

DOI: 10.19783/j.cnki.pspc.241360

基于多尺度二次特征提取的短期电力负荷预测模型

李楠^{1,2}, 金淳熙², 陶亮³, 黄亮³

(1. 现代电力系统仿真控制与绿色电能新技术教育部重点实验室, 吉林 吉林 132012; 2. 东北电力大学电气工程学院, 吉林 吉林 132012; 3. 国家电网吉林省电力有限公司四平供电公司, 吉林 四平 136000)

摘要: 为充分挖掘电力负荷固有多尺度特征(multi-scale feature, MSF)间的复杂时序关系, 进一步提升电力负荷预测模型性能, 特别是提升对节假日负荷预测的能力, 提出了一种基于多尺度二次特征提取的短期电力负荷预测模型。首先, 利用 Prophet 算法的拟合分解功能, 获取不同尺度下的负荷数据分量, 并与强相关的天气数据共同构建多元数据集。其次, 采用改进的特征金字塔网络(improved feature pyramid network, IFPN)匹配负荷数据的多尺度特性, 并设计了卷积特征增强模块强化对节假日特征的表达, 实现 MSF 的第一次提取。基于时间卷积神经网络的优势, 深度挖掘一次特征间的时序依赖关系, 引入 SENet 对特征的权重实现自适应赋值, 同时完成 MSF 的二次提取。最后, 利用鱼鹰算法优化后的 Transformer 模型完成负荷预测。在国内外两套负荷数据集上进行了验证, 仿真结果表明所提模型的预测效果优于对比模型, 特别是在对节假日负荷的预测精度上有所提高。

关键词: 短期电力负荷预测; Prophet 算法; 二次特征提取; 改进的特征金字塔网络; 多尺度时间卷积网络

A short-term electric load forecasting model based on multi-scale secondary feature extraction

LI Nan^{1,2}, JIN Chunxi², TAO Liang³, HUANG Liang³

(1. Key Laboratory of Modern Power System Simulation Control and Green Energy Technologies, Ministry of Education, Jilin 132012, China; 2. School of Electrical Engineering, Northeast Electric Power University, Jilin 132012, China; 3. Siping Power Supply Company, Jilin Electric Power Company Limited of State Grid Corporation of China, Siping 136000, China)

Abstract: To fully explore the complex temporal relationships among the inherent multi-scale features (MSF) of electrical load data and further improve the performance of electricity load forecasting models, especially their accuracy during holidays, a short-term electricity load forecasting model based on multi-scale secondary feature extraction is proposed. First, the Prophet algorithm is used to decompose and fit the load data, extracting components at different scales, which are then combined with correlated weather data to construct a multivariate dataset. Then, an improved feature pyramid network (IFPN) is employed to match the multi-scale characteristics of load data. A convolutional feature enhancement module is designed to strengthen the model's ability to express holiday-specific features, achieving the first extraction of MSF. Leveraging the advantages of temporal convolutional neural networks, the model deeply mines the temporal dependencies among the primary features. Squeeze-and-excitation networks (SENet) is introduced to adaptively assign weights to features, completing the secondary extraction of MSF. Finally, load forecasting is performed using a Transformer model optimized by the Osprey algorithm. Validation on two domestic and international load datasets shows that the proposed model outperforms comparison models, particularly in improving prediction accuracy during holidays.

This work is supported by the General Program of National Natural Science Foundation of China (No. 52277084).

Key words: short term power load forecasting; Prophet algorithm; secondary feature extraction; IFPN; MSTCN

0 引言

近年来, 大量新型能源的并网与消纳以及电动

汽车等灵活多变的负荷加入, 使传统电力系统不断地发展并演变为新型电力系统, 同时也加剧了电力负荷预测的难度^[1-2]。

面对新型电力系统复杂多变的负荷形式, 基于统计学的传统预测方法^[3-4]难以构建精准的负荷模

基金项目: 国家自然科学基金面上项目资助(52277084)

型,预测性能已达不到电力系统的运行与管理要求。电网智能化及电力物理信息系统的开发为数据驱动型负荷预测方法提供了数据支持,随着人工智能算法的快速发展,传统机器学习^[5-6]与深度学习算法^[7-10]能直接利用海量历史数据,考虑多种数据间的潜在关联,自动地挖掘数据中的有效信息特征,特别是深度学习算法还能进一步挖掘数据的时序依赖关系^[11-12],在电力负荷预测方面展现出强大的能力。然而,由于节假日的不确定性及负荷类型的复杂多变等因素,电力负荷的随机性、非线性与非平稳性显著增强。在此背景下,如何深入挖掘负荷特征信息,进一步提升负荷预测模型的综合性能与泛化能力,已成为当前研究的热点问题。

对已有研究成果分析可知,针对提升电力负荷预测性能这一问题,国内外学者主要是从电力负荷数据预处理及提升模型特征提取能力两个方面展开研究。在数据预处理方面,目前普遍采用小波变换(wavelet transform, WT)^[13-14]、经验模态分解(empirical mode decomposition, EMD)^[15-16]以及变分模态分解(variational mode decomposition, VMD)^[17-19]等时频分解算法对原始电力负荷数据进行分解,进而获得不同分辨率下的分量信息,将其送入模型进行预测。在上述方法中,WT虽然能对原始数据的多分辨率信息进行细化分解,但分解效果高度依赖于母小波和分解层数的选择,其自适应性较差。EMD算法具有自适应性,但存在端点效应及模态混叠问题。改进的EMD算法^[20-21]通过添加噪声来抑制模态混叠,但由于添加噪声次数有限,不可避免地存在噪声残留的问题。VMD算法通过构造并求解约束变分问题,能有效地将目标数据分解成为指定个数的固有模态分量。改进的VMD算法^[22-23]引入优化算法,可以对分解固有模态分量的数量进行寻优,具有一定的自适应性。但VMD算法是将多分量信号分解成多个单分量的调幅调频信号,无法有效地拟合电力负荷中的准周期分量,且该算法对噪声具有高敏感性,在噪声干扰下仍会出现模态混叠现象。而在电力负荷数据的处理问题上,除了考虑不同分辨率下信息特征对模型精度的影响,还应注意节假日效应以及社会突发事件等随机因素对预测性能的影响。

在提升模型特征提取能力方面,通常采用的方案是增减卷积核的感受野来改变特征的维度,在模型网络架构中嵌入多种注意力机制模块,重新分配特征的权重,进而提升模型的特征提取能力。文献[24]使用卷积神经网络和门控循环单元捕捉历史数据的时频特征,引入多头注意力机制对输入特征赋权,强化了重要特征的表达能力,提升了模型

的精度。文献[25]通过改进时间卷积网络(temporal convolutional network, TCN)的卷积结构,利用不同尺寸的因果卷积核扩大感受野,构建多尺度通道特征提取层,并嵌入高效通道注意力模块提高了模型对于长时序数据的挖掘能力。文献[26]采用图神经网络与TCN相结合,聚合多维时空特征,有效地提取了相邻目标特征,并利用Transformer中的多头注意力层捕捉重要特征,使得模型特征提取更加全面。但离线训练好的预测模型在线运行时,面临节假日等不确定因素的影响,预测性能会陡然下降,给电力调度人员的决策及电力系统的安全运行带来一定的隐患。

为了更好地挖掘不同尺度下的信息特征,同时兼顾节假日效应的影响,本文采用Prophet算法对负荷数据进行分解,并将其分解后的数据分量与强相关的气象数据分量共同构建数据集,进而提出了一种多尺度二次特征提取方法。首先,利用改进的特征金字塔网络(improved feature pyramid network, IFPN)对多尺度信息特征进行挖掘,设计了卷积特征增强模块对节假日信息特征予以强化;然后,通过在TCN中嵌入SENet模块实现多尺度特征的二次提取及权重的自适应重新分配,有效地促进了多尺度特征的跨通道交互,自适应地强化了模型对重要负荷特征的表达能力;最后,将所提取的特征输入到Transformer模型中进行预测。在国内外两种数据集上设计了仿真实验,验证了本文所提方法的有效性以及泛化能力。

本文所提模型的主要优势体现在以下方面。

1) 在数据分解层面,Prophet算法在处理复杂的历史负荷数据时展现出优异的拟合效果,它不仅能有效地获取节假日信息,还能按周、月、年等时间尺度对电力负荷数据进行精细分解。

2) 在特征提取层面,IFPN模块可以有效捕捉多尺度特征的全局信息,在TCN中嵌入SENet注意力模块可以捕捉多尺度特征之间的时序依赖性,并对不同通道的特征进行自适应地赋权。

3) 在模型预测层面,Transformer模型拥有并行处理时序特征的能力,与多尺度特征相匹配;模型中的多头注意力层可以高效挖掘多尺度特征之间复杂的非线性关系,有效提升模型在不同尺度下的负荷预测精度。

