引用格式：李颖欢，刘吉成，卢运媛，等．基于互信息耦合DBO-BiLSTM-Attention的风光协同发电功率预测模型[J].电力科学与技术学报,2025,40(4):134-149.

Citation: LI Yinghuan, LIU Jicheng, LU Yunyuan, et al. Model of wind-photovoltaic synergy power forecasting based on mutual information coupling DBO-BiLSTM-Attention[J]. Journal of Electric Power Science and Technology,2025,40(4):134-149.

基于互信息耦合DBO-BiLSTM-Attention的风光协同发电功率预测模型

李颖欢，刘吉成，卢运媛，孙嘉康

（华北电力大学经济与管理学院，北京 102206）

摘　要：风、光协同发电是新型电力系统耦合发展的趋势，然而两者发电受环境波动波动影响较大，对系统整体功率的预测精度产生影响。通过探索创新方法模型对风光协同发电功率进行预测分析，以期获得更加精准的预测结果。首先，分析风光协同发电系统结构及其协同发电模式；其次，通过互信息耦合方法探讨风电和光伏功率影响因素之间的关联关系；再次，构建DBO-BiLSTM-Attention组合模型，为风力和光伏协同发电功率预测奠定基础；最后，结合算例分别进行情景分析、方法对比分析和灵敏度分析，验证模型的有效性和合理性。研究表明，所提模型具有良好的性能，能够为风、光协同发电功率高效而精准的预测提供有价值的参考。

关　键　词：风光协同发电；功率预测；互信息；双向长短期记忆网络；注意力机制；蜣螂优化算法

DOI：10.19781/j.issn.1673-9140.2025.04.013　　**中图分类号**：TM615　　**文章编号**：1673-9140(2025)04-0134-16

Forecasting model of wind-photovoltaic synergy power based on mutual information coupling DBO-BiLSTM-Attention

LI Yinghuan, LIU Jicheng, LU Yunyuan, SUN Jiakang

(School of Economics and Management, North China Electric Power University, Beijing 102206, China)

Abstract: Wind-photovoltaic synergy power is the trend in the development of new electric power systems. However, both electricity generation fluctuates greatly with the environment, which exerts an impact on the forecasting accuracy for the whole system power. This paper explores an innovative model to analyze and forecast the wind-photovoltaic synergy power for the purpose of a more accurate forecasting result. Firstly, the structure of the wind-photovoltaic synergy power system and the synergy power model of wind power and photovoltaic power are analyzed. Secondly, the relationship between the influence factors of wind power and photovoltaic power is discussed using the mutual information coupling method. Thirdly, the DBO-BiLSTM-Attention model is constructed to lay the foundation for forecasting the wind-photovoltaic synergy power. Finally, the scenario analysis, method comparison analysis, and the sensitivity analysis are conducted to verify the effectiveness and rationality of the proposed model. The results show that the proposed model has good performance and can provide a valuable reference for forecasting wind-photovoltaic synergy power effectively and accurately.

Key words: wind-photovoltaic synergy power; power forecasting; mutual information; bidirectional long short-term memory; attention mechanism; dung beetle optimizer

以风电、光伏为代表的清洁能源发电是实现电力系统绿色转型的关键。受环境等因素影响，风能和太阳能发电具有间歇性、随机性和强波动性，一方面会导致功率输出不可控，产生弃风弃光等资源

收稿日期：2024-09-13；**修回日期**：2024-12-17

基金项目：国家自然科学基金(71771085)

通信作者：刘吉成(1963—)，男，教授，博士生导师，主要从事电力运营与信息管理、能源互联网理论与应用方面的研究；E-mail：ljc29@163.com

浪费现象；另一方面，风光发电大规模并网，进而导致发电功率与用电负荷失衡，威胁电力系统的安全稳定运行。在构建新型电力系统的背景下，以源网荷储互动与多能互补为支撑的协同发电系统迅速发展[1]，通过风光互补的发电模式，可在一定程度上平抑单一能源的波动性，形成更为稳定的电力输出。因此，准确的功率预测对电力系统的调度优化、安全运行以及清洁能源的高效消纳等起着至关重要的作用[2]。然而，对单一能源的功率进行预测本身就具有较高的复杂性，其预测精度和效率仍有待提升。同时，协同发电模式还需考虑风光出力间的耦合关联特性，这进一步增大了系统整体功率的预测难度。因此，在风光协同发电的创新模式下，探索2种能源协同互补发电的功率预测方法，并研究如何提高预测的准确性和可靠性，有助于提高能源利用率，保障协同发电系统稳定运行。

有学者针对发电功率的影响因素开展了相关研究，认为清洁能源发电受环境因素制约较大，风电场与光伏电站的运行高度依赖于气象条件，且发电功率随气候进行实时变化[3]。文献[4]认为影响风电功率的因素有风速、空气密度、湍流强度以及风切变，并基于偏依赖量分析了这些因素与风电功率的相关性。文献[5]以风能密度、容量系数、光照幅度以及太阳能输出作为评价光伏潜力的关键指标，强调了风速、风向、辐射、云层等气象因素以及季节性变化对能源生产的重要性。在研究影响因素与风、光功率的关系时，常用方法包括灰色关联度[6]、主成分分析[7]、相关系数[8]、趋势系数[9]、经验模态分解[10]等。然而，这些方法或仅能分析线性关系，或存在较强的主观性，可能导致分析结果存在偏差。因此，亟需一种更适配的方法以进一步探明影响因素对发电功率的综合影响。互信息可以用来表明2个变量之间的关联关系，其高计算精度已在计算机强化学习[11]和特征聚类[12]等领域得到广泛验证。该方法利用实际数据来计算相关性，既消除了主观判断性，又考虑了因素间的复杂关系，其在功率预测领域的研究与应用尚不普遍。因此，本文引入互信息来研究影响因素与风光功率的关系，从而为构建考虑多因素差异化影响的精准预测模型奠定基础。

根据各种影响因素与历史数据，学者们围绕风电、光伏功率预测开展了相关研究。文献[13]利用Copula函数构建了风电和光伏发电功率与关键气象因子间的联合分布，将不同因子作为不同输入条件，分别建立了风电和光伏预测模型。文献[14]在利用解释结构模型识别出风力发电影响因素的层次结构关系的基础上，耦合了随机森林模型，以修正不同气象影响下的预测结果。文献[15]采用奇异频谱分析，提取了光伏发电序列的主要趋势与周期成分，引入子模型选择策略来选出不同输入特征组合下的最佳预测模型，并基于多目标灰狼优化器对这些预测模型进行组合预测。然而，多数文献聚焦于单一能源功率的预测，而针对风光协同等多能源联合功率的同时预测研究则相对较少，这为本文开展风光协同功率预测研究提供了契机与方向。

在预测方法方面，各类新兴智能模型不断涌现以提升预测精度及计算效率，包括智能算法[16]、机器学习[17]、深度学习[18]、统计学理论[19]、数据挖掘与聚类[20]等。其中，长短期记忆网络（long short-term memory，LSTM）因其独特的门控结构和在处理时间序列数据上的优势，在风电和光伏功率预测领域得到了广泛应用。采用集成技术、模型杂交或参数调整等方法对LSTM进行优化，可以提高预测的准确性，获得更为可靠的结果[21]，由此产生了一系列改进模型如CS-LSTM[22]、BO-STA-LSTM[23]、SVM-BIRCH-BiLSTM[24]等。尽管这些模型获得了一定的性能提升，但仍存在需要解决的问题：随着新能源并网规模的扩大与影响因素维度的增加，输入模型的数据量急剧膨胀。这不仅加大了模型的计算开销，而且数据中包含的噪声和冗余信息也可能干扰模型的学习过程，从而降低预测精度。针对此问题，注意力（Attention）机制能够为输入数据动态分配权重，从而快速提取关键特征，有效缓解因数据维度增加带来的信息冗余与计算负担[25]。模型的超参数（如网络层数、神经元数量、学习率等）设置对预测性能至关重要。传统的经验试错法主观性强且效率低下，而现有智能算法在全局搜索能力和收敛效率上仍有提升空间。蜣螂优化算法（dung beetle optimizer，DBO）相比于其他智能算法，兼顾了全局探索与局部开发能力，具备收敛速度快、求解精度高、稳定性强等优势，在求解复杂优化问题时表现出优越性能[26]。

综上，本文提出一种互信息耦合的DBO-BiLSTM-Attention模型进行风光协同发电功率预测。首先，计算风电、光伏功率及其影响因素的互信息，以表明变量之间的关联关系。其次，通过组合双向循环网络将LSTM扩展为双向长短期记忆网络BiLSTM，引入注意力机制来凸显重要特征因

素以缓解模型计算负载。进而，采用DBO优化BiLSTM-Attention的隐藏层、神经元、学习率等超参数以增强网络训练效果。最后，以2024年的月度发电特征数据为例划分出不同数据集，将互信息与特征数据代入模型进行训练，用以进行风光协同发电功率预测。通过对结果进行情景分析、方法对比分析以及灵敏度分析以验证模型的可靠性，为实现精准预测从而助力风、光等清洁能源提质增效提供可行方案。

1 风光协同发电系统及其发电功率协同模式

风光协同发电系统（亦称风光互补发电系统）是将风能和太阳能2种可再生能源结合起来进行混合发电的系统，旨在利用2种能源的互补性，以最大化发电效率并保障系统稳定性。通过合理配置风力发电机组与光伏阵列，使风、光出力形成互补，提高能源供应的连续性和可靠性。该系统主要包括风电机组集群、太阳能光伏列阵、储能系统、逆变器以及智能控制模块等部分，结构如图1所示。

