessels in natural regasification mode. IOP Conference Series: Materials Science and Engineering. 2022. Vol. 272. Pp. 255–262. DOI:10.1007/978-981-16-8759-4\_27.

24. Methodology for calculating the norms of liquefied hydrocarbon gas consumption by the population in the absence of gas meters: Order of the Ministry of Regional Development of the Russian Federation № 340 dated of August 15, 2009 [Metodika rascheta norm potrebleniya szhizhennogo uglevodorodnogo gaza naseleniem pri otsutstvii priborov ucheta gaza: prikaz Ministerstva regional'nogo razvitiya RF ot 15 avgusta 2009 g. № 340]. Collection of Legislation of the Russian Federation. M., 2006. No. 25. Article. 2733. (rus)

#### *Information about the authors*

**Osipova, Nataliya N.** DSc, Assistant professor. E-mail: osnat75@mail.ru. Yuri Gagarin State Technical University of Saratov. Russia, 410054, Saratov, st. Politechnicheskaya, 77.

**Yakovlev, Dmitriy S.** Postgraduate student. E-mail: dimon96@bk.ru. Yuri Gagarin State Technical University of Saratov. Russia, 410054, Saratov, st. Politechnicheskaya, 77.

*Received 26.01.2023*

#### **Для цитирования:**

Осипова Н.Н., Яковлев Д.С. Разработка методических основ по эксплуатации композитных баллонов в коммунально-бытовом обеспечении потребителей газом // Вестник БГТУ им. В.Г. Шухова. 2024. №3. С. 27–37. DOI: 10.34031/2071-7318-2024-9-3-27-37

#### **For citation:**

Osipova N.N., Yakovlev D.S. Development of methodological frameworks for the operation of composite cylinders in municipal gas supply to consumers. Bulletin of BSTU named after V.G. Shukhov. 2024. No. 3. Pp. 27–37. DOI: 10.34031/2071-7318-2024-9-3-27-37

DOI: 10.34031/2071-7318-2024-9-3-38-46

*\*Сулейманова Л.А., Обайди А.А.Х.**Белгородский государственный технологический университет им. В.Г. Шухова**\*E-mail: ludmilasuleimanova@yandex.ru*

## УПРАВЛЕНИЕ ЖИЗНЕННЫМ ЦИКЛОМ ЗДАНИЯ НА ЭТАПЕ ЭКСПЛУАТАЦИИ С ИСПОЛЬЗОВАНИЕМ МОДЕЛЕЙ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ И МАШИННОГО ОБУЧЕНИЯ

**Аннотация.** Применение искусственных нейронных сетей и методов машинного обучения для анализа теплопотерь зданий представляет собой существенную актуальность в современном строительстве. Эти технологии обладают высокой точностью и эффективностью в обработке данных. Искусственные нейронные сети обладают способностью анализа обширных объемов информации и выделения сложных закономерностей, что значительно повышает точность определения теплопотерь в зданиях. В свою очередь, методы машинного обучения позволяют учитывать различные воздействующие факторы, такие как географическое положение и метеорологические условия, внося тем самым существенный вклад в повышение качества аналитических результатов. Такие подходы обеспечивают более достоверные и точные выводы, что является критически важным для эффективного управления энергопотреблением и сокращения тепловых потерь в зданиях. В данной статье авторами проведено исследование тепловых потерь зданий и их прогнозирование на этапе эксплуатации с использованием искусственных нейронных сетей и метода машинного обучения. Методика основана на анализе данных о теплопотерях и их связи с различными параметрами здания. Прогнозирование осуществлялось с использованием искусственных нейронных сетей в программном комплексе Statistica и методом машинного обучения на основе библиотеки scikit-learn. Предлагаемый подход позволяет эффективно управлять энергопотреблением здания, оптимизируя его энергетическую эффективность и улучшая управление жизненным циклом объекта капитального строительства. Результаты демонстрируют высокую точность и сходимость модели с фактическими значениями, а также ее способность к предсказанию эффективности.

**Ключевые слова:** анализ данных, искусственные нейронные сети, оптимизация энергопотребления, прогнозирование, тепловые потери, управление жизненным циклом.

