

# 面向复杂工况下分布式光伏发电功率的 向量加权平均-核极限学习机短期预测方法

李宁<sup>1</sup>, 柴浩凯<sup>1</sup>, 葛磊蛟<sup>2\*</sup>, 王晔琳<sup>1</sup>, 张鑫<sup>1</sup>, 魏佳喜<sup>1</sup>, 陈艳波<sup>3</sup>

- (1. 西安理工大学电气工程学院, 陕西省 西安市 710048;
2. 天津大学电气自动化与信息工程学院, 天津市 南开区 300072;
3. 新能源电力系统全国重点实验室(华北电力大学), 北京市 昌平区 102206)

## A Weighted Mean of Vectors Algorithm-kernel Based Extreme Learning Machine Short-term Prediction Method for Distributed Photovoltaic Power Generation Under Complex Conditions

LI Ning<sup>1</sup>, CHAI Haokai<sup>1</sup>, GE Leijiao<sup>2\*</sup>, WANG Yelin<sup>1</sup>, ZHANG Xin<sup>1</sup>, WEI Jiayi<sup>1</sup>, CHEN Yanbo<sup>3</sup>

- (1. College of Electrical Engineering, Xi'an University of Technology, Xi'an 710048, Shaanxi Province, China;
2. School of Electrical and Information Engineering, Tianjin University, Nankai District, Tianjin 300072, China;
3. National Key Laboratory of New Energy Power System (North China Electric Power University), Changping District, Beijing 102206, China)

**ABSTRACT:** Highly accurate short-term prediction of distributed photovoltaic power generation is one of the keys to the new power system scheduling plan and the implementation of new energy consumption. However, distributed photovoltaic has the characteristics of complex operating conditions, wide range of points, strong randomness and insufficient data collection frequency, etc. Traditional data-driven methods are faced with problems such as poor data sample quality and difficult optimization of model parameters. This paper proposes a Kernel based extreme learning machine based on weighted mean of vectors algorithm (INFO) short-term forecast method of distributed photovoltaic power generation by machine, KELM. To solve the problem that the extreme learning machine prediction model needs more hidden layer neurons when processing complex predictions, resulting in a very complex network structure, kernel function is introduced into the model, which can enhance the stability of the model and have strong generalization ability, realize large-scale photoelectric data processing and maintain high real-time

performance. In view of the difficulty of tuning the model parameters of the nuclear extreme learning machine, INFO is used to optimize the KELM parameters and reduce the error of the prediction results. Finally, seasonal data with obvious characteristics and three weather types, sunny, cloudy and rainy, are analyzed. Compared with KELM model, RF model, SVM model, GA-BP model, CNN-LSTM model and GA-KELM model, the results show that: the comprehensive determination coefficient of INFO-KELM PV power short-term prediction is 0.988, which is 8.51% and 6.14% higher than that of GA-BP and GA-KELM respectively. This method not only realizes accurate prediction, but also ensures high real-time performance.

**KEY WORDS:** vector weighted average; extreme learning machine; photovoltaic power generation forecast; kernel function

**摘要:** 高精度的分布式光伏发电功率短期预测是新型电力系统安排调度计划和落实新能源消纳的关键之一,然而,分布式光伏具有运行工况复杂、点多面广、随机性强且数据采集频次不足等特点,传统的数据驱动方法面临数据样本质量差、模型参数优化难等问题,为此,该文提出基于向量加权平均(weighted mean of vectors algorithm, INFO)-核极限学习机(Kernel based extreme learning machine, KELM)的分布式光伏发电功率短期预测方法。针对极限学习机预测模型处理复杂预测时,需要更多的隐层神经元,导致网络结构非常复

基金项目: 新一代人工智能国家科技重大专项(2022ZD0116900); 国家自然科学基金项目(52277118, 52577130); 天津市自然科学基金项目(22JCZDJC00660)。

Project Supported by National Science and Technology Major Project of China (2022ZD0116900); Project Supported by National Natural Science Foundation of China (52277118, 52577130); Natural Science Foundation of Tianjin (22JCZDJC00660).

杂的问题, 将核函数引入该模型中, 可在增强模型稳定性的同时拥有较强的泛化能力, 实现大规模光电数据处理并保持较高实时性; 针对核极限学习机模型参数难以整定的问题, 使用 INFO 对 KELM 参数进行优化, 减小预测结果的误差; 最后, 通过具有明显特征的季节性数据和晴天、多云、雨天 3 种天气类型进行数据分析。将该方法与 KELM 模型、RF 模型、SVM 模型、GA-BP 模型、CNN-LSTM 模型和 GA-KELM 模型 6 种方法进行对比, 结果表明: INFO-KELM 光伏发电功率短期预测的综合决定系数为 0.988, 较 GA-BP 和 GA-KELM 分别提升 8.51% 和 6.14%, 该方法在实现准确预测的同时也保证了较高的实时性。

**关键词:** 向量加权平均; 极限学习机; 分布式光伏发电预测; 核函数

## 0 引言

高精度的分布式光伏发电功率短期预测对于电力系统调度人员合理制定调度计划、提升分布式光伏消纳水平至关重要<sup>[1]</sup>。而分布式光伏发电工况复杂, 受到多种因素的综合影响, 包括天气变化、季节更替、数据不确定性以及功率波动等。现有的分布式光伏发电功率预测方法主要包括基于气象因素的物理方法、基于数理的统计学方法和基于机器学习的统计预测方法<sup>[2]</sup>。其中, 基于气象因素的光伏发电功率预测方法是指利用光伏发电系统的物理特性和原理, 结合气象、天文相关数据, 通过建立数学模型和物理模型来预测光伏发电系统的功率输出。这些物理方法<sup>[3-6]</sup>可能涉及太阳辐射的模拟、光伏组件的特性分析以及天气条件对光伏系统性能的影响等方面, 具有简单、计算速度快和成本低等优点。但这类方法需要大量历史数据, 且由于气象因素复杂性, 预测结果的不确定性会增加。分布式光伏发电功率预测的统计学方法包括自动回归滑动平均模型(autoregressive moving average model with eXogenous inputs, ARMAX)<sup>[7]</sup>、自回归积分滑动平均模型(autoregressive integrated moving average, ARIMA)<sup>[8]</sup>等时间序列法及色理论方法<sup>[9-10]</sup>。文献[8]通过建立 ARIMA 时间序列预测模型, 完成了配电网的分布式光伏发电功率的预测; 文献[9]利用灰色预测理论, 分析电动汽车充电站中的光伏发电系统, 并建立相应的发电量预测模型。这些统计学方法在预测时不需要考虑光伏系统参数和复杂的光电转换模型, 但其缺陷在于通常对数据有一定的假设性要求, 且在处理大规模高维数据时可能面临困难。

