

# 基于 PSO-SVM 的电机故障检测<sup>①</sup>

李圣普, 王小辉

(平顶山学院 计算机科学与技术学院, 平顶山 467001)

**摘要:** 传统智能故障检测模型中算法初始参数复杂, 选取难度较大, 缺乏自学习、自组织能力、泛化能力弱, 极易陷入局部极小值、算法单一等缺点. 组合应用智能检测算法可整合不同算法优势, 避免单一算法缺点, 为此, 文中提出支持向量机算法与改进粒子群算法相结合的电机故障检测模型: 以电机故障特征频率特征数据为基础, 首先使用改进全局求解性能的粒子群算法求解影响支持向量机分类检测性能的最佳参数, 然后把最佳参数应用于的擅长模式识别的支持向量机算法, 进行样本数据的训练, 构建故障检测模型; 最后, 使用故障检测模型对电机的状态进行预测. 实验结果表明, 采用该方法进行故障检测的准确率, 比传统的神经网络方法提高 17%, 比纯支持向量机算法提高 3.33%.

**关键词:** 支持向量机; 改进粒子群; 参数优化; 矿用电机故障检测; Matlab 实验

## Mine Based Motor Fault Detection Model Based on PSO-SVM

LI Sheng-Pu, WANG Xiao-Hui

(College of Computer Science and Technology, Pingdingshan University, Pingdingshan 467001, China)

**Abstract:** Traditional intelligent fault detection model such as neural network has some faults such as lacking of self-learning and self-organization, weak generalization ability, easy to fall into local minimum value and single. Intelligent detection algorithm of combination application can integrate advantages of different algorithms and avoid the disadvantages of single algorithm. Therefore, this paper proposes a mine based motor fault detection model based on combination of vector machine (SVM) algorithm and improved particle swarm optimization (PSO) algorithm. Firstly, the optimal parameters for SVM is got by using improved particle swarm optimization (PSO) algorithm, which has better inspiration performance and relapses into local optimal solution less. Secondly, the optimal parameters are used by SVM algorithm to train sample data for data classification, because SVM algorithm is good at pattern recognition. At last, a fault diagnosis model has built up. The experimental results show that the method can improve the accuracy of fault detection by 3.33%-17%.

**Key words:** support vector machine; optimized particle swarm optimization; parameter optimization; mine based motor fault detection; Matlab experiment

## 1 引言

转子断条故障和轴承故障是矿用感应电动机经常发生的故障, 轴承故障数量达到故障总数的 40%以上, 转子断条故障数量占故障总数的 10%还多, 严重影响着煤矿的安全生产. 因此, 非破坏性的故障检查与预测方法具有重要的研究价值<sup>[1]</sup>.

近年来, 智能算法建模与预测成为故障检测领域的重要研究内容之一, 目前, 人工神经网络、支持向量机、遗传算法、灰色理论等智能算法被应用于电机故障检测<sup>[2,3]</sup>. 但是这些算法也存在一些不可避免的问题: 算法初始参数复杂, 选取难度较大, 学习过程中会深陷于局部极小点; 传统的智能检测技术存在着算法单

① 基金项目:河南省重点科技攻关项目(142102210225)

收稿时间:2015-05-07;收到修改稿时间:2015-06-03

一的缺点<sup>[4,5]</sup>。此外,也出现有计算机智能检测系统,但是由于自身的缺陷,无法保证较好的准确率。因此,如何低成本地提高故障检测的准确率也有待深入研究。

支持向量机(SVM)擅长于模式分类,采用结构化风险原则,且具有小样本数据预测的优点,可有效避免神经网络样本数据较多,收敛速度慢,学习不足或过多和陷入局部最小等缺点,非常适合电机故障的分类检测功能。但网格搜索法作为支持向量机模型中常见的参数选择方法,具有搜索时间长,搜索精度小等缺点<sup>[6]</sup>。粒子群(PSO)算法是启发式的智能搜索算法,由当前的最优值出发,通过适应度评价和进化去寻求全局的最优解,比网格搜索法更好的优势在于,用较快的搜索速度求解更宽广参数空间内的更好的解,其改进算法使用粒子群初始化、邻域拓扑、参数选择和混合策略等方法减少和避免陷入局部解<sup>[7]</sup>。

