
ТЕПЛОФИКАЦИЯ
И ТЕПЛОВЫЕ СЕТИ

**АНАЛИЗ СИТУАЦИИ И ТЕХНИЧЕСКИХ ТРУДНОСТЕЙ
ПРИ ПРОГНОЗИРОВАНИИ ТЕПЛОЙ НАГРУЗКИ НА СИСТЕМУ
ЦЕНТРАЛИЗОВАННОГО ТЕПЛОСНАБЖЕНИЯ¹**

© 2022 г. Bingwen Zhao^a, Yu Jin^{a, *}, Wan Li^a, Hanyu Zheng^a

^aZhejiang Sci-Tech University, 928 Second Avenue, Xiasha Higher Education Zone, Hangzhou, Zhejiang, 310018 P.R. China

*e-mail: 1042809345@qq.com

Поступила в редакцию 17.07.2021 г.

После доработки 16.08.2021 г.

Принята к публикации 25.08.2021 г.

Централизованное теплоснабжение широко используется во всем мире. В четвертом поколении централизованного теплоснабжения дополнительно выдвигается концепция интеллектуальных тепловых сетей и подчеркивается необходимость применения технологии прогнозирования тепловой нагрузки. В статье рассматриваются три основных элемента прогнозирования: предварительная обработка данных, методы моделирования и выбор входных данных. Показано, что эти элементы существенно влияют на точность прогнозирования тепловой нагрузки. В то же время на основе фактического инженерного исследования анализируются трудности применения прогнозирования реальной тепловой нагрузки. Для реализации концепции централизованного теплоснабжения четвертого поколения в практической инженерии прогнозирование тепловой нагрузки оптимизируется с учетом следующих двух аспектов: обогащения и совершенствования базы исходных данных. В целях повышения точности модели прогнозирования используется схема разделения набора данных модели прогнозирования тепловой нагрузки на обучающий и тестовый наборы. Работоспособность предложенной методики подтверждена результатами расчета теплового пункта системы централизованного теплоснабжения г. Кайфэн.

Ключевые слова: централизованное теплоснабжение, прогноз тепловой нагрузки, интеллектуальные тепловые сети, база данных, спрос на отопление, трубопроводная сеть, тепловой пункт, тепловая станция

DOI: 10.1134/S004036362206008X

Энергосбережение и снижение выбросов оксидов углерода в атмосферу – проблемы, стоящие в настоящее время перед учеными всего мира. Парижское соглашение, подписанное 196 сторонами 12 декабря 2015 г., имело основной целью удержание прироста глобальной средней температуры намного ниже 2°C сверх доиндустриальных уровней. При этом необходимо приложить все усилия, чтобы ограничить рост температуры до 1.5°C, что становится глобальной целью развития мировой энергетики. Европейская комиссия 28 ноября 2018 г. опубликовала документ, рассчитанный на долгосрочную перспективу и направленный на достижение нулевых выбросов углекислого газа (углеродной нейтральности) к 2050 г. Страны Северной Европы, такие как Финляндия, Швеция, Норвегия, Дания и Исландия, подписали в ноябре 2019 г. в г. Хельсинки (Финляндия)

совместное заявление об изменении климата. В этом документе указанные пять стран заявили, что они будут работать вместе, чтобы активизировать усилия по борьбе с изменением климата и достичь углеродно-нейтральных целей быстрее, чем другие страны. Здесь следует отметить, что даже в холодных европейских регионах на отопление и охлаждение помещений приходится более 80% общего энергопотребления здания [1]. На 75-й сессии Генеральной Ассамблеи ООН, состоявшейся 22 сентября 2020 г., правительство Китая изложило свою цель: Китай должен достичь пика выбросов углекислого газа к 2030 г., а к 2060 г. обеспечить углеродную нейтральность.

В данной статье обобщается и анализируется состояние исследований в области прогнозирования тепловой нагрузки на систему централизованного теплоснабжения (СЦТ), предлагаются способы уточнения существующих методов.

¹ Работа выполнена при поддержке Исследовательского фонда Бюро образования провинции Чжэцзян, Китай (грант № Y202147916).

ПРОГНОЗИРОВАНИЕ ТЕПЛОВОЙ НАГРУЗКИ

С повышением уровня жизни и развитием технологий спрос населения на энергию растет. В 2013 г. строительный сектор потреблял 35% энергии в мире и на его долю приходилось около 17% общего объема прямых выбросов углекислого газа [2]. В Европейском союзе централизованное теплоснабжение в 2010 г. покрывало около 13% потребностей домашних хозяйств в отоплении. По оценкам [3], к 2050 г. этот показатель может увеличиться до 50%. В Европе в 2020 г. на эксплуатацию зданий приходилось около 40% потребляемой энергии и 36% выбросов оксидов углерода, а на системы отопления зданий – примерно 23% общего объема потребляемой энергии [4].

В Китае отопительные установки размещаются в районах, где среднегодовая дневная температура меньше или равна 5°C в течение более 90 дней. Поэтому в таких провинциях Китая, как Хэйлуцзян, Цзилинь, Ляонин, Пекин, Хэбэй, Шаньси, Шаньдун, Внутренняя Монголия, Ганьсу, Цинхай, Нинся, Синьцзян, имеется централизованное отопление. К 2019 г. общая протяженность теплотрасс Китая достигла 392917 км, суммарная площадь обогрева – 925 137 млн м², население зоны обогрева – 39623 млн чел. Проектная производительность ТЭЦ составляет 100943 т пара в час, горячей воды – 550530 т/ч. Фактические же значения этих показателей – 65067 и 327475 т/ч соответственно [5]. Это свидетельствует о том, что имеется огромный потенциал для сбережения тепла, затрачиваемого на отопление зданий.

