

文章编号: 1000-8152(2007)04-0601-06

基于模糊神经网络的双凸极永磁电机非线性建模

孙 强¹, 程 明²

(1. 合肥学院 电子信息与电气工程系, 安徽 合肥 230022; 2. 东南大学 电气工程学院, 江苏 南京 210096)

摘要: 双凸极永磁电机的电感、磁链等特性呈严重非线性, 常规的线性或准线性模型难以准确反映双凸极永磁电机的实际特性, 影响双凸极永磁电机的控制精度和工作性能。为此, 本文提出采用自适应模糊神经网络建立双凸极永磁电机模型的新方法。首先在介绍了自适应模糊神经网络结构后, 采用改进的递推最小二乘法修改网络参数, 同时采用遗传算法对遗忘因子和学习率进行了优化, 仿真计算和实测结果表明, 该模型有很快的收敛性和很高的精确度, 最后给出了利用模型实现双凸极永磁电机优化控制的方法。

关键词: 双凸极永磁电机; 非线性模型; 自适应模糊神经网络; 混合算法; 遗传算法

中图分类号: TP341 文献标识码: A

Nonlinear modeling for doubly salient permanent magnetic motor based on fuzzy neural network

SUN Qiang¹, CHENG Ming²

(1. Department of Electrical and Electronic Engineering, Hefei University, Hefei Anhui 230022, China;
2. School of Electrical Engineering, Southeast University, Nanjing Jiangsu 210096, China)

Abstract: The doubly salient permanent magnet (DSPM) machine has high nonlinear characteristics of inductance and flux linkage, etc. The normal linear or quasi-linear modeling can not reflect the real nonlinear characteristics of the DSPM machine, degrading control precision and operational performance. In this paper, a new modeling method is proposed for the DSPM machine to take into account its nonlinearity more accurately by using adaptive-network-based fuzzy inference system. After the structure of adaptive-network-based fuzzy inference system is introduced, the recursive least squares method is improved and applied to modify the parameters of the network. Moreover, the forgetting factor and learning rate are optimized by using genetic algorithm. Both simulation and experiment have shown that the developed modeling offers the advantages of fast convergence and high precision. Finally, the optimal controller based on the modeling for the DSPM motor is developed.

Key words: doubly salient permanent magnet motor; nonlinear modeling; adaptive-network-based fuzzy inference system; hybrid algorithm; genetic algorithm

1 引言(Introduction)

双凸极永磁(简称DSPM)电机结构具有简单可靠、功率密度高、效率高、可控参数多、容错性能好、适于高速运行等优点, 因此引起国内外学者的广泛关注^[1~5]。但因定转子都是凸极, 使电路和磁路呈现出强烈的非线性、开关性、强耦合性, 造成数学模型难以准确建立。目前, DSPM电机的数学模型都是采用有限元等方法算出有限个处于一定电流和一定转子位置的参数后以表格形式存储起来, 或对此参数进行拟合, 在电机控制中采用插值等办法求出相应的参数, 或干脆用平均值或某一电流下的

参数(即不计饱和)^[1~3,6,7], 该模型是线性的或是准线性的, 不能准确反映DSPM电机的非线性特性, 使得在优化电流波形以降低转矩脉动、优化能量转换提高效率以及位置控制、速度控制和转矩控制等方面实现难度加大。因此, 应寻找一种能更准确建立DSPM电机数学模型的新方法。

Elmas提出用BP神经网络分析开关磁阻电机(SRM)的模型^[8], 建立了磁链 Ψ 与相电流*i*和转子位置角 θ 之间非线性关系式, 但BP神经网络常存在训练时间长或者陷入局部极值的可能。与SRM类似, 本文采用自适应模糊神经网络系统(ANFIS), 建立一

台三相6/4极DSPM电机合成磁链 Ψ 与相电流 i 和转子位置角 θ 之间非线性数学模型, 并用遗传算法优化了初始值, 仿真分析表明优化后建立的模型较之BP神经网络模型具有更快的收敛速度和更高的精度.

2 自适应模糊神经网络结构(Adaptive-network-based fuzzy inference system)

模糊逻辑系统已经广泛应用于系统建模、系统控制、系统识别和系统预测等^[9], 但缺乏自学习和自适应能力.

