

DOI: 10.19783/j.cnki.pspc.241701

# 基于 VMD-SE-CNN-BiLSTM 的电动汽车充电负荷短期预测

吴方权<sup>1</sup>, 李斯琦<sup>1</sup>, 胡骏涵<sup>1</sup>, 汤成佳<sup>1</sup>, 邹建业<sup>2</sup>

(1. 贵州电网有限责任公司信息中心, 贵州 贵阳 550003; 2. 北京科东电力控制系统有限责任公司, 北京 100194)

**摘要:** 近年来, 随着电动汽车保有量的快速增长, 准确预测电动汽车充电负荷已成为电网规划和充电设施优化的重要研究课题。针对传统预测方法难以处理负荷数据复杂非线性特征和多因素动态影响的问题, 提出了一种基于数据预处理、结合变分模态分解-样本熵(variational mode decomposition-sample entropy, VMD-SE)数据重构和卷积神经网络-双向长短期记忆网络(convolutional neural network-bidirectional long short-term memory, CNN-BiLSTM)深度学习框架的充电负荷预测模型。首先, 利用高斯混合模型-K最近邻(Gaussian mixture model-K-nearest neighbor, GMM-KNN)方法检测并填补数据中的异常值和缺失值, 提升数据质量。然后, 采用 VMD 对负荷数据进行分解, 并通过 SE 筛选重要模态重构信号以提取多尺度特征。最后, 结合 CNN 和 BiLSTM 模型, 构建混合深度学习框架, 捕捉负荷的局部特征和时序依赖关系以实现准确预测。实验结果表明, 该方法在多季节负荷预测中表现出较高的精度和鲁棒性, 显著优于传统方法, 为电动汽车充电负荷预测提供了有效解决方案。

**关键词:** 电动汽车; 充电负荷预测; VMD-SE; CNN-BiLSTM; 深度学习

## Short-term forecasting of electric vehicle charging load based on VMD-SE-CNN-BiLSTM

WU Fangquan<sup>1</sup>, LI Siqi<sup>1</sup>, HU Junhan<sup>1</sup>, TANG Chengjia<sup>1</sup>, ZOU Jianye<sup>2</sup>

(1. Information Communication Branch of Guizhou Power Grid Company, Guiyang 550003, China;

2. Beijing Kedong Electric Power Control System Co., Ltd., Beijing 100194, China)

**Abstract:** In recent years, with the rapid growth of electric vehicle (EV) ownership, accurate forecasting EV charging loads has become a crucial research topic for power grid planning and charging infrastructure optimization. To address the challenges of traditional forecasting methods in handling the complex nonlinear characteristics and dynamically coupled influencing factors in load data, this paper proposes a charging load forecasting model that integrates data preprocessing, variational mode decomposition-sample entropy (VMD-SE) data reconstruction, and a convolutional neural network-bidirectional long short-term memory (CNN-BiLSTM) deep learning framework. First, the Gaussian mixture model-K-nearest neighbor (GMM-KNN) method is utilized to detect and fill abnormal and missing values in the data, improving data quality. Next, VMD is employed to decompose the load data, and SE is applied to select and reconstruct important modal signals to extract multi-scale features. Finally, a hybrid deep learning framework combining CNN and BiLSTM models is constructed to capture local features and temporal dependencies for accurate forecasting. Experimental results demonstrate that the proposed method exhibits high accuracy and robustness in multi-season load forecasting, significantly outperforming traditional methods. This provides an effective solution for EV charging load forecasting.

This work is supported by the Science and Technology Project of China Southern Power Grid Co., Ltd. (No. 066700KC23100032).

**Key words:** EV; charging load forecasting; VMD-SE; CNN-BiLSTM; deep learning

## 0 引言

近年来, 随着环境保护意识的不断提升以及政

府对可再生能源的支持, 电动汽车(electric vehicle, EV)作为一种绿色、低碳的出行方式, 得到了广泛的应用<sup>[1-3]</sup>。根据中国汽车工业协会的数据, 电动汽车保有量呈现快速增长的趋势。到 2023 年底, 中国电动汽车保有量已突破 900 万辆, 预计在未来几年将继续保持较高的增长速度<sup>[4]</sup>。特别是在南方城市,

**基金项目:** 南方电网公司科技项目资助(066700KC23100032)  
“电动汽车有序充电需求响应潜力分析及优化运营技术”

由于气候条件适宜,电动汽车的推广与普及率较高,电动汽车充电设施的建设也迎来了快速发展。

随着电动汽车保有量的增加,充电需求也随之急剧上升。据统计,电动汽车的充电需求呈现出日间高峰、夜间低谷的典型特征,且充电负荷受天气、季节和交通等多重因素的影响<sup>[5-6]</sup>。如何准确预测电动汽车充电负荷,成为确保充电设施高效运行和电网稳定的重要课题。有效的负荷预测能够帮助运营商合理规划充电基础设施的建设、调度和维护,从而避免能源浪费和电力系统过载<sup>[7-9]</sup>。

然而,现有的电动汽车充电负荷预测方法多集中于基于传统时间序列分析或统计模型,如自回归积分滑动平均模型<sup>[10]</sup>、支持向量回归<sup>[11]</sup>和误差反向传播神经网络<sup>[12]</sup>等。文献[13]利用反向传播神经网络算法对电力负荷进行超短期预测,但文中没有对数据进行处理且没有结合其他方法,在处理异常值及复杂序列时效果较差。文献[14]提出结合基于密度的空间聚类应用与噪声-K均值(density-based spatial clustering of applications with noise-K-means, DBSCAN-K)异常值检测、随机森林缺失值填补和长短期记忆网络(long short-term memory network, LSTM)风电功率预测的方法,但存在异常值处理适应性有限、特征处理不充分、泛化性测试不足等问题。这些方法通常依赖于对负荷时间序列的线性假设或简单的统计关系建模,忽略了实际充电负荷数据中所体现的复杂非线性动态特征。此外,由于电动汽车充电负荷具有强烈的随机性、周期性以及易受天气、交通等多种外部因素影响的特性,这些方法在捕捉数据的非线性波动和长期依赖关系方面表现出明显的不足,导致预测精度下降<sup>[15]</sup>。

