

基于自回归小波神经网络的感应电动机滑模反推控制

王家军¹

摘要 为了提高感应电动机控制的鲁棒性, 提出了一种新颖的感应电动机解耦模型. 基于感应电动机的解耦模型, 利用滑模控制和反推控制设计电动机的虚拟转矩和磁链电压控制器. 滑模开关增益的大小是造成系统抖振的关键, 采用自回归小波神经网络 (SRWNN) 在线估计滑模开关增益的大小可以有效降低滑模控制造成的抖振. 仿真结果表明基于 SRWNN 在线估计滑模开关增益的滑模反推控制方案可以有效提高感应电动机控制的鲁棒性, 同时降低了滑模控制造成的抖振.

关键词 感应电动机, 自回归小波神经网络, 滑模控制, 反推控制
中图分类号 TP470.4057

Sliding Mode Backstepping Control of Induction Motor based on Self Recurrent Wavelet Neural Networks

WANG Jia-Jun¹

Abstract A new decoupled induction motor model is introduced for enhancing the robustness of control. Sliding mode control and backstepping control is applied to virtual torque and flux linkage voltage controllers design based on induction motor decoupled model. The magnitude of sliding mode switching gain is the key reason causing system chattering. Self recurrent wavelet neural networks (SRWNN) is applied to estimate sliding mode switching gain on-line, which can reduce chattering caused by sliding mode control effectively. The results of simulation proves that the scheme of sliding mode backstepping control based on SRWNN on-line estimation of switching gain can enhance the robustness of induction motor control effectively, and reduces the chattering caused by sliding mode control.

Key words Induction motor, self recurrent wavelet neural networks, sliding mode control, backstepping control

1 引言

随着工厂自动化技术的快速发展, 工业运动设备对于运动控制提出了越来越高的要求, 伺服控制系统在当前很多高精度运动控制系统中是不可缺少的驱动设备. 感应电动机因其坚固、可靠、廉价、高效等优点而成为很多伺服系统选择的对象. 然而感应电动机是一个多变量、强耦合的非线性控制系统, 电动机的转速和转矩控制受到电动机参数和外部干扰的影响, 因此如何提高感应电动机控制的鲁棒性研究具有重要的意义^[1].

模拟直流电动机的控制模式, 磁场定向 (或矢量) 控制作为感应电动机控制的一种标准控制方法, 可以分为直接磁场定向控制和间接磁场定向控制^[2]. 直接磁场定向控制以转子磁场进行磁场的直接定向, 而间接磁场定向控制通过计算转差进行磁场的定向, 两种方法都容易受到转子时间常数的影响, 因此如何降低参数变化对于感应电动机控制性能的影响成为磁场定向控制的一个重要方面^[3,4].

为了提高感应电动机控制的鲁棒性, 许多学者把模糊控制、神经网络控制、滑模控制、 H_∞ 控制和反推控制等方法以及这些方法的组合来实现感应电动机的控制器设计. Bose^[5] 对于智能控制, 包括专家系统、模糊逻辑和神经网络在电力电子和运动控制中的应用进行了综述, 给出了一些控制设计范例, 并对于智能控制在电力电子和运动控制中的应用进行了展望. Cerruto^[6] 利用自适应模糊转子时间常数调节器, 实现了感应电动机的间接磁场定向模型参考自适应速度控制. Huh^[7] 把径向基函数网络应用于感应电动机不确定性项的观测, 通过 Lyapunov 稳定性构造权值的更新率, 提高了转速控制的鲁棒性. Utkin^[8] 对于滑模控制在电力驱动中的应用进行了综述, 并给出了感应电动机滑模控制设计的一般性原则. Attaianesi^[9] 基于感应电动机的励磁电流和转矩电流进行了 H_∞ 控制器的设计, 降低了参数变化对于系统性能的影响. Shieh^[10] 利用滑模控制进行感应电动机参考模型的跟踪和反推控制进行参数的自适应控制, 实现了两种控制方法的有效结合. Lin^[11,12] 和 Wai^[13,14] 在模糊控制、神经网络控制和滑模控制等方法的结合应用于感应电动机控制方面进行了大量的研究, 并给出了有效的实验结果. Alanis^[15] 基于感应电动机的离散模型把反推控制和高阶神经网络相结合应用于抑制干扰和不确定因素对系统性能的影响.

收稿日期 2007-09-XX 收修改稿日期 XXXX-XX-XX
Received Month Date, Year; in revised form Month Date, Year
浙江省科技计划项目 (2007C31018) 资助
Supported by Science and Technology Department of Zhejiang Province, P. R. China (2007C31018)
1. 杭州电子科技大学自动化研究所 杭州 310018
1. Institute of Automation, Hangzhou Dianzi University, Hangzhou 310018
DOI: 10.1360/aas-007-xxxx

近年来有很多学者着眼于小波和神经网络在感应电动机控制中的应用研究. Wai^[16,17] 把小波神经网络应用感应电动机的不确定性在线预测, 并且有效降低了系统不确定性对于滑模开关增益的过大要求. Liu^[18] 基于小波对感应电动机建模, 并把其应用于电动机的终端过压分析.

自回归小波神经网络 (SRWNN) 不仅具有神经网络的在线学习能力、小波对于信号的分解和辨识能力, 同时也具有强大的反馈和直接控制能力^[19]. 本文首先把感应电动机的模型分解为机械部分和电气部分. 对于机械部分, 感应电动机的转速由虚拟转矩来控制, 而转矩由虚拟转矩电压控制; 对于电气部分, 感应电动机的磁链由虚拟磁链电压来控制. 虚拟转矩电压和虚拟磁链电压控制器的设计采用滑模反推控制设计方法. 为了有效降低滑模控制造成的抖动问题, 采用 SRWNN 对于滑模开关增益进行在线估计. 通过 SRWNN 的在线估计可以有效降低滑模控制对于滑模开关增益的过大要求, 并且滑模开关增益可以根据系统的性能实时调整. 基于 SRWNN 的滑模反推控制器有效降低了参数变化和外部干扰对于感应电动机系统性能的影响, 提高了电动机转速和转矩控制的鲁棒性.