神经网络参数可根据输入、输出样本学习, 具有自学习和自适应能力, 且神经网络可逼近任意非线性函数, 但神经网络所获得的输入/输出关系无法用容易被人接受的方式表示出来^[10].

为此提出了模糊逻辑系统和神经网络相结合的模糊神经网络结构, 尤其是Jang-Sun提出某种模糊推理系统与径向基函数(RBF)神经网络等效后^[11], 更为二者的融合提供了理论依据.

自适应模糊神经网络是被广泛应用的一种, 可分为3种类型, 其中第3种就是Sugeno-Takagi(简称ST)型^[12], 它每条规则的输出都是输入量与常数项的线性组合:

If x is A and y is B , Then $f = px + qy + r$.

其中: A, B 是输入量 x, y 的模糊子集, p, q, r 为常参数.

由于其结论部分是清晰量, 计算简单, 因此, ST型模糊神经网络在建模和控制中应用最广, 其结构模型如图1^[12].

图1是一种多层前向网络, 其中方形节点含有可调参数, 而圆形节点固定不变, 神经元之间的连接权值都是1. 图1中各层的功能如下:

第1层是模糊化层, 它将输入量 x, y 模糊化, 其节点输出是 x, y 在模糊子集 A_1 和 A_2, B_1 和 B_2 上的隶属度值. 这里取常用的高斯形隶属度函数

$$\mu_{A_i}(x) = \exp\left[-\frac{(x - c_{A_i})^2}{2a_{A_i}^2}\right]. \quad (1)$$

式中 a_{A_i}, c_{A_i} 为待学习的前件参数. 实际上任何连续函数或分段可微函数均可作为节点函数^[12].

第2层计算每条规则的激活强度. 由于采用可微的积运算, 使得基于梯度下降的BP算法在调整参数时比不可微的与运算简单:

$$\omega_i = \mu_{A_i}(x) \times \mu_{B_i}(y). \quad (2)$$

第3层是计算每条规则的标准激活强度 $\hat{\omega}_i$, 每个节点的输出是

$$\hat{\omega}_i = \frac{\omega_i}{\sum_{k=1}^n \omega_k}. \quad (3)$$

其中 n 为规则总数, 即第3层中神经元的个数.

第4层计算每条规则的输出, 即

$$\hat{\omega}_i f_i = \hat{\omega}_i (p_i x + q_i y + r_i). \quad (4)$$

其中 p_i, q_i 和 r_i 为第 i 条规则的后件结论部分参数.

第5层是将第4层全部输出在此予以求和, 即

$$f = \sum_{i=1}^n \hat{\omega}_i f_i = \frac{\sum_{i=1}^n \hat{\omega}_i f_i}{\sum_{i=1}^n \hat{\omega}_i}. \quad (5)$$

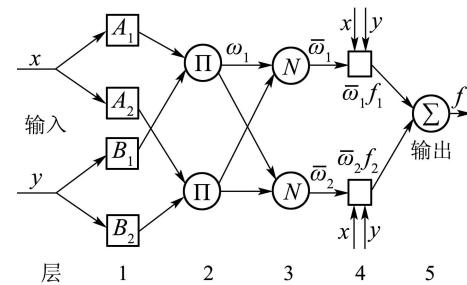


图1 ANFIS 结构模型

Fig. 1 Structure of ANFIS

3 混和算法的改进(Improvement of hybrid algorithm)

在调节模型参数时, 由于BP算法收敛速度慢, 而且可能陷入局部极小, 因此Jang提出了将BP算法与最小二乘法相结合的混和算法, 使收敛速度提高了一个数量级^[12]. 但这非严格意义的最小二乘法, 为此本文对其进行改进, 形成新的混和算法.

