

采用少量样本的开关磁阻电机磁链 SVM 建模与分析

谢勇军, 赵世伟, 程小华

(华南理工大学电力学院, 广东 广州 510640)

摘要: 开关磁阻电机(SRM)中磁链 ψ 是转子位置 θ 和绕组电流 i 的二元非线性函数,常基于 ψ - θ - i 关系数据建立磁链的数值模型,但 ψ - θ - i 关系数据测量成本高。本文基于支持向量机(SVM)算法从少量 ψ - θ - i 关系数据中建立开关磁阻电机的磁链模型。通过改变训练集均匀采样的步长,发现若电角度采样步长超过 14° ,模型预测误差约增加50%;电流较小时,模型预测误差随着采样步长的增大先迅速增加后在某一值附近震荡。训练集确定后,采用原始的 ψ - θ - i 数据训练SVM所得磁链模型,在磁链值较小的区域,预测值的相对误差最大值超过200%。针对误差产生的原因,本文提出一种非线性映射,用于处理训练样本。采用预处理后的样本训练SVM所得模型,在磁链值较小区域预测值的相对误差小于3.5%。为进一步提高最终模型的精度,本文将由原始数据训练所得模型和由映射后数据训练所得模型集成得到最终模型。本文的方案削弱了训练样本的减少对磁链模型精度的影响,使磁链模型预测的相对误差明显减小。

关键词: 开关磁阻电机; 磁链模型; 支持向量机; 少量磁链数据; 非线性映射

DOI: 10.12067/ATEEE1911018 **文章编号:** 1003-3076(2020)08-0010-08 **中图分类号:** TM352

1 引言

开关磁阻电机(Switched Reluctance Motor, SRM)具有结构简单、成本低、调速范围大、可靠性高等优点,被广泛应用于电动汽车、家用电器、航空工业等领域^[1-3]。SRM性能检验和控制都需要建立其数学模型^[4-7]。SRM数学模型主要包括磁链模型和转矩模型。双凸结构和磁饱和效应,使SRM的磁链是电流和角度的二元非线性函数,磁链模型获取难度大。SRM磁链建模方法一般分为等效磁路法^[8]和通过 ψ - θ - i 关系数据建模法。获得 ψ - θ - i 关系数据的方法包括实验法和有限元仿真法^[9]。通过实验数据建立SRM数学模型具有精度高等优点,是最常用的建立SRM数学模型的方法^[10-15]。但实验法获得数据,需要多次重复实验,时间成本较高,因此基于少量样本的SRM建模方法具有实际意义。

学者们对少量样本情况下SRM的建模方法进行了深入的研究。一般可以分为基于先验知识的少样本建模和基于支持向量机(Support Vector Ma-

chine, SVM)的少样本建模。基于先验知识的少样本建模,通过观察 ψ - θ - i 数据分布的特点,采用特定函数或函数组合进行拟合。此类建模方法主要包括分段拟合和非线性函数拟合法。采用文献[3]提出准线性模型,确定每个位置的磁化曲线需要两个样本。文献[16]使用线性函数和非线性函数分段拟合 ψ - θ 曲线,建立磁链模型需要4个固定位置下的磁化曲线。文献[17]将使用傅里叶级数的前三项拟合磁链模型,确定一个位置下的 ψ - i 关系需要3个样本。文献[18]采用指数函数来构建磁链曲线的新型数学模型,确定一个位置的 ψ - i 需要9个样本。

基于先验知识的少样本建模法的优点是能够得到磁链的解析表达式,计算速度快,但是精度依赖于所选函数的类型^[19-21]。SVM的基本思想是正确划分样本,并使几何间隔最大,通过引入核函数SVM具有非线性映射能力^[22]。SVM中超平面是由支持向量决定而与其他样本无关,因此SVM在小训练样本场合具有较好的映射能力^[23]。

许多学者对于 SVM 应用于 SRM 的建模进行了深入的研究。文献[24]为解决 SVM 中参数选择问题,提出一种基于粒子群算法和 SVM 的 SRM 的建模方法;文献[25,26]通过修改核函数提高 SVM 的泛化能力,从而得到更高精度的 SRM 模型。文献[27]一种快速磁链测量的基础上,以少量数据作为训练数据,应用 SVM 作数据重构,在重构数据的基础上采用人工神经网络(Artificial Neural Network, ANN)建立 SRM 的模型。该方法基于的数量较少,使用 ANN 与 SVM 组成串联的形式会造成误差被放大,模型对参数的敏感度增加。

