

DOI: 10.13382/j.jemi.B2508860

融合 STL-OVMD 与优化 BiGRU-Attention 网络的风速预测

陈晓^{1,2} 刘阳^{1,2}

(1. 南京信息工程大学电子与信息工程学院 南京 210044; 2. 南京晓扬电子科技有限公司 南京 211500)

摘要: 风的随机和非平稳特征对目前风速预测方法的精度产生了制约。为了提高预测的准确性,构建了一个混合深度学习预测模型,融合了季节趋势分解、优化变分模态分解、麻雀搜索算法、时间卷积网络、双向门控循环单元以及注意力机制。方法先利用季节趋势分解对原始风速数据做自适应分解,得到趋势项、季节项以及残差项,再利用优化变分模态分解算法对残差项进行分解,得到若干本征模态函数。其次,针对趋势分量与季节分量,采用双向门控循环单元捕捉长期依赖关系及周期性特征,通过前向与后向门控循环单元的双向信息融合输出全局隐藏状态;引入自注意力机制对各本征模态的局部细节特征进行动态加权,生成关键特征聚焦的上下文向量,抑制冗余信息干扰。接着,针对时间卷积网络与长短期记忆网络关键超参数对模型性能的显著影响,引入麻雀优化算法进行全局优化,解决目前搜索易陷入局部最优、计算效率低的问题。最后依靠整合趋势分量、季节分量与各本征模态的预测结果来输出风速预测值。在实际风电场以小时为间隔的风速数据集上与五种预测方法进行了对比验证实验。结果表明,预测精度与趋势捕捉能力显著优于其他模型,和基准模型相比,均方误差降低 33.5%,均方根误差降低 18.5%,平均绝对误差降低 16.9%,决定系数提升 3.6%,训练时间降低 42.0%,参数量降低 41.0%。提出的混合模型为非平稳风速序列的高精度预测提供了有效方案。

关键词: 风速预测;季节趋势分解;变分模态分解;麻雀优化算法;时间卷积网络;注意力机制

中图分类号: TN98;TP391 **文献标识码:** A **国家标准学科分类代码:** 510.40

Wind prediction integrating STL-OVMD and optimized BiGRU network with attention mechanism

Chen Xiao^{1,2} Liu Yang^{1,2}

(1. School of Electronics and Information Engineering, Nanjing University of Information Science and Technology, Nanjing 210044, China; 2. Nanjing Xiaoyang Electronic Science and Technology Co., Ltd., Nanjing 211500, China)

Abstract: Wind speed sequence itself has randomness and non-stationary characteristics, which constrain the accuracy of traditional prediction methods. A hybrid prediction framework was constructed for this purpose, which integrates seasonal trend decomposition, optimized variational mode decomposition, sparrow search algorithm, bidirectional gated recurrent unit, and attention mechanism. This method first uses seasonal and trend decomposition (STL) to adaptively decompose the original wind speed data, obtaining trend terms, seasonal terms, and residual terms. Then, the optimized variational mode decomposition (OVMD) algorithm is used to perform secondary decomposition on the residual terms, obtaining several intrinsic mode functions, effectively reducing signal complexity and mode aliasing phenomena. Secondly, for the trend and seasonal components, a bidirectional gated recurrent unit (BiGRU) is used to capture long-term dependencies and periodic features, and the global hidden state is output through bidirectional information fusion of forward and backward GRUs; Introducing self-attention mechanism to dynamically weight the local detail features of each intrinsic mode function (IMF) component, generate context vectors focused on key features, and suppress redundant information interference. Next, in response to the significant impact of BiGRU key hyper parameters on model performance, the SSA algorithm is introduced for global optimization to solve the problems of traditional grid search being prone to local optima and low computational efficiency. Finally, the final wind speed prediction value is output by integrating the trend component, seasonal component, and the predicted results of each IMF component. Taking the short-term wind speed dataset of actual wind farms as the research object, the results were compared and

verified with five benchmark models. The results showed that the prediction accuracy and trend capture ability were significantly better than other models. Compared with the basis benchmark model, the MSE decreased by 33.5%, RMSE decreased by 18.5%, MAE decreased by 16.9%, and R^2 increased by 3.6%, training time decreased by 42.0%, and parameter number decreased by 41.0%, providing an effective solution for high-precision prediction of non-stationary wind speed sequences.

Keywords: wind prediction; seasonal and trend decomposition; variational mode decomposition; sparrow optimization algorithm; bi-directional gated recurrent unit; attention mechanism

0 引言

风能作为可再生能源领域中极具发展前景的能源形式之一,其高效利用对实现“双碳”战略目标意义重大。风速存在随机性特征、非平稳特性及多尺度特性^[1-3],导致输出风电功率波动。当风速预测精度每降低 1%,电网频率调节成本会增加 2.3%^[2]。高精度的风速预测是提升风电并网消纳水平、保障电力系统安全运行急需解决的核心技术问题。

在风速预测领域,已有的研究方法可分成物理建模方法、统计分析模型及用机器学习而产生的智能预测方法。物理模型方法可达成气象参数的模拟运算,但计算复杂度高,致使系统实时性能难以契合实际应用的需求。统计建模方法一般是基于数据平稳性这一假设,存在着一定的局限性^[4]。而像支持向量机等传统机器学习方法^[5-6],尽管有非线性建模的能力,但在实际运用当中会遭遇一些固有的局限,如梯度消失现象^[7-8],且长期依赖关系的捕捉效果不理想^[9-10]。

深度学习^[11-12]和信号处理方法^[13-15]的交叉融合为风速预测领域开拓了新途径^[16]。对时间序列分析,季节趋势分解(seasonal and trend decomposition, STL),可有效提升复杂的风速时间序列中趋势、季节成分及残差提取的准确性与鲁棒性^[17]。在非平稳信号处理方面,变分模式分解(variational mode decomposition, VMD)凭借其基于变分优化框架的自适应分解特性,有效提高复杂风速信号的分解精度与信噪比^[18-19]。长短期记忆(long short-term memory, LSTM)网络解决了循环神经网络(recurrent neural network, RNN)风速预测时的人为延长时间任务的问题^[20]。在如何解决传统循环神经网络梯度消失和 LSTM^[21-23]结构复杂及单向网络局限的研究中,双向门控循环单元(bi-directional gated recurrent unit, BiGRU)网络依靠其独特的双向门控融合机制,在复杂序列预测任务里呈现出了较为出色的性能^[24]。时间卷积网络(temporal convolutional network, TCN)通过卷积操作捕捉风速数据中的长期依赖关系^[25]。Transformer 网络^[26]使用注意力机制(Attention)来处理风速序列和输出序列,可以并行计算。Feng 等^[27]将 TCN-BiLSTM-Attention 模型应用于短期风速预测。He 等^[28]运用 Transformer-BiLSTM 模型,来纠正极值预测时的滞后效

