

•智能交叉科学与工程•

DOI:10.12454/j.jsuese.202300619



本刊网刊

基于 BWO 优化 VMD 和 TCN-BiGRU 的短期风电功率预测

逯 静,张燕茹,王 瑞*

(河南理工大学 计算机科学与技术学院,河南 焦作 454000)

摘 要:针对风力发电过程中出现的不平稳、波动性大等特点,为了更好地提高风力发电的预测精度,提出一种基于白鲸优化算法(BWO)的变分模态分解(VMD)和时序卷积网络(TCN)-双向门控循环单元(BiGRU)联合构建的短期风力发电功率预测模型。首先,由于风电功率受多方面气象因素的共同影响,采用随机森林(RF)方法来确定气象因素特征的重要性,对特征进行排序并提取出最优的特征。其次,利用 VMD 将原始功率数据由不平稳序列分解成较平稳的子序列,为解决 VMD 的两个参数即模态数和惩罚因子难以人工确定的问题,使用 BWO 对 VMD 的参数进行寻优,利用优化后的 VMD 对非平稳电力信号进行有效分解。然后,将分解后的各平稳子序列加上提取出的最优特征进行 TCN-BiGRU 组合模型预测。最后,将各子序列的预测值进行叠加得到最终的结果。以中国的某风电场的实际数据为例,通过多种单一模型与组合模型对所提出的预测模型进行了仿真对比。仿真结果表明,所提出的基于 BWO 优化 VMD 和 TCN-BiGRU 联合预测方法具有较高的预测精度,其均方根误差、平均绝对误差及平均百分比误差的指标精度均比其他模型有所提高。本文方法在风电功率预测中具有显著优势。

关键词:短期风功率预测;变分模态分解;随机森林;时序卷积网络;双向门控循环单元;白鲸优化算法

中图分类号:TP391.9;TM614

文献标志码:A

文章编号:2096-3246(2025)03-0031-11

近年来,风电作为一种极具发展潜力的新能源发展迅速。在全球变暖及化石能源消耗加剧的背景下,风力发电成为一种最常用的新能源,它所占的比例也越来越大^[1]。中国风力发电产业也得到了很大的发展,这对推动国家能源结构的转变、节能减排起到了积极的作用。虽然风电功率预测技术已有长足进步,但是风电功率的间歇性、多变特性给风电功率预测带来了很大挑战^[2-3]。

国内外学者对于风电功率预测提出了许多方法。传统的风功率预测方法大致归为 3 类:统计方法、物理建模方法和混合方法^[4]。统计方法是基于历史数据和统计模型进行预测。常见的统计方法包括回归分析、时间序列分析、机器学习算法如支持向量机^[5]、随机森林^[6-7]、门控循环单位网络^[8-9]等。物理建模方法是通过基于风场和风机等物理原理进行建模,但依赖准确的气象数据和风机参数,建模复杂。混合方法通过统计方法和物理建模方法的结合,提高预测的准确性和

可靠性。这些传统方法在风电功率预测上有一定的应用,但也存在一些限制和挑战,由于风电功率的不确定性和非线性,使用这些统计方法和物理方法来预测可能存在精度低和时效性差等问题。

针对单一模型精度有限及适应性差的问题,近年来,为提高风电功率预测的准确性和可靠性,学者们往往通过融合多模型、引入领域知识、使用联合学习等方式来构建模型。如:Niksa-Rynkiewicz 等^[10]提出利用多种深度神经网络解决短期风电功率预测问题的智能方法,其关键优点是使用极小的参数子集进行高效的预测,但泛化性不足,复杂关系捕捉能力有限。郭玲等^[11]提出一种基于时序卷积网络和门控循环单元(GRU)相组合的短期负荷预测方法,利用 TCN 对时序数据进行特征提取,将提取的特征和非时序数据组合输入到 GRU 模型中进行训练,但电力负荷数据作为复杂的时间序列,复杂特征提取不充分会导致精度受限。吴慧军等^[12]提出一种在原始信号中引入高斯白

收稿日期:2023-08-11 修回日期:2024-01-23 网络出版日期:2024-05-30

基金项目:河南省科技攻关项目(222102210120);国家自然科学基金项目(62273133)

作者简介:逯 静(1980—),女,副教授,硕士。研究方向:深度学习;物联网技术等。E-mail:lujing@hpu.edu.cn

*通信作者:王 瑞,副教授, E-mail:wangrui@hpu.edu.cn

噪声的集合经验模态分解(EEMD)算法,来对风电序列进行分解降噪,但在分解高噪声信号时,可能会产生较大的模态混叠现象,会导致IMF分量的频率和振幅信息被混合。徐武等^[13]提出一种基于改进局部自注意力机制的变分模态分解,建立GRU模型的预测方法,VMD将原始数据分解为多组中心频率不一的子模态,对各子模态进行预测,叠加得到最终的预测结果,但VMD的两个参数不易人为直接确定,可能导致模态混叠或欠分解。丁同等^[14]提出一种基于遗传算法(GA)优化VMD的参数,建立双向长短期记忆网络(BiLSTM)的风电功率预测模型,使用的BiLSTM模型虽有优势,但存在单一模型的局限性,影响预测效果。

综上所述,为进一步提高短期风力发电功率预测的准确性,本文提出了一种基于BWO优化VMD和TCN-BiGRU相结合的短期风力发电功率预测模型(OVMD-TCN-BiGRU)。首先,采用随机森林的方法筛选出最优的特征;其次,使用BWO优化VMD(BWO-VMD,简化为OVMD),将波动性、非平稳性的风电功率分解成稳定的各个子分量,并以样本熵和误差重构方法构造一个综合指数,以此为基础,实现对VMD的最优分解;然后,根据分解的各分量并结合选取的气象特征,构建OVMD-TCN-BiGRU预测模型,实现对不同分量的预测;最后,通过对各分量预测结果的叠加得出最终的预测结果。

1 算法

1.1 特征提取

考虑风电场的历史信息中包含风速、风向等气象信息及历史功率数据,所以需要在预测前筛选相关联的气象和历史功率数据,避免输入冗余^[15]。随机森林(RF)是一种集成学习算法,它可以评估特征在整个模型中的贡献,不仅考虑特征间的相关性,同时具有较好的鲁棒性且易实现。

根据袋外数据(OOB)计算每棵决策树的袋外误分率 e_{mi} ,再保证其余特征样本不变,随机改变OOB的第 j 个变量 v_j 值,并由式(1)重新计算袋外误分率 e'_{mi} :

$$e_{mi} = \frac{i_{err}}{i_{all}} \quad (1)$$

式中, i_{err} 为预测错误数量, i_{all} 为总数。

为了衡量每个气象特征的重要性,定义平均精度下降(MDA)值 $\zeta(v_j)$,通过式(2)计算 $\zeta(v_j)$,用于量化特征对模型精度的重要度,对所得出的值进行特征重要度排序,筛选出重要程度高的特征,完成特征提取^[16]。

$$\zeta(v_j) = \frac{\sum_{m=1}^M e'_{mi} - e_{mi}}{M} \quad (2)$$

式中, M 为随机森林中决策树的数量, m 为随机森林中第 m 棵决策树。

1.2 BWO优化VMD

1.2.1 VMD分解

变分模态分解(VMD)通过找到约束变分模型的最优解,将非平稳的风电时间序列分解成各种模态成分^[17-18]。VMD将风力发电的不稳定信号序列分解成一组有限宽频带的模态函数,具体步骤如下。

