

# 基于复杂网络聚类的提升机主轴系统故障诊断\*

董磊<sup>1,2</sup>, 石瑞敏<sup>1,2</sup>, 曾志强<sup>1,2</sup>

(1. 中北大学机械与动力工程学院 太原, 030051) (2. 先进制造技术山西省重点实验室 太原, 030051)

**摘要** 针对摩擦提升机主轴系统故障耦合、特征微弱且故障样本不易获得的问题, 提出一种基于复杂网络聚类的故障诊断方法。该方法从故障数据表现出社团结构的本质出发, 以各数据样本为节点, 样本间相似度为加权边, 构建加权无向复杂网络模型。将欧氏空间的距离概念推广到样本的相似性度量上提出广义 Ward 距离, 并以此为划分准则, 采用凝聚型合并过程实现网络模型中社团的聚类, 即故障样本的模式识别。对主轴系统过载、滚动轴承元件故障及减速器齿轮磨损的分析结果表明, 该方法能准确对已知故障类型数据进行聚类, 且在过程中不预设类别数, 为收集异常数据以便未知故障的发现与诊断提供了数据支持。与多元支持向量机与快速 Newman 算法的对比结果表明, 该方法具有更高的识别精度与效率。

**关键词** 复杂网络聚类; 社团结构; 故障诊断; 广义 Ward 距离; 主轴系统

**中图分类号** TH165.3

## 引 言

摩擦提升机具有结构紧凑、提升能力大、适宜深井以及提升效率高等优点, 已成为众多煤矿生产企业选用率较高的提升设备<sup>[1]</sup>。包括摩擦轮、衬垫、钢丝绳、主轴以及两侧轴承等部件的主轴系统是提升机的重要组成部分, 其运行的安全可靠不仅影响生产安全与生产效率, 还涉及到工作人员的生命安全<sup>[2]</sup>。因此, 对主轴系统进行在线监测与故障诊断具有重要的工程应用价值。对于提升系统中机械设备的故障诊断, 振动较其他检测与诊断信息能更迅速、直接地反映机械设备的运行状态。旋转部件的不对中、部件本身的缺陷与磨损或者运行状态的突变等都会引起异常振动。大量的生产实践经验表明, 机械设备的振动与其运行状态之间有着密切的关系<sup>[3]</sup>。相关部件故障、运行过程突发故障等都会通过振动信号反映出来。

目前, 针对主轴系统提出的诊断方法大多是利用现代信号处理技术对采集到的振动信号分析处理提取各部件的故障信息, 然后通过神经网络或支持向量机等模式识别技术进行故障诊断, 最后辅以良好的人机界面, 从而实现对手轴各部件的监测与故障诊断。乔国厚<sup>[4]</sup>提取主轴支撑轴承处振动信号功

率谱的子频带能量作为故障特征值, 采用径向基函数(radical basis function, 简称 RBF)神经网络对滚动轴承进行故障识别。葛森<sup>[5]</sup>分析了主轴系统的主要故障形式及其振动特性, 采用小波变换对非平稳故障信号进行分析, 开发了基于 LabVIEW 的实时监测与故障诊断系统。这些诊断方法大多针对特定部件, 未将主轴系统作为一个部件间相互影响的整体来分析。作为关系到生产与生命安全的重要设备, 主轴系统故障样本不易获得, 样本不完整或故障类型未知的情况时有发生, 使得模式识别方法常常面临缺乏先验知识的情况。

许多复杂系统都以复杂网络的形式存在, 或者能被转化成复杂网络进行处理<sup>[6]</sup>。对于故障诊断问题, 将单个数据样本作为节点, 样本间联系作为关系, 即可将数据样本全体抽象为复杂网络结构, 将故障诊断问题转化为故障数据网络的子网探测问题, 借鉴 Kernighan-Lin 算法、快速 Newman 算法或 Wu-Huberman 算法等复杂网络聚类方法实现故障模式识别<sup>[7]</sup>。孙斌等<sup>[8]</sup>构建了汽轮机转子三种故障振动信号的波动网络, 研究了转子振动信号的变化规律并通过网络统计特性分析准确诊断转子的振动故障。摩擦提升机主轴系统传递动力、承担载荷, 部件间具有耦合效应, 部件特征表现出非线性, 是难以建模的复杂系统, 很难从众多监测数据中提取有用

