

DOI:10.3969/j.issn.2097-0706.2022.09.005

基于 EEMD-BiLSTM 的可调节负荷预测方法

Prediction method for adjustable load based on EEMD-BiLSTM

李彬¹, 胡纯瑾^{1*}, 王婧²
LI Bin¹, HU Chunjin^{1*}, WANG Jing²

(1. 华北电力大学 电气与电子工程学院, 北京 102206; 2. 国网综合能源服务集团有限公司, 北京 100052)

(1. School of Electrical and Electronic Engineering, North China Electric Power University, Beijing 102206, China;

2. State Grid Integrated Energy Service Group Company Limited, Beijing 100052, China)

摘要:“双碳”目标下,可调节负荷成为电网新兴调节资源。为解决经验模态分解(EMD)的模式混叠现象,同时获取负荷序列良好的时间感知能力,提出了一种集合经验模态分解(EEMD)和双向长短期记忆(BiLSTM)组合的可调节负荷预测方法 EEMD-BiLSTM。首先分析了 EEMD 和 BiLSTM 的原理,通过将预处理的可调节负荷序列通过 EEMD 算法进行分解,然后将分解后的分量数据和原始数据分别进行预测建模及重构。试验结果表明 EEMD-BiLSTM 能够有效表达可调节负荷的时序关系,预测精度高。

关键词:“双碳”目标;集成经验模态分解;双向长短期记忆网络;可调节负荷;负荷预测;需求响应

中图分类号:TK 01

文献标志码:A

文章编号:2097-0706(2022)09-0033-07

Abstract: To achieve the goals of carbon peaking and carbon neutrality, adjustable load has become emerging regulation resources of the power grid. In order to solve the mode aliasing phenomenon in EMD and obtain good time perception of load series, an adjustable load prediction method that combines EEMD with BiLSTM is proposed. The working principles of EEMD and BiLSTM were expounded. The preprocessed adjustable load series was decomposed by EEMD algorithm, and then the decomposed component data and original data were used for load prediction modeling and reconstruction, respectively. Experimental results show that EEMD-BiLSTM can effectively express the relation between time sequence and adjustable load with a high accuracy.

Keywords: dual carbon target; ensemble empirical mode decomposition (EEMD); bidirectional long short term memory (BiLSTM); adjustable load; load forecasting; demand response

0 引言

“双碳”目标下,加快构建以新能源为主体的新型电力系统成为必然,为有效提升电网调节能力,源荷互动电网调控模式必将替代传统的“源随荷动”。2022 年,国家发展改革委、国家能源局发布《关于完善能源绿色低碳转型体制机制和政策措施的意见》(发改能源〔2022〕206 号)^[1],提出积极推动电力需求响应市场化建设,将需求侧可调节资源纳入电力电量平衡,发挥需求侧资源削峰填谷、促进电力供需平衡和适应新能源电力运行的作用。可调节负荷作为新兴电网调节资源,能有效改善电网调节资源的局限性,实现“双碳”目标。通过市场机

制创新,可调节负荷可参与电力中长期、现货、调峰、调频、备用市场等。可调节负荷参与市场涉及电网企业、用户、发电企业等的切身利益^[2],不同负荷侧调节资源间及其与传统电源侧调节资源间、与调度机构间存在市场准入、调节量计算等协调需要。

文献[3]阐述了电力负荷预测中常用的几类深度学习算法,对比分析验证得出长短期记忆(LSTM)神经网络算法具有较好的预测性能。文献[4]以卷积神经网络(CNN)与 LSTM 神经网络对时间序列的较强处理能力,提出 CNN-LSTM 混合神经网络模型算法,对时序性短期负荷进行预测。文献[5]在 LSTM 神经网络基础上引入注意力机制,以突出对负荷预测起到关键作用的输入特征,提出基于 Attention-LSTM 网络的短期负荷预测模型。文献[6]在已有的 LSTM 神经网络模型和宽度&深度模型的基础上,建立 Wide&Deep-LSTM 深度学习短期负

收稿日期:2022-02-25;修回日期:2022-05-02

基金项目:国网综合能源服务集团有限公司科技项目(52789921N00D)

