

# 基于流形学习与一类支持向量机的 滚动轴承早期故障识别方法

刘丽娟 陈 果 郝腾飞  
南京航空航天大学, 南京, 210016

**摘要:**提出了一种基于流形学习与一类支持向量机的轴承早期故障识别方法。首先提取轴承信号的时域参数构成原始特征样本空间;然后采用基于拉普拉斯特征映射算法(Laplacian eigenmap, LE)的流形学习方法对特征样本进行特征压缩,提取出敏感的故障特征;最后采用一类支持向量机对各状态实现分类识别。利用实测的滚动轴承故障数据对算法进行了验证,并将LE方法与主成分分析(PCA)方法进行了比较,结果证明该方法可行。

**关键词:**流形学习;一类支持向量机;轴承;故障识别;拉普拉斯特征映射

中图分类号:V263.6;TP277

DOI:10.3969/j.issn.1004-132X.2013.05.013

## Incipient Fault Recognition of Rolling Bearings Based on Manifold Learning and One-class SVM

Liu Lijuan Chen Guo Hao Tengfei

Nanjing University of Aeronautics and Astronautics, Nanjing, 210016

**Abstract:** A method was presented for incipient fault recognition of rolling bearings, which was based on manifold learning and one-class SVM. Firstly, the original feature space was constructed with the domain parameters of bearing signals, and then the LE was used to compress the feature samples and acquire the sensitive fault features. Finally the classification and recognition of all status were implemented with one-class SVM. Besides, with the actual fault data of rolling bearings the method was confirmed and the feasibility was indicated from the comparison of LE and principal component analysis.

**Key words:** manifold learning; one-class SVM; rolling bearing; fault recognition; Laplacian eigenmap(LE)

## 0 引言

在旋转机械中,滚动轴承的运行状态往往会直接影响整台机器的性能,因此,实现对滚动轴承的状态检测与故障诊断具有重要意义。目前,有效地从故障信号中提取特征的方法(如小波变换<sup>[1]</sup>、希尔伯特-黄变换(HHT)<sup>[2]</sup>等)被不断应用于滚动轴承故障特征提取,然而滚动轴承故障特征常常被淹没在强大的噪声背景下,大多数特征提取法所分解出的特征包含大量的冗余信息,从而降低了特征的敏感性,影响了后续分类的智能识别。

流形学习<sup>[3-6]</sup>作为提取数据非线性特征的一种先进方法,较之于传统的线性降维方法,它在处理采集所得高维、复杂非线性的故障信号时更能有效发现非线性数据的本质结构。流形学习可以根据其内在线性或者非线性关系,通过优化融合策略提取敏感特征<sup>[7]</sup>,利于进行维数约简和数据分析,目前已在机械故障诊断领域中被应用。

相对于一般支持向量机常常需要两类或两类以上的样本,一类支持向量机<sup>[8-10]</sup>仅仅需要一类

样本对象。在机械故障诊断领域中,故障状态的样本往往少且表现出多模式化,实际应用中难以获取且代价较高,而一类支持向量机只要测得一种故障的样本就可以建立对应的分类器,从而对机器的状态进行识别。

本文根据轴承早期故障的特点,提出了基于流形学习与一类支持向量机相结合的轴承早期故障识别方法。首先对原始的故障信号提取相应的时域参数构成原始特征空间;然后利用流形学习方法中的拉普拉斯特征映射算法(Laplacian eigenmap, LE)对原始特征空间的样本进行信息融合实现特征压缩,提取敏感的特征;最后采用一类支持向量机对特征压缩所得的特征样本进行分类识别。

## 1 基于拉普拉斯特征映射的流形学习方法

拉普拉斯特征映射<sup>[11-13]</sup>作为一种有效的流形学习算法,在一定程度上最优保持了原空间中数据点的局部分布情况。该方法的基本思想是:在高维空间中离得很近的点投影到低维空间中的像也应该离得很近,以两点间的加权距离作为损失函数,借助图拉普拉斯算子的谱性质进行求解,得

收稿日期:2011-10-20

基金项目:国家自然科学基金资助项目(61179057)

