DOI:10.12158/j.2096-3203.2020.02.012

基于布谷鸟-Elman 算法的光伏发电预测

赵俊浩，吴杰康，张文杰，金锋，叶辉良，任德江
（广东工业大学自动化学院，广东 广州 510006）

摘　要：提高光伏发电功率预测的精度对于保证电网的安全稳定运行、提高光伏资源的开发和利用率具有重要的意义。文中提出了一种基于天气相似度以及改进布谷鸟算法优化 Elman 神经网络的光伏发电短期功率预测模型。首先在选取相似日上，提出一种基于距离和角度趋势的相似度计算方法，选出与待预测日相似度更高的相似日。其次，利用改进后的布谷鸟算法对 Elman 神经网络的权值和阈值进行优化并构建光伏发电短期功率预测模型。最后将文中提出的光伏发电预测模型与传统 Elman 神经网络模型的预测结果及实际输出值进行比较，结果表明改进布谷鸟算法优化 Elman 神经网络的光伏发电短期功率预测模型预测精度更高。

关键词：光伏发电预测；天气相似度；相似日；改进布谷鸟算法；Elman 神经网络
中图分类号：TM73　　**文献标志码**：A　　**文章编号**：2096-3203(2020)02-0081-08

0　引言

随着全球能源危机问题以及能源污染问题日益严重，新能源的利用成为热点研究话题之一[1—3]。光伏发电作为如今新能源发电的形式之一，其年增长率已经超过了 40%，成为全球增长速度最快的新能源。但是，光伏发电与太阳能辐射度以及其他气象因素关系密切，其出力具有随机性、波动性和不确定性等特点[4—6]。随着越来越多的光伏发电系统并入到大电网，光伏发电出力不稳定的特点将给电力系统调度、电网安全稳定运行带来更大的挑战。提高光伏发电短期功率的预测精度，对于实现多种能源互补、电网有效协调以及电网的经济稳定运行具有重要意义。

目前，国内外预测光伏发电的方法主要有 2 种：第一种是间接预测法，该方法不仅需要掌握光伏发电的物理机制，还需要精确的参数以及天气数据，然后对影响光伏发电的物理因素进行探讨，最后构建物理模型，难度较大[7—9]；第二种是直接预测法，又叫统计法，需要大量的历史数据，分析数据集的关联度，构建预测模型进行预测，常用方法包括时序预测法、神经网络和支持向量机等人工智能法[10—12]。

神经网络预测法已经逐渐应用到光伏发电预测中[13—14]。文献[15]使用改进后的遗传算法优化反向传播神经网络对加利福利亚州某光伏电站出力进行预测，该方法没有考虑不同类型天气状况下光伏电站出力的变化，模型适用性较差；文献[16]在考虑不同日类型的情况下建立 Elman 神经网络的光伏发电预测模型，但选取相似日时只考虑了日类型而没有考虑到其他气象因素对光伏发电的影响；文献[17]以气温和相对湿度作为影响光伏发电出力的因子，通过差异度选取相似日并创建 Elman 神经网络的预测模型，但是由于 Elman 神经网络存在着泛化性能差的缺点，所以预测精度一般。

为进一步提高 Elman 神经网络的光伏发电预测模型的精度，文中针对不同类型的气象因素，分析了影响光伏发电功率的主要因素。在考虑相似日选取上，提出距离相似度以及趋势相似度的概念，结合两者计算出综合相似度并由此选取相似日。以传统布谷鸟算法为基础，继续引入趋势相似度增加至算法适应度的计算中，并由此改进算法优化 Elman 神经网络的权值及阈值。最后，创建基于天气相似度和改进布谷鸟优化 Elman 神经网络的光伏发电预测模型，并在 Matlab 环境中进行仿真验证。

1　相似日的选取

1.1　光伏发电出力的影响因素分析

光伏发电的出力主要受到太阳辐射度和环境温度的影响，其输出功率的计算公式可表示为：

$$P = \eta SI[1 - 0.005(T + 25)] \quad (1)$$

式中：η 为光伏转换效率；S 为光伏面板的面积；I 为太阳的辐照强度；T 为环境温度。通过式(1)可看出影响光伏发电输出功率的环境参数较为固定，但事实上，还有许多参数影响着光伏发电的输出功率。文中将环境温度、环境湿度以及太阳辐照度作为影响光伏发电功率的主要因素[18]。

收稿日期：2019-10-16；修回日期：2019-11-19
基金项目：国家自然科学基金资助项目(51567002)；广东省应用型科技研发专项资金项目(2016B020244003)

1.2 基于天气相似度的相似日选取

目前针对相似日的选取已有许多研究[19—21]，其中一部分研究只考虑了单一天气因素的影响，另一部分虽然考虑了多天气因素的影响，但只计算了对应时刻数值的差异。文中在前人研究基础上，提出一种新的相似日选取方法，将距离以及角度趋势作为计算相似度的核心，即对于判断 2 组特征数据序列的相似程度，不仅考虑 2 组序列对应时刻数值的距离，而且考虑了 2 组序列在变化趋势上的差异程度，最后结合距离以及角度趋势计算出综合的天气相似度，以下称为综合相似度，并由此选取相似日。相似日选取算法的步骤如下：

