

基于 COOT-SVM 的短期光伏发电功率预测

陈晓华^{1,2}, 王志平¹, 吴杰康², 许海文², 陈盛语², 张勋祥², 龙泳丞², 谢明钊²

(1. 东莞理工学院电子工程与智能化学院, 广东 东莞 523808;

2. 广东工业大学自动化学院, 广东 广州 510006)

摘要: 为了提高短期光伏发电功率预测的精度, 提出了一种基于白冠鸡优化算法 (COOT) 优化支持向量机 (SVM) 的短期光伏发电功率预测模型。首先, 分别选取某光伏电站在 2017 年 4 月和 7 月的前 21 天数据进行仿真分析, 计算光伏输出功率和每一个气象因素之间的皮尔逊相关系数; 然后, 依据皮尔逊相关系数选择太阳总辐射强度、太阳散射辐射强度、太阳直射辐射强度、组件温度和环境温度 5 个气象因素作为预测模型的输入数据, 光伏电站的发电功率作为输出数据。通过与 BP 和 SVM 预测模型进行仿真对比可知, 对于 4 月和 7 月的数据来说, COOT-SVM 预测模型的均方根误差、均方误差和平均绝对误差均比 BP 和 SVM 预测模型小。因此, 所提 COOT-SVM 预测模型可有效提高短期光伏发电功率的预测精度, 具有较高的工程应用价值。

关键词: 光伏发电; 功率预测; 白冠鸡优化算法; 支持向量机; 皮尔逊相关系数

中图分类号: TM 615 **文献标志码:** A **文章编号:** 1003-6954(2023)06-0028-06

DOI: 10.16527/j.issn.1003-6954.20230605

Short-term Photovoltaic Power Forecasting Based on COOT-SVM

CHEN Xiaohua^{1,2}, WANG Zhiping¹, WU Jiekang², XU Haiwen², CHEN Shengyu²,

ZHANG Xunxiang², LONG Yongcheng², XIE Mingzhao²

(1. School of Electrical Engineering & Intelligitization, Dongguan University of Technology,

Dongguan 523808, Guangdong, China; 2. School of Automation, Guangdong University of

Technology, Guangzhou 510006, Guangdong, China)

Abstract: In order to improve the accuracy of short-term photovoltaic power forecasting, a short-term photovoltaic power forecasting model based on support vector machine (SVM) optimized by coot optimization algorithm (COOT) is proposed. Firstly, the data of a photovoltaic power station in the first 21 days of April and July in 2017 are selected for simulation analysis, and the Pearson correlation coefficient between photovoltaic output power and each meteorological factor is calculated. And then the total solar radiation intensity, solar scattered radiation intensity, solar direct radiation intensity, component temperature and ambient temperature are selected as the input data of the prediction model, and the generated output of photovoltaic power station is used as the output data. Through simulation comparison with BP and SVM prediction models, it is obtained that for the data in April and July, the root mean square error, mean square error and mean absolute error of COOT-SVM prediction model are smaller than those of BP and SVM prediction models. Therefore, the proposed COOT-SVM prediction model can effectively improve the prediction accuracy of short-term photovoltaic power generation, which has high engineering application value.

Key words: photovoltaic power generation; power forecasting; coot optimization algorithm; support vector machine; Pearson correlation coefficient

0 引言

2020年9月,中国在联合国大会上提出了“双碳”的目标:在2030年之前实现“碳达峰”以及在2060年之前实现“碳中和”的目标^[1]。在“双碳”目标的引领下,具有获取方便、取之不尽、用之不竭和低污染等优点的光伏发电将逐步取代传统的化石能源发电。随着光伏发电技术的不断成熟,使用太阳能发电逐渐成为人类能源需求的首选绿色清洁能源。然而,光伏发电具有随机性、波动性和间歇性等缺点,因此,提高光伏功率预测的准确率有助于电网的安全稳定运行、提高光伏发电并网能力、有效减少弃光和提高电网运行的经济性^[1-6]。

现有的大部分文献对光伏功率预测的方法主要有直接预测和间接预测两种^[7]。直接预测的方法只需光伏功率的历史数据和气象信息就能够对光伏功率进行预测,此方法主要包括前馈神经网络算法(back propagation, BP)^[8-14]、支持向量机(support vector machine, SVM)^[5,15-18]和组合预测法^[19]等。间接预测的方法是基于物理法预测太阳辐射等气象因素,根据光电转换效率得到光伏发电的输出功率^[20]。但神经网络算法容易陷入局部最优解并且算法耗时较长,使得光伏发电功率预测很难快速得到最优解;支持向量回归预测模型能够很好地解决预测值偏差过大和局部最优等问题,但核函数的参数和惩罚因子数值的选择对预测结果影响较大;组合预测法可以获得较高精度的光伏功率预测,但计算模型复杂并且消耗时间较长;使用间接预测法对太阳辐射等预测值的准确度要求较高。