\* 山西省基础研究计划青年科技研究基金资助项目(2014021024-4); 中北大学科学研究基金资助项目(XJJ2016004)  
收稿日期: 2014-08-30; 修回日期: 2014-11-19

的故障信息。在小样本与故障类型未知的情况下,从有限的故障信息中得到故障诊断结果也非易事。

笔者提出一种基于复杂网络聚类算法的摩擦提升机主轴系统故障诊断方法。在分析主轴系统振动信号直接与间接所反映的故障信息的基础上,采用复杂网络社团结构描述故障数据,建立主轴系统故障数据网络模型,选用广义 Ward 距离为划分准则,通过自底向上的层次凝聚过程进行社团合并,达到聚类的目的。通过对某矿用摩擦提升机主轴系统过载、滚动轴承元件损坏及减速器齿轮磨损等类型故障的诊断结果分析表明,提出的基于复杂网络聚类算法的故障模式识别方法具有较高的诊断效率与正确率,可有效用于摩擦提升机主轴系统的故障诊断。

## 1 主轴系统故障网络模型及识别算法

### 1.1 摩擦提升机主轴系统故障网络模型

结合复杂网络聚类算法,提取监测数据中反映不同故障类型的特征参数构成故障样本集,以每个故障数据样本为节点,样本间相似度为有权边,构造主轴系统故障数据的加权无向复杂网络模型。

令  $n$  个反映主轴系统故障状态的数据样本组成集合  $\mathbf{X} = \{x_1, x_2, \dots, x_n\}$ , 每一样本由选取的  $m$  个特征值构成, 即  $x_i = \{x_{i1}, x_{i2}, \dots, x_{im}\}$ ,  $i = 1, 2, \dots, n$ , 将每个数据样本  $x_i$  视为网络中的节点, 基于复杂网络社团结构的故障诊断的目的即是各节点  $x_i$  按故障类型与程度划分成互不相交的社团, 使得同社团节点间联系紧密, 不同社团节点间联系疏离。节点  $x_i$  与  $x_j$  之间的联系可用相似度  $a_{ij}$  来表示, 对于向量形式的节点相似度可用节点间距离度量, 为满足聚类准则函数的要求, 笔者采用指数函数增强距离信息, 定义相似度函数为

$$a_{ij} = \begin{cases} \exp(-ed_{ij}^2) & (i \neq j) \\ 0 & (i = j) \end{cases} \quad (1)$$

其中:  $e$  为信息增强函数, 取正整数, 这里  $e$  取 10;  $d_{ij}$  采用欧式距离度量。

$n$  个节点间相似度组成相似度矩阵  $\mathbf{A}$  为

$$\mathbf{A} = \begin{bmatrix} a_{11} & a_{12} & \cdots & a_{1n} \\ a_{21} & a_{22} & \cdots & a_{2n} \\ \vdots & \vdots & & \vdots \\ a_{n1} & a_{n2} & \cdots & a_{nn} \end{bmatrix} \quad (2)$$

以故障数据样本集  $\mathbf{X}$  为网络节点, 各样本间相似度矩阵  $\mathbf{A}$  为加权边, 由此得到全体主轴系统故障

数据的加权无向网络  $\mathbf{G}(\mathbf{X}, \mathbf{A})$ 。

### 1.2 故障网络模型的评价函数及划分准则

社团结构是复杂网络的一种典型结构特性<sup>[9]</sup>, 表征了一种网络节点组织形式, 具有社团内部节点间连接密度高于社区之间的连接密度的特点<sup>[10]</sup>。结构模型如图 1 所示。

