

# 基于神经网络的开关磁阻电机的无位置检测

马晓光<sup>1</sup>, 瞿遂春<sup>1,2</sup>, 谭平<sup>1</sup>

(1. 湖南工业大学, 湖南 株洲 412008; 2. 华中科技大学, 湖北 武汉 430074)

**摘要:** 提出了利用 BP 神经网络实现开关磁阻电机的无位置检测方法。该方法以开关磁阻电机绕组的相电流、磁链作为输入, 转子位置作为输出, 建立以相电流、磁链和转子位置之间的非线性映射, 以此实现转子位置控制。仿真结果证明, 此方法不仅简化了系统的复杂性, 提高了系统的检测精度, 而且使 SRD 具有较好的动态特性、自适应性和鲁棒性。

**关键词:** 开关磁阻电机; 位置传感器; BP 神经网络

中图分类号: TP274+.5

文献标志码: A

文章编号: 1673-9833(2009)06-0042-04

## Sensorless Detection of Switched Reluctance Motor Based on BP Neural Network

Ma Xiaoguang<sup>1</sup>, Qu Suichun<sup>1,2</sup>, Tan Ping<sup>1</sup>

(1. Hunan University of Technology, Zhuzhou Hunan 412008, China;

2. Huazhong University of Science and Technology, Wuhan HuBei 430074, China)

**Abstract:** Proposes the method to realize no position detection for switched reluctance motor using BP neural network. It, with winding phase current and magnetic chains as input and rotor position as output, establishes non-linear mapping between phase current, magnetic chains and the rotor position. Simulation results show that this approach not only simplifies the complexity of the system and improves its detection accuracy, but also makes SRD with good dynamic characteristics, better self-adaptability and robustness.

**Keywords:** SRM; position sensors; BP neural network

## 0 引言

转子位置检测是开关磁阻电机 (switched reluctance motor drive, 简称 SRD) 的重要环节, 检测到的位置信号既是绕组开通与关断的依据, 也为转速闭环控制提供了转速信息。传统的转子位置检测方法是直接利用光电式、电磁式和磁敏式等位置传感器来实现的, 随着电机相数的增加, 所需的传感器数量相应增多, 从而增加了系统的复杂性, 给安装和调试系统带来了很大的不便, 严重削弱了 SRD 结构简单的优势, 降低了系统的可靠性, 并难以实现电机的高速控制, 限制了 SRD 的应用领域。

目前, SRD 无位置传感器技术已成为开关磁阻电机研究领域的热点之一, 各国学者对这一问题从各个角度做了大量研究<sup>[1]</sup>。本文提出了一种基于 BP 神经网络的 SRD 无位置传感器技术, 利用 BP 神经网络实现开关磁阻电机的无位置检测方法。该方法采用有弹回的 BP 神经网络对 SRD 转子位置进行检测, 以电机三相绕组的相电流、磁链作为输入, 转子位置作为输出, 建立 SRD 非线性动态模型, 即建立磁阻电机绕组电流、磁链与转子位置之间的非线性映射, 从而实现了 SRD 无位置传感器的转子位置检测。建立了 SRD 非线性动态模型, 并利用该模型对系统进行了有效仿真。

收稿日期: 2009-10-15

作者简介: 马晓光 (1984-), 男, 安徽阜阳人, 湖南工业大学硕士研究生, 主要研究方向为新型电机及其控制,

E-mail: maxg1021@163.com

# 1 BP神经网络及其结构

## 1.1 BP神经网络

BP神经网络学习的指导思想是对网络权值 ( $\omega_{ij}$ ,  $T_{hi}$ ) 与阈值 ( $\theta$ ) 的修正, 使误差函数 ( $E$ ) 沿梯度方向下降。BP神经网络的3层节点表示为: 输入节点  $x_j$ 、隐层节点  $y_i$ 、输出节点  $o_i$ 。

输入节点与隐层节点间的网络权值为  $\omega_{ij}$ , 隐层节点与输出节点间的网络权值为  $T_{hi}$ 。当输出节点的期望输出为  $t_i$  时, BP模型的计算公式如下<sup>[2]</sup>:

1) 隐层节点输出

$$y_i = f\left(\sum_j \omega_{ij} x_j - \theta_i\right) = f(\text{net}_i), \text{ 其中 } \text{net}_i = \sum_j \omega_{ij} x_j - \theta_i;$$

