

基于扩展粒子群优化算法的同步发电机参数辨识

胡家声, 郭创新, 曹一家

(浙江大学电气工程学院, 浙江省杭州市 310027)

摘要: 提出一种新的扩展粒子群优化(EPSO)算法并应用于同步发电机参数辨识。在粒子群优化(PSO)算法的基础上, EPSO 算法采用更多粒子的位置值信息进行变异操作, 并且提出根据各粒子的适应值大小确定算法控制参数的方法, 保证了扩展后算法的收敛性, EPSO 算法模型更具有通用性。仿真算例结果表明了在系统受到较大干扰的情况下, EPSO 算法比 EP 算法和 PSO 算法具有更精确的参数综合辨识能力, 并且 EPSO 算法比 EP 算法具有更高的收敛效率。

关键词: 同步发电机; 参数辨识; 扩展粒子群优化算法

中图分类号: TM711; TP18

0 引言

由于电力系统动、暂态稳定计算和安全监控策略研究等需要准确的系统参数进行计算, 因此需要高效的算法应用于发电机参数辨识。发电机参数辨识问题是在一定的发电机参数辨识模型的基础上, 利用参数辨识值下的发电机模型离散时刻输出预报值与实际发电机输出值的残差平方和作为最小化目标函数, 通过一定算法迭代寻优。因此, 发电机参数辨识问题可以转化为一个最优化问题进行求解。近年来, 许多研究人员应用广义 Kalman 滤波法^[1,2]、最小二乘法^[3]、进化规划(EP)算法^[4,5]等对同步发电机进行参数辨识。在这些方法中, 最小二乘法的目标函数为测量结果和对应的辨识结果的误差的平方和, 目标函数简单明了, 但在优化过程中要用到目标函数对待辨识参数的导数, 并且算法对测量噪声很敏感。广义 Kalman 滤波法是一种适合于动态数学模型的优化算法, 也适合于研究有噪声干扰的系统, 其缺点是计算量较大。文献[4]提出利用进化规划算法进行同步发电机参数辨识, 与广义 Kalman 滤波算法相比, 显著地提高了在较大干扰的情况下算法对系统参数的辨识精度。然而, 进化规划算法在收敛性、大干扰下辨识的有效性方面仍难以满足较高辨识精度和实时辨识效率的要求, 因此有必要研究更有效的算法来辨识同步发电机参数。

本文在粒子群优化算法的基础上, 提出了一种新的扩展粒子群优化算法应用于同步发电机参数辨识。粒子群优化算法源自对鸟群捕食行为的研究,

最初由 Kennedy 和 Eberhart 提出^[6,7]。粒子群优化算法是一种基于模拟鸟群捕食行为的启发式搜索方法, 所有鸟知道自己当前位置离食物多远, 那么搜索的最简单、有效的策略就是搜寻目前离食物最近的鸟的周围区域, PSO 算法利用这种模型得到启示并应用于解决优化问题。PSO 算法本质上是一种多代理算法, 研究由简单个体组成的群落与环境以及个体之间的互动行为。EPSO 算法在 PSO 算法的基础上, 充分考虑更多粒子的位置值信息进行迭代寻优, 有效地扩展了 PSO 算法的基本公式, 并提高了算法的全局收敛能力。与文献[4]中的进化规划算法和 PSO 算法相比, EPSO 算法对参数的综合辨识能力更强并且更容易实现并行处理, 算法具有更高的收敛效率。本文所做仿真算例验证了该结论。

1 同步发电机参数辨识数学模型

对于远距离输电系统中远离负荷中心的同步发电机而言, 可将其外部等值为一个无穷大系统。发电机接于电力系统的接线图如图 1 所示, 发电机出线为节点 i , 母线为节点 j , 节点 i 和 j 之间的阻抗 $R+jX$ 为变压器的漏抗, 节点 i 对地导纳代表出口负荷, 发电机及其出口端的变量用下标 i 表示, 而系统用下标 j 表示。

