

## ПРОГНОЗИРОВАНИЕ ТЕПЛОВОЙ НАГРУЗКИ СИСТЕМ ЦЕНТРАЛИЗОВАННОГО ТЕПЛОСНАБЖЕНИЯ НА ОСНОВЕ SCSO-TCN

© 2024 г. M. Gong<sup>a</sup>, \*, C. Han<sup>a</sup>, J. Sun<sup>a</sup>, Y. Zhao<sup>a</sup>, S. Li<sup>b, c</sup>, W. Xu<sup>c, d</sup>

<sup>a</sup>School of Integrated Circuit Science and Engineering, Tianjin University of Technology, No. 391 Bin Shui Xi Dao Road, Xiqing District, Tianjin, 300384 China

<sup>b</sup>Tianjin University, Beiyang Ave, Nankai District, Tianjin, 300072 China

<sup>c</sup>Sea Island Environment Science and Technology Research Institute (Tianjin) Co., Ltd, Hetong Building, North Side of Anshan West Road Middle Section, Nankai District, Tianjin, 300072 China

<sup>d</sup>Institute of Marine Energy and Intelligent Construction, Tianjin University of Technology, No. 391 Bin Shui Xi Dao Road, Xiqing District, Tianjin, 300384 China

\*e-mail: gmj790@163.com

Поступила в редакцию 30.08.2022 г.

После доработки 25.12.2022 г.

Принята к публикации 25.01.2023 г.

Прогнозирование тепловой нагрузки играет важнейшую роль в регулировании систем централизованного теплоснабжения (СЦТ). Для этого часто используется алгоритм глубокого машинного обучения – временная сверточная сеть (the temporal convolutional network – TCN). Однако для настройки TCN требуется довольно много гиперпараметров. Ручная настройка временных сверточных сетей неэффективна. В настоящей работе предлагается гибридная модель, основанная на так называемой оптимизации стаи барханных (песчаных) котов (sand cat swarm optimization – SCSO) и TCN (SCSO-TCN). В этой модели для оптимизации используются следующие гиперпараметры: число фильтров, размеры фильтра, процент отсева и размер партии. Для проверки эффективности модели SCSO-TCN ее сравнивали с двумя другими гибридными моделями: оптимизацией роя частиц (particle swarm optimization – PSO) с TCN (PSO-TCN) и алгоритмом поиска воробья (sparrow search algorithm – SSA) с TCN (SSA-TCN). Для тестовых расчетов использовались данные о тепловой нагрузке трех тепловых пунктов, расположенных в г. Тяньцзин (Китай). Результаты расчетов показывают, что гибридная модель SCSO-TCN имеет более высокую точность прогнозирования и лучшую способность к обобщению, чем модели PSO-TCN и SSA-TCN.

**Ключевые слова:** прогнозирование тепловой нагрузки, регулирование тепловой нагрузки, система централизованного теплоснабжения, построение модели, глубокое обучение, временные сверточные сети, оптимизация стаи барханных (песчаных) котов [роевая оптимизация алгоритмов по принципу охоты барханных (песчаных) котов]

**DOI:** 10.56304/S0040363624040015

В настоящее время в мире насчитывается около 80 000 централизованных тепловых сетей (СЦТ) [1], которые являются частью городских энергетических структур. В СЦТ передача тепла осуществляется по тепловой сети от центрального источника тепла к потребителям по всему городу или определенному району. Системы централизованного теплоснабжения обладают такими достоинствами, как высокая эффективность использования энергии, незначительное воздействие на окружающую среду, удобство для потребителей [2]. Однако СЦТ имеют один очевидный существенный недостаток – инерционность [3]. Чтобы удовлетворить требования потребителей, тепловую нагрузку системы следует определять заранее. Поэтому точное прогнозирование тепловой нагрузки становится необходимостью [4].

Методика прогнозирования тепловой нагрузки СЦТ существенно зависит от применяемых моделей управления данными. В таких моделях используются в основном метеорологические данные, а также статистические данные по прогнозируемой потребности в количестве тепла. Ранее для построения таких моделей применялись следующие классические статистические модели: множественная линейная регрессия (multiple linear regression – MLR) [5], авторегрессионная модель скользящего среднего (autoregressive moving average model – ARMA) [6] и сезонная авторегрессионная интегрированная модель прогнозирования скользящего среднего (seasonal autoregressive integrated moving average – SARIMA) [7]. Преимуществами статистических моделей являются их простота и легкость для понимания, а их недо-

статками — низкая точность предсказания и чувствительность к выпадающим значениям.

