

基于 AWOA-TEFN 的热负荷预测模型



杜迎华*, 李天昊

天津商业大学信息工程学院, 天津 300134

摘要: 在节能减排的战略背景下, 区域供热系统的智能优化运行成为提升能源利用效率、降低碳排放的关键环节, 而精准的热负荷预测是实现这一目标的核心技术支撑。为应对热负荷序列非线性、非平稳性显著及多影响因素耦合的复杂特性, 解决现有预测模型对不确定性特征捕捉不足、超参数依赖人工调试、多变量时序信息融合不充分等问题, 助力供热系统实现节能降耗与智能运行升级, 本文提出一种基于自适应鲸鱼算法优化时间证据融合网络 (AWOA-TEFN) 的热负荷预测方案。该方案以证据理论与信息融合技术为核心, 通过基本概率分配、期望融合及时间归一化-反归一化三大模块, 从时间与通道双维度精准捕捉多变量时间序列的不确定性特征; 数据预处理阶段采用三次样条插值填补缺失值、四分位数法剔除异常值, 结合皮尔逊相关系数筛选核心输入特征, 并利用 AWOA 算法自适应优化输入序列长度、预测步长等关键超参数, 显著提升模型鲁棒性与适配性。以安阳换热站小时级热负荷实测数据为基础, 将所提方案与 GRU、RFR、LSTM、LightGBM 等主流预测算法进行性能对比。实验结果表明, AWOA-TEFN 方案的平均绝对百分比误差等各项评估指标均优于对比算法, 能够精准追踪热负荷动态变化趋势, 为供热系统的优化配置、智能调控及能效提升提供了可靠的技术支撑。

关键词: 热负荷预测; AWOA 算法; TEFN 网络; 深度学习; 数据预处理

DOI: 10.57237/j.jest.2025.04.001

Heat Load Forecasting Model Based on AWOA-TEFN

Du Yinghua*, Li Tianhao

School of Information Engineering, Tianjin University of Commerce, Tianjin 300134, China

Abstract: Against the strategic backdrop of energy conservation and emission reduction, the intelligent optimization of regional heating systems has become a key link in improving energy utilization efficiency and reducing carbon emissions, with accurate heat load forecasting serving as the core technological support to achieve this goal. To address the complex characteristics of heat load sequences, such as nonlinearity, pronounced non-stationarity, and the coupling of multiple influencing factors, and to overcome the shortcomings of existing forecasting models—namely insufficient capture of uncertainty features, hyperparameter dependence on manual tuning, and inadequate integration of multivariate time series information—this paper proposes a heat load forecasting scheme based on an Adaptive Whale Optimization Algorithm-optimized Time Evidence Fusion Network (AWOA-TEFN). This scheme centers on evidence theory and information fusion technology, and, through three key modules—basic probability assignment, expectation fusion, and time normalization-denormalization—it accurately captures the uncertainty characteristics of multivariate time series from both temporal and channel dimensions. During the data preprocessing stage, cubic spline interpolation is used to fill in missing values, the quartile method is employed to remove outliers, and core input features are selected based on Pearson correlation coefficients. Additionally, the AWOA algorithm adaptively optimizes critical hyperparameters, such

基金项目: 大学生创新训练计划项目 (202510069001).

*通信作者: 杜迎华, afuetr@163.com

收稿日期: 2025-12-05; 接受日期: 2025-12-24; 在线出版日期: 2025-12-29

<http://www.energysci.tech.org>

as input sequence length and prediction step size, significantly enhancing model robustness and adaptability. Based on hourly measured heat load data from the Anyang heat exchange station, the proposed scheme is compared with mainstream forecasting algorithms, including GRU, RFR, LSTM, and LightGBM. Experimental results indicate that the AWOA-TEFN scheme outperforms the comparative algorithms across all evaluation metrics, including mean absolute percentage error, accurately tracking the dynamic trends of heat load changes. This provides reliable technical support for the optimal configuration, intelligent regulation, and energy efficiency improvement of heating systems.

