

# 基于改进极限学习机 ELM 的光伏发电预测方法研究

李斌, 张一凡, 颜世烨, 叶季蕾

(南京工业大学 能源科学与工程学院, 江苏 南京 211816)

**摘要:** 提升光伏发电预测的准确性有助于电网的调度管理和经济运行, 其关键在于建立高效适用的预测模型。首先采用皮尔逊(Person)相关系数法对影响光伏出力的主要因素进行筛选, 确立预测模型的输入特征向量; 提出了一种融合 Person 相关系数法与遗传算法(GA)优化的 ELM 混合预测模型, 并对预测模型中随机生成的参数进行了优化; 以某一光伏电站的历史数据为研究对象, 采用 GA-ELM 预测模型对预处理后的数据进行训练和测试, 基于模型开展了四个季节典型日的光伏发电功率预测。结果表明: 混合预测模型比单一的 ELM 预测模型和 Person 相关系数与 ELM 混合的预测模型的预估偏差率分别降低了 19.2% 和 4.3%, 验证了本文模型具有更高的准确性和稳定性。

**关键词:** 皮尔逊相关系数法; ELM 模型; 遗传算法; GA-ELM 预测模型; 误差评价指标

**中图分类号:** TK519      **文献标识码:** A      **DOI:** 10.16146/j.cnki.rndlge.2022.10.026

[引用本文格式] 李斌, 张一凡, 颜世烨, 等. 基于改进极限学习机(ELM)的光伏发电预测方法研究[J]. 热能动力工程, 2022, 37(10): 207-214. LI Bin, ZHANG Yi-fan, YAN Shi-ye, et al. Research on photovoltaic power generation prediction method based on improved extreme learning machine(ELM)[J]. Journal of Engineering for Thermal Energy and Power, 2022, 37(10): 207-214.

## Research on Photovoltaic Power Generation Prediction Method based on Improved Extreme Learning Machine(ELM)

LI Bin, ZHANG Yi-fan, YAN Shi-ye, YE Ji-lei

(School of Energy Science and Engineering, Nanjing Technology University, Nanjing, China, Post Code: 211816)

**Abstract:** Improving the accuracy of photovoltaic power generation forecast is helpful to the dispatching management and economic operation of power grid, and the key is to establish an efficient and applicable forecast model. Firstly, Pearson correlation coefficient method was used to choose the main factors affecting the photovoltaic output, so as to establish the input feature vector of the prediction model. Then, a hybrid ELM prediction model optimized by Pearson correlation coefficient method and genetic algorithm (GA) was proposed to improve the optimization of randomly generated parameters in the prediction model. Taking the historical data of a photovoltaic power station as the research object, GA-ELM prediction model was used to train and test the preprocessed data. Finally, based on the prediction model, the PV power of typical days in four seasons was predicted. The results show that the prediction deviation rate of the hybrid prediction model proposed in this paper is 19.2% and 4.3% lower than those of the single ELM prediction model and the prediction model with a mixture of Pearson correlation coefficient and ELM, respectively, using the actual output curve as the reference, thus verifying that the model in this paper has higher accuracy and stability.

**Key words:** Pearson correlation coefficient method, ELM model, genetic algorithm, GA-ELM prediction

收稿日期: 2021-11-02; 修訂日期: 2022-01-11

基金项目: 国网公司科技项目(4000-202122070A-0-0-0-00)

Fund-supported Project: Science and Technology Project of State Grid Corporation of China(4000-202122070A-0-0-0-00)

作者简介: 李斌(1997-), 男, 甘肃平凉人, 南京工业大学硕士研究生。

通讯作者: 叶季蕾(1983-), 女, 江苏南京人, 南京工业大学教授。

model, error evaluation index

## 引言

光伏发电能力极大地依赖于天气条件,具有间歇性和波动性,太阳辐照度是影响光伏发电功率输出的关键因素,温度和湿度等因素也会影响其性能<sup>[1]</sup>。由于上述特性,分布式光伏的大规模接入势必会给电力系统调度管理、消纳水平和经济运行等方面带来巨大挑战。提升光伏出力预测的准确性有助于提前获取光伏出力特性,从而合理安排电网运行方式和应对措施,提高电网的安全性、可靠性和经济性。

