

结合 HS 算法与 ESN 算法的光伏发电短期出力预测

温 润 谭 丽

(兰州交通大学自动化与电气工程学院 兰州 730070)

摘 要 为提高光伏发电系统短期出力预测的精度,提出了一种和声搜索(Harmony Search, HS)算法与回声状态网络(Echo State Network, ESN)算法相结合的预测模型。该模型以光伏电站的历史发电量数据和气象数据为基础。首先通过相似日选择算法挑选出预测日的相似日,将相似日的气象特征向量和预测日的气象特征向量的差值作为预测模型的输入变量;然后选择训练样本,并用和声搜索算法优化后的回声状态网络模型(HS-ESN)对样本进行训练和预测;最后以甘肃某光伏电站为例进行实例验证。实证分析表明,利用和声搜索算法优化回声状态网络预测模型的储备池参数可有效提高回声状态网络的预测精度,因此该模型具有较好的实用价值。

关键词 光伏发电系统,短期出力预测,和声搜索算法,回声状态网络算法,相似日选择算法,HS-ESN 预测模型

中图分类号 TM615 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2017.06.038

Short-term Power Forecasting for Photovoltaic Generation Based on HS-ESN

WEN Run TAN Li

(College of Automation and Electrical Engineering, Lanzhou Jiaotong University, Lanzhou 730070, China)

Abstract To improve the accuracy of short-term power prediction for photovoltaic generation, the forecasting model of combination of harmony search(HS) algorithm and echo state network (ESN) algorithm was proposed. The model is based on historical power and weather data provided by a photovoltaic plant. Firstly, it selects the similar day of the forecasting day by the algorithm of similar day, and treats the difference of meteorological feature between the similar day and the forecasting day as the input variable of the model. Secondly, it chooses the training sample to train and forecast with the ESN model based on optimization of HS algorithm. Finally, it takes the photovoltaic plant in Gansu province as an example to test HS-ESN prediction model. Case analysis shows that the parameters of the reservoir of ESN prediction model optimized by HS algorithm can improve the prediction accuracy effectively, so it has better utility value.

Keywords PV system, Short-term power forecasting, HS algorithm, ESN algorithm, Algorithm of similar day, HS-ESN prediction model

1 引言

光伏发电因其取之不尽、灵活、无污染和成本低的特点逐渐受到了广泛的重视^[1]。但是由于光伏出力具有波动性和间歇性,因此对电网的有功平衡和无功特性造成较大影响。所以加强光伏出力的准确预测,预先获得光伏发电系统(以下简称 PV 系统)的日出力曲线,可协助电力系统调度部门及时调整发电计划,减少光伏发电的随机性和波动性对电网造成的不利影响^[2]。

目前,国内外学者提出了许多光伏发电系统短期出力预测的方法,基本可以分为两类:第一类为直接预测方法,包括概率预测法、时间序列法以及人工智能等方法;第二类是间接预测方法,这类方法又可细分为简单物理模型法和复杂物理

模型法两种方法^[3-4]。

文献[5]首先通过历史天气信息对预测日的太阳辐照强度进行估计,然后由太阳辐照强度计算光伏阵列的输出功率,这是一种典型的间接预测方法,但是该方法没有考虑光伏阵列的使用时间与光电转换效率之间的关系;文献[6]虽然分析了影响光伏出力的主要因素,但预测时需按天气和季节将预测模型划分为若干个子模型,适用性不强;文献[7-8]将天气影响因素映射为日类型指数作为预测模型的输入,大大简化了预测方法,但是预测精度不高;文献[9]将 PV 系统的历史输出功率与天气预报信息相结合,然后利用 ESN(回声状态网络)预测模型直接预测光伏阵列的输出功率,该方法属于目前应用较为广泛的直接预测方法。相对于间接预测法,直接预测法有力地简化了预测过程,但是在样本的选取上,直接预

到稿日期:2016-04-29 返修日期:2016-07-03

温 润(1988-),男,硕士生,主要研究方向为新能源功率预测, E-mail: waynerun@163.com;谭 丽(1962-),女,副教授,主要研究方向为计算机联锁。

测法需要一段时间的历史输出功率的数据积累作为保证,具有局限性。文献[10]根据气温欧氏距离集选择训练样本,明显缩短了样本选取时间,但却忽略了其他因素对光伏出力的影响,降低了预测精度。

针对以上问题,本文提出了基于HS算法改进ESN算法的模型,并利用灰色关联系数法确定相似日和训练样本,然后对PV系统进行短期出力预测。通过实证表明,HS-ESN算法兼顾了HS算法和ESN算法建模时的优点,提高了ESN模型的预测精度,是一种有效的光伏短期出力预测方法。