Keywords: Heat Load Forecasting; Adaptive Whale Optimization Algorithm (AWOA); Temporal Evidence Fusion Network (TEFN); Deep Learning; Data Preprocessing

1 引言

随着全球能源结构的加速转型以及节能减排要求的不断提高,热负荷预测技术的发展对于实现供热系统的节能降耗、优化能源配置以及减少化石能源消耗具有不可忽视的重要意义[1]。热负荷预测算法作为供热系统智能化运行的核心研究方向[2],正受到学术界和工业界越来越多的关注。但由于热负荷受到气象条件、建筑特性、居民用热习惯和地理位置等多种因素的综合影响[3],呈现出极强的时空变异性和非线性特征[4]。此外,预测模型与算法本身的局限性也严重制约着热负荷的预测精度。因此,提升模型算法的预测精度与泛化能力,对于热负荷预测系统的实际应用和供热系统的高效运行起着至关重要的作用[5]。

目前众多热负荷预测方法均存在不同程度的弊端。基于物理机理模型和传统统计模型的预测方法,往往难以精准捕捉热负荷与各影响因素之间复杂的非线性关系,且易受外界随机因素和非线性特征值的干扰,在动态变化的供热场景中预测效果不佳。而基于深度学习和机器学习的人工智能预测方法,虽然在非线性拟合方面表现出一定优势,但也常受网络结构设计不合理、参数优化不足等局限性的影响,导致模型的泛化能力和预测稳定性有待提升。

国内外学者针对热负荷预测展开了大量研究,形成了以传统机器学习、深度学习为核心的两大技术路径,且普遍通过智能优化算法对模型进行改进升级,取得了阶段性成果。在传统机器学习优化方面,韩英杰等人[6]提出的粒子群优化支持向量机模型(Particle Swarm Optimization - Support Vector Machine, PSO-SVM)与基于支持向量机模型(Support Vector Machine, SVM)、极限学习机模型(Extreme Learning Machine, ELM)、反向传播神经网络模型(Back Propagation Neural Network, BP)的预测方法开展对比

实验,充分验证了 PSO-SVM 算法模型预测精度更高。王新雨等人[7]提出了一种基于主成分分析法和粒子群优化算法改进的 BP 神经网络预测模型,将热负荷预测精度提高了 4.07%。在深度学习模型应用与优化方面,杜占强等人[8]利用长短期记忆网络(Long Short-Term Memory, LSTM)构建短期热负荷预测网络模型,预测结果与实际热负荷需求呈正相关。张龙龙等人[9]所提出的霍普菲尔德模型(Hopfield Neural Network, HNN)对热负荷预测有更高的精度,同时引入稀疏自编码器(Sparse Denoising Autoencoder, SDA)对神经网络进行优化升级,缩短了神经网络模型的训练时间。薛贵军等人[10]针对短期供热负荷控制预测的问题,提出了一种基于改进黏菌算法优化双向长短期记忆网络(Bidirectional Long Short-Term Memory, BiLSTM)的预测模型以满足实际工程的需要。刘立巍等人[11]提出了 K 近邻-长短期记忆网络(K-nearest Neighbor - Long Short-Term Memory, KNN-LSTM)模型准确预测热电联产机组的热负荷进而确定机组的热电可行域。

由于热负荷时间序列具有显著的非线性、非平稳性[12]和随机性特征,当前部分研究在预测精度、模型泛化能力以及对复杂工况的适应性方面仍存在不足。因此,本文提出了一种基于自适应鲸鱼算法优化时间证据融合网络(Adaptive Whale Optimization Algorithm-Time Evidence Fusion Network, AWOA-TEFN)的热负荷预测模型。该模型在处理热负荷时间序列预测问题时,从通道和时间两个维度来捕捉多变量时间序列数据的不确定性,并在准确性、效率、稳定性和可解释性之间取得了平衡,是时间序列预测的理想解决方案。自适应鲸鱼优化算法能更好地找出问题的最优解从而提高模型的鲁棒性和适应性。通过对该算法模型的设计与优化,能够提高换热站系统

的运行效率和可靠性。

2 数据及目的

2.1 数据的收集

本研究使用的是安阳三个不同换热站的数据集。该数据集涵盖了热负荷、一次供水温度、一次回水温度等核心指标，数据采集频率为 60 分钟一次；但由于设备问题、通信中断等突发状况，安阳的数据集存在部分缺失，缺失率过高将影响热负荷预测的准确性，导致客户满意度下降。

2.2 问题定义的目的

本文的研究目的是通过过去逐时的热负荷和相关影响因素数据，对未来多个小时的热负荷进行预测。通过输入过去 j 个时间步长的历史数据，从而预测出未来每小时的热负荷。将输入特征表示为一个时间序列：

$$\mathbf{X} = (x_1, x_2, \dots, x_t) \quad (1)$$

其中， x_t 是时间步 t 的输入特征向量（包含该时刻的热负荷，一次供水温度，一次回水温度等特征）希望预测的目标是未来 h 个时间步的热负荷序列，记为：

$$\hat{\mathbf{Y}} = (\hat{y}_{t+1}, \hat{y}_{t+2}, \dots, \hat{y}_{t+h}) \quad (2)$$

