

DOI: 10.19783/j.cnki.pspc.181394

一种基于加权马尔科夫链修正的 SVM 光伏出力预测模型

张静¹, 褚晓红², 黄学安², 范文², 陈雁¹, 万泉¹, 赵加奎¹

(1. 国网信通产业集团北京中电普华信息技术有限公司, 北京 100192;

2. 国网铜陵供电公司, 安徽 铜陵 244000)

摘要: 构建高效的光伏出力预测模型, 能减少光伏出力随机性对电力系统的冲击。考虑光伏发电的随机性和不稳定性, 提出用加权的马尔科夫链修正 SVM 预测模型, 以提高预测精度。首先建立 SVM 光伏出力预测模型, 预测未来 1 天的出力曲线。然后基于均值-均方差方法对预测残差进行分级, 以残差序列标准化的各阶自相关系数为权重, 运用加权马尔科夫链模型, 预测残差的未来状态。最后根据未来状态空间的阈值对 SVM 预测结果进行修正。将此模型应用到某光伏发电系统的出力预测实例中, 仿真结果表明, 修正后的模型预测精度更高, 模型具备可行性和有效性。

关键词: 光伏系统; SVM; 加权马尔科夫链; 出力预测; 残差修正

A model for photovoltaic output prediction based on SVM modified by weighted Markov chain

ZHANG Jing¹, CHU Xiaohong², HUANG Xue'an², FAN Wen², CHEN Yan¹, WAN Quan¹, ZHAO Jiakui¹

(1. Beijing China-Power Information Technology Co., Ltd. State Grid Information & Telecommunication Group,

Beijing 100192, China; 2. State Grid Tongling Electric Power Supply Company, Tongling 244000, China)

Abstract: Building an efficient PV output forecasting model can reduce the impact of PV output fluctuation on the power system. Considering the randomness and instability of photovoltaic power generation, a weighted Markov chain is proposed to modify the SVM prediction model to improve the prediction accuracy. Firstly, the SVM photovoltaic output prediction model is established to predict the output curve of the next day. Then, the relative errors are classified based on mean-mean square deviation method, and the weighted Markov chain model is used to predict the future state of the relative errors by weighting the autocorrelation of each order normalized error sequence. The threshold of state space is used to correct the prediction result of SVM. The model is applied to the output prediction of a photovoltaic power system. The simulation results show that the model modified by weighted Markov chain has higher prediction accuracy, and the model is feasible and effective.

This work is supported by National Natural Science Foundation of China (No. 11601125).

Key words: photovoltaic system; SVM; weighted Markov chain; power forecasting; error correction

0 引言

光伏发电具有随机性、波动性和不稳定性等特点, 大量的分布式光伏发电并网会降低电能质量^[1], 加大配电网的调度管理难度^[2-3], 影响电网的安全与稳定。因此, 结合光伏发电的特性, 构建高效、精确的发电功率预测模型, 对电网的统筹规划和安全稳定具有重要意义。

目前, 效果较好的光伏出力预测模型主要是以

历史发电功率和气象条件等数据作为输入, 基于神经网络^[4-9]、支持向量机^[10-15]、组合方法^[16-17]等算法直接预测发电功率。在神经网络方面, 主要是运用 BP 神经网络^[4-6]、Elman 神经网络^[7]、小波神经网络^[8]等, 大部分采用 BP 网络, 并采用粒子群(PSO)算法^[6,9]、GA 遗传算法等去优化网络参数。支持向量机方面, 往往采用最小二乘法^[11]改进模型, 并与天气聚类^[13]、筛选相似日^[14]、变量选择^[15]等方法结合, 相较 BP 神经网络, 显示出更高的预测精度。组合方法方面通常会先用一种算法建模, 再结合其他算法对预测结果进行修正, 该方法综合了多个算