随着人工智能的发展, 机器学习方法越来越广

泛地应用在光伏发电功率短期预测领域。这类方法包括反向传播神经网络(backpropagation neural network, BP)、随机森林(random forests, RFs)、支持向量机等常规机器学习方法和卷积神经网络(convolutional neural network, CNN)和长短期记忆神经网络(long short-term memory, LSTM)等深度学习方法。文献[11]提出一种基于自适应学习率和权值的 BP 神经网络, 对俄勒冈州阿什兰的一个光伏系统数据进行处理并预测。BP 神经网络能够捕捉输入特征之间的非线性关系, 对于复杂的光伏发电特性建模较为有效。但 BP 神经网络的多个超参数均需要调整, 不合适的参数选择可能影响模型性能, 在这种情况下, 算法可能会陷入局部最优, 而无法找到全局最优解。文献[12]提出一种基于随机森林预测技术和蚁狮优化算法(ant lion optimizer, ALO)结合的混合预测模型, 对澳大利亚不同光照倾角的地区进行光伏发电功率预测, 该方法能够处理大量的输入特征, 并对特征进行自动选择, 无需手动进行特征筛选或数据预处理, 且不易过拟合。然而, 该方法要存储大量的决策树, 因而需要较高的内存容量, 且其可解释性较差。文献[13]提出一种基于环境因素和遗传算法优化支持向量机的预测模型, 该模型利用天津大学智能电网教育部重点实验室的实测功率数据和数值天气预报(numerical weather prediction, NWP)的气象数据, 对光伏系统进行了短期功率预测, 有效避免了参数选择过程中的局部最优。然而, SVM 模型的解释性较差且训练复杂性较高, 并且在处理大规模训练样本时存在困难。

深度学习方法非线性处理能力强、学习效率高, 且擅长解决时序数据预测问题。其中 CNN 在新能源领域应用广泛, 涵盖电力可靠性评估<sup>[14]</sup>、最大功率点电压预测<sup>[15]</sup>等。在发电功率预测方面, 文献[16]提出一个 5 层 CNN-LSTM 模型, 利用墨西哥莫雷洛斯州 Temixco 地区的真实数据进行光伏发电预测; 模型的构建不涉及领域知识或物理定律, 可能产生物理上不合理的预测, 因此文献[17]在 LSTM 预测模型基础上加入了物理约束。CNN 方法通过卷积操作, 能够减少模型的参数数量, 有助于降低过拟合风险, 但计算复杂度较高, 且需要调整卷积核的大小、层数等超参数。

作为一种浅层神经网络算法, 极限学习机(extreme learning machine, ELM)算法相对简单, 进行预测时易于理解和实现, 且初始化权重是随机

的,可以直接计算输出层权重,因此训练速度通常比传统神经网络更快,ELM已广泛应用于许多领域的预测问题<sup>[18-19]</sup>。相对于深度神经网络,ELM由于只能进行一次前向传播计算,容易出现无法进一步学习和过拟合的问题,但该问题在与很多其他方法结合后可以得到解决。许多基于ELM的光伏发电输出预测模型被提出,并证实了其良好的回归能力。Ni等<sup>[19]</sup>采用一种结合下限估计(lower upper bound estimation, LUBE)和ELM的集成方法来预测短期光伏发电量。考虑到收敛速度和预测精度,Tang等<sup>[21]</sup>将ELM与熵值法相结合,设计一种光伏短期输出的混合预测方法,该方法优于径向基函数神经网络和广义回归神经网络。文献[22]提出一种基于遗忘机制的在线顺序极限学习机的短期光伏发电预测模型,该模型的遗忘机制可以不断地用新数据替换过时的数据。核极限学习机(kernel extreme learning machine, KELM)是在传统ELM的基础上延展而来,用核映射代替随机映射,进而将高复杂低维的空间问题转化为高维空间内积运算问题。相较于ELM具有更强的网络输出稳定性和泛化能力,面对复杂、非线性的光伏数据时可以更好地捕捉数据中的时间关联特征。然而,包括KELM在内的传统人工神经网络的一些参数是随机分配的,这将对预测结果造成一定程度的误差和波动性。因此,需要引入优化算法对KELM模型进行改进。

基于以上讨论,本文使用一种元启发式算法向量加权平均(weighted mean of vectors algorithm, INFO)完成参数优化,并提出一种复杂工况下分布式光伏发电功率的INFO-KELM短期预测方法。首先,构建ELM光伏功率预测模型,以核映射代替随机映射,在增强模型稳定性的同时提高了泛化能力;其次,针对核极限学习机模型参数难以整定的问题,采用向量加权平均理论对KELM算法的参数进行优化,提出一种INFO-KELM分布式光伏发电功率预测模型,该方法能够有效改善核极限学习机模型随机产生的参数造成的网络不稳定问题,从而降低预测误差,在优化过程中,通过计算加权平均向量和更新个体位置来调整参数,避免了GA-KELM中的多次选择、交叉和变异操作,降低了计算复杂度和时间消耗,INFO-KELM通过加权平均向量的方法优化参数,能够适应不同的数据分布和特征,具有较强的适应性和鲁棒性;最后,通过真实光伏电站数据,并将发电数据按天气和

季节条件进行分类,验证该方法的预测准确性和通用性。

## 1 基于 INFO-KELM 的分布式光伏发电功率预测方法

本文针对核极限学习机模型进行分布式光伏发电功率这类复杂数据集的预测时,会出现参数难以整定的问题,使用向量加权平均算法对于核极限学习机的正则化系数和核参数进行参数寻优。该方法有效缓解了KELM模型对初始参数选取的敏感性,可以加快神经网络的收敛速度,并显著提升其预测精度。

### 1.1 核极限学习机模型

极限学习机<sup>[19-20]</sup>是由单隐层神经网络演化而来的一种新型网络,其结构类似于人工神经网络,由输入、隐藏和输出3个层次组成。首先对输出层进行数据处理,并将数据传输到输出层,再由输出层依据其对应的函数,得到计算值。

当隐含层神经元的激活函数为 $g(x)$ 时,对于一个给定的数据集 $\mathbf{x}_j = [x_{1j}, x_{2j}, \dots, x_{nj}]^T$ ,光伏发电功率的度量即ELM输出可表示为

$$\mathbf{y}_{\text{ELM}}(\mathbf{x}) = \mathbf{T} = [t_1, t_2, \dots, t_Q]_{m \times Q}, \quad (1)$$

ELM学习过程可等价于利用最小二乘法求最优解。为提高模型的稳定性和泛化能力,引入正则化系数 $C$ ,求得最小二乘解,即:

$$\beta^* = \mathbf{H}^+ \mathbf{T} = \mathbf{H}^T (\mathbf{H} \mathbf{H}^T + \frac{\mathbf{I}}{C})^{-1} \mathbf{T} \quad (2)$$

式中: $\mathbf{H}$ 为隐含层输出矩阵; $\mathbf{H}^+$ 为 $\mathbf{H}$ 的广义逆; $\beta$ 为隐含层与输出层间的连接权值。

最终ELM的输出可以表示为

$$\mathbf{y}_{\text{ELM}}(\mathbf{x}) = g(\mathbf{x}) \beta^* \quad (3)$$

传统ELM网络在预测光伏发电功率的过程中,可能因为随机产生输入层权值和隐含层阈值会造成网络不稳定问题,严重影响预测精度。

将核函数引入ELM中,采用核映射替换ELM中的激活函数。根据Mercer's条件,定义核矩阵为

$$\begin{cases} \Omega = \mathbf{H} \mathbf{H}^T \\ \Omega_{(i,j)} = h(x_i) h(x_j) = K(x_i, x_j) \end{cases} \quad (4)$$