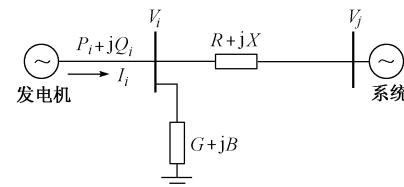


图 1 单机无穷大系统一般接线
Fig. 1 General connection of the generator

系统状态方程为:

$$\dot{\Delta\delta}_i = \omega_b \Delta\omega_i \quad (1)$$

$$\dot{\Delta\omega}_i = -\frac{K_{1i}}{M_i} \Delta\delta_i - \frac{D_i}{M_i} \Delta\omega_i - \frac{K_{2i}}{M_i} \Delta E_{qi}' - \frac{C_{1i}}{M_i} \Delta V_j \quad (2)$$

$$\dot{\Delta E}_{qi}' = -\frac{K_{3i}}{T_{d0i}} \Delta\delta_i - \frac{K_{4i}}{T_{d0i}} \Delta E_{qi}' + \frac{1}{T_{d0i}} \Delta E_{fdi} - \frac{C_{2i}}{T_{d0i}} \Delta V_j \quad (3)$$

$$\dot{\Delta E}_{fdi} = -\frac{K_E K_{5i}}{T_E} \Delta\delta_i - \frac{K_E K_{6i}}{T_E} \Delta E_{qi}' - \frac{1}{T_E} \Delta E_{fdi} - \frac{K_E C_{3i}}{T_E} \Delta V_j + \frac{K_E}{T_E} u \quad (4)$$

量测量和量测方程为:

$$\Delta\omega_i = \Delta\omega_i \quad (5)$$

$$\Delta V_i = K_{5i} \Delta\delta_i + K_{6i} \Delta E_{qi}' + C_{3i} \Delta V_j \quad (6)$$

$$\Delta P_i = K_{1i} \Delta\delta_i + K_{2i} \Delta E_{qi}' + C_{1i} \Delta V_j \quad (7)$$

上述状态方程以及量测量方程中的系数计算详见文献[4]。在图 1 所示单机无穷大系统中,由于以量测量 ΔV_j 作为解耦项,用式(1)~式(4)作为辨识方程,因此可在不知道外域系统信息的情况下考虑外域系统的动态影响进行可靠的辨识。

2 同步发电机参数辨识原理

将式(1)~式(7)描述为以下线性连续时间的状态空间模型:

$$\dot{\mathbf{X}}(t) = \mathbf{A}(\boldsymbol{\theta}) \mathbf{X}(t) + \mathbf{B}(\boldsymbol{\theta}) u(t) + \mathbf{B}_e(\boldsymbol{\theta}) \Delta V_j(t) + \omega(t) \quad (8)$$

$$\mathbf{y}(t_k) = \mathbf{C}(\boldsymbol{\theta}) \mathbf{X}(t_k) + \mathbf{C}_e(\boldsymbol{\theta}) \Delta V_j(t_k) + v(t_k) \quad (9)$$

式中: t_k 为第 k 次采样时刻; $\boldsymbol{\theta}$ 为待辨识参数向量, $\boldsymbol{\theta} = [X_{di}, X_{di}', X_{qi}, T_{d0i}', M_i, D_i]^T$; 状态向量 $\mathbf{X}(t) = [\Delta\delta_i, \Delta\omega_i, \Delta E_{qi}', \Delta E_{fdi}]^T$; 第 k 次采样时刻的输出向量 $\mathbf{y}(t_k) = [\Delta\omega_i, \Delta V_i, \Delta P_i]^T$; $u(t)$ 为在励磁上施加的逆伪随机二位式序列(逆 PRBS)信号; $\omega(t)$ 和 $v(t_k)$ 为系统噪声。

此连续时间状态空间模型作为同步发电机的辨识模型,同步发电机参数辨识试验原理见图 2。

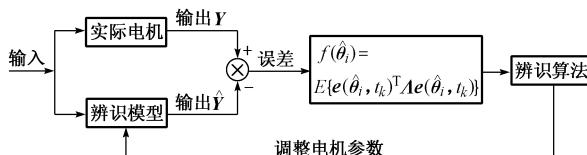


图 2 同步发电机参数辨识试验原理框图

Fig. 2 Parameter identification principle diagram of synchronous generator

发电机参数的最佳辨识值应该使得发电机辨识模型的离散时刻输出预报值与实际发电机输出值的残差平方和最小,因此目标函数取为:

$$f(\hat{\boldsymbol{\theta}}_i, t_k) = E\{e(\hat{\boldsymbol{\theta}}_i, t_k)^T \Lambda e(\hat{\boldsymbol{\theta}}_i, t_k)\} \quad (10)$$