1 多尺度二次特征提取方法

1.1 Prophet算法的原理

Prophet是一种集数据分解与预测的多功能时序数据分析算法。该算法的分解功能^[27]是选取不同

的拟合模型,按周、月、年对时间序列数据的变化规律进行拟合,同时根据给定节假日的先验信息,将时间序列数据分解为趋势分量、周期分量、节假日分量和残差分量,具体分解如式(1)所示。

$$y(t) = g(t) + s(t) + h(t) + \varepsilon(t) \quad (1)$$

式中: $y(t)$ 为原始的时间序列数据; $g(t)$ 为趋势分量,表征时间序列数据的整体变化趋势; $s(t)$ 为周期分量,包括日分量与周分量; $h(t)$ 为节假日分量,其与 Prophet 算法中内置的国家日历信息相关; $\varepsilon(t)$ 为残差分量,表征突发及随机事件引起的负荷波动信息。

在对电力负荷数据进行分解时,趋势分量的拟合模型需根据电力负荷历史数据的统计特征分析进行选择,不同的负荷增长模式应选取不同的拟合模型。若负荷增长或减小的模式以某种恒定的规律出现,选取如式(2)所示的线性模型;若负荷数据的增长是以饱和形势出现,则选取如式(3)所示的逻辑回归模型。

$$g(t) = (k + \mathbf{a}(t)^T \delta)t + (\rho + \mathbf{a}(t)^T \gamma) \quad (2)$$

$$g(t) = \frac{C(t)}{1 + \exp(-(k + \mathbf{a}(t)^T \delta)(t - \rho + \mathbf{a}(t)^T \gamma))} \quad (3)$$

$$\mathbf{a}(t) = \begin{cases} 1 & t \geq s_j \\ 0 & \text{其他} \end{cases} \quad (4)$$

式中: $C(t)$ 为随时间变化的模型渐近值; k 为负荷增长率; δ 、 γ 为增长率的变化量; ρ 为偏移量参数, $\mathbf{a}(t)$ 为指示函数; s_j 为电力负荷数据中第 j 个增长率变化点所在的时刻。

对于电力负荷数据中存在的周期分量,可以采用傅里叶级数进行拟合,拟合公式如式(5)所示。

$$s(t) = \sum_{n=1}^{\varphi} a_n \cos\left(\frac{2\pi n t}{P}\right) + b_n \sin\left(\frac{2\pi n t}{P}\right) \quad (5)$$

式中: P 为周期,周分量中 P 的取值为 7,日分量中 P 的取值为 1; a_n 、 b_n 为加权系数; φ 为加权系数 a_n 和 b_n 的个数; n 为加权系数的序号。

相较于工作日,节假日通常会使得所在地区的工作模式及用电模式发生变化,从而导致负荷数据出现波动。因此,需考虑节假日产生的负荷波动这一特征信息,进一步提升短期电力负荷预测的精度。根据 Prophet 算法中内置的日历信息构建稀疏向量 $\mathbf{Z}(t)$,如式(6)所示。

$$\mathbf{Z}(t) = [I(t \in D_1), \dots, I(t \in D_l), \dots, I(t \in D_L)] \quad (6)$$

式中: D_l 为当前节假日及其前后部分日期的集合,其中 $l=1,2,\dots,L$; I 表示 $\{0,1\}$ 的集合,当给定日期为节假日, I 为 1,否则为 0。

设置 ν 为反映节假日影响的先验变化参数,表

征节假日效应对电力负荷的影响,其满足中心极限定律下的正态分布 $\nu \sim N(0, \xi^2)$, ξ 可根据 Prophet 算法中内置的节假日类型及效应强度进行设置,然后通过 $\mathbf{Z}(t)$ 与 ν 构建节假日回归分量 $h(t)$ 。

$$h(t) = \mathbf{Z}(t)\nu \quad (7)$$

以新加坡 2018 年—2019 年的电力负荷数据为例,原始负荷曲线如附录 A 图 A1(a)所示,采用 Prophet 算法分解后的各项分量如图 A1(b)—图 A1(e)所示,从图 A1(b)趋势分量中的规律可知,新加坡地区用电高峰期集中在每年的 6 月到 9 月,这是由于夏季空调以及其他家用电器增多引起的。图 A1(c)为日分量曲线,在上午 10:00 至下午 16:00 呈现出一天中的用电高峰,反映了人们的工作需求和用电习惯。图 A1(d)中的周分量曲线拟合了新加坡地区一周内的用电规律,其中每周的用电高峰期集中在星期二到星期五之间。图 A1(e)中节假日分量则反映了节假日效应带来的负荷波动。电力负荷经 Prophet 算法分解后,除趋势分量外,各分量均有正负值出现的情况,正负值反映了其他分量以趋势分量为基准上升或下降的变化量,使分解后的各分量之和能逼近原始负荷值。

1.2 基于 IFPN 网络的一次特征提取

为了捕捉不同分辨率下的信息特征,文献[28]提出了一种特征金字塔网络(feature pyramid network, FPN),采用自上而下及横向连接的方式,进行平均池化操作后,采用不同尺寸的卷积核提取多尺度特征并进行拼接,实现了不同尺度特征信息的融合及共享。对电力负荷数据进行 Prophet 分解,由于节假日特征具有较强的稀疏性,且波动性也相较于其他特征更高,因此对节假日的负荷预测难度较大。为了提升模型对节假日特征的敏感度,本文在 FPN 基础上增加了卷积特征增强模块,提出一种改进的特征金字塔网络(improved feature pyramid network, IFPN),其网络结构如图 1 所示,特征提取流程如下所述。

1) 输入数据集构建

对电力负荷历史数据进行 Prophet 分解,得到节假日分量 h_1 、日分量 h_2 、周分量 h_3 以及趋势分量 h_4 ,将它们与所筛选的天气数据 h_5 共同构成多元变量矩阵 $\mathbf{H} \in R^{M \times N}$, M 为各项分量的长度, N 为各项分量的类别,其定义如式(8)所示。

$$\mathbf{H} = [h_1, h_2, h_3, h_4, h_5] \quad (8)$$

2) 平均池化操作

采用 2×1 的池化层对 \mathbf{H} 中的各项分量分别进行平均池化操作,得到池化矩阵 $\mathbf{H}_{\text{pool}} \in R^{m_1 \times N}$, m_1 为池化后的数据长度,池化后各分量的类别维持不变。

