

基于模态分解和误差修正的短期电力负荷预测^{*}

鄢化彪 李东丽 黄绿娥 张航菘 姚龙龙

(江西理工大学理学院 赣州市 341000)

摘要: 针对电力负荷非线性、高波动性和强随机性等特性导致无法充分提取时序特征引起预测误差较大的问题,提出了基于改进的自适应白噪声完全集合经验模态分解和误差修正的双向时间卷积网络-双向长短期记忆网络短期电力负荷预测方法。先由最大信息系数筛选出与负荷高度相关的特征集,以削弱特征冗余;通过改进的自适应白噪声完全集合经验模态分解将高波动性的负荷分解为频率各异的本征模态分量和残差,以降低非平稳性;引入样本熵将复杂度相近的分量重构为新子序列,以降低计算量;然后,结合并行双向时间卷积网络提取不同尺度的特征,利用双向长短期记忆网络对负荷序列初步预测,使用麻雀优化算法对神经网络超参数调优;最后,误差序列通过误差修正模块对初始预测值进行修正。经实验验证,与其他预测模型相比, RMSE 最多降低 51.42%,最少降低 34.26%,验证了模型的准确性和有效性。

关键词: 电力负荷;短期预测;自适应经验模态分解;样本熵;双向时间卷积网络;双向长短期记忆;麻雀搜索算法

中图分类号: TM715; TN0 文献标识码: A 国家标准学科分类代码: 470.40

Short-term electric load forecasting based on mode decomposition and error correction

Yan Huabiao Li Dongli Huang Lyu'e Zhang Hangsong Yao Longlong

(School of Science, Jiangxi University of Science and Technology, Ganzhou 341000, China)

Abstract: In order to solve the problem that the time series features cannot be fully extracted due to the characteristics of power load, such as nonlinearity, high volatility and strong randomness, a short-term power load prediction method based on improved complete ensemble empirical mode decomposition with adaptive noise and a deep error correction multi-scale bidirectional temporal convolution network-bidirectional long short-term memory network is proposed. First, the maximum information coefficient is used to select a highly relevant feature set to reduce feature redundancy. Then, improved complete ensemble empirical mode decomposition with adaptive noise is employed to decompose the highly fluctuating load into intrinsic mode functions with different frequencies and residual, while sample entropy is introduced to reconstruct new subsequences with similar complexities to reduce computational load. Next, using the optimal feature set, each subsequence is forecasted with a multi-scale bidirectional temporal convolution network-bidirectional long short-term memory network model optimized by the sparrow search algorithm to obtain initial load sequence predictions. Finally, the error sequence is corrected using the error correction module to refine the initial predictions. Experimental verification shows that compared with other prediction models, RMSE is reduced by 51.42% at most and 34.26% at least, which verifies the accuracy and effectiveness of the model.

Keywords: electric load; short-term forecasting; adaptive empirical mode decomposition; sample entropy; bidirectional temporal convolutional network; bidirectional long short-term memory; sparrow search algorithm

0 引言

智能电网的出现促进了大规模可再生能源发电装置接入电网,推动了国家短期能源规划和运营方面的变革,同时受到电能储存材料和储存成本的限制,电力负荷供需平衡

是电力系统重大挑战之一。因此准确的短期电力负荷预测变得至关重要,其对电力分配、能源交易、需求响应优化、电网检修计划以及负荷容量确定等方面具有重大意义^[1-2]。

短期电力负荷预测常用的方法分为两类:数理统计和

机器学习法。经典的数理统计方法有:自回归综合移动平均模型法^[3]、卡尔曼滤波法^[4]、指数平滑法^[5]等,有着结构简单,拟合速度快的优点,但其对负荷质量要求较高,并不擅长处理非线性高波动性的数据。经典的机器学习方法有:卷积神经网络^[6] (convolutional neural network, CNN)、长短期记忆网络^[7] (long short-term memory network, LSTM)、时间卷积网络^[8] (temporal convolutional network, TCN)等。CNN 虽然能够提取时间序列中的局部特征,但其难以有效捕捉长时间依赖关系和序列的顺序信息,且在处理长序列数据时可能存在计算复杂度高的问题。LSTM 和 TCN 作为当前主流的时序预测模型,前者通过记忆细胞和独特的门控结构,能有效的捕获和保留时序中长期依赖关系;后者则利用膨胀因果卷积和残差连接,在有效的提取时序特征的同时,缓解了梯度消失问题。然而,二者均未充分考虑负荷反向信息对预测效果的影响。在文献[9-10]中,考虑到反向信息的双向长短期记忆网络 (bidirectional long short-term memory, BiLSTM) 和双向时间卷积网络 (bidirectional temporal convolutional network, BiTCN) 相比于传统的 LSTM 和 TCN,在负荷预测中的性能更优,验证了反向信息对提高预测精度的有效性。由于负荷序列受多种外界因素的影响,单一预测模型的性能具有一定的局限性。文献[11]提出了将卷积神经网络 (convolutional neural network, CNN) 和 BiLSTM 相结合,并使用自注意力机制关注重要特征,从而实现负荷的准确预测。文献[12]提出了一种基于混合 TCN-BiLSTM 的短期负荷预测方法,其中 TCN 负责提取多时间尺度特征,BiLSTM 则捕获特征的时序关系并进行预测,与单一模型相比,混合模型具有更高的预测精度。由于组合预测模型包含较多超参数,因此为确保每个子模型作用最大化,通常需要通过智能优化算法进行调参。文献[13]采用改进的黏菌算法优化 CNN-BiLSTM 的超参数,实验结果表明,该优化算法能够有效提高模型的预测精度和收敛速度。

负荷序列具有高波动性和强随机性,深度学习模型在处理时序噪声方面存在一定局限,因此,负荷分解可通过削弱噪声的影响来平滑数据,从而提高预测精度。文献[14-15]分别采用了经验模态分解 (empirical mode decomposition, EMD) 和变分模态分解 (variational mode decomposition, VMD) 对负荷序列进行降噪处理,并利用 BiLSTM 进行负荷预测,实验结果表明,模态分解能够有效降低电力负荷的非线性和非平稳性,从而提高模型的预测精度。然而,单一的 BiLSTM 模型在预测能力和稳定性上具存在一定局限性。文献[16]采用 VMD 将负荷分解成多个子序列,并利用 CNN-BiLSTM-Att 组合模型进行预测,实验验证表明,该模型能够有效降低预测误差。文献[17-18]皆是基于 VMD 对负荷序列进行双重分解,模态分量分别通过 IASSP-EBILSTM 和 TCN-BiLSTM 组合