对于 SVM 算法在 SRM 磁链建模中的应用,目前的研究方向主要集中于核函数的选择和超参数的确定,但小样本情况下模型与训练数据的关系却鲜见报道。本文通过均匀采样训练样本的方式,分析了模型精度与不同区域训练数据的关系,针对不同区域训练数据对 SVR 算法代价函数的贡献,提出了一种非线性映射和模型融合相结合的方法进一步提高了模型的精度。

2 SRM 的磁链特性和 SVM

2.1 SRM 的磁链特性

开关磁阻电机一相的电动势平衡方程如式(1)所示:

$$u = Ri + \frac{d\psi}{dt} \quad (1)$$

式中, u 为绕组端电压; R 为绕组等效电阻; i 为绕组相电流; ψ 为绕组磁链; t 为时间。

整理式(1)可得磁链表达式:

$$\psi = \int_0^t u - iRdt \quad (2)$$

双凸结构导致 SRM 气隙随转子位置 θ 变化,从而使得 ψ 为 θ 的函数。又因为 i 增加导致的磁饱和不能忽略,所以 ψ 是 θ 和 i 的二元非线性函数。 ψ 与 θ 和 i 的关系称为 SRM 的磁链特性,常采用磁化曲线簇表示。采用有限元仿真得到的开关磁阻电机的磁化特性如图 1 所示。图 1 从下往上依次是机械角度为 $0^\circ, 4^\circ, \dots, 44^\circ$ 和 45° 时 ψ 和 i 的关系曲线。

2.2 支持向量机(SVM)

SVM 包括支持向量分类(Support Vector Classifier, SVC)和支持向量回归(Support Vector Regression, SVR),本文采用的是 SVR。

式(3)为 SVR 算法的假设空间:

$$f(\mathbf{x}) = \boldsymbol{\omega}^T \mathbf{x} + b \quad (3)$$




图 1 开关磁阻电机磁链特性

Fig.1 The character of flux-leakage of SRM

式中, \mathbf{x} 为特征向量; $f(\mathbf{x})$ 为预测值; $\boldsymbol{\omega}$ 为预测超平面系数; b 为偏置。

参数 $\boldsymbol{\omega}$ 与 b 通过求解结构风险在训练集 $D = \{(\mathbf{x}_1, y_1), (\mathbf{x}_2, y_2), \dots, (\mathbf{x}_m, y_m)\}$, $y_i \in \mathbb{R}, \mathbf{x}_i \in \mathbb{R}^n$ 上最小来确定。 \mathbf{x}_i, y_i 分别为第 i 个训练样本的特征向量和标签。

采用函数拟合法建立 SRM 的模型时,损失是预测值 $f(\mathbf{x})$ 与 y 之差的 1 或 2 范数,所以只有 $f(\mathbf{x})$ 与 y 完全一致时,损失为 0。而 SVR 中,若 $f(\mathbf{x})$ 与 y 之间偏差的 1 范数小于 ε ,则损失为 0。因此 SVR 的几何意义为:以超平面 $f(\mathbf{x})$ 为中心,厚度为 2ε 的超平面带拟合训练数据。当 \mathbf{x} 为一维向量时,几何意义如图 2 所示。




图 2 SVR 示意图

Fig.2 Diagram of SVR

SVR 的优化目标为式(4)。

$$\begin{cases} \min_{\boldsymbol{\omega}, b} \frac{1}{2} \|\boldsymbol{\omega}\|^2 + C \sum_{j=1}^m l_{\varepsilon}[f(\mathbf{x}_j) - y_j] \\ l_{\varepsilon}[f(\mathbf{x}_j) - y_j] = \begin{cases} 0 & |f(\mathbf{x}_j) - y_j| \leq \varepsilon \\ |f(\mathbf{x}_j) - y_j| - \varepsilon & \text{其他} \end{cases} \end{cases} \quad (4)$$

