

RBF 网络参数优化方法及其在开关磁阻电机建模中的应用

彭晓燕, 谭震, 陈昌荣, 黄源

湖南大学; 汽车车身先进设计制造国家重点实验室, 长沙 410082

摘要 基于全局搜索的进化算法——粒子群算法(QPSO)和一种局部搜索算法——结构化的非线性参数优化方法(SNPOM), 提出了一种混合的优化算法估计 RBF 神经网络中的参数——网络中心、线性参数、非线性参数, 初始化一定数目的种群作为 SNPOM 的初始值, 得到其适应值, 通过选择、交叉、替换策略更新种群, 完成网络中心初始值的寻优。再用 SNPOM 方法进一步优化, 以提高 SNPOM 算法的全局搜索能力。仿真结果表明, 混合优化方法比单独采用 SNPOM 法更优, 且优于其他算法。并针对开关磁阻电机(SRM)高度非线性的开发重点和难点, 用 RBF 网络进行 SRM 建模, 将 QPSO-SNPOM 算法应用于 RBF 模型参数优化中, 仿真实验结果表明, 该算法较 SNPOM 算法精度更高、泛化能力更强, 较遗传混合算法更快, 训练后的 RBF 模型完全满足开关磁阻电机特性。

关键词 QPSO-SNPOM 混合参数优化方法; 径向基函数网络; 开关磁阻电机建模

中图分类号 TM352

文献标识码 A

文章编号 1000-7857(2010)19-0042-04

Method of RBF Network Parameters for the Optimization of Switched Reluctance Motor Modeling

PENG Xiaoyan, TAN Zhen, CHEN Changrong, HUANG yuan

State Key Laboratory of Advanced Design and Manufacturing for Vehicle Body, Hunan University, Changsha 410082, China

Abstract Based on the evolutionary algorithm, Quantum-behaved Particle Swarm Optimization (QPSO), and the local search strategy, Structured Nonlinear Parameter Optimization Method (SNPOM), a hybrid parameter optimization algorithm (QPSO-SNPOM) for RBF neural networks is proposed. The approach starts with a population of random initial parameter values, and updates the population by selection, crossover, and replacement according to the fitness values obtained by the SNPOM. It is shown through simulation tests that the combination provides better results than either method alone (QPSO or SNPOM) and many other existing algorithms. The switched reluctance motor is a new development in motor technologies, and its characteristics, such as the small starting current, the strong starting torque, and simple structure, have made it a very attractive design. However, it has proven difficult to develop accurate SRM models because SRM exhibits highly-nonlinear characteristics. Therefore, we construct a RBF network model of the SRM, and apply our new method, QPSO-SNPOM, to optimize the parameters of the RBF network model. The simulation results show that the RBF training error is smaller, and the system is more capable of generalization when optimized by this new method rather than by SNPOM. In addition, the training time is shorter than it is when applying evolutionary algorithms. We also confirm that the trained RBF network completely models the characteristics of the SRM.

Keywords QPSO-SNPOM optimization method; radial basis function network; switched reluctance motor modeling

0 引言

径向基函数(Radial Basis Function, RBF)网络是一种前

馈式神经网络, 具有结构简单、泛化能力强、可逼近任意函数等优点, 广泛应用于模式识别、函数逼近、信号处理等领域。

收稿日期: 2010-06-30; 修回日期: 2010-09-06

基金项目: 湖南省自然科学基金项目(07JJ3126)

作者简介: 彭晓燕, 教授, 研究方向为汽车电子与控制工程, 电子邮箱: xypeng@hotmail.com

目前常用的 RBF 网络参数优化算法主要有随机算法、自组织学习算法、最近邻聚类算法等。这些算法均存在中心点数无法确定、计算量大和易出现数据病态等缺点。2003 年, Peng 等^[1]提出了基于结构化非线性参数优化方法 (Structured Nonlinear Parameter Optimization Method, SNPOM), 该方法在收敛速度和收敛精度方面都较普通的梯度法有了很大的提高, 但存在网络中心初值选择带有盲目性、易陷入局部最优解的缺陷。文献[2]提出将遗传算法与 SNPOM 算法结合成为遗传混合算法, 用遗传算法进行网络中心初始值的寻优以提高 SNPOM 算法的全局搜索能力, 但也因引入遗传算法导致优化速度较慢。粒子群算法 (Quantum-based Particle Swarm Optimization, QPSO) 具有结构简单、学习速度快、全局搜索等优点^[3-4], 本文将 QPSO 算法与 SNPOM 方法结合, 提出了一种新的混合参数优化方法 QPSO-SNPOM, 用 QPSO 算法进行网络中心初始值计算, 再用 SNPOM 进一步优化其他网络参数, 从而避免了 SNPOM 算法在网络中心初值选择的盲目性和易陷入局部最小值的缺点, 提高了 RBF 神经网络泛化能力和精度, 同时训练速度较文献[2]的方法得到了很大提高。

