

<https://doi.org/10.21122/1029-7448-2026-69-1-77-94>

УДК 697.343 (004.896)

## Нейронная сеть прогнозирования теплового потребления здания

М. В. Колосов<sup>1)</sup>, А. Ю. Липовка<sup>1)</sup>, Ю. Л. Липовка<sup>1)</sup>

<sup>1)</sup>Сибирский федеральный университет (Красноярск, Российская Федерация)

**Реферат.** Прогнозирование спроса на тепловую энергию необходимо для достижения оптимального управления энергопотреблением здания. Целью данной статьи является выявление важнейших факторов, влияющих на точность прогнозирования теплопотребления зданий с применением нейронных сетей, что соответствует национальной стратегии развития искусственного интеллекта РФ. В статье исследуется зависимость точности моделирования от различных комбинаций параметров окружающей среды, а также от применения разных функций активации нейронных сетей, широко используемых в практике создания систем искусственного интеллекта. Продемонстрировано, что модели машинного обучения, основанные на большом количестве данных о тепловом потреблении, имеют большие возможности в прогнозировании реальных моделей и тенденций потребления, а значение средней абсолютной процентной ошибки лучшей модели прогнозирования сопоставимо с величиной максимального предела допускаемой относительной погрешности измерений тепловой энергии измерительным каналом теплосчетчика. На основе данных, полученных с помощью разработанной системы дистанционного мониторинга индивидуальных тепловых пунктов зданий, продемонстрировано сравнение действительных значений теплового потребления и величин теплового потребления, полученных с использованием модели прогнозирования. Экономия энергии, теплоносителя и прочего на объекте не может быть измерена напрямую, поскольку она представляет собой отсутствие потребления. Поэтому универсальный подход с использованием искусственного интеллекта для технически обоснованного и экономически целесообразного метода прогнозирования результатов применения энергосберегающих решений для сравнения измеренного энергопотребления до и после внедрения энергоэффективного мероприятия может позволить повысить эффективность принятия решений в сфере сбережения энергетических ресурсов.

**Ключевые слова:** энергоэффективность здания, теплоснабжение, отопление зданий, нейросеть, искусственный интеллект, индивидуальный тепловой пункт, компьютерное моделирование, мониторинг теплопотребления

**Для цитирования:** Колосов, М. В. Нейронная сеть прогнозирования теплового потребления здания / М. В. Колосов, А. Ю. Липовка, Ю. Л. Липовка // Энергетика. Изв. высш. учеб. заведений и энерг. объединений СНГ. 2026. Т. 69, № 1. С. 77–94. <https://doi.org/10.21122/1029-7448-2026-69-1-77-94>

## Neural Network for Predicting Building Heat Consumption

М. В. Колосов<sup>1)</sup>, А. Ю. Липовка<sup>1)</sup>, Ю. Л. Липовка<sup>1)</sup>

<sup>1)</sup>Siberian Federal University (Krasnoyarsk, Russian Federation)

**Abstract.** Heat demand forecasting is necessary to achieve optimal management of building energy consumption. The purpose of this article is to identify the most important factors influencing

### Адрес для переписки

Колосов Михаил Викторович  
Сибирский федеральный университет  
просп. Свободный, 79/10,  
660041, Красноярск, Российская Федерация  
Тел.: +375 0000-0003-4884-4889  
MKolosov@sfu-kras.ru

### Address for correspondence

Kolosov Mikhail V.  
Siberian Federal University  
79/10, Svobodny Ave.,  
660041, Krasnoyarsk, Russian Federation  
Tel.: +375 0000-0003-4884-4889  
MKolosov@sfu-kras.ru

the accuracy of forecasting heat consumption of buildings using neural networks, which is in line with the national strategy for the development of artificial intelligence of the Russian Federation. The article studies the dependence of modeling accuracy on various combinations of environmental parameters, as well as on the application of different activation functions of neural networks, widely used in the practice of creating artificial intelligence systems. It is demonstrated that machine learning models based on a large number of data on thermal consumption have great possibilities in predicting real patterns and trends of consumption, and the value of the average absolute percentage error of the best prediction model is comparable to the value of the maximum limit of the tolerable relative error of thermal energy measurements by the measuring channel of the heat meter. On the basis of data obtained using the developed system of remote monitoring of individual heating points of buildings, a comparison of actual values of heat consumption and values of heat consumption obtained using the prediction model was demonstrated. Savings of energy, heat carrier and other things at the object cannot be measured directly, because the savings represent the absence of consumption, so a universal approach using artificial intelligence for a technically sound and economically feasible method of predicting the results of the application of energy-saving solutions to compare the measured energy consumption before and after the implementation of energy-efficient measures may allow to improve the efficiency of decision-making in the field of saving energy resources

**Keywords:** building energy efficiency, heat supply, building heating, neural network, artificial intelligence, individual heat supply unit, computer modeling, heat consumption monitoring

**For citation:** Kolosov M. V., Lipovka A. Yu., Lipovka Yu. L. (2026) Neural Network for Predicting Building Heat Consumption. *Energetika. Proc. CIS Higher Educ. Inst. and Power Eng. Assoc.* 69 (1), 77–94. <https://doi.org/10.21122/1029-7448-2026-69-1-77-94> (in Russian)

## Введение

В 2019 г. принята Национальная стратегия развития искусственного интеллекта, в которой определяются цели и основные задачи искусственного интеллекта в Российской Федерации, а также меры, направленные на его использование в целях обеспечения национальных интересов и реализации стратегических приоритетов, в том числе в области научно-технологического развития. Интерес к исследованиям на тему искусственного интеллекта привел к появлению огромного количества их вариаций, включая искусственный интеллект, построенный на нейросетевых алгоритмах. В то же время количество публикаций по тематике применения нейронных сетей в системе мониторинга и управления энергоэффективностью отапливаемых зданий весьма ограничено. Одной из задач управления энергоэффективностью является разработка инструментария для оценки эффективности внедрения энергосберегающих решений с использованием моделей прогнозирования энергопотребления.

Обзор особенностей построения моделей прогнозирования теплового спроса зданий представлен в [1]. Модели машинного обучения, основанные на большом количестве данных о нагрузке, продемонстрировали свои большие возможности в прогнозировании реальных моделей и тенденций потребления. Показано, что тепловые нагрузки, температура наружного воздуха и часовой индекс имеют наибольшее влияние и наряду с дополнительным использованием данных по скорости ветра и индексу дня, что улучшает среднеквадратичное отклонение, их следует в первую очередь

учитывать в моделях прогнозирования теплового потребления. И, напротив, включение всех доступных параметров не приводит к достижению более высокой точности прогноза. Представленная в [2] методология сопоставления точности методов, используемых для количественной оценки неопределенности в определении общей экономии энергии, может быть использована для оценки неопределенности в прогнозах экономии, возникающей из-за ошибки модели. Показано, что широко используемые стандартные методы, как правило, недооценивают неопределенность, причем эта тенденция сильнее для часовых моделей, чем для дневных из-за более сильной автокорреляции в остатках модели в часовом масштабе времени. В работе [3] сопоставлены два основных подхода к рассмотрению неопределенностей прогнозов управления моделями зданий. Показана существенная разница в ошибках прогноза для зданий с разными характеристиками ограждающих конструкций: для плохо изолированных зданий и для зданий с высокой степенью изоляции.

