

Определение наилучшей конфигурации искусственной нейронной сети для прогнозирования теплотребления

Рецензия эксперта на статью получена
23.06.2025 [The expert review of the article
was received on June 23, 2025]

Пункт 2 статьи 3 Федерального закона №190-ФЗ «О теплоснабжении» [1] устанавливает общие принципы организации отношений и основы государственной политики в сфере теплоснабжения, включающие: обеспечение энергетической эффективности теплоснабжения и потребления тепловой энергии. Для мегаполиса федерального значения города Москвы утверждён документ: «Схема теплоснабжения города Москвы на период до 2035 года», требования к которому прописаны в Постановлении Правительства РФ №154 [2]. Пункт 5, раздел 1 «Показатели существующего и перспективного спроса на тепловую энергию (мощность) и теплоноситель в установленных границах территории поселения, муниципального округа, городского округа, города» включает один из ключевых показателей: «б) существующие и перспективные объёмы потребления тепловой энергии».

Для повышения энергетической эффективности потребителя тепловой энергии необходимо выполнить совершенствование прогнозного теплового баланса объекта посредством комбинированного применения детерминированных и стохастических подходов при расчёте настроек его автоматизированной системы управления тепловыми процессами. Преимущества достоверного и точного прогнозного теплотребления: снижение «перетопа» у потребителя, повышение энергетической эффективности рациональное использование топлива на источнике тепловой энергии, сокращение затрат на по-

Для повышения энергоэффективности потребителя тепловой энергии необходимо выполнить совершенствование прогнозного теплового баланса объекта посредством комбинированного применения детерминированных и стохастических подходов при расчёте настроек его автоматизированной системы управления тепловыми процессами

требление природного газа. Перечисленные преимущества повышают уровень энергосбережения и как следствие, приводят к экономии денежных средств.

Существующие методы расчёта тепловых нагрузок здания, которые основаны на нормативных документах РФ, являются укрупнёнными и статичными. При детализированном расчёте стационарных режимов математическая модель даже для отдельно стоящего здания становится чрезвычайно большой из-за большого количества влияющих параметров; получить все исходные данные для таких моделей не представляется возможным. При расчёте переходных процессов, управляемых системой автоматического регулирования (САР), в математическую модель необходимо ввести дополнительные факторы, которые имеют различный вклад в физику процесса теплообмена [3]. Результатом является система интегральных и логических уравнений, которая зачастую не имеет общего решения.

УДК 621.1.016. Научная специальность: 2.1.3.

Определение наилучшей конфигурации искусственной нейронной сети для прогнозирования теплотребления

Сергей Вадимович Гузов, к.т.н., доцент, Национальный исследовательский университет «Московский энергетический институт» (НИУ «МЭИ»); **Андрей Андреевич Арбатский**, к.т.н., генеральный директор ООО «НИИ «Энерго-эффективных технологий микроклимата»; **Елена Владимировна Крылова**, к.п.н., доцент, заместитель директора по учебной работе Института тепловой и атомной энергетики (ИТАЭ) НИУ «МЭИ»; **Олеся Евгеньевна Романова**, студент, НИУ «МЭИ»; **Анна Олеговна Сорокина**, студент, НИУ «МЭИ»

Приведён обзор структур искусственных нейронных сетей (ИНС), применяющихся для прогнозирования спроса на энергетические ресурсы. Отмечено, что по сравнению с моделями RBF, TSA-RBF и LSTM эффективность предсказания гибридной модели выше. Показано, что для ряда задач в области прогнозирования спроса на энергетические ресурсы целесообразно применение специализированного класса сверточных искусственных нейронных сетей, снижающих показатель статической ошибки дополнительно на 2,0–2,5%. Для dataset по объекту образовательного назначения, расположенному в зоне умеренного климата г. Москва, приведено девять входных факторов, объём выборки по каждому фактору составляет 96 строк. Проведён расчёт показателей качества регулирования АСУ для САР отдельно с ПИ-регулятором и отдельно — с ПИД-регулятором с нейроконтроллером. Показано, что система с ПИД-регулятором и нейроконтроллером эффективнее системы с ПИ-регулятором.

Ключевые слова: система теплоснабжения, автоматизированная система управления (АСУ), система автоматического регулирования (САР), ПИ-регулятор, ПИД-регулятор, нейроконтроллер, степень затухания, возмущение, время регулирования, искусственная нейронная сеть.

UDC 621.1.016. Scientific specialty number: 2.1.3.