式中, C 为平衡正则化项与经验风险的权值; ε 为不敏感度因子; m 为训练样本的数量; y 为实际值; $\|\cdot\|$ 为 2 范数。

引入松弛变量 ξ_i 和 $\hat{\xi}_i$ 后,式(4)可变换为式(5)。式(5)为二次规划(Quadratic Programming,

QP) 问题,可通过传统的 QP 求解方法求解模型参数。由于对偶问题的求解更加方便,SVR 一般采用拉格朗日乘子法并将原始问题转化为对偶问题来求解。对偶问题的求解常采用序列最小最优化 (Sequential Minimal Optimization, SMO) 方法求解。

$$\begin{aligned} \min_{\omega, b, \hat{\xi}_i, \xi_i} \quad & \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^m (\hat{\xi}_i + \xi_i) \\ \text{s.t.} \quad & \begin{cases} f(\mathbf{x}_i) - y_i \leq \varepsilon + \xi_i, \\ y_i - f(\mathbf{x}_i) \leq \varepsilon + \hat{\xi}_i, \\ \xi_i \geq 0 \quad \hat{\xi}_i \geq 0, \quad i = 1, 2, \dots, m \end{cases} \end{aligned} \quad (5)$$

引入核函数后 SVR 能够拟合非线性数据,式 (6) 是加入核函数后的超平面和模型参数。

$$\begin{cases} f(\mathbf{x}) = \sum_{i=1}^m (\alpha_i - \hat{\alpha}_i) k(\mathbf{x}, \mathbf{x}_i) + b \\ b = y_i + \varepsilon - \sum_{j=1}^k (\alpha_i - \hat{\alpha}_i) k(\mathbf{x}, \mathbf{x}_i) \end{cases} \quad (6)$$

式中, $\hat{\alpha}_i$ 和 α_i 为拉格朗日乘子; $k(\mathbf{x}, \mathbf{x}_i)$ 为核函数。

3 基于 SVM 的 SRM 磁链建模

3.1 SVM 超参数和核函数的确定

核函数的选取对模型预测效果起着重要作用,常用的核函数有多项式核函数,高斯核函数,字符串核函数等。从图 1 可得,SRM 转子从非对齐位置到对齐位置, ψ - i 关系由直线逐渐变为曲线。因此本文采用二次多项式核函数和高斯核函数的线性组合作为 SVM 的核函数,如式 (7) 所示。

$$k(\mathbf{x}, \mathbf{z}) = (1 - \lambda) e^{-\gamma \|\mathbf{x} - \mathbf{z}\|^2} + \lambda (\alpha \mathbf{x} - \mathbf{z} + \beta)^2 \quad (7)$$

式中, λ 为平衡高斯核函数和二次多项式核函数的权值; γ 为高斯核函数的系数; β 和 α 为多项式核函数的系数。

超参数对模型预测效果起着决定作用,此模型的超参数包括目标函数中权值 C , 核函数中权值 λ , 系数 γ , β , α 。由于超参数较多,若采用人工调节非常耗时,因此本文采用遗传算法 (Genetic Algorithm, GA) 对参数寻优。GA 算法的适应度由交叉验证的测试误差来决定,测试误差越小适应度越高,本文采用 4 折交叉验证,交叉验证不仅可以提供适应度,还能更好地评价模型降低模型过拟合的可能性。

3.2 训练数据量的确定

训练数据的确定主要分为角度数的确定和电流

数量的确定。由于获得 ψ - θ - i 数据的实验法,多为固定转子一次实验可获得多种电流下的磁链值,在此种实验方法下不同电流下数据的获取难度相对较小,因此本文采用先确定角度数量,再确定电流数量的方式来得到尽可能少的样本数。本文虽采用有限元方法获得数据,仍先确定角度数量再确定电流数量。以 6/4 电机为例进行具体说明:

(1) 建立数据库:在有限元仿真中,分别固定 SRM 角度为 $0^\circ, 3^\circ, 6^\circ, \dots, 45^\circ$,测量在相电流为 1 A, 2 A, $\dots, 20$ A 电流时的 ψ 。由于在训练样本较多时样条插值生成的数据具有较高精度,所以本文在有限元仿真所得的 ψ - θ - i 数据基础上,采用样条插值的方法产生角度为 $0^\circ, 0.5^\circ, 1^\circ, \dots, 45^\circ$, 电流为 0 A, 0.1 A, $\dots, 20$ A 时的数据作为数据库。