法的优点,考虑的因素更全面,有较高的预测精度。组合方法中,有一种常规的思路是对预测残差进行修正,称为残差修正法。马尔科夫链适合描述随机波动性大的变量的预测问题,常常被应用于预测模型的残差修正过程,在风力发电^[18]、降水量^[19]等预测中都取得了显著的成效。文献[20]中,理论推导说明了光伏系统的输出功率是一个马尔科夫链,并建立了基于马尔科夫链算法的光伏出力时间序列预测模型^[20-21]。文献[17]用马尔科夫链修正残差的BP神经网络模型预测光伏系统的日发电量,预测精度与BP神经网络相比有显著提高,进一步表明马尔科夫链残差修正方法在光伏出力预测中是可行的。

本文提出用加权的马尔科夫链修正残差的SVM光伏出力预测模型,该模型兼具SVM预测模型和马尔科夫链的优点,克服了光伏发电功率随机波动性大影响预测精度的缺点。在实例分析中,与文献[17]提出的BP神经网络加马尔科夫链的组合模型进行了比较,结果表明本文提出的组合形式预测效果显著,实用性强。

1 模型简介

1.1 支持向量机(Support Vector Machine, SVM)

支持向量机(SVM)算法建立在统计学习理论的VC维和结构风险最小原理基础上,有唯一的全局最优解,收敛速度快。它在解决小样本、非线性、高维、局部极小等实际问题中表现出特有的优势,在很多领域都取得了成功的应用,如基于SVM的电压种类自动识别^[22]、故障状态诊断^[23]等。

SVM回归是支持向量机在函数回归领域的应用。给定训练样本 $\{x_i, y_i\}$,其中 $i=1, \dots, m$, m 为样本容量, $x_i \in \mathbb{R}^n$, $y_i \in \mathbb{R}$ 分别为输入、输出向量,支持向量回归算法通过一个非线性函数 ϕ ,将数据集映射到高维特征空间 H ,并在该空间中进行线性回归。具体函数形式为

$$f(x) = \omega \cdot \phi(x) + b \quad (1)$$

式中: ω 为权值向量; b 为偏置量。

这样,高维特征空间的线性回归与低维空间的非线性回归对应。式(1)中的 ω 与 b 可由最小化式(2)来估计。

$$E(\omega) = \frac{1}{2}(\omega \cdot \omega) + \frac{c}{m} \sum_{i=1}^m \max\{0, |y_i - f(x_i)| - \varepsilon\} \quad (2)$$

式中:第一项 $(\omega \cdot \omega)$ 描述函数 $f(x)$ 的复杂性;第二项称为经验风险,其作用在于用稀疏点表示决策函数; ε 为回归允许的最大误差; c 为惩罚项常数。

利用对偶原理、拉格朗日函数与核函数,将最小化式(2)转化为最优化问题,解得权值 ω ,再根据KKT(Karush-Kuhn-Tucker)条件,解得偏置量 b 。求解过程中,式(1)可转化为

$$y = f(x) = \sum_{i=1}^m \alpha_i K(x, x_i) + b \quad (3)$$

式中: $K(x, x_i) = \phi(x_i)^T \phi(x)$ 为核函数; α_i 为拉格朗日乘子。

1.2 加权马尔科夫链(Weighted Markov Chain)

马尔科夫过程是指具有马尔科夫性的随机过程。马尔科夫性是指链当随机过程在 t_0 时刻所处状态已知,在 $t > t_0$ 时刻所处状态条件分布与 t_0 之前的状态无关。马尔科夫链是指时间和状态均离散的马尔科夫过程,其马尔科夫性用条件分布律描述如下^[21]。

设随机序列 $\{X_n, n=0, 1, 2, \dots\}$,状态空间为离散空间 $I = \{a_1, a_2, \dots\}$, $a_i \in \mathbb{R}$,时间集 $T = \{0, 1, 2, \dots\}$ 。对任意的正整数 n , r 和任意的 $0 \leq t_1 < t_2 < \dots < t_r < n$; $t_i, m, m+n \in T$,有

$$\begin{aligned} p\{X_{m+n} = a_j | X_{t_1} = a_{i_1}, X_{t_2} = a_{i_2}, \dots, X_{t_r} = a_{i_r}\} \\ = p\{X_{m+n} = a_j | X_n = a_i\} \end{aligned}$$