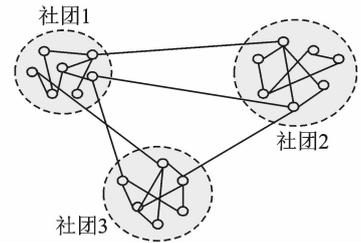


图1 复杂网络社团结构

Fig. 1 Community structure of complex network

故障数据复杂网络具有典型的社团结构特征, 同种类型的故障表现出相似的特征从而形成自然的社团, 社团内部节点拥有密切的相互关系, 可以将故障诊断问题转化为社团聚类问题, 使得每一社团代表一种故障类型, 反映同一故障的节点关系紧密且处于同一社团, 反映不同故障的节点关系稀疏且处于不同社团。即将故障网络模型  $\mathbf{G}(\mathbf{X}, \mathbf{A})$  中节点  $\mathbf{X}$  通过一定的划分准则划分为  $N$  个互不重叠的社团,  $k(\mathbf{X}) = \{C_1, C_2, \dots, C_N\}$ ,  $C_i \subset \mathbf{X}$ ,  $C_i \neq \phi$ ,  $\bigcup_{i=1}^N C_i = \mathbf{X}$ , 且  $C_i \cap C_j = \phi$ ,  $i, j = 1, 2, \dots, N$ ,  $i \neq j$ 。每一子集  $C_i$  代表一种故障类型, 故障诊断的关键在于寻找适当的划分准则使得社团内部相似度大, 社团间相似度小。令  $C_p$  和  $C_q$  为划分所得  $N$  个社团中的两个社团, 定义两个社团之间相似性测度<sup>[11]</sup>  $S_{pq}$  为

$$S_{pq} = \frac{\sum_{x_i \in C_p} \sum_{x_j \in C_q} a_{ij}}{\sum_{x_i \in X} \sum_{x_j \in X} a_{ij}} \quad (p, q = 1, 2, \dots, N) \quad (3)$$

当  $p=q$  时,  $S_{pp}$  表征了社团内节点间的相似度; 当  $p \neq q$  时,  $S_{pq}$  表征了社团  $C_p$  和  $C_q$  之间节点的相似度。根据分类目标  $\max(\sum_p S_{pp})$  和  $\min(\sum_{p \neq q} S_{pq})$ , 定义故障数据网络的模块性评价函数  $Q$  为

$$Q = \sum_{p=1}^N [S_{pp} - (\sum_{q=1}^N S_{pq})] \quad (4)$$

其中:  $\sum_{p=1}^N S_{pp}$  体现了社团内部节点的连接情况;  $\sum_{p=1}^N (\sum_{q=1}^N S_{pq})$  体现了社团间节点的连接情况。

较大的  $Q$  值表明社团内节点连接密度高而社团间节点连接少,因此可用  $Q$  值来评价社团划分结果的优劣<sup>[12]</sup>。

目前,大部分故障模式识别算法直接采用  $Q$  函数变化量作为社团划分准则,取得了较好的效果<sup>[13]</sup>。笔者针对主轴系统故障数据样本特征微弱分散等特点,提出一种广义 Ward 距离作为社团划分准则,较之  $Q$  函数变化量强化了社团整体与待识别节点间连接距离,提高局部判断精细性的同时具有相对简单的计算复杂度。