其中 $\hat{y}_{t+i}$ 表示对时间步 $t+i$ ($i=1, 2, \dots, h$) 的热负荷预测值，其理想的真实值为 y_{t+i} 。本研究的核心是构建预测模型 f ，使 $\hat{\mathbf{Y}} = f(\mathbf{X})$ 尽可能接近真实的热负荷序列 $\mathbf{Y} = (y_{t+1}, y_{t+2}, \dots, y_{t+h})$ 。

3 算法原理

3.1 数据预处理

3.1.1 数据插补

论数据插补可用来弥补数据集中缺失值造成的信息损失。利用三次样条插值法填补安阳数据集的缺失数值，能更好地保留原始数据的分布特征，为后续模型训练提供完整可靠的数据基础，同时又能避免因删除缺失样本导致的样本偏差，保证模型的鲁棒性。

本文通过四分位数法移除了历史序列中的明显异常值，以减少噪声数据对模型插补效果的干扰。具体方法如公式 (3)-(4) 所展示，超出边界 $\mathbf{Y} = (y_{t+1}, y_{t+2}, \dots, y_{t+h})$ 的数据被认定为异常值。其中 Q_1 表示样本按升序排列时的第 25 百分位数的数据， Q_3 表示样本按升序排列时的第 75 百分位数的数据， k 表示系数，通常取值为 1.5 或 3。

$$x_{\max} = Q_3 + k(Q_3 - Q_1) \quad (3)$$

$$x_{\min} = Q_1 - k(Q_3 - Q_1) \quad (4)$$

三次样条插值通过在每一相邻数据点区间上构造三次多项式如公式(5)然后在各区间端点处施加函数值连续条件如公式(6)，一阶导数连续条件如公式(7)和二阶导数连续的条件如公式(8)。通过联立方程求解可得出缺失值的算术结果。这些条件使得计算得到的插补的数据很好的拟合了原有数据，增强了数据可靠性。

$$S_i(x) = a_i + b_i(x - x_i) + c_i(x - x_i)^2 + d_i(x - x_i)^3 \quad (5)$$

$$S(x_i) = y_i \quad (6)$$

$$S'_{i-1}(x_i) = S'_i(x_i) \quad (7)$$

$$S''_{i-1}(x_i) = S''_i(x_i) \quad (8)$$

其中 a_i 、 b_i 、 c_i 、 d_i 为第 i 段样条函数 $S_i(x)$ 的待定系数， x 为插值点坐标， x_i 为第 i 个节点的横坐标其中 y_i 为节点 x_i 对应的已知的纵坐标值。

3.1.2 特征选择方法

皮尔逊相关系数 (Pearson Correlation Coefficient, PCC) 是衡量两个连续变量线性相关程度的参数化方法。利用该系数计算热负荷与一次供水温度，一次回水温度等参数的关联强度，能精准筛选出与目标变量强相关的核心特征，减少数据冗余，同时提升模型对热负荷的预测性能与泛化能力。

$$\rho_{x,y} = \frac{\text{Cov}(x, y)}{\sigma_x \sigma_y} \quad (9)$$

其中 x 为影响热负荷的其他因素， y 为热负荷，

$\text{Cov}(x, y)$ 为协方差, σ_x 和 σ_y 为二者标准差。根据相关系数数值大小, 可将其分类:

$$\left\{ \begin{array}{ll} 0.8 \leq |\rho_{x,y}| \leq 1 & \text{极强相关} \\ 0.6 \leq |\rho_{x,y}| < 0.8 & \text{强相关} \\ 0.4 \leq |\rho_{x,y}| < 0.6 & \text{中度相关} \\ 0.2 \leq |\rho_{x,y}| < 0.4 & \text{弱相关} \\ |\rho_{x,y}| < 0.2 & \text{无相关} \end{array} \right. \quad (10)$$

$|\rho_{x,y}|$ 越大, 相关性较强, 反之相关性越弱。

3.2 TEFN 网络

时间证据融合网络 (Time Evidence Fusion Network, TEFN) [13] 是面向时间序列预测的轻量化神经网络, 以证据理论和信息融合为核心思想, 将时间序列的时间维度与通道维度视为不同信息源, 通过特殊设计的模块实现不确定性建模、多源信息融合与高效预测。其核心部件包括基本概率分配模块 (BPA Module)、期望融合 (Expectation Fusion) 及时间归一化与反归一化 (Time Normalization and De-normalization), 兼具低复杂度、高鲁棒性、强可解释性等优势, 适配长短期时间序列数据处理。