（1）数据归一化。为了避免因不同类型气象数据量纲不一致而出现的误差，需要对气象数据进行归一化处理，公式如下：

$$x = \frac{a - a_{\min}}{a_{\max} - a_{\min}} \tag{2}$$

式中：x 为归一化后的数据；a 为从监控系统中记录的气象数据；$a_{\min}$，$a_{\max}$ 分别为同类型气象数据的最小值和最大值。

（2）构建影响因子矩阵。利用归一化后的数据集，构建每日环境温度、环境湿度以及太阳辐照度 3 类天气因素特征向量，由此构建每日影响因子矩阵 $\boldsymbol{X}_i$：

$$\boldsymbol{X}_i = \begin{bmatrix} x_{i1}(1) & x_{i2}(1) & x_{i3}(1) \\ x_{i1}(2) & x_{i2}(2) & x_{i3}(2) \\ \vdots & \vdots & \vdots \\ x_{i1}(m) & x_{i2}(m) & x_{i3}(m) \end{bmatrix} \tag{3}$$

式中：$\boldsymbol{X}_i$ 为第 i 个历史日的影响因子矩阵；$x_{in}(k)$ 为第 i 个历史日第 n 类气象数据第 k 个样本的归一化值；$n=1,2,3$ 分别为环境温度、环境湿度以及太阳辐射；$k=1,2,\cdots,m$ 为样本数。待预测日的影响因子矩阵相应地表示为：

$$\boldsymbol{X}_{\mathrm{d}} = [\boldsymbol{x}_{\mathrm{d1}} \quad \boldsymbol{x}_{\mathrm{d2}} \quad \boldsymbol{x}_{\mathrm{d3}}] \tag{4}$$

式中：$\boldsymbol{x}_{\mathrm{d}n}$ 为待预测日的第 n 类天气因素特征向量。

（3）计算距离相似度。文中所定义的距离相似度是指待预测日与历史日之间各个对应影响因子的差异程度，具体计算步骤如下。

首先，将待测日的影响因子矩阵与历史日的影响因子矩阵相减，得到距离矩阵 $\boldsymbol{X}_{i\Delta}$：

$$\boldsymbol{X}_{i\Delta} = \begin{bmatrix} x_{i\Delta1}(1) & x_{i\Delta2}(1) & x_{i\Delta3}(1) \\ x_{i\Delta1}(2) & x_{i\Delta2}(2) & x_{i\Delta3}(2) \\ \vdots & \vdots & \vdots \\ x_{i\Delta1}(m) & x_{i\Delta2}(m) & x_{i\Delta3}(m) \end{bmatrix} \tag{5}$$

式中：$x_{i\Delta n}(k)$ 为待预测日与第 i 个历史日第 n 类气象数据的第 k 个样本的差值。

由于距离矩阵的元素表示的是待预测日与历史日每个对应时刻的差异，为表示待预测日与历史日的整体差异，文中将距离矩阵的元素相加，为了将整体的距离差异转换成相似度度量，而相似度度量的范围一般为[0,1]，因此将得到的相加值引入到负指数函数中构成距离相似度 γ_1，可表示为：

$$\gamma_1 = 1/\mathrm{e}^{v} \tag{6}$$

$$v = \sum_{z=1}^{m}\sum_{j=1}^{n} x_{i\Delta j}(z) \tag{7}$$

（4）计算趋势相似度。文中所定义的趋势相似度是指待预测日与历史日之间各个对应影响因子变化程度的相似性，具体计算步骤如下。

首先计算历史日每日影响因子的趋势矩阵 $\boldsymbol{u}_i$：

$$\boldsymbol{u}_i = \begin{bmatrix} u_1(1) & u_2(1) & u_3(1) \\ u_1(2) & u_2(2) & u_3(2) \\ \vdots & \vdots & \vdots \\ u_1(m-1) & u_2(m-1) & u_3(m-1) \end{bmatrix} \tag{8}$$

式中：$u_n(l)=x_{in}(l+1)-x_{in}(l)$，$l=1,2,\cdots,m-1$ 为同类气象因素每 2 个相邻序列之差。同样地，待预测日的趋势矩阵也可以表示为 $\boldsymbol{u}_{\mathrm{o}}$。

$$\boldsymbol{u}_{\mathrm{o}} = \begin{bmatrix} u_{\mathrm{o}1}(1) & u_{\mathrm{o}2}(1) & u_{\mathrm{o}3}(1) \\ u_{\mathrm{o}1}(2) & u_{\mathrm{o}2}(2) & u_{\mathrm{o}3}(2) \\ \vdots & \vdots & \vdots \\ u_{\mathrm{o}1}(m-1) & u_{\mathrm{o}2}(m-1) & u_{\mathrm{o}3}(m-1) \end{bmatrix} \tag{9}$$