荷预测模型,有效解决台区电力负荷预测的多特征维度及时序性特征问题。文献[7]提出一种经验模态分解-堆栈式长短期记忆(Empirical Mode Decomposition-Spatial Long Short Term Memory, EMD-SLSTM)组合的短期负荷预测算法,分别对分量负荷和原始负荷数据进行预测建模及其重构,结果表明经验模态分解算法虽然能有效提高模型的预测性能,但容易出现模态混叠现象,预测模型无法达到更优的准确度。文献[8]通过构建集合经验模态分解(Ensemble Empirical Mode Decomposition, EEMD)及门控循环单元(GRU)神经网络和多元线性回归(MLR)组合而成的 EEMD-GRU-MLR (EGM) 预测方法,有效提高了电力负荷短期预测精度,但由于可调节负荷具有时间相关性,EGM 方法并不适用于可调节负荷预测。

为解决 EMD 的模态混叠现象,同时获取负荷序列良好的时间感知能力,本文提出一种集合经验模态分解-双向长短期记忆(Ensemble Empirical Mode Decomposition-Bidirectional Long Short Term Memory, EEMD-BiLSTM)组合的可调节负荷预测方法,利用 EEMD 将非平稳、非线性负荷分解为更具平稳的分量负荷,分别对分量负荷和原始负荷数据进行预测模型及重构,再结合 BiLSTM 及其参数,利用双向循环神经网络使用顺序和倒序 2 个方向对已知序列进行学习,输出结果包含二者信息,对 EEMD 算法获得的分量负荷进行训练,对各分量结果进行线性叠加,得出最终值。试验结果表明,EEMD 算法能极大提高模型的预测性能,BiLSTM 模型能有效提升模型的时间感知能力。

1 可调节负荷预测方法现状

可调节负荷序列是非线性且非平稳的,对于这类信号,基于小波的去噪方法已经取得过一定的效果,但这些方法必须要预先设定基函数。文献[9]提出的 EMD 虽能快速应用于信号去噪,但当信号出现异常事件时,将影响极值点的选取,筛选出的本征模态函数(Intrinsic Mode Function, IMF)分量包含了信号的固有模式和异常事件或相邻特征时间尺度的固有模式,从而产生模态混叠现象。随后文献[10]对 EMD 进行了改进,提出 EEMD,有效抑制模态混合。

可调节负荷预测有助于提高发电和配电的效率,具有实时调度、提高电力系统可靠性、降低运行成本、影响市场收入等作用。目前国内外对提高负荷预测准确性的研究主要包括基于时间序列的各种方法:自回归移动平均(Auto Regressive Moving

Average, ARMA)模型、回归模型、支持向量机(Support Vector Regression, SVR)、模糊理论以及混合模型。传统的预测算法由于提前假设了相关时间序列的线性关系,无法处理噪声大、波动大、趋势不规则、非线性的数据等问题。在实际应用中,如果原始数据收到突然变化的社会或环境因素的影响,这些预测方法的误差都会显著增加。

浅层学习模型更适用于适应强的非线性学习和快速计算。深度学习模型可以通过增加隐藏层的数量从可调节负荷中提取深度信息。最常用的技术包括递归神经网络(Recurrent Neural Network, RNN)、CNN 和 LSTM。文献[11]提出了一种具有 LSTM 的循环神经网络。LSTM 克服了 RNNs 的长期以来性问题,LSTM 使用单元状态、输入门、遗忘门、输出门 4 部分在序列中保持长期和短期的依赖关系。然而,传统的 LSTM 只提供以前的数据,它通过隐藏状态以 forward 方式接受输入。为解决这个问题,提出了 BiLSTM。在 BiLSTM 网络中,输入可以同时 2 个方向上进行处理,通过拟合 2 个 LSTM 的输出得到最终结果。与 LSTM 相比,对于相同的输入序列,BiLSTM 的预测精度更高。

1.1 EEMD 方法

EMD 在分析非平稳、非线性的时间序列数据时具有自适应且高效分解的特点。根据原始数据信号的局部特征,通过 EMD 技术从任何复杂信号中逐级提取不同尺度的波形或趋势,将原始序列分解为相对稳定的 IMF 和残差分量。各 IMF 必须满足以下 2 个条件。