Модели машинного обучения более эффективны. Машинное обучение позволяет выявить статистические закономерности, что дает возможность компьютерным системам генерировать точные прогнозы на основе предоставленного набора данных. К настоящему времени опубликовано довольно много работ, в которых оценивается производительность машинного обучения при прогнозировании тепловой нагрузки. Экспериментальные данные подтверждают, что прогнозы, полученные с помощью метода опорных векторов (support vector machine – SVM) [8–11], искусственной нейронной сети (artificial neural network – ANN) [12–14] и экстремального повышения градиента (XGBoost) [15, 16], являются более точными и стабильными, чем прогнозы, построенные по классическим моделям.

Глубокое машинное обучение позволяет установить сложную взаимосвязь между тепловыми нагрузками и входными характеристиками. В [17] для прогнозирования тепловой нагрузки предлагается гибридная модель, объединяющая метод отбора похожих дней и глубокую нейронную сеть (deep neural network – DNN). Использование такой гибридной модели значительно повышает точность прогноза. Рекуррентная нейронная сеть (recurrent neural network – RNN) [18] и сеть с долгой кратковременной памятью (long short-term memory network – LSTM) [19, 20] продемонстрировали превосходную производительность при прогнозировании потребления тепла в СЦТ. В [21] для прогнозирования тепловой нагрузки СЦТ применяется временная сверточная сеть (TCN). Авторы провели сравнение TCN с RNN и LSTM и выявили преимущества временной сверточной сети.

Однако качество прогноза, полученного с помощью TCN, существенно зависит от параметров модели. Для улучшения прогностической способности модели в некоторых опубликованных работах предлагается уточнять параметры модели с помощью алгоритмов оптимизации [22–24]. Авторы [25] для такого уточнения используют алгоритм поиска светлячков и метод опорных векторов SVM, что дает возможность повысить уровень прогнозирования модели. В [26] для изменения параметров SVM применяется алгоритм оптимизации кузнецов. Комбинирование различных методов — это способ сделать прогностическую модель более точной. Это побудило авторов настоящей работы найти такой алгоритм оптимизации гиперпараметров TCN, который позволил бы дополнительно улучшить адаптивность и точность оценки временной сверточной сети.

Не так давно в литературе началось обсуждение нового алгоритма оптимизации — оптимиза-

ции стаи барханных (песчаных) котов (SCSO) [27], который по сравнению с другими алгоритмами имеет несколько преимуществ:

позволяет сбалансированно контролировать переходы между стадиями поиска добычи (разведки) и нападения на нее;

требует наличия меньшего числа исходных данных и проведения меньшего количества вычислений;

может быть довольно легко реализован.

Эти преимущества побудили авторов данной работы использовать модель SCSO-TCN для прогнозирования тепловой нагрузки СЦТ, при этом SCSO применяется для поиска параметров TCN в пределах заранее определенной области.

Подробное описание СЦТ и принципа ее работы, предпосылок прогнозирования тепловой нагрузки, а также применения временной сверточной сети приведены в [28].

## ОПТИМИЗАЦИИ СТАИ БАРХАННЫХ (ПЕСЧАНЫХ) КОТОВ (SCSO)

Оптимизация SCSO имитирует поведение барханных (песчаных) котов, которые пытаются выжить в природе. Эти коты способны улавливать низкие частоты (ниже 2 кГц), а также обладают исключительными навыками охотника. Предлагаемый алгоритм, основанный на этих двух функциях, состоит из двух основных этапов [ поиск (разведка) и нападение (эксплуатация)] и сбалансированно контролирует переходы на этапах разведки и эксплуатации.

**Начальная популяция.** Для решения задачи оптимизации в первую очередь следует указать значения задействованных вариантов — количество барханных котов. При оптимизации  $p$ -размерности возможным решением является  $1 \times p$  с массивом  $\{x_1, x_2, \dots, x_p\}$ . Каждая переменная  $x_i$  должна находиться между верхней  $x_1$  и нижней  $x_p$  границами. Это гарантирует, что процесс оптимизации остается в пределах определенного пространства параметров.

Далее необходимо инициализировать матрицу размерами  $N_{pop} \times M_p$  ( $N_{pop}$  — размер популяции,  $M_p$  — переменное число).