2 感应电动机模型

基于定子坐标系的感应电动机模型为^[20]

$$d\omega/dt = k(\psi_{r\alpha}i_{s\beta} - \psi_{r\beta}i_{s\alpha}) - T_L/J \quad (1)$$

$$di_{s\alpha}/dt = a\psi_{r\alpha} + b\omega\psi_{r\beta} - ci_{s\alpha} + du_{s\alpha} \quad (2)$$

$$di_{s\beta}/dt = a\psi_{r\beta} - b\omega\psi_{r\alpha} - ci_{s\beta} + du_{s\beta} \quad (3)$$

$$d\psi_{r\alpha}/dt = -e\psi_{r\alpha} - n_p\omega\psi_{r\beta} + fi_{s\alpha} \quad (4)$$

$$d\psi_{r\beta}/dt = -e\psi_{r\beta} + n_p\omega\psi_{r\alpha} + fi_{s\beta} \quad (5)$$

其中 $a = L_m L_r / (\sigma L_s L_r^2)$, $b = n_p L_m / (\sigma L_s L_r)$, $c = (L_m^2 R_r + L_r^2 R_s) / (\sigma L_s L_r^2)$, $d = 1 / (\sigma L_s)$, $e = R_r / L_r$, $f = L_m R_r / L_r$, $k = 3n_p L_m / (2J L_r)$. ω 为转子机械角速度, $\psi_{r\alpha}$ 、 $\psi_{r\beta}$ 为转子 α 、 β 轴磁链, $i_{s\alpha}$ 、 $i_{s\beta}$ 为定子 α 、 β 轴电流, $u_{s\alpha}$ 、 $u_{s\beta}$ 为定子 α 、 β 轴电压, n_p 为极对数, J 为电机的转动惯量, R_r 为转子电阻, R_s 为定子电阻, L_r 为转子电感, L_s 为定子电感, L_m 为定、转子互感, T_L 为负载转矩, $\sigma = 1 - L_m^2 / (L_s L_r)$.

由式 (1) 至 (5) 可以看出, 感应电动机为多变量强耦合的非线性系统, 直接对转矩和磁链进行解耦, 实现转速和转矩的控制是很困难的.

为了实现感应电动机机械部分和电气部分的分离, 给出如下新的状态变量

$$T = \psi_{r\alpha}i_{s\beta} - \psi_{r\beta}i_{s\alpha} \quad (6)$$

$$\psi = (\psi_{r\alpha}^2 + \psi_{r\beta}^2)/2 \quad (7)$$

$$X = \psi_{r\alpha}i_{s\alpha} + \psi_{r\beta}i_{s\beta} \quad (8)$$

其中 T 称为虚拟转矩, T 和实际转矩 T_e 的关系为

$$T_e = kJT \quad (9)$$

ψ 称为虚拟磁链, ψ 和实际转子磁链的关系为

$$\psi = \psi_r^2/2, \psi_r^2 = \psi_{r\alpha}^2 + \psi_{r\beta}^2 \quad (10)$$

实际运行过程中, 可以根据需要利用感应电动机的电流模型、电压模型或直接测量获得 $\psi_{r\alpha}$ 和 $\psi_{r\beta}$.

利用新的状态变量, 则感应电动机的模型可以分解为机械部分和电气部分.

机械部分

$$d\omega/dt = kT - T_L/J \quad (11)$$

$$dT/dt = -2b\omega\psi - (e + c)T - n_p\omega X + du_T \quad (12)$$

其中 $u_T = \psi_{r\alpha}u_{s\beta} - \psi_{r\beta}u_{s\alpha}$.

电气部分

$$d\psi/dt = -2e\psi + fX \quad (13)$$

$$dX/dt = 2a\psi - (e + c)X + n_p\omega T + f(i_{s\alpha}^2 + i_{s\beta}^2) + du_\psi \quad (14)$$

其中 $u_\psi = \psi_{r\alpha}u_{s\alpha} + \psi_{r\beta}u_{s\beta}$.

对于机械部分, T 为虚拟转矩, u_T 为虚拟转矩电压; 对于电气部分, u_ψ 为虚拟磁链电压.

3 自回归小波神经网络

3.1 SRWNN 的结构

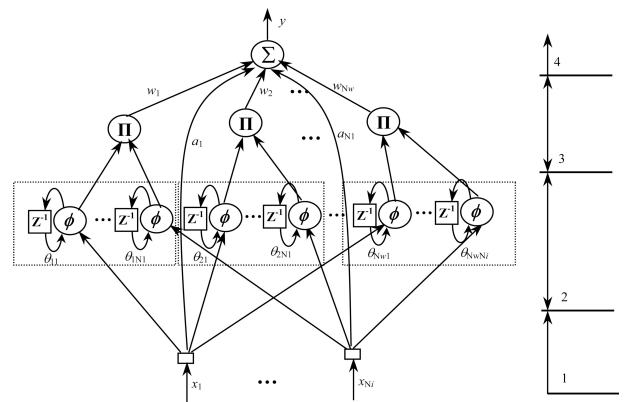


图1 SRWNN 结构

Fig. 1 Structure of SRWNN

SRWNN 结构如图 1 所示, 它包含 N_i 个输入, 1 个输出和 $N_w \times N_i$ 个母小波, 具有四层结构^[19].

第一层是输入层, 这一层接收输入变量, 并把输入变量直接输出.

第二层是母小波层,这一层的每一个节点包含一个母小波和一个自反馈环.本文中母小波函数选择为 $\phi(x)=-x\exp(-x^2/2)$, 每一个节点的小波 ϕ_{jk} 可以由母小波直接衍生出来

$$\phi_{jk}(z_{jk}) = \phi_{jk}((u_{jk} - m_{jk})/d_{jk}) \quad (15)$$

其中 $z_{jk}=(u_{jk} - m_{jk})/d_{jk}$, u_{jk} 代表输入, m_{jk} 代表平移因子, d_{jk} 代表扩展因子, 下标 j 、 k 分别代表第 k 个输入项的第 j 个小波. 在时刻 n 的输入可以表示为

$$u_{jk}(n) = x_k(n) + \theta_{jk}\phi_{jk}(n-1) \quad (16)$$

θ_{jk} 代表自反馈环的系数, 这表明 SRWNN 包含了系统对于过去状态的记忆. 如果 $\theta_{jk}=0$, SRWNN 则退化为普通小波神经网络.