到保持数据集某种局部信息的最优低维表示。算法的实现步骤如下：

(1) 构建邻接图。设样本集  $X = \{x_1, x_2, \dots, x_i, \dots, x_n\}$ , 使用  $\epsilon$  邻域或者  $k$ -近邻的方法计算每个样本点  $x_i$  的邻域  $\Omega(i), i = 1, 2, \dots, n$ 。

①  $\epsilon$  邻域,  $\epsilon \in R$ 。如果样本点  $x_i$  与  $x_j$  满足  $\|x_i - x_j\|^2 < \epsilon$ , 则将顶点  $x_i$  与  $x_j$  连接起来,  $j \in \Omega(i)$ 。

②  $k$ -近邻,  $k < n$ 。如果顶点  $x_j$  属于顶点  $x_i$  的  $k$ -近邻点, 则将  $x_j$  与  $x_i$  连接起来,  $j \in \Omega(i)$ 。

(2) 构造邻接权值矩阵  $W$ 。对于上述任意连接的两个顶点  $x_i$  与  $x_j$ , 有两种方法给连接这两个顶点的边赋权值：

① 直接给顶点  $x_i$  与  $x_j$  相连的边赋予权值  $W_{ij} = 1$ 。

② 使用热核方程给每条边赋予权值  $W_{ij}$ , 设定

$$W_{ij} = \exp(-\|x_i - x_j\|^2 / t) \quad t \in R \quad (1)$$

若顶点  $x_i$  与  $x_j$  不相连, 则设  $W_{ij} = 0$ 。

(3) 特征映射。由样本集  $X$  与邻接权值矩阵  $W$  构造的间接权值图  $G = \{X, W\}$ , 图  $G$  的拉普拉斯算子定义为

$$L = D - W \quad (2)$$

其中,  $D$  为对角矩阵, 且  $D_{ii} = \sum W_{ij} (j \neq i)$ 。求解全局特征值问题即为求解

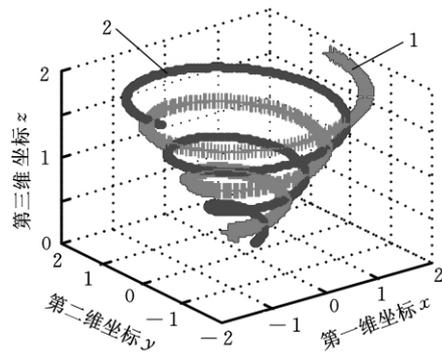
$$L\xi = \lambda D\xi \quad (3)$$

的广义特征值问题, 设  $\xi_0, \xi_1, \dots, \xi_{n-1}$  是对应式 (3) 特征值  $\lambda_0 \leq \lambda_1 \leq \dots \leq \lambda_{n-1}$  的特征向量。最终取第 2 个至第  $d+1$  个特征值对应的特征向量  $\xi_1, \xi_2, \dots, \xi_d$ , 即得到数据集对应的  $d$  维嵌入坐标。

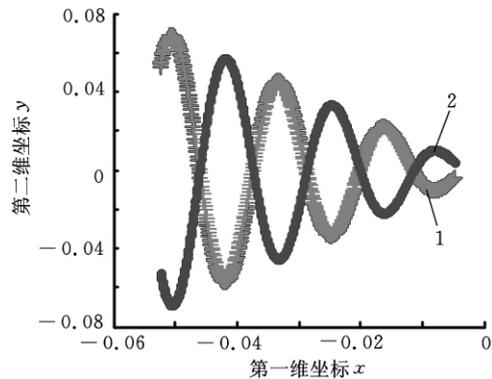
图 1a 所示为呈三维螺旋分布结构的两类样本。图 1b 和图 1c 分别为采用主成分分析 (PCA) 法以及 LE 方法进行特征压缩成二维的样本分布图。其中, LE 方法采用  $k$ -近邻方式 ( $k$  取 6) 构造近邻图, 使用热核方程构造邻接权值矩阵  $W$  ( $t$  取 10)。将图 1b 与图 1c 比较可以明显发现, 采用 LE 方法进行特征压缩后, 同样在压缩为二维的情况下, 要比采用 PCA 方法更容易提取区分样本的敏感特征, 使得两类样本更容易识别。