(2) 确定角度数量:固定角度 0° 和 45° ,对数据库中剩余角度数均匀采样 (对于无法完全均匀的部分适当微调数值),采样出的数据作为训练集。将数据库中剩余的数据作为测试集,训练所得模型在测试集上的均方误差平方 (MSE) 与角度数量关系如表 1 所示。表 1 中, MSE 随着角度数量的减少而逐渐增大,当角度不同取值数量由 8 变为 7 时, MSE 约增加 4 倍。

表 1 不同角度数量下预测误差

Tab.1 MSE in different number of angles

角度数量	MSE	角度数量	MSE
12	6.481 2e-08	9	7.742 06e-08
11	6.610 33e-08	8	9.121 11e-08
10	7.387 22e-08	7	4.094 23e-07

进一步将角度数为 8 和 7 的两个模型的预测结果和误差可视化得到图 3 和图 4。图 3 虽然存在一定的预测误差,但是整体上能够较好地代表磁链模型。图 4 中,在角度较大的区域预测结果较好,但在角度小于 $0^\circ \sim 15^\circ$ 区域 (图 4 中椭圆区域的放大图) 预测值完全偏离实际值,导致预测误差大。若继续减少角度数,预测结果中将出现部分角度下的磁化曲线跑到 0° 磁化曲线的下方,误差也迅速增大。由文献 [5] 可得在角度较小的区域 ψ - θ 的关系曲线较为复杂,因此当角度数小于 8 时,可能已经无法通过数据重构 ψ - θ - i 关系。本文最终选择角度数量为 8。

(3) 确定电流数量:将步骤 (2) 所采样的数据,固定电流 0 A 和 20 A,对电流值 0.1 A, 0.2 A, $\dots, 19.9$ A 均匀采样。采样步长由 0.1 A 逐渐增加至




图3 训练数据中角度数量为8模型预测效果与误差

Fig.3 Predictive result and error trained with 8 kinds of angle data

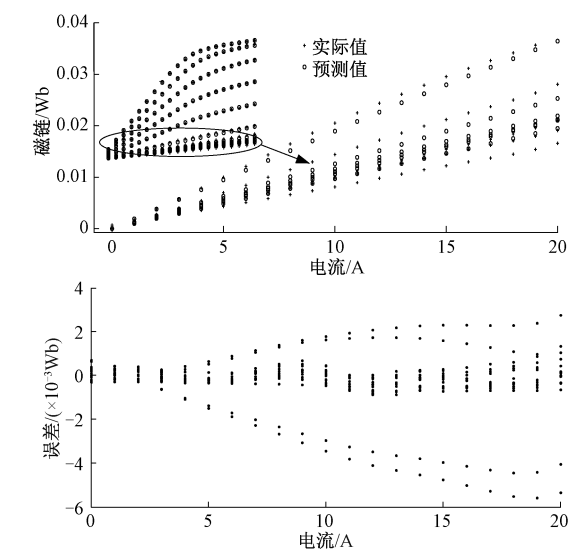


图4 训练数据中角度数量为7模型预测效果与误差

Fig.4 Predictive result and error trained with 7 kinds of angles data

3 A,不同步长的数据训练得到不同的模型。因此得到在某一电流下,电流均匀采样的步长和误差的关系曲线如图5所示。图5中当电流小于2 A时,误差先随着步长的增加而迅速增加,然后在某一值附近震荡。电流大于2 A时,随着电流的增大,误差一直在某一值附近震荡,即采样步长增加对误差影响较小。综上可得在电流较小的区域,电流采样步长应较小,而电流较大的区域可以选择较大的采样步长。本文以电流1.5 A为分界线,采用分段均匀采样的方式进行电流采样。最终选择电流数量为11。




图5 电流采样步长与预测误差的关系

Fig.5 Relationship of current-sample step and error

最终训练集的特征为8种角度和11种电流,标签为对应的磁链值,具体数据如表2所示。电流为0时,磁链值恒为0,所以每一种角度下,只需测量10种电流对应的磁链值。

4 误差分析与改进

4.1 误差分析

使用表2中数据建立SRM的磁链模型,其预测值的相对误差分布如图6所示。图6中,电流较小时,绝对误差小,最大绝对误差为0.000 25 Wb,相对误差大,最大相对误差超过200%;电流大角度小时,相对误差较大,值均大于5%;电流和角度均较大时,相对误差小,值基本小于1%。




图6 SVM模型预测相对误差分布图

Fig.6 Relative error obtained by SVM model

造成上述现象的可能原因包括:

(1) SVM 参数选择不合适。

SVM 中参数除了不敏感因子 ε ,其余参数均由GA算法寻优得到。改变迭代次数重复实验,发现参数和预测误差基本不变。改变初始值并增大参数搜索范围重复试验,发现参数基本收敛于相同值。

表 2 训练样本
Tab.2 Samples for training

电流/A	角度/(°)							
	0	6	13	19	26	32	39	45
0	0	0	0	0	0	0	0	0
0.5	0.000 49	0.000 55	0.000 71	0.001 56	0.002 6	0.003 49	0.004 49	0.005 31
1	0.000 97	0.001 11	0.001 42	0.003 11	0.005 21	0.006 97	0.008 99	0.010 62
1.5	0.001 46	0.001 66	0.002 13	0.004 67	0.007 81	0.010 46	0.013 48	0.015 93
4	0.003 88	0.004 44	0.005 69	0.012 44	0.020 84	0.027 9	0.036 05	0.042 75
7	0.006 8	0.007 76	0.009 96	0.021 79	0.036 53	0.049 1	0.063 56	0.075 19
10	0.009 71	0.011 08	0.014 22	0.031 06	0.052 21	0.070 07	0.090 2	0.104 74
13	0.012 63	0.014 27	0.018 48	0.039 28	0.065 25	0.087 18	0.110 53	0.121 22
16	0.015 54	0.017 27	0.022 72	0.045 8	0.074 02	0.097 81	0.120 34	0.127 67
19	0.018 46	0.020 2	0.026 96	0.051 39	0.080 48	0.104 91	0.125 84	0.131 8
20	0.019 43	0.021 17	0.028 37	0.053 17	0.082 42	0.106 94	0.127 24	0.133 06

因此以交叉验证的测试误差作为 GA 的适应度条件下,除 ε 以外的超参数已经接近最优。

对于不敏感度因子 ε ,减少不敏感因子会使不敏感带厚度变薄,支持向量数目增多。模型的训练误差减小,但模型容易过拟合。逐渐减小不敏感因子重复实验,发现预测误差先略微下降,然后逐渐增大。因此 ε 参数已接近最优。综上 SVM 超参数不是造成误差分布情况的原因。

(2) SVM 中代价函数与所研究问题无法很好匹配。

若忽略式(4)中结构风险部分,代价函数与预测值的绝对误差以及样本数量成正相关关系。3.2 节介绍的样本采样方式,会使得电流较小区域的样本数大于其他区域,但仍为同一数量级。对于磁链值相差大的两个样本,若相对误差相同,则磁链值小的样本对代价函数的贡献很小。SVM 用于求解代价函数的 SMO 算法是一种启发式的算法,模型参数更新是由代价函数中的主要成分所主导的。综上,在样本分布基本均匀且数量较少,代价函数的求解采用 SMO 算法的情况下,采用式(4)作为代价函数将会造成模型在磁链较小区域预测值的相对误差大。

4.2 实现误差减小

从 4.1 节分析可得造成模型预测相对误差呈现图 6 的现象的原因是代价函数与所研究问题不匹配。因此降低磁链值较小区域的相对误差的思路为修改或者等效修改代价函数使得相对误差较大的样本点在代价函数中的比重增加。具体实现方法包括如下方法:

(1) 增大权值 C 。随着权值 C 的增大,模型的训练更加注重经验风险的最小化,但是模型可能过拟合。而且增大 C 以后,样本值相差较大的样本对代价函数的贡献差距会进一步扩大,与最初的目的相悖。

(2) 修改代价函数中误差的 L1 范数为相对误差。若将代价函数修改为式(8),样本对代价函数的贡献将与磁链值的大小无关,磁链值较小的样本预测的相对误差将减小。但式(8)可能非凸,导致优化难度增加,在训练的初期由于模型精度低则 loss 值很大,容易造成优化不收敛。而且本文是基于 libsvm 软件包实现的,源代码的修改容易出错。

$$\begin{cases} \min_{\omega,b} = \frac{1}{2} \|\omega\|^2 + C \sum_{j=1}^m \frac{l_{\varepsilon}(f(\mathbf{x}_j) - y_j)}{y_j} \\ l_{\varepsilon}(z) = \begin{cases} 0 & |z| \leq \varepsilon \\ |z| - \varepsilon & \text{其他} \end{cases} \end{cases} \quad (8)$$