第三层为乘积层, 可以表示为

$$\phi_j(x) = \prod_{k=1}^{N_i} \phi_{jk}(z_{jk}) \quad (17)$$

第四层为输出层, 包含第三层的输入和第一层的直接输入, 可以表示为

$$y = \sum_{j=1}^{N_w} w_j \phi_j(x) + \sum_{k=1}^{N_i} a_k x_k \quad (18)$$

其中 w_j 为第三层输出 $\phi_j(x)$ 到第四层的权值, a_k 为第一层输出 x_k 直接传输到第四层的权值.

3.2 SRWNN训练算法

SRWNN 的权值向量可以表示为 $W=[a_k \ m_{jk} \ d_{jk} \ \theta_{jk} \ w_j]^T$.

假定 SRWNN 的目标性能函数为

$$J = (y_r - y)^2/2 \quad (19)$$

其中 y_r 为目标输出, $e=y_r - y$ 为误差.

利用梯度下降训练方法, 权值修正可以表示为

$$W(n+1) = W(n) + \Delta W(n) + \eta(-\partial J/\partial W) \quad (20)$$

其中 $\eta=\text{diag}[\eta_a \ \eta_m \ \eta_d \ \eta_\theta \ \eta_w]$ 为权值的学习率.

目标性能函数对于权值的导偏数为

$$\partial J/\partial W = -e\partial y/\partial W \quad (21)$$

利用链式递推方法, 输出对于每层权值向量的偏导数为

$$\partial y/\partial a_k = x_k \quad (22)$$

$$\partial y/\partial m_{jk} = -(w_j/d_{jk})\partial\phi_j/\partial z_{jk} \quad (23)$$

$$\partial y/\partial d_{jk} = -(w_j/d_{jk})z_{jk}\partial\phi_j/\partial z_{jk} \quad (24)$$

$$\partial y/\partial\theta_{jk} = (w_j/d_{jk})\phi_{jk}\partial\phi_j/\partial z_{jk} \quad (25)$$

$$\partial y/\partial w_j = \phi_j(x) \quad (26)$$

其中 $\phi_j/\partial z_{jk}=(z_{jk}^2 - 1)\exp(-z_{jk}^2/2)$. SRWNN 的四层结构不仅包括小波对于信号分析的分解特性同时具有了神经网络的学习能力, 如果不存在自回归单元的情况下, 由于单一小波函数的振荡特性, 第三层会表现出剧烈的振荡, 然而由于母小波包含自反馈单元, 这可以使得 SRWNN 包含了对于过去状态的记忆, 因此能够适应控制环境的快速变化, 能够有效抑制第三层剧烈的振荡输出.

4 感应电动机控制器设计

4.1 机械部分控制器设计

假设电动机的给定转速为 ω_r^* , 实际转速为 ω , 则转速误差为

$$e_1 = \omega_r^* - \omega \quad (27)$$

对式 (27) 求导可得

$$de_1/dt = d\omega_r^*/dt - kT + T_L/J \quad (28)$$

T 为转速控制的虚拟转矩, T_L 可以视为系统的干扰, 如果令

$$T^* = (k_1 e_1 + T_L/J + d\omega_r^*/dt)/k, \quad k_1 > 0 \quad (29)$$

则可得 $de_1/dt = -k_1 e_1$.

令 $e_2 = T^* - T$, 并选取滑模平面 s_1 为

$$s_1 = \mu_1 e_2, \quad \mu_1 > 0 \quad (30)$$

选择滑模趋近律方法

$$ds_1/dt = -\xi_1 s_1 - \rho_1 \text{sgn}(s_1) \quad (31)$$

其中 $\xi_1 > 0$ 为趋近指数, $\rho_1 > 0$ 为滑模开关增益, sgn 为符号函数. 对于式 (30) 两边求导, 可得

$$ds_1/dt = -k_1^2 \mu_1 e_1/k - (d^2\omega_r^*/dt^2)/k - (dT_L/dt)/kJ + 2\mu_1 b\omega\psi \quad (32)$$

$$+ \mu_1(e+c)T + \mu_1 n_p \omega X - \mu_1 du_T$$

结合式 (31)、(32), 可得虚拟转矩电压 u_T

$$u_T = [\xi_1 s_1 + \rho_1 \text{sgn}(s_1) - k_1^2 \mu_1 e_1/k - (d^2\omega_r^*/dt^2)/k - (dT_L/dt)/kJ + 2\mu_1 b\omega\psi + \mu_1(e+c)T + \mu_1 n_p \omega X]/(\mu_1 d) \quad (33)$$

4.2 电气部分控制器设计

假设电动机的给定磁链为 ψ^* , 则磁链误差为

$$e_3 = \psi^* - \psi \quad (34)$$

对式 (34) 求导可得

$$\begin{aligned} de_3/dt &= d\psi^*/dt - d\psi/dt \\ &= d\psi^*/dt + 2e\psi - fX \end{aligned} \quad (35)$$

选取滑模平面 s_2 为

$$s_2 = \mu_2 e_3 + \mu_3 de_3/dt, \quad \mu_2 > 0, \mu_3 > 0 \quad (36)$$

选择滑模趋近律方法

$$ds_2/dt = -\xi_2 s_2 - \rho_2 \operatorname{sgn}(s_2) \quad (37)$$

其中其中 $\xi_2 > 0, \rho_2 > 0$. 对于式 (36) 两边求导, 可得

$$\begin{aligned} ds_2/dt &= \mu_2(d\psi^*/dt) + 2e\mu_2\psi - \mu_2fX \\ &+ \mu_3(d^2\psi^*/dt^2) - 4e^2\mu_3\psi - 2e\mu_3fX \\ &- 2f\mu_3a\psi + f\mu_3(e+c)X - f\mu_3n_p\omega T \\ &+ f^2\mu_3(i_{s\alpha}^2 + i_{s\beta}^2) - f\mu_3du_\psi \end{aligned} \quad (38)$$

