

基于频域增强Transformer的多用户短期 负荷预测方法

宋立业¹, 孟凡宇¹, 陈郁林^{2*}, 宋信萍¹

- (1. 辽宁工程技术大学电气与控制工程学院, 辽宁省 葫芦岛市 125105;
2. 浙江大学海南研究院, 海南省 三亚市 572024)

Multi-User Short-Term Load Prediction Method Based on Frequency-Domain Enhanced Transformer

SONG Liye¹, MENG Fanyu¹, CHEN Yulin^{2*}, SONG Xinping¹

- (1. Faculty of Electrical and Control Engineering, Liaoning Technical University, Huludao 125105, Liaoning Province, China;
2. Hainan Institute of Zhejiang University, Sanya 572024, Hainan Province, China)

摘要:【目的】负荷预测对于电力系统规划和运行至关重要。然而, 新能源的高比例接入引发的源荷不确定性增大, 使得新型电力系统负荷的波动性增加, 导致多用户负荷准确预测的难度增大。为提高新型电力系统短期负荷预测的精度, 提出一种基于频域增强Transformer的多用户短期负荷预测方法。【方法】利用Transformer中的编码器捕捉多负荷序列的特征信息; 通过离散余弦变换(discrete cosine transform, DCT)获取其中的频域信息, 并用通道注意力机制进行数据增强; 利用Transformer中的解码器整合特征信息输入到全连接层中, 得到预测数据。为验证所提方法的优越性, 采用Electricity dataset数据集进行算例分析, 并将所提方法与5种常用负荷预测方法进行对比分析。【结果】该方法与传统的Transformer负荷预测模型相比, 误差降低了21.8%。【结论】所提方法在准确性和稳定性方面表现优异, 在实际应用中具有可行性。

关键词: 电力负荷预测; 新能源; 源荷不确定性; 深度学习; Transformer模型; 离散余弦变换; 通道注意力机制; 数据增强

ABSTRACT: [Objectives] Load prediction is crucial for power system planning and operation. However, the high proportion of new energy increases source-load uncertainty, leading to greater volatility in the load of new-type power systems, which makes it more difficult to accurately predict multi-user load. To improve the accuracy of short-term load

forecasting in new power systems, a multi-user short-term load prediction method based on frequency-domain enhanced Transformer is proposed. [Methods] The encoder in the Transformer is used to capture the feature information of multi-load sequences. The frequency-domain information is obtained by the discrete cosine transform (DCT), and the channel attention mechanism is used for data enhancement. The decoder in the Transformer is used to integrate the feature information which is then fed into the fully connected layer to obtain the prediction data. To verify the superiority of the proposed method, the Electricity dataset is used for case analysis, and a comparative analysis is conducted between the proposed method and five commonly used load forecasting methods. [Results] Compared with the traditional Transformer load prediction model, the error of the proposed method is reduced by 21.8%. [Conclusions] The proposed method demonstrates excellent accuracy and stability, showing feasibility for practical applications.

KEY WORDS: power load forecasting; new energy; source-load uncertainty; deep learning; Transformer model; discrete cosine transform; channel attention mechanism; data enhancement

0 引言

在“双碳”目标下, 构建新能源占比逐渐提高的新型电力系统是我国未来能源发展的重要方向, 其中短期电力负荷预测是新型电力系统稳定运行的重要环节^[1-9], 是电力系统规划和运行的重

基金项目: 海南省自然科学基金项目(524RC532)。

Project Supported by Hainan Provincial Natural Science Foundation (524RC532).

要决策依据^[10]。目前我国以风电、光伏为代表的新能源发电量占比已达到15.3%，源侧新能源占比的增多会间接改变用户侧的用电行为，使负荷的不确定性增大^[11]，导致难以获得准确的短期负荷预测结果。为此，越来越多的学者针对短期负荷预测进行研究，目前以数学统计方法、传统机器学习方法和深度学习方法为主^[12]。

数学统计方法包括卡尔曼滤波、多元线性回归、自回归积分滑动平均等。这些方法具有模型简单、计算成本低、计算效率高等优点，但很难处理非线性复杂负荷数据^[13]，并不适合新型电力系统下的负荷预测。

