

ПРОГНОЗИРОВАНИЕ ТЕПЛОВОЙ НАГРУЗКИ  
ДЛЯ СИСТЕМ ЦЕНТРАЛИЗОВАННОГО ТЕПЛОСНАБЖЕНИЯ  
С ПОМОЩЬЮ МОДЕЛЕЙ TCN и CatBoost© 2023 г. С. Han<sup>a</sup>, М. Gong<sup>a</sup>, \*, J. Sun<sup>a</sup>, Y. Zhao<sup>a</sup>, L. Jing<sup>a</sup>, C. Dong<sup>b</sup>, Z. Zhao<sup>c</sup><sup>a</sup>Tianjin Key Laboratory of Film Electronic and Communication Devices,  
School of Integrated Circuit Science and Engineering, Tianjin University of Technology Tianjin, 300384 China<sup>b</sup>School of Computer Science and Engineering, Tianjin University of Technology, Tianjin, 300384 China<sup>c</sup>School of Social Sciences, Waseda University, Tokyo, Japan

\*e-mail: gmj790@163.com

Поступила в редакцию 10.07.2022 г.

После доработки 08.08.2022 г.

Принята к публикации 30.08.2022 г.

Для производства тепла и улучшения управления системами централизованного теплоснабжения (СЦТ) требуется точное прогнозирование тепловой нагрузки. Составить более достоверный прогноз можно с помощью наиболее передовых технологий. В настоящей статье для получения прогнозных данных о тепловой нагрузке СЦТ предложено использовать современные модели машинного обучения: временную сверточную сеть (temporal convolutional network – TCN) и категориальное повышение градиента (categorical boosting – CatBoost). Для проверки и сравнения работы моделей прогнозирования тепловой нагрузки TCN и CatBoost были выбраны две дополнительные показательные модели – дерево решений и множественная линейная регрессия. В качестве обучающего кейса для моделей использовались данные о тепловой нагрузке СЦТ в Тяньцзине (Китай). В качестве входных параметров для моделей выбирались две статистические рабочие характеристики (суточная и часовая тепловые нагрузки) СЦТ и четыре метеорологические (температура и относительная влажность наружного воздуха, скорость ветра и индекс качества воздуха). Представлены и проанализированы результаты прогноза по каждой из обученных моделей. Итоги расчетных экспериментов показали, что прогноз, полученный с помощью TCN и CatBoost, оказался более точным, чем с использованием классических моделей, при том что моделирование с CatBoost является более простым. Следовательно, методы TCN и CatBoost применимы для прогнозирования тепловой нагрузки СЦТ.

*Ключевые слова:* прогнозирование тепловой нагрузки, система централизованного теплоснабжения, CatBoost, TCN, дерево решений, линейная регрессия, глубокое обучение, машинное обучение, модель прогноза временного ряда

DOI: 10.56304/S0040363623090047

В настоящее время тепловые электростанции, на которых сжигаются ископаемые виды топлива или биомасса, являются основными элементами системы централизованного теплоснабжения Китая. Урбанизация в Китае привела к стремительному росту спроса на централизованное теплоснабжение [1, 2], к основным достоинствам которого можно отнести максимальное удобство использования, а также энергосбережение и снижение выбросов вредных веществ.

Изменение климата – глобальная проблема человечества. Во многих странах мира ведется политика по охране окружающей среды и предпринимаются меры по контролю выбросов парниковых газов. Так, Китай поставил своей целью пройти пик выброса парниковых газов к 2030 г. и достичь углеродной нейтральности к 2060 г. Пе-

реход от современных СЦТ к их четвертому поколению (4G СЦТ) – актуальная задача китайской национальной энергетической стратегии [3]. Одой из наиболее отличительных характеристик 4G СЦТ является управление на основе прогнозирующих моделей [4], с помощью которого можно предсказывать возможные потребности тепла и активно регулировать параметры работы СЦТ. Прогнозирование тепловой нагрузки – необходимое требование для реализации этой технологии.

Существующие модели прогнозирования тепловой нагрузки включают в себя, главным образом, модели белого ящика, основанные на физических уравнениях, и модели черного ящика, опирающиеся на ранее полученные данные. Первые прогнозируют теплотребление зданий с использованием группы физических уравнений для модели частей

здания или всего здания [5]. Для разработки модели белого ящика могут применяться несколько общепризнанных программ (EnergyPlus, TRNSYS и др.). Например, для расчета теплопотребления сверхвысотных зданий в работе [6] использовали TRNSYS. Для разработки модели белого ящика для прогнозирования нагрузки СЦТ требуются особые данные, получить которые очень трудно. В результате, хоть эти модели и являются более точными и однозначными, при составлении прогноза теплопотребления от СЦТ и принятии решений специалисты отдают предпочтение моделям черного ящика.

В моделях черного ящика для прогнозирования тепловой нагрузки используются оперативные данные, полученные при эксплуатации оборудования и систем. В предыдущие годы большинство моделей прогноза тепловой нагрузки СЦТ основывались на статистических моделях и их вариантах, таких как множественная линейная регрессия (multiple linear regression – MLR) [7], авторегрессионная модель скользящего среднего (autoregressive moving average – ARMA) [8] и статистический подход авторегрессионной интегрированной модели скользящего среднего (seasonal autoregressive integrated moving average – SARIMA) [9]. Статистические модели имеют несложные структуры, просты для понимания, но при использовании дают недостаточно точные результаты.