设共有 n 条规则, 2个输入变量, p 个训练数据对, 即 $\{(x_j, y_j, D_{hj}) | j = 1, 2, \dots, p\}$, 其中 D_{hj} 是模糊神经网络的期望输出. 若输入为 (x_j, y_j) 时, 图1输出为 R_j , 那么根据图1以及式(1)~(5)有

$$R_j = \sum_{i=1}^n \hat{\omega}_{ij} f_i = \sum_{i=1}^n \hat{\omega}_{ij} (p_i x_j + q_i y_j + r_i) = \sum_{i=1}^n (\hat{\omega}_{ij} x_j p_i + \hat{\omega}_{ij} y_j q_i + \hat{\omega}_{ij} r_i) = G_j X. \quad (6)$$

式中:

$$G_j = [\hat{\omega}_{1j} x_j \hat{\omega}_{1j} y_j \hat{\omega}_{1j} \dots \hat{\omega}_{nj} x_j \hat{\omega}_{nj} y_j \hat{\omega}_{nj}], \quad (7)$$

$$X = [p_1 \ q_1 \ r_1 \ \dots \ p_n \ q_n \ r_n]^T, \quad (8)$$

$$\hat{\omega}_{ij} = \frac{\omega_{ij}}{\sum_{i=1}^n \omega_{ij}} = \frac{\mu_{A_{i1}}(x_j) \mu_{B_{i2}}(y_j)}{\sum_{i=1}^n \mu_{A_{i1}}(x_j) \mu_{B_{i2}}(y_j)}. \quad (9)$$

$\mu_{A_{i1}}(x_j)$ 和 $\mu_{B_{i2}}(y_j)$ 是输入 x_j 和 y_j 在模糊子集 A_{i1} 和 B_{i2} 上的隶属度值, 并且二者构成第 i 条规则, $i1 = 1, 2, \dots, n1$, $i2 = 1, 2, \dots, n2$, $n1$ 和 $n2$ 为输入量的最大模糊子集数, 且有

$$n = n1 \times n2. \quad (10)$$

当 p 个训练数据对都表示成式(6)时有

$$R = GX. \quad (11)$$

调节参数后总希望网络输出为期望输出 D_{hk} , 因此式(11)的期望为

$$D_h = GX. \quad (12)$$

其中:

$$D_h = [D_{h1} D_{h2} D_{h3} \cdots D_{hp}]^T, \quad (13)$$

$$G = [G_1 G_2 G_3 \cdots G_p]^T. \quad (14)$$

通常地, p 远大于 n 及 X 的维数 $3n$, 因此式(12)是一个超定方程组, 无准确解, 但可用最小二乘法求使方差 $\|GX - D_h\|^2$ 最小的近似最优解 X^* :

$$X^* = (G^T G)^{-1} G^T D_h. \quad (15)$$

式中 $G^T G$ 有可能是奇异矩阵, 也可能是非奇异的, 奇异阵的逆不存在; 而维数很大的非奇异阵求逆将很困难费时. 为此采用递推最小二乘法^[12], 但文[12]中的递推最小二乘法不是严格的, 将严格意义上的递推最小二乘法应用于后件参数求解^[13]:

$$\begin{cases} k_i = \frac{S_i G_{i+1}}{1 + G_{i+1}^T S_i G_{i+1}}, \\ X_{i+1} = X_i + k_i (D_{h(i+1)}^T - G_{i+1}^T X_i), \\ S_{i+1} = S_i - k_i G_{i+1}^T S_i. \end{cases} \quad (16)$$

式中 G_{i+1}^T 为式(14)中第 $i+1$ 行矢量, $D_{h(i+1)}^T$ 为式(13)中第 $i+1$ 个元素, S 是递推最小二乘公式的增益矩阵, 初始条件为 $X_0 = 0$, $S_0 = \xi \cdot I$, ξ 是一个较大的正数, 介于 $10^5 \sim 10^{10}$, I 是一个 $3n \times 3n$ 的单位阵, $i = 0, 1, \dots, p-1$. 当式(16)用于时变对象时, 由于“数据饱和”, 式(16)应修改为

$$\begin{cases} k_i = \frac{S_i G_{i+1}}{1 + G_{i+1}^T S_i G_{i+1}}, \\ X_{i+1} = X_i + k_i (D_{h(i+1)}^T - G_{i+1}^T X_i), \\ S_{i+1} = \frac{1}{\lambda_{i+1}} (S_i - k_i G_{i+1}^T S_i). \end{cases} \quad (17)$$

其中 λ 称为遗忘因子, 应有以下特征: 在估计的初期, 为有好的收敛速度, λ 可选得小些; 在后期, 为有好的精度, λ 可趋近于1^[14], 据此设置如下:

$$\lambda_{i+1} = b + (a - b) \exp((a - 1)(i + 1)). \quad (18)$$

其中 a 在 $0.9 \sim 1$ 之间, b 在 $0.95 \sim 1$ 之间, 且 $b > a$.