开关磁阻电机 (Switched Reluctance Motor, SRM) 具有结构简单、启动电流小、启动转矩大等优点, 在电机领域得到广泛应用。但 SRM 高度非线性的特点使电机磁链与电流、转子位置角的数学模型难以准确建立。国内外学者针对如何建立 SRM 电机数学模型做了大量研究, Lawrenson^[5]提出了 SRM 电机线性数学模型, Buja 等^[6-7]提出局部线性化建模方法, Sahoo 等^[8]利用查表法和模糊逻辑建立电流模型等, 但这些方法在一定程度上忽略了非线性因素, 所建模型实用性较差。Elmas^[9]提出按误差逆传播算法训练的多层前馈网络 (BP) 分析 SRM 的模型, 开创了用神经网络建立电机模型的方法, 但由于 BP 网络采用一阶梯度下降法进行网络训练, 网络训练收敛速度慢, 易陷入局部极小值。RBF 神经网络是一种优良的前馈式神经网络, 相比 BP 网络, 具有以下优点: 全局逼近能力强, 不易陷入局部最优解; 拓扑结构紧凑, 结构参数可实现离线学习; 收敛速度快。采用 RBF 网络建立 SRM 模型不但可以简化神经网络结构, 加快训练速度, 模型精度也远高于 BP 网络。

本文应用 RBF 网络建立 SRM 磁链与电流、转子位置角模型, 并用 QPSO-SNPOM 算法对此模型进行参数优化。仿真结果表明, 优化的 RBF 模型精度比单独采用 SNPOM 优化的 RBF 模型精度更高、泛化能力更强, 在训练精度相近的情况下网络收敛速度较文献[2]中方法更快。

1 径向基函数网络结构

RBF 神经网络是一种 3 层前向网络, 第 1 层为输入层, 由信号源结点组成; 第 2 层为隐含层, 隐单元的变换函数是 RBF, 是对中心点径向对称且衰减的非负非线性函数; 第 3 层为输出层, 对输入模式的作用做出响应。从输入层空间到隐

含层空间的变换是非线性的, 而从隐含层空间到输出层空间的变换是线性的。

RBF 神经网络最常用的径向基函数是高斯函数。高斯 RBF 神经网络可以表示为

$$y(t) = \theta_0 + \sum_{k=1}^p \theta_k \exp\{-\lambda_k \|X(t-1) - Z_k\|_2^2\} + e(t) \quad (k=1, 2, \dots, p) \quad (1)$$

其中, $Z_k = (z_{k,1}, z_{k,2}, \dots, z_{k,n_x})$ 为 RBF 神经网络的神经元中心, n_x 为每个神经元对应的输入维数, 即神经网络神经元中心的维数; p 为 RBF 网络中隐含层神经元的数目, θ_k 为 RBF 神经网络的线性加权系数, λ_k 为 RBF 神经网络非线性加权系数; $\|\cdot\|_2$ 为向量或矩阵二次范数运算, $X(t-1)$ 为网络输入。

对于 RBF 神经网络, 需要优化的参数有隐含层神经元数目 p 、线性加权系数 θ_k 、非线性加权系数 λ_k 、神经元中心 Z_k 。

2 QPSO-SNPOM 混合参数优化方法

2.1 SNPOM 参数优化方法

SNPOM 参数优化方法^[1]的主要思路是将参数搜索空间分成线性参数子空间和非线性参数子空间, 在非线性的空间寻找中心, 在每次优化叠加过程中, 非线性 (或者线性) 空间都是基于已有的上一次线性 (或非线性) 空间计算结果。在非线性子空间中的寻优方法与列文伯格-马夸尔特法 (LMM) 相似, 在线性子空间使用最小二乘法 (LSM 法) 寻优。