Цели прогнозирования тепловой нагрузки

Для обеспечения энергосбережения необходимо знать тепловую нагрузку на СЦТ при определении

потребности системы отопления в тепле в определенное время или в определенный период времени в будущем. Прогнозирование этой нагрузки должно проводиться на этапе эксплуатации или проектирования системы отопления. Поэтому большое значение имеют повышение эффективности использования энергии и сокращение выбросов углекислого газа в системе централизованного теплоснабжения. Эту задачу можно решить с помощью методов прогнозирования тепловой нагрузки.

Датские ученые разделяют процесс развития технологий централизованного теплоснабжения на четыре периода [6] (табл. 1). Важнейшей характеристикой четвертого периода, или, как часто говорят, четвертого поколения централизованного теплоснабжения, является возможность использовать интеллектуальные тепловые сети. Это означает, что можно разумно управлять каждой частью системы централизованного теплоснабжения и контролировать ее работу благодаря проведению углубленного анализа полученной информации и данных, собранных в результате мониторинга СЦТ. Управление системой централизованного теплоснабжения является ключом к эффективному использованию энергии и зависит от детального понимания потребностей в тепле потребителей различных уровней. На основе прогноза тепловой нагрузки в период планирования СЦТ может быть реализован масштабный проект трубопроводной сети, рассчитано распределение мощности источника тепла и проработана компоновка оборудования трубопроводной сети. Благодаря точному прогнозированию тепловой нагрузки могут быть обеспечены баланс спроса и предложения у конечных потребителей, оптимальная стратегия управления работой системы централизованного теплоснабжения во время эксплуатации сети теплотрасс, эффективное планирование производ-

Таблица 1. Периоды развития централизованного теплоснабжения [6]

Показатель	Период			
	1880–1930 гг.	1930–1980 гг.	1980–2020 гг.	2020–2050 гг.
Поколение	Первое	Второе	Третье	Четвертое
Теплоноситель (ТН)	Водяной пар	Вода	Вода	Вода
Температура ТН, °С	Более 200	Более 100	Более 60	Менее 50
Топливо	Уголь	Уголь, нефть	Уголь, нефть, солнечная энергия, энергия биомассы и сбросное тепло	Уголь, нефть, солнечная энергия, энергия биомассы, сбросное тепло и все виды возобновляемой энергии
Источник тепла	Распределенные пылеугольные котлы	ТЭС и бойлеры	ТЭС и бойлеры	ТЭС, бойлеры, тепловые насосы и т.п.
Источник, обеспечивающий прокачку теплоносителя по трубам	Давление пара	Концентрирующий насос	Концентрирующий насос	Концентрирующий насос и тепловой насос

ства тепла. На основе такого прогнозирования реализуется интеллектуальное управление тепловой сетью, способствующее повышению качества централизованного теплоснабжения и снижению энергопотребления.

Безусловно, существует определенное несоответствие между прогнозируемым значением тепловой нагрузки и фактическим значением, но она может быть приемлемой до тех пор, пока общее количество тепла, производимого в течение определенного периода времени, превышает потребность в нем. Поэтому исследования многих ученых посвящены тому, как уменьшить это несоответствие и получить результат прогнозирования в пределах допустимого диапазона значений.

Предварительная обработка данных

Система централизованного теплоснабжения характеризуется длительными временными задержками, высокой сложностью, нелинейностью и неопределенностью. Прогнозирование тепловой нагрузки основано на огромном объеме исходных данных, а их качество напрямую связано с результатами прогнозирования. Однако в практической инженерии из-за неисправности того или иного датчика, ошибки передачи данных, утечки в трубопроводной сети и других факторов собранные данные могут свидетельствовать о каких-либо аномальных явлениях. В [7] показано, что такие факторы, как дискретность данных и их экстремальные отклонения (аномальные данные), могут напрямую влиять на точность прогнозирования, поэтому предварительная обработка исходных данных нередко является первым шагом к созданию модели прогнозирования.

На этапе предварительной обработки данных аномальные данные сначала идентифицируются техническими средствами и затем классифицируются по типам аномалий. Для того чтобы обработанные данные были как можно ближе к реальным значениям, их корректируют с помощью различных методов.

В [8] предложен трехэтапный метод коррекции данных для обнаружения аномалий, их классификации и замены. Авторы [9] рассчитали скорость отклонения данных с помощью методов математической статистики и предложили, как устранить или скорректировать аномальные данные. В [10] использованы метод среднего значения и алгоритм интерполяции для получения недостающих данных и исправления аномальных данных. В [11] описан фильтр Калмана для выявления и удаления аномальных данных, а в [12] применено взвешенное скользящее среднее значение для получения недостающих данных с помощью близлежащих значений.

Методы прогнозирования

Прогнозирование тепловой нагрузки может быть долгосрочным, среднесрочным, краткосрочным и сверхкраткосрочным. Последнее в основном дает прогноз тепловой нагрузки в течение 1 ч или менее, краткосрочное — изменение тепловой нагрузки на следующий день. Оба прогноза направлены на достижение баланса спроса и предложения тепла и контроль за теплоснабжением. Период среднесрочного прогноза нагрузки составляет 3–7 дней, а долгосрочного — 1 год. Эти два прогноза предназначены, главным образом, для производственного планирования нагрузки.

Существует много методов построения модели прогнозирования нагрузки, но не все из них подходят для этой цели, в частности к таковым относится метод дерева регрессии, что было доказано в [13]. В настоящее время для прогнозирования тепловой нагрузки используются следующие пространственные методы: временных рядов, регрессии параметров, серой системы, экспертной системы, искусственной нейронной сети, опорных векторов. Преимущества и недостатки этих методов представлены в табл. 2.