**Разведка** (поиск добычи). Как уже отмечалось, барханный кот может слышать частоты ниже 2 кГц. Тем самым определяется диапазон чувствительности барханного кота. В математических уравнениях это означает, что чувствительность  $\tilde{r}_G$  уменьшается линейно от 2 до 0 согласно следующему выражению:

$$\tilde{r}_G = s_M - \frac{2s_M \text{iter}_c}{\text{iter}_{\max} + \text{iter}_{\max}}, \quad (1)$$

где  $s_M$  – гиперпараметр, имитирующий слуховые способности барханных котов;  $\text{iter}_c$  и  $\text{iter}_{\max}$  – номер текущей итерации и максимальное количество итераций.

Поскольку значение  $s_M$  получено на основе слуховых возможностей песчаного кота, ему присвоено значение 2. В зависимости от условий решаемой задачи значение  $s_M$  можно изменить.

Местоположение песчаного кота обновляется с помощью вектора  $\vec{R}$ :

$$\vec{R} = 2 \times \vec{r}_G \times \text{rand}(0,1) - \vec{r}_G. \quad (2)$$

При  $|\vec{R}| > 1$  поисковые агенты (песчаные коты) вынуждены искать цели (проводить разведку). При  $|\vec{R}| < 1$  поисковые агенты должны атаковать цели (эксплуатация – нападение на добычу). Благодаря такой стратегии, SCSO имеет хорошо сбалансированный переход от разведки к эксплуатации.

Каждый песчаный кот обладает собственной чувствительностью к побегу из локальной оптимальной ловушки, что описывается следующим выражением:

$$\vec{r} = \vec{r}_G \times \text{rand}(0,1). \quad (3)$$

Каждый песчаный кот оставляет свою позицию для лучшего кандидата на эту позицию. Это действие можно записать как

$$\vec{P}(t+1) = \vec{r} \times [\vec{P}_{bc}(t) - \text{rand}(0,1)\vec{P}_c(t)], \quad (4)$$

где  $\vec{P}_{bc}(t)$  – решение для лучшего кандидата (лучшее решение);  $\vec{P}_c(t)$  – текущее решение.

**Эксплуатация** (нападение на добычу). В период эксплуатации расстояние  $\vec{P}_{rnd}$  между лучшим решением  $\vec{P}_{bc}$  и текущим положением песчаного кота  $\vec{P}_c$  рассчитывается следующим образом:

$$\vec{P}_{rnd} = |\text{rand}(0,1) \cdot \vec{P}_{bc}(t) - \vec{P}_c(t)|. \quad (5)$$

Предполагается, что чувствительность каждого поискового агента (песчаного кота) представляет собой окружность, а направление его движения определяется случайным углом  $\theta$  на этой окружности. Для выбора угла в методе SCSO применяется колесо рулетки. Песчаный кот изменяет значения своих переменных в соответствии с уравнением

$$\vec{P}(t+1) = \vec{P}_{bc}(t) - \vec{r}\vec{P}_{rnd} \cos\theta. \quad (6)$$

## ТЕСТОВЫЙ ЭКСПЕРИМЕНТ

Основными факторами, влияющими на тепловую нагрузку, являются временные и погодные условия, параметры работы СЦТ и запросы потребителей. Временные факторы относятся к ме-

сяцу, дню и часу и отражают структуру загрузки потребителей. Другими словами, действия потребителей можно рассматривать как функцию временных факторов. В работе [29] отмечается, что влияние временных факторов на прогнозы незначительно. Поэтому в данной работе временные факторы как входные характеристики не рассматриваются.

Такие погодные условия, как температура наружного воздуха, относительная влажность, сила и направление ветра, индекс качества воздуха (air quality index – AQI) и др., оказывают существенное влияние на тепловую нагрузку. Внутренними характеристиками СЦТ являются температура, давление и скорость теплоносителя, а также тепловая инерция системы, которая обеспечивает корреляцию между статистическими и последующими отопительными нагрузками.

На базе СЦТ в г. Тяньцзин (Китай) авторы установили систему для сбора информации, в которую поступают данные о погоде и оперативные данные от трех тепловых пунктов (ТП): № 1, 2 и 3. Важными входными характеристиками считаются тепловая нагрузка на сутки вперед и на час вперед, температура наружного воздуха, относительная влажность, сила и направление ветра, а также AQI.