1)利用Hilbert变换和指数调节中心频率,实现频谱向基带转换。带约束的变分问题表示为:

$$\begin{cases} \min_{u_k, \omega_k} \left\{ \sum_{k=1}^K \left\| \partial t \left[\left(\delta(t) + \frac{j}{\pi t} \right) u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\}, \\ \text{s.t.} \quad \sum_{k=1}^K u_k = f(t) \end{cases} \quad (3)$$

式中, u_k 为第 k 个模态分量, $u_k(t)$ 为第 k 个模态分量随时间 t 的变化关系, ω_k 为第 k 个模态分量的中心频率, K 为模态函数的个数, $\delta(t)$ 为脉冲函数, $f(t)$ 为原始信号。

2)为解决约束问题,引入二次惩罚因子 α 和拉格朗日算子 $\lambda(t)$,构建增广拉格朗日函数如下:

$$\begin{aligned} L(u_k, \omega_k, \lambda(t)) = & \alpha \sum_{k=1}^K \left\| \partial t \left[\left(\delta(t) + \frac{j}{\pi t} \right) u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \\ & \left\| f(t) - \sum_{k=1}^K u_k \right\|_2^2 + \left\langle \lambda(t), f(t) - \sum_{k=1}^K u_k \right\rangle \end{aligned} \quad (4)$$

3)利用交替方向乘子法连续更新各分量及其中心频率,通过式(5)和(6)交替迭代更新,逐步完成VMD的分解。

$$\hat{u}_k^{T+1}(\omega) = \frac{\hat{f}(\omega) - \sum_{i \neq k} \hat{u}_i(\omega) + \frac{\hat{\lambda}(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k)^2} \quad (5)$$

$$\omega_k^{T+1} = \frac{\int_0^\infty \omega \left| \hat{u}_k^{T+1}(\omega) \right|^2 d\omega}{\int_0^\infty \left| \hat{u}_k^{T+1}(\omega) \right|^2 d\omega} \quad (6)$$

式(5)~(6)中, T 为当前迭代次数, ω 为当前频率, $u_k^{T+1}(t)$ 为第 k 个模态分量第 $T+1$ 次迭代随时间 t 的变化关系, $\hat{f}(\omega)$ 、 $\hat{u}_i(\omega)$ 、 $\hat{\lambda}(\omega)$ 和 $\hat{u}_k^{T+1}(\omega)$ 分别为 $f(t)$ 、 $u(t)$ 、 $\lambda(t)$ 和 $u_k^{T+1}(t)$ 的傅里叶变换。

VMD分解中,存在两个关键参数:模态数 K 和惩罚因子 α 。过少的模态数可能导致重要的信号特征被忽略,而过多的模态数可能引入不必要的噪声或模态。并且,较大的惩罚因子会使解更加平滑,但可能导致原始数据信号的细节丢失;较小的惩罚因子则可

能使解变得不平滑,甚至出现震荡。因此,本文采用BWO对VMD的参数进行寻优,即提出OVMD方法。

1.2.2 OVMD方法

白鲸优化算法(BWO)是Zhong等^[19]提出的一种群体智能优化算法。BWO包含探索、开发和鲸鱼坠落的3个阶段,分别对应成对游泳、捕食和鲸落的行为^[20]。

BWO算法可以从探索逐渐转换到开发,这取决于平衡因子 B_f ,其定义为:

$$B_f = B_0(1 - T/(2T_{\max})) \quad (7)$$

式中, T_{\max} 为最大的迭代次数, B_0 为每次迭代中在(0, 1)之间随机变化的随机数。

1) 探索阶段

BWO的探索阶段根据白鲸的游泳行为建立。搜索代理的位置由白鲸的配对游泳来决定,白鲸的位置更新如下:

$$\begin{cases} X_{i,j}^{T+1} = X_{i,p_j}^T + \\ (X_{r,p_1}^T - X_{i,p_j}^T)(1 + r_1)\sin(2\pi r_2), j = \text{奇数}; \\ X_{i,j}^{T+1} = X_{i,p_j}^T + \\ (X_{r,p_1}^T - X_{i,p_j}^T)(1 + r_1)\cos(2\pi r_2), j = \text{偶数} \end{cases} \quad (8)$$

式中: $X_{i,j}^{T+1}$ 为第*i*只白鲸在第*T*+1次迭代时,在第*j*维上的新位置; p_j 为在第*j*维中选择的随机整数, $j=1, 2, \dots, d$; X_{i,p_j}^T 为第*i*只白鲸在第*T*次迭代时,随机选择的第*p_j*维上的位置; X_{r,p_1}^T 为第*r*只白鲸在第*T*次迭代时,随机选择的第*p₁*维上的位置;*r*为随机选择的白鲸;随机数 r_1 和 r_2 均为增强探索阶段的随机算子; $\sin(2\pi r_2)$ 和 $\cos(2\pi r_2)$ 分别为白鲸在奇数、偶数位置上的动态变化。

2) 开发阶段

BWO的开发阶段借鉴了白鲸的捕食行为。同时,为了增强开发阶段的全局收敛性,引入莱维飞行策略来模拟个体在捕食猎物时的行为,能更有效地搜索解空间中的潜在最优解。式(9)表示在BWO开发阶段,第*i*只白鲸在第*T*+1次迭代时位置的更新方式,计算公式如下:

$$X_i^{T+1} = r_3 X_{\text{best}}^T - r_4 X_i^T + C_1 \times L_F \times (X_r^T - X_i^T) \quad (9)$$

式中: X_i^T 和 X_r^T 分别为第*i*只白鲸和随机白鲸的当前位置; X_i^{T+1} 为第*i*只白鲸的新位置; X_{best}^T 为白鲸种群中的最佳位置; r_3 和 r_4 均为(0, 1)间的随机数; C_1 为衡量莱维飞行强度的随机跳跃强度, $C_1 = 2r_4(1 - T/T_{\max})$; L_F 为莱维飞行函数,计算公式如下:

$$L_F = 0.05 \times \frac{u \times \psi}{|v|^{1/\beta}} \quad (10)$$

式中: u 和 v 为正态分布随机数; β 为默认常数,等于1.5; ψ 为步长缩放因子,用于确保莱维飞行步长具有重尾的分布特性,根据式(11)确定 ψ 值,进而计算 L_F 。

$$\psi = \left(\frac{\Gamma(1+\beta) \times \sin(\pi\beta/2)}{\Gamma((1+\beta)/2) \times \beta \times 2^{(\beta-1)/2}} \right) \quad (11)$$