针对以往研究的不足,下面建立了基于白冠鸡优化算法(coot optimization algorithm, COOT)优化SVM的预测模型来提高光伏发电功率短期预测的精度。选取某光伏电站在2017年春季中的4月前21天和夏季中的7月前21天的数据进行仿真;利用皮尔逊相关系数公式可以计算得到对光伏发电影响较大的因素为太阳总辐射强度、太阳散射辐射强度、太阳直射辐射强度、组件温度和环境温度5个气象因素,将它们作为输入数据,光伏发电功率作为输出数据,并对输入和输出的数据进行归一化处理;最后,利用COOT-SVM预测模型实现光伏发电功率的短期预测,对比COOT-SVM预测模型与BP和SVM预测模型,可知COOT-SVM预测模型具有较高的预测精度。

1 影响光伏发电预测结果的因素

光伏发电的日变化周期比较强,其输出功率会受各种气象因素的影响。太阳总辐射强度、太阳散射辐射强度、太阳直射辐射强度、组件温度、环境温度、相对湿度和气压等参数对光伏发电均有不同程度的影响。准确详细的输入数据是提高预测精度的关键,但输入数据过多会使预测过程更加复杂。因此以训练样本数据来计算光伏输出功率与各个气象因素之间的皮尔逊相关系数,计算表达式^[2]为

$$r = \left(\sum X_{pv} Y_{met} - \frac{\sum X_{pv} \sum Y_{met}}{N_{met}} \right) \cdot \left[\left[\sum X_{pv}^2 - \frac{(\sum X_{pv})^2}{N_{pv}} \right] \cdot \left[\sum Y_{met}^2 - \frac{(\sum Y_{met})^2}{N_{met}} \right] \right]^{-\frac{1}{2}} \quad (1)$$

式中: X_{pv} 为光伏输出功率; Y_{met} 为气象因子; N_{pv} 为光伏输出功率数据样本的数量; N_{met} 为气象因子数据样本的数量。

一般而言,两个变量的相关程度由以下范围判断:当 $0 \leq |r| < 0.2$,为极弱相关或不相关;当 $0.2 \leq |r| < 0.4$,为弱相关;当 $0.4 \leq |r| < 0.6$,为中等程度相关;当 $0.6 \leq |r| < 0.8$,为强相关;当 $0.8 \leq |r| \leq 1.0$,为极强相关。

选取某光伏电站在2017年春季中的4月前21天和夏季中的7月前21天的相关气象因素历史数据和光伏发电系统输出功率历史数据作为研究对象,计算其光伏输出功率与每一个气象因素的相关系数,见表1。由表1可知:

1)该地区4月训练样本时间段内太阳总辐射强度、太阳散射辐射强度和太阳直射辐射强度3个气象因素与光伏输出功率极强相关;组件温度和环境温度两个气象因素与光伏输出功率强相关;相对湿度与光伏输出功率中等相关(负相关);气压与光伏输出功率极弱相关。

2)该地区7月训练样本时间段内太阳总辐射强度和太阳散射辐射强度两个气象因素与光伏输出功率极强相关;太阳直射辐射强度、组件温度和环境温度3个气象因素与光伏输出功率强相关;相对湿度与光伏输出功率中等相关(负相关);气压与光伏输出功率极弱相关。

表 1 光伏输出功率与各个气象因素的相关系数

气象因素	相关系数 r	
	4 月前 21 天	7 月前 21 天
太阳总辐射强度	0.916 3	0.864 2
太阳散射辐射强度	0.927 2	0.850 6
太阳直射辐射强度	0.899 7	0.793 4
组件温度	0.775 2	0.655 7
环境温度	0.606 4	0.606 2
相对湿度	-0.568 4	-0.598 9
气压	0.052 3	0.180 0

因此,对于该地区春季 4 月和夏季 7 月的短期光伏功率预测,均选择太阳总辐射强度、太阳散射辐射强度、太阳直射辐射强度、组件温度与环境温度 5 个气象因素作为预测模型的输入数据,光伏发电功率作为输出数据。

