小波网络在直接转矩控制系统低速运行中的应用

刘 琳 沈颂华 刘 强

(北京航空航天大学 自动化科学与电气工程学院, 北京 100083) (中治京诚工程技术有限公司, 北京 100053)

摘 要: 针对传统的异步电动机直接转矩控制系统低速运行时存在较大转矩脉动的问题,详细分析了定子电阻变化对系统控制性能的影响,提出了基于小波网络的定子电阻辨识方法. 将定子电流的误差和定子电流误差的变化量作为小波网络的输入,网络输出为定子电阻误差的动态估计值;综合应用递推正交最小二乘法与改进的 Givens 变换训练小波网络参数,利用小波网络良好的时频局部特性可以准确的观测出定子磁链和转矩,优化了逆变器的控制策略. 仿真结果对比表明该方法可以有效得改善电动机的低速运行性能,优于采用 BP(Backward Propagation)神经网络的方法.

关 键 词: 异步电动机; 直接转矩控制; 定子电阻; 小波网络; 动态系统辨识

中图分类号: TP 921

文献标识码: A **文 章 编 号**: 1001-5965(2006)09-1067-05

Application of wavelet network for induction motor in direct torque control system operating at low speed

Liu Lin Shen Songhua

(School of Automation Science and Electrical Engineering, Beijing University of Aeronautics and Astronautics, Beijing 100083, China)

Liu Qiang

(Capital Engineering and Research Incorporation Limited, Beijing 100053, China)

Abstract: To improve the low-speed dynamic performance of induction motor DTC(direct torque control), a novel method of stator resistance identification based on WN(wavelet network) was presented. The inputs of the WN were the current error and the change in the current error and the output of the WN was the stator resistance error. The synthesized method of ROLSA(recursive orthogonal least squares algorithm) and improved Givens transform was used to fulfill the network structure and parameter identification. By the use of wavelet transform that accurately localized the characteristics of a signal both in the time and frequency domains, the occurring instants of the stator resistance change could be identified by the multi-scale representation of the signal. Once the instants were detected, the accurate stator flux vector and electromagnetic torque were acquired by the parameter estimator, which made the DTC applicable in the low region, and the inverter control strategy was optimized. The simulation results show that the proposed method can efficiently reduce the torque ripple and current ripple, and is superior to the BP(backward propagation) neural network.

Key words: induction motors; direct torque control; stator resistance; wavelet network; dynamic system identification

直接转矩控制 DTC(Direct Torque Control)是继矢量控制技术之后发展起来的一种新型的高性能交流调速传动控制技术,可以获得转矩的高动态性能. 目前,DTC 技术已经成为交流传动领域研究的新热点[1].

作为一种新兴的控制技术,DTC 的不足之处是转矩的低速性能不太理想,定子电流和转矩的脉动比较大,亟待改善. 针对该问题,近年来国内

收稿日期: 2005-10-25

基金项目: 国家自然科学基金资助项目(59775004)

作者简介: 刘 琳(1976-),男,山东聊城人,博士生, buaaliulin@126.com.

外的许多学者提出了不同的、有积极意义的控制算法[2-4],但都在不同程度上存在一些问题. 参考文献[2-3]将神经网络理论引入到 DTC 中,在一定程度上提高了定子电阻的辨识精度. 基于这些研究成果进行分析,虽然神经网络能够映射任意非线性函数关系,然而其缺点是只能学习输入与输出样本的静态映射,不适合于动态映射,用于具有时变非线性特点的 DTC 系统将会带来一定的观测误差. 因此要进一步提高定子电阻辨识精度,就必须将时间延迟量引入到神经网络结构当中. 但是,实时递归神经网络 RNN(Real-time Recurrent Neural Network)在网络训练时间和捕捉动态信号特征等问题的解决上还存在着一定的困难,因而还没有得到广泛的应用. 参考文献[4]将模糊理论引入到 DTC 中,也取得了比较满意的效果,但是同样存在缺乏考虑时间延迟量的问题.

本文提出了基于小波网络的定子电阻辨识方法,利用小波网络良好的时频局部特性,输出定子电阻的动态估计值,再由定子磁链和转矩估计器准确的观测出磁链和转矩,优化了逆变器的控制策略. 通过与 BP(Backward Propagation)神经网络的仿真研究结果对比,该方法对抑制 DTC 系统低速运行时电流和转矩脉动有明显的效果,优于采用 BP 神经网络的方法.