式中: $e(\hat{\boldsymbol{\theta}}_i, t_k)$ 为第 k 次采样时刻的参数辨识值向量下的发电机辨识模型的离散时刻输出预报值与实际发电机输出值的残差; Λ 为单位矩阵。

由以上分析可知,发电机参数辨识问题可转化为一个最优化问题求解,该最优化问题的目标函数即为式(10),即通过一定的辨识算法在辨识参数允许的解空间中迭代寻优最佳辨识值使得目标函数式(10)最小。

3 扩展粒子群优化算法应用于同步发电机参数辨识

3.1 基本粒子群优化算法

粒子群优化算法是一种基于模拟鸟群捕食行为的启发式搜索方法。PSO 算法中,每个优化问题的解都是粒子在搜索空间中的位置,粒子还有一个速度值决定它们飞翔的方向和距离,然后,粒子群就追随当前的最优粒子在解空间中搜索。我们以图 3 为例来说明 PSO 算法中粒子群寻优的过程。

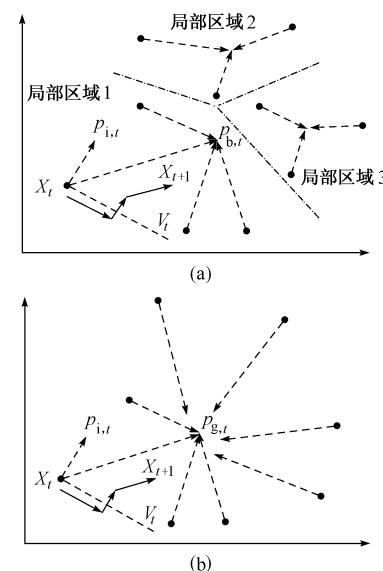


图 3 粒子群空间寻优过程
Fig. 3 Searching process of particles

起初,粒子群的初始位置和速度值是随机分布的,如图 3(a)所示,粒子群按空间划分为几个区域,在各次迭代中,每个粒子通过跟踪两个“极值”来更新自己在解空间中的位置与速度。一个极值就是粒子本身在迭代过程中找到的自身的最优解,这个解所对应的粒子称为个体极值粒子 $p_{i,t}$; 另一个极值是各区域局部粒子群中存在的一个最优解为局部极

值粒子 $p_{b,t}$, 这一寻优过程称为局部 PSO 算法, 采用此寻优方法是为了避免搜索过程中算法过早地陷入局部最优解。经过一定的迭代次数后, 寻优过程改用全局 PSO 算法加速收敛, 如图 3(b) 所示, 整个粒子群通过跟踪个体极值粒子和一个全局极值粒子 $p_{g,t}$ 更新自身的速度及位置, 在解空间中搜寻全局最优解。粒子寻优遵循以下基本公式:

$$v_{t+1} = c_1 v_t + c_2 r_1(t)(p_{i,t} - x_t) + c_3 r_2(t)(\hat{p}_t - x_t) \quad (11)$$

$$x_{t+1} = x_t + v_{t+1} \quad (12)$$

式中: 下标 t 表示迭代次数; x_t 表示 t 次迭代时的粒子空间位置; v_t 表示 t 次迭代时的粒子速度; $p_{i,t}$ 表示个体极值粒子; \hat{p}_t 表示局部极值粒子 $p_{b,t}$ 或者全局极值粒子 $p_{g,t}$; $r_1(t)$ 和 $r_2(t)$ 为 $(0, 1)$ 间的随机数; c_1, c_2, c_3 为算法的控制参数。PSO 算法中, 每个粒子仅根据两个极值给出的信息进行变异。