2 白冠鸡优化算法的原理

在 2021 年由 Naruei I 等人提出的 COOT 优化算法^[21]主要模拟白冠鸡在自然界中获取食物的行为,从而实现算法寻优的目的。该算法假设白冠鸡种群中有 N 个个体,从中选取 10% 的个体作为白冠鸡的领导者,剩余的白冠鸡为跟随者。

对白冠鸡种群领导者的位置进行初始化的计算表达式为

$$x_{LD,s,j} = x_{L,j} + \eta_{s,j} \cdot (x_{U,j} - x_{L,j}) \quad (2)$$

式中: $x_{LD,s,j}$ 为第 s 只白冠鸡领导者在第 j 维上的位置, $s=1,2,\dots,N_{LD}$, N_{LD} 为白冠鸡领导者的数量,并且 $N_{LD}=0.1N$; $\eta_{s,j}$ 为在 $[0,1]$ 区间上第 s 行第 j 列的一个随机数; $j=1,2,\dots,d$, d 为待优化问题的维数; $x_{U,j}$ 、 $x_{L,j}$ 分别为搜索空间中第 j 维变量的上限和下限。

对白冠鸡跟随者种群个体进行初始化的计算表达式为

$$x_{i,j} = x_{L,j} + \eta_{i,j} \cdot (x_{U,j} - x_{L,j}) \quad (3)$$

式中: $x_{i,j}$ 为第 i 只白冠鸡跟随者在第 j 维上的位置, $i=1,2,\dots,N_{cool}$, N_{cool} 为白冠鸡跟随者种群大小,并且 $N_{cool} = N - N_{LD}$; $\eta_{i,j}$ 为在 $[0,1]$ 区间上第 i 行第 j 列的一个随机数。

该算法中,白冠鸡的行为主要包含以下 4 种:

1) 个体随机移动

令白冠鸡跟随者种群朝搜索空间中的一个随机位置移动,随机位置的计算表达式为

$$r_{1,j}^* = x_{L,j} + \eta_{1,j} \cdot (x_{U,j} - x_{L,j}) \quad (4)$$

式中, $\eta_{1,j}$ 为在 $[0,1]$ 区间上第 1 行第 j 列的一个随机数。

随机运动有利于算法跳出局部最优解,使用这种方法更新白冠鸡跟随者位置的计算表达式为

$$x'_{i,j} = x_{i,j} + A \cdot R_2 \cdot (r_{1,j}^* - x_{i,j}) \quad (5)$$

$$A = 1 - \frac{T_{cur}}{T_{max}}$$

式中: R_2 为在 $[0,1]$ 区间上的随机数; T_{cur} 和 T_{max} 分别为当前迭代次数和最大迭代次数。

2) 链式运动

两只白冠鸡跟随者的平均位置可以实现链式运动,计算表达式为

$$\bar{x}_{i,j} = 0.5(x_{i-1,j} + x_{i,j}) \quad (6)$$

式中, $x_{i-1,j}$ 为第 $i-1$ 只白冠鸡跟随者在第 j 维上的位置。

3) 根据种群的领导者调整位置

通常情况下,白冠鸡跟随者种群必须根据白冠鸡领导者的位置调整自己的位置并且朝着它们的方向移动,这里利用 k 来控制白冠鸡领导者的位置引导作用。

$$k = 1 + \text{mod}(i, N_{LD}) \quad (7)$$

式中: i 为第 i 只白冠鸡跟随者的序号; $\text{mod}(i, N_{LD})$ 的含义为 i 对 N_{LD} 取模; k 为白冠鸡领导者的序号。

因此白冠鸡跟随者的位置更新为

$$x'_{i,j} = x_{LD,k,j} + 2R_1 \cdot \cos 2R\pi \cdot (x_{LD,k,j} - x_{i,j}) \quad (8)$$

式中: R_1 为在 $[0,1]$ 区间上的随机数; R 为在 $[-1,1]$ 区间上的一个随机数; $x_{LD,k,j}$ 为第 k 只白冠鸡领导者在第 j 维上的位置。

4) 白冠鸡领导者带领白冠鸡跟随者走向最佳区域

白冠鸡种群的领导者不断更新它们朝着最佳区域目标方向的位置,从而带领白冠鸡跟随者种群走向最佳区域,白冠鸡领导者的位置更新计算表达式为

$$x'_{LD,k,j} = \begin{cases} B \cdot R_3 \cdot \cos 2R\pi \cdot (g_{best} - x_{LD,k,j}) + g_{best} & R_4 < 0.5 \\ B \cdot R_3 \cdot \cos 2R\pi \cdot (g_{best} - x_{LD,k,j}) - g_{best} & R_4 \geq 0.5 \end{cases} \quad (9)$$

$$B = 2 - \frac{T_{cur}}{T_{max}}$$

式中: g_{best} 为种群内个体的最优位置; R_3 和 R_4 为在 $[0,1]$ 区间上的随机数。

3 白冠鸡优化算法优化 SVM 参数的预测模型

3.1 支持向量机(SVM)

