

DOI:10.19651/j.cnki.emt.2519599

## 基于改进 VMD-TCN-LSTM 的电动汽车短期负荷预测\*

花妍<sup>1,2</sup> 李鹏<sup>1,2</sup> 闫冬<sup>1,2</sup> 张翔凯<sup>1,2</sup>

(1.南京信息工程大学电子与信息工程学院 南京 210044; 2.南京信息工程大学江苏省气象探测与信息处理重点实验室 南京 210044)

**摘要:** 针对大规模电动汽车接入电网引发负荷波动的问题,电动汽车充电负荷预测可为电力调度决策提供关键支撑。为进一步保障电网运行的稳定性与可靠性,提出一种电动汽车短期充电负荷预测新方法,旨在提升负荷预测的精准度。首先,运用变分模态分解(VMD)将历史负荷数据拆解为多个子分量,将各子分量连同温度信息输入至多个(TCN-LSTM)分支中进行特征提取与学习,降低电动汽车负荷序列的复杂度。其次,构建双阶段注意力机制改进长短期记忆网络(LSTM)结构,实现负荷特征维度与时序维度的协同融合,从而提升对复杂负荷模式的捕捉能力。最后,提出时间转换预测模块经全连接层对预测结果进行加权整合,进一步提升模型预测精度,降低预测误差。在绍兴某社区实际电动汽车充电桩充电负荷数据集上进行算例分析。实验结果显示,所提方法在均方误差(MSE)、平均绝对误差(MAE)、和 $R^2$ 性能指标上分别提升68%、60%、4%,表明该模型具有较好的预测效果。

**关键词:** 负荷预测;电动汽车;时间卷积网络;长短期记忆网络;注意力机制

**中图分类号:** TM715;TN-9 **文献标识码:** A **国家标准学科分类代码:** 470.40

## Short-term load forecasting of electric vehicles based on improved VMD-TCN-LSTM

Hua Yan<sup>1,2</sup> Li Peng<sup>1,2</sup> Yan Dong<sup>1,2</sup> Zhang Xiangkai<sup>1,2</sup>

(1. School of Electronics and Information Engineering, Nanjing University of Information Science and Technology, Nanjing 210044, China; 2. Jiangsu Key Laboratory of Meteorological Observation and Information Processing, Nanjing University of Information Science and Technology, Nanjing 210044, China)

**Abstract:** Electric vehicle charging load forecasting supports power dispatch decisions by addressing load fluctuations from widespread EV grid integration. A new method for predicting short-term EV charging loads is proposed to enhance power grid stability and reliability by improving load forecasting accuracy. First, historical load data is decomposed into subcomponents using VMD, then combined with temperature data and input into multiple TCN-LSTM branches for feature extraction, simplifying EV load sequence complexity. Secondly, a two-stage attention mechanism enhances the LSTM structure, improving load characteristic capture at specific times and feature dimension fusion, boosting complex load pattern recognition. Finally, a time conversion prediction module integrates results via a fully connected layer to enhance prediction accuracy and reduce errors. Case study analyzes real EV charging station load data from a Shaoxing community. Experimental results show the proposed method reduces MSE by 68%, MAE by 60%, and improves the performance index by 4%, demonstrating strong predictive performance.

**Keywords:** load forecasting; electric vehicles; temporal convolutional network; long short-term memory network attention mechanism

## 0 引言

近年来,我国电动汽车(electric vehicle, EV)产业蓬勃

发展,2023年末其保有量迅速增加至2 041万辆<sup>[1-2]</sup>,充电基础设施累计数量达到886万台。面对当前环境污染和能源问题带来的严峻挑战,电动汽车作为绿色清洁能源,成为

收稿日期:2025-08-14

\* 基金项目:国家自然科学基金项目(41075115)、江苏省重点研发计划社会发展项目(BE2015692)、无锡市社会发展科技示范工程项目(N20191008)资助

交通发展大势<sup>[3]</sup>。然而,电动汽车随机充电行为使得充电负荷模式非常不稳定,电动汽车大规模接入电网会导致电网出现用电高峰期,无序地接入电网会致电网的稳定性降低,导致电网系统的线路损耗,电能质量下降和电网控制难度增加等问题<sup>[4]</sup>。因此,构建高精度的电动汽车充电负荷预测模型,对于电力系统的稳定运行和科学规划以及电网实时调度至关重要。高精度预测不仅能支撑电网调度中的负荷平衡和资源优化,还可促进新能源消纳通过风光发电的灵活协调,并通过需求响应机制引导用户响应峰谷电价,实现削峰填谷和系统稳定性提升。

目前,国内外学者在电动汽车负荷预测领域开展了大量研究,主要包括两种方法:统计方法<sup>[5]</sup>和人工智能技术。统计方法主要有指数平滑法<sup>[6]</sup>、回归分析法(autoregressive integrated moving average model, ARIMA)<sup>[7]</sup>、Holt-Winters<sup>[8]</sup>模型及其他衍生技术<sup>[9]</sup>。这些方法通过对运行数据进行分析,拟合出电动汽车充电行为的概率分布,从而揭示其时间分布特性。虽然该方法实现步骤简单,但是对于非平稳性、非线性和强波动性数据,其预测的精度较低。

