

引用格式: 刘璐瑶, 陈志刚, 沈欣炜, 等. 基于 EMD-MLP 组合模型的用电负荷日前预测 [J]. 南方能源建设, 2024, 11(1): 143-156. LIU Luyao, CHEN Zhigang, SHEN Xinwei, et al. Day-ahead forecast of electrical load based on EMD-MLP combination model [J]. Southern energy construction, 2024, 11(1): 143-156. DOI: 10.16516/j.ceec.2024.1.15.

基于 EMD-MLP 组合模型的用电负荷日前预测

刘璐瑶^{1,2,✉}, 陈志刚¹, 沈欣炜², 吴劲松¹, 廖霄¹

(1. 中国能源建设集团广东省电力设计研究院有限公司, 广东广州 510663;
2. 清华大学深圳国际研究生院, 广东深圳 518055)

摘要: [目的] 用电负荷的精准预测是电力系统运行优化的基础, 是电力系统能量管理中不可或缺的组成部分。针对传统数据分解技术与机器学习模型结合预测存在的精准度低、计算量大等问题, 提出一种将经验模态分解与多层感知机结合 (EMD-MLP) 的新方法对用电负荷进行日前预测。[方法] 首先基于 EMD 将原始负荷时间序列信号分解为多个本征模函数 (Intrinsic Mode Function, IMF) 分量, 然后采用极值点划分法将多 IMF 分量进行重构形成高频和低频两个成分以精简预测对象, 最后对重构的新分量分别建模预测, 并将它们的预测结果叠加作为用电负荷预测值。[结果] 采用澳大利亚电力市场 2018 年、2019 年的实测用电负荷数据进行试验。[结论] 将建立的 EMD-MLP 组合模型与持续性模型、单一 MLP 模型以及传统 EMD 组合模型进行外推预测效果的对比, 验证了所建模型在提高预测精度上的有效性。此外, 所提出的 EMD-MLP 组合新方法在保证精度的同时简化了模型复杂度, 提高了预测效率, 可以方便地应用于实际中的用电负荷日前与实时预测。

关键词: 用电负荷预测; 日前预测; 经验模态分解; 分量重构; EMD-MLP

中图分类号: TK01; TM744

文献标志码: A

文章编号: 2095-8676(2024)01-0143-14

DOI: 10.16516/j.ceec.2024.1.15

OA: <https://www.energychina.press/>



论文二维码

Day-Ahead Forecast of Electrical Load Based on EMD-MLP Combination Model

LIU Luyao^{1,2,✉}, CHEN Zhigang¹, SHEN Xinwei², WU Jinsong¹, LIAO Xiao¹

(1. China Energy Engineering Group Guangdong Electric Power Design Institute Co., Ltd., Guangzhou 510663, Guangdong, China;

2. Shenzhen International Graduate School, Tsinghua University, Shenzhen 518055, Guangdong, China)

Abstract: [Introduction] Accurate load forecasting underpins the operation optimization of the electricity systems and is an indispensable aspect of energy management within such systems. Given the low accuracy and high computational complexity inherent in traditional methodologies that combine data decomposition and machine learning models, this study proposes a novel Empirical Mode Decomposition and Multi-Layer Perceptron (EMD-MLP) model for predicting day-ahead electrical load. [Method] Initially, the EMD method decomposed the original load time series into multiple Intrinsic Mode Function (IMF). These IMFs were then reconstructed into high-frequency and low-frequency components using extreme point partitioning, simplifying the prediction target. Subsequently, each reconstructed components was modeled separately for prediction, and the results were cumulatively used to provide the forecasted electrical load value. [Result] The proposed model is tested using real-world electrical load data of 2018 and 2019 from the Australian electricity market. [Conclusion] Comparing the extrapolative capabilities of our EMD-MLP model with persistence model, standalone MLP model and traditional EMD ensemble model confirms the effectiveness of our model in enhancing prediction accuracy. Moreover, while ensuring accuracy, the proposed EMD-MLP model simplifies the complexity and improves the efficiency of the forecasting process, thereby providing a practical solution for both day-ahead and real-time electrical load forecasting.

Key words: electrical load forecast; day-ahead forecast; empirical mode decomposition; component reconstruction; EMD-MLP

收稿日期: 2023-09-25 修回日期: 2023-10-07

基金项目: 中国能建广东院科技项目“计及可再生能源不确定性的低碳综合能源系统规划方法”(EV10961W)

2095-8676 © 2024 Energy China GEDI. Publishing services by Energy Observer Magazine Co., Ltd. on behalf of Energy China GEDI. This is an open access article under the CC BY-NC license (<https://creativecommons.org/licenses/by-nc/4.0/>).

0 引言

用电负荷日前预测对电力系统的运行优化起重要作用,其精确的预测结果是制定出合理、优质调度计划的基础。用电负荷预测方法主要有统计学方法和基于机器学习的方法 2 种^[1-4]。统计学方法基于自变量、因变量之间的统计规律进行预测,其中比较典型的有状态空间法^[5]、线性回归法^[6]、Box-Jenkins 法^[7]、自回归移动平均(ARMA)^[8]、季节自回归(SA)^[9]、季节自回归积分移动平均(SARIMA)^[10]、门限自回归^[11]等。统计学方法对于平稳性高、周期性强的用电负荷能够做出精确的预测。但是,当用电负荷受到天气等复杂多因素影响时,其数据表现出较强的随机性及非平稳性,此时,统计学方法难以获得有效的预测结果^[12]。针对实际负荷数据具有的显著异方差、非平稳性,学者开发了自回归条件异方差(ARCH)^[13]、广义自回归条件异方差(GARCH)^[14-15]等方法。但是只有在检查了是否存在 ARCH 效应后,才可以使用该类方法对时间序列建模预测^[16]。因此,基于统计学的预测方法对负荷的非线性行为建模能力有限,灵活性不足。

针对非线性数据,人工神经网络(ANN)、深度学习(DL)等机器学习模型则可以更好地模拟异方差性,而不需要对数据做假设检验,表现出了更强的数据处理能力与更高的预测精度^[17-18]。研究中用于用电负荷预测的机器学习模型包括:专家系统算法^[19],灰色模型^[20],模糊逻辑控制器^[21],猫群算法优化的误差反向传播神经网络(CSO-BPNN)^[22],多目标粒子群算法优化的 BP 神经网络(MOPSO-BPNN)^[23],蚁群优化的广义回归神经网络(ACO-GRNN)^[24],粒子群优化的最小二乘支持向量机(PSO-LS-SVM)^[25],深度置信网络(DBN)^[26],长短时记忆循环神经网络(LSTM)^[27-28],Attention 机制改进的 LSTM^[29],卷积神经网络(CNN)^[30]等。以上机器学习模型通过对训练算法、模型结构参数进行优化,使得预测准确度得到一定程度的改善,但却缺少在预测之前对数据进行分解,导致预测精度仍有待提升^[31]。

小波变换是一种有效数据分解方法,研究^[32-34]

采用小波分解方法对原始用电负荷数据去噪,然后使用机器学习模型对剩余分量建模预测,获得了比未经小波分解的单一模型更高的预测精度。然而,不同的小波基函数其时频特性存在差异,因此对同一信号选用不同的基函数进行处理所得的结果往往差别很大,这增加了该方法在实际使用中的复杂程度^[35]。学者们提出了经验模态分解(Empirical Mode Decomposition, EMD)、集合经验模态分解(Ensemble Empirical Mode Decomposition, EEMD)及变分模态分解(Variational Mode Decomposition, VMD)等更高效的方法在预测之前对负荷数据分解^[36]。孔祥玉等^[37]采用 EMD 将原始负荷数据分解为多个固有模态函数(IMF)分量,并采用基于最小二乘支持向量机(LSSVM)的方法对每个 IMF 分量分别建立预测模型,最后将分量预测结果叠加得到最终预测值。邓带雨等^[38]采用 EEMD 的方法将原始电力负荷分解为多个 IMF 分量,使用多元线性回归(MLR)和门控循环单元神经网络(GRU)对各分量分别进行预测并叠加,预测精度明显高于其他未经数据分解的单一预测模型以及基于小波变换的组合预测模型。梁智等^[39]、刘雨薇等^[40]采用 VMD 技术与 DBN、LSTM 等模型结合以对用电负荷预测,与未采用数据分解的单一预测模型比较,MAPE 和 RMSE 指标均有不同程度的改善。

现有将 EMD、EEMD、VMD 与机器学习模型结合预测的研究,大多是对每个分量逐个预测,然后将各分量预测结果累加作为最终预测值。然而,在此过程中各分量预测误差会逐渐积累,导致最终的负荷预测误差增大。此外,由于分解分量较多,对每个分量分别预测导致了计算量繁重的问题,分量越多计算任务越繁重,这极大地限制了该方法的实际应用。因此,本文考虑对多分量进行重构,以精简预测对象、减少预测次数,以期在降低建模难度的同时提高预测精度。

本文提出一种将 EMD 与 MLP 结合预测的新方法,首先利用 EMD 将原始用电负荷分解为多个分量,并采用极值点划分法将各个分量重构为高频和低频两个成分以精简预测对象,然后对二者分别预测并

将它们的预测结果叠加作为最终的用电负荷预测值。利用澳大利亚电力市场(Australian National Electricity Market, NEM)多组实测电力负荷数据进行试验, 对比分析验证本文方法在提高模型预测精度上的有效性。

1 EMD-MLP 组合模型

1.1 多层感知机

1) 多层感知机原理

多层感知器(Multi-Layer Perceptron, MLP)为层级结构, 包括输入层、隐含层和输出层。在 MLP 中, 各层神经元节点之间通过一定的权重连接, 每个节点的输入由连接到它的前面各个节点的输出加权确定(输入层除外)。引入激活函数, 对隐藏层中各节点输入进行非线性变换。通过多层叠加, MLP 可逼近任意连续函数, 解决非线性回归问题。