2) 输出节点计算输出

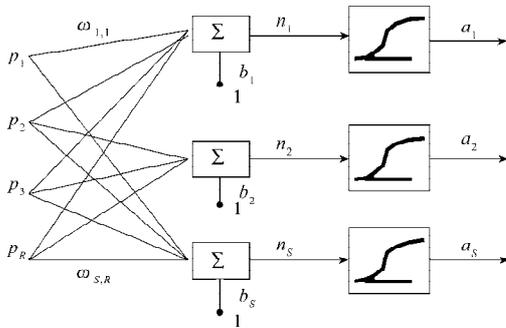
$$o_i = f\left(\sum_j T_{hi} y_j - \theta_i\right) = f(\text{net}_i), \text{ 其中 } \text{net}_i = \sum_j T_{hi} y_j - \theta_i;$$

3) 输出节点的误差公式

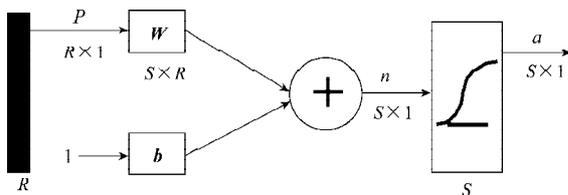
$$E = \frac{1}{2} \sum_i (t_i - o_i)^2 = \frac{1}{2} \sum_i \left( t_i - f\left(\sum_i T_{hi} y_i - \theta_i\right) \right)^2 = \frac{1}{2} \sum_i \left\{ t_i - f\left[\sum_i T_{hi} f\left(\sum_j \omega_{ij} x_j - \theta_i\right)\right] - \theta_i \right\}^2$$

## 1.2 BP神经网络的结构

BP神经网络属于前馈神经网络, 它具有前馈神经网络的基本结构。图1为1个具有  $S$  个输出,  $R$  个输入的单层BP神经网络结构, 它采用了对数S形神经元。



a) Matlab中人工神经元的一般模型



b) 单层神经网络的向量模型

图1 单层BP神经网络结构

Fig. 1 Single-tier structure of BP neural network

BP神经网络经常采用具有多层结构, 除了输入层和输出层, 它们中间的部分称为隐含层。这些隐含层经常使用S形神经元, 输出层对隐含层的输出进行线性加权, 从而实现输入层到输出层的映射, 使整个网

络达到分类和函数逼近的目的, 且线性的输出层保证了网络的输出具有  $-1 \sim 1$  之外的范围。如果要使网络的输出落在  $0 \sim 1$  之间, 输出层就要使用对数S形神经元。图2显示了1个双层的BP神经网络的结构。

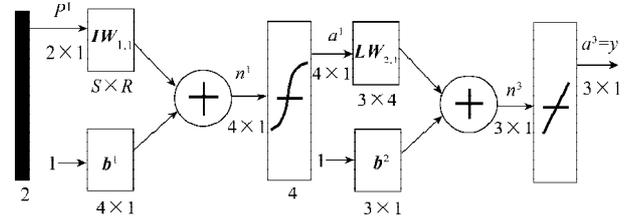


图2 双层BP神经网络结构

Fig. 2 Two-tier structure of BP neural network

## 1.3 BP神经网络学习算法

以图2所示的2层BP神经网络为例, 只有1个输入样本时, 有

$$E(k) = E[e^2(k)] \approx \frac{1}{s^2} \sum_{i=1}^s [t_i^2 - a_i^2(k)]^2,$$

$$a_i^2(k) = f^2 \left\{ \sum_{j=1}^s [\omega_{i,j}^2(k) a_j^1(k) + b_i^2(k)] \right\} =$$

$$f^2 \left\{ \sum_{j=1}^s [\omega_{i,j}^2(k) f^1 \left( \sum_{i=1}^s [i\omega_{i,j}^1(k) p_i + i b_i^1(k)] \right) + b_i^2(k)] \right\}.$$

若有  $n$  个输入样本, 则

$$E(k) = E[e^2(k)] \approx \frac{1}{ns^2} \sum_{j=1}^n \sum_{i=1}^s [t_i^2 - a_i^2(k)]^2.$$