目前,光伏出力预测的研究方法较多,按照预测时间尺度可以划分为短期预测、中期预测和长期预测<sup>[2]</sup>。其中,短期预测模型需要较高的精度,可以协同常规发电机组,优化电力系统调度和管理;长期预测模型指基于大量历史数据预测未来一年或者更长时间的光伏出力情况,主要用于光伏发电站的选址以及经济评估等<sup>[3]</sup>。根据光伏功率预测方法的不同,可以分为单一和混合预测模型,相较于单一模型,混合模型在很大程度上降低了预测误差。文献[4]采用主成分分析(PCA)和 Elman 神经网络的混合模型进行光伏功率预测,与单一的 Elman 模型相比,混合模型的平均绝对误差降低了 71.7%;文献[5]提出了一种基于卷积神经网络(CNN)和长短期记忆循环神经网络(LSTM)的混合深度学习方法,与反向传播神经网络(BPNN)、径向基函数神经网络(RBFNN)方法相比,光伏输出功率预测的平均绝对误差(MAE)分别降低了 0.852 和 0.613;文献[6]考虑了功率的季节性分布,构建了一种基于极限学习机(ELM)的光伏功率确定性预测模型,算例仿真验证表明,预测精度高达 95% 左右;文献[7]提出了基于极限学习机(ELM)的光伏发电短期预测校正方法,有效降低了光伏发电短期预测的误差。总体上看,预测模型的改进均提升了光伏功率预测精度。然而,包括 ELM 在内的传统神经网络算法中随机分配了部分参数,使预测结果产生了一定程度的误差与波动,因此基于 ELM 模型的预测方法仍需

开展进一步的优化研究。

本文首先采用皮尔逊相关系数法(Pearson Correlation Coefficient,简称 PCC 或 Pearson 分析法)对影响光伏出力的气象因素进行降低维度的处理,从而筛选出主要影响因素(温度、辐照度和湿度)作为模型的输入特征向量。为优化 ELM 模型随机生成的参数,进一步提高预测模型的性能和精度。本文采用 Person 相关系数法与遗传算法(GA)优化后的 ELM 混合预测模型(PCC-GA-ELM),首先将历史数据按季节划分为 4 个样本数据组,然后利用预处理后的历史数据对预测模型进行训练和测试,分别获取了四个季节典型日的光伏发电功率预测曲线。结果表明,本文提出的 PCC-GA-ELM 预测模型比 ELM、Person 相关系数法与 ELM 组合模型(PCC-ELM)的预估偏差率分别降低了 19.2%,4.3%,提升了光伏发电预测模型的准确性,且模型具有较强的泛化能力,可为系统调度管理提供有力依据。

## 1 光伏出力主要影响因素筛选

### 1.1 光伏出力的影响因素

光伏发电量受环境温度、辐照度、湿度和风速等气象因素的影响,导致功率输出具有一定的波动性和间歇性。为了减小预测结果与真实值之间的误差,理论上预测模型应全面考虑各类因素。然而,各类气象因素对发电功率的影响程度不同<sup>[8]</sup>,如果对预测模型的输入变量不加筛选,会造成预测模型的冗余及偏差。综上,将采用 Pearson 相关系数法筛选出历史数据中的主要影响因素,确定预测模型的输入变量。

### 1.2 Pearson 分析法

从光伏电站发电量的预测研究来看,采用相关系数法对气象因素进行分析是训练和测试之前的必要措施。文献[9-11]针对光伏电站出力受不同气象因素影响,采用 Pearson 相关系数法对气象因子进行分析,用来区分天气因素与光伏发电出力的关联度,选取重要影响变量作为训练的输入变量,有助于提高预测模型的精度。因此,首先采用 Pearson 相关系数法分析光伏电站监测的气象要素与发电量之间

的相关性。采用两者相关系数描述两个随机变量  $x_i, y_i$  之间的相关度。两变量间的 Pearson 相关系数为:

$$\rho_{X,Y} = \frac{\sum_{i=1}^n (x_i - \bar{x}_i)(y_i - \bar{y}_i)}{\sqrt{\sum_{i=1}^n (x_i - \bar{x}_i)^2 \sum_{i=1}^n (y_i - \bar{y}_i)^2}} \quad (1)$$

其中,  $\bar{x}_i, \bar{y}_i$  分别为变量  $x_i$  和  $y_i$  的平均值, 相关系数  $\rho_{X,Y}$  为正值说明两者是正相关, 如果为负值说明两者呈负相关, 如果为 0 说明两者之间没有关系, 即相关系数越接近于 1 或 -1 相关度越强, 相关系数越接近于零相关度越弱<sup>[12]</sup>。通常情况下, 通过相关系数的取值范围来判断变量间的相关强度, 如表 1 所示。

表 1 判断变量间相关强度的依据

Tab. 1 Basis for judging the strength of correlation between variables

相关系数	相关程度
0.8 ~ 1.0	极强相关
0.6 ~ 0.8	强相关
0.4 ~ 0.6	中等程度相关
0.2 ~ 0.4	弱相关
0.0 ~ 0.2	极弱或无相关

