

DOI: 10.12158/j.2096-3203.2026.01.011

基于 Q-Learning 的多模态自适应光伏功率优化组合预测

隗知初^{1,2}, 杨苹^{1,2}, 周钱雨凡¹, 陈文皓¹, 万思洋¹, 崔嘉雁¹

(1. 华南理工大学电力学院, 广东 广州 510640; 2. 华南理工大学广东省绿色能源技术重点实验室, 广东 广州 510640)

摘要:针对光伏功率序列波动性强、随机性高的问题,文中提出一种基于 Q-Learning 的多模态自适应光伏功率优化组合预测模型。首先,采用鲸鱼优化算法的变分模态分解方法,将原始光伏功率序列分解成不同子模态,并通过集成特征筛选模型,确定各子模态序列最敏感的气象因素。然后,构建反向传播神经网络、双向长短期记忆网络、门控循环单元网络和时间卷积网络 4 种基础预测模型。考虑到不同模型对不同频率特征的子序列预测能力不同,利用 Q-Learning 算法自适应选择各模态对应的最优基础模型组合方式。最后,将不同子模态的预测结果叠加重构,得到最终预测结果,并利用高分辨率光伏气象功率数据集进行验证。结果证明,文中所提出的基于 Q-Learning 的多模态自适应光伏功率优化组合预测模型,相较于单一模型的预测误差平均绝对误差下降了 16.18%,均方误差下降了 17.00%。

关键词:鲸鱼优化算法;变分模态分解;Q-Learning;功率预测;组合模型;光伏发电

中图分类号:TM721

文献标志码:A

文章编号:2096-3203(2026)01-0115-10

0 引言

在双碳目标背景下,能源转型势在必行。太阳能作为清洁能源,其重要性日益凸显。截至 2024 年 3 月底,全国光伏发电装机容量达 6.59 亿 kW,其中集中式光伏为 3.79 亿 kW,分布式光伏为 2.8 亿 kW。光伏发电受气象条件影响显著,具有较强的波动性和不确定性,但准确的功率预测能够降低电网调度难度,提升系统运行稳定性,实现光伏电站的友好并网^[1-5]。同时,随着电力现货市场的逐步建立,高精度功率预测的需求不断增长,推动了功率预测服务市场的快速发展。

光伏阵列的输出功率受到气象条件的显著影响。为提升光伏功率预测模型的精度,国内外学者提出了多种预测方法,如基于气象数据和光伏板光电转换原理的物理模型^[6-9]。文献[10]采用长短期记忆(long short-term memory, LSTM)网络模拟太阳辐照度的变化,通过辐照度和发电量的关系,实现光伏功率的间接预测。

当前,光伏功率预测面临着气象条件复杂且耦合度高的问题,难以通过物理模型准确描述气象变量和光伏出力的关系。因此,主流预测方法主要基于数据驱动的神经网络模型^[11],然而,这类模型对

数据集质量的依赖性较高。为了提高预测精度,现有研究从模型输入和模型本身两个方面展开了广泛研究。

在模型输入方面,文献[12]考虑区域风光资源时空相关性,对数值天气预报(numerical weather prediction, NWP)数据进行修正,以提高输入数据的精度。然而,气象数据之间耦合度高,高维输入特征容易导致神经网络过拟合,从而降低预测准确率。文献[13]利用输入变量与光伏功率的 Spearman 相关系数进行特征选取,构建时间卷积网络(temporal convolutional network, TCN)模型进行光伏功率预测。文献[14]利用因果筛选方法进行特征选择,使得选择结果更具解释性。文献[15]利用主成分分析法提取关键影响因子,但是光伏功率序列存在波动性强、噪声高的问题。文献[16-18]利用变分模态分解(variational mode decomposition, VMD)对原始光伏功率序列进行分解,可有效降低功率的波动性。同时,由于光伏功率预测场景多变,与天气类型关联度高,文献[19-20]按照季节和天气类型对数据集进行划分,并基于气象相似性建立预测模型,提升预测的准确性。

在模型本身方面,神经网络模型的参数与预测效果密切相关。文献[21]利用蜜獾算法优化基于核的极限学习机(kernel based extreme learning machine, KELM)的正则化系数和核参数。文献[22]利用遗传算法(genetic algorithm, GA)优化反向传

收稿日期:2025-06-10;修回日期:2025-08-15

基金项目:国家重点研发计划资助项目(2023YFB4203102);广东省海洋经济发展(海洋六大产业)专项资金项目(GDNRC [2023]27)

播(back propagation, BP)神经网络的超参数,从而提升BP神经网络的预测性能。文献[16]利用射影算法对混合KELM中的核参数进行优化。为进一步提升模型在不同气象条件下的泛化能力,诸多研究结合多种模型的特点,采用串行或者并行的方式对模型进行组合。文献[23]利用卷积神经网络(convolutional neural network, CNN)对气象数据进行特征提取,再通过LSTM网络进行功率预测。文献[20, 24]将光伏功率序列分成不同的子序列,将不同子序列输入到不同模型,最后将不同模型得到的预测结果进行叠加重构,从而有效提升模型的泛化性能。文献[25]利用强化学习对组合模型的权重进行优化,从而提升组合预测模型的性能。

尽管已有研究采用VMD算法对光伏序列进行分解,但算法参数的选择具有主观性,导致分解效果不佳,影响后续预测模型的性能。此外,针对分解后的子序列进行预测时,普遍采用单一预测模型,忽略了分解后各序列的差异性。高频率序列包含较多噪声和短期波动,序列变化较快,预测较难;低频率序列包含趋势和长期波动,变化缓慢,预测相对容易。

为解决上述问题,文中提出一种基于Q-Learning的多模态自适应光伏功率优化组合预测模型。利用鲸鱼优化算法(whale optimization algorithm, WOA)优化VMD的参数,考虑不同频段功率序列特性,选择4种不同基础模型进行预测。在不同模态下,通过Q-Learning自适应选择基础模型的组合方式,动态调整和优化每个子序列的预测模型,避免过拟合和欠拟合,提高预测模型的鲁棒性和稳定性。

1 基于优化VMD算法的功率序列分解

光伏发电序列具有明显的日周期性和强烈的波动性,属于非平稳序列。将光伏出力数据从时域转换到频域内进行分解,可以有效捕捉光伏发电功率的非线性特征。同小波变换和经验模态分解相比,VMD^[16]具有较好的自适应能力,并且能够克服模态混叠现象,因此在光伏功率信号分解中得到了广泛应用。然而,VMD效果与模态数和惩罚因子息息相关,WOA^[26]是一种模仿自然界中鲸鱼捕食行为的群体智能优化算法,鲸鱼的捕食行为主要分为3种:(1)包围猎物;(2)发泡网攻击;(3)搜索捕食。

