

基于云理论和 Relief-F 的滚动轴承故障识别方法*

马森财, 赵荣珍, 吴耀春, 邓林峰

(兰州理工大学机电工程学院 兰州, 730050)

摘要 为了充分利用海量数据中蕴含的信息并对轴承故障进行有效识别,采用云理论方法将轴承的故障数据与其对应的故障类型进行映射,建立了滚动轴承在不同状态下各个特征云分布模型,并依此构造出轴承故障的云判断知识库。同时,引入 Relief-F 算法确定训练集各特征的权重系数,结合云分布隶属度系数,提出了样本对于轴承故障的最终隶属度计算方法。通过根据不同数目的训练样本建立的云分类知识库在分类精度上的对比,证明了该方法具备对数据的学习能力。将该分类方法与常用的分类方法在含有噪声的测试样本上进行对比实验,证明了该分类方法在抗噪性方面的优越性。

关键词 滚动轴承;故障识别;云理论;隶属度

中图分类号 TH165+.3; TP391; TP18

引言

轴承是保证旋转机械正常运转的重要部件之一,准确发现轴承故障并辨识其类型,可以为整个机组及时制定检修计划提供可靠的理论指导^[1]。近年来,大数据处理技术成为新的研究热点之一,其通过寻找设备提供的信息和状态之间的关联关系,为提高设备异常状态检测的准确率提供了新的思路和方法^[2]。云理论属于大数据处理方式的一种,该方法通过构造特定的算子实现定性概念和定量指标之间的转换,将其用于数据挖掘,可以实现对关联规则和预测知识的发现^[3-5]。同时,云理论在调度决策、负荷预测和状态评估等方面得到了较为广泛的应用。文献[6]提出一种基于云模型和粗糙集的配电网空间负荷预测方法,并用实例验证了该方法的有效性。张满银等^[7]为解决传统评价方法存在人为主观性过强的问题,提出一种基于云理论的评价模型,并将其用于油气管道的滑坡危险性评价,结果证明,基于云模型的评价方法提高了最终结果的精确性和合理性。

笔者构建了一种结合云理论和 Relief-F 算法的滚动轴承故障诊断模型。首先,将滚动轴承数据集中的训练样本经归一化,并构建不同状态下所对应的各特征值的分布云模型;其次,通过 Relief-F 算法确定故障数据中各特征的权重系数,并结合云模型

确定样本对不同故障类型的最终隶属度;最后,将该模型应用于滚动轴承的故障识别,并通过实验验证了方法的有效性。

1 相关理论

1.1 云理论及其指标

假设 U 为一个可以用精确数值表示的论域(维数可以为一维或多维), H 为论域 U 对应的定性概念, $\forall x$ 且 $x \in U$, 都存在一个具有稳定倾向的随机数 $y(y = \mu_H(x))$, 称 y 为 x 对定性概念 H 的确定度, x 在论域 H 上的分布称为云模型,简称云^[8-9]。云的数字特征用期望 E_x 、熵 E_n 和超熵 H_c 表征,这是定性概念的定量表示,对于理解定性概念的内涵有重要意义。

1.2 改进的逆向云发生器

云发生器主要分为正向云发生器和逆向云发生器 2 种^[10-11]。正向云发生器是从定性到定量的映射,根据云的 3 个数字特征 (E_x, E_n, H_c) 产生云滴 (x, y) 。逆向云发生器实现从定量值到定性概念的转换,可以将云滴 (x, y) 转换为以数字特征 (E_x, E_n, H_c) 表示的定性概念。云发生器模型如图 1 所示。由于现实中代表概念确定度的 y 值并没有给出或难以获得,故传统的逆向云算法难以向更高维推广。针对该问

