DOI: 10.3901/JME.2014.18.007

基于正交半监督局部 Fisher 判别分析的故障诊断*

苏祖强¹ 汤宝平¹ 刘自然² 秦毅¹

(1. 重庆大学机械传动国家重点实验室 重庆 400030;

2. 河南工业大学机电工程学院 郑州 450007)

摘要: 针对有标记故障样本不足和故障特征集维数过高的问题, 提出基于正交半监督局部 Fisher 判别分析(Orthogonal semi-supervised local Fisher discriminant analysis, OSELF)的故障诊断方法。所提出的 OSELF 能够充分地利用蕴含于无标记故障样本中的故障信息, 避免了因有标记故障样本不足引起的过学习问题, 同时采用正交迭代方式求解最优正交映射矩阵, 克服现有方法无法得到正交映射矩阵的不足。正交映射矩阵的基矢量统计不相关, 可有效地提高所得低维特征矢量的可辨识度。通过正交映射矩阵对故障样本集和新增样本进行维数约简, 并将维数约简的结果输入粗糙优化 k 最近邻分类器(Coarse to fine k nearest neighbor classifier, CFKNNC)进行学习训练和故障识别。所提方法集成了 OSELF 在维数约简和 CFKNNC 在模式识别的优势, 有效地提高了故障诊断的精度。通过齿轮箱故障模拟试验验证了该方法的有效性。

关键词: 故障诊断; 维数约简; 正交半监督局部 Fisher 判别分析; 粗糙优化 k 最近邻分类器

中图分类号: TH165

Fault Diagnosis Method Based on Orthogonal Semi-supervised Local Fisher Discriminant Analysis

SU Zuqiang¹ TANG Baoping¹ LIU Ziran² QIN Yi¹

(1. The State Key Laboratory of Mechanical Transmission, Chongqing University, Chongqing 400030;

2. School of Mechanical & Electrical Engineering, Henan University of Technology, Zhengzhou 450007)

Abstract: Fault diagnosis method based on orthogonal semi-supervised local Fisher discriminant analysis(OSELF) is proposed, aiming to solve the problem of inadequate number of labeled fault samples and high dimensionality of the feature set. A new dimensionality reduction method named OSELF is proposed combining orthogonal iteration algorithm with semi-supervised local Fisher discriminant analysis(SELF), which can effectively utilize the fault information supported by the labeled and unlabeled fault samples to embed the fault samples into the low-dimensional subspace without the over-fitted problem. The basis vectors of the orthogonal projection matrix are statically uncorrelated, and the discriminations of the obtained low-dimensional fault feature vectors are improved. Then the low-dimensional fault samples are fed into coarse to fine k nearest neighbor classifier(CFKNNC) to recognize the fault type. The proposed method integrated the advantages of OSELF in dimension reduction and CFKNNC in pattern recognition and effectively improved the accuracy of fault diagnosis. The validity of the proposed method is verified by the instance of the fault diagnosis of a gearbox.

Key words: fault diagnosis; dimensionality reduction; orthogonal semi-supervised local Fisher discriminant analysis; coarse to fine- k nearest neighbor classifier

0 前言

对机械设备进行故障诊断时, 为了获得可信度高的诊断结果, 就必须提取大量从各个方面反映故障的特征来对故障进行更加全面、综合的描述^[1]。然而, 这使得特征集的维数过高并且特征间往往都

具有非线性耦合, 不仅加大了分类器的工作负担, 同时也难以得到理想的故障诊断效果^[2]。因此, 必须对故障特征集进行非线性维数约简, 获得对故障更加敏感的融合特征。虽然传统的线性维数约简方法, 如主成分分析(Principle component analysis, PCA)^[3]、局部保持投影(Locality preserving projection, LPP)^[4]等通过引入核函数能够实现非线性维数约简, 但是其无监督的基本属性导致了维数约简过程的盲目性, 得到的结果往往不是最优的。常用的有监督维数约简方法, 如监督局部线性嵌

* 国家自然科学基金(51275546, 51375514)和高等学校博士学科点专项科研基金(20130191130001)资助项目。20131108 收到初稿, 20140325 收到修改稿

入^[5]、局部 Fisher 判别分析(Local Fisher discriminant analysis, LFDA)^[6]等在有标记故障样本充裕的情况下能够取得很好的效果。然而在实际工程应用中(如风电机组传动系统的故障诊断)往往难以获取足够的有标记故障样本,而上述有监督维数约简方法无法利用蕴含于无标记故障样本中的故障信息,使得这些方法过度依赖于少量的有标记故障样本而容易陷入过学习的问题^[7]。

针对上述问题,本文提出一种基于正交半监督局部 Fisher 判别分析(Orthogonal semi-supervised local Fisher discriminant analysis, OSELF)的故障诊断方法:首先采用本文提出的 OSELF 对故障特征集进行非线性维数约简,得到对故障更加敏感、可分性更高的融合特征。然后,采用粗糙优化 k 最近邻分类器(Coarse to fine k nearest neighbor classifier, CFKNNC)来进行故障识别^[8],从而实现故障诊断。