2 预测模型的输入变量

影响光伏出力的因素主要有太阳辐照强度、光伏阵列的转换效率、太阳能电池板的安装角度、温度以及气压等因素^[11]。对于有固定安装角度的太阳能电池板,其单位面积的光伏阵列最大输出功率可由式(1)表示^[12]。

$$P_s = \eta SI(1 - 0.005(t_0 + 25)) \quad (1)$$

其中, η 为光伏阵列的转换效率; S 为阵列总面积; I 为光伏阵列斜面接收到的太阳辐照强度; t_0 为太阳能电池板的工作板温。

对于既定的光伏阵列,其发电量数据本身具有高度自相关性,光伏阵列的转换效率 η 和阵列总面积 S 均已隐含在历史发电数据中,可将其视为常量。所以在预测模型输入中不用考虑 η 和 S 对PV系统短期出力预测的影响,但应考虑太阳辐照强度 I 和电池板的工作板温 t_0 。另外,天气类型对光伏出力的影响也是非常显著的。图1是甘肃某光伏电站2014年10月至2014年11月几种常见天气类型下的日发电量图;图2是同月有气类型分别为晴天和雨天时PV系统的输出功率曲线。图1和图2相对应的气象信息如表1所列。由图1和图2可以看出,PV系统在相同的天气类型下,其发电量数据是相近的;而在不同的天气类型下,其对应的发电量数据相差很大,并且输出功率的曲线形状也存在着很大的差异。




图1 不同天气类型下的日发电量




图2 同月中晴天和雨天的输出功率曲线

表1 气象信息

日期	天气类型	最高气温/°C	最低气温/°C	平均气温/°C
2014-10-03	雨	16	4	10
2014-10-10	雨	10	-1	4
2014-10-13	晴	15	1	8
2014-10-14	晴	18	4	11
2014-11-03	晴	12	-3	4
2014-11-04	晴	20	-7	5
2014-11-12	阴	4	-5	0
2014-11-19	阴	7	-5	1
2014-11-22	多云	4	-5	0
2014-11-25	多云	5	-4	1
2014-11-26	雪	3	-4	0
2014-11-29	雪	2	-7	-2

由以上分析可知:PV系统的输出功率与天气类型、气温、太阳辐照强度密切相关,所以将天气类型、气温和太阳辐照强度作为预测模型的输入变量。

3 光伏电站发电功率相似日的选择

由于将天气类型量化后再将其作为预测模型的输入对于非晴天类型的预测误差较大,因此本文利用相似日选择算法选取与预测日天气类型相同、气象特征相近的训练样本对预测模型进行训练。相似日选择算法利用两个独立事件之间的关联程度确定它们之间的相似度^[13-14],若关联程度越大,则相似度越大。本文通过对多种相似日选择算法进行比较后,最终选择灰色关联系数法的相似日选择算法^[15-17],具体步骤如下。

1)选取与预测日天气类型一致的前6个月的 n 条历史记录,组成样本集 N 。

2)从样本集 N 中逆向逐日计算预测日和历史日的灰色关联度,具体内容如下。

首先,取出预测日和样本集 N 中的太阳辐照信息、温度信息作为影响光伏出力的主要构成因素。各构成因素(特征值)组成如下特征向量:

$$Y_i = [T_i, I_{hi}, \bar{I}_i, t_{hi}, \bar{t}_i, t_{li}] \quad (2)$$

其中, T_i 为第 i 日的太阳辐照时间长度; I_{hi}, \bar{I}_i 分别为第 i 日太阳辐照强度的最大值和平均值; $t_{hi}, \bar{t}_i, t_{li}$ 分别为第 i 日最高气温、平均气温和最低气温。

记预测日的气象特征向量为:

$$y_0 = [y_0(1), y_0(2), \dots, y_0(m)]^T \quad (3)$$

则第 i 个历史日的特征向量为:

$$y_i = [y_i(1), y_i(2), \dots, y_i(m)]^T \quad (4)$$

其中, m 为特征向量分量的个数。

其次,采用“极差法”将预测日和第 i 个历史日的各个分量进行归一化,则:

$$x_0(k) = [y_0(k) - m(k)] / [M(k) - m(k)] \quad (5)$$

$$x_i(k) = [y_i(k) - m(k)] / [M(k) - m(k)]$$

其中, $y_0(k), y_i(k)$ 为预测日和第 i 个历史日的第 k 个气象特征向量; $m(k), M(k)$ 为相应的第 k 个特征向量的最小值和最大值。 $x_0(k), x_i(k)$ 为预测日和第 i 个历史日归一化后的向量。

最后,利用灰色关联系数法计算预测日 x_0 与历史日 x_i 在第 k 个特征向量的关联系数,则:

$$\xi_i(k) = \frac{\min_k |x_0(k) - x_i(k)| + \rho \max_k |x_0(k) - x_i(k)|}{|x_0(k) - x_i(k)| + \rho \max_k |x_0(k) - x_i(k)|} \quad (6)$$

