

基于 SSA-CNN-BiGRU-Attention 的超短期风电功率预测模型^{*}

李 青^{1,3}, 张新燕¹, 马天娇², 张 正³, 李志潭⁴

(1. 新疆大学 电气工程学院,新疆 乌鲁木齐 830000;

2. 新疆铁道职业技术学院,新疆 乌鲁木齐 830000;

3. 国网新疆电力有限公司,新疆 乌鲁木齐 830000;

4. 国网新疆电力有限公司营销服务中心,新疆 乌鲁木齐 830000)

摘要: 针对风电功率预测精度较低的问题,提出一种融合奇异谱分析(SSA)、卷积神经网络(CNN)、双向门控循环单元(BiGRU)及 Attention 机制的组合预测模型。为抑制风电功率随机波动特性带来的预测功率曲线滞后性问题,采用 SSA 方法将原始数据序列分解为一系列相对平稳的子分量,并基于各分量模糊熵(FE)值完成各分解分量的有效重构;构建了 CNN-BiGRU-Attention 模型并用于各重构分量建模预测,其中,CNN 网络用以实现各重构分量高维数据特征的有效提取,BiGRU 网络用以完成 CNN 获取的关键特征向量非线性动态变化规律的有效捕捉,Attention 机制的引入用于加强对功率数据关键特征的有效学习;通过叠加基于 CNN-BiGRU-Attention 模型的各重构分量预测值得到最终预测结果。以新疆哈密地区风电场实际运行采集数据为试验样本进行算例分析,结果表明,所提方法可有效缓解风电功率预测结果滞后现象,预测精度全面优于其他预测方法。

关键词: 风电功率预测; 奇异谱分析; 卷积神经网络; 双向门控循环单元; Attention 机制

中图分类号: TM614;TM715 文献标志码: A 文章编号: 1673-6540(2023)05-0061-11

doi: 10.12177/emca.2023.039

Ultra-Short Term Forecasting Model of Wind Power Based on SSA-CNN-BiGRU-Attention^{*}

LI Qing^{1,3}, ZHANG Xinyan¹, MA Tianjiao², ZHANG Zheng³, LI Zhitan⁴

(1. School of Electrical Engineering, Xinjiang University, Urumqi 830000, China;

2. Xinjiang Railway Vocational and Technical College, Urumqi 830000, China;

3. State Grid Xinjiang Electric Power Co., Ltd., Urumqi 830000, China;

4. Marketing Service Center of State Grid Xinjiang Electric Power Co., Ltd., Urumqi 830000, China)

Abstract: To solve the problem of low forecasting accuracy of wind power, a hybrid forecasting model integrating singular spectrum analysis (SSA), convolutional neural network (CNN), bi-directional gated recurrent unit (BiGRU) and Attention mechanism is proposed. In order to suppress the lag problem of the predicted power curve caused by the random fluctuation of wind power, the SSA method is used to decompose the original data into a series of sub-components with a relatively stable fluctuation characteristics, and the effective reconstruction is realized based on the fuzzy entropy (FE) value of each component. The CNN-BiGRU-Attention model is designed for the forecasting

收稿日期: 2022-12-06; 收到修改稿日期: 2023-02-10

*基金项目: 国家自然基金资助项目(51667018);自治区自然科学基金联合基金项目(2021D01C044)

作者简介: 李 青(1989—),男,博士研究生,工程师,研究方向为新能源并网控制、非线性时间序列预测等。

张新燕(1965—),女,博士,教授,研究方向为新能源发电、电力系统分析和优化调度。

of each reconstructed component. For example, CNN network is used to effectively extract the high-dimensional data features of each reconstructed component, BiGRU network is used to capture the nonlinear dynamic changes of key feature vectors obtained by CNN, and the Attention mechanism is used to highlight and strengthen the effective learning of key features of power data. The final forecasting results are obtained by superimposing the prediction values of each reconstruction component based on the CNN-BiGRU-Attention model. The actual operation data of wind farms in the Hami region of Xinjiang province is used as experimental data, the results show that the proposed method can effectively alleviate the lag phenomenon in wind power forecasting, and the forecasting accuracy is fully ahead of other existed prediction methods.

Key words: wind power forecasting; singular spectrum analysis (SSA); convolutional neural network (CNN); bi-directional gated recurrent unit (BiGRU); Attention mechanism

0 引言

随着新型电力系统建设的持续深入,风电装机容量占比持续提高,由此带来的并网稳定性问题日益突出。有效的风电功率预测技术是电力系统规划、管理和运行的关键^[1]。然而,风能的随机性特点导致风电出力表现为随机波动的非线性时间序列,给风电功率预测带来了极大挑战^[2]。目前,风电功率预测方法主要分为统计方法和机器学习方法等^[3]。统计方法简单易行,对波动规律明显、较平稳的时间序列可取得较好的预测效果,但针对非线性较强的风电功率时间序列,预测精度明显不足^[4]。以支持向量机(SVM)、人工神经网络(ANN)为代表的人工智能及机器学习方法,能从风电功率的历史时间序列中描述输入、输出样本间的非线性关系,且模型适用性和迁移性良好,在风电、光伏功率预测领域得到了较为广泛的应用^[5-6]。然而单隐层神经网络模型高度依赖于人为经验的特征选择方式给模型训练结果带来了诸多不确定性;面对随机波动规律性很弱的风电功率数据,单层 ANN 有限的非线性拟合能力难以满足现阶段新能源场站预测精度要求^[7]。

深度神经网络(DNN)的提出,实现了对传统单层 ANN 的有效扩展,且回归预测性能大幅提升;DNN 无监督特征学习特点,良好的非线性拟合能力以及易于实现大数据训练等主要属性使其迅速成为图像处理、非线性时间序列预测等领域的研究热点之一^[8]。其中,新能源功率预测中广泛采用的有卷积神经网络(CNN)及基于递归神经网络(RNN)结构的长短期记忆(LSTM)及门循坏单元(GRU)神经网络等^[9-10],其预测性能相对传统 SVM、反向传播(BP)网络等单隐层网络均得

到了有效提升。但面对随机波动性较大的风电功率时间序列,单一的 DNN 模型在功率曲线剧烈波动区段,也同样存在预测滞后现象,难以避免会产生较大的预测误差^[11]。

近年来,基于多种方法有机结合的风电功率组合预测模型受到学者的广泛关注和研究,且已被证明组合模型可以获得高于单一预测模型的预测精度,但是组合预测方法存在建模复杂且计算规模较大的问题。文献[12]提出基于改进经验模态分解(EMD)结合 SVM 的风电功率预测方法,取得了稳定的预测结果和较高的预测精度。文献[13]提出了基于集合经验模态分解与人群搜索算法优化的核极限学习机(EEMD-SOAKELM)的风电功率概率性短期区间预测方法,预测精度比核极限学习机(KELM)单一模型大幅提升。上述基于 EMD 及其改进集合经验模态分解(EEMD)方法的风电功率组合预测模型虽然取得了较高的预测精度,但 EMD 存在的模态混叠问题,基于噪声辅助的 EEMD 方法存在虚假分量多,组合预测计算规模大的问题仍待解决。奇异谱分析(SSA)是时间序列分析中常用的典型方法,在非线性、非平稳信号处理分析方面非常适用^[14],具有严格的理论支撑和良好的普适性。文献[15]研究结论表明,SSA 方法在信号去噪处理等方面性能优于小波分析和 EMD 方法。

