

# 基于BiLSTM多算法混合神经网络模型的季节性等效惯量短期预测

李世春<sup>1,2</sup>, 刘佳昌<sup>1,2</sup>, 刘蒙恩<sup>1,2</sup>, 杨跳<sup>1,2</sup>, 刘璐<sup>1,2</sup>, 李振兴<sup>1,2</sup>

(1. 三峡大学电气与新能源学院, 湖北 宜昌 443002; 2. 梯级水电站运行与控制湖北省重点实验室(三峡大学), 湖北 宜昌 443002)

**摘要:** 电网惯量大小衡量了系统的频率稳定性, 提前对系统惯量水平进行准确预测可以避免因惯量低而造成风险。为此, 提出了一种基于模态分解及特征融合多算法混合神经网络模型对系统等效惯量进行短期预测。首先, 采用改进自适应噪声完备集合经验模态分解(improved complete ensemble empirical mode decomposition with adaptive noise, ICEEMDAN)方法对四季惯量分解处理, 依据各分解分量的精细复合多尺度模糊熵(refined composite multi-scale fuzzy entropy, RCMFE)重构得到新序列。其次, 采用最小冗余最大相关性(minimum redundancy maximum relevance, mRMR)方法衡量不同分解分量与不同特征之间的相关性, 筛选出高相关、低冗余特征子集。最后使用基于贝叶斯优化算法的双向长短期记忆网络(bidirectional long-short-term memory, BiLSTM)模型对不同季节惯量的不同分量进行预测, 累加得到最终预测结果。通过选用国内外典型算例进行试验, 验证了所提方法能够有效平衡预测精度与预测时间, 解决了因季节性差异对系统惯量预测结果造成影响的问题。

**关键词:** 短期预测; 季节性特征; 精细复合多尺度模糊熵; 最小冗余最大相关性; 双向长短期记忆网络; 超参数寻优

## Short-Term Prediction of Seasonal Equivalent Inertia Based on BiLSTM Multi-Algorithm Hybrid Neural Network Model

LI Shichun<sup>1,2</sup>, LIU Jiachang<sup>1,2</sup>, LIU Meng'en<sup>1,2</sup>, YANG Tiao<sup>1,2</sup>, LIU Lu<sup>1,2</sup>, LI Zhenxing<sup>1,2</sup>

(1. College of Electrical Engineering and New Energy, China Three Gorges University, Yichang, Hubei 443002, China;

2. Hubei Provincial Key Laboratory for Operation and Control of Cascaded Hydropower Station, China Three Gorges University, Yichang, Hubei 443002, China)

**Abstract:** The grid inertia magnitude measures the frequency stability of the system, and accurate prediction of the system inertia level in advance can avoid the risk caused by low inertia. To this end, a multi-algorithm hybrid neural network model based on modal decomposition and feature fusion for short-term prediction of system equivalent inertia is proposed. Firstly, an improved complete ensemble empirical mode decomposition with adaptive noise is used to decompose the inertia of four seasons, and a new sequence is obtained by reconstructing the new inertia based on the fine composite multi-scale fuzzy entropy of each decomposed component. Secondly, the minimum redundancy maximum relevance method is used to measure the correlation between different decomposition components and different features, and a subset of highly correlated and low redundancy features is filtered out. Finally, a bidirectional long-short-term memory network model based on Bayesian optimization algorithm is used to predict different components of different seasonal inertias, and the final prediction results are accumulated. Typical examples at home and abroad are selected for testing, which verify that the proposed method can effectively balance the prediction accuracy and prediction time, and solves the problem of seasonal differences affecting the prediction results of system inertia.

**Key words:** short-term prediction; seasonal characteristics; RCMFE; mRMR; BiLSTM; hyperparameter optimization

## 0 引言

在“双碳”能源政策指引下,风电、光伏等非同步电源数量及容量快速增长<sup>[1-3]</sup>。但其与电网频率解耦,无法为系统提供惯量支撑,导致电力系统稳定性下降<sup>[4]</sup>。倘若规划和调度运行部门无法提前掌握系统真实惯量水平,在低惯量运行场景下发生大扰动时系统切负荷的风险将会显著增加<sup>[5-6]</sup>。基于以上分析,提前预警系统何时面临惯量薄弱风险对电网调度部门制定相应控制措施具有重要意义。

近年来,递归网络(recursive neural network, RNN)、长短期记忆网络(long short-term memory, LSTM)以及门控循环单元(gated recurrent unit, GRU)等模型凭借自身特有的循环单元能够同时处理时序性和非线性问题,使得神经网络模型在电力系统预测领域中得到广泛应用。文献[7]利用组合优化算法确定了RNN的隐层结构,实现了风电功率短期预测。但由于RNN其内在设计的局限,产生了长期依赖的问题,因此学者们提出了LSTM<sup>[8]</sup>以及GRU<sup>[9]</sup>等RNN改进型。文献[10]采用双向长短期记忆网络进行负荷预测,证明了相较于LSTM, BiLSTM对于连续时间序列具有更好的表达能力。

为掌握系统惯量水平,国内外学者在惯量评估方面开展了大量研究。文献[11]利用量测类噪声数据、系统辨识模型实现常态下惯量连续估计。文献[12]通过量测风电场出口处有功功率和频率扰动数据估计风电场时变虚拟惯量。文献[13]构建状态空间模型,利用无迹卡尔曼滤波估计系统惯量。文献[14]建立了电力系统惯量响应的等效模型,从中得到系统等效惯量。惯量评估仅能表现运行当前或系统发生扰动后惯量的水平,不能预知其未来变化态势。预测系统等效惯量有助于提前识别其小于临界水平的时间段,以提前做出相应对策。目前针对于系统等效惯量预测的研究主要运用统计学方法。文献[15]运用回归分析方法对电力系统数据进行分析,实现系统惯量预测,但依赖于特定区域的数据,普适性较差。文献[16]使用自回归积分滑动平均模型通过重新分配网络负载来减少可再生能源的波动性以便控制输出功率,但该方法在增强模型鲁棒性和预测准确性方面仍有一定提升空间。文献[17]提出了一种基于最小方差谐波有限脉冲响应滤

波器的系统惯量分析和预测方法,但在实际工程中存在计算成本高、实施困难的问题。文献[18]提出了一种用于预测电力系统动能时间序列的贝叶斯模型。相较于统计学方法,神经网络模型能够自主学习和识别重要特征,无需推导高维度线性公式,简化分析过程<sup>[19]</sup>。在处理大规模数据和预测方面相较于传统统计学方法具有计算成本低和时间效率高的优势。

系统惯量水平不仅受到系统运行方式的影响,还依赖了季节、气象的变化趋势<sup>[20]</sup>,如风速、光照、温度、降水量等。由于风电、光伏等新能源出力受气象因素影响具有强随机性和间歇性,系统等效惯量在时间尺度上表现出较大的波动特性。这种波动特性需要预测模型具有捕捉这些变化规律的能力,并且要拥有更高的适应性与灵活性来应对系统惯量的随机特性。故而预测模型务必综合考虑这些波动特性,以确保预测结果的准确性和可靠性。为此,本文提出了一种电力系统季节性短期惯量组合预测模型。首先采用ICEEMDAN对四季惯量分解处理,根据熵理论中RCMFE值将四季各分解分量重构得到新序列。分析了等效惯量与其影响因素之间的相关性,利用mRMR方法筛选出与等效惯量高相关特征子集,将数据预处理与季节性特征分析结合,构成预测模型输入变量的特征集合。其次利用基于贝叶斯优化算法参数调优的BiLSTM模型分别对不同季节惯量的不同分量进行预测;实验结果表明本文所提模型可更准确预测惯量未来水平且具有更好的适应性。

