

基于组合模态分解与 IGWO-BiLSTM 的短期风电功率预测

任爽, 姚大学, 刘俊享, 程天祥

(东北石油大学 电气信息工程学院, 黑龙江 大庆 163318)

摘要: 为了提高双向长短期记忆神经网络 (BiLSTM) 进行风电功率预测的精度, 针对 BiLSTM 存在的参数优化问题, 通过引入透镜成像反向学习进行种群初始化、改进收敛方式、并结合柯西变异算法, 改进了传统的灰狼算法 (GWO) 来优化 BiLSTM 的超参数, 并基于 ICEEMDAN-VMD 组合模态分解和改进后的 GWO 算法提出了一种 ICEEMDAN-VMD-IGWO-BiLSTM 组合预测模型; 在我国西北地区某风场公开数据集上做了验证, 实验结果表明: ICEEMDAN-VMD-IGWO-BiLSTM 组合模型的 MAE、MSE、RMSE 分别为 4.918 9、32.368 3、5.689 3 MW; 相较于 CNN-LSTM、CNN-BiLSTM 神经网络模型以及其他组合模型在预测精度上都有明显的提升, 能很好地解决风电预测精度不高的问题。

关键词: 短期风电功率预测; 改进灰狼算法; 分解技术; 样本熵; 双向长短期记忆神经网络

Short-Term Wind Power Prediction Based on Combined Mode Decomposition and IGWO-BiLSTM

REN Shuang, YAO Daxue, LIU Junxiang, CHENG Tianxiang

(School of Electrical and Information Engineering, Northeast Petroleum University, Daqing 163318, China)

Abstract: In order to improve the accuracy of bidirectional long short-term memory (BiLSTM) in wind power prediction, aiming at the parameter optimization in BiLSTM, the paper introduces lens-imaging reverse learning for initializing the population and increases the convergence mode. Combined with the Cauchy mutation algorithm, the improved traditional grey wolf algorithm (GWO) is used to optimize the hyperparameters of the BiLSTM. Based on the ICEEMDAN-VMD mode decomposition and improved GWO algorithm, an ICEEMDAN-VMD-IGWO-BiLSTM combination prediction model is proposed. Through verification on a publicly available data set of a wind farm in northwest China, Experimental results show that the MAE, MSE and RMSE of the ICEEMDAN-VMD-IGWO-BiLSTM combination model reach by 4.918 9, 32.368 3 and 5.689 3 MW, respectively. Compared with CNN-LSTM, CNN-BiLSTM neural network model and other combination models, this model improves prediction accuracy significantly, which can effectively solve the low prediction accuracy of wind power.

Keywords: short term wind power forecast; improved gray wolf algorithm; decomposition technique; sample entropy; BiLSTM neural network

0 引言

在全球环保意识不断提高的背景下, 风力发电作为一种绿色可再生能源正获得日益广泛的应用^[1]。然而, 风电固有的间歇性和波动性特征导致其发电出力具有不确定性, 这给电力系统的并网运行、调度管理及消纳能力带来了显著挑战^[2]。在此背景下, 风电功率预测技术

的重要性日益凸显。通过准确预测风电场的出力情况, 该技术能够有效协调电力供应与负荷需求之间的动态平衡, 不仅有助于优化电网调度决策, 更能显著提升电力系统的运行安全性和稳定性。因此, 提高风电功率预测精度对于保障新型电力系统可靠运行具有重要的意义^[3]。

目前, 国内外学者在风电功率预测领域主要采用物

收稿日期:2024-07-21; 修回日期:2024-08-30。

作者简介:任爽(1979-),女,硕士,副教授。

引用格式:任爽,姚大学,刘俊享,等.基于组合模态分解与 IGWO-BiLSTM 的短期风电功率预测[J].计算机测量与控制,2025,33(9):83-90.