不仅如此,传统方法在应对高频波动、短期异常值以及季节性负荷变化时,往往无法进行有效建模。特别是当数据规模迅速扩大时,这些方法缺乏高效的数据处理能力和良好的泛化性能,难以满足实际应用中大规模数据快速预测的需求。此外,传统方法在多维特征融合建模上表现不足,导致其在多因素动态影响下的预测性能进一步受限<sup>[16-17]</sup>。近年来,深度学习技术在负荷预测领域得到了广泛应用,其优势在于能够高效处理非线性、非平稳的时间序列数据。此外,组合模型在负荷预测领域的应用得到了快速发展,这类模型通过结合多种深度学习算法的优势,在特征提取和时序建模方面表现出卓越性能<sup>[18]</sup>。文献[19]针对在多因素影响下电动汽车充电站充电负荷短期预测精度低的问题,提出一种基于改进麻雀搜索算法优化的卷积神经网络-门控循环单元混合模型的电动汽车充电负荷预测方

法,实验结果表明该方法具有更好的预测效果。由此可见,如何在复杂多变的充电负荷数据中提取关键特征,并构建能够同时捕捉局部模式和长期依赖关系的高效预测模型,成为现阶段充电负荷预测研究中的重要挑战。

因此本文提出了一种基于深度学习和数据分解的电动汽车充电负荷预测方法。首先,利用高斯混合模型(Gaussian mixture model, GMM)和K最近邻(K-nearest neighbor, KNN)方法对原始负荷数据进行预处理,通过GMM补充缺失值并检测异常值,然后用KNN方法进行填补从而提高数据质量;其次,采用变分模态分解(variational mode decomposition, VMD)-样本熵(sample entropy, SE)方法对数据进行分解与重构,将复杂的原始信号分解为若干固有模态函数(intrinsic mode function, IMF),并通过SE选择重要模态重构信号,提取负荷的多尺度特征;最后,结合卷积神经网络(convolutional neural network, CNN)和双向长短期记忆网络(bidirectional long short-term memory, BiLSTM)的深度学习框架,充分利用CNN的局部特征提取能力和BiLSTM的时间依赖关系建模能力,对充电负荷的动态变化进行高精度预测。与传统方法相比,该模型不仅在精度上有所提高,同时在处理大规模数据和长期依赖性方面表现出了更强的适应性。通过该模型能够实现电动汽车充电负荷的高效、准确预测,为电动汽车充电设施的运营和电网调度提供重要支持。

## 1 数据预处理

电动汽车充电负荷预测的准确性在很大程度上取决于数据的质量。为了提高模型的预测准确度,采用一种将GMM与KNN相结合的方法进行数据预处理。该方法能够有效处理数据中的异常值,并挖掘潜在的群体特征,为后续的建模与预测提供高质量的输入数据。

### 1.1 高斯混合模型拟合

GMM是一种概率模型,它假设数据是由多个高斯分布混合组成的。每个高斯分布都有一个均值、方差和权重参数,这些参数通过最大化似然函数进行优化<sup>[20]</sup>。GMM通过估计每个数据点的生成概率来为数据建模,可以有效地拟合复杂的实际数据分布,表达式如式(1)所示<sup>[21]</sup>。

$$p(x) = \sum_{k=1}^{K_g} \pi_k N(x | \mu_k, \Sigma_k) \quad (1)$$

式中: $p(x)$ 为数据点 $x$ 的概率密度; $K_g$ 为高斯分布的数量; $\pi_k$ 为第 $k$ 个高斯分布的权重; $N(x | \mu_k, \Sigma_k)$

为第  $k$  个高斯分布的概率密度函数;  $\mu_k$  和  $\Sigma_k$  分别为第  $k$  个高斯分布的均值和协方差矩阵。

通过估计这些参数, GMM 能够为充电负荷数据提供一个更精确的概率分布。

同时, 在实际充电负荷数据中, 可能会出现连续的零值, 通常表示设备停用或数据丢失。这些零值可能影响预测模型的准确性, 因此需要进行适当的补充。为了填补这些连续的零值, 可以使用 GMM 生成符合数据分布的值来替代零值。假设  $x_{zero}$  是一个零值点, 通过从 GMM 中抽取随机样本  $\tilde{x}$  来替代该零值, 如式(2)所示。

$$x_r = \tilde{x} \text{ where } \tilde{x} \sim N(x|\mu_k, \Sigma_k) \quad (2)$$

式中:  $x_r$  表示补充的数据。

此外, 本研究的异常值检测是通过计算每个数据点的概率密度来实现的。如果数据点的概率密度低于某一设定的阈值, 则该数据点被认为是异常值。在实际应用中, 通常选择一个较低的百分位数(如 0.1 百分位)作为阈值, 标记低于该阈值的数据点为异常值。

### 1.2 K 最近邻

KNN 方法通过计算数据点之间的距离来确定数据点的邻居, 并通过邻居的平均值来填补缺失值<sup>[22]</sup>。本文利用 KNN 方法寻找每个异常值的  $K_k$  个最近的正常值, 并用这些邻居的均值来替代异常值。表达式如式(3)所示。

$$x_r = \frac{1}{K_k} \sum_{k=1}^{K_k} x_k \quad (3)$$

式中:  $x_r$  为替换异常值的数据;  $x_k$  为异常值的邻近数据点, 并且这些邻近数据点均为正常数据点。

## 2 预测模型构建

在电动汽车充电负荷预测中, 由于负荷数据通常包含复杂的多尺度特征和不规则的波动, 因此需要对其进行有效的分解与重构, 以更好地提取数据的特征。同时, 电动汽车充电负荷数据通常具有强非线性及时序相关性, 传统的预测方法难以有效捕捉其复杂的动态特征。因此, 本文提出了一种基于 VMD-SE-CNN-BiLSTM 的预测模型, 以提高对电动汽车充电负荷的预测精度。

### 2.1 VMD 原理

VMD 是一种自适应的、完全非递归的信号处理方法。该方法具有一项显著优势, 即能够根据实际条件确定给定信号序列的模式分解数量, 从而体现出其良好的适应性。在后续的搜索和求解过程中, 自适应匹配每个模式的最优中心频率和有限带宽。它可以有效地分离 IFM, 在频域对信号进行划分,