传统机器学习方法包括人工神经网络^[14-17]、支持向量机^[18-20]、随机森林^[21-23]等。这些方法可以较好地处理非线性数据。文献[24]首先通过改进自适应噪声的完全集成经验模态分解(complete ensemble empirical mode decomposition with adaptive noise, CEEMDAN)获得更多负荷特征，然后采用深度信念网络(deep belief networks, DBN)对用户侧负荷进行预测，但该方法利用CEEMDAN提取负荷特征时，虽然能够获得更多的负荷特征，但对于复杂的新型电力系统来说，仍然难以完全捕捉存在的一些潜在隐藏信息和非线性关系；文献[25]采用小波包分解将用户净负荷时序数据分解为高频分量和低频趋势，然后将气象因素引入预测过程中，利用最小二乘支持向量机来预测和重构低频分量，捕捉更长期的趋势变化，最后通过叠加高频分量和重构后的低频分量，得到用户净负荷的预测结果，该方法在小样本非线性信号训练中表现出高效的性能，具有较强的泛化能力，但该方法对参数选择较为敏感，选择不当可能影响预测效果，且处理大规模数据集时，计算成本较高；文献[26]采用随机森林算法对特征进行筛选，挑选出与负荷关联性强的特征作为模型的输入，之后利用双向长短期记忆网络(long short-term memory network, LSTM)对筛选后的负荷数据进行预测，但LSTM网络难以处理长时间序列或多维输入。为了解决以上传统机器学习方法在负荷预测应用中存在的问题，学者们开始转向基于深度学习的负荷预测方法研究。

近年来，深度学习的发展日臻完善，Transformer等新兴网络模型为负荷预测提供了新的方法^[27-30]。由于堆叠结构和注意力机制的存在，Transformer可以更好地捕捉时间序列和时间序列之间的依赖关系。相较于循环神经网络^[31-32]，Transformer在处理时序问题方面表现出更强的能力。此外，目前大多数负荷预测研究往往只针对单一用户进行，忽略了同一地区负荷间的相似性，从而难以获取负荷间的特征关系。而Transformer除了拥有强大的时序处理能力外，还具备并行化计算的能力^[33]，这使得其在处理大规模数据集时更加高效。同时，注意力机制使得模型能够自动捕捉数据中负荷间的特征，能够进一步提高预测的精度和可靠性。例如，文献[34]采用门控循环单元对输入数据进行编码，融合和提取数据中的关键特征，引入残差连接并结合门控单元。这种结构不仅有助于缓解梯度消失和梯度爆炸等问题，还能更好地保持特征信息的传递。文献[35]利用时空图卷积网络作为输入嵌入层对多元输入序列进行编码，填补了Transformer中没有充分考虑相关信息的空白，利用Transformer中的自注意机制捕获序列数据的时间依赖性，并利用前馈神经网络输出预测负荷值。然而，上述Transformer模型缺乏捕捉真实数据中频域信息的能力，这会导致某些场景下预测结果与真实情况有很大误差。

为提高新型电力系统短期负荷预测的精确度，本文提出了一种基于频域增强Transformer的多用户短期负荷预测方法。利用离散余弦变换(discrete cosine transform, DCT)^[36]提取负荷的频域特征，并通过通道注意力机制(channel attention mechanism, CAM)对其进行增强，以弥补Transformer在频域信息建模方面的不足；将增强后的频域特征与原始时域负荷数据共同输入Transformer解码器，借助自注意力机制捕获序列的时间依赖关系；通过全连接层输出预测结果。

1 算法模型理论介绍

1.1 SENet通道注意力机制

CAM是一种用于增强通道特征捕捉能力的注意力机制。通过引入CAM使神经网络能够更有效

地学习和提取数据中的关键信息。SENet(squeeze-and-excitation networks, SENet)是 CAM 的一种, 主要由 Squeeze 操作 $F_{sq}(\cdot)$ 、Excitation 操作 $F_{ex}(\cdot)$ 以及 Scale 操作 $F_{scale}(\cdot)$ 3 个部分组成, 其结构如图 1 所示。




图1 SENet原理结构图

Fig. 1 SENet principle structure

SENet 通道注意力机制的具体计算流程如下: 为找到不同通道间的相互关系, 通过全局平均池化技术将每个通道的特征图空间维度进行压缩, 并将每个像素点的值进行平均化处理, 从而使每个通道的信息凝聚为单一的统计描述符。此过程通常被称为 Squeeze 操作, 将通道的特征图有效地简化为一个代表性数值, 这不仅保留了通道的重要统计信息, 同时也为后续的网络层提供了更为紧凑的输入。设输入长度为 L 、宽度为 M 的特征矩阵 R , Squeeze 操作的表达式为