深度学习的兴起,为复杂非线性时间序列的建模与预测开辟了全新的理论框架与技术路径。常用的基于深度学习的预测方法主要有长短时记忆网络<sup>[10]</sup>(long short-term memory, LSTM)、双向长短时记忆网络<sup>[11]</sup>、门控循环单元<sup>[12-13]</sup>(gated recurrent unit, GRU)和时间卷积网络<sup>[14]</sup>(temporal convolutional network, TCN)等。随着系统、负荷、环境因素的复杂,单一预测方式无法充分捕捉负荷特征,学者们尝试各种组合方式。赵星宇等<sup>[15]</sup>提出 TCN-LSTM 组合网络强化特征提取;王可睿等<sup>[16]</sup>构建 LSTM-TCN-Attention 框架并引入 Time2Vec 编码;吴小涛等<sup>[17]</sup>则通过卷积神经网络(convolutional neural network, CNN)与双向长短时记忆网络增强空间特征分析;史含笑等<sup>[18]</sup>进一步融合长短期记忆网络与注意力机制提升预测精度。尽管上述方法通过组合网络提升了特征捕获能力,但其对电动汽车负荷在时空维度上的协同演化机理缺乏显

式建模,难以充分解析其非线性和非平稳现象,导致在复杂运行场景下的预测精度仍受制约。

鉴于现有研究普遍忽视充电负荷在时空维度上的耦合演化特征,导致预测精度受限。为了提高电动汽车负荷预测的准确性,针对现有方法未能有效建模负荷数据在时间和特征维度上的动态变化规律,难以准确刻画其非线性与非平稳特征,做出以下改进:

1)引入变分模态分解(variational mode decomposition, VMD)进行负荷数据预处理。针对电动汽车负荷序列受多种因素影响、波动性强、非平稳性显著的问题,采用 VMD 算法将原始负荷信号分解为多个具有不同频率特征的分量,有效降低原始序列的复杂度与噪声干扰。每个子分量携带不同频段的信息,便于后续模型充分挖掘负荷时序特征,提升预测稳定性与准确性。

2)构建双阶段注意力机制,在 LSTM 框架内并行嵌入特征与时间双阶段注意力机制:前者以可学习权重动态量化各输入特征对负荷波动的边际贡献,后者则在长程时序依赖中自适应聚焦关键时间节点的隐状态表征,从而精确刻画其在时域与特征域中的动态演变特性。

3)提出时间转换预测模块以优化最终预测输出。在得到 TCN-LSTM 模型输出后,提出时间转换预测模块对不同时间段的预测结果进行进一步校正与融合。通过捕捉电动汽车负荷在不同时间窗口的演化规律,借助全连接层将多时段预测值进行非线性加权组合,准确刻画其非线性与非平稳特征,提高模型对未来负荷变化趋势的刻画能力,显著降低整体预测误差。

## 1 VMD-TCN-LSTM 模型

### 1.1 改进 VMD-TCN-LSTM 预测模型

改进的 VMD-TCN-LSTM 模型如图 1 所示,原始负荷序列先经 VMD 分解,各子分量依次通过 TCN 残差块提取局部时序特征后,输入双阶段注意力机制改进 LSTM 模块完成深度建模;所得预测值再与时间转换预测模块非线性融合,输出最终预测结果。

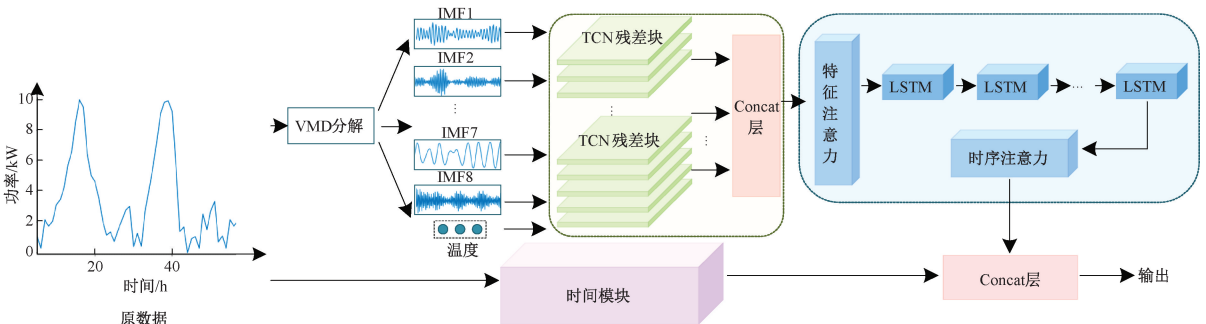


图 1 VMD-TCN-LSTM 模型结构

Fig. 1 VMD-TCN-LSTM model structure

## 1.2 VMD 分解

变分模态分解(VMD)<sup>[19]</sup>通过变分优化,直接从原始信号中提取本征模态分量,不依赖噪声的添加,从而减少了噪声对结果的干扰。该算法通过变分优化技术,将一个复杂信号分解成多个频率带宽较窄的本征模态函数(intrinsic mode functions, IMFs),每个模态分量对应信号在某个频段的振荡模式,其目标是通过信号进行局部频率划分,得到更清晰、准确的频域表示。具体步骤为:

- 1) 初始化参数,包括原始信号、模态数(K)、正则化参数( $\alpha$ )等;
- 2) 通过频率中心的平移和幅度调节,将信号从时域转换到频域;
- 3) 对于每个模态分量,利用变分原理计算出其频域表示,目标是使每个模态分量的频率带宽尽可能窄,从而避免不同模态成分间的重叠;
- 4) 根据优化结果调整模态分量的频率分布,确保每个模态的频率范围与信号的特征相匹配;
- 5) 通过对所有模态分量的重构,获得最终的分解结果。

VMD 算法通过将信号分解为具有不同频率带宽的本征模态函数(IMF),从而去除噪声。VMD 通过引入拉普拉斯算子和惩罚项,确保每个模态具备良好的频谱特性,并避免模态之间的重叠,其约束变分模型表达式如式(1)所示。

