基于改进 CNN-GRU 模型的短期电力负荷预测研究

王寅超，陈博，俞俊霞，沈会
（国网上海市电力公司经济技术研究院，上海 200030）

摘　要： 为维护电力系统的稳定运行，满足电力系统对于短期电力负荷预测精度的需求，提出一种基于改进卷积神经网络与门控循环单元（CNN-GRU）模型的短期电力负荷预测方法。采用核主成分分析（KPCA）法处理多维输入数据，提取主要影响因素作为后续预测模型的输入。构建以改进鱼鹰算法（OOA）优化的 CNN-GRU 组合模型进行训练和预测，并引入注意力机制加强重要信息的影响，提升预测模型的预测性能。最后采用贝叶斯超参数（BH）理论优化的极端梯度提升（XGBoost）模型优化预测误差，并搭建仿真模型与多个模型进行对比实验，根据所得到的预测效果曲线和各项性能指标验证所提方法的有效性。实验结果表明，提出的改进 CNN-GRU 模型在训练与测试时的平均绝对百分比误差（MAPE）分别为 1.56%和 1.99%，由此可以得出所提出的改进预测模型具有更好的预测精度。

关键词： 短期负荷预测；核主成分分析；鱼鹰优化算法；门控循环单元；极端梯度提升
中图分类号： TP391　　**文献标志码：** A　　**DOI：** 10.19678/j.issn.1000-3428.0070109

Research on Short-Term Electricity Load Forecasting Based on Improved CNN-GRU Model

WANG Yinchao, CHEN Bo, YU Junxia, SHEN Hui
(Institute of Economy and Technology, State Grid Shanghai Municipal Electric Power Company, Shanghai 200030, China)

【Abstract】 For stable operation of the power system and to meet its demand for short-term power load forecasting accuracy, a short-term power load forecasting method based on the improved Convolutional Neural Network and Gated Recurrent Unit (CNN-GRU) model is proposed. A Kernel Principal Component Analysis (KPCA) is used to process the multidimensional input data, and the primary influencing factors are effectively extracted as inputs for the subsequent prediction model. A CNN-GRU combination model with an improved Osprey Optimization Algorithm (OOA) is constructed for training and prediction, and an attention mechanism is introduced to strengthen the influence of important information for enhancing the prediction performance of the prediction model. Finally, the eXtreme Gradient Boosting (XGBoost) algorithm optimized by Bayesian Hyperparameters (BH) theory is used to optimize the prediction error, a simulation model is constructed for comparison with multiple models, and the effectiveness of the proposed method is verified based on the obtained prediction effect curves and various performance indexes. The experimental results show that the Mean Absolute Percentage Error (MAPE) of the proposed CNN-GRU model during training and testing are 1.56% and 1.99%, respectively, indicating that the proposed model has improved prediction accuracy.

【Key words】 short-term load forecasting; Kernel Principal Component Analysis (KPCA); Osprey Optimization Algorithm (OOA); Gated Recurrent Unit (GRU); eXtreme Gradient Boosting (XGBoost)

0　引言

在当前可再生能源发电渗透率不断提高的新型电力系统中，为保证稳定性和安全性，合理配置电力市场资源，电力负荷预测研究的重要性和必要性越发重要[1-4]。

为逐步实现“双碳”发展目标，可再生能源的进一步开发利用将起到至关重要的作用[5]。随着我国电力市场的不断扩大，可再生能源发电在电力系统中的比重不断提升，其波动性和不确定性给电网稳定带来了巨大的挑战。为确保“双碳”发展目标稳步实施，同时提升电网的安全性、保障电力系统安全稳定运行以及经济效益，研发准确的电力负荷预测方案具有重要意义[6-8]。

目前，国内外学者对电力系统负荷预测领域展开了深入研究。由于负荷数据的不规律性和复杂多样的影响因素，传统负荷预测方法预测效果较为有限[9-10]。为进一步提升负荷预测精度，研究人员将

基金项目： 国网上海市电力公司科技项目（SGTYHT/23-JS-001）。
作者简介： 王寅超，男，高级工程师，主研方向为微电网控制、新能源发电控制与优化运行；陈博，高级工程师；俞俊霞、沈会，高级工程师、硕士。
收稿日期： 2024-07-12　　**修回日期：** 2024-08-17
E-mail： 13817480885@163.com

计算机工程 www.ecice06.com

机器学习、人工智能等方法融入电力负荷预测领域中，提出了一系列智能预测方法，以其优越的性能逐渐成为当前主流的电力系统负荷预测方法。

文献[11]采用改进 CEEMDAN 分解输入数据并用频谱时间图卷积网络进行预测，预测精度得到较大提升。文献[12]提出将卷积神经网络(CNN)与长短期记忆(LSTM)相结合的集成网络进行短期负荷预测，通过对比实验验证所提策略具有更好的预测效果。文献[13]分别构建基于特征注意力的编码器和基于时间注意力的解码器处理输入数据相关性和时间依赖性，以 LSMT 和弹球损失函数进行预测，仿真实验结果显示，所构建模型具有更高的准确性和泛化能力。文献[14]采用改进萤火虫算法优化支持向量回归模型参数，以非线性映射特征来处理非线性回归问题构建预测模型，经过对比实验得到所提策略具有较好的预测表现。文献[15]采用相似天数分析的负荷预测方法，与现有负荷预测对比，验证所提模型的可行性与高效性。

综上所述，加入了智能算法的电力负荷预测方案相较于传统方法在预测精度上有了较大的提升，在处理非线性、大规模和多特征数据方面体现出强大的能力，具有更为优秀的性能并能适应不断变化的电力需求[16-17]。由此将改进的智能算法融入传统电力负荷预测方法中，在保证预测模型运算速度和精度的条件下开发出更加高效、准确的短期电力负荷预测模型，以提升电力负荷预测准确性。为提升短期电力负荷预测模型的预测性能并保证预测模型的时间复杂度和预测准确度之间的均衡，同时更好地处理复杂多样的输入数据，本文提出一种基于改进卷积神经网络与门控循环单元(CNN-GRU)模型的短期电力负荷预测方法。采用核主成分分析(KPCA)法处理多维输入数据，降低数据非线性并有效提取主要影响因素作为后续输入。构建 CNN-GRU 组合模型进行训练和预测，以改进鱼鹰优化算法(OOA)搜索预测模型的最优超参数，并引入注意力机制加强重要信息的影响，提升预测模型的预测性能。采用贝叶斯超参数(BH)理论优化的极端梯度提升(XGBoost)优化预测误差，充分利用负荷预测的固有误差中所包含的部分潜在未被利用的信息。最后搭建仿真模型，与多个模型进行对比实验，根据得到的预测效果曲线及各项性能指标验证本文所提方法的预测精度。