**Введение.** В современном строительстве управление жизненным циклом зданий становится ключевым аспектом, особенно в контексте энергоэффективности. Прогнозирование тепловых потерь на этапе эксплуатации зданий играет важную роль в оптимизации этого управления, что требует не только точного прогнозирования эффективности, но и использования передовых технологий, включая искусственные нейронные сети (ИНС).

Кладка стен из ячеистобетонных блоков представляет собой эффективный метод строительства наружных стен зданий в современной практике архитектуры и строительства. Отличительные черты данного материала, такие как высокие теплофизические характеристики и механическая прочность, открывают перед ним широкие перспективы применения [1–4].

Использование блоков из ячеистого бетона способствует повышению энергоэффективности зданий. Благодаря своей структуре, они обеспечивают высокий уровень теплоизоляции, что позволяет уменьшить теплопотери через стены и снизить энергозатраты на отопление и кондиционирование помещений. Это одно из ключевых

преимуществ, которое делает газобетон востребованным материалом для создания энергоэффективных зданий [5, 6].

Кроме того, блоки из ячеистого бетона отличаются долговечностью и надежностью. Их устойчивость к воздействию различных факторов, таких как влажность, температурные колебания и механические нагрузки, гарантирует длительный срок службы здания, обеспечивая его стабильность и сохранность конструкции на протяжении многих лет эксплуатации [7].

Современные исследования в области строительства активно используют передовые методы анализа для прогнозирования тепловых потерь через стены из газобетона. ИНС становятся важным инструментом в этом процессе, позволяя улучшить точность прогнозов за счет уникальных характеристик и теплоизоляционных свойств этого строительного материала. Такие современные подходы в анализе данных способствуют оптимизации энергетической эффективности зданий, построенных из газобетона.

В вариационном ряде выделяют две основные категории признаков: средние значения и меры вариации (или рассеяния) [8–10]. Среднее арифметическое представляет собой количественную характеристику однородной группы

данных, определяя обобщенные размеры количественных признаков. Основными показателями средних значений являются среднее арифметическое, мода и медиана.

Среднее арифметическое ( $x$ ) вычисляется по формуле:

$$x = \frac{\sum_{i=1}^n x_i}{n}, \quad (1)$$

где  $x_i$  – значения признака с порядковым номером  $i$  ( $i = 1, n$ );  $n$  – объем данных.

Мода (Мо) – это значение, которое наиболее часто встречается в наборе данных. Медиана (Ме) представляет собой значение, расположенное посередине вариационного ряда. Для нечетного числа вариантов ( $n = 2m + 1$ ) это значение будет таким:  $x_{m+1}$ , для четного ( $n = 2m$ ) – среднее между  $x_m$  и  $x_{m+1}$ .

Медиана широко применяется при анализе неравномерных распределений данных и менее чувствительна к выбросам по сравнению со средним арифметическим. Это делает ее более достоверной мерой центральной тенденции в данных, особенно в случае ассиметричных распределений.

Хотя средние значения дают общую картину о статистической группе, они не отражают, насколько точно они описывают это собрание данных.

Для измерения вариации значений признака используются другие показатели: размах вариации, дисперсия и среднее квадратичное отклонение.

Размах вариации (R) определяется как разница между максимальным ( $x_{max}$ ) и минимальным ( $x_{min}$ ) значениями признака по формуле:

$$R = x_{max} - x_{min}, \quad (2)$$

Другие метрики, такие как дисперсия ( $\sigma^2$ ) и среднее квадратичное отклонение ( $\sigma$ ), вычисляются на основе отклонений всех значений признака от его среднего значения. Дисперсия измеряет абсолютный разброс значений относительно среднего значения, представляя средний квадрат отклонений. Среднее квадратичное отклонение выражает меру вариации в тех же единицах, что и сам признак, и представляет собой корень из дисперсии

$$\sigma = \sqrt{\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n}}, \quad (3)$$

где  $x_i$  – варианта с порядковым номером  $i$ ;  $\bar{x}$  – средняя арифметическая;  $n$  – объем совокупности.