1 DTC 原理

在 DTC 系统中,首先在定子坐标系下观测定子磁链和转矩;观测完毕后,磁链偏差、转矩偏差和磁链位置直接用于选择逆变器的开关状态,输出相应的电压空间矢量,实现异步电动机的转矩和转速调节. 本文采用空间矢量法进行电动机的定子电压和定子电流 abc-$\alpha\beta$ 坐标变换,然后计算定子磁链与转矩. 3/2 变换方程为

$$\begin{bmatrix} U_{s\alpha} \\ U_{s\beta} \end{bmatrix} = \sqrt{\frac{2}{3}} \begin{bmatrix} 1 & -1/2 & -1/2 \\ 0 & \sqrt{3}/2 & -\sqrt{3}/2 \end{bmatrix} \begin{bmatrix} U_a \\ U_b \\ U_c \end{bmatrix} = \begin{bmatrix} \sqrt{\frac{3}{2}} & 0 \\ \frac{1}{\sqrt{2}} & \sqrt{2} \end{bmatrix} \begin{bmatrix} U_a \\ U_b \end{bmatrix} \tag{1}$$

$$\begin{bmatrix} I_{s\alpha} \\ I_{s\beta} \end{bmatrix} = \sqrt{\frac{2}{3}} \begin{bmatrix} 1 & -1/2 & -1/2 \\ 0 & \sqrt{3}/2 & -\sqrt{3}/2 \end{bmatrix} \cdot \begin{bmatrix} I_a \\ I_b \\ I_c \end{bmatrix} = \begin{bmatrix} \sqrt{\frac{3}{2}} & 0 \\ \frac{1}{\sqrt{2}} & \sqrt{2} \end{bmatrix} \begin{bmatrix} I_a \\ I_b \end{bmatrix} \tag{2}$$

其中,$U_{s\alpha}$,$U_{s\beta}$为 α,β 轴上电压分量;$I_{s\alpha}$,$I_{s\beta}$为 α,β 轴上电流分量;U_a,U_b,U_c 为三相电压;I_a,I_b,I_c 为三相电流,且满足:$U_a+U_b+U_c=0$,$I_a+I_b+I_c=0$. 可见,只需检测出电动机的两相电压和电流,就可进行定子磁链和转矩的计算,从而使检测电路得以简化. 图 1 为 DTC 的原理图. 系统由整流器、逆变器、定子磁链和转矩估计器以及开关状态选择器等部分组成. ψ_{ref}为给定定子磁链, T_{ref}为给定定子转矩,$\boldsymbol{S}=(S_a,S_b,S_c)^{\mathrm{T}}$ 为逆变器的控制状态,E_T 为转矩误差,E_ψ 为磁链误差. 采用定子磁链观测的 u-i 数学模型,则定子磁链和转矩估计器输出表达式如下:

$$\boldsymbol{\psi}_{\mathrm{s}} = \int (\boldsymbol{U}_{\mathrm{s}} - \boldsymbol{I}_{\mathrm{s}} R_{\mathrm{s}})\,\mathrm{d}t \tag{3}$$

$$|\boldsymbol{\psi}_{\mathrm{s}}| = \sqrt{\psi_{s\alpha}^2 + \psi_{s\beta}^2} \tag{4}$$

$$T_{\mathrm{e}} = \frac{3}{2} N_{\mathrm{p}} (\psi_{s\alpha} I_{s\beta} - \psi_{s\beta} I_{s\alpha}) \tag{5}$$

$$\theta = \arctan\left(\frac{\psi_{s\beta}}{\psi_{s\alpha}}\right) \tag{6}$$

其中,$\boldsymbol{\psi}_{\mathrm{s}}=(\psi_{s\alpha},\psi_{s\beta})^{\mathrm{T}}$ 为定子磁链;$\psi_{s\alpha}$,$\psi_{s\beta}$为 α,β 轴上的磁链分量;$\boldsymbol{U}_{\mathrm{s}}=(U_{s\alpha},U_{s\beta})^{\mathrm{T}}$ 为定子电压;$\boldsymbol{I}_{\mathrm{s}}=(I_{s\alpha},I_{s\beta})^{\mathrm{T}}$ 为定子电流;R_{s} 为定子电阻; T_{e} 为电磁转矩;N_{p} 为电机极对数;θ 为定子磁链相位角. 式(1)~式(6)即构成了定子磁链和电磁转矩的观测模型. 从式(3)出发,又可推导出:

$$\Delta\boldsymbol{\psi}_{\mathrm{s}} = \frac{\Delta R_{\mathrm{s}} \boldsymbol{I}_{\mathrm{s}}}{\mathrm{j}\omega} + C_0 \tag{7}$$

其中,$\Delta\boldsymbol{\psi}_{\mathrm{s}}$ 为定子磁链变化;ΔR_{s} 为定子电阻变化;ω 为电机频率;C_0 为与 $\Delta\boldsymbol{\psi}_{\mathrm{s}}$ 初始值有关的常数. 式(7)表示在时间区间$[t_0,t]$上的积分结果. 综合式(3)、式(5)和式(7)可知,定子电阻的准确观测将直接影响磁链 $\boldsymbol{\psi}_{\mathrm{s}}$ 和转矩 T_{e} 的精度. 在电机高速运行时,$|\boldsymbol{U}_{\mathrm{s}}|$很大,$|\boldsymbol{I}_{\mathrm{s}}R_{\mathrm{s}}|$与之相比很小,可以忽略不计,定子磁链的观测精度也能满足要求. 但是在电机低速运行时,由于$|\boldsymbol{U}_{\mathrm{s}}|$比较小,常与$|\boldsymbol{I}_{\mathrm{s}}R_{\mathrm{s}}|$在同一数量级上,这时就必须考虑 R_{s} 对 $\boldsymbol{\psi}_{\mathrm{s}}$ 的影响. 如果对 R_{s} 的估计误差过大,就会严重影响系统控制性能,因此如何准确检测 R_{s} 的实时

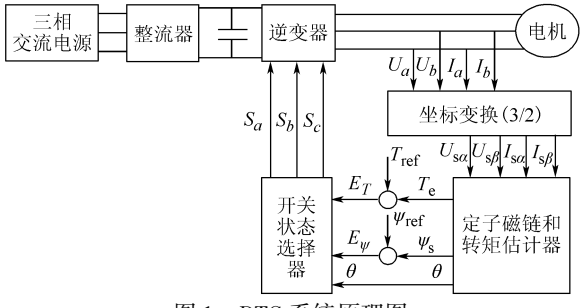


图 1 DTC 系统原理图

变化一直是改善 DTC 系统低速性能的首要问题.

2　定子电阻的小波网络辨识

2.1　小波网络结构的确定

目前广泛研究的小波网络是紧致型小波神经网络,即小波变换和神经网络直接融合,隐含层节点函数是小波函数,输入层到隐含层的权值和阈值分别是小波函数的伸缩因子和平移因子[5].

对于同样的具有 n 个输入节点、m 个输出节点、h 个隐含节点的网络结构,小波网络和 BP 神经网络的对比见表 1,可以看出,小波网络比 BP 神经网络更适合在控制系统中应用.

表 1　小波网络与 BP 神经网络的比较

网络类型	函数逼近能力	单隐层结构形式	可调参数	参数学习算法
BP 神经网络	全局逼近网络	隐含层节点函数:常用 sigmoid 函数	$n\times h+h\times m$ 个输入和输出权值,	基于非线性优化技术
小波网络	局部逼近网络:收敛速度快,易适应新数据避免较大的外推误差.	隐含层节点函数:小波函数,具有良好的捕捉动态信号特征的能力.	$h+m$ 个阈值 $h\times m$ 个输出权值	基于线性优化方法,学习,网络训练时间短. 时间短,收敛速度快.

