

DOI:10.6041/j.issn.1000-1298.2012.S0.062

光伏充气膜温室自跟踪发电系统发电量预测*

徐小力¹ 刘秋爽² 见浪护³

(1. 北京信息科技大学现代测控技术教育部重点实验室, 北京 100192; 2. 北京七星华创电子股份有限公司集成电路工艺设备研发中心, 北京 101312; 3. 冈山大学工学部自然科学学院, 冈山 700-8530)

【摘要】 针对光伏充气膜温室自跟踪发电系统提出了一种加入天气预报信息的自适应变异粒子群神经网络的发电量预测算法。首先结合历史发电量数据和气象数据分析了影响光伏充气膜温室自跟踪发电系统发电量的主要因素,建立了加入天气预报的神经网络预测模型,并针对传统神经网络预测模型中基于梯度下降的BP算法收敛慢、易陷入局部最优、训练难收敛等问题,通过自适应变异粒子群算法改进了神经网络。该算法通过将变异环节引入粒子群优化算法,进行隔代进化找到局部最优解。实验结果表明所采用的自适应变异粒子群的神经网络预测算法的全局收敛性得到了显著提高,能有效避免粒子群优化算法中的早熟收敛问题。

关键词: 光伏充气膜温室 自跟踪发电系统 发电量预测 自适应变异粒子群神经网络算法
中图分类号: TK513.4 **文献标识码:** A **文章编号:** 1000-1298(2012)S0-0305-06

Generating Capacity Prediction of Automatic Tracking Power Generation System on Inflatable Membrane Greenhouse Attached Photovoltaic

Xu Xiaoli¹ Liu Qiushuang² Mamoru Minami³

(1. Key Laboratory of Modern Measurement and Control Technology, Ministry of Education, Beijing Information Science and Technology University, Beijing 100192, China
2. IC Manufacturing Process Equipment R & D Center, Beijing Sevenstar Electronics Co., Ltd., Beijing 101312, China
3. Graduate School of Natural Science and Technology, Okayama University, Okayama 700-8530, Japan)

Abstract

A method which can forecast generating capacity of automatic tracking power system on inflatable membrane greenhouse attached photovoltaic was proposed based on the self-adaptive variation particle swarm neural network by adding with weather information. Firstly, through combining historical data of electricity production and meteorological data, the main factors of the impact on generating capacity of power generation system on inflatable membrane greenhouse attached photovoltaic was analyzed. Then, the neural network forecasting model was established by combining the weather forecast. The self-adaptive variation particle swarm algorithm was introduced to improve the training effect by tackling the problems of slowly converging, easily falling into local optimum, and difficultly converging existed in traditional neural network forecasting model based on gradient-descent BP algorithm. The neural network was optimized with adaptable mutation particle swarm optimization(AMPSO) algorithm. The mutation was put into particle swarm optimization(PSO) algorithm to find local optimal value. Experimental results showed that the entire convergence performance was significantly improved by adopting AMPSO and the premature convergence problem can be effectively avoided in PSO.

Key words Inflatable membrane greenhouse attached photovoltaic, Automatic tracking photovoltaic power generation system, Prediction of generating capacity, Self-adaptive variation particle swarm neural network algorithm

收稿日期: 2012-07-07 修回日期: 2012-07-16

* 国家自然科学基金资助项目(50975020)、国家科技重大专项资助项目(2009ZX04014-101)和北京市引进国外技术重点资助项目(B201101010)

作者简介: 刘秋爽, 博士生, 主要从事光机电一体化研究, E-mail: qiue@mail@sina.com

通讯作者: 徐小力, 教授, 博士生导师, 主要从事光机电一体化研究, E-mail: xuxiaoli@bistu.edu.cn

引言

光伏充气膜温室自跟踪发电系统由于受太阳辐射强度、电池组件温度、天气、云层和一些随机因素的影响,系统运行过程是一个非平衡的随机过程,其发电量和输出功率随机性强、波动大、不可控制,在天气突变时表现得尤为突出。这种发电方式在接入充气膜温室后必会对充气膜温室机电设备的安全和管理带来一系列的问题。所以能较为准确并提前对光伏充气膜温室自跟踪发电系统的出力做出预测尤为重要,同时也为充气膜温室实现经济安全运行、维持系统稳定及合理调度用电提供依据。