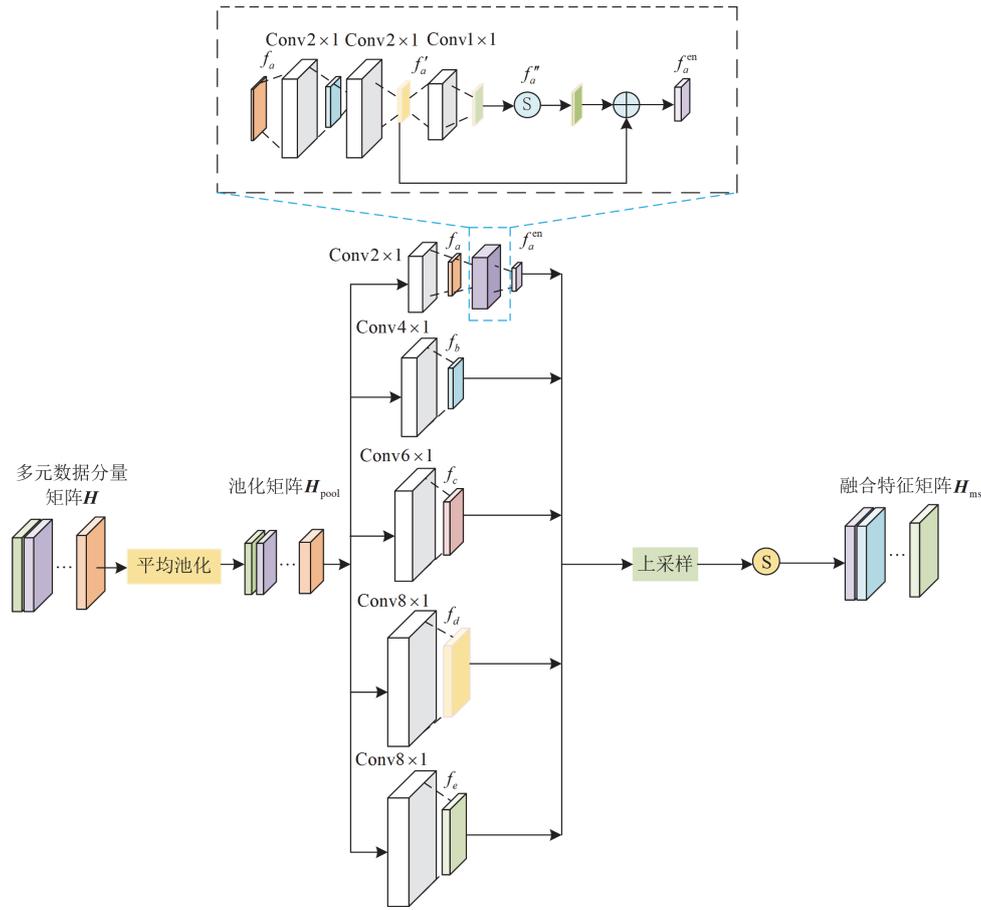


图 1 IFPN 特征提取网络

Fig. 1 IFPN feature extraction network

3) 特征提取

根据各项分量所呈现出的时间尺度信息, 按照小尺寸的卷积核适配高频、小时间尺度分量, 大尺寸的卷积核适配低频、大时间尺度分量, 实现多尺度的特征提取。并且根据大量仿真经验可知, 即使采用不同尺寸的卷积核提取某一分量的特征信息, 若保证各分量按照上述规律选择各自的卷积核尺寸, 则模型整体的预测精度偏差不大。在本文中, 为简化计算复杂度, 选取 2×1 卷积核提取节假日特征信息 f_a ; 选取 4×1 和 6×1 的卷积核提取以天和周变化的日特征信息 f_b 和周特征信息 f_c ; 由于天气分量与趋势分量都具有季节性的变化规律, 选取 8×1 的卷积核提取趋势特征信息 f_d 以及天气特征信息 f_e 。

4) 节假日特征增强

为了强化节假日特征信息的表达能力, 选用 2×1 的因果卷积核, 采用级联方式对 f_a 进一步提取其局部特征信息, 记为 f'_a , 经过 1×1 卷积运算后, 利用 Sigmoid 函数按特征重要性对其进行缩放, 记

为 f''_a , 将其添加到 f'_a 中得到增强后的节假日特征信息 f_a^{en} , 计算公式如式(9)所示。

$$f_a^{\text{en}} = f'_a + f''_a \quad (9)$$

5) 拼接

为将特征还原为原始数据分量的维度, 对提取的特征信息进行上采样并进行拼接, 得到的特征矩阵记为 $\mathbf{H}_{\text{ms}} \in R^{M \times N}$, 该操作实现了多尺度特征信息的融合, 计算公式如式(10)所示。

$$\mathbf{H}_{\text{ms}} = [F_a^{\text{en}}, F_b, F_c, F_d, F_e] \quad (10)$$

式中: F_a^{en} 、 F_b 、 F_c 、 F_d 、 F_e 为经过上采样处理后的各类特征。

1.3 基于 MSTCN 网络的二次特征提取

为了进一步捕捉多尺度特征中的时序依赖关系, 并可对多尺度特征自适应赋权, 通过改进 TCN 模型中的残差模块同时引入 SENet 注意力机制, 提出了一种基于多尺度时间卷积网络(multi scale temporal convolutional network, MSTCN)的二次特征提取方法。该方法挖掘了不同尺度下特征中所隐

藏的时序信息，同时强化了不同尺度下重要特征的表达能力。MSTCN 结构示意图如图 2 所示，二次

特征提取流程如下所述。

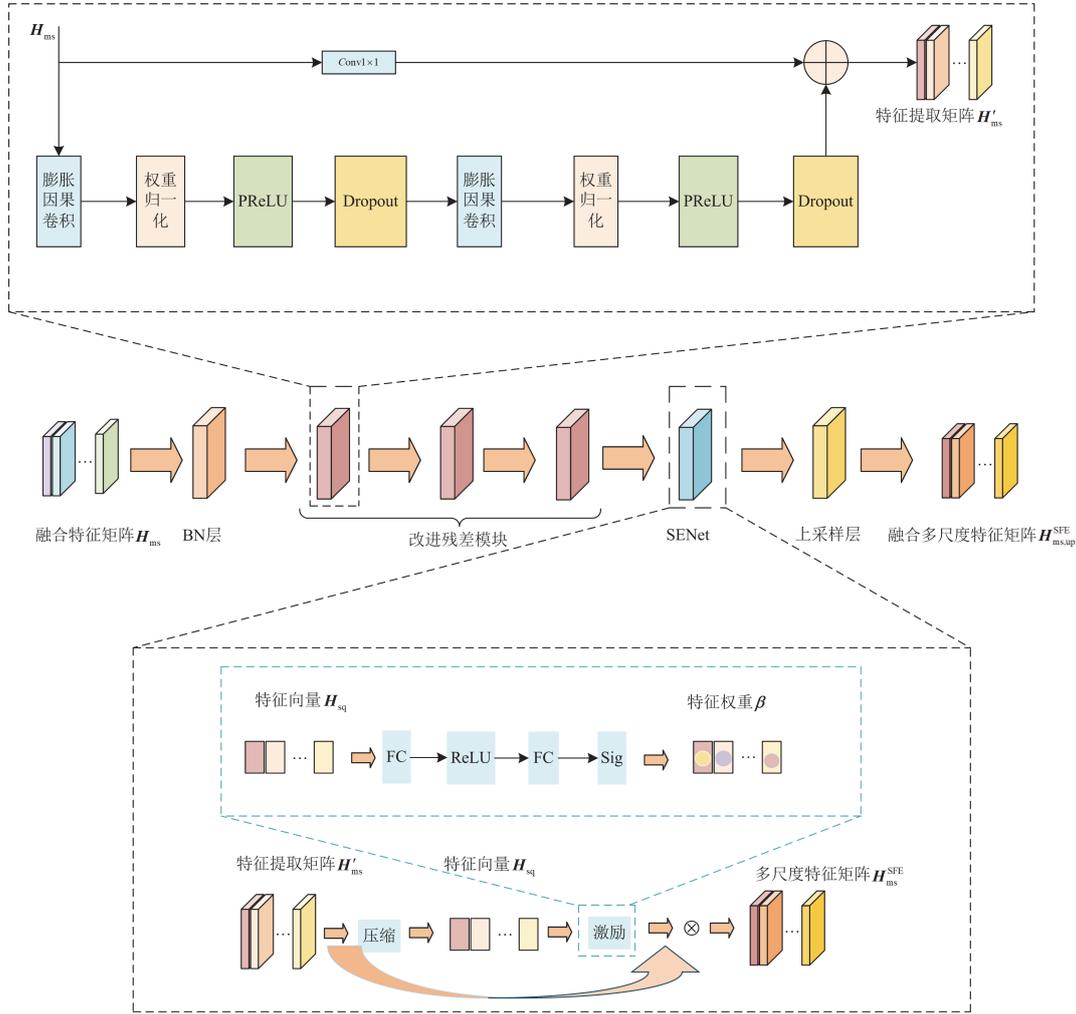


图 2 MSTCN 结构示意图

Fig. 2 Schematic diagram of MSTCN structure

1) 特征矩阵预处理

为解决传统 TCN 模型对于负值特征提取后赋值为 0 的问题，首先将融合特征矩阵 H_{ms} 输入批归一化(batch normalization, BN)层进行处理，以加快模型收敛速度，采用 Parametric ReLU 作为激活函数，将其嵌入到 TCN 的残差模块中以避免出现神经元坏死现象，提高模型的鲁棒性，其映射关系如式(11)所示。

$$PReLU(x) = \begin{cases} x, & x > 0 \\ \alpha x, & x \leq 0 \end{cases} \quad (11)$$

式中： α 为超参数，该参数可以通过训练得到； x 为多尺度特征信息。

2) 二次特征提取

采用残差网络中具有不同感受野的膨胀因果卷

积对 H_{ms} 中的多尺度特征信息进行二次提取，将提取后的特征矩阵记为 $H'_{ms} \in R^{m_2 \times N}$ ， m_2 为二次特征提取后的数据长度，提取后各分量的类别维持不变。提取所用卷积的感受野计算如式(12)所示。

$$\theta_{RF} = (K_{size} - 1)(2^\tau - 1) + 1 \quad (12)$$

式中： θ_{RF} 为二次特征提取所用卷积的感受野； K_{size} 为卷积核大小； τ 为卷积层数。

3) 特征矩阵的压缩与激励

对于二次特征提取后的矩阵 H'_{ms} ，引入 SENet 模块(SENNet 基本原理参见文献[29])对其进行挤压、缩放以及重标定操作，捕捉特征之间的深层相关性。

使用与特征尺寸相匹配的平均池化层对多尺度特征矩阵 H'_{ms} 进行压缩操作，该操作记作 F_{sq} ，将

多尺度特征矩阵压缩为一个特征向量 $\mathbf{H}_{sq} \in R^{1 \times N}$, 其计算公式如式(13)所示。

$$\mathbf{H}_{sq} = F_{sq}(\mathbf{H}'_{ms}) = \sum_{m=1}^{m_2} \frac{\mathbf{H}'_{ms}}{m_2} \quad (13)$$

