

基于 VMD-TCN-BIGRU 的超短期功率预测

林志辉^{1,2}, 刘丽桑^{1,2}, 张立伟^{1,2}, 陈文伟^{1,2}

(1. 福建理工大学 电子电气与物理学院, 福建 福州 350118;

2. 福建省工业集成自动化行业技术开发基地, 福建 福州 350118)

摘要: 为提高电力系统超短期功率预测的准确性, 提出了一种基于变分模态分解(VMD)和时序卷积网络-双向门控循环单元(TCN-BIGRU)的预测模型。通过灰狼优化算法(GWO)优化 VMD 的模态数量和惩罚因子, 以提升信号分解质量并减少噪声干扰。将分解后的模态与基于皮尔逊相关系数提取的特征向量输入 TCN-BIGRU 模型, 提取时间序列的短期与长期依赖特征, 从而提升预测准确性。实验结果显示, 该模型的预测精度达 99.144%, 优于传统单一模型及其他组合模型, 在应对非线性与波动性数据上适应性更强、预测误差更低。

关键词: 灰狼优化算法; 变分模态分解; 时序卷积网络; 双向门控循环单元

中图分类号: TM715

文献标志码: A

文章编号: 2097-3853(2025)04-0374-08

Ultra-short-term power prediction based on VMD-TCN-BIGRU

LIN Zhihui^{1,2}, LIU Lisang^{1,2}, ZHANG Liwei^{1,2}, CHEN Wenwei^{1,2}

(1. School of Electronic, Electrical and Physics, Fujian University of Technology, Fuzhou 350118, China;

2. Technical Development Base of Industrial Integration Automation of Fujian Province, Fuzhou 350118, China)

Abstract: To improve the accuracy of ultra-short-term power prediction in power systems, a prediction model is proposed based on variational mode decomposition (VMD) and temporal convolutional network-bidirectional gated recurrent unit (TCN-BiGRU). The grey wolf optimizer (GWO) is used to optimize the number of modes and the penalty factor of VMD, aiming to enhance the quality of signal decomposition and reduce noise interference. The decomposed modes and the feature vectors extracted based on the Pearson correlation coefficient are input into the TCN-BiGRU model to extract short-term and long-term dependence features of time series, thereby improving the prediction accuracy. Experimental results show that the prediction accuracy of this model reaches 99.144%, which is superior to that of traditional single models and other combined models. It has stronger adaptability in dealing with nonlinear and volatile data and has lower prediction error.

Keywords: grey wolf optimizer (GWO); variational mode decomposition (VMD); temporal convolutional network (TCN); bidirectional gated recurrent unit (BGRU)

风能的间歇性和不稳定性使风电功率预测颇具挑战, 准确的风电功率预测有利于电网调度、降低发电成本、提升交易效率、推动可再生能源整合与碳减排等^[1-2]。

近年来, 深度学习方法在负荷预测领域得到了广泛应用, 并取得了显著成果^[3]。常见的深度学习算法有循环神经网络(RNN)、卷积神经网络(CNN)、长短期记忆神经网络(LSTM)和门控循环

单元(GRU)等。文献[4]提出了一种基于小波变换的DRNN模型, 提升了DRNN的预测精度。文献[5]提出了一种基于CNN的区域风功率预测方法, 其精度也高于传统的预测模型。文献[6]提出了基于北方苍鹰优化算法(NGO)优化LSTM的短期功率预测模型, 提高了LSTM的预测精度和收敛速度。文献[7]使用方差过滤重构并进行主成分分析进行降维, 再将特征向量输入