模型进行负荷预测,实验证明,模态分解和组合模型的集成能够有效地提高预测精度。然而,EMD 存在模态混叠和端点效应问题;VMD 需要预先确定模态的数量和平衡因子,错误的参数设置可能导致分解不准确;此外,组合模型中的 TCN 子模型忽略了双向信息在负荷预测中的重要性。文献[19]提出了一种改进的完全集合经验模态分解与自适应噪声 (improved complete ensemble empirical mode decomposition with adaptive noise, ICEEMDAN) 方法,相较于其他方法,ICEEMDAN 不仅能够有效减少噪声残留,还能自适应的决定模态分解的数量,进一步提升预测的准确性。

上述模型皆是通过模型的改进来提高预测精度,除了前述不足外,许多模型未能充分考虑预测误差中蕴含的大量隐藏信息对预测性能的影响。基于以上研究,本文提出一种基于 ICEEMDAN 和深度误差修正的 BiTCN-BiLSTM 的短期电力负荷预测方法。

1 电力负荷相关性分析及模态分解与重构

1.1 电力负荷相关性分析

电力市场运作模式下的负荷易受气象、日期、历史负荷、经济(电价)等因素影响,变量间存在线性和非线性耦合,弱相关性耦合影响模型训练时间和学习效率,增大预测误差,因此通过 MIC 筛选出高相关性特征。

MIC 核心思想即在不同分辨率下的网格中两变量互信息的最大值。设负荷与电价变量为 $L, C, L = \{l_i\}, C = \{c_i\}$, 其中 $i = 1, \dots, n$, 表示样本数。两变量互信息定义为:

$$I_{MI}(L; C) = \sum_{l \in L} \sum_{c \in C} p(l, c) \log_2 \frac{p(l, c)}{p(l)p(c)} \quad (1)$$

式中: $p(l, c)$ 为 L, C 的联合概率分布, $p(l)$ 和 $p(c)$ 分别为 L, C 的边缘概率分布。

互信息归一化:

$$\hat{I}(L, C) = \frac{I_{MI}(L; C)}{\log_2 \min(m, n)} \quad (2)$$

式中: m, n 为 L, C 划分的分段数。

最大信息系数:

$$I_{MIC}(L, C) = \max_{m \times n < B(n)} \hat{I}(L, C) \quad (3)$$

式中: $B(n)$ 为样本数 n 的函数, $B(n) = n^{0.6}$ 。 $I_{MIC} \in [0, 1]$, 越趋近于 1 表明两变量耦合程度越大, 反之越小。

1.2 改进的自适应噪声完全集合经验模态分解

ICEEMDAN 在 EMD 的基础上,将高波动性不平稳的负荷分解为频率各异的模态分量 (intrinsic mode function, IMF) 和残差,有效地削弱模态混叠,噪声残留等对负荷分解的影响。

设原始信号 $S(t)$, 生成的 N 组高斯白噪声 $\epsilon^n(t)$, 其中 $n = 1, \dots, N, E_n(\cdot)$ 表示经 EMD 分解的 K 阶模态分量, $M(\cdot)$ 为信号上下包络的平均值, 具体步骤为:

1) 迭代 EMD 将 N 组高斯白噪声分解为各自的一阶模

态分量,进而得到加噪信号 $S''(t)$,对加噪信号局部均值操作,得到一阶残差 r_1 ,原始信号与一阶残差的差值即为一阶模态分量 IMF_1 。

$$S''(t) = S(t) + \delta_0 E_1(\epsilon''(t)) \quad (4)$$

式中: δ_0 为噪声系数。

$$r_1 = \frac{1}{N} \sum_{n=1}^N M(S''(t)) \quad (5)$$

$$IMF_1 = S(t) - r_1 \quad (6)$$

2) 通过循环计算得到第 k 阶模态分量 IMF_k 和残差 r_k ,计算等式为:

$$r_k = \frac{1}{N} \sum_{n=1}^N M(r_{k-1} + \delta_{k-1} E_k(\epsilon''(t))) \quad (7)$$

$$IMF_k = r_{k-1} - r_k \quad (8)$$

白噪声残差的极值点数量小于或等于 1 时迭代终止。

1.3 样本熵

负荷序列经过 ICEEMDAN 分解使得要预测的时间序列增多,一定程度上不仅增加了计算量还增加预测误差,由于负荷分量间存在一定的相似性,引入样本熵(sample entropy, SE)将复杂度相近的分量重构,以降低计算规模和误差累积对预测精度的影响。

设 N 维负荷分量 $\mathbf{X} = \{x_1, x_2, \dots, x_n\}$, 样本熵函数 $S_E(N, m, r)$, N 为负荷分量长度, m 为位数, r 为相似度阈值, 具体步骤如下:

1) 构建 m 维的滞后向量 \mathbf{X}_i^m :

$$\mathbf{X}_i^m = \{x_i, x_{i+1}, \dots, x_{i+m-1}\}, i \in [1, N-m+1] \quad (9)$$

2) 计算向量间的距离,即对应元素最大绝对差值:

$$d[i, j] = d[\mathbf{X}_i^m, \mathbf{X}_j^m] = \max_{0 \leq k \leq m} |x_{i+k} - x_{j+k}| \quad (10)$$

3) 计算每个 \mathbf{X}_i^m 相似向量的数量,即距离小于 r 的向量数量:

$$C_i^m(r) = \frac{1}{N-m+1} \sum_{j=1}^{N-m+1} H(r - d[i, j]) \quad (11)$$

式中: H 为 Heaviside 函数,当 $r - d[i, j] \geq 0$ 时, $H=1$,否则为 0。

4) 计算所有 m 维向量平均相似度 $C^m(r)$:

$$C^m(r) = \frac{1}{N-m} \sum_{i=1}^{N-m} C_i^m(r) \quad (12)$$

5) 构建 $m+1$ 维的滞后向量,重复上述步骤,得到平均相似度 $C^{m+1}(r)$ 。

6) 计算样本熵 $S_E(N, m, r)$:

$$S_E(N, m, r) = -\ln(\frac{C^{m+1}(r)}{C^m(r)}) \quad (13)$$

2 基于模态分解和深度误差修正的 BiTCN-BiLSTM 预测方法

2.1 多尺度 BiTCN 模型

TCN 模型由因果卷积、膨胀卷积和残差连接构成,是一种专门为高效处理时序数据而设计的架构^[20]。单向

TCN 只关注了时间序列前向信息对后向信息的影响,忽略了反向隐藏信息对时序预测的影响。为了克服反向信息对预测序列的影响,使用 BiTCN 模型同时提取负荷序列双向隐藏信息流,以捕获长期依赖关系,提高模型的预测精度。

