## Journal of System Simulation

Volume 28 | Issue 5

Article 8

7-3-2020

## Hybrid Quantum-Behaved Particle Swarm Optimization for Parameter Identification of DFIG

Yingying Jiang Key Laboratory of Advanced Process Control for Light Industry, Jiangnan University, Wuxi 214122, China;

Zhicheng Ji Key Laboratory of Advanced Process Control for Light Industry, Jiangnan University, Wuxi 214122, China;

Follow this and additional works at: https://dc-china-simulation.researchcommons.org/journal

Part of the Artificial Intelligence and Robotics Commons, Computer Engineering Commons, Numerical Analysis and Scientific Computing Commons, Operations Research, Systems Engineering and Industrial Engineering Commons, and the Systems Science Commons

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

# Hybrid Quantum-Behaved Particle Swarm Optimization for Parameter Identification of DFIG

#### Abstract

Abstract: In order to ensure the accuracy of the doubly-fed wind power generator (DFIG) and improve the control performance of the generator, a hybrid quantum-behaved particle swarm optimization for parameter identification was proposed. A parameter identification model of DFIG at coordinate was established. Quantum-behaved particle swarm optimization (QPSO) was improved and then mixed with simulated annealing (SA) algorithm. The proposed algorithm was compared with particle swarm optimization (PSO), QPSO and improved QPSO, which were applied to parameter identification of DFIG in Matlab/Simulink. Simulation results show that the proposed algorithm can improve the identification accuracy of the five parameters including stator resistance, stator inductance, rotor resistance, rotor inductance, and mutual inductance of stator and rotor.

#### Keywords

DFIG, parameter identification, QPSO, SA, hybrid algorithm

#### **Recommended Citation**

Jiang Yingying, Ji Zhicheng. Hybrid Quantum-Behaved Particle Swarm Optimization for Parameter Identification of DFIG[J]. Journal of System Simulation, 2016, 28(5): 1054-1062.

第28卷第5期 2016年5月

## 基于混合量子粒子群算法的 DFIG 参数辨识

蒋莹莹, 纪志成

(江南大学轻工过程先进控制教育部重点实验室, 江苏 无锡 214122)

摘要:为了确保双馈感应发电机(Doubly Fed Induction Generator, DFIG)参数的准确性,提高发电机的控制性能,提出了基于混合量子粒子群算法的参数辨识方法。在 dq 坐标系下建立了 DFIG 参数 辨识的模型。对量子粒子群算法进行改进并与模拟退火算法进行混合,得到混合量子粒子群辨识算法。在 Matlab/Simulink 中将所提出的混合算法用于 DFIG 的参数辨识,并与粒子群算法、量子粒子群算法和改进量子粒子群算法进行了对比验证。仿真结果表明所提出的算法能提高定子电阻、定子电感、转子电阻、转子电感以及定转子互感五个参数的辨识精度。

**关键词:**双馈风力发电机;参数辨识;量子粒子群算法;模拟退火算法;混合算法 中图分类号: TP391.9 文献标识码: A 文章编号: 1004-731X (2016) 05-1054-09

#### Hybrid Quantum-Behaved Particle Swarm Optimization for Parameter Identification of DFIG

Jiang Yingying, Ji Zhicheng

(Key Laboratory of Advanced Process Control for Light Industry, Jiangnan University, Wuxi 214122, China)

**Abstract:** In order to ensure the accuracy of the doubly-fed wind power generator (DFIG) and improve the control performance of the generator, a hybrid quantum-behaved particle swarm optimization for parameter identification was proposed. A parameter identification model of DFIG at dq coordinate was established. Quantum-behaved particle swarm optimization (QPSO) was improved and then mixed with simulated annealing (SA) algorithm. The proposed algorithm was compared with particle swarm optimization (PSO), QPSO and improved QPSO, which were applied to parameter identification of DFIG in Matlab/Simulink. Simulation results show that the proposed algorithm can improve the identification accuracy of the five parameters including stator resistance, stator inductance, rotor resistance, rotor inductance, and mutual inductance of stator and rotor.

Keywords: DFIG; parameter identification; QPSO; SA; hybrid algorithm

### 引言

目前双馈感应发电机(Doubly Fed Induction Generator, DFIG)已经较为广泛的应用于风力发电系统。在风力发电系统中发电机的控制技术是比较



收稿日期:2015-07-10 修回日期:2015-09-29; 基金项目:国家高技术研究发展计划(2013AA040405); 作者简介:蒋莹莹(1992-),女,江苏南通,硕士,研 究方向为电力电子及电力传动:纪志成(1959-),男, 浙江杭州,教授,博士,博导,研究方向为电力电子 及电力传动、绿色制造物联应用技术等。 核心的环节,矢量控制等电机控制技术在一定程度 上提高了电机的控制性能。为了得到高性能的控制 效果,准确的风力涡轮发电机(Wind Turbine Generator,WTG)模型和参数对于一些风机的控制 算法至关重要,文献[1-2]介绍了WTG模型的建立。