## Настройка и оценка точности модели

В поверочном эксперименте необработанный набор данных случайным образом разделяется на обучающий и тестовый наборы. Для ТП № 1 на тестовый набор выделяется 168 выборок, а остальные выборки приходятся на обучающий набор. Базы данных ТП № 2 и 3 являются менее наполненными. Обучающий набор должен охватывать определенный объем выборочных данных, чтобы обеспечить точность прогноза, полученного с помощью используемой модели. Так, для ТП № 2 и 3 имелось только 72 выборки, которые разбивались на тестовый и обучающий наборы.

Как уже отмечалось, для оптимизации TCN может использоваться SCSO, или оптимизация роя частиц (PSO), или алгоритм поиска воробьев (SSA). Ограничения сверху и снизу по количеству фильтров, размеру фильтра, проценту отсева и размеру партии выбраны следующим образом: [5, 20], [2, 10], [0.05, 0.3], [5, 30]. В табл. 1 перечислены гиперпараметры для рассматриваемых алгоритмов оптимизации.

Для оценки производительности модели применяется тестовый набор. Среднеквадратическая ошибка (mean squared error – MSE), средняя абсолютная ошибка (mean absolute error – MAE) и коэффициент вариации среднеквадратической ошибки (coefficient of variation of root mean square error – CVRRMSE) выбираются для оценки точ-