结合式 (37)、(38), 可得虚拟磁链电压 u_ψ

$$\begin{aligned} u_\psi &= [\xi_2 s_2 + \rho_2 \operatorname{sgn}(s_2) + \mu_2(d\psi^*/dt) + 2e\mu_2\psi \\ &- \mu_2fX + \mu_3(d^2\psi^*/dt^2) - 4e^2\mu_3\psi - 2e\mu_3fX \\ &- 2f\mu_3a\psi + f\mu_3(e+c)X - f\mu_3n_p\omega T \\ &+ f^2\mu_3(i_{s\alpha}^2 + i_{s\beta}^2)]/(f\mu_3d) \end{aligned} \quad (39)$$

4.3 SRWNN滑模开关增益估计

由式 (33) 和 (39) 可知虚拟转矩电压 u_T 和虚拟磁链电压 u_ψ 与滑模开关增益 ρ_1 和 ρ_2 具有直接的关系, 如果滑模开关增益选择过大将导致系统的抖振, 对于系统是非常不利的, 然而滑模开关增益选择太小将降低系统的鲁棒性能, 因此滑模开关增益的选择对于系统的控制性能具有非常重要的意义. 下面利用 SRWNN 对于滑模开关增益进行在线估计, 使得滑模开关增益可以随着系统性能的变化进行在线调整.

对于虚拟转矩电压 u_T 的滑模开关增益的估计, 以 s_1 和 $s_1(1-z^{-1})$ 作为 SRWNN 的两个输入变量, 输出为滑模开关增益 ρ_1 , 性能指标选择为

$$J_{\rho_1} = (\omega_r^* - \omega)^2/2 = e_1^2/2 \quad (40)$$

滑模开关增益 ρ_1 的 SRWNN 权值训练算法为

$$\begin{aligned} \Delta W(n) &= -\partial J_{\rho_1}/\partial W = -e_1(\partial e_1/\partial W) \\ &= -e_1(\partial e_1/\partial \rho_1)(\partial \rho_1/\partial W) \end{aligned} \quad (41)$$

$\partial \rho_1/\partial W$ 可以根据式 (22)-(26) 计算. $\partial e_1/\partial \rho_1$ 为 SRWNN 的雅可比系数 (或雅可比矩阵). 在进行神经网络训练设计时, 利用梯度下降方法对于神经网络

进行训练必然要进行雅可比系数计算, 雅可比系数的计算常常是神经网络设计的一个难点^[21]. 采用文献^[22] 的计算方法, SRWNN 的雅可比系数为

$$\begin{aligned} \partial e_1/\partial \rho_1 &= (\partial e_1/\partial \omega)(\partial \omega/\partial u_T)|\partial u_T/\partial \rho_1| \\ &= -|\partial \omega/\partial u_T| \operatorname{sgn}(\partial \omega/\partial u_T)|\operatorname{sgn}(s_1)| \\ &= -\beta_1 \operatorname{sgn}(\partial \omega/\partial u_T) \end{aligned} \quad (42)$$

$\beta_1=|\partial \omega/\partial u_T|$ 可以定义为一个正的常数. 由一般控制系统的控制行为, 当被控制量增大时, 控制量应当相应地增大, 或者当被控制量减小时, 控制量也相应减小, 因此可以令 $\operatorname{sgn}(\partial \omega/\partial u_T)=1$. 因为滑模增益必须大于零, 所以可以用 $|\partial u_T/\partial \rho_1|$ 代替 $\partial u_T/\partial \rho_1$. 式 (42) 可以简化为

$$\partial e_1/\partial \rho_1 = -\beta_1 \quad (43)$$

对于虚拟磁链电压 u_ψ 的滑模开关增益的估计, 以 s_2 和 $s_2(1-z^{-1})$ 作为 SRWNN 的两个输入变量, 输出为滑模开关增益 ρ_2 , 性能指标选择为

$$J_{\rho_2} = (\psi^* - \psi)^2/2 = e_3^2/2 \quad (44)$$

滑模开关增益 ρ_2 的 SRWNN 权值训练算法为

$$\begin{aligned} \Delta W(n) &= -\partial J_{\rho_2}/\partial W = -e_3(\partial e_3/\partial W) \\ &= -e_3(\partial e_3/\partial \rho_2)(\partial \rho_2/\partial W) \end{aligned} \quad (45)$$

与滑模开关增益 ρ_1 的 SRWNN 的雅可比系数计算相似, ρ_2 的 SRWNN 的雅可比系数为

$$\begin{aligned} \partial e_3/\partial \rho_2 &= (\partial e_3/\partial \psi)(\partial \psi/\partial u_\psi)|\partial u_\psi/\partial \rho_2| \\ &= -|\partial \psi/\partial u_\psi| \operatorname{sgn}(\partial \psi/\partial u_\psi)|\operatorname{sgn}(s_2)| \\ &= -\beta_2 \end{aligned} \quad (46)$$

其中 $\beta_2=|\partial \psi/\partial u_\psi|$ 为正常数, $\operatorname{sgn}(\partial \psi/\partial u_\psi)=1$.

