

文章编号:1671-251X(2018)03-0081-06

DOI:10.13272/j.issn.1671-251x.2017110006

基于 HGWO-MSVM 的采煤机滚动轴承故障诊断方法

孙明波, 马秋丽, 张炎亮, 雷俊辉

(郑州大学 管理工程学院, 河南 郑州 450001)

摘要:针对采煤机滚动轴承故障特征向量提取较困难、多分类效果不理想等问题,提出了基于 HGWO-MSVM 的采煤机轴承故障诊断方法。对轴承故障信号进行小波降噪处理,利用经验模态分解算法对降噪后信号进行分解,并提取能量特征值,作为 MSVM 的训练集和测试集。采用 MSVM 进行故障状态识别,并用 HGWO 算法对 MSVM 的参数进行优化。试验结果表明,相比于 GWO、GA 和 PSO 优化 MSVM 模型,基于 HGWO-MSVM 的采煤机轴承故障诊断模型可明显提高故障识别精度和效率。

关键词:煤炭开采;采煤机;滚动轴承;故障诊断;经验模态分解;混合灰狼优化算法;多分类支持向量机

中图分类号:TD632

文献标志码:A

网络出版时间:2018-02-07 08:38

网络出版地址:<http://kns.cnki.net/kcms/detail/32.1627.TP.20180206.1755.008.html>

Fault diagnosis method for rolling bearing of shearer based on HGWO-MSVM

SUN Mingbo, MA Qiuli, ZHANG Yanliang, LEI Junhui

(School of Management Engineering, Zhengzhou University, Zhengzhou 450001, China)

Abstract: In view of problems of difficult extracting of fault feature vector and unsatisfactory multi-classification effect of shearer rolling bearing, a fault diagnosis method for rolling bearing of shearer based on HGWO-MSVM was proposed. The bearing fault signal is denoised by wavelet and decomposed by empirical mode decomposition algorithm, then energy characteristic value is extracted and used as training set and test set of MSVM. The MSVM is used to identify fault status and parameters of MSVM are optimized by HGWO algorithm. The experimental results show that the fault diagnosis model of shearer bearing based on HGWO-MSVM can obviously improve accuracy and efficiency of fault identification compared with GWO, GA and PSO optimization MSVM model.

Key words: coal mining; shearer; rolling bearing; fault diagnosis; empirical mode decomposition; hybrid grey wolf optimization algorithm; multi-class support vector machine

0 引言

采煤机是煤炭生产中的关键设备,由于工作条件比较恶劣,采煤机轴承容易发生故障,轴承寿命参差性很大,所以准确地进行故障诊断十分必要。轴承故障诊断的主要过程包括故障特性提取和状态识别两部分^[1],有效信号的特征提取是故障判别的

基础。

实际情况下,采煤机轴承中的振动信号通常伴随强烈的噪声,因此,轴承故障特征向量的提取较困难^[2]。故障特征提取一般采用时频处理方法,如傅里叶变换、小波包分解^[3]等。但小波包分解自适应性较差,傅里叶变换仅针对平稳信号的处理。EMD (Empirical Mode Decomposition,经验模态分解)算

收稿日期:2017-11-06;修回日期:2018-01-15;责任编辑:胡娴。

基金项目:国家自然科学基金资助项目(71271194);河南省基础与前沿技术研究项目(162300410073)。

作者简介:孙明波(1970—),女,河南郑州人,教授,博士,主要从事质量工程与故障诊断方面的研究工作,E-mail:1074278011@qq.com。

引用格式:孙明波,马秋丽,张炎亮,等.基于 HGWO-MSVM 的采煤机滚动轴承故障诊断方法[J].工矿自动化,2018,44(3):81-86.

SUN Mingbo, MA Qiuli, ZHANG Yanliang, et al. Fault diagnosis method for rolling bearing of shearer based on HGWO-MSVM [J]. Industry and Mine Automation, 2018, 44(3): 81-86.