## 2 一类支持向量机原理

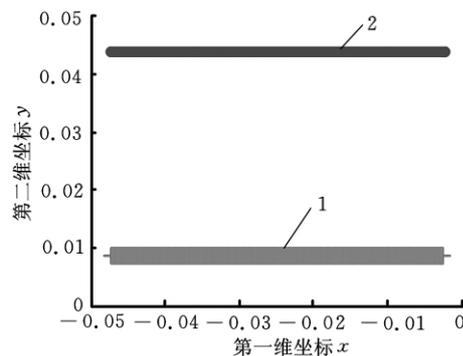
一类支持向量机针对一类对象 (如故障诊断中的正常运行状态, 正类样本), 而相对于该类对象的其他对象 (如故障诊断中的非正常运行状态, 负类样本) 统称异常对象。一类支持向量机本质上是寻找一个能够包含全部正类样本的最小超球体, 在球



(a) 原样本



(b) PCA 方法特征压缩



(c) LE 方法特征压缩

1. 样本 1 2. 样本 2

图 1 样本分布图

体外的点则视为负类样本。对于正类样本集:  $\{x_1, x_2, \dots, x_N\}$ , 该全部样本包围的最小球体的半径为  $R$ , 球心为  $a$ 。为了实现错误划分和区域范围之间的折中, 在优化过程中引入松弛变量, 满足

$$\left. \begin{aligned} \min \quad & L(R) = R^2 + C \sum_{i=1}^N \xi_i \\ \text{s. t.} \quad & (x_i - a)(x_i - a)^T \leq R^2 + \xi_i \\ & \xi_i \geq 0 \quad i = 1, 2, \dots, N \end{aligned} \right\} \quad (4)$$

定义 Lagrange 函数：

$$L(R, a, \Lambda, \xi) = R^2 + C \sum_{i=1}^N \xi_i - \sum_{i=1}^N \alpha_i [R^2 + \xi_i - (x_i^2 - 2ax_i + a^2)] - \sum_{i=1}^N \gamma_i \xi_i \quad (5)$$

其中,  $C$  为惩罚系数,  $\Lambda = \{\alpha_i\}$ , 对应的 Lagrange 系数  $\alpha_i \geq 0, \gamma_i \geq 0 (i = 1, 2, \dots, N)$ 。将式 (5) 分别

对  $R$  和  $\alpha$  求偏微分,并令其等于 0,得到相关的优化方程

$$\left. \begin{aligned} \max L &= \sum_{i=1}^N \alpha_i(x_i, x_i) - \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j(x_i, x_j) \\ \text{s. t. } \sum_{i=1}^N \alpha_i &= 1 \quad 0 \leq \alpha_i \leq C \end{aligned} \right\} \quad (6)$$

引入高斯径向基核函数  $(x, y) \rightarrow K(x, y)$ , 即

$$K(x, y) = \exp\left(-\frac{\|x - y\|^2}{\sigma^2}\right) \quad (7)$$

得到对应的优化方程

$$\left. \begin{aligned} \max L &= \sum_{i=1}^N \alpha_i K(x_i, x_i) - \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j K(x_i, x_j) \\ \text{s. t. } \sum_{i=1}^N \alpha_i &= 1 \quad 0 \leq \alpha_i \leq C \end{aligned} \right\} \quad (8)$$

实际上,根据 KKT(Karush-Kuhn-Tucker)条件,大部分  $\alpha_i$  为 0,只有一小部分  $\alpha_i > 0$ ,与那些不为零的  $\alpha_i$  对应的样本点决定了超球体边界的构成,为此,将这些样本点称为支持对象(support objection)。

对于待定状态数据  $z$ ,它到球心的距离的平方为

$$f(z) = K(z \cdot z) - 2 \sum_{i=1}^N \alpha_i K(z, x_i) + \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j K(x_i, x_j) \quad (9)$$

设任一支持对象  $x_s$ ,则球体半径的平方为

$$R^2 = K(x_s \cdot x_s) - 2 \sum_{i=1}^N \alpha_i K(x_s, x_i) + \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j K(x_i, x_j) \quad (10)$$

