

文章编号:1671-251X(2017)05-0050-04 DOI:10.13272/j.issn.1671-251x.2017.05.012
公茂法,郭一萱,闫鹏,等.采煤机滚动轴承故障诊断新方法[J].工矿自动化,2017,43(5):50-53.

采煤机滚动轴承故障诊断新方法

公茂法, 郭一萱, 闫鹏, 吴娜, 张超

(山东科技大学 电气与自动化工程学院, 山东 青岛 266590)

摘要:针对基于K-means聚类算法的采煤机滚动轴承故障诊断结果存在不稳定的问题,提出了一种基于TDKM-RBF神经网络的采煤机滚动轴承故障诊断新方法。该方法采用Tree Distribution算法确定K-means聚类算法的初始聚类中心,消除K-means聚类结果的波动性,采用K-means算法确定RBF神经网络的参数,再将训练好的神经网络用于故障诊断。仿真结果表明,该方法的聚类过程迅速,稳定性较高,提高了采煤机滚动轴承故障诊断的正确率。

关键词:采煤机;滚动轴承;故障诊断;波动性;径向基核函数;K-means聚类算法;TD算法

中图分类号:TD632 文献标志码:A 网络出版时间:2017-04-25 18:07

网络出版地址:<http://kns.cnki.net/kcms/detail/32.1627.TP.20170425.1807.012.html>

A new fault diagnosis method of rolling bearing of shearer

GONG Maofa, GUO Yixuan, YAN Peng, WU Na, ZHANG Chao

(College of Electrical Engineering and Automation, Shandong University of
Science and Technology, Qingdao 266590, China)

Abstract: In view of unstable problem existed in fault diagnosis result for rolling bearing of shearer based on K-means clustering algorithm, a new fault diagnosis method of rolling bearing of shearer based on TDKM-RBF neural network was proposed. The method adopts Tree Distribution algorithm to determine initial clustering center of the K-means clustering algorithm, so as to eliminate volatility of K-means clustering results. The method uses K-means algorithm to determine the parameters of the RBF neural network, then the trained neural network was used for fault diagnosis. The simulation results show that the method has quick clustering process, higher stability, and obviously improves accuracy of fault diagnosis for rolling bearing of shearer.

Key words: shearer; rolling bearing; fault diagnosis; volatility; RBF; K-means clustering algorithm; TD algorithm

0 引言

采煤机是矿井下的重要设备,滚动轴承是采煤机的重要部件,在外界的巨大冲击下易发生故障。据不完全统计,旋转机械的故障有30%来自于滚动轴承,为确保采煤机安全稳定运行,需要对滚动轴承的故障做出快速、高效的诊断。

目前,国内外提出了一系列的采煤机滚动轴承的故障诊断方法,如基于时频的故障诊断方法^[1-2],基于专家系统的故障诊断方法^[3-4],基于解析模型^[5]和基于神经网络的故障诊断方法^[6-8]等。文献[4]将专家系统成功应用到滚动轴承故障诊断研究中,但该方法推理速度慢、知识库维护管理困难。文献[5]运用了状态估计方法对滚动轴承进行故障诊断,但滚动轴承在运行过程中会产生大量的数据,影响诊

收稿日期:2016-11-15;修回日期:2017-01-17;责任编辑:张强。

基金项目:山东省自然科学基金项目(ZR2012EEM021)。

作者简介:公茂法(1959—),男,山东蒙阴人,教授,博士研究生导师,主要研究方向为电气测量技术、信号检测技术、电力系统及其自动化, E-mail:1520837108@qq.com。

断效率。基于神经网络的故障诊断方法具有优越的容错、处理模糊数据、自学习和处理多种复杂模式等能力,其中径向基核函数(Radial Basis Function, RBF)神经网络以其稳定快速的全局非线性逼近能力在近几年得到了广泛应用。RBF神经网络的构建关键是对径向基函数的中心、宽度和输出权值进行优化。目前有 2 类参数构建方法:一类是采用非监督方法得到径向基函数的中心和宽度,采用监督算法得到输出层权值^[9-10];另一类是直接采用监督算法得到这 3 个参数^[11-12]。第 1 类方法用 K-means 聚类算法确定径向基函数的中心和宽度,然后采用最小二乘算法(LMS)得到输出权值,该方法已成功应用到滚动轴承的故障诊断中^[11]。本文在文献[11]的基础上,将 TDKM(Tree Distribution K-means)算法引入到基于 RBF 神经网络的故障诊断过程中,提出了一种基于 TDKM-RBF 神经网络的采煤机滚动轴承故障诊断新方法,即用 TD 算法确定 K-means 算法的初始聚类中心^[13],消除 K-means 聚类结果的波动性,用 K-means 算法确定 RBF 神经网络的参数,再将训练好的神经网络用于故障诊断。仿真结果表明,与基于传统 RBF 神经网络的故障诊断方法相比,基于 TDKM-RBF 神经网络的故障诊断方法降低了聚类过程中的迭代次数,缩短了聚类时间,明显提高了故障诊断的正确率。