式中 $K(x)$ 为核函数,本文选择平滑性和连续性较好的高斯核函数,即:

$$K(x_i, x_j) = \exp\left(-\frac{x_i - x_j^2}{g^2}\right) \quad (5)$$

式中  $g$  为核参数。

KELM 的预测输出函数可以表示为

$$y_{\text{KELM}}(x) = h(x)\beta^* = h(x)H^T(HH^T + \frac{I}{C})^{-1}T = \begin{bmatrix} K(x, x_1) \\ \vdots \\ K(x, x_l) \end{bmatrix} (\Omega + \frac{I}{C})^{-1}T \quad (6)$$

式中  $I$  为单位矩阵。

综上所述，核参数  $g$  和正则化系数  $C$  是影响 KELM 预测性能的重要因素。KELM 借助核函数，能够有效地捕捉数据中的非线性关系，从而具有较强的泛化能力，且相对基本的 ELM 算法，KELM 中仅需设置一个参数(核函数的参数)，参数调优相对简单。然而还是不能解决 ELM 本身的网络不稳定问题，参数调整受数据类型影响较大，尤其是在处理分布式光伏发电这样波动较大且特征相关性较强的数据集时，可能表现不佳。

因此，本文采用元启发式算法来获取最优参数，这类方法灵活性高、可以适应各类问题并迅速生成较好的最优解。

### 1.2 向量加权平均算法

向量加权平均算法<sup>[23]</sup>作为一种新型元启发式算法，具有寻优能力强、收敛速度快等优点。相比于遗传算法(genetic algorithm, GA)等其他同类算法，INFO 算法更高效，因为其利用了权重的分配来加速收敛，而不是依赖于随机搜索和变异。INFO 基于种群的优化算法，通过向量的不同加权平均规则进行寻优，计算搜索空间中一组向量的加权均值，该算法总体是由一组向量组成，通过证明可行解，INFO 算法在连续几代中找到最优解。

INFO 使用 3 种算子来更新每一代中向量的位置，分别如下。

#### 1.2.1 更新规则

INFO 使用基于均值的规则(meanrule)更新向量的位置，是从一组随机向量的加权均值中提取的。INFO 算法也加入了收敛加速部分(convergence acceleration, CA)以提高全局搜索能力，其使用最佳向量在搜索空间中移动当前向量。收敛加速部分可以表示为  $C_a$ ：

$$C_a = r_n \times \frac{x_{bs} - x_{a_1}}{f(x_{bs}) - f(x_{a_1} + \varepsilon)} \quad (7)$$

相较于 GA-KELM，INFO-KELM 在特征选择上更直接有效，避免了 GA 在特征选择过程中可能

出现的复杂性和冗余计算。该方法最终的新向量可以通过式(8)进行计算：

$$z_l^g = x_l^g + \sigma \times M + C_a \quad (8)$$

式中  $M$  为 MeanRule 变量。优化算法通常应该在全局进行搜索以得到搜索域中更优的解空间。相应地，基于  $x_{bs}$ 、 $x_{bt}$ 、 $x_{lg}$  和  $x_{a_1}^g$  的 INFO 算法的更新规则可以表示为如下两种情况：

$$\begin{cases} r < 0.5 \\ z_l^g = x_l^g + \sigma \times M + r_n \times \frac{(x_{bs} - x_{a_1}^g)}{(f(x_{bs}) - f(x_{a_1}^g) + 1)} \\ z_l^g = x_{bs} + \sigma \times M + r_n \times \frac{(x_{a_1}^g - x_b^g)}{(f(x_{a_1}^g) - f(x_{a_2}^g) + 1)} \end{cases} \quad (9)$$

$$\begin{cases} r > 0.5 \\ z_l^g = x_a^g + \sigma \times M + r_n \times \frac{(x_{a_2}^g - x_{a_3}^g)}{(f(x_{a_2}^g) - f(x_{a_3}^g) + 1)} \\ z_l^g = x_{bt} + \sigma \times M + r_n \times \frac{(x_{a_1}^g - x_{a_2}^g)}{(f(x_{a_1}^g) - f(x_{a_2}^g) + 1)} \end{cases} \quad (10)$$

式中： $z_l^g$  和  $z_l^g$  为第  $g^{\text{th}}$  代的新向量； $f(x)$  为目标函数的值； $a_1 \neq a_2 \neq a_3 \neq l$  是  $[1, N_p]$  中随机选择的整数； $\varepsilon$  为一个很小的常数； $r$  为  $[0, 1]$  的随机数； $r_n$  服从  $[0, 1]$  的正态分布； $x_{bs}$ 、 $x_{bt}$  和  $x_{ws}$  分别为第  $g$  代的群体中最优、较好和最差解向量。

INFO 算法通过基于最佳、较好与最差解的 MeanRule 指标来增加种群的多样性， $M$  可以表示为：

$$M = r \times W_{M_1, l}^g + (1 - r) \times W_{M_2, l}^g \quad (11)$$

$$\begin{cases} W_{M_1, l}^g = \delta \times \gamma + \varepsilon \times r, l = 1, 2, \dots, N_p \\ \gamma = \frac{w_1 \times (x_{a_1} - x_{a_2}) + w_2 \times (x_{a_1} - x_{a_3}) + w_3 \times (x_{a_2} - x_{a_3})}{w_1 + w_2 + w_3 + \varepsilon} \end{cases} \quad (12)$$

$$\begin{cases} w_1 = \cos((f(x_{a_1}) - f(x_{a_2})) + \pi) \times \exp(-|\frac{f(x_{a_1}) - f(x_{a_2})}{\omega}|) \\ w_2 = \cos((f(x_{a_1}) - f(x_{a_3})) + \pi) \times \exp(-|\frac{f(x_{a_1}) - f(x_{a_3})}{\omega}|) \\ w_3 = \cos((f(x_{a_2}) - f(x_{a_3})) + \pi) \times \exp(-|\frac{f(x_{a_2}) - f(x_{a_3})}{\omega}|) \end{cases} \quad (13)$$

式中  $\omega = \max(f(x_{a_1}), f(x_{a_2}), f(x_{a_3}))$ 。

$$\begin{cases} W_{M2i}^g = \delta \times \varphi + \varepsilon \times r, l=1, 2, \dots, N_p \\ \varphi = \frac{w_1 \times (x_{bs} - x_{bt}) + w_2 \times (x_{bs} - x_{ws}) + w_3 \times (x_{bt} - x_{ws})}{w_1 + w_2 + w_3 + \varepsilon} \end{cases} \quad (14)$$

$$\begin{cases} w_1 = \cos((f(\mathbf{x}_{bs}) - f(\mathbf{x}_{bt})) + \pi) \times \exp(-|\frac{f(\mathbf{x}_{bs}) - f(\mathbf{x}_{bt})}{\omega}|) \\ w_2 = \cos((f(\mathbf{x}_{bs}) - f(\mathbf{x}_{ws})) + \pi) \times \exp(-|\frac{f(\mathbf{x}_{bs}) - f(\mathbf{x}_{ws})}{\omega}|) \\ w_3 = \cos((f(\mathbf{x}_{bt}) - f(\mathbf{x}_{ws})) + \pi) \times \exp(-|\frac{f(\mathbf{x}_{bt}) - f(\mathbf{x}_{ws})}{\omega}|) \end{cases} \quad (15)$$