上式右端记为 $p_{ij}(m, m+n) = p\{X_{m+n} = a_j | X_n = a_i\}$,称为马尔科夫链在 m 时刻处于状态 a_i ,在 $m+n$ 时刻转移到状态 a_j 的转移概率。显然

$$\sum_{j=1}^{+\infty} p_{ij}(m, m+n) = 1, i=1, 2, \dots$$

由转移概率组成的矩阵称为状态转移概率矩阵,记为 $P(m, m+n) = (p_{ij}(m, m+n))$ 。

若 $p_{ij}(m, m+n)$ 与时刻 m 无关,只与 i, j 及时间间隔 n 有关,则称此链是齐次马尔科夫链,此时转移概率记为 $p_{ij}(n)$,称为 n 步转移概率,转移概率矩阵记为 $P(n)$,称为 n 步转移概率矩阵。下文出现的均为齐次马尔科夫链。

对于齐次马尔科夫链,由Chapman-Kolmogorov方程可知

$$P(n) = (P(1))^n \quad (4)$$

因此,齐次马尔科夫链的有限分布由初始分布和一步转移概率矩阵完全确定。

在马尔科夫链预测过程中,状态的分级是至关重要的。本文采用理论简单且应用广泛的均值-标准差分级法,该方法依据样本均值和标准差划分状态区间。设样本序列为 $x = (x_1, x_2, \dots, x_n)$,样本均值为 \bar{x} ,标准差为 S ,由数理统计中的中心极限定理,

可将样本序列划分为五个区间: $E1(-\infty, \bar{x} - S]$, $E2(\bar{x} - S, \bar{x} - 0.5S]$, $E3(\bar{x} - 0.5S, \bar{x} + 0.5S]$, $E4(\bar{x} + 0.5S, \bar{x} + S]$, $E5(\bar{x} + S, +\infty)$ 。

光伏发电过程中, 前后时间顺序的出力值具备依赖关系, 残差亦是如此。残差序列的各阶自相关系数可以刻画这种相关关系的强弱。因此, 可考虑依照若干历史日的出力值残差情况对预测日的残差状况进行预测, 并且按前面历史日与预测日相依赖关系的强弱加权求和, 达到充分利用信息进行预测的目的。所以本文采用加权马尔科夫链模型进行残差修正, 步骤如下。

1) 划分预测残差的状态: 计算残差序列 (x_1, x_2, \dots, x_n) 样本均值 \bar{x} 和标准差 S , 划分状态区间 $I = \{E1, E2, E3, E4, E5\}$ 。

2) 计算残差序列的各阶自相关系数 r_k , 并标准化 w_k 。

$$r_k = \frac{\sum_{l=1}^{n-k} (x_l - \bar{x})(x_{l+k} - \bar{x})}{\sum_{l=1}^n (x_l - \bar{x})^2}$$

$$w_k = \frac{|r_k|}{\sum_{k=1}^m |r_k|}$$

式中: r_k 表示第 k 阶自相关系数; w_k 表示步长(滞时)为 k 的马尔科夫链的权重; m 为预测时根据实际情况确定要计算的最大阶数。

3) 统计确定不同步长(滞时)的状态转移概率矩阵。

4) 分别以残差序列后 m 个残差所在的状态为初始状态, 结合其对应的状态转移概率矩阵计算出预测日残差的状态概率 p_i^k , $i \in I$ 为状态, k 为步长, $k \leq m$ 。

5) 将同一状态不同步长的各预测概率 p_i^k 加权作为残差在该状态的预测概率, 即

$$p_i = \sum_{k=1}^m w_k p_i^k \quad (5)$$

并以预测概率的最大值 $\max\{p_i, i \in I\}$ 所对应的状态作为未来状态。

6) 预测值被修正 $V = V_0(1 - \eta)$, 其中 V_0 是原始的预测结果, η 为上一步骤确定的未来状态区间上下阈值的平均值。如果未来状态是 E1, 区间的下阈值取序列的最小值, 如果未来状态是 E5, 区间的上阈值取序列的最大值。