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

式中:  $u_k$  为分解出来的每个本征模态分量,  $\omega_k$  为每个本征模态分量的中心频率。  $k$  为模态数,  $f(t)$  为原始信号,  $\partial_t$  为信号变化率,  $*$  代表卷积。

## 1.3 TCN 模块

TCN<sup>[20]</sup>是一种专为序列数据处理设计的卷积架构,在时间序列预测任务中表现出显著优势。其核心在于采用膨胀卷积结构,通过指数级扩展膨胀因子形成层级空洞结构,有效扩展模型感受野以捕获长程时序依赖。特征提取过程可形式化表示为:

$$h_t = \text{ReLU}(W_t *_{d} x + b_t) \quad (2)$$

式中:  $*_{d}$  表示膨胀率为  $d$  的卷积操作;  $W_t$  和  $b_t$  分别为卷积核参数与偏置项。如图 2 所示,各卷积层输出经 ReLU 非线性激活与 Dropout 正则化处理后,生成具有时序不变性的高阶特征,为后续 LSTM 建模提供优化的特征空间。该架构通过局部特征提取与全局依赖建模的协同作用,显著提升了复杂时序模式的表征能力。

## 1.4 LSTM 模块

TCN 残差块输出的全局特征经特征注意力机制后,输入到单向 LSTM<sup>[21]</sup>进行时动态精炼,通过三重门控机制实现特征优化。单向 LSTM 通过门控滤波对时空特征矩阵

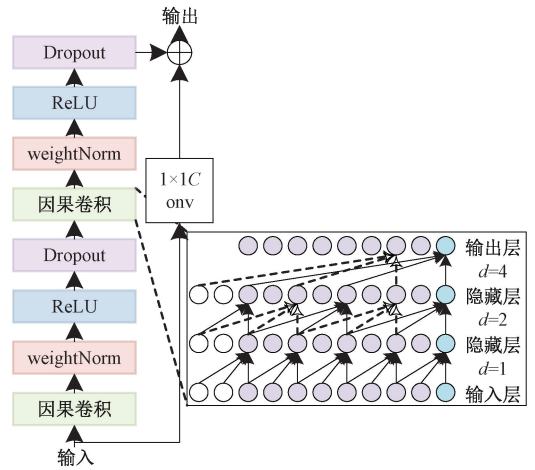


图 2 TCN 结构

Fig. 2 TCN structure

进行定向提纯,重点强化从  $t-1 \sim t$  时刻的正向状态转移建模其数学表达为:

$$h_t = \text{LSTM}(h_{t-1}, x_t | \Theta) \quad (3)$$

式中:  $\Theta$  包含门控权重参数。这种时序聚焦机制使模型更契合负荷预测的因果约束,通过构建严格的时间前向传播链,提升预测任务的时序一致性。

TCN 残差块输出的全局时空特征经单向 LSTM 进行时序动态精炼,其门控计算体系可形式化表述为:

$$i_t = \sigma(W_i[x_t, h_{t-1}] + b_i) \quad (4)$$

$$f_t = \sigma(W_f[x_t, h_{t-1}] + b_f) \quad (5)$$

$$\tilde{C}_t = \tanh(W_C[x_t, h_{t-1}] + b_C) \quad (6)$$

$$C_t = f_t \odot C_{t-1} + i_t \odot \tilde{C}_t \quad (7)$$

$$o_t = \sigma(W_o[x_t, h_{t-1}] + b_o) \quad (8)$$

$$h_t = o_t \odot \tanh(C_t) \quad (9)$$

式中:  $W$  为门控权重矩阵;  $b$  为偏置向量;  $x_t$  表示神经元输入序列值;  $h_t$  表示神经元的隐状态;  $\tilde{C}_t$  表示神经元候选状态信息;  $C_t$  表示神经元状态信息;  $\tanh$  表示双曲正切激活函数;  $\sigma$  表示 sigmoid 激活函数;  $\odot$  表示逐点乘法运算。该结构通过输入门  $i_t$ 、遗忘门  $f_t$ 、输出门  $o_t$  的三重门控机制,系统性地优化 TCN 残差块输出的特征矩阵,重点强化正向时间演化模式的建模能力。

## 1.5 注意力模块

在模型预测阶段,双阶段注意力机制优化了 LSTM 的性能。特征注意力机制首先对 TCN 输出的全局时空特征进行动态加权,采用多头注意力结构<sup>[22]</sup>。多头注意力机制就是在自注意力机制(self-attention)的基础上,采用多头架构,实现对多种类信息不同重要特征的高效处理。图 3 为多头注意力机制单元结构。

注意力机制由注意力函数实现,注意力函数将输入的向量矩阵使用一组权重矩阵  $W^Q, W^K, W^V$  进行变换得到由新的查询向量  $Q'$ 、键向量  $K'$  和值向量  $V'$ 。使用多组  $W^Q$ ,