为此,文章提出关于改进粒子群与支持向量机结合的电机故障检测方法:支持向量机算法作为故障分类和检测的主模型,但分类和检测结果的好坏,取决于支持向量机模型中的参数选择,在最佳参数的求解环节引入粒子群算法,使用启发式的智能搜索方法更加快速的寻找全局最优解,可有效提升故障检测的速度和精度。

## 2 PSO-SVM电机故障检测原理

### 2.1 电机故障机理分析

在电机故障种类中,对轴承故障和转子段条故障占故障总数的一半以上,因此本文主要针对轴承故障和转子段条故障展开感应电动机的故障检测和检测工作。轴承故障和转子段条故障引起的转轴振动最终会在定子绕组中感应出相应的谐波分量,因此可以通过对定子电流信号进行频谱分析,提取出与振动水平相应的谐波分量,从而达到故障检测的目的。定子电流分析方法的优点在于它是一种非侵入式的故障检测方法,不会对机器造成损坏,该方法已经引起了广泛的关注。

转子发生断条故障后,定子相电流的频谱将产生一定的转变,定子相电的频谱中会出现频率分量

$$(1-2s)f_1 \quad (1)$$

其中,s是转差率,f<sub>1</sub>是电源频率为50Hz。s的大小一般为0.02-0.05之间。上述的频率分量被广泛用于电动机转子断条的故障特征频率<sup>[8]</sup>。

轴承发生故障后,也会产生故障特征频率,就是轴承损坏点和其相接触的器件撞击的低频振动的频率<sup>[9,10]</sup>。

$$f_{bf} = |f_s \pm kf_c| \quad (2)$$

式(1)中, $f_{bf}$ 是定子电流谐波频率, $f_s$ 是电机供电频率, $f_c$ 是轴承故障特征频率, $k=1,2,3,\dots$ 。式(1)被广泛应用并成功用于轴承故障检测。

### 2.2 支持向量机与模式分类

支持向量机(Support Vector Machine, SVM)像径向基函数网络与多层感知器网络相似,可用于模式分类和非线性回归,是由Vapnik首先提出的。其主要思想在于建立分类超平面作为决策曲面,将正反例间的隔离边缘最大化来分类。其应用了结构风险最小化准则,较好地解决了小样本、非线性、高维数等实际问题。电动机故障检测技术,其本质是一个模式识别问题,首先判断设备运行是否正常,发生故障后,进而识别出什么设备是否发生故障。

设电机故障样本数据为X,使用2.1节原理测量的电机状态数据;电机状态的集合为Y, $Y = \{0,1,2\}$ (其中,0代表正常状态、1代表转子断条故障、2代表轴承故障)。那么,创建故障模型,就是根据支持向量机原理<sup>[6]</sup>,求解以下问题:

对于数据样本  $T = \{(x_1, y_1), \dots, (x_l, y_l)\} \in (X \times Y)^l$ , 寻找一个实值函数  $y(x)$  在  $x_i \in X = R^n, y_i \in Y = \{0,1,2\}, i=1, \dots, l$  里面,判断任何模式下的  $x$  相对应的  $y$  值,可以方便使用决策参数  $f(x) = \text{sgn}(y(x))$ 。为找到最优分类超平面,需求解下面问题:

$$\min_{\omega, b} \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^l \xi_i$$

$$s.t. \quad y_i((\omega \cdot x_i) + b) + \xi_i \geq 1, i=1, 2, \dots, l \quad (3)$$

其中: $\omega$ 表示系数向量, $\xi_i \geq 0$ 表示松弛变量,C是惩罚因子,通过惩罚因子改变能够在分类器的误分类率和泛化力间折衷。

最终,可求得决策函数

$$f(x, \alpha) = \text{sgn} \left( \sum_{i=1}^l y_i \alpha_i^0 K(x \cdot x_i) + b \right) \quad (4)$$

式中, $k(x_i, x_j)$ 是核函数。

核函数和它的参数主要决定样本数据分布在高维特征空间中的复杂程度。

通过上述计算过程可以看出,惩罚因子C与核函

数的选择及其参数的确定是影响支持向量机分类性能的主要因素. 采用 SVM 来做分类, 想要达到较满意的结果, 需要调节惩罚因子参数和核函数参数, 才能得到比较理想的预测分类准确率, 支持向量机做不到这一点, 下文利用粒子群算法来优化惩罚因子 C 和核函数参数的选取过程.