其中, ρ 为分辨系数, 一般取 0.5。

综合各个特征向量分量的关联系数, 则预测日与第 i 个历史日的总相似度为:

$$F_i = \prod_{k=1}^m \xi_i(k) \quad (7)$$

3) 将相似度 $F_i > 0.85$ 的相似日按升序排列, 取最大值作为预测日的相似日, 其他值作为训练样本。

4 预测模型设计

4.1 和声搜索算法

和声搜索算法是由 Geem Z W 等人提出的一种现代启发式全局搜索算法, 该算法模拟了和声调谐的原理。在音乐演奏中, 乐师往往需要反复调整乐队中各种乐器的音调, 寻找一个最佳的和声状态(目标函数)。因此用 HS 算法寻求和声的过程也就是针对一个具体问题寻求解向量的过程。相对其他算法而言, HS 算法具有实现简单、并行性高、求解速度快、鲁棒性强等优点^[18]。目前, HS 算法已在许多领域中取得了广泛的应用, 以它为基础衍生的新型算法也有很多种。相关研究表明, HS 算法在函数优化方面具有比模拟退火算法(Simulated Annealing, SA)、遗传算法(Genetic Algorithm, GA)等更好的优化效果^[19-22]。

该算法的实现步骤如下。

Step1 给定优化目标函数, 确定算法的参数, 其形式如式(8)所示:

$$\begin{cases} \min f(X) \\ \text{s. t. } x_i \in [L_i, U_i] \end{cases} \quad (8)$$

其中, $f(X)$ 为目标函数, X 是由决策变量 x_i 构成的实值向量 ($i=1, 2, \dots, N$)。

HS 算法的参数有和声记忆库 HM 的大小 HMS 、 HM 的取值概率 $HMCR$ 、音调微调概率 PAR 、音调微调步长 bw 以及创作次数 $Tmax$ 。

Step2 随机生成 HMS 个和声放入和声记忆库 HM 中, 其形式如下:

$$HM = \begin{bmatrix} X^1 & f(X^1) \\ X^2 & f(X^2) \\ \vdots & \vdots \\ X^m & f(X^m) \end{bmatrix} = \begin{bmatrix} x_1^1 & x_2^1 & \dots & x_N^1 & f(X^1) \\ x_1^2 & x_2^2 & \dots & x_N^2 & f(X^2) \\ \vdots & \vdots & \dots & \vdots & \vdots \\ x_1^m & x_2^m & \dots & x_N^m & f(X^m) \end{bmatrix} \quad (9)$$

Step3 创作一个新的和声。记新和声为 X_{new}^j , 则 $X_{new}^j = (x_1^j, x_2^j, \dots, x_i^j, \dots, x_N^j)$ 。然后让新和声中的每一个音调通过向和声记忆库学习、在学习的基础上对音调进行微调以及随机创作 3 种方式产生。其产生方如式(10)所示:

$$x_i^j = \begin{cases} x_i^{rand(j)}, & \text{if } r_1 < HMCR, j=1, 2, \dots, HMS \\ x_i', x_i' \in [L_i, U_i], & \text{other} \end{cases} \quad (10)$$

$i=1, 2, \dots, N$

其中, $x_i^{rand(j)}$ 表示在 HM 的第 i 列分量中随机选取一个

音调; $x_i' \in [L_i, U_i]$ 表示音调在变量范围内随机选取; r_1 表示在 $[0, 1]$ 上均匀分布的随机数。

式(10)表示任何一个新的音调, 有 $HMCR$ 的概率取自和声记忆库 HM 中, 有 $1-HMCR$ 的概率选自 HM 外。其次, 若新的音调 x_i 来自和声记忆库 HM , 则对其进行微调, 产生方式如下:

$$x_i^j = \begin{cases} x_i^j \pm r_2 \times bw, & \text{if } r_3 < PAR \\ x_i^j, & \text{other} \end{cases} \quad (11)$$

其中, $i=1, 2, \dots, N, r_2$ 和 r_3 均表示 $[0, 1]$ 上均匀分布的随机数, bw 是音调微调步长, PAR 是音调微调概率。

Step4 更新和声记忆库 HM , 并对产生的新和声进行评估:

$$\text{If } f(x_{new}^j) < f(x^{worst}), \text{ then } x_{new}^j = x^{worst} \quad (12)$$

Step5 判断是否达到算法终止条件。若迭代次数达到 $Tmax$, 则输出最优解, 算法结束; 否则重复 Step3-Step4。

4.2 回声状态网络

回声状态网络(Echo State Network, ESN)是由输入层、中间层(储备池)、输出层组成的稀疏网络。由于该网络模型的动态储备池(Dynamical Reservoir)具有大量的隐含层神经元, 故其具有短期记忆的功能。在许多预测任务中, ESN 预测模型比传统的神经网络预测模型要优良许多倍, 现已被广泛应用于复杂的非线性模型中^[23-27]。ESN 网络结构如图 3 所示^[28]。




图 3 ESN 网络结构

在 n 时刻, 输入单元、中间层、输出单元的序列为:

$$\begin{aligned} u(n) &= [u_1(n), u_2(n), \dots, u_k(n)]^T \\ x(n) &= [x_1(n), x_2(n), \dots, x_N(n)]^T \\ y(n) &= [y_1(n), y_2(n), \dots, y_L(n)]^T \end{aligned} \quad (13)$$