然而,由于一些实际原因模型参数并不总是可用,我们通常用确定的参数来代替涡轮机的未知参数进行分析,但可能会导致明显的分析误差。另一种方法是通过系统的辨识过程来获得这些参数<sup>[3-4]</sup>。在这过程中,先在一定的干扰下,测量出

http://www.china-simulation.com

第28卷第5期 2016年5月

风力涡轮机的响应数据,然后利用所测量的数据进 行参数辨识估计。非线性最小二乘拟合算法[5-6]、 扩展卡尔曼滤波法[7]和模型参考自适应法[8]等传统 方法都是非常有效的参数识别方法,但对多参数辨 识有一定的困难。近年来,有学者提出将遗传算法, 微变搜索算法,蚁群算法和粒子群算法等<sup>[9-12]</sup>智能 算法应用到电机参数辨识中。文献[9]在αβ坐标系 下建立了DFIG的参数辨识模型,提出了遗传算法, 并采用分步辨识策略,分别辨识出所需要的电机的 各个参数。针对辨识结果不精确和辨识初值不稳定 的问题, 文献[10]提出了基于优选初值-微变搜索算 法的 DFIG 参数辨识方法, 仿真证明该算法能精确 的辨识电机的参数。文献[11]中金宇清等提出了蚁 群算法,并将其应用于 DFIG 参数辨识中,仿真并 验证了该算法的有效性。文献[12]在对 DFIG 参数 辨识过程中,采用的是改进粒子群算法,对全局最 优位置进行了变异,参数辨识精度有所提高。

本文首先介绍了DFIG风力发电系统的模型以 及 DFIG 在 dq 坐标系下的数学模型,由于 DFIG 的数学模型相对复杂,所需要辨识的参数也较多。 因此本文在此基础上提出了DFIG的多参数辨识模 型,通过一些容易测量的电压、电流和转速等数据, 能同时实现对5个参数的准确辨识。粒子群算法具 有收敛速度快、容易实现等特点,在参数辨识等其 他工程领域得到广泛应用,但是该算法在进化后期 易陷入局部最优:相比于粒子群算法,量子粒子群 优化算法具有控制参数少,全局收敛性能更好等优 点,但是仍然容易陷入局优;因此本文采用的是混 合量子粒子群优化算法,该算法在量子粒子群算法 中引入了新的协同因子,与模拟退火算法混合后能 更快的跳出局部最优解。仿真验证可知该方法相比 于其他算法在DFIG的参数辨识过程中有着更快的 辨识速度与更高的辨识精度。

#### 1 DFIG 的模型

#### 1.1 风能转换模型

典型 DFIG 风力发电系统的结构图如图 1 所示,其中风力涡轮机通过传动系与绕线组感应电机

的转子相连接。感应电机的定子直接与电网相连接,向其提供电能;感应电机的转子通过用于控制转子速度的 AC-DC-AC 频率转换器连接到电网。



图 1 基于 DFIG 的风力发电系统基本结构图

风机虽然有很多种,但其作用都是将风能转换 成机械能,最终的输出功率可以用以下2个公式来 表示:

$$P_m = C_p P_{\text{wind}} = \frac{1}{2} C_p(\lambda, \beta) \rho \pi R_w^2 v^3$$
(1)

$$\lambda = \frac{R_w \omega_w}{v_w} \tag{2}$$

式(1)中 $P_m$ 为风力机的输出机械功率; $C_p$ 为风能的 利用系数; $\rho$ 为空气密度; $R_w$ 为风力机叶轮的半 径;v为空气进入风力机扇叶前的风速; $\lambda$ 为叶尖 速比; $\omega_w$ 为风力机角速度; $v_w$ 为风速。由式(2) 可知,风力机捕获的风功率由风能利用系数 $C_p$ 和 风速决定,当风速一定时,风力机的输出功率就只 于 $C_p$ 有关。 $C_p$ 的值取决于叶尖速比及桨距角,如 式(3)所示。根据贝兹理论, $C_p$ 最大值为 0.59。

 $C_{p}(\lambda,\beta) = C_{1}(C_{2} / \lambda_{1} - C_{3}\beta - C_{4})e^{-C_{5}/\lambda_{1}} + C_{6}\lambda \quad (3)$   $\pm \psi, \frac{1}{\lambda_{1}} = \frac{1}{\lambda + 0.08\beta} - \frac{0.035}{\beta^{2} + 1}; C_{1} = 0.5176; C_{2} = 116;$  $C_{3} = 0.4; \quad C_{4} = 5; \quad C_{5} = 21; \quad C_{6} = 0.0086 \circ$ 

#### 1.2 DFIG 的数学模型

DFIG 具有高阶性、非线性、强耦合性、多变 量等特点,因此,建模时通常假设:(1) 忽略铁损; (2) 电机三相绕组对称;(3) 忽略频率和温度对绕 组的影响;(4) 忽略磁路饱和对绕组的影响。DFIG 在任意速旋转坐标系中的数学模型如下所示:

磁链方程:

第 28 卷第 5 期	系统仿真学报	Vol. 28 No. 5
2016年5月	Journal of System Simulation	May, 2016
$(y_i - I_i) + I_i$	$\begin{pmatrix} \uparrow & (I + 1) & f(f + 1) \end{pmatrix}$	$1^2$ $t$ $t$ $1^2$ $(1)$

$$\begin{cases} \psi_{ds} = L_s i_{ds} + L_m i_{dr} \\ \psi_{qs} = L_s i_{qs} + L_m i_{qr} \\ \psi_{dr} = L_m i_{ds} + L_r i_{dr} \\ \psi_{qr} = L_m i_{qs} + L_r i_{qr} \end{cases}$$
(4)