复杂网络社团结构中相似性测度  $S_{pq}$  度量了节点间的相似性,使得连接越多且排他性越强的社团具有较高的相似度,可以将其视作相似性高的社团具有较近的“距离”,这里的距离是相似性测度的一个减函数,即广义的社团距离。将传统 Ward 距离中欧氏距离用社团间“距离”,即相似性测度的单调减函数代替,得到社团间的广义 Ward 距离。传统 Ward 距离表征的是两个集合数据中心的欧式距离,反映了数据聚集的紧密程度。设有待合并的两个子社团  $C_p$  和  $C_q$ ,其传统 Ward 距离<sup>[14]</sup>为

$$d_w(C_p, C_q) = \frac{e_p e_q}{e_p + e_q} d(c_p, c_q) \quad (5)$$

其中:  $e_p$  为社团  $p$  中的节点个数;  $c_p$  为社团  $p$  的数据中心。

将社团间“距离”定义为相似性测度的单调减函数,使得相似性越高的节点距离越近,令

$$d_{pq} = 1 - \sqrt{S_{pq}} \quad (6)$$

将式(6)代替式(5)中的欧式距离,得到社团划分准则  $D_{pq}$  为

$$D_{pq} = \frac{e_p e_q}{e_p + e_q} (1 - \sqrt{S_{pq}}) \quad (7)$$

聚类过程将通过合并具有最小广义 Ward 距离的两个社团进行,充分考虑了社团内部与社团之间节点的连接情况,符合故障诊断的聚类目标。

### 1.3 基于广义 Ward 聚类的故障模式识别算法

实现加权无向网络的社团聚类方法有两种:自顶到下的分裂与自底向上的凝聚。分裂型算法在初始时刻将所有节点视为一个社团,然后每次将某个社团一分为二,而凝聚型算法则在初始时刻将每个节点划分为一个单独的社团,然后每次合并两个社团,最后将  $Q$  取值最大的划分作为社团聚类结果输出。本质上都是划分准则的变化,考虑到计算复杂度,笔者选取自底向上的合并聚类过程,从初始解(每个社团仅包含一个节点)开始,执行使广义

Ward 距离最小的两个社团合并操作,直至网络中只存在一个社团。

基于广义 Ward 聚类算法的故障模式识别过程步骤如下。

1) 输入故障数据训练样本集合  $\mathbf{X}$ ,根据式(1)~(2)计算所有训练样本两两之间的相似度  $a_{ij}$  与不同类型间样本相似性测度  $S_{pq}$ ;组成相似度矩阵  $\mathbf{A}$ ,建立故障数据训练样本的网络模型  $\mathbf{G}(\mathbf{X}, \mathbf{A})$ 。

2) 初始时刻将每个节点作为一个社团,每个社团中心为节点本身,计算社团间距离  $D_{ij}$ 。

3) 为降低算法的时间复杂度,提高分类效率,设定阈值  $\omega$  对所有节点进行初始聚类。设定阈值  $\omega$ ,若两样本间相似度  $D_{ij} < \omega$ ,则将样本  $x_i$  与  $x_j$  划分为同社团,形成  $m$  个初始社团。

4) 计算  $m$  个初始社团的距离矩阵  $\mathbf{D}$ ,找出  $\mathbf{D}$  中最小元素  $\min(D_{pq})$ ;将社团  $p$  与  $q$  合并,形成新社团,并计算此时的网络模块性评价函数  $Q$ 。

5) 将合并后的  $m-1$  个类别的社团重复步骤 4,直到所有社团合并为一。

6) 输出使得模块性评价函数  $Q$  取值最大的划分  $N$  作为最终聚类结果,将所有训练样本划分为  $N$  个社团,实现故障分类。

7) 将测试样本  $y$  作为一个单节点社团输入样本集合,计算  $y$  与所有训练样本的节点相似度与社团间相似性测度。

8) 根据式(5)计算  $y$  与已知  $N$  个社团的 Ward 距离  $\mathbf{D} = (D_1, D_2, \dots, D_N)$ ,  $i = 1, 2, \dots, N$ ,使得  $\min(D_i)$  的第  $i$  个社团作为结果输出,即测试样本属于第  $i$  类故障。