风电机组集群和太阳能光伏列阵分别将风能和太阳能转化为电能，发出的直流电经由逆变器转化为交流电，电能可直接并网以响应各类型电力用户的负荷需求。当风电和光伏功率发生波动时，储能系统可平抑功率波动、保障电网稳定，在发电量超过用电需求时存储电能，在发电量不足时释放电能，以辅助系统进行调峰填谷。所有设备通过物联网技术实现各单元的互联互通，所产生的海量数据在整个系统中进行实时交互，智能控制模块则通过计算与分析相关数据来检测和调节风光协同发电系统的运行状态，实现云端远程控制和自动化管理。为阐明该系统中风电与光伏协同发电的功率输出机理，以便为发电功率的精准预测奠定基础，本文构建的协同模式如图2所示。

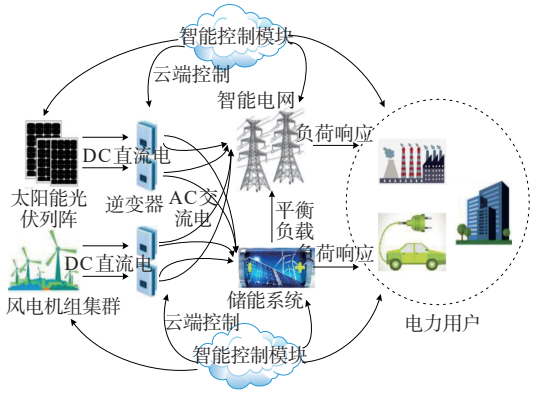

图1 风电、光伏协同发电系统结构

Figure 1 Structure of wind-photovoltaic synergy power system

图2中的风光协同发电模式可看作是由目标层、对象层以及技术层构成的一种三层结构。目标层明确了在进行风光协同发电及其功率预测过程

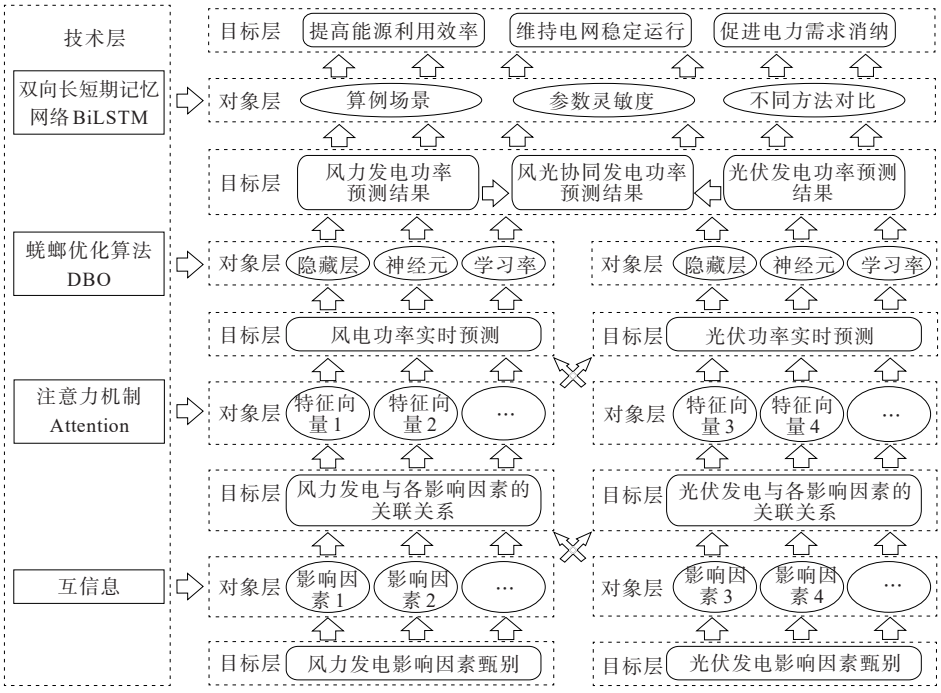

图2 风电、光伏功率及其协同发电模式

Figure 2 Wind power, photovoltaic power, and synergy power generation model

中所希望达到的目标，对象层是指为了达到目标所要作用的对象，方法层则包含为实现目标而进行的各种操作。影响风力发电和光伏发电的因素众多。其中，气象环境因素是关键影响因子。探明各种环境因素对风、光发电的影响是进行预测的首要任务。但影响因素纷繁多样，各因素与发电功率的关联性及影响程度存在显著差异。筛选出与发电功率高度相关的重要特征，是提升预测模型可靠性的关键。针对具有不同关联度和重要性的特征，将其数据代入模型分别进行风力发电功率和光伏发电功率预测，获得单一能源发电功率预测结果。风光协同发电系统的整体功率并非 2 种功率的简单叠加，还需考虑二者间的波动与耦合特性。因此，有必要在单能源预测的基础上，进一步分析各因素对 2 种功率波动的影响，对风光协同发电的总功率进行耦合预测，以得到修正后的输出值。之后通过划分多种场景、调节参数大小以及对比不同算法等分析验证结果及模型的合理可靠性，利用所提模型能够获得较为精准的功率预测结果，有助于提高能源利用率、保障电网运行、促进电力消纳等实现价值创造。整个过程中采用互信息计算各影响因素与风力发电、光伏发电的关联性，引入 Attention 机制将影响因素转化为具有不同重要性的特征向量，将特征向量代入 BiLSTM 模型中分别进行不同功率预测，通过 DBO 算法优化模型中的超参数以提高模型性能。

2　互信息耦合的 DBO-BiLSTM-Attention 模型构建

本文拟采用互信息分别计算出影响因素对风电、光伏的关联程度，将其作为特征向量代入网络中进行训练和预测。期间采用 DBO 智能算法优化网络中的隐藏层、神经元、学习率等超参数，并加入深度学习中的 Attention 机制优化计算过程，以此来构建风光协同发电功率预测模型，如图 3 所示。具体流程步骤如下。

1）采集风速、风向、辐射强度、气温、气压以及湿度等气象数据，同时收集风光发电厂内的风电集群功率及光伏阵列实际功率等原始数据。

2）经过数据清洗、转换等预处理操作对缺失值、异常值、重复值等进行筛选与替换，得到有效的功率数据以及风、光特征数据。

3）计算功率数据与特征数据的互信息值，分别得到与风电、光伏发电功率与各特征向量的关联关系，用于在模型训练中衡量各因素对功率的影响。

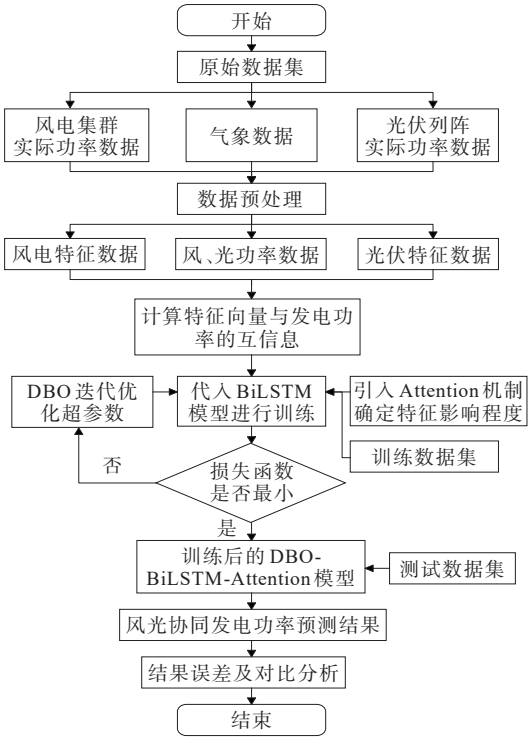

图 3　预测模型整体流程

Figure 3　Overall flow chart of proposed forecasting model

4）在模型训练中引入 Attention 机制来确定特征向量对发电功率的影响程度大小，便于降低噪声数据对训练的干扰，同时减轻模型算力负载。

5）将预处理后的数据集划分为一定比例的训练集和测试集，将训练集数据和互信息代入 BiLSTM-Attention 模型进行训练。

6）利用 DBO 算法对模型隐藏层层数、神经元个数以及学习率等超参数进行寻优，若模型中的损失函数已达最优，则模型训练完成，可以进行实际预测。反之则继续优化其超参数直到损失函数不再降低。

7）将测试集数据代入训练好的模型进行预测，得到风光协同功率预测结果，通过分析误差指标并进行方法、参数等对比，验证改进模型的适用性以及高效性。

2.1　互信息

互信息[27]属于信息论中熵的范畴，可以看作一个随机变量已知另一个随机变量使其不确定性减少的信息量，通常被用来衡量 2 个变量之间的关联程度。假设风力（光伏）发电的影响因素 X 和风电（光伏）功率 Y 的信息熵（即不确定性）分别为 $H(X)$ 和 $H(Y)$。在知道 Y 的情况下，X 的信息熵为 $(X \mid Y)$；反之，在知道 X 的情况下，Y 的信息熵为

$(Y\mid X)$，两者同时发生时的协同信息熵为$H(X,Y)$，则2种发电功率及其影响因素的互信息$I(X,Y)$如图4所示。

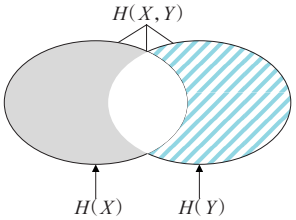

图4 各种信息熵及互信息关系

Figure 4 Relationship between various information entropy and mutual information

互信息值越小，意味着某个影响因素对确定风电（光伏）功率越没有关系，2个变量相关性越弱；而互信息值越大，意味着某个影响因素越能够消除风电（光伏）功率的不确定性，即2个变量相关性越强。此时互信息的值为

$$\begin{aligned} I(X,Y)&=H(X)-H(X\mid Y)=\\ &H(Y)-H(Y\mid X)=\\ &\sum_i\sum_j p(x_iy_j)\log\frac{p(x_iy_j)}{p(x_i)p(y_j)} \end{aligned} \tag{1}$$