(1)整个信号区间中的极值点数等于零点或差值为 1。

(2)信号的平均极值为 0。

EMD 分解流程如图 1 所示。首先计算原始信号上下极值点,画出基于极值点的上下包络线,根据上下线画出均值包络线,将原始信号减去均值包络线,检查得到中间信号是否满足 IMF 条件,若满足则选中为 IMF 分量,若不满足则迭代上述步骤,经过多次迭代得到满足 IMF 条件的分量和 1 个残差值。

循环神经网络中输出对张量 $\mathbf{W}_{sh}$, $\mathbf{W}_{hh}$ 和偏置 $\mathbf{b}$ 均可导,利用自动梯度算法来求解网络的梯度,其中误差 L 为最终输出值 o_i 与真实值之间的差距。

$$x(t) = IMF_n(t) + r(t), \quad (1)$$

$$IMF_n(t) = \sum_{i=1}^n x_i(t), \quad (2)$$

式中: $x(t)$ 为原始信号; $IMF_n(t)$ 为 IMF 分量; $r(t)$ 为残差分量。

对于 2 个局部最小值或最大值点, $c(t)$ 作为平均




图1 EMD分解流程

Fig. 1 EMD decomposition

值为零的振荡函数,取值为零。信号分解过程的理论基础表达式为

$$\int_{t_k}^{t_{k+2}} x(t)dt = \int_{t_k}^{t_{k+2}} c(t)dt + \int_{t_k}^{t_{k+2}} r(t)dt = \int_{t_k}^{t_{k+2}} r(t)dt = r_0(t_{k+2}) - r_0(t_k), \quad (3)$$

式中: $x(t)$ 为非平稳振荡信号; $c(t)$ 为振荡分量; $r(t)$ 为残差分量, r_0 表示过程的初始剩余。

EEMD本质上是用给定的试验次数对原始负荷序列反复应用EMD,然后对所有分解结果取平均值。与EMD不同,在每次EEMD尝试中,将频率范围均匀分布的高斯白噪声加入到原序列中,使得具有噪声辅助的原始负荷序列不仅具有均匀分布特性,还具有平滑等特性。

EEMD^[12]的简要步骤如下。

(1)给原始负荷序列添加1个给定振幅的白噪声。

(2)对加入白噪声的负荷序列进行EMD处理,得到IMF分量和剩余分量。

(3)按照给定试验次数重复步骤(1)和步骤(2),在每次试验中,IMF数量为常数。

误差的最终标准偏差为输入信号和相应IMF之间的差值,计算公式为

$$\varepsilon = \frac{A}{\sqrt{N}}, \quad (4)$$

式中: N 为IMF分量数; A 为附加噪声的振幅; ε 为误差的最终标准偏差。EEMD分解流程如图2所示。

1.2 BiLSTM方法

在LSTM模型中, c 为LSTM模型的状态向量, h 为LSTM网络的输出向量,利用门控值向量 $\sigma(g)$ 表




图2 EEMD分解流程

Fig. 2 EEMD decomposition

示阀门开关程度。输入门和遗忘门的典型行为见表1。

表1 输入门和遗忘门的典型行为

Table 1 Typical behavior of input and forget gates

输入门	遗忘门	LSTM
0	1	只使用记忆
1	1	综合输入和记忆
0	0	清零记忆
1	0	输入覆盖记忆

LSTM记忆细胞的运算过程为

$$i_t = \text{Sigmoid}(\mathbf{W}_f[\mathbf{h}_{t-1}, x_t] + \mathbf{b}_f), \quad (5)$$

$$c_t = \tanh(\mathbf{W}_c[\mathbf{h}_{t-1}, x_t] + \mathbf{b}_c), \quad (6)$$

$$f_t = \text{Sigmoid}(\mathbf{W}_f[\mathbf{h}_{t-1}, x_t] + \mathbf{b}_f), \quad (7)$$

$$\tilde{c}_t = f_t c_{t-1} + i_t c_t, \quad (8)$$

$$o_t = \text{Sigmoid}(\mathbf{W}_o[\mathbf{h}_{t-1}, x_t] + \mathbf{b}_o), \quad (9)$$