При сравнении вариации признака между группами объектов или внутри одной группы в

разные периоды, полезны относительные показатели, такие как коэффициент вариации. Он представляет отношение среднее квадратичное отклонения к средней арифметической, выраженное в процентах:

$$V = \frac{\sigma}{x} \cdot 100\%. \quad (4)$$

Форма распределения данных, соответствующая нормальному распределению, определяется двумя параметрами: средним значением  $x$  и стандартным отклонением  $\sigma$ . Уравнение, описывающее кривую нормального распределения, представлено следующим образом:

$$y = \frac{e^{-\frac{t^2}{2}}}{\sqrt{2\pi}}, \quad (5)$$

где  $t$  – нормализованное отклонение данных от среднего значения.

Основное свойство кривой нормального распределения заключается в том, что расстояние на горизонтальной оси распределения, измеренное в единицах стандартного отклонения от среднего значения, всегда остается постоянным. Это позволяет оценить долю данных в генеральной совокупности с соответствующими параметрами (рис. 1) [8].

Также в качестве инструмента для анализа для прогнозирования тепловых потерь через стены из газобетона возможно использование модели машинного обучения, например, на основе библиотеки scikit-learn, как наиболее доступная для использования и вариации исходных факторов. Scikit-learn – это библиотека машинного обучения для языка программирования Python. Модель машинного обучения, использующая библиотеку scikit-learn, проходит через несколько ключевых этапов. Первым шагом является выбор подходящей модели, что зависит от конкретного типа задачи, будь то классификация или регрессия, а также от особенностей данных. Scikit-learn предоставляет широкий спектр алгоритмов, включая Support Vector Machines, Random Forest, Decision Trees и другие [11–13].

Второй этап – подготовка данных. В этом контексте необходимо обеспечить, чтобы данные были представлены в формате, наиболее подходящем для обучения модели. Это может включать в себя масштабирование, кодирование категориальных переменных и обработку пропущенных значений.

После этого происходит обучение модели на тренировочных данных. С использованием методов, предоставляемых scikit-learn, модель приспособляется к данным и настраивает свои параметры.

Затем модель тестируется на отложенных тестовых данных для оценки ее производительности и обобщающей способности. В случае необходимости можно произвести настройку гиперпараметров для улучшения результатов [14, 15].

Наконец, обученная модель готова к использованию для прогнозирования или классификации новых данных в соответствии с задачей, для которой она была разработана.




Рис. 1. Вид кривой нормального распределения

**Материалы и методы.** В рамках исследования проведено прогнозирование тепловых потерь здания с наружными стенами из газобетонных блоков площадью 18 м<sup>2</sup> с использованием ИНС для г. Белгород (Россия). Прогнозирование осуществлялось с использованием ИНС в программном комплексе Statistica. В качестве исходных данных были приняты следующие показатели: теплопроводность конструкции – 0,141 Вт/(м·°С); приведенное сопротивление теплопередаче конструкции – 1,897 (м·°С)/Вт; толщина стены – 300 мм; ориентация конструкции – север-

ная. Тепловые потери через ограждающие конструкции определяются исходя из температуры наружного воздуха (рис. 2) по формуле:

$$Q = \frac{k \cdot A (T_{вн} - T_{нар})}{d}, \tag{6}$$

где  $Q$  – количество тепла, проходящего через стену за определенное время, Вт;  $k$  – коэффициент теплопроводности материала стены, Вт/(м<sup>2</sup>·°С);  $A$  – площадь стены, м<sup>2</sup>;  $T_{вн}$  – температура внутренней поверхности стены, °С;  $T_{нар}$  – температура наружной поверхности стены, °С;  $d$  – толщина стены.




Рис. 2. Температура наружного воздуха в г. Белгород (2022 г.)

В качестве модели машинного обучения использовалась модель на основе библиотеки `scikit-learn`, элементы которой представлены в табл. 1.

**Основная часть.** При обучении ИНС использовался метод многократных подвыборок с 5 нейронными сетями при построении (рис. 3, а). Число нейронов на внутреннем слое сети было принято от 10 до 25 (табл. 2), циклов построения – 2 000 (рис. 3, б).

Анализируя ошибки и производительности на выборках для полученного набора сетей (табл. 2), делаем вывод, что из всей выборки на тесте

для города Белгорода наиболее оптимальной является сеть 13 с 15 нейронами на внутреннем слое сети с наименьшей ошибкой на тренировке (0,990) и на тесте (0,897).