## 1 算法模型原理

电力系统惯量随时间和季节的变化而变化,具体表现为曲线的季节性形状差异,不同季节下惯量曲线存在明显的峰谷差,峰谷时刻点也大有不同。综上,要充分利用季节性变化信息以进一步提升预测性能,从海量的气象数据、系统运行数据中挖掘系统等效惯量的变化规律。

### 1.1 基于季节性特征的模态分解序列聚合

#### 1.1.1 改进自适应噪声完备集合经验模态分解

本文将全年惯量依据四季划分,分别应用ICEEMDAN算法进行分解。依据电网惯量序列的固有时间尺度,数据被分解成多个频率从高到低的本征模态函数(complex intrinsic mode function,

CIMF)和残差(residual, Res),每个CIMF都能代表电网惯量在不同时间尺度上的特征分量,互不干扰。在分解过程中,ICEEMDAN算法通过添加白噪声 $\eta^i(t)$ 及局部平均来实现邻接尺度之间频率的连续性,从而将非平稳序列 $x(t)$ 自适应地分解为有限个不同频率特征的CIMF分量和一个残差分量,以达到削弱惯量的非线性特征及精细化分析惯量的目的<sup>[21]</sup>。有关ICEEMDAN的分解步骤如式(1)所示。

$$\begin{cases} x^i(t) = x(t) + \alpha_0 E_1(\eta^i(t)) \\ r_k(t) = \langle M(r_{k-1}(t) + \alpha_{k-1} E_k(\eta^i(t))) \rangle \\ I_{MFk}(t) = r_{k-1}(t) - r_k(t) \end{cases} \quad (1)$$

式中: $x(t)$ 为原始惯量序列; $x^i(t)$ 为第*i*次迭代中生成的加噪信号; $E_k(\cdot)$ 为通过经验模态分解算法获取的第*k*阶模态; $\eta^i(t)$ 为添加的第*i*次白噪声; $r_k(t)$ 为第*k*阶残差分量; $\langle \cdot \rangle$ 表示求均值计算; $M(\cdot)$ 为包络计算; $\alpha_{k-1} = \beta_{k-1} std(x(t)) / std(E_k(w^i(t)))$ 为第*k-1*次分解时白噪声的标准差,用于去除噪声,其中 $\beta_{k-1}$ 为加噪与分析信号之间期望信噪比倒数, $w^i(t)$ 为第*i*次迭代时添加的白噪声信号, $std(\cdot)$ 为标准差; $I_{MFk}(t)$ 为第*k*阶模态分量。

### 1.1.2 基于精细复合多尺度模糊熵子序列聚合方法

结合分解方法的系统惯量组合预测模型在各项评估指标方面都有显著的改善,但随着分解级数的增加,组合模型的计算复杂度和时间消耗成本将倍数增加。为平衡预测性能和时间成本,本文采用RCMFE算法<sup>[22]</sup>将按四季划分并分解后的子序列分别聚合。

RCMFE算法为多尺度模糊熵(multiscale fuzzy entropy, MFE)和复合多尺度模糊熵(composite multiscale fuzzy entropy, CMFE)的改进型。通过计算尺度因子 $\tau$ 下的所有粗粒序列,然后进行求和,再计算模糊熵 $E(\cdot)$ ,有效减少了CMFE中未定义熵出现的可能性。针对某一季节的系统惯量,RCMFE的计算公式如式(2)所示。

$$\begin{cases} y_{k,j}^{(\tau)} = \frac{1}{\tau} \sum_{i=(j-1)\tau+k}^{j\tau+k-1} x_i \\ E(x, \tau, m, n, r) = -\ln \left( \frac{\sum_{k=1}^{\tau} \bar{N}_{k,\tau}^{m+1}}{\sum_{k=1}^{\tau} \bar{N}_{k,\tau}^m} \right) \end{cases} \quad (2)$$

式中: $x = \{x_1, x_2, \dots, x_N\}$ 为惯量功率时间序列; $i$ 为求和索引变量; $x_i$ 为惯量功率时间序列中的第*i*个采样值; $N$ 为时间序列的总长度; $y_{k,j}^{(\tau)} = \{y_{k,1}^{(\tau)}, y_{k,2}^{(\tau)}, \dots, y_{k,p}^{(\tau)}\}$ 为粗粒化序列,  $1 \leq k \leq \tau, 1 \leq j \leq N/\tau$ ,  $p$ 为粗粒化序列长度 $p = N/\tau$ ;  $m$ 为嵌入维度; $n$ 为模糊函数梯度; $r$ 为相似容限; $\tau$ 为尺度因子; $\bar{N}_{k,\tau}^{m+1}$ 、 $\bar{N}_{k,\tau}^m$ 分别为尺度因子 $\tau$ 下第*k*个粗粒序列中嵌入维度为*m+1*和*m*时计算匹配向量对的数量,  $\bar{N}_{k,\tau}^{m+1} = \frac{1}{\tau} \sum_{k=1}^{\tau} N_{k,\tau}^{m+1}$ ,  $\bar{N}_{k,\tau}^m = \frac{1}{\tau} \sum_{k=1}^{\tau} N_{k,\tau}^m$ 。

### 1.2 基于季节性特征的惯量影响因素相关性分析

为了分析系统等效惯量与气候及系统运行状况间相互影响的程度,有效选择预测模型的输入特征,需对系统惯量及气候、运行数据进行相关性分析并进一步提取特征。本文采用mRMR特征提取算法<sup>[23]</sup>选择各季节气象及系统运行数据进行特征提取,筛选出影响四季惯量变化最相关的特征因素作为系统惯量预测的输入数据。

mRMR算法作为一种过滤方法进行特征选择,其在考虑特征与类别相关性的同时也考虑了特征之间的相关性。这使得筛选出来的特征子集在保持最大相关性的同时也具有最小的冗余。特征筛选计算过程如式(3)所示。

$$\begin{cases} I(X; Y) = \iint p(x, y) \log \frac{p(x, y)}{p(x)p(y)} dx dy \\ \max D(S, P), D = \frac{1}{|S|} \sum_{f_i \in S} I(f_i, P) \\ \min R(S), R = \frac{1}{|S|^2} \sum_{f_i, f_j \in S} I(f_i, f_j) \\ \max J(D, R), J = D - R \\ \max \phi = \max [I(f_i, c) - \frac{1}{t-1} \sum_{f_j \in S_{t-1}} I(f_i, f_j)] \end{cases} \quad (3)$$

式中: $X$ 、 $Y$ 为特征变量; $p(x)$ 、 $p(y)$ 分别为 $x$ 、 $y$ 的边际概率函数; $p(x, y)$ 为 $x$ 、 $y$ 的联合概率分布;惯量功率*P*的因素集的相关性由各个因素集 $f_i$ 和*P*之间的所有互信息值的平均值来定义; $\max D(S, P)$ 和 $\min R(S)$ 分别量化了特征与类别之间的最大相关性以及特征之间的最小冗余; $D(S, P)$ 为特征与目标类别之间某种相关性的度量; $R(S)$ 为特征之间的冗余; $S$ 为特征集合; $f_i$ 为集合中第*i*个特征; $I(f_i, P)$ 和 $I(f_i, f_j)$ 分别衡量了特征*i*

与目标类别即惯量功率  $P$  以及特征  $i$  与特征  $j$  之间的互信息,二者分别代表了算法的两个核心目标,它们既是竞争又是协同关系;  $\max \phi$  为最大化特征的单变量相关性与其冗余度之间的差值;  $S_{t-1}$  为  $t-1$  步时的特征集合;  $c$  为目标变量;  $\max J(D, R)$  为特征选择算法的评价函数;  $J(D, R)$  为一个具体的评价函数;  $D, R, J$  分别为  $D(S, P), R(S), J(D, R)$  简写式。在选择集合  $S - S_{t-1}$  中选择第  $t$  个特征时需要通过最大化特征的单变量相关性与其冗余度之间的差值来确定。