Точное краткосрочное прогнозирование спроса на тепловую энергию необходимо для достижения оптимального управления энергопотреблением здания, экономии затрат, экологической устойчивости и ответственного потребления энергии. Кроме того, краткосрочное прогнозирование тепловой энергии способствует достижению нулевого энергопотребления зданий в холодном климате. В [4] оценивались шесть распространенных алгоритмов глубокого обучения для прогнозирования энергетической нагрузки, включая одиночные и гибридные модели. Надежное и точное прогнозирование нагрузки на отопление может предоставить исчерпывающую информацию для мониторинга и управления системами отопления, вентиляции и кондиционирования воздуха в зданиях, что позволяет эффективно снизить неопределенность в отношении потребности в энергии. В [5] продемонстрирован потенциал для прогнозирования нагрузки на отопление с учетом комплексного выбора физических переменных, влияющих на почасовые динамические изменения сезонной нагрузки здания. Результаты [6] подчеркивают важность детального анализа предварительной обработки данных в моделях обучения для точного прогнозирования спроса на потребление энергии в реальных условиях. Модели машинного обучения могут улучшить производительность систем теплоснабжения, точно прогнозируя потребление энергии зданием и использование нагрузки [7]. В [8] представлен прогноз потребления тепловой энергии на основе реальных данных интеллектуального учета теплоты с учетом возможностей нейронных сетей. Точное прогнозирование энергопотребления здания имеет решающее значение для рационального проектирования энергосистем зданий [9]. В [10] обсуждаются технические решения, способствующие интеграции электрических и тепловых сетей, а в [11] показано наличие потенциала экономии энергии за счет оптимизации параметров теплопотребляющих систем для различных географических регионов.

Известно, что принцип работы нейросети – механизма обработки информации сводится к тому, что активации в одном слое приводят к активи-

циям в следующем слое, и, наконец, какой-то шаблон активаций в финальном слое – это выбор нейросети. Вместе с тем алгоритм обучения нейронных сетей недостаточно освещен в работах.

Целью статьи является выявление важнейших факторов, влияющих на точность прогнозирования теплопотребления зданий с применением нейронных сетей и активного дистанционного компьютерного мониторинга, оценивающего и, возможно, в будущем корректирующего механизма управления энергоэффективностью зданий.

### **Основная часть**

Существует множество потенциальных интеллектуальных задач, которые разбиваются на слои абстракции (пример – разбор речи, распознавание рукописей), но все они сводятся к получению сырого исходного материала и последующему выделению отдельных параметров, которые комбинируются для образования абстрактных мыслей и т. д. В нашем случае в качестве исходного материала дистанционно на сервер поступают значения тепловых (температур в характерных точках индивидуального теплового пункта здания) и гидравлических (давлений, расходов) параметров, которые впоследствии преобразуются в управленческие действия регулирующих клапанов.

Рассмотрим основные функции активации, широко применяемые в практике создания систем искусственного интеллекта. Активация в нейронах – число от 0 до 1, выражающее, насколько система уверена, что входная информация содержит соответствующую информацию об оптимизируемом параметре энергоэффективности здания.

Переход активаций  $a$  от одного слоя, допустим, исходного – входящего  $a^{(0)}$  к следующему  $a^{(1)}$  представляется в виде выражения

$$a^{(1)} = \sigma(Wa^{(0)} + b),$$

где  $W$  – матрица объединенных весов, каждая строка которой описывает соединения между нейронами одного слоя с конкретным нейроном следующего слоя;  $a$  – вектор-столбец, объединяющий все активации слоя;  $b$  – вектор-столбец сдвигов (смещений).

В качестве сжимающей функции  $\sigma$  может быть использована сигмоидная функция сжатия,  $\sigma(x) = 1 / (1 + e^{-x})$ , или функция выпрямленного линейного модуля  $ReLU(a) = \max(0, a)$ . Значения весов  $W$  и смещений  $b$  необходимо подобрать.

Обучающаяся нейронная сеть, которая по сути является функцией, в нашем случае на входе принимает 11 значений от теплогенератора (температуры и расходы воды) и 13 значений погодных факторов (температура воздуха, скорость ветра, облачность и т. д.), блочно рандомизированных и взаимно синхронизированных по времени.

Разница между фактическим выходом и выходом нейронной сети оценивается с помощью функции стоимости нейронной сети  $C$ , которая равна сумме квадратов различий между промежуточной выходной активацией и желаемым значением, а градиент функции  $\nabla C$  указывает направление наибольшего спуска, – в каком направлении следует сделать шаг, чтобы уменьшить  $C$  быстрее всего, а длина этого вектора-градиента позволяет выявить наиболее крутой склон. То есть алгоритм минимизации функции  $C$  состоит в том, чтобы вычислить направление  $\nabla C$ , затем многократно повторить небольшие шаги вниз. Алгоритм эффективного расчета  $\nabla C$ , являющийся основой обучения нейронной сети, называется обратным распространением ошибки. Этот процесс многократного подталкивания входных данных функции на величину, кратную отрицательному  $\nabla C$ , есть градиентный спуск.

Учитывая, что в задаче управления энергопотреблением некоторые входные параметры теплосчетчика (к примеру, температура воды в подающем трубопроводе) и сами являются функциями климатологических параметров, сложность вычисления функции стоимости кратно возрастает.

Основной алгоритм обучения нашей нейронной сети – это исчисление обратного распространения ошибки. Необходимо оценить степень чувствительности функции стоимости  $C$  одного обучающего примера сети с нейроном последнего слоя с индексом  $L$ , равной квадрату разности последней активации  $a^{(L)}$  и конкретного значения функции  $y$ ,  $C = (a^{(L)} - y)^2$ , где  $a^{(L)} = w^{(L)}a^{(L-1)} + b^{(L)}$  от корректировки переменных: веса  $w^{(L)}$  и смещения  $b^{(L)}$ , т. е. как они приведут к наиболее эффективному уменьшению функции затрат. Преобразуем  $a^{(L)}$  посредством специальной нелинейной функции  $\sigma$  – сигмовидной, или ReLU, тогда после присвоения специального имени  $z^{(L)}$  взвешенной сумме  $w^{(L)}a^{(L-1)} + b^{(L)}$  получим  $a^{(L)} = \sigma(w^{(L)} \cdot a^{(L-1)} + b^{(L)}) = \sigma(z^{(L)})$ .