1 正交半监督局部 Fisher 判别分析

为了方便叙述,在本文的后续部分中记 $\mathbf{X} = \{\mathbf{x}_i \in \mathbf{R}^D, (i=1, 2, \dots, n^c, \dots, n)\}$ 为故障样本集,其中 $\mathbf{x}_i (i=1, 2, \dots, n^c)$ 为有标记故障样本,记 $l_i \in \{1, 2, \dots, C\} (i=1, 2, \dots, n^c)$ 为有标记故障样本 $\mathbf{x}_i$ 的类别标签, D 为故障样本集的维数, n 、 n^c 分别代表故障样本集中故障样本总数和有标记故障样本个数, C 为故障类别数。

1.1 半监督局部 Fisher 判别分析算法

SUGIYAMA 等^[7]将局部 Fisher 判别分析算法与主成分分析算法有效地融合在一起,得到了一种新的半监督局部 Fisher 判别分析算法(Semi-supervised local Fisher discriminant analysis, SELF)^[7],以克服 LFDA 在有标记故障样本不足时容易陷入过学习的问题。PCA 在获取样本集全局分布上具有一定的优势,且能较好地提取蕴含于无标记故障样本中的故障信息,而 LFDA 能够充分地利用故障样本的类别信息对降维过程进行指导,使故障样本集向更有利于样本分类的方向进行投影,将两者结合既克服了 PCA 方法无监督的缺点,又能够避免 LFDA 在有标记故障样本不足时容易陷入过学习的问题。SELF 首先定义了故障样本集的类间散布矩阵 $\mathbf{S}^{(b)}$ 和类内散布矩阵 $\mathbf{S}^{(w)}$,定义如式(1)、(2)所示

$$\mathbf{S}^{(b)} = (1 - \beta)\mathbf{S}^{(lb)} + \beta\mathbf{S}^{(t)} \quad (1)$$

$$\mathbf{S}^{(w)} = (1 - \beta)\mathbf{S}^{(lw)} + \beta\mathbf{I} \quad (2)$$

式中, $\mathbf{S}^{(t)}$ 为 PCA 定义的全局散布矩阵, $\mathbf{S}^{(lb)}$ 和

$\mathbf{S}^{(lw)}$ 则分别为 LFDA 定义的类内散布矩阵和类间散布矩阵。 $\mathbf{I}$ 为标准矩阵, $\beta \in [0, 1]$ 是权衡系数,当 $\beta = 1$ 时 SELE 等效于 PCA, 当 $\beta = 0$ 时则退化为 LFDA

$$\mathbf{S}^{(t)} = \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n W_{i,j}^{(t)} (\mathbf{x}_i - \mathbf{x}_j)(\mathbf{x}_i - \mathbf{x}_j)^T = \sum_{i=1}^n \left(\sum_{j=1}^n W_{i,j}^{(t)} \right) \mathbf{x}_i \mathbf{x}_i^T - \sum_{i,j}^n W_{i,j}^{(t)} \mathbf{x}_i \mathbf{x}_j^T \quad (3)$$

$$\mathbf{S}^{(lb)} = \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n W_{ij}^{(lb)} (\mathbf{x}_i - \mathbf{x}_j)(\mathbf{x}_i - \mathbf{x}_j)^T = \sum_{i=1}^n \left(\sum_{j=1}^n W_{i,j}^{(lb)} \right) \mathbf{x}_i \mathbf{x}_i^T - \sum_{i,j}^n W_{i,j}^{(lb)} \mathbf{x}_i \mathbf{x}_j^T \quad (4)$$

$$\mathbf{S}^{(lw)} = \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n W_{ij}^{(lw)} (\mathbf{x}_i - \mathbf{x}_j)(\mathbf{x}_i - \mathbf{x}_j)^T = \sum_{i=1}^n \left(\sum_{j=1}^n W_{i,j}^{(lw)} \right) \mathbf{x}_i \mathbf{x}_i^T - \sum_{i,j}^n W_{i,j}^{(lw)} \mathbf{x}_i \mathbf{x}_j^T \quad (5)$$

式中, 权值 $W_{i,j}^{(t)} = 1/n$, 而权值矩阵 $\mathbf{W}^{(lb)}$ 和 $\mathbf{W}^{(lw)}$ 的定义如下

$$\mathbf{W}_{i,j}^{(b)} = \begin{cases} A_{i,j} (1/n^c - 1/n_l^c) & l_i = l_j \\ (1 - \beta)1/n^c & l_i \neq l_j \end{cases} \quad (6)$$

$$\mathbf{W}_{i,j}^{(w)} = \begin{cases} A_{i,j}/n_l^c & l_i = l_j \\ 0 & \text{其他} \end{cases}$$

式中, n_l^c 为第 $l_i \in \{1, 2, \dots, C\}$ 类故障的样本个数; $A_{i,j} \in [0, 1]$ 用于描述故障样本 $\mathbf{x}_i$ 和 $\mathbf{x}_j$ 的相似度, 且 $A_{i,j}$ 有多种不同的定义方法, 其中局部尺度启发式定义方法是一种比较常用的定义方法^[5], 如式(7)所示

$$A_{i,j} = \exp \left(- \frac{\|\mathbf{x}_i - \mathbf{x}_j\|}{\sigma_i \sigma_j} \right) \quad (7)$$