图 3 注意力  
Fig. 3 Attention

$W^K, W^V$  来进行变换得到多组  $Q', K'$  和  $V'$ ，并独立计算每组注意力矩阵，并将得到的多个注意力矩阵进行拼接。

研究使用 8 组不同的权重矩阵  $W^Q, W^K, W^V$  进行计算，对反卷积层的输出进行多重关注和信息捕捉。划分为 8 组查询向量、键向量、值向量，每一组计算注意力分数，将所有组的输出拼接起来，通过线性变换进行合并，得到最终的输出，公式为：

$$Q' = QW^Q, K' = KW^K, V' = VW^V \quad (10)$$

$$T(Q', K', V') = \text{softmax}\left(\frac{Q'K'^T}{\sqrt{d_k}}\right)V' \quad (11)$$

$$Y(Q, K, V) = \text{Concat}(T_1, \dots, T_8)W \quad (12)$$

式中： $Q, K, V$  为注意力的输入矩阵； $Q', K', V'$  为变换得到的查询、键、值向量； $W^Q, W^K, W^V, W$  为权重矩阵； $d_k$  为输入的维度， $Y(Q, K, V)$  为注意力机制计算后的输出。通过动态调整权重矩阵  $W^Q, W^K, W^V$  对输入特征的相关性进行评估，特别在 17:00~19:00 晚高峰期间的负荷激增中，8 组多头注意力能够并行关注不同特征的贡献度。例如，当负荷因充电需求激增而呈现非线性变化时，特征注意力机制通过计算  $Q'K'^T$  的相似性得分，分配更高的注意力权重给与高峰负荷强相关的特征，从而增强模型对高峰特征的建模能力，与 VMD 降低非平稳性的作用形成协同效应。

LSTM 生成隐状态后，时间注意力机制对其进行动态加权：

$$\alpha_i = \text{softmax}(q^T \tanh(W_a h_i + b_a)) \quad (13)$$

式中： $q$  为可学习的查询向量（列向量）； $W_a$  为注意力权重矩阵； $b_a$  为偏置向量； $T$  表示转置操作。通过时间注意力聚焦机制，模型可自适应识别与预测目标关联度最高的关键时间步，有效提升对电力负荷突变点的捕捉能力。时间注意力机制通过多头结构并行计算 8 组查询向量  $q$  与隐状态  $h_i$  的相似性得分， $\tanh(W_a h_i + b_a)$  增强非线性表达能力， $\text{softmax}$  动态分配权重  $\alpha_i$  给关键时间步。在早高峰的负荷突变场景中，每组  $q$  能够自适应捕捉不同的时序模式，在负荷快速上升或峰值持续期，8 头多头注意力并行关注短期波动和长期趋势等多个时间维度，通过  $\alpha_i$  放大与预测目标相关的时间步贡献，优化长短期依赖建模。

在本模型中，特征注意力机制对 TCN 输出的时空特征进行加权，输入 LSTM 模块以增强关键特征建模。时间

注意力机制对 LSTM 隐状态进行加权，聚焦关键时间步（如充电高峰），提升对负荷突变点的捕捉能力。两者协同优化后，输出送入时间转换预测模块，生成高精度预测结果。

## 1.6 时间转换预测模块

为了更好地利用电力负荷时序数据对应的日期信息，提出了单独的时间转换预测模块学习输入序列日期信息与输出序列日期信息的表示，模块结构如图 4 所示。首先对日期中包含的年、月、日、时、分 5 类离散整数数据转换为连续的、高维空间中的稠密向量，以便于模型捕捉和学习日期之间的复杂关系。转换的计算过程遵循以下公式：

$$M = \text{TemporalEmbed}(N) \quad (14)$$

式中： $N \in \mathbf{R}^{T \times 5}$  表示初始的日期矩阵， $M \in \mathbf{R}^{T \times d_{\text{bmodel}}}$  表示嵌入后的日期表示， $\text{TemporalEmbed}(\cdot)$  表示时间嵌入函数。然后，将嵌入后的日期向量表示经过前馈神经网络进一步提取时间信息，过程为：

$$M' = \text{FeedForward}(M) \quad (15)$$

$$M_Z = M'_{\text{input}} + M'_{\text{output}} \quad (16)$$

式中： $M'$  表示经过前馈神经网络提取到的日期特征信息， $M'_{\text{input}}$  表示输入序列对应的日期矩阵  $N_{\text{input}}$  经过式(15)、(16)计算得到的结果， $M'_{\text{output}}$  表示输出序列对应的日期矩阵  $N_{\text{output}}$  经过式(15)、(16)计算得到的结果， $M_Z$  表示混合日期表示，即输入序列日期特征信息与输出序列特征信息之和。

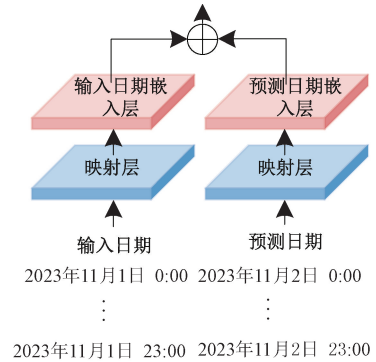


图 4 时间转换预测模块

Fig. 4 Time conversion and prediction module

将混合日期表示  $M_Z$  与式(14)中的预测信息  $Y$  融合共同生成最终的预测结果，以提高模型对日期信息的敏感度，增强模型对时间戳特征的理解，并驱动模型预测结果的生成。这一计算过程为：

$$\hat{Y} = Y + Y \otimes M_Z \quad (17)$$

式中： $\otimes$  表示矩阵相乘操作； $\hat{Y}$  表示最终输出的预测结果。

## 2 数据收集与预处理

### 2.1 数据收集

为验证算法的可行性和有效性，采用中国绍兴某社区

所有电动汽车充电站的历史充电数据进行实验。该原始数据集包括 2023 年 11 月 1 日~2024 年 11 月 1 日的电动汽车充电记录,共 1 387 872 条数据,每条记录包含负荷数据、气象特征数据及对应时间戳,采样间隔为 1 h。以 7:1:2 的比例将完整数据集划分为训练集、验证集与测试集。参数设置如表 1 所示。

表 1 实验参数设置

Table 1 Experimental parameter settings

参数	值
local_epoch	100
global_round	25
batch_size	128
learning_rate	0.000 1
seq_len	96
label_len	48
pred_len	96