应。Wang 等^[29]使用 Transformer-BiGRU 模型校正风速预测结果的误差。

然而目前的研究依旧存在 3 个急需解决的问题。

目前风速信号建模在多尺度特征融合方面存在局限性。单一分解方法难以同时兼顾趋势提取与细节保留,导致高频噪声与低频趋势分量相互干扰,影响后续特征建模的准确性。现有的研究大多采用“一步分解”策略,未能通过层级分解实现信号的精细化表征^[30]。

此外,在 BiGRU 网络中,隐含层单元数、网络堆叠层数以及门控机制的更新参数这类深度学习超参数的设定,会对模型预测精度产生影响。而基于网格搜索或随机采样的参数优化策略,计算资源消耗大,且有收敛于局部最优解的概率^[31]。

注意力机制存在着固有的局限性以及特征冗余方面的问题。自 Transformer 提出并引入多头自注意力机制以来,在长序列建模任务里,传统的注意力机制大多时候不能有效地捕捉到局部的细节特征,使得关键信息的权重分配出现失衡的状况,这对模型性能产生了影响^[32]。

为了攻克上述技术难题,本研究提出了一种融合 STL 和优化变分模式分解(optimized variational mode decomposition, OVMD)二次分解、麻雀搜索算法(sparrow search algorithm, SSA)以及 BiGRU-Attention 混合预测模型。此模型先是运用 STL 将原始风速信号分离为趋势项、季节项与残差项,再通过 OVMD 对残差项进行二次分解,得到具有不同频率特性的本征模式函数(intrinsic mode function, IMF)^[33-35]。然后 BiGRU 网络捕捉各分量的时序依赖关系,并通过改进的自注意力机制动态加权多尺度特征^[36],抑制噪声干扰;最后运用 SSA 算法对 BiGRU 的隐含层维度、学习率及 Attention 头数等关键参数进行全局寻优^[37-38],以此提升模型的预测精度与泛化性能。

1 STL-OVMD 分解

1.1 STL

STL 是一种用于非平稳时间序列分解的自适应信号处理方法,通过局部加权回归平滑实现时间序列的多尺度分解,将原始信号自适应分离为趋势分量、季节分量和残差分量 3 部分,数学模型如下:

$$s(t) = T(t) + S(t) + R(t) \quad (1)$$

式中: $s(t)$ 为原始风速信号; $T(t)$ 为反映长期变化规律的趋势分量; $S(t)$ 为周期性波动的季节分量; $R(t)$ 为包含随机噪声的残差分量。

首先通过预设周期参数构造时序分解框架:

$$P = \text{round}(f_s \cdot T_{\text{season}}) \quad (2)$$

式中: P 为季节周期长度; f_s 为采样频率; T_{season} 为季节波动周期; $\text{round}(\cdot)$ 为取整函数。

随后对原始信号进行去趋势处理,提取季节分量:

$$S(t) = \text{Loess}[s(t) - T_{\text{init}}(t), \alpha_{\text{season}}] \quad (3)$$

式中: $T_{\text{init}}(t)$ 为初始趋势估计(采用移动平均法); $\alpha_{\text{season}} \in [0.5, 0.8]$ 为季节平滑窗口宽度,控制周期特征的提取精度; $\text{Loess}[\cdot]$ 为局部加权回归平滑函数。

接着更新趋势分量,采用 Loess 对去季节序列进行二次平滑:

$$T(t) = \text{Loess}(s(t) - S(t), \alpha_{\text{trend}}) \quad (4)$$

式中: $\alpha_{\text{trend}} \in [0.1, 0.3]$ 为趋势平滑窗口宽度,取值小于季节窗口以保留长期趋势特性。

最后计算残差分量并执行鲁棒性优化:

$$R(t) = s(t) - T(t) - S(t) \quad (5)$$

通过权重函数 $w(t)$ 动态调整异常值权重,迭代优化趋势与季节分量直至收敛,计算公式为:

$$w(t) = (1 - (R(t)/6\sigma)^2)^2, \quad |R(t)| < 6\sigma \quad (6)$$

式中: $w(t)$ 为异常值权重函数(动态降低异常值对分解的影响); σ 为残差序列标准差。

1.2 OVMD

OVMD 是在 VMD 基础上提出的自适应信号分解算法,其核心改进在于通过参数自适应优化与模态数智能确定策略,解决 VMD 中需人工预设模态数 K 和惩罚因子 α 导致的过分解或欠分解问题。

首先,基于能量熵准则实现模态数的自适应选择,确定最优模态数 K_{opt} 。

初始化模态数搜索范围为 $K=2, 3, \dots, 10$, 对 STL 分解后的残差信号 $R(t)$ 执行初步 VMD 分解(预设惩罚因子 $\alpha=2000$), 计算各 K 值下的能量熵 $H(K)$, 计算公式为:

$$H(K) = - \sum_{k=1}^K p_k \lg p_k, p_k = \frac{\int |u_k(t)|^2 dt}{\int |R(t)|^2 dt} \quad (7)$$

式中: $u_k(t)$ 为第 k 个模态分量; p_k 为第 k 个模态的能量占比。选取能量熵最小值对应的 K 作为最优模态数 $K_{\text{opt}} = \arg\min_K H(K)$, 通常风速序列分解中 $K_{\text{opt}} \in [3, 7]$ 。

然后,采用粒子群优化算法动态调整惩罚因子 α , 平衡模态带宽与噪声抑制能力,优化惩罚因子 α_{opt} 。

以 K_{opt} 为固定参数,设置 α 的搜索空间为 $[100,$

$5000]$, 种群规模 = 20, 迭代次数 = 30; 定义适应度函数 $\text{Fitness}(\alpha)$ 为模态包络熵的均值, 公式为:

$$\text{Fitness}(\alpha) = \frac{1}{K_{\text{opt}}} \sum_{k=1}^{K_{\text{opt}}} \text{EnvEntropy}(u_k) \quad (8)$$