MLP 神经网络训练过程的目标是通过调整激活函数、训练函数、隐含层数、隐含层神经元数量等超参数, 找到使损失函数最优的权值和阈值集。

2) 预测评价指标

为定量检验 MLP 模型预测准确性, 采用 3 种预测评价指标: 平均绝对误差、平均绝对百分比误差与均方根误差。

(1) 平均绝对误差 (Mean Absolute Error, MAE) 是用来比较预测值和真实值之间绝对偏离程度的指标, 表示为式(1):

$$\text{MAE} = \frac{1}{N} \sum_{i=1}^N |P_{f,t} - P_{m,t}| \quad (1)$$

式中:

$P_{f,t}$ —— t 时刻的用电负荷预测值;

$P_{m,t}$ —— t 时刻的用电负荷真实值;

N —— 数据集样本数目。

(2) 平均绝对百分比误差(Mean Absolute Percentage Error, MAPE)是表征预测值与真实值之间相对偏离程度的指标, 表示为式(2):

$$\text{MAPE} = \frac{1}{N} \sum_{i=1}^N \left| \frac{P_{f,t} - P_{m,t}}{P_{m,t}} \right| \times 100\% \quad (2)$$

(3) 均方根误差(Root Mean Squared Error, RMSE)是衡量预测值与真实值之间偏差离散程度的指标, 表示为式(3):

$$\text{RMSE} = \sqrt{\text{MSE}} = \sqrt{\frac{1}{N} \sum_{i=1}^N (P_{f,t} - P_{m,t})^2} \quad (3)$$

1.2 经验模态分解

经验模态分解(EMD)是一种针对非线性非平稳信号的时频分析方法, 由黄锷等人提出。EMD 理论认为任一复杂的时间信号是由若干个相互不同的本征模态函数(Intrinsic Mode Function, IMF)组成的, 可采用一定方法将复杂的时间信号分离成具有物理意义的从高频到低频的有限个独立分量, 即基本时间信号。用电负荷时间序列可以看作是一种非平稳的信号, 使用 EMD 将负荷分解成多个基本信号, 并分别采用多个模型建模可获得更准确的负荷预测结果。

EMD 过程中各个 IMF 需要具备以下 2 个要素:

1) 在整个数据段内, 极值个数与穿过时间轴的点个数相同或相差最多不超过 1 个。

2) 在数据段任何一处, 由局部极大、极小值点形成的包络线均值为 0。

用电负荷时间序列采用 EMD 方法的分解过程如下:

首先, 根据原始时间信号 $X(t)$ 的局部上、下极值点, 得到 $X(t)$ 的上、下包络线。求上、下包络线的均值, 得到均值线 $m_1(t)$ 。 $X(t)$ 与 $m_1(t)$ 相减, 则得到:

$$h_1(t) = X(t) - m_1(t) \quad (4)$$

判断 $h_1(t)$ 能否满足 IMF 所需满足的 2 项要求。若满足, 则 $h_1(t)$ 就是第 1 阶 IMF, 若不满足, 则以 $h_1(t)$ 为基础, 重复上述操作, 得到 $h_1(t)$ 的上、下包络线的均值线 $m_1^1(t)$ 。 $h_1(t)$ 减去 $m_1^1(t)$, 得到式(5):

$$h_1^1(t) = h_1(t) - m_1^1(t) \quad (5)$$

此时, 检验 $h_1^1(t)$ 可否满足 IMF 所需条件, 若满足, 则 $h_1^1(t)$ 成为第 1 阶 IMF, 若不满足, 以 $h_1^1(t)$ 为基础, 按上述方法重复 k 次, 直到 $h_1^k(t)$ 满足 IMF 的条件为止。 $h_1^k(t)$ 由 $h_1^{k-1}(t)$ 与 $h_1^{k-1}(t)$ 上、下包络线的均值线 $m_1^k(t)$ 相减得到, 表示为式(6):

$$h_1^k(t) = h_1^{k-1}(t) - m_1^k(t) \quad (6)$$

式中:

$h_1^k(t)$ —— 第 1 阶 IMF, 记作 $c_1(t)$, 它包含着 $X(t)$ 中频率最高的成分。

从 $X(t)$ 中减去 $c_1(t)$, 得到频率较低的残差为 $r_1(t)$,

表示为式(7):

$$r_1(t) = X(t) - c_1(t) \quad (7)$$

将 $r_1(t)$ 看成新的信号, 按照上述操作, 经过多次运算能够得到所有的 $r_j(t)$, 表示为式(8):

$$r_j(t) = r_{j-1}(t) - c_j(t) (j = 2, 3, \dots, n) \quad (8)$$

当满足条件“ $c_n(t)$ 或 $r_n(t)$ 小于给定的误差”, 或“残差 $r_n(t)$ 为单调函数, 不能再从中提取 IMF”时, EMD 对时间序列的分解过程停止。 $X(t)$ 最终分解成式(9)形式:

$$X(t) = \sum_{j=1}^n c_j(t) + r_n(t) \quad (9)$$

1.3 基于多分量重构的 EMD-MLP 组合模型构建

本文提出的基于多分量重构的 EMD-MLP 组合预测模型示意图如图 1 所示, 包含数据分解、分量重构、特征选择、模型训练与测试步骤。

首先, 采用 EMD 方法对原始用电负荷数据进行分解, 形成多个本征模态分量($IMF_1, IMF_2, \dots, IMF_N$, 残差)。传统采用 EMD 分解方法的预测模型对每一个分量分别预测, 再将其结果叠加作为最终预测值。

然而此方法存在一些问题, 首先, 对每个分量分别进行预测会导致建模计算量的增加; 其次, 对分量分别预测后进行叠加可能会引入预测误差的累积, 从而限制了预测精度。

为解决这些问题, 本文提出多分量重构手段, 也即将经过 EMD 分解后的分量根据其平稳程度进行划分, 并进行重构。具体而言, 对各模态分量采用极值点划分法进行划分, 对划分后的分量进行叠加重构, 形成高频成分(High Frequency Component, HFC)与低频成分(Low Frequency Component, LFC)。

使用 MLP 模型对用电负荷数据中的高频与低频成分分别进行预测, 建立的模型分别记为 M-HFC, M-LFC。为了筛选出最优输入特征, 采用皮尔逊相关系数法对候选特征进行分析。使用训练集对 M-HFC, M-LFC 分别进行训练调参, 优化模型结构。最后, 使用训练好的模型在测试集上对用电负荷数据的高频成分和低频成分分别预测。将 M-HFC, M-LFC 的预测结果 O_H, O_L 等权值求和, 得到用电负荷预测值。

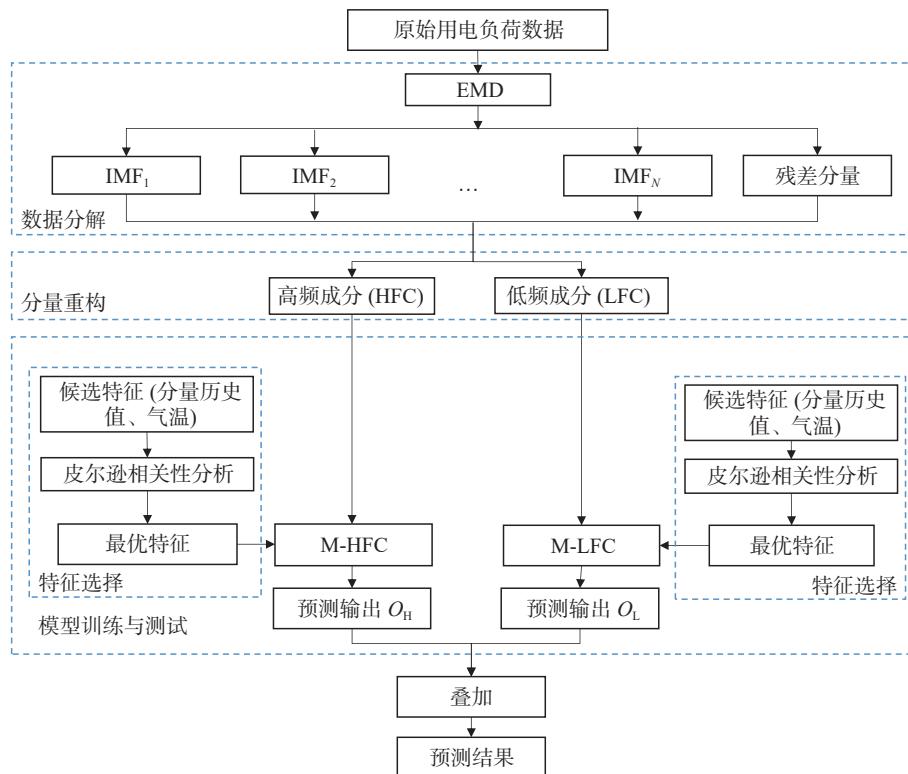


图 1 EMD-MLP 预测模型示意图

Fig. 1 Schematic diagram of the proposed EMD-MLP combination model

2 数据处理

2.1 负荷数据分解及分量重构

本研究使用的负荷数据集从南澳电力市场获取^[41], 时间范围为 2018 年 1 月 1 日至 2018 年 12 月 31 日, 以及 2019 年 1 月 1 日至 2019 年 12 月 31 日, 每步 15 min(如图 2、图 3 所示)。

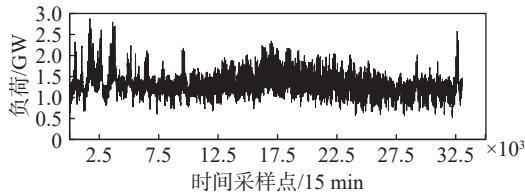


图 2 2018 年南澳用电负荷时间序列图

Fig. 2 Time series of electrical load in South Australia in 2018
(step length: 15 min)