将式 (1) 改写成如下形式:

$$y(t) = \varphi(\theta_N, X(t-1))^T \theta_L + e(t) \quad (2)$$

其中, $\varphi(\cdot)$ 是由 θ_N 和 $X(t-1)$ 构成的非线性函数列矩阵, 等价于 $\exp\{-\lambda_k \|X(t-1) - Z_k\|_2^2\}$ 构成的列矩阵; $\theta_L = (\theta_0, \theta_1, \dots, \theta_p)^T$, $\theta_L \in R^{p+1}$, 表示线性参数; $\theta_N = (\lambda_1, \lambda_2, \dots, \lambda_p, Z_1^T, Z_2^T, \dots, Z_p^T)^T$, $\theta_N \in R^{p+p \times n_x}$, 表示非线性参数。

SNPOM 方法以训练输入数据的平均值或随机数为神经网络中心初始值进行网络参数优化, 因此存在网络中心初值选择具有盲目性、易陷入局部最优解的缺陷。

2.2 QPSO 优化算法

QPSO 算法^[3-4]是标准粒子群 (Particle Swarm Optimization, PSO) 算法的改进算法, 也是进化算法中较为简单有效的一种。这种算法具有全局搜索、优化速度快的优点。本文用此算法初步寻找神经网络中心全局最优解, 以此作为网络中心初始值, 然后采用 SNPOM 算法进行网络参数的进一步优化, 以弥补 SNPOM 算法的缺陷。

2.3 QPSO-SNPOM 混合参数优化方法

QPSO-SNPOM 混合优化方法的基本思想为, 网络中心的初始值 QPSO 算法优化结果代替原来的随机获取值或训练数据平均值, 用 SNPOM 算法对 QPSO 算法搜索得到的初始值进行再次优化, 得到 RBF 网络的最终优化参数。具体步骤如下。

- 1) 确定 RBF 中心数目、种群大小及初始种群取值范围。逐步增加 RBF 神经网络中心数目, 计算不同数目对应的

AIC 值。AIC 值是衡量神经网络规模合理与否的指标, AIC 越小则网络越合理。AIC 值最小时的网络中心数目即为最佳。其计算公式为

$$AIC = \ln V + 2(s+1)/M \quad (3)$$

其中, V 为模型的残差方差, s 为估计参数的总个数, M 为测试样本数目。

粒子群的大小根据问题的难易程度确定, 一般取 50 个个体。初始种群取值范围与训练数据的范围相同。

2) 利用 SNPOM 参数优化方法计算粒子群个体的适应度函数^[1]。

将粒子群个体作为网络中心, 计算 RBF 宽度

$$\lambda_k = -\ln[\varepsilon_k / \max(\|X(t-1) - Z_k\|_2)] \quad (4)$$

其中, $\varepsilon_k \in [0.0001, 0.1]$ 。

将非线性参数 θ_N 代入式(5)计算线性参数 θ_L 。

$$\begin{aligned} \theta_L^0 &= R(\theta_N^0)^{-1} \bar{Y} \\ R(\theta_N^0)^{-1} &= [R(\theta_N^0)^T R(\theta_N^0)]^{-1} R(\theta_N^0)^T \\ R(\theta_N^0) &= \begin{bmatrix} \varphi(\theta_N^0, \bar{X}(\tau)^T) \\ \varphi(\theta_N^0, \bar{X}(\tau+1)^T) \\ \vdots \\ \varphi(\theta_N^0, \bar{X}(M-1)^T) \end{bmatrix} \\ \bar{Y} &= [\bar{y}(\tau+1) \quad \bar{y}(\tau+2) \quad \cdots \quad \bar{y}(M)]^T \end{aligned} \quad (5)$$

其中, $\{(\bar{y}(i), \bar{X}(i-1)) | i = \tau+1, \tau+2, \dots, M\}$ 为测量数据集, τ 为式(5)中任意可估计变量的最大时间延迟, M 为训练个数。

神经网络优化目标函数为

$$V(\theta_N, \theta_L) = \frac{1}{2} \|F(\theta_N, \theta_L)\|_2^2 \quad (6)$$

其中,

$$F(\theta_N, \theta_L) = \begin{bmatrix} \hat{y}(\tau+1|\tau) - \bar{y}(\tau+1) \\ \hat{y}(\tau+2|\tau+1) - \bar{y}(\tau+2) \\ \vdots \\ \hat{y}(M|M-1) - \bar{y}(\tau+1) \end{bmatrix}$$

$$\hat{y}(t+1|t) = f(\theta_N, \theta_L, \bar{X}(t)) \quad (t = \tau, \tau+1, \tau+2, \dots, M-1)$$