收稿日期: 2024-09-24

第一作者简介: 林志辉(1998—), 男, 福建漳州人, 硕士研究生, 研究方向: 新能源预测。

通信作者: 刘丽桑(1984—), 女, 福建莆田人, 副教授, 博士, 研究方向: 智能配网及新能源出力预测。

GRU 模型实现高精度预测。

随着深度学习的发展,国内外的学者们越来越多地采用组合预测的方法来提高预测模型的精度和稳定性^[8],通过融合多个模型的优点与采用联合学习策略,可以克服单一模型的局限,提高预测精确度。王佳钰等^[9]提出一种基于GRU-LSTM的功率预测模型,通过指数平滑法处理提升了功率数据集的可靠性和平滑度,从而提升了数据分析的准确性,但该模型并未对数据进行分解,缺乏多尺度分析导致其处理复杂的信号时预测性能可能下降。孔祥玉等^[10]提出一种特征相关性分析结合最小二乘支持向量机模型,但因其采用的是经验模态分解(EMD),一定程度上会产生模态混叠现象。郭玲等^[11]提出的基于TCN-BIGRU的预测模型在短期负荷预测上提高了精度。为了避免模态混叠,Guanchen Ge等^[12]提出一种基于PSO-VMD与注意力机制结合的TCN模型,但该模型输入只有功率序列,可能导致其过度依赖历史数据,泛化能力差。

综上所述,本研究提出一种GWO-VMD-TCN-BiGRU模型,通过优化VMD的模态数量和惩罚因子有效适应数据特征并提升预测性能;结合TCN-BiGRU网络对各模态分量进行预测并叠加,进一步提高预测准确性。

1 基本原理

1.1 灰狼算法

灰狼优化算法(GWO)^[13]模仿灰狼群体捕猎行为,通过灰狼层级结构进行全局搜索和局部探索,在优化时通过模拟不同狼的定位进行搜索。其中, α 狼负责控制和决策; δ 狼担任不同的功能角色; β 狼作为连接 α 和 δ 之间的桥梁;而 ω 狼则负责保持群体的平衡。

灰狼的捕猎策略分为围捕、追踪和攻击猎物共3个阶段。

首先对猎物进行围捕,如式(1)所示。

$$\begin{cases} D_{\vec{X}} = |\vec{C} \cdot \vec{X}_{\text{prey}} - \vec{X}(t)| \\ \vec{X}(t+1) = \vec{X}_{\text{prey}} - \vec{A} \cdot D_{\vec{X}} \\ \vec{A} = 2 \cdot \vec{a} \cdot \vec{r}_1 - \vec{a} \\ \vec{C} = 2 \cdot \vec{r}_2 \end{cases} \quad (1)$$

式中, $\vec{X}(t)$ 表示当前灰狼的位置, $\vec{X}(t+1)$ 为灰狼

位置的更新, $\vec{X}_{\text{prey}}$ 是猎物的位置, $D_{\vec{X}}$ 为当前灰狼与猎物的距离。 $\vec{A}$ 和 $\vec{C}$ 是两个用于控制围捕行为的系数向量。其中, $\vec{a}$ 随着迭代次数从2线性减少到0,灰狼逐渐从大范围的全局搜索转向对局部解的精细搜索, $\vec{r}_1, \vec{r}_2$ 均是 $[0, 1]$ 的随机数。

其次是追踪阶段,计算灰狼与 α 狼、 β 狼和 δ 狼的距离,如式(2)所示。

$$\begin{cases} D_{\alpha} = |\vec{C}_1 \cdot \vec{X}_{\alpha} - \vec{X}| \\ D_{\beta} = |\vec{C}_2 \cdot \vec{X}_{\beta} - \vec{X}| \\ D_{\delta} = |\vec{C}_3 \cdot \vec{X}_{\delta} - \vec{X}| \end{cases} \quad (2)$$

式中, $D_{\alpha}, D_{\beta}, D_{\delta}$ 分别代表 α, β, δ 狼各自与其他个体之间的距离, $\vec{X}_{\alpha}, \vec{X}_{\beta}, \vec{X}_{\delta}$ 代表 α, β, δ 狼各自的位置。

更新当前狼的位置为:

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

其中,

$$\begin{cases} \vec{X}_1 = \vec{X}_{\alpha} - \vec{A}_1 \cdot D_{\alpha} \\ \vec{X}_2 = \vec{X}_{\beta} - \vec{A}_2 \cdot D_{\beta} \\ \vec{X}_3 = \vec{X}_{\delta} - \vec{A}_3 \cdot D_{\delta} \end{cases} \quad (4)$$