其中, $\psi_{ds}$ , $\psi_{qs}$ , $\psi_{dr}$ , $\psi_{qr}$ 分别为定子转子磁链的 d,q轴上的分量; $i_{ds}$ , $i_{dr}$ , $i_{qs}$ , $i_{qr}$ 定子转子电流的 d,q轴上的分量; $L_m$ 为定转子间的互感; $L_s$ , $L_r$ 分别为dq坐标系中定子转子自感。

电压万程:  

$$\begin{bmatrix}
u_{ds} = R_{s}i_{ds} + D\psi_{ds} - \omega\psi_{qs} \\
u_{qs} = R_{s}i_{qs} + D\psi_{qs} + \omega\psi_{ds} \\
u_{dr} = R_{r}i_{dr} + D\psi_{dr} - (\omega - \omega_{r})\psi_{qr} \\
u_{qr} = R_{r}i_{qr} + D\psi_{qr} + (\omega - \omega_{r})\psi_{dr}
\end{bmatrix} (5)$$

其中,  $u_{ds}$ ,  $u_{dr}$ ,  $u_{qs}$ ,  $u_{qr}$ 为定子转子电流的 d, q 轴上的分量,  $\omega$ 为定子角速度,  $\omega$ 为转子角速度。

转矩和运动方程:

$$T_e = n_p L_m (i_{qs} i_{dr} - i_{ds} i_{qr}) \tag{6}$$

式(4)~(6)组成了 DFIG 在 dq 坐标系中的数学模型, 取电流和转子转速作为状态量,可推导出 DFIG 的 状态方程:

$$\begin{cases} \frac{di_{ds}}{dt} = \frac{1}{L_m^2 - L_s L_r} [((\omega - \omega_r)L_m^2 - \omega L_s L_r)i_{qs} + \\ R_s L_r i_{ds} - R_r L_m i_{dr} - \omega_r L_r L_m i_{qr} - \\ L_r u_{ds} + L_m u_{dr}] \\ \frac{di_{qs}}{dt} = \frac{1}{L_m^2 - L_s L_r} [((\omega_r - \omega)L_m^2 + \omega L_s L_r)i_{ds} + \\ R_s L_r i_{qs} + \omega_r L_r L_m i_{dr} - R_r L_m i_{qr} - \\ L_r u_{qs} + L_m u_{qr}] \\ \frac{di_{dr}}{dt} = \frac{1}{L_m^2 - L_s L_r} [-R_s L_m i_{ds} + \omega_r L_s L_m i_{qs} + \\ R_r L_s i_{dr} - ((\omega - \omega_r)L_s L_r - \omega L_m^2)i_{qr} + \\ L_m u_{ds} - L_s u_{dr}] \\ \frac{di_{qr}}{dt} = \frac{1}{L_m^2 - L_s L_r} [-\omega_r L_s L_m i_{ds} - R_s L_m i_{qs} + \\ R_r L_s i_{qr} + ((\omega - \omega_r)L_s L_r - \omega L_m^2)i_{qr} + \\ L_m u_{qs} - L_s u_{qr}] \end{cases}$$

$$\begin{cases} \hat{i}_{ds}(k+1) = [((\omega - \omega_r(k))L_m^2 - \omega L_s L_r)\hat{i}_{qs}(k) + \\ R_s L_r \hat{i}_{ds}(k) - R_r L_m \hat{i}_{dr}(k) - \omega_r(k)L_r L_m \hat{i}_{qr}(k) - \\ L_r u_{ds}(k) + L_m u_{dr}(k)] \frac{T_s}{L_m^2 - L_s L_r} + \hat{i}_{ds}(k) \\ \hat{i}_{qs}(k+1) = [((\omega_r(k) - \omega)L_m^2 + \omega L_s L_r)\hat{i}_{ds}(k) + \\ R_s L_r \hat{i}_{qs}(k) + \omega_r(k)L_r L_m \hat{i}_{dr}(k) - R_r L_m \hat{i}_{qr}(k) - \\ L_r u_{qs}(k) + L_m u_{qr}(k)] \frac{T_s}{L_m^2 - L_s L_r} + \hat{i}_{qs}(k) \\ \hat{i}_{dr}(k+1) = [-R_s L_m \hat{i}_{ds}(k) + \omega_r(k)L_s L_m \hat{i}_{qs}(k) - (8) \\ ((\omega - \omega_r(k))L_s L_r - \omega L_m^2)\hat{i}_{qr}(k) + R_r L_s \hat{i}_{dr}(k) + \\ L_m u_{ds}(k) - L_s u_{dr}(k)] \frac{T_s}{L_m^2 - L_s L_r} + \hat{i}_{dr}(k) \\ \hat{i}_{qr}(k+1) = [-\omega_r(k)L_s L_m \hat{i}_{ds}(k) - R_s L_m \hat{i}_{qs}(k) + \\ ((\omega - \omega_r(k))L_s L_r - \omega L_m^2)\hat{i}_{dr}(k) + R_r L_s \hat{i}_{qr}(k) + \\ (\omega - \omega_r(k))L_s L_r - \omega L_m^2)\hat{i}_{dr}(k) + R_r L_s \hat{i}_{qr}(k) + \\ (\omega - \omega_r(k))L_s L_r - \omega L_m^2)\hat{i}_{dr}(k) + R_r L_s \hat{i}_{qr}(k) + \\ L_m u_{qs}(k) - L_s u_{qr}(k)] \frac{T_s}{L_m^2 - L_s L_r} + \hat{i}_{qr}(k) \end{cases}$$