## 2.2 仿真环境

本文所有实验均在 Windows 11 操作系统、13thIntel (R) Core (TM)i7-13700KF@3.40 GHz 处理器、NVIDIA GeForce RTX 4070Ti 显卡,显存为 16 GB;相关模型分别于 PyCharm 2023 与 MATLAB R2023b 两种编程环境中实现并运行。

本文设计的改进 VMD-TCN-LSTM 模型有 3 层级联扩张卷积特征提取模块。第 1 层卷积核尺寸 3,扩张率 2,输出通道 16,激活函数为 ReLU;第 2 层保持卷积核尺寸,扩张率 4,输出通道增至 32;第 3 层继续扩展至 64 通道,保持卷积核尺寸,扩张率 8,以捕获多尺度时空特征。序列建模阶段,第 1 层特征注意力(输入维度 64,隐藏维度 32)、第 2 层单向 LSTM(输入维度 128,隐藏维度 64)。经 32 神经单元的时序注意力机制加权序列特征,突出关键特征,最后经全连接层映射至目标输出维度。模型超参数和结构如表 2 所示。

表 2 改进 VMD-TCN-LSTM 预测模型参数

Table 2 Improve the parameters of the VMD-TCN-LSTM prediction model

网络层	描述	过滤器单元个数
TCN	3 层空洞卷积	第 1 层:16
		第 2 层:32
		第 3 层:64
特征注意力	1 层注意力层	32
LSTM	1 层单项 LSTM	64
时序注意力	1 层注意力层	32
FC	1 层全连接层	—

## 2.3 数据处理

为降低原始负荷序列的非平稳性对后续建模的影响,应用 VMD 将负荷序列分解为若干个模态分量和 1 个残差分量,如图 5 所示。




图 5 VMD 分解后的原始负荷序列各分量

Fig. 5 Plots of each component of the original load sequence after VMD decomposition

表 3 汇总了各本征模态分量在均值、方差及模糊熵 (fuzzy entropy, FE) 上的统计特征。以原始序列 FE 为阈值,对 FE 高于阈值的 IMF 予以保留,低于阈值需合并重构。对比结果表明,IMF4~IMF8 的 FE 显著高于阈值,故作为独立分量保留;而 IMF1~IMF3 的 FE 值低于该阈值,因而被整合为新的重构分量。

表 3 VMD 分解后各分量的平均值、方差和模糊熵

Table 3 Mean, variance, and fuzzy entropy of each component after VMD decomposition

IMF	平均值	方差	模糊熵
IMF1	3.411 438 $\times 10^{-1}$	2.382	1.241 155
IMF2	1.313 072 $\times 10^{-6}$	37.722	0.897 935
IMF3	3.234 776 $\times 10^{-7}$	15.840	1.592 439
IMF4	8.647 282 $\times 10^{-8}$	1.085	2.667 450
IMF5	6.261 272 $\times 10^{-8}$	0.737	2.996 241
IMF6	2.736 206 $\times 10^{-8}$	0.402	3.264 675
IMF7	1.611 566 $\times 10^{-8}$	0.364	3.453 982
IMF8	1.280 115 $\times 10^{-8}$	0.617	3.086 383

## 2.4 评价指标

为评估所提出模型的预测性能,本文拟采用选取均方误差 (mean squared error, MSE)、平均绝对误差 (mean absolute error, MAE)<sup>[23]</sup>、以及拟合系数 (r-squared,  $R^2$ ) 作为核心评价指标,其数学表达式为:

$$I_{MSE} = \frac{1}{n} \sum_{j=1}^n (y_n^{pre} - y_n^{ori})^2 \quad (18)$$

$$I_{MAE} = \frac{1}{n} \sum_{j=1}^n |y_n^{pre} - y_n^{ori}| \quad (19)$$

$$R^2 = 1 - \frac{\sum_{j=1}^n (y_n^{pre} - y_n^{ori})^2}{\sum_{j=1}^n (y_n^{ori} - \bar{y})^2} \quad (20)$$

式中： $n$  为电动汽车负荷预测样本容量， $y_n^{pre}$  和  $y_n^{ori}$  分别表示第  $n$  个电动汽车负荷预测值和真实值， $\bar{y}$  表示全部样本真实值的平均值。

### 3 算例分析

#### 3.1 预测结果对比分析

为验证本文所提模型拥有更高的预测精度，将本文所提模型与 TCN、LSTM、VMD-BiLSTM、TCN-LSTM、VMD-TCN-BiLSTM、VMD-TCN-GRU、CNN-LSTM-Attention、CNN-GRU、TCN-LSTM-Attention 进行对比实验以量化评估各模型的预测性能差异，各模型预测结果如图 6 所示。

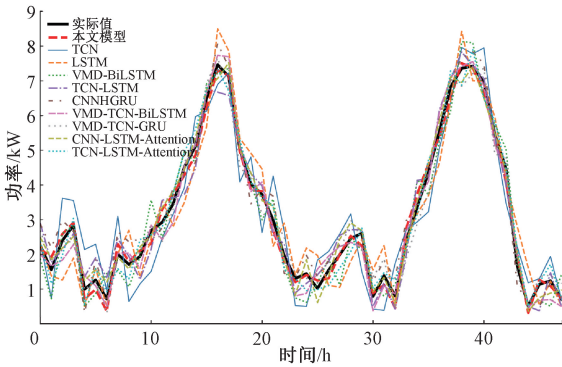


图 6 不同模型预测结果

Fig. 6 Prediction results from different models

由图 6 可见，10 种模型的预测曲线整体上与实测负荷序列保持总体一致的变化趋势，其中单一神经网络模型预测精度最低，而本文提出的组合式神经网络模型精度最优；不同模型预测算法误差如表 4 所示。