依据下式可判断  $z$  是否为正类样本:

$$\left. \begin{aligned} f(z) &\leq R^2 & z \text{ 为正类} \\ f(z) &> R^2 & z \text{ 为负类} \end{aligned} \right\} \quad (11)$$

### 3 基于流形学习与一类支持向量机的轴承故障识别

本文依据轴承早期故障的特征,采用时域参数构造原始特征空间,结合 LE 算法以及一类支持向量机,实现轴承故障识别。具体过程如下:

(1) 首先从滚动轴承数据信号中提取出 9 个时域参数<sup>[14-15]</sup>构成原始特征空间。这 9 个特征分别是:平均值、有效值、峰值、波形因数、冲击指数、波峰因数、歪度值、峭度值、裕度指数。

(2) 对于由时域参数构成的原始特征空间,采用 LE 算法对其实现特征压缩。本文在采用 LE 算法进行特征提取的过程中,首先采用  $k$ -近邻方式来构建邻接图,然后使用热核方程给每条边赋予权值来构造邻接权值矩阵  $W$ 。

(3) 对压缩后的特征样本采用一类支持向量

机实现故障分类识别。对于每种状态的样本,采用一类支持向量机实现故障识别:随机选择一半样本作为训练样本;剩余一半样本作为正类测试样本,同时作为其他状态的负类测试样本集的一部分,重复 10 轮。对于一类支持向量机中涉及的惩罚系数  $C$  和核函数参数  $\sigma$ ,本文采用网格搜索,5-fold 交叉验证。为了提高模型的泛化能力,本文在建立样本对应的分类模型时限定支持向量所占训练样本的比例不得超过 10% 并在此基础上实现对这两个参数的寻优。

#### 3.1 美国 Case Western Reserve University 滚动轴承数据

本文首先选择美国 Case Western Reserve University(CWRU)电器工程实验室的滚动轴承实验数据<sup>[16]</sup>进行实验分析。选择的数据源于 SKF6205 滚动轴承,采样频率 12kHz,选择损伤尺寸为 0.007mm 的四种转速下的内圈、外圈、滚珠故障以及正常状态下的数据。每种状态下每种转速(共四种转速)选择 25 个样本,样本维数均取 4096 维,即一种状态的样本为 100 个,一共取了 400 个样本。

分别对每种状态的样本信号提取 9 个时域参数,构成原始特征空间。对原始特征空间采用 LE 方法进行特征压缩,通过计算实验选择邻域参数  $k$  为 6,热核方程的参数  $t$  取 10,嵌入维数  $d$  取 3。为了进一步验证采用 LE 方法进行特征压缩实现智能诊断方法的可行性,同时将采用 LE 方法进行特征压缩的样本与采用 PCA 方法进行特征压缩(同样取嵌入维数  $d$  为 3)的样本进行比较,分别采用 LE 方法进行特征压缩以及采用 PCA 方法进行特征压缩,在嵌入维数为 3 维的情况下所得的样本分布图见图 2。从图 2 可以发现,相比于 PCA 方法,采用 LE 方法进行特征压缩后内圈样本、外圈样本与其他两种状态的样本分得很开,正常样本与滚珠样本虽然有个别混在一起,但是比 PCA 方法的情况要更容易分类识别。可见 LE 方法比 PCA 方法更能提取用于区分样本的敏感特征。

分别对未经压缩的特征样本、PCA 方法压缩的特征样本、LE 方法压缩的特征样本,同时采用一类支持向量机实现智能识别。三种情况得到的结果分别如下:表 1 是三种情况分别采用一类支持向量机建立各模型对应的支持向量的比例(训练样本个数为  $Train\_N$ ;支持向量比例为  $SVM\_R$ );表 2 是各模型所对应的识别结果(正类识别率  $R_s$ ,负类识别率  $R_b$ ,平均识别率  $R_i = (R_s$