(3) 对训练样本的磁链值进行非线性映射。本文提出一种对磁链值先进行映射的方法,来提高磁链值小的样本对代价函数的贡献。映射过程主要包括如下两部分:

第一部分:归一化。采用式(9)将训练样本中的磁链 ψ 归算至 $[-1,1]$ 。

$$\psi' = \frac{2\psi - (\psi_{\max} - \psi_{\min})}{\psi_{\max} - \psi_{\min}} \quad (9)$$

式中, ψ' 为归一化后的磁链值; ψ_{\max}, ψ_{\min} 分别为训练集中磁链的最大值和最小值。

第二部分:使用负指数函数进行磁链值映射。本文采用的映射函数为:

$$\psi'' = e^{3.5 - 1.5\psi'} \quad (10)$$

式中, ψ'' 为映射后的磁链。

磁链值经过上述映射后原本磁链值小的样本磁链值将会增大,且此时映射后的磁链值最大值只约为最小值的 20 倍,能够有效地避免模型主要是通过一些数值较大的样本训练得出。采用非线性的样本数据训练模型,在预测时需要将预测值重新转换为实际值。得到预测相对误差如图 7 所示。




图 7 映射数据训练所得模型预测相对误差分布图

Fig.7 Relative error obtained by model trained by dataset with nonlinear mapping

图 7 中,相比于使用原始数据训练所得 SVM 模型,在磁链值较小的区域的相对误差明显减小,其值均小于 3.5%。表明上述映射在保证优化问题的凸性的同时,能够有效地降低模型在磁链较小区域的相对误差。

但是图 7 中磁链值较大的区域磁链相对误差增加,峰值超过了 10%。对于此现象可以通过借鉴集成学习的思想,保留使用原始数据得到的 SVM 模型在磁链值较大处预测更准的特点。集成学习是通过一些制造差异的手段,得到多个弱学习器,并使用一定的融合方式得到最终模型。本文通过式(11)融合原始数据训练所得模型和映射后数据训练所得模型,得到最终模型。

$$\begin{cases} \psi = c_1\psi_1 + (1 - c_1)\psi_3 \\ \psi_3 = c_2\psi_1 + (1 - c_2)\psi_2 \\ c_1 = \frac{1}{1 + e^{a_1(\theta' - b_1)}} \\ c_2 = \frac{1}{1 + e^{a_2(i' - b_2)}} \end{cases} \quad (11)$$

式中, ψ 为磁链最终预测值; c_1, c_2 分别为随角度和电流变化的权值; ψ_1, ψ_2 分别为使用映射后数据和原始数据作为训练数据所得模型的磁链预测值; ψ_3 为中间变量; θ' 为角度归一化的值; i' 为电流归一化后的值; a_i, b_i 为待确定常数。权值 c_i 是 S 型函数,参数 a_i 用来调节变化速度, b_i 代表两个权重相等的位置。本文分别选取 a_1, a_2, b_1, b_2 分别为

14.08, 12.2, 0.267, -0.48。最终所得模型的预测效果如图 8 和图 9 所示。所有角度和电流下相对误差都小于 3.5%, MSE 为 $6.13e-8$, 误差明显减小。




图 8 相对误差与误差分布图

Fig.8 Relative error and error obtained by final model




图 9 最终磁链模型效果图

Fig.9 Flux-linkage characteristics obtained by final model

5 结论

基于 SVM 算法,本文对小样本的 SRM 磁链建模问题进行了分析。均匀采样方式下,样本的减少将会使标准的 SVM 模型在磁链较小区域的预测误差明显增大。虽然采用电流分段均匀的方式采样可以一定程度上缓解误差的增大,但是由于 SVR 的代价函数包括正则化项和误差的 L1 范数,从而样本对代价的贡献与磁链值正相关,容易造成模型在磁链值较小区域的相对误差较大的现象。针对该问题,本文提出了磁链数据负指数映射和 S 函数权值融合相结合的方法,有效地降低了 SRM 磁链模型的相对误差。仿真结果表明,对原始磁链数据进行负指数映射可以明显降低预测模型在原数据小的区域的相对误差,采用 S 函数权值融合两个模型能进一步提高磁链的整体的预测精度。

参考文献 (References):