1.1 包围猎物

在VMD过程中,文中利用WOA对惩罚因子

α 和模态数 K 进行优化。将算法中的每个鲸鱼个体视为一个潜在解,其搜索空间设为二维空间。设第 t 次迭代最优鲸鱼个体的位置 $X_{best,t}$ 为 $(\alpha_{best,t}, K_{best,t})$,鲸鱼个体 i 在第 t 次迭代的位置 $X_{i,t}$ 为 $(\alpha_{i,t}, K_{i,t})$,在最佳鲸鱼个体的引导下,该个体 $X_{i,t+1}$ 在下次迭代的位置变化为 $(\alpha_{i,t+1}, K_{i,t+1})$,其表达式如下:

$$X_{i,t+1} = X_{best,t} - A_1 D \quad (1)$$

$$D = |C_1 X_{best,t} - X_{i,t}| \quad (2)$$

$$C_1 = 2r_2 \quad (3)$$

$$A_1 = 2a_{SL}r_1 - a_{SL} \quad (4)$$

式中: A_1 、 C_1 为系数向量; D 为当前个体与最优个体之间的距离; a_{SL} 为收敛因子,其取值从2线性下降到0; r_1 、 r_2 为[0,1]的随机向量。

1.2 发泡网攻击

发泡网攻击是座头鲸特有的捕食行为,在使用该种捕食方式时,可以用对数螺旋方程表达座头鲸与猎物之间的位置关系,现对该捕食行为建立数学模型如下:

$$X_{i,t+1} = D' e^{bl} \cos(2\pi l) + X_{best,t} \quad (5)$$

$$D' = |X_{best,t} - X_{i,t}| \quad (6)$$

式中: D' 为搜索个体与当前最优个体之间的距离; b 为螺旋形状参数; l 为一随机数,其取值均匀分布在[-1,1]之间。

在靠近猎物过程中,座头鲸可能存在两种捕食方式,故WOA根据捕食概率 p 选择发泡网攻击或者包围猎物,其选择方式如下:

$$X_{i,t+1} = \begin{cases} X_{best,t} - A_1 D & p < 0.5 \\ D' e^{bl} \cos(2\pi l) + X_{best,t} & p \geq 0.5 \end{cases} \quad (7)$$

1.3 搜索捕食

当 $|A_1|$ 的取值范围处于[-1,1]时,算法易陷入局部最优。为跳出局部最优解,保证所有可能的解空间都被鲸鱼充分搜索,根据自然界中鲸鱼搜索捕食的行为,扩大 $|A_1|$ 的取值范围。该过程虽然会使得鲸鱼偏离目标猎物,但是能够增强鲸鱼个体的全局搜索能力,数学模型如下:

$$X_{i,t+1} = X_{rand,t} - A_1 D'' \quad (8)$$

其中:

$$D'' = |C_1 X_{rand,t} - X_{i,t}| \quad (9)$$

式中: $X_{rand,t}$ 为第 t 次迭代的随机个体位置; D'' 为搜索个体与随机个体之间的距离。

文中利用WOA对VMD的参数进行优化,其分解流程如图1所示。

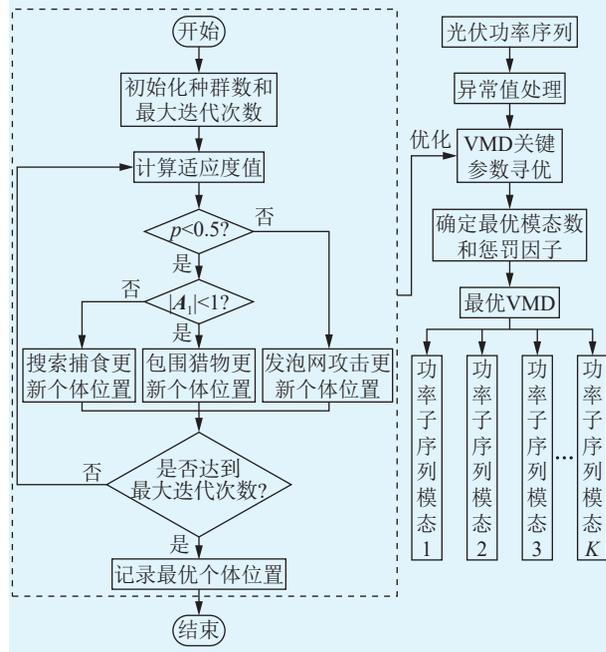


图 1 功率序列分解流程

Fig.1 Power series decomposition process

2 基于 Q-Learning 的自适应光伏功率预测

基于 Q-Learning 的光伏功率预测流程见图 2。

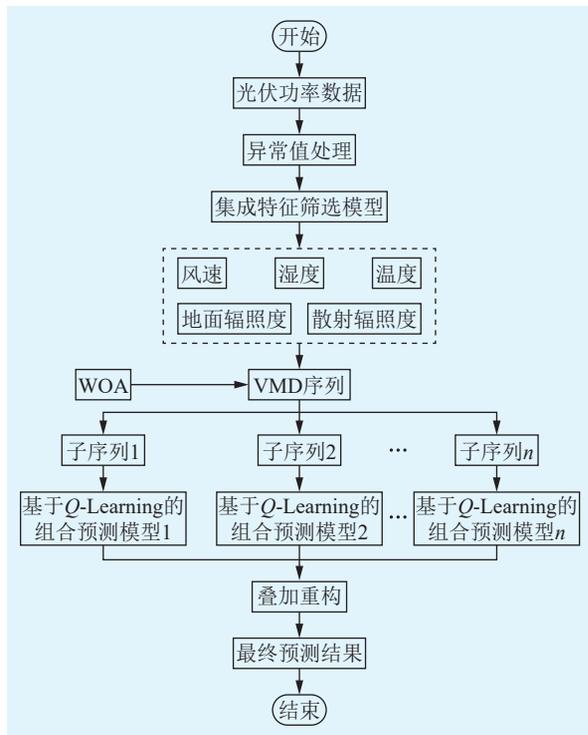


图 2 基于 Q-Learning 的光伏功率预测流程

Fig.2 Process of photovoltaic power forecasting based on Q-Learning

2.1 气象特征因子选取

2.1.1 基于 Pearson 相关系数计算相关性的方法

Pearson 相关系数^[27]又称 Pearson 积矩相关系

数, 常用于度量 2 个变量之间的线性关系, 其表达式如下:

$$r_p = \frac{\sum_{j=1}^n (X_j - \bar{X})(Y_j - \bar{Y})}{\sqrt{\sum_{j=1}^n (X_j - \bar{X})^2} \sqrt{\sum_{j=1}^n (Y_j - \bar{Y})^2}} \quad (10)$$

式中: X 、 Y 为样本中的 2 个序列; r_p 为序列 X 、 Y 的 Pearson 相关系数; \bar{X} 为样本 X 的均值; \bar{Y} 为样本 Y 的均值; X_j 、 Y_j 分别为 X 、 Y 序列中第 j 个样本。

2.1.2 基于 Spearman 相关系数计算相关性的方法

Spearman 相关系数是一种秩相关系数, 常用于衡量 2 个变量之间的关系, 其通过计算变量排名之间的相关性来评估 2 个变量的依赖性, 其表达式如下:

$$r_s = 1 - \frac{6 \sum_{j=1}^n d_j^2}{n(n^2 - 1)} \quad (11)$$

式中: r_s 为 2 个变量之间的 Spearman 相关系数; d_j 为排名之差, 即 $d_j = R(X_j) - R(Y_j)$, $R(\cdot)$ 为样本的排名。

2.1.3 基于随机森林计算相关性的方法

随机森林^[28]是一种集成学习方法, 通过构建多个决策树来提升模型的性能和稳定性, 不仅可以用于分类和回归任务, 还可以用于进行特征筛选。随机森林进行特征筛选的核心思想是通过综合所有树的信息增益, 评估每个特征的重要性。