1 TDKM 优化 RBF 神经网络的训练方法

1.1 TD 算法

TD 算法的基本思想是按照样本数据集合的距离均值剔除样本中的噪声样本,在新的样本数据集合的基础上构造最小生成树。

设数据样本集 $D(m_1, m_2, \dots, m_N)$ 中含有 N 个样本,每个样本均含有 l 个特征向量,根据式(1)计算 D 中任意 2 个样本 $m_i(p_1^i, p_2^i, \dots, p_l^i)$ 和 $m_j(p_1^j, p_2^j, \dots, p_l^j)$ 之间的欧氏距离 d_{ij} ,根据 d_{ij} 即可得到样本空间中两两样本的距离矩阵 $\mathbf{B}$,如式(2)所示。将距离矩阵 $\mathbf{B}$ 中的每列取平均值得到每个样本与其他所有样本距离的均值矩阵 $\mathbf{A}$,如式(3)所示。

$$d_{ij} = \sqrt{(p_1^i - p_1^j)^2 + (p_2^i - p_2^j)^2 + \dots + (p_l^i - p_l^j)^2} \quad 1 \leq i, j \leq N \quad (1)$$

$$\mathbf{B} = \begin{bmatrix} d_{11} & d_{21} & \dots & d_{N1} \\ d_{12} & d_{22} & \dots & d_{N2} \\ \vdots & \vdots & \vdots & \vdots \\ d_{1N} & d_{2N} & \dots & d_{NN} \end{bmatrix} \quad (2)$$

$$\mathbf{A} = [a_1, a_2, \dots, a_N] \quad (3)$$

式中 $a_i = (d_{i1} + d_{i2} + \dots + d_{iN})/N$, $1 \leq i \leq N$ 。

样本空间 D 中的某一个样本与其他样本之间的欧氏距离之和的均值 c 的计算公式如下:

$$c = \left(\sum_{i=1}^N a_i \right) / N \quad (4)$$

将样本空间距离之和的均值大于 c 的样本数据点作为样本空间 D 的噪声点并将其剔除,重新计算样本之间的欧氏距离,再计算每个样本与其他所有样本的距离均值,形成新的矩阵 $\mathbf{A}$ 。对 $\mathbf{A}$ 进行多次扫描,按照两两样本间的最小距离生成最小生成树,再按两两样本间的最大距离进行 $K-1$ 次降序剪枝,得到 K 个子树,最后对各个子树中的样本特征向量求均值得到 K 个初始聚类中心 u_i ($1 \leq i \leq k$)。

1.2 TD 优化的 K-means 算法

K-means 算法^[14-15]是一种基于 SSE(Sum of Squares for Error)的划分方法,其以快速的收敛速度、简洁的算法原理和高效的大数据处理能力得到了广泛的应用。样本集 D 分为 K 类, K 个初始聚类中心 $u_i(j)$ 可被任意选取, j 为迭代次数,初始值为 1, N 个样本数据被按照 SSE 的方法分到与其距离最小的聚类中心所属的类中,设第 i 类的样本为 $w_i(j)$, 样本数为 N_i , 重新按式(5)计算新的聚类中心。

$$u_i(j+1) = 1/N_i \sum_{x \in w_i(j)} x \quad (5)$$

得到新的聚类中心后,重新按照最小误差平方和的原则对样本重新进行分类,再按式(5)得到新的聚类中心,直到前后 2 次聚类中心的距离差达到一个很小的误差精度 ϵ ($\epsilon > 0$),如式(6)所示。

$$\|u_i(j+1) - u_i(j)\| < \epsilon \quad (6)$$

本文用 TD 算法确定初始聚类中心,根据以上公式得到剔除噪声点的距离矩阵之后,对其进行遍历,得到最小生成树,将树进行 $K-1$ 次降序剪枝得到 K 个子树,再对 K 个子树中样本的特征向量取均值,即得 K-means 算法的 K 个初始聚类中心。