$$z_c = F_{sq}(u_c) = \frac{1}{L} \sum_{i=1}^L u_c(i) \quad (1)$$

式中: $u_c(i)$ 为特征向量中的第 i 个通道; z_c 为经过压缩的特征。

经过 Squeeze 操作后, 原本尺寸为 $L \times M$ 的特征矩阵, 变成了 $1 \times M$ 的特征向量, 这种压缩显著减少了数据的维度。经过压缩后, 本文构建了 2 个全连接层, 相比单个全连接层, 其能够更好地综合特征值并提取它们之间的非线性关系。这些全连接层的目的在于捕捉特征间的复杂相互作用, 即 Excitation 操作, 其表达式为

$$s_c = F_{ex}(z, W) = \sigma[W_2 \delta(W_1 z)] \quad (2)$$

式中: z 为经过 Squeeze 操作压缩后的特征向量; σ 为 Sigmoid 函数; δ 为 ReLU 函数; W_1 、 W_2 为权重矩阵; s_c 为经过 Excitation 操作后的结果。

最后, 经过前 2 步操作后, 需要与原特征合

并, 这一步需要把新获得的特征向量与原特征矩阵相乘, 以此调整每个通道的特征, 即 Scale 操作, 其表达式为

$$\hat{x}_c = F_{scale}(u_c, s_c) = s_c u_c \quad (3)$$

式中 $\hat{x}_c$ 为经过 SENet 通道注意力机制后得到的特征矩阵。

1.2 离散余弦变换

为有效地获取频域特征向量, 本文采用了一种基于离散余弦变换的方法, 能够更有效地进行频域变换。相比于经典的离散傅里叶变换(discrete Fourier transform, DFT), DCT 变换可以在频域中得到 1 个实信号, 减少了计算成本。本文采用一维的 DCT 变换, 设 $\{f(i) | i = 0, 1, \dots, N-1\}$ 为离散的信号列, 其表达式为:

$$F_{dct}(u) = c(u) \sum_{i=0}^{N-1} f(i) \cos\left[\frac{(i+0.5)\pi}{N} u\right] \quad (4)$$

$$c(u) = \begin{cases} \frac{1}{\sqrt{2}}, & u=0 \\ 1, & u \neq 0 \end{cases} \quad (5)$$

式中: $c(u)$ 为一个系数, 以确保 DCT 变换矩阵成为正交矩阵; N 为 $f(i)$ 的信号总数。

1.3 多头注意力机制

多头注意力机制是在自注意力机制的基础上发展起来的, 是自注意力机制的变体。在传统的注意力机制中, 只有一个注意力头, 将所有的输入信息都聚焦在一个权重上。而多头注意力机制引入了多个注意力头, 每个头部都会独立地处理输入数据并将输入数据映射到不同的表示空间, 从而实现捕捉输入数据不同方面的效果。

在自注意力机制中使用线性变换矩阵 W^q 、 W^k 、 W^v 计算得到查询向量 Q 、键向量 K 和值向量 V , 通过计算 Q 与 K 的相关度找到合适的 V 向量, 公式如下:

$$Q = \hat{e} \cdot W^q \quad (6)$$

$$K = \hat{e} \cdot W^k \quad (7)$$

$$V = \hat{e} \cdot W^v \quad (8)$$

式中 $\hat{e}$ 为注意力分数, 通过计算查询向量与键向量的点积, 得到每个输出位置与输入序列中的相关性分数。

注意力 H_i 的计算公式为

$$H_i = \text{softmax}\left(\frac{QK}{\sqrt{d}}\right)V \quad (9)$$

式中 $\sqrt{d}$ 为缩放因子,通过将点积方差拉回1,从而稳定训练过程。

在Transformer模型中,多头注意力机制的计算与自注意力机制相同,需要对 n 个头经过权重矩阵 W 并行计算,并合并以计算输出 H 为:

$$H = W[H_1, H_2, \dots, H_n] \quad (10)$$




图2 频域增强通道注意力机制结构图

Fig. 2 Structure of frequency-domain enhanced channel attention mechanism

先沿着通道,将输入的特征映射成 $[Z_1, \dots, Z_h]$,之后对每个通道进行DCT频域分量处理,可得

$$f_{\text{Freq},i} = F_{\text{dct},j}(Z_i) = c(u) \sum_{i=0}^{N-1} Z_i \cos\left[\frac{(i+0.5)\pi}{N} u\right] \quad (11)$$