式中, $\vec{X}_1, \vec{X}_2, \vec{X}_3$ 分别代表当前狼受到 α, β, δ 狼的影响。

最后是攻击阶段。当系数向量 $\vec{A}$ 的值趋近于0时,灰狼开始发起攻击,逐渐收敛到猎物的位置,优化出精确的解。

1.2 VMD 分解原理

VMD^[14]不同于传统的经验模态分解(EMD),其核心在于通过解决变分问题,自适应地同时估计多个模态的频率和窄带信号。

VMD的目标是将输入信号 $f(t)$ 分解为 K 个子信号或模态 $u_k(t)$,使得每个模态具有窄带特性,这些模态的和能够重构原始信号,如式(5)所示。

$$f(t) = \sum_{k=1}^K u_k(t) \quad (5)$$

式中,每个模态 $u_k(t)$ 对应于一个中心频率 ω_k 并且带宽最小。

VMD通过最小化各模态的带宽来实现信号分解。其优化目标是 minimized 各模态在其中心频率附近的频谱带宽,可以表示为:

$$\min_{\{u_k\}, \{\omega_k\}} \sum_{k=1}^K \|\partial_t [u_k(t) \cdot e^{-j\omega_k t}]\|_2^2 \quad (6)$$

式中, ∂_t 是时间导数算子; j 是虚数单位; ω_k 是第 K 个模态的中心频率; $u_k(t)$ 是第 K 个模态函数。

VMD 采用 Hilbert 变换将每个模态 $u_k(t)$ 转换为其解析信号, 以提取频谱信息。随后, 通过指数调制将每个模态移动到基频上, 以分析其带宽, 如式(7)(8)所示。

$$\hat{u}_k(t) = \left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \quad (7)$$

$$u_k^{\text{mod}}(t) = \hat{u}_k(t) \cdot e^{-j\omega_k t} \quad (8)$$

其中, $\hat{u}_k(t)$ 是 $u_k(t)$ 的 Hilbert 变换; $u_k^{\text{mod}}(t)$ 是调制后的信号。

VMD 采用交替方向乘子法 (ADMM) 来迭代求解模态函数 $u_k(t)$ 和中心频率 ω_k 。这一过程可以概括为初始化、更新模态函数和更新中心频率 3 个步骤。

首先, 初始化。设定初始模态函数 $u_k^0(t)$ 和中心频 ω_k^0 。

接着, 更新模态函数。在固定中心频率 ω_k 的情况下, 求解更新后的模态函数 $u_k^{n+1}(t)$, 使得其带宽最小。

然后, 更新中心频率。在固定模态函数 $u_k^{n+1}(t)$ 的情况下, 重新计算中心频率 ω_k^{n+1} , 如式(9)所示。

$$\omega_k^{n+1} = \frac{\int_0^\infty \omega \cdot |U_k^{n+1}(\omega)|^2 d\omega}{\int_0^\infty |U_k^{n+1}(\omega)|^2 d\omega} \quad (9)$$

重复上述步骤, 直到各模态函数和中心频率的变化量小于设定的收敛条件。

经过若干次迭代后, 最终得到 K 个收敛的模态函数 $u_k(t)$ 及其对应的中心频率 ω_k 。

1.3 时序卷积网络

时序卷积网络 (TCN)^[15] 是一种用于处理序列数据的神经网络架构, 主要包括扩张因果卷积和残差模块。

1.3.1 扩张因果卷积

如图 1 所示, 扩张因果卷积模块通过不连续连接隐藏层神经元, 扩大其感受野而不额外增加权重。通过在卷积核元素之间引入间隔、扩张卷积能够捕捉更远的信息。随着扩张因子的增大, 卷积核的感受野进一步扩展, 使得网络能够捕捉到更加遥远的依赖关系。




