

基于模态分解和多模型融合的IES多元负荷预测^{*}

李大华 赵志成 田禾 高强

(天津理工大学天津市复杂系统控制理论与应用重点实验室 天津 300384)

摘要: 针对综合能源系统中多元负荷的随机性和高波动性所带来的挑战,现有的负荷预测方法通常难以实现高精度和稳定的预测效果。为解决这一问题,提出一种基于模态分解和多模型融合的IES短期负荷预测方法。首先,利用最大互信息系数对输入特征进行筛选,旨在有效识别与负荷变化相关的关键因素;其次,将样本熵结合互信息为适应度函数,采用指数三角优化算法获得VMD的最优参数组合,从而实现对IES负荷的有效分解,得到多个本征模态函数;接着,采用排列熵对分解结果进行筛选,提取出反映负荷变化特征的低频和高频分量;最后,采用BiLSTM网络对低频分量进行预测,并通过BiTCN-LPTransformer-BiGRU模型对高频分量的预测,将各分量的预测结果叠加得到最终预测结果。通过对实际负荷数据验证,以春季电负荷为例,该模型的RMSE、R²、MAPE分别为118.394 kW、0.991和0.351%,相较于传统模型,显著提高了预测精度,验证所提方法的有效性。

关键词: 综合能源系统;模态分解;最大互信息系数;指数三角优化算法;负荷预测

中图分类号: TN919 文献标识码: A 国家标准学科分类代码: 470.40

Multimodal load forecasting for IES based on modal decomposition and multi-model fusion

Li Dahua Zhao Zhicheng Tian He Gao Qiang

(Tianjin Key Laboratory of Control Theory & Application in Complicated Systems, Tianjin University of Technology, Tianjin 300384, China)

Abstract: To address the challenges posed by the randomness and high volatility of multi-loads in integrated energy systems, existing load forecasting methods often struggle to achieve high accuracy and stable prediction performance. To overcome this issue, this paper proposes a short-term load forecasting method for IES based on modal decomposition and multi-model fusion. First, the maximum mutual information coefficient is used for feature selection, aiming to effectively identify key factors closely related to load variation. Next, sample entropy combined with mutual information is employed as the fitness function, and the exponential triangular optimization algorithm is applied to obtain the optimal parameter combination for variational mode decomposition (VMD), enabling effective decomposition of IES loads into multiple intrinsic mode functions. Then, permutation entropy is used to filter the decomposition results and extract low-frequency and high-frequency components that reflect the load variation characteristics. Finally, a BiLSTM network is used to predict the low-frequency components, while a BiTCN-LPTransformer-BiGRU model is applied to forecast the high-frequency components. The final load prediction is obtained by aggregating the predictions of all components. Verification using actual load data, specifically for spring electricity load, shows that the model achieves an RMSE of 118.394 kW, an R² of 0.991, and an MAPE of 0.351%. Compared to traditional models, this approach significantly improves prediction accuracy, validating the effectiveness of the proposed method.

Keywords: integrated energy system; modal decomposition; maximum mutual information coefficient; exponential triangular optimization algorithm; load forecasting

0 引言

在我国经济快速增长的背景下,能源需求持续上升,伴随着环境问题日益加剧。为了保障社会经济的可持续发

展,构建清洁、高效、安全的综合能源系统(integrated energy system, IES)并以实现“双碳”目标为核心,是推动现代电力系统绿色低碳转型的必然选择,综合能源系统涉及多种能源形式的耦合与协同,因此,多元负荷预测在保障

这一目标中扮演着至关重要的角色,通过精准的负荷预测,不仅有效能够优化能源资源配置、确保电力系统稳定运行,还能为能源转型及绿色低碳目标的达成提供有力支持。

目前,IES 负荷预测方法主要分为传统统计模型和深度学习方法。传统方法包括回归分析法^[1]、指数平滑模型法^[2]、卡尔曼滤波法^[3]等。这类方法虽然计算效率较高,但对原始数据的平稳性要求较高,在面对高度非线性和复杂时序数据时,难以有效建模;深度学习凭借着自动学习和特征提取能力能够有效捕捉负荷变化的复杂规律,提高预测精度和鲁棒性,特别适用于处理高维、时序性强的负荷数据。常见的深度学习模型包括长短期记忆网络 (long short-term memory, LSTM)^[4-5]、门控循环单元 (gated recurrent unit, GRU)^[6]、时间卷积网络 (temporal convolutional network, TCN)^[7] 和 Transformer 架构^[8]。然而 LSTM 仅依赖于历史数据,未能充分考虑未来信息的影响,限制了其对未来负荷变化的预测能力。GRU 虽然结构更简单,计算速度快,但是在处理长序列时效果逊色于 LSTM。Transformer 模型需要位置信息编码来补充对其序列顺序的识别能力。为了进一步加强对负荷序列隐藏信息的利用,双向长短时记忆神经网络和双向门控循环单元被应用于电力负荷预测^[9-10]。双向长短时记忆网络 (bidirectional lstm, BiLSTM) 和双向门控循环单元 (bidirectional gru, BiGRU) 模型通过双向信息捕捉,能够有效捕捉时序关系和长期依赖,提升对序列模式与趋势的理解,从而提高预测精度。将这些方法进行组合,能够进一步增强预测性能^[11-13]。以上文献大多采用传统的单一模型去预测不同的负荷任务,然而,由于能源形式的多样性和系统间的复杂交互,现有单一负荷预测方法难以有效处理各能源间的相互影响及其动态变化,导致预测结果的准确性较低。

为降低原始负荷数据的随机波动性并挖掘负荷序列特征,信号分解算法逐渐得到应用。文献[14]通过经验模态分解 (empirical mode decomposition, EMD) 对电力负荷数据进行分解,并结合 BiLSTM 对各本征模态函数进行预测,然而,EMD 方法中容易出现模态混叠和端点效应等问题,导致分解结果的不稳定性和预测精度的下降。为了克服 EMD 的缺点,文献[15]提出了使用变分模态分解算法 (variational mode decomposition, VMD) 进行负荷序列分解为多个本征模态分量 (intrinsic mode function, IMF),结合 CNN-BiGRU 组合模型进行预测,显著提升了预测性能,然而 VMD 参数的选择依赖于主观经验,这可能导致分解结果的随机性,且难以获得最优的参数设置。文献[16-17]通过二次模态分解对多元负荷数据进行精细化处理,有效缓解了模态混叠现象,并显著降低了高频成分的波动性,从而提高了预测的准确性。然而,二次模态分解的计算复杂度较高,导致其在预测效率上存在一定的提升空间。

基于上述问题,为了克服传统单一预测模型在多元负

荷预测中的局限性以及提升负荷分解的精度和合理性,本文提出一种考虑变分模态分解与多模型融合的 IES 负荷短期预测方法。首先,通过最大互信息系数分析 (maximal information coefficient, MIC) 多元负荷数据和气象因素,识别出对多元负荷影响较大的气象因素,将其作为模型的输入;其次构建以综合指标为适应度函数,利用三角指数优化算法 (exponential trigonometric optimization Algorithm, ETO) 对 VMD 参数进行优化,以此来实现对负荷精确的分解;接着采用排列熵对分解后的预测分量划分为低频分量和高频分量,从而降低模型计算的复杂度;最后将低频分量输入到 BiLSTM 模型中进行预测,将高频分量输入到 BiTCN-LPTTransformer-BiGRU 模型中进行预测,并将预测结果进行重构和叠加,获得多元负荷曲线。基于美国某大学的多元负荷公开数据集为验证对象,实验结果表明,所提出的模型在预测精度上显著优于传统方法。

1 多元负荷联合预测模型

目前,综合能源多元负荷预测研究已取得诸多成果。然而,单一模型的预测方法往往难以实现较高的预测精度,而多模型融合预测方法通常优于单一模型的表现。为了更好地挖掘多元负荷数据的特征及其变化规律,并提高模型的泛化能力和预测精度,本文提出考虑模态分解和多模型融合的综合能源多元负荷预测设计框架,如图 1 所示。具体步骤如下:

1)首先,采集综合能源系统园区的多元负荷和气象数据,然后进行数据清洗与预处理;通过 MIC 分析多元负荷与气象数据之间的关联性,筛选出与负荷变化关系密切的关键因素,构建输入特征数据集。