В отличие от статистических, модели машинного обучения более результативны. Многие авторы протестировали и проанализировали эффективность различных технологий машинного обучения при проведении оценки теплопотребления. Наиболее широко используемыми среди них являются метод опорных векторов (support vector machine – SVM) [10–14] и искусственные нейронные сети (artificial neural network – ANN) [15, 16]. Модели прогнозов временных рядов, основанные на стратегии увеличения градиента, также демонстрируют высокое качество и надежность и не требуют особенной подготовки входных данных. Один из методов повышения градиента – его экстремальный рост – был разработан для оценки теплопотребления СЦТ [17, 18]. Кроме того, некоторые авторы полагают, что комбинирование нескольких методов и уточнение параметров одного метода через алгоритм оптимизации являются лучшими способами повысить точность и обобщающую способность моделей [19–25].

Растущий объем измеряемых и собираемых оперативных данных СЦТ способствовал использованию глубокого обучения в проектах прогнозирования тепловой нагрузки. При глубоком обучении могут улавливаться более сложные взаимосвязи между тепловыми нагрузками и входными характеристиками. Обычный алгоритм глубокого обучения (deep neural network –

DNN) применялся для прогноза тепловой нагрузки для СЦТ в [26]. В [27, 28] было продемонстрировано, что глубокая нейронная сеть с долговременной краткосрочной памятью (long short term memory – LSTM), специально разработанная для обработки временных рядов, является мощным инструментом для оценки тепловой нагрузки СЦТ.

Фактически у любых алгоритмов имеются ограничения. Всегда целесообразно исследовать, какой из них работает лучше в контексте прогноза тепловой нагрузки СЦТ.

Временная сверточная сеть (TCN) – это новая модель прогнозирования временных рядов, хорошо себя зарекомендовавшая. В работе [29] TCN сравнивалась с рекуррентной нейронной сетью (recurrent neural network – RNN), LSTM и сетью с управляемыми рекуррентными блоками (gate recurrent unit – GRU) в одиннадцати различных вариантах моделирования временных последовательностей. TCN быстрее и точнее выполнила более девяти задач. Эта сеть предлагает альтернативное решение проблемы прогнозирования временных рядов, но результаты ее применения для прогнозирования энергопотребления по-прежнему отсутствуют.

Алгоритмы повышения градиента – это тоже прекрасные инструменты прогнозирования. Однако CatBoost, современная модель с повышением градиента, еще не использовалась для расчета тепловой нагрузки.

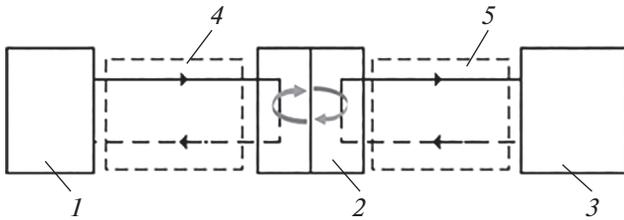
Чтобы изучить возможности TCN и CatBoost для прогнозирования тепловой нагрузки, в настоящей работе применяются данные о почасовой тепловой нагрузке СЦТ в Тяньцзине (Китай) для создания аналитической структуры. Основные идеи заключаются в следующем:

TCN и CatBoost используются для прогнозирования тепловой нагрузки (в качестве входных параметров выбираются две эксплуатационные характеристики СЦТ и четыре метеорологические характеристики);

для сравнения полученных с помощью TCN и CatBoost результатов выбраны традиционные инструменты прогнозирования – модель дерева решений (decision tree – DT) и модель MLR.

## ПРЕДПОСЫЛКИ ПРОГНОЗИРОВАНИЯ ТЕПЛОВОЙ НАГРУЗКИ

На рис. 1 представлена структура исследуемой СЦТ, состоящая из трех основных компонентов: источника тепла, теплораспределительного пункта и тепловых сетей. Источник тепла нагревает воду и передает в тепловой пункт через распределительную сеть. Тепловой пункт принимает тепло из первичных тепловых сетей, непрерывно нагревает воду вторичной тепловой сети и доставляет ее в здания для нужд отопления.



**Рис. 1.** Принципиальная схема СЦТ.  
 1 – источник тепла; 2 – тепловой пункт; 3 – здания;  
 4, 5 – первичный и вторичный контуры; сплошные  
 линии – прямая сетевая вода; штриховые линии – об-  
 ратная сетевая вода

Исследуемая СЦТ используется только для отопления помещений и не обеспечивает жильцов горячей водой для бытовых нужд. На ее базе была выстроена система сбора информации о прогнозируемых погодных изменениях и о работе СЦТ в режиме реального времени. Тепловая нагрузка СЦТ  $Q$ , кВт, для зданий рассчитывается по формуле

$$Q = \frac{c\rho q(t_s - t_r)}{3.6 \times 10^6},$$

где  $c = 4.2 \times 10^3$  Дж/(кг · К) – удельная теплоемкость воды;  $\rho$  – плотность воды при температуре 32°C (средней между температурой воды, подаваемой во вторичный контур,  $t_s$  и температурой возвращаемой воды  $t_r$ ), равная  $0.995 \times 10^3$  кг/м<sup>3</sup>;  $q$  – объемный расход теплоносителя, м<sup>3</sup>/ч.

С учетом того что частая регулировка расхода может стать причиной разбалансировки системы, принимается фиксированный расход теплоносителя для управления тепловой нагрузкой СЦТ путем изменения его температуры. Измеренное значение  $q$  составляет 400 м<sup>3</sup>/ч.

