基于相似日和 CAPSO-SNN 的光伏发电功率预测

陈 通[1],孙国强[1],卫志农[1],臧海祥[1],孙永辉[1],Kwok W Cheung[2],李慧杰[3]

(1. 河海大学 能源与电气学院,江苏 南京 211100;2. ALSTOM Grid Inc.,Redmond,USA Washington 98052;
3. 阿尔斯通电网技术中心有限公司,上海 201114)

摘要:针对光伏发电功率预测精度不高的问题,提出一种基于相似日和云自适应粒子群优化(CAPSO)算法优化 Spiking 神经网络(SNN)的发电功率预测模型。考虑到季节类型、天气类型和气象等主要影响因素,提出以综合相似度指标进行相似日选取;以 SNN 强大的计算能力和其善于处理时间序列问题的特点为基础,结合 CAPSO 算法搜索的随机性和稳定性优化 SNN 的多突触连接权值,减少对权值的约束,提高算法的收敛精度。根据某光伏电站的实测功率数据对所提模型进行测试和评估,结果表明,该模型比传统预测模型具有更高的预测精度和更好的适用性。

关键词:光伏发电;功率预测;Spiking 神经网络;云自适应粒子群优化算法;相似日选取

中图分类号:TM 615 **文献标识码**:A DOI:10.16081/j.issn.1006-6047.2017.03.012

0 引言

光伏发电功率的变化具有随机性和间歇性,会对电力系统运行产生冲击,影响电网的安全与稳定运行。为降低大规模光伏接入对电力系统的影响,保障电网的安全和经济运行,需准确预测光伏发电功率[1-2]。

目前,光伏发电功率预测方法主要分为物理方法和统计方法。物理方法是基于太阳辐照传递方程、光伏组件运行方程等物理方程进行预测。该方法依赖于详细的光伏电站地理信息、气象和太阳辐照数据,建模过程繁琐[3];统计方法是基于预测模型输入、输出因素之间的统计规律进行预测,其对光伏电站的地理信息和测光资料要求不高,简化了预测过程。文献[4-5]分别采用马尔可夫链、自回归滑动平均 ARMA(Auto Regressive Moving Average)等统计方法对光伏发电功率进行直接预测,但其在发电功率波动性较大的雨天、多云等天气的预测精度不高。文献[6]采用灰色神经网络组合模型进行光伏发电功率预测,该模型仅将历史日按天气类型做简单分类,其对不同类型天气的适用性不强。文献[7]依据季节和天气类型选取相似日,在此基础上用人工神经网络 ANN(Artificial Neural Network)对光伏发电功率进行预测。但 ANN 在处理大量历史数据及预测精度上面临着巨大的挑战。文献[8]采用第三代神经网络——Spiking 神经网络 SNN (Spiking Neural Network)进行负荷预测。文献表明,SNN 在处理历史数据的能力和预测精度上较 ANN 均有所提高。SNN 特有的多突触结构以及时间编码方式,使其能更逼真地反映实际生物的神经系统,因而比现有类型的神经网络具有更强的计算能力[9-10]。同时,SNN 在模式识别和分类中具有优越的性能,特别适用于解决高维聚类和非线性回归等问题[11-12]。

基于以上分析,为了提高光伏发电功率预测的精度以及对不同类型天气的适应能力,本文提出了一种基于相似日和 SNN 的光伏发电功率预测模型。首先根据预测日的季节、天气类型以及气象因素的预报值,采用灰色关联分析法结合余弦相似度指标选取相似日。其次,在建模过程中,采用云自适应粒子群优化 CAPSO(Cloud Adaptive Particle Swarm Optimization)算法对 SNN 权值进行优化,以提高 SNN 的数据挖掘和预测能力。最后,运用实际光伏电站量测数据对该模型进行测试,验证该模型的有效性。

1 相似日选取

1.1 气象特征向量的确定

光伏发电功率受多种因素的影响,光伏阵列的输出功率[13]计算如下:

$$p_s=\eta SI[1-0.005(t_0+25)] \tag{1}$$

其中,η 为光伏电池转换效率(%);S 为光伏阵列面积(m^2);I 为太阳辐照强度(kW/m^2);t_0 为工作环境温度(℃)。

既定的光伏发电系统在短期内的阵列面积 S 和转换效率 η 是不变的,因此发电功率主要受到太阳辐照强度和环境温度 2 个因素的影响。其中,太阳辐照强度一方面体现在季节和天气类型等因素对阵列输出功率的影响,另一方面体现在云量对阵列输出功率的影响。考虑到国内对云量的预测实现较困难,本文选取与云量关系较为密切的风速作为影响因素。综上,本文在构建气象特征向量时主要考虑季节类型、天气类型、逐时温度和风速等主要影响因素。