Наряду с методами, упомянутыми в табл. 2, существуют и другие методы, которые также имеют некоторые недостатки. Например, метод ANFIS (adaptive network-based fuzzy inference system — адаптивная сетевая система нечеткого вывода) может точно предсказывать тепловую нагрузку только в пределах 1 ч [14], а структуру скрытого слоя нейронной сети со случайным весом трудно определить [15]. Даже SVM- и DNN-методы (support vector method — метод опорных векторов и deep neural networks — метод глубоких нейронных сетей), которые обычно считаются наиболее эффективными одиночными алгоритмами, все еще не могут избежать таких проблем. Цель алгоритма контролируемого машинного обучения состоит в том, чтобы изучить модель, которая является стабильной и хорошо работает во всех случаях. Реальная же ситуация далеко не идеальна. Зачастую можно использовать только несколько предпочтительных моделей, но в некоторых случаях они слабо описывают реальную ситуацию. Поэтому при прогнозировании тепловой нагрузки для повышения производительности и точности модели при ее машинном обучении все чаще используются такие методы, как комбинационный алгоритм [9, 16–20] и ансамблевое обучение [21–24]. Результаты исследований показывают, что эти методы могут в определенной степени улучшить производительность модели прогнозирования тепловой нагрузки и повысить точность прогнозирования более чем на 80%.

Таблица 2. Методы прогнозирования тепловой нагрузки

Метод прогнозирования	Преимущества	Недостатки
Временных рядов	<ol style="list-style-type: none"> 1. Необходимо небольшое количество исторических данных. 2. Не требуется больших затрат труда 	<ol style="list-style-type: none"> 1. Не учитываются факторы, влияющие на изменение тепловой нагрузки 2. Необходимы достаточные и непрерывные данные
Регрессии параметров	<ol style="list-style-type: none"> 1. Простота принципа и четкая структура. 2. Легко применить и объяснить полученные результаты 	<ol style="list-style-type: none"> 1. Не учитывается влияние на тепловую нагрузку метеорологических факторов. 2. Сложность нахождения математических моделей. 3. Требуется высокая точность исторических данных
Серой системы	<ol style="list-style-type: none"> 1. Необходима небольшая выборка данных. 2. Хорошо оцениваются действительные факторы. 3. Могут быть найдены правила с неопределенными реляционными последовательностями 	<ol style="list-style-type: none"> 1. Дискретность выборочных данных должна быть минимальной. 2. На результат прогнозирования в значительной степени влияют ключевые факторы. 3. Для экспоненциально растущей нагрузки точность прогнозирования значительно снижается из-за большей степени ее подгонки
Экспертной системы	<ol style="list-style-type: none"> 1. Позволяет избежать сложных численных операций. 2. Отличная расширяемость системы 	<ol style="list-style-type: none"> 1. Четко ориентирован и не может быть использован в других системах. 2. Требуются качественные профессиональные знания и навыки
Искусственной нейронной сети	<ol style="list-style-type: none"> 1. Разносторонняя информативность. 2. Высокая отказоустойчивость 	<ol style="list-style-type: none"> 1. Существенное время сходимости решения, большая вероятность попадания в локальный минимум, необходимость переобучения и недообучения нейронной сети. 2. Структуру искусственной нейронной сети трудно определить
Опорных векторов	<ol style="list-style-type: none"> 1. Высокие производительность обобщения и эффективность вычислений. 2. Полученное решение является уникальным. 3. Имеет большие преимущества при работе с нестабильными колебаниями и позволяет давать вероятностный прогноз неопределенности 	<ol style="list-style-type: none"> 1. Сложность выбора параметров метода. 2. Возникают проблемы переобучения при работе с “зашумленными” данными

Выбор входных данных

Существует множество факторов, влияющих на тепловую нагрузку. Это не только температура наружного воздуха, скорость ветра, солнечная радиация, температура прямой и обратной воды, но и тип и расположение здания, поведение людей в помещении и прочие внутренние факторы.

Учесть влияние на тепловую нагрузку всех факторов очень сложно, а порой и невозможно, по-

скольку для этого необходимо провести статистический анализ каждой комбинации параметров. Учет же избыточного фактора увеличивает размерность входных переменных и оказывает негативное воздействие на интерпретируемость и прогностическую способность модели. Кроме того, это не только снижает способность модели к обобщению, но и не повышает существенно ее точность. Например, добавление в модель прогнозирования факторов солнечной радиации и скорости вет-

Таблица 3. Отбор определяющих входных параметров с помощью методов выбора признаков

Литературный источник	Метод выбора признака	Определяющие входные параметры
[13]	Фильтр	Температура наружного воздуха, исторические параметры работы трубопроводной сети, социальные факторы, температура и давление прямой и обратной воды
[16]	»	Температура наружного воздуха, скорость ветра, исторические параметры работы трубопроводной сети
[18]	Оболочка	Температура наружного воздуха, история тепловой нагрузки, температура прямой и обратной воды
[25]	Фильтр	Температура сухого термометра, точка росы, прямое нормальное излучение, рассеянное горизонтальное излучение, скорость ветра
[26]	Оболочка	Температура наружного воздуха, исторические параметры работы трубопроводной сети, температура обратной воды
[27]	»	Температура наружного воздуха, скорость ветра, социальные факторы
[28]	»	Параметр временной характеристики, исторические параметры работы трубопроводной сети, внешний метеорологический параметр
[29]	Фильтр	Скорость ветра, температура наружного воздуха и внутри помещения, температура и массовый расход обратной воды
[30]	»	Социальные факторы, температура наружного воздуха, температура и расход обратной воды, продолжительность отопительного периода
[31]	»	Отопительное оборудование, городская структура, экономическое развитие, социальные факторы
[32]	»	Температура наружного воздуха, скорость ветра, солнечная радиация, число потребителей тепла
[33]	Вложение	Температура наружного воздуха, исторические параметры работы трубопроводной сети

ра практически не увеличивает ее точность [8]. Поэтому при построении модели прогнозирования тепловой нагрузки главными задачами являются поиск наиболее влиятельных переменных, выявление и устранение мультиколлинеарности² между входными переменными. Чтобы уменьшить количество вычислений, исключить взаимосвязь между факторами, сократить время при сборе исходных данных, нужно отказаться от избыточных факторов и получить только необходимую информацию. При этом производительность модели не должна снижаться, а ее размерность должна уменьшиться. Факт уменьшения размерности модели при сокращении количества исходных данных довольно хорошо известен.