式中, $\sigma_i = \|\mathbf{x}_i - \mathbf{x}_i^{(k)}\|$ 代表样本点 $\mathbf{x}_i$ 的局部尺度, $\mathbf{x}_i^{(k)}$ 是 $\mathbf{x}_i$ 的第 k 个最近邻点。而映射矩阵 $\mathbf{T}^{(SE)}$ 的求解等效于式(8)所示的广义特征矢量求取问题

$$\mathbf{S}^{(b)} \boldsymbol{\alpha} = \lambda \mathbf{S}^{(w)} \boldsymbol{\alpha} \quad (8)$$

然而, SELF 仍然是一种线性维数约简方法, 为了使其具有非线性维数约简能力, 可将核方法引入 SELF^[2, 9]。为了达到这个目的首先需要将类间散布矩阵 $\mathbf{S}^{(b)}$ 和类内散布矩阵 $\mathbf{S}^{(w)}$ 转化为点对形式, 即 $\mathbf{S}^{(b)} = \mathbf{X} \mathbf{L}^{(b)} \mathbf{X}^T$ 、 $\mathbf{S}^{(w)} = \mathbf{X} \mathbf{L}^{(w)} \mathbf{X}^T$ 。注意 $\mathbf{S}^{(b)}$ 可直接表示为如式(9)所示的形式

$$\mathbf{S}^{(b)} = \frac{1}{2} \sum_{i,j=1}^n \mathbf{W}_{i,j}^{(b)} (\mathbf{x}_i - \mathbf{x}_j)(\mathbf{x}_i - \mathbf{x}_j)^T = \sum_{i=1}^n \left(\sum_{j=1}^n \mathbf{W}_{i,j}^{(b)} \right) \mathbf{x}_i \mathbf{x}_i^T - \sum_{i,j=1}^n \mathbf{W}_{i,j}^{(b)} \mathbf{x}_i \mathbf{x}_j^T \quad (9)$$

式中, 权值矩阵 $\mathbf{W}^{(b)}$ 可由 LFDA 的权值矩阵 $\mathbf{W}^{(lb)}$ 和 PCA 的权值矩阵 $\mathbf{W}^{(t)}$ 得到

$$\mathbf{W}_{i,j}^{(b)} = \begin{cases} (1-\beta)A_{i,j}(1/n^c - 1/n_i^c) & l_i = l_j \\ (1-\beta)1/n^c + \beta/n & l_i \neq l_j \\ \beta/n & \text{其他} \end{cases} \quad (10)$$

由式(9)可得 $\mathbf{L}^{(b)} = \mathbf{D}^{(b)} - \mathbf{W}^{(b)}$, 其中 $\mathbf{D}^{(b)}$ 为对角矩阵, $D_{i,i}^{(b)} = \sum_{j=1}^n \mathbf{W}_{i,j}^{(b)}$ 。而由于 $\mathbf{S}^{(w)}$ 包含有标准矩阵 $\mathbf{I}$, 因此无法直接表示为点对形式, 在此将 $\mathbf{L}^{(w)}$ 定义为^[7]

$$\mathbf{L}^{(w)} = (1-\beta)\mathbf{L}^{(lw)} + \beta(\mathbf{X}^T \mathbf{X})^\dagger \quad (11)$$

式中, $\mathbf{L}^{(lw)} = \mathbf{D}^{(lw)} - \mathbf{W}^{(lw)}$, $\mathbf{D}^{(lw)}$ 为对角矩阵 $D_{i,i}^{(lw)} = \sum_{j=1}^n \mathbf{W}_{i,j}^{(lw)}$, $(\mathbf{X}^T \mathbf{X})^\dagger$ 是 $\mathbf{X}^T \mathbf{X}$ 的 Moore-Penrose 广义逆。将 $\mathbf{S}^{(b)}$ 和 $\mathbf{S}^{(w)}$ 表示为点对形式后, 则式(8)所示的广义特征矢量求取问题可等效为

$$\mathbf{X} \mathbf{L}^{(b)} \mathbf{X}^T \boldsymbol{\alpha} = \lambda \mathbf{X} \mathbf{L}^{(w)} \mathbf{X}^T \boldsymbol{\alpha} \quad (12)$$

由于故障样本的维数 $D \leq n$, 因此广义特征矢量 $\boldsymbol{\alpha} \in \mathbf{R}^D$ 可以表示为 $\boldsymbol{\alpha} = \mathbf{X} \boldsymbol{\varphi}$, 其中 $\boldsymbol{\varphi} \in \mathbf{R}^n$ ^[6]。将式(12)两边同时左乘 $\mathbf{X}^T$ 并令 $\mathbf{K} = \mathbf{X}^T \mathbf{X}$, 即 $K_{i,j} = \langle \mathbf{x}_i, \mathbf{x}_j \rangle$ 。此时引入核函数来计算 $\mathbf{K}$ 即可得到如式(13)所示的 SELF 的非线性维数约简模式, 即 $K_{i,j} = \langle \phi(\mathbf{x}_i), \phi(\mathbf{x}_j) \rangle = Ke(\mathbf{x}_i, \mathbf{x}_j)$, 其中 $\phi(\mathbf{x})$ 为将故障样本非线性地映射到高维线性可分核空间的非线性映射函数, $Ke(\mathbf{x}, \mathbf{y})$ 为核函数。为了方便起见仍记

$$\begin{aligned} \mathbf{S}^{(b)} &= \mathbf{K} \mathbf{L}^{(b)} \mathbf{K} \\ \mathbf{S}^{(w)} &= \mathbf{K} \mathbf{L}^{(w)} \mathbf{K} \\ \mathbf{K} \mathbf{L}^{(b)} \mathbf{K} \boldsymbol{\varphi} &= \lambda \mathbf{K} \mathbf{L}^{(w)} \mathbf{K} \boldsymbol{\varphi} \end{aligned} \quad (13)$$