Система централизованного теплоснабжения инертна: производителю тепла необходимо заранее так настроить его поставку, чтобы она удовлетворяла требованиям потребителей. Прогнозирование тепловых потерь может быть ориентиром для предварительной корректировки отопления, при том что  $c$ ,  $\rho$  и  $q$  – постоянные параметры. Автоматическая система контроля может показывать разницу между температурами воды, подаваемой во вторичный контур и возвращаемой из него согласно прогнозируемой тепловой нагрузке. Температура  $t_s$  регулируется открытием запорно-регулирующей арматуры на тепловом пункте. Перепад температур подаваемого в сеть и возвращаемого водного теплоносителя поддерживается на заданном уровне. Таким образом осуществляется точная регулировка тепловой нагрузки. В итоге, прогнозирование, направленное на оптимизацию производства тепловой энергии и точное регулирование нагрузки СЦТ, имеет важное для нее значение. Данная статья посвящена прогнозиро-

ванию потребления зданиями тепла в течение часа, следующего после поступления его в СЦТ.

## МЕТОДЫ МОДЕЛИРОВАНИЯ

### Временная сверточная сеть (TCN)

Временная сверточная сеть предназначена для прогнозирования временной последовательности. Метод основан на двух принципах:

результат прогноза  $\hat{y}_t$  зависит от наблюдаемой последовательности  $\{x_0, \dots, x_t\}$ ;

TCN принимает временные ряды любой длины и выводит временные ряды той же длины.

В TCN обработка временных рядов осуществляется с помощью функции отображения

$$\hat{y}_0, \dots, \hat{y}_t = f(x_0, \dots, x_t).$$

Целью моделирования последовательности является обучение структуры, которая минимизирует функцию затрат  $L[y_0, \dots, y_t, f(x_0, \dots, x_t)]$  между фактическими и прогнозируемыми результатами. Структура TCN включает в себя случайные свертки, расширенные свертки и остаточные блоки.

**Случайные свертки:** TCN использует причинно-следственные свертки для удовлетворения первого принципа метода. Элемент  $i_{th}$  выходной последовательности может зависеть только от элементов с индексами  $\{0, \dots, t\}$  во входной последовательности. Кроме того, чтобы выходная последовательность имела ту же длину, что и входная, TCN необходимо выполнить операцию заполнения нулем, а TCN заполняет нулем только с левой стороны входной последовательности.

**Расширенные свертки:** базовая случайная свертка может просматривать только истории, линейные по размеру в глубине сети, что затрудняет применение вышеуказанных причинно-следственных сверток к задачам моделирования более длительных последовательностей. Для решения этой проблемы вводятся расширенные свертки  $F$  для элемента  $s$  входной последовательности  $x$ , которые выражаются следующим образом:

$$F(s) = (x_{*d}f)(s) = \sum_{i=0}^{k-1} [f(i)x_{s-di}],$$

где  $d$  – коэффициент расширения;  $k$  – размер фильтра;  $s - di$  – предыдущий ориентир.

Установка определенных интервалов между соседними фильтрами потоков входных данных называется расширенной сверткой. Расширенная свертка становится обыкновенной, когда  $d = 1$ . Следует отметить, что коэффициент расширения увеличивается по мере углубления сети. Это гарантирует, что некоторые фильтры будут попа-

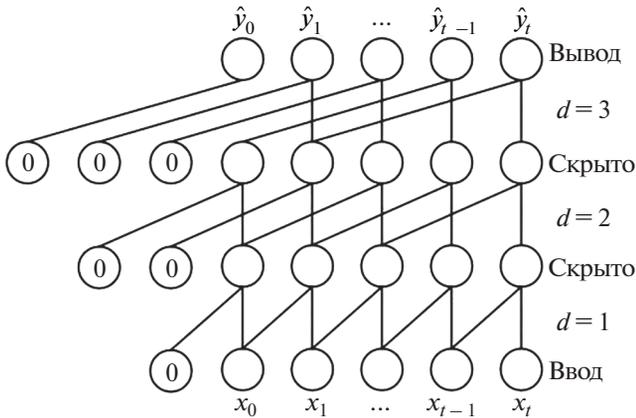


Рис. 2. Пример расширенной причинно-следственной свертки (коэффициенты расширения  $d = 1, 2, 4$ , размер фильтра  $k = 3$ )

дать на все входные данные в изучаемой истории (рис. 2).

**Остаточные блоки:** если рассмотреть блок нейронной сети, входом которого являются  $x$ , то после серии преобразований будет получено распределение истинных результатов  $H(x)$ . Разница (невязка) между выходными и входными данными будет определяться набором остатков  $F(x) = H(x) - x$ . Следовательно, поиск истинных результатов может быть осуществлен путем изучения остатков по идентификационной связи  $H(x) = x + F(x)$ :

$$o = \text{Activation}(x + F(x)),$$

где  $o$  – вывод остаточного блока;  $\text{Activation}$  – функция активации.

Это позволяет слоям учитывать изменения результатов преобразования в сравнении с исходными данными, что выгодно отличает глубокие сети от других.

Область восприятия определяется глубиной сети  $n$ , коэффициентом расширения  $d$  и размером фильтра  $k$ . Если результаты прогнозирования зависят от большого объема архивной статистической информации и многомерных входных последовательностей, то может потребоваться очень глубокая сеть. Как следствие, для поддержания стабильности TCN объединяет не сверточные слои в глубокую сеть, а остаточные блоки.