基本概率分配模块 (BPA Module) 是 TEFN 的核心部件, 基于证据理论和模糊逻辑, 将原始时间序列数据映射为事件空间中的基本概率分配 (Mass Function), 以此建模数据中的不确定性和模糊性。不同于传统卷积的信息压缩特性, BPA 模块是一种信息扩展操作, 通过考虑样本空间子集构成的事件空间中所有可能性, 充分挖掘时间序列内部隐藏信息。BPA 模块分别对时间维度和通道维度进行处理: 时间维度的 BPA 模块共享不同通道的参数, 通道维度的 BPA 模块共享不同时间步的参数, 通过参数化的模糊隶属函数实现维度扩展。其线性模糊隶属函数定义如下:

$$m_{D,i,j,k} = \mu(x_{\text{Norm},i,j}) = w_{D,j,k} \cdot x_{\text{Norm},i,j} + b_{D,j,k} \quad (11)$$

式中, $x_{\text{Norm},i,j}$ 为归一化后的时间序列数据, $w_{D,j,k}$ 和 $b_{D,j,k}$ 隶属函数的斜率和截距参数, 可通过训练学习, D 为时间序列维度 (包含时间维度 T 和通道维度 C), i, j 为维度 D 内的具体索引, 如第 i 个时间步下的第 j

个数据点或第 i 个通道的第 j 个特征, k 为事件空间维度索引, 对应第 k 类事件, $m_{D,i,j,k}$ 为输出的基本概率分配值。

为适配非线性时间序列数据, BPA 模块还可替换为 ReLU、Tanh 等非线性隶属函数, 进一步提升模型对复杂数据模式的建模能力。

期望融合是 TEFN 实现多源信息整合的关键部件, 用于融合时间维度 BPA 模块输出的 my 和通道维度 BPA 模块输出的 mc 这两种不同的概率分布, 生成统一的预测结果。该模块摒弃了计算复杂度高且对极端分布敏感的邓普斯特-沙菲尔规则 (Dempster-Shafer Rule, DSR), 采用基于期望的线性融合方式, 在保证融合效果的同时兼顾计算效率。期望融合通过对变换后的概率函数进行线性加权求和, 实现时间维度与通道维度信息的深度融合, 其运算定义如下:

$$\begin{aligned} \hat{y}_{\text{Norm},D,i,j} &= E_{D,F}(y_{j,k}) \\ &= \sum y_{j,k} \cdot m'_{i,j,k} \left(j \in [1, |D|], k \in [1, |2^S|] \right) \\ &= \sum m_{i,j,k} \left(j \in [1, |D|], k \in [1, |2^S|] \right) \end{aligned} \quad (12)$$

式中, $\hat{y}_{\text{Norm},D,i,j}$ 为归一化后的预测, $y_{j,k}$ 为融合参数, $m'_{i,j,k}$ 为变换后的概率函数, S 为样本空间, $|2^S|$ 为事件空间大小, 由样本空间的幕集决定, $m_{i,j,k}$ 为原始基本概率分配值。

最终通过对不同维度的归一化预测结果求和, 得到最终融合结果, 即 $\hat{y}_{\text{norm}} = \sum_{D \in \{T, C\}} \hat{y}_{\text{Norm},D}$ 。

时间归一化与反归一化模块用于优化模型训练过程, 提升训练效率与稳定性, 避免数据尺度差异和异常值对预测结果的影响。该模块借鉴平稳模型的归一化思想, 通过对称的归一化与反归一化操作, 使模型在标准化的数据分布上学习, 有效加速模型收敛, 降低局部最优解对预测效果的干扰。

归一化过程先计算时间序列片段的均值 m 和方差 σ^2 , 再对数据进行标准化处理; 反归一化过程则将模型输出的归一化预测值恢复为原始数据尺度, 其核心运算定义如下:

$$\mu = \frac{1}{N} \sum_{i=1}^N x_i \quad (13)$$

$$\sigma^2 = \frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2 \quad (14)$$

$$\hat{y} = \sigma \cdot \hat{y}_{Norm} + \mu = \sigma \cdot Net(x_{Norm}) + \mu \quad (15)$$