### 1.3 特征变量筛选

根据本文训练和测试所使用的光伏发电历史数据可以得到, 影响光伏发电预测的因素变量  $X_i$  包括: 辐照度、温度、风速、风向、湿度和压强; 输出变量  $Y_i$  为光伏的实际出力。为了避免变量之间因量纲不同对相关性结果产生影响, 在 Pearson 相关性分析之前对原始数据进行归一化处理:

$$\bar{x}_i = \frac{x_i - x_{i,\min}}{x_{i,\max} - x_{i,\min}} \quad (2)$$

式中:  $x_i$  — 第  $i$  列的原始数据;  $x_{i,\min}$  — 第  $i$  列数据的最小值;  $x_{i,\max}$  — 第  $i$  列数据的最大值;  $\bar{x}_i$  — 归一化后的数据。通过 Pearson 相关性分析, 结果如表 2 所示。

通过表 2 可以看出, 辐照度、温度和湿度是影响光伏出力的主要气象因素, 其中辐照度和温度与光伏发电功率呈正相关, 湿度与光伏发电功率呈负相关, 在下述的训练模型中, 将上述三要素作为预测模

型的输入特征变量。

表 2 影响光伏功率输出的主要影响因素分析

Tab. 2 Analysis of main factors affecting photovoltaic power output

因素( $X_i$ )	相关系数
辐照度	0.859 4
温度	0.431
风速	-0.080 8
风向	0.004 0
湿度	-0.382 4
压强	-0.004 5

## 2 基于 ELM 的光伏发电预测模型

### 2.1 极限学习机(ELM)模型

ELM 是在单隐层前馈神经网络的基础上改进的一种经验模型, 以风险最小化为目标的预测算法, 相比于传统的 BP 神经网络, 没有负反馈过程中过多迭代产生的复杂数学运算, 这极大地提高了网络训练效率, 又满足了隐藏层进行非线性运算的需求<sup>[13~14]</sup>。假设预测光伏电站发电量的训练样本为  $[x_i, p_i]$ ,  $x_i = [x_{i1}, x_{i2}, \dots, x_{iN}]^T \in R^N$  作为影响光伏出力的主要因素,  $p_i \in R$  为训练的学习样本即输出值, 则 ELM 模型的数学表达式为:

$$p_i = \sum_{i=1}^h \beta_i g(\omega_i \cdot x_i + b_i) \quad (3)$$

式中:  $g(\cdot)$  为隐含层神经元的激活函数;  $\omega_i$  为输入与隐含层神经元之间的连接权值;  $b_i$  为隐含层神经元的阈值<sup>[15]</sup>。

ELM 学习算法主要步骤为:

步骤 1: 基于经验公式确定隐含层神经元个数, 随机产生  $\omega_i$  和  $b_i$ ;

$$h = \sqrt{m + n} + a \quad (4)$$

式中:  $h$  — 隐含层神经元个数;  $m$  — 输入层神经元个数;  $n$  — 输出层神经元个数;  $a$  —  $1 \sim 10$  之间的常数。

步骤 2: 选择一个无限可微的隐含层神经元的激活函数, 本文预测模型选用 Sigmoid 函数作为激活函数如式(5)所示, 计算出隐含层输出矩阵  $H$ :

$$g(x) = \frac{1}{1 + e^{-x}} \quad (5)$$

若隐含层的神经元个数与训练样本个数相等,对于任意的  $\omega_i$  和  $b_i$ , ELM 神经网络都能以零误差逼近训练样本,即  $\sum_{i=1}^N \| p_i - t_i \| = 0$ :

$$t_i \approx \sum_{i=1}^h \beta_i g(\omega_i \cdot x_i + b_i) \quad (6)$$

也可以写成矩阵形式  $T = H\beta$ ,故隐含层输出矩阵  $H$  表示为:

$$H = \begin{bmatrix} g(\omega_1 \cdot x_1 + b_1) & g(\omega_2 \cdot x_1 + b_2) & \cdots & g(\omega_h \cdot x_1 + b_h) \\ g(\omega_1 \cdot x_2 + b_1) & g(\omega_2 \cdot x_2 + b_2) & \cdots & g(\omega_h \cdot x_2 + b_h) \\ \vdots & \vdots & \vdots & \vdots \\ g(\omega_1 \cdot x_N + b_1) & g(\omega_2 \cdot x_N + b_2) & \cdots & g(\omega_h \cdot x_N + b_h) \end{bmatrix} \quad (7)$$

步骤 3:计算隐含层与输出层的连接权值  $\beta$ :

$$\min \| H\beta - T' \| \quad (8)$$

可表示为:

$$\beta = H^+ T' \quad (9)$$

式中:  $H^+$  —  $H$  的 Moore-Penrose 广义逆;  $T'$  为网络输出的转置。

可以看出,相较于传统的单隐含层前馈神经网络,ELM 具有显著优势:

(1) 学习速度快,ELM 随机产生输入权值矩阵和隐含层偏置矩阵,而且隐含层的映射函数已知,在训练学习过程中只需要求出输出矩阵的权重,大大减小了运算的时间;

(2) 实现方式简单,不需要在训练之前人为设置大量的训练参数;

(3) 泛化性好,不易产生陷入局部最优解的问题<sup>[15]</sup>。

## 2.2 GA-ELM 预测模型框架

ELM 模型各层的权值和阈值都是随机生成的,然而初始化的权值和阈值对训练的结果有较大影响<sup>[16]</sup>。为了解决这一问题,大多研究中采用遗传算法优化预测模型中参数的方法提高光伏功率输出预测模型的精度。文献[17]提出了一种结合反向传播神经网络(BPNN)与遗传算法来预测光伏发电的混合模型;文献[18]采用 GA 优化神经网络(BP)的模型预测光伏电站的发电量,同时利用主成分分析法对数据预处理,结果表明,GA-BP 模型大大减小了预测误差。然而,在传统的神经网络中,需要通过遗传算法对大量的参数进行优化,提高了计算的复

杂度。本文提出了一种 PCC-GA-ELM 新型混合预测模型,在历史数据预处理的基础上采用遗传算法对 ELM 生成的随机参数进行优化,从而构建了改进的预测模型。

基于 GA 优化后的 ELM 流程如图 1 所示。寻优步骤为:

步骤 1:将光伏出力的实际功率和影响因素通过 Pearson 分析后确定输入变量,并对数据进行归一化处理;

步骤 2:构建 ELM 基本结构,根据输入的训练和测试数据随机产生连接权值和阈值;

步骤 3:初始化,设定遗传算法的参数:种群数 K、迭代次数、交叉概率和变异概率等,参数设置如表 3 所示。

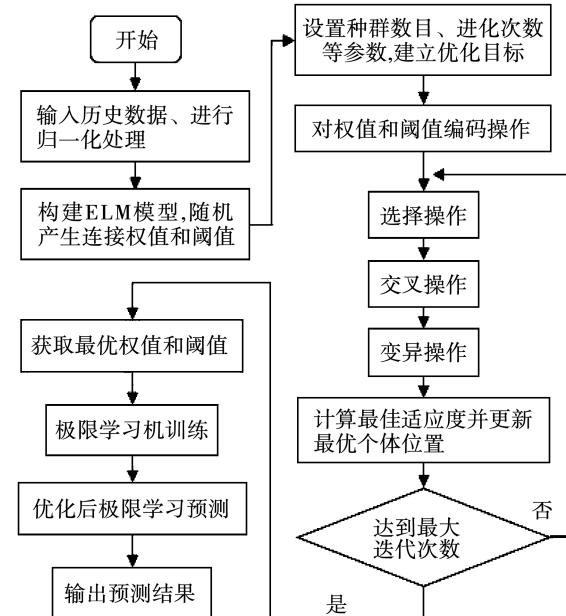


图 1 GA-ELM 的流程

Fig. 1 Flowchart of GA-ELM

表 3 遗传算法参数设置表

Tab. 3 Genetic algorithm parameter setting table

参数	数值
种群大小	50
交叉概率	0.7
突变概率	0.01
终止代数	200
目标误差	0.000 1

将光伏功率训练数据预测的误差绝对值之和作为个体的适应度值,个体适应度越小,则个体最优,适应度函数为:

$$\text{fitness}(y_i) = \min \left[ \frac{1}{N} \sum_{i=1}^N (O_i - T_i)^2 \right] \quad (10)$$

式中:  $O_i$ —预测功率值;  $T_i$ —实际功率值;  $N$ —样本总数。

**步骤 4:**对 ELM 随机产生的连接权值和阈值进行二进制编码,从而构造编码链,产生初始种群;设 ELM 模型中输入层节点数为  $m$ ;隐含层节点数为  $h$ ;输出层节点数为  $n$ ,则输入层到隐含层的权值为  $m \times h$  的矩阵,隐含层的阈值为  $h$ ,隐含层到输出层的权值  $h \times n$ ,输出层的阈值为  $n$ ,那么遗传算法个体的编码长度为:

$$l = m \times h + h \times n + h + n \quad (11)$$

式中:  $m \times h + h \times n$ —权值个数;  $h + n$ —阈值个数。

**步骤 5:**开始对种群进行训练,计算每个种群的适应度,设种群  $F(y), y \in K$ ,其中  $K = (y_1, y_2, \dots, y_k)$ ,对于任意的  $y_i$ ,则有  $y_i = (x_1, x_2, \dots, x_k)$ ,即每个染色体含有  $k$  种基因,则:

$$F(y) = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_K \end{bmatrix} = \begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1k} \\ x_{21} & x_{22} & \cdots & x_{2k} \\ \vdots & \vdots & \vdots & \vdots \\ x_{K1} & x_{K2} & \cdots & x_{Kk} \end{bmatrix} \quad (12)$$