式中，$p(x_i,y_i)$为随机变量X和Y的联合概率密度函数；$p(x_i)$、$p(y_i)$分别为X、Y的边际概率密度函数。

本文在计算互信息时，将某种影响因素与风电或光伏实际功率值作为输入，经过公式计算输出该因素与特定功率的关联程度，以此类推得到所有因素与风、光发电功率的关联关系，在后续预测时可以根据关联程度对这些特征向量进行高效训练。

2.2 双向长短期记忆网络BiLSTM

发电功率是以时间序列为基准的一类输出信息，不仅需要当前实时数据来研究每一时刻的输入特征，而且需要分析前后时刻之间的依赖关系。此时，利用LSTM来处理这种序列化输入和输出较为适用，该网络通过设置遗忘门、输入门和输出门的三重门结构来控制对信息长时记忆和短时记忆的保留，具体结构如图5所示。

首先，LSTM通过遗忘门读取前时刻的短时记忆序列h_{t-1}和本时刻的风、光特征数据x_t，经过Sigmoid函数得到介于0和1之间的值f_t来决定特征数据的保留情况，1表示完全保留，0表示完全丢弃。计算过程为

$$f_t=\sigma(\boldsymbol{W}_{\mathrm{f}}\cdot[h_{t-1},x_t]+b_{\mathrm{f}}) \tag{2}$$

式中，$\boldsymbol{W}_{\mathrm{f}}$为遗忘门的权重矩阵；$b_{\mathrm{f}}$为遗忘门的偏置项。

其次，LSTM识别存储在单元状态中的新信息，包括2个步骤：通过输入门用Sigmoid函数确定更新信息i_t，用以判断特征数据的重要性；通过tanh函数创建候选向量$\tilde{c}_t$，表示需要更新的数据。2种输入分别为

$$i_t=\sigma(\boldsymbol{W}_{\mathrm{i}}\cdot[h_{t-1},x_t]+b_{\mathrm{i}}) \tag{3}$$

$$\tilde{c}_t=\tanh(\boldsymbol{W}_{\mathrm{c}}\cdot[h_{t-1},x_t]+b_{\mathrm{c}}) \tag{4}$$

式(3)、(4)中，$\boldsymbol{W}_{\mathrm{i}}$、$\boldsymbol{W}_{\mathrm{c}}$分别为输入门和候选向量的权重矩阵；$b_{\mathrm{i}}$、$b_{\mathrm{c}}$分别为两者的偏置项。

进而，随时间慢慢遗忘不重要的风、光特征数据，同时对重要数据进行更新。具体表现为利用遗忘门限制前时刻的单元状态c_{t-1}对后面预测序列的影响，并加入输入门的更新信息和候选向量来更新当前时刻的单元状态c_t，该过程为

$$c_t=f_t\cdot c_{t-1}+i_t\cdot\tilde{c}_t \tag{5}$$

最后，通过输出门的Sigmoid函数决定特征数据的输出部分o_t，并与单元状态信息做运算来获得最终预测数据，即

$$o_t=\sigma(\boldsymbol{W}_{\mathrm{o}}\cdot[h_{t-1},x_t]+b_{\mathrm{o}}) \tag{6}$$

$$h_t=o_t\cdot\tanh(c_t) \tag{7}$$

至此，每个单元的状态更新完成，并为下一时刻输出相应信息，而后对LSTM中的每个单元重复上述操作即可实现模型训练。

LSTM被用来传递“过去”的风、光特征数据，但“未来”的特征数据亦可能对功率预测结果产生影响，在实际场景中需要根据影响因素可能的变动

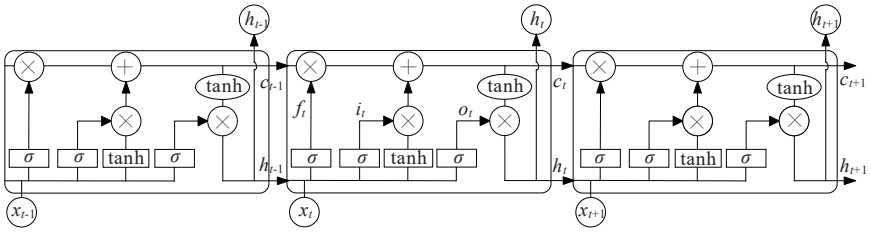

图5 LSTM网络结构及其组成

Figure 5 Network structure and composition of LSTM

情况提前对结果进行修正，此时探索输入和输出序列的双向依赖关系就尤为重要。因此，考虑通过叠加前向LSTM和后向LSTM来提取双向信息，形成BiLSTM以增强整个网络对特征数据的学习能力。此时若将式(2)～(7)的单个LSTM预测流程写成函数 lstm(x, h, c)，则将多个LSTM结合起来形成的BiLSTM预测流程为

$$(h_t, c_t) = \mathrm{lstm}(x_t, h_{t-1}, c_{t-1}) \tag{8}$$

$$(h^*_{t-1}, c^*_{t-1}) = \mathrm{lstm}(x_t, h^*_t, c^*_t) \tag{9}$$

式(8)、(9)中，*为反向传递的信息。

2.3　注意力机制 Attention

注意力 Attention 机制是深度学习领域重要概念之一，在算力有限的情况下优化计算资源以处理更重要的信息，是解决信息过载问题的主要手段[28]。通过在BiLSTM编码器中确定输入序列和输出序列的权重，实现对风、光特征数据的选择性训练，以达到数据增强性学习的效果，同时降低模型的运算负载。在BiLSTM中嵌入Attention机制的网络结构及流程如图6所示。

图6展示了一个由前向传递和后向传递循环网络组成的BiLSTM。其中，h_t代表当前LSTM单元及其风、光特征数据输出值，h^*_t和h'_t分别为上一LSTM和下一LSTM单元及其特征输出值。对于某一LSTM单元来说，该单元的输出既要接收从前面单元传递过来的正向特征数据，也要考虑后面单元的数据可能会带来的反向影响。由于各影响因素与预测功率存在一定关联关系，此处用互信息值表示这种关系，将其引入Attention值a_t的计算中，来评估各特征因素的重要性，从而修正预测输出值。对于前向传播网络来说，Attention值可由当前LSTM和前向LSTM的特征数据计算得到：

$$a_t = \mathrm{score}(h^{*T}_t, h_t) = h^{*T}_t \cdot I(X, Y) \cdot h_t \tag{10}$$

对于后向传播网络来说，Attention值由当前LSTM和后向LSTM的特征数据计算得到：

$$a_t = \mathrm{score}(h'^{T}_t, h_t) = h'^{T}_t \cdot I(X, Y) \cdot h_t \tag{11}$$

为方便计算，应用Softmax函数得到一个概率分布W_t，即Attention分布或Attention权重，代表特征因素的重要程度，其计算式为

$$W_t = \frac{a_t}{\sum_t a_t} \tag{12}$$

最后，将每个LSTM层级进行加权求和，便得到当前LSTM的预测值，依次迭代计算得出整个BiLSTM的功率预测输出：

$$\hat{y}_t = \sum_t W_t \cdot h^*_t + \sum_t W_t \cdot h'_t \tag{13}$$

2.4　蜣螂优化算法DBO

BiLSTM-Attention模型中涉及到门层结构、神经单元、学习率等多个超参数，如何确定较为合适的参数对预测结果有着重要影响。DBO是基于生物在自然界中的行为而提出的群体智能算法，这种方法对蜣螂的滚球、繁殖、觅食和偷窃等行为进行数学建模，以高度鲁棒性和全局搜索功能来处理复杂的非线性优化问题。DBO算法中每个蜣螂群体以寻找食物为目的进行活动，蜣螂对应寻优搜索器，食物则对应超参数的最优值，其寻优策略可分为滚球行为、繁殖行为、觅食行为和偷窃行为等4种。

滚球行为中，蜣螂群体根据光源强度反复更新自身位置，即初步确定一个最优值方向，根据最优值与当前值的差距来探索超参数的最优空间，即

$$p_i^{t+1} = p_i^t + \tau \cdot k \cdot p_i^{t-1} + z \cdot \Delta p \tag{14}$$

$$\Delta p = \left| p_i^t - p_i^{\mathrm{worse}} \right| \tag{15}$$

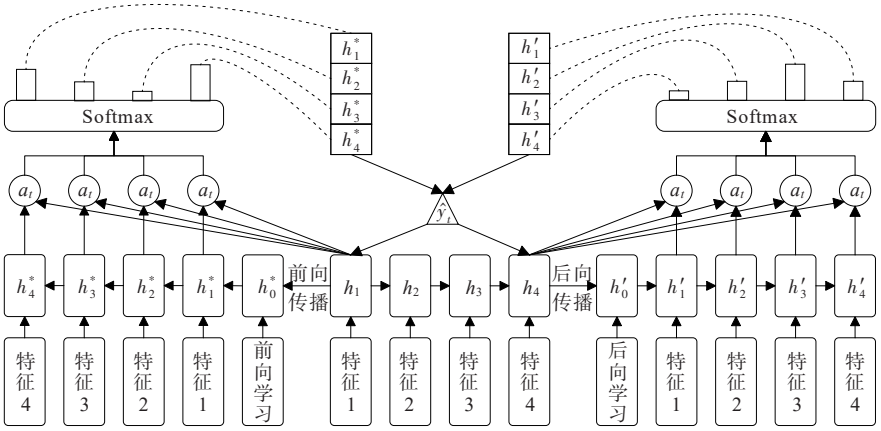

图6　BiLSTM-Attention网络结构及其流程

Figure 6　Network structure and process of BiLSTM－Attention

式(14)、(15)中，t为当前迭代次数；p_i^t为第i只蜣螂在第k次迭代时的超参数取值；k为恒定偏差系数；τ为自然系数；z为(0,1)之间的常数；p_i^{worse}为全局最差的超参数；Δp用于模拟光源强度(即超参数)的变化。