这 3 种计算特征相关性的方法在不同特征选择场景下各有优劣。为了综合这些方法对线性、非线性、高耦合特征建模能力, 优化集成筛选模型的特征提取能力。文中建立一种集成特征筛选模型, 旨在获得更具灵活性且过拟合风险更低的筛选模型, 其表达式如下:

$$r_{j,m} = w_f r_{f,m} + w_p r_{p,m} + w_s r_{s,m} \quad (12)$$

式中: $r_{j,m}$ 为第 j 个样本第 m 个特征的重要性; $r_{f,m}$ 为第 m 个特征在随机森林模型下的重要性; $r_{p,m}$ 为第 m 个特征在 Pearson 系数模型下的重要性; $r_{s,m}$ 为第 m 个特征在 Spearman 系数模型下的重要性; w_f 、 w_p 、 w_s 为不同模型特征重要度所占权重。通过适当调整这些权重, 可以在不同特征选择方法之间达到平衡, 充分发挥各方法的优势, 提升模型的综合特征提取能力。考虑到随机森林具有强大的特征选择能力, 赋予其较高的权重, 设定为 0.4; Pearson 相关系数和 Spearman 相关系数分别衡量气象因子与目标变量之间的线性和非线性关系, 权重分别设定为 0.3。

图 3 为集中特征筛选的重要性评估结果。文中选择重要性排名前五的气象因子作为子模态模

型的输入特征,分别为风速、湿度、温度、地面辐照度、散射辐照度。



图3 集成特征筛选结果

Fig.3 Selection results of integrated feature

图4为基于 Pearson 系数的特征筛选的重要性评估结果,由于散射辐照度相关性仅为 0.080 0,其重要性较低,将被剔除。



图4 基于 Pearson 相关系数特征筛选结果

Fig.4 Selection results of Pearson correlation coefficient feature

故输入特征确定为地面辐照度、风速、湿度及温度。基于此特征集,利用传统预测模型多层感知机(multilayer perceptron, MLP)进行预测,结果如表1所示。其中 MAE 为平均绝对误差, MSE 为均方误差, R^2 为决定系数。

表1 两种特征筛选模型效果对比
Table 1 The performance comparison of two feature selection models

模型	MAE	MSE	R^2
基于Pearson相关系数特征筛选	0.714 4	0.758 4	0.862 3
集成特征筛选	0.638 4	0.618 8	0.887 6

由表1可知,相较于单一 Pearson 相关系数特征筛选的输入方案,采用集成特征筛选模型作为输入时,模型的预测精度更高。这表明,该集成特征筛选模型结合了随机森林、Pearson 相关系数和 Spearman 相关系数等多种特征选择方法,能够从多

个维度对特征进行评价,从而更全面地反映特征与目标变量之间的关系,提高特征选择的准确性。

2.2 基础模型选择及参数设定

BP 神经网络擅长捕捉非线性关系,适合于低频段数据的建模,但在处理高频段数据时能力有限。双向长短期记忆(bi-directional long short-term memory, BiLSTM)网络能够捕捉序列的长短期依赖关系,同时考虑过去和未来的信息,提高对低频段数据的预测准确性。门控循环单元(gated recurrent unit, GRU)结构简单、计算效率高,适合处理高频段数据的短期变化和低频数据的长期依赖。TCN^[29]采用膨胀卷积结构,捕捉长时间跨度的依赖关系,对低频段数据中的长期趋势和周期性变化建模效果明显。基于各模型在处理不同频率特征和时序依赖方面的互补优势,文中选择 BP、BiLSTM、GRU 和 TCN 作为组合模型的基础模型,如表2所示。

表2 4种网络模型参数设定

Table 2 Parameter settings of the four network models

模型	层数	各神经元个数	批次大小	优化器
BP	输入层+2隐藏层+输出层	128, 64	64	Adam
BiLSTM	输入层+2双向LSTM层+输出层	64, 64	64	Adam
GRU	输入层+2GRU层+输出层	64, 64	64	Adam
TCN	输入层+2卷积层+输出层	64, 64	64	Adam

2.3 基于 Q-Learning 的自适应光伏功率预测组合模型

考虑到光伏功率序列经 VMD 后生成多个子序列的频率特征存在差异,文中基于 Q-Learning 对不同模态下的基础模型进行自适应组合。将不同模态下预测模型的组合建模为马尔科夫决策过程,通过建立目标状态变量和动作变量之间关系的 Q 值表,并依据设定的奖励和惩罚机制不断迭代更新 Q 值表,直至满足迭代终止条件,获得最优 Q 值表。根据最优 Q 值表,为不同模态选择不同 BP 模型组合方式,从而提高组合模型的预测精度,其步骤如下。

(1) 定义状态空间和动作空间。

文中选择 BP、BiLSTM、GRU、TCN 4 种模型作为基础模型,状态空间定义为模型组合方法,其表达式如下:

$$S = [S_1 \ S_2 \ S_3 \ \dots \ S_z] \quad (13)$$

式中: S_z 为第 z 种状态组合方法。由于基础模型有 4 种,所以文中 $z=16$,其表达式如下:

$$S_z = M_{z,q} \quad q = 1, 2, 3, 4 \quad (14)$$

式中: $M_{z,q}$ 取值为 1 或 0,表示为第 z 种状态组合中是否选择第 q 个模型,取 1 表示选取,取 0 表示不选取。

动作空间定义为:

$$a = a_w \quad w = 0, 1, 2, 3, 4 \quad (15)$$

式中: a_w 为对当前状态第 w 位进行取反操作; a_0 为不进行任何动作。

(2) 初始化 Q 值表。

(3) 确定损失函数和奖励函数。

$$E_{\text{MSE}} = \frac{1}{n} \sum_{j=1}^n (y_j - \hat{y}_j)^2 \quad (16)$$

$$R = 100(E_{N,\text{MSE}} - E_{N+1,\text{MSE}}) \quad (17)$$

式中: E_{MSE} 为预测值的 MSE; y_j 为第 j 个样本的实际功率值; \hat{y}_j 为第 j 个样本的预测功率值; R 为动作的奖励值; $E_{N,\text{MSE}}$ 为第 N 次动作后组合模型预测值的 MSE, 动作执行后模型的预测误差越小, 对应的奖励越大。

(4) 动作选择原则。

文中基于 ε -greedy 策略和 Q 值表进行动作选择, 其表达式如下:

$$a = \begin{cases} a_Q^{\max} & \beta > \varepsilon \\ a_r & \beta \leq \varepsilon \end{cases} \quad (18)$$

式中: a_Q^{\max} 为根据 Q 值表选择最大 Q 值对应的动作; a_r 为随机选择动作; β 为 $[0,1]$ 之间的随机值; 文中设置 $\varepsilon = 0.5$ 。

(5) Q 值的设置。

Q -Learning 算法基于 Q 值函数, 该函数表示在给定状态下, 采取某个动作所获得的累计奖励值。 Q 值函数的更新表达式如下:

$$Q'(s, a) = Q(s, a) + \eta(R + \gamma \max_{a'} (Q(s', a') - Q(s, a))) \quad (19)$$

式中: $Q(s, a)$ 为存储功率在状态 s 下采取动作 a 的价值; $Q'(s, a)$ 为每次迭代更新后的价值; s' 为执行完动作后进入的下一状态; a' 为下一状态能采取的动作; η 为学习率; γ 为进入下一状态后 Q 值的折扣率。