图 1 扩张因果卷积结构

Fig.1 Dilated causal convolution structure

对于时间序列 x_t , 扩张因果卷积的公式为:

$$F(t) = \sum_{i=0}^{K-1} f(i) x_{t-di} \quad (10)$$

式中, $F(t)$ 表示时间步 t 的卷积输出; x_{t-di} 是输入序列在时间步 $t-di$ 处的值; $f(i)$ 是卷积核第 (i) 个位置的权重; d 是扩张因子 (空洞系数); K 是卷积核的大小。

通过扩张因果卷积, 可以在保持较高的计算效率的同时有效捕捉时间序列数据中的长期依赖关系。

1.3.2 残差连接

基于残差模块的堆叠, TCN 形成了深度网络结构, 末端使用全卷积层替代了传统全连接层。残差模块由一维扩张因果卷积构成, 并通过残差连接增强了网络表达能力, 有效缓解了梯度消失问题, 使其更适合处理时序数据。残差模块结构如图 2 所示。




图 2 残差连接结构

Fig.2 Residual connection structure

1.4 BIGRU

LSTM 能够处理长序列依赖关系,它通过引入遗忘门、输入门和输出门有效解决了 RNN 的梯度消失问题^[16],但其复杂的结构带来了较大的计算量。GRU 保留了 LSTM 的核心思想,使用更新门和重置门代替多个门控单元,在降低计算复杂度的同时,仍然能够处理长序列数据,其结构如图 3 所示。




图 3 GRU 网络结构

Fig.3 GRU network structure

GRU 的计算公式为:

$$\begin{cases} z_t = \sigma(W_z x_t + U_z h_{t-1} + b_z) \\ r_t = \sigma(W_r x_t + U_r h_{t-1} + b_r) \\ \tilde{h}_t = \tanh(W_h x_t + r_t \odot (U_h h_{t-1} + b_h)) \\ h_t = (1 - z_t) \odot h_{t-1} + z_t \odot \tilde{h}_t \end{cases} \quad (11)$$

其中, z_t 是更新门的输出; x_t 是当前时刻的输入; h_{t-1} 是前一时刻的隐藏状态; W_z 和 U_z 是权重矩阵; b_z 是偏置; σ 是 sigmoid 激活函数; r_t 是重置门的输出; W_r 和 U_r 是权重矩阵; b_r 是偏置; $\tilde{h}_t$ 是候选隐藏状态; $\odot$ 表示元素逐点相乘; h_t 是当前时刻的最终隐藏状态。

然而, GRU 只能处理单向序列信息, 无法充分利用双向依赖。BIGRU 引入双向结构, 同时处理从过去到未来和从未来到过去的序列信息, 增强了对上下文的理解能力并提升了预测效果, 其结构如图 4 所示。

2 风电输出功率预测组合模型

2.1 数据处理

为了减少数值过大或过小对算法造成的局部最优问题, 在训练和测试之前对变量数据进行归




图 4 BiGRU 网络结构

Fig.4 BiGRU network structure

一化处理, 将各个变量的数值限制在预定范围内, 以避免算法陷入局部最优, 公式为:

$$X_{\text{norm}} = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (12)$$

式中, X 是原始数据; $X_{\min}$ 和 $X_{\max}$ 分别是归一化前数据的最小值和最大值; X_{norm} 是归一化后的标准数据, 取值范围是 $[0, 1]$ 。

2.2 VMD-TCN-BIGRU 预测模型

由于原始风电输出功率表现出显著的非线性和非平稳性, 本研究首先使用 Pearson 相关性分析提取出相关性高的特征, 接着通过 GWO 优化惩罚因子和模态数进行 VMD 分解, 最后使用 TCN-BIGRU 进行预测。模型流程如图 5 所示。

2.3 评价指标

为检验 GWO-VMD-TCN-BIGRU 模型的优势, 采用 MAE、MAPE、RMSE 和 R^2 作为评价指标。MAE 和 MAPE 值越小, 预测模型的精度越高; RMSE 越小, 预测误差越小; R^2 越接近 1, 模型的拟合越好。计算方法如式 (13) ~ (16) 所示。