Как показано на рис. 3, один остаточный блок содержит два расширенных случайных сверточных слоя. Выпрямленная линейная функция активации (rectified linear unit – ReLU) применяется для преобразования нелинейности. Нормирование веса выполняется для каждого фильтра. Пространственный отсев используется, чтобы упорядочить расширенный случайный сверточный слой: весь канал обнуляется на каждой итерации обучения.

Поскольку вход остаточного блока и выход остаточного соединения могут иметь разную ширину, их нельзя напрямую суммировать. TCN использует свертку  $1 \times 1$ , чтобы устранить несоответствие ширины ввода-вывода.

### Категориальное повышение (CatBoost)

CatBoost – это новый метод повышения градиента, разработанный в 2018 г. [30]. По сравнению с другими алгоритмами дерева принятия решений с повышением градиента (GBDT), он имеет несколько отличительных характеристик.

Во-первых, CatBoost может обрабатывать не только числовые, но и категориальные признаки на этапе обучения. В CatBoost целевая статистика – эффективный подход к работе с категориальными переменными с наименьшими потерями информации (точная методика описана в [30]).

Во-вторых, CatBoost использует упорядоченное повышение, чтобы предотвратить смещение прогноза, характерное для типичных моделей GBDT (см. алгоритм 1 в [30] для конкретной методики). CatBoost генерирует несколько упорядоченных перестановок обучающего набора. Они применяются для повышения надежности CatBoost – получения градиентов предсказаний при перестановке значений признака. Обучение различных моделей при разных перестановках позволит избежать переобучения.

Наконец, CatBoost использует забывчивые деревья решений в качестве базовых предсказателей. Такая модель имеет довольно слабое сходство с обычным решающим деревом, хотя и строится по тем же правилам. Забывчивые решающие деревья разрабатывались для задач с большим числом нерелевантных признаков. Этот тип дерева менее уязвим для переобучения.

### ЭКСПЕРИМЕНТАЛЬНАЯ СТРУКТУРА

Процесс прогнозирования тепловой нагрузки, как правило, состоит из шести этапов.

Первый этап – интеграция данных: объединяются различные источники данных. Авторы настоящей публикации собрали исторические сводки о тепловой нагрузке СЦТ с 17 февраля по 22 марта 2018 г.

Второй этап – предварительная обработка данных: устраняются аномалии в данных о тепловой нагрузке, а отсутствующие показатели дополняются. Недостающие эксплуатационные характеристики СЦТ и температуру наружного воздуха получают путем линейной интерполяции, в то время как данные о скорости ветра и индексе качества воздуха – с помощью расчетного метода. Наконец, что касается TCN, то входные данные должны быть масштабированы таким образом,

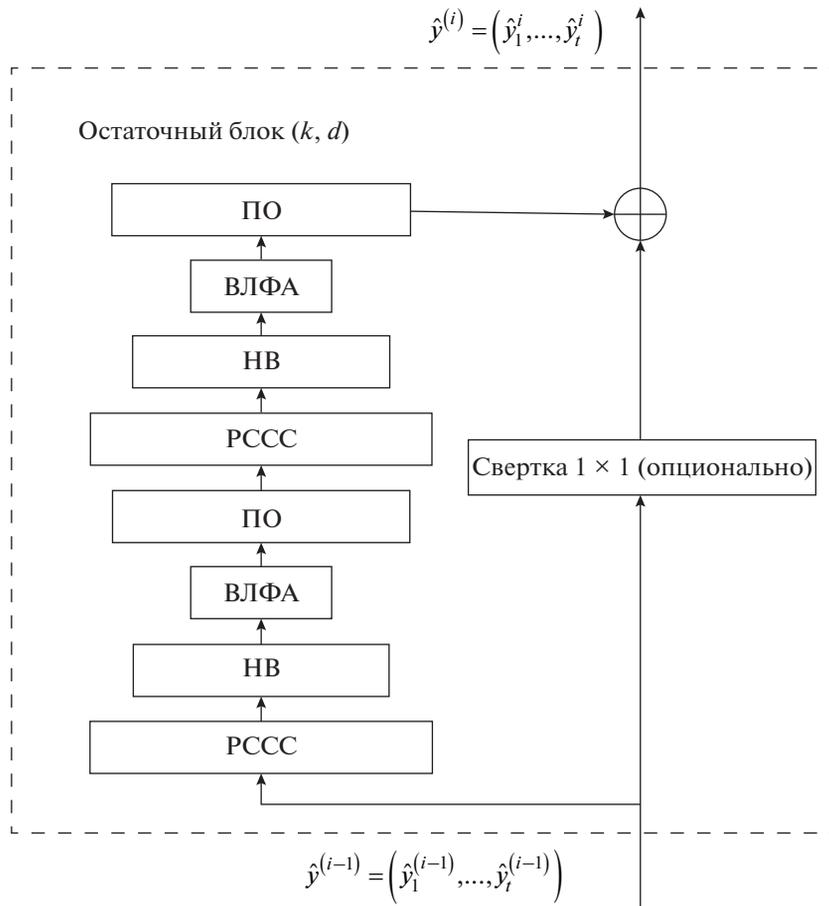


Рис. 3. Принципиальная схема остаточного блока.