$$\mathbf{h}_t = o_t \tanh(\tilde{c}_t). \quad (10)$$

LSTM模型虽然可以捕捉到较长距离的依赖关系,但LSTM模型中一般将过去的信息作为输入和隐藏层,而忽略了未来信息。

BiLSTM在LSTM基础上,采用2个独立的隐藏层对序列数据进行正向和反向处理,将2个连接层连接到同一输出层,将之前的信息和之后的信息作为时间序列数据的当前时间基础。使用BiLSTM网络进行预测,其对于连续时间序列有很好的表达能力,权重参数复用使得其对数据的要求更低。BiLSTM模型如图3所示^[13]。

因此,在数据预处理阶段,针对可调节负荷序列,采用EEMD能有效解决电力负荷数据的非线性、非平稳问题,通过将具有频率范围内均匀分布的统计特性的白噪声添加到负荷序列中,使得负荷序列具有均匀的分解尺度和平滑性。在负荷预测阶段,将扁平化的数据输入BiLSTM,改善负荷序列提取时相互依存的问题。BiLSTM模型中,前向层从负荷序




图3 BiLSTM模型

Fig. 3 BiLSTM model

列的起点开始输入,反向层由数列的末端开始输入,通过多次迭代最终将2层的输出结果进行拟合,有效提高预测精度。

2 EEMD-BiLSTM可调节潜力分析改进方法

2.1 负荷序列分解流程

步骤1:添加正态分布高斯白噪声 ε^s 到原始负荷序列 Y ,然后输入新的负荷序列

$$Y^s = Y + \varepsilon^s. \quad (11)$$

步骤2:利用EMD方法分解 Y^s 为IMF和1个残余量

$$Y^s = \sum_{l=1}^L C_l^{\text{EMD},s} + R_L^{\text{EMD},s}. \quad (12)$$

步骤3:通过添加不同的高斯白噪声,重复步骤1和步骤2。最终得到的 Y 被分解为^[14]

$$Y = (C_1^{\text{EMD},s}, C_2^{\text{EMD},s}, \dots, C_L^{\text{EMD},s}, R_L^{\text{EMD},s}). \quad (13)$$

步骤4:计算相应IMF和残差的均值,以获得最终分解结果

$$C_l = \frac{1}{s} \sum_{s=1}^S C_l^{\text{EMD},s}, l = 1, 2, \dots, L, \quad (14)$$

$$R_L = \frac{1}{s} \sum_{s=1}^S R_L^{\text{EMD},s}, \quad (15)$$

得到1组相对样本子序列 $(C_1, C_2, \dots, C_L, R_L)$ 。可表示为

$$\begin{bmatrix} C_1 \\ C_2 \\ \vdots \\ C_L \\ R_L \end{bmatrix} = \begin{bmatrix} y_1^1 & y_1^2 & \cdots & y_N^1 \\ y_1^2 & y_1^2 & \cdots & y_N^2 \\ \vdots & \vdots & \vdots & \vdots \\ y_1^L & y_1^L & \cdots & y_N^L \\ y_1^{L+1} & y_1^{L+1} & \cdots & y_N^{L+1} \end{bmatrix}. \quad (16)$$

基于高斯分布的统计特性,EEMD方法可以有效抑制EMD分解过程中由于IMF的间歇性而引起的模态混合问题。由于电力负荷序列具有非线性、非平稳特性,电力负荷序列更适用于EEMD分解处理,使用获得的子序列进行训练,得到各个训练后

的结果,线性叠加后就是最终值^[15]。

2.2 可调节负荷预测流程

在BiLSTM模型中,前向层和后向层共同连接着输出层,其中包含了6个共享权重 $w_1 \sim w_6$ 。在前向层从时刻1~ t 正向计算一遍,得到并保存每个时刻向前隐含层的输出。在后向层沿着时刻 $t-1$ 反向计算一遍,得到并保存每个时刻向后隐含层的输出。最后在每个时刻结合前向层和后向层相应时刻输出的结果得到最终的输出^[16]。