² Мультиколлинеарность – тесная корреляционная взаимосвязь между отбираемыми для анализа факторами, совместно воздействующими на общий результат, которая затрудняет оценку искомым параметров.

Методы снижения размерности, также известные как выбор признаков, можно разделить на три категории в соответствии с критериями оценки выбора признаков: фильтры, оболочки и вложения. С помощью методов фильтрации сортируются входные переменные с учетом их корреляции или наличия общей информации, затем из них выбираются наиболее значимые. Методы-оболочки позволяют определять и оценивать подмножество входных переменных на основе их точности по отношению к заданной выходной переменной. Встроенные методы аналогичны методам-оболочкам в том, что они одинаково оценивают сильные и слабые стороны различных наборов входных переменных. Но этот оценочный отбор происходит непосредственно в процессе машинного обучения, что позволяет избежать его многократного повторения для каждого подмножества признаков-кандидатов.

Как видно из табл. 3, входные данные, присутствующие в той или иной модели, включают, как

правило, температуру наружного воздуха и исторические параметры работы трубопроводной сети. Однако для повышения точности и обобщающей способности модели прогнозирования исследователи обычно добавляют другие характерные параметры, например социальные факторы и типы зданий, с учетом таких реальных технических условий, как сложность процесса сбора данных и период прогнозирования. Так, в [34] формулируются две различные стратегии выбора входных параметров для сокращения размерности модели и оптимизации ее производительности. Авторы [28] показали, что температура прямой сетевой воды является фактором, наиболее существенно влияющим на прогнозирование сверхкраткосрочной нагрузки, ее массовый расход – на прогнозирование краткосрочной нагрузки, а температура наружного воздуха – на среднесрочный прогноз. Поэтому выбор входных параметров модели прогнозирования тепловой нагрузки представляет собой задачу со сложными и сильными связями, которые необходимо всесторонне рассматривать с учетом сложности модели, периода прогнозирования, фактической технической ситуации, цели прогнозирования и других аспектов.

СХЕМА ИССЛЕДОВАНИЯ

Даже после анализа довольно большого количества литературных данных и результатов инженерных исследований все еще существует много трудностей для практического применения моделей прогнозирования тепловой нагрузки. В этой статье выдвигаются предложения по двум направлениям: совершенствованию базы исходных данных (БД) и уменьшению несогласованности стандарта создания и разделения набора данных.

Полная база данных

Для прогнозирования тепловой нагрузки используется большое количество реальных и эффективных данных. Однако согласно результатам многочисленных исследований, большинство имеющихся баз данных не могут полностью удовлетворить потребности в информации, пригодной для прогнозирования тепловой нагрузки. Так, небольшой объем исходных данных, ограничения по их типам, чрезмерное количество аномальных данных – все это создает проблему для проведения расчетов. Хотя некоторые исследователи и предложили для решения этой проблемы применять виртуальные выборки для прогнозирования тепловой нагрузки [34, 35], тем не менее недостатки базы исходных данных приводят к переобученности или недообученности модели прогнозирования, а точность прогнозирования и способность к обобщению нельзя считать удовлетворительными. При этом будет вноситься

новая ошибка, связанная с различиями в смоделированной выборке и реальными данными. Таким образом, создание высококачественной базы исходных данных для прогнозирования тепловой нагрузки является как предпосылкой, так и необходимой основой для применения такого прогнозирования в практической инженерии.

Проблемы, возникающие при формировании базы исходных данных, могут быть вызваны различными причинами, такими, например, как ограничение ассортимента измерительных приборов [36] и несогласованная частота сбора данных. К тому же большинство теплоснабжающих компаний не имеют достаточного количества исходных данных. Это означает, что отслеживаются и собираются данные только на самой трубопроводной сети, а данных о факторах, влияющих на тепловую нагрузку за пределами трубопроводной сети (метеорологические условия и типы потребителей тепла), недостаточно. Кроме того, аномальные данные, вызванные перебоями в отоплении, проблемами технического обслуживания трубопроводной сети и сбоями в ее работе, в базу данных не включаются.

Авторы настоящей статьи считают, что необходимо обогатить и усовершенствовать базу данных прогнозирования нагрузки на теплоснабжение путем добавления в нее следующих баз данных: основной информации по теплоснабжению, по эксплуатации системы теплоснабжения и потребителей тепла. База данных основной информации по теплоснабжению содержит проектные параметры объектов отопления, такие как источник тепла, система теплообменников и потребители тепла. База данных по эксплуатации системы теплоснабжения должна включать метеорологические факторы (температуру наружного воздуха и скорость ветра), записи о неисправностях трубопроводной сети и регулировании и техническом обслуживании трубопроводной сети для обеспечения точности последующей предварительной обработки данных. База данных потребителей тепла должна содержать типы зданий, параметры ограждающих конструкций, правила перемещения персонала и требования к обеспечению в зданиях теплового комфорта.