设模糊神经网络每一训练数据的误差为 $E_k = \frac{1}{2}(D_{hk} - R_k)^2$, 则总的输出误差为, 根据BP算法,

可得

$$\begin{cases} \frac{\partial E_k}{\partial c_{Ai}} = -F_A(D_{hk} - R_k) \frac{x_k - c_{Ai}}{a_{Ai}^2 \alpha}, \\ \frac{\partial E_k}{\partial a_{Ai}} = -F_A(D_{hk} - R_k) \frac{(x_k - c_{Ai})^2}{a_{Ai}^3 \alpha}, \end{cases} \quad (19)$$

$$\begin{cases} \frac{\partial E_k}{\partial c_{Bj}} = -F_B(D_{hk} - R_k) \frac{y_k - c_{Bj}}{a_{Bj}^2 \alpha}, \\ \frac{\partial E_k}{\partial a_{Bj}} = -F_B(D_{hk} - R_k) \frac{(y_k - c_{Bj})^2}{a_{Bj}^3 \alpha}. \end{cases} \quad (20)$$

在式(19)(20)中:

$$i=1, 2, \dots, n_1, j=1, 2, \dots, n_2, k=1, 2, \dots, p,$$

$$F_A = M_A(\alpha - \beta_A) - \beta_A(R_k - M_A),$$

$$F_B = M_B(\alpha - \beta_B) - \beta_B(R_k - M_B),$$

$$\beta_A = \sum_{j=1}^{n_2} \mu_{A_i} \mu_{B_j}, \quad \beta_B = \sum_{i=1}^{n_1} \mu_{A_i} \mu_{B_j},$$

$$M_A = \sum_{j=1}^{n_2} \frac{f_{ij} \mu_{A_i} \mu_{B_j}}{\alpha}, \quad M_B = \sum_{i=1}^{n_1} \frac{f_{ij} \mu_{A_i} \mu_{B_j}}{\alpha},$$

$$\alpha = \sum_{i=1, j=1}^{n_1, n_2} \mu_{A_i} \mu_{B_j},$$

f_{ij} 为对应于 $\mu_{A_i} \mu_{B_j}$ 的后件结论.

那么相应于整个训练集全部误差的参数微分为

$$\frac{\partial E}{\partial \beta} = \sum_{k=1}^p \frac{\partial E_k}{\partial \beta}. \quad (21)$$

其中 β 为 $a_{Ai}, c_{Ai}, a_{Bj}, c_{Bj}$ 中的任一参数.

从而第2层节点的参数修正公式为

$$\beta(k+1) = \beta(k) - \eta(k+1) \frac{\partial E(k)}{\partial \beta}. \quad (22)$$

此处 k 表示全部训练集完成的迭代代数. 式(22)中 η 为学习因子, 为有好的收敛特性, 可用自适应调整的改进算法来调节 η ^[12]: 检查权重的修正值是否真正降低了误差函数, 若是则说明所选取的 η 小了, 那么对其增加一个量; 否则就减小 η 的值. 具体修改准则是

$$\eta(k+1) = \begin{cases} 1.05\eta(k), & E(k+1) < E(k), \\ 0.7\eta(k), & E(k+1) > 1.04E(k), \\ \eta(k), & \text{其他.} \end{cases} \quad (23)$$

在自适应学习速率法中, 初始学习速率 $\eta(0)$ 的选取范围一般为 $0.1 \sim 0.5$.