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (13)$$

$$\text{MAPE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \quad (14)$$

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (15)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (16)$$

式中, n 是样本数量; y_i 是实际值; $\hat{y}_i$ 是预测值; $\bar{y}$ 是实际值的均值。




图 5 VMD-TCN-BiGRU 预测流程图

Fig.5 Prediction flowchart of VMD-TCN-BiGRU

3 算例分析

3.1 数据来源

本研究使用新疆某地区 2019 年 2 月 1 日至 2 月 28 日的数 据,数据包含 10、30、50、70 m 的测风塔风速与风向、轮毂风速与风向、温度、气压、湿度、实际发电功率共 14 个参数,每隔 15 min 采一次数据。

3.2 数据相关性分析

在风力发电的过程中,监测的数据种类繁多,如风速、风向、气温和气压等参数,为了提高模型建模效率,可以通过计算 Pearson 来筛选输入变量。用 r 表示两组数据之间的关联程度, r 的公式为:

$$r = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} \quad (17)$$

式中, n 是数据点的数量; x_i 和 y_i 分别是第 i 个数据点的 X 和 Y 值; $\bar{x}$ 是 X 的样本均值; $\bar{y}$ 是 Y 的样本均值; r 越大,两组数据之间的关联程度越强。

当 r 为 0.8 以上时,表示两者具有极强相关

性; r 处于 0.6 到 0.8 之间表示强相关性; r 处于 0.4 到 0.6 之间表示中等相关性; r 处于 0.2 到 0.4 之间表示弱相关性; r 处于低于 0.2 表示相关性极弱。将 14 个参数分别设置为 $z_1 \sim z_{14}$ 。经过计算, $z_1 \sim z_4$ 与 z_{14} 的相关系数超过 0.8,具有极强的相关性,但是 $z_1 \sim z_4$ 两两之间具有极强的相关性,故选取其与 z_{14} 具有较强相关性的 $z_3, z_6 \sim z_9$ 选取 z_9 。模型最终输入的变量如表 1 所示。

表 1 功率序列与变量之间的相关系数
Tab.1 Correlation coefficients between power sequences and variables

变量	变量意义	相关系数
z_3	50 m 测风塔风速	0.83
z_5	轮毂风速	0.80
z_9	测风塔 70 m 风向	-0.65
z_{10}	轮毂风向	-0.42
z_{12}	气压	0.32

3.3 GWO 优化 VMD 参数

VMD 参数设置模态数量设过多,可能会产生噪声模态,导致模型复杂度增大并增加过拟合的风

险;设置过少则会导致 VMD 无法有效捕捉信号特征。为了提高分解准确性和模型预测性能,采用 GWO 对 VMD 参数进行优化。排列熵是一种衡量时间序列复杂度的方法,能够捕捉隐含的动态特征。通过计算不同排列模式的频率来衡量混乱程度,较低的熵值通常表示序列规律性较强,而较高的熵值则表明序列较为混乱,IMF 中包含更多噪声。通过 GWO 寻优后得到的熵值最小为 0.335 41 时, K 为 6, α 为 2 120。分解结果如图 6 所示。




图 6 VMD 分解结果

Fig.6 Results of VMD decomposition

3.4 模型比较及分析

将 BIGRU 模型与单一模型 CNN、LSTM、SVM、GRU 和 TCN 以及常见的组合模型对比。各模型的参数配置和调优结果如表 2 所示。其中,Nb_filters 表示在卷积层使用的滤波器数量;Kernel_size 表示每个卷积层的内核大小;Pool_size 指定池化层的窗口大小;Units 表示输出空间维度;Kernel 为指定卷积核类型; C 为误差项的惩罚参数;Gamma 控制单个训练样本在径向基函数(RBF)中的影响;Dilations 表示扩张列表;Nb_stacks 为网络中堆叠的卷积层数。表 2 所列的这些参数均已达到最佳效果。该数据集在各个单一模型的预测结果如图 7 所示。从图 7 可见,虽然各单一模型在整体数据预测中表现良好,但在波动性较大的区域效果并不佳。CNN 在处理槽型数据时表现出色,但面对频繁波动或复杂的非线性的数据时预测误差较大;SVM 只能捕捉大致的整体趋势;LSTM 在处理短期时间序列特征方面表现良好,但初始预测误差较大;TCN 能捕捉长时间依赖关系,但在数据呈现剧烈波动的情况下