[1] 葛乐飞 (Ge Lefei) 基于小样本磁链特性的开关磁阻

- 电机位置预估方法研究 (Research on the position estimation of SRM based on few flux-linkage characteristic data) [D]. 西安: 西北工业大学 (Xi'an; Northwestern Polytechnical University), 2016.
- [2] Xue X D, Cheng K W E, Ng T W', et al. Multi-objective optimization design of in-wheel switched reluctance motors in electric vehicles [J]. IEEE Transactions on Industrial Electronics, 2010, 57 (9): 2980-2987.
- [3] 吴建华 (Wu Jianhua). 开关磁阻电机设计与应用 (Design and Application of SRM) [M]. 北京: 机械工业出版社 (Beijing: China Machine Press), 2000.
- [4] 杨文浩, 苟斌, 雷渝, 等 (Yang Wenhao, Gou Bin, Lei Yu, et al.). 基于模型预测控制的开关磁阻电机转矩脉动抑制方法研究 (A SRM torque ripple suppression method based on model predictive control) [J/OL]. 电工电能新技术 (Advanced Technology of Electrical Engineering and Energy): 1-11 [2019-11-05]. <http://kns.cnki.net/kcms/detail/1.2283.TM.20190909.0916.002.html>.
- [5] 杨光, 杨明发, 石凯 (Yang Guang, Yang Mingfa, Shi Kai). 基于转矩分配的开关磁阻电机转矩脉动抑制的研究 (Torque ripple minimization for switched reluctance motor based on TSF) [J]. 电工电能新技术 (Advanced Technology of Electrical Engineering and Energy), 2017, 36 (12): 8-14.
- [6] Song S, Zhang M, Ge L. A new fast method for obtaining flux-linkage characteristics of SRM [J]. IEEE Transactions on Industrial Electronics, 2015, 62 (7): 4105-4117.
- [7] Liang X B, Li G J, Ojeda J, et al. Comparative study of classical and mutually coupled switched reluctance motors using multiphysics finite-element modeling [J]. IEEE Transactions on Industrial Electronics, 2014, 61 (9): 5066-5074.
- [8] McCann R, Traore W. Investigation of direct flux measurements in switched reluctance motors [A]. 2008 IEEE Power and Energy Society General Meeting-Conversion and Delivery of Electrical Energy in the 21st Century [C]. Pittsburgh, PA, USA, 2008. 10141733.
- [9] Krishnan R, Materu P. Measurement and instrumentation of a switched reluctance motor [A]. Conference Record of the IEEE Industry Applications Society Annual Meeting [C]. San Diego, CA, USA, 1989. 3613286.
- [10] Song S, Ge L, Ma S, et al. Accurate measurement and detailed evaluation of static electromagnetic characteristics of switched reluctance machines [J]. IEEE Transactions on Instrumentation & Measurement, 2015, 64 (3): 704-714.
- [11] 薛梅, 夏长亮, 王慧敏, 等 (Xue Mei, Xia Changliang, Wang Huimin, et al.). 基于 DSP 的开关磁阻电机磁链特性检测与神经网络建模 (Flux linkage characteristic measurement based on DSP and artificial neural network modeling for switched reluctance motor) [J]. 电工技术学报 (Transactions of China Electrotechnical Society), 2011, 26 (2): 68-73.
- [12] Zhao S W, Cheung N C, Gan W C, et al. A novel flux linkage measurement method for linear switched reluctance motors [J]. IEEE Transactions on Instrumentation and Measurement, 2009, 58 (10): 3569-3575.
- [13] Murthy S S, Singh B, Sharma V K. A frequency response method to estimate inductance profile of switched reluctance motor [A]. Proceedings of Second International Conference on Power Electronics and Drive Systems [C]. Singapore, Singapore, 1997. 5703767.
- [14] Ferrero A, Raciti A. A digital method for the determination of the magnetic characteristic of variable reluctance motors [J]. IEEE Transactions on Instrumentation & Measurement, 1990, 39 (4): 604-608.
- [15] Ferrero A, Raciti A, Urzi C. An indirect test method for the characterization of variable reluctance motors [J]. IEEE Transactions on Instrumentation and Measurement, 1994, 42 (6): 1020-1025.
- [16] Miller T J E, Glinka M, Mcgilp M, et al. Ultra-fast model of the switched reluctance motor [A]. Conference Record of 1998 IEEE Industry Applications Conference. Thirty-Third IAS Annual Meeting [C]. St. Louis, MO, USA, 1998. 6147487.
- [17] Shen L, Wu J, Yang S, et al. Fast flux linkage measurement for switched reluctance motors excluding rotor clamping devices and position sensors [J]. IEEE Transactions on Instrumentation and Measurement, 2013, 62 (1): 185-191.
- [18] 徐建军, 许振亮, 王喜莲 (Xu Jianjun, Xu Zhenliang, Wang Xilian). 基于指数函数的开关磁阻电机磁链非线性模型 (Nonlinear flux linkage model for switched reluctance motor based on exponential function) [J]. 北京交通大学学报 (Journal of Beijing Jiaotong University), 2014, 38 (2): 117-122.
- [19] Chancharoensook P, Rahman M F. Dynamic modeling of a fourphase 8/6 switched reluctance motor using current and torque look-up tables [A]. IEEE 2002 28th Annual Conference of the Industrial Electronics Society [C]. Sevilla, Spain, 2002. 7725876.
- [20] Xue X D, Cheng K W E, Ho S L. Simulation of switched reluctance motor drives using two-dimensional bicubic spline [J]. IEEE Power Engineering Review, 2007, 22