为了寻求 ξ, a, b 和 $\eta(0)$ 的最优组合, 采用遗传算法

进行寻优,为了综合考虑精度和速度之间的关系,定义目标函数和适配度函数为

$$F = \sum kE, \quad (24)$$

$$g_f = \frac{1}{F}. \quad (25)$$

其中 k 为训练代数,为了与文[15]比较,取为200.根据以上介绍,可得模糊神经网络混和学习流程图2.

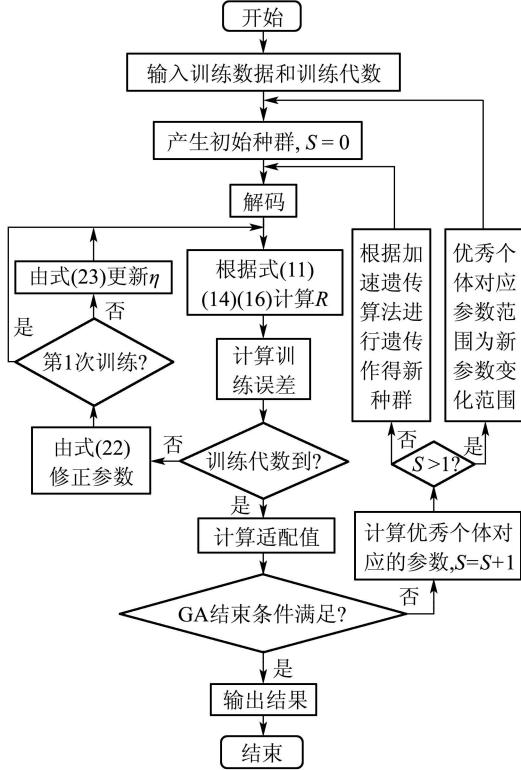


图2 自适应模糊神经网络混和学习流程图

Fig. 2 Hybrid flowchart of ANFIS

4 双凸极永磁电机建模(Modeling of DSPM machine)

用ANFIS建立DSPM电机关于 $\Psi/\theta/i$ 数学模型时,需要有精确的训练样本.本文以一6/4极DSPM电机为对象,在每隔 3° 的转子位置角 θ 处,改变电流*i*,通过有限元计算在不同电流下的磁链 Ψ .电机的结构尺寸参见文[3],由于结构的对称性,因此提取的训练样本只需半个周期就可以了.图3为有限元值和经过训练后的网络输出值.其中:“○”为所提供的训练样本点,实线为训练后所得模糊神经网络输出轨迹.由图可见两者符合很好.定义平均误差为 $\frac{1}{p} \sum_{i=1}^p |D_{hi} - R_i|^2$,那么平均误差随训练周期变化如图4.图5为检验数据结果图,为了比较,图6给出了神经网络训练时的误差训练代数的关系.由此可见自适应模糊神经网络收敛快、精度高,达到了篇首要求.