1 基于改进 CNN-GRU 电力负荷预测模型

本文提出一种基于改进 CNN-GRU 模型的短期电力负荷预测方法来维护电力系统的稳定运行。首先对多维输入数据采用核主成分分析法进行处理，通过非线性映射将多维输入数据投影到高维空间，再应用主成分分析来提取主要特征从而降低数据非线性和复杂度，并将提取出的主要影响因素作为后续预测模型的输入。构建卷积神经网络与门控循环单元组合模型进行训练和预测，卷积神经网络捕捉局部特征，门控循环单元处理数据中的依赖关系，以改进鱼鹰优化算法搜索预测模型的最优超参数，并引入注意力机制加强重要信息的影响，提升预测模型的预测性能。采用贝叶斯理论优化的极端梯度提升算法来优化预测误差，构建超参数概率模型对极端梯度提升模型的超参数进行调整，充分利用负荷预测的固有误差中所包含的部分潜在未被利用的信息，有效降低预测误差，进一步提高组合模型的预测性能。

1.1 多维输入数据处理

负荷预测受到包括天气、温度、湿度、时间序列等多种因素的影响，而这些因素将会在一定程度上影响负荷预测的精度，由此本文采用核主成分分析处理多维输入数据，降低数据的非线性，并提取主要影响因素，有效提高后续短期电力负荷预测的准确度。

核主成分分析是一种通过将数据样本映射到高维特征空间进行主成分分析的方法，可有效降低如温度、湿度以及天气等多维非线性数据之间的相关性[18-19]，具体步骤如下：

假设将原始数据 X 表示为 $x_i \in \mathbb{R}^N$，$i=1,2,\cdots,n$，将其进行非线性变换 $H:\mathbb{R}^N \to F, x \to X$ 投影到特征空间 F，并假定特征空间中的元素为 $H(x_1),H(x_2),\cdots,H(x_n)$。

1)在特征空间 F 中对矩阵 $\boldsymbol{W}$ 进行线性主成分分析，$\boldsymbol{W}$ 的计算公式如下：

$$\boldsymbol{W}=\frac{1}{n}\sum_{j=1}^{n}H(x_j)H(x_j)^{\mathrm{T}} \tag{1}$$

2)为提升计算效率，定义 $\boldsymbol{W}=\boldsymbol{W}-B\boldsymbol{W}-\boldsymbol{W}B+B\boldsymbol{W}B$，更新矩阵 $\boldsymbol{W}$，使得满足：

$$\sum_{i=1}^{n}H(x_i)=0 \tag{2}$$

3)由奇异值分解可得计算矩阵的特征值 λ_k 和特征向量 $\boldsymbol{v}_k$，计算公式如下：

$$\boldsymbol{W}\boldsymbol{v}_k=\lambda_k\boldsymbol{v}_k \tag{3}$$

4)将特征向量 $\boldsymbol{v}_k$ 代入 $\boldsymbol{W}$：

$$\boldsymbol{W}\boldsymbol{v}_k=\frac{1}{n}\sum_{i=1}^{n}H(x_i)^{\mathrm{T}}[H(x_i)\boldsymbol{v}_k] \tag{4}$$

5)将特征向量 $\boldsymbol{v}_k$ 变换为 $H(x_i)$的线性组合：

$$\boldsymbol{v}_k=\sum_{i=1}^{n}a_{ki}H(x_i) \tag{5}$$

式中：a_{ki} 为 $H(x_i)$转换为 $\boldsymbol{v}_k$ 的系数。

6)$H(x)$在特征向量 $\boldsymbol{v}_k$ 上的映射为：

$$H(x)\boldsymbol{v}_k=\sum_{i=1}^{n}a_{ki}H(x)H(x_i)=\sum_{i=1}^{n}a_{ki}k(x,x_i) \tag{6}$$

式中：$k(x,x_i)$为 $H(x)$与 $H(x_i)$的内积。

7)重构的核主成分和方差贡献率为：

$$X'_k=X\boldsymbol{v}_k \tag{7}$$

$$\theta_k=\frac{\lambda_k}{\sum_{k=1}^{n}\lambda_k} \tag{8}$$

式中：X'_k为第 k 个核主成分；θ_k 为第 k 个核主成分的方差贡献率。

通过设定方差贡献率阈值 θ，选择不同的核函数实现数据的降维。根据短期电力负荷预测会受到多种非线性的因素影响，由此本文选取使用高斯核作为核函数的核主成分分析的方法，通过让高斯核选择合适的参数调整映射后数据在高维空间中的分布特性，并以前 k 个最大特征值对应的特征向量构成新的特征空间，以此达到对输入数据有效保留重要数据信息的同时降低数据的维度。KPCA 过程如图 1 所示(彩色效果见《计算机工程》官网 HTML 版，下同)。

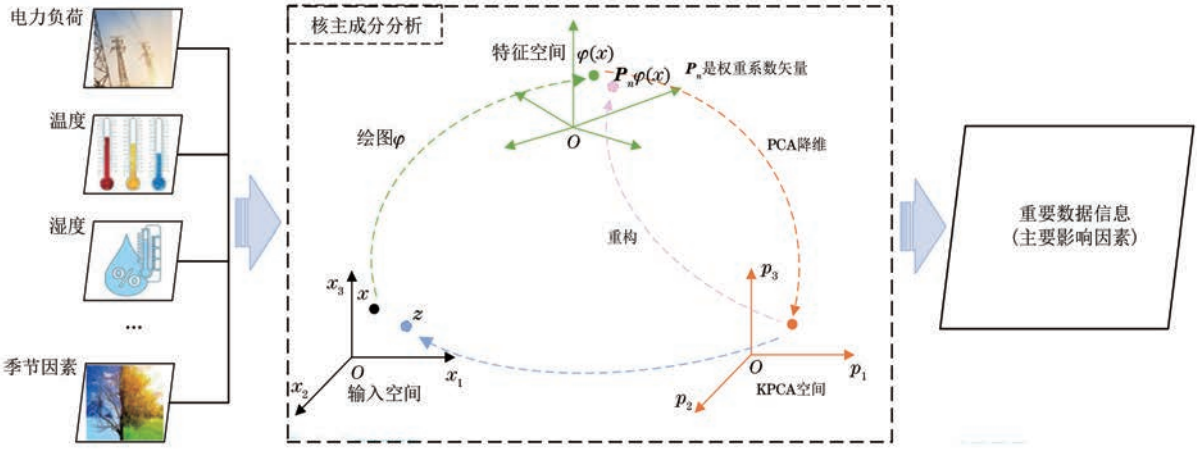


图 1 核主成分分析过程

Fig. 1 Kernel principal component analysis process diagram

1.2 改进预测模型

1.2.1 卷积神经网络

CNN 模型在特征提取方面具有出色的性能，能够有效地提取电力负荷与其他影响因素之间的相关特征，并构建相应的特征表示。CNN 模型由卷积层、池化层以及全连接层 3 个部分组成，其中，卷积层可提取输入数据的特征，池化层可选择和过滤特征，全连接层将特征转化为向量输出[20-22]。CNN 的结构如图 2 所示。