理法和统计方法^[4]。统计学习方法主要基于数据驱动原理,通过整合目标风电场的历史功率输出数据及周边风电场的运行信息,构建具有时空关联特的预测模型。这种方法利用机器学习算法挖掘海量历史运行数据中隐含的时空相关性规律,从而实现对风电功率的准确预测^[5]。当前研究趋势表明,单一预测模型往往难以全面捕捉风电功率的复杂特性。为此,学者们正致力于开发多模型融合的混合预测方法,通过智能优化算法有机整合不同模型的优势,以提升整体预测模型^[6]。文献 [7] 分别引入最大互信息系数法 (MIC, mutual information coefficient) 和灰狼算法 (GWO, grey wolf algorithm) 对长短期记忆 (LSTM, long short-term memory) 神经网络模型进行优化,可有效提升风电功率预测精度。文献 [8] 提出了一种基于误差倒数加权法的混合模型,该模型将长短期记忆网络 (LSTM) 与 XGboost 两种算法的预测结果进行融合。结果表明,该组合模型虽然在一定程度上提高了预测精度,但其在模型参数优化方面仍存在改进空间。文献 [9] 提出了一种结合风速误差校正与 ALO 优化 LSSVM 的混合预测模型,有效提升了风电场多位置风电功率预测精度。文献 [10] 采用黏菌算法对 LSSVM 的惩罚参数和核参数进行优化,有效提升了模型的预测性能。与文献 [9] 类似,该研究也引入智能优化算法,有效解决最小二乘支持向量机 (LSSVM, least squares support vector machines) 在参数选取过程中所面临的关键难题。文献 [11] 改提出了一种改进的蜣螂优化算法,通过引入动态权重系数并融合黄金正弦算法,对 DABiLSTM 模型进行优化,从而显著提升了其预测精度。上述 2 篇文献均借助优化算法有效解决了模型参数选择的问题。基于此,本文提出一种改进灰狼优化算法 (IGWO),通过透镜成像反向学习策略初始化种群,引入非线性收敛因子,并结合柯西变异算法优化种群中个体位置的更新机制。该算法用于优化双向长短期记忆神经网络 (BiLSTM) 的超参数选择,不仅能够更高效的确定模型参数,还可有效缓解梯度爆炸与梯度消失等问题。

同时,由于风速本身具有显著的随机性和强波动特性,若直接采用原始序列进行模型训练与预测,往往难以充分捕捉其深层变化规律和有效信息,导致特征提取不充分、进而制约模型预测精度的提升^[12]。因此,在现有的多数组合预测模型中,常借助数据分解技术对原始序列进行预处理,以降低非平稳性并增强规律性表征。常用方法包括小波分解^[13]、变分模态分解以及经验模态分解等方法。文献 [14-16] 在构建组合预测时,引入了经验模态分解 (EMD) 方法,对原始序列进行自适应频域分解,有效缓解了因其非平稳性和强波动性所带来的建模困难。文献 [17] 提出了一种基于

CEEMDAN-WPE-CLSA 的超短期风电功率预测方法,显著改善了传统 EMD 在分解过程中存在的模态混叠和端点效应问题。然而该方法在实际应用中仍面临残留噪声干扰和伪模态分量等局限性。文献 [18] 提出了一种 EVMD-fRCN 的预测模型,该模型首先利用优化变分模态分解算法将非平稳时间序列自适应地分解为多个相对平稳且独立的模态分量,以降低序列复杂性和噪声干扰。随后,针对每个模态分量的特性,采用改进的循环神经网络 (fRCN) 分别进行精准预测,充分挖掘局部时序依赖关系。最终,通过加权集成策略融合所有分量的预测结果,得到更为准确和稳定的最终输出。在上述研究基础上,本文对 CEEMDAN 方法进行改进,提出了 ICEEMDAN 算法。该方法能够有效缓解模态混叠现象,显著降低本征模态函数 (IMF) 中的残余噪声,并可在较少的迭代次数下获得较为精确的分解结果。为进一步降低计算复杂度,引入变分模态分解 (VMD),该方法兼具优异的非平稳信号与噪声处理能力,有助于进一步提高预测精度^[19]。

综上所述,本文提出一种基于 ICEEMDAN-VMD-IGWO-BiLSTM 的短期风电功率预测方法。首先,针对风电功率时间序列一次分解后高频分量仍具强非平稳性的问题,利用样本熵 (SE) 量化各子分量的复杂度,对复杂度较高的子分量进一步采用变分模态分解进行二次分解;随后,通过改进的灰狼算法 (IGWO) 优化双向长短期记忆神经网络 (BiLSTM) 对各分量进行预测,并整合得到最终结果;最后,通过仿真实验验证了所提方法的有效性。

1 分解方法原理

1.1 ICEEMDAN 的风电功率序列分解

ICEEMDAN 是一种改进自适应噪声完备集合经验模态分解方法^[20],该方法是通过引入白噪声经 EMD 分解后得到的模态分量,自适应调节辅助噪声,并通过降低 IMF 中的噪声残留,显著提高风电功率的预测精度。具体步骤如下:

1) 定义 x 为未经处理的风电功率时间序列,向其中注入特殊噪声 $E_k(\omega^{(i)})$,如式 (1) 所示:

$$x^{(i)} = x + \beta_i E_k(\omega^{(i)}) \quad (1)$$

式中, β_i 为首次分解迭代时期望信噪比; $E_k(\cdot)$ 表示通过改进自适应噪声所得到的第 k 阶模态分量。

2) 在初次分解过程中,计算得到残差 r_1 ,并通过原始风电功率序列 x 减去该残差,提取出模态分量 d_1 ,如式 (2) ~ (3) 所示:

$$r_1 = \frac{1}{I} \sum_{i=1}^I M[x + \beta_i E_k(\omega^{(i)})] \quad (2)$$

$$d_1 = x - r_1 \quad (3)$$

式中, $M(\cdot)$ 为产生信号局部均值的操作符。

3) 继续引入白噪声, 计算第2个残差 r_2 , 并据此提取原始风电功率序列的二阶模态分量 d_2 , 如式(4)~(5)所示:

$$r_2 = \frac{1}{I} \sum_{i=1}^I M[r_1 + \beta_2 E_2(\omega^{(i)})] \quad (4)$$

$$d_2 = r_1 - r_2 \quad (5)$$

4) 重复步骤3的过程, 继续计算后续残差并提取相应的高阶模态分量, 如式(6)~(7)所示:

$$r_k = \frac{1}{I} \sum_{i=1}^I M[r_{k-1} + \beta_k E_k(\omega^{(i)})] \quad (6)$$

$$d_k = r_{k-1} - r_k \quad (7)$$

5) 重复执行步骤4, 直至达到最大迭代次数或残差不再具备可分解性。

1.2 SE方法的原理

SE是一种度量时间序列复杂性的量化手段, SE的核心优势在于它能够以更低的值反映出时间序列更高的自我相似性、从而揭示出序列的简单规律性, 与近似熵对比, SE的优势在于它不受数据长度的限值, 使得分析不同长度的时间序列提供一致和可靠的度量结果。SE的计算公式如式(8):

$$\text{sampen}(m, r, N) = \text{Ln} \left[\frac{B^{m+1}(r)}{B^m(r)} \right] \quad (8)$$

式中, $\text{sampen}(\cdot)$ 为SE计算函数; N 为模态分量的长度。

1.3 基于VMD的高频强非平稳分量的二次分解

变分模态分解(VMD, variational mode decomposition)能够将复杂信号自适应地分解为若干个具有特定中心频率和有限带宽的模态分量, 成为本征模态函数(IMF, intrinsic mode functions)。VMD基于变分贝叶斯推断构建变分模型, 并采用交替方向乘子法进行优化求解。VMD变分模型的构建过程如下:

1) 1) 在变分模态分解(VMD)过程中, 通过构建并求解变分问题, 将原始信号分解为多个子序列, 每个分量均具备有限带宽并围绕特定中心频率波动。分解的核心目标是在满足一定约束条件下, 最小化所有模态分量估计带宽的总和, 该约束条件如式(9)所示:

$$\begin{cases} \min_{(\mu_k), (\omega_k)} \left\{ \sum_{k=1}^K \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * \mu_k(t) \right] e^{j\omega_k t} \right\|_2^2 \right\} \\ \text{s.t.} \sum_{k=1}^K \mu_k = f(t) \end{cases} \quad (9)$$

式中, K 为分解的模态数; $\mu_k(t)$ 为第 k 个模态分量 t 时刻的值; $\|\cdot\|_2^2$ 为二范数的平方;

2) 为将约束优化问题转化为无约束形式, 引入二次惩罚项和拉格朗日乘子 λ , 构造扩展拉格朗日函数, 如式(10)所示:

$$L[(\mu_k), (\omega_k), \lambda] = \alpha \sum_{k=1}^K \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * \mu_k(t) \right] e^{j\omega_k t} \right\|_2^2 +$$

$$\left\| f(t) - \sum_{k=1}^K \mu_k(t) \right\|_2^2 + \left[\lambda, f(t) - \sum_{k=1}^K \mu_k(t) \right] \quad (10)$$

3) 运用交替方向乘子法(ADMM), 并结合Parseval/Plancherel定理及傅里叶变换的等距性质, 可迭代求解出各模态分量及其对应的中心频率, 并同时搜寻拉格朗日函数的鞍点。

2 ICEEMDAN-VMD-IGWO-BiLSTM组合模型

2.1 灰狼算法

灰狼群体内部存在着明确的等级划分, 整个狼群由4种群体的狼构成, 如图1所示。




图1 灰狼等级结构图

图中 α 、 β 、 γ 代表决策狼, ω 代表普通狼。在优化过程中, 适应度最高的3头狼依次为 α 、 β 、 γ , 负责引导不具备独立决策能力的 ω 狼进行搜索。灰狼算法主要包括以下两种行为。

1) 包围:

灰狼算法模拟包围猎物的行为如式(11):

$$\vec{D} = |\vec{C} \vec{X}_p(t) - \vec{X}(t)| \quad (11)$$

式中, $\vec{D}$ 表示个体与猎物间的距离; $\vec{X}_p(t)$ 为 t 时刻猎物的位置; 灰狼在包围过程中以式(12)的方式进行更新:

$$\vec{X}(t+1) = \vec{X}_p(t) - \vec{A} \cdot \vec{D} \quad (12)$$

其中: $\vec{A}$ 、 $\vec{C}$ 为系数矩阵。计算公式如式(13):

$$\begin{cases} \vec{A} = 2a(\vec{r}_1 - 1) \\ \vec{C} = 2\vec{r}_2 \end{cases} \quad (13)$$

$\vec{r}_1$ 、 $\vec{r}_2$ 是 $[0, 1]$ 的随机向量; 参数 a 在迭代的过程中从2线性减少到0, 如式(14):

$$a = 2 - 2 \frac{t}{t_{\max}} \quad (14)$$

2) 狩猎:

灰狼算法通过模拟狼群的捕猎行为, α 狼负责领导, β 和 γ 狼协助, 引导 ω 狼进行搜索和捕获目标。如式(15)~(16)

$$\begin{aligned} \vec{D}_\alpha &= |\vec{C}_\alpha \cdot \vec{X}_\alpha - \vec{X}|, \vec{D}_\beta = |\vec{C}_\beta \cdot \vec{X}_\beta - \vec{X}|, \\ \vec{D}_\gamma &= |\vec{C}_\gamma \cdot \vec{X}_\gamma - \vec{X}| \end{aligned} \quad (15)$$

$$\begin{aligned} \vec{X}_1 &= \vec{X}_\alpha - \vec{A}_\alpha \cdot (\vec{D}_\alpha), \vec{X}_2 = \vec{X}_\beta - \vec{A}_\beta \cdot (\vec{D}_\beta), \\ \vec{X}_3 &= \vec{X}_\gamma - \vec{A}_\gamma \cdot (\vec{D}_\gamma) \end{aligned} \quad (16)$$

式中, $\vec{A}_\alpha$ 和 $\vec{C}_\alpha$ 、 $\vec{A}_\beta$ 和 $\vec{C}_\beta$ 、 $\vec{A}_\gamma$ 和 $\vec{C}_\gamma$ 分别为 α 、 β 、 γ 狼的系数向量。狼群按式 (17) 更新:

$$\vec{X}(t+1) = \frac{\vec{X}_1 + \vec{X}_2 + \vec{X}_3}{3} \quad (17)$$

2.2 灰狼算法改进

灰狼算法作为一种高效的群体智能优化技术, 已被广泛应用于解决复杂的优化问题, 但在实际应用中仍然存在一些问题。

1) 传统灰狼算法种群多样性差, 这是因为随机初始生成初始种群的方式无法保证较好的种群多样性。

2) 传统灰狼算法中参数 a 线性递减方式可能会在搜索初期导致算法过于分散, 减缓算法的收敛速度。同时, 在搜索过程后期, 这种递减方式不足以提供足够的精度来进行精细的局部搜索。

3) 灰狼算法的等级制度可能导致算法过分依赖于决策狼的选择, 增加算法陷入局部最优的风险。

为了解决这些问题, 提出了以下改进策略。

2.2.1 透镜成像反向学习策略初始化种群

在迭代后, 灰狼算法会导致后期种群多样性的减少, 灰狼种群会集中在最优个体的位置附近。因此, 当最优个体落入局部最小值时, 很难跳出局部最小值, 导致算法提前终止, 并导致寻找最优点的准确性下降。为解决这个问题, 本文引入了反向学习策略, 它同时考虑解及其对立面, 并扩大了搜索范围, 通过在搜索空间中进行双向搜索来寻找最优解。将反向学习策略与群体智能算法相结合, 有效地改善了算法的搜索能力。个体 x 根据 o 获得其对应的反向点 x^* , 这可以根据透镜成像原理得到:

$$x^* = (a+b)/2 + (a+b)/2k - x/k \quad (18)$$

式中, a 和 b 为搜索区的上下界, k 是缩放因子, 用于表示物体与像之间的对应关系。将式 (18) 扩展到 d 维优化问题, 并根据透镜成像原理获得反向学习, 在 d 维空间中, 每个维度 d 的反向点 $\dot{x}_j$ 可以通过式 (19) 计算:

$$x_i^{d*} = (a^d + b^d)/2 + (a^d + b^d)/2k - x^d/k \quad (19)$$

因此, 本文使用透镜成像反向学习策略初始化种群, 增强种群的多样性, 并增强算法跳出局部极值最优的概率, 如式 (20):

$$x_i^{d*} = (x_{\min}^d + x_{\max}^d)/2 + (x_{\min}^d + x_{\max}^d)/2k - x_i^d/k \quad (20)$$