Небольшие изменения веса, влияющие на стоимость, для конкретного обучающего примера  $k$ :

$$\frac{\partial C_k}{\partial w^{(L)}} = \frac{\partial z^{(L)}}{\partial w^{(L)}} \frac{\partial a^{(L)}}{\partial z^{(L)}} \frac{\partial C_k}{\partial a^{(L)}},$$

$$\frac{\partial C_0}{\partial a^{(L)}} = 2(a^{(L)} - y); \quad \frac{\partial a^{(L)}}{\partial z^{(L)}} = \sigma(z^{(L)}); \quad \frac{\partial z^{(L)}}{\partial w^{(L)}} = a^{(L-1)}.$$

Функция полной стоимости включает в себя усреднение всех затрат по множеству различных обучающих примеров  $k$ , следовательно, и ее производную необходимо усреднить по всем обучающим примерам  $n$

$$\frac{\partial C}{\partial w^{(L)}} = \frac{1}{n} \sum_{k=0}^{n-1} \frac{\partial C_k}{\partial w^{(L)}}.$$

Компонент вектора градиента состоит из частых производных функции стоимости по всем весам и смещениям

$$\nabla C = \begin{bmatrix} \frac{\partial C}{\partial w^{(1)}} \\ \frac{\partial C}{\partial b^{(1)}} \\ \vdots \\ \frac{\partial C}{\partial w^{(L)}} \\ \frac{\partial C}{\partial b^{(L)}} \end{bmatrix}.$$

Исходные данные для моделирования искусственного интеллекта получены в результате пятилетнего мониторинга теплогидравлических режимов тепловых пунктов более чем 250 зданий [12]. Для демонстрации работы данного метода рассмотрена модель теплопотребления одного из этих зданий. В качестве данных для прогнозирования приняты данные отопительной системы здания г. Красноярска с 13.12.2017 по 25.02.2024.

Следующим шагом является выбор подмножества из исходного, чтобы только наиболее важные входные признаки были включены при разработке модели. В избранном подмножестве приняты пять параметров: среднесуточная температура наружного воздуха, °С, относительная влажность, %, скорость ветра, км/ч, облачность, %, и солнечная энергия, МДж/(м<sup>2</sup>·сут.). Рассмотрим, как полученные данные связаны друг с другом. Для этого воспользуемся математической мерой корреляции. Математической мерой корреляции двух случайных величин служит коэффициент корреляции

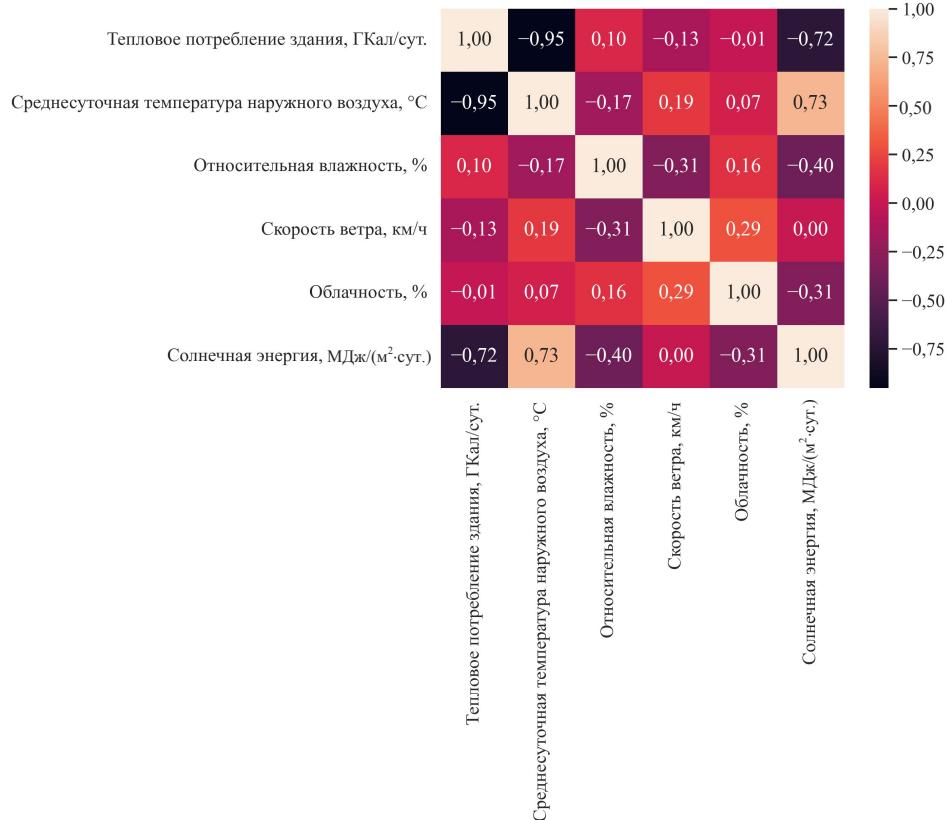
$$r_{xy} = \frac{\sum ((x - \bar{x})(y - \bar{y}))}{\sqrt{\sum (x - \bar{x})^2 \sum (y - \bar{y})^2}}.$$

Полученные значения коэффициентов корреляции параметров модели прогнозирования энергопотребления представлены на рис. 1.

Из рис. 1 видно, что наибольшее абсолютное значение коэффициентов корреляции наблюдается между тепловым потреблением здания, среднесуточной температурой наружного воздуха, а также значением солнечной энергии.

Диаграмма рассеяния, представленная на рис. 2, в удобном виде показывает распределение элементов множества в плоскости и может продемонстрировать зависимость выбранных параметров друг от друга. Особое

внимание следует уделить парам с наибольшим значением коэффициента корреляции.



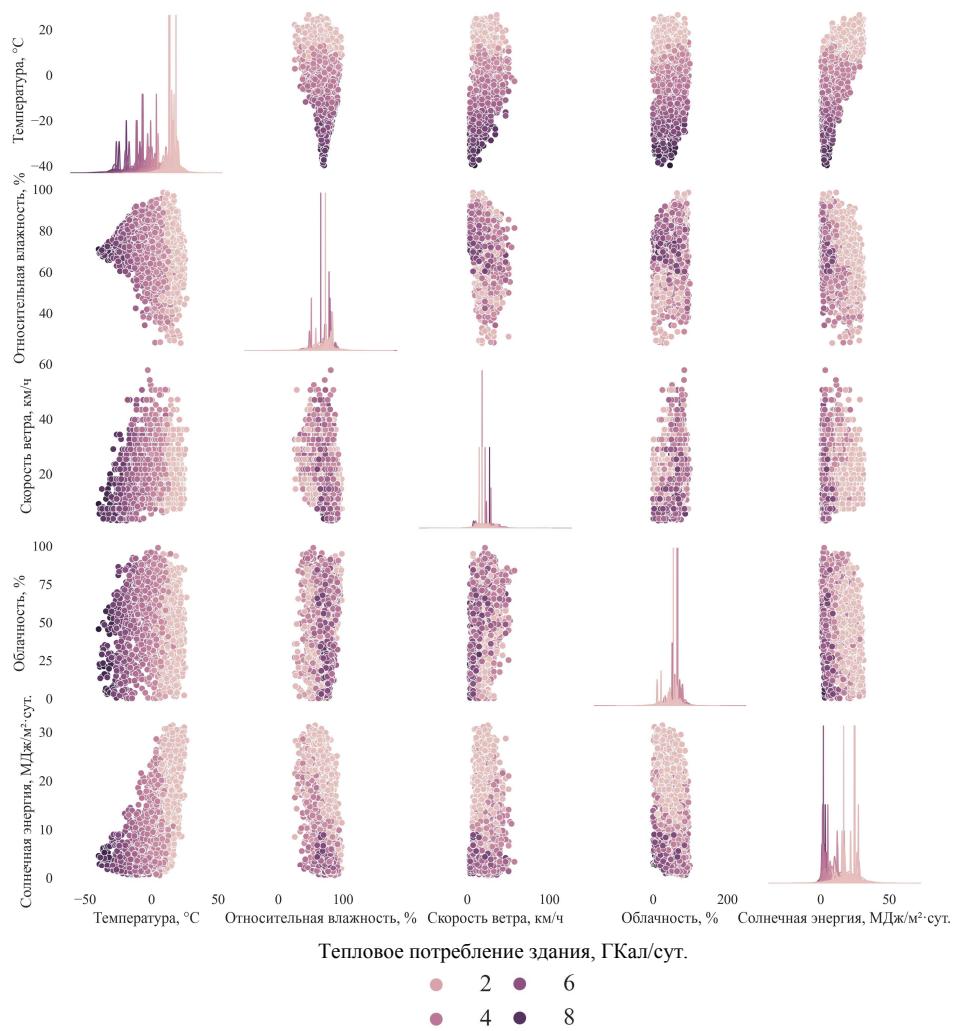
*Rис. 1. Значения коэффициентов корреляции параметров модели прогнозирования энергопотребления*