繁殖行为中，蜣螂群体通过选择合适的产卵地点并明确其边界来扩大搜索范围，即产生多个初始解来同时进行大范围超参数寻优。具体过程可表示为

$$\begin{cases} L^{\text{a}} = \max\left\{ p_{\text{lbest}}^t \cdot (1-R),\ L \right\} \\ U^{\text{a}} = \min\left\{ p_{\text{lbest}}^t \cdot (1+R),\ U \right\} \end{cases} \tag{16}$$

式中，p_{lbest}^t为目前的局部最优超参数；L^{a}、U^{a}分别为产卵区域的下界和上界；L、U分别为超参数空间的下界和上界；R为算法剩余迭代次数与最大迭代次数的比值。此时产卵面积会随着迭代次数动态调整，每一枚卵球位置会在区域范围中不断变化，表明每个初始解通过迭代生成，可表示为

$$b_i^{t+1} = p_{\text{lbest}}^t + \boldsymbol{\alpha} \cdot (b_i^t - L^{\text{a}}) + \boldsymbol{\beta} \cdot (b_i^t - U^{\text{a}}) \tag{17}$$

式中，b_i^t为第t次迭代时第i个卵球的位置信息；$\boldsymbol{\alpha}$、$\boldsymbol{\beta}$分别为维度为3的独立随机向量(因为优化的超参数为3个)。

觅食行为中，蜣螂群体建立最优觅食区域引导种群进行觅食活动，即在多个局部最优范围内继续寻优，此过程是对超参数空间的全局寻优。最佳的觅食区域可表示为

$$\begin{cases} L^{\text{b}} = \max\left\{ p_{\text{gbest}}^t \cdot (1-R),\ L \right\} \\ U^{\text{b}} = \min\left\{ p_{\text{gbest}}^t \cdot (1+R),\ U \right\} \end{cases} \tag{18}$$

式中，p_{gbest}^t为全局最优超参数；L^{b}、U^{b}分别为最优觅食区域的下界和上界。此时其他觅食蜣螂会根据先驱蜣螂已划分好的区域，动态更新自身位置以优化超参数取值，此过程可表示为

$$p_i^{t+1} = p_i^t + \gamma \cdot (p_{\text{gbest}}^t - L^{\text{b}}) + \boldsymbol{\delta} \cdot (p_i^t - U^{\text{b}}) \tag{19}$$

式中，γ为服从正态分布的随机数；$\boldsymbol{\delta}$为随机向量。

偷窃行为中，某些蜣螂会以窃取食物为目标更新自身位置，即直接从局部最优位置来进行超参数优化，此过程可表示为

$$p_i^{t+1} = p_{\text{gbest}}^t + C \cdot \boldsymbol{\varepsilon} \cdot (\left| p_i^t - p_{\text{gbest}}^t \right| + \left| p_i^t - p_{\text{lbest}}^t \right|) \tag{20}$$

式中，C为常数；$\boldsymbol{\varepsilon}$为服从正态分布的随机向量。

通过上述4种行为来执行不同搜索算法，从而在全局对模型隐藏层、神经元以及学习率3个超参数进行优化以增强模型表现性能。

3 算例分析

3.1 特征数据处理

本文讨论的风光耦合发电系统采取风电和光伏协同互补的发电模式，当进行风力发电时还需考虑光伏发电相关因素的影响，反之在进行光伏发电时亦是如此。两者的协同发电功率(即总功率)则需要考虑全部因素的影响，因此分别收集影响风力发电和光伏发电的相关特征数据作为输入。

根据风能转换原理，风力发电机组的功率输出主要取决于风速，除此之外，风向变动、大气压强、环境温度等因素也会影响其功率大小。因此，选取其主要影响因素：不同高度风速、不同高度风向、气温、气压、湿度等，并通过气象网站、云端共享数据等各项平台，以15 min为时间间隔采集中国西北地区某风光协同发电厂2024年1月份的风力发电相关特征数据。受篇幅限制，本文仅列出部分数据以供参考，如表1所示。

光伏发电机组的功率输出主要与光照强度相关，太阳辐射是其主要影响因素之一，其他环境因素会产生两方面的影响效应：一是直接影响机组的运行状态，二是通过环境变化影响光照强度从而引起机组功率波动。因此，选取光伏发电主要影响因素：水平总辐射、水平散射辐射、倾角辐射、光伏组件倾斜角度、气温、气压、湿度等。同理，通过气象网站、云端共享数据等各项平台，以15 min为时间间隔采集该电厂2024年1月份光伏发电相关特征数据。部分数据如表2所示。

对收集到的数据进行完整性检验，通过预处理

表1 2024年1月风力发电特征数据(部分)

Table 1 Wind power characteristic data in January 2024 (partial)

时刻	测风塔30 m风速/(m·s^{-1})	测风塔50 m风速/(m·s^{-1})	测风塔70 m风速/(m·s^{-1})	测风塔30 m风向/(°)	测风塔50 m风向/(°)	测风塔70 m风向/(°)	气温/℃	气压/(hPa)	湿度/%
00:00	0.453	0.612	0.818	166.816	177.355	210.836	−13.154	898.710	53.497
00:15	0.653	0.693	1.092	166.832	177.356	260.855	−13.864	898.621	55.999
00:30	0.826	0.771	1.166	166.859	177.353	264.771	−14.461	898.497	57.747
00:45	0.921	1.297	1.324	166.894	177.344	288.001	−13.066	898.329	54.162

表 2　2024年1月光伏发电特征数据(部分)

Table 2　Photovoltaic power characteristic data in January 2024 (partial)

时刻	水平总辐射/($W \cdot m^{-2}$)	水平散射辐射/($W \cdot m^{-2}$)	倾角辐射/($W \cdot m^{-2}$)	光伏组件倾斜角度/(°)	气温/℃	气压/(hPa)	湿度/%
00:00	2.207	0.606	2.898	35	−13.154	898.710	53.497
00:15	2.057	0.510	2.771	35	−13.864	898.621	55.999
00:30	1.598	0.430	2.846	35	−14.461	898.497	57.747
00:45	2.436	0.809	2.799	35	−13.066	898.329	54.162

操作去除空白值和重复值，利用最邻近法替换异常值得到重构后的数据集。在此基础上，利用互信息来衡量各种影响因素与风电和光伏的相关关系，并代入DBO-BiLSTM-Attention模型中以获取更精准的预测结果。

3.2　模型评价指标

本文从平均绝对误差 e_{MAE}、平均绝对百分比误差 e_{MAPE}、e_{MSE}、均方根误差 e_{RMSE} 以及拟合度 R^2 等方面来对功率预测结果进行评价。其中，前4个指标的误差值越小，模型预测精度越高，最后一个指标值越高，模型表现越好。各种评价指标的计算分别为

$$e_{MAE}=\frac{1}{n}\sum_{i=1}^{n}\left|\hat{y}_i-y_i\right| \tag{21}$$

$$e_{MAPE}=\frac{100\%}{n}\sum_{i=1}^{n}\left|\frac{\hat{y}_i-y_i}{y_i}\right| \tag{22}$$

$$e_{MSE}=\frac{1}{n}\sum_{i=1}^{n}(\hat{y}_i-y_i)^2 \tag{23}$$

$$e_{RMSE}=\sqrt{\frac{1}{n}\sum_{i=1}^{n}(\hat{y}_i-y_i)^2} \tag{24}$$

$$R^2=1-\frac{\sum_{i=1}^{n}(y_i-\hat{y}_i)^2}{\sum_{i=1}^{n}(y_i-\bar{y})^2} \tag{25}$$

式(21)～(25)中，n 为样本数量；y_i 为真实功率值；$\hat{y}_i$ 为预测功率值；$\bar{y}$ 为样本均值。

3.3　特征因素关联关系

各项特征因素可以视作不同的自变量，风电功率和光伏功率则视作不同的因变量，将数据代入式(1)中，计算得到每个特征因素对风电功率和光伏功率的互信息值，即不同特征因素对2种发电功率的关联性，结果如表3所示。

参考文献[29]对相关性的描述，可将表3相关性以0～0.2(弱相关)、0.2～0.4(较弱相关)、0.4～0.6(普通相关)、0.6～0.8(较强相关)、0.8～1.0(强相关)划分为5个等级标准，以此对风光功率和特征因素的关联关系进行分析。对于风电功率，风速的影响较大，这是由风力发电原理造成的，即风力越大所能转化的电势能越多。风向会决定风机叶片对于风能的捕捉利用率，对风电功率有一定影响。此外气压在一定程度上也会对风电功率产生影响，可以理解为压强小的地方气体流速加快，即风速变快、风力变大，从而导致风能质量和发电利用率受影响。其他因素如辐射大小、光伏组件倾斜角度、气温和湿度则对风电功率影响较小。

对于光伏功率来说，辐射大小对其影响较大，即太阳能越多所能转化的电势能越多。光伏组件倾斜角度决定太阳能的捕捉利用率，因此会对光伏功率有一定影响。除此之外，气温和湿度的影响也需要被考虑，因为日照充足的环境下往往显现出干燥和高温特征。而其他因素如风速、风向、气压等则对光伏功率影响不大。