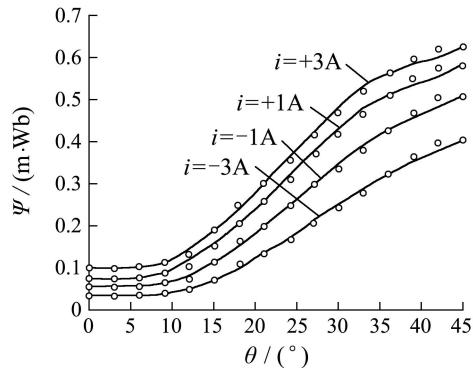


图3 训练结果与实际值比较

Fig. 3 Comparison between training value and actual one

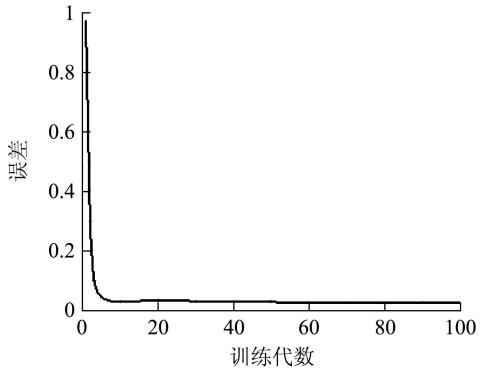


图4 误差与训练代数的关系

Fig. 4 Relation between error and training epoch

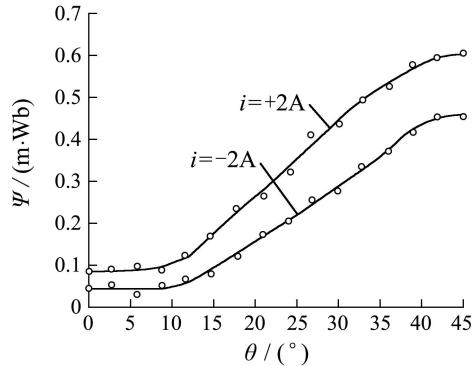


图5 检验数据结果比较图

Fig. 5 Result comparison of check data

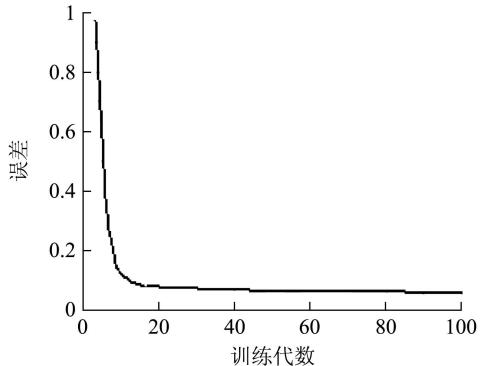
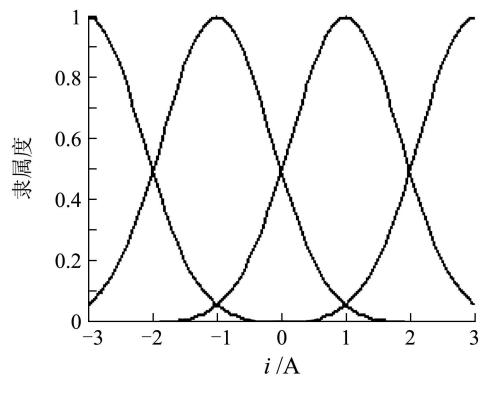


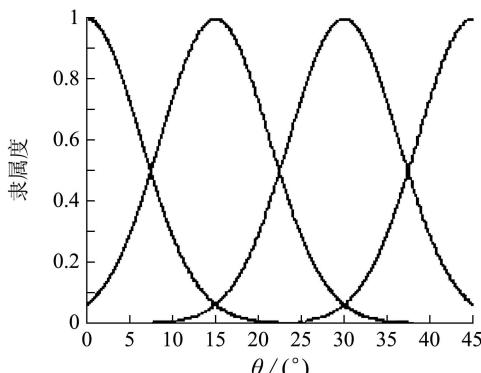
图6 神经网络误差和训练代数的关系

Fig. 6 Relation between error and training epoch with neural network

建模时, 输入量为相电流*i*和转子位置角 θ , 输出量为磁链 Ψ . 每个输入量取有4个模糊子集, 隶属度函数为高斯形函数, 初始值均匀覆盖输入变量的整个论域, 如图7(a)(b)所示. 第4层的所有后件参数初始值都设为0. 相应于输入变量模糊子集的个数, 模糊规则共有16条. 图8(a)(b)为经过训练后得到的最终隶属度函数.