式(13)的前 d 个最大广义特征值对应的广义特征矢量则组成了映射矩阵 $\mathbf{T}^{(SE)} = (\boldsymbol{\varphi}_1, \boldsymbol{\varphi}_2, \dots, \boldsymbol{\varphi}_d)$ 。然而由式(13)求出的广义特征矢量应当满足约束条件 $\boldsymbol{\varphi}_i^T \mathbf{S}^{(w)} \boldsymbol{\varphi}_j = 0, (i \neq j)$, 无法保证 $\boldsymbol{\varphi}_i \boldsymbol{\varphi}_j^T = 0$ 始终成立, 因此易知映射矩阵 $\mathbf{T}^{(SE)}$ 是非正交的^[10]。

1.2 正交半监督局部 Fisher 判别分析算法

CAI 等^[10]在 LPP 的基础上采用正交迭代方式来求取映射矩阵, 得到了一种新的正交局部保持投

影算法, 该算法能够将高维故障样本正交地映射到低维子空间。采用正交映射的优点在于通过维数约简后得到的低维故障样本集仍然保留了高维故障样本集包含的几何结构信息, 相对于非正交映射而言具有更好的判别能力。设有一个映射矩阵 $\mathbf{M}$, 则任意两个样本 ξ_i, ξ_j 通过 $\mathbf{M}$ 进行维数约简后, 在低维子空间中的距离计算如下

$$\begin{aligned} d(\mathbf{M}^T \xi_i, \mathbf{M}^T \xi_j) &= \|\mathbf{M}^T \xi_i - \mathbf{M}^T \xi_j\| = \\ \|\mathbf{M}^T (\xi_i - \xi_j)\| &= \sqrt{(\xi_i - \xi_j)^T \mathbf{M} \mathbf{M}^T (\xi_i - \xi_j)} \end{aligned} \quad (14)$$

若映射矩阵 $\mathbf{M}$ 是正交矩阵, 则 $\mathbf{M} \mathbf{M}^T = \mathbf{I}$ ($\mathbf{I}$ 是标准矩阵), 可以看出对 ξ_i, ξ_j 进行正交投影后样本点间的距离关系未改变, 因此保留了原始样本集中包含的几何结构信息。

本文则将正交迭代方法引入 SELF 来克服其无法获得正交映射矩阵的不足, 得到改进的 OSELF。记 $\mathbf{T}^{(OSE)}$ 为所要求取的正交映射矩阵, 首先定义一个优化判别函数

$$f(\boldsymbol{\varphi}) = \frac{\boldsymbol{\varphi}^T \mathbf{S}^{(b)} \boldsymbol{\varphi}}{\boldsymbol{\varphi}^T \mathbf{S}^{(w)} \boldsymbol{\varphi}} \quad (15)$$

式(13)所示的广义特征矢量求取问题可转化为函数 $f(\boldsymbol{\varphi})$ 极大值点处 $\boldsymbol{\varphi}_i, (i=1, 2, \dots, d)$ 的求取问题, 即最大化类间散度 $\mathbf{S}^{(b)}$ 和最小化类内散度 $\mathbf{S}^{(w)}$ ^[10], 如式(16)所示

$$\boldsymbol{\varphi}_i = \arg \max_{\boldsymbol{\varphi} \in \mathbf{R}^D} \frac{\boldsymbol{\varphi}^T \mathbf{S}^{(b)} \boldsymbol{\varphi}}{\boldsymbol{\varphi}^T \mathbf{S}^{(w)} \boldsymbol{\varphi}} \quad (16)$$

由式(13)和式(16)易得 $\boldsymbol{\varphi}_i$ 为式(13)最大广义特征值对应的广义特征矢量。为了得到唯一且正交的映射矩阵 $\mathbf{T}^{(OSE)}$, 这里给出两个约束条件: $\boldsymbol{\varphi}_i \boldsymbol{\varphi}_j^T = 0, (i \neq j)$ 和 $\boldsymbol{\varphi}_i^T \mathbf{S}^{(w)} \boldsymbol{\varphi}_i = 1$ 。在求取 $\mathbf{T}^{(OSE)}$ 的第 m 维映射矢量 $\boldsymbol{\varphi}_m (m=2, 3, \dots, d)$ 时, 可引入拉格朗日乘数法来描述上述有约束的优化问题

$$\begin{aligned} \mathbf{L}^{(m)} &= \boldsymbol{\varphi}_m^T \mathbf{S}^{(b)} \boldsymbol{\varphi}_m - \lambda (\boldsymbol{\varphi}_m^T \mathbf{S}^{(w)} \boldsymbol{\varphi}_m - 1) - \\ &\quad \mu_1 \boldsymbol{\varphi}_m^T \boldsymbol{\varphi}_1 - \dots - \mu_{m-1} \boldsymbol{\varphi}_m^T \boldsymbol{\varphi}_{m-1} \end{aligned} \quad (17)$$