法是一种新颖的信号处理方法,且适合不平稳信号,自适应分解特性较好^[4]。文献[5]将 EMD 与信息熵的思想相结合,提出了一种基于 EMD 熵特征融合的轴承故障判别方法,通过试验证明了其具有很好的故障模式判别性能。文献[6]利用 EMD 将轴承的不平稳振动信号分成部分平稳的本征模函数,结合奇异值差分谱的思想处理 IMF 分量,能够有效地诊断出轴承的各项故障。

在故障状态识别中,MSVM (Multi-class Support Vector Machine,多分类支持向量机)是可将整体结构风险降低到最小的一种智能学习工具,能很好地处理多分类、高维和非线性问题,可避免神经网络的局部最优和结构选择等问题^[7-8]。但用 MSVM 进行故障识别时,其性能取决于相关参数的选取。常用的参数优化算法有 PSO (Particle Swarm Optimization,粒子群优化)算法^[9]、GA (Genetic Algorithm,遗传算法)^[10]、GWO (Grey Wolf Optimizer,灰狼优化)算法^[11-12]等。但 PSO 算法全面搜索能力差,求解不稳定;GA 和 GWO 算法易出现局部最优,且精确度低。DE (Differential Evolution,差分进化)算法有很强的全局搜索能力, HGWO (Hybrid GWO,混合灰狼优化)算法将 DE 算法和 GWO 算法相结合,能够使 GWO 算法跳出局部最优。

本文提出了一种基于 HGWO-MSVM 的采煤机滚动轴承故障诊断方法。该方法采用 EMD 算法提取振动信号特征向量,采用 MSVM 进行故障状态识别,并用 HGWO 算法对 MSVM 的参数进行优化。

1 振动信号特征提取

1.1 EMD 算法

EMD 算法的核心思想是对多变量振动信号进行分解^[13]。但信号中伴有强烈的噪声,影响有效信号的获得,因此,需先用小波进行降噪,然后再利用 EMD 分解出若干不同类型的特征信号,得到若干特征时间尺度的固有模态函数。设振动信号为 $x(t)$,EMD 算法流程如下。

(1) 求 $x(t)$ 在一定范围内的极大值和极小值所在位置,分别构造 $x(t)$ 的上下包络线 $u(t)$ 和 $v(t)$,然后求振动信号的平均值 $m(t)$ 。

(2) 设 $x(t)$ 与 $m(t)$ 差值为 $h(t)$:

$$h(t) = x(t) - m(t) \quad (1)$$

(3) 判断 $h(t)$ 是否符合 IMF 的 2 个要求,如果

符合则获得第 1 个 IMF 分量 $c_1(t)$,否则重复上述步骤,直到 $h(t)$ 符合 IMF 要求。

(4) 用 $x(t)$ 减去 $c_1(t)$,设差值为 $r_1(t)$,判定 $r_1(t)$ 是否需要分解,若需要,则用 $r_1(t)$ 代替 $x(t)$,重复以上过程,否则停止。

振动信号通过 EMD 算法处理后,被分解为部分 IMF 分量 $c_i(t)$ 与 $r_n(t)$ 之和:

$$x(t) = \sum_{i=1}^n c_i(t) + r_n(t) \quad (2)$$

式中: $c_i(t)$ 是各阶 IMF 分量; $r_n(t)$ 为残余量; n 为 IMF 分量个数。

1.2 特征能量提取

滚动轴承正常状态和故障状态下的振动信号在能量上有差别,本文将经 EMD 算法处理后获得的各阶 IMF 分量的能量作为其特征值,其计算流程如下。

(1) 求 IMF 分量的能量 E_i :

$$E_i = \int_{-\infty}^{+\infty} |c_i(t)|^2 dt \quad (3)$$

(2) 构造出振动信号的能量特征向量:

$$\mathbf{T} = [E_1, E_2, \dots, E_n] \quad (4)$$

(3) 对 $\mathbf{T}$ 进行归一化处理,设信号总能量为 E ,

则 $E = \sum_{i=1}^n E_i$,归一化后的 $\mathbf{T}'$ 为

$$\mathbf{T}' = \left[\frac{E_1}{E}, \frac{E_2}{E}, \dots, \frac{E_n}{E} \right] \quad (5)$$

2 轴承故障状态识别

2.1 MSVM

SVM (Support Vector Machine,支持向量机)在处理少容量、非线性问题的模式识别中展现出较多优点,但其主要解决二值分类问题^[14]。而在实际应用中,多分类问题更为普遍。基于二叉树的 MSVM 所需数据少,各分类器的训练样本数和时间都相对较少,因此,选择二叉树结构算法对 SVM 进行优化,即针对 S 类练习样本,练习 $S-1$ 个 SVM。