然后，将趋势矩阵每一行的 3 个值映射到三维空间中，即每一行元素表示一个向量，计算待预测日与历史日趋势矩阵对应向量的角度余弦值，并将角度的余弦值投射到[0,1]的区间中，最后将每天 $m-1$ 个序列差（m 个时刻）的角度余弦投射值叠加，并把这个叠加值记为 β_i。

$$\beta_i = \sum_{j=1}^{m-1}\left(\frac{\sum_{x=1}^{n} u_x(j)u_{\mathrm{o}x}(j)}{2\sqrt{\sum_{x=1}^{n} u_x^2(j)}\sqrt{\sum_{x=1}^{n} u_{\mathrm{o}x}^2(j)}} + \frac{1}{2}\right) \tag{10}$$

待预测日与历史日的趋势相似度 γ_2 可表示为：

$$\gamma_2 = \frac{1}{m-1}\beta_i \tag{11}$$

（5）计算综合相似度。求得距离相似度和趋势相似度后，文中设定 2 个相似度的重要性一致，所以

待预测日与历史日的综合相似度 γ 的计算表示为:

$$\gamma = (\gamma_1 + \gamma_2)/2 \tag{12}$$

(6) 选择相似日。由步骤(1)—(5)可以计算出各个历史日与待预测日的综合相似度,并设定一个阈值,根据误差递减原则确定阈值大小,最终选取出相似性高于此阈值的前 8 个历史日的数据样本为相似日。

2 光伏发电预测模型

2.1 Elman 神经网络

1990 年,国外学者 J.L.Elman 首次提出了 Elman 神经网络。Elman 神经网络的结构是由输入层、隐含层、承接层以及输出层构成的,是一种具有动态记忆功能的反馈性网络,具体结构见图 1。其中承接层的功能是将前一时刻隐含层的输出值反馈给隐含层,并以此作为隐含层的输入,从而使 Elman 神经网络具有记忆前一时刻的功能,对于动态数据而言,Elman 神经网络的处理能力较强[22—23]。故 Elman 神经网络适合应用于光伏发电预测中。

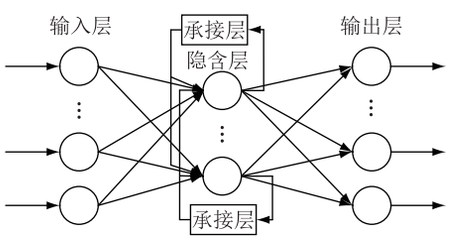


图 1 Elman 神经网络结构

Fig.1 The structure of Elman neural network

2.2 布谷鸟算法

在 2009 年,国内学者杨新社教授和国外学者 S.戴布首先提出了布谷鸟算法(cuckoo search,CS),该算法是模拟布谷鸟育雏行为的一种算法,布谷鸟会在其他鸟类离巢外出捕食的时候,将卵蛋产在宿主巢中,以寄生的方式养育幼鸟[24—29]。而且,布谷鸟每次只在一个鸟巢中产一个卵,原巢主也会以一定概率发现外来卵。在这个前提下,布谷鸟以 levy 飞行的方式来更新自己找到宿主巢的位置,幼鸟能否成功孵化表征着鸟巢的好坏,而鸟巢的好坏最后表示为解的好坏,levy 飞行的公式表示如下:

$$x_{t+1} = x_t + \alpha \otimes Levy(\beta) \tag{13}$$

式中:x_{t+1}和 x_t 分别为第 $t+1$ 和 t 代鸟巢的位置;α 为步长系数;$Levy(\beta)$ 为莱维随机路径,此路径为布谷鸟寻找宿主巢的飞行路径。

$Levy(\beta)$ 服从莱维概率分布,其计算公式如下:

$$Levy(\beta) = \frac{\varphi\mu}{|v|^{1/\lambda}} \tag{14}$$

当 μ 和 v 服从标准正态分布,λ 取 1.5 时:

$$\varphi = \left[\frac{\Gamma(1+\beta)\sin(\pi\beta/2)}{\beta\Gamma\left(\frac{1+\beta}{2}\right)2^{(1+\beta)/2}}\right]^{1/\beta} \tag{15}$$

为了增加布谷鸟算法对于光伏发电功率预测的适应性,文中对布谷鸟算法进行改进,改进布谷鸟算法(improved cuckoo search,ICS)具体步骤如下:

(1) 对种群以及其他相关变量进行初始化;

(2) 对种群中的鸟巢进行适应度计算,并记录最优适应度的鸟巢,其中传统 CS 中鸟巢的适应度函数一般取实际值与输出值的误差,在此基础上,将趋势相似性引入到适应度函数中,即:

$$\begin{cases} A = |x_{t,e} - x_{t,o}| + \left|\dfrac{a-b}{1+ab}\right| \\ a = x_{t+1,e} - x_{t,e} \\ b = x_{t+1,o} - x_{t,o} \end{cases} \tag{16}$$

式中:$x_{t+1,e}$ 和 $x_{t,e}$ 分别为第 $t+1$ 和 t 个时间点的实际值;$x_{t+1,o}$ 和 $x_{t,o}$ 分别为第 $t+1$ 和 t 个时间点的输出值;A 为适应度函数。

(3) 以 Levy 飞行的方式更新鸟巢位置,并与上一代鸟巢的适应度进行比较,除去适应度较差的鸟巢,更新得到适应度更高的鸟巢;