(6) 重复上述步骤, 直至达到最大迭代次数, 得到最终 Q 值表。

(7) 根据收敛的 Q 值表, 输入起始状态, 得到最终状态。

(8) 根据各模态最终状态计算预测结果, 其表达式如下:

$$\hat{P}(t) = \sum_{k=1}^K \hat{P}_k(t) \quad (20)$$

$$\hat{P}_k(t) = \frac{\sum_{q=1}^4 x_q \hat{y}_q(t)}{\sum_{q=1}^4 x_q} \quad (21)$$

式中: $\hat{P}(t)$ 为总序列最终预测值; $\hat{P}_k(t)$ 为第 k 个子序列模态最终预测值; x_q 为第 q 个模型的选择, 取值为 0 或 1; $\hat{y}_q(t)$ 为第 q 个模型预测结果。整个模型组合流程如图 5 所示。

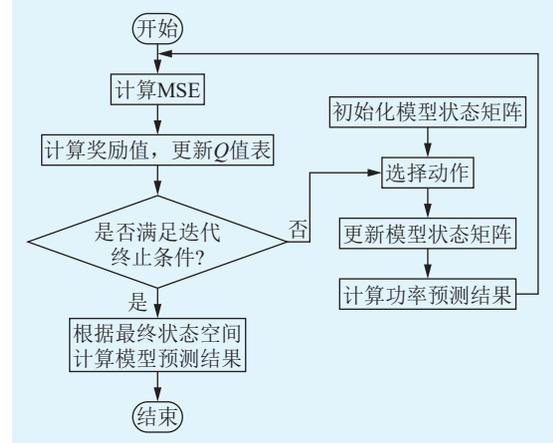


图 5 基于 Q-Learning 的模型组合流程

Fig.5 Model combination process based on Q-Learning

3 算例仿真与分析

3.1 数据集描述

文中采用天合光能 2013 年—2014 年实测的高分辨率气象和功率数据, 采样间隔为 5 min。考虑夜间光伏出力为 0, 其功率在实际工程中无意义, 且夜间数据易受测量误差和噪声干扰, 可能包含异常或不准确值, 影响模型训练效果, 因此文中仅选择 07:00—19:50 的日间数据集作为研究对象。日间数据集被划分为训练集、测试集和验证集, 其中训练集和测试集比例为 7:3, 并额外选择 3 个典型天气日的数据作为验证集, 天气类型分别为多云、晴天和另一晴天。对于数据集中的异常点, 首先采用四分位法识别并剔除离群点, 同时去除光伏功率中的负值点和零出力点, 以避免异常数据对模型训练的干扰。数据清洗完成后, 采用最小最大归一化方法对数据进行归一化处理。部分归一化后的功率样本数据如图 6 所示。

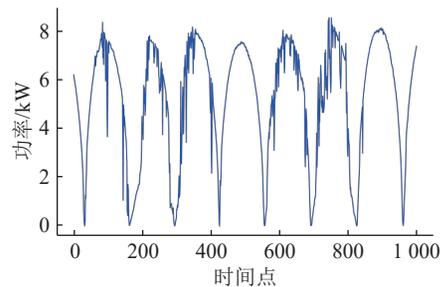


图 6 部分功率样本点

Fig.6 Partial power sample data

为了评价文中建立模型的性能, 使用 MAE、

MSE、均方根误差 (root mean squared error, RMSE) 和 R^2 4 种指标来评估预测值和真实值之间的误差, MSE 表达式同式 (16), 其余表达式分别为:

$$E_{MAE} = \frac{1}{n} \sum_{j=1}^n |y_j - \hat{y}_j| \quad (22)$$

$$E_{RMSE} = \sqrt{\frac{1}{n} \sum_{j=1}^n (y_j - \hat{y}_j)^2} \quad (23)$$

$$R^2 = 1 - \frac{\sum_{j=1}^n (y_j - \hat{y}_j)^2}{\sum_{j=1}^n (y_j - \bar{y})^2} \quad (24)$$

式中: \bar{y} 为光伏功率的平均值。MAE、MSE、RMSE 代表模型预测值和实际值的偏差, 数值越小表示模型拟合效果越优; R^2 为一种衡量回归模型解释能力的统计量, 数值在 [0,1] 之间, 越接近于 1 表示模型拟合精度越高。

3.2 输入步长的选定

输入步长对模型性能至关重要。输入步长过短时虽然计算效率较高, 但容易受到短期噪声的影响, 难以捕捉时间序列中的长期依赖关系, 导致预测精度下降; 而输入步长过长则可能导致模型过拟合历史数据, 难以适应新的数据变化。为确定最优输入步长, 文中采用 4 种基础模型, 分别计算步长为 1、3、5、7、9 时的 MSE, 如图 7 所示, 以评估各步长的预测效果, 并选择最优步长。

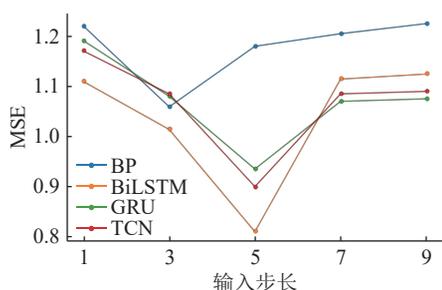


图 7 输入步长与 MSE 的关系
Fig.7 Relationship between input step size and MSE

图 7 中, 当输入步长为 5 时, 4 种基础模型的总 MSE 最小。因此, 后续算例均采用时间步长为 5 的数据作为模型输入。

3.3 实验结果对比分析

3.3.1 VMD 优化效果分析

在图 6 中可以看出, 原始功率曲线波动性较大, 曲线存在较多毛刺, 而 VMD 算法能够有效降低原始功率数据的噪声和冗余, 故文中利用 VMD 算法对原始功率曲线进行处理。同时, 为了验证 VMD 算法能够有效分离噪声, 降低光伏功率序列

的波动性, 提高模型预测精度, 文中设置 VMD-BP、VMD-BiLSTM、VMD-GRU、VMD-TCN、BP、BiLSTM、GRU、TCN 作为对比模型。图 8 为各模型在验证集上的预测结果。

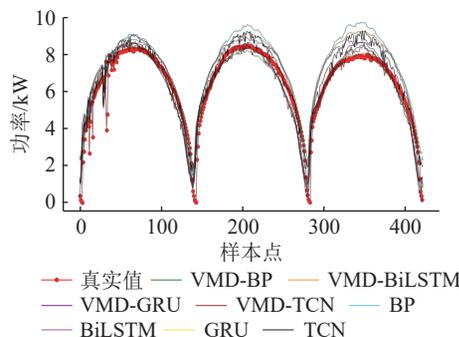


图 8 VMD 算法有效性验证
Fig.8 Validation of the VMD algorithm effectiveness

图 9 为各模型在验证集上的预测误差, 由图 9 可知, 4 种基础模型结合 VMD 算法后与原模型相比, 各项评价指标均有明显提升。其中, VMD-BP 模型的提升尤为明显, 与单一的 BP 模型相比, 其 MAE 和 MSE 误差分别降低了 49.49% 和 60.99%, R^2 提升了 17.43%。与 BP 模型相比, TCN 的提升较弱, MAE 与 MSE 仅降低了 22.00% 和 32.05%, 这可能是由于 TCN 结构复杂, 具有较强的捕捉长时间依赖关系和并行处理能力, 在处理原始时间序列数据时已经表现出较强的建模能力, 因此通过 VMD 算法进行预处理的提升效果相对有限。类似地, GRU 网络模型和 BiLSTM 网络模型由于其结构特殊性, VMD 算法的提升效果均不如 BP 模型。BP 模型结构相对简单, 在经过 VMD 算法减小原始光伏功率序列的噪声和冗余信息后, 能够更好地捕捉气象特征, 从而显著提升预测性能。

