

基于预处理 BP 神经网络的开关磁阻电机建模^{*}

孙利宏, 赵永生, 李存贺, 柳健, 范云生
(大连海事大学 船舶电气工程学院, 辽宁 大连 116026)

摘要: 针对开关磁阻电机(SRM)强耦合、强非线性、难以精确解析建模的问题, 提出一种基于数据预处理的反向传播(BP)神经网络建模方法。首先通过传统直流脉冲法测量一个电周期内 SRM 静态电磁特性, 获取建模样本数据; 其次充分利用电机先验知识, 通过可以初步反映 SRM 非线性特性的磁链和转矩解析表达式对实测样本数据进行预处理并作为 BP 神经网络新的输入, 降低神经网络拟合误差。与传统 BP 神经网络建模的对比结果显示, 引入预处理方法可以有效减少 BP 神经网络节点数量, 增强神经网络泛化能力, 提高神经网络建模精度。

关键词: 开关磁阻电机; 电磁特性; 神经网络; 非线性建模; 数据预处理

中图分类号: TM 352 文献标志码: A 文章编号: 1673-6540(2019)03-0064-07

Modeling of Switched Reluctance Motor Based on Pretreatment BP Neural Network^{*}

SUN Lihong, ZHAO Yongsheng, LI Cunhe, LIU Jian, FAN Yunsheng

(School of Marine Electrical Engineering, Dalian Maritime University, Dalian 116026, China)

Abstract: Aiming at the problem that the switched reluctance motor (SRM) with strong coupling and strong nonlinearity was difficult to accurately resolve and model, a back-propagation (BP) neural network modeling method based on data pretreatment was proposed. Firstly, the static electromagnetic characteristics of SRM in one electrical cycle were measured by the traditional DC pulse method to obtain modeling sample data. Secondly, the motor prior knowledge was fully utilized, and the measured sample data were preprocessed through the flux linkage and torque analytical expressions which could initially reflect the nonlinear characteristics of the SRM, and then sent to the BP neural network so as to reduce the neural network fit error. Compared with the traditional BP neural network modeling, the pretreatment method could effectively reduce the number of BP neural network nodes, enhance the generalization ability of the neural network, and improve the modeling accuracy of the neural network.

Key words: switched reluctance motor (SRM); electromagnetic characteristics; neural network; nonlinear modeling; data pretreatment

0 引言

开关磁阻电机(SRM)具有结构简单、起动转矩大、效率高、鲁棒性好、成本低等优点, 在新能源汽车、风力发电、油田抽油机、矿山机械和家用电器等领域有着良好的应用前景^[1-3]。精确的 SRM 非线性模型是分析、预测电机性能, 实施先进控制算法的基础。由于 SRM 磁路饱和、涡流与磁滞效应等产生的强耦合和强非线性, 建立精确数学模型较为困难, 为此, 国内外学者对 SRM 非线性建

* 基金项目: 国家自然科学基金项目(51609033); 辽宁省自然科学基金项目(20180520005); 中央高校基本科研业务费(3132018306, 3132016312)

作者简介: 孙利宏(1995—), 男, 硕士研究生, 研究方向为开关磁阻电机非线性建模。

赵永生(1962—), 男, 博士, 教授, 研究方向为嵌入式测控系统、电机驱动等。

李存贺(1989—), 男, 博士研究生, 研究方向为开关磁阻电机建模与控制。

模方法进行了深入研究。

常用的 SRM 建模方法包括函数解析法^[4]、有限元分析法^[5-7]和智能建模法^[8-11]等。在函数解析法中, 虽然线性模型^[12]避免了繁琐的数学推导, 但其忽略了电流对电感的影响, 与实际相差较大; 非线性函数解析式^[13]虽然具有更好的模型精度, 但计算也较为复杂, 对硬件要求较高。有限元分析法中常用的二维有限元法^[14]目前较为成熟, 但其局部误差较大的问题很难解决; 三维有限元法^[15]因为未知量过多导致计算规模庞大, 也很难广泛应用。神经网络等智能算法具有任意精度的非线性映射能力和较为强大的学习能力, 被广泛应用于非线性系统建模, 也非常适合用于建立 SRM 模型^[16]。传统的神经网络未充分利用 SRM 的先验知识, 为了获得更为精准的模型往往需要更多的数据作为训练样本来对网络进行多次训练, 增加了建模的复杂性。