式中: $\text{EnvEntropy}(u_k)$ 为第 k 个模态的希尔伯特包络熵, 通过粒子群优化迭代寻优, 输出最小适应度对应的 α_{opt} 。

接着,基于交替方向乘子法求解变分优化模型,执行变分迭代分解。

初始化模态分量 $\{u_k^0(t)\}$ 、中心频率 $\{\omega_k^0\}$ 及拉格朗日乘数 $\lambda^0(t)$, 迭代更新模态分量的频谱 u_k , 公式为:

$$\hat{u}_k^{n+1}(\omega) = \frac{\hat{R}(\omega) - \sum_{i \neq k} i \hat{u}_i^n(\omega) + \hat{\lambda}^n(\omega)/2}{1 + 2\alpha_{\text{opt}}(\omega - \omega_k^n)^2}, \quad (9)$$

式中: $\lambda^n(\omega)$ 为拉格朗日乘数的傅里叶变换。更新中心频率 ω , 公式为:

$$\omega_k^{n+1} = \frac{\int_0^\infty \omega |\hat{u}_k^{n+1}(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k^{n+1}(\omega)|^2 d\omega} \quad (10)$$

计算迭代收敛误差 err , 公式为:

$$\text{err} = \sum_{k=1}^{K_{\text{opt}}} |u_k^{n+1} - u_k^n|_2^2 / \|u_k^n\|_2^2 \quad (11)$$

当 $\text{err} < 10^{-7}$ 时终止迭代, 输出 K_{opt} 个平稳模态分量 $\{u_1(t), u_2(t), \dots, u_{K_{\text{opt}}}(t)\}$ 。

1.3 STL-OVMD

将 STL 分解得到的趋势分量、季节分量与 OVMD 分解得到的 K_{opt} 个模态分量整合, 原始风速信号 $s(t)$ 的最终分解形式为:

$$s(t) = T(t) + S(t) + \sum_{k=1}^{K_{\text{opt}}} u_k(t) \quad (12)$$

式中: $u_k(t)$ 为 OVMD 分解的第 k 个 IMF 分量。具体 STL-OVMD 二次分解过程如图 1 所示。

2 SSA 优化的 BiGRU-Attention

2.1 BiGRU

为捕捉风速序列低频分量中的长期依赖关系与全局趋势特征, 本研究引入 BiGRU。该模型通过融合前向与后向 GRU 网络的时序信息流, 在简化门控机制的同时保留对长序列的建模能力, 有效平衡计算效率与特征表征精度。

BiGRU 包含前向与后向 2 个独立的 GRU 分支。

1) 前向 GRU 从时刻 $t = 1$ 到 $t = T$ 逐次计算隐藏状态 h_t , 其数学表达为:

$$\vec{h}_t = GRU(x_t, \vec{h}_{t-1}) \quad (13)$$

式中: x_t 为 t 时刻的输入特征; $\vec{h}_{t-1}$ 为前向 GRU 在 $t-1$ 时刻的隐藏状态。

该过程通过记忆单元保留历史信息,建模输入序列的正向时序依赖。

2) 后向 GRU 则反向从 $t = T$ 到 $t = 1$ 计算隐藏状态

$$\overleftarrow{h}_t = GRU(x_t, \overleftarrow{h}_{t+1}) \quad (14)$$

式中: $\overleftarrow{h}_{t+1}$ 为后向 GRU 在 $t+1$ 时刻的隐藏状态。

该分支逆向捕捉未来时刻对当前状态的潜在影响,增强对周期性模式的敏感性。




图1 STL-OVMD 分解

Fig. 1 STL-OVMD decomposition

在双向特征融合阶段,将前向与后向的隐藏状态沿特征维度拼接,形成全局特征矩阵 $H_{GRU} \in R^{T \times 2m}$:

$$H_{GRU} = [\vec{h}_t \oplus \overleftarrow{h}_t] \Big|_{t=1}^T \quad (15)$$

式中: H_{GRU} 为 BiGRU 的输出特征矩阵,维度为 $T \times 2m$ (T 为序列长度, m 为单向 BiGRU 隐藏层维度); $\oplus$ 表示特征拼接操作,通过融合双向时序信息实现对风速低频分量的全局表征。

在本研究构建的 BiGRU 结构中,通过特征拼接操作实现前向与后向信息的互补。具体而言,经 STL-VMD 分解得到的低频趋势分量作为网络输入,通过 BiGRU 的双向门控机制进行深层特征提取,最终输出包含长期趋势特性的全局表征 H_{BiGRU} 。

该架构通过整合正反向时序上下文,使模型对风速数据中的季节性波动(如昼夜周期、周周期)和长期趋势变化具有更强的捕捉能力,尤其在风速突变点的预测上误差更低。与传统单向 GRU 相比,BiGRU 的双向信息融合机制,可提升特征表征的完整性,为后续注意力机制的权重分配提供更丰富的时序特征基础。

2.2 Attention 机制

为增强 BiGRU 网络对 STL-VMD 二次分解后多尺度特征的动态捕捉能力,本研究设计掩码多头自注意力机制,通过自适应权重分配抑制冗余分量干扰,实现多尺度特征的高效融合。

首先,BiGRU 网络对 STL-VMD 分解后的各分量特征进行学习后,输出双向隐藏状态序列 $H_{BiGRU} \in R^{T \times 2m}$ 。自注意力机制以 H_{BiGRU} 为输入,通过线性变换生成查询(Q)、键(K)、值(V)矩阵:

$$\begin{aligned} Q &= H_{BiGRU} \cdot W_Q \\ K &= H_{BiGRU} \cdot W_K \\ V &= H_{BiGRU} \cdot W_V \end{aligned} \quad (16)$$