式中, $\lambda, \mu_i (i=1, 2, \dots, m-1)$ 为拉格朗日系数。将式(17)对 $\boldsymbol{\varphi}_m$ 进行求导, 同时令其为 0

$$\begin{aligned} \frac{\partial \mathbf{L}^{(m)}}{\partial \boldsymbol{\varphi}_m} &= 2 \mathbf{S}^{(b)} \boldsymbol{\varphi}_m - 2 \lambda \mathbf{S}^{(w)} \boldsymbol{\varphi}_m - \\ &\quad \mu_1 \boldsymbol{\varphi}_1 - \dots - \mu_{m-1} \boldsymbol{\varphi}_{m-1} = 0 \end{aligned} \quad (18)$$

并将式(18)两边同时左乘 $\boldsymbol{\varphi}_m^T$ 则可得到 λ 的解

$$\lambda = \frac{\boldsymbol{\varphi}_m^T \boldsymbol{S}^{(b)} \boldsymbol{\varphi}_m}{\boldsymbol{\varphi}_m^T \boldsymbol{S}^{(w)} \boldsymbol{\varphi}_m} \quad (19)$$

对比式(19)和式(15)可知 λ 为优化判别函数 $f(\boldsymbol{\varphi})$ 的一个极大值。将式(18)两边分别左乘 $\boldsymbol{\varphi}_1^T (\boldsymbol{S}^{(w)})^{-1}, \dots, \boldsymbol{\varphi}_{m-1}^T (\boldsymbol{S}^{(w)})^{-1}$ 可得如下 $m-1$ 个等式

$$2\boldsymbol{\varphi}_t^T (\boldsymbol{S}^{(w)})^{-1} \boldsymbol{S}^{(b)} \boldsymbol{\varphi}_m = \sum_{i=1}^{m-1} \mu_i \boldsymbol{\varphi}_i^T (\boldsymbol{S}^{(w)})^{-1} \boldsymbol{\varphi}_i \quad (20)$$

式中, $t=1, 2, \dots, m-1$, 为了进一步简化, 在此做以下定义

$$\boldsymbol{\mu}^{(m-1)} = (\mu_1, \mu_2, \dots, \mu_{m-1})^T \quad \boldsymbol{T}^{(m-1)} = (\boldsymbol{\varphi}_1, \boldsymbol{\varphi}_2, \dots, \boldsymbol{\varphi}_{m-1})$$

$$\boldsymbol{A}^{(m-1)} = (\boldsymbol{T}^{(m-1)})^T \boldsymbol{S}^{(w)} \boldsymbol{T}^{(m-1)} \quad (21)$$

将式(21)代入式(20), 可计算得到 $\boldsymbol{\mu}^{(m-1)}$ 的解

$$\boldsymbol{\mu}^{(m-1)} = 2(\boldsymbol{A}^{(m-1)})^{-1} (\boldsymbol{T}^{(m-1)})^T (\boldsymbol{S}^{(w)})^{-1} \boldsymbol{\varphi}_m \quad (22)$$

将式(18)两边同时左乘 $(\boldsymbol{S}^{(w)})^{-1}$ 并将式(22)代入其中, 则式(18)可进一步转化为式(23)所示的特征矢量求取问题

$$\left\{ \boldsymbol{I} - (\boldsymbol{S}^{(w)})^{-1} \boldsymbol{T}^{(m-1)} (\boldsymbol{A}^{(m-1)})^{-1} \right\} \times$$

$$(\boldsymbol{S}^{(w)})^{-1} (\boldsymbol{S}^{(b)}) \boldsymbol{\varphi}_m = \lambda \boldsymbol{\varphi}_m \quad (23)$$

由式(19)可知 λ 是优化判别函数 $f(\boldsymbol{\varphi})$ 的一个极大值, 因此可得出 $\boldsymbol{\varphi}_m$ 为式(23)中最大特征值对应的特征向量。重复迭代计算式(20)~(23)所示过程, 可最终求出正交映射矩阵 $\boldsymbol{T}^{(\text{OSE})} = (\boldsymbol{\varphi}_1, \boldsymbol{\varphi}_2, \dots, \boldsymbol{\varphi}_d)$, 且可得故障样本集的低维坐标 $\boldsymbol{Y} = (\boldsymbol{T}^{(\text{OSE})})^T \boldsymbol{X}$, 其中 $\boldsymbol{Y}_L = \{y_i \in \mathbf{R}^d, i=1, 2, \dots, n^c\}$ 为低维有标记故障样本集, 并将 $\boldsymbol{Y}_L$ 及其类别标签的集合 $\boldsymbol{Y}_r = \{(y_i, l_i)\}$ 作为分类器的训练样本集。

2 粗糙优化 k 最近邻分类器

CFKNNC 是 k 近邻分类器(k nearest neighbor classifier, KNNC)^[11]的一种改进算法, 其通过训练样本对新增样本的重构误差来确定测试样本的 k' 个最近邻训练样本, 这就使得优选出的 k' 个最近邻训练样本能够更好地近似测试样本。而 KNNC 直接通过训练样本与测试样本之间的距离来确定测试样本的 k' 个最近邻训练样本, 由于距离大小并不能代表训练样本与测试样本之间的相似程度, 这就使得选出的 k' 个最近邻训练样本无法很好地近似测试样