基于 2018 年、2019 年南澳原始负荷数据的 EMD 分解结果分别如图 4、图 5 所示。

采用极值点划分法^[42]对经 EMD 分解后的各个分解分量进行重构。该方法首先求出各 IMF 分量的

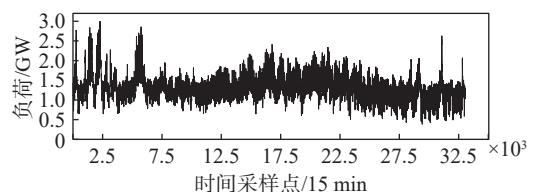


图 3 2019 年南澳用电负荷时间序列图

Fig. 3 Time series of electricity load in South Australia in 2019
(step length: 15 min)

极大、极小值个数, 然后根据极值的个数对各 IMF 分量划分并重构。极值个数反映出分量的波动程度。基于极值点划分法将各分量重构为高、低频 2 个成分。表 1 给出了基于 2018 年、2019 年南澳用电负荷数据得到的各分量极值点个数。选择一个合适的 ρ 作为区分高、低频成分的阈值, 本文选择 $\rho=100$ 。因此, 基于 2018 年、2019 年数据, 得到各分量中的 IMF1-IMF9 重构后形成 HFC, 此成分波动频率较高, 代表短期波动, IMF10-IMF15 叠加重构为 LFC, 此成分波动频率较低, 变化平缓, 代表长期趋势。各分解分量的重构结果如图 6、图 7 所示。

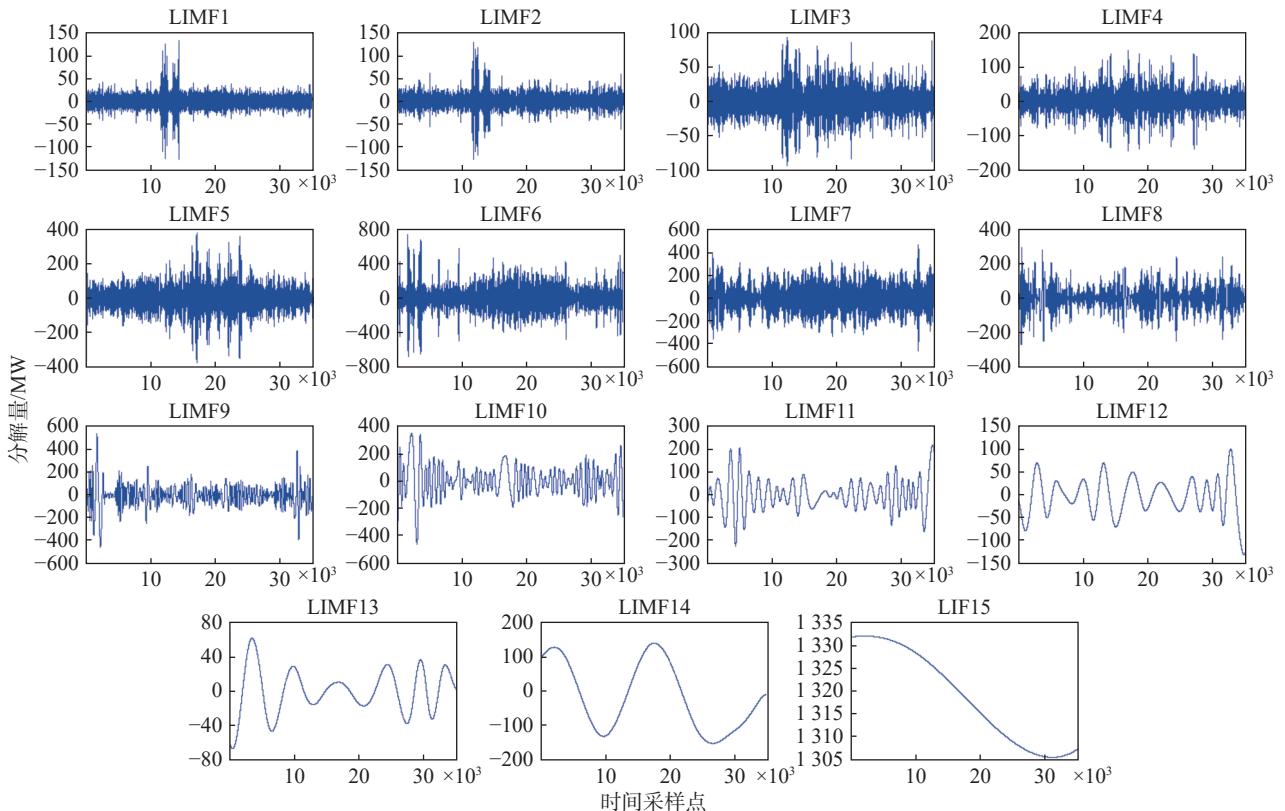


图 4 原始负荷序列的 EMD 分解结果(2018 年南澳用电负荷数据集)

Fig. 4 EMD decomposition results of original load series from South Australia in 2018

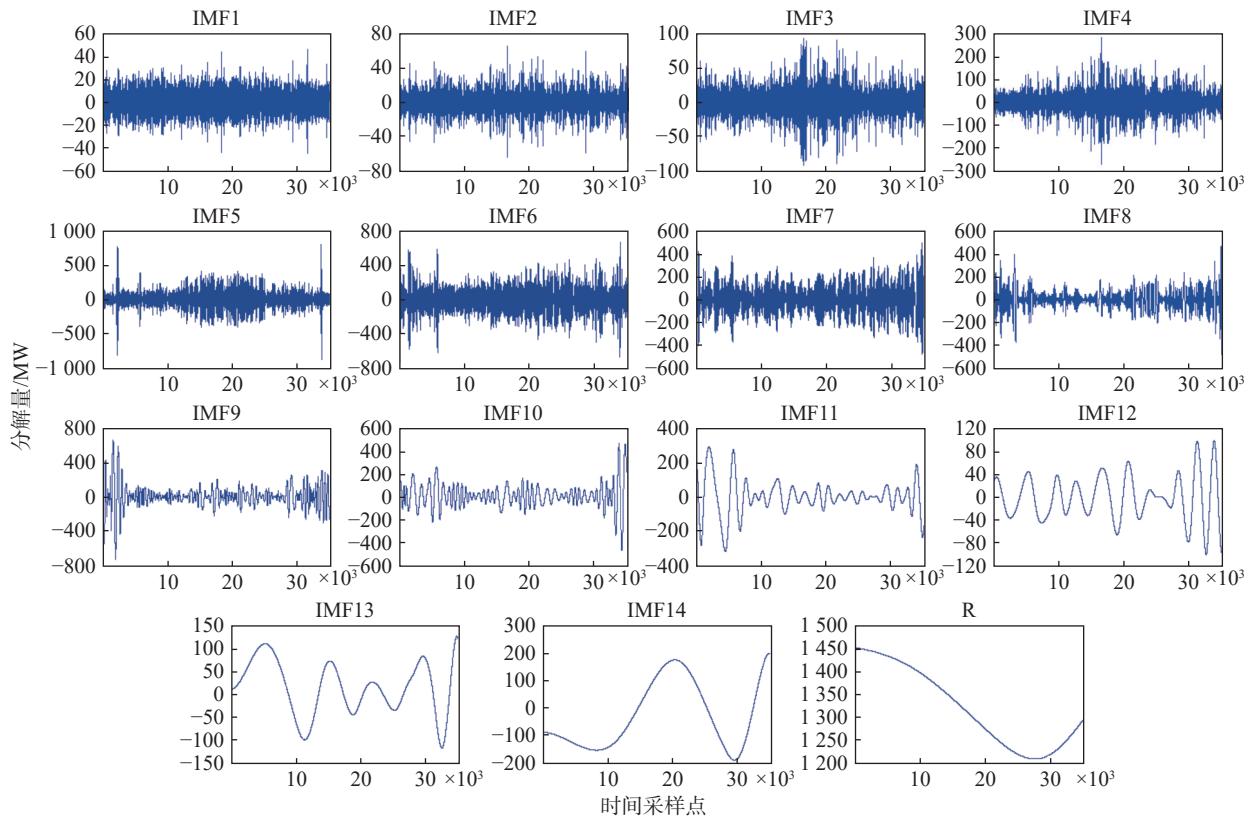


图 5 原始负荷序列的 EMD 分解结果(2019 年南澳负荷数据集)

Fig. 5 EMD decomposition results of original load series from South Australia in 2019

表 1 各分解分量极值点个数

Tab. 1 The number of extreme points of each component

	分量	IMF1	IMF2	IMF3	IMF4	IMF5	IMF6	IMF7	IMF8
2018年数据集	极值个数	20609	12863	8176	5341	3023	1540	749	448
	分量	IMF9	IMF10	IMF11	IMF12	IMF13	IMF14	残差	—
	极值个数	202	94	49	20	11	3	1	—
2019年数据集	分量	IMF1	IMF2	IMF3	IMF4	IMF5	IMF6	IMF7	IMF8
	极值个数	21609	13581	8397	4900	2446	1197	653	357
	分量	IMF9	IMF10	IMF11	IMF12	IMF13	IMF14	残差	—
	极值个数	162	84	38	21	8	3	1	—

2.2 基于皮尔逊相关系数法的特征选择

为了对 d 日 t 时刻用电负荷的高频、低频成分进行预测, 首先分别选取他们的历史值作为候选输入特征^[43-44], 包含前 1 日($d-1$)至前 7 日($d-7$)同一时刻 t 的历史值(记为 $x_t^{d-1}, x_t^{d-2}, \dots, x_t^{d-7}$)。

此外, 一些天气因素, 例如空气温度, 也能影响到用电负荷的大小。本文采用预测日 d 的日最高温度、日平均温度、日最低温度预测值(记为 T_{\max}^d ,

$T_{\text{ave}}^d, \dots, T_{\min}^d$)作为另一组候选输入特征。使用的气温数据与负荷时间范围相同, 为 2018 年 1 月 1 日至 2018 年 12 月 31 日及 2019 年 1 月 1 日至 2019 年 12 月 31 日。日最高、日平均、日最低温度数据为每天记录一次。2018 年与 2019 年的南澳州阿德莱德市温度时间序列如图 8、图 9 所示。