由虚拟转矩电压和虚拟磁链电压可以得到实际定子控制电压 $u_{s\alpha}$ 和 $u_{s\beta}$

$$u_{s\alpha} = (\psi_{r\alpha}u_T + \psi_{r\beta}u_\psi)/2\psi \quad (47)$$

$$u_{s\beta} = (-\psi_{r\beta}u_T + \psi_{r\alpha}u_\psi)/2\psi \quad (48)$$

4.4 SRWNN收敛性证明

定理 1. 假定 $\eta = \operatorname{diag}[\eta_a, \eta_m, \eta_d, \eta_\theta, \eta_w] = \operatorname{diag}[\eta_1, \eta_2, \eta_3, \eta_4, \eta_5]$ 为 SRWNN 权值学习率. 定义 $C_{max} = [C_{1max}, C_{2max}, C_{3max}, C_{4max}, C_{5max}]^T = [\max_n \|\partial y(n)/\partial a\|, \max_n \|\partial y(n)/\partial m\|, \max_n \|\partial y(n)/\partial d\|, \max_n \|\partial y(n)/\partial \theta\|, \max_n \|\partial y(n)/\partial w\|]^T$, 其中 $\|\cdot\|$ 为欧几里德泛数. 如果 η_i 满足

$$0 < \eta_i < 2/(\beta_k C_{imax}^2) \quad (49)$$

其中 $i = 1, 2, \dots, 5, k = 1, 2$, 则 SRWNN 估计是收敛的。

证明. 假定滑模开关增益 SRWNN 估计的相应离散 Lyapunov 函数为

$$V(n) = [R^*(n) - R(n)]^2 = e(n)^2/2 \quad (50)$$

则

$$\begin{aligned} \Delta V(n) &= [e(n+1)^2 - e(n)^2]/2 \\ &= \Delta e(n)[e(n) + 0.5\Delta e(n)] \\ &= \eta_i [\partial e(n)/\partial W_i(n)]^T e(n) [\partial y(n)/\partial W_i(n)] (e(n) \\ &\quad + 0.5[\partial e(n)/\partial W_i(n)]^T e(n) [\partial y(n)/\partial W_i(n)]) \\ &= -\beta_k \eta_i [\partial y(n)/\partial W_i(n)]^T e(n) [\partial y(n)/\partial W_i(n)] (e(n) \\ &\quad - 0.5\beta_k \eta_i [\partial y(n)/\partial W_i(n)]^T e(n) [\partial y(n)/\partial W_i(n)]) \\ &= -e(n)^2 \beta_k \eta_i \|\partial y(n)/\partial W_i(n)\|^2 (1 \\ &\quad - 0.5\beta_k \eta_i \|\partial y(n)/\partial W_i(n)\|^2) = -\gamma e(n)^2 \end{aligned} \quad (51)$$

其中

$$\begin{aligned} \gamma &= \beta_k \eta_i \|\partial y(n)/\partial W_i\|^2 (1 - 0.5\beta_k \eta_i \|\partial y(n)/\partial W_i\|^2) \\ &\geq \beta_k \eta_i C_{imax}^2 (1 - 0.5\beta_k \eta_i C_{imax}^2) \end{aligned} \quad (52)$$

由式 (51) 可以得出, 如果 $0 < \eta_i < 2/(\beta_k C_{imax}^2)$ 则 $\beta_k \eta_i C_{imax}^2 (1 - 0.5\beta_k \eta_i C_{imax}^2) > 0$, 因此 SRWNN 估计是收敛的。□

4.5 感应电动机控制稳定性证明

定理 2. 对于感应电动机系统 (1)-(5), 控制 (33)、(39) 可以使得系统滑模平面稳定, 同时达到转速、转矩和转子磁链的渐近跟踪。

证明. 由式 (31)、(37) 可得

$$ds_i/dt = -\xi_i s_i - \rho_i \operatorname{sgn}(s_i), i = 1, 2 \quad (53)$$

在式 (53) 两边同乘 s_i , 则可得

$$s_i ds_i/dt = -\xi_i s_i^2 - \rho_i |s_i| < 0, i = 1, 2 \quad (54)$$

因此滑模平面满足到达条件, 滑模平面是稳定的。由滑模平面的稳定可以得出

$$\lim_{t \rightarrow \infty} s_i = 0 \quad (55)$$

由式 (55), 同时根据式 (30)、(36), 得出

$$\lim_{t \rightarrow \infty} e_2 = 0, \lim_{t \rightarrow \infty} e_3 = 0 \quad (56)$$