本。由于 CFKNNC 和 KNNC 都是通过优选出的 k' 个最近邻训练样本的故障类别来推断出测试样本的故障类别的, 选出的 k' 个最近邻训练样本与测试样本越相似则最终得出的识别精度就越高, 因此, CFKNNC 能够取得比 KNNC 更高的识别精度。CFKNNC 的实现过程主要有以下几个步骤。

(1) 通过 $\boldsymbol{Y}_L$ 对测试样本进行线性重构, 根据重构误差初步确定测试样本的 n' 个最近邻训练样本, 目的是将步骤(2)的搜索范围限定在局部范围内。

通过训练样本集对测试样本进行线性重构: $y_i = \boldsymbol{Y}_L \boldsymbol{\gamma}$, 其中 $\gamma_i, (i=1, 2, \dots, n^c)$ 代表 y_i 的重构权。 $\boldsymbol{\gamma}$ 的求取应当满足以下两个约束条件, 即最小化重构误差 $e = \|\boldsymbol{y}_i - \boldsymbol{Y}_L \boldsymbol{\gamma}\|$ 和 $\|\boldsymbol{\gamma}\|^2$ 。引入拉格朗日方程表述上述约束: $L' = \|\boldsymbol{y}_i - \boldsymbol{Y}_L \boldsymbol{\gamma}\| + \omega \|\boldsymbol{\gamma}\|$, 其中 ω 为一个正常数, 将 L' 对 $\boldsymbol{\gamma}$ 进行求导并令其为 0 可得

$$\frac{\partial L'}{\partial \boldsymbol{\gamma}} = 2(\boldsymbol{Y}_L^T \boldsymbol{Y}_L + \omega \boldsymbol{I}) \boldsymbol{\gamma} - 2\boldsymbol{Y}_L^T \boldsymbol{y}_i = 0 \quad (24)$$

由式(24)易得 $\boldsymbol{\gamma} = (\boldsymbol{Y}_L^T \boldsymbol{Y}_L + \omega \boldsymbol{I})^{-1} \boldsymbol{Y}_L^T \boldsymbol{y}_i$, 优选出重构误差 $e_i = \|\boldsymbol{y}_i - \boldsymbol{\gamma}_i \boldsymbol{Y}_L\|^2$ 最小的 n' 个训练样本作为测试样本的粗糙最近邻训练样本集, 记为 $\boldsymbol{Z}$ 。

(2) 采用步骤(1)的计算方法从样本集 $\boldsymbol{Z}$ 中优选出测试样本的 k' 个最近邻训练样本。

(3) 根据测试样本的 k' 个最近邻测试样本的故障类别推断出测试样本的故障类别。

测试样本的类别与在其 k' 个最近邻训练样本中拥有最多样本的故障类别相同, 如式(25)所示

$$l_i = \arg \max_{l_i (i=1, 2, \dots, C)} \left(\sum_{j=1}^{k'} \sigma_j \right)$$

$$\sigma_j = \begin{cases} 1 & l_j = l_i \\ 0 & \text{其他} \end{cases} \quad (25)$$

由于 CFKNNC 是通过重构误差来选取测试样本的最近邻训练样本的, 因此所选取的最近邻训练样本能很好地表述测试样本, 从而具有比 KNNC 更高的识别精度。

3 试验验证与结果分析

3.1 故障诊断算法实现

当机械设备发生故障时, 振动信号的时域、频域概率分布以及在不同频带内的能量分布都将发生改变。因此, 从振动信号时域、频率以及时频域提取的故障特征可从不同的侧面反映故障。为了更加全面、综合地表征故障的特性, 从原始振动信号中提取 11 个时域特征(均值、方差、方均根、峰值、

偏态系数等)、13 个频域特征(中心频率、频谱均值、频谱方均根、频率方差等)以及对振动信号进行经验模式分解后与振动信号相关性较强的前 6 阶模态分量的瞬时幅值 Shannon 熵,共 30 个特征组成高维特征集。关于时、频域特征和 IMF 瞬时幅值 Shannon 熵更加详细的解释和说明,可参见文献[1, 12]。

本文提出的基于 OSELF 的故障诊断方法的实现过程如图 1 所示。

图 1 故障诊断流程

本文方法主要包含以下几个步骤。

(1) 对原始振动信号进行特征提取,得到高维故障样本集 $X = \{x_i \in \mathbf{R}^D, i=1, 2, \dots, N\}$ 。

(2) 将故障样本集 X 输入 OSELF 进行训练,得到正交映射矩阵 $T^{(OSE)}$ 及低维故障样本集 Y ,并将低维有标记故障样本及其类别标签的集合 Y_{tr} 作为 CFKNNC 的训练样本集来对分类器进行学习训练。