在激励操作中, 通过两个全连接层 (fully connected, FC) 和非线性 Sigmoid 函数来捕捉通道间的深层关联性, 自主学习通道的重要性并生成通道的权重向量 β , 计算公式如式(14)所示。

$$\beta = \sigma[W_2 \text{ReLU}(W_1 \mathbf{H}_{sq})] \quad (14)$$

式中: W_1 、 W_2 为全连接层的参数; σ 表示非线性 sigmoid 激活函数。

4) 特征矩阵重标定

将权重系数 β 与二次特征提取后的特征矩阵 \mathbf{H}'_{ms} 进行相乘, 得到具有自适应权重的多尺度特征矩阵 $\mathbf{H}_{ms}^{\text{SFE}} \in R^{m_2 \times N}$, 其计算公式如式(15)所示。

$$\mathbf{H}_{ms}^{\text{SFE}} = \beta \mathbf{H}'_{ms} \quad (15)$$

将矩阵 $\mathbf{H}_{ms}^{\text{SFE}}$ 送入上采样层后输出融合多尺度特征矩阵 $\mathbf{H}_{ms,up}^{\text{SFE}} \in R^{M \times N}$ 。

2 基于多尺度二次特征提取的预测模型

2.1 Transformer 预测模型

为了能准确捕捉提取后的多尺度特征信息, 本文采用具有多头注意力机制的 Transformer 模型进行短期电力负荷预测。Transformer 模型结构包括位置嵌入层、多头注意力层以及前馈神经网络层, 结构图如附录 A 图 A2 所示。为确定电力负荷特征的位置信息, 在多尺度特征矩阵中引入位置编码 $\mathbf{H}_{T,PE}$, 编码公式如式(16)和式(17)所示。

$$\mathbf{H}_{T,PE}^{P_{pos}, 2i} = \sin(P_{pos} / 10000^{2i/N}) \quad (16)$$

$$\mathbf{H}_{T,PE}^{P_{pos}, 2i+1} = \cos(P_{pos} / 10000^{2i/N}) \quad (17)$$

式中: P_{pos} 为多尺度特征位于特征矩阵的位置; i 表示 $\mathbf{H}_{ms,up}^{\text{SFE}}$ 中的第 i 个时间步长。

将 $\mathbf{H}_{T,PE}$ 加入到矩阵 $\mathbf{H}_{ms,up}^{\text{SFE}}$, 得到具有位置编码信息的多尺度特征矩阵 \mathbf{H}_{en} , 其计算如式(18)所示。

$$\mathbf{H}_{en} = \mathbf{H}_{ms,up}^{\text{SFE}} + \mathbf{H}_{T,PE} \quad (18)$$

多头注意力层对多尺度矩阵 \mathbf{H}_{en} 进行权值计算, 得到含有映射权重的电力负荷特征 \mathbf{X}_{att} , 然后使用前馈连接层挖掘多尺度特征之间的非线性关系, 输出预测的电力负荷特征 \mathbf{X}_{out} 。

2.2 预测整体流程

本文提出的基于多尺度二次特征提取的短期电

力负荷预测模型框架如图 3 所示。

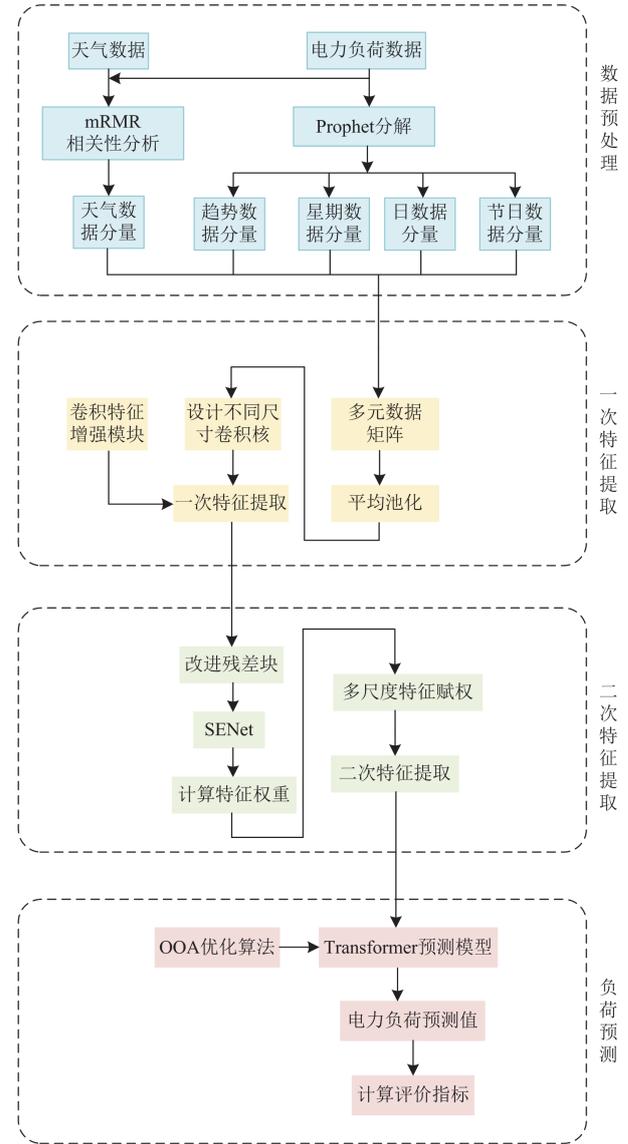


图 3 负荷预测模型框架

Fig. 3 Framework of load forecasting model

模型预测主要步骤如下所述。

1) 使用 Prophet 算法将电力负荷数据分解为趋势分量、日分量、周分量以及节假日分量, 随后与经过 mRMR 算法筛选后得到的相关性高的气象数据分量特征进行拼接融合, 得到多元分量矩阵。

2) 将多元分量矩阵送入 IFPN, 经过平均池化操作, 选用不同尺寸卷积核提取相应尺度的特征信息, 利用特征增强模块提高节假日分量的表达能力, 实现了电力负荷数据多尺度下的一次特征提取;

3) 在 TCN 中引入 SENet 模块, 对一次提取后的多尺度特征进行自适应赋权, 学习并强化重要特征的表征能力, 加强了预测模型对关键特征信息的

感知能力, 实现了电力负荷数据多尺度下的二次特征提取;

4) 利用 Transformer 的多头自注意力机制学习电力负荷特征的映射关系, 并使用鱼鹰优化算法 (osprey optimization algorithm, OOA) 优化模型的超参数, 最终获得负荷预测结果。

3 算例分析

本文使用的模型均基于 PyTorch 环境编译, 编译器是 PyCharm2022, 硬件平台采用 Intel i7-11700 处理器, NVIDIA RTX 3070 显卡, 运行内存为 32 G。本文采用 OOA 对超参数进行寻优。Prophet 分解算法中: lower window 设置为-24, upper window 设置为 24, 训练步长设置为 100, 其他参数均为默认。MSTCN 参数设置为: 卷积核个数 34, 卷积核大小为 3, dropout 为 0.2, 降维系数 μ 为 16, Parametric ReLU 中的激活系数为 0.01, 学习率为 0.001。Transformer 预测模型中学习率设置为 0.001, 训练周期为 150, 学习率衰减率为 0.1。

3.1 模型性能评价指标及数据相关性分析

负荷预测模型性能采用平均绝对百分比误差 (mean absolute percentage error, MAPE)、平均绝对误差 (mean absolute error, MAE) 和均方根误差 (root mean squared error, RMSE) 3 个指标进行衡量, 计算公式分别如式(19)一式(21)所示。

$$\Delta_{MAPE} = \frac{1}{M} \sum_{\psi=1}^M \left| \frac{X_{\psi}^{out} - X_{\psi}^{act}}{X_{\psi}^{act}} \right| \quad (19)$$

$$\Delta_{MAE} = \frac{1}{M} \sum_{\psi=1}^M |X_{\psi}^{out} - X_{\psi}^{act}| \quad (20)$$

$$\Delta_{RMSE} = \sqrt{\frac{1}{M} \sum_{\psi=1}^M (X_{\psi}^{out} - X_{\psi}^{act})^2} \quad (21)$$

式中: X_{ψ}^{out} 和 X_{ψ}^{act} 分别为测试集中第 ψ 个时间点上的预测负荷值和真实负荷值。RMSE、MAE、MAPE 数值上越接近 0, 表示模型的预测精度越高。

短期电力负荷预测受诸多外部因素影响, 其中气象因素影响尤为明显, 为有效筛选与负荷相关性高的天气特征, 本文使用最大相关和最小冗余算法进行相关性分析, 结果如图 4 所示。选用相关系数大于 0.7 的气压、风速、温度以及湿度与电力负荷数据共同构建样本数据集。