式中： $\omega = f(\mathbf{x}_{ws})$ ； $w_1$ 、 $w_2$ 和 $w_3$ 为3个权重函数，用于计算加权平均向量，以实现 INFO 算法在全局解空间中搜寻最优解。

加权重因子 $\delta$ 如式(16)所示：

$$\begin{cases} \delta = 2\beta \times r_n - \beta \\ \beta = 2e^{-\frac{4 \times g}{g_{Max}}} \end{cases} \quad (16)$$

式中  $g_{Max}$  为最大迭代代数。

比例因子 $\sigma$ 用于缩放向量的加权平均值，如式(17)所示：

$$\begin{cases} \sigma = 2\alpha \times r_n - \alpha \\ \alpha = c \times e^{-d \times g / M_{avg}} \end{cases} \quad (17)$$

式中  $c$ 、 $d$  均为常数。较大的 $\sigma$ 使得当前位置偏离加权平均向量，而较小的 $\sigma$ 使得当前位置趋向加权平均向量。INFO-KELM 简化了搜索空间，通过直接加权平均加速收敛，实时性较高。GA-KELM 等方法依赖于算法的进化过程，包括选择、交叉和变异等多个步骤，这增加了计算复杂度和时间消耗。

### 1.2.2 向量组合

为了增加 INFO 的种群多样性，在  $r < 0.5$  时，根据式(18)将上文计算得到新向量  $z_i^g$ 、 $z_i'^g$ 、 $x_i^g$  结合生成的第  $g^{\text{th}}$  向量  $u_i^g$ ：

$$\begin{cases} r < 0.5 & u_i^g = z_i^g + \mu |z_i^g - z_i'^g| \\ r > 0.5 & u_i^g = z_i'^g + \mu |z_i^g - z_i'^g| \end{cases} \quad (18)$$

式中  $\mu = 0.05 \times r_n$ 。

### 1.2.3 局部搜索

有效的局部搜索能力可以防止 INFO 算法落入局部最优解的情况。INFO 算法的局部搜索算子通过考虑全局最优位置  $x_{best}^g$  与平均规则，对全局进行

搜索，以达到收敛到全局最优的目的。基于以上思路，INFO 算法将生成了一个位于  $x_{best}^g$  附近的向量  $u_i^g$ ，有助于提高算法的精度与收敛性。

### 1.3 INFO-KELM 分布式光伏发电功率预测模型

针对核极限学习机模型随机产生的参数造成的网络不稳定问题，采用向量加权平均理论对其进行优化，从而改善网络性能，提升核极限学习机预测精度，优化算法及流程图如表 1 和图 1 所示。在核极限学习机神经网络参数初始化结束后，用向量加权平均算法寻找是适用于当前预测的最佳位置和向量规则，实现对 KELM 算法正则化系数  $C$  和核参数  $g$  的优化，减少其预测的不稳定性。具体优化步骤如下：

表 1 INFO-KELM 算法

Table 1 INFO-KELM algorithm

步骤	内容
1	初始化种群向量，设置向量加权平均过程中的加权重因子 $\delta$ 和比例因子 $\sigma$ 等参数。
2	根据目标函数在 INFO 更新规则基础上寻找更优解空间。
3	更新向量、加权重因子 $\delta$ 和比例因子 $\sigma$ 。
4	利用 INFO 算法的局部搜索算子检验是否达到全局最优。
5	根据迭代次数进行终止判断。若没达到终止条件，返回第 3 步，反之结束。
6	根据优化的正则化系数 $C$ 和核参数 $g$ 建立 KELM 模型，进行预测。

1) 受光照、地理位置、时间段等因素影响，分布式光伏发电具有随机性和间歇性的特点，使用归一化方法处理光伏发电相关数据，将全部数据转换成[0,1]之间的数，对数据量值差进行消除。公式如下：

$$x_i = \frac{x_i - x_{min}}{x_{max} - x_{min}} \quad (19)$$

式中  $x_{max}$  和  $x_{min}$  分别为历史光伏发电相关数据的最大值和最小值，数据包括总辐射、组件温度、环境温度、气压、相对湿度及发电功率。

2) 随机设置核极限学习机模型输入与输出层节点数、隐含层节点等参数，研究不同参数对模型预测效果的影响。

3) 随机给定种群向量，设定向量加权平均过程中的加权重因子 $\delta$ 和比例因子 $\sigma$ ，将均方误差函数作为适应功能函数：

$$f_{fitness} = E = \frac{1}{N} \sum_{i=1}^N (y_{real} - y_i)^2 \quad (20)$$

式中：样本数据的个数为  $N$ ； $y_{real}$  和  $y_i$  为期望的光伏发电功率实际值和模型预测值，更新多次后，得

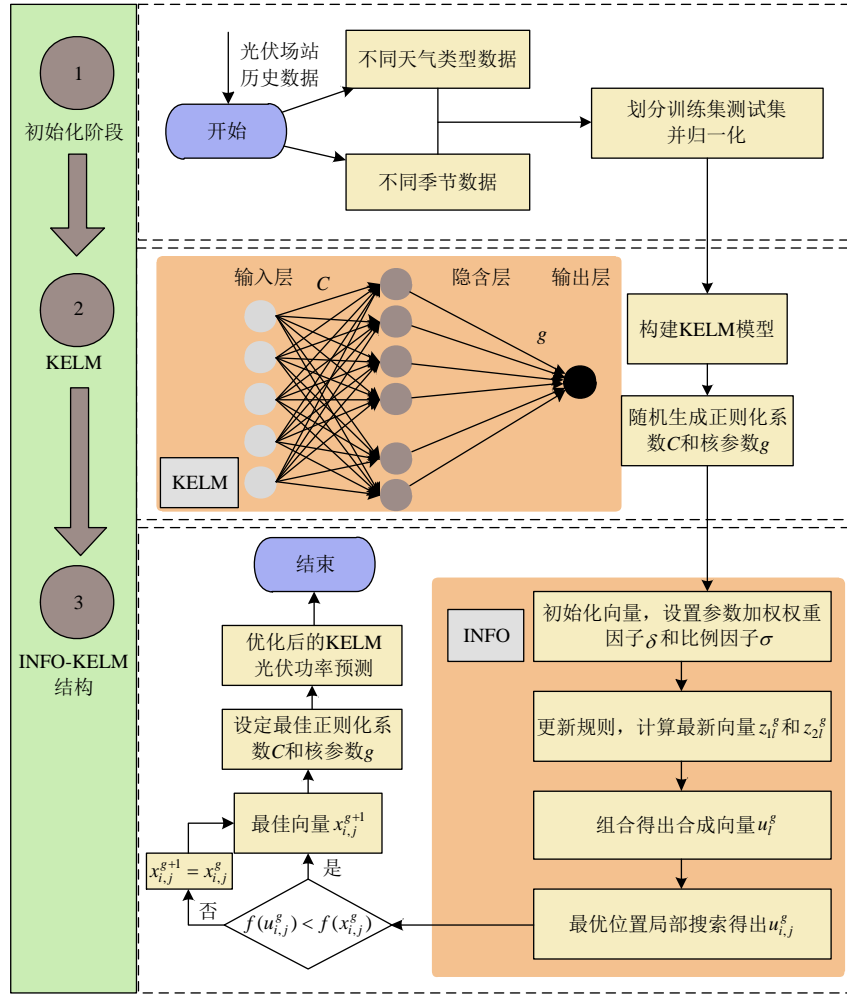


图 1 INFO-KELM 算法预测流程图

Fig. 1 Prediction flow chart of INFO-KELM algorithm

出最佳向量。

4) 根据得到的最佳向量再进行局部搜索对其更新, 得到  $u_{i,j}^g$ :