本文采用的小波网络结构图如图 2 所示. h_1 和 h_2 分别为网络隐含层节点和输出层节点的阈值. 由于定子电阻的变化是时变非线性的,定子电流的变化也是时变非线性的,所以将定子电流的误差 $e(k)$ 和电流误差的变化量 $\Delta e(k)$ 作为网络的输入,输出是定子电阻变化量的估计值 $\Delta R_s(k)$[6]. 第 k 时刻的定子电阻观测值由第 $k-1$ 时刻的定子观测值和 $\Delta R_s(k)$ 线性叠加得到. 设隐含层的小波函数为 $f(t)$,则各表达式如下:

$$e(k)=\Delta I_s^*(k)=I_s^*(k)-I_s(k) \tag{8}$$

$$\Delta e(k)=e(k)-e(k-1) \tag{9}$$

$$I_s(k)=\sqrt{I_{s\alpha}^2(k)+I_{s\beta}^2(k)} \tag{10}$$

$$R_s(k)=R_s(k-1)+\Delta R_s(k) \tag{11}$$

$$\Delta R_s(k)=\sum_{j=1}^{h} w_j f\left(\sum_{i=1}^{m}\frac{t_i-b_j}{a_{ij}}\right) \tag{12}$$

其中,$I_s(k)$ 为给定定子电流值;$I_s(k)$ 为定子电流的测量值;a_{ij},b_j,w_j 分别为小波网络小波基的伸缩因子、平移因子、隐含层到输出层的权系数.

小波网络的母函数采用 Meyer 函数,这个函数已经被证明满足小波框架的允许条件,而且是正交的. 将确定结构的小波网络应用于 DTC 系统,原理图如图 3 所示.

2.2　小波网络的训练算法

目前,对小波网络参数的学习算法,主要有梯度下降法、正交搜索法、矩阵求逆法、最小二乘法等方法. 由式(12)可知,其表达形式就是一个回归方程,权值 w_j 就是回归系数,因此本文采用数值鲁棒性更好的递推正交最小二乘法 ROLSA(Recursive Orthogonal Least Squares Algorithm)对小波网络的权值进行训练. 这时不再采用小波网络的实际输出和期望输出之间的误差对小波网络进行训练,而是使用整个系统的实际输出和期望输出之间的误差对小波网络进行训练. 设有 N 对训练数据 (X_N,Y_N),则式(12)的矩阵形式可写为

$$\boldsymbol{Y}=\boldsymbol{U}\boldsymbol{W}+\boldsymbol{E} \tag{13}$$

其中,$\boldsymbol{Y}$ 为期望输出矩阵;$\boldsymbol{U}$ 为隐含层输出矩阵(也称为回归矩阵);$\boldsymbol{W}$ 为权重矩阵;$\boldsymbol{E}$ 为输出误差矩阵,且有:$\boldsymbol{Y}=(y(1),y(2),\cdots,y(N))^{\mathrm{T}}$,$\boldsymbol{U}=(u(1),u(2),\cdots,u(N))^{\mathrm{T}}$,$\boldsymbol{W}=(w_1,w_2,\cdots,w_N)^{\mathrm{T}}$,$\boldsymbol{E}=(e(1),e(2),\cdots,e(N))^{\mathrm{T}}$.

定义网络优化指标函数为

$$J(\boldsymbol{W})=\|\boldsymbol{E}\|^2=\|\boldsymbol{Y}-\boldsymbol{U}\boldsymbol{W}\|_2^2 \tag{14}$$

当第 i 组学习样本输入时,$\boldsymbol{U}_{i-1}$,$\boldsymbol{U}_i$,$\boldsymbol{Y}_{i-1}$,$\boldsymbol{Y}_i$ 之间的关系可用下面的矩阵表示:

$$\left.\begin{aligned}\boldsymbol{Y}_i&=\begin{bmatrix}\boldsymbol{Y}_{i-1}\\ y_i\end{bmatrix}\\ \boldsymbol{U}_i&=\begin{bmatrix}\boldsymbol{U}_{i-1}\\ \boldsymbol{U}_i\end{bmatrix}\end{aligned}\right\} \tag{15}$$