3.2 新加坡负荷的预测性能分析

算例 1 采用新加坡电网 2018 年—2019 年的 17 569 条电力负荷数据, 按照 7:3 划分训练集与测试集, 验证本文所提预测模型的有效性以及对节假日

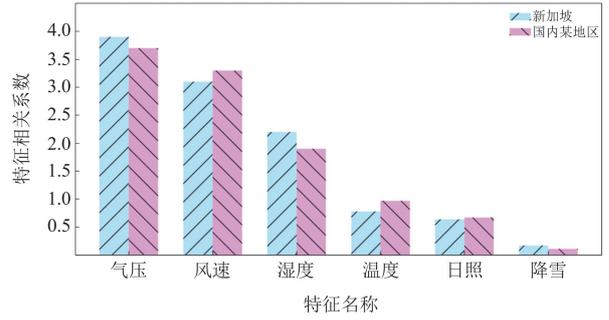


图 4 mRMR 特征相关性分析

Fig. 4 Relevance analysis of mRMR feature

日的预测精度, 并与其他 5 种预测模型进行对比分析。

3.2.1 预测模型整体性能分析

选取 TCN、Transforemr 两种单一模型以及 CEEMD-DBN、AC-BiLSTM、LSTM-XGBoost 3 种组合模型与本文所提模型进行对比分析, 仿真结果如表 1 所示。

表 1 不同模型对新加坡负荷整体预测性能对比

Table 1 Comparative analysis of overall load forecasting performance in Singapore with different models

模型	MAE/MW	RMSE/MW	MAPE/%
TCN	109.1253	160.0529	1.6499
Transformer	103.1686	147.5159	1.7838
CEEMD-DBN ^[30]	63.8239	80.1217	1.1246
AC-BiLSTM ^[31]	70.8945	84.2747	1.0457
LSTM-XGBoost ^[32]	63.5773	78.3328	1.0565
本文所提模型	36.2738	46.4145	0.6326

由表 1 可知, 相对于单一模型 TCN、Transformer, 本文所提模型的 MAE 分别下降了 72.8515 MW 及 66.8948 MW, RMSE 分别下降了 113.6348 MW 及 101.1014 MW, MAPE 分别下降了 1.0173% 及 1.1512%。在与组合模型对比中, 相较于 CEEMD-DBN、AC-BiLSTM、LSTM-XGBoost, 本文所提模型的 MAE 分别下降了 27.5501 MW、34.6207 MW 和 27.3035 MW, RMSE 分别下降了 33.7072 MW、37.8602 MW 以及 31.9183 MW, MAPE 分别下降了 0.492%、0.4131% 和 0.4239%。综上, 相较于其他 5 种模型, 本文所提模型拟合出的预测值最接近真实负荷, 具有更加精准的预测性能。

3.2.2 节假日负荷预测性能分析

为测试不同类型的节假日对于负荷预测精度产生的影响, 将节假日类型进行细化, 将处在工作日的节假日定义为 I 型节假日, 将处在休息日的节假日定义为 II 型节假日, 选择 8 月 9 日和 12 月 25 日的 I 型节假日及 8 月 11 日和 10 月 27 日的 II 型节

假日, 对不同预测模型的性能进行测试, 结果如表 2 所示。从表 2 可以看出, 由于本文所提模型采用 Prophet 分解算法获取了节假日数据分量, 并利用二次

特征提取模块进行特征信息的提取和增强, 因此无论是对处于工作日的节假日, 还是对处于休息日的节假日, 性能指标均优于单一模型和组合模型。

表 2 不同预测模型对新加坡节假日负荷预测的性能对比

Table 2 Comparative analysis of performance of different models for load forecasting during Singaporean holidays

模型	指标	I 型节假日		II 型节假日	
		8.9	12.25	8.11	10.27
TCN	MAE/MW	226.2026	231.8224	229.7591	221.3178
	RMSE/MW	294.8496	292.7322	290.0443	301.9498
	MAPE/%	5.1807	5.6178	5.4226	5.3951
Transformer	MAE/MW	231.5455	232.8052	236.9032	230.8895
	RMSE/MW	294.6661	298.5375	307.5887	299.3932
	MAPE/%	5.8772	6.8648	5.0145	5.6918
CEEMD-DBN	MAE/MW	78.2203	96.4956	70.4369	90.7226
	RMSE/MW	138.8819	157.4043	132.8162	152.0660
	MAPE/%	3.0823	3.1724	2.8345	3.0958
AC-BiLSTM	MAE/MW	66.3773	71.8557	85.0181	83.2078
	RMSE/MW	128.8644	107.6327	148.6761	144.0364
	MAPE/%	2.2499	2.8621	2.8019	2.8563
LSTM-XGBoost	MAE/MW	63.2172	58.0199	76.7874	59.6570
	RMSE/MW	113.8775	109.2559	138.3257	121.0396
	MAPE/%	2.5394	2.3334	3.0478	2.4737
本文所提模型	MAE/MW	46.7198	45.6624	47.8997	47.0355
	RMSE/MW	59.9288	58.9568	61.3729	60.5441
	MAPE/%	0.8165	0.8065	0.8893	0.8731

3.3 国内某地区负荷的预测性能分析

算例 2 采用国内某地区电网 2022 年 8784 条电力负荷数据, 同样按照 7:3 划分训练集与测试集, 验证所提模型在该地区的有效性以及对节假日预测的精准度, 并与其他 5 种预测模型进行对比分析。

3.3.1 预测模型整体性能分析

选取与算例 1 中相同的模型进行仿真对比分析, 仿真结果如表 3 所示。由表 3 可知, 相较于单一模型 TCN、Transformer, 本文所提模型的 MAE 分别下降了 49.7308 MW、46.3389 MW, RMSE 分别下降了 56.2578 MW、49.7141 MW, MAPE 分别下降了 1.8907%、2.055%。本文所提模型相较于 3

表 3 国内某地区各模型整体预测误差对比

Table 3 Comparison of overall prediction errors across models for a specific region in China

模型	MAE/MW	RMSE/MW	MAPE/%
TCN	79.2057	100.5472	2.6818
Transformer	75.8138	94.0035	2.8461
CEEMD-DBN	46.9316	60.1193	1.8263
AC-BiLSTM	48.6843	75.9544	1.9754
LSTM-XGBoost	43.2494	65.4085	1.7528
本文所提模型	29.4749	44.2894	0.7911

种组合预测模型 CEEMD-DBN、AC-BiLSTM、LSTM-XGBoost, MAE 分别下降了 17.4567 MW、19.2094 MW、13.7745 MW, RMSE 分别下降了 15.8229 MW、31.665 MW、21.1191 MW, MAPE 分别下降了 1.0352%、1.1843%、0.9617%。综上, 在其他外部因素相同的情况下, 相较于所选用的 5 种对比预测模型, 本文所提模型对于整体负荷的预测依然可以保持良好的精度, 证明了所提模型在不同样本数据集上的有效性, 具有良好的泛化能力。

3.3.2 节假日负荷预测性能分析

选取国庆节期间 7 个节假日进行仿真分析, 其中 10 月 1 日至 10 月 2 日为 II 型节假日; 10 月 3 日至 10 月 7 日为 I 型节假日, 预测结果如表 4 所示。从表 4 可知, 单一模型对于节假日的预测性能最差, 而 3 种组合模型 CEEMD-DBN、AC-BiLSTM、LSTM-XGBoost 相较于单一模型效果更好, 而本文所提模型相较于 3 种组合模型, 预测性能均有所提高, 这说明所提模型对于节假日类型负荷具有较好的泛化性能。