3.2 扩展粒子群优化算法

粒子群优化算法中, 每个粒子根据自身的个体极值和局部极值或者全局极值两个量更新自己的速度及位置, 并没有考虑其他粒子的值包含的信息。本文提出的 EPSO 算法, 根据更多粒子的位置值包含的信息更新各个粒子的位置和速度, 并提出了一种算法控制参数的设定方法保证算法的收敛性。EPSO 算法基本公式如下:

$$v_{t+1} = w v_t + \sum_{i=1}^m \phi_i (p_{i,t} - x_t) + \sum_{i=1}^n \eta_i (\hat{p}_{i,t} - x_t) \quad (13)$$

$$x_{t+1} = x_t + v_{t+1} \quad (14)$$

式中: $\phi_i = c_{1,i} r_{1,i}(t)$; $\eta_i = c_{2,i} r_{2,i}(t)$ 。

式(13)与 PSO 算法(式(11))比较可知, 粒子根据最优的 m 个个体极值粒子和最优的 n 个局部或者全局极值粒子更新自己的速度和位置值, EPSO 算法充分考虑了更多粒子在迭代寻优过程中包含的信息, 算法的全局收敛性更强。PSO 算法仅为 EPSO 算法中 m 和 n 均取 1 时的一个特例。

EPSO 算法的递推公式计算如下。将式(13)代入式(14), 并且根据 $v_t = x_t - x_{t-1}$ 可得递推式:

$$x_{t+1} = \left(1 + w - \sum_{i=1}^m \phi_i - \sum_{i=1}^n \eta_i\right) x_t - w x_{t-1} + \sum_{i=1}^m \phi_i p_{i,t} + \sum_{i=1}^n \eta_i \hat{p}_{i,t} \quad (15)$$

在每一次迭代过程中, $p_{i,t}$ 和 $\hat{p}_{i,t}$ 均为常量, 式(15)可以写成以下矩阵方程形式:

$$\begin{bmatrix} x_{t+1} \\ x_t \\ 1 \end{bmatrix} = \begin{bmatrix} 1 + w - \phi - \eta & -w & \phi p + \eta \hat{p} \\ 1 & 0 & 0 \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} x_t \\ x_{t-1} \\ 1 \end{bmatrix} \quad (16)$$

式中: $\phi = \sum_{i=1}^m \phi_i$; $\eta = \sum_{i=1}^n \eta_i$; $\phi p = \sum_{i=1}^m \phi_i p_{i,t}$; $\eta \hat{p} = \sum_{i=1}^n \eta_i \hat{p}_{i,t}$ 。

通过对以上矩阵特征根的求解可得递推式(15)的解为:

$$x_t = k_1 + k_2 e^{\alpha t} + k_3 e^{\beta t} \quad (17)$$

式中: α 和 β 为矩阵特征根, $\alpha = (1 + w - \phi - \eta + \gamma)/2$, $\beta = (1 + w - \phi - \eta - \gamma)/2$, 其中 $\gamma = \sqrt{(1 + w - \phi - \eta)^2 - 4w}$; k_1, k_2, k_3 在每次迭代过程中均为常量, 依据初始随机分布的粒子位置值递推求得。

由式(17)可知, EPSO 算法的收敛性条件如下。EPSO 算法收敛及 $\lim_{t \rightarrow \infty} x_t$ 为常量的条件是: 当 $(1 + w - \phi - \eta)^2 < 4w$ 时, $\lim_{t \rightarrow \infty} x_t = k_1 + k_2 \| \alpha \| e^{\alpha t} + k_3 \| \beta \| e^{\beta t}$, 有 $\max(\| \alpha \|, \| \beta \|) < 1$, 保证算法收敛性, 因为当 $\max(\| \alpha \|, \| \beta \|) = 1$ 时, $\lim_{t \rightarrow \infty} x_t = k_1 + k_2 e^{\alpha t} + k_3 e^{\beta t}$ 是发散的, 其中 θ 和 γ 在每次迭代过程中是常量。当 $(1 + w - \phi - \eta)^2 \geq 4w$ 时, 有 $\max(\| \alpha \|, \| \beta \|) \leq 1$, 可保证算法收敛。由于 $\phi \in (0, \sum_{i=1}^m c_{1,i})$, $\eta \in (0, \sum_{i=1}^n c_{2,i})$, 取控制参数 $w = 0.7298$, $\sum_{i=1}^m c_{1,i} = 1.49618$, $\sum_{i=1}^n c_{2,i} = 1.49618$, 因此 $\phi \in (0, 1.49618)$, $\eta \in (0, 1.49618)$ 。