**步骤 6:**根据计算的适应度,对种群进行选择、交叉和变异操作,从而得到新种群,迭代次数加 1。

(1) 选择:计算选择概率  $P_e$ ,根据此值对群体进行选择操作从而得到中间群体;

$$P_e = \frac{\text{fitness}(y_i)}{\sum \text{fitness}(y_i)} \quad (13)$$

式中:  $y_i$ —一种群中第  $i$  类染色体;  $\text{fitness}(y_i)$ —第  $i$  类染色体的适应度;  $\sum \text{fitness}(y_i)$ —一种群所有染色体的适应度。

(2) 交叉:把交叉操作作用于中间群体;

(3) 变异:把变异操作作用于交叉之后所得到的群体,得到下一代群体;

**步骤 7:**判断是否达到最大迭代次数,如果是,继续下一步操作,否则返回至步骤 5 再次循环;

**步骤 8:**对参数解码得到优化后的权值和阈值,通过极限学习机训练,得到优化后极限学习机的预测结果。

### 3 算例分析

#### 3.1 样本数据预处理

以某光伏电站 2017 年 12 月 1 日到 2018 年 12 月 31 日的出力情况和附近的气象因素为研究样本,设置每 15 min 为 1 个样本点。由于不同的季节气象要素差别较大,对发电功率有一定影响。因此,本文按照季节类型将总样本数据分为春、夏、秋、冬 4 个类型,分别选择每一季度典型日的光伏发电量情况进行预测,其中输入变量为辐照度,温度、湿度和实际出力情况;输出变量为功率预测值。样本数据的分配情况如表 4 所示。

表 4 样本数据的分配

Tab. 4 Distribution of sample data

季节	时间划分	数据规模	训练集	测试集
春	2018. 3 ~ 2018. 5	8609 × 4	8513 × 4	96 × 4
夏	2018. 6 ~ 2018. 8	7695 × 4	7599 × 4	96 × 4
秋	2018. 9 ~ 2018. 11	8544 × 4	8448 × 4	96 × 4
冬	2017. 12 ~ 2018. 2	7967 × 4	7871 × 4	96 × 4

#### 3.2 网络参数设置

经过 Pearson 方法对输入数据进行降低维度之后,则输入层节点个数设置为 4,输出为光伏出力,所以输出层节点设置为 1。一般情况下,隐含层数越多其非线性拟合能力就越强,如果隐含层的节点数过大,会出现过拟合的现象,从而影响预测精度<sup>[19~20]</sup>。在式(4)经验模型的基础上,经过多次训练比较,隐含层节点设置为 12 可以得到较好的性能,故 GA-ELM 的网络拓扑结构为 4-12-1。

#### 3.3 误差指标

评价预测结果的指标众多,为了评估文中所提出的光伏出力预测模型的性能,本文采用误差通用评价指标即均方误差 MSE、决定系数  $R^2$ 、平均绝对

误差 MAE 和平均预估偏差率 ADR 对预测结果进行分析。其中, MSE 用来反映光伏功率预测量和真实值之间差异的程度;  $R^2$  用来判断回归方程的拟合程度, 其取值范围为  $[0, 1]$ ,  $R^2$  越大, 表示模型拟合效果越好; MAE 反映预测值与真实值的误差绝对值的平均值; ADR 用来表示预测值与真实值之间的偏差率绝对值的平均数, 数值越大说明预测结果越不稳定。

$$\text{MSE} = \frac{1}{N} \sum_{i=1}^N (P_i - \hat{P}_i)^2 \quad (14)$$

$$R^2 = 1 - \frac{\sum_{i=1}^N (\hat{P}_i - P_i)^2}{\sum_{i=1}^N (P_i - \bar{P}_i)^2} \quad (15)$$

$$\text{MAE} = \frac{1}{N} \sum_{i=1}^N |(P_i - \hat{P}_i)| \quad (16)$$

$$\text{ADR} = \frac{1}{N} \sum_{i=1}^N \left| \frac{\hat{P}_i - P_i}{\bar{P}_i} \right| \times 100\% \quad (17)$$

式中:  $P_i$ —光伏发电功率实际值;  $\hat{P}_i$ —光伏发电功率预测值;  $\bar{P}_i$ — $P_i$  的平均值;  $N$  为样本数量。