基于上述,为了提高风电出力预测精度、降低组合预测计算规模,基于 SSA、CNN、BiGRU 及 Attention 机制各自优点,设计提出了基于 SSA-CNN-BiGRU-Attention 的组合预测模型,用于风电功率单步预测,本文主要提出的方法如下:

(1) 在对原始数据分布不做任何先验假设情况下,采用 SSA-模糊熵(SSA-FE)方法实现对原始

序列的分解处理和有效重构,得到少数可解释的独立分量,提高风电功率数据的可预测性,抑制风电功率随机波动特性导致的预测结果滞后现象。

(2) 基于 BiGRU 网络可同时兼顾时间序列前后输入数据信息的优点,提出采用 BiGRU 网络进行风电功率数据非线性动态变化规律的捕获学习,弥补 GRU 网络单方向提取时间序列特征的局限性。

(3) 基于 CNN、BiGRU、Attention 机制各自优点,构建形成新的 CNN-BiGRU-Attention 预测模型,该混合网络模型通过 CNN 结合 BiGRU 网络实现风电功率数据空间相关性和时间相关性的有效学习,进一步通过引入 Attention 机制突出重要影响信息,全面提高风电功率预测精度。

1 基于 SSA-FE 的风电功率分解

1.1 时间序列预测滞后性问题分析

在采用 LSTM、GRU 等深度学习模型进行非线性时间序列预测任务时,通常会采用滑动窗口策略,即将训练集和测试集划分为若干个滑动时间窗口,在每次训练迭代过程中,利用 N 个历史时间窗口的数据(x_{t-N}, \dots, x_t)来预测未来 M 个样本点的值,模型的整体损失函数为未来 M 个时间窗口的数据真实值与预测值之间的均方根误差。

采用上述训练模式,通常可获得整体较优的均方根误差(RMSE)或者平均绝对误差(MAE)评价指标,特别是相关性评价指标(如皮尔逊相关系数 R 或 R^2 决定系数)均可以取较高的计算值。然而,在非线性时间序列预测领域,预测结果滞后性现象一直存在^[11],且时间序列非线性越强,预测滞后性现象越严重。本文以后续试验中单日风电功率预测结果为例进行说明。如图 1 所示,传统 BP 网络预测值与实际值之间存在明显的滞后现象,GRU 网络基于良好时序记忆能力^[16],预测结果滞后现象比 BP 网络有所改善,但改善效果相对有限。进一步对图 1 所示预测结果进行分析,可看出在风电快速爬坡阶段和风电出力骤降阶段,这种预测滞后现象始终存在,如图 1 中标记数据所示,预测滞后特性使 BP 及 GRU 网络在第 77 个样本点产生了较大的预测误差(分别约为 31.8 MW 和 21.95 MW)。但是,第 77 个样本点的预测值与第 76 个样本点的实际值(43.70 MW)更

为接近,分析整个单日预测结果可得出,神经网络方法当前时刻的预测值整体更加接近于 $t-1$ 时刻的实际值,也就是模型倾向于把上一时刻的真实值作为下一时刻的预测值,导致两条曲线间存在滞后性。

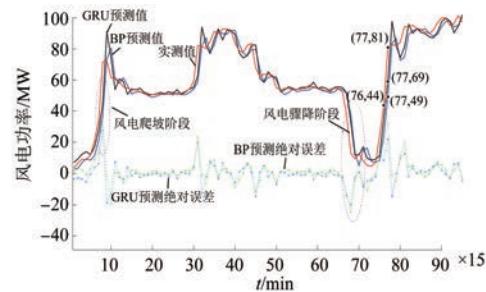


图 1 风电功率结果及绝对误差

预测结果滞后性原因与回归预测问题本身的机制、神经网络训练模式及时间序列随机特性均有一定关系。回归预测问题是基于对历史数据规律的学习进而实现对未知数据的推理,当时间序列非线性极强时,神经网络难以捕获这种突变规律,因此产生滞后性。此外,神经网络训练目标函数通常是最小化 t 时刻真实值与预测值之间的误差,在训练回归模型的过程中,回归器会“偷懒”从输入到回归器的特征中选择最接近的值来确保训练任务的完成。基于此,有学者提出,尝试预测 t 与 $t-1$ 时刻的差值来抑制回归器的“偷懒”行为,同时建议选择特征更加丰富的多维输入变量来辅助回归器捕获时序渐变规律。但是,本文通过多次线下试验论证发现上述抑制办法起到的抑制效果非常有限。

通过相关研究结论可以看出,基于数字信号处理的相关理论方法,可实现对非线性时间序列的有效分解,进而达到平稳化时间序列波动效果,是目前抑制时序预测滞后性方面较为有效的方法^[12-13]。因此,本文基于已有相关文献研究思路,提出采用 SSA 方法对原始风电功率时间序列进行分解处理,在抑制预测结果滞后性的同时,辅助回归预测算法进一步提高预测精度。

1.2 奇异谱分析

风电功率受外界多重气象因素的影响,呈现极强的非线性特性,因此,若直接采用相关人工智能学习方法进行回归预测,不仅难以消除上述的预测结果滞后性现象,同时预测精度也难以有效

提高。SSA 是一种典型的时间序列分析技术, 其结合了时间序列、多元统计、多元几何和奇异值分解(SVD)等多种元素, 可有效提取风电功率序列中蕴含的趋势、振荡及噪声分量成分^[17]。SSA 算法的实现可分为以下四步:

步骤 1, 嵌入。选择适当的窗口长度 M , 其为整个算法实现中唯一需要设定的参数, 通常 $1 < M < N/2$, 且要确保 M 取值为原始数据周期的整数倍。在设定 M 值后, 则可将一维风电功率时间序列 $\mathbf{X}_N = (x_1, x_2, \dots, x_N)$ 转化成大小为 $M \times K$ 的轨迹矩阵:

$$\mathbf{X} = \begin{bmatrix} x_1 & x_2 & \cdots & x_K \\ x_2 & x_3 & \cdots & x_{K+1} \\ \vdots & \vdots & \ddots & \vdots \\ x_M & x_{M+1} & \cdots & x_N \end{bmatrix} \quad (1)$$