На этапе проектирования СЦТ для прогнозирования тепловой нагрузки требуются следующие данные: площадь обогреваемых помещений, расчетная температура прямой и обратной воды, массовый расход воды, температурный диапазон нагрева, схема расположения трубопроводной сети. На этапе эксплуатации системы централизованного теплоснабжения база данных прогнозирования тепловой нагрузки должна включать в себя температуру, давление и массовый расход прямой и обратной воды, исторические параметры работы трубопроводной сети, температуру в поме-




Рис. 1. Схема трубопроводов системы централизованного теплоснабжения г. Кайфэн

щении и на открытом воздухе, а также потребности в тепле у потребителей. Кроме перечисленных факторов в базу данных при необходимости должны быть добавлены метеорологические параметры на открытом воздухе, типы зданий, параметры ограждающих конструкций, требования к обеспечению комфорта потребителей тепла и т.д.

Предложения по созданию и разделению набора данных³

Разработка и оценка эффективности моделей прогнозирования зависят от создания и разделения наборов данных [12]. Небольшой объем обучающего набора приводит к переобучению модели, большой — к низкой эффективности обучения. Размер тестового набора данных определяет точность модели. В большинстве исследований описано, как разделить данные на обучающий и тестовый наборы, приводится также временной интервал этих наборов, но не уделяется достаточного внимания тому, как оптимально разделить наборы данных. Однако полного консенсуса среди исследователей в решении этого вопроса нет. Это приводит к тому, что размеры и продолжительности обучающего и тестового наборов варьируются от дней [37, 38] и месяцев [39] до нескольких лет [34, 40]. В настоящее время наборы данных делятся, в основном, в соответствии с рекомендациями, принятыми в компьютерной об-

ласти, т.е. 80% выборки данных используются для обучения модели, а 20% — в качестве тестовых наборов. Но некоторые исследователи выдвигают и другие схемы разделения, например 70 и 30% соответственно [18], поддержание одинакового количества данных обучающего и тестового наборов (50 и 50%) и т.д.

Авторы настоящей статьи предлагают рассмотреть проблему разделения наборов данных в трех аспектах: обоснованности, своевременности и регулярности. Если набор содержит большое количество аномальных и недостающих данных, что часто встречается в практической инженерии, прогнозирование, конечно же, не даст ожидаемого эффекта. Поэтому перед созданием модели прогнозирования важно провести предварительную обработку данных. Кроме того, следует учитывать такой фактор, как своевременность данных. Большинство систем централизованного теплоснабжения не являются неизменными, и преобразование или расширение теплосети оказывает серьезное воздействие на данные о тепловой нагрузке. Поэтому данные до и после этих изменений должны быть разделены. Кроме того, существуют еще два вопроса, на которые следует ответить: необходимо ли, чтобы данные за несколько лет были частью набора данных? Останется ли размер набора данных прежним или будет обновлен? И сами данные о тепловой нагрузке отражают изменения суточного цикла и сезонность, поэтому также необходимо рассмотреть разделение и создание наборов данных в соответствии с их регулярностью.

³ Набор данных — это набор объектов, в которых хранятся данные из базы данных. Благодаря созданию этих наборов обновляются и удаляются соответствующие данные без постоянного подключения к БД.

ИНЖЕНЕРНОЕ ПРИМЕНЕНИЕ

В данной статье задача повышения эффективности прогнозирования тепловой нагрузки с помощью предложенной выше схемы исследований рассматривается на примере системы централизованного теплоснабжения г. Кайфэн (Китай). Эта СЦТ насчитывает 247 тепловых пунктов (ТП). Система отопления обеспечивает круглосуточный обогрев помещений с периодом отопления в течение 4 мес. Схема трубопроводов СЦТ г. Кайфэн показана на рис. 1.

В предыдущем исследовании [41] авторы настоящей статьи разработали модель прогнозирования тепловой нагрузки на основе метода PSO-LSSVM (от англ. particle swarm optimization–least square support vector machine – оптимизация роя частиц – метод опорных векторов наименьших квадратов). Размер популяции составлял 30, максимальное число итераций – 2000, коэффициент регуляризации – 176.98, а коэффициент ширины ядра – 31.82. Входными параметрами являются температура наружного воздуха, скорость ветра, температура прямой и обратной воды в предыдущий день, давление прямой и обратной воды, массовый расход воды, тепловая нагрузка за первые три дня, а выходным параметром – тепловая нагрузка.

Авторы применили метод PSO-LSSVM для расчета тепловой нагрузки ТП системы централизованного теплоснабжения г. Кайфэн в отопительный сезон 2020 г. Однако полученные за первый месяц результаты показали, что существует определенный разрыв между прогнозным и фактическим значениями тепловой нагрузки (рис. 2, а). В процессе исследований было установлено, что на этапе предварительной обработки данных, используя измененные данные, невозможно отобразить фактическую работу трубопроводной сети с помощью простых математико-статистических средств. Кроме того, система централизованного теплоснабжения была расширена и переоборудована много раз и емкость хранилища данных каждой зоны отопления была различной на разных уровнях. В ходе недавнего расширения была построена новая насосная станция, которая заменила бывшую котельную, что привело к большим аномалиям в данных об отоплении.

Авторы учли все эти факторы и усовершенствовали модель прогнозирования тепловой нагрузки. Для этого были предварительно обработаны исходные параметры в соответствии с аномальными данными, вызванными фактической ситуацией, такой как прерывание отопления, отказ прибора, техническое обслуживание трубопроводной сети, преобразование трубопроводной сети, гидравлический сбой, сбой в трубопроводной сети и т.д. Кроме того, для заполнения недостающих и исправления аномальных данных был использован более




Рис. 2. Изменение тепловой нагрузки на ТП г. Кайфэн в течение 1 сут, рассчитанное по исходной (а) и усовершенствованной (б) модели прогнозирования. 1 – фактические данные; 2 – прогноз

совершенный математико-статистический аппарат. Наборы данных были разделены по принципу подобных дней. Восстановленная модель прогнозирования была применена в третьем месяце отопительного сезона 2020 г., и результат прогнозирования был существенно улучшен по сравнению с первым месяцем (рис. 2, б).

