

结合注意力和多尺度特征的电动汽车负荷预测^{*}

肖霞 马强 杨震

(西南科技大学信息工程学院 绵阳 621010)

摘要: 针对电动汽车负荷随机性以及预测精度低的问题,在TCN基础上,提出一种结合变分模态分解、注意力机制和多尺度特征的电动汽车负荷预测模型(VMD-AM-MSF-TCNnet)。首先,采用鲸鱼优化算法结合变分模态分解将电动汽车负荷序列分解;其次,引入门控机制和双重注意力改进TCN残差块结构,把不同尺寸的改进TCN残差块与注意力相结合实现多尺度特征融合;最后,对负荷分量进行预测再重构得到最终结果。实验结果表明,所提模型相比原始TCN在RSE、RAE、 R^2 性能指标上均有所提升,该模型具有较好的预测效果。

关键词: TCN;变分模态分解;注意力机制;多尺度特征;鲸鱼优化算法

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

Electric vehicle load prediction combining attention and multi-scale features

Xiao Xia Ma Qiang Yang Zhen

(School of Information Engineering, Southwest University of Science and Technology, Mianyang 621010, China)

Abstract: Aiming to address the problems of randomness and low prediction accuracy in electric vehicle charging load forecasting, the paper proposed a novel approach based on TCN. This approach integrated variational mode decomposition, attention mechanisms and multi-scale features, leading to the development of the electric vehicle load forecasting model, VMD-AM-MSF-TCNnet. Firstly, the proposed method utilizes variational mode decomposition, optimized using the whale optimization algorithm, to decompose the electric vehicle charging load sequence. Secondly, the method introduced a gating mechanism and dual attention mechanisms to enhance the residual blocks of the original TCN. The model achieved multi-scale feature fusion by combining the attention-enhanced outputs of improved TCN residual blocks of varying sizes. Finally, it finalized the prediction through the reconstruction of the load components. The experimental results indicate that the proposed model demonstrates improvements in the performance metrics of RSE, RAE and R^2 compared to the original TCN, showing that it has a good predictive performance.

Keywords: TCN; variational mode decomposition; attention mechanism; multi-scale features; whale optimization algorithm

0 引言

随着大量电动汽车接入电网,电动汽车负荷预测显得尤为关键。电动汽车负荷预测是实现电力合理调度的有效保障,电动汽车负荷预测可以为电网调度^[1]、充电站建设规划^[2]、交通出行、用户充电服务^[3]等提供现实意义。

电动汽车负荷预测分类主要可以划分为两种,一种是基于传统数理统计的电动汽车负荷预测方法^[4],包括了时间序列法^[5]、回归分析法^[6]、小波分析法^[7]、相似日法^[8]、蒙特卡洛模拟法^[9]等,通过对电动汽车的出行规律、能量消耗、充电时间等进行统计与分析,从而建立模型实现负荷预测。

然而,随着数据量的增加和复杂性的提升,传统的时间序列分析方法的局限性逐渐显现,深度学习的出现为处理复杂的非线性时间序列数据提供了新的解决途径。

基于深度学习的电动汽车负荷预测方法,近年来受到了广泛关注。其中,循环神经网络(recurrent neural network, RNN)及其变种模型^[10],如长短期记忆网络(long short-term memory, LSTM)^[11]和门控循环单元(gate recurrent unit, GRU)^[12],通过对海量数据进行分析建立深度学习网络模型实现负荷预测。然而,

RNN模型在处理长时序数据时,容易出现梯度消失或梯度爆炸的问题,且并行计算能力有限。为了克服这些限制,一种新的深度学习模型——时序卷积网络(temporal

convolutional network, TCN)^[13] 逐渐进入研究者的视野。TCN 利用卷积操作来提取时间序列特征,并通过膨胀卷积来扩大感受野,有效地捕获长时序依赖关系。同时,TCN 具有高度的并行计算能力,能够显著提高训练效率。因此,TCN 在预测领域展现出了巨大的潜力。为了提升预测性能,柳天虹等^[14] 将频率注意力机制(frequency channel attention, FCA)引入 TCN 改进残差块,并成功应用于风电功率预测。针对电力负荷数据复杂性和随机性的挑战,经验模态分解(empirical mode decomposition, EMD)^[15] 开始被引入该领域。赵一鸣等^[16] 提出 EMD 与 LSTM 结合对电力负荷进行预测,尽管预测准确率有所提高,但未解决 EMD 模态混叠问题。由于变分模态分解(variational mode decomposition, VMD)^[17] 具有自适应分解的特点,其已在海洋科学预测^[18] 和环境科学预测^[19] 等领域展现出潜力,但在电动汽车负荷预测领域的研究仍然有限。