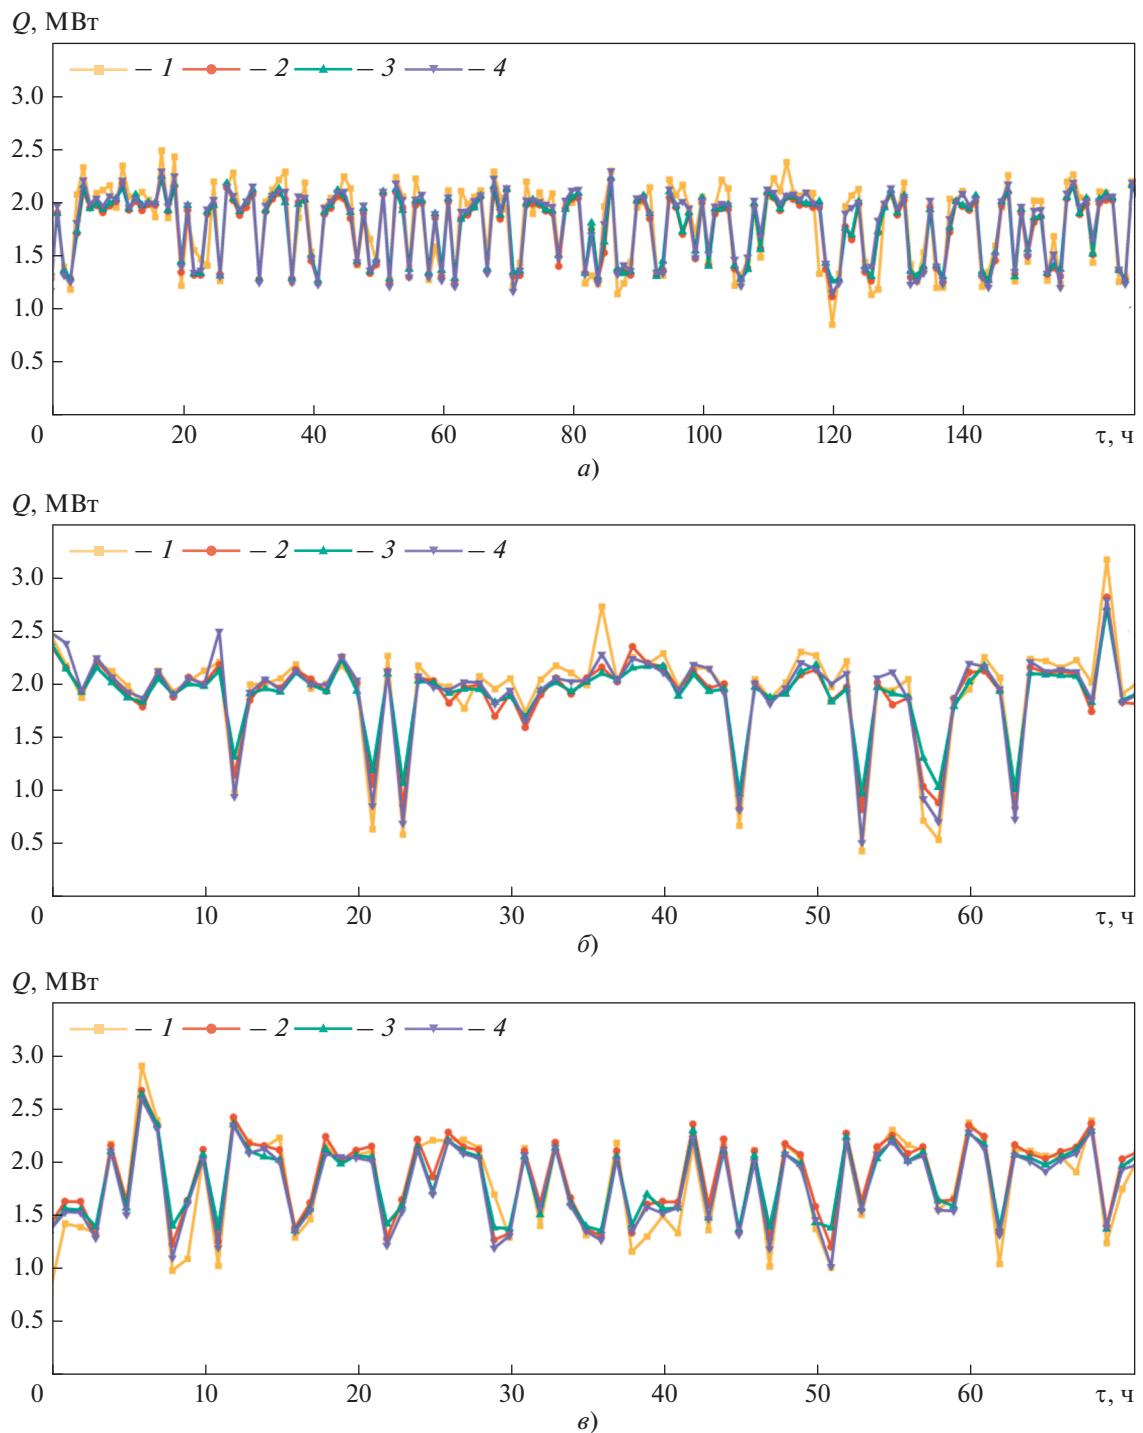


Рис. 1. Результаты прогнозирования тепловой нагрузки  $Q$  для трех тепловых пунктов № 1 (а), № 2 (б) и № 3 (в), полученные с использованием трех моделей прогнозирования.

1 – фактическая нагрузка; нагрузка, определенная с помощью модели: 2 – PSO-TCN; 3 – SSA-TCN; 4 – SCSO-TCN

**Таблица 1.** Значения гиперпараметров для рассматриваемых алгоритмов оптимизации для трех тепловых пунктов

Номер ТП	PSO-TCN	SSA-TCN	SCSO-TCN
1	[12, 6, 0.231, 19]	[5, 2, 0.05, 5]	[16, 8, 0.218, 21]
2	[8, 2, 0.142, 8]	[5, 2, 0.219, 5]	[6, 2, 0.063, 6]
3	[10, 9, 0.158, 6]	[5, 2, 0.05, 5]	[5, 2, 0.05, 5]

**Таблица 2.** Оценка точности алгоритмов оптимизации для трех тепловых пунктов

Номер ТП	PSO-TCN			SSA-TCN			SCSO-TCN		
	MSE	MAE	CVRMSE	MSE	MAE	CVRMSE	MSE	MAE	CVRMSE
1	0.0287	0.1271	0.0938	0.0274	0.1218	0.0916	0.0217	0.1066	0.0816
2	0.0282	0.1289	0.0864	0.0409	0.1400	0.1040	0.0173	0.0995	0.0676
3	0.0301	0.1195	0.0966	0.0342	0.1298	0.1030	0.0280	0.1165	0.0932

ности прогноза. Эти ошибки рассчитываются следующим образом:

$$\text{MSE} = \frac{1}{N} \sum_{n=1}^N (Q_n - \hat{Q}_n)^2; \quad (7)$$

$$\text{MAE} = \frac{1}{N} \sum_{n=1}^N |Q_n - \hat{Q}_n|; \quad (8)$$

$$\text{CVRMSE} = \frac{\sqrt{\frac{1}{N} \sum_{n=1}^N (Q_n - \hat{Q}_n)^2}}{\frac{1}{N} \sum_{n=1}^N Q_n}, \quad (9)$$

где  $Q_n$  и  $\hat{Q}_n$  – фактическая и расчетная тепловая нагрузка;  $N$  – количество моментов времени прогноза.