对于候选特征, 采用皮尔逊相关系数法进行最优输入特征的选取^[45]。皮尔逊相关系数用于度量输

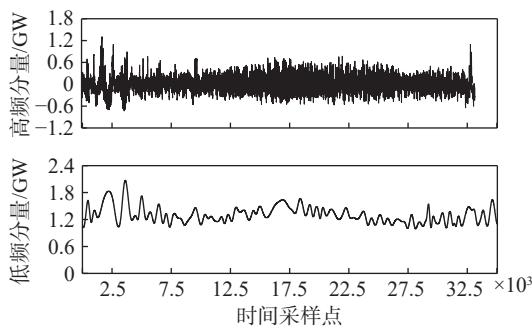


图 6 2018 年南澳用电负荷的分解分量重构结果

Fig. 6 The reconstructed high-frequency and low-frequency components of electrical load in South Australia in 2018

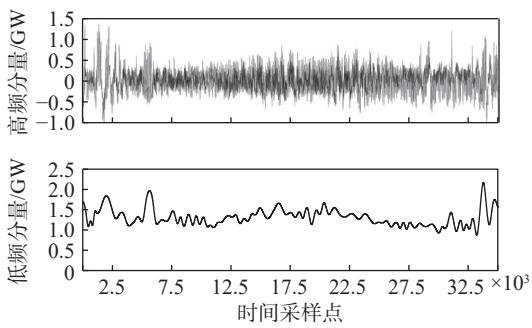


图 7 2019 年南澳用电负荷的分解分量重构结果

Fig. 7 The reconstructed high-frequency and low-frequency components of electrical load in South Australia in 2019

入变量 x 和输出变量 y 之间的线性相关性, 其值介于-1与1之间。两个变量之间的皮尔逊相关系数定义为两个变量之间的协方差和标准差的商, 表示为式(10)。当相关系数为1时, x 和 y 完全正相关, 当相关系数为-1时, x 和 y 完全负相关。相关系数的

绝对值越大, 相关性越强; 相关系数越接近于0, 相关度越弱。相关系数位于0.7~1.0属于强相关, 0.4~0.7为中等程度相关, 0.2~0.4为弱相关, 0.0~0.2为极弱相关或无相关。

$$r_{x,y} = \frac{\text{cov}(x,y)}{\sigma_x \sigma_y} = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2}} \quad (10)$$

式中:

- $r_{x,y}$ ——皮尔逊相关系数;
- $\text{cov}(x,y)$ —— x 和 y 的协方差;
- σ_x ——变量 x 的标准差;
- σ_y ——变量 y 的标准差;
- x_i ——第 i 个样本的输入变量;
- \bar{x} ——输入变量 x 在全样本上的平均值;
- y_i ——第 i 个样本的输出;
- \bar{y} ——输出变量 y 在全样本上的平均值。

各候选特征与高频、低频成分间的相关性检验如表2所示。选取相关系数绝对值大于0.4的特征向量集合(加下划线标注), 分别作为M-HFC与M-LFC的最优输入特征。

3 试验结果

试验中采用了2份初始数据集, 分别为2018年1月1日至2018年12月31日及2019年1月1日至2019年12月31日的南澳用电负荷及气温数据集。每份初始数据集划分为两个子数据集: 前2/3初

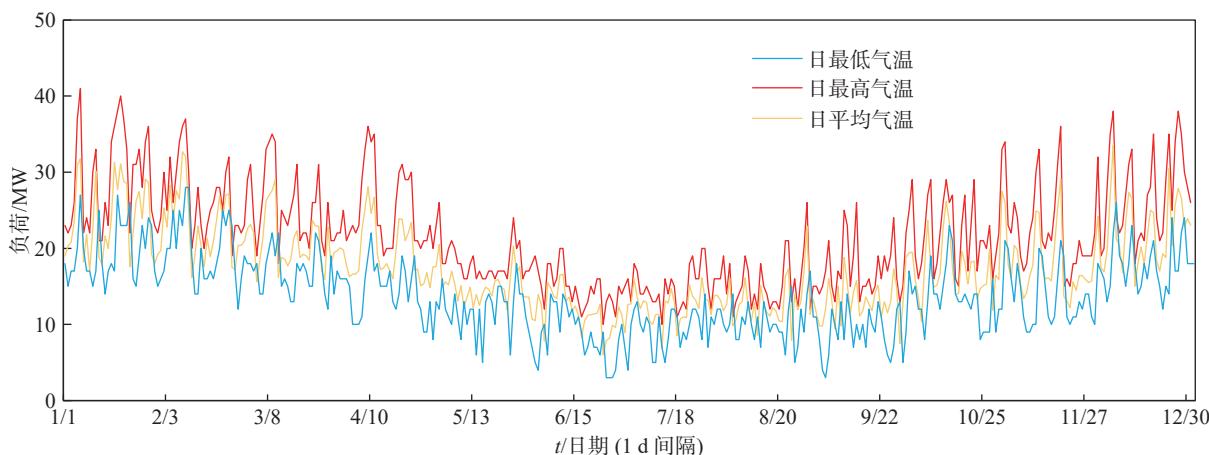


图 8 2018 年南澳阿德莱德温度时间序列

Fig. 8 Temperature time series of Adelaide, South Australia in 2018

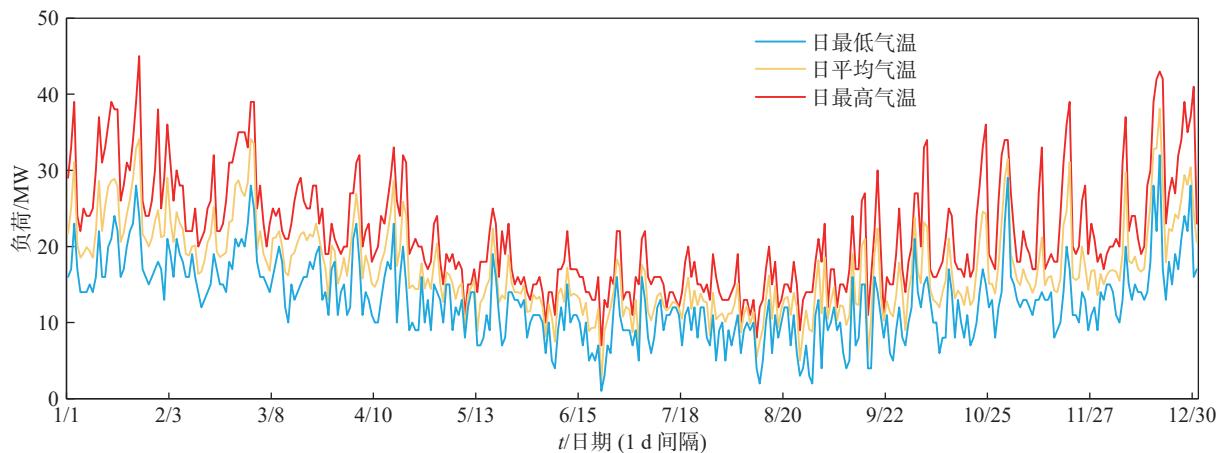


图 9 2019 年南澳阿德莱德温度时间序列

Fig. 9 Temperature time series of Adelaide, South Australia in 2019

始数据集作为初始训练集,后 1/3 初始数据集作为测试集。初始训练集又进一步划分为训练集(前 1/2 初始训练集)与验证集(后 1/2 初始训练集),以确定预测模型超参数。测试集用来检测模型的泛化性能,不允许参与预测模型训练。

M-HFC 与 M-LFC 的输入层、输出层神经元数目与相应训练集的输入、输出维数相等,根据表 2,基于 2018 年数据训练集的模型 M-HFC 与 M-LFC 的输入层神经元个数为 7 和 3,输出层神经元数目为 1 和 1。基于 2019 年数据训练集的模型 M-HFC 与 M-LFC 的输入层神经元个数为 7 和 4,输出层神经元数目为 1 和 1。

M-HFC 与 M-LFC 的最优超参数是通过在对应的训练集上训练得到的。需要调整的超参数有激活函数、训练函数、隐含层数、隐含层神经元数目、学习速率、迭代次数、迭代目标。超参数的选取方法为,设定一个超参数调整范围/可选项,通过误差反馈迭代一定次数找到最优。MLP 神经网络的可选激活函数包括对数 S 型函数,双曲正切函数,线性整流函数。可选用的训练函数包括小批量梯度下降法

(Mini-Batch Gradient Descent, MBGD)、批量梯度下降法(Batch Gradient Descent, BGD, 也叫最速梯度下降法)、随机梯度下降法(Stochastic Gradient Descent, SGD)、动态自适应学习率的梯度下降算法(Adaptive Gradient Descent, Adagad)等。隐含层数、隐含层神经元数目的调节范围分别为 1~2 与 2~100,学习率调节范围为 0.01~0.1,迭代次数调节范围是 100~2 000,迭代目标调节范围为 0.000 01~0.01。基于 2018 年、2019 年数据集的 M-HFC 与 M-LFC 模型在相应训练集上的最优超参数如表 3 所示。

为了验证本文提出的 EMD-MLP 组合模型预测性能,在数据集上建立另外 3 种模型,分别是持续性模型(PERSISTENCE)、单一 MLP 模型(MLP)与传统 EMD 组合模型(EMD-N)进行对比分析。持续性模型是最简单的预测模型,同时具有不错的预测性能,因而常常用作基准模型。持续性模型假设预测时刻的用电负荷 y_t 与预测窗口 L 之前的用电负荷 \bar{y}_{t-L} 相同,将 \bar{y}_{t-L} 直接作为预测值,描述为式(11)。单一 MLP 模型不经过 EMD 分解,直接对用电负荷预测。传统 EMD 组合模型首先将用电负荷经 EMD 分解