令训练样本为 $x_i, i=1, 2, \dots, l$ (l 为样本个数), $x_i \in R^z$, 样本输出 $y_i \in \{+1, -1\}$ 。其中, z 为空间的维度。设分类面方程为 $\omega \cdot x + b = 0$ 。引入非负松弛变量 ξ_i 和惩罚因子 $c, \xi_i \geq 0, c > 0$,则问题转化为如下约束优化问题:

$$\begin{aligned} \min \phi(\omega, \xi) &= \frac{1}{2}(\omega \cdot \omega) + c \sum_{i=1}^l \xi_i \\ \text{s. t. } y_i[\omega \cdot x_i + b] &\geq 1 - \xi_i \end{aligned} \quad (6)$$

式中 $\phi(\omega, \xi)$ 为分类面函数。

引入 Lagrange 函数,则最优分类函数为

$$f(x) = \text{sgn} \left\{ \sum_{i=1}^l y_i \alpha_i^* K(x_i, x) + b^* \right\} \quad (7)$$

式中: $K(x_i, x)$ 为核函数; α_i^* 为 Lagrange 系数; b^* 为分类阈值。

径向基核函数仅需明确一个变量,计算难度较小,能够提高 SVM 的识别和泛化能力,定义如下:

$$K(x_i, x_j) = \exp \left\{ -\frac{\|x_i - x_j\|^2}{2\sigma^2} \right\} \quad (8)$$

式中: σ 为径向基核函数的宽度; $j=1, 2, \dots, l$ 。

2.2 HGWO

GWO 算法是基于生态中灰狼的社会阶级不同和狩猎制度形成的^[15]。首先在可行区域内任意生成三类群体:父灰、子灰及变异狼群体。每个个体可用式(9)表示:

$$X^k = (X_1^k, X_2^k, \dots, X_d^k) \quad (9)$$

$$X_P^k = X_P^k(w) + (X_P^k(p) - X_P^k(w)) \times \text{rand}(0, 1) \quad (10)$$

式中: $X_P^k(p)$, $X_P^k(w)$ 分别为第 k 个个体第 P 维的上下界, $k=1, 2, \dots, p$, p 为个体个数; d 为解的维数; $\text{rand}(0, 1)$ 表示 $[0, 1]$ 的随机数。

针对个体的适应值,将父代灰狼群按不递增的顺序排列,分别设为 α , β 和 δ 。采用式(11)和式(12)分别产生变异代灰狼、子代灰狼种群:

$$V^i(g) = X^{h_1}(g) + F(X^{h_2}(g) - X^{h_3}(g)) \quad (11)$$

$$h_1 \neq h_2 \neq h_3 \neq i$$

$$U_j^k(g) = \begin{cases} V_j^k(g) & \text{rand}(0, 1) \leq C_R \parallel j = j_{\text{rand}} \\ X_j^k(g) & \text{其他} \end{cases} \quad (12)$$

式中: F 为缩放因素; $g=0, 1, \dots, M$, M 为最大迭代次数; C_R 为交叉率; j_{rand} 为 $[1, d]$ 的任意整数; h_1, h_2, h_3 为 3 个互不相同的整数。

3 轴承故障诊断流程

参数 c 和 σ 对滚动轴承故障诊断的效果具有重要影响。为了选取最佳参数,用 HGWO 算法对 MSVM 进行改进。基于 HGWO-MSVM 的轴承故障诊断流程如图 1 所示。

轴承故障诊断具体步骤分为信号处理、参数优化、故障诊断 3 个阶段。其中,第(1)步为信号处理阶段,第(2)~(6)步为参数优化阶段,第(8)步为故障诊断阶段。

(1) 通过小波降噪方法对轴信号进行降噪,利用 EMD 算法对降噪后信号进行分解,并提取能量特征值,作为 MSVM 的训练集和测试集。初始化 MSVM 中的参数 c, σ , 并设置 HGWO 的相关参数。