#### Экспериментальные данные

Чтобы проверить точность прогноза и его способность адаптироваться к новым данным, было проведено сравнение результатов, полученных с помощью моделей SCSO-TCN, PSO-TCN и SSA-TCN. Результаты прогноза по этим моделям представлены на рис. 1. В табл. 2 приведены статистические показатели моделей.

Анализ рисунка позволяет сделать следующие выводы:

рассмотренные модели дают довольно точные прогнозы, поскольку показатель CVRMSE не превышает 30%, что, по мнению авторов [15], вполне приемлемо для практического применения той или иной модели;

прогноз, составленный по предлагаемой в настоящей работе модели SCSO-TCN, по сравнению с PSO-TCN и SSA-TCN имеет наименьшую ошибку;

исходные данные и количество обучающих выборок для трех тепловых пунктов различаются, однако прогнозы, полученные с помощью SCSO-TCN, являются более точными по сравнению с прогнозами, построенными по моделям PSO-TCN и SSA-TCN.

Таким образом, модель SCSO-TCN обладает наилучшей адаптивностью и эффективностью.

Наибольшая неопределенность прогноза получена для ТП № 3, поскольку для этого пункта было недостаточно исходных данных, что затруднило их разделение на обучающий и тестовый наборы.

#### ВЫВОДЫ

- По точности прогноза тепловой нагрузки системы централизованного теплоснабжения гибридная модель SCSO-TCN превосходит такие модели, как PSO-TCN и SSA-TCN.
- Модель SCSO-TCN обладает лучшей адаптивностью и эффективностью по сравнению с моделями PSO-TCN и SSA-TCN.
- Для получения более точного прогноза с помощью модели SCSO-TCN необходимы дополнительные данные о тепловой нагрузке на рассматриваемом тепловом пункте.

#### СПИСОК ЛИТЕРАТУРЫ

- Load forecasting of district heating system based on Informer / M.J. Gong, Y. Zhao, J.W. Sun, C.T. Han, G.N. Sun, B. Yan // Energy. 2022. V. 253. P. 124179. <https://doi.org/10.1016/j.energy.2022.124179>
- Lake A., Rezaie B., Beyerlein S. Review of district heating and cooling systems for a sustainable future // Renewable Sustainable Energy Rev. 2017. V. 67. P. 417–425. <https://doi.org/10.1016/j.rser.2016.09.061>
- A survey of district heating systems in the heating regions of Northern China / X. Xu, S.J. You, X.J. Zheng, H. Li // Energy. 2014. V. 77. P. 909–925. <https://doi.org/10.1016/j.energy.2014.09.078>
- The status of 4th generation district heating: Research and results / H. Lund, P.A. Ostergaard, 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>
- Analysis and evaluation of the operation data for achieving an on-demand heating consumption prediction model of district heating substation / J.J. Yuan, Z.H. Zhou, K. Huang, Z. Han, C.D. Wang, S.L. Lu // Energy. 2021. V. 214. P. 118877. <https://doi.org/10.1016/j.energy.2020.118877>
- 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>