## 2 基于复杂网络聚类算法的主轴系统故障诊断方法

笔者在对摩擦提升机主轴系统各轴承的在线监测过程中发现,提升过程中罐道质量与载荷变化引起的振动可以经由滚筒传导至主轴两端轴承处。减速器元件故障引发的异常振动不仅会影响减速器两侧轴承,还可经由电机与滚筒处轴承振动反映出来。这就为利用较少数据来源诊断较多部件故障提供了可能性,但同时也要看到,经由传导表现出的故障大多微弱且混杂,需要通过更为有效的信号处理与模式识别技术进行诊断。

### 2.1 故障信号特征提取

反映主轴系统故障信息的振动信号往往表现出

非平稳、非线性的特点,从非平稳时变信号中提取体现主轴系统运行状态的特征参数需要全面反映时域和频域特性。局域均值分解(local mean decomposition, 简称 LMD)方法<sup>[15]</sup>可将复杂的多分量调幅调频信号分解为单分量的调幅调频信号,且分解结果保持原信号的幅值与频率变化,非常适合处理主轴系统故障信号等非平稳非线性且多分量的信号。当主轴系统各元件发生故障时,振动信号在相同频带内能量特征数值会发生较大变化,能量特征分布在频带内也会产生较大差异,而 LMD 分解结果乘积函数(product function, 简称 PF)分量包含了各个频段的信息,因此笔者选取主轴系统 6 个滚动轴承振动信号各 PF 分量的能量值结合对负载变化敏感的主机电流构造故障数据样本集。

主轴系统各部件振动信号的故障信息主要集中在高频段,故选择前三阶 PF 进一步分析,提取特征信息并构成特征向量。设采集到的原始信号为  $z_i(t) (i=1, 2, \dots, N)$ , 计算前三阶 PF 分量能量值

$$E_i = \int_{-\infty}^{+\infty} |\text{PF}_j(t)|^2 dt \quad (8)$$

对能量归一化处理,结合主机电流值得到 19 维特征向量

$$\mathbf{T} = \left( \frac{E_{i1}}{E_i}, \frac{E_{i2}}{E_i}, \frac{E_{i3}}{E_i}, I \right) \quad (i=1, 2, \dots, 6)$$

其中:  $E_i = \sqrt{\sum_j |E_{ij}|^2}$  为各轴承能量归一化因子。

## 2.2 主轴系统故障诊断方法

笔者提出采用 LMD 方法对振动信号进行分解,提取分解后前三阶 PF 分量的能量特征结合主机电流构成故障数据特征样本,采用基于广义 Ward 距离的复杂网络聚类算法对样本进行聚类,从而对主轴系统故障进行分类识别。具体实现步骤如下。

1) 以一定采样频率对主轴系统各轴承振动信号进行采集,收集正常、过载、滚动轴承外圈故障、滚动轴承滚动体故障和减速器齿轮磨损故障等状态的振动信号,采集对应状态的主机电流,得到样本数据。

2) 对振动信号进行 LMD 分解,得到各样本信号的 PF 分量并将原始信号进行相关分析,将相关系数很小的分量视为虚假分量剔除。

3) 按式(8)计算各振动信号样本前三阶 PF 分量的能量值并归一化处理,结合主机电流构成故障特征向量。

4) 以得到的特征向量为故障数据样本构建训

练样本的复杂网络模型,根据复杂网络聚类算法对其进行分类,得到训练样本的网络结构及社团归属。

5) 将测试样本的特征向量输入训练好的复杂网络结构,计算其与各社团的广义 Ward 距离,判断测试样本故障状态。

## 3 试验分析

为验证所提出方法的有效性,采用摩擦提升机主轴系统试验数据对其故障进行聚类试验。图 2 为某矿副立井型号为 JKM 2.8×6(I)A 的摩擦提升机,将振动传感器垂直固定于各轴承上方采集正常、过载、滚动轴承外圈故障、滚动轴承滚动体故障和减速器齿轮磨损故障 5 种工作状态的振动信号。采样频率为 500 Hz,截取匀速提升数据作为待分析信号,同时记录匀速提升时主机电流数值。选取每种状态样本各 20 组,形成总数为 100 的样本集,随机抽取 75 组数据构成训练样本,剩余 25 组为测试样本。