在以上的 DFIG 的数学模型中, 电机参数  $\{R_s, R_r, L_s, L_r, L_m\}$ 为辨识参数, 适应度函数的 定义如式(9)所示:

$$F = \sum_{k=1}^{N} (w_1(i_{ds}(k) - \hat{i}_{ds}(k))^2 + w_2(i_{dr}(k) - \hat{i}_{dr}(k))^2 + w_3(i_{qs}(k) - \hat{i}_{qs}(k))^2 + w_4(i_{qr}(k) - \hat{i}_{qr}(k))^2)$$
(9)

其中, $i_{ds}$ , $i_{dr}$ , $i_{qs}$ , $i_{qr}$ 为实际模型中测出来的 dq 坐标系中的电流输入值, $\hat{i}_{ds}$ , $\hat{i}_{dr}$ , $\hat{i}_{qs}$ , $\hat{i}_{qr}$ 为辨识 模型中计算出来的 dq 坐标系中的电流输入值, $w_1$ ,  $w_2$ , $w_3$ , $w_4$ 为权重,分别取 0.25。

#### 2 混合量子粒子群算法

#### 2.1 粒子群算法的简单介绍

粒子群算法 (Particle Swarm Optimization, PSO)是 Kennedy 和 Eberhart 受鱼群或鸟群觅食的 启发,提出的一种用于解决全局优化问题的群体智 能方法<sup>[13]</sup>。在 PSO 算法中,每个粒子都代表搜索 空间中的可行解,用位置向量  $\mathbf{x}_{i,j} = [x_{i1}, x_{i2}, \dots, x_{id}]$ 和飞行速度向量  $\mathbf{v}_{i,j} = [v_{i1}, v_{i2}, \dots, v_{id}]$ 来描述其状

第 28 卷第 5 期		Vol. 28 No. 5
2016年5月	蒋莹莹, 等: 基于混合量子粒子群算法的 DFIG 参数辨识	May, 2016

态,使其在优化过程中能够不断地调整。在每个迭 代过程中,修改后的每个粒子的速度和位置可以由 个体最优和全局最优在种群中的位置计算出来,其 更新公式如式(10)和式(11)所示。

$$v_{i,j}(t+1) = \omega v_{i,j}(t) + c_1 r_1(p \text{best}_{i,j}(t) - x_{i,j}(t)) + c_2 r_2(g \text{best}_j(t) - x_{i,j}(t))$$
(10)

$$x_{i,j}(t+1) = x_{i,j}(t) + v_{i,j}(t+1)$$
(11)

其中,参数 $\omega$ 是惯性权重,用来权衡局部搜索和全局搜索的能力; $r_1$ 和 $r_2$ 是在0和1之间的独立的随机数;学习因子 $c_1$ 和 $c_2$ 均为正常数;pbest<sub>*i*,*j*</sub>代表粒子*i*的最优位置;gbest<sub>*j*</sub>是全局最优位置。

#### 2.2 量子粒子群算法

PSO 算法的最主要的缺点是它并不能保证全局收敛。虽然它的收敛速度快,但是容易陷入局部最优。孙俊等人在研究 PSO 轨迹的基础上,受量子力学的启发,提出了量子粒子群算法(Quantumbehaved Particle Swarm Optimization, QPSO)<sup>[14]</sup>。

假设 PSO 系统是一个量子化的系统,每个粒子都不是自旋的,具有波函数制定的量子行为(不考虑其他粒子的干扰)。受原始 PSO 算法收敛分析的启发,假设每个粒子在一个 $\delta$ 势阱的搜索空间移动,粒子运动的中心位置为  $p_i = [p_{i1}, p_{i2}, \dots, p_{id}]$ ,局部吸引子的坐标被定义为:

$$p_{i,j}(t) = \frac{c_1 \cdot p \text{best}_{i,j}(t) + c_2 \cdot g \text{best}_j(t)}{c_1 + c_2}$$
(12)

与此同时,在算法中引入了平均最好位置来计 算粒子的下一次迭代的变量。定义为所有粒子的局 部极值的平均值,如式(13)所示:

$$mbest(t) = \frac{1}{M} \sum_{i=1}^{M} pbest_{i,j}(t) =$$
$$\left[\frac{1}{M} \sum_{i=1}^{M} pbest_{i,1}(t), \frac{1}{M} \sum_{i=1}^{M} pbest_{i,2}(t), \cdots, \frac{1}{M} \sum_{i=1}^{M} pbest_{i,d}(t)\right]$$
(13)

其中, *M* 是粒子的数量, *p*best<sub>*i*,*j*</sub>是第*i* 个粒子的 最优位置。因此,可以通过以下表达式得到该粒子

的演化方程:

$$X_{i,j}(t+1) = p_{i,j}(t) \pm \beta \cdot$$
$$| m best_j(t) - x_{i,j}(t) | \times \ln(1/u)$$
(14)