叠加运算后可以得到所有的频域分量表示为

$$f_{\text{Freq}} = F_{\text{dct}}(Z) = \text{stack}[(f_{\text{Freq},1}, \dots, f_{\text{Freq},h})] \quad (12)$$

式中stack表示堆栈。

获得频域信息后,按照SENet通道注意力模块来进行学习,整个频域增强机制可以表示为

$$F = \sigma\{W_2 \delta[W_1 F_{\text{dct}}(Z)]\} \quad (13)$$

通过引入频域增强注意力机制,有效地捕捉了各个通道在频域中的特征关系,这种机制增强了特征的表达能力,且从频域中提取了更为全面的负荷信息。在深度学习负荷预测的背景下,这种多维度的特征提取策略显著提高了所使用特征的多样性,在进行负荷预测时能够更加精确地捕捉到负荷变化的趋势和模式,极大地提高了深度学习模型在负荷预测任务中的准确率。

2.2 解码器-编码器机制

基于Transformer的编码器-解码器模型通过使用自注意力机制和残差连接来捕捉序列中的依

2 多用户短期负荷预测模型

2.1 频域增强通道注意力机制

为了提高负荷预测的性能,本文采用了频域增强通道注意力方法,它可以从特征映射中获取更多的时序信息,引入DCT获取了更多的频域分量,可得到更多负荷特征信息。其结构如图2所示。

赖关系,提供了更高的效率和性能。其中编码器中每层输出经过归一化之后通过残差连接模块连接到下一层,公式如下:

$$H_T = \text{Norm}[f_{\text{MultiHead}}(H) + H] \quad (14)$$

$$X_T = \text{Norm}[f_{\text{FFN}}(H_T) + H_T] \quad (15)$$

式中: H 为多头注意力层MultiHead的输入; H_T 为前馈层FFN的输入;Norm为归一化处理; X_T 为编码器的输出。

解码器相比于编码器在输入数据前多了一步掩码操作。掩码操作是为了避免在负荷预测过程中泄露后续负荷信息,确保预测的真实性。解码器将更新后的查询向量 Q 、键向量 K 和值向量 V 合并输出。将解码器输出的特征矩阵经过一个sigmoid激活函数和全连接层进行预测,输出预测结果,其表达式为

$$\hat{Y} = \sigma(W_y X_T^{N_d} + b_y) \quad (16)$$

式中: W_y 为权重矩阵; b_y 为偏置向量; $X_T^{N_d}$ 为编码器的输出。

2.3 预测模型

本文使用Transformer模型来实现对负荷的预测。编码器获得 h 个向量作为输入,表示最后 h 个

时间序列，每个输入向量为各个用户的负荷数据。编码器的输出特征向量进入频域增强通道注意力机制中，通过DCT获取更多频域信息，解码器的输入由 $n-h$ 个向量组成，这些向量代表接下来的 $n-h$ 个时间序列，本文将对这些时间序列进行预测。

输入向量首先通过线性层，通过权重矩阵的线性变换将输入数据映射到编码器和解码器中。经实验分析，本文采用的编码器和解码器都由3层具有8个自注意头的多头注意力层组成，解码器每层具有8个额外的掩码交叉注意力头。最后，全连接层将解码器输出的特征信息向量转换为预测数据。其中，本文在编码器和解码器之间加入了频域增强通道注意力机制，以获得更多频域信息。完整的模型架构如图3所示。




图3 基于频域增强的Transformer多负荷时间序列的负荷预测模型框架

Fig. 3 Framework of load prediction model for Transformer-based multi-load time series with frequency-domain enhancement

3 算例分析

3.1 数据集

为验证本文方法的有效性以及符合实际需求，本文使用的数据集为Electricity Dataset。其数据是葡萄牙能源供应商在2012—2014年，通过每

1 h记录1次其用户的电力负荷得到的数据。本文消除了其中的缺失数据和异常数据，最终得到2012—2014年300个用户的电力负荷。将数据转换为反映每小时电力负荷的数据，并将数据集按照7:1:2的比例分成训练集、验证集和测试集。

3.2 损失函数和评价指标

本文采用均方误差(mean squared error, MSE)作为损失函数 $L(y, \hat{y})$ ，来计算预测值和真实值的误差，计算公式如下：

$$e_{\text{MSE}} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (17)$$

式中： y_i 为真实负荷值； $\hat{y}_i$ 为预测得到的负荷值； n 为进行预测的负荷序列长度。

本文采用均方误差和平均绝对误差(mean absolute error, MAE)作为预测结果的评价指标，其计算公式如下：

$$e_{\text{MAE}} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (18)$$

3.3 对比验证分析

为了验证所提出模型的预测性能，选取自回归移动平均模型(autoregressive integrated moving average model, ARIMA)、LSTM、多层感知机(multilayer perceptron, MLP)、PatchTST模型、Transformer模型5种对照模型使用同样的数据集进行负荷预测实验。