当 $(\phi + \eta) \in (0, 0.0212]$ 时, 有

$$\gamma = \sqrt{(1 + w - \phi - \eta)^2 - 4w} \geq 0$$

$$\max(\| \alpha \|, \| \beta \|) = \frac{1.7298 - \phi - \eta + \gamma}{2} < 1$$

当 $(\phi + \eta) \in (0.0212, 2.9924)$ 时, 有

$$\gamma = \sqrt{(1 + w - \phi - \eta)^2 - 4w} < 0$$

$$\| \alpha \| = \| \beta \| < 1$$

因此, 控制参数的选择可以保证算法的收敛性。

以上收敛性分析中并没有考虑算法公式中随机数 $r()$ 引发的概率性因素。由于 $\phi = \sum_{i=1}^m c_{1,i} r_{1,i}(t)$, $\eta = \sum_{i=1}^n c_{2,i} r_{2,i}(t)$, 其中 $r()$ 为 $(0, 1)$ 间的随机数, 因此在粒子群的迭代过程中, 控制参数 ϕ 和 η 的期望值分别为:

$$E[\phi] = \sum_{i=1}^m c_{1,i} \int_0^1 \frac{r}{1-r} dr = \sum_{i=1}^m c_{1,i} \frac{r}{2} \Big|_0^1 = \frac{1}{2} \sum_{i=1}^m c_{1,i} \quad (18)$$

$$E[\eta] = \sum_{i=1}^n c_{2,i} \int_0^1 \frac{r}{1-r} dr = \sum_{i=1}^n c_{2,i} \frac{r}{2} \Big|_0^1 = \frac{1}{2} \sum_{i=1}^n c_{2,i} \quad (19)$$

因此,在考虑粒子群迭代过程中概率随机因素的情况下,可以取 $\sum_{i=1}^m c_{1,i} = 2 \times 1.49618$, $\sum_{i=1}^n c_{2,i} = 2 \times 1.49618$,使得 $E[\phi] \in (0, 1.49618)$, $E[\eta] \in (0, 1.49618)$,满足算法的收敛性准则。

与 PSO 算法不同的是, ϕ 为 m 个最优的个体极值粒子权系数之和, η 为 n 个局部极值粒子或者全局极值粒子的权系数之和。各个粒子的影响程度根据其解的最优性不同而不同,适值小的解及较优的解影响程度应该大,该解的控制参数应该较大。因此,本文采用如下极值粒子权系数的选择方案:

$$\left\{ \begin{array}{l} \phi_i = r_i() \frac{\frac{1}{f_i}}{\sum_{i=1}^m \frac{1}{f_i}} C \\ \eta_i = r_i() \frac{\frac{1}{f_i}}{\sum_{i=1}^n \frac{1}{f_i}} C \end{array} \right. \quad (20)$$

式中: f_i 和 \hat{f}_i 分别为个体极值粒子和局部极值粒子或者全局极值粒子所对应极小化最优问题的解及粒子的适应值;常数 C 取值 1.49618,但在考虑迭代过程中概率随机性的情况下, C 可取值为 2×1.49618 。

根据式(20)提出的权系数选择方法,可以确保每次迭代过程中,位置值最优的粒子影响程度最大。

3.3 扩展粒子群优化算法应用于同步发电机参数辨识的基本步骤

同步发电机参数的 EPSO 算法辨识流程如下:

a. 随机初始化粒子群中各粒子待辨识参数 $\hat{\theta}_{i,j}^0 = [\hat{X}_{di}^0, \hat{X}_{di}'^0, \hat{X}_{qi}^0, \hat{T}_{do_i}^0, \hat{M}_i^0, \hat{D}_i^0]^T$, i 表示第 i 个粒子, j 表示第 j 维待辨识参数。辨识参数是在一定范围内随机分布的,如下所示:

$$\theta_{\min,j} \leq \hat{\theta}_{i,j}^0 \leq \theta_{\max,j} \quad i = 1, 2, \dots, n \quad (21)$$