本文基于传统的反向传播(BP)神经网络, 加入可以反映磁链与转矩非线性的解析表达式作为网络的预处理函数, 充分利用了 SRM 的先验知识来对网络进行优化, 使得小规模的神经网络可以在减少神经节点的条件下提高建模精度, 增强网络的泛化能力, 降低了建模的复杂性, 在实时控制和小规模网络中有着较强的应用性。

1 SRM 数学模型

1.1 磁链与转矩特性检测

由电路基本定律, 可知相绕组的电压平衡方程式为

$$\frac{d\psi(\theta, i)}{dt} = u - Ri \quad (1)$$

式中: u —相绕组电压;

R —相绕组电阻;

i —相绕组电流;

ψ —相绕组磁链。

根据式(1), 可得磁链表达式为

$$\psi(\theta, i) = \int_0^t [u(t) - Ri(t)] dt + \psi(0) \Big|_{\theta=\text{const}} \quad (2)$$

式中: $\psi(0)$ —磁链初始值, 由于 SRM 无永磁体, 所以视为 $\psi(0)=0$ 。

对式(2)离散化可得:

$$\psi(n) = \sum_{k=1}^n [u(k) - Ri(k)] T + \psi(0) \Big|_{\theta=\text{const}} \quad (3)$$

式中: n —采样点个数;

T —采样周期。

根据式(3)可知, 在转子位置固定后测量其相应的电流值、电压值即可获得相应的磁链特性。本文选用的样机为三相 12/8 极 SRM, 额定功率为 1.5 kW。所选用 SRM 磁链变化周期为 45°, 将定、转子凸极完全对齐位置定义为起始位置 0°, 定子凸极与转子凹槽中心对齐位置为 22.5°。由于 SRM 电磁特性关于 22.5° 位置左右对称, 即测量半个周期电磁特性即可。

采用直流脉冲法^[17]获取电机磁链特性, 其基本原理为先通过锁紧装置将电机转子固定, 然后通过直流脉冲电压激励定子绕组, 同时记录电流上升过程中相绕组电压与电流值, 将采集到的电压与电流值代入式(3)可得该位置下的磁链特性。通过试验测量得到 SRM 样机在半个周期内的磁链曲线, 如图 1(a)所示。

与磁链特性测量不同, 转矩特性的测量采用稳态电流法, 不再对上升阶段电流和转矩进行采样, 而是记录电流稳定后的稳态电流值和转矩值。在完成半个周期的转矩特性检测后, 通过对称性获得 SRM 完整周期的转矩特性, 如图 1(b)所示。

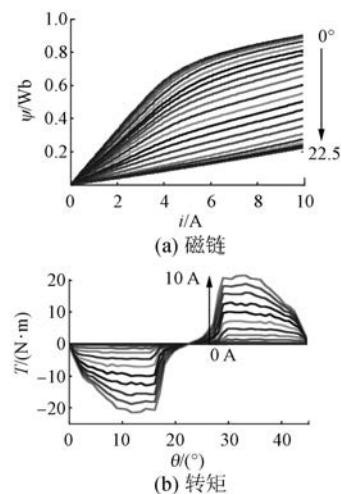


图 1 测量的磁链和转矩特性

1.2 预处理函数

本文采用 Le-Huy 等^[18]提出的 SRM 非线性

模型来作为 BP 神经网络的预处理函数, 实现对样本数据的预处理。磁链曲线表达式如下:

$$\psi(i, \theta) = L_q i + [L_{dsat} i + A(1 - e^{-Bi}) - L_q i] f(\theta) \quad (4)$$

式中: L_q ——定子凸极与转子凹槽中心重合对应的饱和电感;

L_{dsat} ——定、转子凸极中心完全对齐位置饱和电感;

A, B ——拟合系数;

$f(\theta)$ ——位置角函数。

$A, B, f(\theta)$ 表达式分别为

$$A = \psi_m - L_{dsat} I_m \quad (5)$$

$$B = \frac{L_d - L_{dsat}}{\psi_m - L_{dsat} I_m} \quad (6)$$

$$f(\theta) = \frac{2N_r^3\theta^3}{\pi^3} - \frac{3N_r^2\theta^2}{\pi^2} + 1, \quad \theta \in \left[0, \frac{\pi^2}{180N_r}\right] \quad (7)$$

式中: N_r ——转子极数;