### 1.3 惯量预测方法

#### 1.3.1 BiLSTM模型

BiLSTM 神经网络由正向和反向 2 个 LSTM 神经网络组成,相较于传统的 LSTM 神经网络, BiLSTM 神经网络在处理时间序列数据时比 LSTM 具有更全面的时间维度理解能力<sup>[24]</sup>。

LSTM 具体结构如图 1 所示。




图 1 LSTM 模型结构

Fig. 1 LSTM model structure

LSTM 网络内含两条通道和 3 个门控单元( $f_t$  为遗忘单元、 $i_t$  为输入单元、 $o_t$  为输出单元),其下通道为短期记忆通道,用于记忆短期信息  $h_t$ ,上通道为长期记忆通道,保持长期记忆信息  $c_t$ 。通过 3 个门控单元完成信息的增改和弃留。采用式(4)进行数据的传递。

$$\begin{cases} f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \\ i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \\ c'_t = \tanh(W_c[h_{t-1}, x_t] + b_c) \\ o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \\ c_t = f_t * c_{t-1} + i_t * c'_t \\ h_t = o_t * \tanh(c_t) \\ y_t = h_t \end{cases} \quad (4)$$

式中:  $\sigma(\cdot)$  为 Sigmoid 激活函数;  $W$  为权重矩阵,

$W_f, W_i, W_o, W_c$  分别为遗忘单元、输入单元、输出单元以及细胞状态的权重矩阵;  $x_t$  为当前时刻的输入向量;  $b_f, b_i, b_c, b_o$  分别为遗忘单元、输入单元细胞状态和输出门的偏置项;  $c'_t$  为候选细胞状态。上一时刻输出  $h_{t-1}$  通过结合当前时刻长期记忆状态  $c_t$  和输出门输出的信息  $o_t$  得到当前时刻隐藏层输出  $h_t$ , 即  $t$  时刻预测功率。

#### 1.3.2 基于贝叶斯优化的 BiLSTM 超参数寻优

群智能算法,如粒子群优化和麻雀搜索算法,其广泛应用于寻优问题。这些算法在开始时需要初始化优化函数,并不断刷新初始化矩阵,导致必须频繁使用神经网络训练,显著提高了模型寻优成本。因此这类群优化算法用于深度学习模型超参数寻优时并不理想。本文采用贝叶斯优化算法解决 BiLSTM 模型的超参数寻优问题。

贝叶斯优化算法基于贝叶斯定理充分利用之前函数的评估信息,根据目标函数的后验分布,选择下一个最有潜力的采样点。其利用概率代理模型对超参数的先验概率进行观测,进而推导出后验概率分布,而后根据后验概率分布,通过采集函数来确定下一个更优的超参数评估点<sup>[25]</sup>。上述具体流程如图 2 所示。




图 2 基于贝叶斯优化的 BiLSTM 超参数优化流程

Fig. 2 BiLSTM hyperparameter optimization process based on Bayesian optimization

#### 1.3.3 数据预处理

考虑到四季、系统运行中不同影响因素及历史

数据的量纲存在差异, 直接将其作为输入特征会影响模型预测精度。本文采用Min-Max归一化方法对原始数据进行放缩处理。其表达式如式(5)所示。

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (5)$$

式中:  $x'$  为归一化后的数据;  $x$  为原始数据;  $x_{\max}$ 、 $x_{\min}$  分别为原始数据中的最大值和最小值。

## 2 电力系统季节性惯量组合短期预测模型

本文在充分考虑电力系统惯量季节性变化特性的基础上将时频分析方法、熵理论、深度学习算法相结合, 提出了一种基于模态分解及特征融合多算法混合神经网络的系统惯量短期组合预测模型(ICEEMDAN-RCMFE-mRMR-Bayes-BiLSTM, IRMBB)。本文所述的对于季节性的考虑是指依据季节性变化相似性进行数据集的选择, 即: 依据待预测惯量所属季节, 摒弃传统地选用连续性数据作为训练集而选用相同季节的数据作为训练集。而后针对所选的每个季节的原始惯量数据, 充分分析其与能代表季节性变化的影响因素及系统运行方式之间的相关性。

BiLSTM结构如图3所示, 该结构可以对输入数据进行双向时序特征提取, 进一步提高时序特征提取的全局性和完整性。

上述具体步骤为: 首先, 利用ICEEMDAN算法对原始惯量数据进行一次模态分解得到多个CIMF分量, 以求降低原始数据的非平稳性。其次, 采用RCMFE方法衡量各个CIMF分量之复杂度, 将具有相似复杂度的分量合并, 得到较少的IMF分量, 达到减少任务量的目的。然后, 使用mRMR方法衡量不同分量与不同特征之间的相关性, 遴选出相关性较大的特征与历史惯量一并作为后续预测模型的输入特征集, 进而提高输入特征的质量, 同时减轻预测模型的负担。最后, 使用贝叶斯算法优化后的BiLSTM模型对不同季节惯量的不同IMF分量分别进行预测, 累加预测值得到最终结果。

### 2.1 原始惯量数据的模态分解与复杂度评估

本文选取中国北方某地区2017年3月至2018年2月共12个月的数据作为实验数据(包括惯量数据、气象数据、系统运行数据等), 数据采样点间隔为15 min。将12个月的数据划分为4个季度, 即2017年3月—2017年5月(春季)、2017年6月—2017年8月(夏季)、2017年9月—2017年11月(秋季)、2017年12月—2018年2月(冬季)。

基于RCMFE的子序列聚合过程如图4所示, 分别使用ICEEMDAN对不同季节的原始惯量数据进行模态分解。经过反复实验, 以秋季为例, 最终




图3 系统惯量短期预测模型整体框架

Fig. 3 Overall framework of the system inertia short-term prediction mode




图4 基于RCMFE的子序列聚合过程

Fig. 4 Subsequence aggregation process based on RCMFE

确定 ICEEMDAN 分解秋季惯量的参数设置：噪声标准差为 0.5，对信号的平均次数为 500 次，最大迭代次数为 2 000 次。分解结果如图 4(a) 所示。得到 CIMF 分量后，使用 RCMFE 方法计算不同季节不同分量的 RCMFE 值，其大小反映数据的复杂程度，值越大则代表数据复杂度越高，非线性越强。设置 RCMFE 的参数：嵌入维度  $m$  为 2，模糊函数梯度  $n$  为 2，相似容限  $r$  为 0.15，得到的四季惯量各分量 RCMFE 值如图 4(b) 所示。针对不同季节，基于图 4(b) 中的划分线，将复杂度相近似的 CIMF 分量划分为同一类，合并为数量较少的 IMF 分量，具体合并结果如表 1 所示。

表 1 CIMF 分量合并结果

Tab. 1 CIMF component merging results

| 季节 | IMF 分量 | CIMF 分量                              |
|----|--------|--------------------------------------|
| 春季 | IMF1   | CIMF3、CIMF6                          |
|    | IMF2   | CIMF2、CIMF7、CIMF9、CIMF11             |
|    | IMF3   | CIMF1、CIMF4、CIMF5、CIMF10             |
|    | IMF4   | CIMF8、Res                            |
| 夏季 | IMF1   | CIMF3、CIMF6、CIMF9                    |
|    | IMF2   | CIMF2、CIMF4、CIMF5、CIMF7、CIMF8、CIMF10 |
|    | IMF3   | CIMF1、Res                            |
| 秋季 | IMF1   | CIMF3、CIMF6                          |
|    | IMF2   | CIMF2、CIMF7                          |
|    | IMF3   | CIMF4、CIMF5、CIMF10、CIMF11            |
|    | IMF4   | CIMF1、CIMF8、CIMF9、Res                |
| 冬季 | IMF1   | CIMF3、CIMF6                          |
|    | IMF2   | CIMF2、CIMF4、CIMF7、CIMF8              |
|    | IMF3   | CIMF1、CIMF5、CIMF9、CIMF10、Res         |