由于篇幅有限,不再对 SVM 的预测理论进行推导,具体步骤可以参考文献[17]。因为 SVM 的预测结果在很大程度上受惩罚因子和核函数中参数的影响^[17],所以采用白冠鸡优化算法对这两个参数进行寻优,从而提高短期光伏发电功率预测的精度。

3.2 白冠鸡优化算法优化 SVM 参数

利用 COOT 算法对 SVM 的参数进行优化的步骤如下:

1) 利用式(2)和式(3)分别初始化白冠鸡领导者和跟随者数量。设置白冠鸡种群的个体数 $N=50$,其中白冠鸡领导者的数量 $N_{LD}=5$,白冠鸡跟随者的数量 $N_{coot}=45$,最大迭代次数 $T_{max}=30$,待优化问题的维数 $d=2$,搜索空间的上限 $x_{U,1}=x_{U,2}=100$,下限 $x_{L,1}=x_{L,2}=0.01$ 。

2) 计算白冠鸡领导者和白冠鸡跟随者的适应度函数,找出白冠鸡种群内个体的最优位置 g_{best} ,记下此时的适应度函数值为 $f_{coot}(g_{best})$ 。

3) 计算 A 和 B 的值。随机生成一个在 $[0,1]$ 区间上的随机数 r_1 ,若 $r_1 < 0.5$,则 R, R_1 和 R_3 均为 1 行 d 列的随机向量;否则, R, R_1 和 R_3 均为随机数。

4) 计算白冠鸡领导者的序号 k 。

5) 随机生成一个在 $[0,1]$ 区间上的随机数 r_2 ,若 $r_2 > 0.5$,则利用式(8)计算白冠鸡跟随者个体的位置;否则,跳到步骤 6。

6) 若 $r_2 < 0.5$ 且 $i \neq 1$,则利用式(6)计算白冠鸡跟随者个体的位置;否则,利用式(4)和式(5)计算白冠鸡跟随者个体的位置。

7) 以均方误差作为适应度函数 $f_{coot}(\cdot)$,如式(10)所示,分别计算白冠鸡跟随者个体 $x_{i,j}$ 的适应度函数 $f_{coot}(x_{i,j})$ 的值和白冠鸡领导者个体 $x_{LD,k,j}$ 的适应度函数 $f_{coot}(x_{LD,k,j})$ 的值。若 $f_{coot}(x_{i,j}) < f_{coot}(x_{LD,k,j})$,则令白冠鸡跟随者个体的位置与白冠鸡领导者个体的位置进行互换,同时令白冠鸡跟随者个体的适应度函数值与白冠鸡领导者个体的适应度函数值进行互换;否则不变。

$$f_{coot}(\cdot) = \frac{1}{N_t} \sum_{i=1}^{N_t} (y_{pv,t,i} - y_{pv,a,i})^2 \quad (10)$$

式中: N_t 为训练集样本数; $y_{pv,t,i}$ 为光伏功率的预测值; $y_{pv,a,i}$ 为光伏功率的实际值。

8) 随机生成一个在 $[0,1]$ 区间上的随机数 R_4 ,利用式(9)计算白冠鸡领导者的位置。

9) 计算白冠鸡领导者的适应度函数 $f_{coot}(x_{LD,s,j})$ 的值,若 $f_{coot}(x_{LD,s,j}) < f_{coot}(g_{best})$,则将领导者的位置与白冠鸡种群内个体的最优位置互换;否则不变。