首先，将本文所提模型与所选取的对照模型分别输入序列长度720 h，预测序列长度分别为24 h、96 h，得到的预测评价结果见表1，各方法24 h预测曲线与实际负荷曲线如图4所示。

由表1可以看到，本文方法对于24 h和96 h

表1 各预测模型的性能比较

Tab.1 Performance comparison of different prediction models

模型	MSE/MW ²		MAE/MW	
	24 h	96 h	24 h	96 h
ARIMA	0.363	0.395	0.399	0.407
LSTM	0.237	0.268	0.263	0.283
MLP	0.101	0.139	0.199	0.236
PatchTST	0.109	0.142	0.248	0.263
Transformer	0.116	0.149	0.256	0.289
本文方法	0.105	0.117	0.203	0.223




图 4 各方法预测结果与实际负荷对比图

Fig. 4 Comparison of predicted results of different methods with actual load

预测结果的MSE分别为0.105、0.117 MW²，相比于 ARIMA 模型、LSTM 模型、PatchTST 模型、Transformer 模型，本文方法预测结果的MSE分别平均减少了0.268、0.142、0.015、0.022 MW²。本文方法对于24 h和96 h预测的结果的MAE分别为0.203、0.223 MW，相比于 ARIMA 模型、LSTM 模型、PatchTST 模型、Transformer 模型，本文方法预测结果的MAE误差分别平均降低了47.1%、22.1%、16.6%、21.8%。MLP方法由多个全连接层组成，没有复杂的注意力机制或卷积结构，这使得模型结构更加简单直接，在24 h预测时结果略优于本文方法，但在96 h预测时本文方法具有更好的预测精度。可见，本文方法在预测长时间序列时精度更高。由表1还可以看出，本文方法相较于普通的Transformer模型预测效果更好，验证了本文所提方法的有效性。通过24 h和96 h预测结果的对比，可知本文方法在较短时间预测的准确率会更高。

上述实验结果表明：经过频域增强的Transformer模型相较于Transformer模型的预测结果更加准确。由图4可知，本文方法的预测负荷曲线更接近实际负荷曲线，这是因为采用频域增强方法对频域信息进行捕获，能获取更多负荷特征，从而得到更精确的预测结果，验证了频域增强方法可以实现负荷预测准确度的提升。

3.4 多用户对预测性能的影响

在多用户模型的预测时，输入的每个时间步长由大小为C的向量表示，C为加载时间序列的

数量，即用户的数量。模型预测接下来 h 个时间步长的 C 个值，即它的输出由 h 个大小为 C 的向量组成。一个模型被用来同时预测所有的时间序列。

对多个用户分别进行预测时，将300个长度为720 h的用户序列分别输入LSTM、MLP、PatchTST、Transformer与本文模型中，预测序列长度为24 h负荷数据，结果见表2。

表 2 各预测模型对多用户数据预测性能比较

Tab. 2 Performance comparison of different prediction models for multi-user data

预测模型	MSE/MW ²	MAE/MW
LSTM	0.109	0.207
MLP	0.113	0.225
PatchTST	0.095	0.190
Transformer	0.093	0.184
本文方法	0.085	0.171

由表2可见，对于多负荷预测时，本文方法MSE为0.085 MW²，相比于LSTM模型、MLP模型、PatchTST模型、Transformer模型，MSE分别减少了0.024、0.028、0.01、0.008 MW²。本文方法预测结果的MAE为0.171 MW，相比于LSTM模型、MLP模型、PatchTST模型、Transformer模型，MAE分别降低了17.4%、24%、10%、7.1%。结果表明，由于MLP模型处理具有复杂关系的任务能力较差，其误差在5种模型中最大。而本文方法由于可以获得更多用户间相关特征，在对多用户负荷进行预测时具有更高的预测精度。

综合以上分析可知，基于频域增强Transformer的多用户短期负荷预测方法的预测精度明显优于LSTM模型、MLP模型、PatchTST模型、Transformer模型，验证了本文预测模型的有效性。