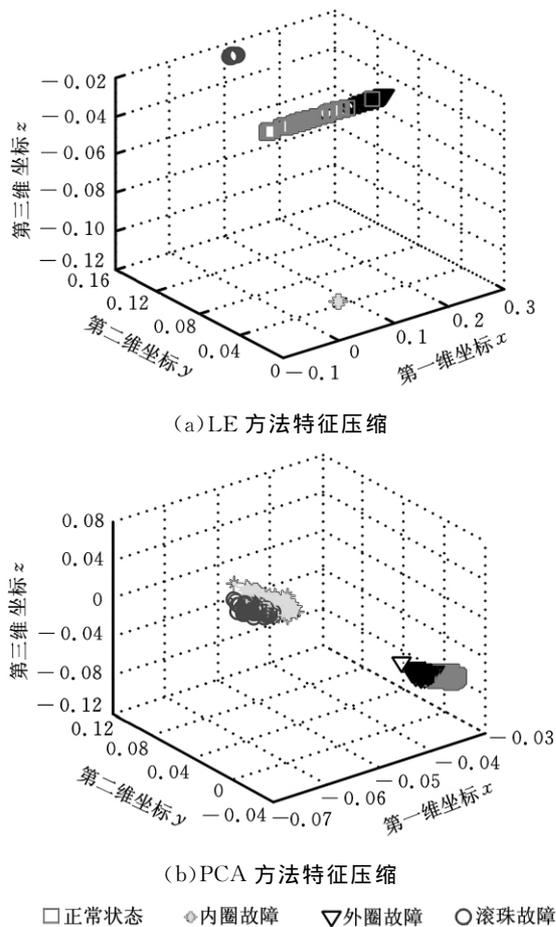


图2 CWRU轴承数据特征压缩后样本分布图

+  $R_b$ )/2 ( $i = 1, 2, 3, 4$ ), 总平均识别率  $R_T = \sum_{i=1}^4 R_i / 4$ 。

表1 CWRU轴承数据对应支持向量比例

|          |          | 未压缩        | PCA法<br>压缩 | LE法<br>压缩 |
|----------|----------|------------|------------|-----------|
| 状态<br>类型 | 正常<br>状态 | $Train\_N$ | 50         |           |
|          |          | $SVM\_R$   | 0.06       |           |
|          | 内圈<br>故障 | $Train\_N$ | 50         |           |
|          |          | $SVM\_R$   | 0.06       | 0.08      |
|          | 外圈<br>故障 | $Train\_N$ | 50         |           |
|          |          | $SVM\_R$   | 0.06       | 0.08      |
|          | 滚珠<br>故障 | $Train\_N$ | 50         |           |
|          |          | $SVM\_R$   | 0.06       |           |

从表1可以看出,一类支持向量机学习结果所得模型的支持向量比例很少,表明模型具有很强的泛化能力<sup>[17]</sup>,证明了所建模型的有效性。

从表2可以发现,采用LE方法对特征空间样本进行特征压缩后,在嵌入维数是3的情况下,采用LE方法进行特征压缩所得四种状态的样本平均识别率以及总平均识别率相比于未采用特征压缩以及采用PCA方法进行特征压缩后这两种情况,LE方法方式所得结果均为最优。这从整体上反映出同样是在嵌入维数为3的情况下,采用LE方法进行特征压缩要比采用PCA方法进行特征压

缩更能有效地提取特征空间中的敏感特征。由此可见,采用LE方法进行特征压缩后能够从特征空间中有效地提取出敏感特征从而实现故障识别,从而反映出本文方法是可行的、有效的。

表2 CWRU轴承数据识别结果

|          |          | 未压缩   | PCA法<br>压缩 | LE法<br>压缩 |       |
|----------|----------|-------|------------|-----------|-------|
| 状态<br>类型 | 正常<br>状态 | $R_a$ | 0.996      | 0.992     | 0.996 |
|          |          | $R_b$ | 0.708      | 0.887     | 0.961 |
|          |          | $R_1$ | 0.852      | 0.940     | 0.979 |
|          | 内圈<br>故障 | $R_a$ | 0.936      | 0.920     | 0.972 |
|          |          | $R_b$ | 1.000      | 1.000     | 1.000 |
|          |          | $R_2$ | 0.968      | 0.960     | 0.986 |
|          | 外圈<br>故障 | $R_a$ | 0.952      | 0.964     | 0.964 |
|          |          | $R_b$ | 1.000      | 1.000     | 1.000 |
|          |          | $R_3$ | 0.976      | 0.982     | 0.982 |
|          | 滚珠<br>故障 | $R_a$ | 0.968      | 0.972     | 0.968 |
|          |          | $R_b$ | 0.843      | 0.905     | 0.961 |
|          |          | $R_4$ | 0.906      | 0.939     | 0.965 |
| $R_T$    |          | 0.926 | 0.955      | 0.978     |       |