式中, $x_{\min}^d$ 和 $x_{\max}^d$ 分别为所有初始解中第 d 维向量的最小值和最大值; x_i^{d*} 为 x_i^d 的透镜成像反向解; 透镜的缩放因子 k 对透镜成像学习性能至关重要。较小的 k 值会产生更广泛的反向解范围, 而较大的 k 值会导致反向解范围较小, 适用于局部精细搜索。为了有效利用灰狼算法的特性, 本文提出了一种随迭代次数变化的调整因子, 如式 (21):

$$k(t) = \left[1 + \left(\frac{t}{T_{\max}} \right)^{1/2} \right]^8 \quad (21)$$

式中, t 为当前迭代次数, $T_{\max}$ 为最大迭代次数解, 随这迭代次数的增加, k 值变大, 导致一个较小范围的反解, 用于透镜成像逆向学习, 在算法的后期迭代中对具位置进行精细搜索。

2.2.2 对参数 a 进行改进

参数 a 直接决定种群在搜索过程中的深度和精度, 为了提高算法的性能, 对灰狼算法进行改进, 调整参数 a 的递减策略, 使得算法在前期递减速度慢, 增强算法的全局探索能力; 后期递减速度快, 提高局部最优解的搜索能力。因此引入一种非线性收敛因子, 能够根据搜索过程的进展自动调整参数 a 的值, 以平衡全局探索于局部搜索的效率, 该收敛因子函数表达式如式 (22):

$$a = 2 - 2 \frac{t^3}{t_{\max}^3} \quad (22)$$

式中, t 为当前迭代次数, $t_{\max}$ 为迭代次数。

改进后的非线性收敛因子、原线性收敛因子和三角函数收敛因子的对比如图 2 所示。




图 2 迭代总次数 50 次时收敛因子对比

2.2.3 融合柯西变异算法

柯西分布在原点处高概率密度和向两侧逐渐减小的密度特征而著称。因此灰狼算法引入柯西变异机制时, 算法能够在当前解的临近区域内产生扰动, 有助于算法探索更广阔的空间。因此, 增加了算法跳出局部最优解并继续向全局最优解探索的可能性, 为了增强这一效果, 本文采用了柯西逆累积分布函数, 充分利用柯西分布在两端的变异特性。柯西分布逆累积分布函数如式 (23) ~ (24):

$$F^{-1}(p, x_0, \gamma) = x_0 + \gamma \cdot \tan \left[\pi \cdot \left(p - \frac{1}{2} \right) \right] \quad (23)$$

$$x(t+1) = x(t) + x(t) \cdot \tan \left[\pi \cdot \left(r - \frac{1}{2} \right) \right] \quad (24)$$

将柯西变异算法与灰狼算法融合, 可以丰富灰狼算法的种群多样性, 增强灰狼算法的寻优空间, 改进流程

如图 3 所示。




图 3 优化灰狼算法流程图

- 1) 定义具有柯西变异寻优特性的灰狼个数为 N_1 , $N_1 \in [1, N]$ 。 N 为灰狼总数, N_1 由优化算法动态确定。
- 2) N_1 只灰狼以柯西变异策略更新其位置, 对应获得 N_1 个具有较高适应度的解; 余下的 $N-N_1$ 只灰狼按照传统的灰狼算法进行位置更新, 得到 $N-N_1$ 个最优解。
- 3) 按照适应度对灰狼群体由小到大进行排序, 识别出表现最佳的 α 、 β 、 γ 狼作为决策引导。
- 4) 根据式 (15) ~ (17) 对灰狼的位置参数进行更新。
- 5) 判断是否已达到迭代的最大次数, 若已达到, 则依据 a 的位置确定最优解。若未达到最大次数, 优化过程重复步骤 1) ~ 4), 以期找到更优解。

2.3 双向长短期记忆神经网络

LSTM 神经网络的优点是保留了传统多层感知器, 并对网络引入自我调节反馈连接, 从而克服传统 RNN 在训练中常见的梯度消失或爆炸问题, 提升模型收敛速率, LSTM 记忆单元模块中含有遗忘门、输入门和输出门, x_t 为 t 时刻的输入向量, 将他们作为记忆单元模块 t 时刻的输入。

虽然 LSTM 解决了 RNN 预测长时间序列的局限性, 但 LSTM 仍采用单向的信息训练, 限值其捕捉时间序列中所有信息的能力, 在风电功率预测中, 同时考虑数据的正向和反向规律, 有助于更准确的预测未来趋势。BiLSTM 的结构包含前向和后向 2 个 LSTM, 分别负责处理时间序列的正向和反向信息, 实现更全面的数