3) 鲸鱼坠落阶段

为了模拟鲸鱼坠落行为,在每次迭代时,从种群中选择鲸鱼坠落概率作为主观假设。在模拟过程中,假设白鲸要么移动到其他位置,要么被击落并坠入深海。为了确保种群大小始终保持不变,利用式(12)根据白鲸的位置和鲸鱼坠落的步长来更新位置,公式为:

$$X_i^{T+1} = \gamma_5 X_i^T - r_6 X_r^T + \gamma_7 X_{\text{step}} \quad (12)$$

式中: γ_5 、 γ_6 和 γ_7 均为(0, 1)之间的随机数; X_{step} 为鲸鱼坠落的步长,定义为:

$$X_{\text{step}} = (u_b - l_b) \exp(-C_2 T/T_{\max}) \quad (13)$$

式中: C_2 为与鲸鱼下降概率和种群规模相关的阶跃因子, $C_2 = 2W_f \times n$,其中, W_f 为鲸鱼坠落概率, n 为种群规模; u_b 和 l_b 分别为优化参数的上、下限。

鲸鱼坠落概率(W_f)作为线性函数计算:

$$W_f = 0.10 - 0.05T/T_{\max} \quad (14)$$

优化过程中,白鲸的坠落概率由最初的0.10下降到最终的0.05,这说明在优化过程中,随着距离的拉近,白鲸的危险程度也随之下落。

本文提出的OVMD方法,利用BWO优化传统的VMD方法中的两个参数(模态数和惩罚因子)^[21],获得更准确和稳定的信号分解结果,有效提高风电功率预测的精度与可靠性。在寻优前,选择合适的适应度函数至关重要,将样本熵和误差重构作为综合指标,通过计算每个模态函数的样本熵衡量其对信号的贡献程度,利用重构误差评估分解的准确性和分解结果的精度及质量,从而选择和调整模态函数;在此基础上,使用BWO优化算法寻找最优的模态函数组合,以实现最佳的信号分解和预测效果。该方法考虑上述综合指标,有助于获得更优的分解结果,使分解后模态分量的质量更高、误差更小。

OVMD算法的流程如图1所示。具体步骤为:

- 1) 初始化VMD待优化参数 K 、 α ,以及范围、种群参数。
- 2) 计算每个白鲸个体的适应度值。
- 3) 根据种群中个体的适应度值,使用自适应机制更新每个白鲸个体的平衡因子和鲸落概率。
- 4) 通过计算式(8)~(11),根据白鲸个体的探索和

开发阶段的结果,判断是否需要更新每个个体的位置。

5)检查是否达到终止条件,例如达到最大迭代次数或找到满意的解。

6)重复步骤2)~5),直到满足终止条件。输出经过优化后的最优解。

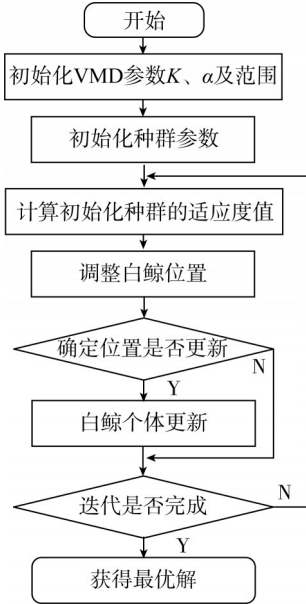


图1 OVMD算法实现流程图

Fig. 1 OVMD algorithm implementation flowchart

1.3 TCN-BiGRU 预测模型

TCN 是一种利用卷积结构解决时间序列问题的算法,具有许多优点,如并行计算、捕捉长期的相关性、避免梯度的消失和梯度的爆炸等^[22]。与传统的卷积神经网络相比,TCN可以更有效地提取时序数据的特征。一种通用的TCN体系结构由因果卷积、残差连接和膨胀卷积组成^[23-24]。因果卷积可以保证输出仅依赖当前和过去的的数据,避免未来信息泄露;膨胀卷积可以增加卷积层的感受野,从而更好地捕捉时间序列中的长期依赖关系;加入残差连接可避免梯度消失和性能下降的问题^[25-27]。TCN利用因果卷积、残差连接和膨胀卷积的结构特点,对输入信息进行处理,可以提高处理时间序列数据的能力。

长短期记忆网络(LSTM)^[28]在循环神经网络(RNN)的基础上改进网络,以解决其存在的梯度消失或者梯度爆炸的问题。为了计算简单且效率高,门控循环单元(GRU)模型^[29-30]被提出,该模型的结构如图2所示。图2中, z_t 和 r_t 分别为 t 时刻的更新门和重置门的的状态向量, h_{t-1} 为前一时刻输入的隐藏状态向量, h_t 为输出的最终隐藏状态向量, \tilde{h}_t 为候选的隐藏状态向量, x_t 为输入向量, σ 表示 sigmoid 函数。




图2 GRU网络结构

Fig. 2 Structure of the GRU network

GRU模型将LSTM模型结构中的遗忘门和输入门合并为一个更新门,简化了网络结构^[31]。式(15)~(17)分别计算更新门、重置门、候选的隐藏状态向量:

$$z_t = \sigma(W_z x_t + U_z h_{t-1}) \quad (15)$$

$$r_t = \sigma(W_r x_t + U_r h_{t-1}) \quad (16)$$

$$\tilde{h}_t = \varphi(r_t \otimes U_h h_{t-1} + W_h x_t) \quad (17)$$

式(15)~(17)中, $\varphi(\cdot)$ 表示非线性激活函数, W 为当前输入向量的权重矩阵, U 为前一时刻隐藏状态的权重矩阵,下标 z 、 r 和 h 分别对应更新门、重置门、候选的隐藏状态, \otimes 表示哈达马积。

式(18)得出最终的隐藏状态向量,计算式如下:

$$h_t = (1 - z_t) \otimes \tilde{h}_t + z_t \otimes h_{t-1} \quad (18)$$

为了充分考虑数据之间前后变化的信息规律,采用双向的GRU(BiGRU)结构。BiGRU由两个单向且方向相反的GRU组成,具体计算如下:

$$\begin{cases} h_t^R = \text{GRU}(x_t, h_{t-1}^R), \\ h_t^L = \text{GRU}(x_t, h_{t-1}^L), \\ h_t = \alpha_t h_t^R + \beta_t h_t^L + b_t \end{cases} \quad (19)$$

式中,GRU(\cdot)表示门控循环单元, h_t^R 和 h_t^L 分别为前向和后向的隐藏层的输出向量, α_t 和 β_t 分别为前向和后向的隐藏层的权重向量, b_t 为偏置向量。