- (7): 51-51
- [21] Xue X D, Cheng K W E, Ho S L, et al. Precise analytical modelling magnetic characteristics of switched reluctance motor drives using two-dimensional least squares [A]. Power Electronics Specialist Conference [C]. 2003, 1: 416-421.
- [22] 黄苏丹, 曹广忠, 钱清泉, 等 (Huang Sudan, Cao Guangzhong, Qian Qingquan, et al.). 平面开关磁阻电机非线性力电流转换模型 (Nonlinear model of force-to-current inverse transform for the planar switched reluctance motor) [J]. 电工技术学报 (Transactions of China Electrotechnical Society), 2017, 32 (2): 135-143.
- [23] 程志友, 丁柏宏, 余国晓 (Cheng Zhiyou, Ding Bohong, Yu Guoxiao). 基于 IPSO-LSVM 的短期负荷预测方法 (Short-term load forecasting method based on IPSO-LSVM) [J/OL]. 电工电能新技术 (Advanced Technology of Electrical Engineering and Energy): 1-7 [2019-11-05]. <http://kns.cnki.net/kcms/detail/11.2283.TM.20191101.1554.004.html>.
- [24] 蒋维婷, 孙玉坤, 朱志莹 (Jiang Weiting, Sun Yukun, Zhu Zhiying). 基于 PSO-LS-SVM 的磁悬浮开关磁阻机电感模型 (Inductance model of bearingless switched reluctance motors based on PSO-LS-SVM) [J]. 微电机 (Micromotors), 2013, 46 (11): 1-5.
- [25] Guo X, Hua W, Xu Y, et al. Accurate model of switched reluctance motor based on indirect measurement method and least square support vector machine [J]. IET Electric Power Applications, 2016, 10 (9): 916-922.
- [26] Zhong R, Cao Y P, Hua W, et al. An improved model of switched reluctance motors based on least square support vector machine [A]. 2013 IEEE International Symposium on Industrial Electronics [C]. Taipei, China, 2013. 10.1109/ISIE.2013.6563624.
- [27] Song S, Ge L, Zhang M. Data-reconstruction-based modeling of srm with few flux-linkage samples from torque-balanced measurement [J]. IEEE Transactions on Energy Conversion, 2016, 31 (2): 424-435.

SVM-based modeling of SRM with few flux-linkage samples

XIE Yong-jun, ZHAO Shi-wei, CHENG Xiao-hua

(Electric Power College, South China University of Technology, Guangzhou 510640, China)

Abstract: To SRM, it is time-consuming to get the data of $\psi-\theta-i$, because the flux-linkage characteristics a binary nonlinear function of position of rotator and current of winding. This paper proposes a SVM-based model of SRM with few flux-linkage samples. In the region of small ψ , the relative error of prediction is large if the model is directly trained by the dataset of $\psi-\theta-i$. The max of relative error is up to 200%. After analysing the reason of large relative error, training dataset is non-linearly mapped. By using the mapped data to training the model, the relative error is under 3.5%. Then, integrating the two kind of models to get the final model. Finally, the influence caused by reducing data and the relative error go down.

Key words: SRM; model of flux linkage; SVM; few flux-linkage samples; nonlinear mapping