图 1 基于 HGWO-MSVM 的轴承故障诊断流程

Fig. 1 Bearing diagnosis flow based on HGWO-MSVM

(2) 通过式(11)随机生成父灰、变异灰、子灰狼群体,初始化参数 $a, \mathbf{A}$ 和 $\mathbf{B}$ 。 a 元素的值在迭代过程中从 2 到 0 线性递减, $\mathbf{A}$ 和 $\mathbf{B}$ 为系数向量。

(3) 父灰狼群体以目标值进行非递减排列,第 1—3 个个体是 α, β 和 δ 。

(4) 根据式(13)改变父灰狼群体的所在点,分别获得变异灰、子灰狼群体。

$$X(t+1) = \frac{1}{3} [X_a - A_1 | C_1 X_a - X(t) | + X_\beta - A_2 | C_2 X_\beta - X(t) | + X_\delta - A_3 | C_3 X_\delta - X(t) |] \quad (13)$$

式中: $A_1, A_2, A_3, C_1, C_2, C_3$ 为系数; X_a, X_β, X_δ 为猎物所在点; $X(t+1)$ 为当前狼群所在点。

(5) 如果子代灰狼群体的目标函数值小于父代灰狼群体,则令子代灰狼群体的目标函数值等于父代灰狼群体对应的目标函数值,否则不变。

(6) 通过式(14)~式(16)更新 $a, \mathbf{A}, \mathbf{B}$ 。

$$\mathbf{A} = 2a\mathbf{q}_1 - a \quad (14)$$

$$\mathbf{B} = 2\mathbf{q}_2 \quad (15)$$

$$a(t) = 2 - 2t/M \quad (16)$$

式中: $\mathbf{q}_1, \mathbf{q}_2$ 为随机向量; M 为最大迭代次数。

(7) 若迭代次数到达上限,则结束算法,输出最优参数,否则返回步骤(5)。

(8) 将最优参数作为 MSVM 诊断模型的参数进行轴承故障诊断。

4 试验分析

4.1 数据采集

本文数据来自采煤机轴承故障模拟试验台。试验中,对轴承的正常、外圈、内圈和滚动体故障 4 种状态单独取样,4 种故障状态的值相应地设置为 1—4。每种状态收集 20 组样本,每组有 8 912 个点,每种状态的前 15 组作为练习样本,后 5 组作为检验样本。

4.2 振动信号的处理

选用小波包对试验数据进行分解和重构,对原始信号进行降噪处理。由于样本数量过多,以滚动体故障状态为例,原始信号 S_1 和降噪信号 S_2 如图 2 所示。




图 2 滚动体故障状态下的原始信号和降噪后信号

Fig. 2 Primitive signal and noise reduction signal under rolling body fault status

4.3 EMD 特征值提取

表 1 轴承各状态能量特征值部分检验样本

Table 1 Partial test samples of energy characteristic values of each state of bearing

序号	E_1	E_2	E_3	E_4	E_5	E_6	E_7	E_8	故障状态
1	0.653 6	0.657 3	0.317 4	0.173 3	0.059 9	0.044 9	0.038 4	0.054 4	1
2	0.618 9	0.577 4	0.493 0	0.127 0	0.097 0	0.028 2	0.079 3	0.089 3	1
3	0.049 5	0.100 6	0.078 5	0.030 6	0.016 9	0.035 6	0.489 7	0.859 6	1
4	0.511 1	0.394 2	0.259 8	0.493 9	0.146 0	0.104 3	0.104 5	0.478 0	2
5	0.096 4	0.234 6	0.850 9	0.458 8	0.032 5	0.006 9	0.001 4	0.002 8	2
6	0.149 5	0.297 5	0.375 4	0.768 9	0.394 3	0.017 4	0.008 5	0.033 1	2
7	0.344 8	0.678 6	0.489 9	0.370 8	0.201 8	0.046 9	0.014 8	0.006 5	3
8	0.808 8	0.492 3	0.202 2	0.232 1	0.092 6	0.013 5	0.003 7	0.000 2	3
9	0.444 4	0.472 1	0.354 2	0.584 9	0.314 1	0.101 4	0.048 4	0.026 6	3
10	0.152 8	0.916 1	0.312 8	0.176 3	0.091 9	0.005 9	0.005 5	0.003 7	4
11	0.483 0	0.701 5	0.235 5	0.388 6	0.244 6	0.060 2	0.045 7	0.051 1	4
12	0.153 8	0.315 4	0.104 6	0.929 2	0.047 2	0.012 5	0.011 2	0.005 8	4