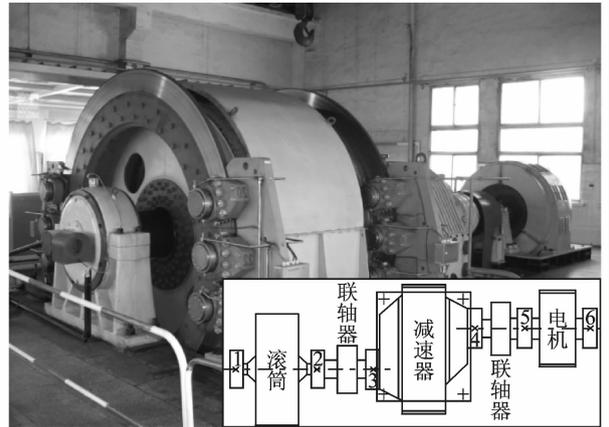


图 2 提升机主轴系统传感器布置

Fig. 2 Sensors placement on spindle system of the hoist

对每一组振动信号进行 LMD 分解(以过载故障为例,滚筒支撑轴承 2 号采样点处振动信号及其 LMD 分解结果如图 3 所示,原始信号被分解为 4 个单分量的调幅-调频 PF 分量及一个剩余分量 R),求取各 PF 分量的能量值,结合对应主机电流构成 19×100 的故障特征数据特征样本集。以各数据样本作为节点,计算节点间相似度,得到 75 个节点,5 550 条边的主轴系统故障数据的加权无向复杂网络模型。将初始节点视为 75 个社团,令初聚类阈值  $\omega=0.1$ ,得到 10 个初始分类,按凝聚型自底向上聚类流程形成树状图,聚类结果与各步骤模块性评价指标 Q 值如图 4 所示,横轴每一个节点代表一个样本。

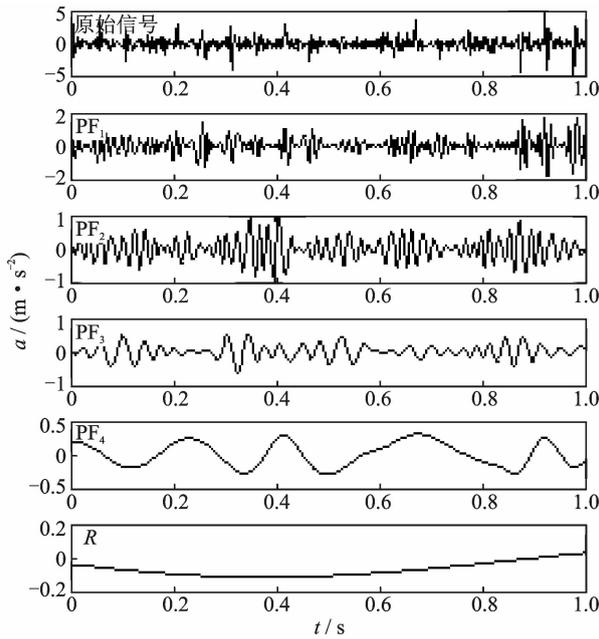


图 3 滚筒支撑轴承振动信号 LMD 分解结果

Fig. 3 The LMD results of bracing bearing on roller

由图 4 可知,在  $\max(Q)=0.649 2$  处样本归为 5 类,类别数与样本故障类型相符,所有样本中仅有 3 组样本归类错误,诊断精度达 97.3%,表现出较高的正确率。另外,聚类最终类别数并未在聚类前设定,而是由算法自行归类确定,当存在未知故障类型数据时并不会盲目将其归入某一类,这样就为收集异常数据以便日后分析诊断提供了可能性。