BiTCN 模型详细结构如图 1 所示,它是由两个独立的输入序列相反的 TCN 子模块构成,通过因果膨胀卷积实现对双向信息流的提取。设 n 维的输入序列 $\mathbf{X} = \{x_1, x_2, \dots, x_n\}$ 和滤波器 $\mathbf{F} = \{f_1, f_2, \dots, f_k\}$, 经双向卷积处理, t 时刻的输出为 y_t :

$$\vec{y}_t = \text{ReLU}(\sum_{i=1}^k \vec{f}_i x_{t-d \times i} + \vec{b}) \quad (14)$$

$$\overleftarrow{y}_t = \text{ReLU}(\sum_{i=1}^k \overleftarrow{f}_i x_{t+d \times i} + \overleftarrow{b}) \quad (15)$$

式中: $\vec{y}_t, \overleftarrow{y}_t$ 分别为正向和反向卷积输出; $\vec{f}_i, \overleftarrow{f}_i$ 分别为正向和反向卷积核权重; $t - d \times i, t + d \times i$ 分别为正向和反向输入序列历史数据位置; ReLU 为激活函数; k 为滤波器大小; d 为膨胀系数。

$$y_t = \mathbf{W}(\vec{y}_t + \overleftarrow{y}_t) + \mathbf{b} \quad (16)$$

式中: \mathbf{W}, \mathbf{b} 为输出层的权重和偏置。

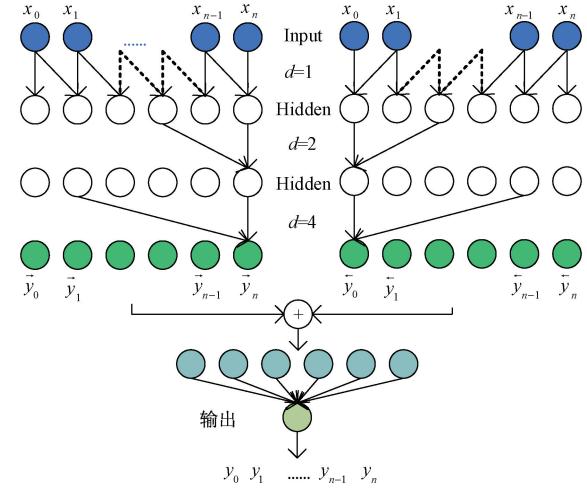


图 1 BiTCN 模型的结构

Fig. 1 Structure of the BiTCN model

从上述公式和结构图可知,可以通过调整卷积核和膨胀因子的大小来增大膨胀卷积的感受野,以获取更多的历史信息,同时多尺度 BiTCN 能够提取时间尺度各异的趋势和周期性特征,以增强模型的预测能力。经实验统计,三层并行叠加的 BiTCN,参数 $k = \{3, 7, 11\}$, $d = \{1, 2, 4, 8\}$ 效果较好。

2.2 BiLSTM 模型

LSTM 通过引入记忆细胞和独特的门控机制(输入门,更新门,输出门)有效地缓解了梯度消失现象,是经典的时序处理模型之一,具体结构和信息流动计算流程参考

文献[21]。然而, LSTM 对时间序列处理时只能单向地学习时序特征而忽略了未来信息对捕获长期依赖关系的影响^[22], 因此采用由正反向 LSTM 共同组成的 BiLSTM 充分提取时序信息提高预测精度, BiLSTM 结构如图 2 所示, 计算过程为:

$$\vec{h}_t = \text{LSTM}(x_t, \vec{h}_{t-1}) \quad (17)$$

$$\overset{\leftarrow}{h}_t = \text{LSTM}(x_t, \overset{\leftarrow}{h}_{t-1}) \quad (18)$$

$$o_t = W_t \vec{h}_t + V_t \overset{\leftarrow}{h}_t + b_t \quad (19)$$

式中: $\vec{h}_t, \overset{\leftarrow}{h}_t$ 分别表示正向和反向 LSTM_t 时刻的隐藏向量; o_t, x_t 分别为 BiLSTM_t 时刻隐藏向量和输入; W_t, V_t, b_t 分别为 t 时刻正向和反向 LSTM 权重及 BiLSTM 输出层的偏置。

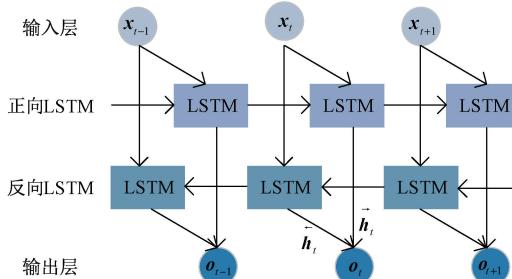


图 2 BiLSTM 模型的结构

Fig. 2 Structure of the BiLSTM model

2.3 SSA-BiTCN-BiLSTM 模型的预测与误差修正

气象、日期、电价和历史负荷等因素的综合作用会引起电力负荷的波动, 如果仅依靠单序列历史负荷进行预测, BiTCN-BiLSTM 网络由于无法充分的捕获负荷的波动特征而导致预测精度下降, 因此结合高相关性特征, 对负荷序列初步预测, 而构建的预测模型仅利用了负荷的预测值, 忽略预测误差包含的隐藏信息, 因此通过误差修正模块对误差序列进行修正来提升预测精度, 其具体结构如图 3 所示, 以 $(f_l, f_w, f_e, f_t, f_{\hat{y}})$ 为输入 x_i , $f_l, f_w, f_e, f_t, f_{\hat{y}}$ 分别为历史负荷, 气象、经济、时间、初步预测值, 历史误差序列为输出 y_i , 构建多尺度 BiTCN-BiLSTM 误差修正模块(error correction model, ECM), 并基于当前时刻的特征对未来时刻的误差进行修正, 误差修正值与初始预测值之和为最终的负荷预测值。这里设置 3 层不同卷积核大小的 BiTCN 并联叠加初步提取时序特征, 随后通过 BiLSTM 对负荷进行预测。为了减小手动调整超参数易受人为经验和偏见的影响, 使用 SSA 对神经网络超参数进行优化, SSA 是一种成熟的优化算法, 具体原理可参考文献[23]。