预测误差较大。GRU 擅长处理短期或中期时间依赖数据。比起单一模型,组合模型精度更高、预测效果更好。BIGRU 的优势在于能够同时处理数据的前向和后向依赖,从而更好地捕捉序列中复杂的上下文依赖关系。从表 3 可以看出 BIGRU 预测模型的 MAPE 最低,为 9.2357%,明显优于其他单一模型,其他 3 个指标也表现更佳。

表 2 模型参数

Tab.2 Model parameters

模型	参数设置
CNN	Nb_Filters = 128; Kernel_size = 1; Pool_size = 1
LSTM	Units = 32
SVM	Kernel = 'rbf'; C = 290; Gamma = 0.001
GRU	Units = 32
TCN	Nb_stacks = 4; Dilations = (1, 2, 4, 8)
BIGRU	Units = 32




图 7 单一模型预测结果对比

Fig.7 Comparison of prediction results of single models

表 3 单一模型误差指标

Tab.3 Error metrics of single models

模型	RMSE/MW	MAE/MW	MAPE/%	R^2 /%
CNN	13.133 7	9.147 3	14.340 7	95.07 5
LSTM	17.661 1	14.008 2	19.065 8	91.205
SVM	17.080 5	11.453 1	19.444 3	91.609
GRU	12.212 9	8.060 4	13.330 9	95.732
TCN	12.538 8	7.363 6	13.134 2	95.48 3
BIGRU	8.936 1	6.260 6	9.235 7	97.70 1

对多种组合模型的预测结果进行对比,结果如图 8 所示。




图 8 组合模型预测结果对比

Fig.8 Comparison of prediction results of combined models

与 CNN-LSTM、CNN-SVM、CNN-BiLSTM 和 CNN-BIGRU 等组合模型相比,本研究提出的 GWO-VMD-TCN-BIGRU 模型在评价指标上表现最佳,如表 4 所示,其 MAPE、RMSE 最小,表明其预测精度最高、预测误差最小;此外,其 R^2 达到 99.144%,说明该模型拟合程度最高。

表 4 组合模型误差指标

Tab.4 Error metrics of combined models

模型	RMSE/MW	MAE/MW	MAPE/%	R^2 /%
CNN-LSTM	10.211 2	7.055 4	10.297	96.995
CNN-SVM	6.153 4	3.829 8	5.567 3	98.905
CNN-GRU	9.684 2	6.506	9.244 9	97.297
CNN-BiLSTM	6.892	4.843 6	6.136 3	98.628
CNN-BIGRU	7.273 8	5.079 5	6.202 7	98.471
GWO-VMD-TCN-BIGRU	5.443	3.689 5	5.526 2	99.144

3.5 消融实验

利用消融实验对模型的性能进行了比较,各组的模型参数设置一致,预测结果如图 9 所示。

通过表 5 可以看出,未进行 VMD 分解的数据可能包含更多的噪声和波动,导致误差较大且拟合度降低,凸显了 VMD 的重要性。加入 BIGRU

后预测模型各个指标进一步提升,表明 BIGRU 在模型中起到关键作用。通过消融实验,清晰显示出在各个模块的加入使误差降低,拟合度提升。其中, RMSE、MAE 以及 MAPE 较次优组合分别降低了 19.1%、17.8%、7.3%,误差更小、精度更高。




图 9 消融实验预测结果比较

Fig.9 Comparison of prediction results of ablation experiments

表 5 消融实验误差指标

Tab.5 Error metrics of ablation experiments

Group	VMD	TCN	BIGRU	RMSE/ MW	MAE/ MW	MAPE/ %	R^2 /%
1	—	✓	✓	10.260 3	8.079 6	9.730 1	96.99
2	✓	✓	—	9.456 1	7.905 4	8.387 9	97.446
3	✓	—	✓	6.728	4.485 3	5.932 2	98.692
4	✓	✓	✓	5.443	3.689 5	5.526 2	99.144