式中: $W_Q, W_K, W_V \in R^{2m \times d_k}$ 为可训练权重矩阵, d_k 为注意力维度(与 BiGRU 隐藏层维度一致)。

随后,为衡量不同时间步特征的相关性,采用加性注意力机制计算权重,具体通过线性层与非线性激活实现特征交互。

1) 能量值计算

将 BiGRU 隐藏状态与扩展后的上下文向量拼接,经线性变换与 $\tanh$ 激活生成注意力能量:

$$e_t = \tanh(W_{attn} \cdot [h_t \oplus c]) \quad (17)$$

式中: W_{attn} 为注意力机制中线性变换的权重矩阵; c 为上下文向量。

2) 权重归一化

通过 Softmax 函数将能量值转化为归一化权重,突出关键时间步贡献:

$$\alpha_t = \frac{\exp(e_t)}{\sum_{t=1}^T \exp(e_t)} \quad (18)$$

式中: α_t 为归一化后的注意力权重; e_t 为注意力能量值; l 为序列长度。

3) 上下文向量更新

加权求和 BiGRU 隐藏状态,生成融合注意力的上下文向量:

$$c = \sum_{i=1}^T \alpha_i \cdot h_i \quad (19)$$

2.3 SSA

SSA 是一种基于麻雀群体觅食行为的启发式优化算法,通过模拟麻雀种群中“发现者-跟随者”协作机制与警戒行为,有效平衡全局探索与局部开发能力。

此算法主要由 3 个关键机制组成:1) 发现者负责全局探索功能,借助引导种群朝着高适应度区域迁移,达成解空间的宏观优化;2) 跟随者执行局部开发任务,在发现者所处区域周边开展精细化搜索,以此提高当前最优解的精度;3) 警戒行为机制引入随机跳跃策略,能有效防止算法陷入局部最优状态,提高全局搜索的鲁棒性与收敛性能。

在初始化阶段,先确定种群规模参数 N ,接着生成由 N 个个体所构成的初始麻雀种群,个体 x_p 的位置向量可表示成 $x_p = [x_{p1}, x_{p2}, \dots, x_{pD}]$,该向量的维度 D 与待优化问题的参数空间维度相对应。过程中,个体位置的初始化更新依据特定的数学表达式进行:

$$x_{pj}^{\tau+1} = \begin{cases} x_{pj}^{\tau} \cdot \exp\left(-\frac{P}{\eta T_{max}}\right), & R2 < ST \\ x_{pj}^{\tau} + Z \cdot L, & \text{其他} \end{cases} \quad (20)$$

式中: $x_{pj}^{\tau+1}$ 为第 τ 代种群中第 p 个个体的第 j 维位置; T_{max} 为最大迭代次数; η 为控制参数,调节指数衰减速率; $R2$ 为随机数 ($R2 \in [0, 1]$),用于判断是否触发探索行为; ST 为安全阈值 ($ST \in [0.5, 1]$),当 $R2 < ST$ 时执行全局探索; Z 为服从正态分布的随机数 ($Z \sim N(0, 1)$); L 为维度为 D 的单位行向量 (D 为待优化参数维度)。

发现者位置更新公式:

$$x_{pj}^{\tau+1} = x_{pj}^{\tau} + \delta \cdot |x_{pj}^{\tau} - x_{worst}^{\tau}| \cdot rand(0, 1) \quad (21)$$

式中: δ 为步长调整系数; x_{worst}^{τ} 表示当前最差解位置,通过全局对比驱动种群向更优区域迁移; $rand(0, 1)$ 为 0~1 均匀分布随机数。

跟随者位置更新阶段,基于当前最优解 x_{best}^{τ} 执行局部搜索,更新公式为:

$$x_{pj}^{\tau+1} = x_{best}^{\tau} + \theta \cdot |x_{pj}^{\tau} - x_{best}^{\tau}| \cdot randn(0, 1) \quad (22)$$

式中: θ 为局部搜索系数 (通常取 1),通过随机扰动细化解空间。

警戒行为则针对适应度长期未改善的个体,触发随机跳跃机制:

$$x_{pj}^{\tau+1} = x_{pj}^{\tau} + \mu \cdot (x_{best}^{\tau} - x_{pj}^{\tau}) \cdot rand(0, 1) \quad (23)$$

式中: μ 为跳跃强度系数,控制随机扰动幅度,以此突破局部最优限制; x_{best}^{τ} 为第 i 个个体的历史最优位置。

算法的适应度函数以预测误差为优化目标,以此提

高预测的精度。定义如下:

$$Fitness = \frac{1}{V} \sum_{i=1}^E (y_i - \hat{y}_i)^2 \quad (24)$$

在对风速预测模型展开优化工作的进程里, V 表示样本总量, E 为参与误差计算的样本数, y_i 以及 $\hat{y}_i$ 分别对应实际观测值与模型预测值。

SSA 的核心优势在于其独特的分工协作机制,即发现者承担全局搜索的任务,而跟随者着重于局部开发,再配合自适应警戒策略所产生的协同作用,提升了算法处理复杂非线性优化问题的能力,特别适用于风电功率预测领域中常见的多峰特性优化场景。

2.4 SSA-BiGRU-Attention 模型

SSA-BiGRU-Attention 模型是一种多创新的联合参数优化框架,运用多目标优化策略来构建帕累托前沿解集,以此在模型预测精度跟计算资源消耗之间达成动态权衡。并且运用二维实数向量来开展模型参数的编码设计工作。展开来说, BiGRU 模块的关键超参数,比如隐藏层神经元数、模型层数,都采用连续数值编码方式。

考虑到预测准确性、计算效率以及模型复杂度等多目标优化需求,本研究运用加权融合策略,对均方根误差指标、模型训练所需时间以及参数规模正则项展开综合评估,设计加权的多目标适应度函数:

$$Fitness = \alpha \cdot RMSE + \beta \cdot TrainingTime + \gamma \cdot Params \quad (25)$$

式中: α, β, γ 为权重系数,平衡预测精度、计算效率和模型复杂度; $RMSE$ 为均方根误差 (预测精度指标); $TrainingTime$ 为模型训练时间 (计算效率指标); $Params$ 为模型参数总量 (复杂度指标)。此方案有效抑制了模型过拟合现象,达成了资源的最优配置。

本研究设计了一种基于迭代进程的自适应优化策略,目的在于提高参数寻优过程的效率,在全局搜索阶段,运用动态调整的高斯变异算子来维持解群体的多样性水平:

$$\begin{aligned} x_1 &= x_j \cdot (1 + N(0, \sigma^2)) \\ \sigma &= 0.1 \cdot (1 - t/T_{max}) \end{aligned} \quad (26)$$

式中: x_j 为父代个体位置; $N(0, \sigma^2)$ 为服从均值 0、方差 σ^2 的正态分布随机数; σ 为变异强度 (随迭代次数 t 从 0.1 线性衰减至 0),确保前期探索、后期收敛。