(4) 根据一定的概率放弃部分鸟巢的位置并随机改变鸟巢的位置,计算更新后的鸟巢适应度,通过比较更新得到适应度更高鸟巢的位置;

(5) 若满足算法的终止条件,则输出鸟巢位置作为问题的解;否则,返回步骤(3)继续迭代。

2.3 ICS 优化 Elman 神经网络

Elman 神经网络的权值以及阈值的取值都是通过随机化函数生成,会导致在模型训练中,其收敛过程不稳定,且 Elman 神经网络还具有易陷入局部最优解的缺点。为进一步提高 Elman 神经网络的泛化能力,增强神经网络的稳定性以及避免输出结果陷入局部最优解,文中结合 ICS 算法全局搜索最优解能力较强的特点,利用该算法去优化 Elman 的权值以及阈值,使得 Elman 神经网络的拓扑结构以及参数更加合理化。而且,如今对于使用优化算法去优化 Elman 神经网络输出-隐含以及隐含-输出权值和阈值的研究较多,但优化隐含-承接的权值和阈值的文章较少,故文中将结合选取相似日的方法,使用 ICS 算法优化 Elman 神经网络的输出-隐含、隐含-承接以及隐含-输出的权值和阈值。构建基于天气相似度和 ICS 优化 Elman 神经网络的光伏预测模型,其流程如图 2 所示,具体步骤如下。

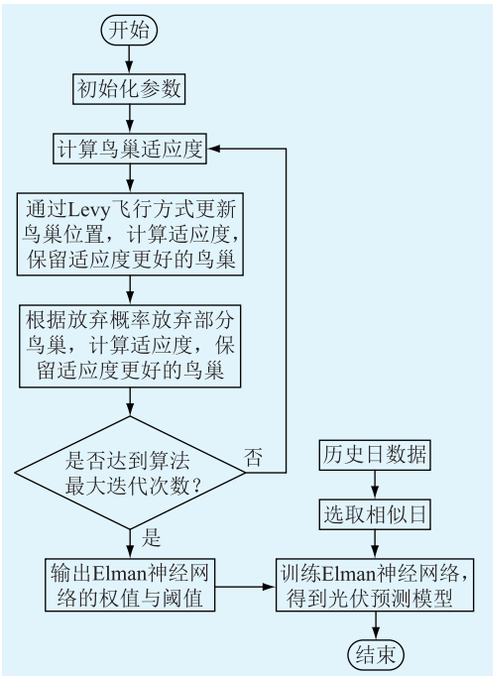


图 2　构建光伏发电预测模型流程

Fig.2　Flow chart of photovoltaic power generation forecasting model

（1）初始化 Elman 神经网络的结构参数：输入层、隐含层和输出层的数目；初始化鸟巢数目、算法迭代次数、放弃概率及步长系数；初始化种群。

（2）根据式（16）计算初始鸟巢位置的适应度，并利用 Levy 飞行的公式更新鸟巢的位置并计算其适应度，通过与上一代鸟巢比较，替换得到适应度更好的鸟巢作为当前鸟巢的位置。

（3）以放弃概率放弃部分鸟巢的位置，然后通过随机偏好游动生成新的鸟巢位置并计算其适应度，通过比较替换得到适应度更好的鸟巢作为当前鸟巢的位置。

（4）判断是否满足算法结束的条件，若满足，将鸟巢解码为 Elman 神经网络的权值和阈值；若不满足则返回步骤（2）继续进行迭代计算。

（5）将 ICS 算法输出的结果作为 Elman 神经网络的权值和阈值。

（6）针对历史日的数据，使用文中的相似日选取方法选取与待预测日相似度较高的相似日，并作为训练集对 Elman 网络进行训练，得到光伏发电功率预测模型。

3　算例与分析

3.1　数据来源

以澳大利亚昆士兰大学的 UQCentre 太阳能 433 kW 光伏电站的实时播报系统记录 2017 年 8～12 月的光伏发电功率数据以及气象数据[30]为研究对象，取该地区晴天（2017-12-24）、阴天（2017-9-21）以及雨天（2017-10-20）的光伏发电数据和气象数据，时间点为 7:00—17:00，时间间隔为 30 min，每天共有 21 个点（即 $m=21$）。

3.2　选取相似日

选择待预测日及其前 2 个月每日数据作为训练样本，根据文中相似日的选取算法，计算出算例中各个历史日与待预测日的综合相似度，从历史日数据中选取出与待预测日相似性更高的相似日集合，计算结果如图 3 所示。