*Fig. 1. Correlation coefficient values for the energy consumption forecasting model parameters*

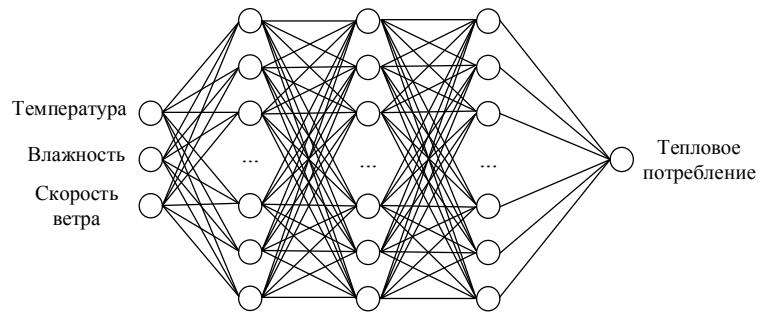
После того как были определены исходные данные, можем перейти к построению нейронной сети. Нейронная сеть для прогнозирования теплового потребления здания была построена с тремя внутренними слоями с количеством нейронов, равным 100 для каждого слоя, с применением функции активации ReLU для каждого слоя. В качестве входных параметров использовались различные комбинации исходных данных. На рис. 3 представлен пример схемы построения нейронной сети прогнозирования теплового потребления здания с тремя входными параметрами.

Для определения лучшей комбинации входных параметров было создано 15 нейронных сетей с различными комбинациями входных параметров, для которых рассчитаны несколько ключевых показателей оценки их эффективности.

Показатели оценки эффективности необходимы для количественного отражения того, насколько точно разработанные модели могут прогнозировать потребленную тепловую энергию.



*Рис. 2. Диаграмма рассеяния параметров модели прогнозирования энергопотребления*  
*Fig. 2. Scatter diagram of the parameters of the energy consumption forecasting model*



*Рис. 3. Пример схемы построения нейронной сети прогнозирования теплового потребления здания*  
*Fig. 3. Example of a neural network for predicting heat consumption of a building*

Поскольку трудно найти один показатель, который бы доминировал над другими по всем параметрам, обычно в типичных задачах статистической регрессии используются несколько показателей для получения более полного представления об эффективности прогноза. Для оценки нейронной сети использованы наиболее часто применяемые показатели оценки эффективности: корень из среднеквадратичной ошибки (*RMSE*), средняя абсолютная процентная ошибка (*MAPE*), средняя абсолютная ошибка (*MAE*), коэффициент вариации среднеквадратичной ошибки (*CV-RMSE*) и коэффициент детерминации (*R*<sup>2</sup>).

Корень из среднеквадратичной ошибки измеряет среднюю разницу между значениями, спрогнозированными моделью прогнозирования, и фактическими значениями:

$$RMSE = \sqrt{\frac{1}{n} \sum (y(x) - a_L)^2}.$$

Чем ниже значение корня средней квадратичной ошибки, тем лучше модель прогнозирования. Корень средней квадратичной ошибки имеет преимущество в том, что представляет величину ошибки в единицах изменения прогнозируемого столбца, что упрощает процесс интерпретации.

Средняя абсолютная процентная ошибка:

$$MAPE = \frac{1}{n} \sum \left| \frac{y(x) - a_L}{y(x)} \right| \cdot 100 \, \%$$

Средняя абсолютная ошибка – среднее абсолютных разностей между целевым значением и значением, предсказанным моделью:

$$MAE = \frac{1}{n} \sum |y(x) - a_L|.$$

В отличие от среднеквадратических ошибок, где используется квадрат разности, средняя абсолютная ошибка является линейной оценкой, поэтому вес разностей одинаков независимо от диапазона.

Коэффициент вариации среднеквадратичной ошибки

$$CV-RMSE = \frac{\sqrt{\frac{1}{n} \sum (y(x) - a_L)^2}}{\frac{1}{n} \sum y(x)} \cdot 100 \, \%$$

Коэффициент детерминации – это доля дисперсии зависимой переменной, объясняемая рассматриваемой моделью зависимости:

$$R^2 = 1 - \frac{\sum (y(x) - a_L)^2}{\sum \left( y(x) - \frac{1}{n} \sum y(x) \right)^2}.$$

При сборе данных с интеллектуальных тепловых счетчиков необходимо всегда учитывать возможность утечки конфиденциальной информации, а также проблем, связанных с сетями передачи данных. Данные, полученные с помощью реальных измерительных устройств, всегда подвержены шуму, выбросам, отсутствующим значениям и дублирующим значениям, поэтому перед использованием полученных данных необходимо произвести процесс очистки. Процесс очистки данных выполняется для того, чтобы сначала обнаружить, а затем интерполировать выявленные пропущенные и аномальные образцы.

Разделение набора данных необходимо для беспристрастной оценки эффективности прогнозирования. Достаточно случайным образом разделить набор данных на тренировочный набор данных, который применяется для обучения модели, а также на набор тестов, который необходим для объективной оценки окончательной модели. Разделение произведено случайным образом в отношении два к одному в пользу тренировочного набора данных.