ПО – пространственный отсев; ВЛФА – выпрямленная линейная функция активации; НВ – нормированные веса; РССС – расширенный случайный сверточный слой

чтобы они были приведены в заданный диапазон. В настоящем исследовании выбрана нормализация [min; max] для преобразования данных в диапазон 0–1:

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}}; \quad x = x'(x_{\max} - x_{\min}) + x_{\min}.$$

Третий этап – разделение данных: 72 выборки берутся в качестве тестовых данных, а остальные рассматриваются как обучающие.

На четвертом этапе тренировочный набор используется для обучения моделей прогнозирования.

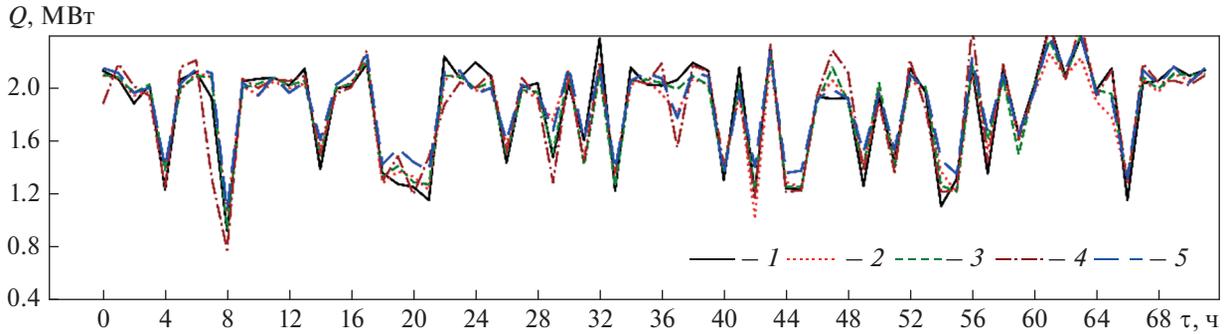
Оценка модели (пятый этап) происходит после обучения моделей и заключается в использовании набора тестов для проверки их (моделей) производительности. Что касается подходов к анализу ошибок прогнозирования (mean error – ME), то выбираются среднеквадратическая ошибка (mean square error – MSE), средняя абсолютная ошибка (mean absolute error – MAE) и коэффициент вариации среднеквадратической ошибки (со-

efficient of variation of root mean square error – CVRMSE). Первый показатель отражает надежность алгоритма, второй – реальную ситуацию с ошибкой прогнозирования, а третий представляет собой безразмерную метрику, позволяющую избежать эффекта масштаба. Меньшие значения MSE, MAE и CVRMSE означают более качественный прогноз модели. Данные показатели определяются следующим образом:

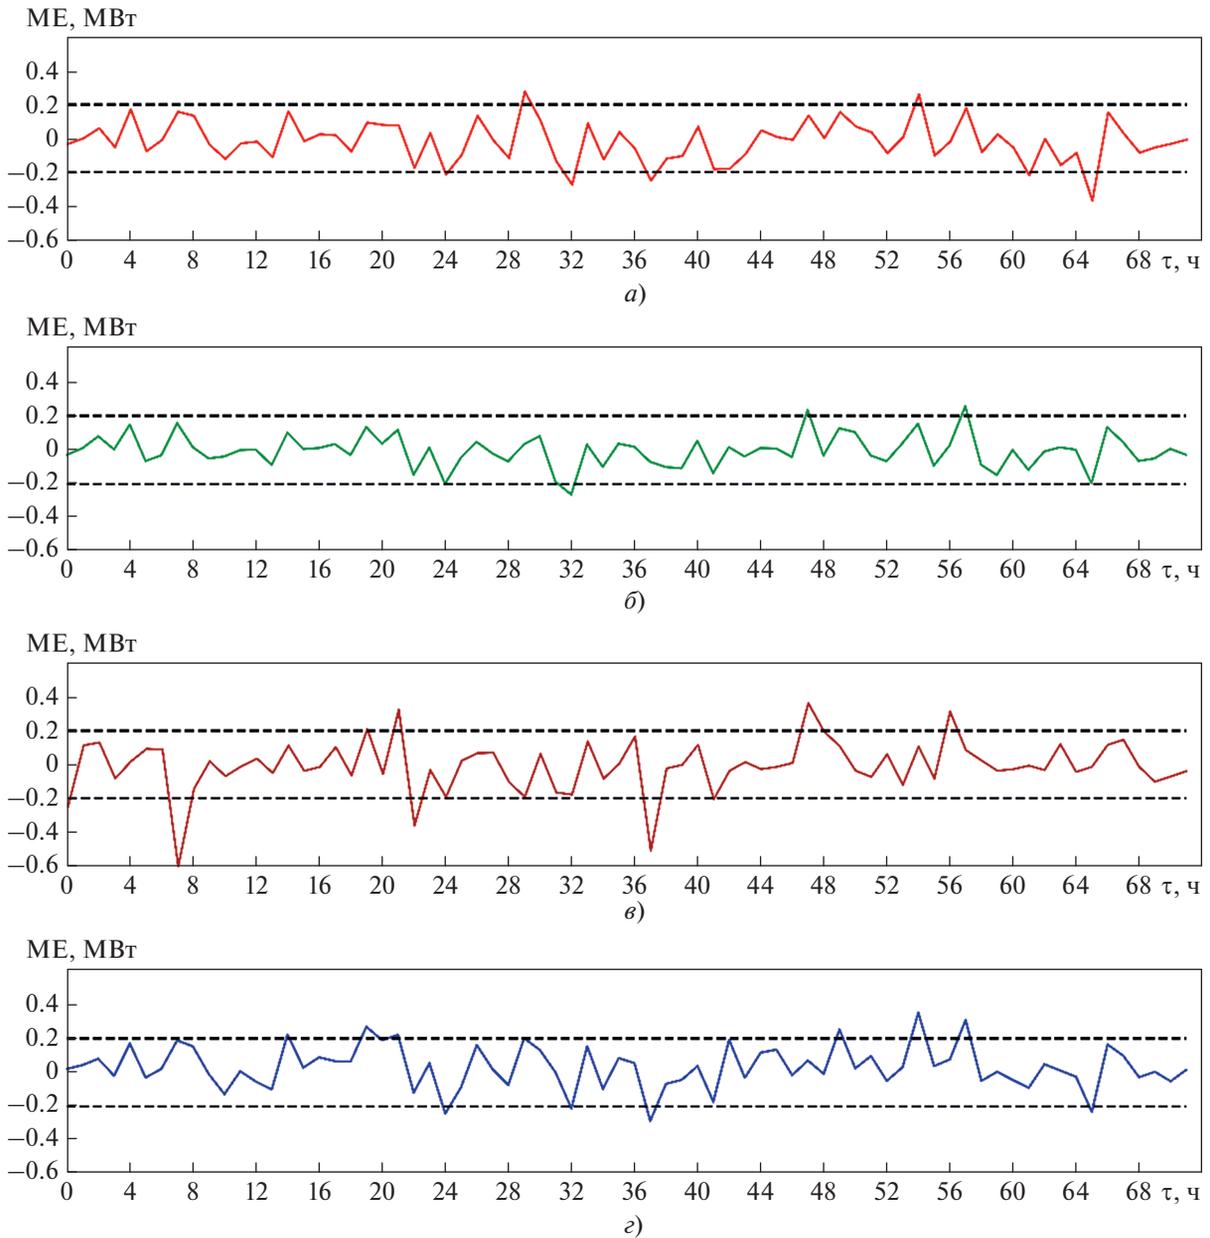
$$MSE = \frac{1}{n} \sum_{i=1}^n (Q_i - \hat{Q}_i)^2; \quad MAE = \frac{1}{n} \sum_{i=1}^n |Q_i - \hat{Q}_i|;$$