* 国家自然科学基金资助项目(51675253);兰州理工大学红柳一流学科建设资助项目

收稿日期:2019-08-29;修回日期:2019-10-08




图1 云发生器模型

Fig.1 The model of cloud generator

题,文献[12]引入了一种无需确定度 y 的逆向云算法。该算法不仅简单,更易于向高维推广,且精度比原来的逆向云算法高。

新的逆向云算法流程如下。

- 1) 输入无需确定度的云滴 $x_i (i = 1, 2, \dots, N)$;
- 2) 输出表示云滴 x_i 定性概念的期望值 E_x 、熵 E_n 和超熵 H_e 。

$$E_x = \bar{X} \quad (1)$$

$$E_n = \sqrt{\frac{\pi}{2}} \times \frac{1}{N} \sum_{i=1}^N |x_i - E_x| \quad (2)$$

$$H_e = \sqrt{S^2 - E_n^2} \quad (3)$$

其中:样本均值 $\bar{X} = \frac{1}{N} \sum_{i=1}^N x_i$; $\frac{1}{N} \sum_{i=1}^N |x_i - \bar{X}|$ 为样本一阶中心距;样本方差 $S^2 = \frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{X})^2$ 。

2 基于云理论的故障分类模型建立

2.1 滚动轴承振动信号的特征提取

测试得到滚动轴承 NSK6308 在滚动体故障、保持架故障、内圈故障、外圈故障和正常情况下共 5 种状态的振动信号各 80 组(训练样本为 60 组,测试样本为 20 组)。采样转速为 3 kr/min,采样频率为 8 kHz。采样通道共 5 个,其中:1~3 号通道利用加速度传感器测取故障轴承所在轴承座 3 个方向的振动加速度信号;4~5 号通道利用电涡流传感器测取与故障轴承直接连接的轴径向振动信号。图 2 为双跨双转子综合故障模拟平台。图 3 为故障轴承安装端。各状态下滚动轴承的振动信号如图 4 所示。

表 1 为通道 i 构造的原始特征集 ($i=1, 2, 3, 4,$




图2 双跨双转子综合故障模拟平台

Fig.2 The double-span double-rotor integrated fault simulation platform




图3 故障轴承安装端

Fig.3 Fault bearing mounting end




图4 各状态下滚动轴承的振动信号

Fig.4 Vibration signal of rolling bearing under different conditions

表 1 通道 i 构造的原始特征集

Tab.1 The original feature set for the channel i

序号	特征	序号	特征
1	峰峰值	7	频谱二阶矩
2	波形指标	8	标准偏差频率
3	峰值指标	9	峭度频率
4	脉冲指标	10	均方根频率
5	裕度指标	11	中心频率
6	峭度指标		

5)。将原始振动信号经一维小波消噪后,按表 1 所示提取故障特征。由于有 5 个通道,所以可得到 $5 \times 11 = 55$ 维的特征。至此,原始的滚动轴承状态特征数据集构造完毕。为了云模型的表达和分类方便,将原始数据集进行归一化,归一化区间为 $[-1, 1]$,后续操作的数据集全部为经过归一化之后的滚动轴承状态数据集。为在可视化阶段能区分不同特征,

将表 1 中的 11 种故障特征用不同三原色 (red green blue, 简称 RGB) 值的颜色表示, 如图 5 所示。




图 5 各颜色所代表的特征

Fig.5 Features represented by different colors

2.2 不同状态下各特征的分布云模型建立

依据所提的改进逆向云算法计算滚动轴承在不同状态下各个特征的期望、熵和超熵, 将此 3 个定性指标作为正向云发生器的输入, 并产生含有隶属度 (确定度) 的云滴, 产生的云滴个数为 1 000 (云滴个数的选取参见文献 [13])。依照这些云滴构建出不同状态下各个特征的云模型, 如表 2 所示。表 2 中: C 为云模型; $C_{m,j}$ 为在滚动体故障、保持架故障、内圈故障、外圈故障和正常这 5 种状态下的第 j 个特征的云模型; m 为 1~5 种故障状态; j 为特征序号, 且 $j=1, 2, \dots, 55$ 。由表 2 可知, 每一种状态的云知识库中储存的是轴承在该状态下振动信号的 55 个特征云。

表 2 不同状态下各个特征的云模型

Tab.2 Cloud models of various characteristics in different states

故障状态	特征序号 j			
	1	2	...	55
滚动体故障	$C_{1,1}$	$C_{1,2}$	$C_{1,j}$	$C_{1,55}$
保持架故障	$C_{2,1}$	$C_{2,2}$	$C_{2,j}$	$C_{2,55}$
内圈故障	$C_{3,1}$	$C_{3,2}$	$C_{3,j}$	$C_{3,55}$
外圈故障	$C_{4,1}$	$C_{4,2}$	$C_{4,j}$	$C_{4,55}$
正常状态	$C_{5,1}$	$C_{5,2}$	$C_{5,j}$	$C_{5,55}$