收稿日期:2015-11-16;**修回日期**:2016-11-14
基金项目:国家自然科学基金资助项目(51277052,51507052)
Project supported by the National Natural Science Foundation of China(51277052,51507052)

根据预测日的季节和天气类型预报信息从历史数据中挑选出相同季节类型下晴天、多云天、阴天和雨天的发电日组成初步样本。考虑到光伏发电出力的集中时间,选取每天 08:00—17:00 时间段内的 10 个整点时刻作为每日预测时刻。设第 i 日的气象特征向量 $\boldsymbol{C}_i$ 包括 08:00—17:00 逐时温度数据 T_{ij} 和风速数据 S_{ij} 共 20 个元素,即:

$$\boldsymbol{C}_i=[T_{ij}\quad S_{ij}]\quad j=1,2,\cdots,10 \tag{2}$$

其中,T_{ij} 单位为℃;S_{ij} 单位为 m/s。为降低不同量纲对后续分析的影响,需对气象特征向量数据进行归一化。

1.2　相似日选取原理

为准确选取与预测日最相似的历史发电日,采用灰色关联分析法结合余弦相似度指标组成相似性综合指标 S_i。灰色关联分析法中,总关联度 R_i 反映第 i 个历史日的气象特征向量 $\boldsymbol{C}_i$ 和预测日的气象特征向量 $\boldsymbol{C}_0$ 间的总体相关性(见式(3)),其值越接近 1 代表越相关。余弦相似度 $D_{\cos i}$ 反映第 i 个历史日的气象特征向量 $\boldsymbol{C}_i$ 和预测日的气象特征向量 $\boldsymbol{C}_0$ 的变化趋势间的相似性(见式(5)),其值越接近 1 代表越相似。

$$R_i=\frac{1}{l}\sum_{k=1}^{l}\varepsilon_i(k) \tag{3}$$

其中,l 为气象特征向量的分量个数,本文中 $l=20$;$\varepsilon_i(k)$为预测日和第 i 个历史日第 k 个气象特征分量的关联系数,计算公式如(4)所示。

$$\varepsilon_i(k)=\frac{\min\limits_i\min\limits_k|x'(k)-x_i'(k)|+\rho\max\limits_i\min\limits_k|x'(k)-x_i'(k)|}{|x'(k)-x_i'(k)|+\rho\max\limits_i\max\limits_k|x'(k)-x_i'(k)|} \tag{4}$$

其中,$x'(k)$、$x_i'(k)$分别为归一化后的预测日和第 i 个历史日第 k 个气象特征分量;ρ 为常数,本文中 $\rho=0.5$。

$$D_{\cos i}=\frac{\sum\limits_{k=1}^{l}C_{ik}C_{0k}}{\sqrt{\sum\limits_{k=1}^{l}C_{ik}^2\sum\limits_{k=1}^{l}C_{0k}^2}} \tag{5}$$

其中,C_{0k}、C_{ik} 分别为预测日和第 i 个历史日气象特征向量的第 k 个分量。

将总关联度 R_i 和余弦相似度 $D_{\cos i}$ 这 2 个指标组合成一个相似性综合指标 S_i,表征总体相似性,其计算公式如(6)所示。将 $S_i\geqslant 0.8$ 的历史发电日按日期顺序排列,选取靠近预测日的 b 天,本文设定 $b=5$。

$$S_i=\alpha R_i+(1-\alpha)D_{\cos i} \tag{6}$$

其中,α 为经验权重系数,其取值应结合具体天气情况,若温度、风速在一天内变化明显,α 取值靠近 0,否则靠近 1。

2　基于 CAPSO 算法的 SNN

本文在选取相似日的基础上,建立了基于 SNN 的光伏发电功率预测模型。但 SNN 采用的 SpikeProp (Spike Propagation)训练算法是利用梯度信息进行连接权值的调整[14],易于陷入局部最优解。因此,本文提出采用 CAPSO 算法[15]优化 SNN 的连接权值,建立一种 CAPSO-SNN 模型以提高网络的寻优能力。

2.1　SNN

SNN 是由多个带延迟突触终端的 Spiking 神经元组成的前向反馈网络。本文采用基于脉冲响应模型[9] SRM(Spike Response Model)的 3 层前向 Spiking 神经网络,其连续层中任意神经元 h 和 i 间的连接结构如图 1 所示。