由 $\lim_{t \rightarrow \infty} e_2 = 0$, 根据式 (28)、(29) 得出

$$\lim_{t \rightarrow \infty} e_1 = 0 \quad (57)$$

由式 (56)、(57) 可知转速、转矩和转子磁链能够渐近跟踪给定参考值, 因此感应电动机的滑模反推控制系统是稳定的。□

5 系统仿真分析

感应电动机控制系统的结构如图 2 所示, 其中 3/2 变换为静止三相电流到两相电流的坐标变换。电动机的参数如表 1 所示。

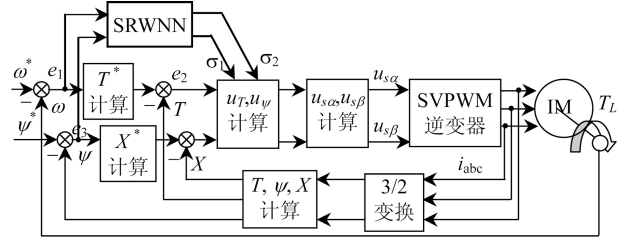


图 2 感应电动机控制结构图

Fig. 2 Structure figure of induction motor control

表 1 感应电动机参数

Table 1 Induction motor parameters

Rr/Ω	Rs/Ω	M/mH	Lr/mH	Ls/mH	np	J/(kgm)
2.77	2.64	74.84	74.84	73.55	2	0.005

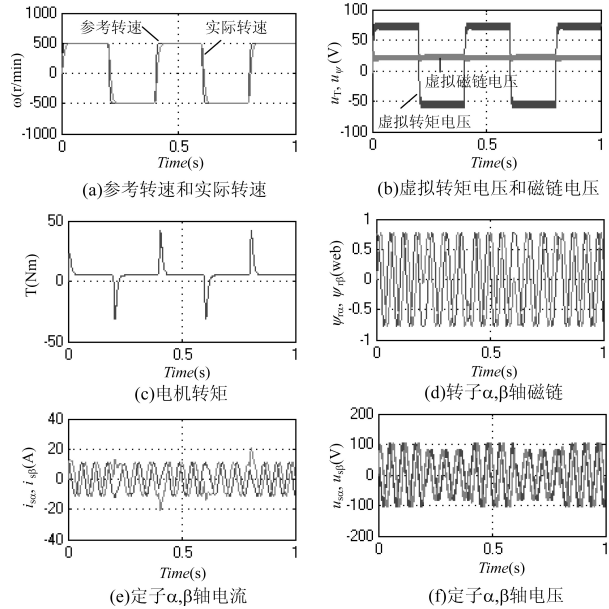


图 3 情况一没有 SRWNN 估计的滑模反推控制

Fig. 3 First case of sliding mode backstepping control without SRWNN estimation

SRWNN 结构为 2-6-3-1, 初始权值除扩展因子为 1, 其余全部初始化为 0. $j = 3, k = 2$. 虚拟转矩电压 SRWNN 估计单元的学习率分别为 $\eta_a = 1 \times 10^{-6}$, $\eta_m = 0.2$, $\eta_d = 0.2$, $\eta_\theta = 0.5$ 和 $\eta_w = 0.15$. 虚拟磁链电压 SRWNN 估计单元的学习率分别为 $\eta_a = 3 \times 10^{-6}$, $\eta_m = 0.2$, $\eta_d = 0.2$, $\eta_\theta = 0.5$

和 $\eta_w = 0.01$ 。感应电动机滑模反推控制的参数为 $k_1 = 150$ 、 $k_2 = 150$ 、 $\mu_1 = 2$ 、 $\mu_2 = 750$ 、 $\mu_3 = 1$ 、 $\xi_1 = 2500$ 、 $\xi_2 = 50$ 、 $\rho_1 = 2000$ 和 $\rho_2 = 3000$ 。