利用 Matlab 自带的 Lsqnonlin 函数对式(5)进行网络中心优化, 然后将优化后的中心代入式(4)、式(5), 计算出整个网络的参数。将该网络计算得到的输出值与真实值的平均差作为粒子群个体的适应度函数。

$$\Delta = \sum_{i=1}^M \frac{F_i(\theta_N, \theta_L) - \bar{F}_i}{M} \quad (7)$$

式中, Δ 为适应度值, $F_i(\theta_N, \theta_L)$ 为以种群个体为神经网络中心初值利用 SNPOM 参数优化方法训练得到的神经网络输出值, \bar{F}_i 为真实值。

3) 采用 QPSO 算法计算最优解, 作为 RBF 网络中心初始值^[3-4]。

$$m_{best} = \frac{1}{M} \sum_{i=1}^M p_i = \frac{1}{M} \left[\sum_{i=1}^M p_{i1} \sum_{i=1}^M p_{i2} \cdots \sum_{i=1}^M p_{id} \right] \quad (8)$$

$$p_{ij} = \varphi \cdot p'_{ij} + (1-\varphi) p_{gd} \quad (9)$$

$$Z(t+1) = p_{id} + \beta \cdot m_{best} - Z(t) \cdot \ln\left(\frac{1}{u}\right) \quad (10)$$

其中, m_{best} 是粒子群的平均最佳位置, p_{ij} 是 p'_{ij} 和 p_{gd} 之间的随机数, $j \in [0, d]$, p'_{ij} 表示第 j 个粒子的适应度, d 为粒子群的维数, φ 和 u 为 $[0, 1]$ 之间的随机数, β 为收缩扩张参数, $Z(t+1)$ 表示网络中心经过一次粒子算法计算后得到的新的网络中心。

具体计算过程为: ① 初始化粒子群; ② 根据式(8)计算 m_{best} ; ③ 根据式(7)计算每个粒子的适应度 p_i ; ④ 对于每个粒子, 比较 p_{id} , 求得 p_{gd} ; ⑤ 对于粒子的每一维, 根据式(9), 在 p_{id} 和 p_{gd} 之间取得一个随机点; ⑥ 根据式(10)获得一个新的位置; ⑦ 重复步骤②~⑥, 直到条件满足, 迭代结束, 求出网络初始值。

4) 优化的网络中心初始值按 SNPOM 参数优化方法继续进行神经网络参数优化, 直到满足误差要求。

3 QPSO-SNPOM 混合参数优化方法在 SRM 建模中的应用

本文建立的 SRM 模型应用于电机的转矩控制中, 以电流为控制对象, 基于 RBF 神经网络的 SRM 模型以电流、转子位置角为输入变量, 磁链值为输出。

$$\psi(i, \theta) = F(i, \theta) \quad (11)$$

其中, ψ 为电机磁链值, i 为电机电流, θ 为电机转子位置角。

应用 QPSO-SNPOM 混合参数优化方法优化该 RBF 网络模型。以 8/6 (电机定子项数/转子项数)、4 相、额定功率为 1.5kW 的 SRM 试验数据 (电流、转子位置角、磁链值) 为网络模型的训练测试样本。训练测试数据中的电流和转子位置角的取值范围分别为 0~12.6A 和 0°~60°, 在此范围内均匀选取 3 组数据, 每组 130 个, 第 1 组用来训练, 后 2 组用来测试。

按 QPSO-SNPOM 混合参数优化方法优化 SRM 的 RBF 模型, 通过训练, 隐含层神经元个数为 17 时模型效果最佳。

为了验证 QPSO-SNPOM 参数优化方法在 SRM 建模中的优势, 本文在神经元数目相等 (17 个神经元), 训练、测试数据训练步数相同的情况下, 分别采用 QPSO-SNPOM 混合参数优化方法、SNPOM 参数优化法和文献[2]提出的遗传混合方法对 SRM 的 RBF 神经网络模型进行训练和测试, 仿真结果及对比分析如图 1~图 3、表 1 所示。