由表 4 可明显看出，以 TCN 与 LSTM 为代表的单一神经网络模型，在处理数据时，难以全面且有效地捕获时序信息与特征之间所隐含的复杂关联关系，预测精度相对较差。相较之下，混合神经网络模型在预测精度上，相较于单一神经网络模型均呈现出一定程度的提升。其中，加入 VMD 分解后再预测的方法精确度更高，VMD-BiLSTM 较于传统 LSTM 在 MSE 指标上提高了 30.6%。TCN-LSTM 和 CNN-GRU 由于组合不同网络模型，提升了对负荷变化的捕捉能力，相较于传统 TCN 模型在 MSE 指标上分别提高了 31.1% 和 39.1%，但仍未引入注意力机制或时间转换模块，限制了其对复杂特征的动态调整能力，误差

表 4 不同模型误差分析

Table 4 Error analysis of different models

预测模型	MSE/ kW <sup>2</sup>	MAE/ kW	R <sup>2</sup>	时间/ s
本文方法	<b>0.443</b>	<b>0.514</b>	<b>0.991</b>	<b>40.9</b>
TCN	1.383	1.287	0.951	21.3
LSTM	1.423	1.314	0.943	27.6
VMD-BiLSTM	0.987	1.147	0.967	35.4
TCN-LSTM	0.953	0.979	0.969	42.7
CNN-GRU	0.842	0.919	0.969	38.8
VMD-TCN-BiLSTM	0.833	0.792	0.975	43.2
VMD-TCN-GRU	0.802	0.820	0.972	32.2
CNN-LSTM-Attention	0.794	0.590	0.981	36.1
TCN-LSTM-Attention	0.613	0.668	0.956	48.2

仍高于本文模型。VMD-TCN-BiLSTM 和 VMD-TCN-GRU 由于 VMD 的预处理显著降低了序列的非平稳性，组合模型进一步增强了时序建模能力，相较于传统 TCN 模型在 MSE 指标上分别提高了 39.7% 和 42%，但仍无法动态优化特征权重和校正多时段预测，MSE 仍高于本文模型。引入注意力机制后，CNN-LSTM-Attention 和 TCN-LSTM-Attention 模型能更好地聚焦关键特征和时间点，MSE 指标分别提高了 42.6% 和 55.7%。本文模型通过双阶段注意力进一步优化了权重分配，并结合时间转换预测模块校正多时段预测，MSE 进一步提高至 67.9%，展现出更优的性能。为了直观比较各模型在预测精度、拟合优度与计算效率上的综合表现，以雷达图形式综合呈现了 MAE、R<sup>2</sup> 及时间评价指标。如图 7 所示。

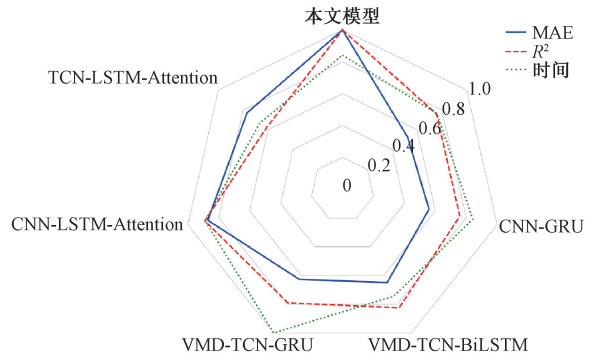


图 7 MAE、R<sup>2</sup> 和时间指标的比较

Fig. 7 Comparison of MAE, R<sup>2</sup>, and time indicators

其中，各模型指标均归一化至 [0, 1] 区间，越接近 1 表明预测性能越优改进 VMD-TCN-LSTM 模型的指标分布最贴近单位边界，显著优于对照模型，充分验证其在精度与效率上的综合优势。

#### 3.2 消融实验

针对改进 VMD-TCN-LSTM 模型中的关键结构，设计了 3 组消融实验，以验证所提出方法的有效性。3 组消融

实验如下:

实验 1:原始 TCN 模型。

实验 2:在原始 TCN 模型基础上加上 VMD。

实验 3:在 VMD 之后,加入双阶段注意力机制改进的 LSTM 模块。

实验 4:在 VMD 之后,改进 LSTM 的基础上加入时间转换模块。消融实验预测误差对比如表 5 所示。

表 5 消融实验预测误差对比

Table 5 Comparison of prediction errors in ablation experiments

实验	MSE/kW <sup>2</sup>	MAE/kW	R <sup>2</sup>
实验 1	1.383	1.287	0.951
实验 2	0.886	0.705	0.970
实验 3	0.574	0.598	0.977
实验 4	<b>0.443</b>	<b>0.514</b>	<b>0.991</b>

从表 5 可以看出,VMD-TCN 模型与单一 TCN 模型相比,实验 2 在加入 VMD 后,其 MSE 下降了 35.9%,其 MAE 下降了 45.2%,该结果说明单独 TCN 网络难以直接学习到历史负荷序列的复杂变化模式,使用 VMD 变分模态分解可以充分挖掘数据在不同频率分量的特征,改良预测效果。