其中, *u* = rand(0,1), β是扩张-收缩因子,可以控制粒子的收敛速度。通常情况下,该算法可以通过 将β的值从 1.0 线性递减至 0.5 获得良好的效果。

β=(1-0.5)×(*Iter*<sub>max</sub> - t)/*Iter*<sub>max</sub> + 0.5 (15)
 其中,t为迭代次数,*Iter*<sub>max</sub>为最大迭代次数。

#### 2.3 改进量子粒子群算法

为了更好的权衡量子粒子群算法中的局部搜 索和全局搜索,引入了一个新的协同因子。其主要 思想是加权量子粒子群算法(Weighted Quantumbehaved Particle Swarm Optimization, WQPSO),它 使用一个线性递减的权重参数来渲染种群中的粒 子在演变时的重要性,这个新的参数由全局最优解 决方案 gbest,最差解决方案 gworst 和局部最优解 决方案 pbest 决定。WQPSO 和 QPSO 相比,局部搜 索能力更强,收敛速度更快。新引入的系数为:

$$\lambda_{i,j}(t) = \left| \frac{f(p\text{best}_i(t)) - f(g\text{worst}(t))}{f(g\text{best}(t)) - f(g\text{worst}(t))} \right|$$
(16)

因此,通过新的控制参数的加入,最优位置 mbest 改写成如下所示:

$$mbest(t) = \frac{1}{M} \sum_{i=1}^{M} \lambda_{i,j}(t) \cdot pbest_{i,j}(t) = \left[\frac{1}{M} \sum_{i=1}^{M} \lambda_{i,1} pbest_{i,1}(t), \frac{1}{M} \sum_{i=1}^{M} \lambda_{i,2} pbest_{i,2}(t), \cdots, \frac{1}{M} \sum_{i=1}^{M} \lambda_{i,d} pbest_{i,d}(t)\right]$$
(17)

#### 2.4 模拟退火算法

模拟退火算法(Simulated Annealing, SA)最早 是由 Metropolis 提出来的<sup>[15]</sup>。它的基本思想是受启 发于固体退火原理,先将固体充分加热,再将其徐 徐冷却。通常先设定一个初始的温和状态,再逐步 的减小温度,结合概率突跳特性在搜索空间中通过 领域函数进行随机搜索,能以一定的概率接受比当

第 28 卷第 5 期	系统仿真学报	Vol. 28 No. 5
2016年5月	Journal of System Simulation	May, 2016

前解要差的解,从而跳出局部最优解,最终得到全局最优解。这里"一定的概率"可由 Metropolis 准则表示为:

$$p_{i,j}(T) = \begin{cases} 1, f(j) \leq f(i) \\ e^{-(\frac{f(j) - f(i)}{kT})} = e^{-(\frac{\Delta E}{kT})}, f(j) > f(i) \end{cases}$$
(18)

其中, *f*(*i*), *f*(*j*)分别表示状态*i*, *j*下的热能, *T*是绝对温度, *k* 是 Boltzman 常数, *e* 是自然对数。

#### 2.5 混合量子粒子群算法的实现

WQPSO 的全局搜索能力高于 QPSO,但依然 存在容易陷入局部最优的缺点。SA 可以在接受较 优解的同时也能接受比较差的解,从而增加了求解 空间的多样性和搜索过程的灵活性,扩大了解空间 的搜索范围。因此,利用 WQPSO 和 SA 在全局搜 索与局部搜索方面的互补特性,将二者进行混合, 充分发挥二者的优点,提出了混合量子粒子群优化 算法(SAWQPSO)。SAWQPSO 的基本流程如下:

Step 1:初始化过程。对于给定的*M* 个粒子组成的粒子群,在[min,max]范围内随机产生一个粒子的位置向量  $x_{i,j} = [x_{i1}, x_{i2}, ..., x_{id}]$ ,其中i = 1, 2, ..., M; 设个体最优位置 pbest<sub> $i,j</sub> = <math>x_{i,j}$ ;初始化 SA 算法的初始温度 T 和退火速率  $\lambda$ 。</sub>

Step 2: 计算每个粒子的适应度函数值,并将 适应度函数值最优的粒子设置成全局最优 gbest, 将适应度函数值最差的粒子设置成全局最差 gworst。

Step 3: 根据公式(12)求局部吸引子  $p_i$ ,根据 公式(17)更新粒子的平均位置 mbest,根据公式(14) 更新粒子的位置。

Step 4: 将每个粒子的当前适应度函数值与其 经历过的个体最优  $pbest_{i,j}$ 和群体全局最优  $gbest_j$ 的适应度函数值相比较,如果当前适应度函数值优 于  $pbest_{i,j}$ 和  $gbest_j$ 的适应度函数值,则更新  $pbest_{i,j}$ 和  $gbest_j$ 。

Step 5: 每迭代 20 步, 对新种群的处于全局最 优位置的粒子 s, 产生一个相邻解 s', 对其进行领 域搜索。令  $\Delta E = f(s') - f(s)$ , 以 min  $[1, \exp(-\Delta E / t_k)]$  的概率接受新解。