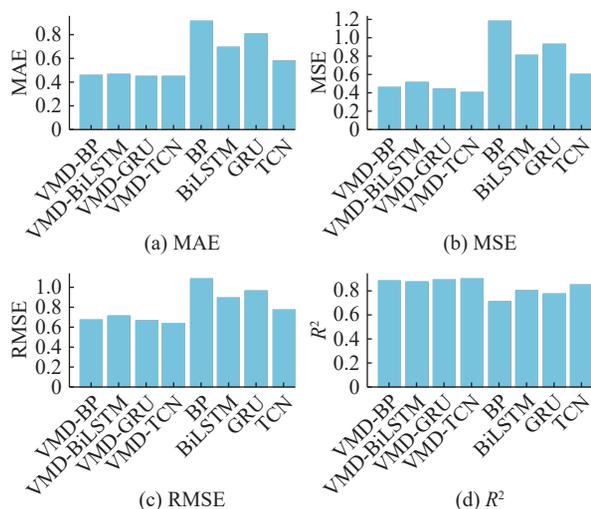


图 9 VMD 算法预测误差
Fig.9 Forecasting errors of the VMD algorithm

3.3.2 WOA 的效果分析

在 VMD 算法中, 惩罚因子 α 和模态数 K 对算法分解结果和预测模型的性能至关重要。为验证 WOA-VMD 中参数的有效性, 设置 GA 与粒子群优化 (particle swarm optimization, PSO) 算法作为对比, GA 通过模拟自然进化过程中的选择、交叉和变异操作, 优化 VMD 序列的参数。其优点在于全局搜索能力强, 但在处理高维数据时可能会陷入局部最优。PSO 算法模拟鸟群觅食行为, 通过一群粒子在解空间中移动找到最佳解。每个粒子代表一个可能的解, 粒子通过不断更新自己的位置和速度来寻找最优解, 并根据个体和其他粒子的经验调整搜索方向, 逐步靠近最佳解。图 10 为 WOA 和 GA、PSO 算法在迭代过程中的收敛曲线。由图 10 可知, WOA 相较于 GA、PSO 算法收敛更快, 且更易跳出局部最优, 达到全局最优。故文中利用 WOA 可以显著提升 VMD 算法的性能, 使得分解后模态函数更纯净、噪声更低, 进而提高后续预测模型的精度。通过 WOA 可以确定 $K = 6$, $\alpha = 10$ 。

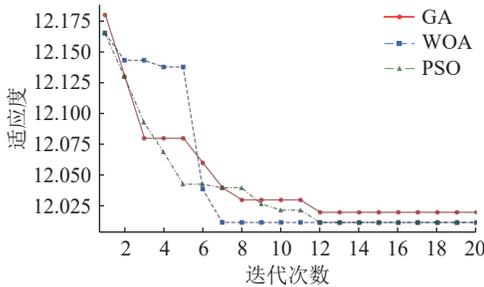


图 10 WOA、GA 和 PSO 算法优化效果对比

Fig.10 Comparison of optimization effect among WOA, GA and PSO algorithms

为了验证 WOA-VMD 算法的有效性, 设置了 WOA-VMD-BP、WOA-VMD-BiLSTM、WOA-VMD-GRU、WOA-VMD-TCN 4 种模型, 并分别与未优化参数的 VMD-BP、VMD-BiLSTM、VMD-GRU、VMD-TCN 模型进行对比分析。图 11 展示了这些模型在验证集上的预测曲线。可以看出, WOA-VMD 算法降低了分解后噪声的影响, 使得组合模型的预测曲线较人工设置的模态数 3 和惩罚因子 100 的 VMD 算法更加平滑, 并且与真实功率曲线的变化趋势更加相似。

图 12 为 WOA 优化前后各模型的预测误差对比。结果表明, 经过 WOA 优化后的模型在 MAE、MSE、RMSE 以及 R^2 评价指标上均表现出更优异的性能。其中, GRU 和 BiLSTM 网络模型的性能提升效果尤为明显。WOA-VMD-GRU 网络模型的 MAE、

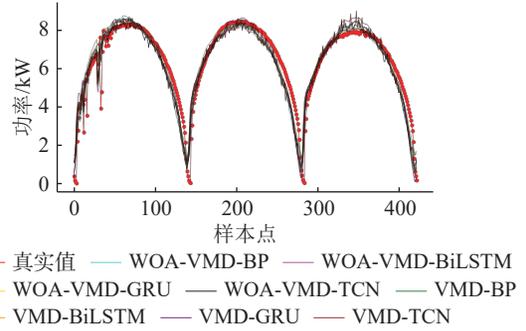


图 11 WOA 有效性验证

Fig.11 Validation of the WOA effectiveness

MSE 分别降低了 14.76% 和 27.39%, 在各项指标上表现最佳。而 WOA-VMD-BiLSTM 网络模型的 MAE 和 MSE 也分别降低了 12.79% 和 22.95%。

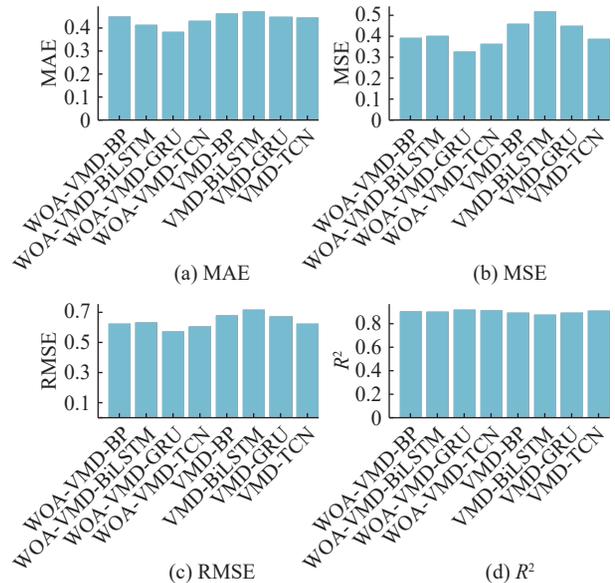


图 12 WOA 预测误差

Fig.12 Forecasting errors of the WOA

3.3.3 Q -Learning 优化效果分析

经 VMD 后, 各子模态包含不同频率和特征, 导致不同预测模型对各模态的拟合效果存在差异。通过 Q -Learning 对每个模态进行自适应选择最优基础模型组合, 有效提升整体预测性能。

以验证集第一日 (多云天气) 为例, 图 13 为验证集在该日各模态下, 4 种基础模型和组合模型在 MAE 和 MSE 评价指标上的表现。可见, 在不同模态下, 各基础模型的预测精度存在差异。通过 Q -Learning 自适应选择某模态的组合预测模型, 可以减少因单一模型不足导致的误差积累, 增加预测模型的灵活性和多样性。若某个模型在特定模态上表现不佳时, 其他模型可以在该模态上进行补偿, 从而实现优化。由图 13 可知, 经 Q -Learning 组合后的模型, 其 MAE 和 MSE 雷达图包围的区域明显