根据上式和各层的传输函数, 可求出第  $k$  次迭代的总误差曲面的梯度, 即  $g(k) = \partial E(k) / \partial x(k)$ , 代入式  $x(k+1) = x(k) - ag(k)$  中, 便可逐次修正其权值和阈值, 并使总误差向减小的方向变化, 直至达到所要求的误差性能为止<sup>[1]</sup>。

# 2 基于Simulink的SRD非线性动态仿真

## 2.1 BP神经网络训练样本的获取

在BP神经网络训练中, 获取训练样本是个重要环节。神经网络的训练样本通常通过2个途径获得, 一是采用合适的数学模型通过计算产生, 这通常在仿真研究中采用; 另一途径是通过实验获得, 通过对所需数据的采样来获得训练样本, 该途径通常在实验研究中采用。

本文利用Simulink建立SRD的仿真模型, 通过仿真计算获得开关磁阻电机的相电流、磁链和转子位置角, 并以之作为网络的训练样本, 对电机的转子位置进行检测<sup>[3-4]</sup>。图3是在Matlab/Simulink中建立的SRD仿真模型。SRD仿真模型主要包含整流器、功率变换器、SRM、角位移传感器、PI调节器及滞环比较器等7个功能模块, 其中整流器、PI调节器和滞环比较器属于控制电路部分。

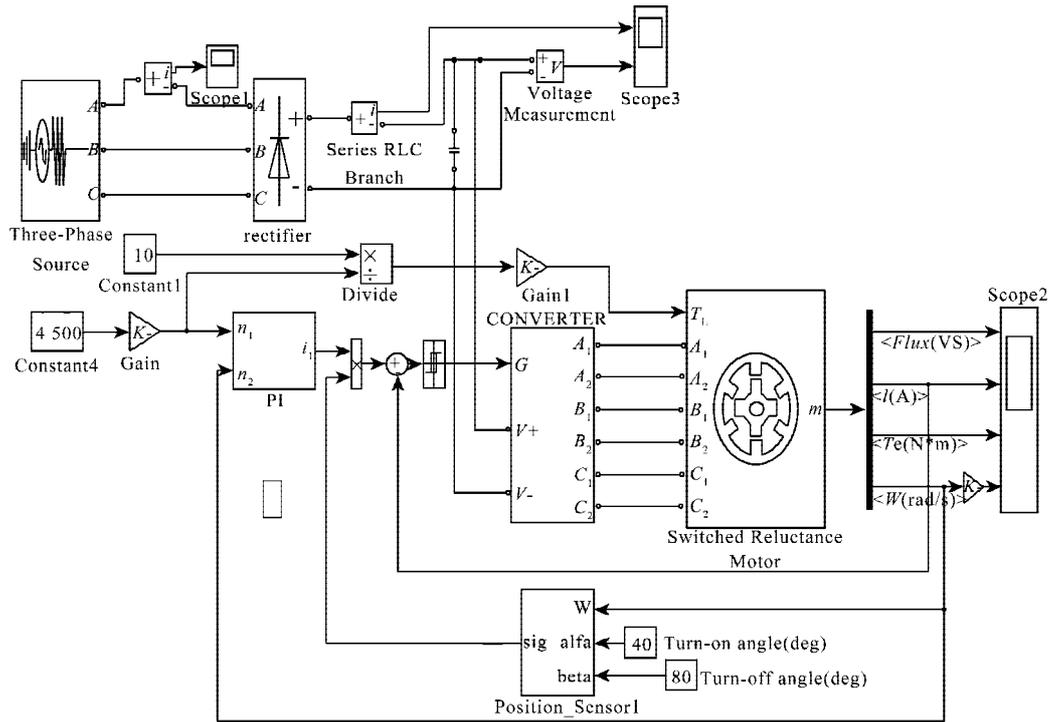


图3 SRD 仿真模型

Fig. 3 SRD simulation model

2.2 对于单相导通角内的转子位置检测

在单相导通角内，通过对 SRD 系统进行仿真，输出电流、磁链、转速、转矩数据，通过采样获得单相导通时的电流和磁链，并运行 BP 神经网络对样本数据进行训练，得到的误差变化曲线如图 4 所示。