10) 判断白冠鸡优化算法是否已达到最大迭代次数。如果已达到,那么输出支持向量机的最优参数;否则迭代次数加 1,并跳至步骤 3 继续寻优。

COOT 算法优化 SVM 参数的流程如图 1 所示。

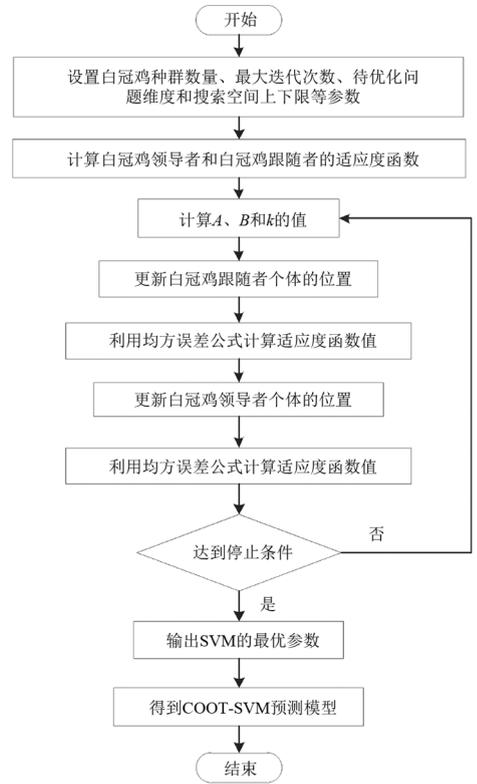


图 1 COOT 算法优化 SVM 参数流程

4 算例分析

以所建立的 COOT-SVM 短期光伏发电功率预测模型,选取某光伏电站在 2017 年春季中的 4 月前 21 天和夏季中的 7 月前 21 天的相关气象因素历史数据和光伏发电系统输出功率历史数据作为研究对象。4 月 1 日至 21 日和 7 月 1 日至 21 日的光伏发电功率历史数据分别如图 2 和图 3 所示,所选取的数据按照每隔 15 min 采样一次的频率进行采集,采

集时间范围为一整天,并分别选取 4 月 22 日和 7 月 22 日作为待预测日期,预测间隔为 15 min,输出 96 个光伏发电功率预测数据。

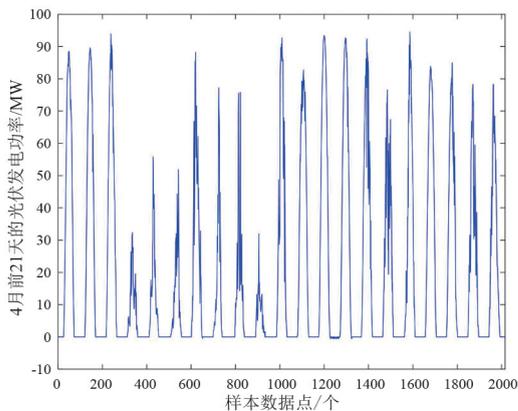


图 2 4 月前 21 天的光伏发电功率

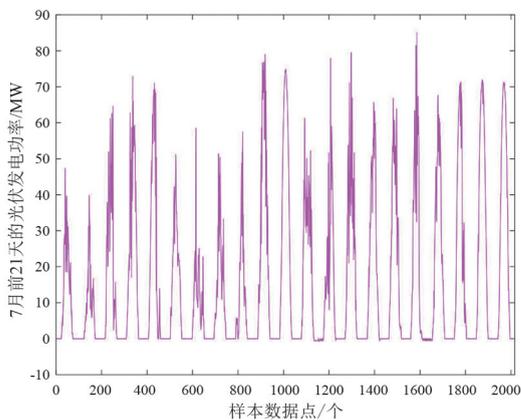


图 3 7 月前 21 天的光伏发电功率

为了避免数据之间因为不同量纲的差异而对预测结果造成影响,对所有输入和输出的数据都进行归一化处理,使数据都规整在 $[0, 1]$ 范围内,归一化的计算表达式^[22-24]为

$$T_{\text{norm}} = \frac{T - T_{\min}}{T_{\max} - T_{\min}} \quad (11)$$

式中: T 为原始数据; T_{\min} 为原始数据最小值; T_{\max} 为原始数据最大值。

4.1 短期光伏功率预测结果及其分析

通过白冠鸡优化算法优化 SVM 的惩罚因子和核函数参数可以获得 COOT-SVM 预测模型对光伏功率进行 24 h 的短期预测。为了进一步验证 COOT-SVM 预测模型的预测效果,通过与 BP 和 SVM 的预测结果进行比较,再通过仿真分析,可得某光伏电站在 2017 年春季中的 4 月 22 日和夏季中的 7 月 22 日的短期光伏发电功率的预测值和实际值,分别如图 4 和图 5 所示。