本文的TCN-BiGRU是将TCN模型的输出作为BiGRU的输入,其网络结构如图3所示。

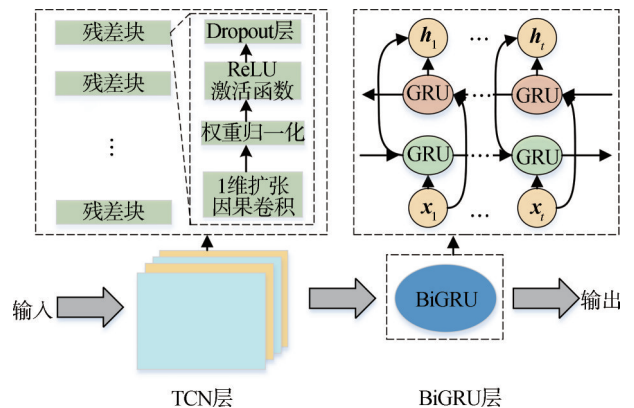


图3 TCN-BiGRU网络结构

Fig. 3 TCN-BiGRU network structure

由图3可见,TCN通过卷积层提取时间序列多尺度特征,BiGRU模型的输出由1个前向隐层和1个后向隐层的结果加权求和决定。将BiGRU应用到功率预测中,可以从前后两个方向来获取数据之间的信息,在预测当前风电功率时,二者相互配合,有助于提升模型的性能。

1.4 基于OVMD-TCN-BiGRU的短期风电功率预测

针对风电功率波动大、不平稳等特点,以OVMD-TCN-BiGRU为基础,建立短期风电功率预测模型。本文的OVMD-TCN-BiGRU预测模型的流程图如图4所示。

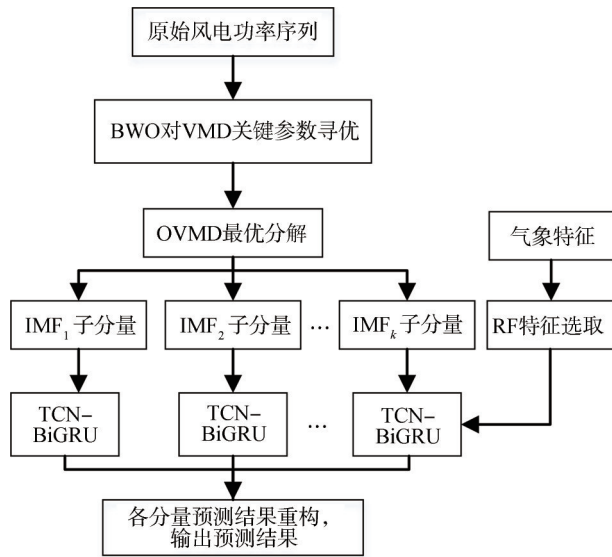


图4 OVMD-TCN-BiGRU预测模型流程图

Fig. 4 OVMD-TCN-BiGRU prediction model flowchart

本文预测模型的具体步骤如下:

1) 采用第1.1节的RF法对各气象因子的重要性进行排序,选择出显著的特征,并在此基础上综合考虑相关的气象信息,以降低输入的数据的冗余。

2) 通过对输入信号的预处理和划分,采用第1.2节中OVMD方法将风电功率分解为一组平稳的IMF分量。

3) 采用第1.3节中TCN-BiGRU模型在训练集上训练每个IMF分量,再将各分量的测试集输入已训练的模型中,得到各分量预测结果。

4) 对各分量的预测值进行叠加,得到最后的预测结果。

2 仿真分析

2.1 数据来源及数据处理

本文所采用的数据来自于某地区风电场的实测数据,采样时间为2019年1月1日—1月31日。采样间隔为15 min,一共采集了2 976个数据点,数据如图5所示。




图5 原始风电功率数据

Fig. 5 Raw wind power data

将前2 874个点(1月1日—1月29日)的数据作为训练样本,后192个点(1月30日—1月31日)的数据作为测试样本。为消除量纲误差,加速训练过程,采用最大最小标准化(min-max normalization)将功率数据归一化到[0, 1]之间,转换为标量值,计算公式如下:

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (20)$$

式中, x' 为归一化后的值, x 为样本实际值, x_{\min} 和 x_{\max} 分别为该数据所在列的最大值和最小值。

2.2 评价指标

为了验证模型的性能,在仿真分析中除了时间指标外,采用均方根误差(RMSE)、平均绝对误差(MAE)及平均绝对百分比误差(MAPE)作为模型的评价指标,计算公式分别为:

$$R_{RMSE} = \sqrt{\frac{1}{q} \sum_{i=1}^q (\hat{y}_i - y_i)^2} \quad (21)$$

$$E_{MAE} = \frac{1}{q} \sum_{i=1}^q |\hat{y}_i - y_i| \quad (22)$$

$$A_{MAPE} = \frac{100\%}{q} \sum_{i=1}^q \left| \frac{\hat{y}_i - y_i}{y_i} \right| \quad (23)$$

式(21)~(23)中, q 为样本点数, \hat{y}_i 和 y_i 分别为第*i*个的风功率样本的预测值和真实值。

2.3 RF特征选取

特征选取需要选取出重要程度高的特征,以降低数据维度,减少训练时间,提高预测精度。选取的特征包含距离地面垂直高度为10、30和50 m高的风速,以及风向、气压和温度共6个气象因素,分别记为 x_0 、 x_1 、 x_2 、 x_3 、 x_4 和 x_5 。本文使用基于RF方法选取的特征重要度如图6所示。

由图6可见,选取的10、30和50 m高的风速特征的重要程度更高,其他3个气象因素(风向、气压和温度)的影响较小,可忽略不计。




图 6 本文方法选取的特征的重要性

Fig. 6 Importance of features selected by the method in this paper

2.4 优化算法对比与分解仿真

为了验证本文使用的BWO算法的寻优性能,将BWO与GA和鲸鱼优化算法(WOA)进行性能对比。其中:GA的交叉概率为0.7,变异概率为0.01;WOA的学习因子为0.5,随机扰动因子为1;BWO的鲸鱼坠落概率为(0.05, 0.10)。VMD的参数中,TAU为0,TOL为 $1e-6$,DC为0,INIT为1。为保证公平性,各优化算法的种群数量和最大迭代次数均设为一致,分别为30和50; $K=[3, 10], \alpha=[100, 2\ 500]$ 。各优化算法的适应度迭代曲线和寻优结果分别如图7和表2所示。




图 7 各优化算法的适应度迭代曲线

Fig. 7 Fitness iteration curves of different optimization algorithms

表 2 各优化算法的寻优结果

Tab. 2 Finding results of different optimization algorithms

算法	参数		分解结果的适应度值
	K	α	
GA	7	1 798	0.044 41
WOA	6	2 144	0.043 15
BWO	5	1 694	0.042 89

从图7可以看出:本文的BWO算法在运行速度和寻优能力上均优于其他两种优化算法,BWO算法可以快速获得全局最优解;GA算法因波动性较强,其寻优的效果并不佳;WOA算法在收敛和寻优能力上不如

本文的BWO算法。随着迭代次数的增加,本文的BWO算法表现出较强的寻优能力及更快的收敛速度。由表2可知,BWO算法的寻优结果比GA、WOA算法更佳。

进一步,验证本文方法的有效性,图8展示了原始功率数据进行本文OVMD方法分解后的结果,包括原始数据及5个IMF分量。综合表2和图8可知,BWO的寻优结果及OVMD的分解效果更优。