从而得到给定信号的有效分解分量, 最终得到变分问题的最优解。VMD 的主要步骤如下<sup>[23]</sup>。

1) 将本征模态函数 IMF 变换为有限带宽的调幅调频信号  $u_k$ , 并以本征模态函数估计带宽的最小和作为分解约束。

$$\left\{ \begin{aligned} f &= \min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_{k=1}^{K_v} \left\| \partial_t \left[ (\delta(t) + \frac{j}{\pi t}) * u_k(t) \right] e^{-j\omega_k t} \right\|^2 \right\} \\ \sum_{k=1}^{K_v} u_k(t) &= x(t) \end{aligned} \right. \quad (4)$$

式中:  $f$  为本征模态函数;  $x(t)$  为原始序列;  $K_v$  为得到的模态分量的个数;  $\omega_k$  表示  $u_k$  的中心频率;  $\partial_t$  表示时间微分操作;  $\delta(t)$  为单位脉冲函数; “\*” 表示卷积运算。

2) 引入拉格朗日乘子  $\lambda(t)$  和二次惩罚项  $a$ , 将约束优化转化为无约束优化, 如式(5)所示。

$$\begin{aligned} L(\{u_k\}, \{\omega_k\}, \lambda) &= \\ a &\left\{ \sum_{k=1}^{K_v} \left\| \partial_t \left[ (\delta(t) + \frac{j}{\pi t}) * u_k(t) \right] e^{-j\omega_k t} \right\|^2 \right\} + \\ &\left\| f(t) - \sum_{k=1}^{K_v} u_k(t) \right\|_2^2 + \left\langle \lambda(t), f(t) - \sum_{k=1}^{K_v} u_k(t) \right\rangle \end{aligned} \quad (5)$$

3) 利用乘子交替方向法, 迭代更新  $u_k$ 、中心频率  $\omega_k$  和拉格朗日乘子  $\lambda(t)$ , 得到最优值, 分别如式(6)一式(8)所示。

$$u_k^{n+1}(\omega) = \frac{f(\omega) - \sum_{i \neq k} u_i(\omega) + \frac{\lambda(\omega)}{2}}{1 + 2a(\omega - \omega_k)^2} \quad (6)$$

$$\omega_k^{n+1} = \frac{\int_0^\infty \omega |u_k(\omega)|^2 d\omega}{\int_0^\infty |u_k(\omega)|^2 d\omega} \quad (7)$$

$$\lambda^{n+1}(\omega) = \lambda^n(\omega) + \tau [x(\omega) - \sum_{k=1}^{K_v} u_k^{n+1}(\omega)] \quad (8)$$

式中:  $u_k^{n+1}(\omega)$  为剩余分量  $[f(\omega) - \sum u_i(\omega)]$  的维纳滤波结果;  $\omega_k^{n+1}$  为模态函数的中心频率;  $\tau$  为更新因子。

4) 重复1)–3), 当  $\sum (\|u_k^{n+1} - u_k^n\| / \|u_k^n\|) < \varepsilon$  (其中  $\varepsilon$  为阈值)时停止迭代。

### 2.2 SE 原理

SE 是一种度量时间序列复杂度的方法, 它与近似熵具有相似的物理意义。这两个指标都是通过测量在信号中产生新模式的概率来衡量时间序列的复杂性。与近似熵相比, SE 具有两个优点: 1) SE 的计算与数据长度无关, 具有更好的一致性; 2) 利用信息论的原理对子部件进行处理, 不仅减少了计算时间, 而且突出了相似部件的特点。SE 的表达式如

式(9)所示<sup>[24]</sup>。

$$\text{Sampen}(m,r,n) = - \left[ \frac{A^m(r)}{B^m(r)} \right] \quad (9)$$

式中： $B^m(r)$ 、 $A^m(r)$ 分别表示两个序列之间在相似容差  $r$  内匹配  $m$  个点和  $m+1$  个点的概率； $n$  表示数据的个数。

对原始数据进行 VMD 分解后，得到多个 IMF。根据 SE 的分析结果，选择合适的 IMF 进行重构，以便更好地保留原始数据的特征和减少噪声。

在实际应用中，VMD 分解得到的模式可能包含较多低相关性或高噪声的成分，如果直接使用全部 IMF，可能会增加数据冗余和噪声干扰，反而降低预测性能。通过 SE 分析，可以筛选出包含主要信息且具有低复杂性的模式，剔除高噪声或无关模式，从而优化重构信号的质量。将 VMD 和 SE 结合，能够充分发挥两者的优势，VMD 提供多尺度分解能力，提取出数据的多频率特征，SE 进行模式筛选，剔除无用模式，提升重构信号的有效性和稳定性。这一联合方法不仅减少了模型训练数据中的噪声干扰，还能保留负荷信号中的主要特征，使后续预测模型能够更好地捕捉数据的动态变化。

### 2.3 CNN

卷积神经网络在处理时序数据时，通过卷积操作提取输入特征的局部信息。卷积操作能够有效地捕捉充电负荷的局部模式，如峰值和波动的频率。卷积操作的公式为<sup>[25]</sup>

$$y_i = \sum_{j=1}^F \omega_j x_{i+j-1} + b \quad (10)$$

式中： $y_i$ 为卷积后的输出； $\omega_j$ 为卷积核的权重； $F$ 为卷积核的大小； $x_{i+j-1}$ 为输入数据； $b$ 为偏置项。卷积层后接批归一化层和 ReLU 激活层，以便提高网络的训练效率和表达能力。

### 2.4 BiLSTM

传统 LSTM 是一种特殊的 RNN 结构，可避免梯度爆炸和梯度消失的发生，主要由输入门、遗忘门和输出门组成。遗忘门通过计算得到的  $f_t$  来决定上一个节点传进来的输入信息是保留还是丢弃，计算公式为<sup>[26]</sup>

$$f_t = \sigma(W_f h_{t-1} + U_f x_t + b_f) \quad (11)$$

式中： $f_t$ 为遗忘门的输出； $\sigma$ 为 Sigmoid 激活函数； $W_f$ 为遗忘门的权重矩阵； $h_{t-1}$ 为前一时刻的隐藏状态； $U_f$ 为遗忘门的循环权重； $x_t$ 为当前时刻的输入； $b_f$ 为遗忘门的偏置项。