ВЫВОДЫ

1. Прогнозирование тепловой нагрузки является основой централизованного теплоснабжения четвертого поколения, а также важным средством достижения экономии энергии и сокращения выбросов вредных веществ.

2. Качество наборов данных оказывает существенное влияние на точность прогнозирования и способность к обобщению модели прогнозирования тепловой нагрузки. Предварительная обработка данных является предпосылкой прогнозирования тепловой нагрузки. Модель прогнозирования тепловой нагрузки, построенная по единому алгоритму, не может удовлетворить потребности реального проектирования. Существует тенденция к повышению точности прогнозирования и произ-

водительности обобщения модели с помощью комбинированного алгоритма и ансамблевого обучения.

3. Среди исследователей нет единого мнения о том, что следует выбрать, чтобы достичь высоких результатов прогнозирования: метод моделирования, наиболее подходящий для прогнозирования тепловой нагрузки, или набор соответствующих входных параметров, создание и разделение наборов данных. Это связано с тем, что превосходство модели в прогнозировании тепловой нагрузки не может быть просто оценено и существует множество факторов, влияющих на производительность модели, поэтому ее можно проанализировать и сравнить только с определенной точки зрения.

4. В целях дальнейшего развития практического применения технологии прогнозирования тепловой нагрузки ее следует изучать дополнительно в следующих двух направлениях:

- необходимо улучшить базу данных прогнозирования тепловой нагрузки. Прогнозирование тепловой нагрузки основано на большом количестве реальных и эффективных данных. В настоящее время база данных, созданная большинством тепловых компаний, имеет некоторые недостатки, такие как небольшой объем, неширокий ассортимент и чрезмерное количество аномальных данных. Поэтому авторы предлагают усовершенствовать базу данных прогнозирования тепловой нагрузки путем включения в нее базовой информации об отоплении, базы данных о работе отопительной системы и базы данных пользователей тепла;

- набор данных для прогнозирования тепловой нагрузки может быть установлен и разделен по признакам своевременности, достоверности и регулярности. Это будет способствовать повышению точности и эффективности обобщения модели прогнозирования. На современном этапе никто не предложил четкого стандарта разделения данных в области отопления.

СПИСОК ЛИТЕРАТУРЫ

1. **Building-to-grid** predictive power flow control for demand response and demand flexibility programs / M. Razmara, G.R. Bharati, D. Hanover, M. Shahbakhhti, S. Paudyal, R.D. Robinett // *Appl. Energy*. 2017. V. 203. P. 128–141. <https://doi.org/10.1016/j.apenergy.2017.06.040>
2. **International** Energy Agency, *Transition to Sustainable Buildings*. IEA, Paris, 2013.
3. **Heat** roadmap Europe: Combining district heating with heat savings to decarbonise the EU energy system / D. Connolly, H. Lund, B.V. Mathiesen, S. Werner, B. Moeller, U. Persson, T. Boermans, D. Trier, P.A. Ostergaard, S. Nielsen // *Energy Policy*. 2014. V. 65. P. 475–489. <https://doi.org/10.1016/j.enpol.2013.10.035>
4. **A literature** review of energy flexibility in district heating with a survey of the stakeholders' participation / M. Zheng, A. Knotzer, J.D. Billanes, N.J. Bo // *Renewable Sustainable Energy Rev.* 2020. V. 123. <https://doi.org/10.1016/j.rser.2020.109750>
5. **Liu A.H., Ye Z.C.** *China Statistical Yearbook*. Beijing: China Statistics Press, 2020 [in Chinese].
6. **4th generation** district heating (4GDH): integrating smart thermal grids into future sustainable energy systems / H. Lund, S. Werner, R. Wiltshir, S. Svendsen, J.E. Thorsen // *Energy*. 2014. V. 68. P. 1–11. <https://doi.org/10.1016/j.energy.2014.02.089>
7. **Deep** neural network-based impacts analysis of multimodal factors on heat demand prediction / Z.Y. Ma, J.Y. Xie, H.L. Li, Q. Sun, F. Wallin, Z.W. Si, J. Guo // *IEEE Trans. Big Data*. 2020. V. 6. No. 3. P. 594–605. <https://doi.org/10.1109/TBDATA.2019.2907127>
8. **Study** on correction method for abnormal operation data of heating network / J.C. Guo, Y. Lan, P.N. Xue, Z.G. Zhou, J. Liu // *Gas and Heat*. 2020. No. 11. V. 40. <https://doi.org/10.13608/j.cnki.1000-4416.2020.11.002>
9. **Tian J.Z.Q., Wang M.P.** Heating load prediction based on support vector regression machine with parameters optimized by genetic algorithm // *Heat. Vent. Air Cond.* 2017. V. 47. No. 2. P. 104–108.
10. **Primary** network operational optimization and algorithm of a district heating system / S.J. Zhou, J.H. Pan, Q.F. Wang, Y.E. Zhao, M.C. Tian // *J. Beijing Univ. Technol.* 2012. V. 38. No. 4. P. 628–635.
11. **Heating** load prediction based on attention long short term memory: A case study of Xingtai / G.X. Xue, C.Y. Qi, H. Li, X. Kong, J.C. Song // *Energy*. 2020. V. 203. P. 117846. <https://doi.org/10.1016/j.energy.2020.117846>
12. **Multi-step** ahead forecasting of heat load in district heating systems using machine learning algorithms / P.N. Xue, Y. Jiang, Z.G. Zhou, X. Chen, X.M. Fang, J. Liu // *Energy*. 2019. V. 188. P. 116085. <https://doi.org/10.1016/j.energy.2019.116085>
13. **Applied** machine learning: Forecasting heat load in district heating system / S. Idowu, S. Saguna, C. Ahlund, O. Schelén // *Energy Build.* 2016. V. 133. P. 478–488. <https://doi.org/10.1016/j.enbuild.2016.09.068>
14. **Heat** load prediction in district heating systems with adaptive neuro-fuzzy method / S. Shamshirband, D. Petković, R. Enayatifar, A.H. Aboullah, D. Markovic, M. Lee, R. Ahmad // *Renewable Sustainable Energy Rev.* 2015. V. 48. P. 760–767. <https://doi.org/10.1016/j.rser.2015.04.020>
15. **Lang K., Zhang M.Y., Yuan Y.B.** Application of extreme learning machine with kernels model based on iterative error correction in short term electricity load forecasting // *J. Comput. Appl.* 2015. V. 35. No. 7. P. 2083–2087.
16. **A forecasting** method of district heat load based on improved wavelet neural network / Z. Zhang, Y. Liu, L. Cao, H. Si // *J. Energy Resour. Technol.* 2020. V. 142. No. 10. P. 102102 (7 pages). <https://doi.org/10.1115/1.4047020>
17. **Forecasting** of consumers heat load in district heating systems using the support vector machine with a discrete