小于单一模型,说明组合模型在子模态验证集上的 MAE、MSE 表现更优,表明利用 Q -Learning 选择的组合模型能有效提升预测精度,显著改善模型的整体性能。

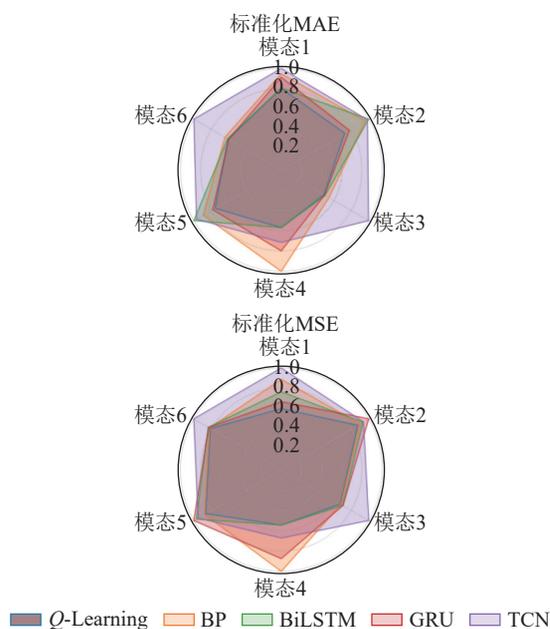


图 13 子模态 MAE、MSE 雷达图对比
Fig.13 Comparison of sub-modal MAE, MSE radar chart

利用 Q -Learning 可对不同时间尺度建立最优组合模型,实现日、月、季的最优模型,文中以日最优为例进行说明。图 14 展示了 4 种基础模型与文中所提组合模型在验证集上的预测曲线,其中文中算法为 WOA-VMD- Q -Learning。可知,文中所提组合模型的预测曲线更加贴近光伏功率的真实输出。

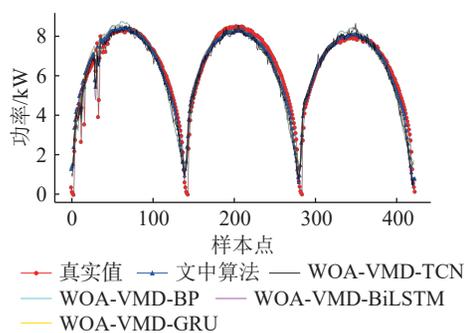


图 14 Q -Learning 算法有效性验证
Fig.14 Validation of Q -Learning algorithm effectiveness

图 15 为经 Q -Learning 优化组合模型与未优化在各项指标上对比, Q -Learning 组合模型在各项评价指标上表现更为优异。相较于表现最优的基础模型 WOA-VMD-GRU,文中组合模型的 MAE 下降了 16.18%,MSE 下降了 17.00%,RMSE 下降了 8.90%, R^2 提升了 1.32%。

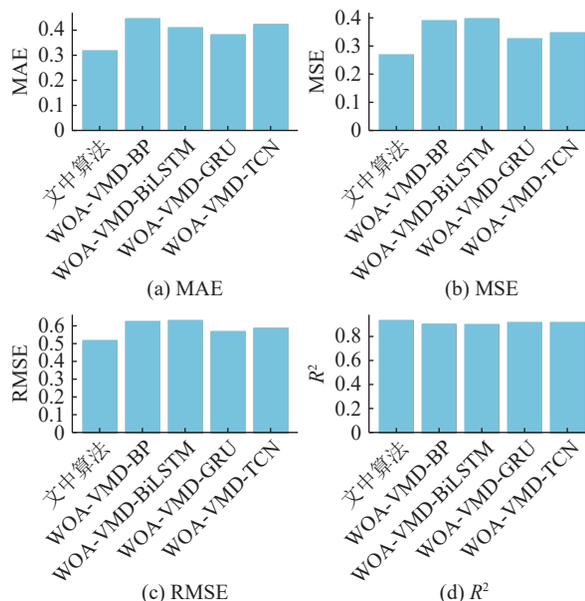


图 15 Q -Learning 算法预测误差
Fig.15 Forecasting errors of Q -Learning algorithm

4 结论

文中提出一种基于 Q -Learning 的多模态自适应光伏功率优化组合预测模型。首先,利用 WOA-VMD 中的模态数 K 和惩罚因子 α ,提升信号分解效果;然后,利用集成特征筛选模型选择最敏感气象因素集;最后,在每个模态上,利用 Q -Learning 进行自适应模型组合。

(1) 针对原始光伏功率序列波动性强、噪声高的问题,文中利用 VMD 算法对光伏功率数据进行分解。该方法有效降低了原始数据中的噪声和冗余成分,使模型能够更好地捕捉数据中的有用信息,提高了后续预测模型的性能。

(2) VMD 算法的模态数 K 和惩罚因子 α 直接影响信号分解效果。为此,文中采用 WOA-VMD 中的模态数 K 和惩罚因子 α ,显著提升了分解效果。优化后的 VMD 能够更精确地提取光伏功率数据中的特征,进一步提高各子模态的建模可靠性,从而为后续预测模型提供更加可靠的数据基础。

(3) 在晴天和多云两种天气类型下,针对每个子模态,通过 Q -Learning 算法选择最合适的基础模型(BP、BiLSTM、GRU、TCN)进行组合。结果表明, Q -Learning 选择的最佳组合模型在两个验证日的所有评价指标均优于单一预测模型。这表明,利用不同模型的优势处理不同模态的数据,不仅可以有效提高整体预测性能,还可以提高模型的泛化性能,但算例未考虑阴天和雨天的气象类型以及季节性差异,后续将在此方面进一步拓展。

参考文献:

- [1] 陈波, 张权旺, 刘柳, 等. 计及 LVRT 的光伏并网系统暂态稳定性分析与参数优化研究[J]. 电力科学与技术学报, 2024, 39(6): 162-173.
CHEN Bo, ZHANG Quanwang, LIU Liu, et al. Transient stability analysis and parameter optimization of PV grid-connected systems considering LVRT[J]. Journal of Electric Power Science and Technology, 2024, 39(6): 162-173.
- [2] 乔辉, 韩璟琳, 李征, 等. 采用日累计发电量重构光伏出力曲线的线损精确计算方法[J]. 电力系统保护与控制, 2024, 52(24): 161-168.
QIAO Hui, HAN Jinglin, LI Zheng, et al. An accurate calculation method of line loss based on reconstructing a photovoltaic output curve by daily cumulative power generation[J]. Power System Protection and Control, 2024, 52(24): 161-168.
- [3] 郑婉婷, 肖浩, 裴玮. 基于 NGBoost 和改进权重优化的区域分布式光伏功率预测[J]. 供用电, 2024, 41(7): 19-28.
ZHENG Wanting, XIAO Hao, PEI Wei. Probabilistic power forecasting for regional distributed photovoltaic systems using NGBoost and enhanced weight optimization[J]. Distribution & Utilization, 2024, 41(7): 19-28.
- [4] 刘迪, 吴林林, 巩宇, 等. 基于滚动采样马尔可夫链模型的光伏时序功率模拟研究[J]. 电力科学与技术学报, 2024, 39(3): 207-216.
LIU Di, WU Linlin, GONG Yu, et al. Study on time series power simulation of photovoltaic output based on rolling sampling Markov chain model[J]. Journal of Electric Power Science and Technology, 2024, 39(3): 207-216.
- [5] 周伊, 肖先勇, 赵清华, 等. 基于组合数据清洗与改进注意力机制的光伏发电功率预测[J]. 供用电, 2024, 41(10): 31-37,49.
ZHOU Yi, XIAO Xianyong, ZHAO Qinghua, et al. Photovoltaic power forecasting based on combined data cleaning and improved attention mechanism[J]. Distribution & Utilization, 2024, 41(10): 31-37,49.
- [6] ALMONACID F, PÉREZ-HIGUERAS P J, FERNÁNDEZ E F, et al. A methodology based on dynamic artificial neural network for short-term forecasting of the power output of a PV generator[J]. Energy Conversion and Management, 2014, 85: 389-398.
- [7] 邹港, 赵斌, 罗强, 等. 基于 PCA-VMD-MVO-SVM 的短期光伏输出功率预测方法[J]. 电力科学与技术学报, 2024, 39(5): 163-171.
ZOU Gang, ZHAO Bin, LUO Qiang, et al. Prediction method of short-term PV output power based on PCA-VMD-MVO-SVM[J]. Journal of Electric Power Science and Technology, 2024, 39(5): 163-171.
- [8] 廖家齐, 于若英, 刘瑜俊, 等. 基于自适应高斯混合模型的含高渗透率分布式光伏电力系统风险评估[J]. 电力系统保护与控制, 2024, 52(19): 144-156.
LIAO Jiaqi, YU Ruoying, LIU Yujun, et al. Risk assessment of a power system with a high penetration of distributed photovoltaic based on self-adaptive Gaussian mixture model[J]. Power System Protection and Control, 2024, 52(19): 144-156.
- [9] 李永飞, 张耀, 林帆, 等. 基于气候特征分析及改进 XGBoost 算法的中长期光伏电站发电量预测方法[J]. 电力系统保护与控制, 2024, 52(11): 84-92.
LI Yongfei, ZHANG Yao, LIN Fan, et al. Medium-and long-term power generation forecast based on climate characterisation and an improved XGBoost algorithm for photovoltaic power plants[J]. Power System Protection and Control, 2024, 52(11): 84-92.
- [10] QING X Y, NIU Y G. Hourly day-ahead solar irradiance prediction using weather forecasts by LSTM[J]. Energy, 2018, 148: 461-468.
- [11] 朱琼锋, 李家腾, 乔骥, 等. 人工智能技术在新能源功率预测的应用及展望[J]. 中国电机工程学报, 2023, 43(8): 3027-3048.
ZHU Qiongfeng, LI Jiateng, QIAO Ji, et al. Application and prospect of artificial intelligence technology in renewable energy forecasting[J]. Proceedings of the CSEE, 2023, 43(8): 3027-3048.
- [12] 张永蕊, 阎洁, 林爱美, 等. 多点数值天气预报风速和辐照度集中式修正方法研究[J]. 发电技术, 2022, 43(2): 278-286.
ZHANG Yongrui, YAN Jie, LIN Aimei, et al. Integrated correction method of multi-point numerical weather prediction wind speed and irradiance[J]. Power Generation Technology, 2022, 43(2): 278-286.
- [13] 吴珺玥, 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.
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 Solaris Sinica, 2023, 44(9): 180-186.
- [14] FENG C, CUI M J, HODGE B M, et al. A data-driven multi-model methodology with deep feature selection for short-term wind forecasting[J]. Applied Energy, 2017, 190: 1245-1257.
- [15] 张云钦, 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.
ZHANG Yunqin, CHENG Qize, JIANG Wenjie, et al. Photovoltaic power prediction model based on EMD-PCA-LSTM[J]. Acta Energetica Solaris Sinica, 2021, 42(9): 62-69.
- [16] 陈龙, 张菁, 张昊立, 等. 基于 VMD 和射影算法优化改进 ELM 的短期光伏发电预测[J]. 太阳能学报, 2023, 44(10): 135-141.
CHEN Long, ZHANG Jing, ZHANG Haoli, et al. Short-term photovoltaic power generation forecast based on VMD-iaaiheklm model[J]. Acta Energetica Solaris Sinica, 2023, 44(10): 135-141.
- [17] 俞敏, 王晓霞. CS 算法优化 VMD-BiLSTM-AM 的光伏功率

- 预测[J]. 计算机系统应用, 2023, 32(2): 347-355.
YU Min, WANG Xiaoxia. Photovoltaic power prediction based on VMD-BiLSTM-AM optimized by CS algorithm[J]. Computer Systems and Applications, 2023, 32(2): 347-355.
- [18] WANG S, WEI L F, ZENG L. Ultra-short-term photovoltaic power prediction based on VMD-LSTM-RVM model[J]. *IOP Conference Series: Earth and Environmental Science*, 2021, 781(4): 042020.
- [19] 王晓霞, 俞敏, 冀明, 等. 基于气候相似性与 SSA-CNN-LSTM 的光伏功率组合预测[J]. 太阳能学报, 2023, 44(6): 275-283.
WANG Xiaoxia, YU Min, JI Ming, et al. Photovoltaic power combination forecasting based on climate similarity and SSA-CNN-LSTM[J]. *Acta Energetica Solaris Sinica*, 2023, 44(6): 275-283.
- [20] 刘源延, 孔小兵, 马乐乐, 等. 基于小波包变换与深度学习的超短期光伏功率预测[J]. 太阳能学报, 2024, 45(5): 537-546.
LIU Yuanyan, KONG Xiaobing, MA Lele, et al. Ultra-short-term photovoltaic power forecasting based on wavelet packet transform and deep learning[J]. *Acta Energetica Solaris Sinica*, 2024, 45(5): 537-546.
- [21] 李超然, 潘鹏程, 杨伟荣, 等. 基于改进相似日优化 HBA-BiLSTM-KELM 的光伏发电功率预测[J]. 太阳能学报, 2024, 45(5): 508-516.
LI Chaoran, PAN Pengcheng, YANG Weirong, et al. Research on PV system power prediction based on improved similar day and HBA-BiLSTM-KELM neural network[J]. *Acta Energetica Solaris Sinica*, 2024, 45(5): 508-516.
- [22] 何玉灵, 焦凌钰, 孙凯, 等. 基于变权重组合的短期风光发电功率混合预测[J/OL]. 华北电力大学学报(自然科学版), 2023: 1-12. (2023-09-18) [2024-08-29]. <https://kns.cnki.net/KCMS/detail/detail.aspx?filename=HBDL20230912001&dbname=CJFD&dbcode=CJFQ>.
HE Yuling, JIAO Lingyu, SUN Kai, et al. Short-term wind and photovoltaic power hybrid prediction based on variable weight combination prediction model[J/OL]. *Journal of North China Electric Power University (Natural Science Edition)*, 2023: 1-12. (2023-09-18) [2024-08-29]. <https://kns.cnki.net/KCMS/detail/detail.aspx?filename=HBDL20230912001&dbname=CJFD&dbcode=CJFQ>.
- [23] 严璐晗, 林培杰, 程树英, 等. 基于增量学习的 CNN-LSTM 光伏功率预测[J]. 电气技术, 2024, 25(5): 31-40.
YAN Luhan, LIN Peijie, CHENG Shuying, et al. CNN-LSTM photovoltaic power prediction based on incremental learning[J]. *Electrical Engineering*, 2024, 25(5): 31-40.
- [24] LI P T, ZHOU K L, LU X H, et al. A hybrid deep learning model for short-term PV power forecasting[J]. *Applied Energy*, 2020, 259: 114216.
- [25] 孟安波, 许炫淙, 陈嘉铭, 等. 基于强化学习和组合式深度学习模型的超短期光伏功率预测[J]. 电网技术, 2021, 45(12): 4721-4728.
MENG Anbo, XU Xuancong, CHEN Jiaming, et al. Ultra short term photovoltaic power prediction based on reinforcement learning and combined deep learning model[J]. *Power System Technology*, 2021, 45(12): 4721-4728.
- [26] 王颖超. 鲸鱼优化算法研究与应用进展[J]. 计算机工程与科学, 2024, 46(5): 881-896.
WANG Yingchao. Research and application of whale optimization algorithm[J]. *Computer Engineering & Science*, 2024, 46(5): 881-896.
- [27] 刘抒睿, 李培强, 陈家煜, 等. 基于 VMD 分解下的皮尔逊相关性分析及 T-tFD 的混合储能容量配置[J]. 中国电力, 2024, 57(7): 82-97.
LIU Shurui, LI Peiqiang, CHEN Jiayu, et al. Allocation of hybrid energy storage capacity based on Pearson correlation analysis and T-tFD algorithm under VMD decomposition[J]. *Electric Power*, 2024, 57(7): 82-97.
- [28] 李鑫, 李海明, 马健. 基于单步预测 LSTM 的短期负荷预测模型[J]. 计算机仿真, 2022, 39(6): 98-102, 117.
LI Xin, LI Haiming, MA Jian. Short-term load forecasting model based on LSTM of single-step forecasting[J]. *Computer Simulation*, 2022, 39(6): 98-102, 117.
- [29] 逯静, 张燕茹, 王瑞. 基于 BWO-VMD 和 TCN-BiGRU 的短期风功率预测[J/OL]. 工程科学与技术, 2024: 1-14. (2024-06-05) [2024-08-29]. <https://kns.cnki.net/KCMS/detail/detail.aspx?filename=SCLH2024060300B&dbname=CJFD&dbcode=CJFQ>.
LU Jing, ZHANG Yanru, WANG Rui. Short-term wind power prediction based on BWO-VMD and TCN-BiGRU[J/OL]. *Advanced Engineering Sciences*, 2024: 1-14. (2024-06-05) [2024-08-29]. <https://kns.cnki.net/KCMS/detail/detail.aspx?filename=SCLH2024060300B&dbname=CJFD&dbcode=CJFQ>.