数学表达式为

$$h_t = f(w_1 x_t + w_2 h_{t-1}), \quad (17)$$

$$h'_t = f(w_3 x_t + w_5 h'_{t-1}), \quad (18)$$

$$o_t = g(w_4 h_t + w_6 h'_t), \quad (19)$$

式中: x_t 为 t 时刻的输入量; h_t 和 h'_t 为 t 时刻的前向层与后向层的输出量; o_t 为 t 时刻输出层的输出; f 为前向层与后向层的激活函数; g 为输出层的激活函数; w_1 为输入层映射到前向层的权重矩阵; w_3 为输入层映射到后向层的权重矩阵; w_2 为前向层前一时刻输出映射到当前计算时刻的权重矩阵; w_5 为后向层前一时刻输出映射到当前计算时刻的权重矩阵; w_4 为前向层的输出映射到输出层的权重矩阵; w_6 为后向层的输出映射到输出层的权重矩阵。

结合各方法的优点,构建EEMD-BiLSTM可调节负荷预测模型,流程如图4所示。




图4 基于EEMD-BiLSTM可调节负荷预测模型流程

Fig. 4 Adjustable load prediction model based on EEMD-BiLSTM

选取可调节负荷数据,分析数据集是否存在异常值或缺失值等情况,针对异常值利用函数进行修补或删除,针对异常值一般采用删除或补全法,完成可调节负荷数据的清洗。对清洗后的可调节负荷序列进行EEMD分解,将分解后的序列作为输入,建立BiLSTM模型,初始化参数,通过模型训练寻找最优Epoch和Adam优化器,设置提前停止机制防止

模型过拟合,选择合适的误差函数对比验证预测模型结果,确认模型预测精度。

3 仿真验证

数据选取国内某地区连续5年涵盖日需求负荷的真实运行数据作为原始负荷数据集,日平均负荷曲线如图5所示,纵坐标为日平均负荷量。




图5 2009—2014年日平均负荷曲线

Fig. 5 Average daily load from 2009 to 2014

观察原始负荷曲线图,发现部分日平均负荷出现极低的情况,可能是由于大停电等特殊情况或电

表监测失误所形成。每年2月出现集中日平均负荷极低的情况,分析可能是2月春节放假期间,办公地区及工厂等工作区域用电量骤降。

2014年4月前后该地区的日平均负荷与其他月份相比较低,考虑到温度影响,认为4月基本没有温度敏感性负荷。

从5月开始,随着温度升高,日平均负荷曲线开始逐渐升高,温度敏感性负荷开始大量使用。至10月温度再次回归适宜,但与4月相比,日平均负荷稍有增加,考虑是由于公共区域人流量较上半年有所增加,用电负荷相应有所增长。进入冬季后,地区温度下降,温度敏感性负荷再次增长,用电量再次升高。将温度设定为23℃,观察温度历史数据集,发现4月13日温度恰好适宜,选取当日平均负荷作为基本正常负荷,将温度上升后5—9月扣除基本正常负荷,获得剩余日总负荷视作可调节负荷,如图6所示。




图6 2014年可调节负荷曲线

Fig. 6 Adjustable load curve in 2014

针对提取的可调节负荷序列,采用EEMD方法分解得到5个IMF分量,将每个分量数归一化到[0,1]内,将归一化的数据作为输入,在BiLSTM模型中进行预测,选取2009—2012年可调节负荷序列作为训练集,2013年可调节负荷序列作为验证集,2014年可调节负荷数据作为预测集。

将预测结果反归一化后,各分量预测结果线性叠加得出预测结果,将预测结果与原始负荷数据进行对比,对比预测结果与原始负荷数据,计算参数优化的EEMD-BiLSTM模型预测精度。

在BiLSTM模型训练阶段,通过多次迭代得出权重的最优值,而Epoch参数的大小与预测结果息息相关。Epoch参数过大时,网络分类复杂,模型不仅学习到正确信息,也会从一些错误信息中学习,会造成训练结果出现过拟合现象,而Epoch参数较小时,网络分类过于简单,模型无法学习到正确信息,会造成训练结果出现欠拟合现象。选用