$$CVRMSE = \frac{\sqrt{\frac{1}{n} \sum_{i=1}^n (Q_i - \hat{Q}_i)^2}}{\frac{1}{n} \sum_{i=1}^n Q_i} \times 100\%,$$

где  $\hat{Q}_i$  и  $Q_i$  – прогнозируемая и фактическая тепловая нагрузка в час  $i$ , МВт;  $n$  – общее число прогнозируемых часов.



**Рис. 4.** Результаты прогнозирования тепловой нагрузки  $Q$  СЦТ для всех моделей на тестовой выборке. 1 – фактическая; нагрузка, определенная с помощью: 2 – TCN; 3 – CatBoost; 4 – DT; 5 – MLR



**Рис. 5.** Ошибка прогнозирования ME при использовании моделей TCN (а), CatBoost (б), DT (в) и MLR (г) на тестовой выборке в каждый момент времени  $\tau$

Статистические показатели моделей в тестовом наборе

Модель	MSE, МВт	MAE, МВт	CVRMSE, %
TCN	0.0153	0.0962	0.0667
CatBoost	0.0091	0.0711	0.0516
DT	0.0244	0.1080	0.0844
MLR	0.0169	0.0989	0.0702

Последний, шестой, этап (анализ результатов прогнозирования) основан на их визуализации в тестовом наборе для каждой модели, в результате чего можно наблюдать и оценивать их эффективность.

## РЕЗУЛЬТАТЫ И ОБСУЖДЕНИЕ

Итак, исходные данные о тепловой нагрузке известны и прерываются случайным образом. 72 выборки выделены в тестовый набор, для которого на рис. 4 представлены прогнозные кривые для всех моделей. На рис. 5 можно наблюдать различия между прогнозируемыми и фактическими значениями в каждый момент времени. В таблице приведены статистические показатели для каждой модели из тестового набора.

В [17] утверждается, что значение CVRMSE не должно превышать 30% для моделей, используемых в промышленности. Из таблицы следует, что этому критерию удовлетворяют все модели прогнозирования. Что еще более важно, по сравнению с базовыми моделями, TCN и CatBoost дают более точные и надежные результаты прогнозирования (CatBoost показывает наиболее совершенные результаты). Точность предсказания TCN немного ниже, чем у CatBoost, но лучше, чем у MLR и DT. Как видно на рис. 5, а и б, ошибки прогнозирования TCN и CatBoost в определенной степени меняются в зависимости от колебаний фактической тепловой нагрузки, но в большинстве моментов времени находятся в пределах 10%. Прогнозы MLR (см. рис. 5, г) при некоторых минимальных значениях всегда превышают фактическую тепловую нагрузку, что ведет к перерасходу тепловой энергии. Ошибка предсказания DT (см. рис. 5, в) относительно велика: ее прогнозы в момент времени 7 и 37 ч особенно неточны.

## ВЫВОДЫ

1. Результаты расчетного эксперимента подтвердили, что все четыре модели черного ящика: TCN, CatBoost, DT, MLR – могут быть применены для прогнозирования тепловой нагрузки СЦТ. Коэффициент вариации среднеквадратической

ошибки прогноза тепловой нагрузки не превысил 10% при известном ограничении 30%.