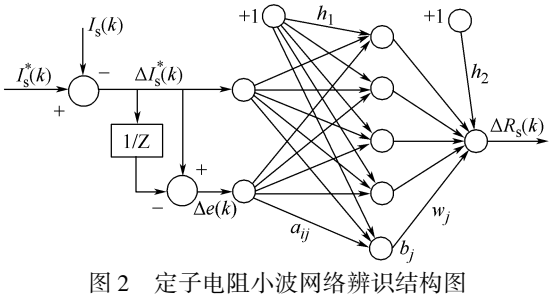


图 2　定子电阻小波网络辨识结构图

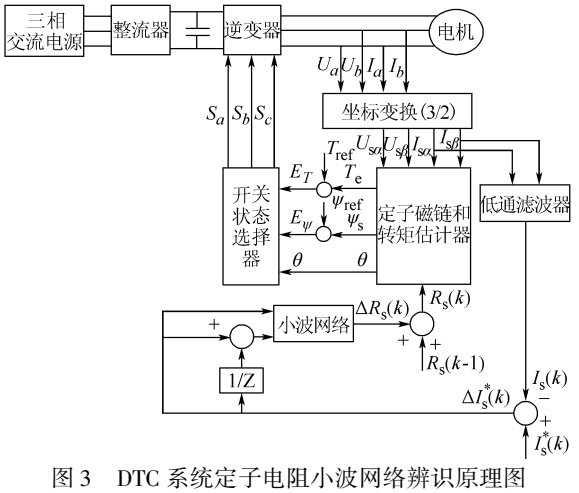


图 3　DTC 系统定子电阻小波网络辨识原理图

根据参考文献[7]可以推导出 $\boldsymbol{U}_{i-1}$,$\boldsymbol{U}_i$,$\boldsymbol{Y}_{i-1}$,$\boldsymbol{Y}_i$ 之间的 QR 分解的递推关系:

$$\left.\begin{aligned}\boldsymbol{U}_{i-1}&=\boldsymbol{Q}_1\begin{bmatrix}\boldsymbol{R}_{i-1}\\0\end{bmatrix}\\\begin{bmatrix}\boldsymbol{R}_{i-1}\\u_i\end{bmatrix}&=\boldsymbol{Q}_2\begin{bmatrix}\boldsymbol{R}_i\\0\end{bmatrix}\end{aligned}\right\}\tag{16}$$

$$\left.\begin{aligned}\boldsymbol{Q}_1^{\mathrm{T}}\boldsymbol{Y}_{i-1}&=\begin{bmatrix}\hat{\boldsymbol{Y}}_{i-1}\\\tilde{\boldsymbol{Y}}_{i-1}\end{bmatrix}\\\boldsymbol{Q}_2^{\mathrm{T}}\begin{bmatrix}\hat{\boldsymbol{Y}}_{i-1}\\y_i\end{bmatrix}&=\begin{bmatrix}\hat{\boldsymbol{Y}}_i\\\tilde{y}_i\end{bmatrix}\end{aligned}\right\}\tag{17}$$

其中,$\boldsymbol{Q}_1$ 和 $\boldsymbol{Q}_2$ 为正交矩阵;$\boldsymbol{R}$ 为上三角矩阵. $J(w_i)$取极小值的线性输出权矩阵 $\boldsymbol{W}_i$ 和 i 组样本输入时,网络输出与期望输出的偏差分别计算如下:

$$\boldsymbol{R}_i\boldsymbol{W}_i=\hat{\boldsymbol{Y}}_i,\ \|\tilde{\boldsymbol{Y}}_i\|_2^2=\|\tilde{y}_i\|_2^2+\|\tilde{\boldsymbol{Y}}_{i-1}\|_2^2\tag{18}$$

其中 $\|\tilde{\boldsymbol{Y}}_{i-1}\|_2^2$ 为 $i-1$ 个样本输入时产生的偏差. 上述推导的递推正交最小二乘法,用计算机编程实现比较困难,而且当输入输出数据较多且海明距较小时,正交分解容易产生病态问题,即出现 $\boldsymbol{u}_i^{\mathrm{T}}\boldsymbol{u}_i=0$ 的情况. 本文对参考文献[8]中的 Givens 变换进行修改适用于 QR 分解,式(19)给出两个行向量变换的情况.

$$\begin{bmatrix}0,a_i,a_{i+1},\cdots\\0,b_i,b_{i+1},\cdots\end{bmatrix}\xrightarrow{\text{行变换}}\begin{bmatrix}0,a'_i,a'_{i+1},\cdots\\0,0,b'_{i+1},\cdots\end{bmatrix}\tag{19}$$

其中,$a'_p=ca_p+sb_p$,$b'_p=-sa_p+cb_p$,$a'_i=(a_i^2+b_i^2)^2$,$c=a_i/a'_i$,$s=b_i/b'_i(p=i+1,i+2,\cdots)$.