式中: n 为总的粒子数; k 为第 k 次迭代次数; 将粒子群按序号 i 划分为 3 个区域。

b. 计算每个粒子相应的目标函数值 $f(\hat{\theta}_i, t_k)$, t_k 表示第 k 次采样时刻,并比较得到该粒子的前 m 个最优的个体极值粒子。

c. 如果 $k < 2N_{\text{maxiter}}/3$,在各局部区域中,计算局部粒子群中的前 n 个最优的局部极值粒子;如果 $k \geq 2N_{\text{maxiter}}/3$,计算全部粒子群中的前 n 个最优的全局极值粒子。 N_{maxiter} 为最大迭代次数。

d. 利用步骤 b 计算得到的各个粒子的适应值,根据式(20)计算控制参数。

e. 根据步骤 b 和步骤 c 计算得到的 m 个最优的个体极值粒子和 n 个最优的局部或者全局极值粒子,利用 EPSO 算法(式(13))计算各个粒子的更新速度值。

f. 利用步骤 e 所得粒子的速度值,根据 EPSO 算法(式(14))更新粒子所含的待辨识参数值。

g. 如果 $\| f(\hat{\theta}_i, t_k) \| < e$, 或者迭代次数 $k > N_{\text{maxiter}}$, 算法终止;否则, $k = k + 1$, 转步骤 b。

EPSO 算法可根据离散时刻在线采样得到的发电机输出数据进行迭代操作,因此适用于同步电机参数的在线辨识。

4 数字模拟试验

为了验证本文算法,在量测量 $\Delta\omega_i$, ΔV_i , ΔP_i 和 ΔV_j 受到 4 种程度干扰的情况下,对 EP 算法、PSO 算法和 EPSO 算法分别做了模拟仿真试验。励磁激励采用的逆 PRBS 信号,幅值大小为 0.002(标么值),待辨识参数值初始范围取为真值的 $\pm 200\%$,量测量干扰采用正态分布的信号 $N(0, \sigma^2)$, σ^2 取 0, 0.0001, 0.0005 和 0.001 这 4 种测试情况。EPSO 算法中粒子数选取为 m 取 1, n 取 2, 前 300 次迭代考虑算法的概率随机性影响。

由于 EP 算法、PSO 算法和 EPSO 算法本质上是随机搜索算法,因此每次运行结果略有不同。为能客观地比较各算法的性能,我们分别将算法运行多次(在本研究中为 10 次),取一组最佳的结果为准。最佳的标准是指 3 个最大的辨识值与设计值之间的相对误差之和为最小。

表 1 给出了 3 种算法的仿真试验结果,取 3 个最大的辨识值与设计值间的相对误差来衡量算法的综合辨识能力。由表 1 的试验结果可知, EPSO 算法显著地提高了 PSO 算法的全局收敛能力,在系统量测量受到较大干扰的情况下, EPSO 算法辨识结果的最大误差与 EP 算法很接近,而其他辨识结果的误差显著小于 EP 算法的辨识结果。因此, EPSO 算法参数辨识的综合能力强于 EP 算法。与 PSO 算法相比较,在较大干扰情况下, PSO 算法的发散趋势比较明显。因此, EPSO 算法的辨识结果更为可靠。

图 4~图 6 给出了系统量测量的实测响应与由参数辨识仿真所得响应的比较。由图可知,通过 EPSO 算法辨识仿真所得响应曲线可以比较准确地拟合实测响应曲线,因此采用 EPSO 算法所得到的参数是较为准确、可靠的。