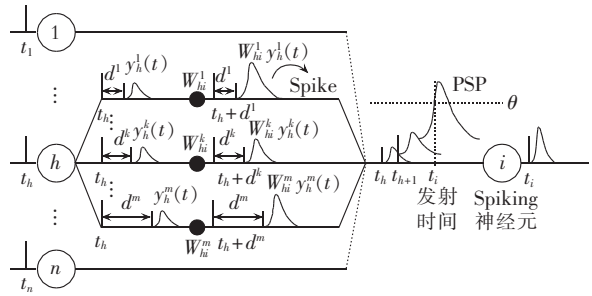

图 1　神经元 h 和 i 间多个有延迟突触终端的连接

Fig.1 Connectivity between neuron h and i with multiple delayed synaptic terminals

由图 1 可看出,在结构上,SNN 连续层中任意 2 个神经元 h 和 i 间有 m 个突触子连接,且各突触子连接具有可调节的突触延时 d^k 和连接权值 W_{hi}^k;在编码方式上,SNN 采用将神经元的发射时间直接作为输入输出信号的时间编码方式。当神经元 i 接收到突触前神经元的信号,使其膜电位值超过神经元激发阈值 θ 时,该神经元就发射一个脉冲(Spike),并发送一个输出信号,称为突触后电位 PSP(Post Synaptic Potential)。一个输入脉冲产生的 PSP 的性能由脉冲响应函数SRF (Spike Response Function)表示,其数学表达式为:

$$\varepsilon(t)=\begin{cases}\dfrac{t}{\tau}\mathrm{e}^{1-\frac{t}{\tau}} & t>0\\ 0 & t\leqslant 0\end{cases} \tag{7}$$

其中,τ 为 PSP 衰减时间常数(ms)。

神经元 h 接收到一系列脉冲,其脉冲发射时间为t_h,则神经元 i 的实际脉冲发射时间 t_i^{a} 为:

$$Y_h^k(t)=\varepsilon(t-t_h-d^k) \tag{8}$$

$$X_i(t)=\sum_h\sum_{k=1}^{m}W_{hi}^kY_h^k(t) \tag{9}$$

$$t_i^{\mathrm{a}}:X_i(t_i^{\mathrm{a}})=\theta,\ \left.\frac{\mathrm{d}X_i(t)}{\mathrm{d}t}\right|_{t=t_i^{\mathrm{a}}}>0 \tag{10}$$

其中,$Y_h^k(t)$为一个突触子连接未加权重的激励;$X_i(t)$为神经元 i 的膜电位值(mV)。

2.2　CAPSO 算法

传统粒子群优化 PSO(Particle Swarm Optimization)算法源于对鸟群觅食行为的模拟研究,已经被广泛应用于解决非线性优化问题[16]。但是 PSO 算法中的惯性权重 w 和加速因子 c_1、c_2 都是常数,因此在寻优过

程中所有粒子的移动方向同一化于最优粒子,使群体逐渐失去多样性,导致其在处理高维问题时易早熟,陷入局部最优。CAPSO 算法将云模型的稳定性和随机倾向性[17-18]特点引入传统 PSO 算法的收敛机制,具有收敛速度快、寻优精度高等优点。

2.2.1 惯性权重的云自适应调整

CAPSO 算法采用云算子对惯性权重 w 进行自适应调整,其随机性可避免搜索陷入局部极值,而稳定倾向性又可很好地确定全局最优值,调整方法如下。

a. 设粒子的总数为 N,第 k 次迭代中粒子 i 的适应度值为 f_i^k。计算 N 个粒子的适应度均值 $\bar{f}_0^k$,以及适应度优于和非优于 $\bar{f}_0^k$ 的粒子的适应度均值 $\bar{f}_1^k$ 和 $\bar{f}_2^k$:

$$\bar{f}_0^k=\frac{1}{N}\sum_{i=1}^{N}f_i^k \tag{11}$$

$$\bar{f}_1^k=\mathrm{mean}(f_i^k<\bar{f}_0^k),\ \bar{f}_2^k=\mathrm{mean}(f_i^k>\bar{f}_0^k) \tag{12}$$

b. 确定云滴 f_i^k 的参数并计算其确定度 $u(f_i^k)$:

$$E_x=\bar{f}_0^k,\ E_n=(\bar{f}_0^k-f_{\min}^k)/k_1,\ H_e=E_n/k_2 \tag{13}$$

$$u(f_i^k)=\mathrm{e}^{-\frac{(f_i^k-E_x)^2}{2E_n'^2}} \tag{14}$$

其中,k_1、k_2 为调整系数;$E'_n=\mathrm{normrnd}(E_n,H_e,1,1)$,normrnd(·)表示生成正态随机数。

c. 计算第 k 次迭代的惯性权重 w^k:

$$w^k=\begin{cases} w_{\min} & f_i^k\leqslant\bar{f}_1^k \\ w_{\max}-0.5u(f_i^k) & \bar{f}_1^k<f_i^k<\bar{f}_2^k \\ w_{\max} & f_i^k\geqslant\bar{f}_2^k \end{cases} \tag{15}$$

其中,$w_{\min}$、$w_{\max}$ 分别为 w 的最小值和最大值。

2.2.2 加速因子的动态调整

加速因子包括认知因子 c_1 和社会因子 c_2,其决定了粒子间信息的交换。在搜索初期粒子飞行主要参考本身的历史信息 c_1,在搜索后期,更加注重群体信息 c_2。本文按照图 2 所示的收敛曲线 L 对 c_1、c_2 进行动态调整[15]:c_1 由大变小,c_2 由小变大。调整公式为:

$$R=2\sqrt{2}\arccos(\pi/4-\gamma_{\min}) \tag{16}$$

$$c_1=R\cos[\gamma_{\min}+(\pi/2-2\gamma_{\min})k/K] \tag{17}$$

$$c_2=R\sin[\gamma_{\min}+(\pi/2-2\gamma_{\min})k/K] \tag{18}$$

其中,R 为收敛曲线半径;$\gamma_{\min}$ 为收敛曲线初始角;k 为当前迭代数;K 为迭代总次数。

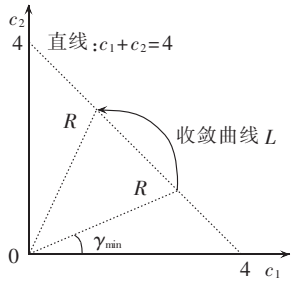

图 2 c_1、c_2 收敛曲线示意图

Fig.2 Schematic diagram of c_1-c_2 convergence curve

2.3 CAPSO-SNN 的训练算法

采用 CAPSO 算法优化 SNN 的实质是一个高维、多变量的非线性优化问题。CAPSO-SNN 训练算法能较好地改善传统 SNN 和 PSO 算法的缺陷,提高寻优精度,减少了对网络连接权值的约束。

将 SNN 中需调整的各层中的连接权值映射为 CAPSO 算法中的粒子,通过粒子相互间的信息交流,使适应度值最小化,即可找到最好的连接权值使得 SNN 能产生正确的输出。训练算法流程见图 3,其中适应度函数选取为网络训练误差函数 E,见式(19)。

$$E=\frac{1}{2}\sum_{j\in J}(t_j^{\mathrm{a}}-t_j^{\mathrm{d}})^2 \tag{19}$$

其中,t_j^{a} 和 t_j^{d} 分别为输出层 J 中任一神经元 j 的实际和期望脉冲发射时间。

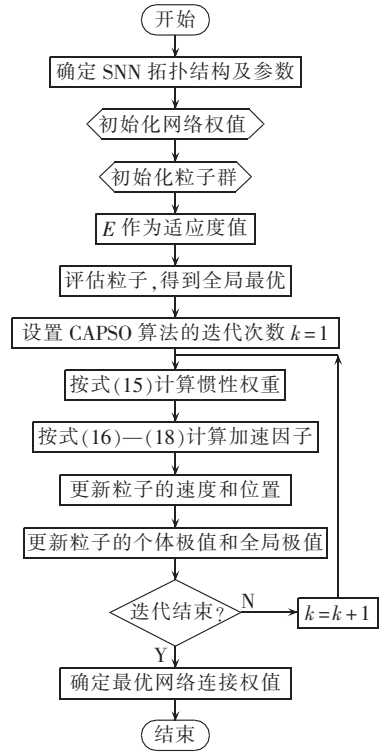

图 3 CAPSO-SNN 训练算法流程

Fig.3 Flowchart of training algorithm based on CAPSO-SNN

3 基于 CAPSO-SNN 的光伏发电功率预测模型

3.1 预测模型设计

3.1.1 输入和输出变量的选取

利用所提 CAPSO-SNN 模型对待预测日 08:00—17:00 时间段内 10 个整点时刻的发电功率值进行预测,输出变量为逐时的发电功率值。考虑到光伏的特性,将相似日中同时刻的发电功率值、温度和风速值以及待预测时刻的温度和风速值作为输入变量。预测模型输入、输出变量详见表 1。