式中: $K = N - M + 1$ 。

步骤 2, SVD。通过 $\mathbf{X}\mathbf{X}^T$ 计算得到协方差矩阵, 然后, 对协方差矩阵进行 SVD 分解, 得到特征值 $\lambda_1, \lambda_2, \dots, \lambda_M$ 和相应的正交特征向量 $\mathbf{U}_1, \mathbf{U}_2, \dots, \mathbf{U}_M$, 并对其按从小到大顺序进行排列, 则相应的主成分分量为 $\mathbf{V}_i = \mathbf{X}^T \mathbf{U}_i \sqrt{\lambda_i}$ ($i = 1, 2, \dots, d$)。SVD 计算式可表示如下:

$$\mathbf{X} = \sum_{i=1}^d \sqrt{\lambda_i} \mathbf{U}_i \mathbf{V}_i^T \quad (2)$$

式中: d 为大于 0 的特征值最大数量。

步骤 3, 分组。对于上述分解得到的集合 $(\lambda, \mathbf{U}_i, \mathbf{V}_i)$, 通过提取其他分量的频率, 然后将 \mathbf{X} 划分为 m 个互不相交的子集 $\{I_1, I_2, \dots, I_m\}$ 来代表不同的趋势变化, 则第 k 个子集 I_k 可以表示为

$$I_k = \{i_{j1}, i_{j2}, i_{jh}\}, j = 1, 2, \dots, m \quad (3)$$

则与 I_k 相对应的矩阵 \mathbf{X}_{I_k} 可通过下式计算可以得到:

$$\mathbf{X}_{I_k} = \mathbf{X}_{i_{j1}} + \mathbf{X}_{i_{j2}} + \cdots + \mathbf{X}_{i_{jh}} \quad (4)$$

矩阵 \mathbf{X} 可以表示为

$$\mathbf{X} = \mathbf{X}_{I_1} + \mathbf{X}_{I_2} + \cdots + \mathbf{X}_{I_m} \quad (5)$$

步骤 4, 对角线平均。将每个分组的矩阵 \mathbf{X}_{I_k} 通过对角线平均的方法转化为 M 个长度为 N 的新序列, 每组时间序列数据表示涵盖不同特征信息的子分量, 即趋势信息分量、周期信息分量和噪声信息分量等。设 \mathbf{Y} 为经分组后的任意矩阵, y_{ij}^* 为矩阵中的元素, 其中 $1 \leq i \leq M, 1 \leq j \leq K$; 设

$M^* = \min(M, K), K^* = \max(M, K), N = K + M - 1$, 当 $M < K$ 时, $y_{ij}^* = y_{ij}$, 否则 $y_{ij}^* = y_{ji}$, 通过下式进行对角线求平均, 将矩阵 \mathbf{Y} 转换为序列 y_1, y_2, \dots, y_N :

$$y_k = \begin{cases} \frac{1}{k} \sum_{m=1}^k y_{m,k-m+1}^*, & 1 \leq k < M^* \\ \frac{1}{M^*} \sum_{m=1}^{M^*} y_{m,k-m+1}^*, & M^* \leq k < K^* \\ \frac{1}{N-K+1} \sum_{m=k-K^*+1}^{M^*} y_{m,k-m+1}^*, & M^* \leq k < N \end{cases} \quad (6)$$

1.3 FE 算法引入

上述 SSA 方法通过嵌入、奇异值分解、分组、对角线平均四步运算将原始信号分解为 M 个幅频特性各异的子序列。针对各分解子序列: 一种做法是将前一部分子序列合并构成趋势分量, 然后将后半部分分量合并构成噪声分量, 这种基于主观意识的简单合并缺乏严格的理论依据^[18]。另一种做法是通过计算每个子序列相对原始序列的贡献率, 然后根据贡献率大小将各子序列进行重构合并。然而基于贡献率大小进行重构的方法仅考虑了各子序列的幅值大小, 并未对序列波动特性进行分析^[19]。在时间序列预测方面, 影响预测精度最主要的因素是序列自身的波动规律性, 规律性越强越有利于预测。

基于上述, 为实现 SSA 分解子序列的有效重构, 本文引入 FE 算法^[20] 进行各分解子序列复杂度的有效判别, 进而以 FE 值大小为依据完成各子序列重构合并, 进一步提高各重构分量在波动规律性上的同步性, 为全面提高预测精度奠定数据基础。

FE 通过采用模糊隶属度函数代替样本熵中单位阶跃函数来实现阈值判据, 降低了对参数的依赖性, 使得其更加适用于非线性、非平稳信号复杂性测度。FE 算法的实现过程如下:

步骤 1, 针对风电功率子序列 $\{rc(i), i = 1, 2, \dots, N\}$, 设定嵌入维数为 m , 对上述子序列进行相空间重构, 即:

$$\begin{aligned} \mathbf{RC}(i) = \\ \{rc(i), rc(i+1), \dots, rc(i+m-1) - u(i)\} \end{aligned} \quad (7)$$

式中: $i = N - m + 1$; $u(i)$ 为连续 m 个 $rc(i)$ 的均值。

步骤2, 定义 d_{ij}^m 为两个窗口向量 $\mathbf{RC}(i)$ 与 $\mathbf{RC}(j)$ 间的最大绝对距离:

$$\begin{aligned} d_{ij}^m &= d[\mathbf{RC}(i), \mathbf{RC}(j)] = \\ &\max_{p=1,2,\dots,m} [|u(i+p-1) - u_0(i)| - \\ &|u(j+p-1) - u_0(j)|] \end{aligned} \quad (8)$$

步骤3, 引入模糊隶属度函数:

$$A(x) = \begin{cases} 1, & x = 0 \\ \exp\left[-\ln(2)\left(\frac{x}{r}\right)^2\right], & x > 0 \end{cases} \quad (9)$$

式中: r 为相似容限度, 其大小为原一维风电功率子序列标准差(δ)的 H 倍, 即 $r=H\times\delta$ 。

步骤4, 定义函数 $C_i^m(r)$:

$$C_i^m(r) = \frac{1}{N-m+1} \sum_{j=1, j \neq i}^{N-m+1} A_{ij}^m \quad (10)$$

由式(10)可得, 向量 $\mathbf{RC}_m(i)$ 、 $\mathbf{RC}_m(j)$ 间基于嵌入维数 m 的关系维度为

$$\phi^m(r) = \frac{1}{N-m} \sum_{i=1}^{N-m} C_i^m(r) \quad (11)$$

步骤5, 当嵌入维数增加为 $m+1$ 时, 重复上述步骤1~步骤4, 即得到 $\phi^{m+1}(r)$ 为

$$\phi^{m+1}(r) = \frac{1}{N-m} \sum_{i=1}^{N-m} C_i^{m+1}(r) \quad (12)$$

步骤6, 针对原时间序列 $rc(i)$ 的 FE 为

$$FuzzyEn(m,r) = \lim_{N \rightarrow \infty} [\ln \phi^m(r) - \ln \phi^{m+1}(r)] \quad (13)$$