表 1 数字模拟试验结果
Table 1 Results of the identification test

方法		X_d	X_d'	X_q	T_{d0}'	M	D	3 个最大误差/(%)
$\sigma^2 = 0$	EP	1.292	0.265	1.102	4.875	8.525	5.315	6.43 6.05 3.37
	PSO	1.273	0.272	1.172	4.840	8.513	4.810	9.24 4.03 3.83
	EPSO	1.286	0.261	1.162	4.901	8.605	5.362	6.98 4.82 2.62
$\sigma^2 = 0.0001$	EP	0.993	0.223	1.160	5.183	9.045	5.765	23.14 15.02 10.44
	PSO	0.891	0.257	1.337	5.052	8.787	5.514	31.04 17.28 10.02
	EPSO	1.211	0.252	1.246	4.967	8.771	5.126	9.30 6.27 2.27
$\sigma^2 = 0.0005$	EP	1.002	0.254	1.430	5.114	8.833	5.748	25.44 22.45 14.68
	PSO	1.328	0.285	1.484	4.915	8.621	4.710	30.18 14.46 6.03
	EPSO	1.295	0.265	1.437	4.756	8.671	5.199	26.05 6.43 5.45
$\sigma^2 = 0.01$	EP	0.991	0.235	1.580	5.486	9.099	5.812	38.6 23.30 15.96
	PSO	1.234	0.284	1.700	4.900	8.656	4.631	49.12 14.06 7.60
	EPSO	1.513	0.251	1.439	4.813	8.847	4.745	26.23 17.11 5.33
设计值		1.292	0.249	1.140	5.033	8.822	5.012	

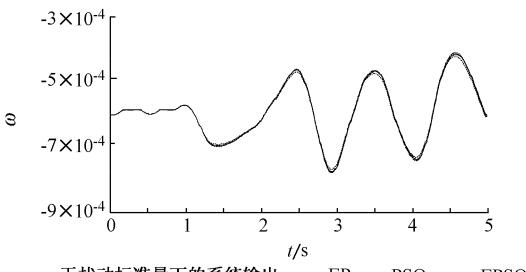


图 4 逆 PRBS 激励下的 $\Delta\omega_i$ 响应

Fig. 4 Machine speed response

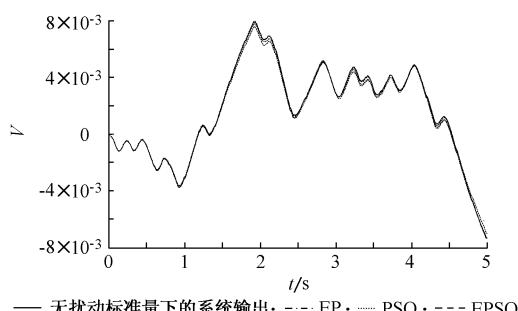


图 5 逆 PRBS 激励下的 ΔV_i 响应

Fig. 5 Terminal voltage response

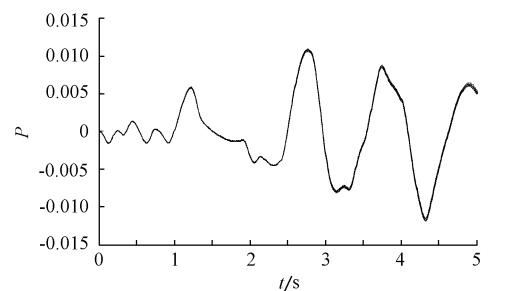


图 6 逆 PRBS 激励下的 ΔP_i 响应

Fig. 6 Generator power response

在实时参数辨识过程中,对算法的收敛速度有很高要求, EPSO 算法由于在收敛过程中具有较强

的方向性,因此收敛速度一般较 EP 算法快。在 4 种测试情况下, EPSO 算法迭代 450 次左右即收敛,而 EP 算法需要迭代 600 次左右。而且由于 EPSO 算法的局部寻优过程是将粒子群划分为几个部分分别迭代处理的,几部分粒子群之间并没有信息交互,因此可以很容易地对几部分局部粒子进行并行处理,以期达到实时要求。