式中, x 为原始时间序列片段, N 为时间序列片段长度, μ 为序列均值, σ^2 为序列方差, x_{Norm} 为归一化后的时间序列, $Net(\cdot)$ 为 TEFN 的神经网络运算, $\hat{y}_{Norm}$ 为归一化预测值, $\hat{y}$ 为反归一化后的最终预测值。

该模块与 BPA 模块、期望融合协同工作, 不仅解决了模型训练中梯度不稳定的问题, 还进一步增强了 TEFN 对不同尺度时间序列数据的适配能力。

3.3 自适应鲸鱼优化算法

自适应鲸鱼优化算法 (Adaptive Whale Optimization Algorithm, AWOA) [14] 是在鲸鱼优化算法 (Whale Optimization Algorithm, WOA) [15] 基础上改进而来的一种增强型群体智能优化技术, 通过引入自适应调节机制提升了原始算法的搜索精度与收敛效率。

该算法保留了 WOA 模拟座头鲸群体狩猎行为的核心逻辑, 同时针对原始算法在迭代过程中全局搜索与局部开发平衡不足的问题, 增加了参数动态调整策略, 其灵感同样源自自然界中座头鲸群体协同捕食的智能行为。在 AWOA 算法中, 每只座头鲸的位置仍代表一个可行解, 整个算法过程依旧通过模拟鲸鱼的泡泡网捕食行为, 包含搜索觅食、收缩包围和螺旋更新位置三个核心阶段, 但各阶段的关键参数会根据迭代进程自适应变化。

AWOA 算法将鲸鱼捕食的目标视为潜在的最优解, 而鲸鱼的当前位置则被视为可能的解。在每次迭代过程中, 算法不仅根据随机数 p 的值和系数 A 的大小来确定鲸鱼位置的调整方式, 还引入了自适应权重因子 β 动态调节三种更新机制的触发概率。随着迭代次数的增加, 算法通过非线性调整控制参数, 使鲸鱼群体在迭代前期侧重全局探索以避免局部最优, 在迭代后期侧重局部精细搜索以加速收敛, 最终稳定向最优解靠拢。AWOA 算法的 3 种种群更新机制中, 自适应搜索觅食机制的数学定义为:

$$X^r(t+1) = X(t) - A \cdot |C \cdot X^r(t) - X(t)| \quad (16)$$

式中, r 是用于选取随机个体的随机整数索引,

t 为当前迭代次数; $X^r(t)$ 是从当前鲸鱼群体中随机选取的一个鲸鱼个体位置向量; $X(t)$ 是当前的鲸鱼个体位置向量; $|C \cdot X^r(t) - X(t)|$ 表示当前鲸鱼个体和随机选取鲸鱼个体之间的距离向量。与原始 WOA 不同, AWOA 中系数 A 和 C 采用自适应策略定义为:

$$A = \begin{cases} 2r \cdot a - a & t < 0.7T_{\max} \\ 0.5r \cdot a & t \geq 0.7T_{\max} \end{cases} \quad (17)$$

$$C = 2r \cdot \left(1 + \frac{t}{T_{\max}} \right) \quad (18)$$

在此式中, 步长控制参数 a 随着迭代次数的增加从 2.5 非线性减小到 0, 相较于原始 WOA 的线性递减, 更利于平衡全局与局部搜索; r 是一个分布于 [0,1] 之间的随机数; $T_{\max}$ 为最大迭代次数, C 的自适应调整进一步增强了算法的动态搜索能力。

自适应收缩包围机制的数学模型定义如下:

$$X^b(t+1) = X^b(t) - A \cdot |C \cdot X^b(t) - X(t)| \quad (19)$$

式中 $X^b(t)$ 是当前鲸鱼群体中目标函数值最优的鲸鱼个体位置向量; $A \cdot |C \cdot X^b(t) - X(t)|$ 为当前鲸鱼个体的包围步长。AWOA 中引入了步长自适应衰减因子, 使得 A 值不仅线性减小, 还会根据当前最优解的变化速率动态微调, A 越小时鲸鱼游走的步长越小, 且在最优解附近的步长衰减速度更快, 提升局部收敛精度。

自适应螺旋更新位置阶段, 其数学模型可表示为:

$$X^{bl}(t+1) = X^b(t) - |X^b(t) - X(t)| \cdot e^{bl} \cdot \cos(2\pi l) + X^b(t) \quad (20)$$