由图 5(a) 可见，惯量分解后的分量均未出现明显模态混叠现象，且原始数据的非平稳性大大降低。低频分量的趋势性和平稳性明显；高频分量的周期性突出。各分量的规律性较原始数据更易掌握。秋季惯量 CIMF 分量合并后形成 4 个 IMF 分量，分别包含复杂度高、规律性差的随机分量 IMF1；振幅小、频率高且具有明显周期性的周期分量 IMF2；频率较大、规律性较差的高频分量 IMF3；波动平缓、规律性较为明显且在一定程度上可以反映惯量原始数据整体变化情况的趋势分量 IMF4。从分量整体看来，各个季节 IMF 分量的平稳性优于原始惯量数据，规律性也要更加明显。

## 2.2 惯量影响因素的相关性分析及特征筛选

由于不同季节的气象条件大不相同,系统运行方式也存在差异,系统惯量的变化因此受到影响。除各个分量的历史惯量这一特征外,本文另外择取风速 $W(\text{m/s})$ 、光照强度 $I(\text{lux})$ 、平均温度 $t_{\text{mean}}(^{\circ}\text{C})$ 、降水量 $R(\text{mm})$ 、净负荷 $P_{\text{net}}(\text{GW})$ 、同步电源出力 $P_{\text{syn}}(\text{GW})$ 、非同步电源出力 $P_{\text{non}}(\text{GW})$ 、系统频率 $f_{\text{sys}}(\text{Hz})$ 8个影响因素作为考虑的输入特征。此外,当风速超过一定阈值时,为防止过速风电机组的控制系统会启动刹车系统降低转速,此时机组惯量基本不发生变化。为此额外使用一个二进制变量来表示风电机组刹车系统的启停,使预测结果更加精确。

基于不同季节惯量形成的IMF分量,本文使用mRMR方法计算各季节惯量的IMF分量与各个特征的相关性大小。为了保证输入特征的质量,同时减轻预测模型的负担,经择优选取,除去历史惯量数据外,各季节惯量IMF分量的输入特征如表2所示。

表2 各季节惯量IMF分量输入特征

Tab. 2 Inertia IMF component input characteristics of various seasons

| 季节 | IMF分量 | 输入特征                                                                                       |
|----|-------|--------------------------------------------------------------------------------------------|
| 春季 | IMF1  | $W, I, R$                                                                                  |
|    | IMF2  | $W, I, P_{\text{net}}, P_{\text{syn}}, P_{\text{non}}, f_{\text{sys}}$                     |
|    | IMF3  | $P_{\text{net}}, P_{\text{syn}}, P_{\text{non}}, f_{\text{sys}}$                           |
|    | IMF4  | $W, R, P_{\text{net}}, P_{\text{syn}}, P_{\text{non}}, f_{\text{sys}}$                     |
| 夏季 | IMF1  | $P_{\text{syn}}, P_{\text{non}}$                                                           |
|    | IMF2  | $I, t_{\text{mean}}, P_{\text{net}}, P_{\text{syn}}, P_{\text{non}}, f_{\text{sys}}$       |
|    | IMF3  | $I, t_{\text{mean}}, R, P_{\text{net}}, P_{\text{syn}}, P_{\text{non}}, f_{\text{sys}}$    |
| 秋季 | IMF1  | $I, R, P_{\text{syn}}, P_{\text{non}}$                                                     |
|    | IMF2  | $W, P_{\text{syn}}, P_{\text{non}}$                                                        |
|    | IMF3  | $W, I, R, t_{\text{mean}}, P_{\text{net}}, P_{\text{syn}}, P_{\text{non}}$                 |
|    | IMF4  | $t_{\text{mean}}, P_{\text{net}}, P_{\text{syn}}, P_{\text{non}}, f_{\text{sys}}$          |
| 冬季 | IMF1  | $W, P_{\text{net}}, P_{\text{syn}}, P_{\text{non}}, f_{\text{sys}}$                        |
|    | IMF2  | $W, I, t_{\text{mean}}, R, P_{\text{net}}, P_{\text{syn}}, P_{\text{non}}, f_{\text{sys}}$ |
|    | IMF3  | $W, I, t_{\text{mean}}, R, P_{\text{net}}, P_{\text{syn}}, P_{\text{non}}, f_{\text{sys}}$ |

## 2.3 超参数优化

传统的寻优方法为试凑法,但考虑到手动调参主观性强,随机性大,且本文需要预测的分量较多,因此采用滑动窗口方式进行预测,在归一化数据后,基于贝叶斯优化算法对BiLSTM网络的学习

率 $l$ 、L2正则化系数 $a$ 、最大迭代数量 $N$ 以及第一和第二隐藏层神经元数量 $L_1$ 和 $L_2$ 这5个超参数进行寻优。BiLSTM寻优范围设置:学习率 $l$ 的寻优范围为 $[10^{-6}, 0.1]$ ,L2正则化系数 $a$ 的寻优范围为 $[10^{-10}, 10^{-2}]$ ,最大迭代次数 $N$ 的寻优范围为 $[50, 300]$ ,第一、二隐藏层神经元数量 $L_1$ 、 $L_2$ 寻优范围均为 $[20, 200]$ 。BiLSTM的批样本大小设置为256,采用Adam优化器进行训练。最终寻优结果如表3所示。

表3 BiLSTM超参数寻优结果

Tab. 3 BiLSTM hyperparameter optimization results

| 季节 | 分量   | 超参数                       |                            |     |       |       |
|----|------|---------------------------|----------------------------|-----|-------|-------|
|    |      | $l$                       | $a$                        | $N$ | $L_1$ | $L_2$ |
| 春季 | IMF1 | $1.002\ 3 \times 10^{-2}$ | $1.765\ 2 \times 10^{-4}$  | 297 | 136   | 158   |
|    | IMF2 | $1.020\ 7 \times 10^{-2}$ | $2.336\ 8 \times 10^{-8}$  | 83  | 170   | 197   |
|    | IMF3 | $1.027\ 7 \times 10^{-2}$ | $8.503\ 6 \times 10^{-5}$  | 193 | 188   | 103   |
|    | IMF4 | $1.115\ 9 \times 10^{-2}$ | $6.017\ 6 \times 10^{-6}$  | 123 | 189   | 142   |
| 夏季 | IMF1 | $1.043\ 8 \times 10^{-2}$ | $1.397\ 5 \times 10^{-10}$ | 137 | 132   | 181   |
|    | IMF2 | $1.004\ 2 \times 10^{-2}$ | $1.345\ 7 \times 10^{-4}$  | 61  | 63    | 153   |
|    | IMF3 | $1.011\ 3 \times 10^{-2}$ | $4.052\ 6 \times 10^{-9}$  | 87  | 196   | 189   |
| 秋季 | IMF1 | $1.276\ 7 \times 10^{-2}$ | $1.828\ 8 \times 10^{-6}$  | 262 | 161   | 163   |
|    | IMF2 | $1.002\ 8 \times 10^{-2}$ | $1.398\ 7 \times 10^{-6}$  | 97  | 62    | 192   |
|    | IMF3 | $1.451\ 7 \times 10^{-2}$ | $1.936\ 1 \times 10^{-6}$  | 173 | 103   | 97    |
|    | IMF4 | $1.076\ 6 \times 10^{-2}$ | $2.818\ 6 \times 10^{-6}$  | 234 | 181   | 196   |
| 冬季 | IMF1 | $1.037\ 1 \times 10^{-2}$ | $4.670\ 9 \times 10^{-10}$ | 83  | 147   | 68    |
|    | IMF2 | $1.021\ 6 \times 10^{-2}$ | $1.065\ 2 \times 10^{-3}$  | 293 | 173   | 196   |
|    | IMF3 | $1.032\ 8 \times 10^{-2}$ | $7.456\ 4 \times 10^{-8}$  | 52  | 192   | 177   |