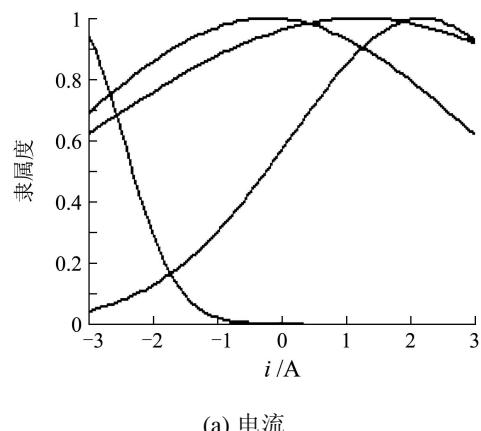
(a) 电流



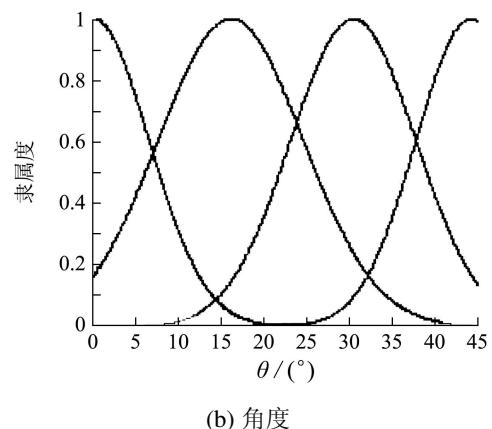
(b) 角度

图7 初始隶属度函数

Fig. 7 Initial membership function



(a) 电流



(b) 角度

图8 训练后的隶属度函数

Fig. 8 Final membership function

对于6/4极DSPM电机来说, 运行时满足以下基本方程^[1~4]:

$$u_p = R_p i_p + \frac{d\Psi}{d\theta}, \quad (26)$$

$$T_{em} = J \frac{d\omega}{dt} + k_\omega \omega + T_l. \quad (27)$$

其中: $p = a, b, c$ 表示各相序号, 而 u, R, i, Ψ 分别表示绕组的外加电压、内阻以及绕组磁链, T_{em} 为电磁转矩, J 为转动惯量, k_ω 为摩擦系数, T_l 为负载转矩.

T_{em} 为各相转矩的合成, 其每相转矩 T_{emp} 为

$$T_{emp} = \frac{\partial W'_p(\theta, i)}{\partial \theta} \Big|_{i=\text{const.}} \quad (28)$$

式中 $W'_p = \int_0^i \Psi_p(\theta, i) di_p$.

在DSPM电机模糊神经网络模型中, 如果实验条件许可, 可以利用测得电机数据来建立 $\Psi(\theta, i)$ 离线模型, 在在线控制过程中, 利用测量的 θ 和*i*值作为输入量, 可以得到 Ψ 值, 根据式(26)就可以得到转矩, 从而实现在线控制.

5 结论(Conclusion)

本文利用自适应模糊神经网络建立了DSPM电机的模型, 该模型除了训练样本, 不需要电机的任何磁特性知识, 因此, 它很适用于具有强烈非线性特性的DSPM电机的建模, 与通常的局部线性化模型相比, 所建模型更能正确反映DSPM电机的磁特性, 对参数的扰动也有很强的鲁棒性, 同时, 具有快速的收敛性、很高的精确度, 这为DSPM电机的实时在线控制创造了条件. 模型建立过程和思想方法同样适用于电励磁和混合励磁双凸极电机.

参考文献(References):

- [1] LIAO Y, LIPO T A. A new doubly salient permanent magnet motor for adjustable speed drives[J]. *Electric Machines and Power System*, 1994, 22(2): 259~270.
- [2] BLAABJERG F, CHRISTENSEN L, RASMUSSEN P O, et al. New advanced control methods for doubly salient permanent magnet mo-