1.3 TDKM 优化的 RBF 神经网络

得到聚类中心后,按照新的聚类中心与其最近聚类中心之间的距离来计算 RBF 神经网络隐含层径向基的宽度,如式(7)所示。

$$\sigma_i = kd_i, \quad d_i = \min_i \|u_j - u_i(k)\| \quad (7)$$

式中 k 为重叠系数。

确定了径向基函数的中心、宽度之后,再用 LMS 计算 RBF 神经网络的输出层权值。基于

TDKM-RBF 神经网络的故障诊断算法流程如图 1 所示。




图 1 基于 TDKM-RBF 神经网络的故障诊断算法流程

2 基于 TDKM-RBF 的故障诊断分析

2.1 故障诊断系统

采煤机滚动轴承故障诊断系统包括压电传感器、电荷放大器、数据采集系统和计算机。采煤机主要部件的振动信号通过压电传感器采集,经电荷放大器放大转换为电信号,由数据采集系统接收,再对这些原始数据进行小波分析和特征提取,最后在计算机上由基于 TDKM-RBF 神经网络的故障诊断算法对采集到的数据进行故障分类。根据故障发生位置的不同,滚动轴承故障可分为滚动轴承内圈故障、滚动体故障、外圈故障 3 种^[16]。本文将故障诊断系统收集到的 64 组数据作为 TDKM-RBF 神经网络的训练及测试数据,将采集的振动信号利用 *coif5* 进行 3 层小波包分解,提取第 3 层的 8 个频带的小波包能量谱尺度作为样本的 8 个特征向量。采用试凑法确定隐含层层数为 10 层,构造出结构为 8-10-4 的 RBF 神经网络,再根据 TDKM 算法确定的径向基函数的参数自动完成训练。RBF 神经网络拓扑结构如图 2 所示。

参数设置:K-means 算法的误差精度 ϵ 取 10^{-3} ,重叠系数 k 取 1。RBF 神经网络的径向基函数的类型为高斯函数,权值训练的逼近误差 MSE 取 10^{-3} 。

2.2 样本仿真及结果分析

采用仿真软件 Matlab R2014a 对 64 组滚动轴




图 2 RBF 神经网络拓扑结构

承故障数据进行仿真,其中训练数据为 32 组,测试数据为 32 组,具体样本的故障类型见表 1。

表 1 样本的故障类型

测试样本编号	训练样本编号	故障类型
1—8	33—40	正常运行
9—16	41—48	轴承内圈故障
17—24	49—56	轴承滚动体故障
25—32	57—64	轴承外圈故障

采用 TD 算法得到 32 组训练数据的两两样本的距离矩阵和样本间欧氏距离的均值矩阵 A ,剔除训练数据中的噪声样本:第 33—40 组,第 44 组,第 45 组数据,形成新的距离矩阵 A ,按照最小距离原则对其进行遍历,生成最小生成树,再进行 3 次剪枝得到 4 个子树,分别对 4 个子树中的样本求取均值得到 4 个类的初始聚类中心。将这种采用 TDKM 算法确定初始聚类中心的方案与以下 2 种任意选取初始聚类中心的方案作对比。

方案 1:在 4 类运行模式下,任意选取 32 组训练样本中的 1 个样本作为一组初始聚类中心。

方案 2:在正常运行模式下,任意选取 32 组训练样本中的 4 个样本作为一组初始聚类中心。

将这 3 种选取初始聚类中心的方法运用到 K-means 聚类算法中进行迭代直到误差精度 ϵ 为 10^{-3} ,3 种方案的迭代步数如图 3 所示。




图 3 3 种方案的迭代步数

将这 3 种方案得到的聚类中心运用到基于 RBF 神经网络的故障诊断算法中,最终得到各类运

行模式下的诊断识别率,见表 2,对应的均方误差及运行时间见表 3。

表 2 3 种方案的诊断识别率

初始聚类 中心确定 方案	各运行模式下的识别率/%				总识别 率/%
	正常 运行	轴承内 圈故障	轴承滚动 体故障	轴承外 圈故障	
方案 1	87.5	37.5	100	100	81.25
方案 2	100	62.5	100	12.5	68.75
TDKM 算法	87.5	100	100	100	96.875