以图 6 所示的外圈故障下通道 1 振动信号的频谱二阶矩的云模型为例, 来说明如何根据数字特征 (E_x, E_n, H_e) 建立一个云模型, 其中: E_x 为该特征在外圈故障下的期望值, 可以将该值视为云的中心; E_n 为特征值属于外圈故障的确定程度; H_e 为云层的厚度, 反应了该特征值的随机性和模糊性。




图 6 外圈故障下通道 1 振动信号的频谱二阶矩云模型

Fig.6 The cloud model of spectrum second-order moment of channel 1 vibration signal in the state of outer ring fault

图 7 为 5 种状态下通道 1 中信号的各特征分布云模型, 图例的设置如图 5 所示。图 8 为 5 种状态下通道 1 振动信号的峭度频率分布云。图 6~8 中, 各特征值经归一化后均为无量纲量。

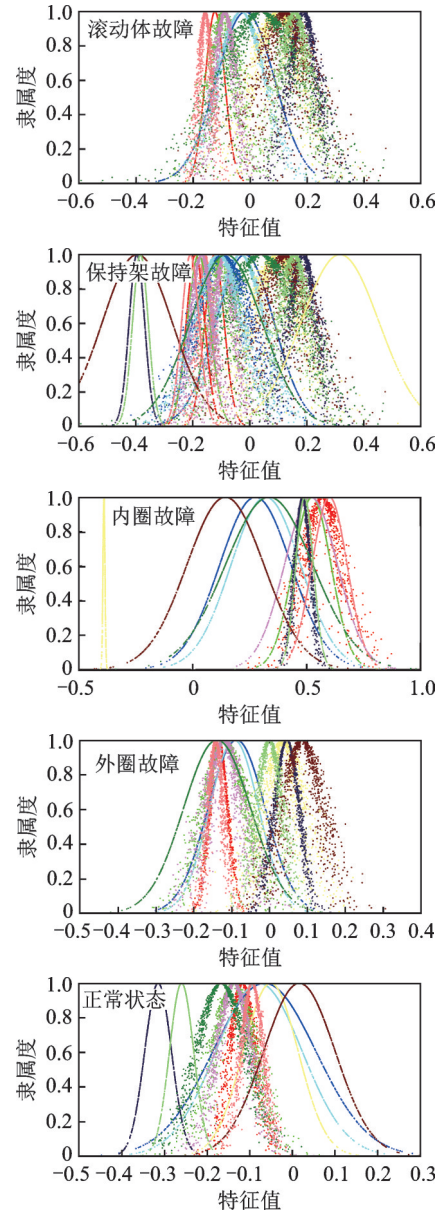


图 7 5 种状态下通道 1 中信号各特征分布云模型

Fig.7 The distribution cloud model of each feature in channel 1 under 5 conditions




图 8 5 种状态下通道 1 振动信号的峭度频率分布云

Fig.8 Kurtosis frequency distribution cloud from channel 1 vibration signal in five states

2.3 计算测试样本对不同状态的隶属度

取任意测试样本 N_k , 计算其特征 $F_{k,j}$ 与不同状态下对应特征分布云之间的分隶属度, 计算公式为

$$\mu_{m,j} = \exp \left[\frac{-(F_{k,j} - E_{x,m,j})^2}{2(E'_{n,m,j})^2} \right] \quad (4)$$

其中: $\mu_{m,j}$ 为待测样本 N_k 的第 j 个特征在状态 m 中与对应特征云的隶属度; $m=1, 2, 3, 4, 5$; $F_{k,j}$ 为测试样本 N_k 的第 j 个特征的值; $E_{x,m,j}$ 为状态 m 中第 j 个特征的期望值; $E'_{n,m,j}$ 为状态 m 中第 j 个特征的等效方差, 是以状态 m 中第 j 个特征的 E_n 为期望、 H_e 为标准差生成的一个正态随机数, 由正向云发生器自动产生; 分隶属度向量 $U_m = (\mu_{m,1}, \mu_{m,2}, \dots, \mu_{m,55})$ 。