### 3.4 性能测试及分析

本文通过 MATLAB 软件仿真平台对所建立的模型进行了仿真研究, 为了能够更加清楚地获取所提方法的准确性, 另外选取极限学习机模型 (ELM)、Pearson 相关系数法与 ELM 组合模型 (PCC-ELM) 进行了仿真分析。通过对不同预测模型的训练和测试, 获得春、夏、秋、冬 4 个季节典型日的光伏发电功率预测结果, 如图 2 所示。

由图 2 可知, PCC-GA-ELM 模型的预测结果更加接近实际值, PCC-ELM 模型次之, 为了可视化不同模型预测误差的高低, 将 3 种模型预测的 4 个季节典型日的光伏出力的平均误差做了对比, 结果如图 3 所示。

从图 3 中可以清晰地看出, 相比于 ELM 和 PCC-ELM, PCC-GA-ELM 模型的平均预测误差分别降低了 68.7% 和 4.7%。此外, 基于仿真结果对不同方法得到的预测值与实际值之间的误差指标做了统计, 得到了不同季节典型日的 3 种预测模型误差

统计结果, 如表 5 所示。

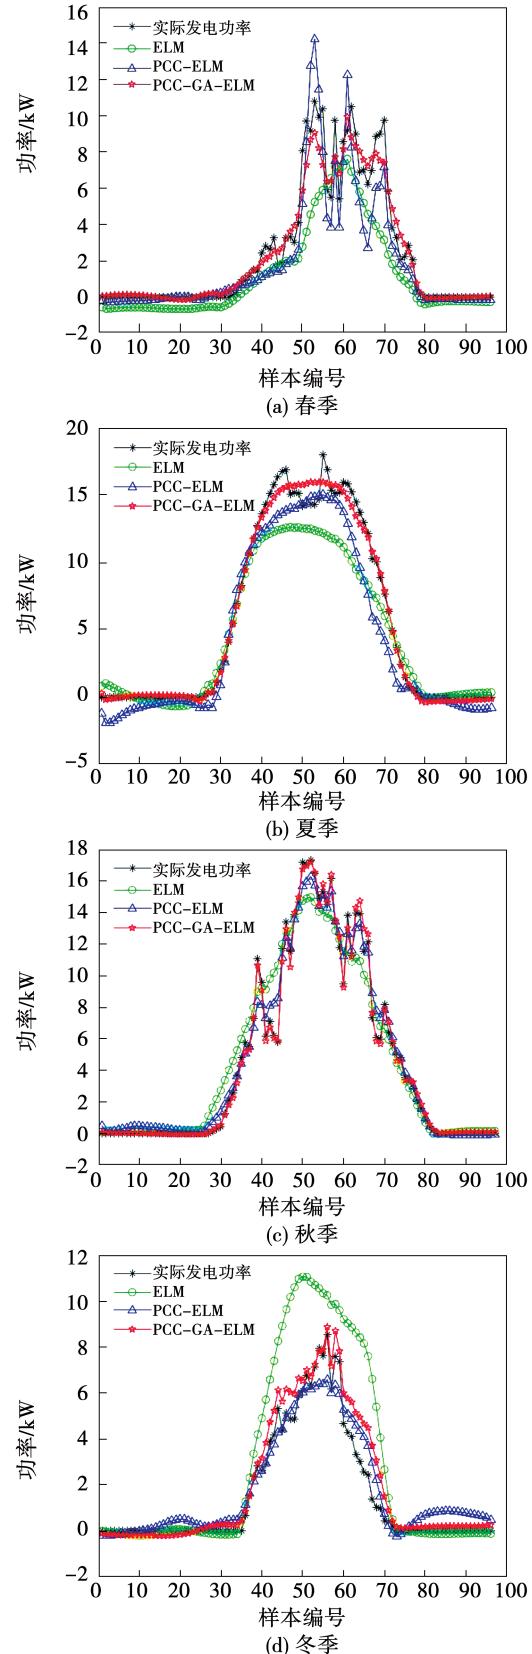


图 2 光伏功率预测对比

Fig. 2 Comparison of photovoltaic power predictions

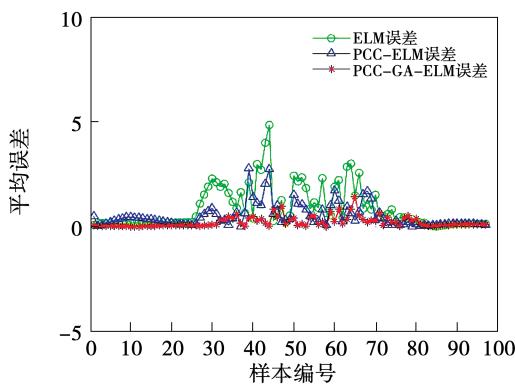


图3 平均误差对比

Fig. 3 Comparison of average errors

表5 不同季节下的3种预测模型误差统计表

Tab. 5 Error statistics for the three prediction

models in different seasons

模型	指标	春	夏	秋	冬	平均值
ELM	MSE	3.798	2.310	1.719	3.514	2.835
	$R^2$	0.855	0.968	0.951	0.906	0.920
	MAE	1.271	1.379	0.865	1.383	1.225
	ADR	31.4%	26.9%	47.4%	42.1%	37.0%
PCC-ELM	MSE	1.689	1.602	0.545	0.500	1.084
	$R^2$	0.884	0.971	0.984	0.943	0.946
	MAE	0.833	0.923	0.495	0.518	0.692
	ADR	17.3%	19.6%	20.1%	30.5%	21.9%
PCC-GA-ELM	MSE	0.601	0.345	0.110	0.442	0.375
	$R^2$	0.955	0.992	0.997	0.961	0.976
	MAE	0.458	0.389	0.215	0.470	0.383
	ADR	17.4%	14.1%	16.9%	22.5%	17.7%

由表5可知,在春、夏、秋、冬4个季节典型日的模式下,基于PCC-GA-ELM模型的预测结果更加接近实际值。其中,PCC-ELM模型的MSE比ELM模型平均误差降低了61.8%,而基于PCC-GA-ELM模型的MSE平均误差降低至0.375;决定系数 $R^2$ 是阐明因变量变化可靠程度的一个统计指标,3种方法预测得的 $R^2$ 值都较高,其中PCC-GA-ELM预测结果的 $R^2$ 值更加接近于1;平均绝对误差MAE用来描述预测值与真实值的误差情况,PCC-ELM和PCC-GA-ELM模型相比单一的ELM模型都将MAE的值平均降至1以下,但PCC-GA-ELM的平均绝对误差