Determining the best configuration of artificial neural network for predicting heat consumption

Sergey V. Guzhov, PhD (Engineering), Associate Professor, National Research University "Moscow Power Engineering Institute" (NRU "MPEI"); **Andrey A. Arbat-sky**, PhD (Engineering), General Director of the "Research Institute of Energy-Efficient Microclimate Technologies", LLC; **Elena V. Krylova**, PhD (Engineering), Associate Professor, deputy director for Academic Affairs of the Institute Thermal and Nuclear Power Engineering of the NRU "MPEI"; **Olesya E. Romanova**, student, NRU "MPEI"; **Anna O. Sorokina**, student, NRU "MPEI"

An overview of the structures of artificial neural networks used to predict demand for energy resources is given. It is noted that compared with the RBF, TSA-RBF and LSTM models, the prediction efficiency of the hybrid model is higher. It is shown that for a number of tasks in the field of forecasting demand for energy resources, it is advisable to use a specialized class of convolutional artificial neural networks that reduce the static error rate by an additional 2.0–2.5%. For a dataset on an educational facility located in the temperate climate zone of Moscow, nine input factors are given, the sample size for each factor is 96 lines. The calculation of the quality indicators of the regulation of an automated control system for an automatic control system separately with a PI controller and separately with a PID controller with a neurocontroller is carried out. It is shown that a system with a PID controller and a neurocontroller is more effective than a system with a PI controller.

Key words: heat supply system, automated control system, automatic control system, PI controller, PID controller, neurocontroller, degree of attenuation, disturbance, control time, artificial neural network.




Рис. 1. Структурная схема системы регулирования с ПИД-регулятором и нейроконтроллером

В настоящее время для прогнозирования теплопотребления зданиями используют четыре основных метода:

1. Детерминированный подход. Применение хорошо разработанных формульных моделей позволяет выполнить прогноз энергопотребления всего здания или его локального участка. Результаты прогнозирования ограничены точностью входных параметров, а недостаток входной информации может привести к существенному снижению точности моделирования.

2. Метод серого прогнозирования. Данный метод относится к нестатистическим методам прогнозирования и основан на выделении трендов и снижении влияния случайных факторов.

3. Методы многофакторного регрессионного анализа. Широко распространённый подход множественной линейной регрессии в MS Excel прост в применении, но имеет относительно невысокую точность моделирования.

4. Искусственные нейронные сети (ИНС). Демонстрируют достаточно высокую точность прогнозирования, но требуют специфических знаний на этапе подбора структуры, обучения и верификации модели.

Регулирование в системе происходит по отклонению с помощью отрицательной обратной связи, которая охватывает регулятор и объект. После подачи на вход сигнала с выхода системы на регулятор подаётся сигнал рассогласования, который учитывается при регулировании объекта. По заданию используются ПИ- и ПИД-регуляторы. ПИ-регулятор состоит из статического и интегрирующего звена, сочетая в себе достоинства двух звеньев: наиболее оптимальное динамическое отклонение, нет остаточной неравномерности, достаточно лёгкая настройка с помощью двух параметров. ПИД-регулятор и нейроконтроллер (рис. 1), в свою очередь, совмещают в себе ещё дифференцирующее звено, которое повышает качество работы. Отклонение регулятора намного ниже, но основным недостатком является высокая чувствительность при трех параметрах настройки. Нейроконтроллер — средство

(аппаратное или программное) интеллектуального управления, использующее ИНС для решения задач управления динамическими объектами.

ИНС позволяют без применения процедур упрощения анализировать большой объём данных и устанавливать связи между входными и выходными параметрами. Применяется гибридная модель прогнозирования, сочетающая нейронную сеть с радиальной базисной функцией (RBF) и нейронную сеть с длинной кратковременной памятью (LSTM), что позволяет улучшить точность, надёжность и обобщающую способность прогнозирования энергопотребления зданий [4]. Для разложения данных об энергопотреблении здания на группу компонентов внутренней модовой функции (IMF) и остаточный компонент использовалась полная ансамблевая эмпирическая модовая декомпозиция с алгоритмом адаптивного шума [5]. Компоненты были разделены на высокочастотные и низкочастотные с помощью алгоритма выборочной энтропии. Затем для отбора признаков применялся метод наименьшего абсолютного сужения и оператор выбора (LASSO) [6]. Для прогнозирования низкочастотных компонентов может использоваться RBF-модель, оптимизированная алгоритмом TSA, а для высокочастотных компонентов — модель LSTM [4]. Результаты оценки модели показали, что точность гибридной модели прогнозирования составила 98,72%. По сравнению с моделями RBF, TSA-RBF и LSTM, эффективность предсказания гибридной модели выше [7]. Кроме того,

ПИ-регулятор состоит из статического и интегрирующего звена и характеризуется оптимальным динамическим отклонением, отсутствием остаточной неравномерности, достаточно лёгкой настройкой. ПИД-регулятор и нейроконтроллер совмещают в себе дифференцирующее звено, повышающее качество работы

модель обладает высокой устойчивостью и способностью к обобщению, что позволяет более эффективно использовать её для прогнозирования почасового потребления электроэнергии в зданиях [8].