2.4 特征评估及最终隶属度的确定

Relief-F 算法为 Relief 算法的扩展, 主要应用于多类数据的特征评估^[14], 此方法会根据指定的评价准则为每个特征赋予一个适当的权重。Relief-F 算法的主要思想是: 一个特征重要与否, 取决于其是否可以使同类的样本距离近而不同类的样本距离远。图 9 为笔者采用 Relief-F 算法得到的滚动轴




图 9 各特征的权重分布

Fig.9 Weight distribution of each feature

承数据集中各特征的权重分布, $W = (\omega_1, \omega_2, \dots, \omega_{55})$ 。

2.3 节仅计算得到样本 N_k 的各特征在 5 种状态下对应特征云的分隶属度(分确定度) U_m , 而模型建立的最终目的是判断任意样本 N_k 是否属于状态 m 。笔者根据 Relief-F 算法得到特征权重 W , 并结合已经得到的分隶属度 U_m , 定义最终的隶属度计算公式为

$$S_m = U_m W^T = \sum_{j=1}^{55} \mu_{m,j} \omega_j \quad (5)$$

其中: S_m 为样本 N_k 对于 5 种状态的最终隶属度; $m=1, 2, 3, 4, 5$ 。

3 实验结果及分析

3.1 识别结果

根据求得样本 N_k 对于各状态的最终隶属度 S , $S = (S_1, S_2, S_3, S_4, S_5)$, 将所得样本 N_k 对 5 种状态的最终隶属度进行归一化, 得到 $S'_m = S_m / \sum_{m=1}^5 S_m$, 使得 $\sum_{m=1}^5 S'_m = 1$, 最终选取归一化隶属中最大的 S'_m 对应的状态 m 为样本 N_k 的最终状态归属。

将本研究构建的分类器命名为云理论 (cloud theory, 简称 CT) 分类器。表 3 为部分样本的隶属度测试结果。表 4 为 CT 分类器、极限学习机 (extreme learning machine, 简称 ELM)、k 近邻 (k-nearest neighbor, 简称 KNN) 分类器和误差反向传播神经网络 (back propagation neural network, 简称 BPNN) 这 4 种分类器的识别准确率。实验数据为 3 kr/min 下的轴承状态数据集。

表 3 部分样本的隶属度测试结果

Tab.3 The membership test results of some samples

测试样本序号	状态 m 的隶属度					预测结果	实际结果
	$m=1$	$m=2$	$m=3$	$m=4$	$m=5$		
1	0.442 178	0.131 990	0.128 795	0.174 080	0.122 957	滚动体故障	滚动体故障
5	0.443 510	0.128 029	0.120 059	0.187 075	0.121 345	滚动体故障	滚动体故障
21	0.211 508	0.479 976	0.071 086	0.084 967	0.152 463	保持架故障	保持架故障
25	0.208 343	0.525 901	0.059 905	0.073 659	0.132 193	保持架故障	保持架故障
41	0.093 416	0.051 709	0.650 412	0.079 927	0.124 536	内圈故障	内圈故障
45	0.097 600	0.047 487	0.649 890	0.084 475	0.120 548	内圈故障	内圈故障
61	0.257 981	0.128 723	0.084 077	0.398 404	0.130 815	外圈故障	外圈故障
65	0.281 919	0.129 980	0.082 711	0.370 233	0.135 158	外圈故障	外圈故障
81	0.152 491	0.120 293	0.122 107	0.190 528	0.414 581	正常状态	正常状态
85	0.151 175	0.123 438	0.115 867	0.194 326	0.415 194	正常状态	正常状态

表4 4种分类器的识别准确率

Tab.4 Comparison of recognition accuracy of four classifiers %

故障类型	分类器			
	CT	ELM	KNN	BPNN
滚动体故障	100	85	100	85
保持架故障	100	80	100	75
内圈故障	100	100	100	100
外圈故障	100	100	100	100
正常状态	100	100	100	100
平均准确率	100	93	100	92

根据表3和表4可知,笔者设计的云分类器与传统的分类方法相比具有较高的分类精度。

3.2 云分类器在变工况下的识别准确率

旋转机械在运行时其转速的变更比较频繁,而将不同工况下的故障区分开是衡量一个分类器泛化性能的重要手段。为了验证云分类器模型在不同工况下的识别能力,采集在2.6,2.8,3.0和3.2 kr/min 4种转速下5种状态的振动信号,以检验本研究方法的识别准确率,结果如表5所示。