ESN 的状态方程为:

$$\begin{aligned} x(n+1) &= f(W_{in} \times u(n+1) + Wx(n) + W_{back}y(n)) \\ y(n+1) &= f^{out}(W_{out}(u(n+1), x(n), y(n))) \end{aligned} \quad (14)$$

其中, f 为中间层的激活函数, 通常取双曲正切函数; f^{out} 为输出层的激活函数, 通常取线性函数。 $W_{in}, W, W_{out}, W_{back}$ 分别表示 ESN 中输入层和中间层的连接权值、中间层内部之间的连接权值、中间层和输出层的连接权值, 以及输出层和中间层的反馈连接权值。

ESN 的 W_{out} 通过最小二乘法线性回归计算, 然后通过 W_{out} 计算出网络的实际输出 $\hat{y}(n)$, 再由 $\hat{y}(n)$ 逼近期望输出 $y(n)$, 即:

$$y(n) \approx \hat{y}(n) = \sum_{i=1}^L W_{out}^i x_i(n) \quad (15)$$

为使式(15)满足网络的均方误差最小, 对其进行如下计算:

$$\min \frac{1}{p-q+1} \sum_{n=q}^p (y(n) - \sum_{i=1}^q W_i^{out} x_i(n))^2 \quad (16)$$

然后将式(16)进行转化,即:

$$W_{out} = (X^{-1} \times L)^T \quad (17)$$

其中, X 是由 $x_1(n), x_2(n), \dots, x_k(n) (k=q, q+1, \dots, p)$ 组成的矩阵, L 是由 $y(n)$ 组成的矩阵。

4.3 HS-ESN 模型

ESN 的性能主要取决于储备池内部的连接权谱半径 SR 、储备池规模 N 、储备池输入单元尺度 IS 以及储备池的稀疏程度 SD , 这 4 个主要参数对 ESN 的预测精度的影响非常大^[29]。本文通过优化这 4 个参数来提高 ESN 的预测精度。HS-ESN 算法的基本原理如下:

首先, 将 ESN 的参数 SR, N, IS, SD 作为一个整体进行编码, 编码后的二进制串按式(18)转化为十进制表示的参数。

$$p = \min p + \frac{\max p - \min p}{2^b - 1} \times d \quad (18)$$

其中, p 为转化后的十进制数参数, $\min p$ 和 $\max p$ 为参数的最小值和最大值, b 表示编码后的二进制串长度, d 表示二进制串的十进制值, 编码位数为 10。

其次, 初始化 HS 算法参数。确定 HS 算法的适应度函数, 本文以均方误差作为适应度函数, 如式(19)所示。

$$fitness = \frac{1}{N} \sum_{p=1}^N (T_p - Y_p)^2 \quad (19)$$

其中, Y_p 为第 p 个样本的实际输出, T_p 为第 p 个样本的期望输出, N 为样本数量。

最后, 按上述的 HS 算法中的寻优方法对 ESN 的参数进行寻优, 再将满足条件的最优和声所对应的向量进行译码, 即可得到优化后的参数 SR, N, IS 和 SD 。具体流程如图 4 所示。

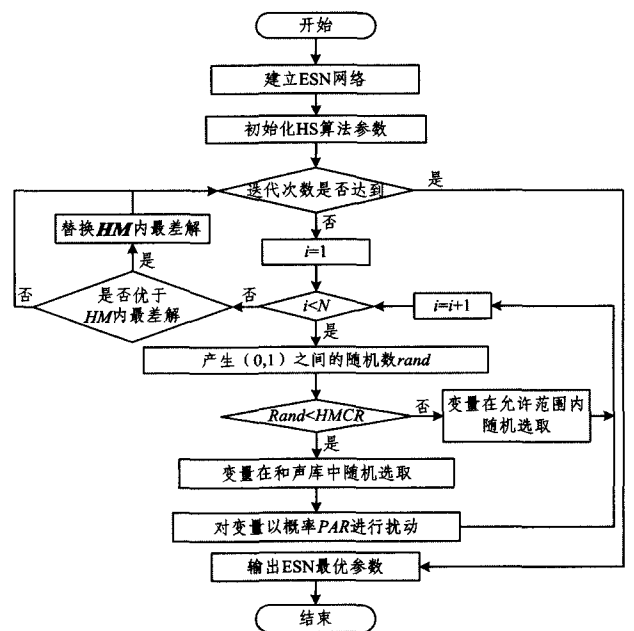


图 4 HS 算法优化 ESN 网络的建模流程图

4.4 本文提出的预测模型

结合提出的相似日选择算法, 本文进一步提出了基于 HS 算法优化 ESN 算法的光伏发电短期出力预测模型。该模

型的预测步骤如下:

1) 在训练样本中, 通过灰色关联系数法逆向逐次寻找历史日的相似日。

2) 以历史日和相似日的气象数据 $T_i, I_{hi}, \bar{I}_i, t_{hi}, \bar{t}_i, t_{li}$ 的差值作为预测模型的输入变量, 将历史日的光伏输出功率作为 HS-ESN 预测模型的输出量, 然后对 HS-ESN 预测模型进行训练。