Правильность выбора данных сетей подтверждается высокой сходимостью с фактическими значениями на графике прогнозов временных рядов для данной сети как с выборкой тренировки, теста, валидации (рис. 4), где синим цветом – фактические значения, красным – данные, прогнозируемые сетью.

Таблица 1

**Элементы модели машинного обучения на основе библиотеки `scikit-learn`**

Назначение	Элемент модели
	<pre>from sklearn.model_selection import train_test_split from sklearn.linear_model import LinearRegression from sklearn.metrics import mean_squared_error import pandas as pd</pre>
Загрузка данных из отдельных файлов CSV для каждого показателя	<pre>'Теплопроводность_конструкции': 'путь_к_файлу_теплопроводность.csv', 'Приведенное_сопротивление_теплопередаче': 'путь_к_файлу_сопротивление.csv', 'Теплопотери_через_ограждающие_конструкции': 'путь_к_файлу_теплопотери.csv', 'Дополнительные_удельные_потери_теплоты_через_стык_j-го_вида': 'путь_к_файлу_потери_через_стык.csv', 'Ориентация_конструкции': 'путь_к_файлу_ориентация.csv', 'Температура_воздуха': 'путь_к_файлу_температура.csv', 'Относительная_влажность': 'путь_к_файлу_влажность.csv',</pre>
Замена названия ключей на фактические названия показателей	<pre>file_paths = { }</pre>
Считывание данных из каждого файла CSV	<pre>data = {} for key, file_path in file_paths.items():     data[key] = pd.read_csv(file_path)</pre>
Объединение данных в один DataFrame по общему идентификатору	<pre>merged_data = data['Теплопроводность_конструкции'] for key in file_paths.keys():     if key != 'Теплопроводность_конструкции':         merged_data = pd.merge(merged_data, data[key], on='ID')</pre>
Разделение на признаки и целевую переменную	<pre>X = merged_data.drop('Тепловые_потери_через_ограждающие_конструкции', axis=1) y = merged_data['Тепловые_потери_через_ограждающие_конструкции']</pre>
Создание обучающего и тестового наборов данных	<pre>X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.2, random_state=42)</pre>
Создание и обучение модели линейной регрессии	<pre>model = LinearRegression() model.fit(X_train, y_train)</pre>
Предсказание на тестовом наборе данных	<pre>y_pred = model.predict(X_test)</pre>
Оценка качества модели	<pre>mse = mean_squared_error(y_test, y_pred) print(f"Среднеквадратичная ошибка: {mse}")</pre>
Использование модели для прогнозирования тепловых потерь для новых данных	<pre>new_data = {     'новый набор данных' }</pre>
	<pre>new_df = pd.DataFrame(new_data) predicted_heat_losses = model.predict(new_df) print(f"Прогноз тепловых потерь для конструкции: {predicted_heat_losses[0]}")</pre>

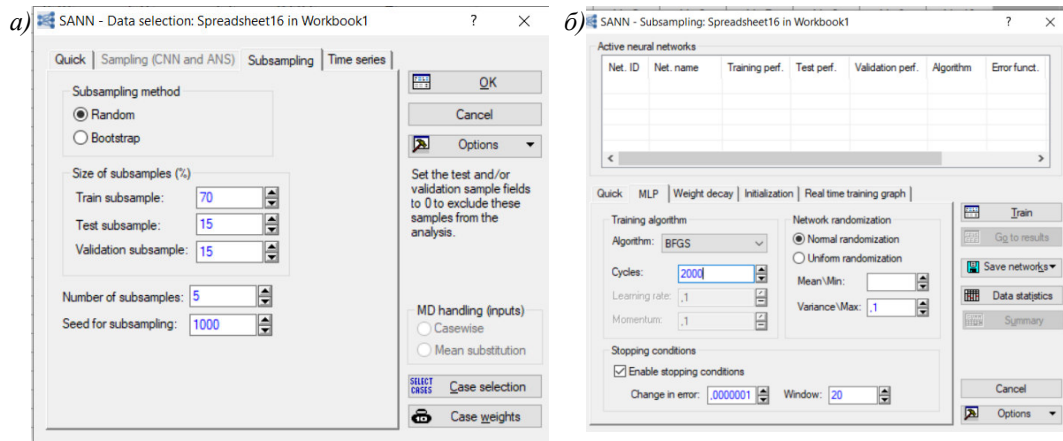


Рис. 3. Создание подвыборок: а – задание количества нейронных сетей при построении; б – задание количества циклов построения