为了提高电动汽车负荷预测的准确性,本文首次提出一种 VMD-AM-MSF-TCNnet 模型用于电动汽车负荷预测。首先,对电动汽车负荷数据进行下采样得到小时粒度聚合数据。然后,采用 VMD 对聚合后的电动汽车负荷数据进行分解,降低电动汽车负荷序列的复杂度,并采用鲸鱼优化算法(whale optimization algorithm, WOA)优化 VMD 参数,降低经验参数的随机性。在此基础上,引入门控机制、时间注意力和通道注意力改进 TCN 中残差块结构,实现特征对于特定时间点的增强和通道维度上的融合,从而捕捉不同层面的重要信息,提高特征的抽取效果和模型的表现能力,使得网络能够有效地学习丰富的特征表示。此外,使用不同卷积核大小和膨胀率的改进 TCN 残差块来捕捉不同时间尺度的信息,并将提取的多尺度特征通过注意力机制进行融合,以提高模型对复杂时间序列数据的建模能力和预测性能。

1 预测模型

1.1 VMD-AM-MSF-TCNnet 模型

考虑电动汽车负荷数据存在随机性、预测准确度不高的问题,提出一种 VMD-AM-MSF-TCNnet 模型,模型整体框架如图 1 所示。

VMD-AM-MSF-TCNnet 模型利用 VMD 将原始电动汽车负荷数据分解为子序列,然后通过对于子序列分别进行预测,并通过叠加预测分量获得最终的预测值。对于电动汽车负荷预测步骤如下:

- 1) 对电动汽车负荷数据集和气象数据集进行数据预处理和下采样,得到小时级粒度聚合的数据。
- 2) 对电动汽车负荷进行 VMD 分解,再利用 WOA 优化 VMD 分解参数。
- 3) 分析影响电动汽车负荷因素,并利用线性多元模型实现气象特征筛选。
- 4) 将电动汽车历史负荷分量和日期、星期、相关性大的




图 1 VMD-AM-MSF-TCNnet 模型

Fig. 1 VMD-AM-MSF-TCNnet model

气象特征作为输入特征,进行电动汽车负荷预测。

5) 对电动汽车负荷分量的预测结果进行重构得到最终预测值。

1.2 数据预处理

为了保持数据的完整性,对数据进行缺失值检查,并采用线性插补的方法填补缺失值。为了有效分析电动汽车负荷,将电动汽车负荷数据按照小时粒度进行聚合,以获得每小时的总负荷。同时,对气象特征序列进行处理,对于离散型气象特征,采用独热编码来表示其数据值;对于连续型气象特征,对其数据值进行 Min-Max 归一化处理,以消除量纲影响。归一化方法为:

$$w'_j = \frac{w_j - w_{\min}}{w_{\max} - w_{\min}} \quad (1)$$

其中, w'_j 表示归一化的第 j 个气象数据值, w_j 表示第 j 个气象数据值, $w_{\max}$ 和 $w_{\min}$ 分别表示气象数据值的最大值和最小值。

1.3 WOA 优化 VMD 参数

WOA 是模仿座头鲸捕食行为的一种元启发式算法,主要包括了搜索猎物、围捕猎物、气泡网攻击 3 种行为模式。VMD 是一种将信号自适应地分解成多个本征模态函数(intrinsic mode function, IMF)的信号分解技术。这种方

法能够将负荷成分给预测精度带来的干扰降低到可接受的范围内,同时避免了频谱混叠现象的产生。分解数目 K 和惩罚因子 α 直接影响 VMD 分解效果,因此本文采用 WOA 对其进行优化,提高分解质量。WOA 优化 VMD 参数算法流程图如图 2 所示。