为此提出一种加入天气预报信息的基于自适应变异粒子群算法(adaptable mutation particle swarm optimization,简称 AMPSO)的神经网络光伏发电量预测算法。首先针对传统神经网络预测模型中基于梯度下降的 BP 算法收敛慢、易陷入局部最优、训练难收敛等问题,提出利用自适应变异粒子群算法改进神经网络的训练效果。该算法在变异环节引入粒子群优化算法,通过隔代进化进一步寻找局部最优解;然后分析影响光伏充气膜温室自跟踪发电系统发电量的主要因素,建立加入天气预报信息的基于 AMPSO 的神经网络的自跟踪发电系统发电量预测模型;最后基于历史发电量数据和气象数据对训练好的模型进行测试和评估。

1 基于自适应变异粒子群的神经网络算法

光伏充气膜温室自跟踪发电系统在某时间段发电量的神经网络表达式为

$$P=f\left(\sum_{i=1}^n A_i f\left(\sum_{j=1}^m a_{ij} x_j(k)\right)\right) \tag{1}$$

式中 A_i ——隐含层与输出层间权值
 n ——隐含层节点数
 m ——输入层节点数
 a_{ij} ——输入层与隐含层间权值
 $x_j(k)$ ——输入变量

光伏充气膜温室自跟踪发电系统的基于神经网络的发电量预测算法,目标函数值为实测功率与预测功率的最小平方差,通过不断调整权值 a_{ij} ,直到网络输出误差收敛,寻找到最优权值 a_{ij} 。

梯度下降法是神经网络的常见训练方法,但是这种算法非常依赖于初始权值的选择,且实际运用中训练速度较慢且易陷入局部极小值而达到早熟,直接影响着神经网络的非线性逼近与泛化能力。

粒子群算法的优点在于收敛速度快,不需要计算目标函数的最佳梯度下降,减轻了计算的负担,但

是仍然容易陷入局部极小值^[1-2]。针对这个缺陷,本文将变异与进化的思想加入到粒子群优化算法中,这种 AMPSO 可以在有限时间内最大化搜索全局最优值。

1.1 自适应变异粒子群算法

粒子群优化算法(particle swarm optimization,简称 PSO)是模拟鸟类捕食行为的群体智能算法,是一种全局优化进化算法^[3]。由于 PSO 优化算法容易实现,需要调整的参数少,一经提出就受到了研究者的重视,被广泛应用到各个领域,已经成功地用于系统辨识、神经网络训练等。

PSO 算法同遗传算法(GA)类似,是一种迭代的优化工具,系统初始化为一组随机解,通过迭代搜寻最优解,但是并没有 GA 的交叉及变异,而是粒子在解空间中追随最优的粒子进行搜索。同 GA 相比,PSO 算法的优势在于简单容易实现,能够记忆个体最优和全局最优信息,但是 PSO 优化算法同 GA 等其他全局优化算法一样,同样存在早熟收敛现象,尤其是在比较复杂的多峰搜索问题中,很容易陷入一个局部最优值^[4]。目前解决这一问题的主要方法是增加粒子群的规模,但仍不能从根本上克服早熟收敛和计算量大的问题^[5]。

为了克服这一问题,将 GA 中变异的过程和进化算法的思想引入到自适应粒子群算法中,形成 AMPSO 算法,其寻优过程是对代表最优解的粒子在局部进行位置调整。根据以往的寻最优解的经验,适应度最好的解往往是被包围在大量的次最优解之中,因此很多时候,次最优解被寻找出来,而真正的最优解往往就在附近。因此在 AMPSO 算法中就很有必要加上一步针对局部小范围寻找最优的进化算法。