局部开发阶段引入 Levy 飞行策略:

$$x_{pj}^{\tau+1} = x_{best}^{\tau} + Levy(\lambda) \cdot |x_{pj}^{\tau} - x_{best}^{\tau}|, \quad (27)$$

式中: $Levy(\lambda)$ 为服从 Levy 稳定分布的随机数 ($\lambda = 1.5$),其特点是“短步长局部搜索+长步长全局探索”,增强算法对局部最优解的跳出能力,提升参数寻优精度。

此外,运用重尾分布的概率特性展开探索,突破传统参数组合约束,借助随机步长策略提高搜索精度,检测到

种群个体相似度超预设阈值时,系统自动激活警戒机制,对种群 20% 个体进行位置重置操作,保障种群进化多样性。

本文提出的 3 阶段协同机制在 6 维参数空间里达成了对帕累托前沿的高效逼近,此机制的创新之处在于,可依据不同应用场景,在模型预测精度以及部署成本之间达成最优权衡,提供多种模型配置解决方案。模型建立过程如图 2 所示。




图 2 SSA-BiGRU-Attention 模型
Fig. 2 SSA-BiGRU-Attention model

3 风速预测模型

本研究的风速预测方法先用 STL-OVMD 结合分解策略处理原始风速时序数据,通过 STL 算法将风速序列初步分解为趋势分量、季节分量与残差分量,实现非平稳信号的结构化拆分;针对 STL 分解后含高频噪声的残差分量,进一步采用 OVMD 进行自适应分解,得到一系列具有不同中心频率的本征模态函数分量。二次分解机制通过“宏观趋势-微观波动”的层级化处理,有效减轻传统单一分解方法的模态混叠现象,为后续特征提取提供更纯净的多尺度输入。

为精准捕捉分解后各分量的时序动态特性,用 BiGRU 构建基础特征提取网络。通过前向与后向 GRU 的并行计算,将各本征模态的历史依赖与未来趋势信息

进行双向融合;通过简化门控结构,在保留长期依赖捕捉能力的同时,降低了模型参数量与计算复杂度,克服了单一方向循环网络无法利用未来信息的局限。

针对多分量特征的有效融合问题,引入自注意力机制构建动态加权融合模块。基于提供的 Attention 类实现,该机制以 BiGRU 输出的隐藏状态为输入,通过计算各时刻特征的能量权重,经归一化后生成上下文向量,实现关键特征的自适应聚焦。此过程通过特征权重的动态分配,抑制冗余分量对模型的干扰,提升对风速突变点的敏感度。

然后用 SSA 来全局优化双向门控循环单元的隐含层数和神经元数量等关键超参数,以此提升模型性能,此智能优化算法依据麻雀种群的觅食与警戒行为机制,可在高维参数空间里进行高效搜索,提高了模型的预测精度,还提高了其泛化能力。

此风速预测系统借助 STL-OVMD 分解以及特征融合的协同工作机制,融合动态权重分配与 SSA 参数优化,搭建起一个有全频段特征表征与自适应参数调节能力的集成化预测框架。预测模型流程如图 3 所示。




图 3 STL-OVMD-SSA-BiGRU-Attention 模型
Fig. 3 STL-OVMD-SSA-BiGRU-Attention model

4 实验

STL-OVMD-SSA-BiGRU-Attention 网络模型基于 PyTorch1. 11. 0 版本深度学习框架进行了搭建,硬件操作系统使 NVIDIA RTX 3050 显卡,CUDA 版本为 11. 6。

数据集与预处理流程基于公开气象数据构建非平稳风速预测任务的特征工程。实验数据选用 kaggle 平台公开的气象历史数据集-Weather in Szeged。该地区为温带大陆性气候,地形平坦,气象条件具有显著的季节性交替特征和非平稳性特征。该数据集可从 Kaggle 平台公开获取。

选取 2012 年 4 月 7 日至 2014 年 4 月 2 日期间的地面观测数据,涵盖了完整的季节循环。数据记录间隔为 1 h,总计包含 17 420 条有效样本。输入特征包括温度、

湿度、气压、能见度等 6 维气象参数。通过 STL 分解和 OVMD 分解,风速被进一步扩展为包含趋势项、季节项和本征模态函数的 12 维特征向量。

选取后 17 420 条样本数据开展实验设计,依照 9 : 1 把数据集划分成训练集以及测试集。为契合监督学习任务的要求,借助设置窗口长度为 12 的滑动窗口策略对时序数据给予重构,此方法借助历史 12 个时间步的特征数据来预测未来单步的风速值。总风速数据序列(共 17 420 条)如图 4 所示,对该风速数据序列进行 STL 分解,分解结果如图 5 所示,对残差分量进行 OVMD 分解,分解结果如图 6 所示。




图 4 风速数据
Fig. 4 Wind speed data




图 5 风速序列 STL 分解结果
Fig. 5 Wind speed series decomposition result with STL

运用 StandardScaler 方法,针对输入特征以及标签数据开展 Z-score 标准化处理工作,来消除不同特征之间存在的量纲差异问题。借助 joblib 工具对归一化参数实施持久化存储操作,以此保证模型训练阶段跟推理阶段的数据预处理过程有一致性。

模型配置与训练参数通过多阶段优化策略确定。SSA 用于超参数优化的实验设置如下:种群规模设为 5 个个体,最大迭代次数限制在 10 次,搜索空间涉及 BiLSTM 网络结构的 2 个关键参数,网络层数 *num_layers* 的取值范围是从 1 到 3,每层神经元数量 *bilstm_neurons*




图 6 OVMD 分解结果
Fig. 6 Decomposition result with OVMD

的区间是从 10 到 100。经过优化计算,最优网络架构为 2 层 BiGRU,每层有 90 个神经元,依靠双向拼接操作后,最终隐状态输出的特征维度为 180 维,优化过程中的适应度曲线如图 7 所示。




图 7 SSA 算法优化 BiLSTM 参数时的适应度值
Fig. 7 The fitness values of the SSA algorithms in optimizing BiLSTM parameters

运用 Adam 优化算法来开展模型训练工作,将初始学习率设定为 3×10^{-4} ,并且选用均方误差当作损失函数,并引入 L2 正则化项以此来控制模型的复杂度。训练过程采用 64 的批处理规模,总共进行 50 个训练轮次,并且实施早停策略,即当验证集损失连续 10 个轮次没有下降的时终止训练。