输入门一是通过 tanh 激活函数输出  $a_t$ ，二是用 Sigmoid 函数将值控制在 0~1 之间并输出  $i_t$ ，并对当前时刻的记忆信息进行更新，计算公式为

$$\begin{cases} a_t = \tanh(W_a h_{t-1} + U_a x_t + b_a) \\ i_t = \sigma(W_i h_{t-1} + U_i x_t + b_i) \\ C_t = f_t \times c_{t-1} + i_t \times a_t \end{cases} \quad (12)$$

式中： $a_t$ 为注意力权重分布； $W_a$ 为注意力权重矩阵； $U_a$ 为注意力循环权重； $b_a$ 为注意力机制的偏置项； $i_t$ 为输入门的输出； $W_i$ 为输入门的权重矩阵； $U_i$ 为输入门的循环权重； $b_i$ 为输入门的偏置项； $C_t$ 为记忆单元状态； $c_{t-1}$ 为前一时刻记忆单元状态。

输出门用来控制当前时刻单元的输出状态，计算公式为

$$\begin{cases} h_t = O_t \times \tanh C_t \\ O_t = \sigma(W_o h_{t-1} + U_o x_t + b_o) \end{cases} \quad (13)$$

式中： $h_t$ 为当前时刻的隐藏状态； $O_t$ 为输出门的输出； $W_o$ 为输出门的权重矩阵； $U_o$ 为输出门的循环权重； $b_o$ 为输出门的偏置项。

双向长短期记忆网络用于捕捉时间序列的长期依赖关系，它由一个前向 LSTM 和一个反向 LSTM 叠加构成，可以同时考虑前向和后向的时间信息，能够更全面地了解负荷的时间动态变化。BiLSTM 的网络结构如图 1 所示。

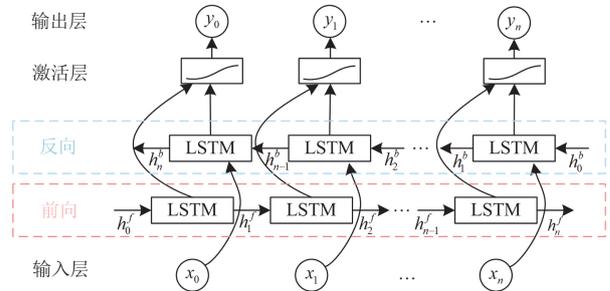


图 1 BiLSTM 网络结构

Fig. 1 BiLSTM network structure

结合 CNN 和 BiLSTM 的模型能够有效整合局部特征提取和全局时间依赖关系建模的优势，在捕捉复杂负荷波动和非线性变化方面表现突出，为电动汽车充电负荷的高精度预测提供了可靠支持。

### 2.5 模型评价指标

实验选取平均绝对误差(mean absolute error, MAE)、均方根误差(root mean square error, RMSE)和决定系数  $R^2$  对预测模型精度进行评估，各评价指标如式(14)~式(16)所示<sup>[27]</sup>。

$$e_{MA} = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (14)$$

$$e_{\text{RMS}} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (15)$$

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y}_i)^2} \quad (16)$$

式中:  $N$  为样本总数;  $y_i$  为实际值;  $\hat{y}_i$  为预测值;  $\bar{y}_i$  为实际值的均值。

这些指标在负荷预测领域中广泛应用, 能够全面衡量模型的预测性能。MAE 能够直观反映预测值与实际值之间的平均绝对偏差, RMSE 对较大误差更为敏感, 有助于捕捉极端情况, 从而在评估预测精度时起到互补作用。此外,  $R^2$  作为相对指标, 用于衡量模型对数据趋势的拟合程度, 能够实现对整个预测效果的直观衡量。

### 2.6 基于 VMD-SE-VNN-BiLSTM 的电动汽车充电负荷短期预测模型建立

本文采用 VMD 将充电负荷数据处理为多个稳定的模态分量, 并通过 SE 对这些分量进行重构, 以减少计算复杂度。之后, 将重构后的数据输入 CNN-BiLSTM 混合模型进行预测。所提组合模型的流程如图 2 所示, 具体步骤如下所述。

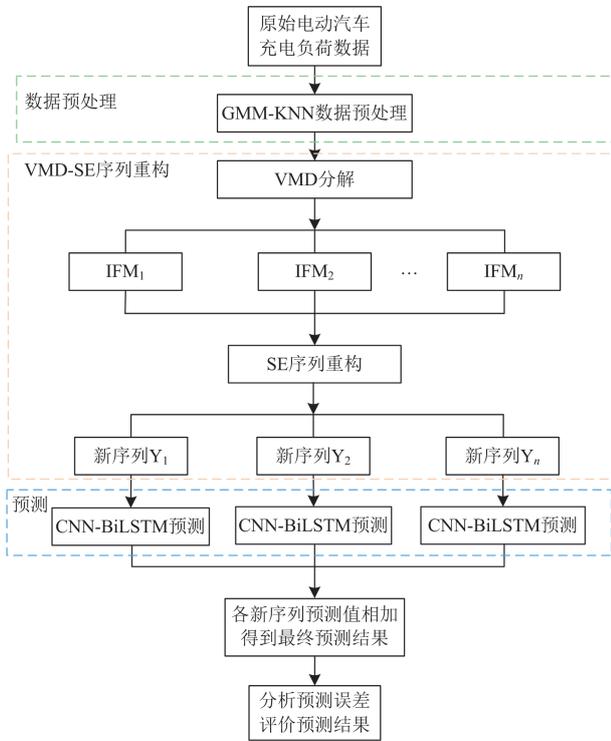


图 2 组合预测模型流程图

Fig. 2 Flow chart of combination prediction model

1) 利用 VMD 对原始充电负荷时间序列数据进行分解, 得到若干个 IMF, 这些 IMF 代表原始信号的不同频率成分。随后, 利用 SE 对相似熵值的子序列进行重构, 以确保保留关键信息的同时减少计算量。

2) 将重构后的数据输入 CNN 进行特征提取。CNN 的卷积层通过滑动窗口提取局部时序特征, 使得特征表示能够更好地反映局部数据变化趋势。然后, 通过 BiLSTM 捕捉充电负荷数据中的长期依赖关系和时间特征。