7. 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>
8. Forecasting of consumers heat load in district heating systems using the support vector machine with a discrete wavelet transform algorithm / M. Protic, S. Shamshirband, D. Petkovic, 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>
9. 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>
10. Prediction of heating 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>
11. 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>
12. Heat demand forecasting algorithm for a Warsaw district heating network / T. Kurek, A. Bielecki, K. Swirski, K. Wojdan, M. Guzek, J. Bialek, R. Brzozowski, R. Serafin // Energy. 2021. V. 217. P. 119347.  
<https://doi.org/10.1016/j.energy.2020.119347>
13. Yabanova I., Kecebas A. Development of ANN model for geothermal district heating system and a novel PID-based control strategy // Appl. Therm. Eng. 2013. V. 51. Is. 1–2. P. 908–916.  
<https://doi.org/10.1016/j.applthermaleng.2012.10.044>
14. Heat load prediction of small district heating system using artificial neural networks / M.B. Simonovic, V.D. Nikolic, E.P. Petrovic, I.T. Cirim // Therm. Sci. 2016. V. 20. S1355–S1365.  
<https://doi.org/10.2298/TSCI16S5355S>
15. 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>
16. 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>
17. 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>
18. 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>
19. 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.egyr.2021.08.140>
20. 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>
21. Hourly heat load prediction model based on temporal convolutional neural network / J.C. Song, G.X. Xue, X.H. Pan, Y.P. Ma, H. Li // IEEE Access. 2020. V. 8. P. 16726–16741.  
<https://doi.org/10.1109/access.2020.2968536>
22. 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. Inform. 2020. V. 16. Is. 12. P. 7743–7755.  
<https://doi.org/10.1109/tnii.2020.2970165>
23. Medium-term heat load prediction for an existing residential building based on a wireless on-off control system / J.H. Gu, J. Wang, C.Y. Qi, C.H. Min, B. Sundén // Energy. 2018. V. 152. P. 709–718.  
<https://doi.org/10.1016/j.energy.2018.03.179>
24. Wang M., Tian Q. Dynamic heat supply prediction using support vector regression optimized by particle swarm optimization algorithm // Math. Probl. Eng. 2016. V. 2016. Article ID 3968324.  
<https://doi.org/10.1155/2016/3968324>
25. 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. Mostafaeipour, P.L. Yee, D. Petkovic, S. Ch // Energy. 2016. V. 95. P. 266–273.  
<https://doi.org/10.1016/j.energy.2015.11.079>
26. Barman M., Choudhury N.B.D., Sutradhar S. A regional hybrid GOA-SVM 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>
27. Seyyedabbasi A., Kiani F. Sand Cat swarm optimization: a nature-inspired algorithm to solve global optimization problems // Eng. Comput. 2023. V. 39. P. 2627–2651.  
<https://doi.org/10.1007/s00366-022-01604-x>
28. Прогнозирование тепловой нагрузки для систем централизованного теплоснабжения с помощью моделей TCN и CatBoost / C. Han, M. Gong, J. Sun, Y. Zhao, L. Jing, C. Dong, Z. Zhao // Теплоэнергетика. 2023. № 9. С. 97–105.  
<https://doi.org/10.56304/S0040363623090047>
29. Statistical analysis of energy consumption patterns on the heat demand of buildings in district heating systems / Z.Y. Ma, H.L. Li, Q. Sun, C. Wang, A.B. Yan, F. Starfelt // Energy Build. 2014. V. 85. P. 464–472.  
<https://doi.org/10.1016/j.enbuild.2014.09.048>

## Heat Load Prediction of District Heating Systems based on SCSO-TCN

**M. Gong<sup>a, \*</sup>, C. Han<sup>a</sup>, J. Sun<sup>a</sup>, Y. Zhao<sup>a</sup>, S. Li<sup>b, c</sup>, and W. Xu<sup>c, d</sup>**

<sup>a</sup> School of Integrated Circuit Science and Engineering, Tianjin University of Technology, Xiqing District, Tianjin, 300384 China

<sup>b</sup> Tianjin University, Tianjin, 300072 China

<sup>c</sup> Sea Island Environment Science and Technology Research Institute (Tianjin) Co., Ltd,  
Hetong Building, Tianjin, 300072 China

<sup>d</sup> Tianjin University of Technology, Tianjin, 300384 China

\*e-mail: gmj790@163.com

**Abstract**—Heat load prediction is crucial to the heat regulation of district heating systems (DHS). In heat load forecasting tasks, deep learning can frequently achieve more accurate model building. A deep learning algorithm, the temporal convolutional network (TCN), has been used for DHS heat load prediction. However, there are many hyperparameters for TCN. Manually tuning the TCN parameters cannot make the model have good performance. This study presents a hybrid method based on sand cat swarm optimization (SCSO) and TCN. The SCSO is used to optimize the hyperparameters (number of filters, filter size, dropout rate, and batch size) of TCN. To verify the effectiveness of SCSO-TCN, another two hybrid models, particle swarm optimization with TCN and the sparrow search algorithm with TCN, are established for comparison. The historical heat load data of three heat exchange stations in Tianjin is utilized for the testing experiments. The findings demonstrate that SCSO-TCN has higher predictive accuracy and better generalization ability than the PSO-TCN and SSA-TCN models.

**Keywords:** heat load prediction, heat regulation, district heating system, model building, deep learning, temporal convolutional network, sand cat swarm optimization