为验证提出的 STL-OVMD-SSA-BiGRU-Attention 风速预测模型的有效性,选取对照组 2(STL-OVMD-SSA-

BiLSTM)、对照组 3 (STL-OVMD-SSA-TCN-BiLSTM-Attention^[27])、对照组 4 (STL-OVMD-SSA-Transformer-BiLSTM^[28])、对照组 5 (VMD-CEEMD-Transformer-BiGRU^[29])、对照组 6 (VMD-CEEMD-BiLSTM-Attention) 作为对比模型,在相同测试数据集上进行对比实验。实验采用决定系数 R^2 、均方误差 MSE、均方根误差 RMSE、平均绝对误差 MAE、模型训练时间(Training Time)、模型参数作为评价指标。

选取对比模型基于如下 3 个维度。


1) 模型组件的消融与替换:选取对照组 2,旨在通过替换核心循环单元,对比 BiGRU 与 BiLSTM 在处理风速长距离依赖关系时的特征表征能力差异^[39]。

2) 主流架构的性能对标:选取对照组 3 和 4,分别融合了 TCN 与 Transformer 架构。将这些当前风速预测领域的主流先进模型作为基准,能客观地衡量本研究模型在预测精度上的表现^[40]。


3) 分解策略的效能验证:对照组 5 与对照组 6,采用了不同的二次分解技术。通过与这两组模型对比,可以评估 STL-OVMD 分解策略在抑制模态混叠、分离非平稳特征以及降低信号复杂度方面的性能。

图 8 所示为本文预测模型和对比模型对于风速测试数据集数据的预测结果,表 1 为不同预测模型的性能指标的对比。


1) 模型性能全面提升,所提模型在 MSE(0.076 71)、RMSE(0.276 96)、MAE(0.205 85)和 R^2 (0.934 89)、Training Time(318 s)以及 Params(268 381)6 项指标上




(a) SSA-BiGRU-Attention模型结果
(a) SSA-BiGRU-Attention model results




(b) SSA-BiLSTM模型结果
(b) SSA-BiLSTM model results




(c) SSA-TCN-BiLSTM-Attention模型结果
(c) SSA-TCN-BiLSTM-Attention model results



(d) SSA-Transformer-BiLSTM模型结果
(d) SSA-Transformer-BiLSTM model results



(e) VMD-CEEMD-Transformer-BiGRU模型结果
(e) VMD-CEEMD-Transformer-BiGRU model results



(f) VMD-CEEMD-BiLSTM-Attention模型结果
(f) VMD-CEEMD-BiLSTM-Attention model results

图 8 不同模型实验预测结果

Fig. 8 Experimental prediction results of different models

均表现优异,综合性能显著优于各对照组。在体现模型表征能力的 Params 指标达到 268 381 的情况下,其 Training Time 仅需 318 s,在所有实验模型中耗时最少,证明模型在实现“高复杂度特征捕捉”的同时,兼顾了优异

的计算效率。相较于 STL-OVMD-SSA-TCN-BiLSTM-Attention 模型, MSE 降低 33.5%, RMSE 降低 18.5%, MAE 降低 16.9%, R^2 提升 3.6%, Training Time 降低 42.0%, Params 降低 41.0%。

表 1 不同模型在测试集上的性能对比

Table 1 Performance comparison of different models on the test set

模型	MSE	RMSE	MAE	R^2	Training Time/s	Params
STL-OVMD-SSA-BiGRU-Attention(1)	0.076 71	0.276 96	0.205 85	0.934 89	318	268 381
STL-OVMD-SSA-BiLSTM(2)	0.078 54	0.280 25	0.211 32	0.933 34	370	225 829
STL-OVMD-SSA-TCN-BiLSTM-Attention(3)	0.081 76	0.285 94	0.214 63	0.930 60	548	454 651
STL-OVMD-SSA-Transformer-BiLSTM(4)	0.115 42	0.339 73	0.247 63	0.902 04	365	96 075
VMD-CEEMD-Transformer-BiGRU(5)	0.103 13	0.321 14	0.231 81	0.912 07	663	88 609
VMD-CEEMD-BiLSTM-Attention(6)	0.077 32	0.286 54	0.213 76	0.934 03	390	114 448

3) 鲁棒性与泛化性,实验组模型的 R^2 值达到 0.934 89,表明模型对时序变化的解释能力更强,且 MSE 与 RMSE 的显著下降进一步证明了 STL-OVMD 分解与 SSA 优化的联合设计可有效抑制噪声干扰,提升非线性特征学习能力。

综上,所提模型通过 STL-OVMD 分解、SSA 参数优化与 BiGRU-Attention 特征融合的协同设计,在时序预测任务中展现了更高的精度与稳定性。

5 结 论

针对风速序列非平稳性与多尺度波动特性导致的预测精度瓶颈问题,本研究提出的融合 STL-OVMD、SSA 优化与 BiGRU-Attention 多模块协同的混合预测模型,通过理论分析与实验验证,为非平稳序列预测提供多尺度协同建模范式;通过“分解-特征提取-参数优化”三级架构,验证了复杂时序数据建模的高效路径。

1) 模型结构的协同设计。STL 分离的趋势项、季节项和残差项以及 OVMD 分离的 IMF,有效解决单一分解方法对多尺度波动捕捉不充分的问题,降低信号模式混叠干扰。趋势项与季节项由 BiGRU 捕捉长期依赖与周期性特征,高频分量通过 Attention 机制动态加权,实现“全局趋势-局部细节”的精准建模。

2) 优化算法的工程适配。SSA 算法对超参数的全局寻优结果表明,启发式优化算法在解决深度学习“参数组合爆炸”问题上具有高效性,其“发现者-跟随者-警戒机制”的协同策略可作为复杂模型参数调优的优先选择。

3) 加权函数的多目标平衡。构建融合预测精度、计算效率与模型复杂度的加权适应度函数,实现“精度-效率-泛化性”动态平衡。通过调节权重系数分配目标优先级,结合 SSA 全局搜索逼近帕累托最优解集,解决复杂模型“精度与效率难以兼顾”的难题,为非平稳时序预测提供可迁移优化范式。

2) 多模块协同优势,STL-OVMD 分解有效剥离风速序列的多尺度特征(趋势-季节-高频波动),BiGRU 双向时序建模与自注意力机制协同捕捉关键时序依赖,降低极端值预测误差。

本研究提出的混合预测框架不仅为风速预测问题提供了高精度解决方案,更为非平稳时序数据建模提供了可迁移的方法论参考,其技术路线与工程启示对可再生能源利用、工业预测控制等提供系统性指导。

参考文献

[1] 任晓晔,陈晓,郭妍. 超声波测风换能器对风速的影响研究[J]. 电子测量技术, 2019, 42(7): 118-124.
Ren Xiaoye, Chen Xiao, Guo Yan. Study on the Influence of Ultrasonic Wind Transducer on Wind Speed [J]. Electronic Measurement Technology, 2019, 42(7): 118-124.