3) 最终使用全连接层将 BiLSTM 提取到的特征映射到目标空间, 并通过回归层输出预测的充电负荷值。

4) 使用 MAE、RMSE 以及  $R^2$  对模型误差进行评估。

### 3 仿真分析

本文使用中国南方某城市充电站电动汽车实际充电需求数据集<sup>[26]</sup>, 该数据集记录了 2022 年全年某南方核心城市一座电动汽车充电站的负荷信息, 时间范围为 2022 年 1 月 1 日至 12 月 31 日, 覆盖 4 个季节的数据。数据采集间隔为 15 min, 每天记录 96 个时间点, 共计约 35 040 条记录。

#### 3.1 数据预处理结果

本节使用高斯混合模型对充电负荷数据进行拟合, 以补充数据中的缺失值, 并通过计算数据的概率密度函数检测出低于设定阈值的异常值。这些异常值被认为是噪声数据。图 3 明确展示了原始数据中的异常点及其分布情况, 检测出的异常值通过 KNN 方法进行补充, 使用与异常点距离最近的正常数据点来估算异常值的替代值。通过 GMM-KNN 处理后, 数据的平稳性和可解释性明显提高, 为后续的特征提取和建模提供了可靠的数据基础。

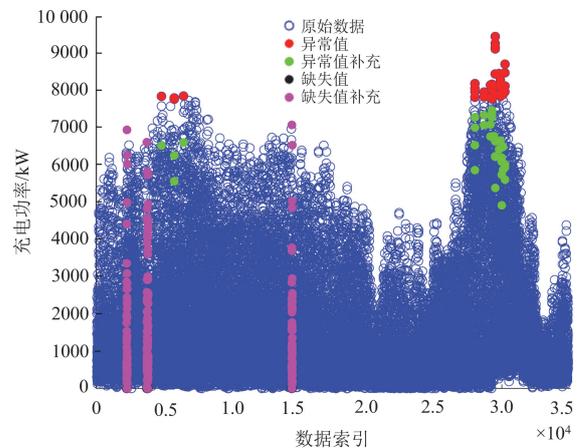


图 3 数据预处理结果

Fig. 3 Data preprocessing results

### 3.2 序列重构结果

本节使用 VMD 方法将预处理后的数据分解为 6 个具有不同频率特征的 IMF。图 4 展示了每个 IMF 的时间序列图，以便分析不同频段的特征。接着对每个 IMF 进行 SE 计算，用以评估模态的复杂性和规律性。SE 越高，表示信号的随机性越强。根据 SE 的大小将选择后的 IMF 进行重构，生成用于建模的特征数据。图 5 及表 1 展示了通过 SE 的序列复杂度分析，将 SE 相近(差值不超过 0.1)的分量划为一组进行叠加。

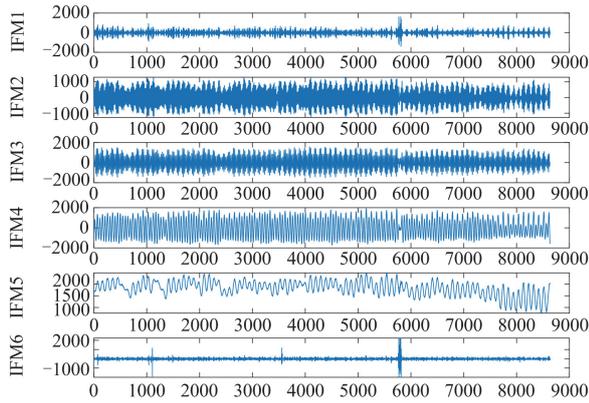


图 4 VMD 序列分解结果

Fig. 4 VMD sequence decomposition results

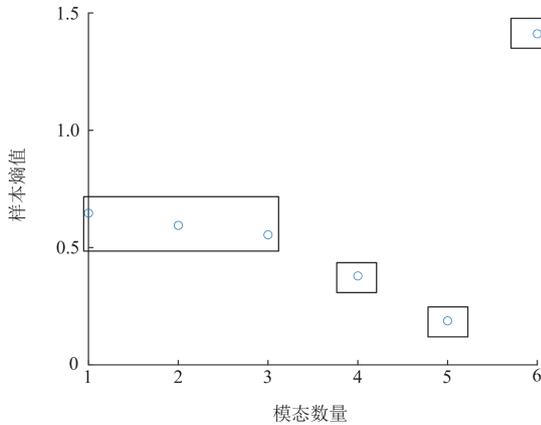


图 5 SE 序列复杂度分析

Fig. 5 SE sequence complexity analysis

表 1 各分量序列 SE 值

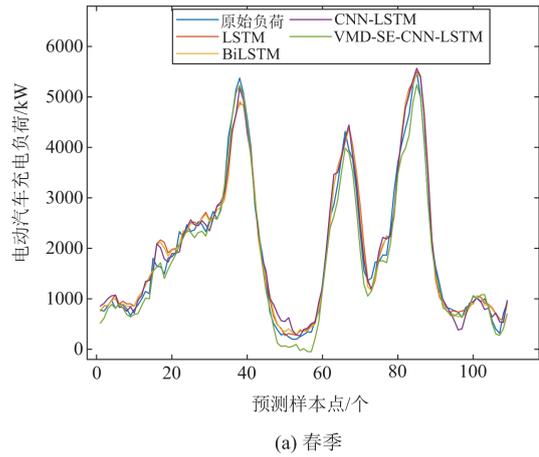
Table 1 SE values of each component sequence

固有模态函数	SE 值
IFM1	0.6468
IFM2	0.5947
IFM3	0.5545
IFM4	0.3793
IFM5	0.1880
IFM6	1.4113

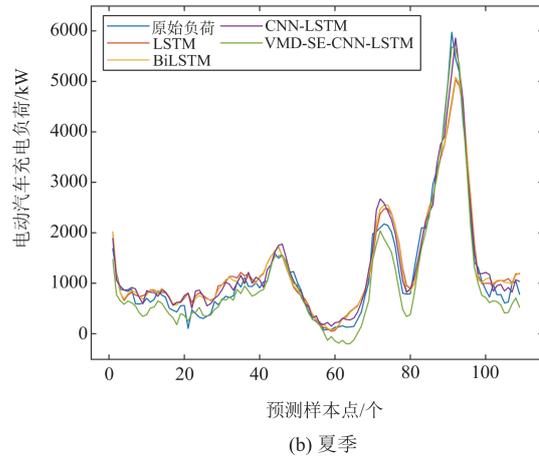
### 3.3 预测结果及对比分析

对 3.2 节中重构后的分量分别进行预测，再将预测结果相加得到最终预测结果。为全面评估各模型的预测性能，对春季、夏季、秋季和冬季 4 个季节的预测结果和预测误差进行分析。4 种模型不同季节的预测结果和预测误差如图 6 和表 2 所示。