 Step 6: 令k = k + 1,进行退火操作 $t_k = \lambda t_{k-1}$ 。

 Step 7: 若满足终止条件,输出最优适应值

  $f_{hest}$ ,否则跳转到 Step 2。

SAWQPSO 算法流程图如图 2 所示。



图 2 SAWQPSO 算法流程图

#### 3 DFIG 的参数辨识

#### 3.1 参数辨识原理

DFIG 的参数辨识过程是根据电机的实际输出 和辨识模型输出的差值,通过混合量子粒子群算法 对辨识模型不断地调整,最终辨识出 DFIG 参数。 辨识原理如图 3 所示。



在对 DFIG 的电机参数进行辨识时,图 3 中的

 $i_{ds}$ ,  $i_{dr}$ ,  $i_{qs}$ ,  $i_{qr}$ 为实际模型中的测量值,  $\hat{i}_{ds}$ ,  $\hat{i}_{dr}$ ,  $\hat{i}_{as}$ ,  $\hat{i}_{ar}$ 为辨识模型中的计算值。

#### 3.2 仿真环境及参数设置

本文采用 Matlab/Simulink 软件平台,对风力 发电系统中双馈电机的参数辨识进行了仿真实验。 其中,实验 PC 机软硬件配置为: Intel(R) core(TM) i3-3240 处理器,主频 3.4 GHZ,内存 4 GB。

图 4 是一个包含 6 个 1.5 MW 风力发电机的 9 MW 风电场通过 30 kM, 25 kV 电线连接到一个 向 120 kV 电网供电的 25 kV 配电系统,风电场的 出口处带有 500 kW 负荷。在本算例中,风速保持 在 15 m/s。控制系统采用一个转矩控制器,以维持 1.2 PU 的恒定转速。由风力发电机产生的无功功率 被规定在 0 Mvar。扰动点设置在 25 kV 与 120 kV 的单回线路中间,发生三相短路故障。在故障期间, 测量出定转子在 dq 轴上的电压、定转子在 dq 轴上 的电流和转子转速,采样时间为 10<sup>-3</sup> s,数据长度 为 300。基于上述所描述的辨识过程,利用测量数 据进行参数辨识。表 1 是 DFIG 的设置参数。



图 4 DFIG 接入 120 kV 系统

表 1 DFIG 的设置
--------------

	±1,2 %,
参数	标幺值
定子电阻 R <sub>s</sub> /pu	0.007 06
转子电阻 R <sub>rs</sub> /pu	0.005
定子电感 L <sub>ss</sub> /pu	3.071
转子电感 L <sub>rs</sub> /pu	3.056
定转子互感 Lms/pu	2.9
惯性常数 H <sub>s</sub> /pu	5.04
摩擦系数 F <sub>s</sub> /pu	0.013
极对数 p	3

本文将混合量子粒子群算法应用于DFIG参数 辨识中,并将其仿真结果与 PSO 算法,QPSO 算 法和 WQPSO 算法相比较。仿真时,PSO 算法中的 参数设置如下:根据经验一般将加速度系数设为  $c_1 = c_2 = 2$ ,惯性权重从 0.9~0.4 线性递减;QPSO 和 WQPSO 中,算法运行时,扩张-收缩因子 $\beta$ 的 值均从 1.0 线性递减至 0.5<sup>[16]</sup>,文献[16]中用实验数 据证明了 $\beta$ 参数设置为 1~0.5 线性递减时,算法性 能更好;SAWQPSO 算法中,扩张-收缩因子 $\beta$ 的 设置与上面相同,退火速率一般为略小于 1 的正 数,文中设为 $\lambda = 0.95$ 。本文的参数辨识仿真实验 中,4种算法的种群粒子的初始值,都是在给出的 解空间的初始化范围内随机初始化得来的,初始化 范围若设置的过大,会增加辨识的难度,也会影响 辨识的精度;若设置的过小,会出现把真实值排除 在外的可能性。因此电机参数的初始搜索区间如表 2 所示。为保证比较结果的公正性,其他仿真参数 均保持一致:每个算法都独立运行 20 次,粒子种 群大小为 20,搜索空间维数为 5,迭代次数为 100。

表 2 电机参数的实际值及其对应的初始化范围

参数标幺值/pu	初始化范围	真实值
定子电阻 R <sub>s</sub>	0.003 00~0.012 00	0.007 06
转子电阻 R <sub>r</sub>	0.002 00~0.009 00	0.005 00
定子电感 L <sub>s</sub>	1.450 00~5.000 00	3.071 00
转子电感 L <sub>r</sub>	1.450 00~5.000 00	3.056 00
定转子互感 Lm	1.450 00~5.000 00	2.900 00

#### 3.3 实验结果与分析

适应度优化结果如表 3 所示,表 3 依次列出了 20 次适应度函数值的平均值 Average、最小值 Min、最大值 Max 和方差 Std.var.。其中, {*R<sub>s</sub>*,*R<sub>r</sub>*,*L<sub>s</sub>*,*L<sub>r</sub>*,*L<sub>m</sub>*}分别表示电机定子电阻、转子电 阻、定子电感、转子电感和定转子互感。从表 3 中可得,相比于 PSO 算法、QPSO 算法和 WQPSO 算法, SAWQPSO 算法的适应度函数值都较小,从 平均值、最小值、最大值来看均具有明显的优势, 从方差来看,此算法也比其他 3 种算法更加稳定。