2 模型应用

本文利用 Matlab 实现了模型的仿真预测过程。样本数据为某光伏发电客户一年的输出功率值与当地的温度和天气数据。功率数据值从 8:00 至 17:00 每 15 min 取样一次, 与当天的温度共同作为模型的输入变量。算例以晴天的光伏发电预测模型为例, 其他天气类型模型建立和预测过程类似, 不再详述。

具体来说, 取 2014 年 7 月 9 日至 10 月 26 日晴天的历史发电数据和温度作为样本数据。将数据分组, 前 50% 的数据作为 SVM 的学习样本, 最后一天数据即 10 月 26 日的数据作为整个模型的检验样本, 其他数据作为残差修正的测试样本。

首先对样本数据进行预处理, 检测发电功率数据的异常值并处理, 对温度数据线性归一化。设定 SVM 模型的参数, 如惩罚项、核参数的设定。从 8:00—17:00, 每间隔 15 min, 建立该时刻的 SVM 预测模型, 共建立 37 个。模型采用预测日及其前 3 天的最高气温、平均气温和预测日前 3 天同一时刻的发电功率共 11 条数据作为输入, 输出是预测日某时刻的发电功率。

应用构建好的 SVM 模型对测试样本进行预测, 通过计算得到残差序列, 选取 13:00 时刻进行观察, 结果如表 1 所示。采用均值-均方差分级法将残差分为 5 种: $E1(-\infty, -9.19\%)$, $E2(-9.19\%, 1.52\%)$, $E3(1.52\%, 22.94\%)$, $E4(22.94\%, 33.66\%)$, $E5(33.66\%, +\infty)$, 建立马尔科夫状态空间集。

表 1 出力值 SVM 拟合结果

Table 1 SVM fitting output				
日期(13:00)	实际发电功率/kW	SVM 预测功率/kW	相对误差/%	状态
10-6	1.313 4	1.646 5	25.36	E4
10-7	1.497 5	1.334 0	-10.922	E1
10-8	1.566 5	1.358 5	-13.29	E1
10-9	1.500 9	1.448 9	-3.470	E2
10-10	1.513 0	1.432 5	-5.320	E2
10-17	0.888 3	1.431 3	61.13	E5
10-19	1.190 9	1.347 4	13.14	E3
10-20	1.280 3	1.347 0	5.210	E3
10-22	1.253 4	1.489 4	18.83	E3
10-24	1.199 6	1.444 4	20.41	E3
10-25	1.142 5	1.410 5	23.46	E4

根据上述状态区间的划分, 获得预测结果的状态转移情况, 如表 2 所示, 据此确定状态转移概率矩阵。

$$P(1) = \begin{bmatrix} \frac{1}{2} & \frac{1}{2} & 0 & 0 & 0 \\ 0 & \frac{1}{2} & 0 & 0 & \frac{1}{2} \\ 0 & 0 & \frac{3}{4} & \frac{1}{4} & 0 \\ 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 \end{bmatrix}$$

$$P(2) = P(1)^2, P(3) = P(1)^3$$

表 2 残差的状态转移统计

Table 2 State transition statistics

状态	E1	E2	E3	E4	E5	合计
E1	1	1				2
E2		1			1	2
E3			3	1		4
E4	1					1
E5			1			1
合计	2	2	4	1	1	10

前三步的状态转移概率矩阵的权重系数为 $w = [0.1553, 0.4034, 0.4413]$ (比较了几种步长加权预测后的结果, 选择了前三步)。根据步骤 4) 步骤 6), 计算修正后预测值为 1.079 8, 真实值为 1.082 2, SVM 预测值为 1.230 3, 因此, 在 13:00 时刻相对误差绝对值降低了 13.47%。

应用本文的模型预测 10 月 26 日当天各个时刻的光伏出力值。另外, 建立 BP 神经网络与加权马尔科夫链修正残差的组合模型, BP 神经网络的输入输出与 SVM 相同。预测结果如图 1 和表 3 所示。