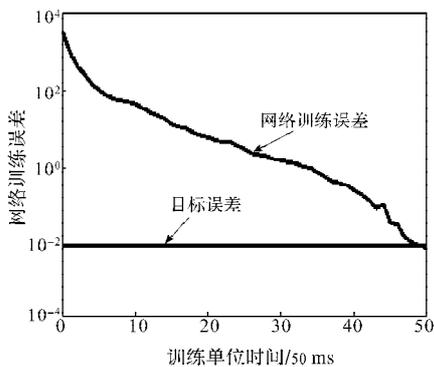


图4 单相导通角内网络训练误差曲线

Fig. 4 The error curve of single-phase turn-on angle network training

从图4可看出，在单相导通角内，BP神经网络的训练误差是0.009 457，而目标误差是0.01，显然通过神经网络对SRD系统的训练，能够很好地将误差控制在较小范围内，从而能更加精确地确定转子位置。网络训练完成后，利用训练过的网络模型，以测试样本作为网络输入进行仿真，得到网络输出向量，其结果见表1，实际位置曲线和检测位置曲线的对比见图5。

表1 单相导通角内部分样本及测试训练结果

Table 1 Some samples of single-phase turn-on angle and the results of testing and training

样本 $\theta$	时 间 /s			
	0.004	0.007	0.010	0.013
输入位置角	45.356 2	50.732 3	55.032 3	60.408 6
训练结果	44.842 3	49.918 3	55.186 9	61.001 2
误 差	0.513 9	0.814 0	0.154 6	0.592 6

样本 $\theta$	时 间 /s			
	0.016	0.019	0.022	0.025
输入位置角	65.786 6	70.189 8	75.468 2	79.968 7
训练结果	65.900 0	70.053 3	76.638 4	80.367 3
误 差	0.113 4	0.136 5	1.170 2	0.418 6

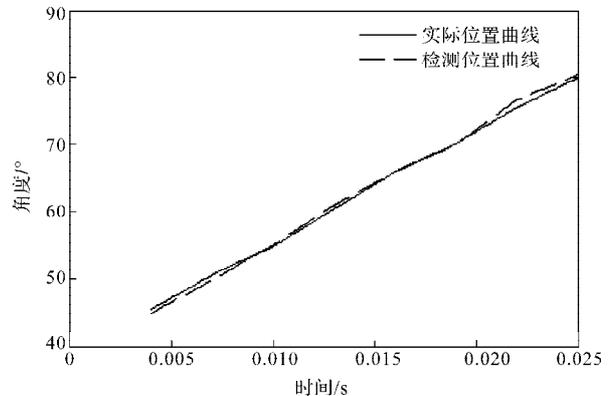


图5 单相导通角内实际位置曲线与检测位置曲线对比  
Fig. 5 The contrast of the detection location curve and the actual location curve for single-phase turn-on angle

由实际位置曲线和检测位置曲线对比可看出, 在单相导通角内, 检测位置与实际位置曲线基本重合。由此可见, BP神经网络在单相导通角内对电机转子位置检测具有较高的精度。

### 2.3 对于三相全角度域内的转子位置检测

要实现SRD系统中的电流正确换相, 并实现无位置传感器控制, 除对单相导通角内电机的转子位置检测外, 还要对三相全角度域内的转子位置进行检测。

神经网络在全角度域内的输入样本为三相电流和磁链, 输出样本为对应的转子位置角。所以此时BP神经网络的输入神经元个数为6, 输出的神经元个数为1。经过BP神经网络对样本数据进行训练得到的误差变化曲线见图6。从图6可看出, 在三相全角度域内, BP神经网络的训练误差是0.009 993, 而目标误差是0.01, 与单相导通角内的网络训练一样, 同样能将误差控制在较小范围内, 从而能更加精确地确定转子位置。

表2 三相全角度域内部分样本及测试训练结果

Table 2 Some samples of three-phase full area and the results of testing and training

样本 $\theta$	时 间 /s												
	0.001	0.003	0.005	0.007	0.009	0.011	0.013	0.015	0.017	0.019	0.021	0.023	0.025
输入 $\theta$	43.363 2	46.299 3	49.296 5	52.352 2	55.464 4	58.631 4	61.851 2	65.122 0	68.442 7	71.812 4	75.228 8	78.691 3	82.198 1
训练结果	42.666 8	46.302 8	49.822 2	52.885 4	55.778 2	58.794 2	62.361 0	65.683 4	68.043 5	71.409 8	75.835 3	79.488 7	82.093 4
误 差	0.696 4	0.003 5	0.525 7	0.533 2	0.318 2	0.162 8	0.509 8	0.561 4	0.399 2	0.402 6	0.606 5	0.797 4	0.094 7