表 3 4 种算法的适应度函数	值
-----------------	---

算法	Average	Min	Max	Std.var.
PSO	0.103 15	0.092 51	0.120 10	0.871
QPSO	0.046 68	0.025 36	0.064 71	0.425
WQPSO	0.036 68	0.013 25	0.058 13	0.216
SAWQPSO	0.004 90	0.001 82	0.006 50	0.007 49

http://www.china-simulation.com

第28卷第5期	系统仿真学报	Vol. 28 No. 5
2016年5月	Journal of System Simulation	May, 2016

DFIG 的参数辨识结果如表 4 所示,表 4 给出 了 20 次仿真的平均值、最小值、最大值和方差。 从表 4 中可以看出,在对 DFIG 的定子电阻、转子 电阻、定子电感、转子电感和定转子互感的辨识结 果中,SAWQPSO与PSO,QPSO和WQPSO算法相比,误差更小,方差更小,因此本文所提出的算法更稳定。(注明:误差是由真实值和平均值计算所得。)

表 4 4 种算法的电机参数辨识结果比较						
算法	参数	$R_{\rm s}$	$R_{ m r}$	$L_{ m s}$	$L_{ m r}$	$L_{\rm m}$
	真实值	0.007 06	0.005	3.071	3.056	2.9
	Average	0.007 546	0.005 412	2.953 253	2.953 412	3.041 360
DCO	Min	0.004 926	0.004 441	2.606 182	2.202 903	1.969 725
PS0	Max	0.009 081	0.008 588	3.936 322	3.736 322	3.535 977
	Std.var.	0.632e-3	0.957e-2	0.521e-3	0.928e-3	0.655e-2
	误差%	6.88	8.24	3.83	3.36	4.87
	Average	0.006 758	0.005 302	3.113 521	3.105 483	2.825 710
	Min	0.005 509	0.003 997	2.707 682	2.680 768	2.585 425
QPSO	Max	0.008 581	0.008 024	3.810 133	3.212 779	3.355 573
	Std.var.	0.278e-3	0.465e-2	0.285e-3	0.315e-3	0.457e-2
	误差%	4.27	6.04	1.38	1.61	2.56
	Average	0.007 234	0.005 237	3.089 764	3.009 586	2.845 410
	Min	0.005 829	0.004 741	2.556 871	2.756 871	1.622 802
WQPSO	Max	0.008 086	0.006 250	3.536 097	3.536 097	3.212 748
	Std.var.	0.187e-3	0.157e-2	0.803e-4	0.192e-3	0.235e-2
	误差%	2.46	4.74	0.61	1.52	1.88
	Average	0.007 162	0.004 823	3.063 272	3.070 251	2.918 075
	Min	0.006 149	0.003 689	3.003 263	3.012 432	2.782 555
SAWQPSO	Max	0.008 023	0.006 568	3.515 451	3.245 271	2.947 541
	Std.var.	0.546e-4	0.807e-3	0.141e-4	0.595e-4	0.349e-3
	误差%	1.44	3.54	0.25	0.47	0.62

本文采用双边 t-test 统计学方法<sup>[17]</sup>, 通过 DFIG 参数辨识的结果来评估两种算法之间的优劣。 t-value 为 t-test 的统计值, SAWQPSO 与 PSO、 QPSO 和 WQPSO 之间的 t-value 如上表 5 所示。如 果 |t-value|≤2.093,则表示在 95%的置信度下,两 种算法无明显差异。从表 5 中可以看出,本文所提 出的算法与其他 3 种算法之间的 t-value 值均大于 2.093,因此在 95%的置信度下 SAWQPSO 算法的 性能明显优于其他算法。

表 5 算法之间的 t-val	lue 值
算法	t-value
SAWQPSO/PSO	4.57
SAWQPSO/QPSO	3.15
SAWQPSO/WQPSO	2.86

图 5 为适应度函数收敛曲线,从中可以看出, PSO 算法在迭代到第 10 步时就陷入局部最优解, QPSO 和 WQPSO 算法的寻优能力优于 PSO 算法, 相比这 3 种算法,SAWQPSO 算法增加了种群的多 样性,能够及时跳出局部最优,防止了算法陷入早 熟的问题,最终能获取全局最优解。利用 PSO, QPSO, WQPSO 和 SAWQPSO 算法对 DFIG 的五 个电气参数进行辨识后的仿真结果如图 6~10 所 示。从中可以看出,PSO 算法在迭代至 65 步时才 能辨识出电机参数值,而且辨识曲线偏离真实值最 远;QPSO 算法和 WQPSO 算法相比于 PSO 算法, 收敛速度有了明显的提高,辨识误差较小,WQPSO 算法在 QPSO 算法的基础上增加了线性递减的惯 性权重这一参数,收敛速度略有提高,辨识结果较 第28卷第5期 2016年5月 Vol. 28 No. 5 May, 2016

好; SAWQPSO 算法的收敛速度最快,辨识曲线能 很快收敛到真实值附近,与真实值的误差最小。综 上所述,在 DFIG 参数辨识问题上,SAWQPSO 算 法与 PSO, QPSO 和 WQPSO 算法相比,收敛速度 和收敛精度均有明显提高,能更好的应用于 DFIG 参数辨识问题中。