从表 5 中可以看出,VMD-TCN 模型在没有经过特征增强处理,预测结果仍不够精确。实验 3 对比 VMD-TCN 模型,MSE 和 MAE 分别下降了 35.2%和 15.2%,这一改进主要源于双阶段注意力机制在 LSTM 框架中的嵌入,该机制通过特征注意力和时序注意力两个阶段协同工作,显著提升模型对复杂动态负荷特性的捕捉能力。首先,特征注意力模块基于多头注意力机制,在 LSTM 输入端动态量化温度、负荷趋势输入特征的边际贡献,使模型自适应地聚焦于对预测结果影响较大的特征维度。例如,在温度超过 30℃ 场景下,特征注意力模块将提升温度特征的平均权重,更好地捕捉环境因素对充电负荷的非线性影响。其次,时序注意力模块在 LSTM 输出端自适应聚焦关键时间节点的隐状态表征,通过多头注意力机制增强对日周期性负荷变化长时序依赖的建模能力。例如,在 7:00~9:00 早高峰的预测中,时序注意力机制通过动态调整时间维度的权重,有效提升模型对负荷突变和周期性模式的刻画精度。该机制通过特征维度和时序维度的协同融合,弥补 VMD-TCN 在捕捉复杂模式时的不足,使模型在实际电网调度场景中更具实用性。表明加入的双阶段注意力机制的 LSTM 模型能够增强对负荷序列复杂动态特性的刻画能力,促使模型更为聚焦于对预测结果具有显著影响的时间节点与特征通道,进而有效提升模型的预测精度。

实验 4 中所提模型在 MSE、MAE 和 R<sup>2</sup> 这 3 项评价指标中均取得最优表现,验证了各组件之间的强耦合性,这

表明时间转换模块通过对原始时间信息的非线性校正,与改进 LSTM 输出进行全连接层加权融合,进一步优化了预测精度。表明其通过加入时间转换预测模块对多时段预测的非线性校正,进一步降低了误差,特别是在峰值负荷和波动较大的时段表现出色,LSTM 模块中引入双阶段注意力机制通过动态调整特征和时间维度的权重,增强了 LSTM 模型对关键特征(如天气)和长期依赖(如日/周周期性)的捕捉能力。

## 4 结 论

本研究针对现有电动汽车负荷预测方法难以有效建模负荷数据在时间和特征维度上的动态变化规律、难以准确刻画其非线性与非平稳特征的问题,提出了基于变分模态分解(VMD)、时间卷积网络与长短期记忆网络(TCN-LSTM)、双阶段注意力机制以及时间转换预测模块的复合预测模型,首先利用 VMD 降低序列非平稳性与噪声;继而以 TCN-LSTM 联合双阶段注意力机制强化时序及特征模式提取;最后通过时间转换模块加权融合多时段预测,进一步提升高波动场景下的稳定性。

在数据集上结果表明,本研究所提的模型在短期电力负荷预测任务上表现出色,验证了其在实际应用中的有效性和可靠性,但模型仍存在较高的计算复杂度导致训练和推理时间较长,尤其在资源受限设备上可能面临效率瓶颈。未来研究可探索模型压缩与轻量化技术以提升模型性能和实用性。

## 参考文献

- [1] 邓衍辉,李剑,卢国强,等.考虑分区域动态电价机制引导的电动汽车充电优化策略[J].电力系统保护与控制,2024,52(7):33-44.  
DENG Y H, LI J, LU G Q, et al. Charging optimization strategy of electric vehicles guided by the dynamic tariff mechanism of a subregion[J]. Power System Protection and Control, 2024, 52(7):33-44.
- [2] 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 Y B, GONG N W, WANG H J, 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.
- [3] GIL-GARCIA I C, GARCIA-CASCALES M S, DAGHER H, et al. Electric vehicle and renewable energy sources: Motor fusion in the energy transition from a multi-indicator perspective[J]. Sustainability, 2021,13(6): 3430.
- [4] 齐彩娟,张泽龙,吕干云,等.计及用户行为决策的电动