## 2.4 评价指标

为验证本文所提模型的预测性能,采用平均绝对误差 $E_{\text{MAE}}$ 、均方根误差 $E_{\text{RMSE}}$ 、平均绝对百分比误差 $E_{\text{MAPE}}$ 作为评价指标,以验证模型对于系统惯量预测的准确性。其中, $E_{\text{MAE}}$ 为模型的实际误差; $E_{\text{RMSE}}$ 为预测结果中极端异常值的影响; $E_{\text{MAPE}}$ 为惯量大小绝对百分比误差和的平均值,可以体现预测模型的整体预测效果。各评价指标表达式如下。

$$\begin{cases} E_{\text{MAE}} = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \\ E_{\text{RMSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \\ E_{\text{MAPE}} = \frac{1}{n} \sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right| \times 100\% \end{cases} \quad (6)$$

式中: $n$ 为样本数量; $\hat{y}_i$ 、 $y_i$ 分别为预测值和真

实值。

### 3 算例分析

本文所提方法已在 MATLAB2016b 上实现。所用计算的配置：处理器为 AMD Ryzen 5 6600H CPU@3.30GHz，运行内存为 16 GB，显卡为 NVIDIA 的 RTX3050。在不同季节的系统惯量中，以最后一周之前的数据作为训练数据，采用滑动窗口的方式分别对每个季节最后一周的惯量进行单步预测。滑动窗口长度设置为 96，即将前 96 组样本作为输入数据，对第 97 个采样点进行预测，然后滑动窗口，将预测所得的第 97 个数据作为新的特征，实现滚动预测。

#### 3.1 不同组合预测模型对比分析

本节将现有的多种组合预测方法和本文提出的 IRMBB 方法在中国北方某城市的数据集上进行实验，均考虑季节变化信息，进行对比分析，验证本文提出的组合预测方法对高效惯量预测的有效性。

##### 3.1.1 预测精度与时间有效性的平衡

为验证本文提出的电力系统季节性短期惯量组合预测模型的优越性，建立 ICEEMDAN-mRMR-Bayes-BiLSTM (IMBB)<sup>[26]</sup>、mRMR-Bayes-BiLSTM (MBB)<sup>[27]</sup>、ICEEMDAN-RCMFE-mRMR-SSA-BiLSTM (IRMSB)<sup>[28]</sup> 共 3 个模型与本文所提出的 (ICEEMDAN-RCMFE-mRMR-Bayes-BiLSTM, IRMBB) 模型进行对比分析。上述对比模型各有其独特的优势和局限性。IMBB 模型通过 ICEEMDAN 算法增强了对非线性和非平稳数据的处理能力，但在极端事件处理上可能存在鲁棒性低问题；MBB 模型简化了结构，但可能在处理复杂数据时不如运用了 ICEEMDAN 算法的模型有效；IRMSB 模型通过结合多种方法提高了准确性及鲁棒性，但计算成本可能过高。为了保证模型对比分析的公平性，贝叶斯优化 (bayesian optimization, BO) 与樽海鞘群算法 (salp swarm algorithm, SSA) 的迭代数量均设置为 30 次；SSA 的种群数设置为 10，种群中发现、加入、警戒者的比例为 7:2:1。4 种方法分别预测 4 个季节惯量所花费的预测时间与预测评估指标值如图 5 所示。

由图 5(a) 可知，IMBB 预测各季节的惯量所花费的时间远高于 IRMBB 及 MBB。其中，IMBB 在

预测秋、冬两季惯量上所花时间为 IRMBB 的 2 倍；在预测春、夏两季惯量上所花费的时间甚至达到了 IRMBB 的 3 倍以上；对比于 IRMSB，其预测春、夏、秋、冬天四季惯量所花费的时间分别为 IRMBB 的 2.1 倍、1.98 倍、1.99 倍、1.77 倍。虽然 IRMSB 与 IRMBB 所需预测的 IMF 分量是完全相同的，但由于采用了群智能算法 SSA 对预测模型 BiLSTM 进行优化，且训练数据维度较高、数据量较大，加之 BiLSTM 需寻优的超参数较多，从而增大了 IRMSB 预测所需时间。再结合图 5(b) — (d) 来看，MBB 虽然耗时很短，但由于未采用 ICEEMDAN-RCMFE 方法对原始惯量数据进行处理，而仅采用 Bayes-BiLSTM 对经过特征筛选后的季节惯量进行预测，未能得到很好的预测效果，各项评价指标都要大幅劣于本文所提的 IRMBB。IMBB 虽然预测效果在一定程度上较优于 IRMBB，但所耗费时间过长，效率低下。而 IRMSB 预测时间虽然超出 IRMBB 不少，但其预测效果却并未得到改善，各项指标略低于 IRMBB。直观上来看，可以初步验证本文提出的 IRMBB 方法的优越性。

为了进一步定量分析本文方法在平衡预测精度和预测时间方面的优越性，本文采用 Topsis 熵权法<sup>[26]</sup>对本节所述的 4 种方法进行评价，在最小化“预测时间”指标后，4 种方法在 4 个季节的评价值如表 4 所示。

由表 4 可知，IRMBB 方法在 4 个季节的 Topsis 值最低，为最佳值；其次是 IRMSB 法，其在各季节与 IRMBB 具有相同量级，但数值仍略小于 IRMBB；其次是 IRMB 方法；MBB 方法的 Topsis 值最高，也是预测效果最差的方法。综上，验证了 IRMBB 方法对平衡惯量预测精度和预测时间的有效性和优越性。

##### 3.1.2 预测精度的有效性

为了进一步验证本文所提方法在预测精度方面相较于其他组合模型的优越性，本文分别设立了 5 组对比模型：1) ICEEMDAN-RCMFE-mRMR-BiLSTM (IRMB)<sup>[29]</sup>；2) ICEEMDAN-RCMFE-mRMR-Bayes-SVM (IRMBs)<sup>[30]</sup>；3) ICEEMDAN-RCMFE-mRMR-Bayes-XGBoost (IRMBX)<sup>[31]</sup>；4) ICEEMDAN-RCMFE-mRMR-Bayes-LSTM (IRMBL)<sup>[31]</sup>；5) ICEEMDAN-RCMFE-mRMR-Bayes-GRU (IRMBG)<sup>[32-34]</sup>。本文所提 IRMBB 与 5 组对比模型的预测结果评价指标




图5 不同模型预测不同季节惯量所需预测时间与预测评估指标

Fig. 5 Prediction time and prediction evaluation indexes required by different models to predict the inertia of different seasons

表4 基于Topsis熵权法的4种预测方法评价

Tab. 4 Evaluation values of four prediction methods based on topsis entropy weight method

| 方法           | 春季             | 夏季             | 秋季             | 冬季             |
|--------------|----------------|----------------|----------------|----------------|
| IRMB         | 0.134 6        | 0.135 7        | 0.111 7        | 0.112 4        |
| <b>IRMBB</b> | <b>0.016 2</b> | <b>0.017 3</b> | <b>0.024 3</b> | <b>0.029 8</b> |
| IRMSB        | 0.062 3        | 0.058 8        | 0.068 8        | 0.067 5        |
| MBB          | 0.786 8        | 0.788 1        | 0.795 1        | 0.790 3        |