Таблица 2

**Результаты обучения нейронных сетей**

Индекс	Имя	Ошибка на тренировке	Ошибка на тесте	Ошибка на валидации
1	MLP 168-25-1	0,975309	0,939692	0,916330
2	MLP 168-25-1	0,974771	0,909163	0,917442
3	MLP 168-25-1	0,992309	0,896421	0,849101
4	MLP 168-25-1	0,967524	0,910456	0,920615
5	MLP 168-25-1	0,976584	0,919458	0,870481
6	MLP 168-20-1	0,954770	0,938841	0,919451
7	MLP 168-20-1	0,977932	0,904333	0,907534
8	MLP 168-20-1	0,988593	0,896304	0,883655
9	MLP 168-20-1	0,981821	0,906755	0,903165
10	MLP 168-20-1	0,979376	0,930609	0,879652
11	MLP 168-15-1	0,960189	0,935911	0,921713
12	MLP 168-15-1	0,976658	0,906108	0,913985
13	MLP 168-15-1	0,990239	0,897884	0,879350
14	MLP 168-15-1	0,969767	0,911645	0,916526
15	MLP 168-15-1	0,979235	0,925683	0,894693
16	MLP 168-10-1	0,950672	0,940617	0,914498
17	MLP 168-10-1	0,936904	0,902839	0,908218
18	MLP 168-10-1	0,988885	0,898756	0,875421
19	MLP 168-10-1	0,980602	0,906507	0,923584
20	MLP 168-10-1	0,978299	0,915976	0,860043




Рис. 4. График прогнозов временных рядов для сети с выборкой тренировки, теста и валидации

Гистограмма остатков (рис. 5) соответствует нормальному закону распределения Гаусса – Лапласа с пиком в центре и относительно симметричными боковыми сторонами (рис. 1).

Фактическая функция соответствует прогнозной, что подтверждается высокой плотностью точек на прямой (рис. 6). Полученная регрессионная модель допускает ошибку около 1,22%.

Результат обучения модели машинного обучения представлен на рис. 7. После применения модели машинного обучения получено низкое значение среднеквадратичной ошибки (до 1,8), что указывает на высокую точность модели в предсказании энергоэффективности конструкций.




Рис. 5. Гистограмма остатков временного ряда с выборкой тренировки, теста и валидации




Рис. 6. Диаграмма рассеяния для сети с выборкой тренировки, теста и валидации




Рис. 7. График предсказания модели машинного обучения и ИНС для данных по г. Белгород: — расчетные значения; — прогноз ИНС; — прогноз машинного обучения

Кроме того, результаты предсказаний логически сходятся с известными факторами влияния на энергоэффективность, такими как климатические условия и другие показатели, что также подтверждается большой сходимостью результатов с нейросетевым прогнозированием.

**Выводы.** Таким образом, исследования показали, что использование нейросетевых моделей способствует улучшению точности прогнозов и оптимизации энергетической эффективности зданий, возведенных из газобетонных материалов. Использование ИНС позволяет более точно предсказывать тепловые потери через такие стены, что существенно важно для улучшения управления энергопотреблением зданий в различных климатических условиях.

Нейросетевые технологии демонстрируют свою эффективность не только в обеспечении точности прогнозов, но и в способности адаптироваться к изменяющимся условиям и динамике процессов. Этот подход не только содействует оперативному управлению ресурсами и оборудованием, но и обеспечивает более долгосрочное и устойчивое функционирование объектов. Таким образом, внедрение и использование искусственных нейронных сетей в прогнозировании на стадии эксплуатации становится ключевым аспектом повышения эффективности инженерного управления в области капитального строительства.

Использование модели машинного обучения на основе библиотеки scikit-learn для определения теплопотерь здания представляет высокую актуальность в свете нескольких существенных преимуществ этого подхода. Прежде всего, модели, построенные с использованием данной библиотеки, обладают высокой точностью и способностью обобщения, что особенно ценно в контексте сложных взаимосвязей и закономерностей, характерных для анализа теплопотерь зданий.