图2 WOA 优化 VMD 参数流程图

Fig.2 WOA optimizes VMD parameter flow chart

- 1) 初始化鲸鱼种群数量大小 N_{whale} 、迭代次数 $t = 1$ 、迭代最大次数 t_{max} 、初始化位置向量 $L^t(n) = (K, \alpha)$ 。
- 2) 根据当前位置对电动汽车负荷进行 VMD 分解。
- 3) 采用最小包络熵计算每条鲸鱼的适应度值并对其进行评估。
- 4) 根据随机概率值 R 的取值范围,判断当前种群的状态,选择不同方式迭代种群中每个个体的位置, R 是 $0 \sim 1$ 范围内的随机数。

若 $R \geq 0.5$,位置更新采用非线性更新,具体方法如下:

$$L^{t+1}(n) = L_{best}^t + |L_{best}^t - L^t(n)| \cdot e^{\pi r_1} \cos(2\pi r_1) \quad (2)$$

其中, r_1 是 $-1 \sim 1$ 的一个随机数。

若 $R < 0.5$ 同时满足 $|\beta| < 1$,位置更新采用下面方法进行计算:

$$\Delta L^t(n) = |\gamma L_{best}^t - L^t(n)| \quad (3)$$

$$L^{t+1}(n) = L_{best}^t - \beta \Delta L^t(n) \quad (4)$$

其中, L_{best}^t 表示当前最好的位置, $\Delta L^t(n)$ 表示当前进

行更新的个体位置与当前最优位置的距离,控制位置更新的参数 γ, β 的计算方法如下:

$$\beta = 2\theta r_2 - \theta \quad (5)$$

$$\gamma = 2r_3 \quad (6)$$

$$\theta = 2 - 2 \frac{t}{t_{max}} \quad (7)$$

其中, r_2, r_3 是 $0 \sim 1$ 范围内的随机数。

若 $R < 0.5$ 同时满足 $|\beta| \geq 1$,采用随机更新,位置更新方法如下:

$$L'^t(n) = |\gamma L_{rand}^t - L^t(n)| \quad (8)$$

$$L^{t+1}(n) = L_{rand}^t - \beta L'^t(n) \quad (9)$$

其中, L_{rand}^t 是随机个体的位置, $L'^t(n)$ 表示当前进行更新位置的个体与当前随机个体位置的距离。

5) 判断当前迭代次数是否达到 t_{max} 。如果当前迭代次数满足 $t < t_{max}$,则使得 $t = t + 1$,进入下一次迭代,并返回步骤 2);如果当前迭代次数满足 $t \geq t_{max}$,那么输出最优位置即 VMD 最佳分解参数。

1.4 影响因素分析

影响电动汽车负荷预测因素包括历史负荷、日期、气象因素等,考虑到日期因素对电动汽车负荷预测的必要性,用户的充电习惯会根据不同的时间段呈现差异化的行为模式,选取日期因素作为输入特征之一,同时对星期进行独热编码。考虑到气象因素包括很多种,为提高预测的准确性,选择影响程度大的气象因素作为相关特征,对气象和电动汽车负荷建立多元线性关系实现气象特征筛选。通过对电动汽车负荷和气象特征拟合线性模型,可以得到气象特征对电动汽车负荷的影响程度,多元线性模型的形式为:

$$Y = a_1 W_1 + \dots + a_i W_i + \dots + a_s W_s + b \quad (10)$$

其中, a_i 是气象特征对应的系数, b 是截距;若 $a_i > P_1$,保留 a_i 对应的第 i 个气象特征;否则忽略 a_i 对应的第 i 个气象特征。这里, P_1 是一个阈值常数。

1.5 改进残差块和多尺度特征

改进残差块主要是在 TCN 原始残差块中引入门控机制,通过门控机制动态调整信息流,强化电动汽车负荷和特征的复杂关系,捕捉序列的长期依赖关系,提高模型记忆能力。同时,在此基础上结合时间注意力和通道注意力,时间注意力聚焦于不同时间步的信息,通道注意力机制专注于通道层面的特征重要性学习,这种双管齐下的策略不仅增强了模型对输入时间序列数据的多维度理解,而且显著提升了模型在处理复杂时序数据和复杂任务时的准确性和鲁棒性。通过这种方式,残差块能够在保持网络深度和鲁棒性的同时,实现对时间序列数据中丰富时频信息的精炼和利用。改进残差块结构图如图 3 所示。