$$\begin{cases} r < 0.5: \\ \mathbf{u}_{i,j}^g = \mathbf{x}_{bs} + r_n \times (M + r_n \times (\mathbf{x}_{bs}^g - \mathbf{x}_{a1}^g)) \\ r > 0.5: \\ \mathbf{u}_{i,j}^g = \mathbf{x}_{md} + r_n \times (M + r_n \times (v_1 \times \mathbf{x}_{bs} - v_2 \times \mathbf{x}_{md})) \\ \mathbf{x}_{rnd} = \phi \times \mathbf{x}_{avg} + (1 - \phi) \times (\phi \times \mathbf{x}_{bt} + (1 - \phi) \times \mathbf{x}_{bs}) \\ \mathbf{x}_{avg} = \frac{\mathbf{x}_a + \mathbf{x}_b + \mathbf{x}_3}{3} \end{cases} \quad (21)$$

式中  $x_{rnd}$  为一个随机组合了  $x_{avg}$ 、 $x_{bt}$  与  $x_{bs}$  的新解。这种处理过程增加了 INFO 算法的随机性, 以达到更好地在解空间中进行搜索操作。 $v_1$  和  $v_2$  为式(22)所示的随机数:

$$\begin{cases} v_1 = \begin{cases} 2 \times r, & p > 0.5 \\ 1, & \text{其他} \end{cases} \\ v_2 = \begin{cases} r, & p < 0.5 \\ 1, & \text{其他} \end{cases} \end{cases} \quad (22)$$

式中  $p$  为(0,1)区间的随机数。 $v_1$  和  $v_2$  的引入增加了最佳位置对矢量的影响。

将 INFO 生成的向量与原向量进行比较, 从中找出适应度函数最小值, 并从而得到全局最优。

若  $f(u_{i,j}^g) < f(x_{i,j}^g)$ , 则  $x_{i,j}^{g+1} = u_{i,j}^g$ ; 否则  $x_{i,j}^{g+1} = x_{i,j}^g$ 。

$x_{i,j}^{g+1}$  即为最优向量, 对应目标函数值为最优解, 即优化后的正则化系数  $C$  和核参数  $g$ , 将改进后的模型进行光伏发电功率预测。

KELM 采用随机生成的正则化系数  $C$  和核参数  $g$  作为 INFO 的初始位置向量进行迭代优化。KELM 训练的输出可以作为 INFO 算法的适应度函数, 通过训练最终得到最优向量。INFO 输出的正则化系数和核参数代入 KELM 进行训练, 最终得到分布式光伏发电功率的预测值。其中 KELM 的模型见图 1, 在 KELM 模型中的正则化系数  $C$  和核参数  $g$  对预测精度和泛化能力有较大的影响能力。

## 2 仿真与实验验证

### 2.1 实验数据集

本次实验选择中国西北地区分布式光伏发电场的真实数据集，包括 2020 年全年的光伏发电数据，数据类型包括：环境温度、组件温度、相对湿度、气压、总辐射、历史发电功率。从 2020 年 1 月到 2020 年 12 月，每 15 min 记录一次，每日 96 个记录点。

### 2.2 数据处理

为了定量评估各特征量对光伏发电功率的影响程度，本文采用皮尔逊相关系数对拟输入的总辐射、组件温度、环境温度、气压、相对湿度、历史发电功率相关性进行判断，皮尔逊相关系数<sup>[24]</sup>是一种度量两个变量间线性关系的方法，如式(23)所示。

$$r_{xy} = \frac{\sum_{i=1}^m (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^m (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^m (y_i - \bar{y})^2}} \quad (23)$$

式中： $\bar{x}$  和  $\bar{y}$  分别为随机向量  $\mathbf{x}$  和  $\mathbf{y}$  中元素的平均值； $r_{xy}$  的取值范围为-1~1，取值的绝对值越大，相关程度越高，如表 2 所示。

当  $r_{xy}$  越接近 1 时，两个因素相关性越强。光

表 2  $r_{xy}$  对应的相关程度

参数大小	相关程度
$ r_{xy}  \leq 0.2$	极弱相关
$0.2 <  r_{xy}  \leq 0.4$	弱相关
$0.4 <  r_{xy}  \leq 0.6$	中等相关
$0.6 <  r_{xy}  \leq 0.8$	强相关
$0.8 <  r_{xy}  \leq 1.0$	极强相关

伏发电影响因素的皮尔逊相关矩阵热力图如图 2 所示。由相关性分析结果可以知，与光伏实际发电功率存在相关性从大到小排列为：总辐射、组件温度、环境温度、气压、相对湿度。

不同的天气类型也会对发电功率有不同的影响，图 3 展示了天气类型为晴天、多云天、雨天时 3 天内光伏发电功率的变化。根据光伏发电与辐照强度强相关，其功率波形在一天中呈现先增后减的特性，为分析不同天气下光伏功率输出波形的优劣及可预测性，使用变分模态分解(variational mode decomposition, VMD)对数据组的波形进行分解并重构。在保持 VMD 参数和分解模态数量都相等的情况下，分解不同天气类型的输出波形，最终将重构后的波形与原始波形进行对比，分析误差与相似性见图 4 和表 3，得到的相似性越高证明波形越好，预测难度也越小。




图 2 光伏发电影响因素的热力图

Fig. 2 Thermal map of factors affecting photovoltaic power generation




图 3 不同天气类型发电功率波形

Fig. 3 Generation power waveform of different weather types

如图 4 所示，在 3 种天气条件下都由 VMD 对波形进行 3 次模态分解并重构，可以看出，晴天重构的光伏功率输出与原始输出最相近。综合表 3，当天气类型为晴天时，光伏发电功率 VMD 分解重构前后相关系数为 0.9950，发电功率波形最好；当天气类型出现多云和雨天时，其对应相关系数分别为 0.9860 和 0.9653，相对误差也较大。因此不同天气类型的发电功率有不同的特征和变化，应综合考虑。




图 4 光伏发电功率 VMD 分解及重构前后对比图

Fig. 4 Comparison of PV power before and after VMD decomposition and reconstruction

表 3 不同天气类型发电功率重构前后误差与相似性

Table 3 Error and similarity before and after power reconstruction of different weather types