Таким образом, использование модели машинного обучения на основе scikit-learn выгодно благодаря ее точности, гибкости в выборе моделей и эффективности обработки данных, что подтверждается высокой сходимостью данных с расчетными показателями.

В заключение следует подчеркнуть, что использование ИНС на стадии эксплуатации объекта капитального строительства открывает новые возможности для управления жизненным циклом проекта. Нейросетевые технологии и модели машинного обучения позволяют спрогнозировать результаты организационно-технологических и конструктивных решений, принятых на стадии проектирования и возведения, уменьшая вероятность человеческих ошибок и оптимизируя использование ресурсов. Эксплуатация

объектов капитального строительства с применением искусственных нейронных сетей и методов машинного обучения становится ключевым фактором в повышении конкурентоспособности проектов и обеспечении их успешного функционирования в долгосрочной перспективе.

## БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Grinfeld G.I. Performance Characteristics of Autoclaved Aerated Concrete with Density 400 kg/cub.m // *Construction of Unique Buildings and Structures*. 2013. No. 5(10). Pp. 28–57.
2. Сулейманова Л.А., Погорелова И.А., Кондрашев К.Р., Сулейманов К.А., Пириев Ю.С. Энергосберегающие газобетоны на композиционных вяжущих // *Вестник БГТУ им. В.Г. Шухова*. 2016. № 4. С. 73–83.
3. Сулейманова Л.А. Управление процессом формирования пористой структуры ячеистых бетонов // *Вестник БГТУ им. В.Г. Шухова*. 2016. № 2. С. 69–76.
4. Peng P.F., Qin X.M., Wu Y.S. Performance Study on Masonries of Different Aerated Concrete Blocks // *Key Engineering Materials*. 2014. No. 633. Pp. 299–302. DOI: <https://doi.org/10.4028/www.scientific.net/KEM.633.299>
5. Harmati N., Jakšić Ž., Vatin N. Energy consumption modelling via heat balance method for energy performance of a building // In: *Procedia Engineering*. 2015. Pp. 786–794. DOI: 10.1016/j.proeng.2015.08.238
6. Stritih U. Heat Transfer Enhancement in Latent Heat Thermal Storage System for Buildings // *Energy and Buildings*. 2003. No. 35(11). Pp. 1097–1104. DOI: 10.1016/j.enbuild.2003.07.001
7. Girault M., Petit D. Identification methods in nonlinear heat conduction. Part II: inverse problem using a reduced model // *Int. Journal of Heat and Mass*. 2005. No. 48(1). Pp. 119–133. DOI: 10.1016/j.ijheatmasstransfer.2004.06.033
8. Богданова Р.А., Казазаева П.И. Первичная оценка статистических данных в программе STATISTICA // *Информация и образование: границы коммуникаций*. 2022. № 14(22). С. 157–162.
9. Камашев В.В., Кучерова Е.А., Раскин П.Н. Выбор оптимальных настроек нейронной сети при прогнозировании временного ряда в пакете статистика // *Молодежь. Наука. Современность: IV Всероссийская научно-практическая конференция с международным участием, Воткинск*. 2017. С. 107–109.
10. Клемина В.И. Софинская Е.Н., Зироян А.А. Анализ временных рядов и прогнозирование на примере программы // *Человеческий капитал*. 2015. № 2(74). С. 66–74.



11. Deo T.Y., Sanju A. Data imputation and comparison of custom ensemble models with existing libraries like XGBoost, CATBoost, AdaBoost and Scikit learn for predictive equipment failure // *Materials Today: Proceedings*. 2023. Vol. 72(3). Pp. 1596–1604. DOI: 10.1016/j.matpr.2022.09.410.

12. Qu C., Houston P.L., Yu Q., Pandey P., Conte R., Nandi A., Bowman J.M. Machine learning software to learn negligible elements of the Hamiltonian matrix // *Artificial Intelligence Chemistry*. 2023. Vol. 1(2). 100025. DOI: 10.1016/j.aichem.2023.100025.

13. Qu, C., Houston, P.L., Yu, Q., Conte, R., Pandey, P., Nandi, A., Bowman, J.M. Machine learning classification can significantly reduce the cost of

calculating the Hamiltonian matrix in CI calculations // *The Journal of Chemical Physics*. 2023. 159(7). 1. DOI: 10.1063/5.0168590

14. Hastie T., Tibshirani R., Friedman J.H. The elements of statistical learning: data mining, inference, and prediction. Springer Series in Statistics: Springer New York. 2009. Vol. 2. 758 p. DOI: 10.1007/BF02985802.