在 FE 值计算中, 嵌入维数 m 与相似容限度 r 的取值影响 FE 值的计算结果; 嵌入维数 m 的大小决定着重构系统的动态演化精细化程度, 通常 m 取值位于 2~7 之间, 本文后续试验中通过交叉验证确定 $m=3$ 。相似容限 $r=\theta \cdot SD$, 其中, 标准差 SD 为原一维时间风电功率时间序列的标准差, θ 为位于(0,1)之间的系数, 本文取值为 0.2。与近似熵、样本熵类似, FE 值计算结果可用于衡量时间序列的复杂性, 即 FE 值越大, 时间序列预测复杂, 规律性越差。

2 基于 CNN-BiGRU-Attention 混合神经网络模型

CNN 网络在深度学习领域得到了广泛的应用, 具有局部连接和权重共享的特点, 能够有效地提取输入特征^[21]。BiGRU 为 GRU 网络的改进模

型, 其基本单元由一个向前传播的 GRU 和向后传播的 GRU 组成^[22], 通过从正反两个方向同时进行特征映射学习, 可有效提高特征向量提取的准确率, 充分挖掘历史功率数据潜在关键特征, 进而提高预测精度。在神经网络中, Attention 机制通常以一个额外神经网络的角色存在, 能够硬性选择输入的某些部分, 或者给输入分配不同的权重, 进而用于重点突出与输入更加相似的关键特征^[23]。

为避免篇幅过大, 本文不再对 CNN、BiGRU、Attention 机制进行详细理论介绍。CNN-BiGRU-Attention 混合网络模型如图 2 所示, 可看出, CNN-BiGRU-Attention 模型大体由五部分构成, 第一部分为输入层, 即将历史风电功率数据作为模型的输入; 第二部分为 CNN 网络, 用于挖掘数据空间相关性和消除不稳定因素影响, 本文设计的 CNN 网络由卷积-池化-卷积-池化共计 4 层构成, 其中, 卷积层用于提取特征并捕获数据之间的相关性, 然后采用池化层通过池操作压缩参数数量, 降低数据维数, 提高网络学习效率; 第三部分为 BiGRU 网络, 其在充分吸取 GRU 收敛快、预测精度高的优点基础上, 通过增加对特征向量反向提取功能, 进一步增强了 GRU 网络的非线性拟合能力, 可实现对经 CNN 网络处理后的风电功率充分学习, 进一步提高了时序特征提取的准确率; 第四部分为 Attention 机制, 通过对 BiGRU 处理后的特征向量分配不同的权重, 突出关键特征; 第五部分为全连接层, 用于输出最终预测结果。

CNN-BiGRU-Attention 预测模型各层网络参数及具体表述如下:

- (1) 输入层。将长度为 n 的风电功率数据向量输入到预测模型中。
- (2) CNN 网络层。CNN 网络中的 2 个卷积层卷积核大小设置为 4, 采用补齐策略 SAME(用 0 对空白数据进行填充)来尽可能保留和使用输入特征, 激活函数为线性整流单元(ReLU); 池化层采用最大池化方法来保留更多数据波动信息, 在垂直和水平位置上的滑动步长分别设置为 1 和 2, 数据补齐策略同卷积层。CNN 卷积和池化计算过程可归纳如下:

$$\begin{cases} \mathbf{C}_1 = \text{ReLU}(\mathbf{X} \otimes \mathbf{W}_1 + \mathbf{b}_1) \\ \mathbf{P}_1 = \max(\mathbf{C}_1) + \mathbf{b}_2 \\ \mathbf{C}_2 = \text{ReLU}(\mathbf{P}_1 \otimes \mathbf{W}_2 + \mathbf{b}_3) \\ \mathbf{P}_2 = \max(\mathbf{C}_2) + \mathbf{b}_4 \\ \mathbf{H}_c = \text{Sigmoid}(\mathbf{P}_2 \times \mathbf{W}_3 + \mathbf{b}_5) \end{cases} \quad (14)$$

式中: \mathbf{C}_1 、 \mathbf{C}_2 、 \mathbf{P}_1 、 \mathbf{P}_2 、 \mathbf{H}_c 分别为卷积层 1、卷积层 2、池化层 1、池化层 2 和 CNN 网络最终的输出; \mathbf{W}_1 、 \mathbf{W}_2 、 \mathbf{W}_3 分别为卷积层 1、卷积层 2 和 CNN 网络输出层的权值向量; \mathbf{b}_1 、 \mathbf{b}_2 、 \mathbf{b}_3 、 \mathbf{b}_4 、 \mathbf{b}_5 分别为对应各层的偏置向量; \otimes 为卷积运算。

(3) BiGRU 网络层。本文设计 BiGRU 网络层数为 1, 神经元数量设置为 128, BiGRU 层在第 t 步的输出可表示为

$$\mathbf{h}_t = \text{BiGRU}(\mathbf{H}_{c,t-1}, \mathbf{H}_{c,t}) \quad (15)$$

(4) Attention 层。Attention 层的输入为 BiGRU 网络层输出向量 \mathbf{H} , Attention 层通过不断更新迭代计算出较优的权重参数矩阵, 并将关键

特征突显出来, 其权重系数计算可表示为

$$\begin{cases} \mathbf{p}_t = \mathbf{u} \tanh(\mathbf{w} \mathbf{h}_t + \mathbf{b}) \\ \mathbf{a}_t = \frac{\exp(\mathbf{p}_t)}{\sum_{j=1}^t \mathbf{p}_j} \\ \mathbf{s}_t = \sum_{i=1}^j \mathbf{a}_i \mathbf{h}_i \end{cases} \quad (16)$$

式中: \mathbf{p}_t 为基于 BiGRU 网络层 t 时刻的输出向量 \mathbf{h}_t 计算得到的注意力概率分布值; \mathbf{a}_t 为 \mathbf{p}_t 对应的幅值变换。