2)利用 ETO 算法优化 VMD 的分解层数 K 和惩罚因子 α ,并结合样本熵与互信息作为适应度函数进行优化。通过优化后的 ETO-VMD,对多元负荷数据进行分解,获得多个固有模态分量 IMF 。

3)计算各分量的排列熵 (permutation entropy, PE) 并依据熵值将其分为低频成分和高频成分。将低频成分输入 BiLSTM 模型,高频成分输入 BiTCN-LPTTransformer-BiGRU 模型,以进行多尺度特征提取。最后,通过重构和叠加各分量的预测结果,获得 IES 多元负荷的最终预测值。

1.1 VMD 分解

变分模态分解算法^[18]分解步骤如下:

1)变分问题构造

$$\begin{cases} f_{\min} = \min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_k \left\| \partial(t)[(\delta(t) + \frac{j}{\pi t}) * u_k(t)] e^{-j\omega_k t} \right\|_2^2 \right\} \\ \text{s.t. } \sum_{k=1}^K u_k = f(t) \end{cases} \quad (1)$$

其中, k 是分解模态个数; $u_k = \{u_1, u_2, \dots, u_k\}$ 为 IMF ; $\{\omega_k\} = \{\omega_1, \omega_2, \dots, \omega_k\}$ 是 IMF 中心频率; $f(t)$ 为原始信号; ∂t 是函数对时间 t 的偏导; $*$ 为卷积运算符。

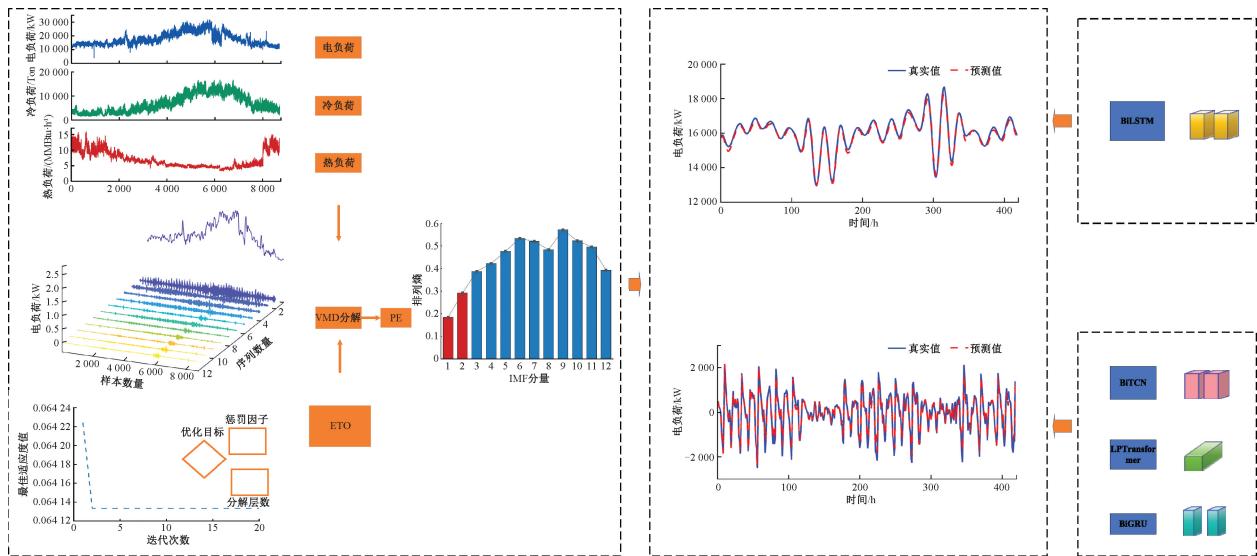


图 1 综合能源多元负荷预测设计框架

Fig. 1 Design framework for multivariate load forecasting of IES

2) 约束变分问题的求解

在式(1)基础上,加入 Lagrange 算子 λ 、二次惩罚因子 a ,将不等式约束变换为等式约束。表达式如下:

$$L(\{u_k\}, \{\omega_k\}, \lambda) =$$

$$\alpha \sum_k \left\| \alpha \left[(\delta(t) + \frac{j}{\pi t}) * u_k(t) \right] e^{-j\omega k} \right\|_2^2 + \left\| f(t) - \sum_k u_k(t) \right\|_2^2 + \langle \lambda(t), f(t) - \sum_k u_k(t) \rangle \quad (2)$$

其中, α 和 λ 的分布旨在保持约束问题的严格性和保证信号重建的准确性。

3) 各模态分量和中心频率的傅里叶变换求解

利用交替方向乘子法(ADMM)与傅里叶等距变换法求解。

$$\hat{u}_k^{n+1}(\omega) = \frac{f(\omega) - \sum_{i \neq k} \hat{u}_i(\omega) + \frac{\lambda(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k)^2} \quad (3)$$

$$\omega_k^{n+1} = \frac{\int_0^\infty \omega \left| \hat{u}_k^{n+1}(\omega) \right|^2 d\omega}{\int_0^\infty \left| \hat{u}_k^{n+1}(\omega) \right|^2 d\omega} \quad (4)$$

$$\lambda^{n+1}(\omega) = \lambda^n(\omega) + \gamma(f(\omega) - \sum_k \hat{u}_k^{n+1}(\omega)) \quad (5)$$

1.2 三角指数优化算法

ETO 算法是一种先进的启发式搜索算法,它巧妙地将指数衰减与三角函数的周期性特征相结合,从而能够有效适应复杂问题的优化需求。ETO 算法的过程可分为四个阶段,每个阶段旨在逐步优化搜索过程。该算法的具体原理可参考文献[19]。

1.3 考虑综合指标的 ETO-VMD 算法

在变分模态分解方法中,分解层数 K 和惩罚因子 a 是决定分解效果的关键因素。分解尺度 K 不同,导致分解结

果的数量发生变化,并且影响效果的差异。惩罚因子 a 控制模态分量的带宽,与带宽成反比关系。在采用 ETO 算法对 VMD 参数进行优化时,选择合适的适应度函数对分解性能和结果的可靠性至关重要。考虑到多元负荷序列的非平稳性,单一指标难以全面捕捉信号的有效特征,因此本研究采用了样本熵(sample entropy, SE)和互信息(mutual information, MI)的组合构建了一个综合评估指标。通过最小化这两个指标比值的商作为优化的适应度函数,从而提升 VMD 分解的准确性与有效性。

样本熵是衡量时间序列复杂度和不规则性的一种方法,反映了序列中模式的可预测程度和自相似特征^[20]。与其他熵度量方法相比,样本熵的计算不受时间序列的长度的影响,具有更好的鲁棒性和稳定性。

$$SampEn(m, r) = -\ln \frac{A(m, r)}{B(m+1, r)} \quad (6)$$

其中, m 是嵌入维度(通常为 2 或 3), r 是容忍度, $A(m, r)$ 是当嵌入维度为 m 时,满足相似度小于 r 的向量对数的比例。 $B(m+1, r)$ 是在嵌入维度为 $m+1$ 时,满足相似度小于 r 的向量对数的比例。