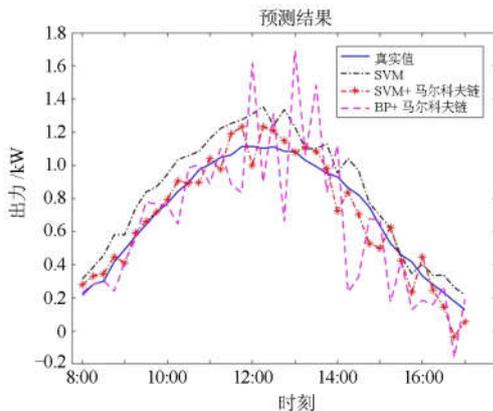


图 1 预测日拟合结果

Fig. 1 Fitting of forecasting day

采用常用的评价指标平均绝对百分误差 (MAPE) 和均方根误差 (RMSE) 对模型进行评估, 定义为

$$e_{MAPE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{P_i^f - P_i}{P_i} \right| \times 100\%$$

$$e_{RMSE} = \sqrt{\frac{\sum_{i=1}^n (P_i^f - P_i)^2}{n}}$$

式中: P_i^f 、 P_i 分别为预测功率和实际功率; n 为预测样本数。

表 3 预测日整点拟合结果

Table 3 Fitting of forecasting daily integral point

时刻	实际值/ kW	SVM 预 测值/kW	相对 误差/%	修正后预 测值/kW	相对 误差/%
8:00	0.214 2	0.312 5	45.91	0.279 0	30.23
9:00	0.491 9	0.581 1	18.13	0.408 0	-17.06
10:00	0.770 9	0.944 2	22.48	0.793 7	2.96
11:00	1.005 7	1.159 9	15.33	1.039 2	3.33
12:00	1.113 4	1.308 9	17.56	1.000 8	-10.12
13:00	1.082 2	1.230 3	13.69	1.079 8	-0.22
14:00	0.929 5	0.952 7	2.49	0.723 5	-22.16
15:00	0.634 5	0.696 1	9.71	0.500 7	-21.09
16:00	0.330 0	0.403 0	22.11	0.445 2	34.91
17:00	0.127 6	0.218 3	71.06	0.055 5	-56.48

经过加权马尔科夫链修正后, SVM 预测模型的 MAPE 从 22.57% 下降到 16.90%, 下降了 5.67%, RMSE 从 0.142 6 下降到 0.099 2, 下降了 0.043 4, 预测精度提高幅度显著。另外, 经过加权马尔科夫链修正后的 BP 神经网络预测模型的 MAPE 和 RMSE 分别为 29.60% 和 0.256 1, 显然本文提出的组合模型预测效果更好。

3 结论

本文提出 SVM 光伏出力预测与加权马尔科夫链修正残差的组合预测模型, 综合了 SVM 模型与马尔科夫链模型的优点, 适用于样本量少且随机波动性大的光伏出力时间序列预测问题。算例仿真表明该模型有较高的预测精度, 具备可行性和实用性。

参考文献

[1] 金卓勃, 向铁元, 陈红坤, 等. 考虑电能质量问题的分布式光伏发电接入规划方法[J]. 电力系统保护与控制, 2017, 45(9): 1-8.
JIN Zhuoqing, XIANG Tieyuan, CHEN Hongkun, et al. Planning method of distributed photovoltaic power generation considering power quality[J]. Power System Protection and Control, 2017, 45(9): 1-8.