4.4 参数设置及结果分析

经过 80 组样本的学习拟合,建立了基于 HGWO-MSVM、GWO-MSVM、GA-MSVM 及 PSO-MSVM 的采煤机轴承故障诊断模型。参数设置如下:HGWO 算法的种群范围是 10,迭代上限是 200,缩放因数下界是 0.1,上界是 0.9,交叉率是 0.8。MSVM 参数 c 的变化范围是 0.01~100, σ 的

对降噪后的信号进行 EMD 处理,结果如图 3 所示。




图 3 滚动体故障状态下的 EMD 分解结果

Fig. 3 EMD decomposition result under rolling body fault status

从图 3 可看出,EMD 将信号分成了 8 个 IMF 分量,可以分辨出信号特征的区别。轴承各状态能量特征值部分检验样本见表 1。

变化范围是 0.01~100,交叉验证次数是 5。GWO 算法的种群范围是 10,迭代上限是 200。GA 算法的种群范围是 10,迭代上限是 200,交叉概率是 0.9,交叉验证次数是 3。PSO 算法的种群范围是 10,迭代上限是 200,速度调节参数为 1.6 和 1.5,惯性权重是 0.5。

将上述 4 种诊断模型的诊断结果与实际故障类

别对比,结果如图 4—图 7 所示,4 种模型的比较结果汇总见表 2。由表 2 可以看出,4 种算法都能很好地改进 MSVM 诊断模型的参数,且 HGWO 算法在准确率和收敛速率方面均优于其他算法,显示了优越的诊断性能和全局搜索能力。




图 4 HGWO-MSVM 诊断故障与实际故障对比
Fig. 4 Comparison between HGWO-MSVM diagnostic fault and actual fault




图 5 GWO-MSVM 诊断故障与实际故障对比
Fig. 5 Comparison between GWO-MSVM diagnostic fault and actual fault




图 6 GA-MSVM 诊断故障与实际故障对比
Fig. 6 Comparison between GA-MSVM diagnostic fault and actual fault

5 结语

根据采煤机轴承不同故障状态下频域能量的差




图 7 PSO-MSVM 诊断故障与实际故障对比
Fig. 7 Comparison between PSO-MSVM diagnostic fault and actual fault

表 2 4 种模型的测试结果

Table 2 Test results of four models

故障诊断 模型	参数 (c, σ)	训练样本 准确率	测试样本 准确率
HGWO- MSVM	(17.205 0, 15.188 2)	100 % (60/60)	100 % (20/20)
GWO- MSVM	(67.800 5, 15.292 6)	100 % (60/60)	95 % (19/20)
GA- MSVM	(51.318 1, 0.625 6)	93.333 3 % (56/60)	85 % (17/20)
PSO- MSVM	(16.579 1, 1.229 0)	93.333 3 % (56/60)	70 % (14/20)

异,通过 EMD 进行能量特征值提取,结合 HGWO 优化 MSVM 故障诊断模型,能够很好地识别轴承的故障状态。试验结果表明,相比于 GWO、GA 和 PSO 优化 MSVM 模型,基于 HGWO-MSVM 的采煤机轴承故障诊断模型可明显提高故障识别精度和效率。

参考文献 (References):

[1] 孙炎平,陈捷,洪荣晶,等. 基于 EMD-HMM 的转盘轴承故障诊断方法[J]. 轴承,2017(1):41-45.
SUN Yanping, CHEN Jie, HONG Rongjing, et al. Application of empirical mode decomposition and hidden Markov model in fault diagnosis of slewing bearing [J]. Bearing, 2017(1):41-45.