(5) 输出层。对 Attention 机制层的输出采用全连接层进行计算, 得出 CNN-BiGRU-Attention 模型最终的预测值 $\mathbf{Y} = [y_1 \ y_2 \cdots \ y_n]$ 。

y_t 为第 t 时刻的预测输出值为

$$y_t = \text{Sigmoid}(\mathbf{w}_0 \mathbf{s}_t + \mathbf{b}_0) \quad (17)$$

式中: \mathbf{w}_0 和 \mathbf{b}_0 分别为对应的偏差矩阵向量和偏置向量, 本文在全连接层选取 Sigmoid 作为激活函数。

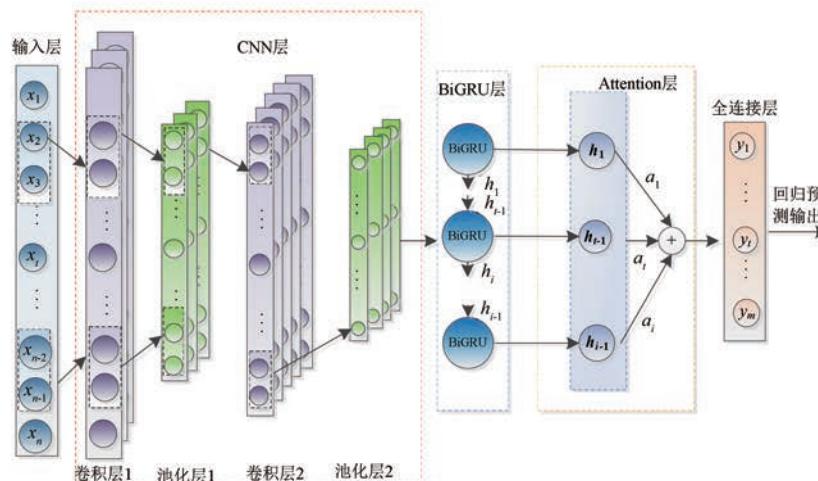


图 2 CNN-BiGRU-Attention 模型架构

3 基于 SSA-CNN-BiGRU-Attention 的风电功率预测模型设计

采用 SSA 对异常值处理后的训练样本进行分解处理, 得到若干子序列; 为降低组合预测模型计算规模, 避免对各个子序列逐一进行预测带来的计算耗时, 通过计算各子序列 FE 值, 进而基于熵值大小将各子序列合并重构为 3~4 个重构分量; 针对各重构分量的幅频特性, 建立相应的 CNN-BiGRU-Attention 预测模型进行单独预测, 并

将各重构分量预测结果叠加即可得到最终的预测结果。

概言之, SSA-CNN-BiGRU-Attention 方法的实现步骤如下:

步骤 1, 选取试验样本, 并采用单变量异常值检测方法及多变量异常值检测方法分两步完成原始风电功率数据样本异常值检测及剔除, 全面提高试验样本数据质量。

步骤 2, 对经异常值处理后的原始风电功率序列 $\mathbf{X} = (x_1, x_2, \dots, x_N)$ 进行 SSA 分解, 得到若干

个分解子序列 $\{RC_1, RC_2, \dots, RC_n\}$ 。

步骤3,采用FE算法计算步骤2中得到的各子序列FE值,然后将位于同一FE值区间的各子序列进行合并重构,进而得到3~4个重构分量。

步骤4,根据各重构分量的波动特点建立对应的CNN-BiGRU-Attention预测模型分别进行预测。

步骤5,叠加各分量预测结果,得到最终组合预测结果,并基于RMSE、MAE、最大误差(ME)、 R^2 四种评价指标,对本文模型及对比模型预测结果进行横向比较,验证预测结果的可行性。

SSA-CNN-BiGRU-Attention预测方法实现流程如图3所示。

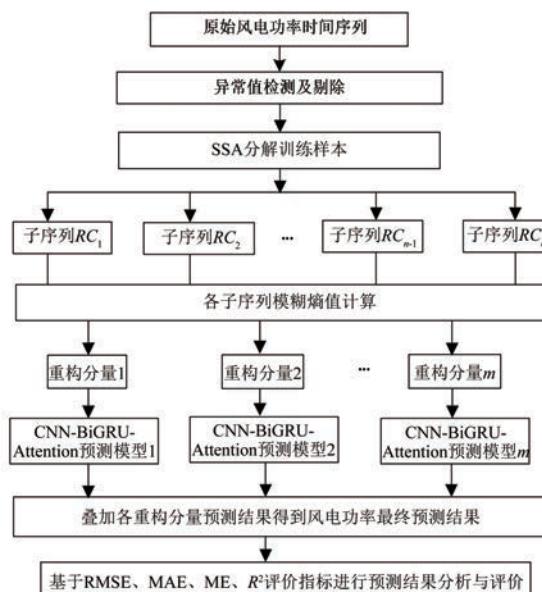


图3 SSA-CNN-BiGRU-Attention组合模型预测流程图

4 算例分析

选取新疆哈密地区某风电场2019年数据为研究对象,该风电场总装机容量200 MW。考虑到该地区全年春、冬两季风力相对匮乏特点,截取3月~8月实际运行采集数据进行仿真分析;试验中,将3月~5月划分为一组(后续分析中统称为数据集1),6月~8月划分为另一组(后续统称为数据集2)。数据集1中,选取3月1日~5月15日数据为训练样本,5月16日~5月31日为测试样本;数据集2中,选取6月1日~8月15日数据为训练样本,8月16日~8月31日为测试样本;通过与GRU、BiGRU、CNN-BiGRU、CNN-BiGRU-

Attention、经验模态分解-径向基函数(EMD-RBF)、EEMD-LSTM模型的预测结果进行对比,验证所提SSA-CNN-BiGRU-Attention模型的有效性。

4.1 数据清洗及评价指标

风电功率数据大多是从场站前端功率预测系统或电力公司调度相关监测系统导出,受场站机组故障检修、测量设备故障、通信受阻等因素影响,系统采集数据中存在一定比例的异常数据,这些异常数据会对网络训练学习产生一定的干扰,进而带来预测误差。因此,本文通过单变量异常点检测方法结合风速-风电功率双变量耦合散点图对风电场采集数据中异常运行数据进行自动检测和清洗。通过箱须图分析方法对极端离群点进行识别和剔除^[23],针对箱须图法初步处理后的风速-风电功率数据,采用局部异常因子法^[24]对不符合风速-风电功率耦合原理的数据样本进行自动识别和剔除,以全面提高训练样本数据质量。

图4(a)~图4(c)给出了未经任何处理、基于箱须图法处理极端异常点后、采用局部异常因子法基于风速-风电功率耦合原理处理后的风速-风电功率散点图结果对比。可以看出,未进行任何处理前的原始场站数据中存在形式各异的异常数据,主要是以少量平行于y轴的恒值风速数据(-99)为主,这类数据本文采用典型的箱须图法进行了识别和剔除,剔除后的数据如图4(b)所示。从图4(b)可看出,去除极端异常样本后的数据集里仍夹杂了大量不符合风速-风电功率耦合原理的异常数据(在风力发电中,风速-风电功率理想曲线为一条近似的“s”型曲线),针对该部分数据,本文采用局部异常因子法进行剔除,剔除后的数据如图4(c)所示。结合图4(c)可看出,采用局部异常因子法处理后的数据整体已非常接近理想发电模式,虽然仍有平行于x轴成带状的部分限电原因造成的异常样本点没有实现彻底识别,但是考虑到我国西部地区客观存在的弃风现象,为贴近场站实际发电运行情况,本文不再做进一步识别处理。

4.2 多种方法预测结果对比分析

本文预测模型可表示如下:

$$y(t) = f(\mathbf{x}_t), \forall t = \Delta \dots l \quad (18)$$

式中: $f(\cdot)$ 为用CNN-BiGRU-Attention构建的函数; \mathbf{x}_t 为由历史风电功率值($y_{t-1}, y_{t-2}, \dots, y_{t-\Delta}$)构