如表5所示。

由表5可知,本文所提IRMBB方法在4个季节的各项评估指标均优于其他组合模型。相较于LSTM、GRU这类深度学习领域的基准模型,BiLSTM由于具有良好的捕捉时间序列数据双向依赖关系的能力,故其评价指标略优于LSTM与GRU,IRMBB 4个季节的 $E_{MAPE}$ 值均在IRMBL和IRMBG的52%~83%之间。LSTM与GRU相比,LSTM略胜一筹。作为机器学习领域典型模型的SVM、XGBoost,其预测效果又要劣于LSTM与GRU,且较大幅度低于BiLSTM。即使在IRMBX预测效果最好的夏季,其 $E_{MAE}$ 、 $E_{RMSE}$ 、 $E_{MAPE}$ 3项指标也分别达到了IRMBB的1.64、1.62、1.71倍;而IRMSB 4个季节的各项评估指标均达到了IRMBB的3倍以上。但是,如若BiLSTM没有经过Bayes寻优,即使数据经过ICEEMDAN-RCMFE方法处理过,也无法得到较好的预测效果,如IRMB的各项评估指标均在IRMBB的5倍以上。

图6是该节所述6种方法在4个季节的小提琴误差图。表明未经Bayes进行超参数寻优的IRMB方法整体误差最大,IRMSB和IRMBX次之。IRMBG与IRMBL整体误差相差不大,由于本文所采用训练集的规模较大,IRMBL略优于IRMBG。而本文所提出的IRMBB的整体误差变化在六组模型中最小,其预测性能之优可见一斑。综上所述,本文所提的IRMBB方法相较于其他5种方法的优越性得以验证。

### 3.2 典型地区季节性惯量短期预测对比分析

由于不同季节的惯量变化特性具有较大区别,故针对不同季节的惯量分别进行预测,能够为深度学习预测模型提供更高质量的输入数据,相较于未考虑季节变化的方法应具有更高的惯量预测精度。为验证这一点本节采用本文所提IRMBB方法和3.1.2节中所述5个对比模型分别针对美国得克萨

表 5 6 种模型在不同季节的预测性能指标

Tab. 5 Predictive performance indexes of the six models in different seasons

| 方法           | 春季            |                |                | 夏季            |                |                | 秋季            |                |                | 冬季            |                |                |
|--------------|---------------|----------------|----------------|---------------|----------------|----------------|---------------|----------------|----------------|---------------|----------------|----------------|
|              | $E_{MAPE}/\%$ | $E_{MAE}/s$    | $E_{RMSE}/s$   | $E_{MAPE}/\%$ | $E_{MAE}/s$    | $E_{RMSE}/s$   | $E_{MAPE}/\%$ | $E_{MAE}/s$    | $E_{RMSE}/s$   | $E_{MAPE}/\%$ | $E_{MAE}/s$    | $E_{RMSE}/s$   |
| IRMB         | 9.2           | 0.669 6        | 0.74           | 9.5           | 0.722 6        | 0.803 2        | 8.64          | 0.571 2        | 0.689 9        | 7.9           | 0.446 4        | 0.506 6        |
| IRMBS        | 4.0           | 0.331 7        | 0.380 2        | 4.7           | 0.383 4        | 0.506 3        | 5.2           | 0.328 1        | 0.415 4        | 4.9           | 0.265 9        | 0.310 4        |
| IRMBX        | 3.3           | 0.228 3        | 0.264 0        | 2.4           | 0.180 8        | 0.224 7        | 3.3           | 0.182 6        | 0.242 5        | 3.5           | 0.179 5        | 0.239 0        |
| IRMBG        | 3.1           | 0.217 3        | 0.252 4        | 2.3           | 0.178 5        | 0.197 0        | 2.5           | 0.140 7        | 0.172 3        | 2.8           | 0.152 4        | 0.183 2        |
| IRMBL        | 2.5           | 0.166 2        | 0.192 3        | 1.7           | 0.131 4        | 0.174 6        | 2.1           | 0.133 1        | 0.141 3        | 2.3           | 0.129 7        | 0.166 7        |
| <b>IRMBB</b> | <b>1.5</b>    | <b>0.113 7</b> | <b>0.136 9</b> | <b>1.4</b>    | <b>0.110 2</b> | <b>0.138 8</b> | <b>1.6</b>    | <b>0.087 6</b> | <b>0.104 2</b> | <b>1.5</b>    | <b>0.075 2</b> | <b>0.085 2</b> |




图 6 不同模型对四季的预测效果

Fig. 6 Prediction effects of different models on the four seasons

斯州 2020 年冬季的极端低温周惯量与 2021 年夏季的极端高温周惯量进行了预测。为形成对照, 分别设立两类训练集: 第一类为本文所述的季节性训练集, 第二类为传统的连续性训练集, 使用包括 IRMBB 在内的 6 种预测方法对惯量进行预测。预测所用训练集、测试集的配置如表 6 所示。6 种方法对德克萨斯州夏季和冬季的惯量预测结果评价指标如表 7 所示。

表 6 训练集与测试集配置

Tab. 6 Training sets and test sets configuration

| 数据集 | 时间段                                    |                                                                                 |
|-----|----------------------------------------|---------------------------------------------------------------------------------|
|     | 2020 年冬季                               | 2021 年夏季                                                                        |
| 训练集 | 季节性训练集                                 | 2019/12/1—2020/2/29 2020/6/1—2020/9/30<br>2020/12/1—2021/2/8 2021/6/1—2021/6/12 |
|     | 连续性训练集                                 | 2020/9/1—2021/2/8 2021/3/1—2021/6/12                                            |
| 测试集 | 2021/2/9—2021/2/15 2021/6/13—2021/6/19 |                                                                                 |

表7 6种方法预测性能比较

Tab. 7 Comparison of prediction performance of six methods

| 方法           | 冬季季节性训练集      |             |              | 冬季连续性训练集      |             |              | 夏季季节性训练集      |             |              | 夏季连续性训练集      |             |              |
|--------------|---------------|-------------|--------------|---------------|-------------|--------------|---------------|-------------|--------------|---------------|-------------|--------------|
|              | $E_{MAPE}/\%$ | $E_{MAE}/s$ | $E_{RMSE}/s$ | $E_{MAPE}/\%$ | $E_{MAE}/s$ | $E_{RMSE}/s$ | $E_{MAPE}/\%$ | $E_{MAE}/s$ | $E_{RMSE}/s$ | $E_{MAPE}/\%$ | $E_{MAE}/s$ | $E_{RMSE}/s$ |
| IRMB         | 13            | 0.487 4     | 0.634 6      | 14.9          | 0.646 0     | 0.721 6      | 5.8           | 0.952 1     | 1.031 8      | 11.0          | 1.428 1     | 1.562 4      |
| IRMBs        | 4.9           | 0.290 4     | 0.388 7      | 6.7           | 0.320 0     | 0.370 8      | 4.4           | 0.505 2     | 0.650 3      | 5.6           | 0.820 3     | 1.132 3      |
| IRMBX        | 3.7           | 0.196 0     | 0.299 3      | 5.8           | 0.220 2     | 0.257 4      | 2.7           | 0.238 2     | 0.288 6      | 4.4           | 0.456 5     | 0.661 0      |
| IRMBG        | 3.6           | 0.166 5     | 0.229 5      | 4.4           | 0.209 7     | 0.246 1      | 1.7           | 0.235 2     | 0.253 1      | 3.0           | 0.351 9     | 0.469 8      |
| IRMBL        | 3.3           | 0.141 7     | 0.208 8      | 4.0           | 0.160 3     | 0.187 5      | 1.9           | 0.173 2     | 0.224 3      | 4.4           | 0.332 7     | 0.385 3      |
| <b>IRMBB</b> | 1.8           | 0.082 1     | 0.106 7      | 2.7           | 0.109 7     | 0.133 5      | 1.7           | 0.145 2     | 0.178 3      | 2.3           | 0.218 9     | 0.284 1      |