- [2] 吴峰, 张涵. 用户光伏发电储能优化配置研究[J]. 智慧电力, 2018, 46(7): 1-6.
WU Feng, ZHANG Han. Study on optimized configuration of energy storage for photovoltaic power generation[J]. Smart Power, 2018, 46(7): 1-6.
- [3] 刘岩, 吴以岷, 徐荣敏, 等. 含智能负荷和分布式能源接入的配电网调度研究[J]. 电力系统保护与控制, 2018, 46(20): 116-123.
LIU Yan, WU Yimin, XU Rongmin, et al. Research on distribution network scheduling with smart load and distributed energy access[J]. Power System Protection and Control, 2018, 46(20): 116-123.
- [4] SULAIMAN S I, RAHMAN T K A, MUSIRIN I. Partial evolutionary ANN for output prediction of a grid-connected photovoltaic system[J]. International Journal of Computer and Electrical Engineering, 2009, 1(1): 40-45.
- [5] 于群, 朴在林, 胡博. 基于 EEMD 和 BP 神经网络的短期光伏功率预测模型[J]. 电网与清洁能源, 2016, 32(7): 132-137.
YU Qun, PIAO Zailin, HU Bo. A hybrid model for short-term photovoltaic power forecasting based on EEMD-BP combined method[J]. Power System and Clean Energy, 2016, 32(7): 132-137.
- [6] 张佳伟, 张自嘉. 基于 PSO-BP 神经网络的短期光伏系统发电预测[J]. 可再生能源, 2012, 30(8): 28-32.
ZHANG Jiawei, ZHANG Zijia. Short-term photovoltaic system power forecasting based on PSO-BP neural network[J]. Renewable Energy Resources, 2012, 30(8): 28-32.
- [7] 彭道刚, 张宇, 张浩, 等. 能源互联网下基于 HS-Elman 的光伏出力预测研究[J]. 可再生能源, 2018, 36(2): 215-222.
PENG Daogang, ZHANG Yu, ZHANG Hao, et al. The research on PV power prediction based on HS-Elman under energy internet[J]. Renewable Energy Resources, 2018, 36(2): 215-222.
- [8] 刘爱国, 黄泽平, 薛云涛, 等. 基于遗传算法小波神经网络的光伏微网发电预测[J]. 电测与仪表, 2017, 54(7): 28-33.
LIU Aiguo, HUANG Zeping, XUE Yuntao, et al. Application for photovoltaic micro-grid power forecasting using improved wavelet neural networks-based on GA[J]. Electrical Measurement & Instrumentation, 2017, 54(7): 28-33.
- [9] 胡秀云, 齐泓深, 刘道华. 一种约束类问题的带权 PSO 优化方法[J]. 信阳师范学院学报(自然科学版), 2018, 31(4): 661-665.
HU Xiuyun, QI Hongshen, LIU Daohua. An optimized method for solving constrained problem based on weighted PSO algorithm[J]. Journal of Xinyang Normal University (Natural Science Edition), 2018, 31(4): 661-665.
- [10] 栗然, 李广敏. 基于支持向量机回归的光伏发电出力预测[J]. 中国电力, 2008, 41(2): 74-78.
LI Ran, LI Guangmin. Photovoltaic power generation output forecasting based on support vector machine regression technique[J]. Electric Power, 2008, 41(2): 74-78.
- [11] 朱永强, 田军. 最小二乘支持向量机在光伏功率预测中的应用[J]. 电网技术, 2011, 35(7): 54-59.
ZHU Yongqiang, TIAN Jun. Application of least square support vector machine in photovoltaic power forecasting[J]. Power System Technology, 2011, 35(7): 54-59.
- [12] 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.
ZHANG Yujin, YANG Lingfan, GE Shuangye, et al. Short-term photovoltaic power forecasting based on Kmeans algorithm and support vector machine[J]. Power System Protection and Control, 2018, 46(21): 118-124.
- [13] 金鑫, 袁越, 傅质馨, 等. 天气类型聚类的支持向量机在光伏系统输出功率预测中的应用[J]. 现代电力, 2013, 30(4): 13-18.
JIN Xin, YUAN Yue, FU Zhixin, et al. Application of support vector machine based on weather type clustering in power output forecasting of photovoltaic generation system[J]. Modern Electric Power, 2013, 30(4): 13-18.
- [14] 傅美平, 马红伟, 毛建容. 基于相似日和最小二乘支持向量机的光伏发电短期预测[J]. 电力系统保护与控制, 2012, 40(16): 65-69.
FU Meiping, MA Hongwei, MAO Jianrong. Short-term photovoltaic power forecasting based on similar days and least square support vector machine[J]. Power System Protection and Control, 2012, 40(16): 65-69.
- [15] 杨少华, 李艾玲, 雍浩, 等. 基于变量选择和 DE-GWO 算法的光伏发电功率预测[J]. 智慧电力, 2018, 46(12): 38-44.
YANG Shaohua, LI Ailing, YONG Hao, et al.