- wavelet transform algorithm / M. Protić, S. Shamshirband, D. Petković, A. Abbasi, M.L.M. Kiah, J.A. Unar, L. Zivkovic, M. Raos // *Energy*. 2015. V. 87. P. 343–351.
<https://doi.org/10.1016/j.energy.2015.04.109>
18. **Prediction** of heat load in district heating systems by Support Vector Machine with Firefly searching algorithm / E.T. Al-Shammari, A. Keivani, S. Shamshirband, A. Mostafaipour, P.L. Yee, D. Petkovic, S. Ch // *Energy*. 2016. V. 95. P. 266–273.
<https://doi.org/10.1016/j.energy.2015.11.079>
 19. **Comparison** of several centralized heating load forecasting models / X.J. Yu, J.H. Gu, C.Y. Qi, C.H. Sun // *Heat. Vent. Air Cond.* 2019. V. 49. No. 2. P. 96–99.
 20. **Zhang J., Tian Q., Wang M.P.** Heating load prediction based on support vector regression machine with parameters optimized by genetic algorithm // *Heat. Vent. Air Cond.* 2017. V. 47. No. 2. P. 104–108.
 21. **Operational** demand forecasting in district heating systems using ensembles of online machine learning algorithms / C. Johansson, M. Bergkvist, D. Geysen, O. De Somer, N. Lavesson, D. Vanhoudt // *Energy Procedia*. 2017. V. 116. P. 208–216.
<https://doi.org/10.1016/j.egypro.2017.05.068>
 22. **A least** square support vector machine prediction algorithm for chaotic time series based on the iterative error correction / Z.J. Tang, F. Ren, T. Peng, W.B. Wang // *Acta Phys. Sin.* 2014. V. 63. No. 5. P. 050505.
<https://doi.org/10.7498/aps.63.050505>
 23. **Dalipi F., Yayilgan S.Y., Gebremedhin A.** Data-driven machine-learning model in district heating system for heat load prediction: a comparison study // *Appl. Comput. Intell. Soft Comput.* 2016. V. 2016.
<https://doi.org/10.1155/2016/3403150>
 24. **Dahl M., Brun A., Andresen G.B.** Using ensemble weather predictions in district heating operation and load forecasting // *Appl. Energy*. 2017. V. 193. P. 455–465.
<https://doi.org/10.1016/j.apenergy.2017.02.066>
 25. **Sholahudin S., Han H.** Simplified dynamic neural network model to predict heating load of a building using Taguchi method // *Energy*. 2016. V. 115. Part 3. P. 1672–1678.
<https://doi.org/10.1016/j.energy.2016.03.057>
 26. **Evaluation** of the most influential parameters of heat load in district heating systems / D. Petković, M. Protić, S. Shamshirband, S. Akib, M. Raos, D. Markovic // *Energy Build.* 2015. V. 104. P. 264–274.
<https://doi.org/10.1016/j.enbuild.2015.06.074>
 27. **Fang T.T., Lahdelma R.** Evaluation of a multiple linear regression model and SARIMA model in forecasting heat demand for district heating system // *Appl. Energy*. 2016. V. 179. P. 544–552.
<https://doi.org/10.1016/j.apenergy.2016.06.133>
 28. **Identifying** the most significant input parameters for predicting district heating load using an association rule algorithm / Y.F. Liu, X.X. Hu, X. Luo, Y. Zhou, D.J. Wang, S. Farah // *J. Cleaner Prod.* 2020. V. 275. P. 122984.
<https://doi.org/10.1016/j.jclepro.2020.122984>
 29. **Popescu D., Ungureanu F., Hernández-Guerrero A.** Simulation models for the analysis of space heat consumption of buildings // *Energy*. 2009. V. 34. Is. 10. P. 1447–1453.
<https://doi.org/10.1016/j.energy.2009.05.035>
 30. **Liu P.F., Li R., Wang Y.** Prediction of district heating load based on grey neural network model // *Heat. Vent. Air Cond.* 2019. V. 49. No. 5. P. 124–128.
<https://doi.org/10.12783/dtcese/ammms2018/27287>
 31. **Wang Y.Y., Wang P., Duan Y.J.** Selection of water-mixing connection structures and power analysis of pumps in heating system // *Heat. Vent. Air Cond.* 2014. V. 44. No. 9. P. 66–70.
 32. **Analysis** on influencing factors of heating load based on grey correlation degree / N. Xu, C.L. Wu, Q. Fu, K. Chen, L.H. Zhu // *Build. Energy Environ.* 2019. V. 38. No. 11. P. 19–22.
 33. **Appraisal** of soft computing methods for short term consumers' heat load prediction in district heating systems / M. Protić, S. Shamshirband, M.H. Anisi, D. Petkovic, D. Mitic, M. Raos, M. Arir, K.A. Alam // *Energy*. 2015. V. 82. P. 697–704.
<https://doi.org/10.1016/j.energy.2015.01.079>
 34. **The role** of data sample size and dimensionality in neural network based forecasting of building heating related variables / M. Macas, F. Moretti, A. Fonti, A. Giantomassi, G. Comodi, M. Annunziato, S. Pizzuti, A. Capara // *Energy Build.* 2016. V. 111. P. 299–310.
<https://doi.org/10.1016/j.enbuild.2015.11.056>
 35. **Sample** data selection method for improving the prediction accuracy of the heating energy consumption / T.H. Yuan, N. Zhu, Y.F. Shi, C. Chang, K. Yang, Y. Ding // *Energy Build.* 2018. V. 158. P. 234–243.
<https://doi.org/10.1016/j.enbuild.2017.10.006>
 36. **An analyze** of long-term hourly district heat demand forecasting of a commercial building using neural networks / A. Sandberg, F. Wallin, H. Li, M. Azaza // *Energy Procedia*. 2017. V. 105. P. 3784–3790.
<https://doi.org/10.1016/j.egypro.2017.03.884>
 37. **Thermal** load prediction model based on T-S fuzzy neural network / P. Jiang, B.G. Zhao, H.W. Zhang, L.F. Li, P.C. Wang, X.F. Wang, W.X. Yuan // *Process Autom. Instrum.* 2019. V. 40. No. 11. P. 20–23.
<https://doi.org/10.16086/j.cnki.issn1000-0380.2019010034>
 38. **Study** and application of intelligent dispatch technology for steam heating networks in industrial parks / Q. Ye, H.L. Sun, F.Q. Kong, Y.F. Wang, Q. Zhao, W. Zhong, F.J. Li, G.T. Ju // *Huadian Technol.* 2020. V. 42. No. 11. P. 6–13.
 39. **Analysis** of key factors in heat demand prediction with neural networks / J.Y. Xie, H.L. Li, Z.Y. Ma, Q. Sun, F. Wallin, Z.W. Si, J. Guo // *Energy Procedia*. 2017. V. 105. P. 2965–2970.
<https://doi.org/10.1016/j.egypro.2017.03.704>
 40. **Potočnik P., Strmčnik E., Govekar E.** Linear and neural network-based models for short-term heat load forecasting // *Strojnicki vestnik – J. Mech. Eng.* 2015. V. 61. Is. 9. P. 543–550.
<https://doi.org/10.5545/sv-jme.2015.2548>
 41. **Zhao B.W., Li W., Jin Y.** Heating load prediction based on PSO-LSSVM // *Build. Energy Effic.* 2021. V. 49. No. 6. P. 46–49.