表 3 3 种方案的均方误差及运行时间

初始聚类中心确定方案	均方误差	运行时间/s
方案 1	9.125×10^{-5}	1.250
方案 2	1.2015×10^{-4}	1.150
TDKM 算法	2.6151×10^{-5}	0.848

对比方案 1 和方案 2,虽然方案 2 的迭代步数仅为方案 1 的 40%,但是识别率低至 68.75%。方案 1 的识别率虽高至 81.25%,但是迭代步数为 10,耗时间较长。可见,若用传统的 K-means 算法,故障识别率和运行时间均会有较大的波动。

由表 3 可知,3 种方案均达到误差精度 ϵ 要求,与方案 1 和方案 2 相比,TDKM 算法得到的聚类中心与达到迭代精度的聚类中心十分接近,仅需 3 次迭代即达迭代精度,且运行速度最快仅需 0.848 s。根据表 2 可知,该算法对轴承内圈、滚动体和外圈的故障识别率为 100%,整体识别率高达 96.875%,运行时间仅为传统 K-means 算法的 40%。经多次试验,其迭代步数始终为 3 步,且故障识别率维持在 96.875%不变。

由此可见,TDKM 算法的聚类过程迅速,故障识别率和稳定性都非常高。基于 TDKM 算法的神经网络故障诊断系统,解决了传统 K-means 聚类算法中的诊断结果的波动问题,提升了故障诊断的正确率。

3 结语

采煤机滚动轴承故障诊断新方法采用 TD 算法优化 K-means 聚类算法,消除了聚类结果的不稳定性。仿真结果表明,该故障诊断方法比基于传统 K-means 神经网络的诊断方法有更快的故障识别速度、更高的故障识别率和更好的稳定性,成功解决了

故障诊断结果的波动性问题,为采煤机滚动轴承的故障诊断提供了一种新方法。

参考文献:

[1] 崔宝珍. 基于小波分析的滚动轴承故障诊断方法研究与应用[D]. 太原:中北大学,2005.

[2] 胡爱军,马万里,唐贵基. 基于集成经验模态分解和峭度准则的滚动轴承故障诊断特征提取方法[J]. 中国电机工程学报,2012,32(11):106-111.

[3] 徐同乐,陈武勤. 基于专家系统滚动轴承故障诊断研究[J]. 煤矿机械,2010,31(11):234-236.

[4] 赵志宇,邵诚,于云满. 基于小波变换的滚动轴承故障诊断专家系统的研究[J]. 机械设计与研究,2005,21(1):50-52.

[5] 李卉. 基于状态监测的滚动轴承性能退化评估[D]. 大连:大连工业大学,2015.

[6] 胡耀斌,厉善元,胡良斌. 基于神经网络的滚动轴承故障诊断方法的研究[J]. 机械设计与制造,2012(2):187-189.

[7] 孙旺旺,任传胜,朱春伟. 基于模糊 RBF 神经网络的滚动轴承故障诊断[J]. 机械研究与应用,2013,26(2):13-14.

[8] 张应红,李聪,景晖,等. 基于人工神经网络技术的矿用皮带机滚动轴承故障诊断[J]. 机床与液压,2014,42(3):180-183.

[9] 谢振平,刘基宏,王士同. RBF 网络的鲁棒最小二乘算法[J]. 控制与决策,2010,25(4):502-506.

[10] 苏铁明,叶三排,孙伟. 基于 FCM 聚类和 RBF 神经网络的机床热误差补偿建模[J]. 组合机床与自动化加工技术,2011(10):1-4.

[11] 吴秋明. 基于 RBF 神经网络的故障诊断[D]. 镇江:江苏大学,2006.

[12] PENG J X, LI K, IRWIN G W. A novel continuous forward algorithm for RBF neural modelling[J]. IEEE Transactions on Automatic Control, 2007, 52(1):117-122.

[13] 冯波,郝文宁,陈刚,等. K-means 算法初始聚类中心选择的优化[J]. 计算机工程与应用,2013,49(14):182-185.

[14] 庞振,徐蔚鸿. 一种基于改进 K-means 的 RBF 神经网络学习方法[J]. 计算机工程与应用,2012,48(11):161-163.

[15] 赖玉霞,刘建平. K-means 算法的初始聚类中心的优化[J]. 计算机工程与应用,2008,44(10):147-149.

[16] 刘亚军. 基于小波分析和神经网络的电机故障诊断研究[D]. 太原:中北大学,2009.