作者简介:



魏知初

魏知初(2000), 男, 硕士在读, 研究方向为新能源功率预测(E-mail: 574262735@qq.com);
杨苹(1967), 女, 博士, 教授, 博士生导师, 研究方向为可再生能源并网与微电网技术;
周钱雨凡(2001), 女, 硕士在读, 研究方向为电力市场、算力电力协同、信息物理融合的电网优化调度。

(下转第 163 页)

Diffusion characteristics of multi-component gases in gas to liquid insulating oil via molecular dynamics analysis

LIU Jinfeng¹, CHEN Beibei¹, ZHANG Wenqian¹, LI Xiaohan², ZHANG Xiang³, JIANG Jun¹

(1. Nanjing University of Aeronautics and Astronautics (Jiangsu Key Laboratory of New Energy Generation and Power Conversion), Nanjing 211106, China; 2. State Grid Jiangsu Electric Power Co., Ltd. Research Institute, Nanjing 211103, China; 3. Manchester Metropolitan University, Manchester M15GD, United Kingdom)

Abstract: In power transformers, insulating oil deteriorates continuously due to aging, overheating, discharge, and other factors, accompanied by the production of characteristic gases such as H₂, CH₄, C₂H₂, C₂H₄, C₂H₆, and varying degrees of diffusion within the oil. However, due to differences in gas structure and insulation systems, the diffusion characteristics of characteristic gases in gas to liquid (GTL) insulating oil are not yet clear, and the interactions among multiple gas molecules remain unclear. In order to elucidate this diffusion mechanism, this study employs molecular dynamics methods to investigate the diffusion behavior of mixed gases in stationary GTL insulating oil at the microscopic level. By comparing the diffusion coefficients, trajectories, free volume fractions, and interaction energies of single-component, binary, and multicomponent gas systems, the influence of mixed gas addition on diffusion is analyzed. The results indicate that for single-component diffusion systems, the diffusion coefficients of gases in GTL insulating oil exhibit the order: H₂ > hydrocarbon gases, and the diffusion coefficients of hydrocarbon gases are inversely proportional to molecular mass, with diffusion of different gases conforming to the "vacancy jump diffusion theory". For binary diffusion systems, the diffusion of gas molecules in mixed gas systems exhibits a synergistic effect, manifested by repulsive interactions between different gas molecules. Moreover, the addition of mixed gases reduces the interaction energy of CH₄ with GTL insulating oil by 9.21 kJ/mol and that of H₂ by 3.76 kJ/mol, respectively; the free volume fractions of H₂ and CH₄ increase by 27.5% and 113.7%, respectively, expanding gas movement space, weakening GTL's binding effect on gases, and increasing gas diffusion coefficients. Clarifying the diffusion characteristics of gases in GTL insulating oil will effectively serve the fault diagnosis of power transformers.

Keywords: gas to liquid (GTL); characteristic gases; molecular dynamics simulation; diffusion coefficient; interaction energy; free volume

(编辑 陆海霞)

(上接第 124 页)

Multi-modal adaptive photovoltaic power optimization and combination forecasting based on Q-Learning

WEI Zhichu^{1,2}, YANG Ping^{1,2}, ZHOU Qianyufan¹, CHEN Wenhao¹, WAN Siyang¹, CUI Jiayan¹

(1. School of Electric Power Engineering, South China University of Technology, Guangzhou 510640, China; 2. Guangdong Key Laboratory of Green Energy Technology, South China University of Technology, Guangzhou 510640, China)

Abstract: To address the challenges of high volatility and stochasticity in photovoltaic (PV) power series, a multi-modal adaptive PV power optimization forecasting model based on Q-Learning is proposed. The original PV power series are first decomposed into different submodalities using the variational mode decomposition algorithm optimized by the whale optimization algorithm. An integrated feature selection model is then employed to identify the most sensitive meteorological features for each submodal series. Four basic forecasting models: back propagation neural network, bidirectional long short-term memory, gated recurrent unit and temporal convolutional network, are constructed to predict the power sub-series. Given that different models exhibit varying forecasting abilities for sub-series with different frequency characteristics, Q-Learning is utilized to adaptively select the optimal combination of forecasting models for each modality. The final forecasting result is obtained by superimposing and reconstructing the forecasts of the different submodalities. The proposed model is validated using a high-resolution PV meteorological power dataset. The results demonstrate that the proposed multi-modal adaptive photovoltaic power optimization and combination forecasting based on Q-Learning achieved a 16.18% reduction in mean absolute error and a 17.00% reduction in mean squared error compared to the single model.

Keywords: whale optimization algorithm; variational mode decomposition; Q-Learning; power forecasting; combination model; photovoltaic (PV) power generation

(编辑 吴昊)