4 结论

为提高短期负荷预测精度，提出一种基于频域增强Transformer的多用户短期负荷预测方法。并通过Electricity dataset数据集对本文方法进行了验证。结论如下：

1) 与传统Transformer模型对比，采用频域增强通道注意力机制能够有效捕获负荷的频域特

征, 进而提高短期负荷预测精确度。

2) 与常用的负荷预测模型相比, 频域增强的 Transformer 预测模型可以获取用户间的近似特征, 使其在多用户负荷预测时的预测精度更高。

3) 未来研究可以考虑将负荷波动性与预测模型进行结合, 进一步对模型进行优化。

参考文献

- [1] 程志友, 余国晓, 丁柏宏. 采用改进温湿度变量策略的夏季短期负荷预测方法[J]. 电力系统保护与控制, 2020, 48(1): 48-54.
CHENG Z Y, YU G X, DING B H. Summer short-term load forecasting method based on improved temperature and humidity variable strategy[J]. Power System Protection and Control, 2020, 48(1): 48-54.
- [2] 刘义艳, 李国良, 代杰. 基于 VMD-TCN-BiLSTM-Attention 的短期电力负荷预测[J]. 智慧电力, 2025, 53(10): 87-94.
LIU Y Y, LI G L, DAI J. Short-term power load forecasting based on VMD-TCN-BiLSTM-attention[J]. Smart Power, 2025, 53(10): 87-94.
- [3] 李科, 潘庭龙, 许德智. 基于 MSCNN-BiGRU-Attention 的短期电力负荷预测[J]. 中国电力, 2025, 58(6): 10-18.
LI K, PAN T L, XU D Z. Short-term power load forecasting based on MSCNN-BiGRU-attention[J]. Electric Power, 2025, 58(6): 10-18.
- [4] 冉启武, 张宇航. 基于模态分解及 GRU-XGBoost 短期电力负荷预测[J]. 电网与清洁能源, 2024, 40(4): 18-27.
RAN Q W, ZHANG Y H. Short-term power load forecasting based on modal decomposition and GRU-XGBoost[J]. Power System and Clean Energy, 2024, 40(4): 18-27.
- [5] 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 H T, LI F, SHI L, 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.
- [6] 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 L Y, CHEN Z G, SHEN X W, et al. Day-ahead forecast of electrical load based on EMD-MLP combination model[J]. Southern Energy Construction, 2024, 11(1): 143-156.
- [7] 张明泽, 栾文鹏, 艾欣, 等. 基于边缘计算的台区短期负荷预测方法[J]. 电测与仪表, 2024, 61(4): 93-99.
ZHANG M Z, LUAN W P, AI X, et al. Short-term substation load forecasting method based on edge computing[J]. Electrical Measurement & Instrumentation, 2024, 61(4): 93-99.
- [8] 许青, 张龄之, 梁琛, 等. 基于联合时序场景和改进 TCN 的高比例新能源电网负荷预测[J]. 广东电力, 2024, 37(1): 1-7.
XU Q, ZHANG L Z, LIANG C, et al. Short-term load forecasting for power system with high proportion new energy based on joint sequential scenario and improved TCN[J]. Guangdong Electric Power, 2024, 37(1): 1-7.
- [9] 张远航, 寇鹏, 梅铭洋, 等. 电压敏感型负荷参与频率响应的分层模型预测控制策略[J]. 电工技术学报, 2026, 41(1): 127-141.
ZHANG Y H, KOU P, MEI M Y, et al. Control of voltage-dependent loads for grid frequency response based on hierarchical model predictive control[J]. Transactions of China Electrotechnical Society, 2026, 41(1): 127-141.
- [10] 刘洪波, 刘坤诚, 盖雪扬, 等. 高比例新能源接入的主动配电网规划综述[J]. 发电技术, 2024, 45(1): 151-161.
LIU H B, LIU S C, GAI X Y, et al. Overview of active distribution network planning with high proportion of new energy access[J]. Power Generation Technology, 2024, 45(1): 151-161.
- [11] 李永飞, 张耀, 林帆, 等. 基于气候特征分析及改进 XGBoost 算法的中长期光伏电站发电量预测方法[J]. 电力系统保护与控制, 2024, 52(11): 84-92.
LI Y F, ZHANG Y, LIN F, et al. Medium-and long-term power generation forecast based on climate characterisation and an improved XGBoost algorithm for photovoltaic power plants[J]. Power System Protection and Control, 2024, 52(11): 84-92.
- [12] 范杏蕊, 李元诚. 基于改进 Autoformer 模型的短期电力负荷预测[J]. 电力自动化设备, 2024, 44(4): 171-177.
FAN X R, LI Y C. Short-term power load forecasting based on improved Autoformer model[J]. Electric Power Automation Equipment, 2024, 44(4): 171-177.
- [13] 陈德启. 基于浮动车数据的信号交叉口运行态势推演