考虑到将样本熵作为适应度函数直接应用的话,可能会导致不同问题的适应度值不可比,从而影响算法的收敛速度和效果。因此将其归一化处理,归一化后的样本熵的可表示为:

$$NormS(m) = \frac{S(m) - \min(S(m))}{\max(S(m)) - \min(S(m))} \quad (7)$$

其中, $\min(S(m))$ 、 $\max(S(m))$ 分别表示 SE 中的最小值和最大值。

互信息是衡量两个随机变量之间的相互依赖性,互信息值越高,表明两个序列的关联程度越紧密。归一化后的

互信息通过式(8)计算:

$$NormMI = \frac{MI(X, Y)}{\max(H(X), H(Y))} \quad (8)$$

其中, $MI(X, Y)$ 为序列 X 和 Y 之间的互信息, $H(X)$ 和 $H(Y)$ 为 X 和 Y 的熵值。

样本熵反映了时间序列的动态复杂性,而互信息揭示了时间序列之间的依赖关系,因此结合两者,可以构建为综合指标 SI :

$$SI = \frac{NormS(m)}{NormMI} \quad (9)$$

该指标综合评估了 IMF 分量所代表的复杂性与其特征信息的丰富性。当 IMF 分量的复杂性降低且其特征信息趋于更加丰富时,复合指标 SI 的值将减小。因此,选取该指标的最小值作为适应度函数,并予以定义如下:

$$fit(IMF) = \min\{SI\} \quad (10)$$

2 多层次特征提取

2.1 双向长短时记忆网络

BiLSTM 是一种基于 LSTM 的变体。BiLSTM 通过结合前向和反向 LSTM 网络,能够同时捕捉数据的正向和反向时间依赖关系,从而更全面地探索当前数据与过去及未来数据之间的联系,从而增强了模型的表达力。BiLSTM 结构如图 2 所示,计算过程如式(11)所示。

$$\begin{cases} \vec{h}_t = LSTM(x_t, \vec{h}_{t-1}) \\ \hat{h}_t = LSTM(x_t, \hat{h}_{t-1}) \\ y_t = \sigma(W_y[\vec{h}_t, \hat{h}_t] + b_y) \end{cases} \quad (11)$$

其中, LSTM 单元为传统 LSTM; \vec{h}_t 为正向隐藏层状态; \hat{h}_t 为逆向隐藏层状态; W_y 和 b_y 分别为权重矩阵和偏置函数。 x_t 、 y_t 分别为各时刻对应的输入和输出数据; σ 为激活函数。

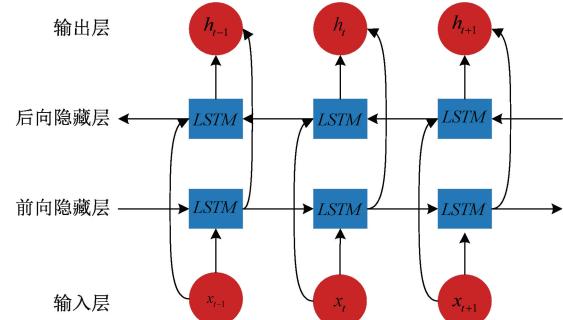


图 2 BiLSTM 结构

Fig. 2 Schematic of the BiLSTM structure

2.2 双向时间卷积网络

TCN 是一种卷积神经网络(convolutional neural network, CNN)的变体。在算法中加入了因果卷积、膨胀卷积、残差模块等机制,相比于传统的循环神经网络(recurrent neural network, RNN)更能灵活地处理变长的输入序列。另外,TCN 采用卷积操作,可以进行高效的并行计算,使得 TCN 在大规模的数据上的训练和推理方面具有优势。传统的 TCN 只对输入序列进行正向卷积计算,只提取了正向的负荷数据特征,然后忽略了反向中的隐含信息。所以,本文采用双向时间卷积结构来捕捉序列前后方向的隐藏特征,来更好地获得负荷序的长时间依赖性。BiTCN 结构如图 3 所示。

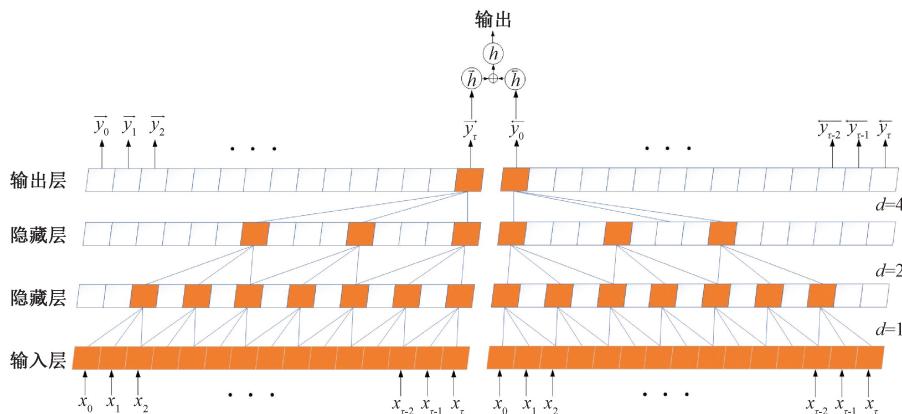


图 3 BiTCN 结构

Fig. 3 Schematic of the BiTCN architecture

扩张卷积(dilated convolution 或 atrous convolution)是一种卷积操作的变体,通过在卷积核元素之间插入间隔来扩大感受野。扩张卷积在处理一维序列输入 $\mathbf{X} = (x_0, x_1, \dots, x_t, \dots, x_T)$ 时,隐藏层在第 t 时刻的输出值如式(12)所示。

$$h(t) = \sum_{i=0}^{S-1} f(i) \cdot x_{t-di} \quad (12)$$

其中, $f(i)$ 为卷积核中的第 i 个数据, S 为卷积核的大小, x_{t-di} 表示仅对过去的数据进行卷积的结果, d 是膨胀系数。在输入序列的每一层卷积之后, d 呈指数增长。

BiTCN 经过多次卷积操作, 利用扩张卷积技术, 显著扩大了感受野。然而, 增加感受野带来梯度消失和收敛速度缓慢等问题。为了解决这问题, 残差块的引入起到了关键作用。残差块通过引入跳跃连接(skip connection)将输入直接传递给输出, 然后与中间层的输出相加。使得网络可以学习输入和输出之间的残差映射, 而非直接学习映射本身。残差块的输出 \mathbf{O} 为:

$$\mathbf{O} = \text{Activation}(\mathbf{x} + \mathbf{F}(\mathbf{x})) \quad (13)$$

其中, \mathbf{x} 是残差块的输入, $\mathbf{F}(\mathbf{x})$ 是残差块中间层的变换函数。

残差块主要由扩张因果卷积层、权重初始层、Relu 层和 Dropout 层组成。残差块的结构如图 4 所示。其中, 权重初始层确保了参数的合理初始化, 从而减少了训练初期梯度消失或梯度爆炸的风险。Relu 激活层引入非线性变换, 使得网络能够更好地学习复杂的特征关系。Dropout 层通过随机丢弃神经元, 有效防止过拟合, 提升网络的泛化能力。通过这种设计, 残差块不仅缓解了深层网络的梯度消失和爆炸问题, 还优化了学习路径, 提高了训练效率和稳定性。它的引入使得网络在更深层次保持良好的梯度流动, 加速了收敛过程, 增强了对复杂数据的特征提取能力和鲁棒性。

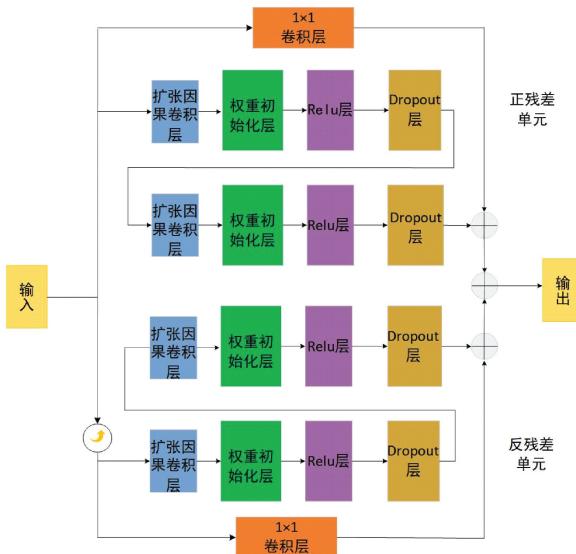


图 4 BiTCN 中的残差块结构

Fig. 4 Schematic structure of the residual block in BiTCN

2.3 LPTransformer 编码器

近年来, Transformer 模型凭借高效的并行计算能力和强大的长依赖建模能力, 在自然语言处理以及其他序列建模任务中取得了显著成功。传统的 Transformer 模型在处理位置编码时存在一定的局限性, 主要表现为位置编码是静态的, 无法在训练过程中进行自适应优化。为此, 本文提出了一种改进的 Transformer 架构, 加入可学习的位