L_d ——定、转子凸极中心完全对齐位置的未饱和电感;

ψ_m ——最大磁链值;

I_m ——最大磁链下的电流值。

根据虚位移原理^[19], 任一运行点 x 处的瞬时电磁转矩为

$$T(i, \theta) = -\frac{\partial W(i, \theta)}{\partial \theta} \Big|_{\psi = \text{const}} \quad (8)$$

式中: W ——绕组磁共能。

$$W(i, \theta) = \int_0^i \psi(i, \theta) di \quad (9)$$

将式(4)代入式(9), 由式(8)可得电磁转矩表达式:

$$T(i, \theta) = \left[\frac{(L_{dsat} - L_q)i^2}{2} + Ai - \frac{A(1 - e^{-Bi})}{B} \right] f'(\theta) \quad (10)$$

其中:

$$f'(\theta) = \frac{6N_r^3}{\pi^3}\theta^2 - \frac{6N_r^2}{\pi^2}\theta, \quad \theta \in \left[0, \frac{\pi^2}{180N_r}\right] \quad (11)$$

2 基于预处理的 BP 神经网络建模

BP 神经网络是一种按照误差逆向传播算法训练的多层前馈网络。其结构包括输入层、隐含

层、输出层, 是目前应用最广泛的神经网络模型之一。本节将介绍 BP 神经网络并引入第 1 节的预处理函数对网络进行优化, 在此基础上完成对 SRM 电磁特性的建模。

传统 BP 神经网络的基本结构如图 2 所示。从图 2 中可以看到, BP 神经网络输入层节点为 x_j , 隐含层节点为 y_k , 输出层节点为 z_l 。其中输入层与隐含层节点间权值为 w_{jk} , 隐含层与输出层节点间权值为 w_{kl} , θ_k 为阈值, 输出节点的期望输出 T_l 。

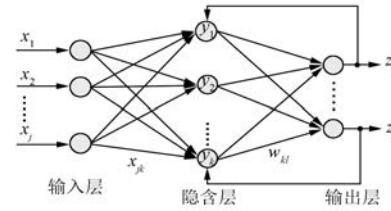


图 2 BP 神经网络结构示意图

网络隐含层节点输出为

$$y_k = f(\sum_j w_{jk} x_j - \theta_k) \quad (12)$$

输出层节点输出为

$$z_l = f(\sum_k w_{kl} y_k - \theta_k) \quad (13)$$

输出节点误差为

$$e = \frac{1}{2} \sum_l (T_l - z_l) \quad (14)$$

采用 LM 算法^[20]对 BP 神经网络权值和阈值进行更新。设 w 表示权值和阈值所组成的向量, 可以得到 BP 神经网络权值和阈值的更新公式如下:

$$\mathbf{w}_{(t+1)} = \mathbf{w}_{(t)} + [\mathbf{J}^T(w) \mathbf{J}(w) + \mu \mathbf{I}]^{-1} \mathbf{J}^T(w) \mathbf{e}(w) \quad (15)$$

式中: μ ——学习速率;

\mathbf{I} ——单位矩阵;

\mathbf{e} ——网络误差向量;

$\mathbf{J}(w)$ ——雅克比矩阵^[21]。

$$\mathbf{J}(w) = \begin{bmatrix} \frac{\partial e_1(w)}{\partial w_1} & \frac{\partial e_1(w)}{\partial w_2} & \dots & \frac{\partial e_1(w)}{\partial w_k} \\ \frac{\partial e_2(w)}{\partial w_1} & \frac{\partial e_2(w)}{\partial w_2} & \dots & \frac{\partial e_2(w)}{\partial w_k} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial e_l(w)}{\partial w_1} & \frac{\partial e_l(w)}{\partial w_2} & \dots & \frac{\partial e_l(w)}{\partial w_k} \end{bmatrix} \quad (16)$$

采用 2 个单隐层 BP 神经网络分别建立 SRM 磁链与转矩模型, 如图 3 所示。图 3(a)中, 网络的输入为电流和位置, 输出为磁链; 图 3(b)中, 网络的输入为电流和位置, 输出为转矩。