2. При использовании для прогнозирования моделей временных рядов TCN и повышения градиента CatBoost были получены более точные результаты, чем по модели дерева решений DT и статистической модели множественной линейной регрессии MLR. Ошибки прогноза TCN и CatBoost в большинстве моментов времени находились в пределах 10%.

3. Поскольку при реализации модели на основе деревьев решений не требуется нормализация входных данных, процесс моделирования с помощью CatBoost является менее трудозатратным, чем с использованием TCN.

## СПИСОК ЛИТЕРАТУРЫ

1. **Case study on industrial surplus heat of steel plants for district heating in Northern China** / Y.M. Li, J.J. Xia, H. Fang, Y.B. Su, Y. Jiang // *Energy*. 2016. V. 102. P. 397–405. <https://doi.org/10.1016/j.energy.2016.02.105>
2. **Heat roadmap China: new heat strategy to reduce energy consumption towards 2030** / W. Xiong, Y. Wang, B.V. Mathiesen, H. Lund, X. Zhang // *Energy*. 2015. V. 81. P. 274–285. <https://doi.org/10.1016/j.energy.2014.12.039>
3. **Smart energy systems and 4th generation district heating** / H. Lund, N. Duic, P.A. Østergaard, B.V. Mathiesen // *Energy*. 2016. V. 110. P. 1–4. <https://doi.org/10.1016/j.energy.2016.07.105>
4. **The status of 4th generation district heating: research and results** / H. Lund, P.A. Østergaard, M. Chang, S. Werner, S. Svendsen, P. Sorknaes, J.E. Thorsen, F. Hvelplund, B.O.G. Mortensen, B.V. Mathiesen, C. Bojesen, N. Duic, X.L. Zhang, B. Moller // *Energy*. 2018. V. 164. P. 147–159. <https://doi.org/10.1016/j.energy.2018.08.206>
5. **Li X.W., Wen J.** Review of building energy modeling for control and operation // *Renewable Sustainable Energy Rev.* 2014. V. 37. P. 517–537. <https://doi.org/10.1016/j.rser.2014.05.056>
6. **Cao J.L., Liu J., Man X.X.** A united WRF/TRNSYS method for estimating the heating/cooling load for the thousand-meter scale megatall buildings // *Appl. Therm. Eng.* 2017. V. 114. P. 196–210. <https://doi.org/10.1016/j.applthermaleng.2016.11.195>
7. **Applied machine learning: forecasting heat load in district heating system** // S. Idowu, S. Saguna, C. Ahlund, O. Schelen // *Energy Build.* 2016. V. 133. P. 478–488. <https://doi.org/10.1016/j.enbuild.2016.09.068>
8. **Huang S.J., Shih K.R.** Short-term load forecasting via ARMA model identification including non-Gaussian process considerations // *IEEE Trans. Power Syst.* 2003. V. 18. Is. 2. P. 673–679. <https://doi.org/10.1109/tpwrs.2003.811010>
9. **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>
10. **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. Mostafaiepour, P.L. Yee, D. Petkovic, S. Ch // *Energy*. 2016. V. 95. P. 266–273.  
<https://doi.org/10.1016/j.energy.2015.11.079>
  11. **Barman M., Choudhury N.B.D., Sutradhar S.** A regional hybrid GOASVM model based on similar day approach for short-term load forecasting in Assam, India // *Energy*. 2018. V. 145. P. 710–720.  
<https://doi.org/10.1016/j.energy.2017.12.156>
  12. **Prediction** of heat load fluctuation based on fuzzy information granulation and support vector machine / T. Wang, T.Y. Ma, D.S. Yan, J. Song, J.S. Hu, G.Y. Zhang, Y.H. Zhuang // *Therm. Sci.* 2021. V. 25. Is. 5. P. 3219–3228.  
<https://doi.org/10.2298/tsci200529307w>
  13. **Appraisal** of soft computing methods for short term consumers' heat load prediction in district heating systems / M. Protic, S. Shamshirband, M.H. Anisi, D. Petkovic, D. Mitic, M. Raos, M. Arif, K.A. Alam // *Energy*. 2015. V. 82. P. 697–704.  
<https://doi.org/10.1016/j.energy.2015.01.079>
  14. **Koschwitz D., Frisch J., van Treeck C.** Data-driven heating and cooling load predictions for non-residential buildings based on support vector machine regression and NARX recurrent neural network: A comparative study on district scale // *Energy*. 2018. V. 165. P. 134–142.  
<https://doi.org/10.1016/j.energy.2018.09.068>
  15. **GMM** clustering for heating load patterns in-depth identification and prediction model accuracy improvement of district heating system / Y. Lu, Z. Tian, P. Peng, J. Niu, W. Li, H. Zhang // *Energy Build.* 2019. V. 190. P. 49–60.  
<https://doi.org/10.1016/j.enbuild.2019.02.014>
  16. **Heat** load prediction of small district heating system using artificial neural networks / M.B. Simonovic, V.D. Nikolic, E.P. Petrovic, I.T. Ciric // *Therm. Sci.* 2016. V. 20. P. 1355–1365.  
<https://doi.org/10.2298/TSCI16S5355S>
  17. **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>
  18. **Prediction** of residential district heating load based on machine learning: A case study / Z.Q. Wei, T.W. Zhang, B. Yue, Y.X. Ding, R. Xiao, R.Z. Wang, X.Q. Zhai // *Energy*. 2021. V. 231. P. 120950.  
<https://doi.org/10.1016/j.energy.2021.120950>
  19. **Heating** and cooling loads forecasting for residential buildings based on hybrid machine learning applications: A comprehensive review and comparative analysis / A. Moradzadeh, B. Mohammadi-Ivatloo, M. Abapour, A. Anvari-Moghaddam, S.S. Roy // *IEEE Access*. 2022. V. 10. P. 2196–2215.  
<https://doi.org/10.1109/access.2021.3136091>
  20. **Operational** thermal load forecasting in district heating networks using machine learning and expert advice // D. Geysen, O. de Somer, C. Johansson, J. Brage, D. Vanhoudt // *Energy Build.* 20218. V. 162. P. 144–153.  
<https://doi.org/10.1016/j.enbuild.2017.12.042>
  21. **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>
  22. **Heat** load prediction of residential buildings based on discrete wavelet transform and tree-based ensemble learning / M.J. Gong, J. Wang, Y. Bai, B. Li, L. Zhang // *J. Build. Eng.* 2020. V. 32. P. 101455.  
<https://doi.org/10.1016/j.jobbe.2020.101455>
  23. **Eseye A.T., Lehtonen M.** Short-term forecasting of heat demand of buildings for efficient and optimal energy management based on integrated machine learning models // *IEEE Trans. Ind. Informatics*. 2020. V. 16. Is. 12. P. 7743–7755.  
<https://doi.org/10.1109/tii.2020.2970165>
  24. **Appraisal** of the support vector machine to forecast residential heating demand for the district heating system based on the monthly overall natural gas consumption // N. Izadyar, H. Ghadamian, H.C. Ong, Z. Moghadam, C.W. Tong, S. Shamshirband // *Energy*. 2015. V. 93. P. 1558–1567.  
<https://doi.org/10.1016/j.energy.2015.10.015>
  25. **Wu D.Z., Foong L.K., Lyu Z.J.** Two neural-meta-heuristic techniques based on vortex search and backtracking search algorithms for predicting the heating load of residential buildings // *Eng. Computers*. 2022. V. 38. Is. 1. P. 647–660.  
<https://doi.org/10.1007/s00366-020-01074-z>
  26. **District** heating systems load forecasting: a deep neural networks model based on similar day approach / M. Gong, H. Zhou, Q. Wang, S. Wang, P. Yang // *Adv. Build. Energy Res.* 2020. V. 14. Is. 3. P. 372–388.  
<https://doi.org/10.1080/17512549.2019.1607777>
  27. **Heating** load forecasting for combined heat and power plants via strand-based LSTM / J.Y. Liu, X. Wang, Y. Zhao, B. Dong, K. Lu, R.R. Wang // *IEEE Access*. 2020. V. 8. P. 33360–33369.  
<https://doi.org/10.1109/access.2020.2972303>
  28. **A comprehensive** thermal load forecasting analysis based on machine learning algorithms / S. Leiprecht, F. Behrens, T. Faber, M. Finkenrath // *Energy Rep.* 2021. V. 7. P. 319–326.  
<https://doi.org/10.1016/j.egy.2021.08.140>
  29. **Bai S., Kolter J.Z., Koltun V.J.** An empirical evaluation of generic convolutional and recurrent networks for sequence modeling. 2018.  
<https://doi.org/10.48550/arXiv.1803.01271>
  30. **CatBoost:** unbiased boosting with categorical features / L. Prokhorenkova, G. Gusev, A. Vorobev, A.V. Dorogush, A.J.A. Gulin. 20218. V. 31.