上述变换和式(16)与式(17)中的 QR 变换分解具有相同的功能,对于式(16)和式(17),应用增广矩阵,则回归矩阵 $\boldsymbol{U}$ 的变换形式如下:

$$\begin{bmatrix}\boldsymbol{R}_{i-1}&\vdots&\hat{\boldsymbol{Y}}_{i-1}\\&\vdots&\\\boldsymbol{U}_i&\vdots&y_i\end{bmatrix}\xrightarrow{\boldsymbol{Q}^{\mathrm{T}}(q)}\begin{bmatrix}\boldsymbol{R}_i&\vdots&\hat{\boldsymbol{Y}}_i\\&\vdots&\\0&\vdots&\tilde{y}_i\end{bmatrix}\tag{20}$$

综上所述,ROLS 计算步骤总结如下:

1) 初始化 $i=0$,$\boldsymbol{R}_0=a\boldsymbol{I}$,其中 a 为任意小正实数,$\boldsymbol{I}$ 为单位矩阵;令 $\hat{\boldsymbol{Y}}_0=0$,$\|\tilde{\boldsymbol{Y}}_0\|_2^2=0$,$\boldsymbol{R}_{i-1}=\boldsymbol{R}_0$,$\hat{\boldsymbol{Y}}_{i-1}=\hat{\boldsymbol{Y}}_0$,$\|\tilde{\boldsymbol{Y}}_{i-1}\|_2^2=\|\tilde{\boldsymbol{Y}}_0\|_2^2$.

2) 从学习样本中选取一组样本数据 $\boldsymbol{X}_i$ 和期望输出 $\boldsymbol{Y}_i$,当 $q\geqslant 1$ 时利用式(20)进行 QR 分解. 依次用 $\boldsymbol{R}_{i-1}$的主对角线元素与最低行对应元素做 Givens 变换,直到

$$\begin{bmatrix}\boldsymbol{R}_{i-1}\\\boldsymbol{U}_i\end{bmatrix}\longrightarrow\begin{bmatrix}\boldsymbol{R}_i\\0\end{bmatrix}\tag{21}$$

得到 $\boldsymbol{R}_i$,$\boldsymbol{Q}^{\mathrm{T}}$,$\hat{\boldsymbol{Y}}_i$ 和 $\tilde{y}_i$.

3) 计算偏差 $\|\tilde{\boldsymbol{Y}}_i\|_2^2$,并令 $\boldsymbol{R}_{i-1}=\boldsymbol{R}_i$,$\hat{\boldsymbol{Y}}_{i-1}=\hat{\boldsymbol{Y}}_i$,$\|\tilde{\boldsymbol{Y}}_{i-1}\|_2^2=\|\tilde{\boldsymbol{Y}}_i\|_2^2$. $i=i+1$,若 $i<N$ 时,转到第 2 步;否则 $\hat{\boldsymbol{Y}}(N)=\boldsymbol{R}(N)\boldsymbol{U}(N)$,结束.

3 仿真实例

在 MATLAB7.0/SIMULINK 仿真软件环境下,采用上述控制策略对 DTC 系统进行了仿真. 仿真中所用的三相交流电动机为星型接法,电动机参数如下:额定功率 $P_{\mathrm{n}}=15$ kW,额定电压 $U_{\mathrm{n}}=380$ V,额定电流 $I_{\mathrm{n}}=45.5$ A,额定转速 $n_{\mathrm{s}}=1\,500$ r/min;极对数 $N_{\mathrm{p}}=2$,额定频率 $f_{\mathrm{n}}=50$ Hz,定子电阻 $R_{\mathrm{s}}=0.088\ \Omega$,转子电阻 $R_{\mathrm{r}}=0.065\ \Omega$,定子自感 $L_{\mathrm{s}}=0.0236$ H,转子自感 $L_{\mathrm{r}}=0.0207$ H,定转子互感 $L_{\mathrm{m}}=0.0183$ H,机械转动惯量 $J=0.018\ \mathrm{kg\cdot m^2}$. 系统控制参数:给定参考磁链 $\psi_{\mathrm{ref}}=0.98$ Wb,参考负载转矩 $T_{\mathrm{ref}}=100.0$ N·m.