假设在一个 d 维的目标搜索空间中有 n 个粒子,则粒子 i 的位置矢量和速度矢量可以表示为

$$\begin{cases} \mathbf{X}_i = [x_{i1}, x_{i2}, \cdots, x_{id}] \\ \mathbf{V}_i = [v_{i1}, v_{i2}, \cdots, v_{id}] \end{cases} \quad (i = 1, 2, \cdots, n) \tag{2}$$

待求问题初始化为一群随机粒子,每个粒子在搜索空间中“飞翔”,可以根据目标函数 $f(\cdot)$ 来计算它的适应度。通过迭代找到最优解。在迭代过程中,粒子通过跟踪两个极值不断调整自己的位置,进行更新。第一个就是粒子 i 本身所找到的个体最优解(即粒子 i 到目前为止自身搜索到的最好的适应度位置),记为 $\mathbf{P}_{ibest}$,用向量 $\mathbf{P}_i = [p_{i1}, p_{i2}, \cdots, p_{id}]$ 来记录此位置;另一个极值是整个种群目前所找到的全局最优解(即全局所有粒子最好的适应度位置),记为 $\mathbf{P}_{gbest}$,用向量 $\mathbf{P}_g = [p_{g1}, p_{g2}, \cdots, p_{gd}]$ 来记录此位置。

在找到这个最优值时,粒子更新自己的速度和新位置为

$$\begin{cases} v_{ij}(k+1) = wv_{ij}(k) + c_1 r_1 (p_{ij}(k) - x_{ij}(k)) + \\ c_2 r_2 (p_{gj} - x_{ij}(k)) \\ x_{ij}(k+1) = x_{ij}(k) + v_{ij}(k+1) \end{cases} \quad (1 \leq i \leq n, 1 \leq j \leq d) \quad (3)$$

式中 i ——粒子标号 w ——惯性因子

k ——迭代步数

c_1, c_2 ——加速因子,取 $c_1 = c_2 = 2$

r_1, r_2 —— $[0, 1]$ 之间的随机数

其中 w 值随着最优适应度变化率 K 来改变,二者的表达式为

$$K = \frac{|f(t) - f(t-5)|}{|f(t)|} \quad (4)$$

$$w = \begin{cases} 0.6 + r/2 & (K \geq 0.05) \\ 0.2 + r/2 & (K < 0.05) \end{cases} \quad (5)$$

式中 r ——均匀分布于 $[0, 1]$ 之间的随机数

$f(t)$ ——种群迭代的最优适应度

$f(t-5)$ ——种群第 $t-5$ 代的最优适应度

第 d 维的位置变化范围和速度变化范围分别为 $[-x_{j,\max}, x_{j,\max}]$ 和 $[-v_{j,\max}, v_{j,\max}]$,迭代中若某一维的 x_{ij} 或 v_{ij} 超过边界则取边界值。

当粒子群进化到一定的步数, $P_{g\text{best}}$ 在较长时间未发生变化时,所有粒子都会向这个具有最优位置的粒子靠拢,若该最优粒子并非全局最优解,则粒子群算法会陷入局部极值点。因此当种群进化到一定的程度,执行变异可以提高种群的多样性,而变异后的粒子会进入全局其他区域进行搜索,如此循环,在以后的进化过程就有可能发现新的最优解^[6]。

为了表示群内所有粒子到历史最佳位置 $P_{g\text{best}}$ 的最大空间距离,定义粒子群半径为

$$R = \max_{i=1,2,\dots,n} \left(\sqrt{\sum_{d=1}^D (p_{gd} - x_{id})^2} \right) \quad (6)$$