### 2.3 改进粒子群算法优化支持向量机参数

粒子群算法是一种启发式的智能优化算法, 该算法具有搜索机制较为简单, 收敛速度快, 运算量小等优点, 粒子群算法在进行大规模搜索时, 改进措施使用粒子群初始化、邻域拓扑、参数选择和混合策略等方法能够减少和避免陷入局部最优解的缺陷. 利用粒子群算法来优化支持向量机算法中惩罚因子 C 和核函数参数的优化选择, 可以避免 SVM 算法传统的网格搜索方法计算量大, 搜索区域不易精确定位等缺点, 提高搜索速度, 智能优化搜索区域与精度.

PSO 算法数学理论基础为<sup>[7]</sup>: 设在 D 维的搜索空间内有 n 个粒子. 向量  $L_i=(x_{i1}, x_{i2}, \dots, x_{iD})$  表示 i 粒子的位置空间, 其“飞行”中最优历史位置(最优解)为  $P_i=(p_{i1}, p_{i2}, \dots, p_{iD})$ , 设第 g 个粒子的历史最优位置  $P_g$  为全部局部最优解  $P_i (i=1, \dots, n)$  的最优; 第 i 个粒子的速度用向量  $V_i=(v_{i1}, v_{i2}, \dots, v_{iD})$  表示. 按如下公式进行每个粒子的位置变化:

$$V_{id}(t+1) = w \times V_{id}(t) + c_1 \times rand() \times [P_{id}(t) - L_{id}(t)] + c_2 \times rand() \times [P_{gd}(t) - L_{id}(t)] \quad (5)$$

$$L_{id}(t+1) = L_{id}(t) + V_{id}(t+1) \quad 1 \leq i \leq n \quad 1 \leq d \leq D \quad (6)$$

其中, 速度的变化区间  $[-VMAX_d, VMAX_d]$ , 第 d  $(1 \leq d \leq D)$  维的位置变化区间为  $[-XMAX_d, XMAX_d]$ , 当迭代中如果位置或速度越界就取边界值.  $c_1, c_2$  为加速因子是正常数;  $rand()$  是区间  $[0, 1]$  的随机数; w 是惯性因子. 粒子群的初始位置与速度均随机产生, 后根据公式(5), (6)进行迭代, 直至找到最优解.

在算法改进方面, 为了减少陷入局部解, 当粒子群收敛到一定程度采取变异措施, 围绕粒子群的当前质心对粒子群重新初始化<sup>[11]</sup>. 在粒子群的迭代求解过程中获得新的搜索位置, 增加了求得更优解的机会.

粒子群算法启发式寻优, 速度快, 参数简单的特点, 加上全局寻优性能的改进, 应用于优化 SVM 的最

佳参数寻找, 主要步骤如下:

- 1) 选择阈值与最大迭代次数 maxgen
- 2) 初始化粒子的随机位置和速度为:  $L_i=(x_{i1}, x_{i2}, \dots, x_{iD}), V_i=(v_{i1}, v_{i2}, \dots, v_{iD})$ ;
- 3) 测量每个粒子的适应值; 调研 svmTrain;
- 4) 根据公式(5)(6)更新初始化粒子的位置和速度;
- 5) 把每个粒子相对应的适应值与其寻找过程中的最好位置的适应值进行对比, 发现较好的, 则将其作为自身当前最好位置;
- 6) 对比每个粒子相对应的适应值与全局所经历过的最好位置的适应值取优, 作为自身当前全局最好位置;
- 7) 通过以上步骤, 若没有达到结束条件要求的适应值, 返回步骤 2); 否则执行步骤 8);
- 8) 输出 gbest.

## 3 PSO-SVM电机故障检测实现

### 3.1 实现的总体思路

要实现基于粒子群支持向量机的电机故障检测的功能, 主要进行 4 大步的工作:

- 1) 特征数据采集: 依据 2.1 节的感应电机故障机理分析, 根据公式(1)和(2)可以准确的提取电机故障的特征频率等特征数据, 准备算法的训练数据和测试数据.
- 2) 根据 2.3 节改进粒子群算法的步骤, 应用 PSO 粒子群算法求解 SVM 的最佳参数.
- 3) 使用上步求得的最佳参数, 使用公式(3)和(4), 结合训练样本数据, 构建 SVM 算法故障分类模型.
- 4) 使用 SVM 算法故障分类模型, 对测试数据进行故障预测, 并验证模型预测的准确性.
- 5) 分析实验结果, 并从 SVM 不同核函数选择和 PSO 优化 SVM 等多方面对比多种不同检测方法的检测准确率.