图 4 表示定子电阻未辨识前定子电流、定子磁链和电磁转矩的变化曲线. 图 4a 表示对网络进行训练的定子电阻变化曲线,定子电阻的起始值为 0.08 Ω 并保持恒定值约 1 s,然后以 0.02 Ω/s 的速度增长至 0.12 Ω,约需 2 s 的时间,然后保持恒定约 1 s,然后以相同的速率下降到初始值 0.08 Ω,此过程重复 3 遍. 图 4b 表示定子电阻未辨识前定子电流 A 相的变化曲线,图 4c 和图 4d 分别表示定子电阻未辨识前定子磁链和电磁转矩的变化曲线. 由图 4 中可以看出,在定子电阻未辨识前,定子电阻下降时定子电流和电磁转矩增加,定子电阻上升时定子电流和电磁转矩减少,而且定子磁链和电磁转矩的波动比较大.

利用仿真数据对BP神经网络和小波网络分

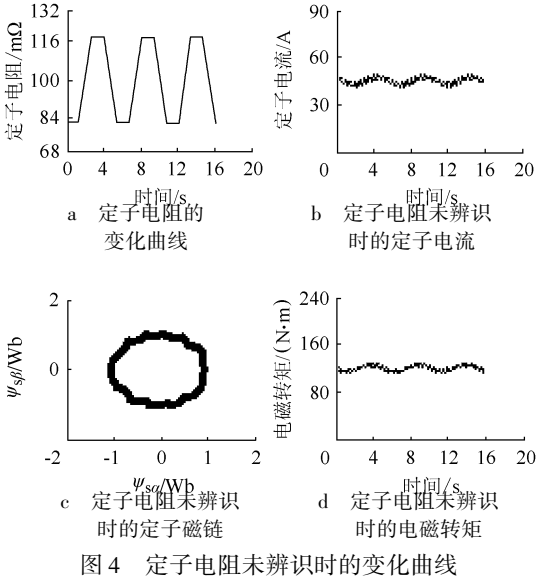
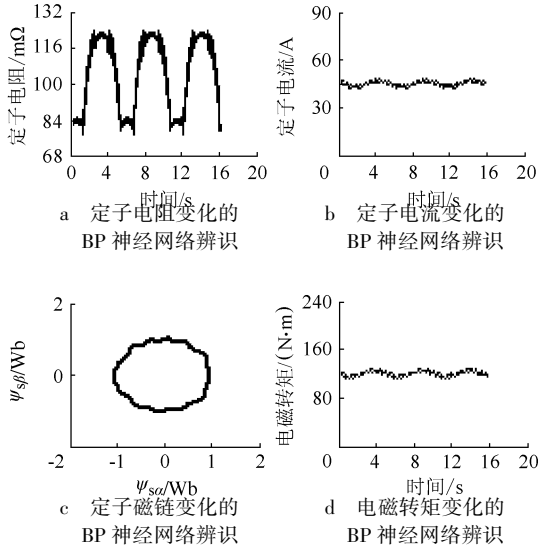


图 4 定子电阻未辨识时的变化曲线

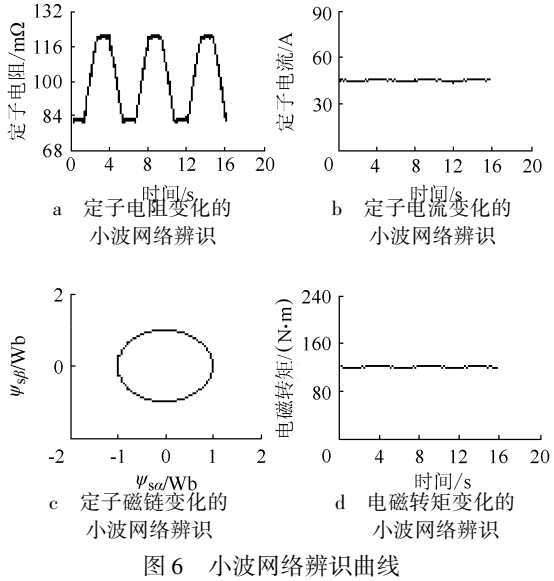
别进行训练,得到网络的初始权值,然后利用所得的权值进行在线辨识. 图 5 表示使用 BP 神经网络对定子电阻进行辨识后的曲线,图 6 表示使用小波网络对定子电阻进行辨识后的曲线.