- 与配时优化方法[D]. 北京: 北京交通大学, 2021.
- CHEN D Q. Research on deduction of signalized intersections operation state and timing optimization method based on floating car data[D]. Beijing: Beijing Jiaotong University, 2021.
- [14] 史佳琪, 张建华. 基于多模型融合 Stacking 集成学习方式的负荷预测方法[J]. 中国电机工程学报, 2019, 39(14): 4032-4042.
- SHI J Q, ZHANG J H. Load forecasting based on multi-model by stacking ensemble learning[J]. Proceedings of the CSEE, 2019, 39(14): 4032-4042.
- [15] 付小标, 侯嘉琪, 李宝聚, 等. 一种二模态天气分型方法及其在光伏功率概率预测的应用[J]. 发电技术, 2024, 45(2): 299-311.
- FU X B, HOU J Q, LI B J, et al. A two-modal weather classification method and its application in photovoltaic power probability prediction[J]. Power Generation Technology, 2024, 45(2): 299-311.
- [16] 王丹, 薛激光, 璇璇, 等. 考虑相似日优选的EPGA-BPNN 短期光伏功率预测[J]. 供用电, 2024, 41(5): 80-87.
- WANG D, XUE J G, XUAN X, et al. Short-term PV power prediction of EPGA-BPNN considering similar day preferences[J]. Distribution & Utilization, 2024, 41(5): 80-87.
- [17] 郑婉婷, 肖浩, 裴玮. 基于NGBoost和改进权重优化的区域分布式光伏功率预测[J]. 供用电, 2024, 41(7): 19-28.
- ZHENG W T, XIAO H, PEI W. Probabilistic power forecasting for regional distributed photovoltaic systems using NGBoost and enhanced weight optimization[J]. Distribution & Utilization, 2024, 41(7): 19-28.
- [18] 张宇帆, 艾芊, 林琳, 等. 基于深度长短时记忆网络的区域级超短期负荷预测方法[J]. 电网技术, 2019, 43(6): 1884-1892.
- ZHANG Y F, AI Q, LIN L, et al. A very short-term load forecasting method based on deep LSTM RNN at zone level[J]. Power System Technology, 2019, 43(6): 1884-1892.
- [19] 杨茂, 张书天, 王勃. 基于因果正则化极限学习机的风电功率短期预测方法[J]. 电力系统保护与控制, 2024, 52(11): 127-136.
- YANG M, ZHANG S T, WANG B. Short-term wind power forecasting method based on a causal regularized extreme learning machine[J]. Power System Protection and Control, 2024, 52(11): 127-136.
- [20] 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 Z 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.
- [21] 张丽, 李世情, 艾恒涛, 等. 基于改进Q学习算法和组合模型的超短期电力负荷预测[J]. 电力系统保护与控制, 2024, 52(9): 143-153.
- ZHANG L, LI S Q, AI H T, et al. Ultra-short-term power load forecasting based on an improved Q-learning algorithm and combination model[J]. Power System Protection and Control, 2024, 52(9): 143-153.
- [22] RAFI S H, MASOOD N A, DEEBA S R. An effective short-term load forecasting methodology using convolutional long short term memory network[C]//2020 11th International Conference on Electrical and Computer Engineering (ICECE). Dhaka, Bangladesh: IEEE, 2021: 278-281.
- [23] 吕海灿, 王伟峰, 赵兵, 等. 基于Wide&Deep-LSTM模型的短期台区负荷预测[J]. 电网技术, 2020, 44(2): 428-436.
- LÜ H C, WANG W F, ZHAO B, et al. Short-term substation load forecast based on wide & deep-LSTM model[J]. Power System Technology, 2020, 44(2): 428-436.
- [24] 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 Y B, WU H, LIU T J, et al. User-side net load forecasting method integrating empirical mode decomposition and deep learning[J]. Automation of Electric Power Systems, 2021, 45(24): 57-64.
- [25] 吴浩, 齐放, 张曦, 等. 基于小波包分解与最小二乘支持向量机的用户侧净负荷预测[J]. 现代电力, 2023, 40(2): 192-200.
- WU H, QI F, ZHANG X, et al. User-side net load forecasting based on wavelet packet decomposition and least squares support vector machine[J]. Modern Electric Power, 2023, 40(2): 192-200.
- [26] 伍乙杰, 黄文灏, 赖仕达, 等. 基于随机森林和双向长短期记忆网络的超短期负荷预测研究[J]. 电气自动化, 2022, 44(5): 35-37.
- WU Y J, HUANG W H, LAI S D, et al. Research on ultra-short-term load forecasting based on Random forest and bidirectional long-short-term memory network[J]. Electrical Automation, 2022, 44(5): 35-37.
- [27] 周念成, 廖建权, 王强钢, 等. 深度学习在智能电网中的应用现状分析与展望[J]. 电力系统自动化,