3) 选择预测日的相似日, 并将预测日和相似日的相关数据输入训练好的 HS-ESN 预测模型, 得出预测日的光伏出力。

根据经验^[20-29]对 HS-ESN 预测模型进行如下初始化设置: SR 取 $[0.1, 0.9]$, N 取 $[20, 150]$, IS 取 $[0.01, 0.5]$, SD 取 $[0.01, 0.05]$, 和声记忆库的大小 $HMS=40$, 和声记忆库的取值概率 $HMCR=0.4$, 音调微调概率 $PAR=0.1$, 音调微调步长 $bw=0.08$ 。

5 实例应用与分析

5.1 预测模型的训练与评估

本文以甘肃某光伏电站(东经 98° , 北纬 39° 左右, 海拔 1800m)作为研究对象, 该光伏电站一期容量为 10MW。根据该电站 2014 年光伏监控系统数据库的历史数据显示, 一天中 20:00 至次日 07:00 的光伏出力为 0, 故研究时段为 08:00—19:00, 时间分辨率为 15min, 同时选择 2014 年 1 月至 2014 年 6 月的相关数据作为样本集 N 。

由于在 PV 系统中选取的样本数据的单位和数量级均不同, 若直接使用则使对网络产生过饱和。因此, 对网络进行训练之前, 必须先对原始数据进行预处理。本文对原始数据按式(20)进行归一化处理。

$$P_n = \frac{p_n - p_{\min}}{p_{\max} - p_{\min}} \quad (20)$$

$$X_n = \frac{x_n - x_{\min}}{x_{\max} - x_{\min}}$$

其中, P_n, X_n 为归一化后的目标和输入数据; p_n, x_n 为原始目标和输入数据; $p_{\min}, p_{\max}, x_{\min}, x_{\max}$ 为 p 和 x 中的最小值和最大值。

经过 HS 算法优化后得到的预测模型的参数为: $SR=0.252, N=100, IS=0.0229, SD=0.0541$ 。然后用训练好的 HS-ESN 预测模型对该光伏电站进行短期出力预测。

为了预测几种比较典型的天气, 从光伏历史数据中选择具有代表性的一组天气, 即 2014 年 4 月 7 日、2014 年 4 月 9 日、2014 年 4 月 10 日和 2014 年 4 月 17 日。这 4 天的天气类型分别为晴天、多云、阴天和雨天。

5.2 预测结果及分析

分别采用两种模型对 2014 年 4 月 7 日、2014 年 4 月 9 日、2014 年 4 月 10 日和 2014 年 4 月 17 日进行光伏出力的短期预测。模型一为本文提出的基于 HS-ESN 算法的预测模型; 模型二为文献[9]提出的利用 ESN 算法预测光伏出力的预测模型。两种模型均采用 Matlab 编程实现。

根据本文提出的相似日选取方法, 可得出 2014 年 4 月 7 日、2014 年 4 月 9 日、2014 年 4 月 10 日和 2014 年 4 月 17 日

的相似日分别为2014年4月6日、2014年4月2日、2014年4月3日和2014年4月15日。将这4个相似日的相关数据输入已经训练好的HS-ESN预测模型中,可得到模型一的预测值,将其输入ESN预测模型中可以得到模型二的预测值。

2014年4月7日的天气类型为晴,08:00—19:00之间的最大太阳辐照强度为 $824\text{W}/\text{m}^2$,平均太阳辐照强度为 $550\text{W}/\text{m}^2$,最高气温为 21°C ,最低气温为 6°C ,平均气温为 14°C 。模型一和模型二的预测结果如图5所示,从图5中可以明显地看出:模型二的预测值比实际值更小,且误差更大,而本文提出的模型一比模型二具有更高的精度。




图5 2014年4月7日的预测结果

2014年4月9日的天气类型为多云,08:00—19:00之间的最大太阳辐照强度为 $752\text{W}/\text{m}^2$,平均太阳辐照强度为 $408\text{W}/\text{m}^2$,最高气温为 15°C ,最低气温为 5°C ,平均气温为 10°C 。模型一和模型二的预测结果如图6所示,从图6中可以看出:当天气类型为阴天时,模型一和模型二的预测结果与实际值相比波动较大,但相对于模型二,模型一的预测结果比较理想。




图6 2014年4月9日的预测结果

图7和图8分别是阴天和雨天的预测结果。无论是模型一还是模型二,其预测结果的误差都比前两种天气类型的大。这是由于雨天的天气变化多样,而阴天有可能是雨前的阴天,也有可能是雨后的阴天。但是从图7和图8中仍然可以看出,模型一的预测结果更加接近实际值。