在进行样本选取时, 要注意选择具有代表性的样本数据作为支持向量机识别模型所需要的样本. 以下是感应电机故障检测模型整体流程如图 1.




图 1 电机故障检测模型整体流程

### 3.2 工具选择与基础数据设置

采用 Matlab2014a 软件与支持向量机加强工具箱——Libsvm, 进行 PSO-SVM 模型的电机故障检测实验与仿真。

基于上文分析, 试验中选取电机正常、转子断条故障、轴承故障这三种情况下的各 20 个样本特征频率进行模型的训练和预测识别。选取的每个特征样本数据共 4 个特征值; 分别选取三种状态下的前 10 个样本作为训练样本, 三种状态下的后 10 个样本作为测试样本, 下面仅列出轴承故障状态的部分数据如表 1, 其他数据不再赘述。

表 1 轴承内圈故障状态下的特征数据

样本	A1	A2	A3	A4	类别 标签
1	6.0641	0.2796	0.0375	0.0812	2
2	6.1503	0.3226	0.0499	0.1043	2
3	6.1503	0.3226	0.0499	0.1043	2
4	6.2097	0.3129	0.0431	0.0927	2
5	6.2205	0.3201	0.0461	0.092	2
6	6.1206	0.1856	0.0206	0.0391	2
7	6.1778	0.2524	0.0243	0.0599	2
8	6.1882	0.2532	0.0253	0.0599	2
9	6.3197	0.2637	0.0285	0.0632	2
10	6.3442	0.2481	0.0259	0.0538	2
11	6.3538	0.1856	0.0212	0.0434	2
12	6.3337	0.1557	0.02	0.0354	2
13	6.3858	0.164	0.0144	0.0316	2
14	6.5708	0.1042	0.0131	0.0205	2
15	6.5928	0.0866	0.0118	0.0214	2
16	6.6101	0.0682	0.0132	0.0202	2
17	6.6668	0.0392	0.0099	0.0103	2
18	6.7133	0.0253	0.0104	0.0081	2
19	6.7376	0.0178	0.009	0.0063	2
20	6.7105	0.0128	0.0079	0.0055	2

### 3.3 Matlab 实验设计

使用 Matlab 实现 PSO\_SVM 算法故障检测功能的实验, 主要需要以下 5 个步骤:

#### 1) 数据文件设计

将电机的状态信息(正常状态、转子断条故障、轴承故障)等数据保存到 Matlab 的 mat 数据文件中, 为后续的故障检测算法提供基础数据。复杂的地方在于需要把状态数据重新组织成适合 SVM 算法使用的数据结构, 根据 SVM 算法状态数据、类别数量、类别标签

的要求, 电机故障检测的数据文件设计如下:

**motor:** 存储单纯的电机状态信息: 正常状态 20 条数据、转子断条故障 20 条数据、轴承故障 20 条数据, 每条状态数据包括该状态下的 4 个特征值。

**motor\_labels:** 存储电机状态的标签, 0 代表正常状态、1 代表转子断条故障、2 代表轴承故障。

**classNumber:** 分类个数, 其数值为 3。

#### 2) 选定训练集和测试集

在第一步的数据文件中取出部分状态数据及其状态标签单独存放, 为后续的 SVM 模型训练提供输入数据和测试数据, 程序设计为取 3 种电机状态的前一半数据作为训练数据集, 后一半数据作为测试数据集, 具体如下:

% 将第一类的 1-10,第二类的 21-30,第三类的 41-50 做为训练集

```
train_motor = [motor(1:10,:);motor(21:30,:);motor(41:50,:)];
```

% 相应的训练集的标签也要分离出来

```
train_motor_labels = [motor_labels(1:10);motor_labels(21:30);motor_labels(41:50)];
```

% 将第一类的 11-20,第二类的 31-40,第三类的 51-60 做为测试集

```
test_motor = [motor(11:20,:);motor(31:40,:);motor(51:60,:)];
```

% 相应的测试集的标签也要分离出来

```
test_motor_labels = [motor_labels(11:20);motor_labels(31:40);motor_labels(51:60)];
```