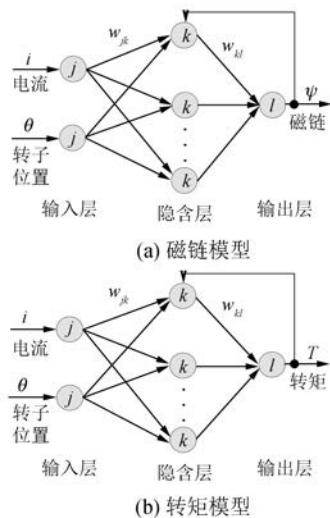


图 3 基于 BP 网络的磁链和转矩模型

在此基础上分别建立 SRM 磁链与转矩预处理模型, 如图 4 所示。图 4(a)中, 网络的输入为电流、位置和磁链预处理函数, 输出为磁链; 图 4(b)中, 网络的输入为电流、位置和转矩预处理函数, 输出为转矩。

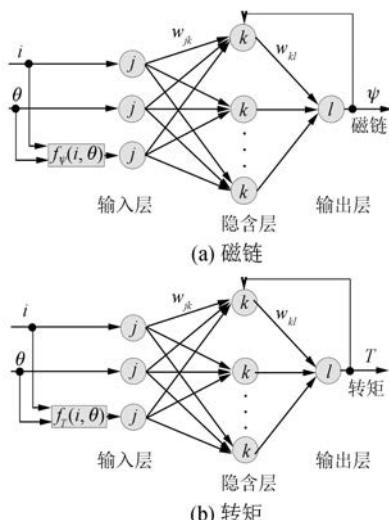


图 4 磁链和转矩预处理模型

将由样机测得的磁链和转矩数据作为样本对神经网络进行训练。由于数据过于庞大, 增加训练时间的同时也使得预处理效果不明显,

因此选取位置角为 $0^\circ \sim 22.5^\circ$ 的数据作为网络训练样本。在磁链数据 $0 \sim 10$ A 电流值中选取 21 个电流值, 间隔为 0.5 A, $0^\circ \sim 22.5^\circ$ 的位置角中选取 6 个位置角, 间隔为 4.5° 作为磁链模型训练样本。转矩数据中取 21 个电流值, 间隔为 0.5 A, 选取 16 个位置角间隔为 1.5° 作为转矩模型训练样本。

神经网络选用三层网络, 隐含层传递函数为 tansig, 输出层传递函数为 pureline, 采用梯度下降学习函数, 学习速率设为 0.001 来训练出不加预处理的 BP 网络, 输入为 i, θ , 输出为磁链 ψ 或转矩 T 。在网络基础上分别加入预处理函数式(4)和式(10)作为网络第三个输入并分别训练, 比较不同节点预处理函数对网络的优化作用。将所有数据作为网络输入获得全部数据的网络输出, 比较在相同节点下加入预处理后网络的泛化能力。

3 建模结果分析

为了验证本文预处理函数对 BP 网络的优化性能, 通过 MATLAB 对本次设计进行仿真。

针对电机磁链模型和转矩模型, 依次训练一组未加预处理的 10 节点和 6 节点网络, 再训练一组加预处理的 7 节点和 4 节点网络。分别比较未加预处理的 10 节点网络和加预处理的 7 节点网络输出、未加预处理的 6 节点网络和加预处理的 4 节点网络输出, 确定预处理函数对网络的优化效果。为了比较网络泛化能力, 针对磁链模型分别建立未加预处理的 6 节点网络与加预处理的 6 节点网络作为对比; 对于转矩模型分别建立未加预处理的 10 节点网络与加预处理的 10 节点网络作为对比。

3.1 磁链建模结果

在目标精度设置为 0.000 05 的条件下训练未加预处理的 10 节点网络, 其线性回归系数为 0.999 94, 如图 5(a)所示, 网络输出与期望的均方误差 (MSE) 为 9.042×10^{-6} , 最大磁链误差为 0.011 701 Wb, 如图 6(a)所示; 训练加预处理的 7 节点网络, 其线性回归系数为 0.999 95, 如图 5(b)所示, 网络输出与期望的 MSE 为 7.420×10^{-6} , 最大磁链误差为 0.009 979 7 Wb, 如图 6(b)所示。