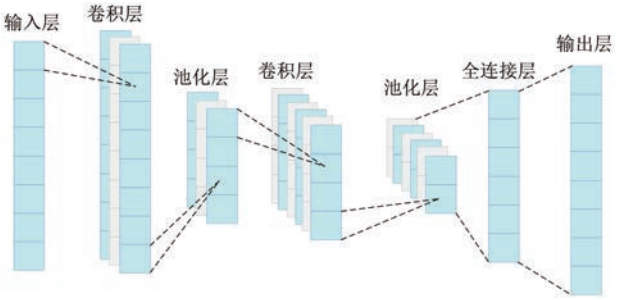


图 2 CNN 结构

Fig. 2 CNN structure

1.2.2 门控循环单元

RGU 是一种循环神经网络(RNN)的变体，在简化了模型结构的同时保证了模型的性能。GRU 模型主要包括更新门与复位门两个关键门控单元，更新门确定过去信息的保留程度，重置门控制过去信息在当前的遗忘程度[23]。GRU 的结构如图 3 所示。

在图 3 中，x_t 为输入，z_t 和 r_t 分别为更新门和重置门，h_t 为隐藏层的输出，具体计算公式如下：

$$z_t=\sigma(\boldsymbol{W}^{(z)}x_t+\boldsymbol{U}^{(z)}h_{t-1}) \tag{9}$$

$$r_t=\sigma(\boldsymbol{W}^{(r)}x_t+\boldsymbol{U}^{(r)}h_{t-1}) \tag{10}$$

$$\tilde{\boldsymbol{h}}_t=\tanh(r_t\circ\boldsymbol{U}h_{t-1}+\boldsymbol{W}x_t) \tag{11}$$

$$\boldsymbol{h}_t=(1-z_t)\circ\tilde{\boldsymbol{h}}_t+z_t\circ h_{t-1} \tag{12}$$

式中：$\tilde{\boldsymbol{h}}_t$ 为隐藏状态向量；$\boldsymbol{W}^{(z)}$、$\boldsymbol{U}^{(z)}$、$\boldsymbol{W}^{(r)}$、$\boldsymbol{U}^{(r)}$、$\boldsymbol{U}$ 和 $\boldsymbol{W}$ 为权重矩阵；σ 代表 Sigmoid 函数；tanh 代表

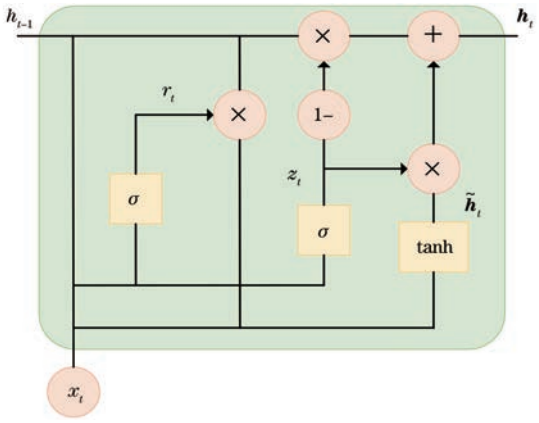


图 3 GRU 结构

Fig. 3 GRU structure

双曲正切函数。σ、tanh 的计算公式分别如式(13)、式(14)所示：

$$\sigma(x)=\frac{1}{1+e^{-x}} \tag{13}$$

$$\tanh(x)=\frac{e^{x}-e^{-x}}{e^{x}+e^{-x}} \tag{14}$$

1.2.3 改进鱼鹰优化算法

鱼鹰优化算法是一种模拟鱼鹰捕食行为发展而来的优化算法，以全局搜索和局部开采行为得到最优解，具有高效的搜索能力和快速的收敛性能[24]，主要过程如下：

1)初始化一个鱼鹰种群，定义每个鱼鹰个体的位置向量和搜索边界，位置向量公式如式(15)所示：

$$\boldsymbol{x}_{i,j}=l_j+r\cdot(u_j-l_j) \tag{15}$$

式中：u_j 和 l_j 表示第 j 维的上下界；r 是[0,1]之间的一个随机数；$i=1,2,\cdots,N$，$j=1,2,\cdots,D$，$D=2$，$N=150$。

2)计算每个鱼鹰个体的适应度值。

3)定位与捕鱼(全局搜索)，每个鱼鹰个体以式(16)更新位置，并进行边界处理，对于超出边界的个体修正至边界上，计算适应度，将最好的适应度替换至当前位置：

$$\boldsymbol{x}_{i,j}^{P_1}=\boldsymbol{x}_{i,j}+r_{i,j}\cdot(F_{i,j}-I_{i,j}\cdot\boldsymbol{x}_{i,j}) \tag{16}$$

式中：$F_{i,j}$ 是随机选择的适应度较好的鱼鹰个体位置；$I_{i,j}$ 是{1,2}之间的随机整数。

4)将鱼带到合适位置(局部开发)，鱼鹰个体将捕获的鱼带到合适位置食用，即算法中的局部搜索，位置更新公式如式(17)所示：

$$\boldsymbol{x}_{i,j}^{P_2}=\boldsymbol{x}_{i,j}+\frac{l_j+r\cdot(u_j-l_j)}{t} \tag{17}$$

式中：t 是当前迭代次数。随着迭代次数的增加，局部搜索范围变小，算法收敛。

5)终止条件，达到预设最大迭代次数或满足其他终止条件。

鱼鹰优化算法通过全局搜索和局部开发的方式进行位置更新，可有效优化神经网络的初始权值和阈值以改善网络性能，算法流程如图 4 所示。

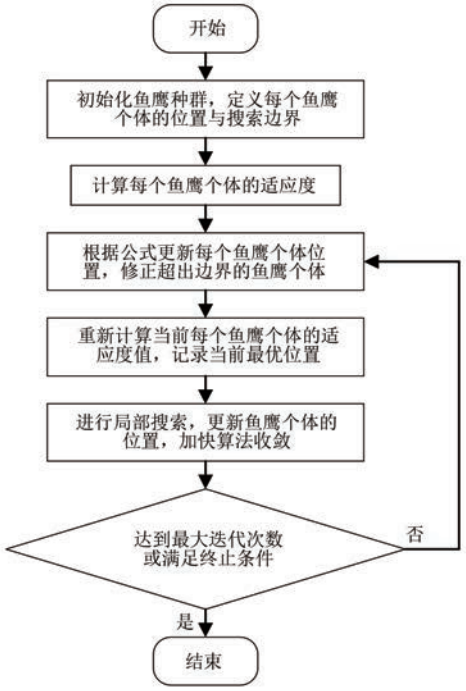


图 4 鱼鹰优化算法流程

Fig. 4 Osprey optimization algorithm procedure

为提升上述鱼鹰算法的寻优能力并避免局部最优问题，采用基于 Sobol 序列的种群初始化方法增加种群多样性，并引入 Lévy 策略改进鱼鹰个体位置进行更新，避免出现局部最优情况。