当 R 小于极限值或者全局最优解 $P_{g\text{best}}$ 在较长时间(如 15 步)无明显变化时,则对种群中粒子按照一定的概率 p_m 执行变异操作。具体的操作方法为:首先对最优粒子外的 $n-1$ 个粒子进行适应度排序,然后产生 $n-1$ 个随机分布于 $[0, 1]$ 之间的随机数 $r_i (i=1, 2, \dots, n-1)$,如果 $r_i < p_m (p_m < 0.3)$,则按照式(5)对粒子产生新的位置,否则保留粒子当前位置^[7~8]。编译后新的位置为

$$\tilde{x}_{id} = x_{id} (1 + 0.5\eta) \quad (7)$$

式中 η ——服从柯西分布函数的随机变量

x_{id} —— d 维的数值

搜索在全局最优解 $P_{g\text{best}}$ 的邻域可能的最优解的公式为

$$\Delta P = m \Delta P_n + (1 - m) g P_n \quad (m = 0.5) \quad (8)$$

$$P_{n+1} = P_n + \Delta P_{n+1} \quad (9)$$

式中 g —— $[0, 0.1]$ 之间的随机数

P_n ——粒子 $P_{g\text{best}}$ 在第 n 代的向量值

粒子 $P_{g\text{best}}$ 从第 n 代进化到 $n+1$ 代后,若此时的 P_{n+1} 适应度比上一代更好,则用 P_{n+1} 代替 P_n ,否则, P_n 的值保持不变,如此循环直至达到进化上限步数为止。

AMPSO 算法实现的流程如下所示:

Begin

(1) 随机初始化种群中各粒子的速度、位置以及各种参数。

(2) 根据适应度函数计算各粒子的适应度。

(3) 存储各粒子的位置和适应度于个体极值中,将所有个体极值中适应度最优的个体的位置和适应度存储于全局极值中。

While(终止条件不满足) do

(4) 按式(3)更新各粒子的速度和位置。

(5) 根据式(6)的 R 和 $P_{g\text{best}}$,决定是否变异,需要变异则根据式(9)进行变异。

(6) 判断是否达到最大迭代次数,没有达到最大次数则返回步骤(2),根据适应度函数重新计算各粒子的适应度。

(7) 获取更新粒子的个体极值 P_{ibest} 和全局极值 $P_{g\text{best}}$,根据式(8)和(9)进行进化。

(8) 判断 P_{n+1} 和 P_n 谁最优,如果 P_{n+1} 最优,则用 P_{n+1} 代替 P_n ,否则 P_n 保持不变。

(9) 判断是否达到最大迭代次数,没有达到则返回步骤(7)获取更新粒子的个体极值 P_{ibest} 和全局极值 $P_{g\text{best}}$ 。

EndWhile

记录全局极值等数据。

End

1.2 基于 AMPSO 的神经网络算法

对于神经网络来说,主要的工作是动态调整网络的权重,使得输出的均方误差能量最小。对于 AMPSO 算法来说,主要的工作过程是不断更新粒子的速度和位置,更新的依据是适应度函数的计算结果(粒子的适应度)。因此,可以利用神经网络的权重和阈值来构成粒子的位置矢量,利用均方误差能量函数作为粒子群的适应度函数,即粒子群中第 k 个粒子的维数为

$$X_k = [w_{ij}, v_{jt}, \theta_j, \gamma_i]$$

$$(i = 1, 2, \dots, I; j = 1, 2, \dots, J; t = 1, 2, \dots, T) \quad (10)$$

式中 I ——输入层节点数

J ——隐含层节点数
 T ——输出层节点数
 w_{ij}, v_{jt} ——输入层、中间层和隐含层之间的连接权值
 θ_j, γ_t ——隐含层和输出层的阈值

以各层之间的连接权值和阈值确定的网络输出与期望值的方差作为种群的适应度函数,即

$$J(t) = \frac{1}{N} \sum_{j=1}^N (y_j(t) - \hat{y}_j(t))^2 \quad (11)$$

式中 N ——训练样本数
 $\hat{y}_j(t)$ ——第 t 次迭代第 j 个训练样本输入的网络实际输出
 $y_j(t)$ ——期望输出值

AMPSO 训练神经网络的步骤为:①根据问题确定神经网络结构。②根据式(10)确定粒子的维数。③根据式(11)确定粒子群的适应度函数。④随机初始化粒子群。⑤用 AMPSO 算法训练神经网络,直到满足停止准则。⑥输出最优粒子。