置编码, 并优化了位置编码的合成方式, 以增强模型对输入序列顺序信息的适应能力。LPTransformer 编码器的结构如图 5 所示。

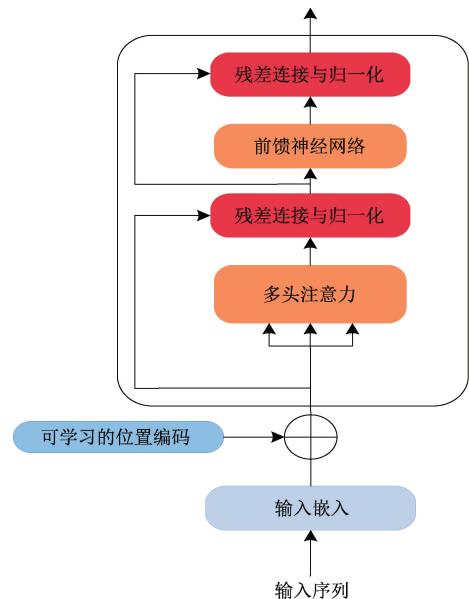


图 5 LPTransformer 编码器结构

Fig. 5 Schematic of the LPTransformer encoder architecture

1) 自注意力机制与多头注意力

类似于标准 Transformer 模型, 本模型仍然采用自注意力机制(self-attention)来识别输入序列中不同位置之间的相互依赖性。其计算公式为:

$$\text{Attention}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{softmax}\left(\frac{\mathbf{Q}\mathbf{K}^T}{\sqrt{d_k}}\right)\mathbf{V} \quad (14)$$

其中, \mathbf{Q} 制是查询向量, \mathbf{K} 是键向量, \mathbf{V} 是值向量, d_k 是键向量的维度。

$$\mathbf{MHead}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{Concat}(\mathbf{head}_1, \dots, \mathbf{head}_h)\mathbf{W}^0 \quad (15)$$

其中, $\mathbf{head}_i = \text{Attention}(\mathbf{Q}\mathbf{W}_i^0, \mathbf{K}\mathbf{W}_i^K, \mathbf{V}\mathbf{W}_i^V), \mathbf{W}_i^0, \mathbf{W}_i^K, \mathbf{W}_i^V$ 为线性变换矩阵, \mathbf{W}^0 为输出的线性变化矩阵, \mathbf{head} 是头数。

2) 位置编码

标准 Transformer 采用固定的正弦波位置编码(sinusoidal positional encoding), 这种方式虽然有效, 但无法在训练过程中根据具体任务进行调整。因此, 本研究提出了可学习的位置编码, 使得位置编码能够在训练过程中进行优化, 提升其对数据的适应性。可学习的位置编码通过全连接层进行建模, 其计算方式如下:

$$\mathbf{PE}_{\text{learnable}}(i, j) = f(i, j, \theta) \quad (16)$$

其中, $f(i, j, \theta)$ 是由全连接层学习到的映射函数, θ 表示该层的学习参数, i 是位置索引, j 是位置编码的维度索引。

3) 位置编码与输入的融合

为了将可学习的位置编码与输入特征融合,在模型中设计了一个加法层,将输入嵌入与学习到的位置编码相加,得到新的输入表示:

$$\text{Input}_{final} = \text{Input}_{embedding} + PE_{learnable} \quad (17)$$

2.4 双向门控循环单元

GRU 通过引入门控机制,将 LSTM 中的输出门和遗忘门合并为重置门和更新门,单向 GRU 只能捕捉序列的正向时序特征。为了更好地处理多元负荷之间的内在关联,本文引入了双向门控循环单元。BiGRU 通过前向和后向隐藏层的对称结构,同时从正反两个方向提取时序特征,极大丰富了特征信息,提升了模型的表达能力。其网络结构如图 6 所示。

$$\begin{cases} \tilde{h}_t = \text{GRU}(x_t, \tilde{h}_{t-1}) \\ \tilde{h}_t = \text{GRU}(x_t, \tilde{h}_{t-1}) \\ h_t = \tilde{h}_t \oplus \tilde{h}_t \end{cases} \quad (18)$$

其中, \tilde{h}_t 和 \tilde{h}_t 分别为 t 时刻的前向和后向的隐藏层的输出; h_t 为整个 BiGRU 的输出。

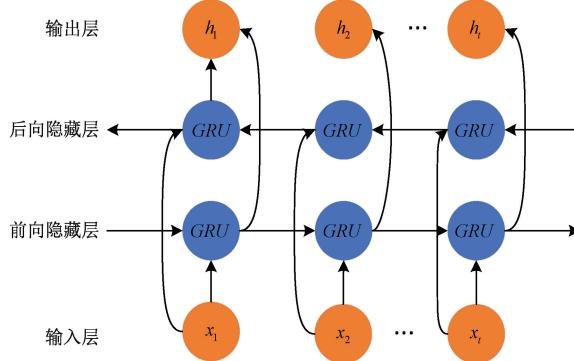


图 6 BiGRU 网络结构

Fig. 6 Schematic diagram of the BiGRU network architecture

2.5 评价指标

为了评估模型的性能,本研究选取均方根误差(root mean squared error, RMSE)、决定系数 R^2 和平均绝对误差(mean absolute percentage error, MAPE)作为评价指标。3 种评价的指标的表达式如下:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (19)$$

$$R^2 = 1 - \frac{\sum_{s=1}^S (y_i - \hat{y}_i)^2}{\sum_{s=1}^S (y_i - \bar{y}_i)^2} \quad (20)$$

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \quad (21)$$

其中, N 为预测样本的数量; y_i 为实际值; \hat{y}_i 为预测值。

3 算例分析

3.1 数据来源及处理

本文采用美国某大学 2022 年 1 月 1 日 00:00~2022 年 12 月 31 日 23:00 的 IES 电、冷、热负荷数据,记录数据的时间粒度为 1 h,长度为 8760 条。气象数据来自美国国家可再生能源实验室^[21],包括温度、云类型、露点、湿度、太阳天顶角、地表反射率、压力、降雨量、风向和风速共 10 类,同时将日、月以及时刻三类考虑为输入特征。

为了评估模型的泛化能力,考虑到全年数据的覆盖以及季节负荷的变化,本文分别对不同季节进行实验验证。将全年数据划分为 4 组,每组数据按照 8:2 划分为训练集和测试集。通过分析数据中的缺失值和异常值,采用线性插值法进行修正与填补,即用相邻数据的均值替代异常或缺失值。对负荷及气象因素进行归一化处理:

$$y_i = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (22)$$

3.2 实验环境及超参数设置

本实验的硬件设置为 Intel Core i7-13700H CPU,16 GB 内存,采用 NVIDIA RTX 4060 GPU 进行加速。软件采用 Windows 11 的操作系统下的 Matlab R2024a 编译器进行模型的训练与测试。实验主要采用 Matlab 提供的 Deep Learning Toolbox 和 Parallel Computing Toolbox 等工具箱来实现。

本文采用小批次梯度下降法进行训练,批次大小为 32。

优化过程中使用 Adam 优化器,损失函数为均方误差(MSE),最大训练周期为 200,初始学习率设置为 0.001,采用分段学习率下降策略,训练过程中采用 gpuArray 在 GPU 上加速计算。对于低频分量采用 BiLSTM 网络进行建模,包括输入层、双向 LSTM 层、Dropout 层、全连接层和输出层。BiLSTM 层的隐藏单元数设置为 64,丢弃率为 0.1,以防止过拟合。对于高频分量采用 BiTCN-LPTTransformer-BiGRU 网络结构进行建模,BiTCN 特征提取层包含 2 个残差块,每个残差块由正向支路和反向支路组成。每个支路包含 2 个膨胀卷积层,卷积核大小为 5×5 ,卷积核的数量为 64,两个归一化层、两个 ReLU 激活层和两个 Dropout 层。LPTTransformer 部分包含一个可学习的位置编码层,由一个 64 维的全连接层生成,权重和偏置的学习率调整因子设置为 10,让位置编码层的学习更加迅速和更容易适应数据。采用 8 个自注意力头和 256 个通道作为每个注意力头的维度。BiGRU 部分包含两个 GRU 层,第一层 GRU 隐层单元数为 64,第二层 GRU 隐层单元数为 32。

3.3 特征筛选

MIC 相关性分析方法^[22]能够有效降低输入维度,减少

无关或弱相关因素对预测模型精度的干扰,同时与皮尔逊相关分析等方法^[23-25]相比,具有较低的计算复杂度和更强的鲁棒性。MIC 计算过程包括以下步骤:

1) 构建网格划分:对变量 X 和 Y 进行不同尺度的网格划分,即将数据空间划分成 $m \times n$ 的离散网格,从而捕捉不同尺度上的模式关系。

2) 计算互信息:在每种网格划分方式下,计算变量 X 和 Y 之间的互信息,公式如下:

$$I(X, Y) = \sum_{i,j} p(i, j) \log \frac{p(i, j)}{p(i)p(j)} \quad (23)$$

其中, $p(i, j)$ 表示第 i, j 个网格单元中的联合概率分布, $p(i)$ 和 $p(j)$ 分别表示变量 X 和 Y 在该网格划分下的边际概率分布。

3) 归一化互信息:由于不同的网格划分会导致互信息值的变化,需要对其归一化处理,以确保 MIC 的取值范围在 $[0, 1]$ 之间,定义如下:

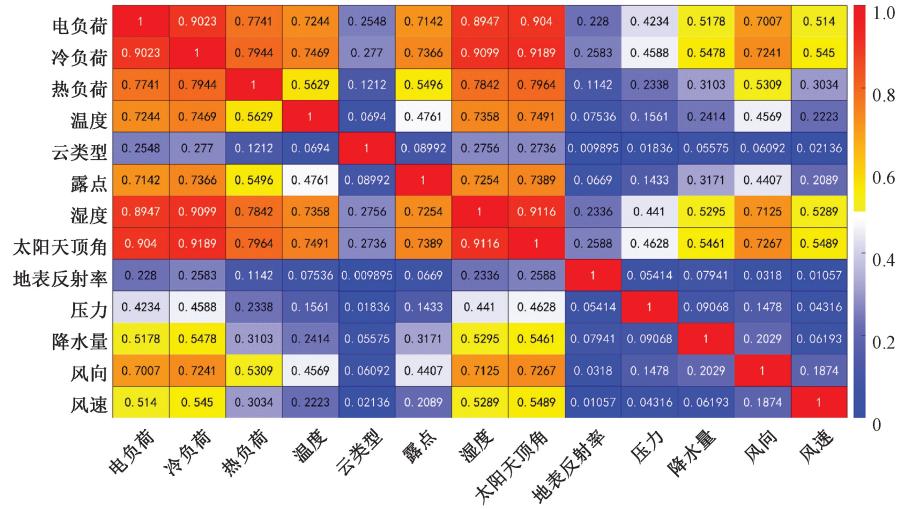


图 7 多元负荷与气象因素间的 MIC

Fig. 7 Maximum mutual information between multivariate loads and meteorological factors

图 7 中显示,电、冷、热负荷之间具有显著的相关性。这主要由于多元负荷间的能量转换机制,使得负荷之间表现出明显的耦合特性。在所收集的气象因素中,温度、露点、湿度、太阳天顶角和风向与三者负荷有较强的相关性,因此将它视为主要影响因素。此外,云类型、地表反射率和压力与电、冷、热负荷的 MIC 值都低于 0.5,呈现出弱相关性。因此,联合预测 IES 多元负荷时,应考虑负荷之间以及气象因素的耦合关系。通过 MIC 分析,选择多元负荷影响较大的气象因素作为输入,可显著提高模型的准确性。这种方法还能过滤掉影响程度较小的因素,从而简化模型,提高训练与预测效率。

3.4 多元负荷分解

本文采用考虑综合指标的 ETO 优化的 VMD 算法优化分解层数和惩罚因子。具体参数设置:种群数为 20,迭代次数 200 次,优化目标为分解尺度和惩罚因子,二者的

$$MIC(X, Y) = \max_{m, n} \frac{I(X, Y)}{\log \min(m, n)} \quad (24)$$

其中, m, n 分别表示网格的行数和列数。MIC 的最大值为 1, 表示两个变量完全相关; 值接近 0, 则说明变量之间几乎没有关系。

在本研究中,过多的气象特征作为模型输入会导致模型复杂度增加且精度降低,通过 MIC 分析气象特征与负荷之间的相关性,筛选出对多变量负荷影响较大的气象特征。具体步骤为:(1)对多元负荷数据和气象数据进行归一化处理,以消除不同量纲和量级的影响。(2)针对每个气象特征和多元负荷之间的关系,计算他们的 MIC 值。(3)根据 MIC 的值大小,设定一个阈值来筛选特征。通常, MIC 值大于 0.5 表示两个变量之间具有较强的关联性。(4)将 MIC 值大于阈值的气象特征选择出来,作为与多元负荷变化密切相关的关键因素。这些关键特征将作为模型的输入,用于后续的负荷预测。相关性程度如图 7 所示。

搜索范围分别为 $[2, 12]$ 和 $[300, 3000]$ 。经 ETO 寻优后的 K 和 α 取值为 $[12, 2500]$, 以电负荷为例, 分解后的模态分量如图 8 所示。

在 VMD 分解后,各分量表现出不同的特征,单一模型难以精确地对每个分量进行预测,进而导致预测性能的显著下降。为此,本文引入排列熵^[26],作为衡量时间序列复杂性和非线性动态行为的指标,能够精确评估不同频率分量的内在动态特性。根据排列熵值的差异,将各分量划分为高频分量和低频分量,从而实现针对性的建模与预测优化,进一步提升模型的准确性和鲁棒性。通过计算各分量的 PE,结果如表 1 所示。

由图 8 和表 1 可见,IMF1 为低频信号,揭示了 IES 负荷的长期趋势和周期性变化,有助于准确捕捉系统的负荷需求规律。通过后续的 BiLSTM 模型可以实现精准的预测。然而其余分量体现了系统较为快速的波动和短期变

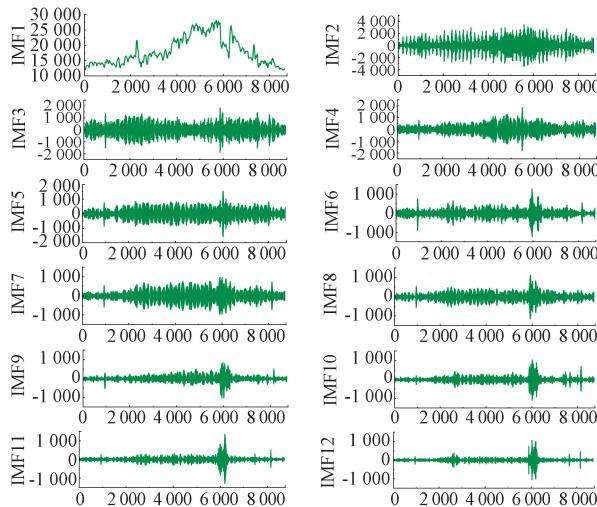


图 8 电负荷分解结果

Fig. 8 Decomposition results of electrical load

化,预测难度较大,故采用 BiTCN-LPTtransformer-BiGRU 模型进行预测,以提升负荷预测的精度和效率。

3.5 实验设计

为验证本文模型在 IES 中的多元负荷预测中具有较高的预测精度和泛化能力,设计了两组实验进行系统评估。第 1 组实验对比了所提模型与传统单一模型的表现;第 2 组实验通过消融分析评估模型中各个模块对性能的贡献。

在实验 1 中,将所提的模型与 LSTM、GRU、TCN、BiLSTM、BiGRU、BiTCN 和 Transformer 这 7 个类型的对照模型进行对比,来验证本模型的准确性和泛化性。实验 2 将所提模型分别与去除考虑综合指标 ETO 算法的模型

表 1 不同分量排列熵
Table 1 Different component permutation entropies

分量	排列熵
IMF1	0.184
IMF2	0.292
IMF3	0.387
IMF4	0.421
IMF5	0.476
IMF6	0.533
IMF7	0.519
IMF8	0.483
IMF9	0.571
IMF10	0.522
IMF11	0.495
IMF12	0.392

(VBTB)、去掉 VMD 分解模块的(E-BTB)、去掉 BiTCN 特征提取模块(E-VTB)、去掉 LPTtransformer-BiGRU 序列建模模块(E-VB)和去掉 BiLSTM 低频分量(E-VBTB)预测模块的融合模型进行比较,根据预测结果,评估各模块对最终预测性能的影响。