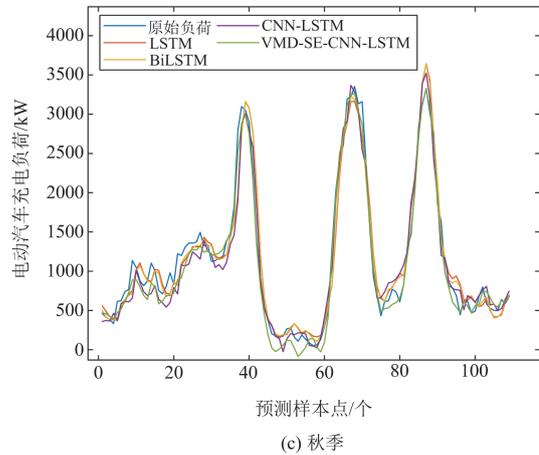
从表 2 可以看出，随着模型复杂度的增加，预测精度逐步提高，3 种评价指标在不同季节和模型



(a) 春季



(b) 夏季



(c) 秋季

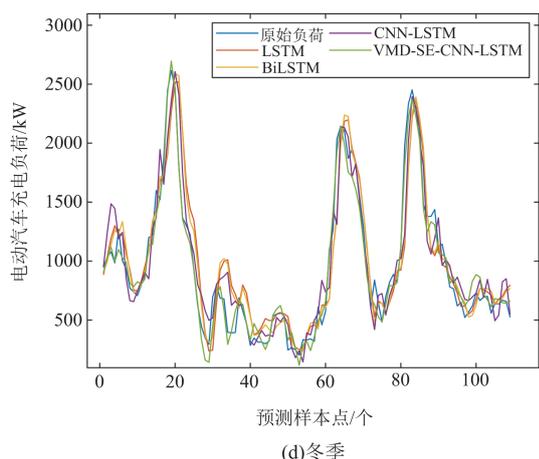


图 6 4 种模型不同季节预测结果

Fig. 6 Four models prediction results for different seasons

表 2 4 种模型不同季节的预测误差

Table 2 Prediction errors of four models in different seasons

季节	模型	MAE/kW	RMSE/kW	$R^2$
春季	LSTM	195.457	256.741	0.968
	BiLSTM	190.518	246.132	0.970
	CNN-BiLSTM	183.338	228.523	0.974
	VMD-SE-CNN-BiLSTM	<b>153.196</b>	<b>189.365</b>	<b>0.982</b>
夏季	LSTM	228.516	302.580	0.932
	BiLSTM	222.842	292.869	0.937
	CNN-BiLSTM	193.512	242.563	0.957
	VMD-SE-CNN-BiLSTM	<b>188.717</b>	<b>227.677</b>	<b>0.962</b>
秋季	LSTM	164.618	221.841	0.939
	BiLSTM	154.126	214.210	0.943
	CNN-BiLSTM	150.765	212.647	0.944
	VMD-SE-CNN-BiLSTM	<b>108.717</b>	<b>131.678</b>	<b>0.979</b>
冬季	LSTM	176.986	247.501	0.829
	BiLSTM	173.819	239.821	0.839
	CNN-BiLSTM	161.477	218.856	0.866
	VMD-SE-CNN-BiLSTM	<b>76.064</b>	<b>96.239</b>	<b>0.974</b>

中的表现展现了模型性能的差异性和趋势性。在所有季节中, MAE 和 RMSE 均呈现出由 LSTM、BiLSTM、CNN-BiLSTM 到 VMD-SE-CNN-BiLSTM 依次降低的趋势, 表明后续模型的改进在捕捉负荷变化方面更加精确。例如, 春季中 MAE 从 LSTM 的 195.457 kW 下降到 VMD-SE-CNN-BiLSTM 的 153.196 kW, RMSE 从 256.741 kW 下降到 189.365 kW, 体现出改进后的模型在春季负荷变化较为平稳的情况下表现尤为突出; 而夏季 MAE 和 RMSE 的改进幅度同样显著, VMD-SE-CNN-BiLSTM 的 MAE 和 RMSE 分别为 188.717 kW 和 227.677 kW, 相较于 LSTM 分别降低了 17.4% 和 24.7%, 证明了 VMD-SE 数据重构对非平稳负荷数据处理的有效性。秋季和冬季负荷数据的复杂性相

对较高, 对模型的特征提取和时序依赖关系捕捉能力提出了更高要求。在秋季, VMD-SE-CNN-BiLSTM 的 MAE 为 108.717 kW, 远低于其他模型, 同时 RMSE 为 131.678 kW, 显著优于 CNN-BiLSTM 的 212.647 kW; 而冬季, VMD-SE-CNN-BiLSTM 的 MAE 和 RMSE 分别为 76.064 kW 和 96.239 kW, 相较于 LSTM 的 176.986 kW 和 247.501 kW, 分别降低了约 57% 和 61%, 进一步验证了该模型在应对复杂负荷波动时的强鲁棒性。此外, 从  $R^2$  指标来看, VMD-SE-CNN-BiLSTM 的  $R^2$  在所有季节均达到最高值, 春季为 0.982, 夏季为 0.962, 秋季为 0.979, 冬季为 0.974, 表明其对负荷趋势的拟合能力在各个季节均表现卓越。

综合来看, 3 种指标的变化趋势反映了模型性能的逐步优化。LSTM 和 BiLSTM 在捕捉负荷整体趋势上表现良好, 但对负荷波动的精确预测有限; CNN-BiLSTM 引入卷积层后, 显著改善了特征提取能力, 尤其是在秋季和冬季; VMD-SE-CNN-BiLSTM 通过分解、特征选择和深度学习模型的结合, 进一步提升了对于复杂负荷动态的捕捉能力, 表现出最低的误差和最高的拟合度。这表明该方法在应对季节性负荷波动时具有明显优势, 为电动汽车充电负荷的短期预测提供了强有力的技术支持。但该模型在应对春季、夏季的高峰负荷和充电需求显著波动时误差相对较大, 显示出对极端负荷处理能力的局限性。此外, 该模型主要依赖历史负荷数据, 未充分考虑外部因素(如用户行为模式、政策变化等)的动态影响, 可能限制其在更复杂场景中的应用。