## Heat Load Prediction for District Heating Systems with Temporal Convolutional Network and CatBoost

C. Han<sup>a</sup>, M. Gong<sup>a, \*</sup>, J. Sun<sup>a</sup>, Y. Zhao<sup>a</sup>, L. Jing<sup>a</sup>, C. Dong<sup>b</sup>, and Z. Zhao<sup>c</sup>

<sup>a</sup> Tianjin Key Laboratory of Film Electronic and Communication Devices, School of Integrated Circuit Science and Engineering, Tianjin University of Technology, Tianjin, 300384 China

<sup>b</sup> School of Computer Science and Engineering, Tianjin University of Technology, Tianjin, 300384 China

<sup>c</sup> School of Social Sciences, Waseda University, Tokyo, Japanese

\*e-mail: gmj790@163.com

**Abstract**—Accurate heat load prediction is essential for heat production and refined management of district heating systems (DHSs). More advanced technology can often achieve more accurate forecasts. This paper suggests using temporal convolutional network (TCN) and categorical boosting (CatBoost) for heat load prediction. To test the performance of TCN and CatBoost in heat load prediction missions, two additional benchmark models, the decision tree model (DT) and the statistically based multiple linear regression (MLR), are built for comparison. A DHS in Tianjin, China, is used as the study case. Two historical operational characters (day-ahead heat load and hour-ahead heat load) and four meteorological characters (outdoor temperature, relative humidity, wind scale, and air quality index) are selected as input features for the models. The prediction results of every model on the test set are displayed and discussed. The experimental findings indicate that the prediction results of TCN and CatBoost are more accurate than the traditional prediction models, while the modeling process of CatBoost is simpler. Overall, TCN and CatBoost are potential heat load prediction methods.

**Keywords:** heat load prediction, district heating system, CatBoost, TCN, decision tree, linear regression, deep learning, machine learning, time series, prediction model