从图 1 可以看出, 采用混合优化方法的网络误差比单独采用 SNPOM 优化方法的网络误差平均减小了一个数量级, 且误差结果更加平稳, 证明采用混合优化方法优化的网络模型误差小、精度高。由图 2 可知, 采用 QPSO-SNPOM 混合优化方法所得网络磁链、电流、转角模型曲线与实验曲线基本重合, 且满足 SRM 的磁链特性, 说明采用 QPSO-SNPOM 混合优化方法训练的 SRM 模型有很高的泛化能力。由表 1 可知, 3




图 1 误差对比图

Fig. 1 Curves of compared error




图 2 SRM 的 RBF 神经网络模型仿真结果

Fig. 2 Simulation waveforms of RBF neural networks of SRM




图 3 RBF 模型所得磁链-电流-转子位置角三维图

Fig. 3 Magnetic linkage-current-rotor three-dimensional image from RBF model

种方法的训练时间分别为 35,30,50min, 可见 QPSO-SNPOM 法比单独采用 SNPOM 法训练时间长了 5min, 但测试精度提高了一个数量级。虽然 QPSO-SNPOM 法精度与文献[2]中方法相近,但训练时间大大缩短。

表 1 训练时间对比

Table 1 Comparison of training time

优化方法名称	训练时间/min		
	第 1 组(训练)	第 2 组(测试)	第 3 组(测试)
SNPOM	35	40	41
QPSO-SNPOM	30	38	37
文献[2]算法	50	56	58

综上, 采用 QPSO-SNPOM 混合优化方法训练 SRM 模型在用时较短的情况下可以达到很高的精度,具有很强的泛化能力。

4 结论

结合 QPSO 和 SNPOM 的混合参数优化新方法具有训练精度高、泛化能力强、训练时间短的优点。将此方法应用于 SRM 的 RBF 模型训练中, 仿真结果与实验值对比表明,SRM 的 RBF 网络模型测试结果与实验值比较误差很小,完全可以代替电机真实值,同时模型具有很强的泛化能力,用训练后的 RBF 网络模型作为 SRM 仿真对象是完全可行、合理的。

参考文献 (References)

- [1] Peng H, Ozaki T, Haggan-Ozaki V, et al. A parameter optimization method for radial basis function type models [J]. *IEEE Transactions on Neural Networks*, 2003, 14(2): 432-438.
- [2] 甘敏, 彭晓燕, 彭辉. 神经网络参数混合优化算法 [J]. *控制与决策*, 2009, 24(8): 1172-1176.
Gan Min, Peng Xiaoyan, Peng Hui. *Control and Decision*, 2009, 24(8): 1172-1176.
- [3] Sun J, Feng B, Xu W B. Particle swarm optimization with particles having quantum behavior [C]//*Proceedings of the 2004 Congress on Evolutionary Computation*. 2004: 325-331.
- [4] Sun J, Xu W B, Feng B. A global search strategy of quantum-behaved particle swarm optimization[C]//*Proceedings of 2004 IEEE Conference on Cybernetics and Intelligent Systems*. 2004, 1: 111-116.
- [5] Lawrenson P J, Stephenson J M, Fulton N N, et al. Variable-speed switched reluctance motors [J]. *IEEE Proceedings B: Electric Power Applications*, 1980, 127(4): 253-265.
- [6] Buja G S, Valla M I. Control characteristics of the SRM drives. I. Operation in the linear region [J]. *IEEE Transactions on Industrial Electronics*, 1991, 38(5): 313-321.
- [7] Buja G S, Valla M I. Control characteristics of the SRM drives. II. Operation in the saturated region [J]. *IEEE Transactions on Industrial Electronics*, 1994, 41(3): 316-325.
- [8] Gobbi R, Sahoo N C, Ahamed Khan M K A. A fuzzy logic based current modulation for torque ripple minimization in switched reluctance motors [C]//*Proceedings of Power and Energy Conference*. 2004: 46-51.
- [9] Elmas C, Sagioglu S, Colak I, et al. Modelling of a nonlinear switched reluctance drive based on artificial neural networks[EB/OL]. [2010-05-30]. http://www.dee.hcmut.edu.vn/vn/bomon/bmthietbi/dongco_tutro/srm/18.pdf.

(责任编辑 刘志远)