在鱼鹰种群的初始化过程中引入 Sobol 序列得到鱼鹰种群位置向量，如式(18)所示：

$$\boldsymbol{x}_{i,j}=l_j+S_{i,j}\cdot(u_j-l_j) \tag{18}$$

式中：$S_{i,j}$ 是在[0,1]之间的 Sobol 序列值。

为避免陷入局部最优问题，增强鱼鹰个体的移动能力，引入一个 Lévy 分布：

$$L_{\text{Lévy}}(x)=0.01\frac{r_1\sigma}{|r_2|^{\frac{1}{\beta}}} \tag{19}$$

$$\sigma=\left(\frac{\Gamma(1+\beta)\sin\frac{\pi\beta}{2}}{\Gamma\left(\frac{1+\beta}{2}\right)\beta\cdot 2^{\left(\frac{\beta-1}{2}\right)}}\right)^{\frac{1}{\beta}} \tag{20}$$

式中：r_1 和 r_2 为 0～1 之间的随机数；β 为常量，设为 1.5；$\Gamma()$为 Gamma 函数。

Lévy 的位置更新公式为：

$$l_e=\frac{u}{|v|^{\frac{1}{\beta}}} \tag{21}$$

式中：u 为 $u\sim N(0,\sigma^2)$；v 为 $v\sim N(0,1)$。

更新后的鱼鹰个体位置更新公式如式(22)、式(23)所示：

$$\boldsymbol{x}_{i,j}^{P_1}=l_e\cdot\boldsymbol{x}_{i,j}+r_{i,j}\cdot(F_{i,j}-I_{i,j}\cdot\boldsymbol{x}_{i,j}) \tag{22}$$

$$\boldsymbol{x}_{i,j}^{P_2}=l_e\cdot\boldsymbol{x}_{i,j}+\frac{l_j+r\cdot(u_j-l_j)}{t} \tag{23}$$

利用改进鱼鹰优化算法避免局部最优问题的同时，快速收敛找到 CNN-GRU 模型最优超参数，增强预测模型的精度。

1.2.4 Attention 机制

Attention 机制模仿了人脑对事物的注意力分配方式，赋予重要信息足够的关注度，从而提高了预测模型的准确性[25]。Attention 机制的结构如图 5 所示，其中，x_t 表示 GRU 输入，$\boldsymbol{h}_t$ 表示隐藏层输出，α_t 表示注意力分配权重，y 表示输出。

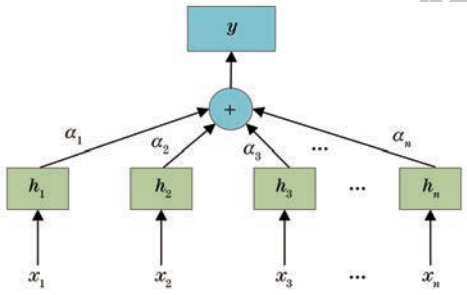


图 5 Attention 机制结构

Fig.5 Attention mechanism structure

1.3 极限梯度提升误差修正模型

在短期电力负荷预测中会存在一定的固有误差，其中包含有部分潜在信息未被完全利用的问题，选择 XGBoost 学习预测误差的变化规律，从而改进和修正预测模型，进一步提高预测精度。

XGBoost 本质上是一种梯度提升决策树，可以有效提升预测的速度和效率。通过不断添加树和连续分割特征生成新的决策树来降低之前的预测误差，提升预测精度。在误差修正问题上，主要采用分类与回归树的模型，其计算公式如下：

$$\hat{y}_i=\sum_{k=1}^{n}f_k(x_i),\ f_k(x_i)\in F,\ i=1,2,\cdots,n \tag{24}$$

式中：n 为样本数；F 为回归树集合；f_k 为 F 中第 k 个函数；$\hat{y}_i$ 为树的预测值。

XGBoost 误差修正模型以列抽样的方式进行学习训练，为了提升误差修正模型的泛化能力，采用贝叶斯理论优化 XGBoost 模型中的超参数，定义超参数的搜索空间，通过迭代将性能更好的超参数应用于误差修正模型中，使得模型具有较好的影响变量信息提取功能，同时提升了运行时间，也提高了短期电力预测的精度。

1.4 改进 CNN-GRU 电力负荷预测流程

为实现维护电力系统的稳定运行，本文提出一种基于改进 CNN-GRU 模型的短期电力负荷预测方法。首先对多维输入数据采用核主成分分析法进行处理，将多维输入数据映射到高维空间，采用主成分分析提取数据中的主要影响因素，从而有效降低数据非线性和复杂度并有效提取主要影响因素作为后续预测模型的输入。构建 CNN-GRU 组合模型进行训练和预测，CNN 层对输入数据进行特征提取，GRU 层对 CNN 层提取后数据中的时序依赖关系进行学习，得到数据内部变化规律，并通过改进鱼鹰优化算法搜索预测模型最优超参数，引入注意力机制加强输入数据中重要信息的影响，提升预测模型的预测性能。最后采用贝叶斯理论优化的极端梯度提升模型来进一步优化预测误差，构建概率模型优化极端梯度提升模型中的超参数，降低预测误差，提高预测模型的精度，从而进一步提升整体预测模型的准确性和可靠性。具体流程如图 6 所示。

2 仿真结果与分析

2.1 仿真条件

本文在 Python 中通过构建 CNN-GRU 模型、PCA-CNN-GRU 模型、CNN-GRU-Attention 模型以及本文改进 CNN-GRU 模型进行比较实验，以某地区的用电负荷、温度以及湿度作为输入数据进行实验。为方便后期对比，定义本文提出方法为方案 1，CNN-GRU 模型为方案 2，PCA-CNN-GRU 模型为方案 3，CNN-GRU-Attention 模型为方案 4。为验证本文所提方案的有效性，比较 4 种方案所得到的平均绝对误差(MAE)、均方误差(MSE)、均方根误差(RMSE)以及平均绝对百分比误差(MAPE)等性能指标，从而验证本文所提方法对于提升短期电力负荷预测精度的有效性和优越性。