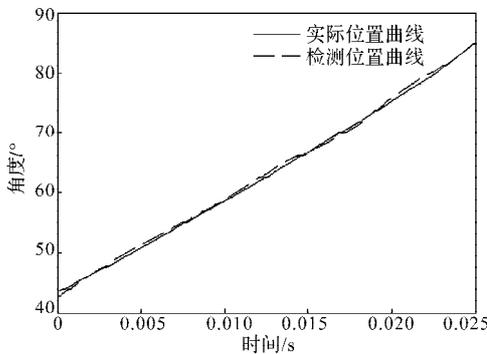


图7 三相全角度域内实际位置曲线与检测位置曲线对比  
Fig. 7 The contrast of the detection location curve and the actual location curve for three-phase full angle area

从仿真的结果看, 将样本数据扩展到三相全角度域内, 实现了电机全角度域内的转子位置检测, 并且扩大了网络训练的样本集, 避免了网络训练不足的情况, 有利于网络模型的建立和评价。

## 3 结论

BP神经网络具有很强的学习功能, 本文采用有弹回的BP神经网络, 建立SRM的相电流、磁链与转子位置间的非线性映射, 实现了SRM全角度域内的转子位置检测。不仅进一步简化了SRD的结构, 提高了系统的稳定性, 且BP神经网络在对转子位置检测时的检测精度高, 动态特性好, 有较好的自适应性和鲁棒性。

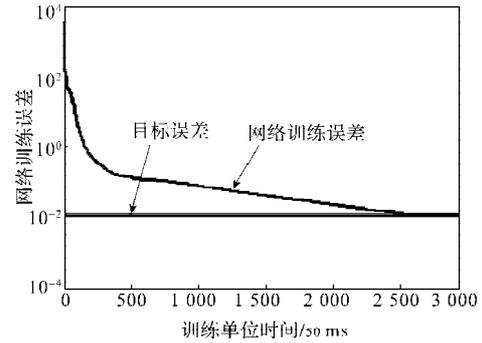


图6 三相全角度域内网络训练误差曲线  
Fig. 6 The error curve of three-phase full area network training

网络训练完成后, 利用训练过的网络模型, 以测试样本作为网络输入, 调用sim函数仿真, 即可得到网络输出向量, 其结果如表2所示, 实际位置曲线和检测位置曲线的对比见图7。

### 参考文献:

- [1] 周素莹, 林辉. 基于神经网络的开关磁阻电机转子位置估计[J]. 微电机, 2006, 39(2): 16-18.  
Zhou Suying, Lin Hui. Rotor Position Estimation of Switched Reluctance Motor Based on Neural Network[J]. Micromotors Servo Technique, 2006, 39(2): 16-18.
- [2] 周开利, 康耀红. 神经网络模型及其MATLAB仿真程序设计[M]. 北京: 清华大学出版社, 2005: 70-88.  
Zhou Kaili, Kang Yaohong. Neural Network Model and Its MATLAB Simulation Programming[M]. Beijing: Tsinghua University Press, 2005: 70-88.
- [3] 王旭东, 张奕黄. 无位置传感器开关磁阻电动机位置的检测与预报[J]. 中国电机工程学报, 2002(7): 5-8.  
Wang Xudong, Zhang Yihuang. Positions Detection and Forecast of Sensorless Switched Reluctance Motor[J]. Proceedings of the CSEE, 2002(7): 5-8.
- [4] Zheng Hongtao, Jiang Jingping, Xu Dehong, et al. Switched Reluctance Motor Sensorless Drive with Energy Optimizing Control Strategy[J]. Proceedings of the CSEE, 2004, 24(1): 153-157.
- [5] Xu Longya, Wang Chuangyang. Accurate Rotor Position Detection and Sensorless Control of SRM for Supre-High Speed Operation[J]. IEEE Transactions on Power Electronics, 2005, 17(5): 757-763.

(责任编辑: 廖友媛)