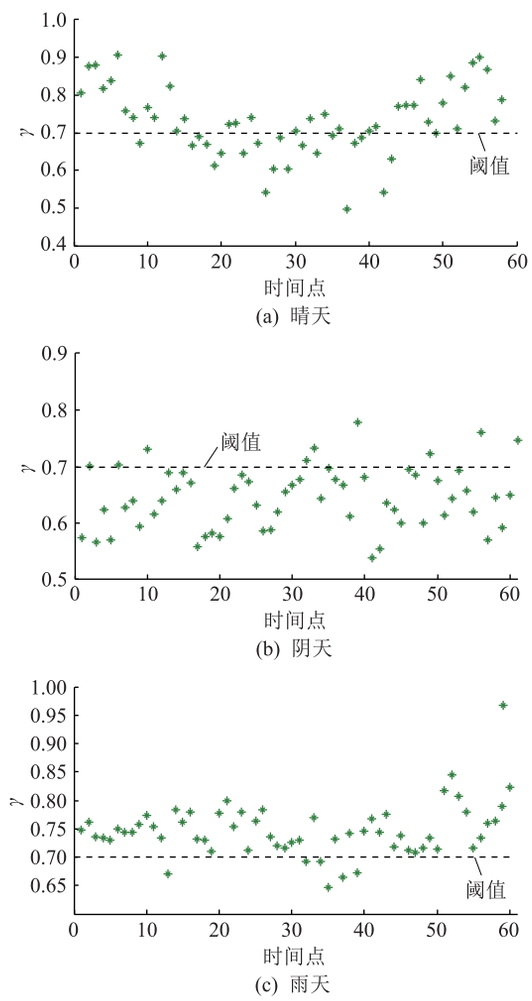


图 3　综合相似度计算结果

Fig.3　The result of weather similarity degree

图 3 中横坐标时间点的范围为待预测日前 2 个月的每日时间点。文中选取相似性等于 0.7 为阈值，最终选取出相似性高于 0.7 的前 8 个历史日的数据样本，所选取相似日的相似度如表 1 所示。

根据表 1 选取相似日的结果，将表中所选日期和待预测日的环境温度、环境湿度、太阳辐照度以及前一天 7:00—17:00 每隔 30 min 的发电功率作为模型的输入，待预测日的对应时刻发电功率作为

表 1 相似日及其综合相似度

Table 1 Similarity days and weather similarity degree

(a) 晴天

日期	γ	日期	γ
2017-10-29	0.907 1	2017-10-26	0.879 4
2017-11-04	0.904 4	2017-10-25	0.878 1
2017-12-20	0.900 6	2017-12-21	0.868 3
2017-12-19	0.884 9	2017-12-16	0.849 9

(b) 阴天

日期	γ	日期	γ
2017-09-20	0.880 1	2017-09-12	0.807 8
2017-09-11	0.844 5	2017-08-11	0.798 3
2017-09-19	0.821 9	2017-09-18	0.788 7
2017-09-10	0.816 0	2017-08-04	0.783 1

(c) 雨天

日期	γ	日期	γ
2017-09-26	0.779 0	2017-08-28	0.731 6
2017-10-13	0.759 5	2017-10-06	0.723 4
2017-10-18	0.746 4	2017-09-19	0.711 3
2017-09-20	0.732 0	2017-08-24	0.703 3

模型的输出,创建基于天气相似性的 ICS-Elman 神经网络光伏发电功率预测模型,模型参数如下:(1) Elman 神经网络。输入层、隐含层以及输出层数目分别为 4,20,1;输入-隐含以及隐含-输出的激活函数分别为 tansig、purelin;训练函数为 traingdm;迭代次数为 30 000。(2) 布谷鸟算法。鸟巢数目为 50;放弃概率为 0.25;步长系数为 0.01;算法迭代次数为 200。

为了验证文中提出的基于天气相似性的 ICS-Elman 光伏发电功率预测模型优化效果,利用相同数据集创建 Elman 预测模型与文中模型进行比较。

3.3 结果分析

将待预测日的气象数据放入各个预测模型中训练,可以预测得出待预测日各个模型各个时刻的预测值,并将这些预测值与实际值进行比较,得出各个模型的预测精度。文中采用 2 种误差对预测模型进行评价,即均方误差(mean-square error,MSE)和平均相对误差(mean relative error,MRE)。

$$\varepsilon_{\mathrm{MSE}} = \frac{1}{m}\sum_{i=1}^{m}(Y_i - y_i)^2 \tag{17}$$

$$\varepsilon_{\mathrm{MRE}} = \frac{1}{m}\sum_{i=1}^{m}\frac{|Y_i - y_i|}{Y_i} \times 100\% \tag{18}$$

式中:m 为预测时间点数,文中取 21;Y_i 为实际值;y_i 为模型的预测值。

图 4 为 Elman 与 ICS-Elman 预测模型的预测值曲线与实际光伏发电输出值曲线的比较,从 3 种天气类型的不同模型预测值对比可以看出,ICS-Elman 的预测曲线比 Elman 的预测曲线更接近实际值的曲线,由此可得出:ICS-Elman 光伏发电预测模型具有更好的预测拟合能力。