#### 3) 数据预处理

数据归一化处理, 可明显提高算法模型的精度, 将训练集和测试集归一化到[0,1]区间, 使用 Matlab 的归一化函数 mapminmax:

%求出训练集和测试集的大小: 行数和列数

```
[mtrain,ntrain] = size(train_motor);
```

```
[mtest,ntest] = size(test_motor);
```

%将训练集和测试集归并为数据集

```
dataset = [train_motor;test_motor];
```

%使用 Matlab 的归一化函数 mapminmax 归一化到 [0,1]区间

```
[dataset_scale,ps] = mapminmax(dataset',0,1);
```

```

dataset_scale = dataset_scale';
%求得归一化后的训练集和测试集
train_motor = dataset_scale(1:mtrain,:);
test_motor =
dataset_scale( (mtrain+1):(mtrain+mtest),:);

```

4) 应用 PSO 算法求解最佳的 SVM 参数 c 与 g

根据 PSO 粒子群算法自定义函数 psoSVMcgForClass, 求解 SVM 算法所需的最佳 c 值与 g 值, 自定义函数的具体实现思路参考的 2.3 节 PSO 算法实现步骤.

```

[bestacc,bestc,bestg] =
psoSVMcgForClass(train_motor_labels,train_motor);

```

其中: 参数 train\_motor\_labels 和 train\_motor 为测试集中的状态数据及其类别标签, bestacc 为求解的最佳准确率, bestc 为求解的最佳 c 值, bestg 为求解的最佳 g 值.

5) 利用最佳的参数进行 SVM 网络训练:

%将上步求得的最佳值生成 SVM 训练模型的参数字符串, 其中参数 t 的值确定核函数的类型

```

cmd = ['-c ',num2str(bestc),' -g ',num2str(bestg),'-t
1'];

```

%使用 svmLib 工具箱的 svmtrain 函数训练预测模型 model =

```

svmtrain(train_motor_labels,train_motor,cmd);

```

其中, 参数 train\_motor\_labels,train\_motor 为测试集中的状态数据及其类别标签, model 为训练所得的分类模型.

6) SVM 网络测试与检测:

%使用 svmLib 工具箱的 svmpredict 函数训练预测模型

```

[predict_label,accuracy] =
svmpredict(test_motor_labels,test_motor,model);

```

其中, 参数 model 即上一步中训练所得的分类模型, predict\_label 为预测所得的分类结果, accuracy 为预测的准确率.

3.4 实验结果与分析

该部分主要讨论以下 2 种情形的实验结果及对比分析:

1) PSO 优化 SVM 模型选用不同 SVM 核函数的预测效果及对比, 因为 SVM 算法的预测精度与所选取的核函数密切相关, 而支持向量机核函数的选取方面还

没有严格的理论依据, 需要对比找到最优的 PSO 优化 SVM 预测模型.

2) 单纯的 SVM 模型的预测效果及其与 PSO 优化 SVM 预测模型的对比, 观察 PSO 优化后的 SVM 是否比单纯的 SVM 模型性能优越.

根据 3.2 节整理的数据和 3.3 节设计的实验进行电机故障检测实例的分析和研究, 首先进行数据归一化预处理, 接着对样本中基础数据进行训练样本与测试样本的分类, 输入训练样本数据后, 然后利用粒子群 PSO 算法对支持向量机的参数进行优化, 设最大迭代步数为 200, 电机状态测试数据的 BOX 可视化图和分维可视化图如图 2 和图 3, 参数寻优结果如图 4.




图 2 电机状态测试数据的 BOX 可视化图




图 3 电机状态测试数据的分维可视化图

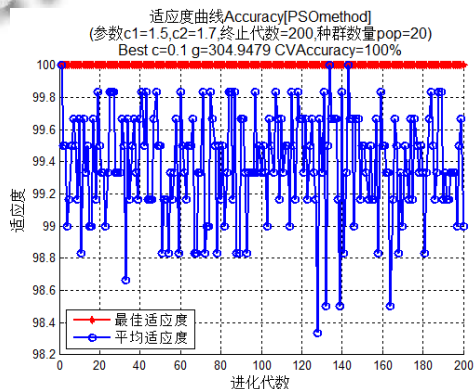


图 4 粒子群优化参数结果

将最优参数 c 和 g 的值引入支持向量机故障识别, 分别实验四种核函数下的电机故障检测, 经过模型训

练,输入测试样本对模型进行准确性检验的结果如图5和6,从图中可以看出 PSO 优化 SVM 的预测模型,使用线性核函数、RCF 核函数、Sigmoid 核函数三种核函数时的预测准确率均为 90%(27/30),而使用多项式核函数时的预测准确率更高一点,达到了 93.33%(28/30)。