a　定子电阻变化的 BP 神经网络辨识　　b　定子电流变化的 BP 神经网络辨识

c　定子磁链变化的 BP 神经网络辨识　　d　电磁转矩变化的 BP 神经网络辨识

图 5　BP 神经网络辨识曲线



a　定子电阻变化的小波网络辨识　　b　定子电流变化的小波网络辨识

c　定子磁链变化的小波网络辨识　　d　电磁转矩变化的小波网络辨识

图 6　小波网络辨识曲线

从图 5 和图 6 的对比中,可以明显的看出:

1) 在定子电阻变化曲线的上升段和下降段,与使用 BP 神经网络的方法相比,采用小波网络进行辨识使定子电阻的脉动进一步减少,数值稳定;

2) 使用小波网络进行辨识后,定子电流、磁链和电磁转矩的脉动有了明显的减少,曲线比较平滑,定子磁链的运行轨迹已经比较接近于圆形.

4　结 束 语

针对传统的异步电动机 DTC 在低速运行时存在转矩和电流脉动严重,影响实际应用的问题,本文提出了应用小波网络进行定子电阻辨识的方法,进一步提高了定子电阻的辨识精度,可以更加准确的观测出定子磁链和转矩,有效的改善了系统的低速运行性能,优于采用 BP 神经网络的控制方法.

经过进一步的完善,该方法可以用于实际的控制系统中,具有一定的实用价值,为开发新型交流传动系统提供了一条有效的途径.

参考文献 (References)

[1] 赵争鸣,袁立强,孟朔,等. 通用变频器矢量控制与直接转矩控制特性比较[J]. 电工技术学报,2004,19(4):81-84
Zhao Zhengming, Yuan Liqiang, Meng Shuo, et al. Comparison of vector control and direct torque control for general inverters [J]. Transactions of China Electrotechnical Society, 2004, 19(4):81-84(in Chinese)

[2] 王萍,李斌,黄瑞祥,等. 基于神经网络的无速度传感器直接转矩控制系统的研究[J]. 电工技术学报,2003,18(2):5-8
Wang Ping, Li Bin, Huang Ruixiang, et al. Study of speed-sensorless direct torque control system based on neural-network[J]. Transactions of China Electrotechnical Society, 2003, 18(2):5-8(in Chinese)

[3] 王晓东,石海峰. 基于自适应线性神经元速度观测器在直接转矩控制系统中的应用[J]. 电工技术学报,2003,18(1):27-32
Wang Xiaodong, Shi Haifeng. Application of direct torque control system based on speed observer of ADALINE[J]. Transactions of China Electrotechnical Society, 2003, 18(1):27-32(in Chinese)

[4] 张春,郭兴众. 模糊直接转矩控制系统的设计与仿真研究[J]. 电子科技大学学报,2004,33(5):582-585
Zhang Chun, Guo Xingzhong. Design and simulation of fuzzy direct torque control system[J]. Journal of UEST of China, 2004, 33(5):582-585(in Chinese)

[5] Stephen A Billings, Hua Liangwei. A new class of wavelet networks for nonlinear system identification[J]. IEEE Transactions on Neural Network, 2005, 16(4):862-874

[6] 陈硕,迁峰男,山田英二. 感应电机无速度传感器矢量控制系统的定子电阻在线辨识[J]. 中国电机工程学报,2003,23(2):88-92
Chen Shuo, Tsuji Mineo, Yamada Eiji. On-line identification of stator resistance for sensorless vector control system of induction motors[J]. Proceedings of the CSEE, 2003, 23(2):88-92(in Chinese)

[7] Chen S. Nonlinear times series modeling and prediction using Gaussian RBF network with enhanced clustering and RLS learning[J]. Inst Elect Electron Lett, 1995, 31(2):117-118

[8] Barry G J, Ding L Y. Selecting radial basis function network centers with recursive orthogonal least squares training[J]. IEEE Transactions on Neural Networks, 2000, 11(2):306-314

(责任编辑:彭　徽)