2 影响光伏充气膜温室自跟踪系统发电量的各种因素

对光伏充气膜温室自跟踪发电系统的发电量进行准确预测,必须实测光伏充气膜温室自跟踪发电系统所在区域主要气象参数和光伏自跟踪发电站电气参数,如图 1 所示。




图 1 影响光伏充气膜温室自跟踪发电系统发电量的因素
Fig.1 Factors affected PV inflatable membrane greenhouse track generation system generating capacity

光伏充气膜温室自跟踪发电系统的太阳能电池板的类型不同,转换效率也不同,直接影响系统的发电量。一般来讲,单晶硅电池转换效率高,但成本高;而多晶硅电池转换效率虽略低于单晶硅电池,但性价比高;聚光电池转换效率较高,但是制造成本仍较高,受聚光温度及环境因素影响大。

对于制作好的单晶硅太阳能电池组件,根据太阳能光伏电池的特性分析,可知光伏电池的开路电压、填充因子、输出功率随组件温度的升高,都有所下降;短路电流随组件温度的升高,略有增加。

光伏充气膜温室自跟踪发电系统的太阳能电池板温度、大气温度等也直接影响太阳能电池的发电量。尽管光伏自跟踪系统不同类型太阳能电池板的温度特性存在差异,但都具有随着温度的上升,转换效率降低,输出功率下降的特性。

光伏充气膜温室自跟踪发电系统具有不同内部配线的同样面积的 2 块太阳能电池板,在其他外界条件相同情况下,即使 2 块太阳能电池板上有同样形状、同样面积的阴影,也会造成发电量上的差异。当电池组按照横向串联配线,如图 2 所示,在阴影下只有一个串联回路受影响,其他串联回路的电池组发电量基本不受影响。而当电池组按照竖向串联配线时,如图 3 所示,每个串联回路的输出电压都会受到阴影遮挡而降低,电流也都随之发生变化,导致整体发电功率输出较前者少。




图 2 横向串联配线
Fig.2 Transverse series wiring




图 3 竖向串联配线
Fig.3 Vertical series wiring

光伏充气膜温室自跟踪发电系统的光伏阵列接收到的日照量大小直接影响系统发电量,日照量越大,发电量越多。日照强度与季节、时间、光伏充气膜温室自跟踪发电系统所处地理位置有直接的关系。夏季日照时间较长,发电量较多;冬季日照时间短,发电量少。一天中通常正午太阳高度角较大,到达的日照量较大,发电量也会较多。纬度越低的地区,太阳入射角越大,日照强度越大,发电量也会越大。

光伏充气膜温室自跟踪发电装置跟踪太阳方位的精确度(影响太阳能电池板方位角和倾斜角)和设置场所的选取也是影响系统发电量的重要因素。

天气和周边环境的因素也不可忽略。阴雨天和雪天,日照量少,发电量会受到抑制。光伏充气膜温室自跟踪发电系统的太阳能电池板周边建筑物、树

本的阴影也会对发电量产生影响。阴影的面积、形状、浓度不同,影响程度也不同。

此外,太阳能电池板上的异物等都会对实际发电量造成影响。

3 基于 AMPSO 神经网络的光伏发电量预测模型

神经网络能够逼近任意复杂的非线性函数,但随着问题复杂程度的增加,训练一个复杂网络所需的样本量和学习时间都急剧增加,而且得到的复杂网络往往并不能揭示问题的层次和结构。一种有效的办法是利用模块化思想,把一个复杂的模型分解成几个简单的子模型,分别用几个网络去模拟。既简化了模型,方便了网络的训练,又有利于提高模型的预测精度。

因为本文着重于同一个光伏充气膜温室自跟踪发电系统的短期发电量预测,所以只考虑将前一天发电量、天气情况、气温、风速和预测日的天气情况、气温和风速作为预测模型的输入变量。在北京地区光伏充气膜自跟踪发电系统的工作时间平均在 11 h/d 左右,从早晨 7:00 开始采集,以后每过 1 h 再记一次,直到晚上 17:00,总共采集 11 h 的发电量。因此构成的 BP 神经网络如图 4 所示。