天气类型	相关系数	相对误差/%
晴天	0.9950	21.775 7
多云	0.9860	22.168 6
雨天	0.9653	22.960 4

因此，由上文分析，本文将总辐射强度、环境温度、组件温度、气压和历史发电数据这些强相关的变量作为输入量训练模型，并且根据光照、湿度等特征对天气进行分类(雨天、多云、晴天)。还按照季节(春、夏、秋、冬)进行了分类，并对每个分类的数据集进行了全面的预处理，包括缺失值处理、异常值处理和数据标准化，确保了每个分类数据集的质量和代表性。这样做出的实验结果更具普适性。

### 2.3 实验结果

本实验调用以 15 min 为单位的时间样本，INFO-KELM 模型迭代次数设置为 500，根据对问题的复杂性和搜索空间的大小调整的经验，分别选取不同的  $c$ 、 $d$  对比准确率曲线的收敛速度和最大准确率，如图 5 所示。

可以看出，当参数  $c$ 、 $d$  分别设置为 0.5、2 时，模型的迭代速度和准确率最高，利用训练好的网络对未来 48 h 的光伏功率进行预测，与其他 5 种方法进行对比，使用决定系数( $R^2$ )、平均绝对误差(mean absolute error,  $M_{AE}$ )和均方根误差(root mean square




图 5 不同参数取值下算法准确率变化图

Fig. 5 Variation diagram of algorithm accuracy under different parameter values

error,  $R_{MSE}$ )衡量模型的预测能力，这几种衡量系数定义为

$$\begin{cases} R^2 = 1 - [\sum_i (\hat{y}_i - y_i)^2] / [\sum_i (y_i - \bar{y})^2] \\ M_{AE} = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \\ R_{MSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \end{cases} \quad (24)$$

式中： $y_i$ 为光伏发电真实的输出功率； $\hat{y}_i$ 为预测模型的输出功率； $\bar{y}$ 为真实数据平均值。

#### 2.3.1 不同天气条件下预测对比

为了验证 INFO-KELM 算法的光伏预测能力，将该模型与 KELM 模型、RF 模型、SVM 模型、GA-BP 模型、CNN-LSTM 模型和 GA-KELM 模型

6种方法进行对比,在实验中,对比预测模型初始参数设置如表4所示。

表4 对比预测模型初始参数

Table 4 Compares the initial parameters of the prediction model

预测模型	参数设置	最大迭代次数
KELM	隐含层节点 $L=2$ , 正则化系数 $C=10$ , 核为高斯径向基核	500
RF	决策树数目=100、最小叶子数=5	500
SVM	惩罚因子 $c=4.0$ 、径向基函数参数 $g=1.2$	500
CNN-LSTM	2层卷积、卷积核大小 $3*1$	500
GA-BP	交叉概率 $P_c=0.8$ 、变异概率 $P_m=0.05$	1000
GA-KELM	交叉概率 $P_c=0.8$ 、变异概率 $P_m=0.05$	500

考虑不同天气类型对光伏发电出力的影响,本文在全年数据中随机选取7个晴天、雨天和多云天的典型日,其中5天作为训练集,后2天也就是192点作为测试集。表5分别列举使用INFO-KELM模型与其他几种模型预测光伏发电功率的误差情况。

表5 天气类型为晴天时不同算法光伏发电预测误差对比

Table 5 Comparison of photovoltaic power generation prediction errors of different algorithms when the weather type is sunny

预测模型	$R^2$	$M_{AE}$	$R_{MSE}$
KELM	0.96042	3.7805	6.8278
RF	0.97384	3.4938	5.5510
SVM	0.96081	3.6901	6.7941
CNN-LSTM	0.9824	2.7332	4.5528
GA-BP	0.98233	2.7586	4.5622
GA-KELM	0.98637	1.8507	3.9023
<b>INFO-KELM</b>	<b>0.992</b>	<b>1.9763</b>	<b>3.0694</b>

本文模型与预测光伏发电功率效果较好的GA-BP、CNN-LSTM和GA-KELM模型的对比如图6

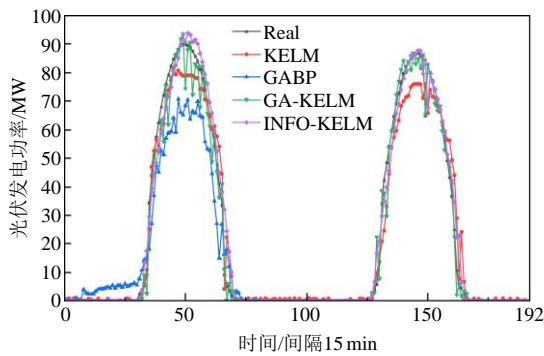


图6 天气类型为晴天时不同算法光伏发电预测误差对比图

Fig. 6 Comparison of photovoltaic power generation prediction errors of different algorithms when the weather type is sunny

所示。

由表5和图6可以看出,对比其他方法,本文方法分布式光伏发电功率的预测值和实际值极为接近,证明基于INFO-KELM的光伏发电功率超短期预测模型可以学习光伏发电功率变化的趋势和回归相关特征。

由表6和图7可以看出,在晴天与多云条件下,对比模型以及本文方法都有较好的预测效果,但本文方法的 $R^2$ 大于0.99,效果显著好于其他几种方法。

表6 天气类型为多云时不同算法光伏发电预测误差对比

Table 6 Comparison of photovoltaic power generation prediction errors of different algorithms when the weather type is cloudy

预测模型	$R^2$	$M_{AE}$	$R_{MSE}$
KELM	0.95835	2.4472	4.2694
RF	0.96183	2.4862	4.0872
SVM	0.96909	2.2133	3.6780
CNN-LSTM	0.98426	1.234	2.6244
GA-BP	0.97912	1.9211	3.0231
GA-KELM	0.97278	2.6745	4.0081
<b>INFO-KELM</b>	<b>0.98999</b>	<b>1.0128</b>	<b>1.6219</b>

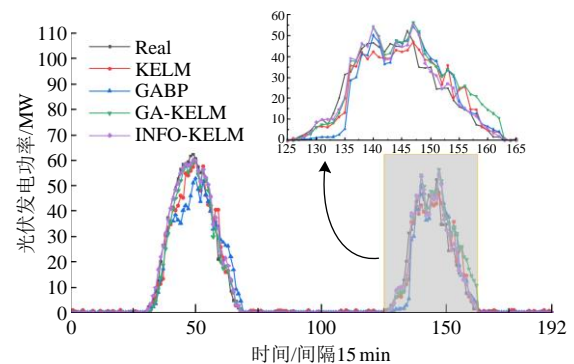


图7 天气类型为多云时

不同算法光伏发电预测误差对比图

Fig. 7 Comparison of PV power generation prediction errors of different algorithms when the weather type is cloudy

由表7和图8可以看出,雨天条件下,由于光伏实际结果波动较大,KELM等对比模型效果都显著减弱,本文方法在这种情况下仍然有很好的预测效果。

### 2.3.2 不同天气条件和季节预测

一年4季有不同的气候特征,为验证该模型在每个季节的适用性,用INFO-KELM模型对春、夏、秋、冬进行预测,与不同天气类型预测误差结果汇总如表8所示,在全年光伏电量数据中取192个随机的点进行预测,可以看出,不同季节和天气类型