将输入 X 进行因果膨胀卷积,得到 H_1 :

$$H_1 = \text{ReLU}(W_1 * X + b_1) \quad (11)$$

通过更新门和重置门控制信息流动,灵活调节特征因素对负荷的影响,增强模型对长时间序列的记忆能力。公




图 3 改进残差块结构图

Fig. 3 Improved residual block structure diagram

式如下:

$$z_1 = \text{sigmoid}(W_{z1} * H_1 + b_{z1}) \quad (12)$$

$$r_1 = \text{sigmoid}(W_{r1} * H_1 + b_{r1}) \quad (13)$$

$$\tilde{H}_1 = r_1 \odot \text{state} \quad (14)$$

通过新旧信息融合得到门控输出:

$$H'_1 = (1 - z_1) \odot \tilde{H}_1 + z_1 \odot H_1 \quad (15)$$

$$G_1 = \text{Dropout}(\text{ReLU}(H'_1)) \quad (16)$$

其中, W_{z1} 、 W_{r1} 是对应卷积核的权重矩阵, b_{z1} 、 b_{r1} 是对应的偏置矩阵, state 表示上一时刻的隐藏状态。

经过两层膨胀卷积和门控处理的新特征 G_2 通过时间注意力进一步优化。时间注意力为每个时间步生成权重值,从而增强特定时间点的特征,使模型能够自适应地分配关注点于序列的不同部分,更好地捕捉时间序列数据的动态变化和关键特征。将 G_2 通过非线性变换映射到新的空间,生成一个新的特征表示,再进行 Flatten 操作,使用

softmax 将输出的标量值转换为概率分布,从而为每个时间步分配归一化的注意力权重 A_t 。

$$A_t = \text{softmax}(\text{Flatten}(\tanh(W_t * X + C))) \quad (17)$$

其中, W_t 是权重矩阵, C 是偏置矩阵。将时间注意力权重向量重复以匹配特征维度,对其重新排列维度之后,得到 A'_t :

$$A'_t = \text{Permute}(\text{RepeatVector}(A_t)) \quad (18)$$

将其应用到序列,生成加权特征:

$$Y = G_2 * A'_t \quad (19)$$

经过时间注意力处理后的输出 Y 会进入通道注意力模块,对其进行全局平均池化,将每个通道的特征汇聚成一个标量,从而减少维度并得到每个通道的全局信息。

$$Y' = \text{GlobalAveragePooling}(Y) \quad (20)$$

通过第 1 个 Dense 层对全局特征进行压缩从而提取关键特征,第 2 个 Dense 层恢复压缩后的特征,生成通道注意力权重 A_c 。

$$A_c = \text{Dense}(\text{Dense}(\text{Reshape}(Y'))) \quad (21)$$

使用 Multiply 层将 Y 与通道注意力权重逐元素相乘,加权通道特征,并实现残差连接,从而得到新的特征表示 Res 。

$$\text{Res} = X + Y * A_c \quad (22)$$

多尺度特征融合主要通过 3 个不同改进残差块与注意力模块协同工作以实现时间序列数据的精细化建模。多尺度特征融合结构如图 4 所示。




图 4 多尺度特征融合结构图

Fig. 4 Multi-scale feature fusion structure diagram

TCN 残差块能够以多尺度的方式捕获时间序列中的特征,使用不同的卷积核大小和膨胀率构建多个残差块,每个残差块分别在不同时间尺度上对输入序列进行卷积操作,从而提取出具有不同时间跨度的特征。通过将这些多尺度残差块的输出进行相加形成综合的特征表示 Res_{mul} 。

$$\text{Res}_{mul} = \text{Res}_1 + \text{Res}_2 + \text{Res}_3 \quad (23)$$

再用注意力对多尺度特征进行动态调整,通过维度变换充分考虑每一个特征在每一个时间步上的重要程度,应用 softmax 计算每个特征在时间步上的重要性,并通过全连接层进一步调整。

$$\mathbf{A}_d = \text{Dense}(\text{softmax}(\text{Permute}(\mathbf{Res}_{mul}))) \quad (24)$$

将注意力权重 $\mathbf{A}_d$ 应用到多尺度特征,最终的融合特征表示更能准确反映序列数据的重要信息。 $\mathbf{Res}_{mul}$ 通过 *Dropout* 层随机丢弃神经元,通过 *Flatten* 操作将多维特征张量转换为一维张量,应用多个 *Dense* 层对展平后特征进行处理得到输出 $\mathbf{V}$ 。

$$\mathbf{Res}_{fusion} = \text{Flatten}(\text{Dropout}(\mathbf{Res}_{mul} * \mathbf{A}_d)) \quad (25)$$

$$\mathbf{V} = \text{Dense}(\text{Dense}(\text{Dense}(\mathbf{Res}_{fusion}))) \quad (26)$$