[2] Shan J, Wang H, Pei G, et al. Research on short-term power prediction of wind power generation based on WT-CABC-KELM[J]. Energy Reports, 2022, 8 (S8): 800-809.

[3] 陈晓,张凯. 嵌入式自动气象站故障检测系统研究[J]. 电子测量技术, 2021, 44(23): 158-164.
Chen Xiao, Zhang Kai. Fault detector for automatic weather stations based on embedded system [J]. Electronic Measurement Technology, 2021, 44 (23): 158-164.

[4] Chen H. A Comprehensive statistical analysis for residuals of wind speed and direction from numerical weather prediction for wind energy [J]. Energy Reports, 2022, 8 (S9): 618-626.

[5] 韩鹏飞,陈晓. 基于 MFCC-IMFCC 和 GA-SVM 的鸟声识别研究[J]. 计算机系统应用, 2022, 31(11): 393-399.
Han Pengfei, Chen Xiao. Bird sound recognition based on MFCC-IMFCC and GA-SVM [J]. Computer Systems & Applications, 2022, 31(11): 393-399.

[6] Zhang Y, Li R, Zhang J. Optimization scheme of wind energy prediction based on artificial intelligence [J]. Environmental Science and Pollution Research, 2021:

- 1-1.
- [7] 陈晓, 曾昭优. 基于特征融合和 B-SVM 的鸟鸣声识别算法[J]. 声学技术, 2024, 43(1): 119-126.
Chen Xiao, Zeng Zhaoyou. Bird sound recognition algorithm based on feature fusion and B-SVM [J]. Technical Acoustics, 2024, 43(1): 119-126.
- [8] Gupta D, Natarajan N, Berlin M. Short-term wind speed prediction using hybrid machine learning techniques [J]. Environmental Science and Pollution Research, 2022, 29(34): 50909-50927.
- [9] 陈晓, 曾昭优. 基于声音特征优化和改进支持向量机的鸟声识别. 测控技术, 2024, 43(6): 21-25.
Chen Xiao, Zeng Zhaoyou. Bird sound recognition based on optimized sound feature and improved SVM [J]. Measurement and Control Technology, 2024, 43(6): 21-25.
- [10] Abbasipour M, Igder M, Liang X. A novel hybrid neural network-based Day-Ahead wind speed forecasting technique [J]. IEEE Access, 2021, 9: 151142-151154.
- [11] 陈晓, 颜灏, 曾昭优. 特征融合的密集连接卷积网络识别鸟鸣声. 电子测量与仪器学报, 2025, 39(5): 241-250.
Chen Xiao, Yan Hao, Zeng Zhaoyou. Birdsong recognition based on improved DenseNet with feature fusion [J]. Journal of Electronic Measurement and Instrumentation, 2025, 39(5): 241-250.
- [12] 陈晓, 夏颖. 基于改进 MobileViT 网络的番茄叶片病害识别[J]. 电子测量技术, 2023, 46(14): 188-196.
Chen Xiao, Xia Ying. Improved MobileViT network for tomato leaf disease identification [J]. Electronic Measurement Technology, 2023, 46(14): 188-196.
- [13] 陈晓, 戴杰. 基于相同传播距离路径的兰姆波无基准损伤概率成像[J]. 电子测量与仪器学报, 2023, 37(8): 94-104.
Chen Xiao, Dai Jie. Lamb wave baseline-free damage probability imaging based on same propagation distance path [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(8): 94-104.
- [14] 陈晓, 汪陈龙. 基于赛利斯模型和分数阶微分的兰姆波信号消噪[J]. 物理学报, 2014, 63(18): 282-290.
Chen Xiao, Wang Xiaolong. Noise suppression for Lamb wave signals by Tsallis mode and fractional-order differential [J]. Acta Physica Sinica, 2014, 63(18): 282-290.
- [15] 邹胜男, 陈晓, 陈霞. 基于改进的 UKF 算法的室内测距定位[J]. 激光杂志, 2017, 38(4): 61-65.
Zou Shengnan, Chen Xiao, Chen Xia. Indoor ranging and positioning based on improved UKF algorithm [J]. Laser Journal, 2017, 38(4): 61-65.
- [16] Ozbek A, Ilhan A, Bilgili M, et al. One-hour ahead wind speed forecasting using deep learning approach [J]. Stochastic Environmental Research and Risk Assessment, 2022, 36(12): 4311-4335.
- [17] Xu L, Ou Y, Cai J, et al. Offshore wind speed assessment with statistical and attention-based neural network methods based on STL decomposition [J]. Renewable Energy, 2023, 216: 119097.
- [18] Jiang W, Lu Q, Xu Y, et al. Short-term wind speed prediction based on denoising algorithm of enhanced successive variational mode decomposition and integrated parallel prediction model [J]. Energy, 2025, 338, 138857.
- [19] 江星星, 宋秋昱, 杜贵府, 等. 变分模式分解方法研究与应用综述[J]. 仪器仪表学报, 2023, 44(1): 55-73.
Jiang Xingxing, Song Qiuyu, Du Guifu. Overview of research and application of variational mode decomposition method [J]. Journal of Instrumentation and Control, 2023, 44(1): 55-73.
- [20] Juyal V, Kakran S. CNN-LSTM-based wind forecasting for a residential energy management system [J]. Neural Comput & Applic, 2025, 37, 27117-27135.
- [21] 陈晓, 杨瑶. 融合注意力机制的 BiLSTM 网络实现无创血压测量[J]. 电子测量技术, 2022, 45(23): 59-65.
Chen Xiao, Tang Yao. Non-Invasive Blood Pressure measurement based on BiLSTM Network with attention mechanism [J]. Electronic Measurement Technology, 2022, 45(23): 59-65.
- [22] 王希, 孙娜, 苏浩, 等. 基于样本熵双分解和 SSA-LSTM 的超短期风速预测[J]. 太阳能学报, 2025, 46(3): 611-618.
Wang Xi, Sun Na, Su Hao, et al. Ultra-short-term wind speed prediction based on sample entropy double decomposition and SSA-LSTM [J]. Acta Energiæ Solaris Sinica, 2025, 46(3): 611-618.
- [23] 陈晓, 王志雄, 杨瑶. 基于 BiLRCN 和注意力机制的脉搏波血压测量[J]. 测控技术, 2024, 43(7): 23-30.
Chen Xiao Wang Zhixiong, Yang Yao. Pulse wave blood pressure measurement based on BiLRCN and attention mechanism [J]. Measurement and Control Technology, 2024, 43(7): 23-30.
- [24] Zhang X, Zhao H, Yao J, et al. A multi-scale component feature learning framework based on CNN-BiGRU and online sequential regularized extreme learning machine for wind speed prediction [J]. Renewable