将测试样本输入训练好的复杂网络结构,对其进行模式识别。分别把多元支持向量机与快速 Newman 算法与本研究算法应用于主轴系统故障诊断,性能比较结果如表 1 所示。在统计正确率的同时,比较在相同软硬件环境下几种算法对单个样本识别的平均耗时。

对比表 1 中几种算法对主轴系统工作状态的识别情况,发现与多元支持向量机相比,复杂网络聚类算法具有更高的识别精度与更短的识别时间。笔者所提出的算法以广义 Ward 距离为划分准则,较以模块性评价函数变化量为划分准则的快速 Newman

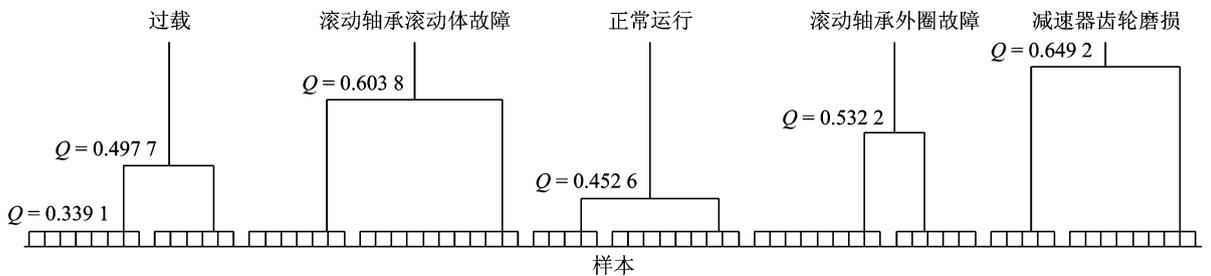


图 4 聚类树状图

Fig. 4 Dendrogram of clustering

表 1 多种算法识别性能比较

Tab. 1 Comparison of recognition performance of algorithms

算法	正确识别率/%	单个样本平均耗时/s	模块性评价函数 Q
m-SVMs	20/25=80	3.875 4	—
快速 Newman	23/25=92	2.414 8	0.52
本算法	24/25=96	1.968 1	0.67

算法,强化了社团间连接紧密程度判断,提高局部判断的精细性的同时具有相对简单的计算复杂度,在识别精度与效率上具有综合的较优性能,适合主轴系统故障的诊断。

## 4 结论

1) 机械设备故障数据的网络分布体现出复杂网络典型的社团结构特征,通过构建以故障特征样

本为网络节点,样本间相似度为边权的复杂网络模型,可以将故障诊断转化为复杂网络的社团聚类问题。笔者通过对主轴系统典型故障分类与模式识别验证了该方法应用于此类故障的有效性。

2) 复杂网络聚类算法的关键是合理选择节点间相似度度量与优化聚类社团的划分准则。笔者提出以广义 Ward 距离表征节点或社团间连接的紧密程度,较之模块性评价函数变化量更注重社团联系的整体性,通过初始分类阈值的设定简化计算复杂度,提高局部判断的精细性,是对优化聚类准则函数的有益尝试。

3) 提出的基于复杂网络聚类的摩擦提升机主轴系统故障诊断方法,以 LMD 能量与主机电流构造故障特征向量。提出基于广义 Ward 距离的复杂网络聚类划分准则,采用凝聚型自底向上的合并过程,实现故障的模式识别,表现出较高的识别精度

与识别效率,可有效用于主轴系统的典型故障诊断。另外,该方法聚类前可不预设聚类结果的类别数,由算法对提供数据样本进行归类,对于缺乏先验知识及故障样本的系统,可以从长期监测数据中总结某一类未知类型数据表现出的规律,为故障诊断提供样本参考。