图 8 本文 OVMD 分解结果

Fig. 8 Decomposition results of OVMD

2.5 单一模型预测结果分析

为验证本文所使用的BiGRU的有效性,将本文的BiGRU(双向门控循环单元神经网络)与BP(反向传播神经网络模型)、SVR(支持向量回归模型)、ELM(极限学习机模型)、GRU(门控循环单元神经网络)等单一模型进行对比分析。图9和表4分别给出了单一模型的预测结果及误差指标和时间指标。其中:BP神经元个数为64,以tanh作为激活函数;SVR基于RBF核函数, $\gamma=0.01$;ELM使用双层隐藏层,神经元个数为64,32,并用tanh作为激活函数;GRU的神经元个数为64;BiGRU的神经元个数为64^[32];TCN的神经元个数为64,采用的卷积核大小为6^[33],批大小(batch size)为32,学习率为0.001,为防止训练过拟合,Dropout系数设为0.15,扩张系数设定为1、2、4、8、16、32,卷积层采用的神经元数量为32。各单一模型的迭代次数均为100次。

从图9可以看出,虽然单一预测模型可以预测电力系统中风电功率的大致趋势,但当波动性较大时,

其他方法预测效果较差,而本文使用的BiGRU方法凭借其独特的结构,依然表现稳定,能较精确地进行预测,展现出更优的预测性能。

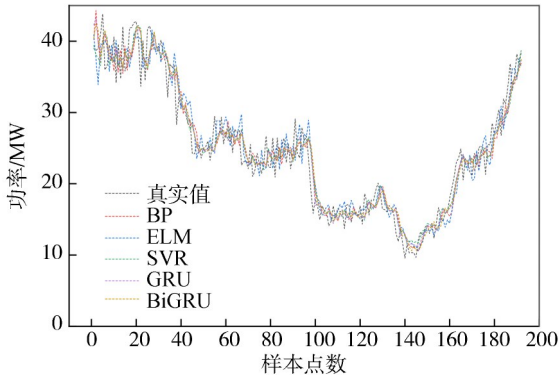


图9 单一模型的预测结果

Fig. 9 Prediction results of single models

表4 单一模型的误差指标和时间指标

Tab. 4 Error and time indicators of single models

模型	RMSE/MW	MAE/MW	MAPE/%	时间/s
BP	2.475	1.942	8.025	0.143
SVR	2.387	1.874	7.794	0.158
ELM	2.687	2.190	9.068	0.092
GRU	2.347	1.872	7.755	15.278
BiGRU	2.324	1.821	7.470	17.608

由表4可以看出:本文BiGRU模型的MAPE值比ELM、BP、SVR模型分别降低了1.598%、0.555%和0.324%,且本文BiGRU模型的RMSE值和MAE值均低于其他单一模型,故本文BiGRU网络模型预测精度更高,其在预测精度方面表现出色。虽然本文BiGRU模型的耗时略高于其他模型的耗时,但从预测精度来看,本文BiGRU模型的整体效果比其他单一模型更优。这是因为BiGRU采用双向门控循环单元,在每个时间步中,两个方向的网络分别进行计算,导致计算量增加,但其能充分捕捉时序数据中的双向信息,从而提高模型对序列数据的建模和预测性能,使得BiGRU在处理复杂的时序任务时具有更好的表现。

2.6 组合模型预测结果分析

风电功率数据复杂,组合模型优势互补,可以提高预测精度。为了验证本文OVMD-TCN-BiGRU组合模型的预测效果,将本文第1.2节所提的OVMD分解方法与其他方法相组合形成多种组合模型,如OVMD-BiGRU(BWO优化VMD+双向门控循环单元神经网络)、OVMD-TCN-GRU(BWO优化VMD+时间卷积网络+门控循环单元神经网络),以及EEMD-TCN-BiGRU(EEMD功率分解+时间卷积网络+双向门控循环单元神经网络),与本文的OVMD-TCN-BiGRU模

型的预测结果比较。组合模型的预测结果如图10所示,其误差和时间指标如表5所示。

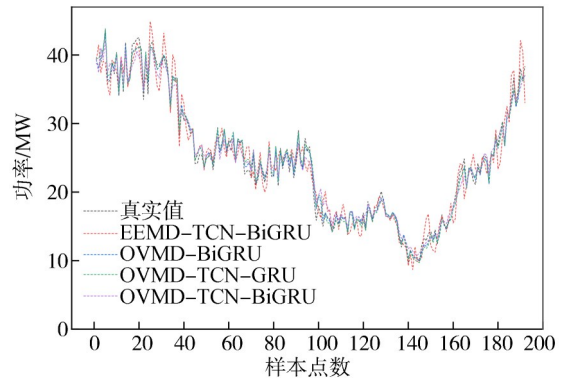


图10 组合模型的预测结果

Fig. 10 Prediction results of combined models

表5 组合模型的误差指标和时间指标

Tab. 5 Error and time indicators of combined models

模型	RMSE/MW	MAE/MW	MAPE/%	时间/s
OVMD-BiGRU	0.668	0.525	2.251	159.993
EEMD-TCN-BiGRU	1.986	1.555	6.586	1 608.172
OVMD-TCN-GRU	0.815	0.642	2.882	612.973
OVMD-TCN-BiGRU	0.441	0.331	1.485	639.840

从图10和表5可以看出:组合模型的预测效果优于单一模型,因为经过分解能将不稳定、波动剧烈的风力发电信号分解成更加稳定的子序列,从而减少原始风力发电的复杂度,大大提高模型预测的准确性。本文OVMD-TCN-BiGRU模型的MAPE值比EEMD-TCN-BiGRU、OVMD-BiGRU、OVMD-TCN-GRU模型分别降低了5.101%、0.766%、1.397%,且本文OVMD-TCN-BiGRU模型的RMSE值和MAE值也比其他组合模型更低,表明本文模型的OVMD分解方法更优越,既保证收敛性,也对信号中的噪声和干扰具有一定的抗干扰能力。组合模型的耗时会更长,这是因为组合模型将经过分解得到的子分量分别进行预测,再叠加得到最终的预测结果,所需时间较长。虽然单一模型的耗时短,但单一模型的预测精度不如组合模型。本文模型的耗时处于所有对比的组合模型的中间水平。综合预测效果、误差和时间指标来看,本文OVMD-TCN-BiGRU模型的预测效果更好,其主要原因是:一方面,本文模型使用OVMD方法,使得原始风电序列由非平稳序列分解为平稳的子序列;另一方面,本文模型使用TCN网络结构可以有效地提取隐含数据的隐含特征,同时借助BiGRU可以更好地分析数据的时序性及复杂的非线性关系,从而显著提高预测的准确率。

2.7 不同数据集对模型效果的影响分析

为进一步验证本文模型的泛化性,增加中国其他地区某风电场的2020年1月和8月的实际数据进行仿真,采样间隔为15 min,前29 d作为训练集,后2 d作为测试集。1月和8月的原始风电功率数据如图11所示。