据分析, 如图 4 所示。




图 4 BiLSTM 神经网络的结构图

BiLSTM 通过其独特的设计, 能够同时处理正向和反向的时间序列数据, 同时考虑了输入和输出之间的时间依赖关系, 展示出更高的性能, 神经网络更新如式 (25):

$$\begin{cases} \vec{h}_t = H(W_1 x_t + W_2 \vec{h}_{t-1} + \vec{b}) \\ \overleftarrow{h}_t = H(W_3 x_t + W_5 \overleftarrow{h}_{t+1} + \vec{b}) \\ y_t = W_4 \vec{h}_t + W_6 \overleftarrow{h}_t + b_y \end{cases} \quad (25)$$

式中, $\vec{h}_t$ 、 $\overleftarrow{h}_t$ 分别为隐藏层的前向、反向输出, y_t 为最终输出。

2.4 IGWO 优化 BiLSTM

在 BiLSTM 模型中, 参数配置对网络结构及整体性能具有关键影响, 参数值过大容易导致过拟合, 而过小则可能引起欠拟合, 两者均会降低模型的预测性能。为此, 本文提出采用改进的灰狼优化算法 (IGWO) 对 BiLSTM 模型的参数进行优化, 该算法通过模拟灰狼群体包围与捕猎行为, 搜索最优参数组合, 从而提升 BiLSTM 模型的预测有效性与准确性, IGWO-BiLSTM 流程图如图 5 所示。




图 5 IGWO-BiLSTM 流程

2.5 ICEEMDAN-VMD-IGWO-BiLSTM 模型

相较于 LSTM 模型, BiLSTM 模型考虑了正向和反向输入输出的时间依赖性信息。本文在 BiLSTM 模型基础上引入 ICEEMDAN-VMD, 减少了 BiLSTM 模型的输入维度, 并提升了预测精度, 该预测模型的整体流程如图 6 所示。




图 6 预测模型流程图

1) 将处理后的风电功率数据进行 ICEEMDAN, 分解出 n 个子模态。

2) 应用 SE 计算方法, 对模态的复杂性进行量化分析, 计算每个分量的样本熵。

3) 对具有较高样本熵的样本部分, 采用变分模态分解技术进行进一步的二次分解处理, 将分解得到的各个子分量作为输入, 利用改进后的灰狼算法对双向长短期记忆神经网络模型中进行优化, 以预测风电功率。

4) 所有预测值累加, 以获得风电场在预测期间的总功率预测值。

3 算例分析

数据来源于我国某风电场的实际运行风电功率数据, 为了满足电网在实际工程中对风电功率预测精度的高标准, 对原始数据进行预处理, 将原始数据的采样频率由 5 分钟一次改成 15 分钟一次, 最终获得 5 000 个 15 钟的风电功率数据点, 本文采用四分位四分位法对其中的缺失值、异常值进行处理, 为后续的分析 and 预测模型提供更加精确的支持。

3.1 ICEEMDAN-VMD 分解结果

本文采用 ICEEMDAN 分解方法对 5 000 个时间序列的风电功率数据进行分解, 得到 10 个子分量, 为了直观的展示这些分量的频谱特性, 构建相应的幅频特性图。经过 ICEEMDAN 分解后子分量的频谱分析图如

图 7 所示。




图 7 ICEEMDAN 分解结果图

根据图 7 可以发现, 经过 ICEEMDAN 分解, 能够模态混叠, 但是部分子分量依然比较复杂, 直接预测会产生较大误差, 因此将各个子分量的复杂度用样本熵表示, 如图 8 所示。




图 8 ICEEMDAN 各分量样本熵曲线

观察图 8 中子模态的样本熵, 模态 1~4 的样本熵分别为 0.635 6、0.555 8、0.378 2、0.245 1, 前 4 个子分量具有较高的复杂度。而复杂度高的子分量会降低风电功率预测的准确性。因此, 为了使预测效果更优, 对模态 1~4 进行 VMD 再次分解。将分解后的子模态用样本熵表示, 并和 ICEEMDAN 的子分量样本熵进行

比较,结果如图9所示。




图9 ICEEMDAN-VMD和ICEEMDAN样本熵情况

根据图9可知,经过变分模态分解(VMD)技术进行二次分解,各个子分量的样本熵有所降低,表明VMD二次分解有效的简化了子分量的结构。对比一次分解于二次分解得到的子模态样本熵,这些关键指标的对比如表1所示。