Tensorflow-keras 库中的 EarlyStopping 函数,提前停止机制防止过拟合现象^[17]。

当网络模型层数较深时,Sigmoid 函数容易出现梯度弥散现象,导致预测精度下降,而 ReLU 函数在 $x < 0$ 时梯度值恒为 0,容易出现梯度弥散现象,因此针对可调节负荷序列,选取 tanh 函数作为激活函

数,Adam 作为模型优化器搭建训练环境。将参数优化后的 EEMD-BiLSTM 模型与 LSTM 模型、EEMD-LSTM 模型和 BiLSTM 模型选用误差函数平均绝对误差(MAE)、均方根误差(RMSE)对预测结果进行评估。可调节预测负荷曲线对比情况如图 7 所示。




图 7 可调节预测负荷曲线对比

Fig. 7 Comparison of adjustable load prediction curve

各模型评价指标对比见表 2。观察曲线图及其误差函数可知,加入高斯白噪声后,运用 EEMD 分解方法对原始可调节负荷序列进行分解,EEMD-LSTM 模型预测精度高于 LSTM 模型,EEMD-BiLSTM 模型预测精度高于 BiLSTM 模型。

表 2 各模型预测情况对比

Table 2 Comparison of prediction made by different model

模型	MAE/MW	MAPE
LSTM	19.560 0	0.010 6
EEMD-LSTM	13.740 2	0.007 8
BiLSTM	7.160 8	0.004 4
EEMD-BiLSTM	4.132 6	0.004 7

此外,观察对比图 7 可知,BiLSTM 模型预测精度高于 LSTM 模型,EEMD-BiLSTM 模型预测精度高于 BiLSTM 模型,BiLSTM 模型具有更优秀的时间序列感知力,能够从训练集中提取更多的有效信息进而提高预测精度,与 BiLSTM 模型相比,LSTM 模型稍有滞后效应。EEMD-BiLSTM 模型不仅具有良好

的时间序列感知力,可以从较长训练集中提取更多有效信息以提高预测精度,在面对较长训练集时,EEMD 有效降低了尺度混合对分解的影响,提高了模型的预测精度。

4 结论

本文分析了 EEMD 和 BiLSTM 算法的原理,提出了 EEMD-BiLSTM 模型应用到可调节负荷预测中。对预处理后的可调负荷进行 EEMD 分解,试验设计了 BiLSTM 架构及其参数,分别对分量负荷和原始负荷进行训练和重构预测。试验结果表明,EEMD 分解算法能有效规避 EMD 分解算法中的模态混叠问题,有效提高模型的预测性能。同时,基于 BiLSTM 的学习方法可以将过去和未来的数据序列统一为输入值,考虑数据的反向关系,有效预测可调节负荷序列的动态趋势。由于在 LSTM 的基础上增加了反向结构,BiLSTM 模型明显延长了模型的训练时间,降低了运算速度。因此在选择预测模型

时,应权衡模型的训练效率和预测精度,选择更适合的训练模型。

参考文献:

- [1]国家发展改革委,国家能源局.关于完善能源绿色低碳转型体制机制和政策措施的意见[R].2022.
- [2]国家电网有限公司.能源互联网情境下负荷调控能力提升工作三年行动计划[R].2022.
- [3]张建寰,吉莹,陈立东.深度学习在电力负荷预测中的应用[J].自动化仪表,2019,40(8):8-12.
ZHANG Jianhuan, JI Ying, CHEN Lidong. Application of deep learning in power load forecasting [J]. Automation Instrumentation, 2019, 40(8): 8-12.
- [4]陆继翔,张琪培,杨志宏,等.基于CNN-LSTM混合神经网络模型的短期负荷预测方法[J].电力系统自动化,2019,43(8):131-137.
LU Jixiang, ZHANG Qipei, YANG Zhihong, et al. Short-term load forecasting method based on CNN-LSTM hybrid neural network model [J]. Automation of Electric Power Systems, 2019, 43(8): 131-137.
- [5]彭文,王金睿,尹山青.电力市场中基于Attention-LSTM的短期负荷预测模型[J].电网技术,2019,43(5):1745-1751.
PENG Wen, WANG Jinrui, YIN Shanqing. Short-term load forecasting model based on Attention-LSTM in power market [J]. Power Grid Technology, 2019, 43(5): 1745-1751.
- [6]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.
LV Haican, WANG Weifeng, ZHAO Bing, et al. Short-term station load forecasting based on Wide & Deep LSTM model [J]. Power Grid Technology, 2020, 44(2): 428-436.
- [7]刘建华,李锦程,杨龙月,等.基于EMD-SLSTM的家庭短期负荷预测[J].电力系统保护与控制,2019,47(6):40-47.
LIU Jianhua, LI Jincheng, YANG Longyue, et al. Household short-term load forecasting based on EMD-SLSTM [J]. Electric Power System Protection and Control, 2019, 47(6): 40-47.
- [8]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 power load forecasting based on EEMD-GRU-MLR [J]. Power Grid Technology, 2020, 44(2): 593-602.
- [9]HUANG E, STEVER R L. A new view of nonstationary time series analysis: Empirical mode decomposition and Hilbert spectral analysis [J]. Proceedings of SPIE—The International Society for Optical Engineering, 2000, 4056: 197-209.
- [10]WU Z, HUANG N E. Ensemble empirical mode decomposition: A noised-assisted data analysis method [J]. Advances in Adaptive Data Analysis, 2009, 1(1): 1-41.
- [11]HOCHREITER S, SCHMIDHUBER J. Long short-term memory [J]. Neural Computation, 1997, 9(8): 1735.
- [12]JIA Y C, LI G L, et al. A novel denoising method for vibration signal of hob spindle based on EEMD and grey theory [J]. Measurement, 2021, 169: 108490.
- [13]YANG M, WANG J. Adaptability of financial time series prediction based on BiLSTM [J]. Procedia Computer Science, 2022, 199: 18-25.
- [14]侯回位,郑东健,刘永涛,等.基于EEMD-SE-LSTM的混凝土坝变形监测模型[J].水利水电科技进展,2022,42(1):61-66.
HOU Huiwei, ZHENG Dongjian, LIU Yongtao, et al. Deformation monitoring model of concrete dams based on EEMD-SE-LSTM [J]. Advances in Science and Technology of Water Resources, 2022, 42(1): 61-66.
- [15]董军,陈正鹏,窦熙皓,等.基于EEMD-FCM的需求响应用户负荷曲线分类研究[J].电力科学与工程,2021,37(10):45-54.
DONG Jun, CHEN Zhengpeng, DOU Xihao, et al. Research on demand response of user load curve classification based on EEMD-FCM method [J]. Electric Power Science and Engineering, 2021, 37(10): 45-54.
- [16]张栋栋,陈洁,李洋.基于VMD-SE和BiLSTM在短期负荷预测应用[J].现代电子技术,2021,44(23):155-159.
ZHANG Dongdong, CHEN Jie, LI Yang. In short-term load forecasting based on VMD-SE and BiLSTM application [J]. Journal of Modern Electronic Technology, 2021, 44(23): 155-159.
- [17]赵征,周孜钰,南宏钢.基于VMD的CNN-BiLSTM超短期风电功率多步区间预测[J/OL].华北电力大学学报(自然科学版):1-7.(2021-09-07)[2022-02-23].<http://kns.cnki.net/kcms/detail/13.1212.TM.20210907.1610.004.html>.
ZHAO Zheng, ZHOU Ziyu, NAN Honggang. Multi-step interval prediction of ultra-short-term wind power based on CNN-BiLSTM based on VMD [J/OL]. Journal of North China Electric Power University (Natural Science Edition): 1-7. (2021-09-07) [2022-02-23]. <http://kns.cnki.net/kcms/detail/13.1212.TM.20210907.1610.004.html>.

(本文责编:张帆)

作者简介:

李彬(1983),男,副教授,工学博士,从事电力通信、电气信息技术等方面的研究,direfish@163.com;

胡纯瑾*(1997),女,在读硕士研究生,从事能源互联网、电力负荷预测等方面的研究,13261690955@163.com;

王婧(1984),女,高级工程师,工学硕士,从事综合能源系统、虚拟电厂方面的研究,pingjingbei@126.com。