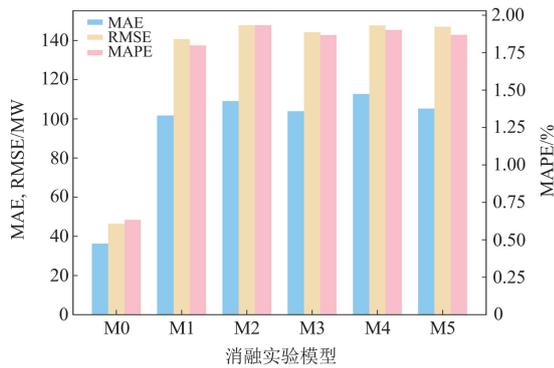
3.4 消融实验

为了验证本文所设计的关键模块的有效性, 使用如表 5 中所示的实验模型分别对电力整体负荷以及节假日负荷进行预测, 预测结果如图 5—图 7 所示。

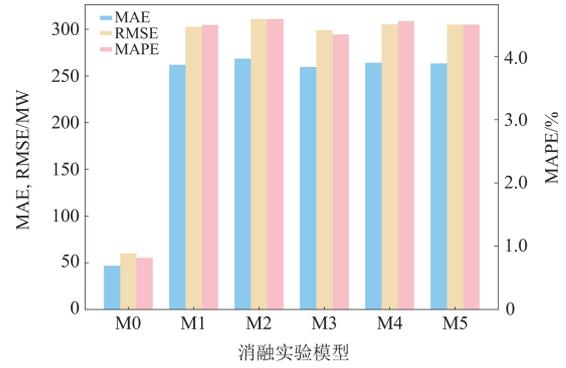
表 4 该模型对国内某地区节假日的预测结果

Table 4 Prediction results of the model for domestic holidays in China

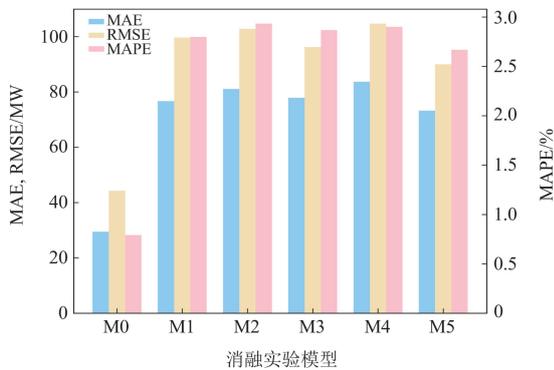
模型	指标	I 型节假日					II 型节假日	
		10.3	10.4	10.5	10.6	10.7	10.1	10.2
TCN	MAE/MW	174.2581	182.3646	184.0921	179.5537	167.0738	180.5486	172.3065
	RMSE/MW	222.4704	199.9625	201.9204	198.9251	185.3875	207.6577	191.3875
	MAPE/%	9.3317	7.8852	8.2572	8.0391	6.7872	8.5303	7.9549
Transforemr	MAE/MW	170.8164	194.4306	182.1104	190.8796	187.3736	190.3748	203.5874
	RMSE/MW	198.9464	249.4092	235.4135	247.1323	231.0516	227.6289	258.9002
	MAPE/%	7.8192	9.6387	8.1843	9.3638	7.4131	9.6796	9.8012
CEEMD-DBN	MAE/MW	82.3631	74.4364	78.7416	91.0704	91.2581	70.8787	88.8831
	RMSE/MW	146.1113	138.2639	142.0247	153.8914	154.3717	130.8783	151.6592
	MAPE/%	5.7433	5.2326	5.1109	6.4656	6.8273	4.4195	5.8404
AC-BiLSTM	MAE/MW	92.5221	72.0705	62.0662	71.4792	63.2397	83.2916	88.2981
	RMSE/MW	153.4680	133.5876	124.0157	132.6341	133.8063	144.7731	149.3952
	MAPE/%	6.8297	5.6056	4.9694	5.5178	4.9088	6.3349	6.4515
LSTM-XGBoost	MAE/MW	102.787	70.1257	81.3620	68.3476	48.8679	75.6321	56.336
	RMSE/MW	178.224	131.4056	143.6275	130.0364	110.6007	137.8093	106.7792
	MAPE/%	7.7656	4.7934	6.7219	5.3401	3.8576	5.1928	4.3138
本文所提模型	MAE/MW	36.0878	35.9137	36.4051	29.7021	18.3101	32.3552	22.4202
	RMSE/MW	45.5276	51.7909	52.6623	44.8145	30.0547	48.9418	32.0739
	MAPE/%	1.0694	1.4074	1.3782	0.9486	0.6449	1.0836	1.1333



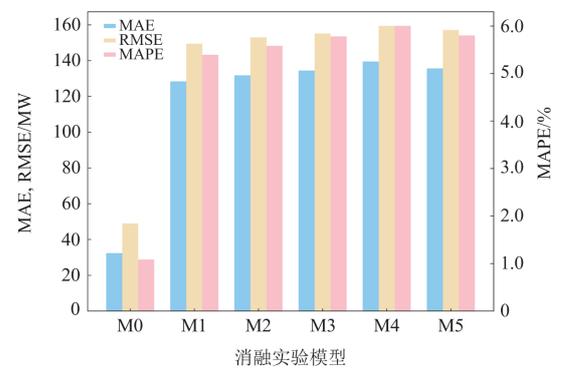
(a) 新加坡消融实验结果



(a) 新加坡I型节假日消融结果



(b) 国内某地区消融实验结果



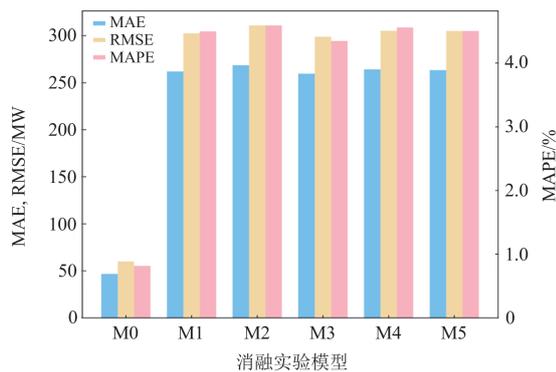
(b) 国内某地区I型节假日消融结果

图 5 电力负荷预测消融实验结果

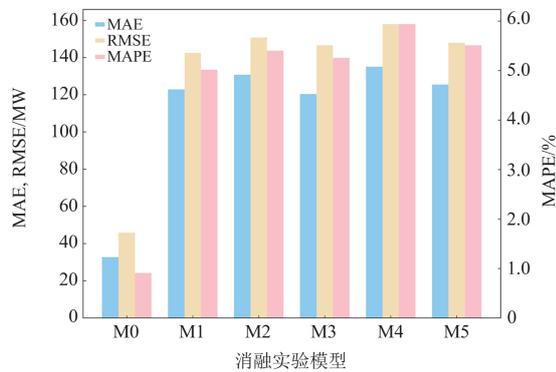
Fig. 5 Ablation experimental results for electric load forecasting

图 6 I 型节假日消融实验结果

Fig. 6 Ablation experimental results for type I holiday load forecasting



(a) 新加坡II型节假日消融结果



(b) 国内某地区II型节假日消融结果

图7 II型节假日消融实验结果

Fig. 7 Ablation experimental results for type II holiday load forecasting

表5 消融实验模型

Table 5 Ablation experiment models

模型	IFPN 特征提取网络	卷积特征增强模块	MSTCN 二次特征提取网络	SENet 通道注意力机制	Prophet 分解算法
M0	✓	✓	✓	✓	✓
M1	✓	-	✓	✓	✓
M2	-	-	✓	✓	✓
M3	✓	✓	✓	-	✓
M4	✓	✓	-	-	✓
M5	✓	✓	✓	✓	-

由图5可知, M1模型的预测效果优于M2, 证明了IFPN特征提取网络有效地捕捉并提取了不同分辨率下的特征; M0模型的预测效果优于M1则证明了本文所提的卷积特征增强模块强化了节假日特征的表达能力, 有效提升了模型对于负荷整体的预测精度; M3模型的预测效果优于M4, 表明使用SENet通道注意力对多尺度特征赋权, 有效捕捉了不同尺度特征的重要性; M0优于M3表明了所提的MSTCN二次特征提取模块适合挖掘多尺度特征之

间隐藏的时序依赖关系; M0优于M5则说明Prophet分解算法为预测模型提供了更丰富的多尺度特征信息。

由图6和图7可知, 在两类节假日负荷预测中, M1模型的性能均优于M2, 且M0的性能均优于M1, 这证明了IFPN一次特征提取网络以及卷积特征增强模块有效增强了模型对于节假日效应的敏感度, 提升了模型对于节假日负荷预测的精度; M3模型的性能均优于M4, 且M0的性能均优于M3, 这表明MSTCN二次特征提取网络以及SENet注意力机制模块有效地强化了节假日特征的表达能力; M0性能优于M5则表明Prophet分解算法为所提模型提供了有效的节假日信息特征, 准确拟合了数据分量。

4 总结

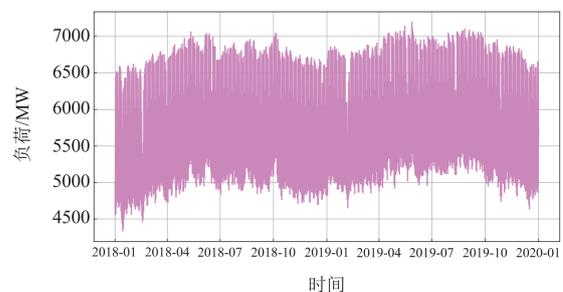
为进一步提升电力负荷预测模型的性能, 考虑多尺度特征及节假日因素对预测模型的影响, 本文提出了一种基于多尺度二次特征提取的短期电力负荷预测模型, 并在国内外两套电力负荷数据集上进行验证, 得出如下结论。