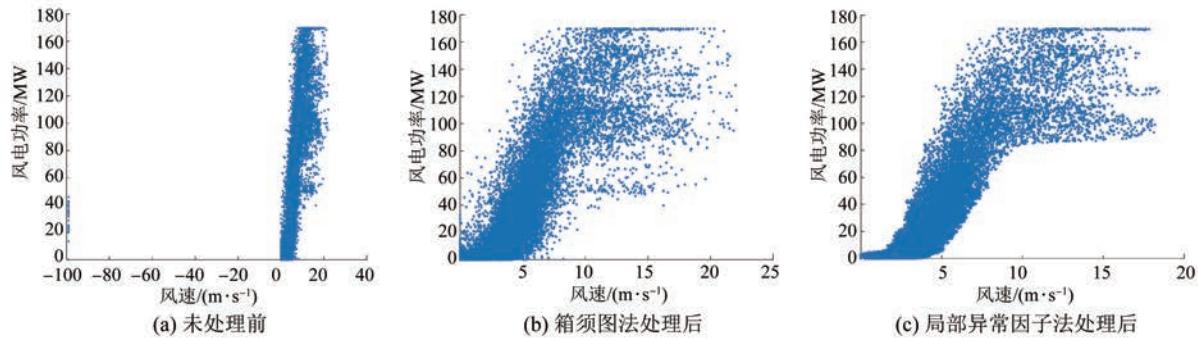


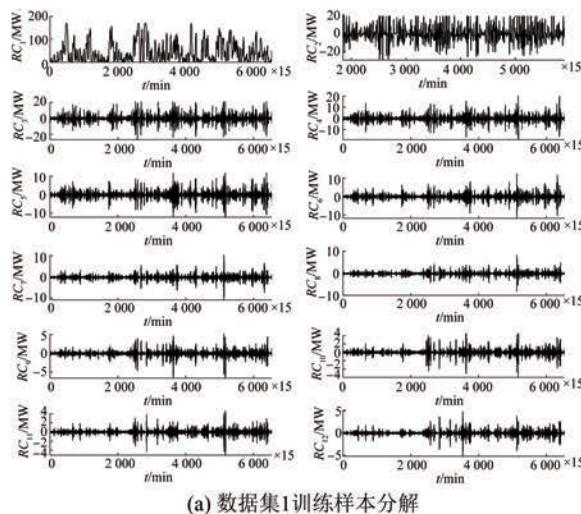
图 4 风速-风电功率异常数据处理

成的多维输入向量; Δ 为输入变量嵌入维数。

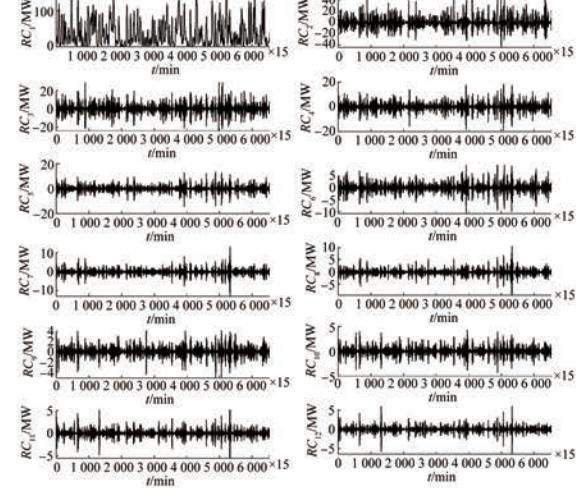
在后续风电功率预测算例中, 为使得各种方法结果对比相对公平, 在 6 种竞争对比模型及各重构分量预测中, 嵌入维数均设定为 7。

对原始风电功率序列进行 SSA 分解, 为避免过分解, 结合原始风电功率数据波动特性、同步参考相关文献 [15] 设定方法, 选择窗口长度 M 为 12, 即分别将 2 组测试样本训练数据分解为 12 个子序列, 分解结果如图 5 所示。可以看出, SSA 方法分解得到的各分量从 $RC_1 \sim RC_{12}$ 幅值总体逐渐

变小, 其中, 幅值最大的为 RC_1 分量, 其为原始序列的主导趋势分量, 其余各分量波动特性各有差异, 无法通过肉眼观察分析其变化特性。因此, 本文基于 FE 方法计算分析各分解分量变化的规律性。表 1 给出了两组数据集各分量的 FE 值计算明细, 可以看出各分量 FE 值计算结果存在明显差异, 其中变化规律性最强的为 RC_1 主导分量, 其余各分量 $R_2 \sim R_{11}$ 规律性越来越差, 但 RC_{12} 分量 FE 值较小, 这可能与窗口长度 M 值设定稍显偏大有关。



(a) 数据集1训练样本分解



(b) 数据集2训练样本分解

图 5 基于 SSA 方法的风电功率训练样本分解结果

表 1 风电功率各分量 FE 值计算结果

| 分量 | RC_1 | RC_2 | RC_3 | RC_4 | RC_5 | RC_6 | RC_7 | RC_8 | RC_9 | RC_{10} | RC_{11} | RC_{12} |
|---------------|--------|--------|--------|--------|--------|--------|--------|--------|--------|-----------|-----------|-----------|
| FE 计算值(数据集 1) | 0.14 | 0.23 | 0.43 | 1.19 | 2.71 | 5.04 | 9.32 | 18.50 | 5.97 | 7.69 | 11.32 | 0.46 |
| FE 计算值(数据集 2) | 0.12 | 0.20 | 0.30 | 0.67 | 1.30 | 1.92 | 2.11 | 1.49 | 2.20 | 2.20 | 6.62 | 0.46 |

为降低组合预测计算规模, 避免针对幅值很小的各分量单独建模预测带来的计算耗时, 以 FE

值 $[0, 0.3], [0.3, 0.7], [0.7, 2]$ 及 >2 为划分原则, 将初始分解分量重组合并为 4 个重构分量, 合并

结果如表 2 所示。

图 6 给出了 GRU、BiGRU、BiGRU-Attention、CNN-BiGRU-Attention、EMD-RBF (文献 [25])、EEMD-LSTM (文献 [26])、SSA-CNN-BiGRU-Attention 方法预测结果对比,得益于 CNN 网络良好的时空特征提取能力及 Attention 机制对功率数据关键特征的突出及强化学习,CNN-BiGRU-

Attention 方法预测效果比 BiGRU 及 BiGRU-Attention 方法的有所提高。结合图 6 局部放大图来看,本文方法在风电功率剧烈波动区段对实际功率曲线的跟踪预测效果明显优于其他 6 种对比方法,在风电爬坡、骤降时段无明显的预测结果滞后现象,预测性能最为稳定。