图 4 预测模型拓扑结构
Fig. 4 Prediction model topology

(1) 输入层节点

输入层节点对应于模型的输入变量,本模型采用 19 个输入变量。由于处于夜间的 13 个时间点光伏阵列的电量为零,故选取白天的 11 个发电时间序列作为预测模型的 11 个输入量,前一天的天气类型、最高气温、最低气温、风速和预测日的天气类型、最高气温、最低气温、风速作为预测模型的 8 个输入量,即: $X_1 \sim X_4$ 为预测日的天气类型、最高气温、最低气温和风速; $X_5 \sim X_8$ 为前一天的天气类型、最高气温、最低气温和风速; $X_9 \sim X_{19}$ 为前一天 11 h 的发电量,这里既可以是累积发电量,也可以是小时发电量。

(2) 输出层节点

发电量模型预测的是未来一天白天 11 h 的发电量,因此输出端采用 11 个输出节点,即 $Y_1 \sim Y_{11}$ 为预测日的 11 h 的发电量。

(3) 隐层及隐节点数

输入层节点数为 19,输出层节点数为 11,隐层节点数设定为 27。

4 验证分析

将 AMPSO 神经网络应用于光伏充气膜温室自跟踪发电系统的发电量预测问题时,训练网络的原始数据中,不同的变量通常以不同的单位变化,数量级的差异也比较大,光伏充气膜温室自跟踪发电系统发电量的数值变化范围在 0 ~ 100 kW·h 之间,而气温通常的数值变化范围则在 -15 ~ 50℃ 之间。由神经元激活函数的特性可以知道,神经元的输出通常被限制在一定的范围内,大多数人工神经网络的应用中使用的非线性激活函数为 S 函数,其输出被限定在 (0,1) 或 (-1,1) 之间,直接以原始数据对网络进行训练会引起神经元饱和,因此在对网络进行训练之前必须对数据进行预处理,以消除原始数据形式不同所带来的不利,通常的做法是归一化处理^[9-10]。然后采用 AMPSO 算法对神经网络进行训练与测试。

为了验证提出的加入了天气预报信息的基于 AMPSO 的神经网络的光伏充气膜温室自跟踪发电系统的光伏发电量预测方法,利用 Matlab 实现基于 AMPSO 的神经网络的学习算法和迭代过程,利用光伏充气膜温室自跟踪发电的远程测控系统数据库中的历史发电数据和气象数据进行建模预测,样本数据是冬季 11 ~ 12 月份的发电量数据,前 70% 的左右的样本点用来训练,后 30% 左右的样本点用来进行该方法的验证。

为了将基于 AMPSO 的神经网络的自跟踪光伏发电量预测方法与基于神经网络的自跟踪光伏发电量预测方法进行比较,在相同的外部条件下,使用相同的数据,在预测模型中使用传统的梯度下降法与 AMPSO 算法进行训练与测试。两种方法的预测结果分别如表 1 与图 5 所示。

从图 5 中可以看出,本文提出的预测方法的预测发电量曲线能够跟踪实际发电量曲线,二者有更好的拟合关系,且从图 5 和表 1 可看出,本文算法比传统 BP 算法的波动范围明显要小,这说明 AMPSO 算法比传统 BP 算法在训练神经网络过程中输出误差的范围更小,从而能够得到更精确的预测值。这也证明了本文提出方法的精确性与优越性。

表 1 实测发电量和预测发电量对比

当地 时间		forecast generation capacity kW·h			
		基于 BP 神经		基于 AMPSO	
		网络	神经网络	神经网络	神经网络
	实际 发电量	预测发 电量	预测 误差	预测 发电量	预测 误差
7:20~8:20	2.450	2.660	0.210	2.550	0.100
8:20~9:20	4.950	5.655	0.705	5.520	0.570
9:20~10:20	6.650	7.615	0.965	7.200	0.550
10:20~11:20	8.200	8.565	0.365	8.100	-0.100
11:20~12:20	8.550	8.700	0.150	8.600	0.050
12:20~13:20	8.500	8.560	0.060	8.520	0.020
13:20~14:20	7.300	7.710	0.410	7.200	-0.100
14:20~15:20	6.100	5.100	-1.000	5.980	-0.120
15:20~16:20	6.000	4.900	-1.100	5.850	-0.150
16:20~17:20	2.000	2.600	0.600	1.900	-0.100
17:20~18:20	1.320	1.360	0.040	1.340	0.020