Analysis on the Technical Situation and Applied Difficulties of District Heating Load Forecasting

Bingwen Zhao^a, Yu Jin^{a, *}, Wan Li^a, and Hanyu Zheng^a

^a Zhejiang Sci-Tech University, Xiasha Higher Education Zone, Hangzhou, Zhejiang, 310018 P.R. China

*e-mail: 1042809345@qq.com

Abstract—As an effective means of energy use, district heating is widely used all over the world. The 4th generation of district heating further puts forward the concept of smart thermal grids and emphasizes the application of heating load prediction technology. This paper mainly reviews the three core elements of data preprocessing, modeling method and input eigenvalue, which affects the accuracy of heating load prediction. At the same time, based on the actual engineering investigation, the difficulties in the application of heating load forecasting in actual engineering are analyzed. On this basis, in order to promote the adoption rate of the 4th generation district heating, the application of heating load prediction in practical engineering is optimized from the following two aspects: enrich and perfect the heating load forecasting database to provide sufficient data support for the heating load forecasting; A partitioning scheme for data set construction of heating load prediction model is proposed in order to improve the accuracy of the prediction model. In order to prove the applicability of the proposed methods, the methods are applied to a district heating system in Kaifeng, and the results show that the prediction effect is obviously improved.

Keywords: district heating, heat load forecast, smart thermal grids, database, heating demand, pipe network, heat station

Свидетельство о регистрации средства массовой информации
ПИ № ФС77-79408 от 27 ноября 2020 г., выдано Федеральной службой по надзору в сфере связи,
информационных технологий и массовых коммуникаций (Роскомнадзор)

Подписано к печати 10.12.2019 г.

Формат 60 × 88¹/₈

Тираж 301 экз.

Усл. печ. л. 9.53

Дата выхода в свет 28.02.2020 г.

Уч.-изд. л. 9.75

Цена свободная

Учредители: Российская академия наук,
Национальный исследовательский университет «Московский энергетический институт»

Издатель: ООО «ТЕМАТИЧЕСКАЯ РЕДАКЦИЯ»,
125252, г. Москва, ул. Зорге, д. 19, этаж 3, помещ. VI, комн. 44
Отпечатано в типографии «Book Jet» (ИП Коняхин А.В.),
390005, г. Рязань, ул. Пушкина, 18, тел. (4912) 466-151