同时为验证本文所提出的模型的有效性以及普适性，在 Python 中构建 PCA-CNN-LSTM-Attention 模型、PCA-GRU-Attention 模型、PCA-TCN-Attention 模型以及本文改进 CNN-GRU 模型进行比较实验，得到 4 种方案的训练和测试曲线，以及 MAE、MSE、RMSE、MAPE 等指标数据。为方便后期对比，定义本文提出方案为方案 a，CNN-GRU 模型方案为方案 b，PCA-CNN-GRU 模

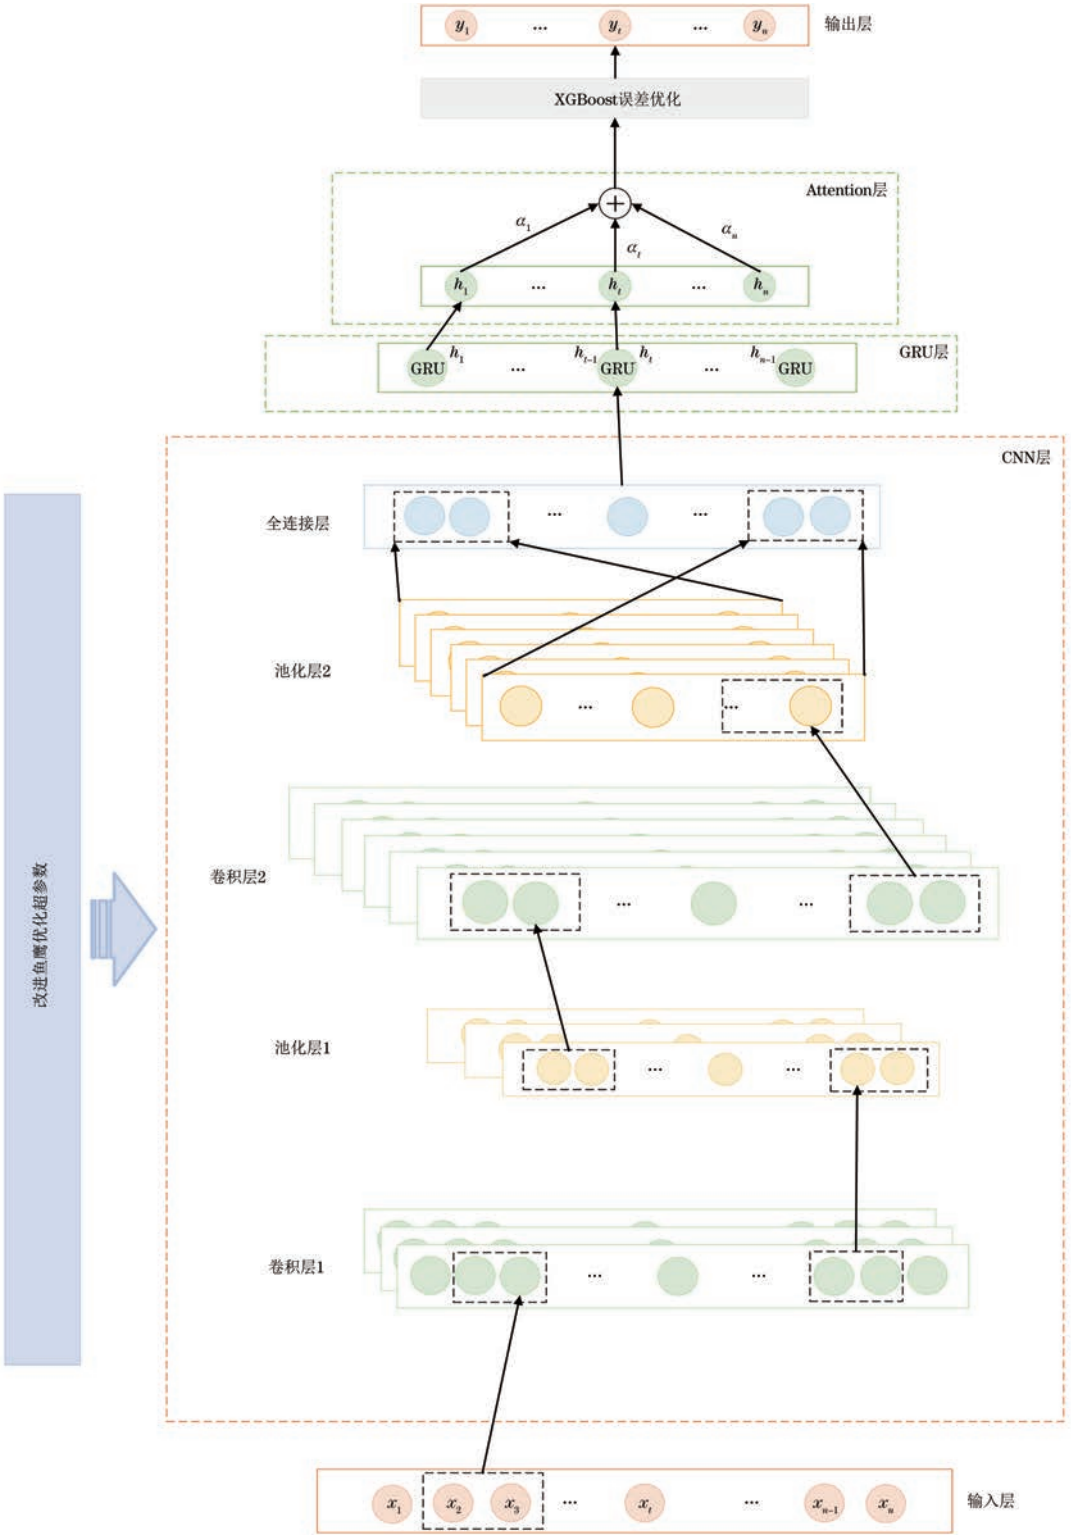


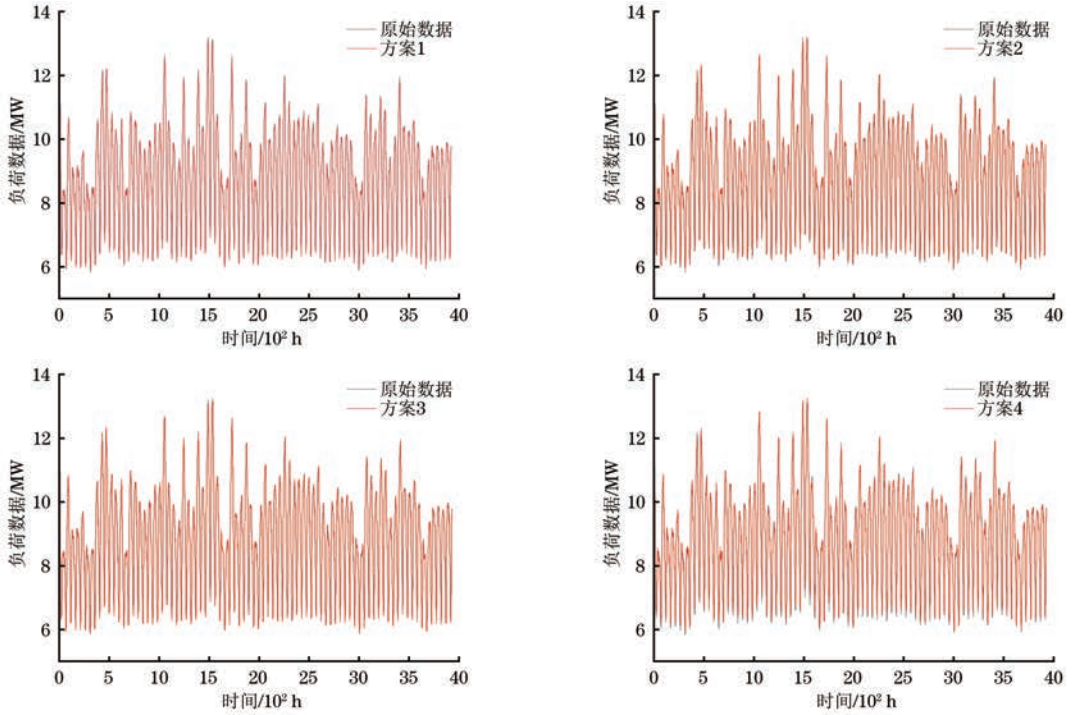
图 6 改进模型结构

Fig. 6 Improved model structure

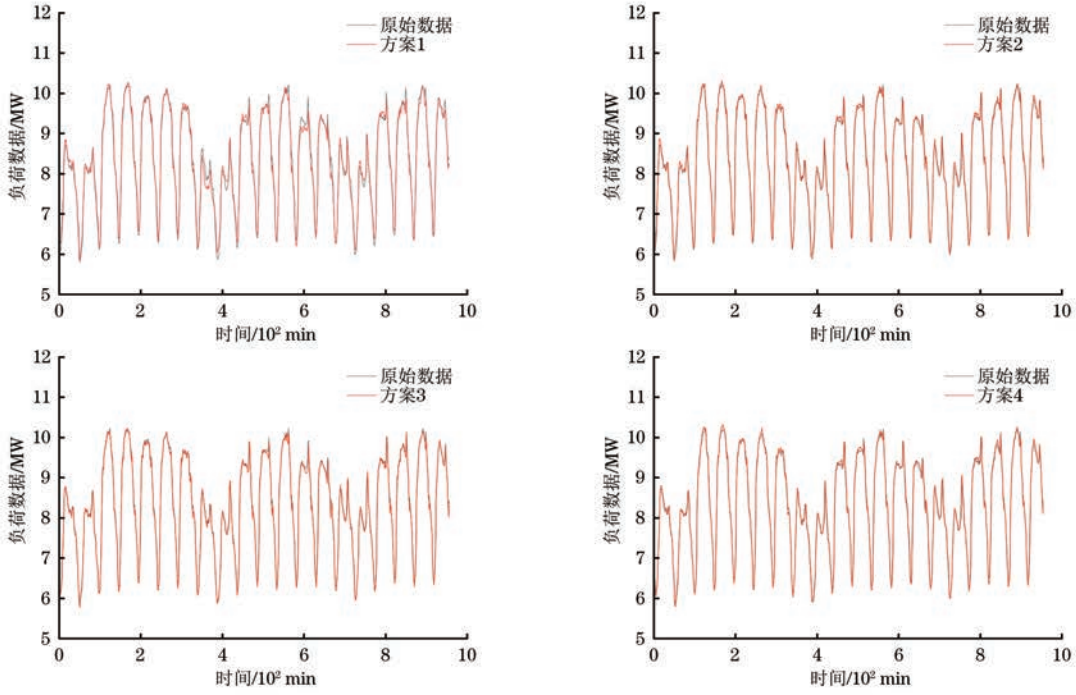
型方案为方案 c，CNN-GRU-Attention 模型为方案 d。

2.2 短期电力负荷预测仿真实验

本文以三维数据输入进行实验，将某地区的用电负荷、温度以及湿度作为输入数据进行实验，共 5 000 组数据，选取前 4 000 组数据作为训练集，剩余 1 000 组数据作为测试集，得到两组对比实验的训练与测试效果以及误差指标对比，如图 7 和表 1 所示。为更清晰地比对第一组对比实验训练与测试图中的效果曲线，截取其中部分曲线得到图 8 和图 9；同时为更直观地对比第一组对比实验不同模型所得的误差指标，得到误差指标柱状图如图 10 和图 11 所示。



(a)训练效果曲线



(b)测试效果曲线

图 7 各方案的训练与测试效果

Fig. 7 Training and test results for each program

表 1 各方案性能指标对比

Table 1 Comparison of performance indicators of each schemes

方案	MAE		MSE		RMSE		MAPE/%	
	训练	测试	训练	测试	训练	测试	训练	测试
方案 1	0.09	0.12	0.01	0.02	0.11	0.15	1.56	1.99
方案 2	0.19	0.20	0.04	0.07	0.21	0.27	2.21	2.63
方案 3	0.17	0.19	0.04	0.06	0.19	0.24	2.12	2.41
方案 4	0.13	0.23	0.03	0.08	0.16	0.29	1.87	2.98