图7 2014年4月10日的预测结果




图8 2014年4月17日的预测结果

从表2中也可进一步看出,在这4种比较典型的天气类型中,当日类型为晴天和多云时模型一的预测精度非常高,其平均绝对百分比误差均小于14%,完全符合电力调度部门的运用需求;当天气类型为阴天和雨天时,使用模型二预测光伏出力的误差非常大,平均绝对百分比误差均在30%左右,已经失去了光伏出力预测的价值,而利用本文提出的模型一的平均绝对百分比误差均在20%左右,虽然预测精度有待提高,但相比模型二,本文提出的预测模型仍得到了较好的预测效果。

表2 两种模型的预测误差比较

预测日期	天气类型	HS-ESN 模型平均 绝对百分比误差/%	ESN 模型平均 绝对百分比误差/%
2014-04-07	晴	12.77	15.32
2014-04-09	多云	13.92	18.47
2014-04-10	阴天	19.91	29.08
2014-04-17	雨天	20.01	31.50

除了以上挑选的4种比较典型的天气类型外,HS-ESN预测模型在其他天气类型下也取得了比较好的预测效果。表3所列为HS-ESN预测模型和单一的ESN预测模型分别在5月份前两周中的预测误差。

表3 HS-ESN和ESN预测模型在5月份前两周中的预测误差

预测日期	天气类型	HS-ESN 模型平均 绝对百分比误差/%	ESN 模型平均 绝对百分比误差/%
2014-05-05	晴	12.81	15.75
2014-05-06	晴	12.85	16.42
2014-05-07	晴	12.94	13.21
2014-05-08	扬沙	13.66	15.91
2014-05-09	阴	20.10	25.87
2014-05-10	多云转晴	13.15	14.73
2014-05-11	晴	13.35	13.98
2014-05-12	多云	14.12	15.89
2014-05-13	多云转阴	23.75	33.94
2014-05-14	晴	13.51	16.54
2014-05-15	晴间多云	13.93	13.88
2014-05-16	多云转晴	14.21	16.82
2014-05-17	小雨	20.56	37.22
2014-05-18	阴	20.19	33.03

从表2和表3中可以看出,相比单一的ESN算法,HS-ESN算法在多种天气类型下都取得了更高的运算精度,因此,本文提出的基于HS-ESN算法的光伏发电短期出力预测模型为PV系统配合电力系统制定发电计划提供了较好的参考。