- 汽车负荷时空分布建模[J]. 南方电网技术, 2023, 17(10):170-177.
- QI C J, ZHANG Z L, LYU G Y, et al. Spatial-temporal modeling of EV load considering user behavior decision [J]. Southern Power System Technology, 2023, 17(10): 170-177.
- [5] 赵寒亭, 张耀, 霍巍, 等. 基于纵向联邦学习的短期风电功率协同预测方法[J]. 电力系统自动化, 2023, 47(16):44-53.
- ZHAO H T, ZHANG Y, HUO W, et al. Collaborative short-term wind power forecasting method based on vertical federated learning[J]. Power System Automation, 2023, 47(16):44-53.
- [6] 秦茜茜, 王圆秋. 一种改进的差分-指数平滑预测模型[J]. 四川大学学报(自然科学版), 2025, 62(3): 745-750.
- QIN X X, WANG Y Q. An improved difference-exponential smoothing forecasting model[J]. Journal of Sichuan University(Natural Science Edition), 2025, 62(3):745-750.
- [7] GUO X F, GAO Y, LI Y P, et al. Short-term household load forecasting based on long and short-term timeseries network[J]. Energy Reports, 2021, 7: 58-64.
- [8] 杨国华, 郑豪丰, 张鸿皓, 等. 基于 Holt-Winters 指数平滑和时间卷积网络的短期负荷预测[J]. 电力系统自动化, 2022, 46(6):73-82.
- YANG G H, ZHENG H F, ZHANG H H, et al. Short-term load forecasting based on Holt-Winters exponential smoothing and temporal convolutional network[J]. Automation of Electric Power Systems, 2022, 46(6):73-82.
- [9] 杨首晖, 陈传彬, 王雪品, 等. 基于小波变换和季节性 Holt-Winters 模型的短期负荷预测方法[J]. 电力需求侧管理, 2021, 23(5):70-75.
- YANG SH H, CHEN CH B, WANG X P, et al. A short-term load prediction method based on the wavelet transform and seasonal Holt-Winters model[J]. Power Demand Side Management, 2021, 23(5):70-75.
- [10] 陈纬楠, 胡志坚, 岳菁鹏, 等. 基于长短期记忆网络和 LightGBM 组合模型的短期负荷预测[J]. 电力系统自动化, 2021, 45(4):91-97.
- CHEN W N, HU ZH J, YUE J P, et al. Short-term load prediction based on combined model of long short term memory network and light gradient boosting machine[J]. Automation of Electric Power Systems, 2021, 45(4):91-97.
- [11] 冯俊磊, 吕卫东, 段雪艳, 等. 基于模态分解和 TCN-BiLSTM 的风电功率预测[J]. 电子测量技术, 2024, 47(14):49-56.
- FENG J L, LYU W D, DUAN X Y, et al. Wind power forecasting based on modal decomposition and TCN-BiLSTM[J]. Electronic Measurement Technology, 2024, 47(14):49-56.
- [12] GUO L, SHI P R, ZHANG Y, et al. Short-term EV charging load forecasting based on GA-GRU model[C]. The 3rd Asia Energy and Electrical Engineering Symposium(AEES). IEEE, 2021: 679-683.
- [13] 马志远, 王勃, 杨茂, 等. 基于二维风速修正和多重集成的两阶段迁移学习短期风电功率预测[J]. 高电压技术, 2024, 50(9):3934-3943.
- MA ZH Y, WANG B, YANG M, et al. Two-stage transfer learning short-term wind power prediction based on two-dimensional wind speed correction and multiple integration[J]. High Voltage Engineering, 2024, 50(9): 3934-3943.
- [14] 刘杰, 金勇杰, 田明. 基于 VMD 和 TCN 的多尺度短期电力负荷预测[J]. 电子科技大学学报, 2022, 51(4): 550-557.
- LIU J, JIN Y J, TIAN M. Multi-scale short-term power load forecasting based on VMD and TCN[J]. Journal of University of Electronic Science and Technology of China, 2022, 51(4):550-557.
- [15] 赵星宇, 吴泉军, 朱威. 基于 CEEMDAN 和 TCN-LSTM 模型的短期电力负荷预测[J]. 科学技术与工程, 2023, 23(4):1557-1564.
- ZHAO X Y, WU Q J, ZHU W. Short-term power load forecasting based on CEEMDAN and TCN-LSTM models [J]. Science Technology and Engineering, 2023, 23(4):1557-1564.
- [16] 王可睿, 邵必林. 基于 Time2Vec-LSTM-TCN-Attention 的天然负荷组合预测[J]. 南京信息工程大学学报, 2024, 16(6):801-809.
- WANG K R, SHAO B L. Combined forecasting of natural gas load based on Time2Vec-LSTM-TCN-Attention [J]. Journal of Nanjing University of Information Science and Technology, 2024, 16(6): 801-809.
- [17] 吴小涛, 袁晓辉, 毛玉鑫, 等. 基于鸮鹞优化 CNN-BiLSTM 的电力负荷预测[J]. 水电能源科学, 2024, 42(8):209-212.
- WU X T, YUAN X H, MAO Y X, et al. Power load forecasting based on pelican-optimized CNN-BiLSTM[J]. Hydropower Energy Science, 2024, 42(8):209-212.
- [18] 史含笑, 王雷春. 结合 LSTM 和自注意力机制的图卷积网络短期电力负荷预测[J]. 计算机应用, 2024,

- 44(1):311-317.
- SHI H X, WANG L CH. Short-term power load forecasting based on graph convolutional network combining LSTM and self-attention mechanism [J]. Computer Applications, 2024,44(1):311-317.
- [19] 范竞敏,贺广林,王新刚,等. 基于 VMD-TCN-GRU-AM 的超短期风电预测[J]. 太阳能学报,2025,46(6):538-547.
- FANG J M, HE G L, WANG X G, et al. Ultra-short-term wind power forecasting based on VMD-TCN-GRU-AM[J]. Journal of Solar Energy, 2025, 46(6): 538-547.
- [20] 唐贤伦,陈洪旭,熊德意,等. 基于极端梯度提升和时间卷积网络的短期电力负荷预测[J]. 高电压技术, 2022, 48(8):3059-3067.
- TANG X L, CHEN H X, XIONG D Y, et al. Short-term power load forecasting based on extreme gradient boosting and temporal convolutional network [J]. High Voltage Engineering, 2022,48(8):3059-3067.
- [21] 张未,余成波,王士彬,等. 基于 VMD-LSTM-LightGBM 的多特征短期电力负荷预测[J]. 南方电网技术,2023,17(2):74-81.
- ZHANG W, YU CH B, WANG SH B, et al. Multi-featured short-term power load forecasting based on VMD-LSTM-LightGBM[J]. Southern Power System Technology,2023,17(2):74-81.
- [22] 李维焯,贾海蓉,申陈宁,等. 基于多头自注意力机制的 LSTM-TCN 基站流量预测算法[J]. 现代电子技术, 2024,47(23):125-130.
- LI W Y, JIA H R, SHEN CH N, et al. LSTM-TCN base station traffic prediction algorithm based on multi-head self-attention mechanism [J]. Modern Electronic Technology,2024,47(23):125-130.
- [23] 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 networks and EMD-ISSA-LSTM [J]. Electronic Measurement Technology,2024,47(20):92-100.

### 作者简介

花妍,硕士研究生,主要研究方向为有序充电、机器视觉。  
E-mail:1439418328@qq.com

李鹏(通信作者),教授,博士生导师,主要研究方向为超声成像、通信信号处理、北斗定位、图像处理等。  
E-mail:202312490320@nuist.edu.cn

闫冬,硕士研究生,主要研究方向为图像处理、视觉控制。  
E-mail:202312490331@nuist.edu.cn

张翔凯,硕士研究生,主要研究方向为机器视觉。  
E-mail:583385427@qq.com