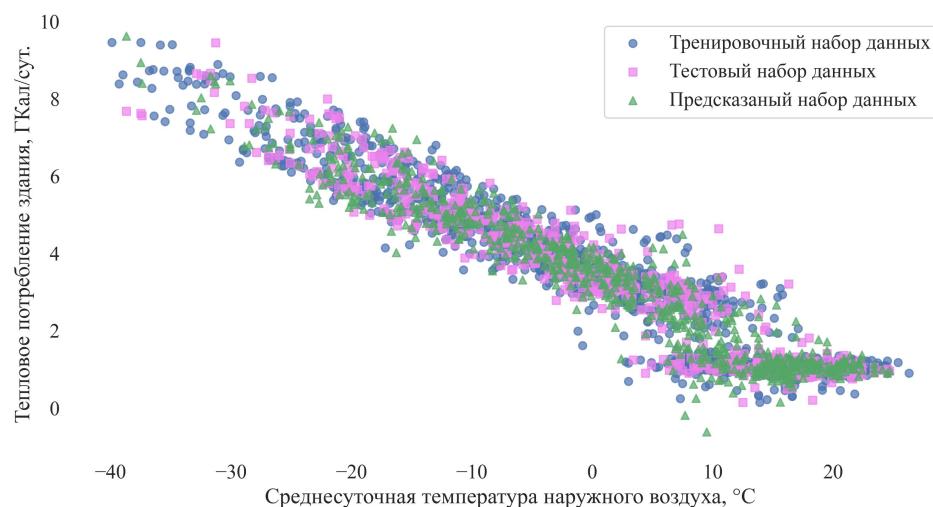
Результаты моделирования сведены в табл. 1, в которой параметры представляют соответственно: среднесуточную температуру наружного воздуха  $T$ , °C, относительную влажность  $H$ , %, скорость ветра  $W$ , км/ч, облачность  $C$ , % и солнечную энергию  $S$ , МДж/(м<sup>2</sup>·сут.). В каждой строке цветом выделены первичные независимые параметры, по которым проводилось моделирование.

**Сравнение точности различных моделей**  
**Comparison of accuracy of various models**

Таблица 1

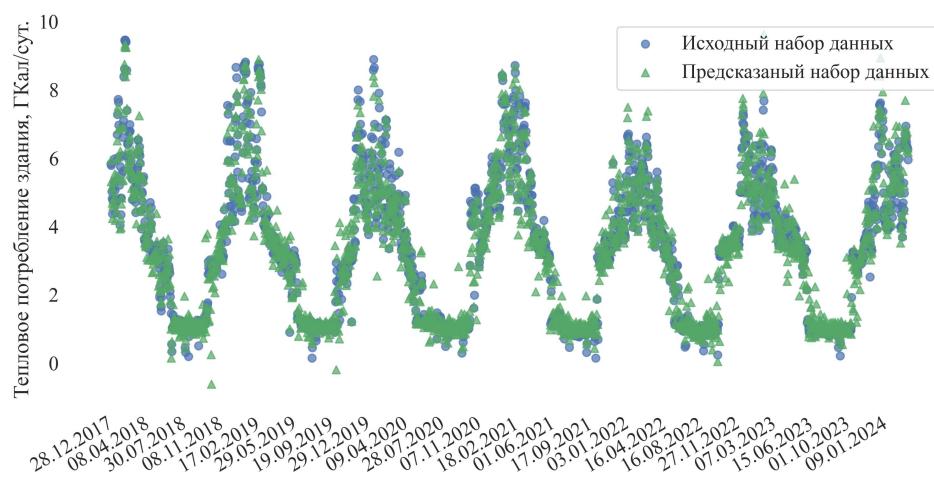
№ п/п	<i>T</i>	<i>H</i>	<i>W</i>	<i>C</i>	<i>S</i>	RMSE	MAPE	MAE	CV-RMSE	<i>R</i> <sup>2</sup>
1						0,578	18,6	0,419	17,45	0,915
2						0,579	17,4	0,404	17,49	0,915
3						0,572	18,9	0,402	17,28	0,917
4						<b>0,571</b>	18,6	<b>0,402</b>	<b>17,27</b>	<b>0,917</b>
5						0,643	19,0	0,438	19,44	0,894
6						0,601	19,4	0,425	18,18	0,908
7						0,576	18,1	0,403	17,40	0,915
8						0,594	<b>17,1</b>	0,407	17,96	0,910
9						0,647	21,0	0,441	19,54	0,893
10						0,599	19,8	0,421	18,09	0,909
11						0,681	21,7	0,469	20,58	0,882
12						0,671	20,4	0,463	20,28	0,885
13						0,690	20,9	0,497	20,84	0,879
14						0,746	24,0	0,506	22,53	0,858
15						0,748	24,6	0,518	22,61	0,857

На рис. 4 изображены тренировочный, тестовый и предсказанный наборы данных, служащие для демонстрации работы нейронной сети прогнозирования теплового потребления здания.



*Рис. 4. Пример результатов предсказания нейронной сети прогнозирования теплового потребления здания*  
*Fig. 4. Example of neural network prediction results for forecasting building heat consumption*

Из рис. 4 видно, что модель прогнозирования учитывает нелинейность в характере распределения данных. Сравнение оригинальных значений и значений, полученных с использованием модели предсказания, на всем временном интервале, показано на рис. 5.

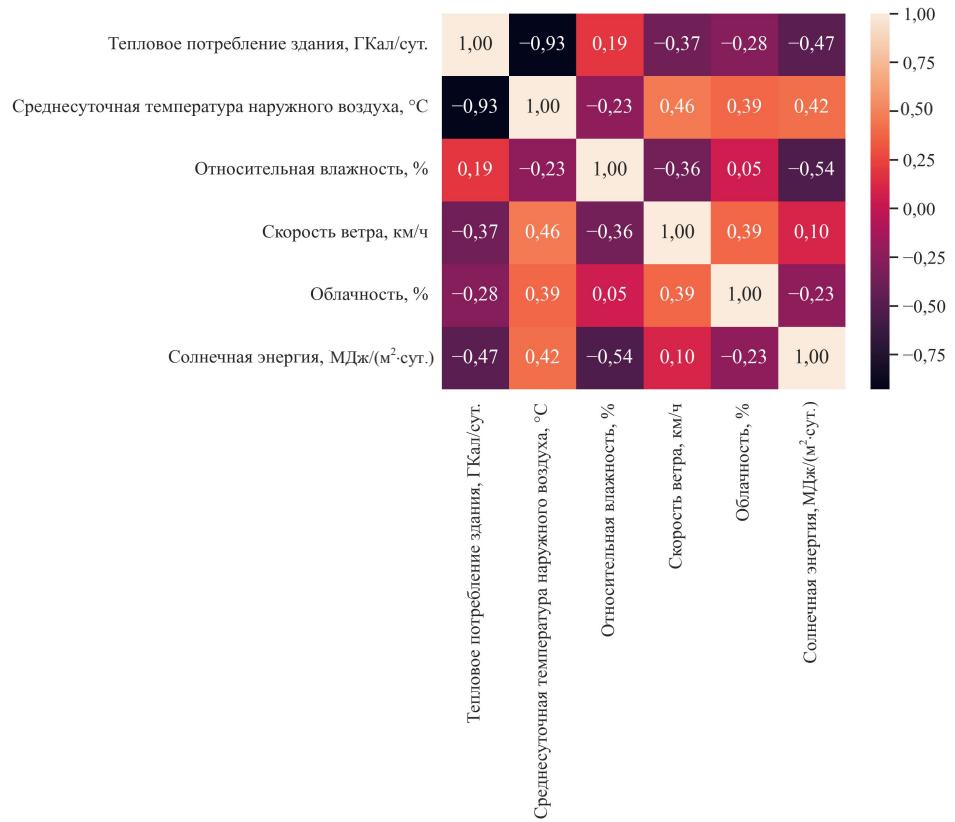


*Рис. 5. Сравнение оригинальных значений и значений, полученных с использованием модели предсказания, на всем временном интервале*  
*Fig. 5. Comparison of original values and values obtained using the prediction model over the entire time interval*

При рассмотрении системы отопления следует отметить, что период ее работы значительно меньше целого года, а значит, модель должна это отражать. Поэтому в качестве исходных данных для модели отберем

только те данные, которые соответствуют периоду отопления здания, и повторим процесс.