5 结语

本文提出了一种新的进化算法——EPSO 算法并应用于同步发电机参数辨识。在 PSO 算法的基础上,综合考虑更多粒子在寻优过程中的位置信息来更新各个粒子的位置值,并且提出了根据粒子的适应值大小确定相关权系数的方法,确保了 EPSO 算法的收敛性。仿真结果表明了 EPSO 算法比 EP 算法具有更好的参数综合辨识能力以及更有效率的收敛性。本文提出的 EPSO 算法模型具有通用性,可以应用于其他的优化问题。

参 考 文 献

- 沈善德(Shen Shande). 电力系统辨识(Electric Power System Identification). 北京: 清华大学出版社(Beijing: Tsinghua University Press), 1993
- 米增强,陈志忠,南志远,等(Mi Zengqiang, Cheng Zhizhong, Nan Zhiyuan, et al). 同步发电机动态参数辨识(Dynamic Parameter Identification of Synchronous Machines). 中国电机工程学报(Proceedings of the CSEE), 1998, 18(2): 100~105
- Ma J T, Hong B W, Nan Z Y, et al. Determination of Synchronous Generator Parameters by System Identification. In: Proceedings of International Conference on Electrical Machines, Vol 1. Manchester(UK): Manchester University, 1992. 54~58
- Ma J T, Wu Q H. Generator Parameter Identification Using Evolutionary Programming. Electrical Power and Energy Systems, 1995, 17(6): 417~423
- 黄开胜,童怀,郑泰胜,等(Huang Kaisheng, Tong Huai, Zheng Tai Sheng, et al). Generator Parameter Identification Using Evolutionary Programming. Electrical Power and Energy Systems, 1995, 17(6): 417~423
- 黄开胜,童怀,郑泰胜,等(Huang Kaisheng, Tong Huai, Zheng Tai Sheng, et al). Generator Parameter Identification Using Evolutionary Programming. Electrical Power and Energy Systems, 1995, 17(6): 417~423
- 黄开胜,童怀,郑泰胜,等(Huang Kaisheng, Tong Huai, Zheng Tai Sheng, et al). Generator Parameter Identification Using Evolutionary Programming. Electrical Power and Energy Systems, 1995, 17(6): 417~423

Zheng Taisheng, et al). 遗传算法在异步电动机动态模型参数识别中的应用 (Parameter Estimation for an Induction Motor's Dynamic Model Using Genetic Algorithms). 中国电机工程学报 (Proceedings of the CSEE), 2000, 20(8): 37~41

- 6 Eberhart R, Kennedy J. A New Optimizer Using Particle Swarm Theory. In: Proceedings of the Sixth International Symposium on Micro Machine and Human Science. New York: IEEE, 1995. 39~43
- 7 Kennedy J, Eberhart R. Particle Swarm Optimization. In: Proceedings of IEEE International Conference on Neural Networks, Vol 4. New York: IEEE, 1995. 1942~1948

胡家声(1979—),男,博士研究生,主要研究方向为智能计算方法、电力系统优化运行、电力系统规划与可靠性。
E-mail: huijasheng@263.net

郭创新(1969—),男,博士,高级工程师,研究方向为智能计算方法、电力系统优化调度及信息技术在电力系统中的应用。

曹一家(1969—),男,长江学者特聘教授,博士生导师,主要研究领域为电力系统优化与控制、智能控制系统与决策以及信息技术在电力系统中的应用。

GENERATOR PARAMETER IDENTIFICATION BASED ON EXTENDED PARTICLE SWARM OPTIMIZATION METHOD

Hu Jiasheng, Guo Chuangxin, Cao Yijia
(Zhejiang University, Hangzhou 310027, China)

Abstract: A new method of extended particle swarm optimization (EPSO) is presented and used to the generator parameter identification. Based on the original particle swarm optimization(PSO) method, EPSO method uses more particles' information to control the mutation operation and employs coefficients through the comparison of particles' fitness values, thus the convergence of the extended method is ensured. Under the condition of measurements of generator which are highly contaminated by noise, EPSO method possesses stronger capability of parameter identification than EP and PSO methods and has better integrated identification capability of parameters than EP method. Numerical simulation results demonstrate the conclusion.

This work is supported by National Natural Science Foundation of China (No. 60074040)

Key words: synchronous generator; parameter identification; extended particle swarm optimization (EPSO)