- Energy, 2025, 242:122427.
- [25] 冯俊磊, 吕卫东, 段雪艳, 等. 基于模态分解和 TCN-BiLSTM 的风电功率预测[J]. 电子测量技术, 2024, 47(14): 49-56.
- Feng J L, Lyu W D, Duan X Y, et al. Wind power prediction based on modal decomposition and TCN-BiLSTM[J]. Electronic Measurement Technology, 2024, 47(14): 49-56.
- [26] Luo H, Shi H, Shi Q, et al. Wind speed forecasting using dual-attention patch-based multiscale transformer, Energy, 2025, 340, 139178.
- [27] Feng Y, Zhu J, Qiu P, et al. Short-term power load forecasting based on TCN-BiLSTM-attention and multi-feature fusion [J]. Arabian Journal for Science and Engineering, 2025, 50(8): 5475-5486.
- [28] He H, He W, Guo J, et al. Research on new energy power generation forecasting method based on Bi-LSTM and transformer[J]. Energies, 2025, 18(19): 5165.
- [29] Wang X, Xie G, Zhang Y, et al. The application of a bigru model with transformer-based error correction in deformation prediction for bridge SHM [J]. Buildings, 2025, 15(4): 542.
- [30] Du J, Chen S, Pan L, et al. A Wind speed prediction method based on signal decomposition technology deep learning model [J]. Energies, 2025, 18(5): 1136.
- [31] Mumtazina U, Alahakoon S, Wolfs P. Hyperparameter tuning of load-forecasting models using metaheuristic optimization algorithms-a systematic review [J]. Mathematics, 2024, 12(21): 3353.
- [32] Geng X, He X, Hu M, et al. Multi-attention network with redundant information filtering for multi-horizon forecasting in multivariate time series [J]. Expert Systems With Applications, 2024, 257, 125062.
- [33] 赵杰, 解则晓, 刘世萱. 基于能量熵 VMD 最优分解与 GRU 循环神经网络的潮汐预测精度提升方法研究[J]. 仪器仪表学报, 2023, 44(12): 79-87.
- Zhao Jie, Xie Zexiao, Liu Shixuan. Research on tidal prediction accuracy improvement method based on energy entropy vmd optimal decomposition and gru recurrent neural network [J]. Journal of Instruments and Meters, 2023, 44(12): 79-87.
- [34] 任晓晔, 陈晓, 郭妍. 基于 Fluent 和 LSTM 神经网络的超声波测风仪阴影效应补偿研究[J]. 计算机应用与软件, 2019, 36(7): 89-98.
- Ren Xiaoye, Chen Xiao, Guo Yan. Research on shadow effect compensation of ultrasonic anemometer based on Fluent and LSTM neural network [J]. Computer Applications and Software, 2019, 36(7): 89-98.
- [35] 张登攀, 兰征, 杜怡衡. 基于 PCHIP-VMD 数据分析与 SSA-LSTM 模型的短期风电功率预测[J]. 电子测量与仪器学报, 2025, 39(5): 251-261.
- Zhang Dengpan, Lan Zheng, Du Yiheng. Short-term wind power forecasting based on PCHIP-VMD data analysis and SSA-LSTM model [J]. Journal of Electronic Measurement and Instrumentation, 2025, 39(5): 251-261.
- [36] 孙超文, 陈晓. 基于多尺度特征融合反投影网络的图像超分辨率重建[J]. 自动化学报, 2021, 47(7): 1689-1700.
- Sun Chaowen, Chen Xiao. Multiscale feature fusion back-projection network for image super-resolution [J]. Acta Automatica Sinica, 2021, 47(7): 1689-1700.
- [37] 包广斌, 杨龙龙, 范超林, 等. 基于 SSA 优化的 Transformer-BiGRU 短期风电功率预测[J]. 电子测量技术, 2025, 48(13): 139-147.
- Bao Guangbin, Yang Longlong, Fan Chaolin, et al. Short-term wind power forecasting based on ssa-optimized transformer-BiGRU [J]. Electronic Measurement Technology, 2025, 48(13): 139-147.
- [38] Jiankai X, Bo S. A survey on sparrow search algorithms and their applications [J]. International Journal of Systems Science, 2024, 55(4): 814-832.
- [39] Yousef K, Yuce B, He A. A hybrid deep learning framework for wind speed prediction with snake optimizer and feature explainability [J]. Sustainability, 2025, 17(12): 5363.
- [40] Mi L, Han Y, Long L, et al. A physics-informed temporal convolutional network-temporal fusion transformer hybrid model for probabilistic wind speed predictions with quantile regression [J]. Energy, 2025, 326: 136302.

作者简介




陈晓(通信作者), 博士, 南京信息工程大学教授, 主要研究方向为声信号与信息处理、现代电子系统统计、图像处理与成像等。

E-mail: chenxiao@nuist.edu.cn

Chen Xiao (Corresponding author),

Ph. D., is a Professor in the Nanjing University of Information Science and Technology. His main research interests are acoustical signal and information processing, modern electronic system design, image processing and imaging.



刘阳, 南京信息工程大学硕士研究生, 主要研究方向为风电功率预测。

E-mail: chenxiao@nuist.edu.cn

Liu Yang is now a M. Sc. candidate at Nanjing University of Information Science and Technology. His main research interest

includes wind power prediction.