表1 二次分解前后样本熵比较

分解方法	样本熵平均值	样本熵最大值
ICEEMDAN	0.200 1	0.635 6
ICEEMDAN-VMD	0.053 9	0.254 2

根据表1分析,可以观察到ICEEMDAN方法分解得到的模态的样本熵平均值达到0.200 1,最大值高达0.635 6;相比之下,采用变分模态分解(VMD)进一步的二次分解,所得子模态中样本熵平均值显著降低,仅为0.053 9,最大值也降至0.254 2。对比两种方法,表明VMD二次分解在降低样本熵方面的有效性,从而可能提升数据的可预测性。

3.2 ICEEMDAN-VMD-IGWO模型多步预测效果

将全部数据划分为两部分,前3 500个数据点作为训练集,后1 500个数据点作为测试集。通过分析特定时间点的风电功率数据,实现对风电场总输出功率的预测,该总功率有场内所有风力发电机的预测输出累加得到。本文所构建的预测模型为ICEEMDAN-VMD-IGWO混合模型,为验证模型中二次分解策略与改进灰狼优化算法的有效性,将其与ICEEMDAN-GWO和ICEEMDAN-IGWO两种模型进行对比分析,结果如图10所示。

将ICEEMDAN-GWO编号为1、ICEEMDAN-IGWO编号为2、ICEEMDAN-VMD-IGWO编号为3,由图10可知,编号3在预测性能上表现最优。为了更直观的展示这些算法之间的差异,分别对编号1至编号3的模型进行了评价指标的计算,如表2所示。




图10 二次分解与改进算法对风电功率预测的影响

表2 编号1~3风电功率预测准确度评价

编号	MAE/MW	MSE/MW ²	RMSE/MW
1	24.521 2	793.493 8	28.169 0
2	13.048 4	232.627 4	15.252 1
3	4.797 8	30.907 9	5.559 5

通过表2的数据分析,平均绝对值(MAE)、均方差(MSE)、均方根值(RMSE)这3个关键的评价指标,编号2均小于编号1,这表明编号2的预测效果优于编号1,这意味改进灰狼算法可以有效提高风电功率预测的精确度。将编号2和编号3的预测结果进行比较时,编号3的这些评价指标也小于编号2,其中编号3的MAE从13.048 4 MW降低到4.797 8 MW,降低了63.2%,这表明二次分解可以提高预测性能。

3.3 与其他方法进行对比

本文提出的ICEEMDAN-VMD-IGWO模型在风电功率预测的精度上取得了显著提升,为了评估该模型相较于现有技术的表现,选择了CNN-LSTM、CNN-BiLSTM、HO-BiLSTM和IGWO-BiLSTM模型,在一致的实验设置下,对风电功率的预测性能进行了对比分析,实验结果如图11所示。




图11 不同模型风电功率预测对比

观察图 11, 相比于 CNN-LSTM、CNN-BiLSTM 来讲, IGWO-BiLSTM 的预测准确性最高。相关的指标如表 3 所示。由表 3 可知, 本文提出的 IGWO-BiLSTM 模型相较 CNN-LSTM、HO-BiLSTM、CNN-BiLSTM 模型, 其 MAE 分别降低了 81.81%、80.85%、76.76%; MSE 分别降低了 96.99%、96.26%、94.37%; RMSE 分别降低了 82.67%、80.65%、76.29%。可见, IGWO-BiLSTM 模型相较于 CNN-LSTM、HO-BiLSTM、CNN-BiLSTM 组合模型具有更高的精度。同样的, 相较于 IGWO-BiGRU 组合模型, 其 MAE、MSE、RMSE 分别降低了 61.01%、84.63% 以及 60.79%, 因此, 本文提出的 IGWO-BiLSTM 相较于其他模型具有更高的预测精度。

表 3 3 种方法预测准确度指标

方法	MAE/MW	MSE/MW	RMSE/MW
CNN-LSTM	27.035 3	1 077.720 5	32.828 7
HO-BiLSTM	25.691 3	864.626 4	29.404 5
CNN-BiLSTM	21.166 2	575.410 9	23.987 7
IGWO-BiGRU	12.616 2	210.549 2	14.510 3
IGWO-BiLSTM	4.918 9	32.368 3	5.689 3

4 结束语

针对风电功率预测中的波动性和非平稳特性, 以及提升预测精度的要求, 本文将 ICEEMDAN-VMD 组合模态分解与深度学习相结合: 通过二次模态分解和 SE 技术的应用, 对风电功率数据进行预处理, 有效抑制一次分解中高频强非平稳分量对预测结果的干扰, 同时简化了模型结构, 为提高预测的准确性打下了基础; 采用透镜成像反向学习策略初始化灰狼算法种群位置, 引入非线性递减权重机制, 并与柯西变异算法融合以更新 α 、 β 、 γ 三类决策狼的位置, 有效改善了传统 GWO 中种群初始化不均衡及决策狼更新效率低的问题, 进而利用 IGWO 对 BiLSTM 网络进行超参数优化, 以实现更合理的模型配置。本文所提出的 ICEEMDAN-VMD-IGWO-BiLSTM 组合模型, 能够有效应对风电功率数据的复杂波动特性及 BiLSTM 参数设定难题, 相比现有组合模型具有更低的预测误差, 进一步提升了预测精度。