图11 1月和8月的原始风电功率数据

Fig. 11 Raw wind power data for January and August

使用第2.6节中提到的所有组合模型进行预测和对比,各组合模型在1月和8月两个数据集上的预测结果如图12所示,其预测的误差和时间指标如表6所示。

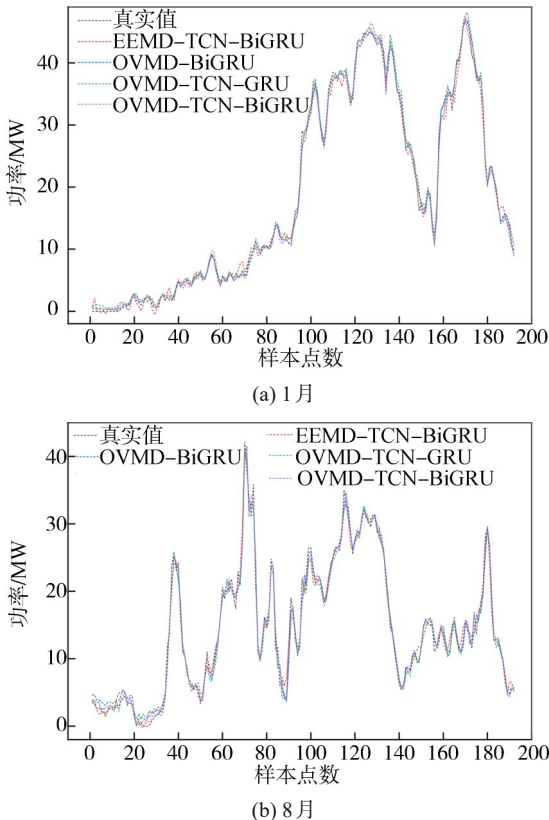


图12 各模型在1月和8月两个数据集的预测结果

Fig. 12 Prediction results of models for two datasets in January and August

表6 各模型1月和8月预测的评价指标结果

Tab. 6 Evaluation indicators predicted by models in January and August

月份	模型	RMSE/ MW	MAE/ MW	MAPE/%	时间/s
1	OVMD-BiGRU	0.868	0.663	2.879	161.030
	EEMD-TCN-BiGRU	1.117	0.862	4.553	1572.790
	OVMD-TCN-GRU	1.138	0.955	2.579	647.175
	OVMD-TCN-BiGRU	0.780	0.585	2.022	668.792
8	OVMD-BiGRU	1.233	0.921	3.756	179.898
	EEMD-TCN-BiGRU	1.252	0.966	5.746	1599.200
	OVMD-TCN-GRU	1.111	0.701	3.456	624.302
	OVMD-TCN-BiGRU	0.835	0.622	2.222	657.148

由图12可以看出:各模型的预测结果均接近真实值,都能够预测出真实功率的大概变化趋势,但本文OVMD-TCN-BiGRU模型比其他模型更接近真实值。从表6中也可以看出,在1月、8月两个数据集,本文OVMD-TCN-BiGRU模型的耗时略高于OVMD-BiGRU模型的耗时,其原因在于本文模型的结构相对复杂导致耗时更多,但本文模型的误差评价指标均比其他模型更小。综合考虑,本文模型具有很好的泛化性和准确性。

3 结论

针对风力发电过程中的非平稳性和波动性,以BWO优化的VMD和TCN-BiGRU为基础,建立适用于风力发电系统的短期风力发电功率预测模型。通过利用VMD算法将原始风电功率数据进行分解,本文模型可以大幅度减少序列的复杂性和波动性。本文利用BWO算法对VMD的参数进行寻优,将样本熵和误差重构两种指标作为适应度函数,并综合考虑这两个指标,有利于获得更优的VMD分解结果,使分解得到的分量质量更高、误差更小。通过仿真对比优化算法发现,与其他两种优化算法相比,本文使用的BWO优化算法表现更加稳定;同时,OVMD方法结合了BWO的优势,提升了分解质量效果显著。

本文构建的OVMD-TCN-BiGRU组合预测模型将TCN和BiGRU共同作为神经网络模型,在风电功率预测方面具有强大的建模能力和高效性,可以有效捕捉时间序列数据中的特征和依赖关系,提高了预测的准确性和稳定性。仿真结果表明,本文的OVMD-TCN-BiGRU模型展现出良好的准确性与稳定性。

未来,将进一步研究风电功率预测中气象特征提取与预测模型,以提高相关的气象特征的提取精确

率;对预测模型进一步优化,使得预测更精确。

参考文献:

- [1] Xiao Yulong,Zou Chongzhe,Chi Hetian,et al.Boosted GRU model for short-term forecasting of wind power with feature-weighted principal component analysis[J].Energy,2023,267:126503.
- [2] Huang Ling,Li Linxia,Cheng Yu,et al.Short-term wind power prediction based on SAM-WGAN-GP[J].Acta Ener-giae Solaris Sinica,2023,44(4):180-188.[黄玲,李林霞,程瑜,等.基于SAM-WGAN-GP的短期风电功率预测[J].太阳能学报,2023,44(4):180-188.]
- [3] Sun Rongfu,Zhang Tao,He Qing,et al.Review on key technologies and applications in wind power forecasting[J].High Voltage Engineering,2021,47(4):1129-1143.[孙荣富,张涛,和青,等.风电功率预测关键技术及应用综述[J].高电压技术,2021,47(4):1129-1143.]
- [4] Krishna Rayi V,Mishra S P,Naik J,et al.Adaptive VMD based optimized deep learning mixed kernel ELM autoen-coder for single and multistep wind power forecasting[J].Energy,2022,244:122585.
- [5] Li Guoquan,Gao Jianyu,Bai Tianyu,et al.Wind power pre-diction based on improved crow search algorithm and sup-port vector machine[J].Foreign Electronic Measurement Technology,2022,41(2):40-45.[李国全,高建宇,白天宇,等.基于SVM与改进型乌鸦搜索算法的风电功率预测方法[J].国外电子测量技术,2022,41(2):40-45.]
- [6] Lahouar A,Ben Hadj Slama J.Hour-ahead wind power fore-cast based on random forests[J].Renewable Energy,2017,109:529-541.
- [7] Liu Xing,Wang Yan, Ji Zhicheng.Short-term wind power prediction method based on random forest[J].Journal of Sys-tem Simulation,2021,33(11):2606-2614.[刘兴,王艳,纪志成.基于随机森林的风电功率短期预测方法[J].系统仿真实学报,2021,33(11):2606-2614.]
- [8] Niu Zhewen,Yu Zeyuan,Li Bo,et al.Short-term wind pow-er forecasting model based on deep gated recurrent unit neu-ral network[J].Electric Power Automation Equipment,2018,38(5):36-42.[牛哲文,余泽远,李波,等.基于深度门控循环单元神经网络的短期风功率预测模型[J].电力自动化设备,2018,38(5):36-42.]
- [9] Wang Yucheng,Zeng Xianwen,Gao Guige.Short-term fore-cast model of wind power based on GRU network[J].In-strumentation Technology,2020(1):9-12.[王雨城,曾宪文,高桂革.基于GRU网络的风功率短期预测模型[J].仪表技术,2020(1):9-12.]
- [10] Niksa-Rynkiewicz T,Stomma P,Witkowska A,et al.An in-telligent approach to short-term wind power prediction us-ing deep neural networks[J].Journal of Artificial Intelli-gence and Soft Computing Research,2023,13(3):197-210.
- [11] Guo Ling,Xu Qingshan,Zheng Le.A forecasting method for short-term load based on TCN-GRU model[J].Electric Power Engineering Technology,2021,40(3):66-71.[郭玲,徐青山,郑乐.基于TCN-GRU模型的短期负荷预测方法[J].电力工程技术,2021,40(3):66-71.]
- [12] 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.[吴慧军,郭超雨,苏承国,等.基于EE-MD-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.]
- [13] Xu Wu,Liu Yang,Shen Zhifang,et al.Short-term wind pow-er prediction based on VMD-GRU model with improved local self-attention mechanism[J].Power System and Clean Energy,2023,39(3):83-92.[徐武,刘洋,沈智方,等.基于改进局部自注意力机制的VMD-GRU模型短期风电功率预测[J].电网与清洁能源,2023,39(3):83-92.]
- [14] Ding Tong,Fu Xiaojin,Liu Mingwang.Research on wind power prediction based on GA-VMD-BiLSTM algorithm [J].Journal of Yangzhou University(Natural Science Edi-tion),2022,25(4):44-49.[丁同,傅晓锦,刘明旺.基于GA-VMD-BiLSTM算法的风电功率预测[J].扬州大学学报(自然科学版),2022,25(4):44-49.]
- [15] Wang Xiaodong,Li Shanshan,Liu Yingming,et al.Ultra-short-term wind power prediction based on variable fea-ture weight[J].Acta Ener-giae Solaris Sinica,2023,44(2):52-58.[王晓东,栗杉杉,刘颖明,等.基于特征变权的超短期风电功率预测[J].太阳能学报,2023,44(2):52-58.]
- [16] He Kunmin,Wang Xiao,Yang Jing,et al.Fault diagnosis of wind turbine gearbox based on RF feature optimization and WOA-ELM[J].Electronic Measurement Technology,2023,46(5):57-64.[何坤敏,王霄,杨靖,等.基于RF特征优选和WOA-ELM的风电齿轮箱故障诊断[J].电子测量技术,2023,46(5):57-64.]
- [17] Zeng Liang,Lei Shumin,Wang Shanshan,et al.Ultra-short-term wind power prediction based on OVMD-SSA-DE-LM-GM model[J].Power System Technology,2021,45(12):4701-4710.[曾亮,雷舒敏,王珊珊,等.基于OVMD-SSA-DELM-GM模型的超短期风电功率预测方法[J].电网技术,2021,45(12):4701-4710.]
- [18] Lu Peng,Ye Lin,Pei Ming,et al.Short-term wind power forecasting based on meteorological feature extraction and optimization strategy[J].Renewable Energy,2022,184:642-661.
- [19] Zhong Changting,Li Gang,Meng Zeng.Beluga whale opti-mization: A novel nature-inspired metaheuristic algorithm [J].Knowledge-Based Systems,2022,251:109215.

- [20] Zhu Juxiang, Gu Wei, Qian Wei, et al. Modeling of air quality prediction based on IF-SVMD-BWO-LSTM[J]. *China Measurement & Test*, 2024, 50(11): 173–184. [朱菊香, 谷卫, 钱炜等. 基于 IF-SVMD-BWO-LSTM 的空气质量预测建模[J]. *中国测试*, 2024, 50(11): 173–184.]
- [21] Wang Rui, Xu Xinchao, Lu Jing. Short-term wind power prediction based on SSA optimized variational mode decomposition and hybrid kernel extreme learning machine [J]. *Information and Control*, 2023, 52(4): 444–454. [王瑞, 徐新超, 逯静. 基于麻雀搜索算法优化变分模态分解和混合核极限学习机的短期风电功率预测[J]. *信息与控制*, 2023, 52(4): 444–454.]
- [22] Li Lei, Lin Shan, Jia Jiehui. Short-term load forecasting based on TCN-attention neural network[J]. *Electric Power Information and Communication Technology*, 2023, 21(3): 10–16. [李磊, 林珊, 贾颀辉. 基于 TCN-Attention 神经网络的短期负荷预测[J]. *电力信息与通信技术*, 2023, 21(3): 10–16.]
- [23] Zhao Xingyu, Wu Qianjun, Zhu Wei. Short-term power load forecasting based on CEEMDAN and TCN-LSTM model[J]. *Science Technology and Engineering*, 2023, 23(4): 1557–1564. [赵星宇, 吴泉军, 朱威. 基于 CEEMDAN 和 TCN-LSTM 模型的短期电力负荷预测[J]. *科学技术与工程*, 2023, 23(4): 1557–1564.]
- [24] Zhou Jianguo, Wei Siti. Hybrid carbon price prediction model based on time convolution neural network and double-scale feature selection[J]. *Electric Power Science and Engineering*, 2023, 39(4): 41–49. [周建国, 韦斯梯. 基于时间卷积神经网络和双尺度特征选择的混合碳价预测模型[J]. *电力科学与工程*, 2023, 39(4): 41–49.]
- [25] Su Liancheng, Zhu Jiaojiao, Li Yingwei. Short-term wind power prediction based on temporal convolutional network residual correction model[J]. *Acta Energetica Sinica*, 2023, 44(7): 427–435. [苏连成, 朱娇娇, 李英伟. 基于时间卷积网络残差校正的短期风电功率预测[J]. *太阳能学报*, 2023, 44(7): 427–435.]
- [26] Zhu Ruijin, Liao Wenlong, Wang Yusen. Short-term prediction for wind power based on temporal convolutional network[J]. *Energy Reports*, 2020, 6: 424–429.
- [27] Liang Lu, Liu Yuanlong, Liu Shaohua, et al. Research on short-term load forecasting of power system based on ECA-TCN[J]. *Proceedings of the CSU-EPSCA*, 2022, 34(11): 52–57. [梁露, 刘远龙, 刘韶华, 等. 基于 ECA-TCN 的电力系统短期负荷预测研究[J]. *电力系统及其自动化学报*, 2022, 34(11): 52–57.]
- [28] Wang Chenyang, Duan Qianqian, Zhou Kai, et al. A hybrid model for photovoltaic power prediction of both convolutional and long short-term memory neural networks optimized by genetic algorithm[J]. *Acta Physica Sinica*, 2020, 69(10): 143–149. [王晨阳, 段倩倩, 周凯, 等. 基于遗传算法优化卷积长短记忆混合神经网络模型的光伏发电功率预测[J]. *物理学报*, 2020, 69(10): 143–149.]
- [29] Liu Hui, Ling Ningqing, Luo Zhiqiang, et al. Power grid short-term load forecasting method based on TCN-LSTM and meteorological similar day sets[J]. *Smart Power*, 2022, 50(8): 30–37. [刘辉, 凌宁青, 罗志强, 等. 基于 TCN-LSTM 和气象相似日集的电网短期负荷预测方法[J]. *智慧电力*, 2022, 50(8): 30–37.]
- [30] Yang Fei, Liu Yang, Chang Suoliang, et al. Pre-stack seismic porosity prediction method based on bidirectional GRU and attention mechanism[J]. *Geophysical Prospecting for Petroleum*, 2024, 63(3): 598–609. [杨菲, 刘洋, 常锁亮, 等. 基于双向 GRU 和注意力机制的叠前地震孔隙度预测方法[J]. *石油物探*, 2024, 63(3): 598–609.]
- [31] Jia Taorong, Yao Lixiao, Yang Guoqing, et al. A short-term power load forecasting method of based on the CEEMDAN-MVO-GRU[J]. *Sustainability*, 2022, 14(24): 16460.
- [32] Zeng Liang, Di Feichao, Lan Xin, et al. Short-term wind power prediction based on CEEMD-CNN-BiGRU-RF model[J]. *Renewable Energy Resources*, 2022, 40(2): 190–195. [曾亮, 狄飞超, 兰欣, 等. 基于 CEEMD-CNN-BiGRU-RF 模型的短期风电功率预测[J]. *可再生能源*, 2022, 40(2): 190–195.]
- [33] Wu Junyue, Zhao Ergang, Guo Zengliang, et al. Ultra-short-term photovoltaic power multi-step prediction based on spearman coefficient and TCN[J]. *Acta Energetica Sinica*, 2023, 44(9): 180–186. [吴玥玥, 赵二刚, 郭增良, 等. 基于 Spearman 系数和 TCN 的光伏出力超短期多步预测[J]. *太阳能学报*, 2023, 44(9): 180–186.]