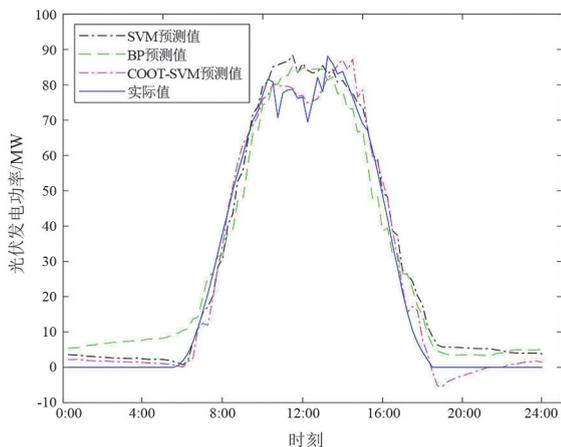


图 4 4 月短期光伏发电功率预测结果

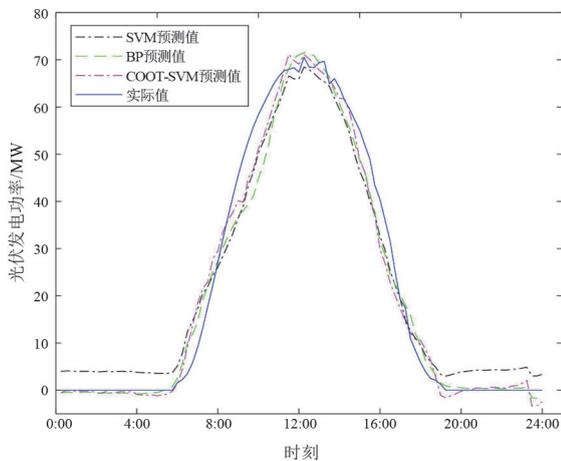


图 5 7 月短期光伏发电功率预测结果

从图 4、图 5 中可以看出,COOT-SVM 预测模型的预测值比 BP 和 SVM 预测模型更接近实际光伏功率的数值。

4.2 预测结果评价指标

考虑多种误差对预测结果的影响,提高了预测结果的鲁棒性。这里采用 3 种误差指标对光伏功率预测结果进行评价,分别为均方根误差、均方误差以及平均绝对误差。

1) 均方根误差^[25]

$$T_{\text{RMSE}} = \left\{ \sum_{t=1}^m [T_{\text{real}}(t) - T_{\text{pred}}(t)]^2 / m \right\}^{\frac{1}{2}} \quad (12)$$

式中: $T_{\text{real}}(t)$ 为 t 时刻实际的光伏发电功率; $T_{\text{pred}}(t)$ 为 t 时刻预测的光伏发电功率; m 为预测样本数据的数量。

2) 均方误差^[1]

$$T_{\text{MSE}} = \frac{\sum_{t=1}^m [T_{\text{pred}}(t) - T_{\text{real}}(t)]^2}{m} \quad (13)$$

3) 平均绝对误差^[26]

$$T_{MAE} = \frac{\sum_{t=1}^m |T_{\text{real}}(t) - T_{\text{pred}}(t)|}{m} \quad (14)$$

使用 BP、SVM 和 COOT-SVM 模型对 4 月短期光伏发电功率进行的预测误差如表 2 所示。

表 2 不同方法预测误差分析(4 月)

预测方法	均方根误差 T_{RMSE}/MW	均方误差 T_{MSE}/MW	平均绝对误差 T_{MAE}/MW
BP	6.730 3	45.297 6	6.139 5
SVM	5.562 3	30.938 9	4.512 6
COOT-SVM	3.404 2	11.588 8	2.508 7

从表 2 中可以计算出,COOT-SVM 预测模型的 T_{RMSE} 比 BP 和 SVM 预测模型分别降低了 49.42% 和 38.80%;COOT-SVM 预测模型的误差 T_{MSE} 比 BP 和 SVM 预测模型分别降低了 74.42% 和 62.54%;COOT-SVM 预测模型的 T_{MAE} 比 BP 和 SVM 预测模型分别降低了 59.14% 和 44.41%。

使用 BP、SVM 和 COOT-SVM 模型对 7 月短期光伏发电功率进行预测的误差如表 3 所示。

表 3 不同方法预测误差分析(7 月)

预测方法	均方根误差 T_{RMSE}/MW	均方误差 T_{MSE}/MW	平均绝对误差 T_{MAE}/MW
BP	4.472 0	19.998 8	2.886 7
SVM	5.036 7	25.368 2	4.537 9
COOT-SVM	3.826 3	14.640 4	2.648 9

从表 3 中可以计算出,COOT-SVM 预测模型的 T_{RMSE} 比 BP 和 SVM 预测模型分别降低了 14.44% 和 24.03%;COOT-SVM 预测模型的 T_{MSE} 比 BP 和 SVM 预测模型分别降低了 26.79% 和 42.29%;COOT-SVM 预测模型的 T_{MAE} 比 BP 和 SVM 预测模型分别降低了 8.24% 和 41.63%。