参考文献:

[1] CAO B, CHANG L. Development of short-term wind power forecasting methods [C] //2022 IEEE 7th Southern Power Electronics Conference (SPEC). IEEE, 2022: 1-5.

[2] SUN Y, LI Z, YU X, et al. Research on ultra-short-term wind power prediction considering source relevance [J]. Ieee Access, 2020, 8: 147703-147710.

[3] YU G, SHEN L, DONG Q, et al. Ultra-short-term wind power forecasting techniques: comparative analysis and future trends [J]. Frontiers in Energy Research, 2024,

11: 1345004.

[4] 唐新姿, 顾能伟, 黄轩晴, 等. 风电功率短期预测技术研究进展 [J]. 机械工程学报, 2022, 58 (12): 213-236.

[5] 钱 政, 裴 岩, 曹利霄, 等. 风电功率预测方法综述 [J]. 高电压技术, 2016, 42 (4): 1047-1060.

[6] 王 涵, 白宏坤, 王世谦, 等. 基于组合集成学习模型的区域碳排放预测方法研究 [J]. 电力需求侧管理, 2023, 25 (4): 55-59.

[7] 梁昌侯, 龙 华, 李 帅, 等. 基于 MIC-VMD-GWO-LSTM 的短期风电功率预测 [J]. 现代电子技术, 2023, 46 (22): 115-120.

[8] 王愈轩, 梁沁雯, 章思远, 等. 基于 LSTM-XGboost 组合的超短期风电功率预测方法 [J]. 科学技术与工程, 2022, 22 (14): 5629-5635.

[9] 王 斌, 魏成伟, 谢丽蓉, 等. 基于风速误差校正和 ALO-LSSVM 的风电功率预测 [J]. 太阳能学报, 2022, 43 (1): 58-63.

[10] 席语莲, 凌周玥, 许晓敏. 短期风电功率 CEEMDAN-SMA-LSSVM 预测模型研究 [J]. 科学技术与工程, 2024, 24 (6): 2396-2404.

[11] 卢苡锋, 王 霄. 基于二次分解和 IDBO-DABiLSTM 的短期风电功率预测模型 [J]. 计算机工程, 2024, 50 (12): 99-109.

[12] HANIFI S, CAMMARONO A, ZARE-BEHTASH H. Advanced hyperparameter optimization of deep learning models for wind power prediction [J]. Renewable Energy, 2024, 221: 119700.

[13] 张振中, 郭傅傲, 刘大明, 等. 基于最大互信息系数和小波分解的多模型集成短期负荷预测 [J]. 计算机应用与软件, 2021, 38 (5): 82-87.

[14] 余 周, 姜 涛, 范鹏辉, 等. 基于 EMD-DELM-LSTM 组合模型的湖泊水位多时间尺度预测 [J]. 长江科学院院报, 2024, 41 (6): 28-35.

[15] 侯金霄, 黄林显, 胡晓农, 等. 基于 EMD-LSTM 耦合模型的趵突泉岩溶地下水水位预测应用 [J]. 水资源与水工程学报, 2023, 34 (4): 92-98.

[16] 张雲钦, 程起泽, 蒋文杰, 等. 基于 EMD-PCA-LSTM 的光伏功率预测模型 [J]. 太阳能学报, 2021, 42 (9): 62-69.

[17] 李 杰, 孟凡熙, 牛明博, 等. CEEMDAN-WPE-CLSA 超短期风电功率预测方法研究 [J]. 大连交通大学学报, 2024, 45 (2): 101-108.

[18] WANG Z, WANG L, REVANESH M, et al. Short-term wind speed and power forecasting for smart city power grid with a hybrid machine learning framework [J]. IEEE Internet of Things Journal, 2023.

[19] 王维高, 魏云冰, 滕旭东. 基于 VMD-SSA-LSSVM 的短期风电预测 [J]. 太阳能学报, 2023, 44 (3): 204-211.

[20] 韦 权, 汤占军, 贺建峰. 基于 ICEEMDAN-ICSSA-CK-ELM-TCCA 的短期风电功率预测研究 [J]. 现代电子技术, 2023, 46 (24): 39-46.