2.4 短期电力负荷预测模型总体框架

针对非线性、高波动性、强随机性的负荷预测误差较大的问题, 提出一种基于模态分解和深度误差修正的 BiTCN-BiLSTM 负荷预测模型, 整体框架如图 4 所示, 负荷预测流

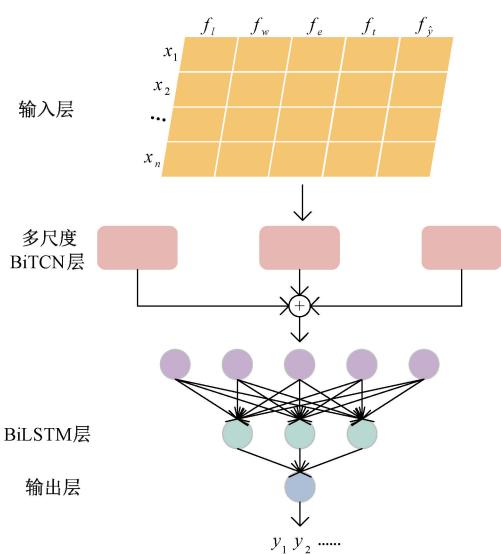


图 3 BiTCN-BiLSTM 模型的结构

Fig. 3 Structure of the BiTCN-BiLSTM model

程为:

1) 首先对原始数据预处理: 负荷和气象数据异常值处理、MIC 筛选与负荷高相关性耦合的特征集和数据归一化。

2) 通过 ICEEMDAN 将预处理以后的非平稳负荷分解成多个 IMF 和一个 Res, 为了减小后续预测的复杂度和计算量, 引入 SE 根据各分量复杂度重构新的分量 (IMF₁, IMF₂, ..., IMF_m)。

3) 将重构分量与最佳特征集输入 BiTCN-BiLSTM 网络进行训练, 使用 SSA 算法优化网络的超参数, 各分量预测值的和为初始预测值。

4) 利用训练集的历史负荷, 最佳特征集, 初步预测值及误差序列构建误差修正模型 SSA-BiTCN-BiLSTM, 对误差序列进行修正, 误差修正值和初始预测值之和为最终预测值。

3 实验设置

3.1 数据预处理

数据来源于澳大利亚 2009 年 3 月 1 日~2009 年 5 月 31 日公开负荷数据集, 采样间隔为 30 min, 数据集包含负荷、气象(干球温度、露点温度、湿球温度、湿度)和实时电价六大特征。

1) 异常数据处理

异常值多是由于设备故障或工作人员误录造成的, 本文利用箱线图方法检测负荷和气象数据的异常数据。由于负荷具有日周期性, 异常值用相邻日同时刻负荷平均值修正; 气象数据用样条插值法修正。

2) MIC 筛选最佳特征集

负荷不仅受气象因素影响, 还随时间呈周期性变化, 因此在原始数据集六大特征的基础上增加日期特征(节假日、星期、日、月、时刻)。这些特征并不一定和负荷高度相关性

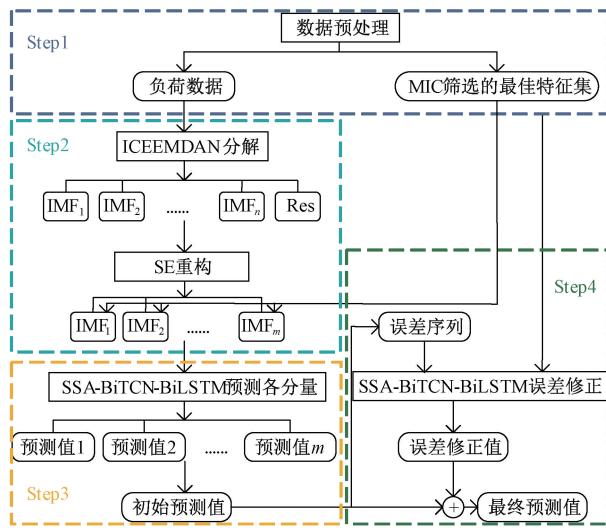


图 4 短期电力负荷预测框架

Fig. 4 Framework of short-term electricity load forecasting

耦合,弱相关耦合会影响预测精度,因此通过 MIC 筛选高相关性特征。各特征的 MIC 值如表 1 所示,只有节假日、星期和月与负荷的 MIC 值小于 0.5,因此除节假日、星期和月剩余的特征为最佳特征。

表 1 各特征与负荷序列的 MIC

Table 1 MIC between each feature and the load sequence

类型	变量	MIC 值	类型	变量	MIC 值
	节假日	0.132		干球温度	0.738
	星期	0.362		露点温度	0.746
日期	日	0.538	气象	湿球温度	0.723
	月	0.241		湿度	0.661
	时刻	0.589	经济	电价	0.824

3) 数据归一化

各特征量纲的差异会影响预测精度和训练速度,因此将数据缩放到 $[0,1]$, 归一化公式为:

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (20)$$

式中: x' 为归一化结果, x_{\max} 和 x_{\min} 为该特征最大值和最小值。

3.2 评价指标

以均方根误差 (RMSE/KW)、平均绝对百分比误差 (MAPE/%)、平均绝对误差 (MAE/KW) 和决定系数 R^2 为衡量预测准确度的评价指标^[10,19]。

3.3 参数设置

数据按照 8:1:1 的比例分为训练集、验证集和测试集,通过滑动窗口用过去一天的特征数据进行单步预测。预测和修正模块都是基于多尺度 BiTCN-BiLSTM 模型,该实验设置 3 层的 BiTCN 并行叠加对时序特征进行提取,其卷积核大小分别为 {3,7,11} 和每个子模块膨胀因子为 {1,2,4},

8); 经实验验证,两层的 BiLSTM 对输入的时序特征进行预测,预测效果并没有显著提升反而增加预测时间,因此 BiLSTM 设置为一层。本文使用 Adam 优化器,ReLU 为激活函数,以 RMSE 为适应度函数,使用 SSA 算法对该模型的超参数进行优化,优化参数如表 2 所示。

表 2 SSA 算法寻优参数

Table 2 Optimization parameters of the SSA algorithm

分量	SE 值
IMF1	1.519
IMF2	0.951
IMF3-IMF4	1.057
IMF5-Res	0.470

本文实验采用硬件设备: Intel(R) Core(TM) i5-8265U CPU, 8 GB RAM, 模型的搭建和训练在 Matlab2023b 实现。

4 实例分析

4.1 ICEEMDAN 分解与 SE 重构

为了削弱负荷序列的高波动性随机性对时序特征提取的影响,负荷序列输入神经网络前先经 ICEEMDAN 分解为较为平稳的分量,实验参数设置噪声系数 $\delta_0 = 0.2$, 噪声添加 $N = 500$ 次,最大迭代 1 000 次,负荷序列分解效果如图 5 所示。共得到 11 个模态分量和 1 个残差分量,且频