表5 云分类器模型在4种转速下的识别准确率

Tab.5 The recognition accuracy of the cloud classifier model at four kinds of speeds %

状态 m	转速/($\text{kr}\cdot\text{min}^{-1}$)			
	2.6	2.8	3.0	3.2
1	100	100	100	100
2	100	100	100	100
3	100	100	100	100
4	100	100	100	100
5	100	100	100	100
平均准确率	100	100	100	100

表5表明,在不同工况下,本研究所建立的云分类器都能达到较好的识别精度。

3.3 训练样本数目对云分类器分类性能的影响

本研究在模型建立之前,已将训练集和测试集的数目确定。为了更好地验证笔者提出的CT分类器方法对数据的自学习能力,以2.8 kr/min下的轴承状态数据集作为研究对象,将不同训练样本数目下本研究方法、BP神经网络和ELM这3种方法的分类准确率进行了对比。在实验过程中,测试集数目始终保持每种状态20组不变,训练集从每组10个开始增加,增量为10,直至到60。3种方法的分类准确率如图10所示。可见,在训练样本很少时,本

研究提出的云分类方法就可以达到较高的识别精度,对数据具有较强的学习能力。




图10 3种方法的分类准确率

Fig.10 Classification accuracy of three methods

3.4 云分类器鲁棒性验证

为了验证本研究提出的云分类器的鲁棒性,以3.2 kr/min下的数据集为操作对象,给其测试样本添加一定量的随机扰动,模拟含噪情况下的测试集。扰动矩阵定义为 $M=0.1 \text{ rand}(m, n)$,其中: m 为测试样本数; n 为特征维数; rand 为一个随机数生成函数,生成的随机数范围为 $[0, 1]$ 。在不同状态下将本研究方法、极限学习机、BP神经网络和支持向量机(support vector machine, 简称SVM)这4种方法的鲁棒性进行对比,如表6所示。可见,笔者设计的云分类器鲁棒性较好,具有一定的实际应用价值。

表6 4种分类器鲁棒性对比

Tab.6 Comparison of robustness among four classifiers %

状态 m	分类器			
	CT	ELM	BPNN	SVM
1	100	70	92	100
2	80	90	88	95
3	100	100	99	95
4	95	55	72	90
5	100	100	84	95
平均准确率	95	83	87	95