表 2 各候选特征与负荷高频、低频成分之间的相关系数(基于 2018 年、2019 年南澳用电负荷数据训练集)

Tab. 2 Correlation coefficients between the candidate features and HFC, LFC (Based on the training data of South Australia electrical load in 2018 and 2019)

数据集	模型	x_t^{d-1}	x_t^{d-2}	x_t^{d-3}	x_t^{d-4}	x_t^{d-5}	x_t^{d-6}	x_t^{d-7}	T_{\max}^d	T_{ave}^d	T_{\min}^d
2018年	M-HFC	0.70	0.54	0.51	0.50	0.48	0.53	0.58	0.04	0.03	0.02
	M-LFC	0.89	0.64	0.40	0.25	0.21	0.22	0.23	0.17	0.19	0.18
2019年	M-HFC	0.68	0.48	0.43	0.44	0.48	0.53	0.60	0.09	0.07	0.05
	M-LFC	0.93	0.77	0.57	0.41	0.32	0.29	0.29	0.23	0.26	0.25

表 3 M-HFC 与 M-LFC 在相应训练集上的最优超参数 (基于 2018 年、2019 年南澳用电负荷数据训练集)

Tab. 3 Optimal hyper-parameters of M-HFC and M-LFC (Based on the corresponding training data from South Australia electrical load in 2018 and 2019)

模型数据集	2018		2019	
	M-HFC	M-LFC	M-HFC	M-LFC
激活函数	Logistic	Logistic	Logistic	Logistic
训练函数	Adagrad	Adagrad	Adagrad	Adagrad
隐含层数	1	1	1	1
隐含层神经元数目	30	8	25	50
学习速率	0.1	0.1	0.4	0.1
迭代次数	600	1 000	800	500
迭代目标	0.004	0.004	0.01	0.004

为多个分量, 然后对各个分量分别预测, 最后将所有分量的预测结果叠加作为用电负荷预测值。

$$\hat{y}_{t-L} = y_t \quad (11)$$

基于 2018 年、2019 年南澳电力负荷数据测试集, 本文提出的 EMD-MLP 组合模型与持续性模型、

单一 MLP 模型、传统 EMD 组合模型的泛化误差箱型图如图 10、图 11 所示。结果显示, 在 4 种模型中, EMD-MLP 模型的预测误差不仅平均值更低, 分布也更集中, 表明本文提出的 EMD-MLP 组合模型不仅可提高预测准确度, 也具有更好的稳定性。图 12、图 13 为基于 4 种预测模型的用电负荷预测值与真实值在局部测试集上的对比图, 该图也显示 EMD-MLP 组合模型预测值与真实值更贴近。

对误差箱型图 10 和图 11 中的绝对百分比误差、绝对误差在全测试样本上取平均值, 对平方误差在全测试样本上取平均值再开方, 得到 4 种模型(EMD-MLP 组合模型、持续性模型、单一 MLP 模型、传统 EMD 组合模型)的 MAPE、MAE、RMSE3 个误差指标的结果。基于 2018 年、2019 年数据测试集, 这些误差指标结果如图 14 所示。对于持续性模型, 在 2018 年、2019 年的数据集上, MAPE 分别为 12.98% 与 15.68%, MAE 分别为 148.5 MW 与 173.7 MW, RMSE 分别为 207.1 MW 与 271.2 MW。而单一 MLP 模型在这两个数据集上的 MAPE、MAE 和

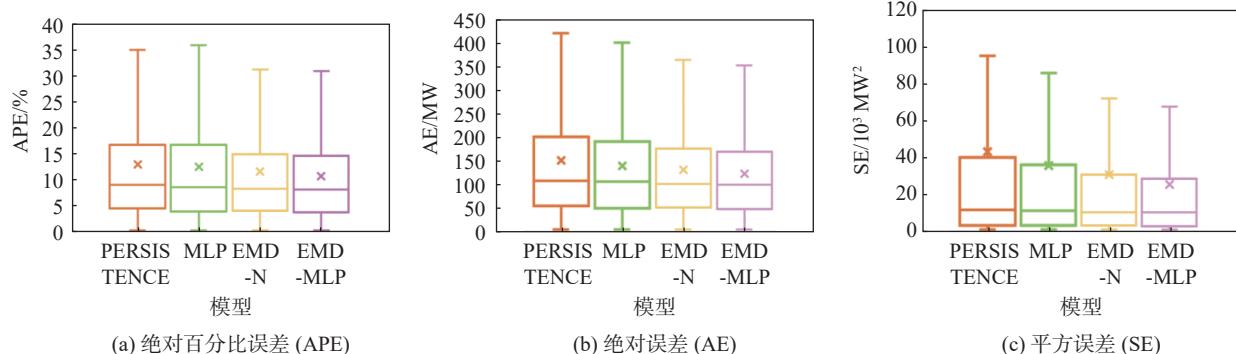


图 10 绝对百分比误差(APE), 绝对误差(AE)与平方误差(SE)的箱型图(2018 年)

Fig. 10 Boxplots of APE, AE and SE based on the test dataset in 2018

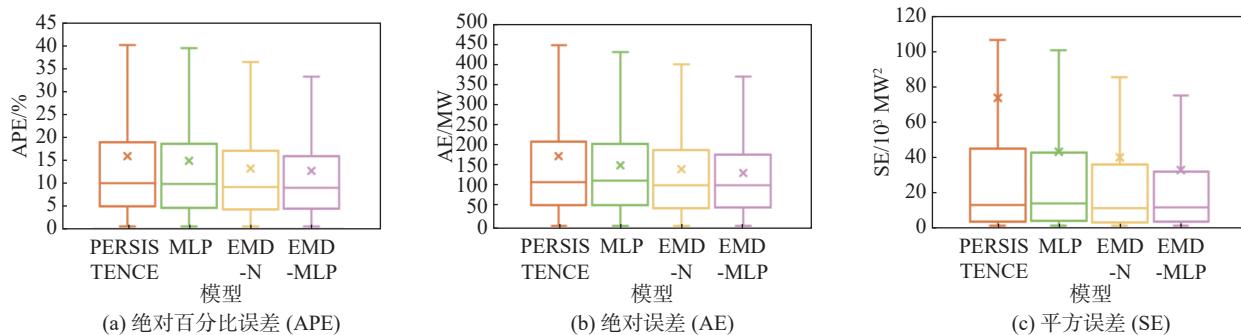


图 11 绝对百分比误差(APE), 绝对误差(AE)与平方误差(SE)的箱型图(2019 年)

Fig. 11 Boxplots of APE, AE and SE based on the test dataset in 2019

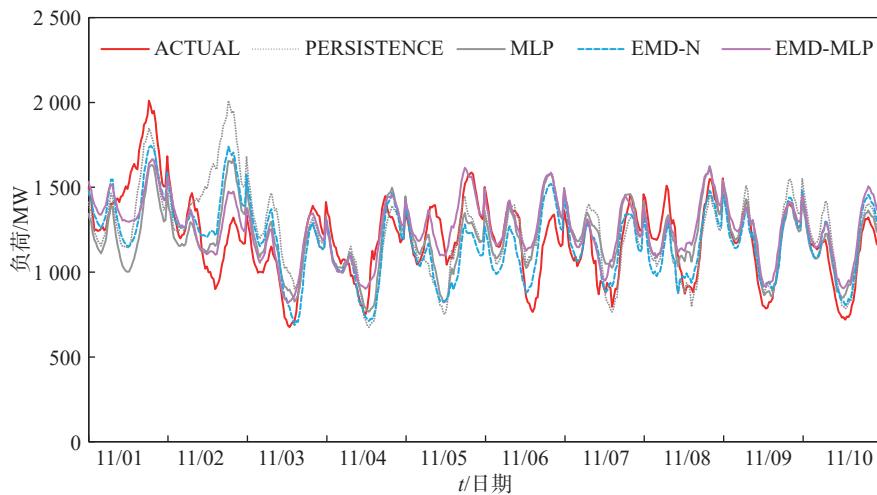


图 12 4 种模型负荷预测值与真实值对比(2018 年部分测试集:2018 年 11 月 1~10 日)

Fig. 12 Comparison of forecasted and actual values of load regarding the four models (part of the test dataset in 2018: Nov. 1, 2018 ~ Nov. 10, 2018)

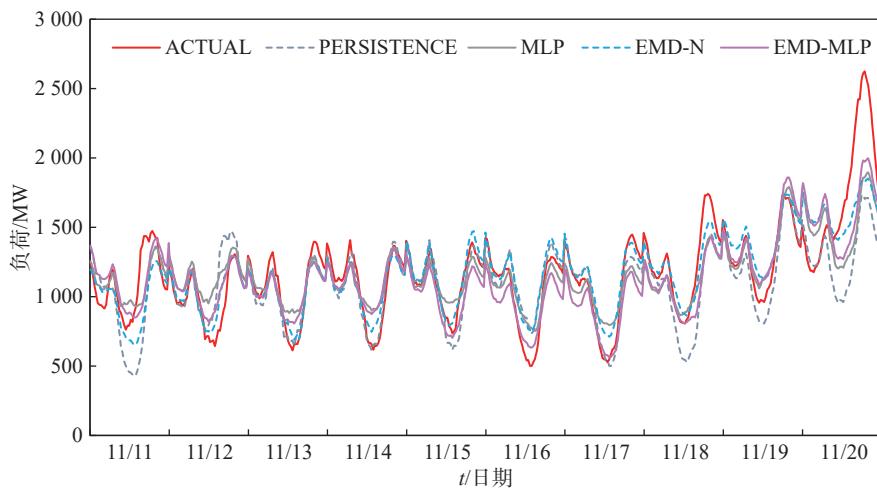


图 13 4 种模型负荷预测值与真实值对比(2019 年部分测试集:2019 年 11 月 11~20 日)

Fig. 13 Comparison of forecasted and actual values of load regarding the four models (part of the test dataset in 2019: Nov. 11, 2019 ~ Nov. 20, 2019)