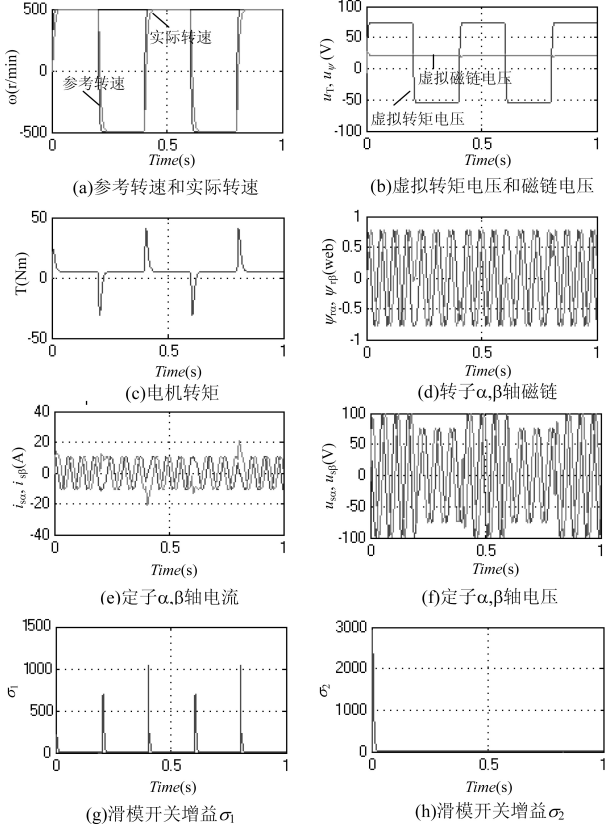


图 4 情况一具有 SRWNN 估计的滑模反推控制

Fig. 4 First case of sliding mode backstepping control with SRWNN estimation

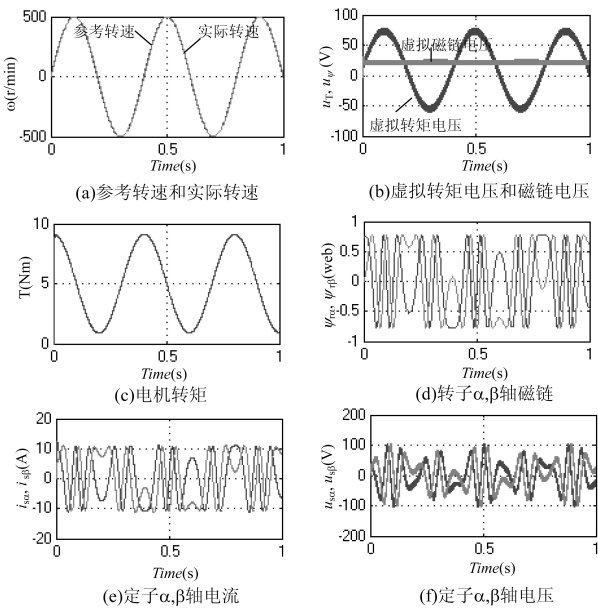


图 5 情况二没有 SRWNN 估计的滑模反推控制

Fig. 5 Second case of sliding mode backstepping control without SRWNN estimation

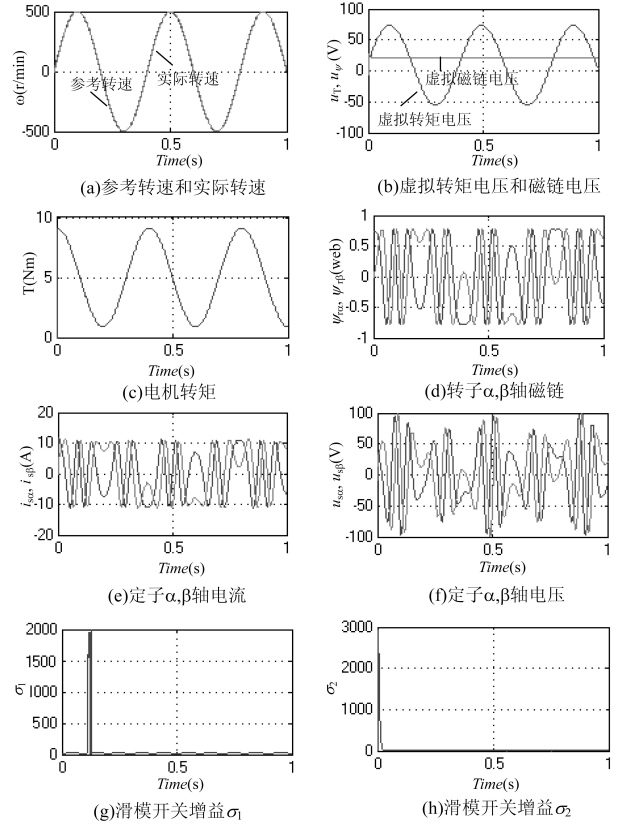


图 6 情况二具有 SRWNN 估计的滑模反推控制

Fig. 6 Second case of sliding mode backstepping control with SRWNN estimation

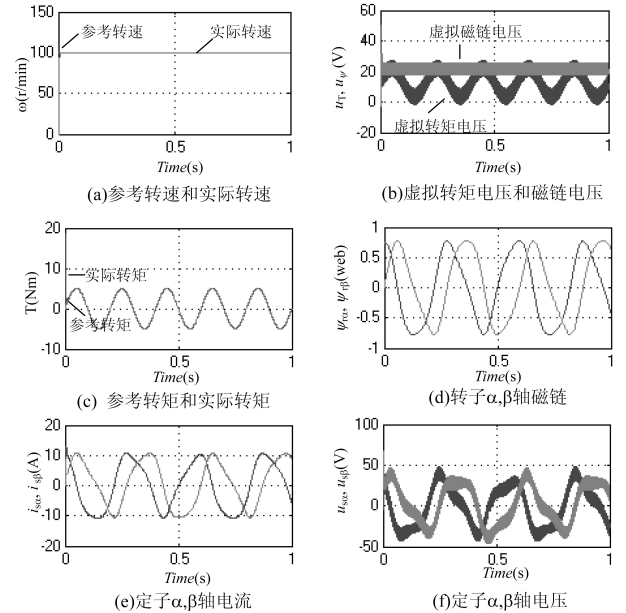


图 7 情况三没有 SRWNN 估计的滑模反推控制

Fig. 7 Third case of sliding mode backstepping control without SRWNN estimation

仿真情况一: 在没有 SRWNN 估计的情况下, 电机的初始设定转速为经过一定处理的幅值为 500

转/分, 频率为 2.5Hz 的阶梯波, 电动机负载为 5Nm, 仿真如图 3 所示. 在同样的条件下, 加入 SRWNN 滑模开关增益估计环节, 仿真如图 4 所示.

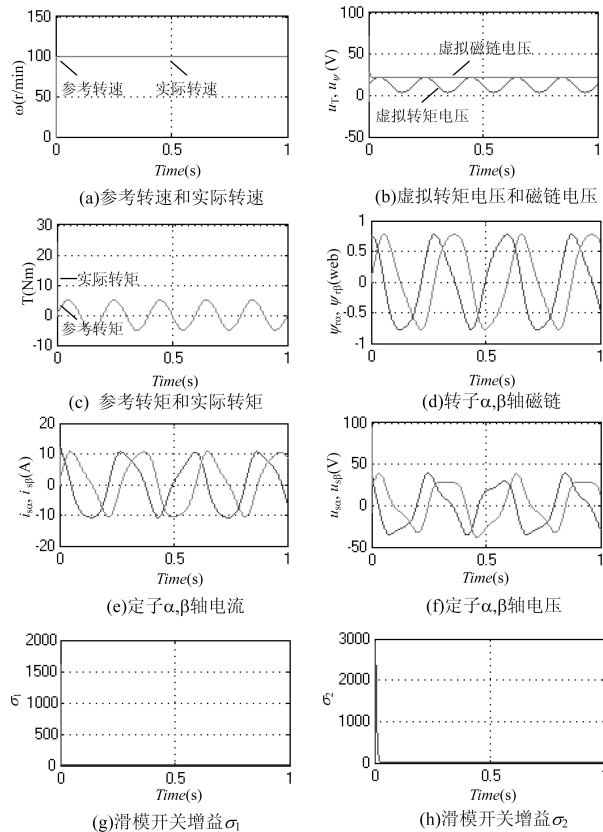


图 8 情况三具有 SRWNN 估计的滑模反推控制

Fig. 8 Third case of sliding mode backstepping control with SRWNN estimation

仿真情况二: 在没有 SRWNN 进行滑模开关增益估计的情况下, 电机的初始设定转速为幅值 500 转/分, 频率 2.5Hz 的正弦波, 电动机负载为 5Nm, 仿真结果如图 5 所示. 在同样的条件下, 加入 SRWNN 滑模开关增益估计环节, 仿真结果如图 6 所示.

仿真情况三: 在没有 SRWNN 进行滑模开关增益估计的情况下, 给定参考负载转矩为幅值 5Nm, 频率 4Hz 的正弦波, 电机的设定转速为 100 转/分. 仿真结果如图 7 所示. 在同样条件下, 加入 SRWNN 滑模开关增益估计环节, 仿真结果如图 8 所示.

由仿真结果可以看出基于 SRWNN 进行滑模开关增益估计的滑模反推控制器能够使得电机的转速和转矩快速跟踪设定值. 在转速跟踪给定值时, 电动机能够快速跟踪电动机转速的给定值, 并且稳态跟踪误差小于 0.1%, 在转速跟踪的过程中, 转速对于负载转矩的变化很不敏感. 在转速一定的情况下, 当负载转矩跟踪给定值时, 电动机的电磁转矩能够快速跟踪负载转矩的变化, 并且稳态跟踪误差

小于 0.25%, 在电动机电磁转矩跟踪负载转矩的过程中电动机的转速几乎不受转矩波动的影响. 由图 3(b)、5(b) 和 7(b) 可以看出在没有 SRWNN 进行滑模开关增益估计的情况下虚拟转矩和磁链电压抖动比较厉害, 并且直接导致定子电压波动比较大. 由图 4(b)、6(b) 和 8(b) 可以看出在具有 SRWNN 进行滑模开关增益估计的情况下虚拟转矩和磁链电压抖动大大降低, 系统的控制性能具有明显的提高. 由图 4(g)、4(h)、6(g)、6(h)、8(g) 和 8(h) 可以得出, SRWNN 可以在线快速调整滑模开关增益的大小, 在系统给定参考转速或转矩变化过程中滑模增益需要较大的值, 而在系统稳定之后, 很小的值便可以满足系统的性能要求.