Полученные значения коэффициентов корреляции параметров модели прогнозирования энергопотребления за отопительный период представлены на рис. 6.



*Rис. 6. Значения коэффициентов корреляции параметров модели прогнозирования энергопотребления за отопительный период*

*Fig. 6. Values of the correlation coefficients of the parameters of the energy consumption forecasting model for the heating period*

Рис. 6 показывает, что наибольшее абсолютное значение коэффициента корреляции наблюдается между тепловым потреблением здания и среднесуточной температурой наружного воздуха. Значения коэффициентов корреляции между тепловым потреблением здания и остальными параметрами резко возросли, что говорит о том, что в отопительный период изменение данных параметров оказывает более сильное влияние на тепловое потребление здания.

Построим диаграмму рассеяния для данных за отопительный период, представленную на рис. 7.

Как можно видеть из рис. 7, значения относительной влажности скорости ветра и солнечной радиации сходятся к постоянному значению при уменьшении температуры.

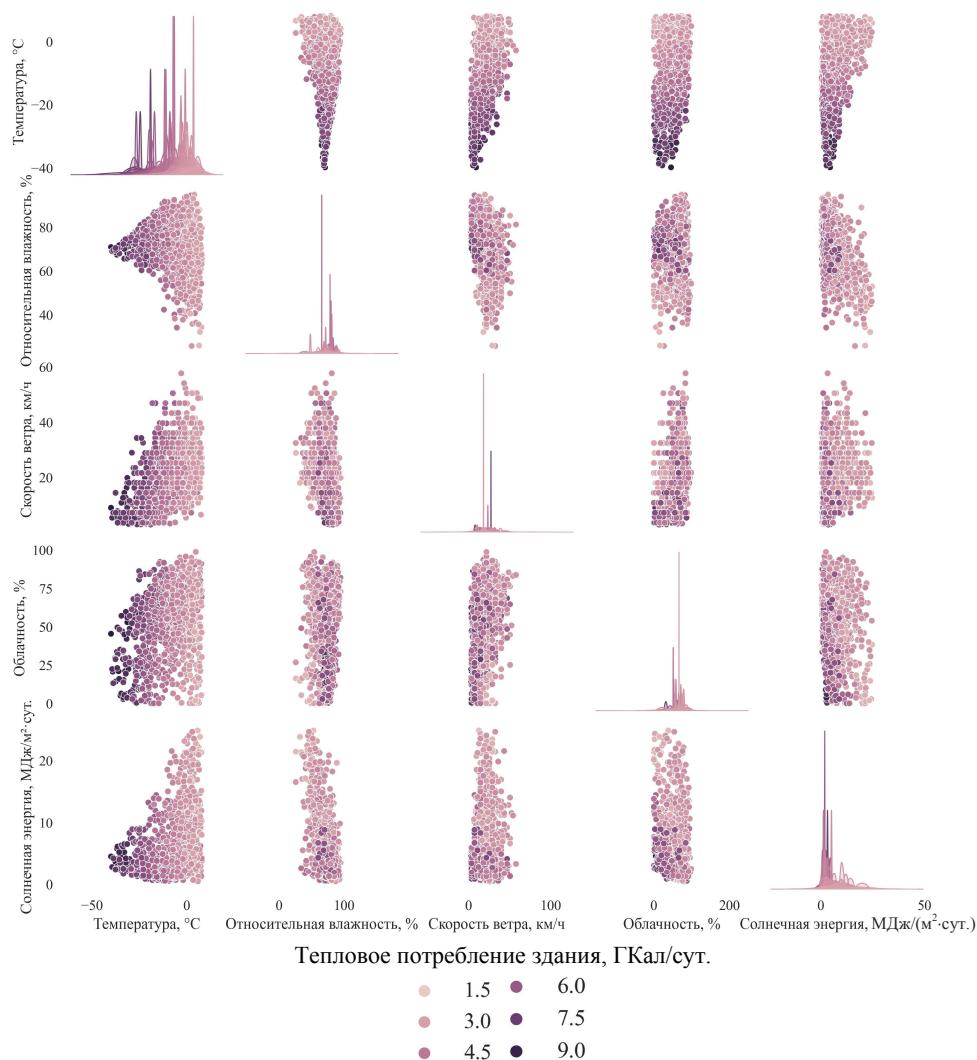


Рис. 7. Диаграмма рассеяния параметров модели прогнозирования энергопотребления за отопительный период

Fig. 7. Scatter diagram of the parameters of the energy consumption forecasting model for the heating period

Проведем моделирование на новой выборке данных, представляющих исключительно отопительный период. В данной модели сети также использовались три промежуточных слоя, но в отличие от предыдущего случая в двух первых слоях вместо функции активации ReLU использовалась функция активации “sigmoid”. Результаты моделирования сведены в табл. 2.

Для демонстрации работы нейронной сети прогнозирования теплового потребления здания изобразим тренировочный, тестовый и предсказанный наборы данных для отопительного периода, как показано на рис. 8.

Таблица 2

**Сравнение точности различных моделей**  
**Comparison of accuracy of various models**

№ п/п	T	H	W	C	S	RMSE	MAPE	MAE	CV-RMSE	R <sup>2</sup>
1						0,535	8,69	0,411	11,33	0,851
2						0,513	8,52	0,400	10,87	0,863
3						0,505	8,30	0,387	10,70	0,867
4						0,512	8,69	0,399	10,84	0,864
5						0,503	8,43	0,392	10,67	0,868
6						0,510	8,41	0,392	10,80	0,865
7						0,522	8,52	0,397	11,06	0,858
8						0,499	8,04	0,383	10,58	0,870
9						0,503	8,02	0,372	10,67	0,868
10						0,506	8,30	0,390	10,72	0,867
11						0,536	8,36	0,402	11,35	0,851
12						0,545	8,61	0,398	11,55	0,845
13						0,540	9,25	0,419	11,44	0,848
14						0,533	8,33	0,389	11,29	0,852
15						0,556	9,27	0,423	11,78	0,839