表 3　风电功率、光伏功率及其特征因素的互信息值

Table 3　Mutual information values of wind power, photovoltaic power, and characteristic factors

功率类型	测风塔30 m风速/($m \cdot s^{-1}$)	测风塔50 m风速/($m \cdot s^{-1}$)	测风塔70 m风速/($m \cdot s^{-1}$)	测风塔30 m风向/(°)	测风塔50 m风向/(°)	测风塔70 m风向/(°)	气温/℃
风电	0.81	0.86	0.82	0.53	0.58	0.49	0.21
光伏	0.28	0.29	0.26	0.17	0.19	0.11	0.51

功率类型	气压/(hPa)	湿度/%	水平总辐射/($W \cdot m^{-2}$)	水平散射辐射/($W \cdot m^{-2}$)	倾角辐射/($W \cdot m^{-2}$)	光伏组件倾斜角度/(°)
风电	0.44	0.25	0.29	0.21	0.22	0.19
光伏	0.34	0.49	0.79	0.71	0.72	0.59

尽管不同因素对风电和光伏的影响不尽相同，但风光协同发电时仍然需要充分考虑这些因素带来的影响。因此，将所有互信息值代入式(10)～(12)求得各特征向量分别对风电、光伏功率的影响重要性，将带有权重的全部特征向量数据作为输入以进行模型训练和功率预测。

3.4 模型预测结果评价

算例共采集2 976个样本点，划分前70%的2 083个样本点作为训练集，后30%的893个样本点作为测试集。首先，利用DBO算法对模型隐藏层层数、神经元个数和学习率3个超参数进行寻优，寻优过程如图7所示。

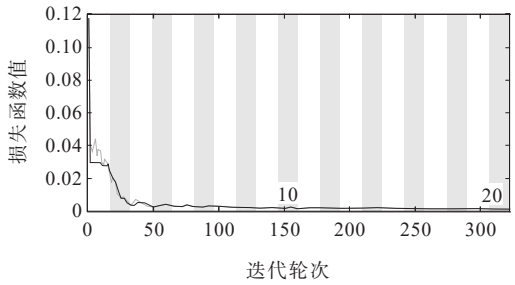

图7 DBO优化BiLSTM-Attention模型超参数的过程

Figure 7 Optimization process of DBO for hyperparameters of BiLSTM-Attention model

该过程进行了22轮、每轮15次的迭代计算，总共进行了330次寻优操作，损失函数在约第50代开始逐渐收敛，从第100代开始逐渐平缓并趋于最小值，在第330代不再降低。此时找到的最优超参数分别为：隐藏层层数10、神经元个数100、学习率0.1。保持最优超参数设置，将所有特征数据及其与风电功率、光伏功率的互信息值代入模型，以15 min为间隔进行训练和预测，得到风光协同发电功率的预测结果如图8所示。

图8展示了风光协同发电时的总功率预测情况，其真实值是风电功率和光伏功率的总和，预测值则是考虑了各特征因素对风电和光伏2种功率的影响所得出的结果。由图8可知，预测值和真实值的走势基本相同，两者数值普遍比较贴合，训练集误差较测试集误差小，模型表现较好。对于整个发电系统来说，预测的总功率是2种能源协同发电的结果，并非仅仅是简单的单一能源预测功率的加和，因为其中一种功率在预测时有误差，另一种功率同样也会产生预测误差，简单的相加可能会导致误差更大或是相互抵消，反而对结果精度造成影响。因此，在考虑2种发电方式受各种特征因素影响的情况下，从整体上进行总功率预测，对于能源的整体协同利用有着重大意义。

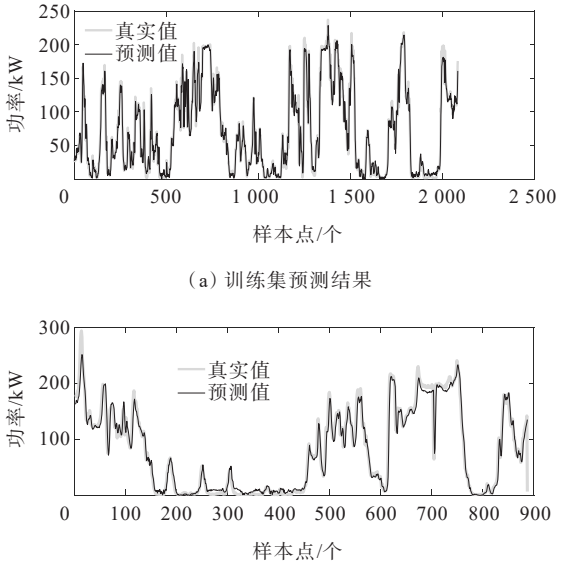

图8 基于DBO-BiLSTM-Attention模型的风光协同发电功率预测结果

Figure 8 Wind-photovoltaic synergy power forecasting results based on DBO-BiLSTM-Attention model

为进一步描述所提模型的性能改进情况，将特征数据代入不同阶段的模型中进行预测，分别为LSTM、BiLSTM、BiLSTM-Attention以及DBO-BiLSTM-Attention共4种模型，结果如图9所示。

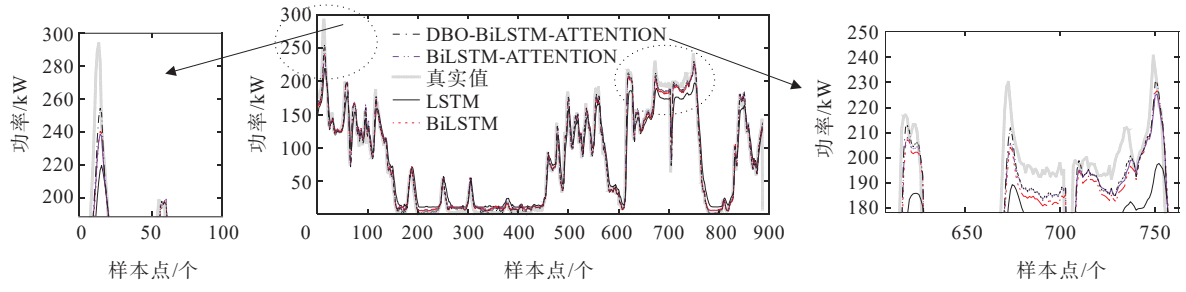

图9 改进前后的4种模型预测值与真实值对比

Figure 9 Comparison between forecasting values and observed values of 4 models before and after improvement

由图 9 可知，随着方法的不断改进和优化，其预测结果不断趋近于真实值，预测精度也在不断提高，尤其是图中标记的两处峰值较为明显。对于 LSTM 和 BiLSTM 而言，由于没有 Attention 机制，因此互信息值并不参与到计算过程当中，这意味着模型在训练样本时平等地将所有特征向量作为输入，这会使得大量的噪声数据和干扰项混入其中，从而导致网络建模效果变差。而两者的唯一区别则是 BiLSTM 网络会接收来自前后双向的信息，以考虑多个时刻之间的信息关联性，较 LSTM 只考虑单向信息的效果要好。对于 BiLSTM-Attention 而言，在 Attention 机制和互信息的作用下，模型会根据不同特征向量对风力发电和光伏发电的影响程度来进行预测，既可以专注于重要特征的适配计算，又可以避免冗余数据的算力负载。当使用 DBO 优化算法寻得 BiLSTM-Attention 隐藏层层数、神经元个数和学习率的最优值时，相当于对其网络结构进行了优化，使模型表现效果得到一定程度的提升，此时 DBO-BiLSTM-Attention 模型的表现效果最好。

为更精确地评价预测结果，根据式(21)～(24)计算出 4 种模型的预测误差，各模型的各项误差指标对比如图 10 所示。

图 10(a)表明不同指标的相对大小，可以看出各项误差指标排序均是 LSTM＞BiLSTM＞BiLSTM-Attention＞DBO-BiLSTM-Attention。具体数值可参考图 10(b)中的柱状图，e_{MAE} 大小排列为 15.98＞12.35＞10.88＞8.86，方法改进后得到的精度提升分别为 22.72%、11.90% 和 18.57%。e_{MAPE} 排列为 5.87%＞4.69%＞3.78%＞3.09%，表明所提模型相对真实值的误差是最小的，效果最好。由于 e_{MSE} 量纲较大，此处用 e_{RMSE}(对 e_{MSE} 进行开平方根)来衡量误差大小，其值排列为 20.97＞16.12＞14.68＞13.14，经过方法改进后其精度提升分别为 23.13%、8.93% 和 10.49%。结果表明，对方法的每一步改进都一定程度上提高了原有模型的精度，所提的 DBO-BiLSTM-Attention 模型是所有改进模型里性能最好的。

根据式(25)对模型拟合程度进行分析，评价其表现效果，一般认为 R^2＞0.8 时拟合效果较好。4 种模型的误差指标和拟合效果如图 11 所示。

从图 11 中可以看出，所有模型的拟合度均高于 0.8，表明这些模型在预测方面的表现是比较良好的，其中 LSTM 拟合度最低，为 0.870 7，其次是 BiLSTM 为 0.901 2，然后是 BiLSTM-Attention 为 0.914 2，最高是 DBO-BiLSTM-Attnetion 模型为 0.927 3，拟合度分别提升了 3.50%、1.44% 和 1.43%。因此，改进后的模型在各项性能上都有了一定程度的提高，可取得较为准确的预测结果。