### 3.2 转子滚动轴承故障实验台数据

实验设备如图3所示,实验台主要由调速电动机、齿轮增速器、综合电子控制系统、丹麦B&K公司4508型加速度传感器、东大仪器厂SE系列电涡流位移传感器、NI公司USB9234数据采集器以及转子故障智能诊断系统RFIDS等部分构成。B&K加速度传感器安装在图3所示的左侧故障轴承座垂直(通道3)和水平(通道2,4)位置上,用于测加速度;电涡流位移传感器安装在右侧(通道1)位置,用于测转速。振动加速度信号由NI9234数据采集卡得到,转速通过控制调速电机来实现。待检测的轴承支撑着转轴转动,转轴两端轴承型号为HRB6304,采用电火花线切割方式,切割出图4所示的内圈、外圈、滚珠这三种轴承损伤故障,切割尺寸为0.2mm。

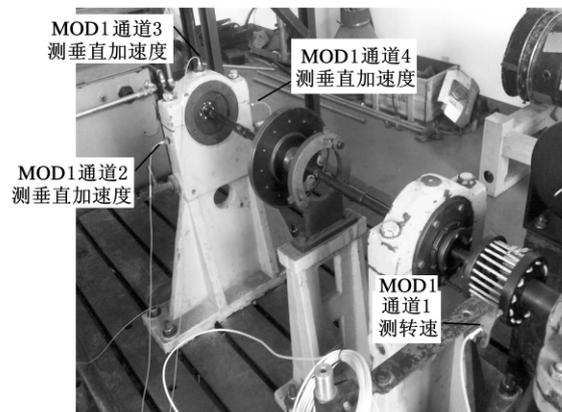


图3 转子滚动轴承故障实验器

本文从图3所示实验台的通道3采集对应内圈故障、外圈故障、滚珠故障以及正常这四种状态的数据,每种状态的样本均取100个,样本维数均

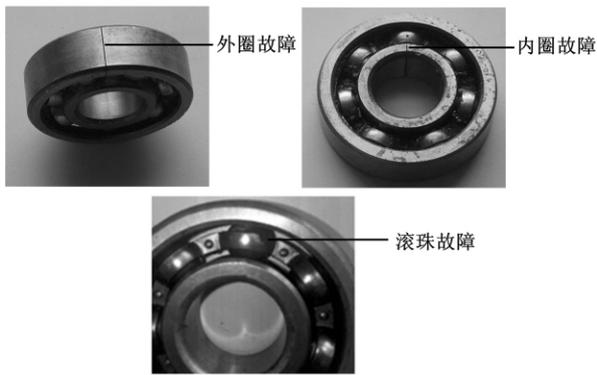
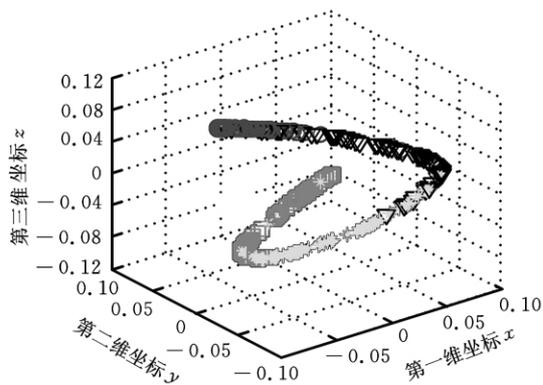