在上述条件下使得感应电动机的定子、转子电阻变化 200%, 定子、转子电感变化 50%, 转动惯量变化 400% 的情况下, 转速和转矩跟踪与图 3-8 相比几乎没有变化, 这说明系统设计具有强的鲁棒性, 系统的控制性能几乎不受系统参数变化和外部干扰的影响.

6 结论

本文结合 SRWNN 的强大在线学习能力和滑模反推控制的简洁设计思路, 实现了感应电动机转速和转矩的精确和快速跟踪. 设计方案的主要新颖之处体现在如下三个方面:

(1) 与感应电动机的磁场定向控制相区别, 基于定子坐标系模型把感应电动机的模型分解为机械部分和电气部分, 控制设计过程不需要转子转差或转子磁链角的计算.

(2) 通过滑模反推控制设计实现了转矩和磁链的解耦控制, 有效降低了状态变量之间的耦合, 能够达到快速的转速和转矩跟踪, 同时提高了系统控制的鲁棒性.

(3) 把 SRWNN 应用于滑模开关增益的在线估计有效降低了滑模开关增益造成的抖动, 提高了滑模反推控制的自调整能力.

论文给出了 SRWNN 估计的收敛性证明和系统控制器设计的稳定性证明, 并通过仿真验证了系统设计的有效性和可行性.

References

- 1 Bose B K. *Modern Power Electronics and AC Drive*. U.S.A: Prentice Hall, 2002.
- 2 Lorenz R D, Lipo T A, Novotny D W. Motion control with induction motor. *Proceedings of IEEE*, 1994, **82**(8): 1215-1240
- 3 Karanayil B, Rahman M F, Grantham C. Stator and rotor resistance observers for induction motor drive using fuzzy logic and artificial neural networks. *IEEE Transactions on Energy Conversion*, 2005, **20**(4): 771-780

- 4 Koubaa Y. Recursive identification of induction motor parameters. *Simulation Modeling Practice and Theory*, 2004, **12**: 363–381
- 5 Bose B K. Expert system, fuzzy logic, and neural network application in power electronics and motion control. *Proceedings of IEEE*, 1994, **82**(8): 1303–1323
- 6 Cerruto E, Consoli A, Raciti A, Testa A. Fuzzy adaptive vector control of induction motor drives. *IEEE Transactions on Power Electronics*, 1997, **12**(6): 1028–1040
- 7 Huh S, Park J H, Choy I, Park G T. Nonlinear uncertainty observer for AC motor control using the radial basis function networks. *IEE Proceedings Control Theory and Application*, 2004, **151**(3): 369–375
- 8 Utkin V I. Sliding mode control design principles and applications to electric drives. *IEEE Transactions on Industrial Electronics*, 1993, **40**(1): 23–36
- 9 Attaianesi C, Tomasso G. H_∞ control of induction motor drives. *IEE Proceedings Electrical Power Application*, 2004, **148**(3): 272–278
- 10 Shieh H, Shyu K. Nonlinear sliding-mode torque control with adaptive backstepping approach for induction motor drive. *IEEE Transactions on Industrial Electronics*, 1999, **46**(2): 380–389
- 11 Lin F, Wai R, Lin C, Liu D. Decoupled stator-flux-oriented induction motor uncertainty observer. *IEEE Transactions on Industrial Electronics*, 2000, **47**(2): 356–367
- 12 Lin F, Yu J, Tzeng M. Sensorless induction spindle motor drive using fuzzy neural network speed controller. *Electrical Power Systems Research*, 2001, **58**: 187–196
- 13 Wai R, Lin H, Lin F. Hybrid controller using fuzzy neural networks for identification and control of induction servo motor drive. *Neurocomputing*, 2000, **35**: 91–112
- 14 Wai R, Lin F. Fuzzy neural network sliding-mode position controller for induction servo motor drive. *IEE Proceedings Electrical Power Application*, 1999, **146**(3): 297–308
- 15 Alanis A Y, Sanchez E N, Loukianov A G. Discrete-time adaptive backstepping nonlinear control via high-order neural networks. *IEEE Transactions on Neural networks*, 2007, **18**(4): 1185–1194
- 16 Wai R, Chang J. Implementation of robust wavelet-neural-network sliding-mode control for induction servo motor drive. *IEEE Transactions on Industrial Electronics*, 2003, **50**(6): 1317–1334
- 17 Wai R, Duan R, Lee J, Chang H. Wavelet neural network control for induction motor drive using sliding-mode design technique. *IEEE Transactions on Industrial Electronics*, 2003, **50**(4): 733–748
- 18 Liu J, Pillay P, Douglas H. Wavelet modeling of motor drives applied to the calculation of motor terminal overvoltages. *IEEE Transactions on Industrial Electronics*, 2004, **51**(1): 61–66
- 19 Yoo S, Park J, Choi Y. Indirect adaptive control of nonlinear dynamic systems using self recurrent wavelet neural networks via adaptive learning rates. *Information Sciences*, 2007, **177**: 3074–3098
- 20 Marino R, Peresada S, Valigi P. Adaptive input-output linearizing control of induction motors. *IEEE Transactions on Automation Control*, 1993, **38**(2): 208–221
- 21 Lin F, Wai R, Chen H. A PM synchronous servo motor drive with an on-line trained fuzzy-neural network controller. *IEEE Transactions on Energy Conversion*, 1998, **13**(4): 319–325
- 22 Wai R. Total sliding-mode controller for PM synchronous servo motor drive using recurrent fuzzy neural network. *IEEE Transactions on Industrial Electronics*, 2001, **48**(5): 926–944



王家军 杭州电子科技大学自动化学院副教授, 2003 年在天津大学获得博士学位。主要研究方向为电机控制和电力电子。E-mail: wangjiujun@hdu.edu.cn (WANG Jiu-Jun Associate professor of Automation School of Hangzhou Dianzi University. He received his Ph. D. degree from Tianjin University in 2003.

His research interests include motor control and power electronics.)