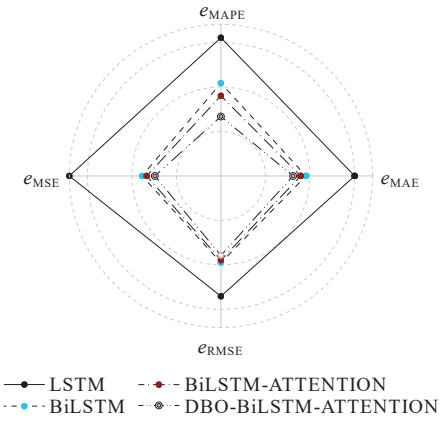

(a) 误差雷达图

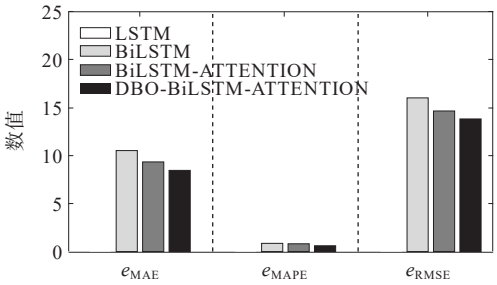

(b) 误差柱状图

图 10　改进前后的 4 种模型预测结果误差对比

Figure 10　Error comparison of 4 models before and after improvement

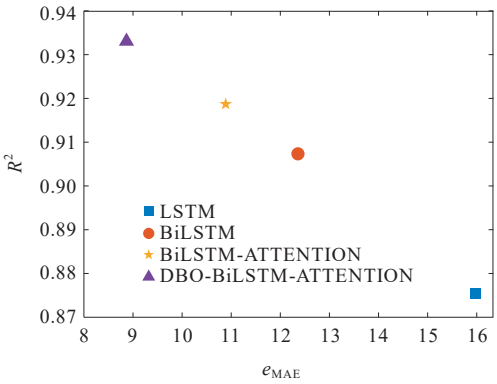

图 11　改进前后的 4 种模型拟合情况对比

Figure 11　Comparison of fitting degree of 4 models before and after improvement

3.5　情景分析

算例利用互信息值表示特征因素与风电功率和光伏功率的相关性，为进一步证实这些关联关系的合理性，需要将互信息值与相关性分析方法得出

的值进行对比验证，并考虑不同相关性情景下的模型预测结果。本文选取Pearson系数、Spearman系数以及Kendall系数这3种常用的相关系数来衡量特征因素与2种功率的相关性，并与互信息值作比较；同时就不同因素对不同功率的相关性，采用ICC组内相关系数分析互信息值与各相关系数的一致性，以检验互信息值的可信度。各系数计算与检验结果如表4所示。

由表4结果可知，尽管互信息与3种相关系数的取值不尽相同，但特征因素与2种功率的关联程度基本一致。对于风电功率，风速呈强相关性，风向和气压呈一般相关性，光照辐射、光伏组件倾斜角度、气温和湿度呈弱相关性。互信息值与Pearson系数、Spearman系数、Kendall系数的ICC组内相关系数分别为0.932、0.947、0.951，表明在衡量风电功率和各特征因素相关性时，使用互信息与使用其他3种相关系数所得的结果具有很强一致性，可信度较高。同理，对于光伏功率，光照辐射呈强相关性，光伏组件倾斜角度、气温和湿度呈一般相关性，风速、风向、气压呈弱相关性。互信息值与Pearson系数、Spearman系数、Kendall系数的ICC组内相关系数分别为0.939、0.926、0.941，光伏功率和各特征因素的互信息通过了一致性检验。

虽然互信息与3种相关系数都能表示特征因素与风、光发电功率的关联关系，但其在风光协同发电功率预测中的表现效果仍需进行讨论。本文考

表4 互信息值与不同相关系数的结果对比与一致性检验

Table 4 Result comparison and consistency test between mutual information values and different correlation coefficients

功率类型	相关系数	测风塔30 m风速/(m·s^{-1})	测风塔50 m风速/(m·s^{-1})	测风塔70 m风速/(m·s^{-1})	测风塔30 m风向/(°)	测风塔50 m风向/(°)	测风塔70 m风向/(°)	ICC组内相关系数
风电	互信息值	0.81	0.86	0.82	0.53	0.58	0.49	1
	Pearson系数	0.85	0.88	0.83	0.48	0.53	0.52	0.932
	Spearman系数	0.78	0.80	0.81	0.49	0.56	0.55	0.947
	Kendall系数	0.72	0.75	0.79	0.51	0.52	0.44	0.951
光伏	互信息值	0.28	0.29	0.26	0.17	0.19	0.11	1
	Pearson系数	0.23	0.25	0.22	0.21	0.22	0.14	0.939
	Spearman系数	0.19	0.20	0.16	0.19	0.21	0.15	0.926
	Kendall系数	0.22	0.24	0.19	0.22	0.24	0.19	0.941

功率类型	相关系数	水平总辐射/(W·m^{-2})	水平散射辐射/(W·m^{-2})	倾角辐射/(W·m^{-2})	光伏组件倾斜角度/(°)	气温/℃	气压/(hPa)	湿度/%
风电	互信息值	0.29	0.21	0.22	0.19	0.21	0.44	0.25
	Pearson系数	0.31	0.25	0.23	0.15	0.19	0.41	0.29
	Spearman系数	0.25	0.21	0.20	0.16	0.18	0.47	0.25
	Kendall系数	0.26	0.22	0.23	0.16	0.19	0.46	0.23
光伏	互信息值	0.79	0.71	0.72	0.59	0.51	0.34	0.49
	Pearson系数	0.85	0.81	0.79	0.52	0.56	0.31	0.44
	Spearman系数	0.81	0.79	0.78	0.53	0.49	0.30	0.48
	Kendall系数	0.78	0.74	0.75	0.60	0.52	0.36	0.53

考虑将不同相关系数和对应的特征数据代入DBO-BiLSTM-Attention模型中进行风光协同功率预测，分析产生的结果误差，以讨论不同相关系数对预测结果的影响。为此设置如下4种情景。

情景1：多元互信息耦合的风光协同发电功率预测。该情景为文3.3节的基本算例情景，即将各项特征因素的互信息和数据代入所提模型进行训练和预测。

情景2：考虑Pearson系数的风光协同发电功率预测。该情景将各项特征因素的Pearson系数和数据代入所提模型进行训练和预测。

情景3：考虑Spearman系数的风光协同发电功率预测。该情景将各项特征因素的Spearman系数和数据代入所提模型进行训练和预测。

情景4：考虑Kendall系数的风光协同发电功率预测。该情景将各项特征因素的Kendall系数和数据代入所提模型进行训练和预测。

4种情景下风光协同发电功率的预测误差如图12所示。可知，从误差分布来看，情景1的预测误差围绕中心零点进行浮动，其他情景的预测误差或者部分高于零点，或者部分低于零点。这反映出在利用互信息衡量特征因素相关性时，误差能够保持在一个稳定的范围内，预测结果稳定贴合实际值。而考虑用其他系数衡量特征因素进行预测时，误差时而偏高时而偏低，结果稳定性较差。从误差程度来看，情景1的预测误差相较于其他情景，其浮动范围较小，距离中心点的离散程度偏低，表明互信息能较好地解释特征因素和发电功率的相关性，减小预测误差和随机性。因此在衡量变量间的关联关系并用于模型预测时，考虑互信息能取得比较良好的效果。

3.6　方法对比分析

为验证本文所提模型的有效性和合理性，需要

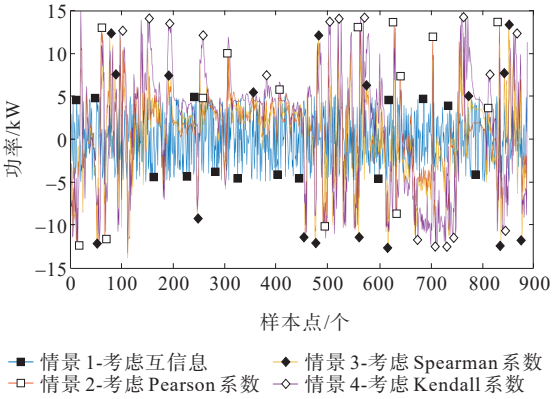

图12　不同情景下的风光协同功率预测误差对比

Figure 12　Error comparison of wind-photovoltaic synergy power forecasting under different scenarios

将特征数据和功率数据代入其他不同模型进行预测，并对各模型表现进行评价分析。方法对比主要从如下几个方面进行：首先，对比DBO-BiLSTM-Attention模型改进前后的预测结果，讨论方法改进效果；其次，将所提模型与其他预测方法进行对比，参考文献[30-31]并选取GA-BP和VPSO-Elman这2种先进算法作为对照；最后，由于DBO在模型中的作用是优化隐藏层层数、神经元个数以及学习率，同为智能算法的GA和VPSO也具备优化效果。因此，分别考虑采用这2种智能算法对超参数进行优化并对比最终预测结果，以讨论DBO在方法改进中的效用。利用各种方法模型进行风光协同发电功率预测的比较结果如表5所示。

根据表5分析不同方法模型的表现性能，发现随着算法不断改进，预测拟合度和结果精度也在不断优化，其中模型式(1)～(4)的改进结果已在文3.3进行分析，在此不再赘述。对比模型式(4)～(6)，可看出模型式(4)的拟合度及误差都是最优，表明DBO对模型超参数的优化效果要高于GA和VPSO。对比模型式(4)、(7)、(8)，发现与GA-PB