更低;预估偏差率ADR更能反映预测值与真实值的误差波动情况,PCC-GA-ELM模型的ADR比PCC-ELM模型降低了4.2%,相比于ELM模型降低了19.3%。综上所述,本文所提出的PCC-GA-ELM模型对光伏功率的预测具有较强的泛化性,且将光伏功率预测的精度大大提高。

## 4 结论

通过Pearson相关系数法对影响光伏输出功率的因素进行分析筛选,建立了改进的ELM光伏预测模型,通过遗传算法对ELM模型进行改进优化,逐步迭代出优化后的权值和阈值,有效避免了模型的输入冗余和ELM随机产生的参数对预测结果精度的影响。通过算例验证,本文所提出的PCC-GA-ELM模型能够准确预测光伏发电功率,相比于ELM和PCC-ELM模型平均误差分别降低了68.7%和4.7%;预估偏差率分别降低了19.3%和4.2%。综上,本文所提出的模型挖掘并利用了光伏发电历史数据的关键影响因素及数据相关性规律,可适合多场景下光伏发电功率的准确预测,具有较好的泛化性能,提供了一种较好的短期光伏功率预测方法。

## 参考文献:

- [1] GÓMEZ L J, MARTÍNEZ O A, PASTORIZA T F, et al. Photovoltaic power prediction using artificial neural networks and numerical weather data[J]. Sustainability, 2020, 12(24):10295.
- [2] DAS U K, TEY K S, SEYEDMAHOUDIAN M, et al. Forecasting of photovoltaic power generation and model optimization: a review [J]. Renewable and Sustainable Energy Reviews, 2018, 81: 912–928.
- [3] 倪强.光伏发电超短期输出功率的概率预测若干方法研究[D].成都:西南交通大学,2018.  
NI Qiang. Research on several methods for probabilistic prediction of ultra-short-term output power of photovoltaic power generation [D]. Chengdu: Southwest Jiaotong University, 2018.
- [4] DOU Chun-xia, QI Hang, LUO Wei, et al. Elman neural network based short-term photovoltaic power forecasting using association rules and kernel principal component analysis[J]. Journal of Renewable and Sustainable Energy, 2018, 10(4):043501.