RMSE 分别降至 12.52%、137.6 MW、187.8 MW 以及 14.68%、151.0 MW、206.7 MW。这证明采用多影响因素作为输入的 MLP 相比简单的持续性模型可以提高预测精度, 表明了采用 MLP 建模的必要性。

相比单一 MLP 模型, EMD-N 和 EMD-MLP 模型进一步提高了预测效果, 表明将 EMD 分解与 MLP 结合进行预测的性能更具优越性。而与传统的 EMD 组合模型相比, 本文提出的 EMD-MLP 组合模型预测精度更高。在 2018 年和 2019 年的数据集上, MAPE、MAE 和 RMSE 分别进一步降低至 10.60%、119.8 MW、157.3 MW 和 12.37%、132.1 MW、

179.5 MW。因此, 本文提出的将 EMD 与 MLP 结合的新方法通过将 EMD 分量重构后进行预测, 避免了传统 EMD 组合预测方法中误差累加的问题, 有效提高了预测精度。同时, 本章提出的方法相比传统 EMD 组合预测方法, 能够实现数据压缩, 极大地降低了计算量, 提高了预测效率。

为了验证所提出模型的鲁棒性, 选取另一场景下, 即塔斯马尼亚电力市场 2018 年、2019 年的用电负荷数据进行模拟。相应的用电负荷数据展示于附图 S1、附图 S2, 空气温度数据展示于附图 S3、附图 S4。基于相应训练数据集选取的模型最优输

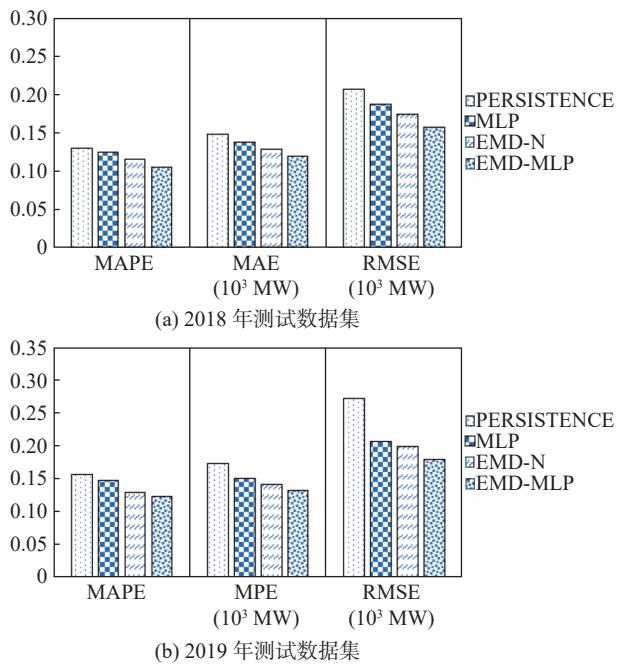


图 14 4 种模型在南澳电力负荷不同数据测试集上的预测误差(2018 年和 2019 年)

Fig. 14 Forecast errors of the four models based on the test data of South Australia electrical load in 2018 and 2019

表 4 各模型在塔斯马尼亚电力市场 2018 年和 2019 年用电负荷数据测试集上的泛化误差

Tab. 4 Forecast errors of different models on the test dataset of electrical load in Tasmania electricity market in 2018 and 2019

数据集	模型	MAPE/%	MAE/MW	RMSE/MW
2018年	PERSISTENCE	7.50	82.95	104.87
	MLP	6.65	72.73	91.84
	EMD-N	5.89	64.54	82.76
	EMD-MLP	4.61	50.19	62.60
2019年	PERSISTENCE	8.18	84.58	108.15
	MLP	7.42	75.62	96.44
	EMD-N	6.50	66.99	86.25
	EMD-MLP	5.13	52.41	67.79

入特征见附表 S1。经过训练后模型的最优超参数见附表 S2。各模型在相应测试数据集上的泛化误差列于表 4。结果显示, 基于多分量重构的 EMD-MLP 组合模型相比其他基线模型在 MAPE、MAE 和 RMSE 上都表现出更好的泛化性能。

综上所述, 本文提出的将 EMD 与 MLP 结合的新方法有效提高了预测精度, 并且在不同数据集上具有鲁棒性, 在用电负荷预测领域具有一定的使用价值与应用潜力。

4 结论

本研究提出了一种将经验模态分解与多层感知机结合用于电力系统用电负荷日前预测的新方法。该方法将原始负荷信号分解为多个本征模函数分量, 并采用极值点划分法将这些分量重构为高频和低频两个成分, 对它们分别建模预测并将其预测结果叠加作为最终的用电负荷预测值。为验证所提出的 EMD-MLP 组合模型在提高预测精度方面的有效性, 使用澳大利亚南澳以及塔斯马尼亚电力市场 2018 年和 2019 年的实测用电负荷数据进行试验。通过与持续性模型、单一 MLP 模型以及传统 EMD 组合模型进行外推预测效果对比, 所提出的 EMD-MLP 组合模型在泛化误差上表现最优, 验证了该模型在用电负荷预测精度方面的优越性。

此外, 本文所提方法将多分量重构合并为个数较少的分量并对这些分量进行预测, 相比传统的 EMD 分解后对各分量分别预测的方法, 具有以下实际意义: (1)该方法通过精简预测对象减少了预测计算量与模型复杂度, 提高了预测效率与模型可调节性, 可以方便地在实际应用中进行日前、实时预测; (2)通过将分量合并为个数较少的分量, 该方法减少了预测过程中的噪声和干扰, 可有效提高预测模型的稳定性和准确性。因此, 提出的 EMD-MLP 组合预测新方法在电力系统能量管理中具有重要的应用前景, 为实现电力系统的运行优化提供了可靠基础。

参考文献:

- [1] 吴亚雄, 谢敏. 基于 BP 神经网络灰色回归组合模型的年最大负荷预测 [J]. 南方能源建设, 2017, 4(2): 46-50, 57. DOI: 10.16516/j.gedi.issn2095-8676.2017.02.007.
- [2] WU Y X, XIE M. Annual peak load forecasting based on combination model of back propagation neural network and grey regression [J]. Southern energy construction, 2017, 4(2): 46-50, 57. DOI: 10.16516/j.gedi.issn2095-8676.2017.02.007.
- [3] 李彬, 白雪峰, 王京菊, 等. 新型电力负荷管理系统发展的关键支撑技术研究 [J]. 内蒙古电力技术, 2023, 41(2): 1-6. DOI: 10.19929/j.cnki.nmgdls.2023.0018.
- [4] LI B, BAI X F, WANG J J, et al. Research on key supporting technology for development of new power load management system [J]. Inner Mongolia electric power, 2023, 41(2): 1-6. DOI: 10.19929/j.cnki.nmgdls.2023.0018.
- [5] 孙玉芹, 王亚文, 朱威, 等. 基于考虑气温影响的门限自回归移动平均模型居民日用电负荷预测 [J]. 电力建设, 2022, 43(9): 117-124. DOI: 10.12204/j.issn.1000-7229.2022.09.012.
- [6] SUN Y Q, WANG Y W, ZHU W, et al. Residential daily power load forecasting based on threshold ARMA model considering the influence of temperature [J]. Electric power construction, 2022, 43(9): 117-124. DOI: 10.12204/j.issn.1000-7229.2022.09.