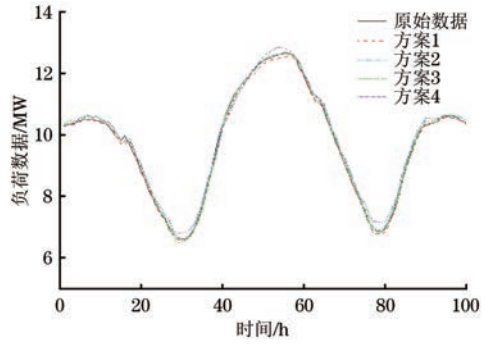


图 8 部分训练效果曲线

Fig. 8 Partial training effect curves

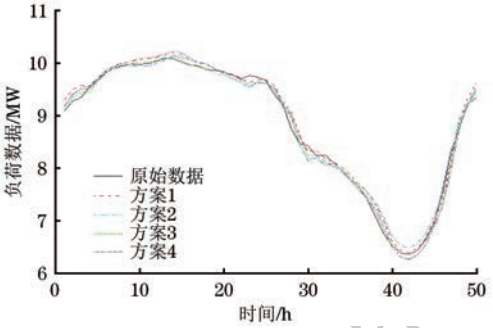


图 9 部分测试效果曲线

Fig. 9 Partial test effect curves

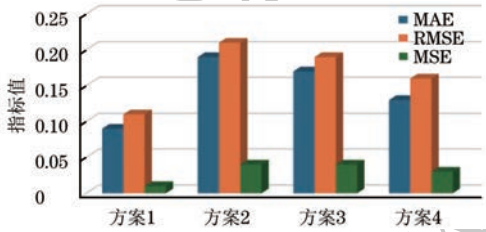


图 10 训练误差指标

Fig. 10 Training error indicator

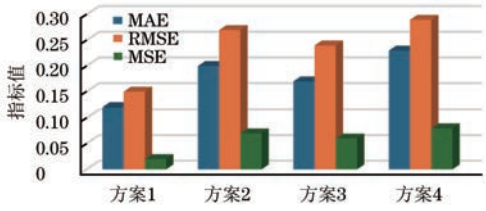


图 11 测试误差指标

Fig. 11 Test error indicator

2.3 仿真实验分析

为验证本文所提出的方法对于提升短期电力负荷预测精度的有效性，进行了两组对比实验，得到了在同一数据集输入的条件下不同预测模型的训练效果曲线、测试效果曲线以及各个方案的误差指标数据，分析第一组对比实验的图像曲线和表格数据可以看到：方案 1 所得到的训练效果图像和测试效果图像相较于其他 3 种方案所得图像更贴近原数据曲线；同时由性能指标对比中的误差数据和误差指标柱状图可得出，对比 4 种方案所得的训练和测试的 MAE、MSE、RMSE、MAPE 误差指标，方案 1 训练和测试的 MAE、MSE、RMSE、MAPE 误差指标均小于其他 3 种方案。由此可以看出，方案 1 相较于其他 3 种方案在同一个输入数据集的条件下具有更好的预测效果和预测精度。同时，为了验证模型的普适性和鲁棒性，将相似的模型进行对比实验，观察所得到的训练效果和测试效果以及误差指标数据，如图 12、图 13 和表 2 所示。可以看出，方案 a 的预

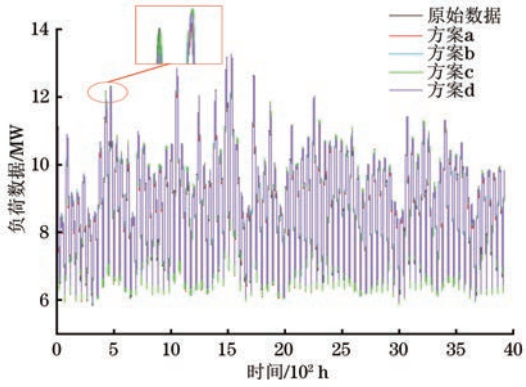


图 12 不同方案训练效果

Fig. 12 Training effect of different schemes

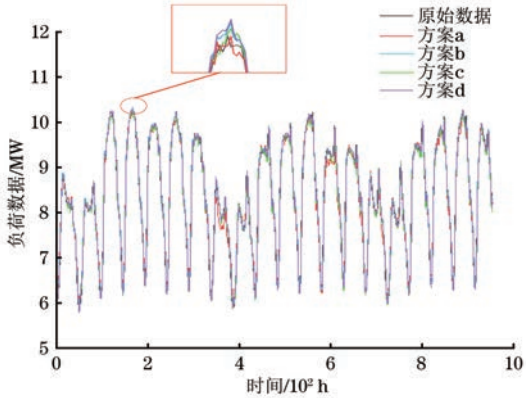


图 13 不同方案测试效果

Fig. 13 Test effect of different schemes

表 2 不同方案性能指标对比

Table 2 Comparison of performance indicators of different schemes

方案	MAE		MSE		RMSE		MAPE/%	
	训练	测试	训练	测试	训练	测试	训练	测试
方案 a	0.09	0.12	0.01	0.02	0.11	0.15	1.56	1.99
方案 b	0.11	0.15	0.03	0.05	0.14	0.21	1.89	2.13
方案 c	0.11	0.15	0.03	0.05	0.14	0.22	1.94	2.16
方案 d	0.13	0.18	0.04	0.07	0.16	0.25	2.18	2.48

测效果优于其他方案，由此本文所提出的方案对于短期电力负荷预测的精度具有一定的提升作用，并验证了本文对于提升短期电力负荷预测精度的有效性和优越性。

3 结束语

本文旨在一定程度上解决不准确的短期电力负荷预测给电力系统带来的安全隐患问题，提出一种基于改进 CNN-GRU 模型的短期电力负荷预测方法，预测模型的准确性，保证电力系统的安全稳定运行。首先对多维输入数据采用核主成分分析法进行处理，降低数据非线性并有效提取主要影响因素，为后续预测模型提供更好的输入。构建 CNN-GRU 组合模型进行训练和预测，改进鱼鹰优化算法，得到预测模型的最优超参数，并引入注意力机制加强对重要信息的处理，提升预测模型的预测性能。采用极端梯度提升算法优化预测误差，充分利用固有误差中部分未被利用的信息，以便进一步提高预测精度。最后以某地区的用电负荷、温度以及湿度的三维输入数据进行验证实验，经过两组对比实验比较不同方案所得到的训练及测试图像和各项性能指标，结果表明，本文提出的方法优于其他的对比方法，从而验证本文方法对于提升短期电力负荷预测精度的有效性和优越性。同时本文所提出的模型在处理影响短期电力负荷预测的多种影响因素的问题以及预测模型的最优超参数寻优问题上，增加了一定的计算复杂度和运算时长，但综合考虑未来实际应用中电力系统对于预测精度的要求，提出模型可根据具体需求和计算资源进行调整，以达到最优的预测性能和计算效率的平衡，具有一定的现实意义和应用前景。

参考文献

[1] 赖小玲，贺嫚嫚，胡伟，等. 基于改进变分模态分解与深度学习的多因素电力负荷预测[J]. 计算机工程，2025，51(2)：375-386.
LAI X L，HE M M，HU W，et al. Multi-factor power load forecasting based on improved variational mode decomposition and deep learning[J]. Computer Engineering，2025，51(2)：375-386.（in Chinese）

[2] YANG J，QIN Z J，LIM H，et al. Short-term power load forecasting of a city in Henan province using attention based LTSM[C]//Proceedings of the 6th Asia Energy and Electrical Engineering Symposium. Washington D. C.，USA：IEEE Press，2024：1186-1192.