结束语 1)本文分析了天气类型、温度、太阳辐照强度对光伏出力的影响,然后通过灰色关联系数法对历史数据进行筛选,找出了与预测日关联度最相近的相似日,并将相似日的

气象数据和功率数据作为预测模型的输入变量,提高了预测模型的精度。

2) HS-ESN 算法具有较强的泛化能力,与单一的 ESN 算法相比具有非常高的运算精度,可用于光伏发电系统的短期出力预测。

3) 本文所有数据全部来源于甘肃某光伏电站的 PV 系统,通过实例对预测模型进行验证,其效果比较理想,具有一定的实用价值。

致 谢 本文中实验方案的制定和实验数据的测量记录工作是在中国华电集团甘肃分公司赵礼永、李娟等工作人员的大力支持下完成的,在此向他们表示衷心的感谢。

参 考 文 献

- [1] 中华人民共和国气象行业标准—太阳能评估方法[M]. 北京:气象出版社,2007.
- [2] ZHANG X, KANG C Q, ZHANG N, et al. Analysis of Mid/Long Term Random Characteristics of Photovoltaic power Generation[J]. Automation of Electric Power Systems, 2014, 38(6):6-13. (in Chinese)
张曦,康重庆,张宁,等. 太阳能光伏发电的中长期随机特性分析[J]. 电力系统自动化,2014,38(6):6-13.
- [3] KONG B L, CUI L Y, DING Z, et al. Short term power prediction based on hybrid wind-PV forecasting model[J]. Power System Protection and Control, 2015, 4(18):62-66. (in Chinese)
孔波利,崔丽艳,丁钊,等. 基于风光混合模型的短期功率预测方法研究[J]. 电力系统保护与控制,2015,4(18):62-66.
- [4] CUI Y, SUN Y C, CHANG Z L. A Review of Short-term Solar Photovoltaic Power Generation Prediction Methods [J]. Resources Science, 2013, 35(7):1474-1481. (in Chinese)
崔洋,孙银川,常倬林. 短期太阳能光伏发电预测方法研究进展[J]. 资源科学,2013,35(7):1474-1481.
- [5] YENONA A, SENJYU, FUNABASHI T. Application of recurrent neural network to short-term ahead generation power forecasting for photovoltaic system[C]// IEEE Power Engineering Society General Meeting. 2007:1-6.
- [6] WANG S Y, ZHANG N. Short-term Output Power Forecast of Photovoltaic Based on a Grey and Neural Network Hybrid Model[J]. Automation of Electric Power Systems, 2012, 36(19):1-5. (in Chinese)
王守阳,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):1-5.
- [7] YUAN X L, SHI J H, XU J Y. Short-term power forecast for photovoltaic generation based on BP neural network[J]. Renewable Energy Resources, 2013, 31(7):11-16. (in Chinese)
袁晓玲,施俊华,徐杰彦. 基于 BP 神经网络的光伏发电短期出力预测[J]. 可再生能源,2013,31(7):11-16.
- [8] YUAN X L, SHI J H, XU J Y. Short-term Power Forecasting for Photovoltaic Generation considering Weather Type Index [J]. Proceeding of the CSEE, 2013, 33(34):57-64. (in Chinese)
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.
- [9] PENG G H, MA J C, GONG W J, et al. Research of Prediction Model for Photovoltaic Power Based on ESN[J]. Journal of Qingdao University(E&T), 2015, 30(3):12-15. (in Chinese)
彭光虎,马景超,龚文杰,等. 基于 ESN 的光伏发电功率预测模型研究[J]. 青岛大学学报(工程技术版),2015,30(3):12-15.
- [10] DING M, WANG L, BI R. A short-term prediction model to forecast output power of photovoltaic system based on improved BP neural network[J]. Power System Protection and Control, 2012, 40(11):93-100. (in Chinese)
丁明,王磊,毕锐. 基于改进 BP 神经网络的光伏发电系统输出功率短期预测模型[J]. 电力系统保护与控制,2012,40(11):93-100.
- [11] YE L, CHEN Z, ZHAO Y N, et al. Photovoltaic Power Forecasting Model Based on Genetic Algorithm and Fuzzy Radial Basis Function Neural Network [J]. Automation of Electric Power Systems, 2015, 39(16):16-22. (in Chinese)
叶林,陈政,赵永宁,等. 基于遗传算法—模糊径向基神经网络的光伏发电功率预测模型[J]. 电力系统自动化,2015,39(16):16-22.
- [12] LI Y Z, NIU J C. Forecast of power generation for grid-connected photovoltaic system based on Markov chain[C]// Proceedings of Asia-Pacific Power and Energy Engineering Conference. 2009:1-4.
- [13] WU Z Y, TANG Y, FANG J X, et al. Collaborative Filtering Recommendation Algorithm Based on Ontology Semantic Similarity [J]. Computer Science, 2015, 42(9):204-207. (in Chinese)
吴正洋,汤庸,方家轩,等. 一种基于本体语义相似度的协同过滤推荐方法[J]. 计算机科学,2015,42(9):204-207.
- [14] GU H, ZHANG W X, JIN P, et al. Method of Software Design Patterns Identification Based on Correlation and Feature Constraints[J]. Computer Science, 2015, 42(2):133-176. (in Chinese)
古辉,张炜星,金鹏,等. 基于关联度和特征约束的软件设计模式识别方法[J]. 计算机科学,2015,42(2):133-176.
- [15] WANG X L, GE P J. PV array output power forecasting based on similar day and RBFNN[J]. Electric Power Automation Equipment, 2013, 33(1):100-103. (in Chinese)
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.
- [16] LI C B, LI X H, ZHAO R, et al. A Novel Algorithm of Selecting Similar Days for Short-term Power Load Forecasting[J]. Automation of Electric Power Systems, 2008, 32(9):69-73. (in Chinese)
黎灿兵,李晓辉,赵瑞,等. 电力短期负荷预测相似日选取算法[J]. 电力系统自动化,2008,32(9):69-73.
- [17] CAI J H, LIU J Y. Selecting method for similar day in super short-term load forecasting[J]. Journal of North China Electric Power University, 2006, 33(1):38-41. (in Chinese)
蔡佳宏,刘俊勇. 超短期负荷预测中相似日的选择方法[J]. 华北电力大学学报,2006,33(1):38-41.
- [18] YANG J S, ZENG B Q, HU P P. Spectrum Allocation and Power Control Based on Harmony Search Algorithm in Cognitive Radio Network[J]. Computer Science, 2015, 42(11A):258-262. (in Chinese)
杨劲松,曾碧卿,胡翩翩. 认知无线网络中基于和声搜索的频谱分配与功率控制[J]. 计算机科学,2015,42(11A):258-262.