- [4] 赵爽, 阮俊枭, 支刚, 等. 考虑尖峰负荷特性指标的用户用电行为分析 [J]. *内蒙古电力技术*, 2022, 40(5): 39-45. DOI: 10.19929/j.cnki.nmgdls.2022.0079.
- [5] ZHAO S, RUAN J X, ZHI G, et al. Analysis of power consumption behavior of users considering peak load characteristic indicators [J]. *Inner Mongolia electric power*, 2022, 40(5): 39-45. DOI: 10.19929/j.cnki.nmgdls.2022.0079.
- [6] DORDONNAT V, KOOPMAN S J, OOMS M, et al. An hourly periodic state space model for modelling French national electricity load [J]. *International journal of forecasting*, 2008, 24(4): 566-587. DOI: 10.1016/j.ijforecast.2008.08.010.
- [7] PAPALEXOPOULOS A D, HESTERBERG T C. A regression-based approach to short-term system load forecasting [J]. *IEEE transactions on power systems*, 1990, 5(4): 1535-1547. DOI: 10.1109/59.99410.
- [8] VÄHÄKYLA P, HAKONEN E, LÉMAN P. Short-term forecasting of grid load using Box-Jenkins techniques [J]. *International journal of electrical power & energy systems*, 1980, 2(1): 29-34. DOI: 10.1016/0142-0615(80)90004-6.
- [9] CHEN J F, WANG W M, HUANG C M. Analysis of an adaptive time-series autoregressive moving-average (ARMA) model for short-term load forecasting [J]. *Electric power systems research*, 1995, 34(3): 187-196. DOI: 10.1016/0378-7796(95)00977-1.
- [10] MBAMALU G A N, EL-HAWARY M E. Load forecasting via suboptimal seasonal autoregressive models and iteratively reweighted least squares estimation [J]. *IEEE transactions on power systems*, 1993, 8(1): 343-348. DOI: 10.1109/59.221222.
- [11] TARSITANO A, AMERISE I L. Short-term load forecasting using a two-stage sarimax model [J]. *Energy*, 2017, 133: 108-114. DOI: 10.1016/j.energy.2017.05.126.
- [12] HUANG S R. Short-term load forecasting using threshold autoregressive models [J]. *IEE proceedings-generation, transmission and distribution*, 1997, 144(5): 477-481. DOI: 10.1049/ip-gtd:19971144.
- [13] ROMAN-PORTABALES A, LOPEZ-NORES M, PAZOS-ARIAS J J. Systematic review of electricity demand forecast using ANN-based machine learning algorithms [J]. *Sensors*, 2021, 21(13): 4544. DOI: 10.3390/s21134544.
- [14] CHEN H, WAN Q L, ZHANG B, et al. Short-term load forecasting based on asymmetric ARCH models [C]//Anon. IEEE PES General Meeting, Minneapolis, July 25-29, 2010. Minneapolis: IEEE, 2010: 1-6. DOI: 10.1109/PES.2010.5590185.
- [15] HOR C L, WATSON S J, MAJITHIA S. Daily load forecasting and maximum demand estimation using ARIMA and GARCH [C]//Anon. 2006 International Conference on Probabilistic Methods Applied to Power Systems, Stockholm, June 11-15, 2006. Stockholm: IEEE, 2006: 1-6. DOI: 10.1109/PMAPS.2006.36023.
- [16] LIU H P, SHI J. Applying ARMA-GARCH approaches to forecasting short-term electricity prices [J]. *Energy economics*, 2013, 37: 152-166. DOI: 10.1016/j.eneco.2013.02.006.
- [17] CORBA B S, EGROGLU E, DALAR A Z. AR-ARCH type artificial neural network for forecasting [J]. *Neural processing letters*, 2020, 51(1): 819-836. DOI: 10.1007/s11063-019-10117-6.
- [18] 鲍海波, 吴阳晨, 张国应, 等. 基于特征加权 Stacking 集成学习的净负荷预测方法 [J]. *电力建设*, 2022, 43(9): 104-116. DOI: 10.12204/j.issn.1000-7229.2022.09.011.
- [19] BAO H B, WU Y C, ZHANG G Y, et al. Net load forecasting method based on feature-weighted stacking ensemble learning [J]. *Electric power construction*, 2022, 43(9): 104-116. DOI: 10.12204/j.issn.1000-7229.2022.09.011.
- [20] ZHENG K, WEI Y F, WEN Z S, et al. Analysis and application of wind speed interpolation in wind farm based on BP neural network method [J]. *Southern energy construction*, 2021, 8(1): 51-55. DOI: 10.16516/j.gedi.issn2095-8676.2021.01.007.
- [21] RAHMAN S, BHATNAGAR R. An expert system based algorithm for short term load forecast [J]. *IEEE transactions on power systems*, 1988, 3(2): 392-399. DOI: 10.1109/59.192889.
- [22] YINSHENG S, CHUNXIAO L, BAO L, et al. Principal component analysis of short-term electric load forecast data based on grey forecast [J]. *Journal of physics: conference series*, 2020, 1486(6): 062031. DOI: 10.1088/1742-6596/1486/6/062031.
- [23] PANDIAN S C, DURAISWAMY K, RAJAN C C A, et al. Fuzzy approach for short term load forecasting [J]. *Electric power systems research*, 2006, 76(6-7): 541-548. DOI: 10.1016/j.epsr.2005.09.018.
- [24] 王克杰, 张瑞. 基于改进 BP 神经网络的短期电力负荷预测方法研究 [J]. *电测与仪表*, 2019, 56(24): 115-121. DOI: 10.19753/j.issn1001-1390.2019.024.019.
- [25] WANG K J, ZHANG R. Research on short-term power load forecasting method based on improved BP neural network [J]. *Electrical measurement & instrumentation*, 2019, 56(24): 115-121. DOI: 10.19753/j.issn1001-1390.2019.024.019.
- [26] 张静, 石鑫. 基于改进 MOPSO-BP 算法的短期电力负荷预测研究 [J]. *电力学报*, 2019, 34(6): 556-563. DOI: 10.13357/j.cnki.jep.002844.
- [27] ZHANG J, SHI X. Short-term power load forecasting based on improved MOPSO-BP algorithm [J]. *Journal of electric power*, 2019, 34(6): 556-563. DOI: 10.13357/j.cnki.jep.002844.
- [28] LIANG Y, NIU D X, HONG W C. Short term load forecasting based on feature extraction and improved general regression neural network model [J]. *Energy*, 2019, 166: 653-663. DOI: 10.1016/j.energy.2018.10.119.
- [29] 刘岩, 彭鑫霞, 郑思达. 基于改进 LS-SVM 的短期电力负荷预测方法研究 [J]. *电测与仪表*, 2021, 58(5): 176-181. DOI: 10.19753/j.issn1001-1390.2021.05.026.
- [30] LIU Y, PENG X X, ZHENG S D. Research on short-term power load forecasting method based on improved LS-SVM [J]. *Electrical measurement & instrumentation*, 2021, 58(5): 176-181. DOI: 10.19753/j.issn1001-1390.2021.05.026.
- [31] RYU S, NOH J, KIM H. Deep neural network based demand side short term load forecasting [J]. *Energies*, 2017, 10(1): 3. DOI: 10.3390/en10010003.
- [32] KONG W C, DONG Z Y, JIA Y W, et al. Short-term residential load forecasting based on LSTM recurrent neural network [J]. *IEEE transactions on smart grid*, 2019, 10(1): 841-851. DOI: 10.1109/TSG.2017.2753802.
- [33] SUN G P, JIANG C W, WANG X, et al. Short - term building load forecast based on a data - mining feature selection and LSTM - RNN method [J]. *IEEJ transactions on electrical and electronic engineering*, 2020, 15(7): 1002-1010. DOI: 10.1002/tee.23144.
- [34] 彭文, 王金睿, 尹山青. 电力市场中基于 Attention-LSTM 的短期负荷预测模型 [J]. *电网技术*, 2019, 43(5): 1745-1751. DOI: 10.13335/j.1000-3673.pst.2018.1554.
- [35] PENG W, WANG J R, YIN S Q. Short-term load forecasting model based on attention-LSTM in electricity market [J]. *Power system technology*, 2019, 43(5): 1745-1751. DOI: 10.13335/j.1000-3673.pst.2018.1554.
- [36] 陆继翔, 张琪培, 杨志宏, 等. 基于 CNN-LSTM 混合神经网络模型的短期负荷预测方法 [J]. *电力系统自动化*, 2019, 43(8): 131-137. DOI: 10.7500/AEPS20181012004.
- [37] LU J X, ZHANG Q P, YANG Z H, et al. Short-term load forecasting method based on CNN-LSTM hybrid neural network model [J]. *Automation of electric power systems*, 2019, 43(8):

- [31] HE F F, ZHOU J Z, FENG Z K, et al. A hybrid short-term load forecasting model based on variational mode decomposition and long short-term memory networks considering relevant factors with Bayesian optimization algorithm [J]. *Applied energy*, 2019, 237: 103-116. DOI: [10.1016/j.apenergy.2019.01.055](https://doi.org/10.1016/j.apenergy.2019.01.055).
- [32] BAHRAMI S, HOOSHMAND R A, PARASTEGARI M. Short term electric load forecasting by wavelet transform and grey model improved by PSO (Particle Swarm Optimization) algorithm [J]. *Energy*, 2014, 72: 434-442. DOI: [10.1016/j.energy.2014.05.065](https://doi.org/10.1016/j.energy.2014.05.065).
- [33] GHASEMI A, SHAYEGHI H, MORADZADEH M, et al. A novel hybrid algorithm for electricity price and load forecasting in smart grids with demand-side management [J]. *Applied energy*, 2016, 177: 40-59. DOI: [10.1016/j.apenergy.2016.05.083](https://doi.org/10.1016/j.apenergy.2016.05.083).
- [34] LI S, GOEL L, WANG P. An ensemble approach for short-term load forecasting by extreme learning machine [J]. *Applied energy*, 2016, 170: 22-29. DOI: [10.1016/j.apenergy.2016.02.114](https://doi.org/10.1016/j.apenergy.2016.02.114).
- [35] FAN X Q, ZHU Y L. The application of empirical mode decomposition and gene expression programming to short-term load forecasting [C]//Anon. Sixth International Conference on Natural Computation, Yantai, August 10-12, 2010. Yantai: IEEE, 2010: 4331-4334. DOI: [10.1109/ICNC.2010.5583605](https://doi.org/10.1109/ICNC.2010.5583605).
- [36] 李秀昊, 刘怀西, 张智勇, 等. 基于 VMD-LSTM 的超短期风向多步预测 [J]. *南方能源建设*, 2023, 10(1): 29-38. DOI: [10.16516/j.gedi.issn2095-8676.2023.01.004](https://doi.org/10.16516/j.gedi.issn2095-8676.2023.01.004).
- [37] LI X H, LIU H X, ZHANG Z Y, et al. Very short-term wind direction multistep forecast based on VMD-LSTM [J]. *Southern energy construction*, 2023, 10(1): 29-38. DOI: [10.16516/j.gedi.issn2095-8676.2023.01.004](https://doi.org/10.16516/j.gedi.issn2095-8676.2023.01.004).
- [38] 邓带雨, 李坚, 张真源, 等. 基于 EEMD-GRU-MLR 的短期电力负荷预测 [J]. *电网技术*, 2020, 44(2): 593-602. DOI: [10.13335/j.1000-3673.pst.2019.0113](https://doi.org/10.13335/j.1000-3673.pst.2019.0113).
- [39] DENG D Y, LI J, ZHANG Z Y, et al. Short-term electric load forecasting based on EEMD-GRU-MLR [J]. *Power system technology*, 2020, 44(2): 593-602. DOI: [10.13335/j.1000-3673.pst.2019.0113](https://doi.org/10.13335/j.1000-3673.pst.2019.0113).
- [40] KONG X Y, LI C, ZHENG F, et al. Short-term load forecasting method based on empirical mode decomposition and feature correlation analysis [J]. *Automation of electric power systems*, 2019, 43(5): 46-52. DOI: [10.7500/AEPS20180404008](https://doi.org/10.7500/AEPS20180404008).
- [41] LIANG Z, SUN G Q, LI H C, et al. Short-term load forecasting based on VMD and PSO optimized deep belief network [J]. *Power system technology*, 2018, 42(2): 598-606. DOI: [10.13335/j.1000-3673.pst.2017.0937](https://doi.org/10.13335/j.1000-3673.pst.2017.0937).
- [42] 刘雨薇. 基于 VMD 和改进 LSTM 的短期电力负荷预测研究 [D]. 武汉: 湖北工业大学, 2020. DOI: [10.27131/d.cnki.ghugc.2020.000099](https://doi.org/10.27131/d.cnki.ghugc.2020.000099).
- [43] LIU Y W. Research on short-term power load forecasting based on VMD and improved LSTM [D]. Wuhan: Hubei University of Technology, 2020. DOI: [10.27131/d.cnki.ghugc.2020.000099](https://doi.org/10.27131/d.cnki.ghugc.2020.000099).
- [44] AEMO. Australian energy market operator electricity price & demand [EB/OL]. <https://www.aemo.com.au/>.
- [45] 杨茂, 陈郁林. 基于 EMD 分解和集对分析的风电功率实时预测 [J]. *电工技术学报*, 2016, 31(21): 86-93. DOI: [10.3969/j.issn.1000-6753.2016.21.010](https://doi.org/10.3969/j.issn.1000-6753.2016.21.010).
- [46] YANG M, CHEN Y L. Real-time prediction for wind power based on EMD and set pair analysis [J]. *Transactions of China electrotechnical society*, 2016, 31(21): 86-93. DOI: [10.3969/j.issn.1000-6753.2016.21.010](https://doi.org/10.3969/j.issn.1000-6753.2016.21.010).
- [47] RAZA M Q, KHOSRAVI A. A review on artificial intelligence based load demand forecasting techniques for smart grid and buildings [J]. *Renewable and sustainable energy reviews*, 2015, 50: 1352-1372. DOI: [10.1016/j.rser.2015.04.065](https://doi.org/10.1016/j.rser.2015.04.065).
- [48] KUSTER C, REZGUI Y, MOURSHED M. Electrical load forecasting models: a critical systematic review [J]. *Sustainable cities and society*, 2017, 35: 257-270. DOI: [10.1016/j.scs.2017.08.009](https://doi.org/10.1016/j.scs.2017.08.009).
- [49] 严雪颖, 秦川, 鞠平, 等. 负荷功率模型的最优特征选择研究 [J]. *电力工程技术*, 2021, 40(3): 84-91. DOI: [10.12158/j.2096-3203.2021.03.013](https://doi.org/10.12158/j.2096-3203.2021.03.013).
- [50] YAN X Y, QIN C, JU P, et al. Optimal feature selection of load power models [J]. *Electric power engineering technology*, 2021, 40(3): 84-91. DOI: [10.12158/j.2096-3203.2021.03.013](https://doi.org/10.12158/j.2096-3203.2021.03.013).