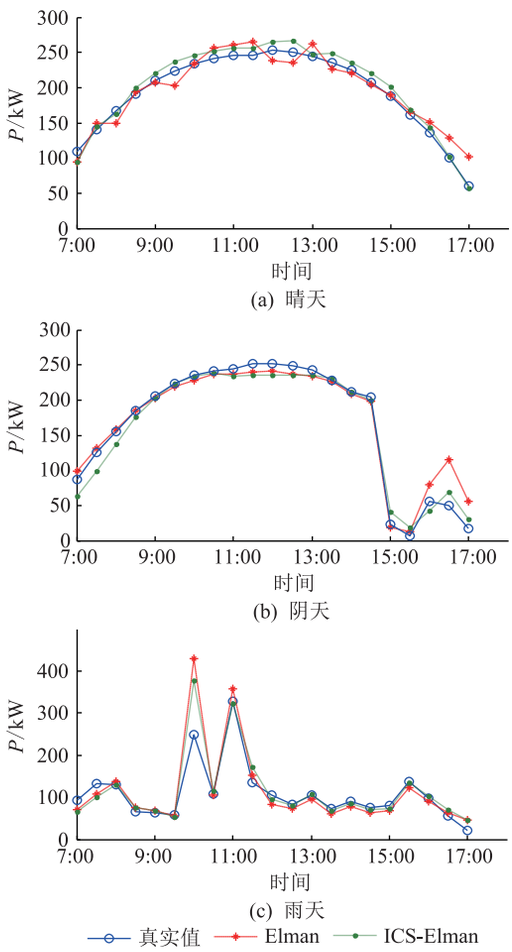


图 4 不同模型预测值对比图

Fig.4 The comparison of different models' results

表 2 为不同预测模型在不同天气下的 MSE 和 MRE 误差值。由表 2 可见,在同一模型下不同天气的预测精度大小关系为:晴天>阴天>雨天。而对于同一天气类型,ICS-Elman 预测模型的精度比传统 Elman 的精度要更高:(1) 对于晴天,ICS-Elman 预测模型的均方误差和平均相对误差比传统 Elman 预测模型分别减少了 153.039 5 和 4 个百分点;(2) 对于阴天,ICS-Elman 预测模型的均方误差和平均相对误差比传统 Elman 预测模型分别减少了 11.159 4 和4.44个百分点;(3) 对于雨天,ICS-Elman 预测模型的均方误差和平均相对误差比传统 Elman 预测模型分别减少了 791.775 2 和 2.72 个百分点。由此可得,在同一类型天气下,ICS-Elman 预测模型的预测精度比传统 Elman 预测模型的预测精度更高。

图 5 是 ICS-Elman 预测模型在晴天、阴天以及

表 2 不同模型误差对比

Table 2 The error comparison of different models

天气	Elman		ICS-Elman	
	ε_{MSE}	ε_{MRE}/%	ε_{MSE}	ε_{MRE}/%
晴	262.625 3	8.38	109.585 8	4.38
阴	817.245 0	15.99	806.085 6	11.55
雨	1 802.756 5	17.44	1 010.981 3	14.72

雨天每时刻的绝对误差对比图，由图可见，晴天的预测模型比其他 2 种天气预测模型的预测精度要更高，而雨天的预测模型在某些时刻的预测误差较大，其主要原因为晴天天气因素的波动性较小，而雨天、阴天的天气因素波动性较大，这将导致模型的输入量变化较大，使得最终的输出与实际误差变大。在晴天的光伏预测中，7:00 的预测误差较大，原因是早晨太阳辐射量较低，空气水汽量较大，而光伏发电功率主要与太阳辐射量有关，因此光伏出力不稳定，而且在太阳辐射度低时，可能使得预测模型的输入量相关性较差，故其预测精度误差误差较其他时刻要大。

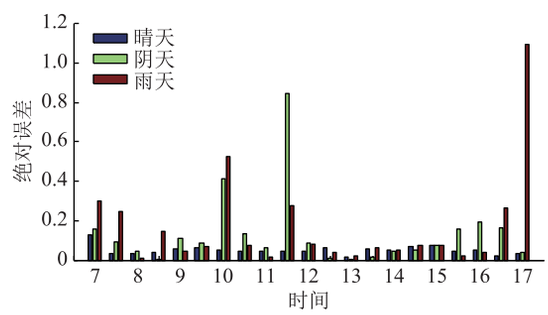


图 5 ICS-Elman 模型不同天气的每时刻绝对误差对比

Fig.5 ICS-Elman model's error comparison of different weather at each time

4 结语

文中提出了一种基于天气相似度选取相似日的方法以及基于 ICS-Elman 神经网络的光伏发电预测模型，研究结果表明：在利用天气相似度分析选取日的基础上，基于 ICS-Elman 神经网络的光伏预测模型比传统 Elman 神经网络预测模型的预测精度高，对于晴天、阴天及雨天，该模型的均方误差分别减少了 153.039 5，11.159 4 和 791.775 2，平均相对误差分别减少了 4%，4.44%和 2.72%。而晴天光伏预测模型的精度比阴天和雨天光伏预测模型的精度要更高。由此可见，基于天气相似度和 ICS-Elman 神经网络的预测模型可以有效预测光伏短期发电功率。

参考文献：

[1] 祁希，何山，王维庆，等. 基于 FMPC 的储能系统跟踪光伏发电计划控制策略[J]. 可再生能源，2019，37(3)：354-360.
QI Xi，HE Shan，WANG Weiqing，et al. FMPC based control strategy for tracking PV power schedule output of energy storage system[J]. Renewable Energy Resources，2019，37(3)：354-360.