由表7可知,在对德州极端天气情况下的惯量进行预测时,采用季节性训练集对BiLSTM进行训练,最终预测所得的结果普遍优于采用连续性训练集对BiLSTM进行训练所得出的预测结果。单独来看,IRMBB在冬季极端低温情况和夏季极端高温情况下采用季节性训练集预测出结果的 $E_{MAPE}$ 仅为1.8%和1.7%,较前文对国内正常天气情况下的惯量预测结果 $E_{MAPE}$ 略大,这是由于极端天气情况下各种影响因素存在更大的随机性所致。整体看来,本文所提出的IRMBB相较于另外5组对比模型,预测效果更好,且即使采用连续性训练集,亦能取得较为理想的预测结果,其在冬夏两季的惯量预测结果 $E_{MAPE}$ 指标分别为2.7%、2.3%。

此外,当训练集数据量大幅减少时,采用GRU的预测效果反而优于LSTM,例如:在夏季两类训练集仅采用了2 664个样本,故IRMBG在夏季的 $E_{MAPE}$ 值分别为1.7%、3%,优于IRMBL的1.9%与4.4%,且EMAE与ERMSE也一定程度上小于IRMBL;而当在冬季采用4 032个样本量进行训练时,IRMBL的预测结果又要优于IRMBG,结合前文4个季节均采用8 000以上规模的样本集对国内正常天气情况下的惯量预测所得出的“LSTM优于GRU”这一结论,如若进一步增大训练集样本量,LSTM与BiLSTM这类模型的预测效果将更优于GRU。从另一个角度来讲,这也验证了本文所提出的“ICEEMDAN-RCMFE-mRMR-Bayes-BiLSTM”预测模型框架对于惯量预测精度提升的有效性。

图7是所述6种方法采用不同训练集所得的训练效果图。其中“实际值”为由同步发电机组运行状态和新能源出力等数据计算求得的系统等效惯量,“预测值”为IRMBB系统等效惯量预测模型的输出

值。结果表明面对极端天气影响因素存在更大的随机性的情况下,本文所提出的IRMBB方法相较于其他5种方法更好地贴合了实际惯量曲线。对比图7(a)两图可见,采用季节性训练集预测所得惯量曲线的轮廓相较于连续性训练集预测所得出的惯量曲线,更相似于、贴合于实际惯量曲线。而在对德州电网六月极端高温天气情况下的惯量进行预测时,由图7(b)两图可知,IRMBB的预测惯量曲线在部分峰谷处的拟合效果不如IRMBX、IRMBL等方法,但在整体轮廓曲线上IRMBB要更加贴合于实际惯量曲线。

#### 4 结论

本文针对系统等效惯量的时变性与强波动性特点,构建了基于模态分解及特征融合多算法混合神经网络模型的电力系统季节性惯量短期组合预测模型(IRMBB)。理论分析揭示其原理与优势,实际算例验证其有效性。本文所做工作表明:

1)本文所提IRMBB模型经过模态分解、聚合等过程,降低任务量的同时提升了预测精度,与现有组合模型相比具有预测精度高,预测时间短的优势。

2)与目前常用组合模型及优化算法相比,IRMBB模型更适合四季惯量分解与特征提取,评价指标更优。

3)本文采用分季节分析策略对电力系统惯量进行了细致的分析,针对不同季节的不同分量建立与之对应的模型分别进行预测。这种方法不仅提供了优质的输入数据,而且通过实际案例证明,相较于未考虑季节性变化的方法,显著提高了预测精度。





图 7 不同模型采用季节性训练集和连续性训练集的预测结果对比

Fig. 7 Prediction results of different models using seasonal training set and continuous training set are compared

## 参考文献

[1] 辛保安, 李明节, 贺静波. 新型电力系统安全防御体系探究

[J]. 中国电机工程学报, 2023, 43(15): 5723 – 5732.

XIN Baoan, LI Mingjie, HE Jingbo. Research on security defense system of new power system [J]. Proceedings of the CSEE, 2023, 43(15): 5723 – 5732.

- [2] 舒印彪,薛禹胜,蔡斌.关于能源转型分析的评述(一)转型要素及研究范式[J].电力系统自动化,2018,42(9):1-15.  
SHU Yinbiao, XUE Yusheng, CAI Bin. A review of energy transition analysis part one elements and paradigms [J]. Automation of Electric Power Systems, 2018, 42(9): 1-15.
- [3] 何伊慧,管霖,王彤,等.南方电网新型电力系统规划建设的量化评估与分析[J].南方电网技术,2024,18(10):40-53.  
HE Yihui, GUAN Lin, WANG Tong, et al. Quantitative evaluation and analysis of planning and construction of the new power system in China Southern Power Grid [J]. Southern Power System Technology, 2024, 18(10): 40-53.
- [4] 陈国平,李明节,许涛.我国电网支撑可再生能源发展的实践与挑战[J].电网技术,2017,41(10):3095-3103.  
CHEN Guoping, LI Mingjie, XU Tao. Practice and challenge of renewable energy development based on interconnected power grids [J]. Power System Technology, 2017, 41(10): 3095-3103.
- [5] 张武其,文云峰,迟方德.电力系统惯量评估研究框架与展望[J].中国电机工程学报,2021,41(20):6842-6856.  
ZHANG Wuqi, WEN Yunfeng, CHI Fangde. Research framework and prospect on power system inertia estimation [J]. Proceedings of the CSEE, 2021, 41(20): 6842-6856.
- [6] 王博,杨德友,蔡国伟.高比例新能源接入下电力系统惯量相关问题研究综述[J].电网技术,2020,44(8):2998-3007.  
WANG Bo, YANG Deyou, CAI Guowei. Review of research on power system inertia related issues in the context of high penetration of renewable power generation [J]. Power System Technology, 2020, 44(8): 2998-3007.
- [7] 周洪煜,曾济贫,王照阳,等.基于混沌DNA遗传算法与PSO组合优化的RNN短期风电功率预测[J].电力系统保护与控制,2013,41(2):144-149.  
ZHOU Hongyu, ZENG Jipin, WANG Zhaoyang, et al. Ridgelet neural network model for short-term wind power forecasting based on the combination of chaos DNA genetic and particle swarm optimization algorithm [J]. Power System Protection and Control, 2013, 41(2): 144-149.
- [8] 张未,余成波,王士彬,等.基于VMD-LSTM-LightGBM的多特征短期电力负荷预测[J].南方电网技术,2023,17(2):74-81.  
ZHANG Wei, YU Chengbo, WANG Shibin, et al. Multi-featured short-term power load forecasting based on VMD-LSTM-LightGBM [J]. Southern Power System Technology, 2023, 17(2): 74-81.
- [9] 吴慧军,郭超雨,苏承国,等.基于EEMD-GRU-MC的短期风功率组合预测方法[J].南方电网技术,2023,17(2):66-73.  
WU Huijun, GUO Chaoyu, SU Chengguo, et al. Combined prediction method for short-term wind power based on EEMD-GRU-MC [J]. Southern Power System Technology, 2023, 17(2): 66-73.
- [10] HU S, ZHANG T, YANG F, et al. Short-term load forecasting based on mutual information and Bi-LSTM considering fluctuation in importance values of features [J]. IEEE Access, 2023(12): 23653-23665.
- [11] 李世春,夏智雄,程绪长.基于类噪声扰动的电网惯量常态化连续估计方法[J].中国电机工程学报,2020,40(14):4430-4439,4723.  
LI Shichun, XIA Zhixiong, CHENG Xuchang. Continuous estimation method of power system inertia based on ambient disturbance [J]. Proceedings of the CSEE, 2020, 40(14): 4430-4439, 4723.
- [12] 李世春,徐松林,李惠子.风电场等效虚拟惯量快速估计方法[J].电网技术,2021,45(12):4683-4692.  
LI Shichun, XU Songlin, LI Huizi. Rapid estimation of equivalent virtual inertia of wind farm [J]. Power System Technology, 2021, 45(12): 4683-4692.
- [13] TAN B D, ZHAO J B. Data-driven time-varying inertia estimation of inverter-based resources [J]. IEEE Transactions on Power Systems, 2023, 38(2): 1795-1798.
- [14] LUGNANI L, DANIEL D, CHRISTOPH L. ARMAX-based method for inertial constant estimation of generation units using synchrophasors [J]. Electric Power Systems Research, 2020(180): 106097.1-106097.10.
- [15] DU P, MATEVOSYAN J. Forecast system inertia condition and its impact to integrate more renewables [J]. IEEE Transactions on Smart Grid, 2017, 9(2): 1531-1533.
- [16] MAKOLO P, OLADEII I, ZAMORA R, et al. Short-range inertia prediction for power networks with penetration of RES [C]//TENCON 2021 - 2021 IEEE Region 10 Conference (TENCON). December 7-10, 2021, Auckland, New Zealand. New York: IEEE, 2021: 765-770.
- [17] CARLINI E M, DEL P F, GIANNUZZI G M, et al. Online analysis and prediction of the inertia in power systems with renewable power generation based on a minimum variance harmonic finite impulse response filter [J]. International Journal of Electrical Power & Energy Systems, 2021(131): 107042.1-107042.12.
- [18] SHRESTHA A, GHIMIRE B, GONZALEZ-LONGATT F. A Bayesian model to forecast the time series kinetic energy data for a power system [J]. Energies, 2021, 14(11): 3299.1-3299.10.
- [19] 李正文,王祥旭,丁奇力,等.基于模型-数据融合驱动的频率响应分析方法[J].电网与清洁能源,2022,38(5):16-24.  
LI Zhengwen, WANG Xiangxu, DING Qili, et al. Model-data integration driven based frequency response analysis method [J]. Power System and Clean Energy, 2022, 38(5): 16-24.
- [20] DU P, MATEVOSYAN J. Forecast system inertia condition and its impact to integrate more renewables [J]. IEEE Transactions on Smart Grid, 2018, 9(2): 1531-1533.
- [21] WU J, MIU F, LI T. Daily crude oil price forecasting based on improved CEEMDAN, SCA, and RVFL: a case study in WTI oil market [J]. Energies, 2020, 13(7): 1-20.
- [22] AZAMI H, FERNÁNDEZ A, ESCUDERO J. Refined multiscale fuzzy entropy based on standard deviation for biomedical signal analysis [J]. Medical & Biological Engineering & Computing, 2017, 55(11): 2037-2052.
- [23] PENG H C, LONG F H, DING C. Feature selection based on mutual information: criteria of max-dependency, max-relevance, and min-redundancy [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2005, 27(8): 1226-1238.
- [24] SCHUSTER M, PALIWAL K K. Bidirectional recurrent neural networks [J]. IEEE Transactions on Signal Processing, 1997, 45(11): 2673-2681.
- [25] 龚雪娇,朱瑞金,唐波.基于贝叶斯优化XGBoost的短期峰值负荷预测[J].电力工程技术,2020,39(6):76-81.  
GONG Xuejiao, ZHU Ruijin, TANG Bo. Short-term peak load forecasting based on Bayesian optimization XGBoost [J].