3.1.2 网络拓扑结构的确定

SNN 输入、输出层神经元的个数 n 和 q 分别对

表 1 预测模型输入、输出变量

Table 1 Inputs and outputs of forecasting model

输入/输出变量	变量名称
x_1—x_5	预测日的相似日中与待预测时刻同时刻的发电功率
x_6—x_{10}	预测日的相似日中与待预测时刻同时刻的温度 T_i
x_{11}—x_{15}	预测日的相似日中与待预测时刻同时刻的风速 S_i
x_{16}	预测日中待预测时刻的温度 T_0
x_{17}	预测日中待预测时刻的风速 S_0
y	预测日中待预测时刻的发电功率

注:x 表示输入变量,y 表示输出变量。

应于模型输入、输出变量的个数,即 $n=17$,$q=1$。隐含层神经元个数 p 的确定是网络结构的重要内容之一,本文根据经验公式(20),经过多次试验以确定 SNN 隐含层神经元数为 $p=10$。综上,本文选取的 3 层前向 SNN 的结构为 17-10-1。

$$p=\sqrt{n+q}+a \tag{20}$$

其中,n、p 和 q 为各层神经元个数;a 为 1~10 之间的整数。

3.2 参数设置

SNN 中突触子连接数值 m 减小时,网络计算能力减弱;m 值增大会提高计算能力,但同时也会增加 CAPSO 算法的变量维数,使学习速度变慢。本文结合实际情况,通过反复测试之后确定 m 值为 3,相应的突触延时 d^k 选取从 1~3 递增的整数值。PSP 衰减时间常数 τ 取为 6 ms;所有的神经元的激发阈值 θ 均取为 1 mV;计算步长为 0.1 ms;误差限值 $\varepsilon=10^{-4}$。

CAPSO 算法和 PSO 算法中进化迭代数 $K=200$,种群规模 $N=30$。CAPSO 算法中,控制系数 $k_1=0.5$,$k_2=10$;惯性权重 $w\in[0.3,0.7]$;收敛曲线初始角 $\gamma_{\min}=\pi/6$。PSO 算法的惯性权重 w 在[0.3,0.7]间线性递减,学习因子 c_1、c_2 均取为 2.0。

4 算例分析

为了验证上述 CAPSO-SNN 光伏发电功率预测模型的有效性,本文选取江苏省某光伏电站 2010 年 1 月 1 日至 2011 年 11 月 30 日的实测发电功率数据和其对应的气象数据作为样本。利用 BP、SNN、PSO-SNN 和 CAPSO-SNN 这 4 种预测模型对光伏电站 2011 年 11 月 1 日至 30 日的每日 08:00—17:00 间 10 个整点时刻的发电功率进行预测,并对 4 种模型的预测结果进行比较验证分析。其中,上述 4 种模型的相似日选取均采用本文提出的方法,对应的输入、输出变量亦相同,如表 1 所示。预测模型的学习算法程序采用 MATLAB(R2014a)实现。

上述连续 30 个预测日中包含晴天 6 d、阴天 2 d、雨天 7 d 和多云天 15 d。在 4 种广义天气类型下各选取 1 d 进行定性分析,4 种预测模型的预测与实测结果分别如图 4—7 所示。图 4 是 11 月 15 日(晴天)

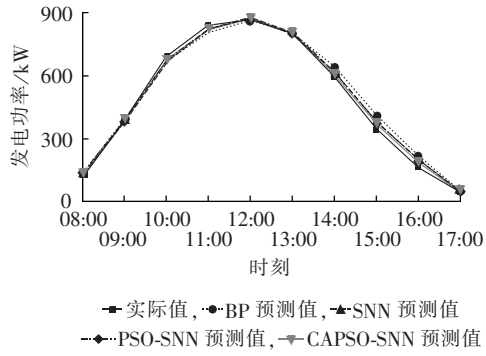

图 4 晴天预测结果

Fig.4 Forecasting results of sunny days

的光伏发电功率预测曲线与实际曲线。光伏发电功率曲线变化较有规律性,4 种预测模型的预测曲线与实际曲线较接近,预测效果较理想。

图 5 是 11 月 18 日(阴天)的光伏发电功率预测曲线与实际曲线。实际测试时,阴天训练样本数较少,而且其天气情况复杂多变等因素对预测结果产生影响,4 种预测模型与实际发电功率曲线在发生突变的时间段如 10:00—13:00 的偏差较大。对于预测误差较大的时段 11:00—13:00,CAPSO-SNN 模型的预测曲线更接近实际曲线,可明显降低预测误差。