2 实验分析

2.1 仿真环境

本文实验在处理器 AMD Ryzen7、显卡 4060、内存 16 G 的系统上进行,仿真平台为 Pycharm2022。实验中,将历史负荷分量、日期、星期、气象因素作为输入标签,采用 3 个不同尺度的残差块,分别为 3、5、7 的卷积核大小和 1、2、4 的膨胀率,使用 Adam 优化器,采用平均绝对误差作为损失函数,训练 50 轮次。

2.2 数据来源

实验所用的电动汽车负荷数据集来自 ElaadNL 项目,包含了 2019 年 1 月 1 日~2019 年 6 月 30 日的电动汽车充电记录,一共包含 163 255 条电动汽车充电记录,每条记录包含负荷数据及对应时间戳,数据无序采样。气象数据集是荷兰 2019 年 1 月 1 日~2019 年 6 月 30 日的气象数据,包含温度、大气压等气象特征,一共 4 344 条气象记录,每条记录包含气象特征数据及对应时间戳,采样间隔为 1 h。因此本文实验基于上述数据预测电动汽车负荷变化情况,并以最后 1 200 h 的数据作为测试集。

2.3 气象因素分析结果

气象因素对电动汽车负荷的影响如表 1 所示,选取系数大于 0.5 的气象特征作为影响电动汽车负荷的相关特征。

表 1 气象因素对电动汽车负荷的影响

Table 1 Effect of meteorological factors on electric vehicle load

特征	系数
T	0.81
Po	-0.86
P	0.85
Pa	1.33
U	0.05
Ff	0.28

其中,T 表示大气温度,Po 表示水平大气压,P 表示海平大气压,Pa 表示 3 h 内气压变化,U 表示地面相对湿度,Ff 表示平均风速。

2.4 评价指标

为了评估所提模型的性能表现,本文拟采用均方误差

(mean squared error,MSE)、平均绝对误差(mean absolute error,MAE)、以及拟合系数(r-squared, R^2)作为评估指标,各个评估指标的表达式如下:

$$MSE = \frac{1}{sampp} \sum_{\mathfrak{Z}=1}^{sampp} (y_{\mathfrak{Z}}^{pre} - y_{\mathfrak{Z}}^{ori})^2 \quad (27)$$

$$MAE = \frac{1}{sampp} \sum_{\mathfrak{Z}=1}^{sampp} |y_{\mathfrak{Z}}^{pre} - y_{\mathfrak{Z}}^{ori}| \quad (28)$$

$$R^2 = 1 - \frac{\sum_{\mathfrak{Z}=1}^{sampp} (y_{\mathfrak{Z}}^{pre} - y_{\mathfrak{Z}}^{ori})^2}{\sum_{\mathfrak{Z}=1}^{sampp} (y_{\mathfrak{Z}}^{ori} - \bar{y})^2} \quad (29)$$

其中, $sampp$ 为电动汽车负荷预测样本数量, $y_{\mathfrak{Z}}^{pre}$ 表示第 $\mathfrak{Z}$ 个电动汽车负荷预测值, $y_{\mathfrak{Z}}^{ori}$ 表示第 $\mathfrak{Z}$ 个电动汽车负荷真实值, $\bar{y}$ 表示电动汽车负荷样本的平均值。

2.5 基于 WOA 优化 VMD 参数结果

基于 WOA 的 VMD 将原始电动汽车负荷序列分解为 5 个子序列,其分解效果图如图 5 所示。由于电动汽车负荷具有随机性,为提高预测精度,对电动汽车负荷采用 VMD,将原始复杂序列分解为较有规律的子序列。同时,为了降低经验参数的随机性,采用 WOA 对 VMD 分解参数进行优化,提高分解质量。设置鲸鱼种群数量为 10,最大迭代次数为 50,维度为 2, k 值范围为 $[2, 10]$, α 值范围为 $[100, 3\ 000]$ 。




图 5 分解效果图

Fig. 5 Decomposition effect diagram

2.6 实验结果分析

为了验证模型的有效性,选取 GRU、LSTM、CNN-Attention-LSTM(CNN-AT-LSTM)、EMD-LSTM、VMD-CNN、VMD-FCA-TCN、VMD-LSTM、ICEEMDAN-TCN-