4 结 论

1) 云分类方法具有良好的泛化性,能准确识别不同工况下的轴承状态。该方法不仅对数据有较强的学习能力,还可准确识别出含噪声样本的类别。

2) 本研究所设计的分类器更加直观明了,易于操作,并兼顾了研究对象的随机性和模糊性。该研究结果可为监测含滚动轴承的设备提供指导。

参 考 文 献

- [1] 何俊,杨世锡,甘春标.一类滚动轴承振动信号特征

- 提取与模式识别[J]. 振动、测试与诊断, 2017, 37(6): 1181-1186.
- HE Jun, YANG Shixi, GAN Chunbiao. Feature extraction and pattern recognition of vibration signals in a rolling bearing [J]. Journal of Vibration, Measurement & Diagnosis, 2017, 37(6): 1181-1186. (in Chinese)
- [2] 李德毅, 刘常昱, 杜鹃, 等. 不确定性人工智能[J]. 软件学报, 2004, 15(11): 1583-1594.
- LI Deyi, LIU Changyu, DU Yi, et al. Artificial intelligence with uncertainty [J]. Journal of Software, 2004, 15(11): 1583-1594. (in Chinese)
- [3] TORABZADEH E, ZANDIEH M. Cloud theory-based simulated annealing approach for scheduling in the two-stage assembly flowshop [J]. Advances in Engineering Software, 2010, 41(10/11): 1238-1243.
- [4] JIANG Y, JIANG J, ZHANG Y. A novel fuzzy multiobjective model using adaptive genetic algorithm based on cloud theory for service restoration of shipboard power systems [J]. IEEE Transactions on Power Systems, 2012, 27(2): 612-620.
- [5] 周濂, 王时征, 廖瑞金, 等. 基于AdaBoost优化云理论的变压器故障诊断方法[J]. 高电压技术, 2015, 41(11): 3804-3811.
- ZHOU Quan, WANG Shizheng, LIAO Ruijin, et al. Power transformer fault diagnosis method based on cloud model of AdaBoost algorithm [J]. High Voltage Engineering, 2015, 41(11): 3804-3811. (in Chinese)
- [6] 杨薛明, 苑津莎, 王剑锋, 等. 基于云理论的配电网空间负荷预测方法研究[J]. 中国电机工程学报, 2006, 26(6): 30-36.
- YANG Xueming, YUAN Jinsha, WANG Jianfeng, et al. A new spatial forecasting method for distribution network based on cloud theory [J]. Proceedings of the CSEE, 2006, 26(6): 30-36. (in Chinese)
- [7] 张满银, 王生新, 孙志忠, 等. 基于云理论的油气管道滑坡危险性综合评价[J]. 工程科学学报, 2018, 40(4): 427-437.
- ZHANG Manyin, WANG Shengxin, SUN Zhizhong, et al. Comprehensive evaluation of landslide risks of oil and gas pipelines based on cloud theory [J]. Chinese Journal of Engineering, 2018, 40(4): 427-437. (in Chinese)
- [8] 于少伟, 史忠科. 基于正态分布区间数的逆向云新算法[J]. 系统工程理论与实践, 2011, 31(10): 2021-2026.
- YU Shaowei, SHI Zhongke. New algorithm of backward cloud based on normal interval number [J]. Systems Engineering-Theory & Practice, 2011, 31(10): 2021-2026. (in Chinese)
- [9] 徐昕军, 杨峰. 基于SPA和云理论的城市地下病害风险评估模型[J]. 工程科学与技术, 2018, 50(3): 224-232.
- XU Xinjun, YANG Feng. Risk assessment model of urban underground diseases based on SPA and cloud theory [J]. Advanced Engineering Sciences, 2018, 50(3): 224-232. (in Chinese)
- [10] 傅鹤林, 黄震, 黄宏伟, 等. 基于云理论的隧道结构健康诊断方法[J]. 工程科学学报, 2017, 39(5): 794-801.
- FU Helin, HUANG Zhen, HUANG Hongwei, et al. Health diagnosis method of shield tunnel structure based on cloud theory [J]. Journal of Engineering Science, 2017, 39(5): 794-801. (in Chinese)
- [11] 赵静, 王崇倡, 王家海, 等. 基于云理论的遥感影像分类方法分析[J]. 测绘工程, 2014, 23(12): 21-24.
- ZHAO Jing, WANG Chongchang, WANG Jiahai, et al. Remote sensing image classification method based on cloud theory [J]. Engineering of Surveying and Mapping, 2014, 23(12): 21-24. (in Chinese)
- [12] 关山, 康振兴, 彭昶. 基于云理论与LS-SVM的刀具磨损识别方法[J]. 振动、测试与诊断, 2017, 37(5): 996-1003.
- GUAN Shan, KANG Zhenxing, PENG Chang. Method of tool wear recognition based on cloud theory and LS-SVM [J]. Journal of Vibration, Measurement & Diagnosis, 2017, 37(5): 996-1003. (in Chinese)
- [13] 谢鹏, 吕鹏飞. 基于改进云模型-IAHP的涉爆粉尘企业安全风险评估[J]. 中国安全生产科学技术, 2018, 14(8): 187-192.
- XIE Peng, LÜ Pengfei. Assessment on safety risk of enterprises involved in explosive dust based on improved cloud model and IAHP [J]. Journal of Safety Science and Technology, 2018, 14(8): 187-192. (in Chinese)
- [14] HUANG L L, TANG J, SUN D D, et al. Feature selection algorithm based on multi-label Relief-F [J]. Journal of Computer Applications, 2012, 32(10): 2888-2890.



第一作者简介:马森财,男,1994年7月生,硕士生。主要研究方向为旋转机械故障诊断。

E-mail: masencaibangong@163.com

通信作者简介:赵荣珍,女,1960年12月生,博士、教授、博士生导师。主要研究方向为旋转机械故障诊断和动态测试技术。

E-mail: zhaorongzhen@lut.cn