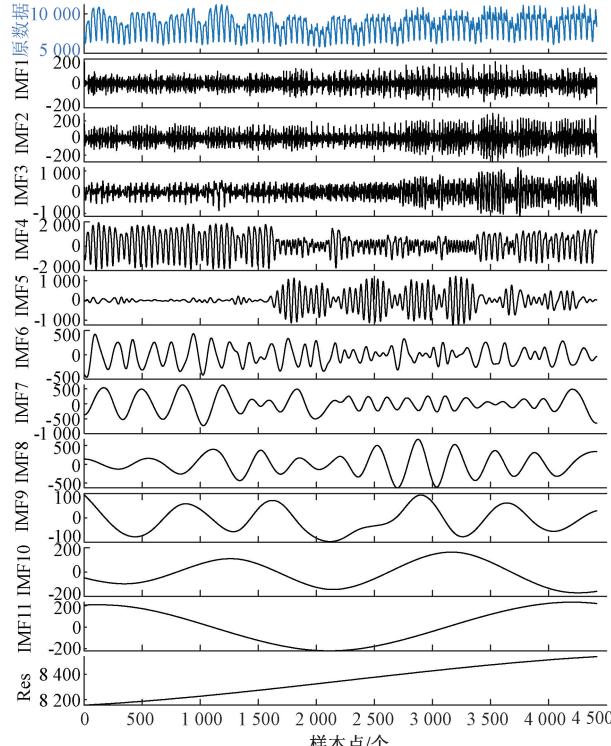


图 5 ICEEMDAN 分解结果

Fig. 5 ICEEMDAN decomposition results

率从上到下依次下降,由于相邻的分量波动情况相似,考虑后续神经网络预测效率和计算规模,通过 SE 计算各分量的复杂度将其进行重构,实验参数设置模式维数为 $m = 2$,相似度阈值 $r = 0.2 \times (\text{原始负荷序列标准差})$ ^[24]。各分量 SE 值如表 3 所示。

表 3 IMF 分量的 SE 值

Table 3 SE values of the IMF components

分量	SE 值	分量	SE 值	分量	SE 值
IMF1	1.519	IMF5	0.166	IMF9	0.020
IMF2	0.951	IMF6	0.156	IMF10	0.008
IMF3	0.599	IMF7	0.067	IMF11	0.003
IMF4	0.458	IMF8	0.050	Res	0.000 1

由表 3 可知,IMF1-IMF11,Res 复杂度依次降低,SE 值逐次下降,通过对相邻分量 SE 差值分析,将差值阈值设定为 0.17。IMF3 和 IMF4 的 SE 值相差 0.141,IMF5 和 Res 的 SE 值相差 0.165 9,因此将 IMF3 和 IMF4 合并,IMF5-Res 合并,重构后的 4 个分量 SE 值如表 4 所示。

表 4 重构分量的 SE 值

Table 4 SE values of the reconstructed components

寻优参数	寻优范围
学习率	[0.000 1, 0.01]
BiLSTM 神经元个数	[10, 100]
卷积核个数	[3, 11]
迭代次数	[80, 150]

4.2 ICEEMDAN-SE-SSA-BiTCN-BiLSTM-ECM 预测效果分析

1) ICEEMDAN 分解与 SE 重构有效性验证

ICEEMDAN 将高波动性序列分解为较为平稳的负荷子序列,考虑后续的计算规模,通过 SE 将子序列进行重构,一定程度上增加预测精度。为了验证 ICEEMDAN 分解与 SE 重构的有效性,分别将 ICEEMDAN 和 ICEEMDAN-SE 应用到 BiTCN、BiLSTM、BiTCN-BiLSTM 预测模型中。考虑各模型实验结果公平有效性对比,设置 BiTCN 和 BiLSTM 模型的结构和参数与 SSA 优化后的 BiTCN-BiLSTM 模型保持一致,其优化后的学习率为 0.005 7, BiLSTM 神经元个数为 87, 卷积核的个数为 5, 最大迭代次数为 123, 测试集的预测结果如表 5 所示, 表中 + ICEEMDAN 和 + SE 分别表示将 ICEEMDAN 和 ICEEMDAN-SE 应用到对应模型中。

由表 5 可知,在 BiTCN、BiLSTM 和 BiLSTM-BiTCN 3 种预测模型中,加入 ICEEMDAN 后各模型的 MAE 分别降低了 5.946%、34.610%、24.614%; MAPE 分别降低了 8.124%、34.718%、25.831%; RMSE 分别降低了

2.603%、38.233%、34.153%,在模态分解的基础上通过 SE 重构分量,上述 3 种模型的 MAE 分别降低了 9.990%、39.329%、37.308%; MAPE 分别降低了 14.452%、41.166%、35.976%; RMSE 分别降低了 10.656%、41.832%、38.753%; R^2 分别提高了 2.102%、1.639%,0.913%,误差评价指标的降低及拟合程度的增高验证了 ICEEMDAN 负荷序列分解和 SE 重构分量一定程度上有助于预测精度的提高。

表 5 基于分解和重构的模型评价结果

Table 5 Model evaluation results based on decomposition and reconstruction

模型	MAE /KW	MAPE /%	RMSE /KW	R^2
BiTCN	299.880	3.619	362.678	0.904
+ ICEEMDAN	282.050	3.325	353.238	0.909
+ SE	269.923	3.096	324.031	0.923
BiLSTM	133.399	1.613	180.982	0.976
+ ICEEMDAN	87.230	1.053	111.787	0.991
+ SE	80.935	0.949	105.254	0.992
BiTCN- BiLSTM	100.893	1.173	138.499	0.986
+ ICEEMDAN	76.059	0.870	91.199	0.994
+ SE	63.252	0.751	84.827	0.995

2) 模块有效性验证

通过内部消融实验验证各个模块的有效性和所提模型的可行性,即在 BiTCN 模块的基础上,依次添加 BiLSTM 模块,SSA 模块,ICEEMDAN 模块,SE 模块和 ECM 模块。实验设置未经 SSA 优化的 BiTCN 中的卷积核个数为 7, BiLSTM 神经元个数为 50, 学习率为 0.001, 最大迭代次数为 100, 其他模型的参数均与优化以后的参数保持一致, 各组合模型在测试集的预测效果和评价指标如图 6 和表 6 所示, 表 6 中“+”表示在前面模型的基础上继续添加。