## 4 结论

本文提出了一种基于 GMM-KNN 数据预处理、VMD-SE 数据重构和 CNN-BiLSTM 深度学习框架的电动汽车充电负荷短期预测方法。该方法通过 GMM 模型补充缺失值并检测异常值, 结合 KNN 方法进行填补, 显著提升了数据的完整性和可靠性; 采用 VMD-SE 方法对充电负荷数据进行分解和重构, 成功提取了多尺度特征; 利用 CNN-BiLSTM 模型充分捕捉负荷的局部特征和时间依赖关系, 实现了对充电负荷的高精度预测。实验结果表明, 所提预测方法在各个季节的负荷预测中均表现出较高的精度和鲁棒性。与传统模型相比, VMD-SE-CNN-BiLSTM 模型在 MAE、RMSE 和  $R^2$  等指标上表现最优, 在复杂的非平稳负荷数据和季节性波动场景下具有显著优势。未来的研究可以聚焦在以下几点:

1) 鉴于充电负荷预测中长期趋势分析的重要性, 未来研究可以结合贝叶斯深度学习或概率图模

型, 量化预测中的不确定性, 得到更加可靠的长期负荷预测结果;

2) 进一步结合更多影响电动汽车充电负荷的外部因素(如用户行为模式、充电站的地理分布特征、政策导向等), 并探索分场景优化的预测方法, 构建多因素协同预测模型, 从而提升模型对复杂动态环境和实际应用的适应性。

### 参考文献

- [1] 周原冰, 龚乃玮, 王皓界, 等. 中国电动汽车发展及车网互动对新型储能配置的影响[J]. 中国电力, 2024, 57(10): 1-11.  
ZHOU Yuanbing, GONG Naiwei, WANG Haojie, et al. Study on the influence of electric vehicle development and the vehicle-grid interaction on new energy storage configuration in China[J]. Electric Power, 2024, 57(10): 1-11.
- [2] 张琳娟, 周志恒, 陈婧华, 等. 含电动汽车的县域光伏台区储能容量优化配置研究[J]. 供用电, 2024, 41(10): 101-113.  
ZHANG Linjuan, ZHOU Zhiheng, CHEN Jinghua, et al. Research on optimal allocation of energy storage capacity in county photovoltaic distribution station area with electric vehicles[J]. Distribution & Utilization, 2024, 41(10): 101-113.
- [3] 袁洪涛, 徐潇源, 严正, 等. 电动汽车集中充换电设施规划和优化运行研究综述[J]. 电力系统保护与控制, 2024, 52(19): 157-174.  
YUAN Hongtao, XU Xiaoyuan, YAN Zheng, et al. Review of centralized EV charging and battery swapping facility planning and optimal scheduling[J]. Power System Protection and Control, 2024, 52(19): 157-174.
- [4] 于梦桐, 高辉, 杨凤坤. 计及电动汽车保有量增长需求的充电负荷预测[J]. 现代电子技术, 2024, 47(6): 55-62.  
YU Mengtong, GAO Hui, YANG Fengkun. Charging load forecasting considering growth demand for electric vehicle ownership[J]. Modern Electronics Technique, 2024, 47(6): 55-62.
- [5] 朱永胜, 常稳, 武东亚, 等. 考虑充放储一体站与电动汽车互动的主从博弈优化调度策略[J]. 电力系统保护与控制, 2024, 52(7): 157-167.  
ZHU Yongsheng, CHANG Wen, WU Dongya, et al. A Stackelberg game optimization scheduling strategy considering the interaction between a charging-discharging-storage integrated station and an electric vehicle[J]. Power System Protection and Control, 2024, 52(7): 157-167.
- [6] 张夏韦, 梁军, 王要强, 等. 电动汽车充电负荷时空分布预测研究综述[J]. 电力建设, 2023, 44(12): 161-173.  
ZHANG Xiawei, LIANG Jun, WANG Yaoqiang, et al. Overview of research on spatiotemporal distribution prediction of electric vehicle charging[J]. Electric Power Construction, 2023, 44(12): 161-173.
- [7] 秦建华, 潘崇超, 张璇, 等. 基于充电行为分析的电动汽车充电负荷预测[J]. 电测与仪表, 2023, 60(4): 19-26.  
QIN Jianhua, PAN Chongchao, ZHANG Xuan, et al. Charging load forecast of electric vehicle based on analysis of charging behavior[J]. Electrical Measurement & Instrumentation, 2023, 60(4): 19-26.
- [8] 丁乐言, 柯松, 张帆, 等. 考虑出行需求和引导策略的电动汽车充电负荷预测[J]. 电力建设, 2024, 45(6): 10-26.  
DING Leyan, KE Song, ZHANG Fan, et al. Forecasting of electric-vehicle charging load considering travel demand and guidance strategy[J]. Electric Power Construction, 2024, 45(6): 10-26.
- [9] 张延宇, 张智铭, 刘春阳, 等. 基于动态自适应图神经网络的电动汽车充电负荷预测[J]. 电力系统自动化, 2024, 48(7): 86-93.  
ZHANG Yanyu, ZHANG Zhiming, LIU Chunyang, et al. Electric vehicle charging load prediction based on dynamic adaptive graph neural network[J]. Automation of Electric Power Systems, 2024, 48(7): 86-93.
- [10] 冯剑, 姚罕琦, 黄啸虎, 等. ARIMA 算法在工业控制器故障预测的应用[J]. 自动化仪表, 2022, 43(11): 62-67.  
FENG Jian, YAO Hanqi, HUANG Xiaohu, et al. Application of ARIMA algorithm to industrial controller fault prediction[J]. Process Automation Instrumentation, 2022, 43(11): 62-67.
- [11] 付昊, 戴健, 高兴, 等. 基于支持向量回归的发电机温度预测方法[J]. 电机技术, 2024(2): 46-48.  
FU Hao, DAI Jian, GAO Xing, et al. Generator temperature prediction method based on the support vector regression[J]. Electrical Machinery Technology, 2024(2): 46-48.
- [12] 吴青峰, 杨艺涛, 刘立群, 等. 基于 GA-SA-BP 神经网络的锂电池健康状态估算方法[J]. 电力系统保护与控制, 2024, 52(19): 74-84.  
WU Qingfeng, YANG Yitao, LIU Liqun, et al. Lithium battery state of health estimation method based on a GA-SA-BP neural network[J]. Power System Protection and Control, 2024, 52(19): 74-84.
- [13] 张晋轩. 基于 BP 神经网络电力负荷预测[J]. 中国高新技术, 2024(18): 78-79.  
ZHANG Jinxuan. Power load prediction based on BP neural network[J]. China High and New Technology, 2024(18): 78-79.