表 2 风电功率各分量重构结果

| 分量 | 重构分量 1 | 重构分量 2 | 重构分量 3 | 重构分量 4 |
|---------------|------------------|----------------|------------------|-----------------------------|
| 数据集 1 各分量合并结果 | RC_1+RC_2 | RC_3+RC_{12} | RC_4 | RC_5+RC_{11} |
| 数据集 2 各分量合并结果 | $RC_1+RC_2+RC_3$ | RC_4+RC_{12} | $RC_5+RC_6+RC_8$ | $RC_7+RC_9+RC_{10}+RC_{11}$ |

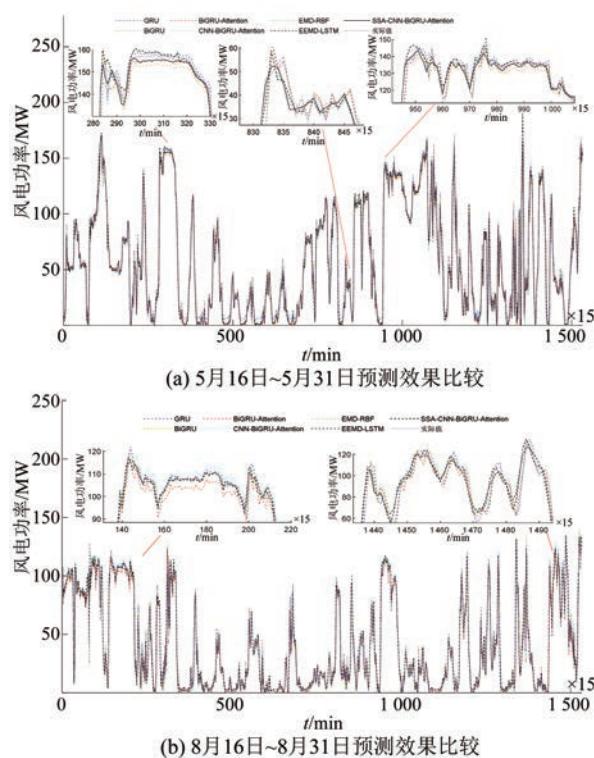


图 6 多种方法预测结果比较

表 3 给出了各种预测方法的 RMSE、MAE、ME 及 R^2 相关度的定量对比,可以看出,所提方法在 4 种评价指标上全部取得了最优值;GRU、BiGRU、BiGRU-Attention、CNN-BiGRU-Attention 预测方法也取得了较高的 R^2 相关性计算值,但与 R^2 指标形成鲜明对比的是,其余 3 种误差评价指标相对较大;基于 EMD 和 EEMD 分解方法的 (EMD-RBF 和 EEMD-LSTM) 2 种组合预测方法相比其他 4 种对比方法各项指标取得了明显的提升,但预测精度不及本文方法,且 EMD 和 EEMD

针对数据集 1 和数据集 2 均是产生了 13 个分解分量,存在部分虚假模态分量,计算规模相对本文方法增加了约 3~3.5 倍。从 ME 指标来看,针对实际发电功率最大值不超过 200 MW 的风场,6 种对比方法的 ME 值达到了 34.85~80.36 MW,最大误差几乎达到了发电功率最高值的 50%,不利于电力调度、决策。相比较而言,本文所提方法 RMSE、MAE、ME 三个误差指标计算值大幅降低,相比 GRU、BiGRU、BiGRU-Attention、CNN-BiGRU-Attention、EMD-RBF 和 EEMD-LSTM 预测方法,在 5 月份测试样本上,RMSE 指标降低了 36.08%~70.04%,MAE 指标降低了 29.45%~68.14%,ME 指标降低了 53.83%~79.98%。在 8 月份测试样本上,RMSE 指标降低了 41.44%~75.00%,MAE 指标降低了 19.56%~66.67%,ME 指标降低了 64.32%~83.33%。综合来看,针对装机容量 200 MW 的风场,本文方法 RMSE 指标控制在 2.8 MW 以内,ME 指标控制在装机容量的 10% 以内,预测效果良好,满足当前电力调度需求。

图 7 通过箱须图方式展示给出了多种方法预测误差绝对值对比,可以看出本文正常预测误差分布明显更集中(箱体更短),异常预测样本点 (+) 更少且误差幅值显著低于其他 6 种对比方法,包括 CNN-BiGRU-Attention 在内的 4 种单一混合神经网络预测方法在大多数样本点产生了较大的绝对预测误差,这些预测误差的产生很大程度上是因为单纯基于数据驱动的神经网络预测模型当前时刻的预测值更加接近前一时刻的实际值,预测结果滞后实际值。结合图 6 的预测效果可看出,EMD、EEMD 分解方法在辅助神经网络方

表3 多种方法 RMSE、MAE、ME、 R^2 风电功率预测性能指标对比

| 预测方法 | 5月16日~5月31日 | | | | 8月16日~8月31日 | | | |
|-------------------------|-------------|--------|-------|-------|-------------|--------|-------|-------|
| | RMSE/MW | MAE/MW | ME/MW | R^2 | RMSE/MW | MAE/MW | ME/MW | R^2 |
| GRU | 9.23 | 6.09 | 80.36 | 0.96 | 8.76 | 5.43 | 66.85 | 0.95 |
| BiGRU | 9.33 | 5.87 | 77.07 | 0.96 | 8.12 | 4.69 | 76.38 | 0.95 |
| BiGRU-Attention | 8.93 | 5.51 | 79.57 | 0.96 | 7.71 | 4.77 | 72.82 | 0.96 |
| CNN-BiGRU-Attention | 8.73 | 5.28 | 65.79 | 0.97 | 7.62 | 4.55 | 71.32 | 0.96 |
| EMD-RBF | 4.37 | 2.78 | 36.61 | 0.99 | 3.83 | 2.34 | 40.59 | 0.99 |
| EEMD-LSTM | 4.24 | 2.75 | 34.85 | 0.99 | 3.74 | 2.25 | 35.68 | 0.99 |
| SSA-CNN-BiGRU-Attention | 2.71 | 1.94 | 16.09 | 0.99 | 2.19 | 1.81 | 12.73 | 0.99 |

法抑制预测结果滞后性方面也有明显的效果, EMD-RBF 和 EEMD-LSTM 方法的预测误差相对其他 4 种单一预测模型方法明显更低。本文模型基于 SSA 分解方法实现了对原始数据的平稳化处理, 全面提高了风电功率数据的可预测性, 展现出了良好的泛化性和鲁棒性。