由图 6 可知,各个模型预测值基本符合真实值的变化趋势,但在尖峰阶段本文模型的预测值与真实值的误差值最小;由表 6 可知:单一 BiTCN 模型效果最差,BiLSTM 模型的结合使 MAE 降低了 27.828%, RMSE 降低了 28.804%,说明 BiLSTM 能够有效的捕获负荷序列中双向隐藏信息和非线性关系;SSA 算法自适应调整 BiTCN-BiLSTM 模型中的超参数,与 BiTCN-BiLSTM 模型相比 MAE 降低了 24.352%, RMSE 降低了 43.948%,能够高效的搜索潜在的超参数组合,避免因人工经验造成的结果偏差;经 ICEEMDAN 时序分解和 SE 重构,与 SSA-BiTCN-BiLSTM 模型相比 MAE 降低了 37.308%, RMSE 降低了 38.753%,说明负荷分解的有效性;本文提出的误差修正模型预测效果最好,与单一 BiTCN 模型相比, MAE 降低了

67.406%, RMSE 降低了 68.118%, R² 提升了 4.293%。说明各个模块对预测精度具有一定程度的提升, 协同作用使模型发挥最佳性能。

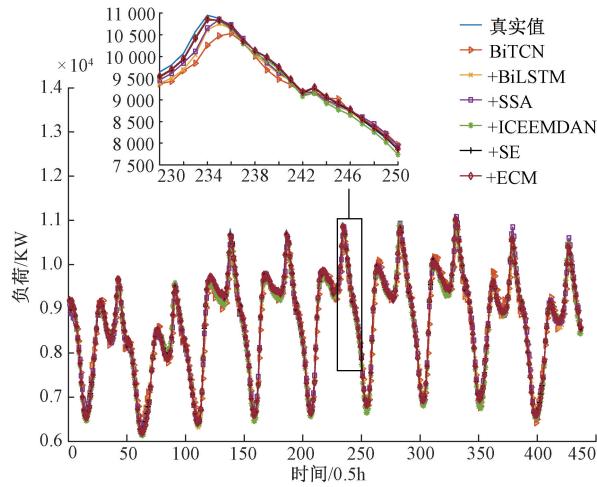


图 6 消融实验预测结果

Fig. 6 Prediction results of the ablation experiment

表 6 消融实验误差对比

Table 6 Comparison of errors in the ablation experiment

模型	MAE /KW	MAPE /%	RMSE /KW	R ²
BiTCN	184.795	2.131	247.091	0.955
+BiLSTM	133.371	1.558	175.919	0.977
+SSA	100.893	1.173	138.499	0.986
+ICEEMDAN	76.059	0.870	91.199	0.994
+SE	63.252	0.751	84.827	0.995
+ECM (本文模型)	60.233	0.714	78.778	0.996

3) 模型优越性和泛化性验证

为了验证本文模型的优越性, 将该模型和其他模型 (TCN^[25]、LSTM^[26]、BiLSTM^[27]、CNN-BiLSTM^[28]、TCN-LSTM^[29]) 进行预测对比, 各模型的输入特征及参数设置均与本文模型保持一致, 其预测效果和评价指标如图 7 和表 7 所示。

由图 7 和表 7 可知, 本文模型的预测曲线与真实值的变化高度吻合, 即使在误差较大的尖峰或峰谷期间, 也能表现出较高的拟合度。BiLSTM 模型相比 LSTM 模型, MAE 分别下降了 11.57%, MAPE 分别下降了 13.652%, RMSE 分别下降了 8.642%, 这表明反向信息能够有效地提高模型的预测精度; CNN-BiLSTM 组合模型相比于 BiLSTM 单模型, MAE 分别下降了 19.626%, MAPE 分别下降了 18.577%, RMSE 分别下降了 18.919%; TCN-LSTM 模型相比于 TCN 和 LSMT 单模型, MAE 分别下降了 7.038%、21.444%, MAPE 分别下降了 6.074%、23.349%, RMSE

分别下降了 3.139%、20.951%, 说明组合模型相较于单一模型更能捕获时序特征, 从而提高模型的预测精度。本文模型与次优模型 CNN-BiLSTM 相比, MAE、MAPE、RMSE 分别下降了 30.233%、30.680%、34.167%, R² 提高了 0.606%, 得益于本文模型不仅继承了组合模型在预测中的优势, 还充分考虑了负荷序列不平稳性和高波动性, 并通过模态分解有效降低了噪声影响, 并利用了误差序列中的隐藏信息, 从而提高模型的预测精度。

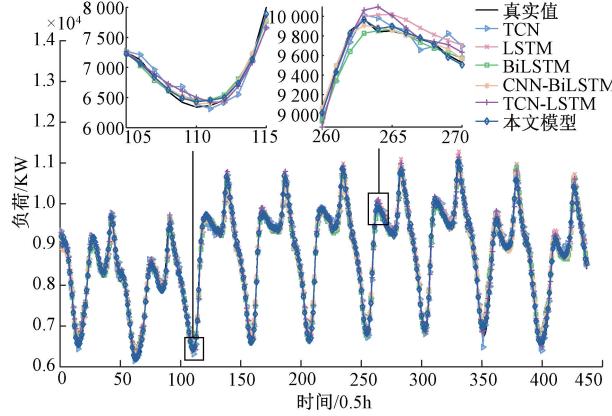


图 7 各模型预测效果

Fig. 7 Prediction performance of different models

表 7 不同模型预测结果

Table 7 Predictions from each model

模型	MAE /MW	MAPE /%	RMSE /MW	R ²
TCN	0.103	1.195	0.132	0.987
LSTM	0.121	1.465	0.162	0.981
BiLSTM	0.107	1.265	0.148	0.984
CNN- BiLSTM	0.086	1.030	0.120	0.990
TCN- LSTM	0.095	1.123	0.128	0.988
本文模型	0.060	0.714	0.079	0.996

为了验证本文模型的泛化性, 分别在两个数据集上进行了模型的有效性验证: 一个是澳大利亚地区 2008 年 3 月~2009 年 2 月的数据集, 另一个是新英格兰地区 2020 年 9 月~2020 年 11 月的数据集。新英格兰数据集包含电力负荷和气象特征, 采样间隔为 1 h。由于气象信息具有较强的季节性特征, 因此将 2008 年 3 月~2009 年 2 月的数据集按照春、夏、秋、冬 4 个季度进行划分, 并在每个季度分别验证模型的性能, 同时保持数据预处理方式和参数设置一致。