Attention-BiGRU(ITCN-AT-BiGRU)作为所提模型对比实验。为了更清晰地展示预测结果,图 6 仅展示 24 h 原始值与预测值的拟合曲线,各个模型预测误差如表 2 所示。




图 6 对比实验预测曲线对比

Fig. 6 Comparison of experimental prediction curves

表 2 各模型预测误差

Table 2 Prediction error of each model

模型	MSE/kW ²	MAE/kW	R ²
GRU	46.28	5.02	0.618
LSTM	43.26	4.89	0.643
CNN-AT-LSTM	41.15	4.67	0.653
EMD-LSTM	25.84	3.80	0.787
VMD-CNN	7.31	2.05	0.937
VMD-FCA-TCN	6.93	1.97	0.940
VMD-LSTM	4.53	1.63	0.960
ITCN-AT-BiGRU	3.43	1.42	0.970
所提模型	1.47	0.91	0.987

从表 2 中可以看出,由于 GRU 模型和 LSTM 模型模型简单,预测精度低。CNN-AT-LSTM 模型相比 LSTM 模型效果有所提升,通过 CNN 提取特征,再采用注意力进行特征融合,模型性能得到改善,说明混合模型比单一模型预测效果好,但由于数据复杂,预测效果较差。EMD-LSTM 先通过 EMD 分解电动汽车负荷数据,再用 LSTM 预测分解后的结果,通过分解策略对复杂的电动汽车负荷数据进行了一定处理,预测效果较 GRU 模型、LSTM 模型、CNN-AT-LSTM 模型有所提升。与 EMD-LSTM 模型相比,VMD-CNN、VMD-FCA-TCN 和 VMD-LSTM 模型表现出更优异的性能,这是由于 VMD 能够更有效地减少模态混叠,使得 VMD 的分解效果优于 EMD,从而提取出电动汽车负荷更具代表性的特征。ITCN-AT-BiGRU 模型使用了 ICEEMDAN 分解,并使用了注意力机制和 BiGRU

来捕捉电动汽车负荷数据的双向时间依赖,在性能上有了进一步提升。所提模型与 ITCN-AT-BiGRU 模型相比,尽管 ICEEMDAN 在理论上具有更好的噪声处理和模态混叠抑制能力,但所提模型通过改进 TCN 残差块以及多尺度特征融合,有效提升了特征表达能力,比 TCN-attention-BiGRU 结构更有效地提取了电动汽车负荷序列中的关键信息,通过充分学习电动汽车负荷不同时间尺度特征,实现了更好的预测性能。整体来看,所提模型的评价指标均有所提升,整体表现均优于对比模型,所提模型 MSE 比 GRU 模型、LSTM 模型、CNN-Attention-LSTM 模型、EMD-LSTM 模型、VMD-CNN 模型、VMD-FCA-TCN 模型、VMD-LSTM 模型、ITCN-AT-BiGRU 模型分别降低了 96.82%、96.60%、96.43%、94.31%、79.89%、78.79%、67.55%、57.14%,MAE 分别降低了 81.87%、81.39%、80.51%、76.05%、55.61%、53.81%、44.17%、35.92%,R² 分别提高了 59.71%、53.50%、51.15%、25.41%、5.34%、5.00%、2.81%、1.75%。可以看出采用 VMD 对复杂的负荷数据进行处理,提高了数据质量,在 TCN 残差块中引入门控机制提高了对长时间跨度信息的建模能力和信息流的控制,结合时间注意力和通道注意力使模型更关注重要时间点和特征通道,同时多尺度特征提取增强了模型对数据多样性的处理能力。

为了评估所提出的模型每一步产生的预测效果,将建立消融实验证明所提模型预测效果。消融实验采取的几个模型如下:

- TCN:原始 TCN 模型。
- VT:在原始 TCN 模型基础上加上 VMD。
- VT-IR:在 VMD 之后,加入改进残差块的 TCN。
- VT-MSR:在 VMD 之后,TCN 的基础上加入多尺度残差块。