- [3] CHAU K T, CHENG Ming, CHAN C C. Performance analysis of 8/6 pole doubly salient permanent magnet motor[J]. *Electric Machines and Power Systems*, 1999, 27(10): 1055 – 1067.
- [4] 沙德尚, 孔力, 孙晓. 双凸极无刷直流发电机的非线性数学模型[J]. 电工技术学报, 2003, 18(4): 6 – 10.
(SHA Deshang, KONG Li, SUN Xiao. A nonlinear mathematical model of the doubly salient brushless DC motor[J]. *Trans of China Electrotechnical Society*, 2003, 18(4): 6 – 10.)
- [5] 王莉, 宋晓峰, 孟小利, 等. 用支持矢量机建立电励磁双凸极发电机的非线性模型[J]. 电工技术学报, 2004, 19(9): 1 – 5.
(WANG Li, SONG Xiaofeng, MENG Xiaoli, et al. Nonlinear modeling of field-winding doubly salient generator by support vector machine[J]. *Trans of China Electrotechnical Society*, 2004, 19(9): 1 – 5.)
- [6] CHENG Ming, CHAU K T, CHAN C C. Design and analysis of a new doubly salient permanent magnet motor[J]. *IEEE Trans on Magnetics*, 2001, 37(4): 3012 – 3020.
- [7] CHENG Ming, CHAU K T, CHAN C C, et al. Control and operation of a new 8/6-pole doubly salient permanent-magnet motor drive[J]. *IEEE Trans on Industry Applications*, 2003, 39(5): 1363 – 1371.
- [8] ELMAS C, SAGIROGLU S, COLAK I, et al. Modeling of a nonlinear switched reluctance driver based on artificial neural networks[C] // Proc of the Fifth Int Conf on Power Electronics and Variable Speed Drives. London: IEE Press, 1994: 7 – 12.
- [9] JANG J S R, SUN C T. Neuro-fuzzy modeling and control[J]. *Proceedings of the IEEE*, 1995, 83(3): 378 – 406.
- [10] ZHANG J, MORRIS A J. Fuzzy neural networks for nonlinear systems modeling [C] // IEE Proc: Control Theory and Applications, 1995, 142(6): 551 – 561.
- [11] JANG J S R, SUN C T. Functional equivalence between radial basis function networks and fuzzy inference system[J]. *IEEE Trans on Neural Networks*, 1993, 4(1): 156 – 159.
- [12] JANG J S R. ANFIS: Adaptive-network-based fuzzy inference system[J]. *IEEE Trans on System, Man, Cybernetics*, 1993, 23(3): 665 – 685.
- [13] JANG J S R, SUN C T. Neuro-fuzzy modeling and control[J]. *Proceedings of the IEEE*, 1995, 83(3): 378 – 406.
- [14] ZHANG Chenghui. Modified performance index method for parameter estimation for industrial process with time varying[J]. *Engineering Science*, 2001, 3(11): 54 – 59.
- [15] PEDRYCZ W, LAM P C F, ROCHA A F. Distributed fuzzy system modeling[J]. *IEEE Trans on Systems, Man and Cybernetics*, 1995, 25(5): 769 – 780.

作者简介:

孙 强 (1968—), 男, 博士, 副教授, 目前研究方向为电机及控制等, E-mail: sun211@hfuu.edu.cn;

程 明 (1960—), 男, 博士, 教授, 博士生导师, IEEE高级会员, 目前研究方向为电机及控制等, E-mail: mcheng@seu.edu.cn.

下期要目

- | | |
|----------------------------------|-------------------------|
| 一种完全数据驱动的子空间辨识与鲁棒预测控制器设计 | 杨 华, 李少远 |
| 基于观测器的受扰非线性系统近似最优跟踪控制 | 唐功友, 高德欣, 张宝琳 |
| 广义系统 H_∞ 多步预报器设计 | 王好谦, 张焕水, 段广仁, 王高才 |
| 奇异摄动系统的 H_∞ 控制: 基于奇异系统的方法 | 钟宁帆, 孙敏慧, 邹 云 |
| 利用稳定零点构造降阶 H_∞ 控制器的方法 | 钟瑞麟, 程 鹏 |
| 不确定关联大系统分散鲁棒 H_∞ 输出反馈控制 | 蒋朝辉, 桂卫华, 谢永芳, 裴智峰 |
| 基于CPG模型的仿生机器鱼运动控制 | 王 龙, 谭 民, 曹志强, 王 硕, 沈志忠 |
| 基于观测器的轮式移动机器人路径跟踪控制 | 马保离 |
| 基于支持向量机的一类混沌系统自适应逆控制 | 刘 涵, 刘 丁 |
| 具有多分段损失函数的多输出支持向量机回归 | 胡根生, 邓飞其 |
| 非线性不确定系统的鲁棒滑模观测器设计 | 张袅娜, 冯 勇, 邱 东 |
| 混沌吕系统的约束控制 | 宋运忠, 赵光宙, 齐冬莲 |
| 工业过程的子空间模型辨识 | 李幼凤, 苏宏业, 褚 健 |
| 基于混合算法的带时间窗车辆路径问题 | 陈宝文, 宋申民, 陈兴林 |
| 采用序贯滤波的红外—雷达机动目标跟踪 | 张高煜, 江 水, 梁继民, 赵 恒 |