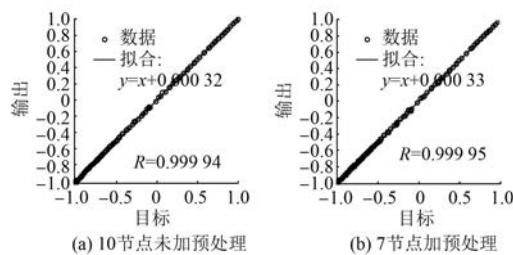


图 5 基于 10 节点和 7 节点网络的磁链线性回归系数

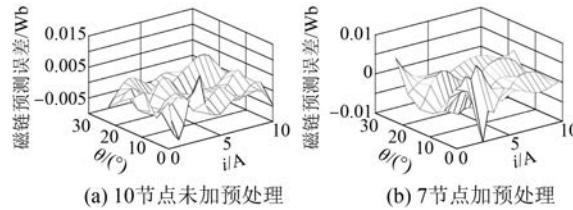


图 6 基于 10 节点和 7 节点网络的磁链预测误差

在目标精度设置为 0.000 1 的条件下训练未加预处理的 6 节点网络, 其线性回归系数为 0.999 85, 如图 7(a)所示, 网络输出与期望的 MSE 为 $2.467 6 \times 10^{-5}$, 最大磁链误差为 0.013 563 Wb, 如图 8 (a)所示; 训练加预处理的 4 节点网络, 其线性回归系数为 0.999 89, 如图 7(b)所示, 网络输出与期望的 MSE 为 $1.647 0 \times 10^{-5}$, 最大磁链误差为 0.009 504 7 Wb, 如图 8(b)所示。

未加预处理与加预处理的 SRM 磁链模型训练结果如表 1 所示。

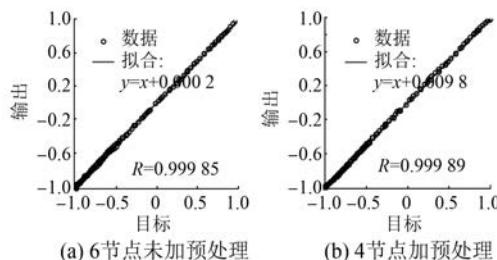


图 7 基于 6 节点和 4 节点网络的磁链线性回归系数

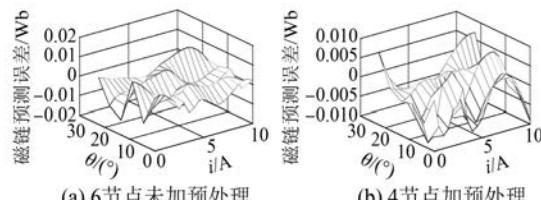


图 8 基于 6 节点和 4 节点网络的磁链预测误差

表 1 BP 神经网络磁链模型训练结果

目标精度	网络类型	网络节点	MSE	回归系数
0.000 05	未加预处理	10	$9.042 2 \times 10^{-6}$	0.999 94
	加预处理	7	$7.420 9 \times 10^{-6}$	0.999 95
0.000 10	未加预处理	6	$2.467 6 \times 10^{-5}$	0.999 85
	加预处理	4	$1.647 0 \times 10^{-5}$	0.999 89

为了观察神经网络的泛化能力, 分别训练出均为 6 节点的加入预处理与未加入预处理的神经网络对磁链建模, 目标精度设置为 0.000 1。将全部数据代入 2 个网络, 比较网络输出与实际磁链数据, 其中加预处理的网络输出结果如图 9(a)所示, 未加预处理的网络输出结果如图 9(b)所示。

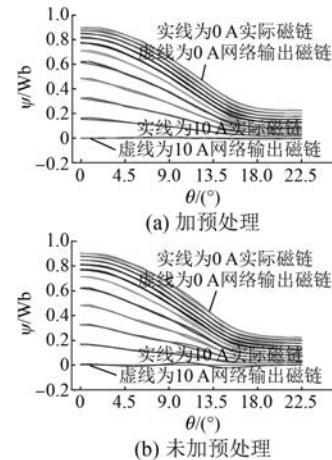


图 9 6 节点磁链神经网络的泛化能力

3.2 转矩建模结果

由于转矩模型较为复杂, 所以适当降低训练的目标精度。在目标精度为 0.000 5 的条件下训练未加预处理的 10 节点网络, 其线性回归系数为 0.999 1, 如图 10(a)所示, 网络输出与期望的 MSE 为 0.061 5, 最大转矩误差为 0.861 31 N·m, 如图 11(a)所示; 训练加预处理的 7 节点网络, 其线