为了更清晰地展示预测结果,图 7 仅展示 24 h 原始值与预测值的拟合曲线。TCN、VT、VT-IR、VT-MSR、所提模型预测误差如表 3 所示。




图 7 消融实验预测曲线对比

Fig. 7 Comparison of ablation experiment prediction curves

表 3 消融实验预测误差对比

Table 3 Comparison of prediction errors in ablation experiments

模型	MSE/kW ²	MAE/kW	R ²
TCN	47.55	4.97	0.607
VT	7.59	2.09	0.934
VT-IR	2.39	1.21	0.980
VT-MSR	1.67	1.01	0.985
所提模型	1.47	0.91	0.987

从表 3 中可以看出,对比 TCN 模型和 VT 模型,TCN 模型在加入了 VMD 之后,MSE 和 MAE 降低了 84.04%、57.95%,这说明使用 VMD 将负荷分解为相对平稳的子序列,为模型提供了更清晰的负荷信息,使得 TCN 在子序列上表现得更好,从而提高预测准确率。对比 VT 模型和 VT-IR 模型,MSE 和 MAE 分别降低了 68.51% 和 42.11%,表明在残差块中引入门控机制和注意力,能够提升模型对长时间跨度信息的建模能力,同时使模型更加关注对预测结果影响较大的时间点和特征通道,有利于提高模型预测精度。对比 VT 模型和 VT-MSR 模型,VT-MSR 模型在采用多尺度残差块之后,MSE 和 MAE 分别降低了 78.00% 和 51.67%,说明采取多尺度特征提取,模型能够处理数据中的不同层次信息,使模型能够更加全面地理解负荷数据的复杂性,有助于负荷预测。对比所提模型与 TCN 模型、VT 模型、VT-IR 模型、VT-MSR 模型,所提模型在 MSE、MAE、R² 指标上表现最佳,这表明所提模型通过基于 WOA 的 VMD 提升了负荷数据质量,此外,残差块中引入门控机制和注意力机制增强了模型对重要信息的敏感性,多尺度特征提取有效整合电动汽车负荷不同尺度特征,从而更好地捕捉负荷数据复杂性和多样性,实现良好的预测效果。

3 结 论

本文提出了一种基于 VMD-AM-MSF-TCNnet 的电动汽车负荷预测模型,主要结论有:

通过 VMD 将原始负荷序列分解能够可以充分挖掘数据中隐藏的信息,降低负荷序列复杂性,有利于提高电动汽车负荷预测精度;在 TCN 残差块中引入门控机制和注意力机制,能够使模型关注不同维度的特征,从而增强模型对输入数据的表示能力,提高模型预测能力;在 TCN 中使用多个不同残差块进行多尺度特征融合可以帮助模型提取不同尺度下的数据特征,使模型更加全面地理解输入数据,提高预测准确性。

未来还可以考虑更多输入特征,如电动汽车充电价格,进一步提高电动汽车负荷预测精度。

参考文献

[1] 史书恒. 基于出行信息的 V2G 电动汽车能耗估算与充

电需求预测研究[D]. 吉林:吉林大学,2024.
SHI SH H. Research on V2G electric vehicle energy consumption estimation and charging demand prediction based on travel information[D]. Jilin: Jilin University,2024.
[2] 庞松岭,赵雨楠,唐金锐,等. 基于充电桩利用率的充电负荷超短期预测方法研究[J]. 电力科学与技术学报, 2024,39(1):115-123,133.
PANG S L, ZHAO Y N, TANG J R, et al. A novel ultra short-term charging load forecasting method based on usage degree of charging piles [J]. Transactions of Electric Power Science and Technology, 2024, 39(1): 115-123, 133.
[3] 高超,孙道嫔,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.
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.
[4] 张道路. 基于深度学习和集成学习的配电网中期负荷预测研究[D]. 广州:华南理工大学,2022.
ZHANG D L. Research on medium term load forecasting of distribution network based on deep learning and ensemble learning[D]. Guangzhou: South China University of Technology,2022.
[5] NESPOLI A, OGLIARI E, LEVA S. User behavior clustering based method for EV charging forecast[J]. IEEE Access, 2023, 11: 6273-6283.
[6] GUO X F, GAO Y, LI Y P, et al. Short-term household load forecasting based on long-and short-term time-series network[J]. Energy Reports, 2021, 7: 58-64.
[7] RAFI S H, MASOOD N A, DEEBA S R, et al. A short-term load forecasting method using integrated CNN and LSTM network[J]. IEEE Access, 2021, 9: 32436-32448.
[8] 王慧敏. 计及需求响应的电动汽车充电负荷分区预测[D]. 南京:南京邮电大学,2022.
WANG H M. Demand response based zonal load forecasting for electric vehicle charging stations[D]. Nanjing: Nanjing University of Posts and Telecommunications, 2022.
[9] 王海鑫,袁佳慧,陈哲,等. 智慧城市车-站-网一体化运行关键技术研究综述及展望[J]. 电工技术学报, 2022, 37(1): 112-132.
WANG H X, YUAN J H, CHEN ZH, et al. Review and prospect of key technologies of vehicle-station-network integrated operation in smart city [J]. Transactions of China Electrotechnical Society, 2022,