- [5] LI G,XIE S,WANG B,et al. Photovoltaic power forecasting with a hybrid deep learning approach [ J ]. IEEE Access, 2020, 8: 175871 – 175880.
- [6] HAN Yu-tong,WANG Ning-bo,MA Ming,et al. A PV power interval forecasting based on seasonal model and nonparametric estimation algorithm[ J ]. Solar Energy,2019,184:515 – 526.
- [7] 周 海,李登宣,尹万思,等.基于极限学习机的光伏发电短期预测校正方法[J].电网与清洁能源,2020,36(6):64 – 69,77.  
ZHOU Hai,LI Deng-xuan,YIN Wan-si,et al. Short-term forecasting correction method of photovoltaic power based on extreme learning machine [ J ]. Power Grid and Clean Energy, 2020 , 36 (6):64 – 69,77.
- [8] 宋绍剑,李博涵.基于LSTM网络的光伏发电功率短期预测方法的研究[J].可再生能源,2021,39(5):594 – 602.  
SONG Shao-jian,LI Bo-han. Research on the short-term prediction method of photovoltaic power based on LSTM network[ J ]. Renewable Energy,2021,39(5):594 – 602.
- [9] ZHONG Jia-qi,LIU Lu-yao,SUN Qie,et al. Prediction of photovoltaic power generation based on general regression and back propagation neural network [ J ]. Energy Procedia, 2018 , 152: 1224 – 1229.
- [10] 尹晓敏,孟祥剑,侯昆明,等.一种计及空间相关性的光伏电站历史出力数据的修正方法[J].山东大学学报(工学版),2021,51(4):118 – 123.  
YIN Xiao-min,MENG Xiang-jian,HOU Kun-ming,et al. A correction method for historical power output data of photovoltaic power plants taking into account spatial correlation[ J ]. Journal of Shandong University ( Engineering Edition ), 2021 , 51 ( 4 ): 118 – 123.
- [11] 李瑞青.计及气象因素的超短期光伏电站出力预测研究[D].吉林:东北电力大学,2019.  
LI Rui-qing. Research on ultra-short-term photovoltaic power plant output prediction taking into account meteorological factors [ D ]. Jilin:Northeastern Electric Power University ,2019.
- [12] 荆 博.光伏电站短期功率预测方法研究[D].镇江:江苏大学,2017.  
JING Bo. Research on short-term power prediction method for photovoltaic power plants[ D ]. Zhenjiang:Jiangsu University,2017.
- [13] 王宏刚,田洪迅,谈 军,等.基于蜻蜓算法优化ELM的电能质量扰动诊断与识别研究[J].电力电容器与无功补偿,2019,40(1):142 – 147.  
WANG Hong-gang,TIAN Hong-xun,TAN Jun,et al. Research on power quality disturbance diagnosis and identification based on dragonfly algorithm optimized ELM[ J ]. Power Capacitors and Reactive Power Compensation,2019,40(1):142 – 147.
- [14] 周 海,李登宣,尹万思,等.基于极限学习机的光伏发电短期预测校正方法[J].电网与清洁能源,2020,36(6):64 – 69,77.  
ZHOU Hai,LI Deng-xuan,YIN Wan-si,et al. A short-term forecast correction method for photovoltaic power generation based on limit learning machine[ J ]. Power Grid and Clean Energy,2020 , 36 (6):64 – 69,77.
- [15] 饶宇飞,刘 阳,李玲玲,等.基于改进鸟群算法和极限学习机模型的光伏发电系统输出功率预测研究[J].可再生能源,2020,38(10):1318 – 1325.  
RAO Yu-fei,LIU Yang,LI Ling-ling,et al. Research on output power prediction of photovoltaic power generation system based on improved bird flock algorithm and extreme learning machine model[ J ]. Renewable Energy,2020,38(10):1318 – 1325.
- [16] A new PV generation power prediction model based on GA-BP neural network with artificial classification of history day [ C ]// International Conference on Power System Technology. Guangzhou,2018.
- [17] 缪家森,成丽珉,吕宏水.基于PSO-ELM的储能锂电池荷电状态估算[J].电力工程技术,2020,39(1):165 – 169,199.  
MIAO Jia-sen,CHENG Li-min,LYU Hong-shui. PSO-ELM-based charge state estimation of energy storage lithium batteries [ J ]. Power Engineering Technology,2020,39(1):165 – 169,199.
- [18] 蒋 浩,洪 丽,张国江.主成分分析结合神经网络的光伏发电量预测[J].电力系统及其自动化学报,2013,25 ( 6 ): 101 – 105.  
JIANG Hao,HONG Li,ZHANG Guo-jiang. Principal component analysis combined with neural network for photovoltaic power generation prediction[ J ]. Journal of Power Systems and Automation , 2013 , 25 ( 6 ): 101 – 105.
- [19] ZHOU Y,ZHOU N,GONG L,et al. Prediction of photovoltaic power output based on similar day analysis,genetic algorithm and extreme learning machine[ J ]. Energy,2020,204:117894.
- [20] 赵永宁.基于时空相关性的大规模风电功率短期预测方法研究[D].北京:中国农业大学,2019.  
ZHAO Yong-ning. Research on short-term prediction method of large-scale wind power based on spatial and temporal correlation [ D ]. Beijing:China Agricultural University,2019.