Short-term Wind Power Forecasting Based on BWO-VMD and TCN-BiGRU

LU Jing, ZHANG Yanru, WANG Rui*

(School of Computer Science and Technology, Henan Polytechnic University, Jiaozuo 454000, China)

Abstract:

Objective Under the guidance of the “dual carbon” target, wind power, as a critical component of clean energy, plays a crucial role in its efficient utilization. Short-term wind power forecasting helps improve grid stability, optimize wind farm power generation plans, and reduce operating costs, enhancing the economic benefits of wind power and supporting the goals of low-carbon development. In addition, the prediction results

provide valuable reference information for wind farms, assist the dispatching department in adjusting the generation plan in advance, reduce the impact of wind power grid connection on the grid, and ensure the safe operation of the power system. Given the instability and high volatility of wind power generation, this study proposes a short-term wind power prediction method based on BWO-VMD and TCN-BiGRU to improve the accuracy of wind power prediction and better support the energy transition under the “dual carbon” strategy.

Methods A short-term wind power generation prediction model based on the beluga whale optimization (BWO) algorithm, variational mode decomposition (VMD), temporal convolutional network (TCN), and bidirectional gated recurrent unit (BiGRU) was carefully proposed to improve the prediction accuracy of wind power generation, particularly considering its inherent instability and high volatility. Firstly, considering the comprehensive and complex impact of various meteorological factors on wind power generation, the random forest (RF) method was employed. This involves a comprehensive process of carefully determining the importance of various meteorological factor characteristics, systematically and accurately ranking them, and then extracting the truly optimal features that have a significant impact on subsequent predictions. Secondly, VMD is effectively utilized to decompose raw power data, which is originally in a non-stationary sequence, into relatively stationary subsequences. However, due to its complexity, it is difficult to manually determine the two parameters. Therefore, the BWO algorithm began optimizing these parameters of VMD. On this basis, a comprehensive index combining sample entropy and VMD decomposition to reconstruct the errors of each order component is used as a fitness function. Through this method, a thorough search was conducted to identify the optimal parameter combination. Then, the optimized VMD (OVMD) is utilized to decompose non-stationary power signals. Then, the decomposed stationary subsequence is combined with carefully extracted optimal features and input into the TCN-BiGRU combination model for prediction. This combination model aims to use the advantages of TCN and BiGRU to process data and make more accurate predictions. Finally, the predicted values of each subsequence are sequentially stacked to obtain the result, which is expected to provide reliable predictions for wind power generation.

Results and Discussions The RF algorithm is strategically employed to screen meteorological features and systematically rank their importance, enabling the accurate selection of features that significantly impact wind power forecasting. The experimental results indicate that wind speeds at vertical heights of 10, 30, and 50 m from the ground play an important role in influencing the accuracy of wind prediction. VMD is adopted to address the non-stationarity of wind power generation; however, manually determining its two parameters has proven to be challenging. Therefore, the BWO is proposed to optimize these parameters, with sample entropy and error reconstruction serving as key fitness function indicators. Compared to other optimization algorithms such as genetic algorithm (GA) and whale optimization algorithm (WOA), the BWO algorithm demonstrates significant performance, with faster running speed, stronger stability, and greater robustness. Then, the optimized VMD is utilized to decompose the non-stationary power signal, resulting in higher-quality subsequences and ultimately improving prediction accuracy. The dataset is carefully divided into a training set, a validation set, and a testing set to verify the accuracy of the model. This study selects a single model to compare the BiGRU network model and the OVMD-TCN-BiGRU combination model proposed in this study with other combination models for experimental analysis. Through the graph, error evaluation indicators, and time indicators, the experimental results show that although the time of the proposed model is not optimal, its error evaluation indicator value is the smallest, highlighting its advantages. In addition, experiments are conducted not only on the main dataset but also extended to January and August data, which represent seasonal differences, for generalization to verify the re-liability and broad applicability of the model. The verification results indicate that the constructed model effectively handles various datasets and complex time series features, with strong robustness and generality, and can run stably and efficiently in various practical scenarios.

Conclusions The decomposition of raw wind power data is primarily examined using the OVMD algorithm in this study. The meteorological factors selected by combining the decomposed sub-components with RF features are input into the TCN-BiGRU model for prediction. Their respective advantages are integrated to enhance the accuracy and stability of the prediction. The experimental results indicated that applying this series of methods improves the prediction accuracy. Its capacity to manage complex time series data is demonstrated, and the advancement and innovation of algorithms and models are supported. New directions for technological progress and practical application in the field of wind power prediction are established.

Key words: short-term wind power prediction; variational mode decomposition; random forest; temporal convolutional network; bidirectional gate recurrent unit; beluga whale optimization

(编辑 赵婧)

引用格式: Lu Jing,Zhang Yanru,Wang Rui.Short-term wind power forecasting based on BWO-VMD and TCN-BiGRU[J].
Advanced Engineering Sciences,2025,57(3):31-41.[逯静,张燕茹,王瑞.基于BWO优化VMD和TCN-BiGRU的短期风电
功率预测[J].工程科学与技术,2025,57(3):31-41.]