- 37(1):112-132.
- [10] 孟金鑫, 黄山, 印月. 基于特征优选策略和 DLSTMs-FCN 优化的短期负荷预测[J]. 电子测量技术, 2023, 46(10):46-52.
- 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.
- [11] 陈伟楠, 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.
- [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] 李春辉, 张瑛琪, 孙洁. 融合 2 维卷积与注意力以预测 PM2.5 浓度的 S-TCN 模型[J]. 国外电子测量技术, 2024, 43(1):77-86.
- LI CH H, ZHANG Y Q, SUN J. S-TCN model fusing 2D convolution and attention to predict PM2.5 concentrations [J]. Foreign Electronic Measurement Technology, 2024, 43(1):77-86.
- [14] 柳天虹, 乔显著, 营利彬, 等. 引入注意力机制和参数优化的 TCN 短期风电功率预测[J]. 电力系统及其自动化学报, 2024, 36(9):88-95.
- LIU T H, QIAO X ZH, JIAN L B, et al. TCN short-term wind power prediction by introducing attention mechanism and parameter optimization[J]. Proceedings of the CSU-EPSA, 2024, 36(9):88-95.
- [15] 刘亚琿, 赵倩. 基于聚类经验模态分解的 CNN-LSTM 超短期电力负荷预测[J]. 电网技术, 2021, 45(11):4444-4451.
- LIU Y H, ZHAO Q. Ultra-short-term power load forecasting based on cluster empirical mode decomposition of CNN-LSTM [J]. Power System Technology, 2021, 45(11):4444-4451.
- [16] 赵一鸣, 吉月辉, 刘俊杰, 等. 基于 EMD-IPSO-LSTM 模型的短期电力负荷预测[J]. 国外电子测量技术, 2023, 42(1):132-137.
- ZHAO Y M, JI Y H, LIU J J, et al. Short term power load forecasting based on EMD-IPSO-LSTM model[J]. Foreign Electronic Measurement Technology, 2023, 42(1):132-137.
- [17] 江星星, 宋秋昱, 杜贵府, 等. 变分模式分解方法研究与应用综述[J]. 仪器仪表学报, 2023, 44(1):55-73.
- JIANG X X, SONG Q Y, DU G F, et al. Review on research and application of variational mode decomposition [J]. Chinese Journal of Scientific Instrument, 2023, 44(1):55-73.
- [18] 赵杰, 解则晓, 刘世萱. 基于能量熵 VMD 最优分解与 GRU 循环神经网络的潮汐预测精度提升方法研究[J]. 仪器仪表学报, 2023, 44(12):79-87.
- ZHAO J, XIE Z X, LIU SH X. Tide prediction accuracy improvement method research based on VMD optimal decomposition of energy entropy and GRU recurrent neural network [J]. Chinese Journal of Scientific Instrument, 2023, 44(12):79-87.
- [19] 张诗云, 朱菊香, 张涛, 等. 基于 VMD-DBO-LSTM 的空气质量预测[J]. 国外电子测量技术, 2024, 43(3):58-66.
- ZHANG SH Y, ZHU J X, ZHANG T, et al. Air quality prediction based on VMD-DBO-LSTM [J]. Foreign Electronic Measurement Technology, 2024, 43(3):58-66.

作者简介

肖震, 硕士研究生, 主要研究方向为电动汽车负荷预测以及优化调度。

E-mail: 52642301@qq.com

马强(通信作者), 副教授, 硕士生导师, 博士, 主要研究方向为车联网、信息智能处理。

E-mail: maqiang_my@163.com

杨震, 硕士研究生, 主要研究方向为智能电网。

E-mail: 1003291733@qq.com