[2] 薛阳，王琳，王舒，等. 一种结合 CNN 和 GRU 网络的超短期风电预测模型[J]. 可再生能源，2019，37(3)：456-462.
XUE Yang，WANG Lin，WANG Shu，et al. An ultra-short-term wind power forecasting model combined with CNN and GRU networks[J]. Renewable Energy Resources，2019，37(3)：354-360.

[3] 张蕾. 考虑风功率预测不确定性的水电风电联合调度[D]. 西安：西安理工大学，2018.
ZHANG Lei. Combined dispatching of hydropower and wind power considering the uncertainty of wind power prediction[D]. Xi'an：Xi'an University of Technology，2018.

[4] 张彩庆，郑强. SKBA-LSSVM 短期光伏发电功率预测模型[J/OL]. 电力系统及其自动化学报：1-9(2018-10-31)[2019-08-16]. https://doi.org/10.19635/j.cnki.csu-epsa.000104.
ZHANG Caiqing，ZHENG Qiang. SKBA-LSSVM short-term PV power forecasting model[J/OL]. Proceedings of the CSU-EPSA：1-9(2018-10-31)[2019-08-16]. https://doi.org/10.19635/j.cnki.csu-epsa.000104.

[5] 刘卫亮，刘长良，林永君，等. 计及雾霾影响因素的光伏发电超短期功率预测[J]. 中国电机工程学报，2018，38(14)：4086-4095，4315.
LIU Weiliang，LIU Changliang，LIN Yongjun，et al. Super short-term photovoltaic power forecasting considering influence factor of smog[J]. Proceedings of the CSEE，2018，38(14)：4086-4095，4315.

[6] 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.

[7] 韩立涛. 考虑云遮挡的光伏超短期功率预测研究[D]. 北京：华北电力大学，2018.
HAN Litao. Research on ultra-short-term photovoltaic power prediction considering cloud shelterting[D]. Beijing：North China Electric Power University，2018.

[8] 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.
TAN Jin，DENG Changhong，YANG Wei，et al. Ultra-short-term photovoltaic power forecasting in microgrid based on adaboost clustering[J]. Automation of Electric Power Systems，2017，41(21)：33-39.

[9] 李芬，钱加林，杨兴武，等. 基于 CAR 模型的短期光伏发电量预测[J]. 上海电力学院学报，2015，31(6)：514-518.
LI Fen，QIAN Jialin，YANG Xingwu，et al. Forecasting short-

term photovoltaic power generation on car model basis[J]. Journal of Shanghai University of Electric Power, 2015, 31(6): 514-518.

[10] 冉成科,夏向阳,杨明圣,等. 基于日类型及融合理论的 BP 网络光伏功率预测[J]. 中南大学学报(自然科学版),2018,49(9):2232-2239.
RAN Chengke, XIA Xiangyang, YANG Mingsheng, et al. BP network PV power forecast based on daily type and fusion theory[J]. Journal of Central South University (Science and Technology),2018,49(9):2232-2239.

[11] 杨洁,成珂. 基于数据挖掘的神经网络光伏发电预测研究[J]. 激光杂志,2018,39(8):59-62.
YANG Jie, CHENG Ke. Research of neural network power forecasting model of photovoltaic[J]. Laser Journal, 2018, 39(8):59-62.

[12] RAMENAH H, TANOUGAST C, CICERO L. Toward a prediction of the photovoltaic based power production from experimental thermal modeling[C]//Transportation Electrification Asia-pacific, IEEE, 2014.

[13] ZHU Honglu, LI Xu, YAO Jianxi. The power prediction method for photovoltaic power station based on wavelet analysis and neural networks[J]. Acta Energiae Solaris Sinica, 2015.

[14] XU G, LIU M. Photovoltaic power prediction model based on parallel neural network and genetic algorithms[C]//International Workshop on Management of Information, Processes and Cooperation. Springer, Singapore, 2016.

[15] 刘娟,杨俊杰. 基于改进的 GA-BP 神经网络光伏发电短期出力预测[J]. 上海电力学院学报,2018,34(1):9-13.
LIU Juan, YANG Junjie. PV short-term output forecasting based on improved GA-BP neural network[J]. Journal of Shanghai University of Electric Power, 2018, 34(1):9-13.

[16] 李练兵,张佳,韩靖楠,等. 基于 Elman 算法的光伏阵列的短期功率预测研究[J]. 太阳能学报, 2017, 38(6): 1560-1566.
LI Lianbing, ZHANG Jia, HAN Jingnan, et al. Short-term power forecast research of PV array based on elman algorithm[J]. Acta Energiae Solaris Sinica, 2017, 38(6): 1560-1566.

[17] 钟春霞. 基于相似日选择算法和 Elman 神经网络的光伏输出功率预测[J]. 南京工程学院学报(自然科学版),2016,14(1):42-47.
ZHONG Chunxia. Output power prediction of a photovoltaic system based on similar day algorithm and elman neural network[J]. Journal of Nanjing Institute of Technology (Natural Science Edition), 2016, 14(1):42-47.

[18] 张世丰. 影响太阳能光伏发电的气象因子分析[J]. 农业与技术,2014(7):194-194.
ZHANG Shifeng. Analysis of meteorological factors affecting solar photovoltaic power generation[J]. Agriculture and Technololgy, 2014(7):194-194.