澳大利亚数据集中, 各模型的评价指标如图 8 所示。从图 8 可以看出, 在春、夏、秋、冬 4 个季节中, 与其他模型相比, 本文模型的误差评价指标 (MAE、MAPE、RMSE) 均为最低, 而预测值和真实值的拟合程度 (R²) 均为最高, 证

明了本文预测模型在该数据集上具有良好的优越性和泛化性。此外,新英格兰数据集中,各模型的预测结果如表 8 所示,本文模型各评价指标均为最优值,预测效果最好,与次优模型 TCN-LSTM 相比,MAE、MAPE、RMSE 分别降低了 36.716 0%、35.175%、35.826%,R2 提高了 2.073%,体现了本文模型的有效性和优越性。

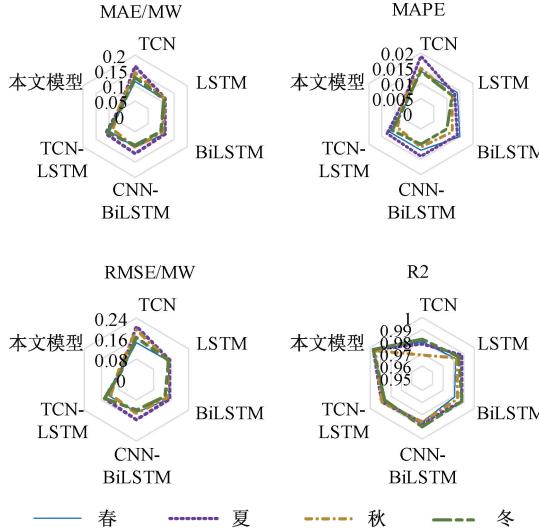


图 8 四季各模型评价指标

Fig. 8 Evaluation metrics of different models for each season

表 8 各模型预测结果

Table 8 Prediction results of different models

模型	MAE /MW	MAPE /%	RMSE /MW	R ²
TCN	604.587	4.773	774.406	0.829
LSTM	630.867	4.857	831.005	0.803
BiLSTM	555.585	4.325	708.253	0.857
CNN-BiLSTM	335.707	2.638	409.456	0.952
TCN-LSTM	277.107	2.172	352.801	0.965
本文模型	175.364	1.408	226.408	0.985

5 结 论

针对电力负荷高波动性、强随机性和非线性等特性造成预测精度不高的问题,本文提出了一种基于ICEEMDAN 负荷分解和误差修正的 BiTCN-BiLSTM 短期电力负荷预测模型。该模型的特点在于,首先,多尺度 BiTCN-BiLSTM 能够同时提取负荷序列的双向隐藏信息流,从而捕获长期依赖关系,提升预测精度;其次,ICEEMDAN 序列分解有助于削弱负荷的强随机性和高波动性,SE 分量重构不仅降低了模型的计算规模,还提升了预测精度和训练效率;最后,误差修正模块综合考虑了气

象、日期、电价和历史负荷等因素对负荷预测的影响,充分挖掘负荷的波动特性,从而提升了模型的预测性能。然而,本文未考虑不同时刻相关特征对负荷序列影响的差异,未来可引入注意力机制等方法,以进一步提高短期负荷预测的精度。

参考文献

- [1] BAUR L, DITSCHUNEIT K, SCHAMBACH M, et al. Explainability and interpretability in electric load forecasting using machine learning techniques-a review[J]. Energy and AI, 2024, 16: 100358.
- [2] AQUILA G, MORAIS L B S, DE FARIA V A D, et al. An overview of short-term load forecasting for electricity systems operational planning: Machine learning methods and the brazilian experience [J]. Energies, 2023, 16(21): 7444.
- [3] WU F, CATTANI C, SONG W Q, et al. Fractional ARIMA with an improved cuckoo search optimization for the efficient short-term power load forecasting[J]. Alexandria Engineering Journal, 2020, 59 (5): 3111-3118.
- [4] 陈培垠, 方彦军. 基于卡尔曼滤波预测节假日逐点增长率的电力系统短期负荷预测[J]. 武汉大学学报: 工学版, 2020, 53(2): 139-144.
- [5] CHEN P Y, FANG Y J. Short-term load forecasting of power system for holiday point-by-point growth rate based on Kalman filtering[J]. Engineering Journal of Wuhan University, 2020, 53(2): 139-144.
- [6] RENDON-SANCHEZ J F, MENEZES L D. Structural combination of seasonal exponential smoothing forecasts applied to load forecasting [J]. European Journal of Operational Research, 2019, 275 (3): 916-924.
- [7] 魏玮, 吕游, 齐欣宇, 等. 基于 CNN-LSTM-AM 动态集成模型的电站风机状态预测方法[J]. 仪器仪表学报, 2023, 44(4): 19-27.
- [8] WEI W, LYU Y, QI X Y, et al. State prediction method for power plant fans based on the CNN-LSTM-AM dynamic integrated model[J]. Chinese Journal of Scientific Instrument, 2023, 44(4): 19-27.
- [9] 曾进辉, 苏旨音, 肖峰, 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.
- [10] ZENG J H, SU ZH Y, XIAO F, et al. Short-term power load forecasting based on generative adversarial networks and EMD-ISSA-LSTM [J]. Electronic Measurement Technology, 2024, 47(20): 92-100.
- [11] 王朋飞, 刘长良, 徐健, 等. 基于图注意力和时间卷积网络的风电齿轮箱故障预警方法[J]. 电子测量与仪