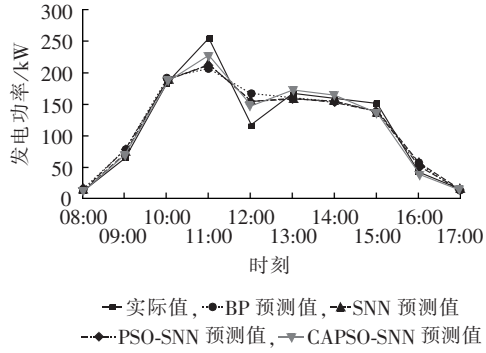

图 5 阴天预测结果

Fig.5 Forecasting results of overcast days

图 6 是 11 月 5 日(雨天)的光伏发电功率预测曲线与实际曲线。雨天光伏电站的发电具有更多的不确定性和随机性,在实际曲线波动较大的 10:00—13:00 时间段,CAPSO-SNN 模型的预测曲线更接近实际曲

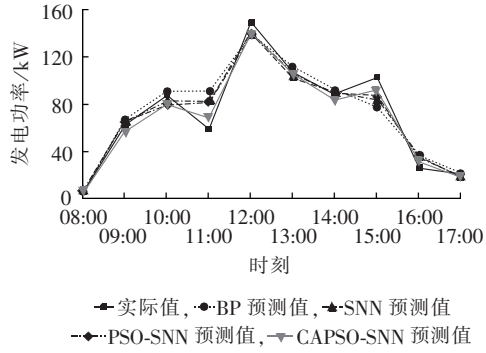

图 6 雨天预测结果

Fig.6 Forecasting results of rainy days

线,说明CAPSO-SNN模型有更好的学习和映射能力。

图7是11月13日(多云天)的光伏发电功率预测曲线与实际曲线。相对于晴天,多云天气的云团厚薄和移动趋势难以预测,所以4种模型的预测曲线在某些时段较实际曲线偏差较大。然而,CAPSO-SNN模型的预测曲线更能反映实际功率的整体变化趋势。

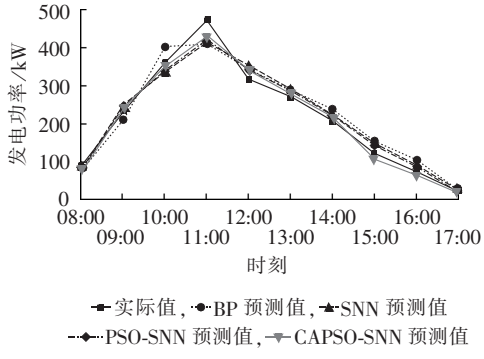

图7 多云天预测结果

Fig.7 Forecasting results of cloudy days

本文采用平均绝对百分比误差MAPE(Mean Absolute Percent Error)和希尔不等系数TIC(Theil Inequality Coefficient)[19]2种评价指标对各种天气类型下4种预测模型的预测误差情况进行定量分析。其中MAPE采用百分数(%)表示,TIC的计算公式为:

$$\mathrm{TIC}=\frac{\sqrt{\sum_{i=1}^{M}(X_{ri}-X_{fi})^2/M}}{\sqrt{\sum_{i=1}^{M}X_{fi}^2/M}+\sqrt{\sum_{i=1}^{M}X_{ri}^2/M}} \tag{21}$$

其中,X_{ri}为预测日实际发电功率;X_{fi}为预测发电功率;M为数据总数。

上述图示各天对应的预测误差统计如表2所示,由于光伏发电功率预测的日误差离散度很大,表3给出了11月份30 d各种天气类型的预测误差统计。

由表2、3可看出:无论是单日还是多日的误差统计数据,在晴天时,4种预测模型预测误差的MAPE和TIC均较小,预测结果均较准确。在阴天、雨天和多云天等发电功率波动较大的天气类型时,4种模型预测误差的MAPE和TIC相对于晴天较大,但CAPSO-SNN模型的整体预测结果相比其余3种模型在2种评价指标上表现出更优越的性能,说明其预测精度更高,更加适用于随机性和波动性较大的天气类型。