- [14] 潘鹏程, 刘晖, 王仁明. 自适应密度聚类组合数据清洗的 LSTM 风电功率预测[J]. 电力系统及其自动化学报, 2024, 36(7): 59-66.  
PAN Pengcheng, LIU Hui, WANG Renming. LSTM wind power prediction based on combined data cleansing algorithm of selfadaptive DBSCAN and K-means clustering[J]. Proceedings of the CSU-EPSA, 2024, 36(7): 59-66.
- [15] 顾玮, 段敬, 张栋, 等. 基于数据与模型联合驱动的电动汽车充电负荷时空分布预测[J]. 计算机科学, 2024, 51(增刊 2): 1032-1037.  
GU Wei, DUAN Jing, ZHANG Dong, et al. Prediction of spatial and temporal distribution of electric vehicle charging loads based on joint data and modeling drive[J]. Computer Science, 2024, 51(S2): 1032-1037.
- [16] 吴军英, 路欣, 刘宏, 等. 基于 Spearman-GCN-GRU 模型的超短期多区域电力负荷预测[J]. 中国电力, 2024, 57(6): 131-140.  
WU Junying, LU Xin, LIU Hong, et al. Ultra-short-term multi-region power load forecasting based on Spearman-GCN-GRU model[J]. Electric Power, 2024, 57(6): 131-140.
- [17] 周思思, 李勇, 郭钊秀, 等. 考虑时序特征提取与双重注意力融合的 TCN 超短期负荷预测[J]. 电力系统自动化, 2023, 47(18): 193-205.  
ZHOU Sisi, LI Yong, GUO Yixiu, et al. Ultra-short-term load forecasting based on temporal convolutional network considering temporal feature extraction and dual attention fusion[J]. Automation of Electric Power Systems, 2023, 47(18): 193-205.
- [18] XIA S, ZHANG C, LI Y, et al. GCN-LSTM based transient angle stability assessment method for future power systems considering spatial-temporal disturbance response characteristics[J]. Protection and Control of Modern Power Systems, 2024, 9(6): 108-121.
- [19] 姚芳, 汤俊豪, 陈盛华, 等. 基于 ISSA-CNN-GRU 模型的电动汽车充电负荷预测方法[J]. 电力系统保护与控制, 2023, 51(16): 158-167.  
YAO Fang, TANG Junhao, CHEN Shenghua, et al. Charging load prediction method for electric vehicles based on an ISSA-CNN-GRU model[J]. Power System Protection and Control, 2023, 51(16): 158-167.
- [20] 黄杰忠, 杨健, 李东升. 环境影响下基于模糊 C 均值聚类和高斯混合模型的隐式损伤识别方法[J/OL]. 振动工程学报: 1-12[2024-12-09]. <http://kns.cnki.net/kcms/detail/32.1349.TB.20241029.0932.002.html>  
HUANG Jiezhou, YANG Jian, LI Dongsheng. Implicit damage identification method based on fuzzy C-means clustering and Gaussian mixture model under changing environments[J]. Journal of Vibration Engineering: 1-12 [2024-12-09]. <http://kns.cnki.net/kcms/detail/32.1349.TB.20241029.0932.002.html>
- [21] LI Chuang, SUN Li, LIU Zhaoqi, et al. Structural damage identification and experiment based on FBG sensors and PCA-KNN approach[J]. Optical Fiber Technology, 2025, 89.
- [22] XUE Haiteng, WANG Gongda, LI Xijian, et al. Predictive combination model for CH<sub>4</sub> separation and CO<sub>2</sub> sequestration with CO<sub>2</sub> injection into coal seams: VMD-STA-BiLSTM-ELM hybrid neural network modeling[J]. Energy, 2024, 313.
- [23] 袁耀, 黄克捷, 陈建兴, 等. 基于 WSO-VMD 样本熵和 SSA-SVM 算法的有载分接开关故障诊断方法研究[J]. 西南大学学报(自然科学版), 2024, 46(11): 203-216.  
YUAN Yao, HUANG Kejie, CHEN Jianxing, et al. Fault diagnosis method of OLTC based on WSO-VMD sample entropy and SSA-SVM[J]. Journal of Southwest University (Natural Science Edition), 2024, 46(11): 203-216.
- [24] BASHIR T, WANG Huifang, TAHIR M, et al. Wind and solar power forecasting based on hybrid CNN-ABiLSTM, CNN-transformer-MLP models[J]. Renewable Energy, 2025, 239.
- [25] PAN Mingzhang, FU Changcheng, CAO Xinxin, et al. An energy management strategy for fuel cell hybrid electric vehicle based on HHO-BiLSTM-TCN-self attention speed prediction[J]. Energy, 2024, 307.
- [26] 彭曙蓉, 陈慧霞, 孙万通, 等. 基于改进 LSTM 的光伏发电功率预测方法研究[J]. 太阳能学报, 2024, 45(11): 296-302.  
PENG Shurong, CHEN Huixia, SUN Wantong, et al. Research on photovoltaic power prediction method based on improved LSTM[J]. Acta Energetica Solaris Sinica, 2024, 45(11): 296-302.
- [27] CAO Tingwei, XU Yinliang, LIU Guowei, et al. Feature-enhanced deep learning method for electric vehicle charging demand probabilistic forecasting of charging station[J]. Applied Energy, 2024, 371.

收稿日期: 2024-12-20; 修回日期: 2025-02-19

作者简介:

吴方权(1986—), 男, 工程师, 研究方向为电力信息技术; E-mail: wufq@gz.csg

李斯琦(2000—), 女, 工程师, 研究方向为电力信息技术; E-mail: 761217461@qq.com

邹建业(1990—), 男, 通信作者, 工程师, 研究方向为电力市场。E-mail: 1677804641@qq.com

(编辑 魏小丽)