[3] GAO J G，WANG K，KANG X H，et al. Ultra-short-term electricity load forecasting based on improved random forest algorithm[J]. AIP Advances，2023，13(6)：065208.

[4] CAO Z N，WANG J Z，XIA Y R. Combined electricity load-forecasting system based on weighted fuzzy time series and deep neural networks[J]. Engineering Applications of Artificial Intelligence，2024，132：108375.

[5] 黄雨涵，丁涛，李雨婷，等. 碳中和背景下能源低碳化技术综述及对新型电力系统发展的启示[J]. 中国电机工程学报，2021，41(S1)：28-51.
HUANG Y H，DING T，LI Y，et al. Overview of low carbon energy technologies under carbon neutrality background and implications for the development of new power systems[J]. Chinese Journal of Electrical Engineering，2021，41(S1)：28-51.（in Chinese）

[6] 程明，翟金星，马骏，等. 基于迁移学习的 CNN-GRU 短期电力负荷预测方法[J]. 武汉大学学报(工学版)，2024，57(6)：812-820.
CHENG M，ZHAI J X，MA J，et al. CNN-GRU short term power load forecasting method based on transfer learning[J]. Journal of Wuhan University(Engineering Edition)，2024，57(6)：812-820.（in Chinese）

[7] MAGALHAES B，BENTO P，POMBO J，et al. Short-term load forecasting based on optimized random forest and optimal feature selection[J]. Energies，2024，17(8)：1926.

[8] 王寅超，蒋本建，韩东，等. 基于变分模态分解数据分解的多通道短期电力负荷预测模型[J]. 流体测量与控制，2024，5(3)：25-31.
WANG Y C，JIANG B J，HAN D，et al. A multi-channel short-term power load forecasting model based on variational mode decomposition data decomposition[J]. Fluid Measurement and Control，2024，5(3)：25-31.（in Chinese）

[9] 曾小青，胡敏，刘澳. “双碳”背景下基于用电行为大数据的电力负荷预测[J]. 现代工业经济和信息化，2023，13(4)：27-31，34.
ZENG X Q，HU M，LIU A. Power load forecasting based on big data of electricity consumption behavior under the background of “dual carbon”[J]. Modern Industrial Economy and Informatization，2023，13(4)：27-31，34.（in Chinese）

[10] CHEN J L，SUN L，WU B. An improved whale algorithm for power load forecasting based on adaptive weight adjustment[J]. Journal of Physics，2023，26(1)：012061.

[11] 朱莉，夏禹，朱春强，等. 基于 CEEMDAN 和频谱时间图卷积网络的电力负荷预测方法[J]. 计算机工程，2025，51(4)：339-349.
JU L，XIA Y，ZHU C Q，et al. Electric load forecasting method based on CEEMDAN and spectrum time graph convolutional network[J]. Computer Engineering，2025，51(4)：339-349.（in Chinese）

[12] RAFI S H，NAHID-AL-MASOOD，DEEBA S R，et al. A short-term load forecasting method using integrated CNN and LSTM network[J]. IEEE Access，2021，9：32436-32448.

[13] LIN J，MA J，ZHU J G，et al. Short-term load forecasting based on LSTM networks considering attention mechanism[J]. International Journal of Electrical Power & Energy Systems，2022，137：107818.

[14] KAVOUSI-FARD A，SAMET H，MARZBANI F. A new hybrid modified firefly algorithm and support vector regression model for accurate short term load forecasting[J]. Expert Systems with Applications，2014，41(13)：6047-6056.

[15] JIANG Z X，ZHANG L L，JI T Y. NSDAR：a neural network-based model for similar day screening and electric load forecasting[J]. Applied Energy，2023，349：121647.

[16] 母先应，罗彬，陆志华，等. 深度学习驱动的电力负荷预测方法研究[J]. 电脑知识与技术，2023，19(23)：23-25.
MU X Y，LUO B，LU Z H，et al. Research on power load forecasting method driven by deep learning[J]. Computer Knowledge and Technology，2023，19(23)：23-25.（in Chinese）

[17] LI Y Z，ZHANG F S，LIU Y，et al. Residential load forecasting：an online-offline deep kernel learning method

[J]. IEEE Transactions on Power Systems, 2024, 39(2): 4264-4278.

[18] ZHANG Z Y, DENG A B, WANG Z W, et al. Wind power prediction based on EMD-KPCA-BiLSTM-ATT model[J]. Energies, 2024, 17(11): 2568.

[19] 董 浩,李明星, 张淑清, 等. 基于核主成分分析和极限学习机的短期电力负荷预测[J]. 电子测量与仪器学报, 2018, 32(1): 188-193.
DONG H, LI M X, ZHANG S Q, et al. Short term power load forecasting based on kernel principal component analysis and extreme learning machine[J]. Journal of Electronic Measurement and Instrumentation, 2018, 32(1): 188-193. (in Chinese)

[20] AHMAD A AL-JA'AFREH M, MOKRYANI G, AMJAD B. An enhanced CNN-LSTM based multi-stage framework for PV and load short-term forecasting: DSO scenarios[J]. Energy Reports, 2023, 10: 1387-1408.

[21] ALI AGGA F, ABBOU S A, EL HOUM Y, et al. Short-term load forecasting based on CNN and LSTM deep neural networks[J]. IFAC-PapersOnLine, 2022, 55(12): 777-781.

[22] 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. CNN-GRU short term power load forecasting method based on attention mechanism[J]. Grid Technology, 2019, 43(12): 4370-4376. (in Chinese)

[23] 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/OL]. 电测与仪表: 1-11 [2024-03-22]. https://kns.cnki.net/kcms/detail/23.1202.th.20240321.1323.002.html.
LIU W, CAI D S, FENG F Y, et al. Research on short-term power load forecasting based on DCT-CNN-GRU[J/OL]. Electrical Measurement & Instrumentation, 2024: 1-11. [2024-03-22]. https://kns.cnki.net/kcms/detail/23.1202.th.20240321.1323.002.html. (in Chinese)

[24] ZHANG Y, LIU P T. Research on reactive power optimization based on hybrid osprey optimization algorithm[J]. Energies, 2023, 16(20): 7101.

[25] 赵星宇, 吴泉军, 展晴晴, 等. 基于贝叶斯优化注意力机制 LSTNet 模型的短期电力负荷预测[J]. 科学技术与工程, 2023, 23(15): 6465-6472.
ZHAO X Y, WU Q J, ZHAN Q Q, et al. Short term power load forecasting based on Bayesian optimization attention mechanism LSTNet model[J]. Science Technology and Engineering, 2023, 23(15): 6465-6472. (in Chinese)

文字编辑 索书志
栏目编辑 宋 圆

计算机工程 www.ecice06.com