- Electric Power Engineering Technology, 2020, 39(6): 76 – 81.
- [26] 胡威, 张新燕, 李振恩. 基于优化的VMD-mRMR-LSTM模型的短期负荷预测[J]. 电力系统保护与控制, 2022, 50(1): 88 – 97.
- HU Wei, ZHANG Xinyan, LI Zhenen. Short-term load forecasting based on an optimized VMD-mRMR-LSTM model [J]. Power System Protection and Control, 2022, 50(1): 88 – 97.
- [27] 白冰青, 刘江涛, 王旭. 基于MRMR和双重注意力机制的城市能源多元负荷短期预测[J]. 电力系统自动化, 2022, 46(17): 44 – 55.
- BAI Bingqing, LIU Jiangtao, WANG Xu. Short-term multivariate load forecasting for urban energy based on minimum redundancy maximum relevance and dual-attention mechanism [J]. Automation of Electric Power Systems, 2022, 46(17): 44 – 55.
- [28] 胡如乐, 陈逸枫, 张大海. 基于SSA-Bi-LSTM神经网络的母线负荷预测方法[J]. 广东电力, 2022, 35(2): 19 – 26.
- HU Rule, CHEN Yicong, ZHANG Dahai. Bus load prediction method based on SSA-Bi-LSTM neural network [J]. Guangdong Electric Power, 2022, 35(2): 19 – 26.
- [29] 李青, 李军, 马昊. 基于互补型集成经验模态分解-模糊熵和回声状态网络的短期电力负荷预测[J]. 计算机应用, 2014, 34(12): 3651 – 3655, 3659.
- LI Qing, LI Jun, MA Hao. Short-term electricity load forecasting based on complementary ensemble empirical mode decomposition-fuzzy permutation and echo state network [J]. Computer Applications, 2014, 34(12): 3651 – 3655, 3659.
- [30] 杨小明, 崔雪, 周斌. 基于粒子群优化支持向量机的短期负荷预测[J]. 武汉大学学报(工学版), 2018, 51(8): 715 – 720.
- YANG Xiaoming, CUI Xue, ZHOU Bin. Short-term load forecasting based on particle swarm optimisation support vector machine [J]. Engineering Journal of Wuhan University, 2018, 51(8): 715 – 720.
- [31] 陈振宇, 刘金波, 李晨. 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. Ultra short-term power load forecasting based on combined LSTM-XGBoost model [J]. Power System Technology, 2020, 44(2): 614 – 620.
- [32] 邹智, 吴铁洲, 张晓星. 基于贝叶斯优化CNN-BiGRU混合神经网络的短期负荷预测[J]. 高电压技术, 2022, 48(10): 3935 – 3945.
- ZOU Zhi, WU Tiezhou, ZHANG Xiaoxing. Short-term load forecast based on Bayesian optimized CNN-BiGRU hybrid neural networks [J]. High Voltage Engineering, 2022, 48(10): 3935 – 3945.
- [33] 罗林霖, 王霄, 何志琴, 等. 基于滚动模态分解和GCN-DABiLSTM的综合能源系统多元负荷预测模型[J]. 广东电力, 2025, 38(9): 130 – 138.
- LUO Linlin, WANG Xiao, HE Zhiqin, et al. Multi-load forecasting model for integrated energy system based on rolling mode decomposition and GCN-DABiLSTM [J]. Guangdong Electric Power, 2025, 38(9): 130 – 138.
- [34] 林彦旭, 高辉. 基于SSA-VMD-BiLSTM模型的充电站负荷预测方法[J]. 广东电力, 2024, 37(6): 53 – 61.
- LIN Yanxu, GAO Hui. Load prediction method of charging station based on SSA-VMD-BiLSTM model [J]. Guangdong Electric Power, 2024, 37(6): 53 – 61.

收稿日期: 2024-04-08; 网络首发日期: 2024-09-30

作者简介:

李世春(1984), 男, 副教授, 硕士生导师, 博士, 研究方向为含新能源电力系统运行与控制, lschun\_023@126.com;

刘佳昌(1999), 男, 通信作者, 硕士研究生, 研究方向为含新能源电力系统运行与控制, 202208080021030@ctgu.edu.cn;

刘蒙恩(2000), 男, 硕士研究生, 研究方向为新型电力系统运行与控制, 2690133340@qq.com。