式中 $|X^b(t) - X(t)|$ 表示当前鲸鱼个体与最优位置个体之间的距离; 常数系数 b 不再固定为 1, 而是根据迭代进程自适应调整为 $b = 1.5 - \frac{t}{2T_{\max}}$, 通过改变螺旋路径的形状, 使迭代前期增强全局搜索, 迭代后期提升局部开发精度; l 是区间 [-1,1] 内的随机数, AWOA 算法中鲸鱼个体位置向量的每一个分量 $X(t)$ 在种群更新时均独立进行, 且各分量的更新步长会根据自身

维度的适应度值动态调整。

综上所述，通过将自适应鲸鱼优化算法应用于 TEFN 的超参数优化中，可以利用其自适应调节的参数策略、动态平衡的搜索机制以及更强的全局寻优能力，更好地调整 TEFN 模型的参数，解决原始 WOA 易陷入局部最优的问题，进一步提高模型的预测性能和泛化能力，从而使其更适应各种实际任务和数据集。

4 基于 AWOA-TEFN 热负荷预测模型

4.1 模型原理

TEFN 需要优化的八个超参数分别为：输入序列长度、预测步长、特征优化与分配模块（Feature Optimization and Distribution Module, FOD）数量、非平稳

归一化开关、批次大小、训练轮次、学习率、权重衰。利用 AWOA 对 TEFN 超参数进行优化。每只鲸鱼的位置由一个 8 维向量表示，其维数等于待优化的超参数个数。鲸鱼适应度值的计算方法如下：以鲸鱼的位置参数作为模型的超参数，模型建立后进行一次训练，此时模型在热负荷验证集上的平均绝对百分比误差（Mean Absolute Percentage Error, MAPE）的倒数即为鲸鱼在当前位置的适应度，MAPE 越小，适应度越高。然后，让每只鲸鱼根据自适应位置调整策略移动到新位置。上述过程称为一次搜索。设鲸鱼数量为 20 只，搜索次数为 20 次。所有搜索结束后，将选出适应度最高的鲸鱼，其位置参数代表最优超参数。基于上述选出的最优超参数构建 TEFN 模型，经过 30 次迭代最终得到训练好的模型。该算法流程图如图 1 所示。




图 1 TEFN 网络算法流程

其优化和训练过程可分为以下五步:

将热负荷数据集按照 7:2:1 的比例分为训练集、测试集和验证集,同时对数据进行归一化预处理,消除量纲差异对模型训练的影响。

将种群初始化为 20 只鲸鱼。根据适应度计算公式评估每只鲸鱼的适应度值,记录初始最优超参数组合。

鲸鱼根据自适应围捕行为、自适应泡泡网攻击和自适应探索行为调整位置:

- 自适应围捕行为:鲸鱼围绕当前最优解移动,通过非线性递减的控制参数调整围步步长,模拟精准捕食过程。
- 自适应泡泡网攻击:鲸鱼通过动态调整螺旋路径形状的泡泡网策略调整位置,迭代前期扩大搜索范围,后期聚焦最优解附近精细搜索。
- 自适应探索行为:引入迭代阶段阈值的随机探索机制,前期侧重全局搜索新位置,后期减少随机探索频率,避免陷入局部最优。

用最优超参数构建基于 TEFN 的热负荷预测模型,配置自适应优化策略对应的模型训练参数。

训练完成后利用测试集进行模型评估,计算平均绝对误差(Mean Absolute Error, MAE)、均方误差(Mean Squared Error, MSE)、均方根误差(Root Mean Squared Error, RMSE)、MAPE 等多维度指标,验证模型的热负荷预测性能。

通过上述步骤,AWOA 能够有效优化时间演化模糊网络的超参数。通过 AWOA 优化的超参数,TEFN 模型在热负荷预测中可以表现出更高的准确性和稳定性,解决了传统 TEFN 模型超参数人工调试效率低、预测精度受限的问题。

4.2 评价指标

为了综合评价 TEFN 模型的性能,本实验选取了

MAE, MSE, MAPE, RMSE 四个评价指标,计算公式如下:

$$E_{MAE} = \frac{1}{n} \times \sum_{i=1}^n |\hat{y}_j - y_j| \quad (21)$$

$$E_{MSE} = \frac{1}{n} \sum_{i=1}^n (\hat{y}_j - y_j)^2 \quad (22)$$

$$E_{MAPE} = \frac{1}{n} \times \sum_{i=1}^n \left| \frac{\hat{y}_j - y_j}{y_j} \right| \times 100\% \quad (23)$$

$$E_{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_j - y_j)^2} \quad (24)$$