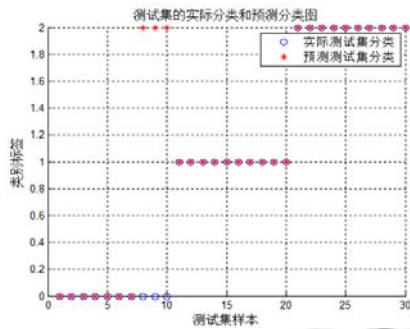


图5 PSO\_SVM(线性核函数、RCF核函数、Sigmoid核函数)故障检测结果




图6 PSO\_SVM(多项式核函数)故障检测结果

此外,还进行了单独使用 SVM 算法的预测实验,只使用 SVM 算法的求解到的预测模型的故障诊断结果如图7所示,其诊断结果的准确率为 76.67% (23/30),大幅度低于 PSO 优化后的 SVM 预测模型,原因就在于单独的 SVM 算法中的参数  $c$  和  $g$  的是大概估算,并不是最优的,较大程度的影响了 SVM 故障检测的准确性。




图7 SVM(多项式核函数)故障检测结果

以上的实验结果可以用表2更清晰的表示。

表2 结果对比表

类型	准确率
SVM 模型(多项式核函数)	76.67%
PSO-SVM 模型(线性核函数)	90%
PSO-SVM 模型(多项式核函数)	93.33%
PSO-SVM 模型(RBF核函数)	90%
PSO-SVM 模型(Sigmoid核函数)	90%

从模型的故障检测准确率来看 PSO-SVM 模型明显优于单独的 SVM 模型,且多项式核函数模型优于其它三种核函数模型。经测试样本验证,参数  $c=0.1, g=304.9479$ , 选用多项式核函数的 PSO-SVM 模型可用于矿用电动机故障检测,检测准确率明显提高。

#### 4 结语

上文提出 PSO-SVM 故障检测模型,以电机故障特征频率特征数据为基础,首先,应用 PSO 粒子群算法以实现快速动态选取 SVM 故障检测模型的最佳参数,然后应用具有最佳参数的 SVM 算法训练样本数据,构建故障检测模型;最后,使用故障分类模型进行故障预测,并验证模型预测的准确性,采用该方法进行故障检测的准确率,比传统的神经网络方法提高 17%,比纯支持向量机算法提高 3.33%。通过分析和对比多种不同检测方法的实验,表明该方法提高了故障检测的准确率和效率。

#### 参考文献

- 康云霞.基于粗糙集与神经网络的异步电机故障诊断方法的研究[硕士学位论文].锦州:渤海大学,2014.
- 余梓唐.基于粒子群算法优化支持向量机汽车故障诊断研究.计算机应用研究,2012,29(2):572-574.
- 刘亚军.基于小波分析和神经网络的电机故障诊断研究[硕士学位论文].太原:中北大学,2009.
- 许允之,韩丽,方永丽,严加明,曹海洋.基于神经网络算法的感应电机故障诊断方法.大电机技术,2013,(1):15-18.
- 穆丽娟,苏晓娜,李晓明.RBF神经网络在异步电机故障诊断中的应用.火力与指挥控制,2012,37(6):148-151.
- 李淑英,田慕琴,薛磊.基于支持向量机的矿用电机故障诊断.煤矿安全,2013,44(6):104-106.
- 鲁姝颖.粒子群优化算法的几种改进算法及应用[硕士学位论文].北京:中国矿业大学,2014.
- 王攀攀.感应电机定转子故障的微粒群诊断方法研究[博士学位论文].北京:中国矿业大学,2013.
- 李青松.基于定子电流分析的机车牵引电机轴承故障诊断[硕士学位论文].北京:北京交通大学,2011.
- 杨江天,赵明元,张志强,等.基于定子电流小波包分析的牵引电机轴承故障诊断.铁道学报,2013,35(2):32-36.
- 黄敏,江渝,毛安,等.基于全局最优位置自适应选取与局部搜索的多目标粒子群优化算法.计算机应用,2014,34(4):1074-1079.