1) 利用Prophet分解算法将负荷数据分解为包括可量化的节假日特征在内的多尺度数据分量, 有利于模型挖掘不同时间尺度下的用电特性, 提升了模型对负荷整体的预测精度;

2) 所设计的二次特征提取网络具有对节假日特征的高效提取能力, IFPN特征提取网络引入卷积特征增强模块, 加强了对节假日特征的敏感度; MSTCN对节假日特征赋权, 强化了节假日特征在多尺度特征中的表达能力, 提高了模型对于节假日负荷的预测精度。

尽管所提模型在节假日负荷预测中表现出良好的性能, 但该研究并未对社会突发事件等随机因素对模型性能的影响做进一步分析及研究。因此, 后续将研究随机因素对负荷预测的影响, 并提出针对性措施与优化预测方法。

附录 A



(a) 原始负荷分量

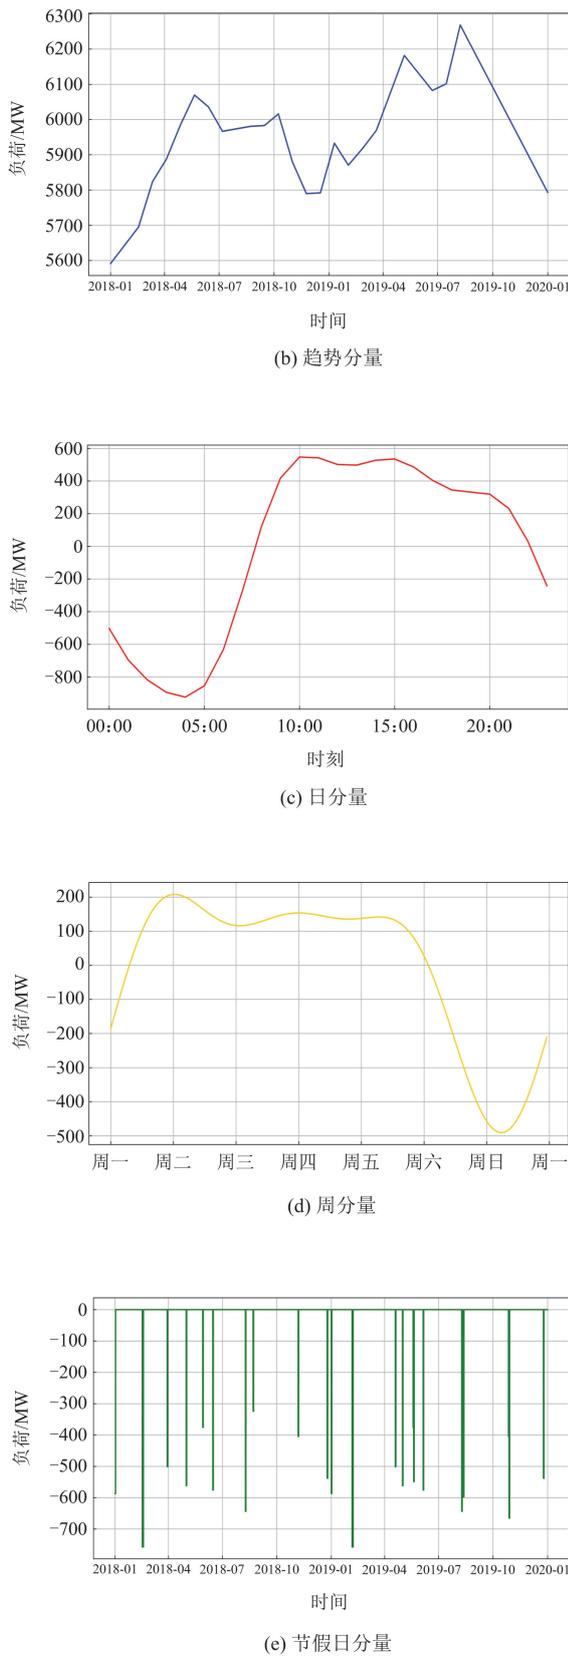


图 A1 新加坡地区分解结果

Fig. A1 Decomposition results for Singapore region

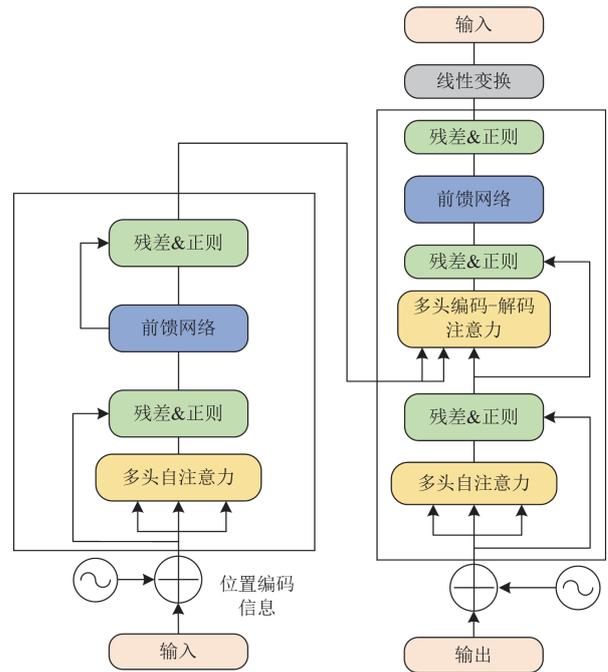


图 A2 Transformer 模型结构

Fig. A2 Structure of the Transformer model

参考文献

[1] 韩富佳, 王晓辉, 乔骥, 等. 基于人工智能技术的新型电力系统负荷预测研究综述[J]. 中国电机工程学报, 2023, 43(22): 8569-8591.
 HAN Fujia, WANG Xiaohui, QIAO Ji, et al. Review on artificial intelligence based load forecasting research for the new-type power system[J]. Proceedings of the CSEE, 2023, 43(22): 8569-8591.

[2] 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.

[3] SONG K, BAEK Y, JANG G, et al. Short-term load forecasting for the holidays using fuzzy linear regression method[J]. IEEE Transactions on Power Systems, 2005, 20(1): 96-101.

[4] 赵峰, 孙波, 张承慧. 基于多变量相空间重构和卡尔曼滤波的冷热电联供系统负荷预测方法[J]. 中国电机工程学报, 2016, 36(2): 399-406.
 ZHAO Feng, SUN Bo, ZHANG Chenghui. Cooling, heating and electrical load forecasting method for CCHP system based on multivariate phase space reconstruction and Kalman filter[J]. Proceedings of the CSEE, 2016, 36(2): 399-406.