表2 4种预测模型单日的预测误差统计

Table 2 Statistics of single-day forecasting errors for four forecasting models

图号	天气类型	误差类型	BP	SNN	PSO-SNN	CAPSO-SNN
4	晴天	MAPE/%	9.406	5.955	5.341	3.618
		TIC	0.028	0.017	0.015	0.012
5	阴天	MAPE/%	17.683	13.498	12.227	9.530
		TIC	0.086	0.072	0.068	0.051
6	雨天	MAPE/%	17.175	14.328	12.532	8.636
		TIC	0.085	0.066	0.060	0.039
7	多云天	MAPE/%	17.877	14.363	12.164	8.515
		TIC	0.062	0.052	0.043	0.032

表3 4种预测模型多日的预测误差统计

Table 3 Statistics of multi-day forecasting errors for four forecasting models

天气类型	天数	误差类型	BP	SNN	PSO-SNN	CAPSO-SNN
晴天	6	MAPE/%	9.176	5.025	4.965	3.135
		TIC	0.027	0.016	0.014	0.012
阴天	2	MAPE/%	18.412	14.498	13.354	10.248
		TIC	0.091	0.079	0.075	0.059
雨天	7	MAPE/%	22.537	16.691	15.186	10.753
		TIC	0.117	0.086	0.076	0.052
多云天	15	MAPE/%	20.013	15.142	14.224	9.986
		TIC	0.092	0.062	0.056	0.041

5 结论

本文针对光伏发电功率的随机性和间接性等特点,提出一种基于相似日和CAPSO-SNN的光伏发电功率预测模型。算例结果表明:基于相似日和CAPSO-SNN的光伏发电功率预测模型相比于传统预测模型具有更高的预测精度,其对于不同的天气类型有更好的适用性,对于光伏发电系统配合电力系统制定发电计划有一定的应用价值。

参考文献:

[1] 陈炜,艾欣,吴涛,等. 光伏并网发电系统对电网的影响研究综述[J]. 电力自动化设备,2013,33(2):26-32.
CHEN Wei,AI Xin,WU Tao,et al. Influence of grid-connected photovoltaic system on power network[J]. Electric Power Automation Equipment,2013,33(2):26-32.

[2] 李斌,袁越. 光伏并网发电对保护及重合闸的影响与对策[J]. 电力自动化设备,2013,33(4):12-17.
LI Bin,YUAN Yue. Impact of grid-connected photovoltaic power generation on protection and reclose,and its countermeasures[J]. Electric Power Automation Equipment,2013,33(4):12-17.

[3] ALMONACID F,PÉREZ-HIGUERAS P J,FERNÁNDEZ E F,et al. A methodology based on dynamic artificial neural network for short-term forecasting of the power output of a PV generator[J]. Energy Conversion and Management,2014(85):389-398.

[4] 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.

[5] 郭旭阳,谢开贵,胡博,等. 计入光伏发电的电力系统分时段随机生产模拟[J]. 电网技术,2013,37(6):1499-1505.
GUO Xuyang,XIE Kaigui,HU Bo,et al. A time-interval based probabilistic production simulation of power system with grid-connected photovoitaic generation[J]. Power System Technology,2013,37(6):1499-1505.

[6] 王守相,张娜. 基于灰色神经网络组合模型的光伏短期出力预测[J]. 电力系统自动化,2012,36(19):37-41.
WANG Shouxiang,ZHANG Na. Short-term output power forecast

of pho tovoltaic based on a grey and neural network hybrid model[J]. Automation of Electric Power Systems,2012,36(19):37-41.

[7] 王晓兰,葛鹏江. 基于相似日和径向基函数神经网络的光伏阵列输出功率预测[J]. 电力自动化设备,2013,33(1):100-103.
WANG Xiaolan,GE Pengjiang. PV array output power forecasting based on similar day and RBFNN[J]. Electric Power Automation Equipment,2013,33(1):100-103.

[8] KULKARNI S,SIMON S P,SUNDARESWARAN K. A Spiking Neural Network(SNN) forecast engine for short-term electrical load forecasting[J]. Applied Soft Computing,2013,13(8):3628-3635.

[9] MAASS W. Networks of spiking neurons:the third generation of neural network models[J]. Neural Networks,1997,10(9):1659-1671.

[10] GERSTNER W,KISTLER W M. Spiking neuron models:single neuron,populations,plasticity[M]. Cambridge,UK:Cambridge University Press,2002:1-29.