表5　不同方法模型的预测结果对比

Table 5　Result comparison of different models

序号	方法模型	训练集/%	测试集/%	拟合度 R^2	e_{MAE}	e_{MAPE}
(1)	LSTM	70%	30%	0.870 7	15.98	5.87%
(2)	BiLSTM	70%	30%	0.901 2	12.35	4.69%
(3)	BiLSTM-Attention	70%	30%	0.914 2	10.88	3.78%
(4)	DBO-BiLSTM-Attention	70%	30%	0.927 3	8.86	3.09%
(5)	GA-BiLSTM-Attention	70%	30%	0.921 1	9.75	3.28%
(6)	VPSO-BiLSTM-Attention	70%	30%	0.922 8	10.23	3.31%
(7)	GA-BP	70%	30%	0.919 9	11.23	3.36%
(8)	VPSO-Elman	70%	30%	0.920 8	12.09	3.49%

和VPSO-Elman相比，LSTM在拓展成BiLSTM以及加入Attention机制后仍然不具备性能上的优势，但通过DBO算法对其超参数进行优化后，模型表现相较其余算法得到一定改进。因此，DBO算法与BiLSTM-Attention有着良好的契合效果，所构建的模型可作为功率预测的有力手段，助力实现风光资源高效利用。

3.7 灵敏度分析

模型参数的取值将会对预测结果产生影响，训练集和测试集的划分也会有一定程度上的作用，为探究本算例中超参数优化前后的模型性能，以及超参数变化对预测结果的影响，本文对样本比例和超参数进行灵敏度分析以验证所提模型的可靠性。算例中训练集和测试集的划分比例为70%和30%，DBO-BiLSTM-Attention模型优化后的超参数分别为：隐藏层层数为10，神经元个数为100，学习率为0.1。因此划分不同比例的数据集合，围绕最优参数增大或减小3个超参数的取值，讨论数据集和超参数变动对模型预测性能的影响。为更清晰地展示影响结果，先将学习率固定为最优取值0.1，调整样本比例、隐藏层层数和神经元个数，进行模型训练和预测后得到如表6所示的结果。

从表6可以得出以下结论。

1）训练集和测试集的样本划分对模型的预测时间几乎没有影响，但对预测精度有着不同作用。当训练集样本量足够大时，最终的预测值拟合度较高，结果误差也越小，这是因为模型得到了充分训练，而后将测试数据代入经过训练的模型后，所得到的结果越能够接近真实值。

表6 不同数据集下隐藏层层数和神经元个数对DBO-BiLSTM-Attention模型性能的影响

Table 6 Effects of number of hidden layers and neuron on performance of DBO-BiLSTM-Attention model under different datasets

训练集/%	测试集/%	隐藏层层数	神经元个数	预测时间/s	拟合度 R^2		e_{MAE}	e_{MAPE}/%
					训练集	测试集		
		5	80	19.4±1.3	0.960 8	0.922 2	9.21	3.36
		5	100	17.6±1.0	0.980 8	0.926 5	8.98	3.15
		5	120	12.0±1.1	0.973 8	0.924 6	9.13	3.27
		10	80	27.0±1.0	0.961 8	0.922 9	8.98	3.24
70	30	**10**	**100**	**18.2±1.1**	**0.981 7**	**0.927 3**	**8.86**	**3.09**
		10	120	14.5±1.0	0.974 4	0.925 2	8.94	3.18
		15	80	42.0±1.0	0.961 3	0.922 3	9.16	3.58
		15	100	22.0±1.0	0.981 1	0.926 7	9.02	3.22
		15	120	16.6±1.0	0.973 9	0.924 8	9.08	3.39
		5	80	18.5±1.5	0.961 9	0.930 3	8.37	3.09
		5	100	13.1±1.1	0.981 5	0.933 2	8.22	2.89
		5	120	12.0±1.1	0.974 6	0.931 8	8.34	2.97
		10	80	27.0±1.0	0.963 3	0.931 3	8.17	2.93
80	20	**10**	**100**	**18.2±1.2**	**0.982 4**	**0.933 9**	**8.05**	**2.74**
		10	120	15.0±1.2	0.975 8	0.932 5	8.21	2.84
		15	80	43.0±1.0	0.962 8	0.930 8	8.24	3.02
		15	100	22.0±1.0	0.981 7	0.933 4	8.17	2.81
		15	120	19.1±1.3	0.974 4	0.932 2	8.26	2.91
		5	80	18.5±1.5	0.963 6	0.930 3	8.08	2.12
		5	100	13.0±1.3	0.983 3	0.932 9	7.93	1.93
		5	120	12.0±1.3	0.975 1	0.932 0	8.12	2.06
		10	80	28.0±1.5	0.964 2	0.931 1	8.01	2.01
90	10	**10**	**100**	**17.0±1.5**	**0.984 5**	**0.934 5**	**7.85**	**1.81**
		10	120	14.6±1.2	0.976 7	0.932 6	8.03	1.94
		15	80	43.0±1.0	0.963 5	0.930 8	8.12	2.08
		15	100	23.0±1.0	0.983 7	0.933 1	8.03	1.89
		15	120	16.5±1.1	0.975 2	0.932 1	8.15	2.03

2）当模型中隐藏层的层数越多，预测所需要的时间越长，这是由算法的神经网络结构和Attention机制结合所导致的。由于当前网络层需要从前后网络层中读取输入信息以便进行输出，因此中间隐藏的网络层数越多，所需要的计算时间越长。但该现象可以通过增加网络中的神经元节点得以缓解，表现为节点数越多，所能够并行计算的能力越强，计算效率越高。

3）在不同比例的数据集下，当隐藏层为10层、神经元为100个时，预测拟合度和误差都为最优（表6中标黑数据）。此时不论是增大或减小隐藏层层数还是神经元个数，模型的预测性能都呈下降趋势，表明超参数取值确实为最优，优化后的模型结果较为可靠。值得注意的是，代入最优超参数进行预测的用时并非最短，需依实际情况权衡预测速度和精度之间的关系。

基于上述分析进一步讨论学习率变动对模型预测的影响，将隐藏层层数和神经元个数分别固定为最优取值10和100，调整样本比例和学习率，进行模型训练和预测后得到如表7所示的结果。

表7　不同数据集下学习率对DBO-BiLSTM-Attention模型性能的影响

Table 7　Effects of learning rates on performance of DBO-BiLSTM-Attention model under different datasets

训练集/%	测试集/%	学习率	预测时间/s	拟合度 R^2		e_{MAE}	e_{MAPE}/%
				训练集	测试集		
		0.05	31.0±1.4	0.981 4	0.926 6	8.91	3.17
70	30	**0.10**	**18.2±1.1**	**0.981 7**	**0.927 3**	**8.86**	**3.09**
		0.15	11.4±1.1	0.971 2	0.918 7	10.57	4.42
		0.05	32.0±1.2	0.981 9	0.932 5	8.33	2.82
80	20	**0.10**	**18.2±1.2**	**0.982 4**	**0.933 9**	**8.05**	**2.74**
		0.15	12.0±1.1	0.973 6	0.921 8	10.24	4.15
		0.05	31.6±1.5	0.983 5	0.933 9	7.96	1.95
90	10	**0.10**	**17.5±1.5**	**0.984 5**	**0.934 5**	**7.85**	**1.81**
		0.15	11.6±1.0	0.975 1	0.924 8	9.95	3.78

从表7数据可以发现，模型预测时间随着学习率的增大而变短，当学习率为0.1时，不论何种数据集，预测结果的表现都最好（表7中标黑数据），表明学习率取值达到最优。当学习率由0增长到0.1时，模型拟合度与预测精度的提升较小；而当学习率大于0.1继续增长时，模型拟合度与预测精度反而呈下降趋势。这是因为采用小值学习率进行模型训练时，训练结果最终都会逐渐收敛于最优，对精度影响并不明显，只不过会产生效率上的弊端。过大的学习率虽然能加快收敛进程，但可能会使预测结果在大范围内浮动并偏离原始数据，导致精度下降。因此，通过DBO算法寻找模型超参数的最优取值，优化隐藏层层数为10、神经元个数为100、学习率为0.1，能对提高模型性能发挥良好作用，确保预测结果的准确可靠。

4　结语

风能、太阳能等清洁能源互补发电是创新协同发电系统能源利用优化、供能稳定可靠的重要举措。然而，风电功率和光伏功率受环境波动影响较大，两者协同进行发电时的总功率亦会同时受到风力发电和光伏发电的影响，亟需探索能够精准预测风光协同发电功率的方法以保障电力供需平衡。本文主要做了如下研究工作。

1）论述了风光协同发电系统的结构及组成，分析了风电、光伏及其协同发电模式，为进行风光协同发电功率预测奠定基础。考虑影响风力发电和光伏发电的环境因素，通过创新方法模型进行功率预测分析，为提高风光资源利用效率、保障电网稳定运行、促进电力能源需求消纳提供可行思路。

2）在原有LSTM网络的基础上将其扩展成具有双向结构的BiLSTM网络，将互信息耦合进来以探讨各影响因素与风电功率、光伏功率的关联关系，同时嵌入Attention机制突出关联影响因素对风力发电和光伏发电的重要特征，既缓解网络算力负载又能够根据特征数据进行针对性的训练计算，在此基础上引入DBO算法来优化网络结构中的隐藏层数、神经元个数和学习率等3个超参数，最终构建DBO-BiLSTM-Attention模型来对风光协同发电功率进行超短期预测。

3）将不同高度的风速和风向、不同角度的太阳辐射、光伏组件倾斜角度、气温、气压、湿度等作为预测的特征向量，收集了大量相关样本数据用作模型训练和测试，对风光协同发电功率进行预测和分析。结果表明，在进行风光协同发电总功率预测时，考虑各特征因素对风电和光伏各自功率的影响，预测结果与实际数值比较贴合。且随着原有方法的不断改进和优化，不论是从预测误差还是拟合度来进行评价，DBO-BiLSTM-Attention模型性能都得到了一定提升，表现效果都是最优。

4）为了验证所提模型的可靠性和合理性，分别进行了情景分析、方法对比分析以及灵敏度分析。

结果表明，利用互信息来衡量特征因素与发电功率的关联关系，在此情景下输入特征数据将对风光协同功率的预测结果起到更好的修正作用。同时，所提的 DBO-BiLSTM-Attention 模型具有良好的性能，可作为功率预测的有力手段来实现风光资源高效利用以及优化电力系统运行，助力提升清洁能源价值创造。

本文尚存在可改进之处，如还需考虑更多因素对于风电、光伏的影响情况、如何进一步优化模型参数以提高模型表现、实现精准功率预测后如何推动能源有效利用等，后续将围绕这一系列方向开展研究工作。

参考文献：

[1] 高志远，张晶，庄卫金，等．关于新型电力系统部分特点的思考[J]．电力自动化设备，2023，43(6)：137-143+151.
GAO Zhiyuan, ZHANG Jing, ZHUANG Weijin, et al. Thoughts on some characteristics of new style power system[J]. Electric Power Automation Equipment, 2023, 43(6):137-143+151.