式中: y_j 表示热负荷实测值, $\hat{y}_j$ 表示热负荷预测值, n 表示样本数。

5 实验和讨论

5.1 特征选择结果

图 2 展示了热负荷与其他参数之间的相关性热图。从图中可以看出,热负荷与一次供水温度、一次回水温度、二次供水温度、二次回水温度的相关系数绝对值较高且均大于 0.7,显示出显著的相关性。由此,这些参数被确定为热负荷预测的输入特征。

5.2 超参数优化结果

为了提高预测结果的准确性,本文采用了 AWOA 算法对 TEFN 模型超参数进行了寻优。AWOA 算法更加全面地搜索模型参数空间,进一步提升 TEFN 模型在预测任务中的性能。超参数寻优结果如表 1 所示。

表 1 AWOA 对 TEFN 的超参数寻优结果

参数名称	参数取值范围	参数值
输入序列长度	[16, 32, 64]	16
预测步长	[7, 14]	1
FOD 模块数量	[2, 3, 4]	2
非平稳归一化开关	[True, False]	False
批次大小	[16, 32, 64]	11
训练轮次	[155, 200, 300, 400]	155
学习率	[5.5e-5, 1e-3, 2e-3]	5.5e-5
权重衰减	[5e-6, 1e-4, 1e-3]	5e-6




图2 热负荷及影响因素的皮尔逊相关系数热力图

5.3 性能对比分析

为了证明 TEFN 模型在热负荷预测方面优势，本研究将其与门控循环单元（Gated Recurrent Unit, GRU）、随机森林回归器（Random Forest Regressor, RFR）、LSTM、轻量级梯度提升机（Light Gradient Boosting Machine, LightGBM）四种算法进行了深入的对比探究。表 2 列出 TEFN 模型与其它算法在性能指标上的对比，

包括 MSE、RMSE、MAE、MAPE。TEFN 在这些指标上均表现出最优的拟合性能，这表明该模型能够更好地捕捉长时间序列的变化趋势以及在短期大幅度波动的情况下能够做出精准预测。图 3-图 5 分别呈现了 TEFN 模型与 GRU、RFR、LSTM、LightGBM 模型对换热站 A、B、C 热负荷的预测结果及真实值的时序对比曲线可以看出 TEFN 模型的预测优越性。

表 2 AWOA-TEFN 预测模型与其他算法的性能评价指标对比

换热站	预测模型	MAE	MSE	RMSE	MAPE
A	TEFN	0.1408	0.0396	0.1990	0.0413
	GRU	0.2791	0.1117	0.3342	0.1132
	RFR	0.1397	0.0575	0.2398	0.0418
	LSTM	0.1882	0.0595	0.2439	0.0747
	LightGBM	0.3445	0.5869	0.2088	0.0696
B	TEFN	0.3247	0.3470	0.5891	0.0324
	GRU	0.5065	0.5386	0.7339	0.0537
	RFR	0.7815	0.8593	0.9270	0.0719
	LSTM	0.4451	0.4570	0.6760	0.0493
	LightGBM	0.6077	1.1344	1.0651	0.0520
C	TEFN	0.2382	0.1181	0.3462	0.0319
	GRU	0.4153	0.2989	0.7339	0.0584
	RFR	0.6793	0.8110	0.9005	0.0923
	LSTM	0.2487	0.1370	0.3701	0.0379
	LightGBM	0.3764	0.3218	0.5673	0.0631




图 3 换热站 A 小时热负荷预测结果




图 4 换热站 B 小时热负荷预测结果




图 5 换热站 C 小时热负荷预测结果

6 结论

区域供热系统的稳定高效运行，高度依赖热负荷的精准预测，但热负荷序列易受气温突变、居民用热习惯波动等因素影响，呈现出高非线性、非平稳性的显著特征，直接导致传统预测方法难以匹配实际供热调度的精度需求，极易引发“供大于需”造成的能源浪费，或“供小于需”导致的用户用热体验下降等行业痛点。针对这一实际问题，本文提出一种基于自适应鲸鱼优化算法优化时间证据融合网络的热负荷预测模型——AWOA-TEFN。该模型通过自适应鲸鱼优化算法（AWOA）对时间证据融合网络（TEFN）的超参数进行全局寻优，从根本上解决了传统人工调试超参数效率低、易陷入局部最优的难题；而TEFN网络搭载的基本概率分配（BPA）模块，能够精准建模热负荷时间序列的不确定性，在通道与时间双维度实现多源数据的深度融合，有效捕捉隐藏在数据中的用热需求规律与波动特征。详细对比实验结果表明，相较于GRU、RFR、LSTM、LightGBM等经典模型，所提AWOA-TEFN模型在应对寒潮、升温等气候剧变引发的热负荷陡升陡降场景时，表现出更优的预测精度与泛化稳定性，在MAE、MSE、RMSE及MAPE等核心评价指标上均达到最优水平。这一成果直接为供热企业的精细化调度提供了可靠的数据支撑，既有助于减少热源机组的无效启停、降低供热系统整体能耗，也能提升热网供需匹配度，为实现区域供热的节能化、智能化运营提供了关键技术参考。