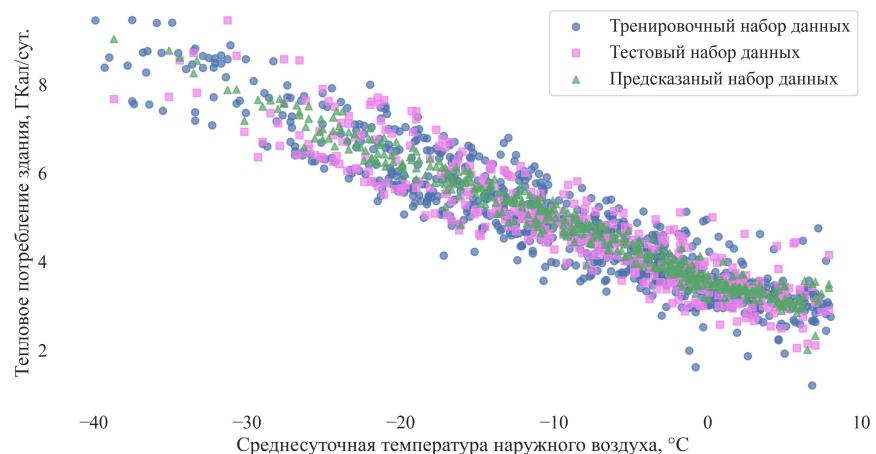


Рис. 8. Пример результатов предсказания нейронной сети  
прогнозирования теплового потребления здания для отопительного периода

Fig. 8. Example of neural network prediction results for forecasting building  
heat consumption for the heating period

Из рис. 8 можно увидеть, что модель прогнозирования также учитывает нелинейность в характере распределения данных. Сравнение оригиналь-

ных значений и значений, полученных с использованием модели предсказания на всем временном интервале, показано на рис. 9.

Чтобы оценить точность моделирования, проведем сравнение средней абсолютной процентной ошибки лучшей модели прогнозирования со значением предела допускаемой относительной погрешности измерений тепловой энергии измерительным каналом теплосчетчика.

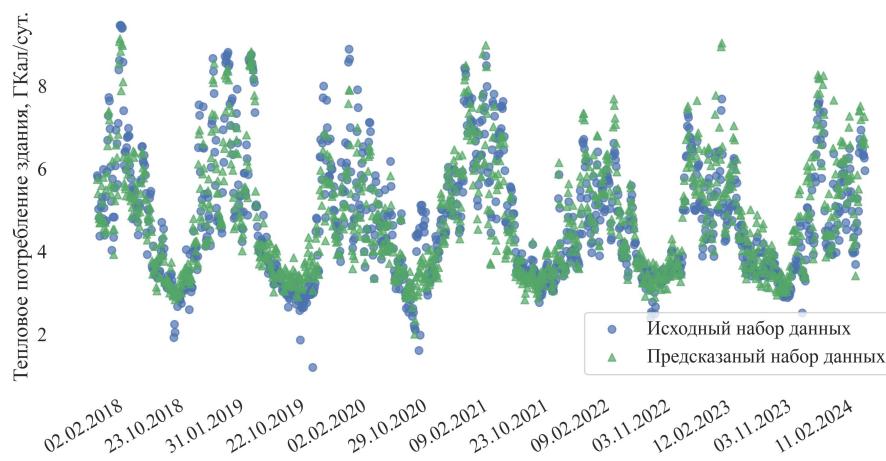


Рис. 9. Сравнение результатов предсказания нейронной сети и исходных данных теплового потребления здания для отопительного периода

Fig. 9. Comparison of neural network prediction results and initial data on building heat consumption for the heating season

Согласно нормативным данным, значение максимального предела допускаемой относительной погрешности измерений тепловой энергии измерительным каналом теплосчетчика составляет 5 %. Значение средней абсолютной процентной ошибки лучшей модели прогнозирования составило примерно 8 %, что сравнимо со значением максимального предела допускаемой относительной погрешности измерений тепловой энергии измерительным каналом теплосчетчика, и может быть использовано для практических целей.

Для исследований, основанных на данных, их объем и качество серьезно влияют на выбор используемых методов и точность получаемых результатов. В последние годы быстро появляются новые алгоритмы машинного обучения, что в будущем может позволить получать точность моделей прогнозирования, стремящуюся к точности реальных приборов измерения тепловой энергии, поэтому разработка процедур обучения, и определения наилучшего набора входных данных, безусловно, заслуживают изучения. Нейронные сети, созданные для различных объектов, могут иметь различный порядок важности входных признаков. Если предполагается прогнозирование с учетом внутренних факторов здания, таких как из-

менение физических характеристик, функций здания, состояния людей и факторов внутренней среды, то оптимальный набор входных характеристик и уровней важности также могут существенно отличаться.

Данные модели прогнозирования обучаются и тестируются на основе реальных исторических погодных данных, зарегистрированных коммунальными предприятиями и метеостанциями. Это означает, что в таких данных нет неопределенности. Для прогнозирования теплового спроса могут быть доступны только данные прогноза погоды, которые, безусловно, содержат ошибки прогнозирования. Следовательно, модели прогнозирования теплового потребления наилучшим образом подходят не для прогнозирования будущего теплового спроса, а для прогнозирования результатов применения энергосберегающих решений.

## ВЫВОДЫ

1. Получены значения коэффициентов корреляции параметров модели прогнозирования энергопотребления, которые позволяют продемонстрировать зависимости выбранных параметров друг от друга, что является необходимым условием ранжирования этих параметров, дающих превалирующий вклад. Установлено, что коэффициенты корреляции между тепловым потреблением здания и климатологическими параметрами, рассчитанные для отопительного периода, значимо превышают аналогичные показатели, полученные по данным за календарный год.
2. Построены модели теплопотребления зданий с использованием искусственного интеллекта по данным, полученным в результате пятилетнего мониторинга теплогидравлических режимов тепловых пунктов зданий г. Красноярска.
3. Произведено сравнение точности моделей с различными наборами входных параметров по нескольким критериям. Показано, что точность лучшей модели прогнозирования сопоставима со значением предела допускаемой относительной погрешности измерений тепловой энергии измерительным каналом теплосчетчика.

## ЛИТЕРАТУРА

1. Wang, C. Role of Input Features in Developing Data-Driven Models for Building Thermal Demand Forecast / C. Wang, X. Li, Hailong Li // Energy & Buildings. 2022. Vol. 277. P. 112593. <https://doi.org/10.1016/j.enbuild.2022.112593>.
2. Evaluation of Methods to Assess the Uncertainty in Estimated Energy Savings / S. Touzani, J. Grandersona, D. Jumpb, D. Rebello // Energy & Buildings. 2019. Vol. 193. P. 216–225. <https://doi.org/10.1016/j.enbuild.2019.03.041>.
3. Langner, F. Model Predictive Control of Distributed Energy Resources in Residential Buildings Considering Forecast Uncertainties / F. Langner, W. Wang, V. Hagenmeyer // Energy & Buildings. 2024. Vol. 303. P. 113753. <https://doi.org/10.1016/j.enbuild.2023.113753>.
4. Comparative Study of Univariate and Multivariate Strategy for Short-Term Forecasting