## 参 考 文 献

- [1] 潘英. 矿山提升机械设计[M]. 徐州:中国矿业大学出版社,2001:2-3.
- [2] 吴海青,石瑞敏,娄玉华,等. 多绳摩擦提升机主轴振动监测与故障诊断研究[J]. 煤矿机械,2013,34(8):302-304.  
Wu Haiqing, Shi Ruimin, Lou Yuhua, et al. Research of vibration monitoring and fault diagnosis on spindle of multi-rope friction hoist [J]. Coal Mine Machinery, 2013, 34(8):302-304. (in Chinese)
- [3] 孙宜权,张英堂,陈爱民,等. 基于阶比滤波的单通道缸盖振动信号盲源分离[J]. 振动、测试与诊断,2014,34(1):136-140.  
Sun Yiquan, Zhang Yingtang, Chen Aimin, et al. Blind source separation of single-channel cylinder-head vibration signal based on order filtering[J]. Journal of Vibration, Measurement & Diagnosis, 2014, 34(1):136-140. (in Chinese)
- [4] 乔国厚. 基于振动信号分析的矿井提升机主轴装置在线监测与故障诊断系统设计应用[J]. 矿山机械,2013,41(12):51-55.  
Qiao Guohou. Design an application of online monitoring and fault diagnosis system for spindle assembly of mine hoist based on vibration signal analysis [J]. Mining & Processing Equipment, 2013, 41(12):51-55. (in Chinese)
- [5] 葛森. 矿井提升机主轴实时监测与故障诊断系统研究[D]. 唐山:河北联合大学,2012.
- [6] 金弟,刘大有,杨博,等. 基于局部探测的快速复杂网络聚类算法[J]. 电子学报,2011,39(11):2540-2546.  
Jin Di, Liu Dayou, Yang Bo, et al. Fast complex network clustering algorithm using local detection [J]. Acta Electronica Sinica, 2011, 39(11):2540-2546. (in Chinese)
- [7] 杜海峰,王娜,张进华,等. 基于复杂网络的故障诊断策略[J]. 机械工程学报,2010,46(3):90-96.  
Du Haifeng, Wang Na, Zhang Jinhua, et al. Fault diagnosis strategy based on complex network analysis [J]. Journal of Mechanical Engineering, 2010, 46(3):90-96. (in Chinese)
- [8] 孙斌,尚达. 复杂网络在转子故障诊断中的应用[J]. 振动、测试与诊断,2012,32(6):1010-1015.  
Sun Bin, Shang Da. Complex network in application of rotor fault diagnosis[J]. Journal of Vibration, Measurement & Diagnosis, 2012, 32(6):1010-1015. (in Chinese)
- [9] Newman M E J, Girvan M. Finding and evaluating community structure in network[J]. Physical Review E, 2004, 69(2):026113.
- [10] Girvan M, Newman M E J. Community structure in social and biological network[J]. Proceedings of the National Academy of Sciences of the United States of America, 2002, 99(12):7821-7826.
- [11] Newman M E J. Detecting community structure in networks[J]. European Physical Journal (B), 2004, 38(2):321-330.
- [12] Newman M E J. Fast algorithm of detecting community structure in networks [J]. Physical Review E, 2004, 69(6):066133.
- [13] 陈安华,潘阳,蒋玲莉. 基于复杂网络社团聚类的故障模式识别方法研究[J]. 振动与冲击,2013,32(20):129-133.  
Chen Anhua, Pan Yang, Jiang Lingli. Fault pattern recognition method based on complex network community clustering [J]. Journal of Vibration and Shock, 2013, 32(20):129-133. (in Chinese)
- [14] Mirkin B. Core concepts in data analysis: summarization, correlation and visualization [M]. London: Springer, 2011:31-35.
- [15] Smith J S. The local mean decomposition and its application to EEG perception data [J]. Journal of the Royal Society Interface, 2005, 2(5):443-454.



**第一作者简介:**董磊,男,1982年10月生,博士、讲师。主要研究方向为机械系统状态监测及故障诊断,摩擦学设计及理论。曾发表《无驱动桥矿用重载车辆全轮转向特性分析》(《煤炭科学技术》2010年第38卷第10期)等论文。  
E-mail:13754892010@163.com