未来的研究可进一步优化TEFN模型的结构细节，引入实时自我反馈与修正机制，使其能够动态适配极端天气频发、供热管网拓扑调整等复杂多变的实际供热场景，从而更好地满足民生用热保障与行业低碳转型的双重需求。

参考文献

[1] 黄润智. 基于机器学习的换热站热负荷预测控制研究[D]. 吉林化工学院, 2024.
<https://doi.org/10.27911/d.cnki.ghjgx.2024.000058>

[2] Fan H, Li Y, Wang G, et al. Heat load prediction model based on LSTM-GRU neural network method [J]. Journal of Building Engineering, 2025, 114: 114456-114456.
<https://doi.org/10.1016/j.Job.2025.114456>

[3] 孙一文. 热负荷预测中基于皮尔逊相关系数挑选相关因素[J]. 科学技术创新, 2025(22): 1-4.

[4] Zhang X, Luo H, Pei Y, et al. Mechanism-guided short-term heat load prediction of district heating system based on a hybrid data-driven model [J]. Applied Thermal Engineering, 2025, 280(P2): 128113-128113.
<https://doi.org/10.1016/j.Applthermaleng.2025.128113>

[5] 孙嘉旺. 区域供热系统的节能预测和智能调控方法研究[D]. 天津理工大学, 2023.
<https://doi.org/10.27360/d.cnki.gtlgy.2023.000244>

[6] 韩英杰, 徐媛媛, 胡蓉. 基于 PSO-SVM 的多参数条件下供热负荷预测研究 [J]. 科技创新与应用, 2025, 15(08): 73-76.
<https://doi.org/10.19981/j.CN23-1581/G3.2025.08.016>

- [7] 王新雨, 郭振伟, 于丹, 等. 基于 PCA-PSO-BP 神经网络的住宅供热逐时负荷预测 [J]. 暖通空调, 2023, 53(03): 138-142+160. <https://doi.org/10.19991/j.hvac1971.2023.03.25>
- [8] 杜占强, 鄢烈祥, 罗勇, 等. 基于 LSTM 神经网络的热力站短期热负荷预测仿真 [J]. 计算机仿真, 2025, 42(10): 125-129.
- [9] 张龙龙, 刘建军, 李冲, 等. 基于 HNN 和 SDA 的超短期热负荷预测研究 [J]. 暖通空调, 2025, 55(08): 174-180+93. <https://doi.org/10.19991/j.hvac1971.2025.08.24>
- [10] 薛贵军, 赵广昊, 史彩娟. 基于改进黏菌算法优化 BiLSTM 的短期供热负荷控制预测 [J]. 沈阳工业大学学报, 2024, 46(04): 434-441.
- [11] 刘立巍, 周建新, 刘培栋, 等. 基于 KNN-LSTM 的区域热负荷短期预测及在机组热电可行域的应用研究 [J]. 热能动力工程, 2023, 38(03): 91-97. <https://doi.org/10.16146/j.cnki.rndlgc.2023.03.012>
- [12] 杨博, 李晨晓, 徐嘉骋, 等. 面向非平稳热负荷序列的多模态分解与双路径预测框架 [J]. 热能动力工程, 2025, 40(11): 191-198. <https://doi.org/10.16146/j.cnki.rndlgc.2025.11.021>
- [13] Zhan T, He Y, Deng Y, et al. Time Evidence Fusion Network: Multi-Source View in Long-Term Time Series Forecasting [J]. IEEE transactions on pattern analysis and machine intelligence, 2025, PP. <https://doi.org/10.1109/tpami.2025.3596905>
- [14] 孔芝, 杨青峰, 赵杰, 等. 基于自适应调整权重和搜索策略的鲸鱼优化算法 [J]. 东北大学学报 (自然科学版), 2020, 41(01): 35-43.
- [15] Mirjalili S, Lewis A. The whale optimization algorithm [J]. Advances in engineering software, 2016, 95: 51-67.