表 7 天气类型为雨天时不同算法光伏发电预测误差对比

Table 7 Comparison of prediction errors of different algorithms for photovoltaic power generation when the weather type is rainy

预测模型	$R^2$	$M_{AE}$	$R_{MSE}$
KELM	0.60222	2.9318	5.7684
RF	0.63358	2.7482	5.5364
SVM	0.74046	3.7153	4.6595
CNN-LSTM	0.91902	2.1464	2.6027
GA-BP	0.87468	2.0309	3.2378
GA-KELM	0.89260	1.2565	2.6238
<b>INFO-KELM</b>	<b>0.98261</b>	<b>0.18363</b>	<b>0.7864</b>

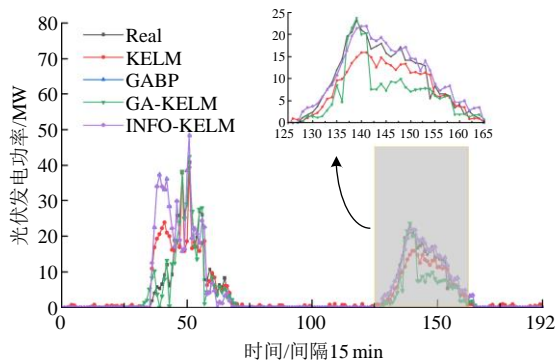


图 8 天气类型为雨天时不同算法光伏发电预测误差对比图

Fig. 8 Comparison of prediction errors of different algorithms for photovoltaic power generation when the weather type is rainy

表 8 不同天气/季节类型 INFO-KELM 预测结果

Table 8 INFO-KELM forecast results for different weather/season types

天气/季节类型	$R^2$	$M_{AE}$	$R_{MSE}$
晴天	0.992	1.9763	3.0694
多云	0.990	1.0128	1.6219
雨天	0.982	0.18363	0.7864
春	0.989	1.3984	2.549
夏	0.987	1.9167	3.1829
秋	0.990	1.9511	2.7989
冬	0.987	0.65344	1.7847

时，决定系数  $R^2$  都接近 0.99，在不同的功率大小和波动情况下均有较好的预测精度。

图 9 为一年中“四立”节气近两天的光伏发电功率预测结果，将 INFO-KELM 预测结果与实际值对比，可以看出，曲线基本重合。图 10 为不同季节下对预测结果 3 个评价指标对比，本文方法的预测平均决定系数为 0.988，且每个季节的误差 MAE 和 RMSE 都显著低于 GA-BP 和 GA-KELM 方法，说明 INFO-KELM 分布式光伏预测模型的准确度能达到比较高的水平，证明了该方法在不同天气类型

和不同季节的适应性和准确性。




图 9 不同季节类型 INFO-KELM 光伏电量预测结果图

Fig. 9 Forecast results of INFO-KELM PV power in different seasons



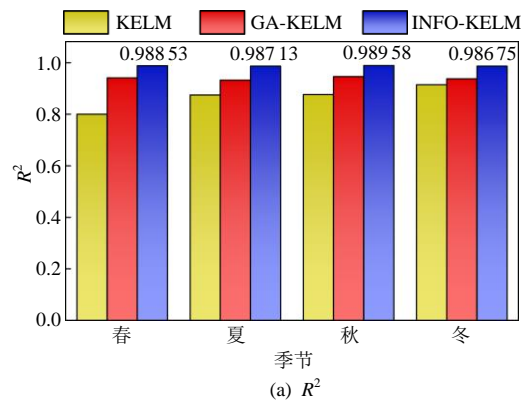


图 10 不同季节类型下不同模型预测误差结果对比

Fig. 10 Comparison of prediction error results of different models under different seasonal types

### 2.3.3 运行时间对比

为验证方法的实时性，在 2.3.2 节中的实验中记录几种预测方法在不同情况下的运行时间，求得平均运行时间如表 9 所示。

表9 各算法预测模型运行时间对比  
Table 9 Comparison of the running time of each algorithm prediction model

方法	平均运行时间/s
KELM	0.248 2
RF	0.481 1
SVM	0.269 2
CNN-LSTM	6.412 0
GA-BP	32.992 7
GA-KELM	9.804 9
INFO-KELM	3.681 8

由表9可以看出,相对CNN-LSTM等复合算法,KELM、RF和SVM 3种基础模型的运行时间较短,有较好的实时性,INFO-KELM算法需要通过整合信息增益来增强模型的性能和鲁棒性,这也附带了额外的算力消耗。结合表4—6,INFO-KELM模型在有更好的预测效果的同时运行时间也很短,较GA-BP和GA-KELM有更好的准确性、鲁棒性和实时性。

### 3 结论

针对极限学习机预测模型处理复杂预测时需要更多的隐层神经元,导致网络的结构非常复杂以及模型参数难以整定的问题,本文提出一种复杂工况下分布式光伏发电功率的INFO-KELM短期预测方法。该模型采用向量加权平均算法对KELM算法的正则化系数和核参数进行优化,从而提高了网络的稳定性和预测精度。

在模型的构建过程中,首先对光伏发电数据进行了预处理,包括数据清洗、特征提取和数据归一化等步骤;然后,采用基于向量加权平均的算法对KELM算法的正则化系数和核参数进行优化。该算法通过对历史数据进行学习,自适应地调整正则化系数和核参数,从而提高了网络的泛化能力和稳定性。为了验证该模型的有效性,本文采用3种误差指标将本文方法与KELM模型、RF模型、SVM模型、GA-BP模型、CNN-LSTM模型和GA-KELM模型6种方法进行了对比。通过不同季节、不同天气类型的数据验证,发现该模型具有较高的预测精度和稳定性。其中,综合决定系数为0.977,较GA-BP和GA-KELM分别提升8.51%和6.14%,并且在保证准确率的情况下平均运行时间达到3.681 8 s,表明该模型能够迅速有效地预测光伏发电的输出功率,并保证其鲁棒性。

该模型的预测结果对促进新能源消纳和光伏电站规划设计选址具有参考意义。在实际应用中,该模型可以为分布式光伏电站的规划设计提供科学依据,帮助决策者更好地了解分布式光伏发电的输出特性,从而制定更加合理的运营策略。