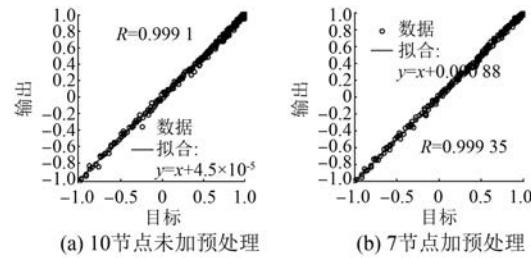


图 10 基于 10 节点和 7 节点网络的转矩线性回归系数

性回归系数为 0.999 35, 如图 10(b) 所示, 网络输出与期望的 MSE 为 0.043 3, 最大转矩误差为 0.784 89 N·m, 如图 11(b) 所示。

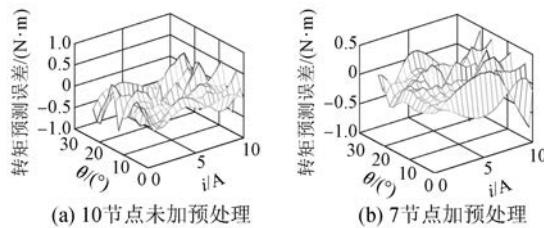


图 11 基于 10 节点和 7 节点网络的转矩预测误差

在目标精度设置为 0.005 的条件下训练未加预处理的 6 节点网络, 其线性回归系数为 0.991 66, 如图 12(a) 所示, 网络输出与期望的 MSE 为 0.557 4, 最大转矩误差为 2.454 7 N·m, 如图 13(a) 所示; 在加预处理的情况下训练 4 节点网络, 其线性回归系数为 0.993 36, 如图 12(b) 所示, 网络输出与期望的 MSE 为 0.454 5, 最大转矩误差为 2.179 8 N·m, 如图 13(b) 所示。

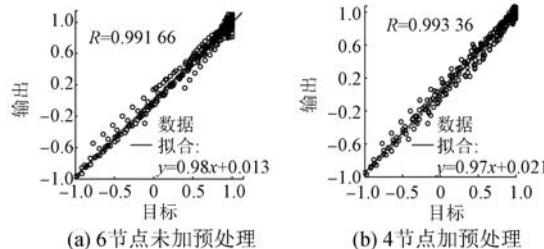


图 12 基于 6 节点和 4 节点网络的转矩线性回归系数

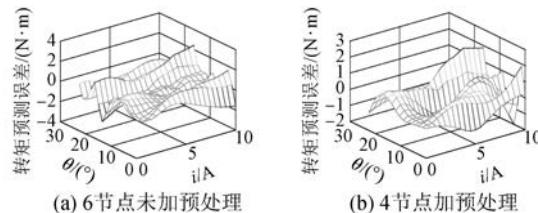


图 13 基于 6 节点和 4 节点网络的转矩预测误差

未加预处理与加预处理的 SRM 转矩模型的神经网络训练结果如表 2 所示。

对于转矩分别训练出均为 10 节点的加入预处理与未加入预处理的神经网络, 目标精度为 0.000 5。分别将全部数据代入两个网络比较网络输出与实际转矩, 其中加预处理的网络输出结果

表 2 BP 神经网络转矩模型训练结果

目标精度	网络类型	网络节点	MSE	回归系数
0.000 5	未加预处理	10	0.061 5	0.999 10
	加预处理	7	0.043 3	0.999 35
0.005 0	未加预处理	6	0.557 4	0.991 66
	加预处理	4	0.454 5	0.993 36

如图 14(a) 所示, 未加预处理的网络输出结果如图 14(b) 所示。

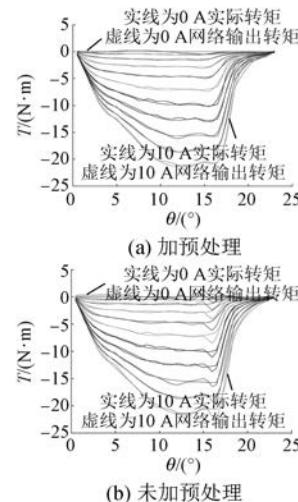


图 14 10 节点转矩神经网络的泛化能力

由表 1 和表 2 的训练结果可以看出, 加入预处理函数后的神经网络在减少节点情况下拟合度更好, 均方误差较小, 可以达到更好的精度。此外, 由图 9 和图 14 可知, 在相同节点情况下, 加入预处理的网络具有较强的泛化能力。