- Photovoltaic power generation forecasting based on variable selection and DE-GWO algorithm[J]. Smart Power, 2018, 46(12): 38-44.
- [16] 丁明, 刘志, 毕锐, 等. 基于灰色系统校正-小波神经网络的光伏功率预测[J]. 电网技术, 2015, 39(9): 2438-2443.
DING Ming, LIU Zhi, BI Rui, et al. Photovoltaic output prediction based on grey system correction-wavelet neural network[J]. Power System Technology, 2015, 39(9): 2438-2443.
- [17] 姜侨娜, 陈中. BP-马尔科夫组合预测方法在光伏发电量预测中的应用[J]. 电力需求侧管理, 2011, 13(6): 21-24.
JIANG Qiaona, CHEN Zhong. The study of solar power forecasting based on BP-Markov method[J]. Power DSM, 2011, 13(6): 21-24.
- [18] GAO S J, TIAN J Y, WANG F, et al. The study of GRNN for wind speed forecasting based on Markov Chain[C] // International Conference on Modelling, Simulation and Applied Mathematics (MSAM 2015), 2015: 285-288.
- [19] 王宇博, 梁秀娟, 乔雨, 等. 基于叠加马尔科夫链和BP神经网络模型的降水量预测研究[J]. 中国农村水利水电, 2014(9): 80-86.
WANG Yubo, LIANG Xiujuan, QIAO Yu, et al. The prediction of rainfall based on superimposed Markov chains and BP neural network model[J]. China Rural Water and Hydropower, 2014(9): 80-86.
- [20] 丁明, 徐宁舟. 基于马尔可夫链的光伏发电系统输出功率短期预测方法[J]. 电网技术, 2011, 35(1): 152-157.
DING Ming, XU Ningzhou. A method to forecast short-term output power of photovoltaic generation system based on Markov Chain[J]. Power System Technology, 2011, 35(1): 152-157.
- [21] 丁明, 鲍玉莹, 毕锐. 应用改进马尔科夫链的光伏出力时间序列模拟[J]. 电网技术, 2016, 40(2): 459-464.
DING Ming, BAO Yuying, BI Rui. Simulation of PV output time series used improved Markov Chain[J]. Power System Technology, 2016, 40(2): 459-464.
- [22] 刘洋, 张刚, 刘睿洁, 等. 330 kV 变电站过电压仿真分析及分类识别[J]. 电网与清洁能源, 2017, 33(4): 64-70, 76.
LIU Yang, ZHANG Gang, LIU Ruijie, et al. Simulation analysis and classification recognition of 330 kV substation overvoltage[J]. Power System and Clean Energy, 2017, 33(4): 64-70, 76.
- [23] 田松峰, 胥佳瑞, 王美俊, 等. 基于 EEMD 云模型与 SVM 的汽轮机转子故障诊断方法[J]. 热力发电, 2017, 46(4): 111-114.
TIAN Songfeng, XU Jiarui, WANG Meijun, et al. A rotor fault diagnosis method based on EEMD cloud model and SVM[J]. Thermal Power Generation, 2017, 46(4): 111-114.

收稿日期: 2018-11-08; 修回日期: 2019-05-23

作者简介:

张静(1987—), 女, 通信作者, 博士, 研究方向为数据挖掘; E-mail: jingzh1036@163.com

褚晓红(1968—), 男, 研究生, 研究方向为建筑光伏系统的应用技术研究。E-mail: 401678734@qq.com

(编辑 周金梅)