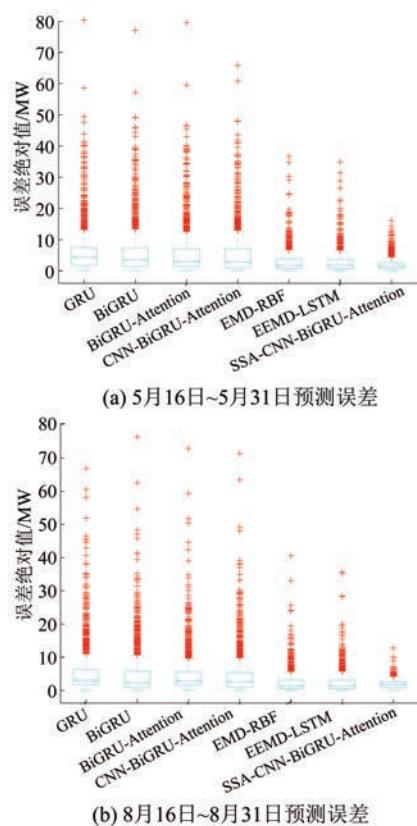


图7 多种方法预测绝对误差比较

5 结语

本文提出一种基于 SSA-CNN-BiGRU-

Attention 的风电功率组合预测方法。该方法首先基于 SSA 方法实现了原始风电功率时间序列的分解处理, 降低了风电功率的随机波动性, 全面提高了风电功率数据的可预测性;其次, 基于 FE 算法完成了波动频度相似的分解分量重构处理, 有效降低了预测模型的计算规模。最后, 在基于 CNN-BiGRU 混合网络充分提取输入-输出变量时空及时序映射关系的同时, 引入 Attention 机制突出了重要影响信息, 有效保障了各重构子分量的预测精度。试验结果表明, 所提模型相对 4 种单一预测模型, 可降低 RMSE 指标高达 68.96% ~ 75.00%; 相对 2 种同类型组合预测模型, 在显著降低计算规模的同时, 可降低 RMSE 指标 36.08% ~ 42.82%, 显著提高了风电功率的预测精度, 具有更好的应用潜力。

【参考文献】

- [1] 游坤奇, 熊殷, 贾永青, 等. 基于 PCC-RBF 网络的风电功率短期预测方法[J]. 电机与控制应用, 2021, 48(1): 41.
- [2] YANG M, CHEN X, DU J, et al. Ultra-short-term multistep wind power prediction based on improved EMD and reconstruction method using run-length analysis[J]. IEEE Access, 2018, 6: 31908.
- [3] 熊音笛, 刘开培, 秦亮, 等. 基于时序数据动态天气划分的短期风电功率预测方法[J]. 电网技术, 2019, 43(9): 3353.
- [4] 刘金莹. 考虑时空特性的可再生能源发电功率预测模型研究[D]. 北京: 北京交通大学, 2021.
- [5] LIU J, LI C. The short-term power load forecasting based on sperm whale algorithm and wavelet least square support vector machine with DWT-IR for

- feature selection [J]. Sustainability, 2017, 9 (7): 1188.
- [6] 王新友, 李青, 郑少鹏. 基于 EWT-ESN 的短期风电功率预测研究 [J]. 太阳能学报, 2018, 39 (3): 633.
- [7] 曾亮, 狄飞超, 王珊珊, 等. 基于浅层方法和深度网络集成的短期风电功率预测 [J]. 现代电子技术, 2022, 45 (11): 118.
- [8] 李聪, 彭小圣, 王皓怀, 等. 基于 SDAE 深度学习与多重集成的风电集群短期功率预测 [J]. 高电压技术, 2022, 48 (2): 504.
- [9] 杨子民, 彭小圣, 郎建勋, 等. 基于集群动态划分与 BLSTM 深度学习的风电集群短期功率预测 [J]. 高电压技术, 2021, 47 (4): 1195.
- [10] SAJJAD M, KHAN Z A, ULLAH A, et al. A novel CNN-GRU-based hybrid approach for short-term residential load forecasting [J]. IEEE Access, 2020, 8: 143759.
- [11] 李昌明. 基于 CEEMDAN 与深度学习的时间序列预测模型研究 [D]. 阜新: 辽宁工程技术大学, 2021.
- [12] 王涛, 高靖, 王优胤, 等. 基于改进经验模态分解和支持向量机的风电功率预测研究 [J]. 电测与仪表, 2021, 58 (6): 49.
- [13] 杨锡运, 康宁, 杨雨薇, 等. 基于 EEMD 的 SOA-KELM 风电功率概率性短期区间预测 [J]. 动力工程学报, 2019, 39 (11): 926.
- [14] 林涛, 刘航鹏, 赵参参, 等. 基于 SSA-PSO-ANFIS 的短期风速预测研究 [J]. 太阳能学报, 2021, 42 (3): 128.
- [15] DU W H, ZHOU J, WANG Z J, et al. Application of improved singular spectrum decomposition method for composite fault diagnosis of gear boxes [J]. Sensors, 2018, 18 (11): 3804.
- [16] 周满国, 黄艳国, 段锦锋. 基于 GRU-RF 模型的太阳辐照度短时预测 [J]. 太阳能报学报, 2022, 43 (7): 166.
- [17] LI L, ZHANG M, WEN Z. Dynamic prediction of landslide displacement using singular spectrum analysis and stack long short-term memory network [J]. Journal of Mountain Science, 2021, 18: 2597.
- [18] 黄雨薇, 彭道刚, 姚峻, 等. 基于 SSA 和 K 均值的 TD-BP 神经网络超短期光伏功率预测 [J]. 太阳能学报, 2021, 42 (4): 229.
- [19] 林涛, 刘航鹏, 赵参参, 等. 基于 SSA-PSO-ANFIS 的短期风速预测研究 [J]. 太阳能学报, 2021, 42 (3): 128.
- [20] ZHENG J D, PAN H Y, TONG J Y, et al. Generalized refined composite multiscale fuzzy entropy and multi-cluster feature selection based intelligent fault diagnosis of rolling bearing [J]. ISA Transactions, 2022, 123: 136.
- [21] 刘可真, 梁玉平, 代莹皓, 等. 基于 CNN-ISSA-GRU 模型的短期负荷预测方法 [J]. 电机与控制应用, 2022, 49 (8): 79.
- [22] 方娜, 余俊杰, 李俊晓, 等. 基于 CNN-BIGRU-ATTENTION 的短期电力负荷预测 [J]. 计算机仿真, 2022, 39 (2): 40.
- [23] QU J, QIAN Z, PEI Y. Day-ahead hourly photovoltaic power forecasting using attention-based CNN-LSTM neural network embedded with multiple relevant and target variables prediction pattern [J]. Energy, 2021, 232: 120996.
- [24] 吴琼, 李永飞, 李铭洋. 异常数据实时检测方法研究综述 [J]. 现代计算机, 2022, 28 (16): 9.
- [25] 王佶宣, 邓斌, 王江. 基于经验模态分解与 RBF 神经网络的短期风功率预测 [J]. 电力系统及其自动化学报, 2020, 32 (11): 109.
- [26] 杨芮, 徐虹, 文武. 基于 EEMD-GRU 网络模型的短期风速预测 [J]. 计算机系统应用, 2022, 31 (6): 231.