- of Heat Demand Density: Exploring Single and Hybrid Deep Learning Models / S. Salehi, M. Kavgic, H. Bonakdari, L. Begnoche // Energy and AI. 2024. Vol. 16. P. 100343. <https://doi.org/10.1016/j.egyai.2024.100343>.
5. Building Heating Load |Forecasting Based on the Theory of Transient Heat Transfer and Deep Learning / Z. Shi, R. Zheng, R. Shen [et al.] // Energy and Buildings. 2024. Vol. 313. P. 114290. <https://doi.org/10.1016/j.enbuild.2024.114290>.
6. Forecasting Building Energy Demand and On-Site Power Generation for Residential Buildings Using Long and Short-Term Memory Method with Transfer Learning / D. Kim, G. Seomun, Y. Lee [et al.] // Applied Energy. 2024. Vol. 368. P. 123500. <https://doi.org/10.1016/j.apenergy.2024.123500>.
7. Mohan, R. An Ensemble Model for the Energy Consumption Prediction of Residential Buildings / R. Mohan, N. Pachauri // Energy. 2025. Vol. 314. P. 134255. <https://doi.org/10.1016/j.energy.2024.134255>.
8. A Novel Intelligent Modeling and Prediction of Heat Energy Consumption in Smart Buildings / M. Jayashankara, A. Sharma, A. Kumar Singh [et al.] // Energy and Buildings. 2024. Vol. 310. P. 114105. <https://doi.org/10.1016/j.enbuild.2024.114105>.
9. Application of the Hybrid Neural Network Model for Energy Consumption Prediction of Office Buildings / L. Wang, D. Xie, L. Zhou, Z. Zhang // Journal of Building Engineering. 2023. Vol. 72. P. 106503, <https://doi.org/10.1016/j.jobe.2023.106503>.
10. Седнин, А. В. Энергоэффективность применения гибридных тепловых пунктов в условиях интеграции электрических и тепловых сетей городских микрорайонов. Ч. 1: Обоснование целесообразности применения гибридных тепловых пунктов / А. В. Седнин, М. И. Позднякова // Энергетика. Изв. высш. учеб. заведений и энерг. объединений СНГ. 2023. Т. 66, № 6. С. 552–566. <https://doi.org/10.21122/1029-7448-2023-66-6-552-566>.
11. Моделирование и расчет параметров малой гелиотеплицы с целью повышения энергоэффективности / Г. Н. Узаков, В. А. Седнин, А. Б. Сафаров [и др.] // Энергетика. Изв. высш. учеб. заведений и энерг. объединений СНГ. 2025. Т. 68, № 4. С. 367–384. <https://doi.org/10.21122/1029-7448-2025-68-4-367-384>.
12. Колосов, М. В. Система мониторинга теплопотребления зданий / М. В. Колосов, А. Ю. Липовка, Ю. Л. Липовка // Известия Томского политехнического университета. Инжиниринг георесурсов. 2024. Т. 335, № 7. С. 206–220. <https://doi.org/10.18799/24131830/2024/7/4443>.

Поступила 25.09.2025   Подписана в печать 27.11.2025   Опубликована онлайн 30.01.2026

## REFERENCES

1. Wang C., Li X., Li H. (2022) Role of Input Features in Developing Data-Driven Models for Building Thermal Demand Forecast. *Energy and Buildings*, 277, 112593. <https://doi.org/10.1016/j.enbuild.2022.112593>.
2. Touzani S., Granderson J., Jump D., Rebello D. (2019) Evaluation of Methods to Assess the Uncertainty in Estimated Energy Savings. *Energy and Buildings*, 193, 216–225. <https://doi.org/10.1016/j.enbuild.2019.03.041>.
3. Langner F., Wang W., Frahm M., Hagenmeyer V. (2024) Model Predictive Control of Distributed Energy Resources in Residential Buildings Considering Forecast Uncertainties. *Energy and Buildings*, 303, 113753. <https://doi.org/10.1016/j.enbuild.2023.113753>.
4. Salehi S., Kavgic M., Bonakdari H., Begnoche L. (2024) Comparative Study of univariate and Multivariate Strategy for Short-Term Forecasting of Heat Demand Density: Exploring Single and hybrid Deep Learning Models. *Energy and AI*, 16, 100343. <https://doi.org/10.1016/j.egyai.2024.100343>.
5. Shi Z., Zheng R., Shen R., Yang D., Wang G., Liu Y., Zhao J. (2024) Building Heating Load Forecasting Based on the Theory of Transient Heat Transfer and Deep Learning. *Energy and*

- Buildings*, 313, 114290. <https://doi.org/10.1016/j.enbuild.2024.114290>.
6. Kim D., Seomun G., Lee Y., Cho H., Chin K., Kim M.-H. (2024) Forecasting Building Energy Demand and On-Site Power Generation for Residential Buildings Using Long and Short-Term Memory Method with Transfer Learning. *Applied Energy*, 368, 123500. <https://doi.org/10.1016/j.apenergy.2024.123500>.
  7. Mohan R., Pachauri N. (2025) An Ensemble Model for the Energy Consumption Prediction of Residential Buildings. *Energy*, 314, 134255. <https://doi.org/10.1016/j.energy.2024.134255>.
  8. Jayashankara M., Sharma A., Singh A. K., Chanak P., Singh S. K. (2024) A Novel Intelligent Modeling and Prediction of Heat Energy Consumption in Smart Buildings. *Energy and Buildings*, 310, 114105. <https://doi.org/10.1016/j.enbuild.2024.114105>.
  9. Wang L., Xie D., Zhou L., Zhang Z. (2023) Application of the Hybrid Neural Network Model for Energy Consumption Prediction of Office Buildings. *Journal of Building Engineering*, 72, 106503. <https://doi.org/10.1016/j.jobe.2023.106503>.
  10. Sednin A. V., Pozdnyakova M. I. (2023) Energy Efficiency of Using Hybrid Heating Points in Conditions of Integration of Electrical and Thermal Networks of Urban Neighborhoods. Part 1. Justification of the Feasibility of Using Hybrid Thermal Points. *Energetika. Izvestiya Vysshikh Uchebnykh Zavedenii i Energeticheskikh Ob'edinenii SNG = Energetika. Proceedings of CIS Higher Education Institutions and Power Engineering Associations*, 66 (6), 552–566 <https://doi.org/10.21122/1029-7448-2023-66-6-552-566> (in Russian).
  11. Uzakov G. N., Sednin V. A., Safarov A. B., Mamedov R. A., Rakhmatov O. I. (2025) Simulation and Calculation of Parameters of a Small Solar Greenhouse in Order to Increase its Energy Efficiency. *Energetika. Izvestiya Vysshikh Uchebnykh Zavedenii i Energeticheskikh Ob'edinenii SNG = Energetika. Proceedings of CIS Higher Education Institutions and Power Engineering Associations*, 68 (4), 367–384. <https://doi.org/10.21122/1029-7448-2025-68-4-367-384> (in Russian).
  12. Kolosov M. V., Lipovka A. Yu., Lipovka Yu. L. (2024) System for Monitoring Building Heat Consumption. *Bulletin of the Tomsk Polytechnic University. Geo Assets Engineering*, 335 (7), 206–220. <https://doi.org/10.18799/24131830/2024/7/4443> (in Russian).

Received: 25 September 2025 Accepted: 27 November 2025 Published online: 30 January 2026