[2] ZHANG J J, ZHANG Q, LI G L, et al. Hybrid model for renewable energy and load forecasting based on data mining and EWT[J]. Journal of Electrical Engineering & Technology, 2022, 17(3):1517-1532.

[3] KUSZNIER J. Influence of environmental factors on the intelligent management of photovoltaic and wind sections in a hybrid power plant[J]. Energies, 2023, 16(4): 1716.

[4] 姚明明，张新，杨培宏，等．基于改进风光场景聚类联合虚拟储能的源网荷储低碳优化调度[J]．电力系统保护与控制，2024，52(15)：115-130.
YAO Mingming, ZHANG Xin, YANG Peihong, et al. Low-carbon optimal scheduling of source-grid-load-storage based on improved wind-solar scene clustering combined with virtual energy storage[J]. Power System Protection and Control, 2024, 52(15):115-130.

[5] DOS REIS J, BOSE N, AMORIM A, et al. Wind and solar energy generation potential features in the extreme northern Amazon using reanalysis data[J]. Energies, 2023, 16(22):7671.

[6] 付小标，侯嘉琪，李宝聚，等．一种二模态天气分型方法及其在光伏功率概率预测的应用[J]．发电技术，2024，45(2)：299-311.
FU Xiaobiao, HOU Jiaqi, LI Baoju, et al. A two-modal weather classification method and its application in photovoltaic power probability prediction[J]. Power Generation Technology, 2024, 45(2):299-311.

[7] 林泽源，王宗尧，张凡，等．考虑氢能应用的光伏直流微电网中储能容量配置寻优方法研究[J]．高压电器，2024，60(7)：78-87.
LIN Zeyuan, WANG Zongyao, ZHANG Fan, et al. Research on optimization method for energy storage capacity configuration in photovoltaic DC micro grid considering hydrogen energy application[J]. High Voltage Apparatus, 2024, 60(7):78-87.

[8] 陈璨，苏紫诺，马原，等．基于分层关联性建模的分布式光伏功率超短期概率预测[J]．中国电力，2024，57(12)：50-59.
CHEN Can, SU Zinuo, MA Yuan, et al. Ultra-short-term probabilistic forecasting of distributed photovoltaic power generation based on hierarchical correlation modeling[J]. Electric Power, 2024, 57(12):50-59.

[9] 张建辉，白永利，马正雄，等．基于模糊二阶滤波的风电场混合储能双级能量管控策略[J]．电网与清洁能源，2024，40(7)：38-47.
ZHANG Jianhui, BAI Yongli, MA Zhengxiong, et al. Two-stage energy management strategy of wind farm hybrid energy storage based on fuzzy second-order filter[J]. Power System and Clean Energy, 2024, 40(7):38-47.

[10] WANG Z J, WANG L, REVANESH M, et al. Short-term wind speed and power forecasting for smart city power grid with a hybrid machine learning framework[J]. IEEE Internet of Things Journal, 2023, 10(21):18754-18765.

[11] 乌兰，刘全，黄志刚，等．优势加权互信息最大化的最大熵分层强化学习[J]．计算机学报，2023，46(10)：2066-2083.
WU Lan, LIU Quan, HUANG Zhigang, et al. Maximum entropy hierarchical reinforcement learning with advantage-weighted mutual information maximization[J]. Chinese Journal of Computers, 2023, 46(10):2066-2083.

[12] 刘超，孔兵，杜国王，等．高阶互信息最大化与伪标签指导的深度聚类[J]．浙江大学学报(工学版)，2023，57(2)：299-309.
LIU Chao, KONG Bing, DU Guowang, et al. Deep clustering via high-order mutual information maximization and pseudo-label guidance[J]. Journal of Zhejiang University (Engineering Science), 2023, 57(2): 299-309.

[13] HAN S, QIAO Y H, YAN J, et al. Mid-to-long term wind and photovoltaic power generation prediction based on copula function and long short term memory network[J]. Applied Energy, 2019, 239:181-191.

[14] LIU J C, LI Y H. Study on environment-concerned short-term load forecasting model for wind power based on feature extraction and tree regression[J]. Journal of Cleaner Production, 2020, 264:121505.

[15] LIU Z K, LI P, WEI D X, et al. Forecasting system with sub-model selection strategy for photovoltaic power output forecasting[J]. Earth Science Informatics, 2023, 16

(1):287-313.

[16] HOU H, LIU C, WANG Q, et al. Review of load forecasting based on artificial intelligence methodologies, models, and challenges[J]. Electric Power Systems Research,2022,210:108067.

[17] MUNAWAR U, WANG Z L. A framework of using machine learning approaches for short-term solar power forecasting[J]. Journal of Electrical Engineering & Technology,2020,15(2):561-569.

[18] CHENG L L, ZANG H X, WEI Z N, et al. Evaluation of opaque deep-learning solar power forecast models towards power-grid applications[J]. Renewable Energy, 2022,198:960-972.

[19] 刘念璋,杨健,柳玉,等.分布函数差异化导向的风电功率预测误差气象条件概率建模方法[J].电力自动化设备,2022,42(12):58-65.
LIU Nianzhang, YANG Jian, LIU Yu, et al. Probabilistic modeling method of weather condition for wind power forecasting error based on differentiation orientation of distribution function[J]. Electric Power Automation Equipment,2022,42(12):58-65.

[20] 唐冬来,周强,宋卫平,等.基于网格聚类的峡谷风电短期功率预测方法[J].供用电,2023,40(1):80-87.
TANG Donglai,ZHOU Qiang,SONG Weiping,et al.Short term power prediction method of canyon wind power based on grid clustering[J]. Distribution & Utilization, 2023,40(1):80-87.

[21] VALDIVIA-BAUTISTA S M, DOMÍNGUEZ-NAVARRO J A, PÉREZ-CISNEROS M, et al. Artificial intelligence in wind speed forecasting: a review[J]. Energies,2023,16(5):2457.

[22] HAN L J, WANG X H, YU Y, et al. Power load forecast based on CS-LSTM neural network[J]. Mathematics, 2024,12(9):1402.

[23] LI G N,WANG Y,XU C L,et al.BO-STA-LSTM:building energy prediction based on a Bayesian optimized spatial-temporal attention enhanced LSTM method[J]. Developments in the Built Environment,2024,18:100465.

[24] 张晓珂,张辉,戴小然,等.基于层次聚类和 BILSTM 的光伏短期功率预测模型[J].智慧电力,2024,52(9):41-48.
ZHANG Xiaoke, ZHANG Hui, DAI Xiaoran, et al. Photovoltaic short-term power forecasting model based on hierarchical clustering & BILSTM[J]. Smart Power, 2024,52(9):41-48.

[25] 任欢,王旭光.注意力机制综述[J].计算机应用,2021,41(S1):1-6.
REN Huan, WANG Xuguang. A summary of attention mechanism[J].Journal of Computer Applications,2021,41(S1):1-6.

[26] XUE J K, SHEN B. Dung beetle optimizer: a new meta-heuristic algorithm for global optimization[J]. The Journal of Supercomputing,2023,79(7):7305-7336.

[27] LIU R Y, ZHANG X J, WANG J, et al. An adversarial training-based mutual information constraint method[J]. Applied Intelligence,2023,53(20):24377-24392.

[28] BRAUWERS G, FRASINCAR F. A general survey on attention mechanisms in deep learning[J]. IEEE Transactions on Knowledge and Data Engineering,2021, 35(4):3279-3298.

[29] 牟长兴,张俊涛,程春田,等.考虑时空相关性的流域水风光多能互补系统高维不确定性场景生成方法[J].电网技术,2024,48(9):3614-3623.
MU Changxing,ZHANG Juntao,CHENG Chuntian,et al. High-dimensional uncertainty scenario generation method for hydro-wind-solar multi-energy complementary system considering spatio-temporal correlation[J]. Power System Technology, 2024, 48(9): 3614-3623.

[30] 邹文进,郝少飞,马刚,等.基于 CEEMD-GA-BP 神经网络的风光发电功率预测[J].电网与清洁能源,2022,38(3):111-118.
ZOU Wenjin, HAO Shaofei, MA Gang, et al. Forecast of wind and solar power generation based on CEEMD-GA-BP neural network[J]. Power System and Clean Energy, 2022,38(3):111-118.

[31] 李殿文,甘海涛,丁力,等.基于改进的 VPSO-ELman 神经网络的短期负荷预测[J].东北电力技术,2018,39(12):24-27+56.
LI Dianwen,GAN Haitao,DING Li,et al.Short term load forecasting based on improved VPSO-ELman neural network[J].Northeast Electric Power Technology,2018,39(12):24-27+56.