图 5 DFIG 参数辨识模型适应度函数平均值收敛曲线



图 6 DFIG 定子电阻辨识曲线



图 7 DFIG 转子电阻辨识曲线



#### 4 结论

本文针对 DFIG 的多参数辨识问题,提出了一 种混合量子粒子群算法,并将该算法应用于 DFIG 参数辨识中。所提出的算法加入了新的协同因子, 更好的权衡了 QPSO 算法的局部搜索和全局搜索,

http://www.china-simulation.com

第 28 卷第 5 期	系统仿真学报	Vol. 28 No. 5
2016年5月	Journal of System Simulation	May, 2016

与 SA 算法混合,使粒子能够跳出局部最优解,从 而提高算法搜索能力。仿真结果证明,本文所提出 的算法能够准确地辨识定子电阻、转子电阻、定子 电感、转子电感和定转子互感电感,其辨识效果优 于 PSO 算法和 QPSO 算法。

#### 参考文献:

- Asmine M, Brochu J, Fortmann J, et al. Model Validation for Wind Turbine Generator Models [J]. IEEE Transactions on Power Systems (S0885-8950), 2011, 26(3): 1769-1782.
- [2] Xiaobing Kong, Xiangjie Liu, Kwang Y Lee. Data-driven Modeling of A Doubly Fed Induction Generator Wind Turbine System Based on Neural Networks [J]. IET Renewable Power Generation (S1752-1416), 2014, 8(8): 849-857.
- [3] Zubia I, Zatarain A, Alcalde C, et al. In Situ Electrical Parameter Identification Method for Induction Wind Generators [J]. IET Electric Power Applications (S1751-8660), 2011, 5(7): 549-557.
- [4] Dirik H, Gezegin C, Ozdemir M. A Novel Parameter Identification Method for Single-Phase Transformers by Using Real-Time Data [J]. IEEE Transactions on Power Delivery (S0885-8977), 2013, 29(3): 1074-1082.
- [5] Mourad Hasni, Zohir Mancer, Said Mekhtoub, et al. Parametric Identification of the Doubly Fed Induction Machine [J]. Energy Procedia (S1876-6102), 2012, 18(12): 177-186.
- [6] 景卉. 双馈风力发电机电流预测控制和参数辨识方法 研究 [D]. 哈尔滨:哈尔滨工业大学, 2012.
- [7] Lalami A, Wamkeue R, Kamwa I, et al. Unscented Kalman Filter for Non-linear Estimation of Induction Machine Parameters [J]. IET Electric Power Applications (S1751-8660), 2013, 6(9): 611-620.
- [8] Lihang Zhao, Jin Huang, He Liu, et al. Second-Order Sliding-Mode Observer with Online Parameter Identification for Sensorless Induction Motor Drives [J]. IEEE Transactions on Industrial Electronics (S0278-0046),

2014, 61(10): 5280-5289.

- [9] 王红,梁俊霞,胡佳琳. 基于 αβ 坐标系模型的双馈风 力发电机参数辨识 [J]. 电力系统保护与控制, 2014, 42(20): 81-85.
- [10] Yangfei Zhang, Yue Yuan, Xiaohu Chen, et al. The Optimization Initial Value and Micro-variation Search Algorithm and Its Simulation in Parameter Identification of Doubly Fed Induction Generator [C]// International Conference on Sustainable Power Generation and Supply, Nanjing, China: IEEE, 2009: 1-4.
- [11] 金宇清, 赵泽, 鞠平, 等. 双馈感应风力发电机的参数 辨识分析 [J]. 高电压技术, 2011, 37(7): 1700-1705.
- [12] 刘永康,潘学萍,鞠平.基于改进粒子群算法的双馈 感应发电机参数辨识 [J].河海大学学报(自然科学版), 2014, 42(3): 273-277.
- [13] Kennedy J, Eberhart R. Particle Swarm Optimization [C]// Proceedings of IEEE International Conference on Neural Networks. Piscataway, USA: IEEE, 1995: 1942-1948.
- [14] Elnaz Davoodi, Mehrdad Tarafdar Hagh, Saeid Ghassem Zadeh. A Hybrid Improved Quantum-behaved Particle Swarm Optimization-Simplex Method (IQPSOS) to Solve Power System Load Flow Problems [J]. Applied Soft Computing (S1568-4946), 2014, 21(14): 171-179.
- [15] Kirkpatrick S, Gelatt C D, Vecchi M P. Optimization by Simulated Annealing [J]. Science (S0036-8075), 1983, 220(4598): 671-680.
- [16] Kaiqiao Yang, Kenjiro Maginu, Hirosato Nomura. Parameters identification of chaotic systems by quantumbehaved particle swarm optimization [J]. International Journal of Computer Mathematics (S0020-7160), 2009, 86(12): 2225-2235.
- [17] Ling S H, Iu H H C, Chan K Y, et al. Hybrid particle swarm optimization with wavelet mutation and its industrial applications [J]. Systems, Man, and Cybernetics, Part B: Cybernetics, IEEE Transactions on (S1083-4419), 2008, 38(3): 743-763.