(3) 通过映射矩阵 $T^{(OSE)}$ 对新增样本 x_i 进行维约,将结果 y_i 输入训练好的 CFKNNC 得到新增样本的故障类别。

3.2 试验数据

本文的试验数据来源于如图 2 所示的齿轮箱故障模拟试验台。齿轮箱故障模拟试验台主要由驱动电动机、联轴器、齿轮箱、加速度传感器、磁粉制动器组成。齿轮箱为一级减速齿轮箱,其中输入端齿轮齿数为 $z_1 = 55$,输出端齿轮齿数为 $z_2 = 75$,模数 $m = 2$,轴承型号为 N205。振动信号由安装在齿轮箱上的振动加速度传感器采集得到,采集过程中驱动电动机转速设定为 1 200 r/min,采样频率设定为 10 kHz。按时间顺序以 4 096 个采样值为 1 组,分别测取轴承外圈故障、内圈故障、滚动体故障和齿轮齿面损失及断齿故障(分别记为 $f_1, f_2, \dots, f_5$)的振动信号各 65 组(共 325 组),以其中的 25 组作为训练样本(10 组有标记故障样本,15 组无标记故障样本),剩余的 40 组作为测试样本。

图 2 齿轮箱故障模拟试验

3.3 试验结果分析

从原始振动信号时域、频域以及时频域中提取相应的故障特征组成高维故障特征集,并将高维故障特征集输入 OSELF 进行维数约简。据文献[8]提供的经验,设定 OSELF 中样本点邻域大小 $k=7$ 、权衡系数 $\beta=0.5$,并设定低维子空间的维数 $d=4$ 。将得到的低维融合特征集输入 CFKNNC 来进行故障模式识别。CFKNNC 中粗糙邻域大小 n' 应当满足 $n' \geq k'$,且根据文献[7]提供的经验并结合本文具体情况(低维子空间维数 $d=4$)设定 $k'=4$ 、 $n'=10$ 。表 1 给出了本文方法得到的故障诊断结果。试验从以下几个方面来验证所提方法的有效性。

表 1 基于 OSELF 维数约简的故障诊断结果

故障类别	样本编号	OSELF 维数约简后的 4 维故障特征矢量	是否正确	诊断精度(%)
f_1	20	(0.042 8, -0.113 1, 0.107 9, 0.017 2)	是	100
	21	(0.064 5, -0.140 9, 0.112 5, 0.031 5)	是	
f_2	20	(-0.021 8, -0.098 3, -0.128 0, -0.062 9)	是	97.5
	21	(-0.040 2, -0.055 5, -0.061 7, -0.035 3)	是	
f_3	20	(-0.106 0, 0.067 3, 0.050 9, 0.044 9)	是	100
	21	(-0.065 0, 0.059 6, 0.024 8, 0.010 1)	是	
f_4	20	(0.106 5, 0.052 7, -0.040 3, 0.020 3)	否	95
	21	(0.097 3, 0.128 5, -0.015 0, -0.189 1)	是	
f_5	20	(0.030 5, 0.019 6, -0.037 2, 0.028 5)	是	92.5
	21	(0.030 1, 0.017 8, -0.028 9, 0.020 5)	是	

(1) 将 OSELF 的维数约简效果与 PCA、LFDA、SELF 进行对比。其中, LFDA、SELF 的样本点邻域大小 $k=7$, SELF 的权衡系数 $\beta=0.5$, 且几种方法

的低维子空间维数都设定为 4。故障诊断实质上为模式识别问题,维数约简后同类样本越聚集、不同类样本越分散则故障诊断的精度越高。因此,可将低维故障样本集类间平均距离与类内平均距离之比作为各维数约简方法有效性的评价指标,值得注意的是在进行计算时对于 LFDA 只考虑有标记训练样本,而其他方法则考虑所有训练样本。图 3 给出了采用几种方法进行维数约简后得到的低维故障样本集类间平均距离与类内平均距离之比。

图 3 采用几种方法进行维数约简后的类间平均距离与类内平均距离之比

从图 3 可以看出 PCA 维数约简后训练样本的聚类效果不理想, LFDA 维数约简后训练样本的聚类效果最好,而 SELF 和 OSLEF 维数约简后训练样本的聚类效果介于 PCA 和 LFDA 之间,且 OSLEF 维数约简后训练样本的聚类效果要优于 SELF。同时, PCA、SELF 和 OSLEF 维数约简后测试样本的聚类效果略差于训练样本,而 LFDA 维数约简后测试样本的聚类效果退化明显。表 2 给出了几种方法得到的故障诊断结果。从图 3 和表 2 给出的结果可知 PCA 作为一种无监督方法,无法利用故障类别信息来有效地指导维数约简过程,因此得到的结果不理想; LFDA 过度依赖于少数的有标记故障样本导致了过学习的问题,因此无法将测试样本很好地映射到所属低维子空间中,同样不能取得理想的故障诊断效果; SELF 和 OSLEF 集成了 PCA 在全局结构获取和 LFDA 在样本类别信息利用上的优势,既能够利用蕴含于无标记故障样本中的故障信息,又避

表 2 几种维数约简方法得到的故障诊断精度 %

约简方法	f_1	f_2	f_3	f_4	f_5	平均值
PCA	87.5	60	72.5	82.5	70.0	74.5
LFDA	60.0	75.0	87.5	80.0	72.5	75.0
SELF	100.0	90.0	95.0	92.5	87.5	92.5
OSLEF	100.0	97.5	100.0	95.0	92.5	97.0