注:“✓”表示包含该模块;“—”表示不包含该模块

4 结论

为了解决波动性和非线性给电力系统中的超短期功率预测带来的挑战,提出了一种 GWO-VMD-TCN-BIGRU 的组合预测模型。通过多组实验对比分析得出以下结论:

1)通过皮尔逊相关系数对原始数据进行相关性分析,精准筛选与目标负荷高度相关的特征序列,有效消除冗余信息,降低维度,提升数据处理的效率。

2)引入 GWO 对 VMD 的参数进行自适应优化,克服传统人工设定参数的局限性,确保数据分解更为精准,捕捉时序数据中的复杂非线性动态

特征,实现分解质量的提升。

3)设计并集成 TCN 与 BIGRU,充分利用 TCN 在长时序依赖方面的优势,结合 BIGRU 在捕捉双向时间特征的能力,从 VMD 分解的子序列中提取深层时序特征,提升模型的表征能力与预测精度。

参考文献:

[1] 谢丽蓉,王斌,包洪印,等. 基于 EEMD-WOA-LSSVM 的超短期风电功率预测[J]. 太阳能学报,2021,42(7):290-296.

[2] KHALID M, SAVKIN A V. A method for short-term wind power prediction with multiple observation points[J]. IEEE Transactions on Power Systems, 2012, 27(2): 579-586.

[3] WANG K J, QI X X, LIU H D. Photovoltaic power forecasting based LSTM-convolutional network[J]. Energy, 2019, 189:116225.

[4] 杨伟玥,伏潜,万定生. 基于深度循环神经网络的时间序列预测模型[J]. 计算机技术与发展,2017,27(3):35-38,43.

[5] 查雯婷,杨帆,陈波,等. 基于 CNN 的区域风功率预测方法[J]. 计算机仿真,2021,38(5):318-323.

[6] CHEN P, LI J. Wind power prediction based on NGO-LSTM[C]//Journal of Physics: Conference Series. IOP Publishing, 2024, 2782(1): 012068.

[7] 赵全明,李珂,王笑欢,等. 基于 SSA-GRU 神经网络的超短期风电功率预测[J]. 传感器与微系统,2023,42(11):151-155.

[8] NIE Y,JIANG P,ZHANG H P. A novel hybrid model based on combined preprocessing method and advanced optimization algorithm for power load forecasting[J]. Applied Soft Computing,2020,97:106809.

[9] 王佳钰,郝思鹏,李森文,等. 基于 ES-GRU-LSTM 的风电场群功率预测[J]. 计算技术与自动化,2022,41(3):37-41.

[10] 孔祥玉,李闯,郑锋,等. 基于经验模态分解与特征相关分析的短期负荷预测方法[J]. 电力系统自动化,2019,43(5):46-52.

[11] 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] GENG G C, HE Y, ZHANG J, et al. Short-term power load forecasting based on PSO-optimized VMD-TCN-attention mechanism[J]. Energies, 2023, 16(12):4616.

[13] 张晓凤,王秀英. 灰狼优化算法研究综述[J]. 计算机科学,2019,46(3):30-38.

[14] 刘丽桑,郭凯琪,陈健,等. 基于 VMD-MWOA-ELM 的日前光伏功率预测[J]. 福建工程学院学报,2023,21(3):269-276.

[15] 钟璐,杨华,李世林,等. 基于二次分解和 JSO-TCN 模型的短期光伏功率预测[J]. 水力发电, 2024, 50(11): 74-80, 105.

[16] GAO H B, QIU S, FANG J, et al. Short-term prediction of PV power based on combined modal decomposition and NARX-LSTM-LightGBM[J]. Sustainability, 2023, 15(10):8266.

(责任编辑:方素华)