Для ИНС при увеличении количества обучающих выборок структура модели становилась достаточно сложной, а количество операций — огромным. Модель CNN (Convolutional Neural Network, свёрточная нейронная сеть) наряду с XGBoost, MLP и RBF является наиболее используемой из простых негибридных нейросетевых моделей для прогнозирования нагрузок зданий [9]. Модель CNN представляет собой многослойную сеть с прямой передачей данных с сильным локальным привлечением признаков на основе механизма разделения веса [10]. На основе трех наборов данных модель SBO-CNN снизила MAPE, RMSE и MAE в среднем на 12,33 %, 25,03 % и 29,90 %, соответственно, и улучшила R^2 в среднем на 8,13 % по сравнению с CNN благодаря масштабируемости CNN, что ещё раз демонстрирует лучшую предсказательную эффективность оптимизированных SBO гиперпараметров, используемых для построения сети CNN. Кроме того, на основе трех случайно выбранных наборов данных с различными статистическими характеристиками гибридная модель прогнозирования имеет немного большую ошибку прогнозирования при изменении фактической тепловой нагрузки, но всё же обладает более высокой точностью прогнозирования, чем традиционные классические модели прогнозирования [11]. При использовании ИНС типа CNN снижается статическая ошибка с приблизительно 18,4 % до 16,2 %, и точность прогнозирования будет повышаться примерно на 10–12 %.

Объём факторов для расчёта теплового баланса объекта зависит от применяемой методики [12] и включает: характеристики источника теплоснабжения (расход теплоносителя, температура теплоносителя в прямой и обратной трубе), характеристики светопрозрачных и светонепрозрачных ограждающих конструкций (толщина, теплопроводность, площадь).

Характеристики трубопроводов: длина, диаметр, теплоизоляция. Метеорологические данные: температура наружного воздуха, скорость и направление ветра на высоте 10–12 м над поверхностью земли, зафиксированное за десятиминутный период перед наблюдением, влажность воздуха, средняя продолжительность облачности светлого дня, степень затенённости неба облаками в течение светлого дня и продолжительность светового дня в минутах [13].




Рис. 2. Годограф КЧХ объекта

Для определения теплотребления объекта необходимо учитывать лишь некоторые из возможных факторов, так как данные о нём могут быть недостоверными или труднодоступными.

На этапе индексирования данные промаркированы по признаку даты и времени для обеспечения возможности последующего изучения результатов численного эксперимента. После заполнения базы данных необходимо провести тестирование и проверку, чтобы убедиться, что данные корректно структурированы надлежащим образом и доступны для использования. Тестирование состоит из формулирования запросов и проверки результатов, осуществляется «холодной запуском» программы нейронной сети для определения отсутствия проблем.

Пример расчёта и результаты оптимизации

Объектом исследования стал индивидуальный тепловой пункт, обеспечивающий передачу тепловой энергии из центральной сети к корпусу А НИУ «МЭИ». Объект расположен в климатических условиях города Москвы и имеет следующие параметры: абсолютная минимальная температура за весь период наблюдения $t_{\min} = -43^\circ\text{C}$, температура наиболее холодной пятилетки $t_{\text{нх}}^{\text{Б}} = -26^\circ\text{C}$, средняя температура за отопительный период $t_{\text{н}}^{\text{ср.0}} = -2,2^\circ\text{C}$, средняя относительная влажность воздуха наиболее холодного месяца $\phi = 84\%$, продолжительность отопительного периода составляет 205 суток, преобладающим направлением ветра за декабрь — февраль является западное.

На основе требований и собранных данных определена структура базы данных. База данных включает в себя обучающую тестовую выборки. Объём тестовой выборки (96 значения) — один календарный год с января по декабрь 2022 года. Объём обучающей выборки — четыре года, предшествующих прогнозируемому.