一个复杂的可视化系统选用适当的方法进行增量模块的划分,同时进行增量模块之间无缝耦合从而提高系统整体的内聚性为下一步的研究方向。

参 考 文 献

- [1] HABER R B, MCNABB D A. Visualization idioms: A conceptual model for scientific visualization systems[J]. *Visualization in Scientific Computing*, 1990, 74: 93.
- [2] CARD S K, MACKINLAY J D, SHNEIDERMAN B. Readings in information visualization: using vision to think[M]. Morgan Kaufmann, 1999.
- [3] MUNZNER T. Visualization Analysis and Design[M]. CRC Press, 2014.
- [4] MUNZNER T. A nested model for visualization design and validation[J]. *IEEE Transactions on Visualization and Computer Graphics*, 2009, 15(6): 921-928.
- [5] STOLTLE C, HANRAHAN P. Polaris: A system for query, analysis and visualization of multi-dimensional relational databases[J]. *IEEE Transactions on Visualization and Computer Graphics*, 2002, 8(1): 52-56.
- [6] KEIM D, ANDRIENKO G, FEKETE J D, et al. Visual Analytics: Definition, Process, and Challenges[J]. *Lecture Notes in Computer Science*, 2008, 4950: 154-175.
- [7] 陈为, 沈则潜, 陶煜波. 数据可视化[M]. 北京: 电子工业出版社, 2014: 6.
- [8] 海藩. 软件工程导论[M]. 北京: 清华大学出版社, 2003.
- [9] ROYCE W W. Managing the development of large software systems[J]. *Proceedings of IEEE WESCON*, 1970, 26(8): 328-338.
- [10] KANDEL S, PAEPCKE A, HELLERSTEIN J, et al. Wrangler: Interactive visual specification of data transformation scripts[C]// *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems*. ACM, 2011: 3363-3372.
- [11] MORRIS T, GUIDRY T, MAGDINIE M. OpenRefine: A free, open source, powerful tool for working with messy data[R/OL]. Technical report, The OpenRefine Development Team, 2015. <http://openrefine.org>, 2015.
- [12] MACQUEEN J. Some methods for classification and analysis of multivariate observations[J]. *Proceedings of the Fifth Berkeley Symposium on Mathematical Statistics and Probability*, 1967, 1(14): 281-297.
- [13] SIBSON R. SLINK: an optimally efficient algorithm for the single-link cluster method[J]. *The Computer Journal*, 1973, 16(1): 30-34.
- [14] ESTER M, KRIEDEL H P, SANDER J, et al. A density-based algorithm for discovering clusters in large spatial databases with noise[J]. *Kdd*, 1996, 96(34): 226-231.
- [15] MACKINLAY J. Automating the design of graphical presentations of relational information[J]. *ACM Transactions on Graphics (Tog)*, 1986, 5(2): 110-141.
- [16] FERRAILOLO J, JUN F, JACKSON D. Scalable vector graphics (SVG) 1.0 specification[M]. Iuniverse, 2000.
- [17] FULTON S, FULTON J. HTML5 canvas[M]. O'Reilly Media, Inc. 2013.
- [18] JOHNSON D W, JANKUN-KELLY T J. A scalability study of web-native information visualization[C]// *Proceedings of Graphics Interface 2008*. Canadian Information Processing Society, 2008: 163-168.
- [19] ZHENG Y, CAPRA L, WOLFSON O, et al. Urban computing: concepts, methodologies, and applications[J]. *ACM Transactions on Intelligent Systems and Technology (TIST)*, 2014, 5(3): 38.
- [20] HAKLAY M, WEBER P. Openstreetmap: User-generated street maps[J]. *IEEE Pervasive Computing*, 2008, 7(4): 12-18.
- [21] GEEM Z W, TSENG C L. New Methodology, Harmony Search and Its Robustness[C]// *Late-Breaking Papers of Genetic and Evolutionary Computation Conference (GECCO-2002)*. New York, USA, 2002: 174-178.
- [22] KANG S L, GEEM Z W. A new structural optimization Method based on harmony search algorithm[J]. *Computes and Structures*, 2004, 82(9/10): 781-798.
- [23] LEE K S, GEEM Z W. A new meta-heuristic algorithm For continuous engineering optimization: harmony Search theory and practice[J]. *Computer Methods in Applied Mechanics and Engineering*, 2005, 194(36-38): 3902-3933.
- [24] GEEM Z W, LEE K S, PARK Y. Application of harmony search to vehicle routing[J]. *American Journal of Applied Sciences*, 2005, 2(12): 1552-1557.
- [25] KOUNTOURIOTIS P A, OBRADOVIC D, MANDIC D P, et al. Multi-step forecasting using echo state networks[C]// *International Conference on Computer As a Tool*. 2005: 1574-1577.
- [26] BUEHNER M, YOUNG P. A Tighter Bound for the Echo State Property[J]. *IEEE Transactions on Neural Networks*, 2006, 17(3): 820-824.
- [27] SKOWRONSKI M D, HARRI J G. Automatic speech recognition using a predictive echo state network classifier[J]. *Neural Networks*, 2007, 20(3): 414-423.
- [28] LIN X, YANG Z, SONG Y. Short-term stock price prediction based on echo state networks[J]. *Expert Systems with Applications*, 2009, 36(3): 7313-7317.
- [29] HOLZMANN G, HAUSER H. Echo State networks with filter neurons and a delay & sun readout[J]. *Neural Networks*, 2010, 23(2): 244-256.
- [30] OZTURK M C, XU D M, Principle J C. Analysis and design of echo state networks[J]. *Neural Computation*, 2007, 19(1): 111-138.
- [31] TIAN Z D, GAO X W, LI S J, et al. Prediction Method for Network Traffic Based on Genetic Algorithm Optimized Echo State Network[J]. *Journal of Computer Research and Development*, 2015, 52(5): 1137-1145. (in Chinese)
- [32] 田中大, 高宪文, 李树江, 等. 遗传算法优化回声状态网络的网络流量预测[J]. *计算机研究与发展*, 2015, 52(5): 1137-1145.

(上接第 231 页)