对比结果表明,COOT-SVM 预测模型比 BP 和 SVM 预测模型具有更好的预测精度和稳定性。

5 结 论

上面构建了一种 COOT-SVM 预测模型对短期光伏发电功率进行预测。通过皮尔逊相关系数公式可以计算得到对光伏发电影响较大的因素为太阳总辐射强度、太阳散射辐射强度、太阳直射辐射强度、组件温度和环境温度 5 个气象因素,将它们作为输入数据,光伏电站的发电功率作为输出数据,并对输入和输出的数据进行归一化处理;利用 COOT-SVM 预测模型实现光伏发电功率的短期预测。通过将由

COOT-SVM 预测模型与 BP、SVM 预测模型得到的预测功率的曲线和实际输出功率进行对比,并计算出 BP、SVM 和 COOT-SVM 预测模型的均方根误差、均方误差和平均绝对误差,可知 COOT-SVM 预测模型具有优越的预测性能和较高的稳定性,能够为短期光伏发电功率预测提供理论参考。

参考文献

- [1] 杨锡运,赵泽宇,杨岩,等.基于时空信息组合的分布式光伏功率预测方法研究[J].热力发电,2022,51(8):64-72.
- [2] 宋子博,葛曼玲,谢冲,等.基于改进 CSO 算法的光伏系统发电功率短期预测[J].电源技术,2022,46(2):182-185.
- [3] 王小杨,罗多,孙韵琳,等.基于 ABC-SVM 和 PSO-RF 的光伏微电网日发电功率组合预测方法研究[J].太阳能学报,2020,41(3):177-183.
- [4] 张涛,朱瑞金,扎西顿珠.基于改进骨干差分进化算法优化 LSSVM 的短期光伏发电功率预测[J].热力发电,2021,50(5):102-107.
- [5] 张雨金,杨凌帆,葛双冶,等.基于 Kmeans-SVM 的短期光伏发电功率预测[J].电力系统保护与控制,2018,46(21):118-124.
- [6] 王昕,黄柯,郑益慧,等.基于 PNN/PCA/SS-SVR 的光伏发电功率短期预测方法[J].电力系统自动化,2016,40(17):156-162.
- [7] 谭津,邓长虹,杨威,等.微电网光伏发电的 Adaboost 天气聚类超短期预测方法[J].电力系统自动化,2017,41(21):33-39.
- [8] 孙子涵,姜志海,刘延龙,等.基于小波变换和优化的 Elman 神经网络的光伏功率预测[J].电网与清洁能源,2022,38(6):98-103.
- [9] 马磊,黄伟,李克成,等.基于 Attention-LSTM 的光伏超短期功率预测模型[J].电测与仪表,2021,58(2):146-152.
- [10] 何家裕,吴杰康,杨金文,等.基于改进 BP 神经网络的光伏发电预测模型[J].黑龙江电力,2021,43(1):1-10.
- [11] 王英立,陶帅,候晓晓,等.基于 MIV 分析的 GA-BP 神经网络光伏短期发电预测[J].太阳能学报,2020,41(8):236-242.
- [12] 胡兵,詹仲强,陈洁,等.基于 PCA-GA-Elman 的短期光伏出力预测研究[J].太阳能学报,2020,41(6):256-263.
- [13] 孟巍,郭腾炫,刘映娟,等.基于长短记忆神经网络优化的短期光伏发电预测方法[J].电网与清洁能源,2022,38(5):129-134.