作者简介:

刘璐瑶 (通信作者)

1993-, 女, 助理研究员, 博士, 主要从事可再生能源系统规划运行与源荷预测相关研究工作(e-mail)liuluyao@gedi.com.cn; liuluyao@tsinghua.edu.cn。

刘璐瑶

(编辑 孙舒)

附录

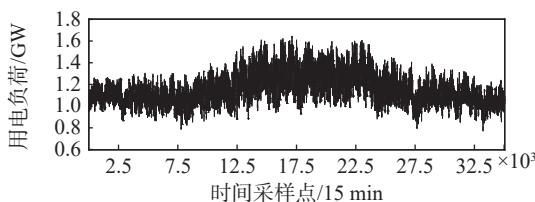


图 S1 2018 年塔斯马尼亚用电负荷时间序列图

Fig. S1 Time series of electrical load in Tasmania in 2018 (step length: 15 min)

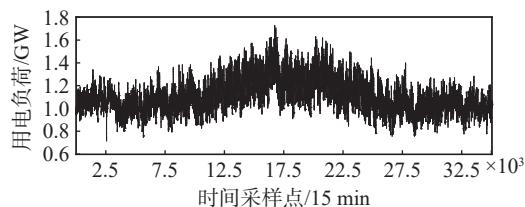


图 S2 2019 年塔斯马尼亚用电负荷时间序列图

Fig. S2 Time series of electrical load in Tasmania in 2019 (step length: 15 min)

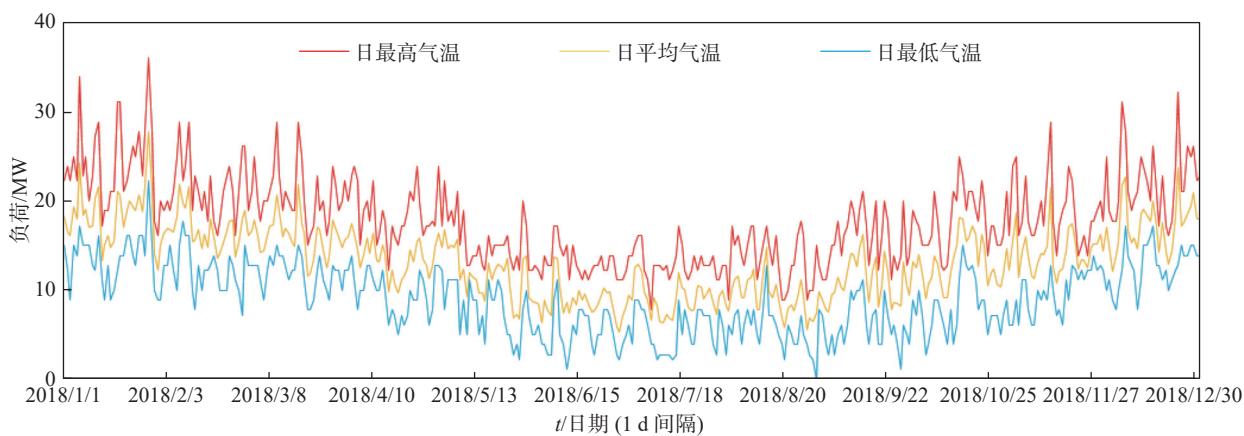


图 S3 2018 年塔斯马尼亚州霍巴特市温度时间序列

Fig. S3 Temperature time series of Hobart, Tasmania in 2018

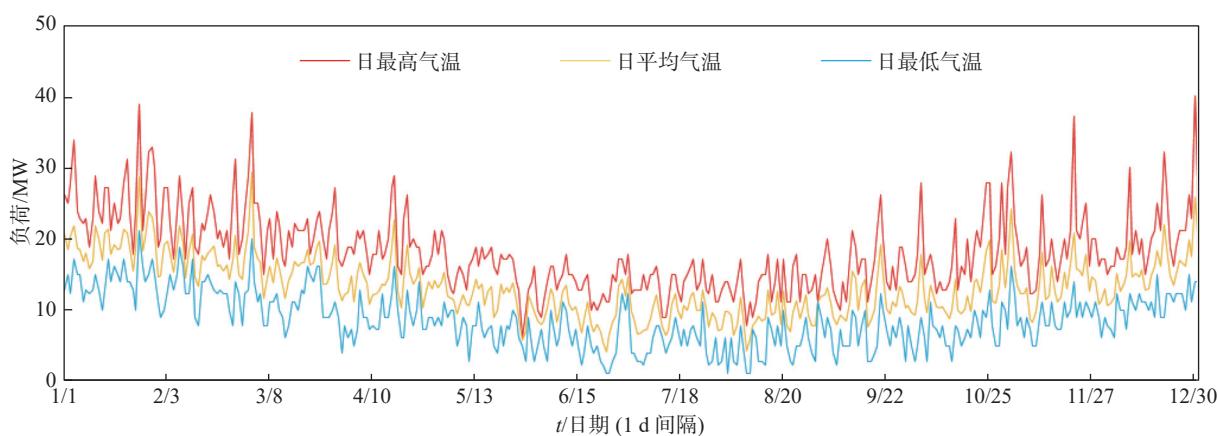


图 S4 2019 年塔斯马尼亚州霍巴特市温度时间序列

Fig. S4 Temperature time series of Hobart, Tasmania in 2019

表 S1 各候选特征与负荷高频、低频成分之间的相关系数
(基于 2018 年、2019 年塔斯马尼亚负荷数据训练集)

Tab. S1 Correlation coefficients between the candidate features and HFC, LFC (based on the training data of Tasmania electrical load in 2018 and 2019)

数据集	模型	x_t^{d-1}	x_t^{d-2}	x_t^{d-3}	x_t^{d-4}	x_t^{d-5}	x_t^{d-6}	x_t^{d-7}	T_{\max}^d	T_{ave}^d	T_{\min}^d
2018	M-HFC	0.78	0.70	0.68	0.67	0.64	0.68	0.71	0.12	0.09	0.10
	M-LFC	0.90	0.90	0.90	0.89	0.89	0.89	0.88	0.49	0.48	0.43
2019	M-HFC	0.75	0.64	0.64	0.64	0.61	0.64	0.67	0.36	0.31	0.30
	M-LFC	0.90	0.89	0.88	0.87	0.85	0.83	0.81	0.64	0.77	0.68

表 S2 基于 2018 年、2019 年塔斯马尼亚负荷数据训练集的模型 M-HFC 与 M-LFC 的最优超参数

Tab. S2 Optimal hyper-parameters of M-HFC and M-LFC based on the training dataset of Tasmania electrical load in 2018 and

模型数据集	2018年				2019年			
	模型	M-HFC	M-LFC	M-HFC	M-LFC	M-HFC	M-LFC	M-HFC
激活函数	Logistic	Logistic	Logistic	Logistic	Logistic	MBGD	MBGD	MBGD
训练函数	MBGD	MBGD	MBGD	MBGD	MBGD	MBGD	MBGD	MBGD
隐含层数	1	1	1	1	1	1	1	1
隐含层神经元数目	8	6	9	5	5	8	6	9
学习速率	0.01	0.1	0.001	0.1	0.1	0.01	0.001	0.01
迭代次数	400	1 200	700	900	900	400	1 200	700
迭代目标	0.004	0.004	0.01	0.004	0.004	0.004	0.004	0.004

(刘璐瑶)