图 5 实测发电量和预测发电量对比

Fig.5 Measured power generation and forecast generation capacity

5 结论

(1)基于 AMPSO 的神经网络发电量预测模型考虑的因素较多,而所需样本数据相对多元线性回归模型较少,模型只需要一组输入输出样本,无需输入输出变量具有确定的关系,因而大大简化了建模的过程。

(2)针对光伏充气膜温室自跟踪发电系统光伏发电不确定性对配电系统的影响,可对不同天气、季节下的样本数据进行划分,考虑自跟踪光伏发电系统和气象部门天气预报的相关性,建立不同的训练样本,在不同的天气、季节对光伏系统发电量做出预测。

(3)对一些随机非线性问题,实践证明基于 AMPSO 的神经网络处理有较好的优势,用该模型预测自跟踪光伏发电系统的发电量,误差最小,有力地提高了自跟踪光伏发电系统光伏发电的稳定性和供电可靠性。该模型还可随时更换训练样本数据,不断注入新的测试数据,以提高精度,解决了传统神经网络预测模型中基于梯度下降的 BP 算法收敛慢、易陷入局部最优、训练难收敛等问题。

(4)提出的加入天气预报信息的基于 AMPSO 的神经网络的预测光伏发电量方法的实现过程相对繁琐,但是在发电量有较强随机性的情况下,提高了预测精度,证明了此预测方法的有效性和可行性。

参 考 文 献

1 Bashir Z A, Eihawary M E. Applying wavelets to short-term load forecasting using PSO-based neural networks[J]. IEEE Transactions on Power Syst., 2009, 24(2): 20~27.

2 刘波. 粒子群优化算法及其工程应用[M]. 北京: 电子工业出版社, 2010.

3 Kennedy J, Eberhart R C. Particle swarm optimization[C]//Proc. IEEE International Conference on Neural Networks, 1995, 4: 1 942~1 948.

4 Amjady N, Keynia F. Short-term load forecasting of power systems by combination of wavelet transform and neural evolutionary algorithm[J]. Energy, 2009, 34(1): 46~57.

5 Cleer M, Kennedy J. The particle swarm-explosion, stability and convergence in a multidimensional complex space[J]. IEEE Transactions on Evolutionary Computation, 2002, 6(1): 58~73.

6 张珣,颜文俊,王超. 基于 AMPSO 算法与神经网络的风电场发电量预测[J]. 华东电力, 2011(5): 797~802. Zhang Xun, Yan Wenjun, Wang Chao. Prediction study of wind energy based on AMPSO algorithm and neural network[J]. East China Electric Power, 2011(5): 797~802. (in Chinese)

7 吕振肃,侯志荣. 自适应变异的粒子群优化算法[J]. 电子学报, 2004,32(3): 416~420. Lü Zhensu, Hou Zhirong. Particle swarm optimization with adaptive mutation[J]. Acta Electronic Sinica, 2004,32(3): 416~420. (in Chinese)

参 考 文 献

1 刘军,刘伟军,王天然,等. 基于常规 PID 和风门开关控制的 PCR 基因芯片温度快速跟踪算法的研究[J]. 仪表技术与传感器,2008(10): 72 ~ 73,105.
Liu Jun, Liu Weijun, Wang Tianran, et al. Algorithm for PCR gene-chip temperature-tracking based on regular PID and ventilator door on-off control[J]. Instrument Technique and Sensor, 2008(10): 72 ~ 73,105. (in Chinese)

2 贾晓宇,牛志强,张卫平,等. 微型聚合酶反应芯片的精确温度控制[J]. 微计算机信息(测控自动化),2005,21(8 ~ 1):6 ~ 8.
Jia Xiaoyu, Niu Zhiqiang, Zhang Weiping, et al. Precise temperature control of a micro PCR chip[J]. Microcomputer Information, 2005,21(8 ~ 1):6 ~ 8. (in Chinese)

3 Lin Y C, Yang C C, Huang M Y. Simulation and experimental validation of micro polymerase chain reaction chips[J]. Sensors and Actuators B, 2000, 71(1 ~ 2): 127 ~ 133.