免了 LFDA 存在的过学习问题,因此可得到比 PCA 和 LFDA 好的故障诊断效果,同时 OSLEF 采用正交映射矩阵将故障样本正交地映射到低维子空间,因此约简后的低维故障样本具有更好的可分性,更有利于分类器对新增故障样本进行故障识别。图 3 和表 2 的结果验证了 OSLEF 的有效性。

(2) 将 CFKNNC 进行故障识别的结果与 KNNC 进行对比。表 3 为采用 CFKNNC 和 KNNC 进行故障识别的结果对比,可以看出 CFKNNC 的识别精度较 KNNC 高。这是由于 CFKNNC 采用重构误差的大小来选取测试样本的最近邻训练样本,也就是说通过训练样本和测试样本间的线性相关度进行最近邻训练样本的选取,这就使得选出的最近邻训练样本能更好地代表测试样本,提高了分类器的识别精度。

表 3 两种分类器的平均识别率 %

分类器	f_1	f_2	f_3	f_4	f_5	平均值
CFKNNC	100.0	97.5	100.0	95.0	92.5	97.0
KNNC	100.0	92.5	97.5	90.0	92.5	94.5

4 结论

本文提出一种新的基于 OSLEF 的故障诊断方法,首先采用本文提出的 OSLEF 对故障样本集进行维数约简,由于 OSLEF 采用正交维数约简策略,因此具有比 SELF 更好的判别能力;然后通过 CFKNNC 来对低维故障样本进行故障模式识别,得到故障样本的故障类别。通过试验验证,本文方法能够有效、精确地对故障进行识别,为故障诊断提供了一种新的解决思路。

本文的后续研究可从以下几个方面进行。

(1) 目前 OSLEF 仍然是一种静态约简方法,如何将新增样本嵌入映射模型中仍待进一步的研究。

(2) 本文只对典型故障的诊断进行了研究,尚未涉及对早期故障的诊断(即故障萌芽即将出现、刚刚出现或者故障程度尚轻微)。

参 考 文 献

- [1] 雷亚国,何正嘉,訾艳阳. 基于混合智能新模型的故障诊断[J]. 机械工程学报, 2008, 44(7): 112-117.
LEI Yaguo, HE Zhengjia, ZI Yanyang. Fault diagnosis based on novel hybrid intelligent model[J]. Chinese Journal of Mechanical Engineering, 2008, 44(7): 112-117.
- [2] 李凌均,韩捷,李朋勇,等. 基于矢双谱的智能故障诊断方法[J]. 机械工程学报, 2011, 47(11): 64-68.

- LI Lingjun ,HAN Jie ,LI Pengyong ,et al. Intelligent fault diagnosis method based on vector-bispectrum[J]. Journal of Mechanical Engineering , 2011 , 47(11) : 64-68.
- [3] VIET H N , JEAN C G. Fault detection based on kernel principal component analysis[J]. Engineering Structures , 2010 , 32 : 3683-3691.
- [4] YU Jianbo. Bearing performance degradation assessment using locality preserving projections and Gaussian mixture models[J]. Mechanical Systems and Signal Processing , 2011 , 25 : 2573-2588.
- [5] LI Benwei , ZHANG Yun. Supervised locally linear embedding projection(SLLEP) for machinery fault diagnosis[J]. Mechanical Systems and Signal Processing , 2011 , 25 : 3125-3134.
- [6] SUGIYAMA M. Dimensionality reduction of multimodal labeled data by local Fisher discriminant analysis[J]. Journal of Machine Learning Research , 2007 , 8 : 1027-1061.
- [7] SUGIYAMA M. Semi-supervised local Fisher discriminant analysis for dimensionality reduction[J]. Journal of Machine Learning Research , 2010 , 78 : 35-61.
- [8] XU Yong , ZHU Qi. Coarse to fine k nearest neighbor classifier[J]. Pattern Recognition Letters , 2013 , 34 : 980-986.
- [9] WANG Ziqiang , SUN Xia. Multiple kernel local Fisher discriminant analysis for face recognition[J]. Signal Processing , 2013 , 93 : 1496-1509.
- [10] CAI Deng , HE Xiaofei , HAN Jiawei , et al. Orthogonal Laplacian faces for face recognition[J]. IEEE Transactions of Image Processing , 2006 , 11 : 3608-3614.
- [11] TAN Songbo. An effective refinement strategy for KNN text classifier[J]. Expert Systems with Applications , 2006 , 30 : 290-298.
- [12] 李锋 , 汤宝平 , 董绍江. 基于正交邻域保持嵌入特征约简的故障诊断模型[J]. 仪器仪表学报 , 2011 , 32(3) : 621-627.
- LI Feng , TANG Baoping , DONG Shaojiang. Fault diagnosis model based on feature compressing with orthogonal neighborhood preserving embedding[J]. Chinese Journal of Scientific Instrument , 2011 , 32(3) : 621-627.

作者简介：苏祖强，男，1987 年出生，博士研究生。主要研究方向为机械设备状态监测与故障诊断。

E-mail : jhonsu1987@126.com

汤宝平(通信作者)，男，1971 年出生，教授，博士研究生导师。主要研究方向为设备状态监测与故障诊断、虚拟仪器、无线传感器网络等。

E-mail : bptang@cqu.edu.cn