4 结语

针对 SRM 磁链和转矩模型的高度非线性, 充分利用电机先验知识, 在传统 BP 神经网络对 SRM 磁链和转矩建模的基础上加入预处理函数对网络加以改进。通过 MATLAB 仿真验证, 加入预处理后的神经网络训练出的模型在减少网络节点的条件下, 具有更高的精度; 与传统的 BP 网络相比具有更强的泛化能力, 降低了网络复杂性。加入预处理的 BP 神经网络在小规模网络中具有更为明显的优越性, 更适合用于实时控制。

【参考文献】

- [1] 李俊卿, 李和明. 开关磁阻电机发展综述 [J]. 华北

- 电力大学学报,2002,29(1): 1.
- [2] 林显军,程小华.开关磁阻风力发电技术[J].电机与控制应用,2011,38(9): 46.
- [3] 陈飞,瞿遂春,邱爱兵,等.电动车用开关磁阻电机设计与优化方法[J].电机与控制应用,2017,44(10): 114.
- [4] HUSAIN I, HOSSAIN S A. Modeling, simulation, and control of switched reluctance motor drives [J]. IEEE Transactions on Industrial Electronics, 2005, 52(6): 1625.
- [5] 丁文,梁得亮.12/8 极双通道开关磁阻电机非线性数学模型与有限元分析[J].电机与控制学报,2009,13(2): 190.
- [6] 孙玉坤,吴建兵,项倩雯.基于有限元法的磁悬浮开关磁阻电机数学模型[J].中国电机工程学报,2007,27(12): 33.
- [7] 吴建华.基于物理模型开关磁阻电机定子模态和固有频率的研究[J].中国电机工程学报,2004,24(8): 109.
- [8] 高宇,戴跃洪,宋林.基于 BP 神经网络的开关磁阻电机建模[J].电力电子技术,2017,51(2): 72.
- [9] 杨先有,易灵芝,段斌,等.开关磁阻电机调速系统 BP 神经网络建模[J].电机与控制学报,2008,12(4): 447.
- [10] CAI J, DENG Z Q, QI R Y, et al. A novel BVC-RBF neural network based system simulation model for switched reluctance motor [J]. IEEE Transactions on Magnetics, 2011, 47(4): 830.
- [11] 司利云,林辉.基于支持向量机的开关磁阻电机转子位置在线建模[J].电机与控制学报,2014,18(4): 72.
- [12] AHMAD S S, NARAYANAN G. Linearized modeling of switched reluctance motor for closed-loop current control [J]. IEEE Transactions on Industry Applications, 2016, 52(4): 3146.
- [13] ZHANG P M, MA Q S, YE W, et al. A modeling method of nonlinear flux linkage for switched reluctance motors using a Gaussian function [C] // 2018 13th IEEE Conference on Industrial Electronics and Applications (ICIEA), 2018: 1410.
- [14] 刘闯,严利,严加根,等.开关磁阻电机非线性磁参数建模方法[J].南京航空航天大学学报,2007,39(6): 706.
- [15] CAI W, PILLAY P, TANG Z. Impact of stator windings and end-bells on resonant frequencies and mode shapes of switched reluctance motors [J]. IEEE Transactions on Industry Applications, 2002, 38(4): 1027.
- [16] CAI Y, GAO C. Nonlinear modeling of switched reluctance motor based on BP neural network [C] // International Conference on Natural Computation, IEEE Computer Society, 2007: 232.
- [17] GOBBI R, SAHOO N C, VEJIAN R. Experimental investigations on computer-based methods for determination of static electromagnetic characteristics of switched reluctance motors [J]. IEEE Transactions on Instrumentation and Measurement, 2008, 57(10): 2196.
- [18] LE-HUY H, BRUNELLE P. A versatile nonlinear switched reluctance motor model in Simulink using realistic and analytical magnetization characteristics [C] // Conference of IEEE Industrial Electronics Society, 2005: 1156.
- [19] 王宏华.开关磁阻电动机调速控制技术[M].北京:机械工业出版社,2014.
- [20] 闻新,李新,张兴旺.应用 MATLAB 实现神经网络[M].北京:国防工业出版社,2015.
- [21] LÜ C, XING Y, ZHANG J, et al. Levenberg-Marquardt backpropagation training of multilayer neural networks for state estimation of a safety critical cyber-physical system [J]. IEEE Transactions on Industrial Informatics, 2017, 14(8): 3436.

收稿日期: 2018-09-18