- 的影响研究[J].电测与仪表,2020,57(19):14-20.
- [8] 朱大锐,王睿,程文姬,等.基于改进 PageRank 算法的输电网关键节点辨识方法研究[J].电力系统保护与控制,2022,50(5):86-93.
- [9] 罗志刚,韦钢,袁洪涛,等.基于区间直觉模糊理论的直流配电网规划方案综合决策[J].电工技术学报,2019,34(10):2011-2021.
- [10] TABARI M, YAZDANI A. An energy management strategy for a DC distribution system for power system integration of plug-in electric vehicles [J]. IEEE Transactions on Smart Grid, 2016, 7(2): 659-668.
- [11] 廖建权,周念成,王强钢,等.直流配电网电能质量指标定义及关联性分析[J].中国电机工程学报,2018,38(23):6847-6860.
- [12] JIA Ke, XUAN Zhenwen, FENG Tao, et al. Transient high-frequency impedance comparison-based protection for flexible DC distribution systems [J]. IEEE Transactions on Smart Grid, 2020, 11(1): 323-333.
- [13] 李国庆,边竞,王鹤,等.直流电网潮流分析与控制研究综述[J].高电压技术,2017,43(4):1067-1078.
- [14] 许丹,王斌,张晓天,等.考虑节点控制模式的柔性直流电网潮流线性化计算方法[J].电力系统自动化,2017,41(19):54-58.
- [15] 柴润泽,窦竟铭,张保会.含电压源换流器的交直流混合电网潮流统一表达与可行解求取[J].中国电机工程学报,2016,36(5):1260-1268.
- [16] 张朝学,邹晓松,余梦天,等.基于电压下垂控制的含 MMC 直流电网潮流计算方法研究[J].电力科学与工程,2018,34(11):1-7.
- [17] 孙银锋,吴学光,汤广福,等.基于节点阻抗矩阵 GS 法的直流电网稳态潮流计算[J].中国电机工程学报,2015,35(8):1882-1892.
- [18] 杨堤,程浩忠,姚良忠,等.基于电压控制特性的电压源型多端直流/交流系统潮流求解[J].电力系统自动化,2016,40(6):42-48.
- [19] 和敬涵,李智诚,王小君,等.计及多种控制方式的直流电网潮流计算方法[J].电网技术,2016,40(3):712-718.
- [20] 汤广福.基于电压源换流器的高压直流输电技术[M].北京:中国电力出版社,2010.

作者简介:

叶 希(1987),女,博士,高级工程师,从事电网调度运行相关工作;

陈 振(1991),男,博士,高级工程师,从事电网智能调度运行研究;

朱 童(1992),男,硕士,工程师,从事电网调度运行工作。

(收稿日期:2023-05-29)

(上接第 33 页)

- [14] 谢宏文,查浩,陈庆文,等.一种使用 CALSTM 模型进行短期光伏功率预测的方法[J].供用电,2020,37(12):61-66.
- [15] 王继东,宋智林,冉冉.基于改进支持向量机算法的光伏发电短期功率滚动预测[J].电力系统及其自动化学报,2016,28(11):9-13.
- [16] 于秋玲,许长清,李珊,等.基于模糊聚类和支持向量机的短期光伏功率预测[J].电力系统及其自动化学报,2016,28(12):115-118.
- [17] 马骏,江锐,丁倩,等.基于多元宇宙优化支持向量机的短期光伏发电功率预测[J].热力发电,2020,49(4):87-92.
- [18] 魏鹏飞,樊小朝,史瑞静,等.基于改进麻雀搜索算法优化支持向量机的短期光伏发电功率预测[J].热力发电,2021,50(12):74-79.
- [19] 王鹏翔,沈娟,王菁昉,等.基于 PCA-LMD-WOA-ELM 的短期光伏功率预测[J].智慧电力,2022,50(6):72-78.
- [20] 谭海旺,杨启亮,邢建春,等.基于 XGBoost-LSTM 组合模型的光伏出力预测[J].太阳能学报,2022,43(8):75-81.
- [21] NARUEI I, KEYNIA F. A new optimization method based on coot bird natural life model[J]. Expert Systems with Applications, 2021, 183(2): 115352.
- [22] 陈晓华,吴杰康,陈盛语,等.基于 EMD 和 IABC-SVM 算法的复合电压暂降源辨识方法[J].广东电力,2022,35(2):11-18.
- [23] 陈晓华,王志平,吴杰康,等.基于 VMD 和 IAO-SVM 的电压暂降源识别方法[J].广东电力,2023,36(1):59-67.
- [24] CHEN Xiaohua, WANG Zhiping, HONG Mingzhi, et al. Power quality disturbance identification method based on improved GSA-SVM algorithm [C]//2022 IEEE 5th International Electrical and Energy Conference (CIEEC), IEEE, 2022:191-196.
- [25] 殷豪,张铮,丁伟锋,等.基于生成对抗网络和 LSTM-CSO 的少样本光伏功率短期预测[J].高电压技术,2022,48(11):4342-4351.
- [26] 孟安波,许炫溶,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.

作者简介:

陈晓华(1996),男,硕士研究生,研究方向为电能质量分析、电力系统运行与控制、智能算法优化、能源需求预测、备用容量优化、虚拟电厂管控等;

王志平(1978),男,博士,研究员,硕士生导师,研究方向为电力电子装置及控制、智能制造等;

吴杰康(1965),男,博士,教授,博士生导师,研究方向为电力系统运行与控制等。

(收稿日期:2023-02-21)