[11] NATSCHLÄER T,RUF B. Spatial and temporal pattern analysis via spiking neurons[J]. Network,1998,9(3):319-332.

[12] BOHTE S M,POUTRE H L,KOK J N. Unsupervised clustering with spiking neurons by sparse temporal coding and multi-layer spike neural network [J]. IEEE Transactions on Neural Networks,2002,13(2):426-435.

[13] 杨锡运,刘欢,张彬,等. 组合权重相似日选取方法及光伏输出功率预测[J]. 电力自动化设备,2014,34(9):118-122.
YANG Xiyun,LIU Huan,ZHANG Bin,et al. Similar day selection based on combined weight and photovoltaic power output forecasting[J]. Electric Power Automation Equipment,2014,34(9):118-122.

[14] BOHTE S M,POUTRE J A L,KOK J N. Error-backpropagation in temporally encoded networks of spiking neurons[J]. Neurocomputing,2002,48(1):17-37.

[15] 吴杰康, 熊焰. 风水气互补发电优化的云模型自适应粒子群优化算法[J]. 中国电机工程学报,2014,34(增刊 1):17-24.
WU Jiekang,XIONG Yan. Based adaptive particle swarm optimization algorithm for complementary power generation optimization of wind-energy,hydro-energy and natural gas[J]. Proceedings of the CSEE,2014,34(Supplement 1):17-24.

[16] 徐茹枝,王宇飞. 粒子群优化的支持向量回归机计算配电网理论线损方法[J]. 电力自动化设备,2012,32(5):86-89,93.
XU Ruzhi,WANG Yufei. Theoretical line loss calculation based on SVR and PSO for distribution system[J]. Electric Power Automation Equipment,2012,32(5):86-89,93.

[17] 李德毅,刘常昱,杜鹢,等. 不确定性人工智能[J]. 软件学报,2004,15(11):1583-1594.
LI Deyi,LIU Changyu,DU Yi,et al. Artificial intelligence with uncertainty[J]. Journal of Software,2004,15(11):1583-1594.

[18] 李德毅,孟海军,史雪梅. 隶属云和隶属云发生器[J]. 计算机研究与发展,1995,32(6):15-20.
LI Deyi,MENG Haijun,SHI Xuemei. Membership clouds and membership cloud generators[J]. Journal of Computer Research and Development,1995,32(6):15-20.

[19] 易丹辉. 数据分析与 Eviews 应用[M]. 北京:中国人民大学出版社,2008:47.

作者简介:

陈　通

陈　通(1988—),男,江苏徐州人,硕士研究生,研究方向为可再生能源发电预测技术(**E-mail**:hhuchentong@163.com);

孙国强(1978—),男,江苏江阴人,副教授,博士,研究方向为电力系统运行分析与控制、可再生能源发电系统(**E-mail**:hhusunguoqiang@163.com);

卫志农(1962—),男,江苏江阴人,教授,博士研究生导师,博士,研究方向为电力系统运行分析与控制、输配电自动化(**E-mail**:wzn_nj@263.com)。

Photovoltaic power generation forecasting based on similar day and CAPSO-SNN

CHEN Tong[1],SUN Guoqiang[1],WEI Zhinong[1],ZANG Haixiang[1],
SUN Yonghui[1],Kwok W Cheung[2],LI Huijie[3]

(1. College of Energy and Electrical Engineering,Hohai University,Nanjing 211100,China;2. ALSTOM Grid Inc.,Redmond,Washington 98052,USA;3. ALSTOM GRID Technology Center Co.,Ltd.,Shanghai 201114,China)

Abstract: Since the forecasting accuracy of PV(PhotoVoltaic) power generation is not high,a forecasting model based on the similar day and SNN(Spiking Neural Network) optimized by CAPSO(Cloud Adaptive Particle Swarm Optimization) algorithm is proposed. The comprehensive similarity index considering the main influencing factors,e.g. season,weather,meteorology,etc.,is adopted for selecting the similar day. Based on the powerful computation ability and efficiency in dealing with the time series problem of SNN,its multiple synaptic connection weights are optimized by the randomness and stability of CAPSO algorithm to loosen the constraint of weight and improve the convergence accuracy of algorithm. The proposed model is tested and evaluated based on the measured power data of a PV station and results show that,it has higher forecasting accuracy and better applicability than traditional forecasting models.

Key words: photovoltaic generation; power forecasting; Spiking neural network; cloud adaptive particle swarm optimization algorithm; similar day selection