3.6 与单一模型对比实验

为全面评估本文所提模型在多元负荷中的性能,实验 1 中将所提的模型与 LSTM、GRU、TCN、BiLSTM、BiGRU、BiTCN 和 Transformer 单一模型进行对比,分别对多元负荷数据进行预测。通过分析春秋两季的预测结果,详细展示了各模型的评价指标及预测曲线,具体结果如表 2~3 和图 9~10 所示。

表 2 春季不同模型评价指标
Table 2 Spring season evaluation metrics of different models

模型	电负荷			冷负荷			热负荷		
	RMSE/kW	MAPE/%	R ²	RMSE/Ton	MAPE/%	R ²	RMSE/(MMBtu·h ⁻¹)	MAPE/%	R ²
LSTM	243.692	1.288	0.962	188.070	4.274	0.963	0.211	2.025	0.909
GRU	209.675	1.054	0.972	135.015	3.276	0.981	0.146	1.461	0.956
TCN	405.365	2.038	0.897	131.667	3.156	0.982	0.224	2.085	0.898
BiLSTM	181.277	0.914	0.979	61.114	1.505	0.996	0.172	1.766	0.939
BiGRU	193.713	0.954	0.976	60.618	1.373	0.996	0.108	0.974	0.976
BiTCN	374.966	1.798	0.912	64.419	1.594	0.995	0.179	1.585	0.935
Transformer	284.958	1.475	0.949	51.808	1.250	0.997	0.134	1.303	0.963
本文模型	118.394	0.351	0.991	42.859	1.036	0.998	0.096	0.957	0.981

通过对表 2~3 和图 9~10 分析,结果表明本文提出的模型在负荷预测曲线与实际负荷曲线的拟合度上显著优于其他传统单一模型,预测曲线的走势与实际负荷曲线保持高度一致,且预测值在实际值周围仅呈现小幅波动。本

文所提出的 ETO-VMD-BiTCN-LPTtransformer-BiGRU 模型在电、冷、热负荷预测中的表现尤为突出,春季 RMSE 值分别为 118.394 kW、42.859 Ton 和 0.096 MMBtu/h,MAPE 值分别为 0.351%、1.036% 和 0.957%,R² 分别为

表 3 秋季不同模型评价指标

Table 3 Autumn season evaluation metrics of different models

模型	电负荷			冷负荷			热负荷		
	RMSE/kW	MAPE/%	R ²	RMSE/Ton	MAPE/%	R ²	RMSE/(MMBtu·h ⁻¹)	MAPE/%	R ²
LSTM	783.073	2.339	0.948	191.284	1.215	0.989	0.127	2.112	0.881
GRU	724.918	1.819	0.955	307.762	1.904	0.972	0.120	1.877	0.894
TCN	1035.727	2.514	0.909	379.786	2.296	0.957	0.125	2.870	0.885
BiLSTM	772.121	2.256	0.949	169.667	1.099	0.991	0.077	1.745	0.956
BiGRU	374.657	1.218	0.988	212.332	1.304	0.986	0.087	1.958	0.944
BiTCN	1019.156	2.240	0.912	231.024	1.484	0.984	0.078	1.776	0.955
Transformer	491.870	1.630	0.979	208.877	1.399	0.987	0.047	0.758	0.983
本文模型	308.443	0.819	0.991	157.022	0.772	0.992	0.037	0.648	0.990

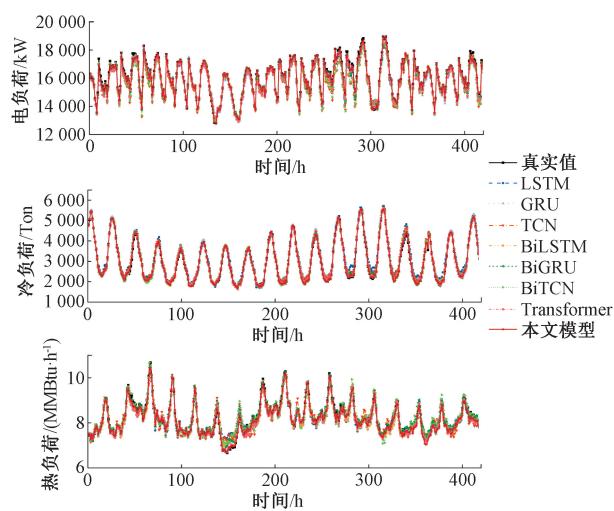


图 9 春季 IES 负荷预测结果

Fig. 9 Spring season IES load forecasting results

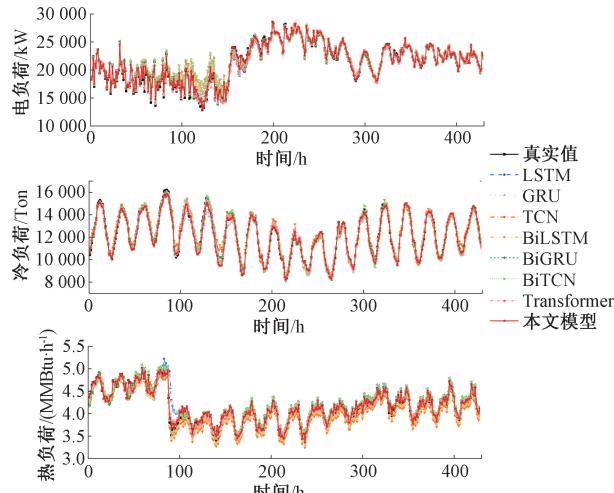


图 10 秋季 IES 负荷预测结果

Fig. 10 Autumn season IES load forecasting results

0.991、0.998 和 0.981。秋季 RMSE 值分别为 308.443 kW、157.022 Ton 和 0.037 MMBtu/h, MAPE 值分别为 0.819%、0.772% 和 0.648%, R² 分别为 0.991、0.992 和 0.990。

相较于其他预测方法,本模型在各类负荷预测任务中展现出更高的预测精度,显著优于现有的其他预测模型。这是因为:所建的模型首先利用 VMD 分解算法对原始信号进行了精细的分解,使得每个模态成分能够更好地反映负荷数据的多尺度特征;再者,BiTCN 通过双向时序卷积捕捉了时序数据的长短期依赖性,进一步提升了特征提取的精度;最后,LPTTransformer 和 BiGRU 相互结合,不仅保留了时间序列的非线性特性,还加强了模型对负荷数据波动和复杂关系的适应能力。

3.7 消融实验

为了评估所提模型各模块的有效性,将本文模型与 3.4 节实验 2 中所提到的模型 1(VBTB)、模型 2(E-BTB)、模型 3(E-VTB)、模型 4(E-VB) 和模型 5(E-VBTB) 进行对比。以春、秋两季的预测结果进行详细分析预测结果如表 4~5 所示,预测曲线如图 11~12 所示。

1) 对比本文模型与模型 1,可论证考虑综合指标 ETO 算法的重要性。通过 ETO 算法对 VMD 的超参数进行优化后,模型预测性能明显提升,相比之下,模型 1 在参数选择上若不当,可能导致较大的预测误差。进行多次实验选择后,误差仍然高于本模型。图 13 展示了 ETO 算法与其他常见的算法收敛性能测试。结果显示,随着迭代次数的增加,ETO 的算法下降幅度最大,且达到适应度最优值的迭代次数要少于其他算法。ETO 算法不仅对参数选择更优,还能降低算法运算迭代次数,缩短了运算时间。

2) 对比本文模型与模型 2 的预测结果,进一步证明 VMD 分解模块的重要性。以春季指标 RMSE 进行分析,模型 2 预测电、冷、热负荷的 RMSE 分别为 227.018 kW, 154.057 Ton 和 0.116 MMBtu/h,而本文模型加入 VMD 分解模块后,其 RMSE 分别降低了 47.84%、72.18% 和

表 4 春季消融实验各模型评价指标

Table 4 Evaluation metrics of different models in the spring season ablation experiment