15. Ma Sh., He B., Ge X., Luo X. Spatial prediction of soil salinity based on the Google Earth Engine platform with multitemporal synthetic remote sensing images // *Ecological Informatics*. 2023. Vol. 75. 102111. DOI: 10.1016/j.ecoinf.2023.102111.

*Информация об авторах*

**Сулейманова Людмила Александровна**, доктор технических наук, профессор, заведующий кафедрой строительства и городского хозяйства. E-mail: ludmilasuleymanova@yandex.ru. Белгородский государственный технологический университет им. В.Г. Шухова. Россия, 308012, Белгород, ул. Костюкова, д. 46.

**Обайди Адхам Абдулсаттар Хамид**, исследователь кафедры строительства и городского хозяйства. E-mail: Adkhem@mail.ru. Белгородский государственный технологический университет им. В.Г. Шухова. Россия, 308012, Белгород, ул. Костюкова, д. 46.

*Поступила 19.01.2024 г.*

© Сулейманова Л.А., Обайди А.А.Х., 2024

**\*Suleymanova L.A., Adham A.H.**

*Belgorod State Technological University named after V.G. Shukhov*

*\*E-mail: kloud09@mail.ru*

## BUILDING LIFE CYCLE MANAGEMENT AT THE OPERATION STAGE USING ARTIFICIAL NEURAL NETWORK MODELS AND MACHINE LEARNING

**Abstract.** *The use of artificial neural networks and machine learning methods for the analysis of heat loss in buildings is of significant relevance in modern construction. These technologies are highly accurate and efficient in data processing. Artificial neural networks have the ability to analyze vast amounts of information and identify complex patterns, which significantly increases the accuracy of determining heat loss in buildings. In turn, machine learning methods make it possible to take into account various influencing factors, such as geographic location and meteorological conditions, thereby making a significant contribution to improving the quality of analytical results. Such approaches provide more reliable and accurate conclusions, which is critical for effective energy management and reducing heat loss in buildings. In this article, the authors conducted a study of heat losses of buildings and their prediction at the operational stage using artificial neural networks and machine learning methods. The technique is based on the analysis of data on heat loss and their relationship with various building parameters. Forecasting was carried out using artificial neural networks in the Statistica software package and the machine learning method based on the scikit-learn library. The proposed approach allows you to effectively manage the energy consumption of a building, optimizing its energy efficiency and improving the life cycle management of a capital construction project. The results demonstrate the high accuracy and convergence of the model with actual values, as well as its ability to predict performance.*

**Keywords:** *data analysis, artificial neural networks, energy consumption optimization, forecasting, heat losses, life cycle management.*

### REFERENCES

1. Grinfeld G.I. Performance Characteristics of Autoclaved Aerated Concrete with Density 400 kg/cub.m. Construction of Unique Buildings and Structures. 2013. No. 5(10). Pp. 28–57.

2. Suleymanova L.A., Pogorelova I.A., Kondrashev K.R., Suleymanov K.A., Piriev Yu.S. Energy-saving aerated concrete with composite binders [Energoberegayushchie gazobetonny na kompozitsionnyh vyazhushchih]. Bulletin of BSTU named after V.G. Shukhov. 2016. No. 4. Pp. 73–83. (rus)