- 2019, 43(4): 180-191.
- ZHOU N C, LIAO J Q, WANG Q G, et al. Analysis and prospect of deep learning application in smart grid[J]. Automation of Electric Power Systems, 2019, 43(4): 180-191.
- [28] 赵兵, 王增平, 纪维佳, 等. 基于注意力机制的 CNN-GRU 短期电力负荷预测方法[J]. 电网技术, 2019, 43(12): 4370-4376.
- ZHAO B, WANG Z P, JI W J, et al. A short-term power load forecasting method based on attention mechanism of CNN-GRU[J]. Power System Technology, 2019, 43(12): 4370-4376.
- [29] LIAO H Y, RADHAKRISHNAN K K. Short-term load forecasting with temporal fusion transformers for power distribution networks[C]//2022 IEEE Sustainable Power and Energy Conference (iSPEC). Perth, Australia: IEEE, 2023: 1-5.
- [30] 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 Y, SONG Y B, JIN S, 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.
- [31] HUA Q, FAN Z, MU W, et al. A short-term power load forecasting method using CNN-GRU with an attention mechanism[J]. Energies, 2024, 18(1): 106.
- [32] 韩肖清, 李廷钧, 张东霞, 等. 双碳目标下的新型电力系统规划新问题及关键技术[J]. 高电压技术, 2021, 47(9): 3036-3046.
- HAN X Q, LI T J, ZHANG D X, et al. New issues and key technologies of new power system planning under double carbon goals[J]. High Voltage Engineering, 2021, 47(9): 3036-3046.
- [33] 张超然, 袁杭萍, 孙毅, 等. 基于预训练模型的机器阅读理解研究综述[J]. 计算机工程与应用, 2020, 56(11): 17-25.
- ZHANG C R, QIU H P, SUN Y, et al. Review of machine reading comprehension based on pre-training language model[J]. Computer Engineering and Applications, 2020, 56(11): 17-25.
- [34] 李云松, 张智晟. 基于 GRU-TGTransformer 的综合能源系统多元负荷短期预测[J]. 电力系统保护与控制, 2023, 51(15): 33-41.
- LI Y S, ZHANG Z S. Multi load short-term forecasting of an integrated energy system based on a GRU-TGTransformer[J]. Power System Protection and Control, 2023, 51(15): 33-41.
- [35] 孟伟, 俞斌, 白隆, 等. 基于 STGCN-Transformer 的短期电力净负荷预测[J]. 中国测试, 2025, 51(6): 160-169.
- MENG W, YU B, BAI L, et al. Short-term electricity net load forecasting based on STGCN-Transformer[J]. China Measurement & Test, 2025, 51(6): 160-169.
- [36] 刘伟, 蔡东升, 冯付勇, 等. 基于 DCT-CNN-GRU 的短期电力负荷预测研究[J]. 电测与仪表, 2026, 63(2): 138-147.
- LIU W, CAI D S, FENG F Y, et al. Research on short-term electric load forecasting based on DCT-CNN-GRU[J]. Electrical Measurement & Instrumentation, 2026, 63(2): 138-147.

收稿日期: 2025-04-19.

修回日期: 2025-06-18.

作者简介:



宋立业

宋立业(1972), 男, 博士, 副教授, 研究方向为智能电网优化运行等, 372492761@qq.com;



孟凡宇

孟凡宇(2000), 男, 硕士研究生, 研究方向为数据挖掘、电力负荷预测, 15658744@qq.com;



陈郁林

陈郁林(1992), 男, 博士, 副研究员, 研究方向为新能源分布式控制、信息物理安全、虚拟电厂, 本文通信作者, chenyl2017@zju.edu.cn.

(责任编辑 杨阳)