- 器学报, 2023, 37(8): 204-213.
- WANG P F, LIU CH L, XU J, et al. Wind turbine gearbox fault warning method based on graph attention and temporal convolutional network [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(8): 204-213.
- [9] ZHAO H X, ZHOU ZH L, ZHANG P ZH. Forecasting of the short-term electricity load based on WOA-BiLSTM [J]. International Journal of Pattern Recognition and Artificial Intelligence, 2023, 37(11): 2359018.
- [10] ZHANG D D, CHEN B AN, ZHU H Y, et al. Short-term wind power prediction based on two-layer decomposition and BiTCN-BiLSTM-attention model [J]. Energy, 2023, 285: 128762.
- [11] WU M P, WU F. Predicting residential electricity consumption using CNN-BiLSTM-SA neural networks [J]. IEEE Access, 2024, 12: 71555-71565.
- [12] WU Q L, ZHANG W, WEI CH F, et al. A novel short-term intelligent forecasting method for bus loads driven by hybrid TCN-BiLSTM [C]. Sustainable Power and Energy Conference(iSPEC), IEEE, 2023: 1-6.
- [13] 马苗洁, 孟昭亮, 张乐, 等. 基于多目标优化的 ISMA-CNN-BiLSTM 短期负荷预测 [J]. 国外电子测量技术, 2023, 42(12): 116-122.
- MA M J, MENG ZH L, ZHANG Y, et al. Short-term load forecasting based on ISMA-CNN-BiLSTM multi-objective optimization [J]. Foreign Electronic Measurement Technology, 2023, 42(12): 116-122.
- [14] 陈晓华, 吴杰康, 蔡锦健, 等. 基于猎人猎物优化算法优化 BiLSTM 的电力负荷短期预测 [J]. 山东电力技术, 2024, 51(4): 64-71.
- CHEN X H, WU J K, CAI J J, et al. Short-term load prediction based on BiLSTM optimized by hunter-prey optimization algorithm [J]. Shandong Electric Power, 2024, 51(4): 64-71.
- [15] 郝露茜, 刘琳, 刘白杨, 等. 基于变分模态分解和麻雀搜索算法的双向长短期记忆网络的风电短期功率预测方法研究 [J]. 湖南电力, 2024, 44(3): 89-95.
- HAO L Q, LIU L, LIU B Y, et al. Research on short-term wind power prediction method of bidirectional long short-term memory based on variational mode decomposition and sparrow search algorithm [J]. Hunan Electric Power, 2024, 44(3): 89-95.
- [16] 王金玉, 胡喜乐, 闫冠宇. 基于 VMD 的 CNN-BiLSTM-Att 的短期负荷预测 [J]. 吉林大学学报(信息科学版), 2023, 41(6): 1007-1014.
- WANG J Y, HU X L, YAN G Y. Short-term load prediction of CNN-BiLSTM-Att based on VMD [J]. Journal of Jilin University (Information Science Edition), 2023, 41(6): 1007-1014.
- [17] 杨健, 孙涛, 陈小龙, 等. 基于 VMD-EWT-IASSP-EBILSTM 的短期电力负荷预测 [J]. 科学技术与工程, 2023, 23(27): 11646-11654.
- YANG J, SUN T, CHEN X L, et al. Research of short-term power load forecasting based on VMD-EWT-IASSP-EBILSTM [J]. Science Technology and Engineering, 2023, 23(27): 11646-11654.
- [18] 杨汪洋, 魏云冰, 罗程浩. 基于 CVMD-TCN-BiLSTM 的短期电力负荷预测 [J]. 电气工程学报, 2024, 19(2): 163-172.
- YANG W Y, WEI Y B, LUO CH H. Short-term electricity load forecasting based on CVMD-TCN-BiLSTM [J]. Transactions of China Electrotechnical Society, 2024, 19(2): 163-172.
- [19] LI L B, JING R X, ZHANG Y L, et al. Short-term power load forecasting based on ICEEMDAN-GRA-SVDE-BiGRU and error correction model [J]. IEEE Access, 2023, 11: 110060-110074.
- [20] CHOI H S, YANG J H. Innovative use of self-attention-based ensemble deep learning for suicide risk detection in social media posts [J]. Applied Sciences, 2024, 14(2): 893.
- [21] WAN AN P, CHANG Q, KHALIL A L B, et al. Short-term power load forecasting for combined heat and power using CNN-LSTM enhanced by attention mechanism [J]. Energy, 2023, 282: 128274.
- [22] 陈晓梅, 肖徐东. 基于集群辨识和卷积神经网络-双向长短期记忆-时序模式注意力机制的区域级短期负荷预测 [J]. 现代电力, 2024, 41(1): 106-115.
- CHEN X M, XIAO X D. Regional short-term load forecasting based on cluster identification and convolutional neural network-bidirectional long short-term memory-temporal pattern attention [J]. Modern Electric Power, 2024, 41(1): 106-115.
- [23] HUANG W H, SONG Q, HUANG Y. Two-stage short-term power load forecasting based on SSA-VMD and feature selection [J]. Applied Sciences, 2023, 13(11): 6845.
- [24] AI X Y, LI SH J, XU H X. Short-term wind speed forecasting based on two-stage preprocessing method, sparrow search algorithm and long short-term memory neural network [J]. Energy Reports, 2022, 8: 14997-15010.

- [25] 赵洋, 王瀚墨, 康丽, 等. 基于时间卷积网络的短期电力负荷预测 [J]. 电工技术学报, 2022, 37(5): 1242-1251.
ZHAO Y, WANG H M, KANG L, et al. Temporal convolution network-based short-term electrical load forecasting [J]. Transactions of China Electrotechnical Society, 2022, 37(5): 1242-1251.
- [26] 崔星, 李晋国, 张照贝, 等. 基于改进粒子群算法优化 LSTM 的短期电力负荷预测 [J]. 电测与仪表, 2024, 61(1): 131-136.
CUI X, LI J G, ZHANG ZH B, et al. The short-term power load forecasting based on NIWPSO-LSTM neural network [J]. Electrical Measurement & Instrumentation, 2024, 61(1): 131-136.
- [27] XU J, ZENG P. Short-term load forecasting by BiLSTM model based on multidimensional time-domain feature [C]. Neural Networks Information and Communication Engineering (NNICE), IEEE, 2024: 1526-1530.
- [28] ZHANG J L, LIN T, XIONG B P, et al. Short-term load forecasting of power system based on attention mechanism CNN-BiLSTM [C]. China Automation Congress(CAC), 2022: 1443-1446.
- [29] XU X Y, ZHOU ZH L, ZHAO H X. Short-term power load forecasting based on TCN-LSTM model [C]. International Conference on Energy, Power and Electrical Technology (ICEPET), IEEE, 2024: 1340-1343.

作者简介

鄢化彪, 硕士, 副教授, 主要研究方向为复杂系统建模和深度学习。

E-mail:yanhuabiao@21cn.com

李东丽, 硕士研究生, 主要研究方向为深度学习在短期电力负荷预测的应用。

E-mail:3173970864@qq.com

黄绿娥(通信作者), 博士, 副教授, 主要研究方向为机器视觉与深度学习。

E-mail:9320080310@jxust.edu.cn

张航菘, 硕士研究生, 主要研究方向为机器学习与图像去模糊。

E-mail:3373693905@qq.com

姚龙龙, 硕士研究生, 主要研究方向为机器学习与三维重构。

E-mail:3193620647@qq.com