[19] 耿博,高贞彦,白恒远,等. 结合相似日 GA-BP 神经网络的光伏发电预测[J]. 电力系统及其自动化学报,2017,29(6):118-123.
GENG Bo, GAO Zhenyan, BAI Hengyuan, et al. PV generation forecasting combined with similar days and GA-BP neural network[J]. Proceedings of the CSU-EPSA, 2017, 29(6): 118-123.

[20] 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 andphotovoltaic power output forecasting[J]. Electric Power Automation Equipment, 2014, 34(9):118-122.

[21] CHEN Y, LUH P B, GUAN C. Short-term load forecasting: similar day-based wavelet neural networks[J]. IEEE Transactions on Power Systems, 2010, 25(1):322-330.

[22] 吴佳懋,李艳,符一健. 基于粗糙集-混沌时间序列 Elman 神经网络的短期用电量预测[J]. 电力系统保护与控制,2019,47(3):23-30.
WU Jiamao, LI Yan, FU Yijian. Short-term power consumption prediction based on rough set chaotic time series Elman neural network[J]. Power System Protection and Control, 2019, 47(3):23-30.

[23] LIN W M, HONG C M. A new Elman neural network-based control algorithm for adjustable-pitch variable-speed wind-energy conversion systems[J]. IEEE Transactions on Power Electronics, 2011, 26(2):473-481.

[24] PIECHOCKI J, AMBROZIAK D, PALKOWSKI A. Use of modified cuckoo search algorithm in the design process of integrated power systems for modern and energy self-sufficient farms[J]. Applied Energy, 2014, 114(114):901-908.

[25] 武小梅,林翔,谢旭泉,等. 基于 VMD-PE 和优化相关向量机的短期风电功率预测[J]. 太阳能学报,2018,39(11):3277-3285.
WU Xiaomei, LIN Xiang, XIE Xuquan, et al. Entropyandoptimized relevance vector machine[J]. Acta Energiae Solaris Sinica, 2018, 39(11):3277-3285.

[26] 高叶军,连志刚,曹宇. 基于改进布谷鸟算法的火电厂机组组合优化[J]. 电气自动化,2015,37(4):64-66.
GAO Yejun, LIAN Zhigang, CAO Yu. Optimization of unit commitment of thermal power plant based on improved Cuckoo algorithm[J]. Power System & Automation, 2015, 37(4): 64-66.

[27] 李啸骢,李春涛,从兰美,等. 基于动态权值相似日选取算法的短期负荷预测[J]. 电力系统保护与控制,2017,45(6):1-8.
LI Xiaocong, LI Chuntao, CONG Lanmei, et al. Short-term load forecasting based on dynamic weight similar day selection algorithm[J]. Power System Protection and Control, 2017, 45(6): 1-8.

[28] 甘锡淞,李云,傅成华,等. 基于信息融合和 CS-SVM 的变压器绕组变形故障诊断方法研究[J]. 电力系统保护与控制,2018,46(1):156-161.
GAN Xisong, LI Yun, FU Chenghua, et al. Information fusion and CS-SVM based research on diagnosis method for transfor-

mer winding deformation fault[J]. Power System Protection and Control,2018,46(1):156-161.

[29] 李燕青,袁燕舞,郭通. 基于 AMD-ICSA-SVM 的超短期风电功率组合预测[J]. 电力系统保护与控制,2017,45(14):113-120.
LI Yanqing,YUAN Yanwu,GUO Tong. Combination ultra-short-term prediction of wind power based on AMD-ICSA-SVM [J]. Power System Protection and Control,2017,45(14):113-120.

[30] The University of Queensland. All arrays combined [EB/OL]. [2019-10-16]. http://solar.uq.edu.au/user/repot-Power.php? pa=2-2&dtra=day&etp=n.

作者简介:



赵俊浩

赵俊浩(1993),男,硕士在读,研究方向为电力系统运行与控制等(E-mail:1213077078@qq.com);

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

张文杰(1994),男,硕士在读,研究方向为电力系统运行与控制等。

Photovoltaic power prediction based on Elman neural network with improved cuckoo algorithm

ZHAO Junhao, WU Jiekang, ZHANG Wenjie, JIN Feng, YE Huiliang, REN Dejiang

(School of Automation,Guangdong University of Technology,Guangzhou 510006,China)

Abstract: Improving the accuracy of photovoltaic power generation prediction has important significance for ensuring the security and stability of power system and improving the development and utilization of solar energy resources. A short-term power forecasting model for photovoltaic power generation is proposed in this paper. This model is based on weather similiarty degree and improved cuckoo search algorithm(ICS),which is used to optimize Elman neural network. Firstly,in order to select the similar days with higher similarity,a similarity calculation method based on distance and angle trend is proposed. Secondly, the improved cuckoo algorithm is used to optimize the weight and threshold of Elman neural network,and a short-term power prediction model for photovoltaic power generation is established. Finally, the prediction results of the proposed model is compared with the results of traditional model. The results show that the prediction accuracy of this method is higher.

Keywords:photovoltaic power prediction;weather similarity;similar days;improved cuckoo algorithm;Elman neural network

(编辑　方晶)