Рис. 3. График переходной функции по каналу возмущения АСР с ПИ- и ПИД-регулятором

Передаточная функция объекта регулирования имеет следующий вид:

$$W_{\text{uy}}(s) = \frac{1e^{-20s}}{(100s + 1)^3}, \frac{^\circ\text{C}}{\% \text{УП}}. \quad (1)$$

Годограф комплексной частотной характеристики (КЧХ) объекта приведён на рис. 2. График переходной функции по каналу возмущения АСР с ПИ- и ПИД-регулятором (рис. 3) демонстрируют повышенную эффективность переходного процесса для системы автоматического регулирования с ПИД регулятором и нейроконтроллером.

Оценка качества работы рассматриваемых систем регулирования выполняется на основании показателей следую-

щих: динамическое, статическое и максимальное отклонение, время регулирования и степень затухания (табл. 1). По результатам таблицы на основании прямых показателей качества можно сделать вывод о том, что система с ПИД-регулятором и нейроконтроллером эффективнее системы с ПИ-регулятором, это наблюдается по лучшим показателям степени затухания на 0,11 при изменении задания и 0,05 при возмущении на входе объекта, и времени регулирования на 700 с. При изменении задания и 1100 при возмущении на входе объекта, а также по значительному уменьшению динамического отклонения на 0,284 при нанесении возмущения на вход объекта. ●

Показатели качества регулирования

табл. 1

Система	Изменение задания / возмущение на вход объекта		
Система с ПИ-регулятором	$\Delta u_{\text{дин}}$	$t_{\text{рег}}$	Ψ
	0,301 / 0,508	2000 / 2600	0,86 / 0,90
Система с ПИД-регулятором с нейроконтроллером	$\Delta u_{\text{дин}}$	$t_{\text{рег}}$	Ψ
	0,376 / 0,224	1400 / 1500	0,97 / 0,95

- О теплоснабжении (посл. ред.): Федеральный закон от 27.07.2010 №190-ФЗ.
- О требованиях к схемам теплоснабжения, порядку их разработки и утверждения (с изм. и доп.): Постановление Правительства РФ от 22.02.2012 №154.
- Денисенко В.В., Карипова Н.А., Каламов Р.М. Искусственные нейронные сети и их применение // Colloquium-Journal, 2019. №23–2. С. 18–20.
- Молодюк В.В., Исамухамедов Я.Ш., Илюшин П.В., Ивановский Д.А. Мультиагентное оптимальное управление электрическими сетями с активными потребителями и возобновляемыми источниками энергии // Энергетик, 2022. №2. С. 45–52.
- Молодюк В.В., Илюшин П.В., Исамухамедов Я.Ш., Ивановский Д.А. Методы формирования логической части устройств РЗА в электрических сетях с распределённой генерацией на основе машинного обучения // Энергетик, 2022. №11. С. 50–65.
- Неуимин В.М. Исследование вентиляционных процессов, сопровождающих эксплуатацию паровых турбин в режимах с малыми объёмными расходами пара // Библиотека электротехника, 2022. №1. С. 1–83.
- Варшавский П.Р., Поляков С.А. Архитектура распределённой системы для интеллектуального анализа данных на основе прецедентов // Вестник МЭИ, 2023. №4. С. 155–161.
- Аракелян Э.К., Косой А.А. Выбор и оценка приоритетных направлений повышения интеллектуальности АСУ ТП ТЭС // Вести в электроэнергетике, 2022. №5. С. 52–57.
- Vanting N. Bo, Ma Zh., Jørgensen Bo N. A scoping review of deep neural networks for electric load forecasting. From 1st Energy Informatics Academy Conference Asia (Beijing, China; May 29–30, 2021). Energy Informatics. 2021. Vol. 4. Suppl. 2. Article No. 49. 13 p.
- Aurangzeb Kh., Alhussein M., Javadi K., Haider S.I. A pyramid-CNN based deep learning model for power load forecasting of similar-profile energy customers based on clustering. IEEE Access. Vol. 9. Publ.: January 20, 2021. 12 p.
- Мектепкалиева А.К., Ханова А.А., Проталинский О.М. Система программной поддержки краткосрочного прогнозирования электропотребления // Математические методы в технологиях и технике, 2022. №6. С. 113–116.
- Архив погоды в Москве (центр, Балчуг) [Электр. ресурс]. Режим доступа: rp5.ru. Дата обрац.: 20.06.2025.
- Устюгов Н.В., Проталинский О.М. Управление процессом энергопотребления предприятия // Вестник МЭИ, 2021. №3. С. 96–102.

References — see page 80.