- [5] 李焱, 贾雅君, 李磊, 等. 基于随机森林算法的短期电力负荷预测[J]. 电力系统保护与控制, 2020, 48(21): 117-124.
LI Yan, JIA Yajun, LI Lei, et al. Short term power load forecasting based on a stochastic forest algorithm[J]. Power System Protection and Control, 2020, 48(21): 117-124.
- [6] 封钰, 宋佑斌, 金晟, 等. 基于随机森林算法和粗糙集理论的改进型深度学习短期负荷预测模型[J]. 发电技术, 2023, 44(6): 889-895.
FENG Yu, SONG Youbin, JIN Sheng, et al. Improved deep learning model for forecasting short-term load based on random forest algorithm and rough set theory[J]. Power Generation Technology, 2023, 44(6): 889-895.
- [7] WU Kailang, GU Jie, MENG Lu, et al. An explainable framework for load forecasting of a regional integrated energy system based on coupled features and multi-task learning[J]. Protection and Control of Modern Power Systems, 2022, 7(2): 349-362.
- [8] ZHU Suxun, MA Hengrui, CHEN Laijun, et al. Short-term load forecasting of an integrated energy system based on STL-CPLE with multitask learning[J]. Protection and Control of Modern Power Systems, 2024, 9(6): 71-92.
- [9] 申洪涛, 李飞, 史轮, 等. 基于气象数据降维与混合深度学习的短期电力负荷预测[J]. 电力建设, 2024, 45(1): 13-21.
SHEN Hongtao, LI Fei, SHI Lun, et al. Short-term power load forecasting based on reduction of meteorological data dimensionality and hybrid deep learning[J]. Electric Power Construction, 2024, 45(1): 13-21.
- [10] 赵紫昱, 陈渊睿, 陈霆威, 等. 基于时空图注意力网络的超短期区域负荷预测[J]. 电力系统自动化, 2024, 48(12): 147-155.
ZHAO Ziyu, CHEN Yuanrui, CHEN Tingwei, et al. Ultra-short-term regional load forecasting based on spatio-temporal graph attention network[J]. Automation of Electric Power Systems, 2024, 48(12): 147-155.
- [11] 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 Yang, WANG Hanmo, KANG Li, et al. Temporal convolution network-based short-term electrical load forecasting[J]. Transactions of China Electrotechnical Society, 2022, 37(5): 1242-1251.
- [12] 欧阳福莲, 王俊, 周杭霞, 等. 基于改进迁移学习和多尺度 CNN-BiLSTM-Attention 的短期电力负荷预测方法[J]. 电力系统保护与控制, 2023, 51(2): 132-140.
OUYANG Fulian, WANG Jun, ZHOU Hangxia, et al. Short-term power load forecasting method based on improved hierarchical transfer learning and multi-scale CNN-BiLSTM-Attention[J]. Power System Protection and Control, 2023, 51(2): 132-140.
- [13] 向东, 赵文博, 王玖斌, 等. 结合小波变换与改进 SSA 优化小波神经网络的电力负荷预测[J]. 计算机测量与控制, 2024, 32(5): 46-52, 59.
XIANG Dong, ZHAO Wenbo, WANG Jiubin, et al. Combining wavelet transformed and improved SSA optimizing wavelet neural network for power load prediction[J]. Computer Measurement & Control, 2024, 32(5): 46-52, 59.
- [14] 李甲祎, 赵兵, 刘宣, 等. 基于 DWT-Informer 的台区短期负荷预测[J]. 电测与仪表, 2024, 61(3): 160-166, 191.
LI Jiayi, ZHAO Bing, LIU Xuan, et al. Short-term substation load forecasting based on DWT-Informer model[J]. Electrical Measurement & Instrumentation, 2024, 61(3): 160-166, 191.
- [15] 孔祥瑞, 李闯, 郑锋, 等. 基于经验模态分解与特征相关分析的短期负荷预测方法[J]. 电力系统自动化, 2019, 43(5): 46-52.
KONG Xiangyu, LI Chuang, ZHENG Feng, et al. Short-term load forecasting method based on empirical mode decomposition and feature correlation analysis[J]. Automation of Electric Power Systems, 2019, 43(5): 46-52.
- [16] 刘璐瑶, 陈志刚, 沈欣炜, 等. 基于 EMD-MLP 组合模型的用电负荷日前预测[J]. 南方能源建设, 2024, 11(1): 143-156.
LIU Luyao, CHEN Zhigang, SHEN Xinwei, et al. Day-ahead forecast of electrical load based on EMD-MLP combination model[J]. Southern Energy Construction, 2024, 11(1): 143-156.
- [17] 叶剑华, 曹旌, 杨理, 等. 基于变分模态分解和多模型融合的用户级综合能源系统超短期负荷预测[J]. 电网技术, 2022, 46(7): 2610-2618.
YE Jianhua, CAO Jing, YANG Li, et al. Ultra short-term load forecasting of user level integrated energy system based on variational mode decomposition and multi-model fusion[J]. Power System Technology, 2022, 46(7): 2610-2618.
- [18] 李鹏, 罗湘淳, 孟庆伟, 等. 基于 Spearman 相关性阈值寻优和 VMD-LSTM 的用户级综合能源系统超短期负荷预测[J]. 全球能源互联网, 2024, 7(4): 406-420.
LI Peng, LUO Xiangchun, MENG Qingwei, et al. Ultra short-term load forecasting of user level integrated energy system based on Spearman threshold optimization and variational mode decomposition and long short-term memory[J]. Journal of Global Energy Interconnection,

- 2024, 7(4): 406-420.
- [19] 王宇飞, 杜桐, 边伟国, 等. 基于 DTW K-medoids 与 VMD-多分支神经网络的多用户短期负荷预测[J]. 中国电力, 2024, 57(6): 121-130.
WANG Yufei, DU Tong, BIAN Weiguo, et al. Short-term load forecasting based on DTW K-medoids and VMD multi-branch neural network for multiple users[J]. Electric Power, 2024, 57(6): 121-130.
- [20] 邓带雨, 李坚, 张真源, 等. 基于 EEMD-GRU-MLR 的短期电力负荷预测[J]. 电网技术, 2020, 44(2): 593-602.
DENG Daiyu, LI Jian, ZHANG Zhenyuan, et al. Short-term electric load forecasting based on EEMD-GRU-MLR[J]. Power System Technology, 2020, 44(2): 593-602.
- [21] 李楠, 姜涛, 隋想, 等. 一种时频尺度下的多元短期电力负荷组合预测方法[J]. 电力系统保护与控制, 2024, 52(13): 47-58.
LI Nan, JIANG Tao, SUI Xiang, et al. A multi-component short-term power load combination forecasting method on a time-frequency scale[J]. Power System Protection and Control, 2024, 52(13): 47-58.
- [22] 刘杰, 从兰美, 夏远洋, 等. 基于 DBO-VMD 和 IWOA-BiLSTM 神经网络组合模型的短期电力负荷预测[J]. 电力系统保护与控制, 2024, 52(8): 123-133.
LIU Jie, CONG Lanmei, XIA Yuanyang, et al. Short-term power load prediction based on DBO-VMD and an IWOA-BiLSTM neural network combination model[J]. Power System Protection and Control, 2024, 52(8): 123-133.
- [23] 张淑清, 李君, 姜安琦, 等. 基于 FPA-VMD 和 BiLSTM 神经网络的新型两阶段短期电力负荷预测[J]. 电网技术, 2022, 46(8): 3269-3279.
ZHANG Shuqing, LI Jun, JIANG Anqi, et al. A novel two-stage model based on FPA-VMD and BiLSTM neural network for short-term power load forecasting[J]. Power System Technology, 2022, 46(8): 3269-3279.
- [24] 任爽, 杨凯, 商继财, 等. 基于 CNN-BiGRU-Attention 的短期电力负荷预测[J]. 电气工程学报, 2024, 19(1): 344-350.
REN Shuang, YANG Kai, SHANG Jicai, et al. Short-term power load forecasting based on CNN-BiGRU-Attention[J]. Journal of Electrical Engineering, 2024, 19(1): 344-350.
- [25] 梁露, 张智晟. 基于多尺度特征增强 DHTCN 的电力系统短期负荷预测研究[J]. 电力系统保护与控制, 2023, 51(10): 172-179.
LIANG Lu, ZHANG Zhisheng. Short-term load forecasting of a power system based on multi-scale feature enhanced DHTCN[J]. Power System Protection and Control, 2023, 51(10): 172-179.
- [26] 孟衡, 张涛, 王金, 等. 基于多尺度时空图卷积网络与 Transformer 融合的多节点短期电力负荷预测方法[J]. 电网技术, 2024, 48(10): 4297-4311.
MENG Heng, ZHANG Tao, WANG Jin, et al. Multi-node short-term power load forecasting method based on multi-scale spatiotemporal graph convolution network and Transformer[J]. Power System Technology, 2024, 48(10): 4297-4311.
- [27] LIANG S, DENG T, HUANG A, et al. Energy consumption prediction using the GRU-MMattention LightGBM model with features of prophet decomposition[J]. PLoS One, 2023, 18(1).
- [28] ZHANG Yifan, WU Rui, DASCALU S M, et al. Multi-scale transformer pyramid networks for multivariate time series forecasting[J]. IEEE Access, 2024, 12: 14731-14741.
- [29] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, June 18-22, 2018, Piscataway, NJ, USA: 7132-7141.
- [30] 刘友波, 吴浩, 刘挺坚, 等. 集成经验模态分解与深度学习的用户侧净负荷预测算法[J]. 电力系统自动化, 2021, 45(24): 57-64.
LIU Youbo, WU Hao, LIU Tingjian, et al. Customer-side net load forecasting algorithm based on integrated empirical mode decomposition and deep learning[J]. Automation of Electric Power Systems, 2021, 45(24): 57-64.
- [31] 任建吉, 位慧慧, 邹卓霖, 等. 基于 CNN-BiLSTM-Attention 的超短期电力负荷预测[J]. 电力系统保护与控制, 2022, 50(8): 108-116.
REN Jianji, WEI Huihui, ZOU Zhuolin, et al. Ultra-short-term power load forecasting based on NN-BiLSTM-Attention[J]. Power System Protection and Control, 2022, 50(8): 108-116.
- [32] 陈振宇, 刘金波, 李晨, 等. 基于 LSTM 与 XGBoost 组合模型的超短期电力负荷预测[J]. 电网技术, 2020, 44(2): 614-620.
CHEN Zhenyu, LIU Jinbo, LI Chen, et al. Ultra short-term power load forecasting based on combined LSTM-XGBoost model[J]. Power System Technology, 2020, 44(2): 614-620.

收稿日期: 2024-10-14; 修回日期: 2025-02-25

作者简介:

李楠(1973—), 女, 通信作者, 博士, 副教授, 研究方向为数据挖掘在电力系统中的应用; E-mail: jllinan@163.com

金淳熙(1999—), 男, 硕士研究生, 研究方向为人工智能在电力系统中的应用。E-mail: 2801824101@qq.com

(编辑 魏小丽)