### 参考文献

- [1] 辛保安,单葆国,李琼慧,等. “双碳”目标下“能源三要素”再思考[J]. 中国电机工程学报, 2022, 42(9): 3117-3125.  
XIN Bao'an, SHAN Baoguo, LI Qionghui, et al. Rethinking of the “three elements of energy” toward carbon peak and carbon neutrality[J]. Proceedings of the CSEE, 2022, 42(9): 3117-3125 (in Chinese).
- [2] DAS U K, TEY K S, SEYEDMAHMOUDIAN M, et al. Forecasting of photovoltaic power generation and model optimization: a review[J]. Renewable and Sustainable Energy Reviews, 2018, 81: 912-928.
- [3] 赵书强,张婷婷,李志伟,等. 基于数值特性聚类的日前光伏出力预测误差分布模型[J]. 电力系统自动化, 2019, 43(13): 36-45.  
ZHAO Shuqiang, ZHANG Tingting, LI Zhiwei, et al. Distribution model of day-ahead photovoltaic power forecasting error based on numerical characteristic clustering[J]. Automation of Electric Power Systems, 2019, 43(13): 36-45 (in Chinese).
- [4] 袁晓玲,施俊华,徐杰彦. 计及天气类型指数的光伏发电短期出力预测[J]. 中国电机工程学报, 2013, 33(34): 57-64.  
YUAN Xiaoling, SHI Junhua, XU Jieyan. Short-term power forecasting for photovoltaic generation considering weather type index[J]. Proceedings of the CSEE, 2013, 33(34): 57-64 (in Chinese).
- [5] 王飞,米增强,甄钊,等. 基于天气状态模式识别的光伏电站发电功率分类预测方法[J]. 中国电机工程学报, 2013, 33(34): 67-74.  
WANG Fei, MI Zengqiang, ZHEN Zhao, et al. A classified forecasting approach of power generation for photovoltaic plants based on weather condition pattern recognition[J]. Proceedings of the CSEE, 2013, 33(34): 67-74 (in Chinese).
- [6] RAMSAMI P, OREE V. A hybrid method for forecasting the energy output of photovoltaic systems[J]. Energy Conversion and Management, 2015, 95: 406-413.
- [7] LI Yanting, SU Yan, SHU Lianjie. An ARMAX model for forecasting the power output of a grid connected photovoltaic system[J]. Renewable Energy, 2014, 66: 78-89.
- [8] 赵滨滨,王莹,王彬,等. 基于ARIMA时间序列的分布式光伏系统输出功率预测方法研究[J]. 可再生能源,

- 2019, 37(6): 820-823.
- ZHAO Binbin, WANG Ying, WANG Bin, et al. Photovoltaic power prediction in distribution network based on ARIMA model time series[J]. Renewable Energy Resources, 2019, 37(6): 820-823 (in Chinese).
- [9] LI Yingzi, WANG Zefeng, NIU Jincang. Forecast of power generation for grid-connected photovoltaic system based on grey theory and verification model [C]//Proceedings of the IEEE 4th International Conference on Intelligent Control and Information Processing. Beijing: IEEE, 2013: 129-133.
- [10] 侯伟, 肖健, 牛利勇. 基于灰色理论的光伏发电系统出力预测方法[J]. 电气技术, 2016(4): 53-58.
- HOU Wei, XIAO Jian, NIU Liyong. Analysis of power generation capacity of photovoltaic power generation system in electric vehicle charging station[J]. Electrical Engineering, 2016(4): 53-58 (in Chinese).
- [11] LIU Luyao, LIU Diran, SUN Qie, et al. Forecasting power output of photovoltaic system using a BP network method[J]. Energy Procedia, 2017, 142: 780-786.
- [12] IBRAHIM I A, HOSSAIN M J, DUCK B C. An optimized offline random forests-based model for ultra-short-term prediction of PV characteristics[J]. IEEE Transactions on Industrial Informatics, 2020, 16(1): 202-214.
- [13] WANG Jidong, LI Peng, RAN Ran, et al. A short-term photovoltaic power prediction model based on the gradient boost decision tree[J]. Applied Sciences, 2018, 8(5): 689.
- [14] 邵成成, 任孟极, 徐天元, 等. 基于分类-回归卷积神经网络的新能源电力系统可靠性评估方法[J]. 中国电机工程学报, 2024, 44(23): 9134-9144.
- SHAO Chengcheng, REN Mengji, XU Tianyuan, et al. Renewable power system reliability evaluation method based on classification-regression convolutional neural networks[J]. Proceedings of the CSEE, 2024, 44(23): 9134-9144(in Chinese).
- [15] 毛明轩, 冯心营, 陈思宇, 等. 基于贝叶斯优化卷积神经网络的路面光伏阵列最大功率点电压预测方法[J]. 中国电机工程学报, 2024, 44(2): 620-630.
- MAO Mingxuan, FENG Xinying, CHEN Siyu, et al. A novel maximum power point voltage forecasting method for pavement photovoltaic array based on Bayesian optimization convolutional neural network[J]. Proceedings of the CSEE, 2024, 44(2): 620-630(in Chinese).
- [16] TOVAR M, ROBLES M, RASHID F. PV power prediction, using CNN-LSTM hybrid neural network model. Case of study: Temixco-Morelos, México [J]. Energies, 2020, 13(24): 6512.
- [17] LUO Xing, ZHANG Dongxiao, ZHU Xu. Deep learning based forecasting of photovoltaic power generation by incorporating domain knowledge[J]. Energy, 2021, 225: 120240.
- [18] MOHAMMADI K, SHAMSHIRBAND S, MOTAMEDI S, et al. Extreme learning machine based prediction of daily dew point temperature[J]. Computers and Electronics in Agriculture, 2015, 117: 214-225.
- [19] MOHAMMADI K, SHAMSHIRBAND S, YEE P L, et al. Predicting the wind power density based upon extreme learning machine[J]. Energy, 2015, 86: 232-239.
- [20] NI Qiang, ZHUANG Shengxian, SHENG Hanming, et al. An ensemble prediction intervals approach for short-term PV power forecasting[J]. Solar Energy, 2017, 155: 1072-1083.
- [21] TANG Pingzhou, CHEN Di, HOU Yushuo. Entropy method combined with extreme learning machine method for the short-term photovoltaic power generation forecasting[J]. Chaos, Solitons & Fractals, 2016, 89: 243-248.
- [22] WANG Jidong, RAN Ran, ZHOU Yue. A short-term photovoltaic power prediction model based on an FOS-ELM algorithm[J]. Applied Sciences, 2017, 7(4): 423.
- [23] AHMADIANFAR I, HEIDARI A A, NOSHADIAN S, et al. INFO: an efficient optimization algorithm based on weighted mean of vectors[J]. Expert Systems with Applications, 2022, 195: 116516.
- [24] 韩富佳, 王晓辉, 乔骥, 等. 基于人工智能技术的新型电力系统负荷预测研究综述[J]. 中国电机工程学报, 2023, 43(22): 8569-8591.
- HAN Fujia, WANG Xiaohui, QIAO Ji, et al. Review on artificial intelligence based load forecasting research for the new-type power system[J]. Proceedings of the CSEE, 2023, 43(22): 8569-8591 (in Chinese).



李宁

收稿日期: 2024-09-03。

作者简介:

李宁(1983), 男, 教授, 主要从事新能源并网设备优化控制、高效直流变换装置优化设计及综合新能源系统状态检测与评估, lining83@xaut.edu.cn;

柴浩凯(2000), 男, 硕士研究生, 主要从事深度学习算法在新能源领域的应用研究;

\*通信作者: 葛磊蛟(1984), 男, 副教授, 主要从事智能配电网态势感知、新能源并网优化控制、人工智能赋能微电网/配电网、轨道交通供电系统状态感知等方面的研究, legendgj99@tju.edu.cn。

(责任编辑 邱丽萍)