[2] 王宏超,陈进,董广明. 基于最小熵解卷积与稀疏分解的滚动轴承微弱故障特征提取[J]. 机械工程学报, 2013,49(1):88-94.
WANG Hongchao, CHEN Jin, DONG Guangming. Fault diagnosis method for rolling bearing's weak fault based on minimum entropy deconvolution and sparse decomposition [J]. Journal of Mechanical

- Engineering, 2013, 49(1): 88-94.
- [3] 罗毅, 甄立敬. 基于小波包与倒频谱分析的风电机组齿轮箱齿轮裂纹诊断方法[J]. 振动与冲击, 2015, 34(3): 210-214.
- LUO Yi, ZHEN Lijing. Diagnosis method of turbine gearbox gearcrack based on wavelet packet and cepstrum analysis [J]. Journal of Vibration and Shock, 2015, 34(3): 210-214.
- [4] 胡荣华, 楼佩煌, 唐敦兵, 等. 基于 EMD 和免疫参数自适应 SVM 的滚动轴承故障诊断[J]. 计算机集成制造系统, 2013, 19(2): 438-447.
- HU Ronghua, LOU Peihuang, TANG Dunbing, et al. Fault diagnosis of rolling bearings based on EMD and parameter adaptive support vector machine [J]. Computer Integrated Manufacturing Systems, 2013, 19(2): 438-447.
- [5] 向丹, 岑健. 基于 EMD 熵特征融合的滚动轴承故障诊断方法[J]. 航空动力学报, 2015, 30(5): 1149-1155.
- XIANG Dan, CEN Jian. Method of roller bearing fault diagnosis based on feature fusion of EMD entropy [J]. Journal of Aerospace Power, 2015, 30(5): 1149-1155.
- [6] 张超, 陈建军, 徐亚兰. 基于 EMD 分解和奇异值差分谱理论的轴承故障诊断方法[J]. 振动工程学报, 2011, 24(5): 539-545.
- ZHANG Chao, CHEN Jianjun, XU Yalan. A bearing fault diagnosis method based on EMD and difference spectrum theory of singular value [J]. Journal of Vibration Engineering, 2011, 24(5): 539-545.
- [7] 李巍华, 翁胜龙, 张绍辉. 一种萤火虫神经网络及在轴承故障诊断中的应用[J]. 机械工程学报, 2015, 51(7): 99-106.
- LI Weihua, WENG Shenglong, ZHANG Shaohui. A firefly neural network and its application in bearing fault diagnosis [J]. Journal of Mechanical Engineering, 2015, 51(7): 99-106.
- [8] 陈法法, 汤宝平, 苏祖强. 基于局部切空间排列与 MSVM 的齿轮箱故障诊断[J]. 振动与冲击, 2013, 32(5): 38-42.
- CHEN Fafa, TANG Baoping, SU Zuqiang. Gearbox fault diagnosis based on local target space alignment and multi-kernel support vector machine [J]. Journal of Vibration and Shock, 2013, 32(5): 38-42.
- [9] ZHOU C, YIN K, CAO Y, et al. Application of time series analysis and PSO-SVM model in predicting the Bazimen landslide in the Three Gorges Reservoir, China [J]. Engineering Geology, 2016, 204: 108-120.
- [10] CERRADA M, ZURITA G, CABRERA D, et al. Fault diagnosis in spur gears based on genetic algorithm and random forest [J]. Mechanical Systems and Signal Processing, 2016, 70-71: 87-103.
- [11] ZHANG X, MIAO Q, LIU Z, et al. An adaptive stochastic resonance method based on grey wolf optimizer algorithm and its application to machinery fault diagnosis [J]. ISA Transactions, 2017, 71: 206-214.
- [12] KAMBOJ V K. A novel hybrid PSO-GWO approach for unit commitment problem [J]. Neural Computing and Applications, 2016, 27(6): 1643-1655.
- [13] 乔淑云. 基于 EMD 方法的煤矿绞车轴承故障诊断[J]. 工矿自动化, 2016, 42(4): 51-54.
- QIAO Shuyun. Fault diagnosis for mine hoist bearing based on EMD method [J]. Industry and Mine Automation, 2016, 42(4): 51-54.
- [14] 赵春华, 董海江, 钟先友. 风电齿轮箱故障诊断的 SVM 参数优化[J]. 中国机械工程, 2015, 26(16): 2222-2225.
- ZHAO Chunhua, DONG Haijiang, ZHONG Xianyou. SVM parameter optimization in fault diagnosis for wind power gear box [J]. China Mechanical Engineering, 2015, 26(16): 2222-2225.