模型	电负荷			冷负荷			热负荷		
	RMSE/kW	MAPE/%	R ²	RMSE/Ton	MAPE/%	R ²	RMSE/(MMBtu·h ⁻¹)	MAPE/%	R ²
模型 1	210.824	0.899	0.972	105.301	2.635	0.988	0.097	0.968	0.980
模型 2	227.018	1.150	0.967	154.057	3.627	0.975	0.116	1.275	0.972
模型 3	152.814	0.790	0.985	120.403	2.890	0.984	0.136	1.399	0.962
模型 4	229.906	1.171	0.967	104.786	2.580	0.988	0.106	1.064	0.977
模型 5	169.498	0.596	0.982	103.753	2.442	0.988	0.111	1.179	0.974
本文模型	118.394	0.351	0.991	42.859	1.036	0.998	0.096	0.957	0.981

表 5 秋季消融实验各模型评价指标

Table 5 Evaluation metrics of different models in the autumn season ablation experiment

模型	电负荷			冷负荷			热负荷		
	RMSE/kW	MAPE/%	R ²	RMSE/Ton	MAPE/%	R ²	RMSE/(MMBtu·h ⁻¹)	MAPE/%	R ²
模型 1	363.152	1.132	0.988	183.636	1.225	0.990	0.057	1.057	0.976
模型 2	579.115	0.756	0.971	291.981	1.592	0.974	0.069	1.623	0.964
模型 3	462.122	1.476	0.981	175.509	1.114	0.990	0.081	1.503	0.951
模型 4	414.454	1.323	0.985	197.934	1.303	0.988	0.079	1.453	0.954
模型 5	478.511	1.167	0.980	211.272	1.403	0.986	0.065	0.803	0.968
本文模型	308.443	0.819	0.991	157.022	0.772	0.992	0.041	0.582	0.987

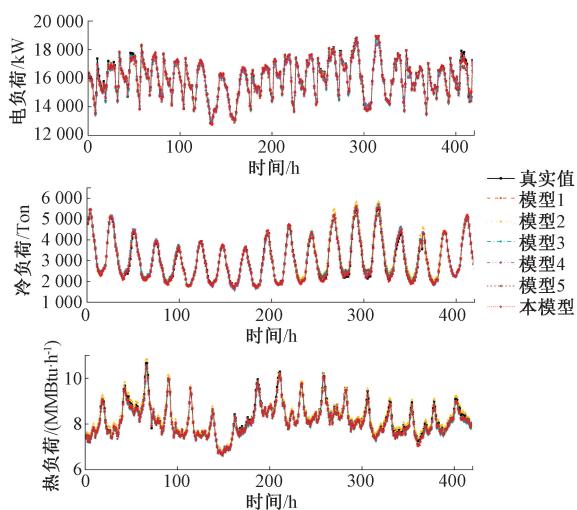


图 11 春季消融 IES 负荷预测结果

Fig. 11 Ablation analysis of spring season IES load forecasting results

17.24%，这表明通过 VMD 信号分解后，将复杂的时间序列数据转换为更易于处理的低频和高频成分，有助于模型捕捉到数据中的复杂模式和趋势，从而提高模型的预测精度。

3) 对比本文模型与模型 3，可以看出 BiTCN 在特征提

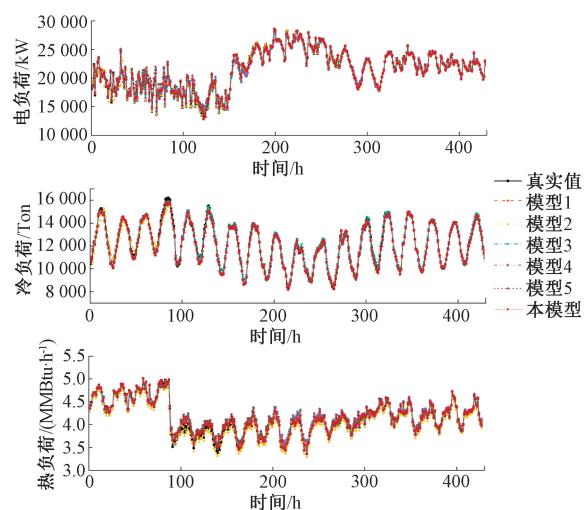


图 12 秋季消融 IES 负荷预测结果

Fig. 12 Ablation analysis of autumn season IES load forecasting results

取上的重要性。模型 3 预测电、冷、热负荷 RMSE 分别为 152.814 kW、120.403 Ton 和 0.136 MMBtu/h，加入 BiTCN 模块后，其 RMSE 分别降低了 22.52%、64.40% 和 29.41%。这表明 BiTCN 模块能够有效地捕捉数据中的局部模式，对其进行深入挖掘，从而一定程度上提高了预测

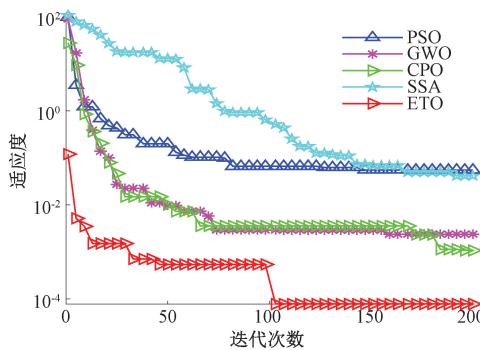


图 13 算法收敛曲线

Fig. 13 Algorithm convergence curve

精度。

4) 对比本文与模型 4, 本文所提出的 LPTransformer-BiGRU 模型在捕捉时间序列依赖关系方面优于模型 4。具体而言, 通过结合 LPTransformer 的自注意力机制和 BiGRU 的双向递归特性, 本文模型能够更有效地提取长短期依赖特征, 从而提升了负荷预测的准确性。相比模型 4, 电、冷、热负荷预测中的 RMSE 分别为 229.906 kW、104.786 Ton 和 0.106 MMBtu/h, 本文模型在这 3 个负荷类型上的 RMSE 分别降低了 30.15%、59.10% 和 9.43%。这一显著的性能提升表明, LPTransformer 的局部位置编码和自注意力机制在捕捉序列中的复杂时序关系和全局特征方面发挥到了关键作用, 此外, BiGRU 的双向建模能力有助于更好地捕捉负荷序列中的双向依赖模式。

5) 对比本文模型与模型 5 的预测结果, 可以看出 BiLSTM 在低频分量预测中的优势。本文模型在相应负荷的 RMSE 分别降低了 30.15%、58.69% 和 13.51%。这一结果表明, 将低频分量与高频分量分离并单独建模有助于提高预测精度。低频分量通常反映了时间序列中的长期趋势和周期性变化, 具有平稳的特征, 适合用 BiLSTM 进行建模。BiLSTM 能够有效捕捉低频分量中的时间依赖性, 特别是在长时依赖和趋势变化方面。通过对低频分量的精确建模, 本模型在负荷预测中的整体精度得到了显著提升。

4 结 论

本文针对综合能源系统中多元负荷预测的复杂性, 提出了一种基于模态分解和多模型融合的 IES 负荷预测方法。首先, 将互信息与样本熵构建适应度函数, 并采用 ETO 算法优化 VMD 的分解层数和惩罚因子, 实现了 IES 多元负荷数据的分解, 为后续的预测模型提供了高质量的输入。接着, 通过计算排列熵对 VMD 分解后的分量进行筛选, 将序列分为低频和高频分量, 分别采用 BiLSTM 和 BiTCN-LPTransformer-BiGRU 模型进行多尺度特征提取。充分发挥了不同模型在处理各频率分量上的优势, 显著提升了预测的准确性和鲁棒性。与传统模型相比, 本文

提出的模型在不同季节的电、冷、热负荷预测中显示出更高的预测精度。在 RMSE、MAPE 和 R^2 等指标上均优于对照模型, 证明了其有效性和泛化能力。未来的工作将探索该方法在其他类型负荷预测中应用, 并进一步优化模型以适应更广泛的实际需求。