3. Suleymanova L.A. Control of the process of formation of the porous structure of cellular concrete [Upravlenie processom formirovaniya poristoj struktury yacheistyh betonov]. Bulletin of BSTU named after. V.G. Shukhov. 2016. No. 2. Pp. 69–76. (rus)
4. Peng P.F., Qin X.M., Wu Y.S. Performance Study on Masonries of Different Aerated Concrete Blocks. Key Engineering Materials. 2014. No. 633. Pp. 299–302. DOI: 10.4028/www.scientific.net/KEM.633.299
5. Harmati N., Jakšić Ž., Vatin N. Energy consumption modeling via heat balance method for energy performance of a building. In: Procedia Engineering. 2015. Pp. 786–794. DOI: 10.1016/j.proeng.2015.08.238
6. Stritih U. Heat Transfer Enhancement in Latent Heat Thermal Storage System for Buildings. Energy and Buildings. 2003. No. 35(11). Pp. 1097–1104. DOI: 10.1016/j.enbuild.2003.07.001
7. Girault M., Petit D. Identification methods in nonlinear heat conduction. Part II: inverse problem using a reduced model. Int. Journal of Heat and Mass. 2005. No. 48(1). Pp. 119–133. DOI: 10.1016/j.ijheatmasstransfer.2004.06.033
8. Bogdanova R.A., Kazazaeva P.I. Primary assessment of statistical data in the STATISTICA program [Pervichnaya ocenka statisticheskikh dannyh v programme STATISTICA]. Information and education: boundaries of communications. 2022. No. 14(22). Pp. 157–162. (rus)
9. Kamashev V.V., Kucherova E.A., Raskin P.N. Selection of optimal settings for a neural network when forecasting a time series in the statistics package [Vybor optimal'nyh nastroek nejronnoj seti pri prognozirovanii vremennogo ryada v pakete statistika]. Youth. The science. Modernity: IV All-Russian scientific and practical conference with international participation, Votkinsk. 2017. Pp. 107–109. (rus)
10. Klenina V.I. Sofinskaya E.N., Ziroyan A.A. Time series analysis and forecasting using the example of a program [Analiz vremennyh ryadov i prognozirovanie na primere programmy]. Human capital. 2015. No. 2(74). Pp. 66–74.
11. Deo T.Y., Sanju A. Data imputation and comparison of custom ensemble models with existing libraries like XGBoost, CATBoost, AdaBoost and Scikit learn for predictive equipment failure. Materials Today: Proceedings. 2023. Vol. 72(3). Pp. 1596–1604. DOI: 10.1016/j.matpr.2022.09.410.
12. Qu C., Houston P.L., Yu Q., Pandey P., Conte R., Nandi A., Bowman J.M. Machine learning software to learn negligible elements of the Hamiltonian matrix. Artificial Intelligence Chemistry. 2023. Vol. 1(2). 100025. DOI: 10.1016/j.aichem.2023.100025.
13. Qu C., Houston P.L., Yu Q., Conte R., Pandey P., Nandi A., Bowman J.M. Machine learning classification can significantly reduce the cost of calculating the Hamiltonian matrix in CI calculations. The Journal of Chemical Physics. 2023. 159(7). 1. DOI: 10.1063/5.0168590
14. Hastie T., Tibshirani R., Friedman J.H. The elements of statistical learning: data mining, inference, and prediction. Springer Series in Statistics: Springer New York. 2009. Vol. 2. 758 p. DOI: 10.1007/BF02985802.
15. Ma Sh., He B., Ge X., Luo X. Spatial prediction of soil salinity based on the Google Earth Engine platform with multitemporal synthetic remote sensing images. Ecological Informatics. 2023. Vol. 75. 102111. DOI: 10.1016/j.ecoinf.2023.102111.

#### Information about the authors

**Suleymanova, Lyudmila A.** DSc, Professor, Head of the Department of Construction and Urban Economy. E-mail: ludmilasuleimanova@yandex.ru. Belgorod State Technological University V.G. Shukhov. Russia, 308012, Belgorod, st. Kostyukova, 46.

**Obaidi Adham Abdulsattar Hameed.** Researcher, Department of Civil Engineering and Urban Development. E-mail: Adkhem@mail.ru. Belgorod State Technological University V.G. Shukhov. Russia, 308012, Belgorod, st. Kostyukova, 46.

Received 19.01.2024

#### Для цитирования:

Сулейманова Л.А., Обайди А.А.Х. Управление жизненным циклом здания на этапе эксплуатации с использованием моделей искусственных нейронных сетей и машинного обучения // Вестник БГТУ им. В.Г. Шухова. 2024. №3. С. 38–46. DOI: 10.34031/2071-7318-2024-9-3-38-46

#### For citation:

Suleymanova L.A., Adham A.H. Building life cycle management at the operation stage using artificial neural network models and machine learning. Bulletin of BSTU named after V.G. Shukhov. 2024. No. 3. Pp. 38–46. DOI: 10.34031/2071-7318-2024-9-3-38-46