4 El-Ali J, Perch-Nielsen I R. Simulation and experimental validation of a SU - 8 based PCR thermo cycler chip with integrated heaters and temperature sensor[J]. Sensors and Actuators A, 2004, 110(1 ~ 3): 3 ~ 10.

5 Shin Y S, Cho K C. PDMS-based micro PCR chip with parylene coating [J]. Journal of Micromechanics and Microengineering, 2003,13(5): 768 ~ 774.

6 Yoon D S, Lee Y S, Lee Y, et al. Precise temperature control and rapid thermal cycling in a micro machined DNA polymerase chain reaction chip[J]. Journal of Micromechanics and Microengineering, 2002, 12(6): 813 ~ 823.

7 毕雪芹,倪原,王丽娟. PCR 温度模糊 PID 控制器的设计及仿真[J]. 计算机工程与设计,2008,29(10): 2 604 ~ 2 606.
Bi Xueqin, Ni Yuan, Wang Lijuan. Design and simulation of PCR temperature fuzzy PID control[J]. Computer Engineering and Design, 2008,29(10): 2 604 ~ 2 606. (in Chinese)

8 李宁,倪原,孙金龙,等. 改进的 PCR 仪模糊 PID 温度控制算[J]. 生命科学仪器,2009, 7(5):29 ~ 31.
Li Ning, Ni Yuan, Sun Jinlong, et al. Modified fuzzy-PID temperature control algorithm of PCR machine[J]. Life Science Instruments, 2009, 7(5):29 ~ 31. (in Chinese)

9 Zhao Weihua, Zhang Min, Li Yan, et al. Research and exploit on PCR apparatus[C] // IEEE International Conference on BioMedical Engineering and Informatics, 2008,2:676 ~ 680.

10 苏明,陈伦军,林浩. 模糊 PID 控制及其 MATLAB 仿真[J]. 现代机械,2004(5): 51 ~ 55.

11 刘金琨. 先进 PID 控制 MATLAB 仿真[M]. 2 版. 北京:电子工业出版社,2007.

12 张国良,曾静,柯熙政,等. 模糊控制及其 Matlab 应用[M]. 西安:西安交通大学出版社,2002.

13 王沫然. Simulink4 建模及动态仿真[M]. 北京:电子工业出版社,2002.

(上接第 310 页)

8 滕奇志,唐棠,李征骥,等. 基于粒子群优化的岩石薄片三维图像重建[J]. 电子与信息学报, 2011, 33(8): 1 871 ~ 1 876.
Teng Qizhi, Tang Tang, Li Zhengji, et al. Three-dimensional reconstruction of sandstone section image based on particle swarm optimization[J]. Journal of Electronics & Information Technology, 2011, 33(8): 1 871 ~ 1 876. (in Chinese)

9 陈昌松,段善旭,殷进军. 基于神经网络的光伏阵列发电预测模型的设计[J]. 电工技术学报, 2009,24(9): 153 ~ 158.
Chen Changsong, Duan Shanxu, Yin Jinjun. Design of photovoltaic array power forecasting model based on neural network [J]. Transactions of China Electrotechnical Society, 2009,24(9): 153 ~ 158. (in Chinese)

10 张兵,孙旭,高连如,等. 一种基于离散粒子群优化算法的高光谱图像端元提取方法[J]. 光谱学与光谱分析, 2011, 31(9): 2 455 ~ 2 461.
Zhang Bing, Sun Xu, Gao Lianru, et al. A method of end member extraction in hyperspectral remote sensing images based on discrete particle swarm optimization(D-PSO) [J]. Spectroscopy and Spectral Analysis, 2011, 31(9): 2 455 ~ 2 461. (in Chinese)