参 考 文 献

- [1] 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.
- [2] SUN Y Q, WANG Y W, ZHU W, et al. Residential daily power load forecasting based on threshold ARMA model considering the impact of temperature[J]. Electric Power Construction, 2022, 43(9): 117-124.
- [3] SULANDAR W, SUHARTONO, SUBANAR, et al. Exponential smoothing on modeling and forecasting multiple seasonal time series: an overview [J]. Fluctuation and Noise Letters, 2021, 20(4): 213003.
- [4] SHARMA S, MAJUMDAR A, ELVIRA V, CHOUZENOUX É. Blind Kalman filtering for short-term load forecasting[J]. IEEE Transactions on Power Systems, 2020, 35(6): 4916-4919.
- [5] 高超, 孙谊婧, 赵洪峰, 等. 基于 ICOA-LSTM 的短期负荷预测研究[J]. 电子测量技术, 2022, 45(13): 88-95.
- [6] GAO CH, SUN Y Q, ZHAO H F, et al. Research on short-term load forecasting based on ICOA-LSTM[J]. Electronic Measurement Technology, 2022, 45(13): 88-95.
- [7] 孟金鑫, 黄山, 印月. 基于特征优选策略和 DLSTMsFCN 优化的短期负荷预测[J]. 电子测量技术, 2023, 46(10): 46-52.
- [8] MENG J X, HUANG SH, YIN Y. Short-term load forecasting model based on feature optimization strategy and DLSTMs-FCN [J]. Electronic Measurement Technology, 2023, 46(10): 46-52.
- [9] 岳伟民, 刘青荣, 阮应君, 等. 基于 MTL-GRU-Attention 的综合能源系统多元负荷预测[J]. 电力系统及其自动化学报, 2023, 35(6): 83-89.
- [10] YUE W M, LIU Q R, RUAN Y J, et al. Multiple load forecasting of integrated energy system based on MTL-GRU-Attention [J]. Proceedings of the CSU-EPSA, 2023, 35(6): 83-89.
- [11] 肖霞, 马强, 杨震. 结合注意力和多尺度特征的电动汽车

- 车负荷预测[J/OL]. 电子测量技术,1-9[2025-04-01]. <http://kns.cnki.net/kcms/detail/11.2175.TN.20250206.1115.007.html>.
- XIAO X, MA Q, YANG ZH. Electric vehicle load forecasting combining attention mechanism and multi-scale features [J/OL]. Electronic Measurement Technology,1-9[2025-04-01]. <http://kns.cnki.net/kcms/detail/11.2175.TN.20250206.1115.007.html>.
- [8] VASWANI A, SHAZEE N, PARMAR N, et al. Attention is all you need [C]. Advances in Neural Information Processing Systems. Long Beach, USA, 2017.
- [9] 李玉志,刘晓亮,邢方方,等.基于BiLSTM和特征关联性分析的日尖峰负荷预测[J].电网技术,2021,45(7):2719-2730.
- LI Y ZH, LIU X L, XING F F, et al. Day-ahead peak load forecasting based on BiLSTM and feature correlation analysis [J]. Power System Technology, 2021,45(7):2719-2730.
- [10] 任爽,杨凯,商继财,等.基于CNN-BiGRU-Attention的短期电力负荷预测[J].电气工程学报,2024,19(1):344-350.
- REN SH, YANG K, SHANG J C, et al. Short-term power load forecasting based on CNN-BiGRU-Attention[J]. Journal of Electrical Engineering, 2024,19(1):344-350.
- [11] RUBASINGHE O, ZHANG X, CHAU T K, et al. A novel sequence to sequence data modelling based CNN-LSTM algorithm for three years ahead monthly peak load forecasting [J]. IEEE Transactions on Power Systems, 2024,39(1):1932-1947.
- [12] 曾进辉,苏旨音,肖锋,等.基于生成对抗网络和EMD-ISSA-LSTM的短期电力负荷预测[J].电子测量技术,2024,47(20):92-100.
- ZENG J H, SU ZH Y, XIAO F, et al. Short-term power load forecasting based on generative adversarial network and EMD-ISSA-LSTM [J]. Electronic Measurement Technology, 2024,47(20):92-100.
- [13] ZHANG J L, WEI Y M, LI D Z, et al. Short term electricity load forecasting using a hybrid model[J]. Energy,2018,158:774-781.
- [14] LIANG Y, NIU D X, HONG W. Short term load forecasting based on feature extraction and improved general regression neural network model[J]. Energy, 2019,166:653-663.
- [15] 杨胡萍,余阳,汪超,等.基于VMD-CNN-BiGRU的电力系统短期负荷预测[J].中国电力,2022,55(10):71-76.
- YANG H P, YU Y, WANG CH, et al. Short-term power load forecasting based on VMD-CNN-BiGRU model[J]. Electric Power, 2022,55(10):71-76.
- [16] 于润泽,窦震海,张志一,等.基于二次分解重构与多任务学习的综合能源系统多元负荷短期预测[J].电力建设,2024,45(12):149-161.
- YU R Z, DOU ZH H, ZHANG ZH Y, et al. Short-term multi-energy load forecasting for integrated energy systems based on secondary decomposition and reconstruction and multi-task learning [J]. Electric Power Construction,2024,45(12):149-161.
- [17] 陈锦鹏,胡志坚,陈纬楠,等.二次模态分解组合DBiLSTM-MLR的综合能源系统负荷预测[J].电力系统自动化,2021,45(13):85-94.
- CHEN J P, HU ZH J, CHEN W N, et al. Load forecasting for integrated energy systems based on secondary modal decomposition combined DBiLSTM-MLR[J]. Automation of Electric Power Systems, 2021,45(13):85-94.
- [18] 王维高,魏云冰,滕旭东.基于VMD-SSA-LSSVM的短期风电预测[J].太阳能学报,2023,44(3):204-211.
- WANG W G, WEI Y B, TENG X D. Short-term wind power forecasting based on VMD-SSA-LSSVM [J]. Journal of Solar Energy, 2023,44(3):204-211.
- [19] TRAN M L, KHATIR S, TRAN M T, et al. Exponential-trigonometric optimization algorithm for solving complicated engineering problems [J]. Computer Methods in Applied Mechanics and Engineering, 2024,432(Part B):117411.
- [20] 宋江涛,崔双喜,樊小朝,等.基于SGMD-SE与优化TCN-BiLSTM/BiGRU的超短期风功率预测[J].太阳能学报,2024,45(10):588-596.
- SONG J T, CUI SH X, FAN X CH, et al. Ultra-short-term wind power prediction based on SGMD-SE and optimized TCN-BiLSTM/BiGRU[J]. Journal of Solar Energy, 2024,45(10):588-596.
- [21] NSRDB. Data Viewer[EB/OL]. <https://nsrdb.nrel.gov/>,2023-02-21.

- [22] RESHEF D N, RESHEF Y A, FINUCANE H K, et al. Detecting novel associations in large data sets[J]. *Science*, 2011, 334(6062):1518-1524.
- [23] 李文武,张鹏宇,石强,等.基于聚合混合模态分解和时序卷积神经网络的综合能源系统负荷修正预测[J].*电网技术*,2022,46(9):3345-3357.
LI W W, ZHANG P Y, SHI Q, et al. Load correction forecasting for integrated energy systems based on ensemble mixed mode decomposition and temporal convolutional neural network [J]. *Power System Technology*, 2022, 46(9):3345-3357.
- [24] 乔石,王磊,张鹏超,等.基于时间模式注意力机制的 GRU 短期负荷预测[J].*电力系统及其自动化学报*,2023,35(10):49-58.
QIAO SH, WANG L, ZHANG P CH, et al. Short-term load forecasting based on time pattern attention mechanism using GRU[J]. *Proceedings of the CSU-EPSA*, 2023, 35(10):49-58.
- [25] 黄南天,孙赫宏,王圣元,等.计及多公共充电站差异化耦合关联的电动汽车充电负荷时-空短期预测[J].*中国电机工程学报*,2025,45(4):1424-1436.
HUANG N T, SUN H H, WANG SH Y, et al. Short-term spatiotemporal forecasting of electric vehicle charging load considering differentiated coupling associations of multiple public charging stations[J]. *Proceedings of the CSEE*, 2025, 45(4): 1424-1436.
- [26] BANDT C, POMPE B. Permutation entropy: A natural complexity measure for time series [J]. *Physical Review Letters*, 2002, 88(17):174102.

作者简介

李大华,硕士,教授,主要研究方向为新能源利用与优化。
E-mail:lidah@163.com

赵志成(通信作者),硕士研究生,主要研究方向为综合能源系统负荷预测与调度。
E-mail:361504060@qq.com