图 4 三种故障类型

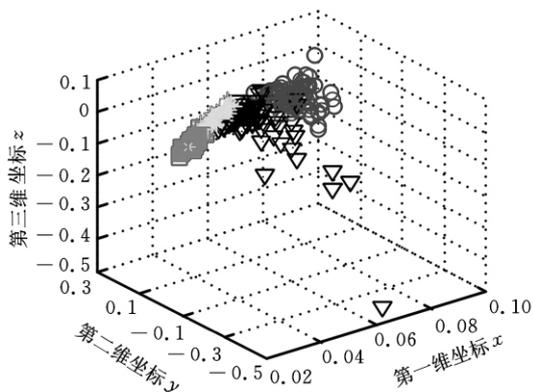
取 8192, 共取了 400 个样本。

### 3.3 实验与结果

对于实验台所得的四种状态的样本数据, 每种状态的样本信号均提取 9 个时域参数, 构成原始特征空间。同样对原始特征空间采用 LE 方法进行特征压缩, 通过计算, 设定邻域参数  $k$  为 6, 参数  $t$  取 10, 嵌入维数  $d$  取 3。为了验证 LE 方法的有效性, 同样采用 PCA 方法(同样取嵌入维数  $d$  为 3)对所构成的原始特征空间进行特征压缩。图 5 为采用 LE 方法以及 PCA 方法进行特征压缩后所得的样本数据分布图, 可以看出, 采用 LE 方法压缩后得到的三维特征能够将四类故障在空间中有效分离, 而采用 PCA 方法压缩后得到的三维特征在空



(a) LE 特征压缩



(b) PCA 特征压缩

□ 正常状态    ◆ 内圈故障    ▽ 外圈故障    ○ 滚珠故障

图 5 实验台数据特征压缩后样本分布图

间中区别度较前者差很多。由此可见, 采用 LE 方法充分提取了故障敏感的非线性特征。

对实验台数据在三种情况(未经特征压缩的原始特征空间样本, 采用 PCA 方法进行特征压缩后的特征样本, 采用 LE 方法进行特征压缩后的特征样本)下分别采用一类支持向量机进行智能识别。建立各模型时支持向量占训练样本所对应的比例见表 3, 可以看出, 所建模型的支持向量比例很少, 体现了模型的泛化能力及有效性。表 4 所示为所建模型对应的识别结果。

表 3 转子滚动轴承故障实验台数据对应支持向量比例

|              |          | 未压缩        | PCA 法<br>压缩 | LE 法<br>压缩 |
|--------------|----------|------------|-------------|------------|
| 状态<br>类<br>型 | 正常       | $Train\_N$ | 50          |            |
|              | 状态       | $SVM\_R$   | 0.04        | 0.08       |
|              | 内圈<br>故障 | $Train\_N$ | 50          |            |
|              |          | $SVM\_R$   | 0.04        |            |
|              | 外圈<br>故障 | $Train\_N$ | 50          |            |
|              |          | $SVM\_R$   | 0.04        | 0.06       |
|              | 滚珠<br>故障 | $Train\_N$ | 50          |            |
|              |          | $SVM\_R$   | 0.08        | 0.04       |

表 4 转子滚动轴承故障实验台数据识别结果

|              |          | 未压缩   | PCA 法压缩 | LE 法压缩 |
|--------------|----------|-------|---------|--------|
| 状态<br>类<br>型 | 正常<br>状态 | $R_a$ | 0.845   | 0.983  |
|              |          | $R_b$ | 0.786   | 0.867  |
|              |          | $R_1$ | 0.816   | 0.925  |
|              | 内圈<br>故障 | $R_a$ | 0.770   | 0.900  |
|              |          | $R_b$ | 0.727   | 0.800  |
|              |          | $R_2$ | 0.749   | 0.850  |
|              | 外圈<br>故障 | $R_a$ | 0.770   | 0.903  |
|              |          | $R_b$ | 0.840   | 0.941  |
|              |          | $R_3$ | 0.805   | 0.922  |
|              | 滚珠<br>故障 | $R_a$ | 0.868   | 0.974  |
|              |          | $R_b$ | 0.545   | 0.692  |
|              |          | $R_4$ | 0.707   | 0.833  |
| $R_T$        |          | 0.769 | 0.883   |        |

从表 4 可以看出, 采用 LE 方法对轴承样本数据构成的特征空间进行特征压缩, 所得的四种状态的平均识别率以及整体平均识别率比其他两种情况下所得的实验结果更好, 均为最优。由此可见, 采用本文提出的基于 LE 方法的流形学习方法对轴承早期故障可更有效地提取特征, 能够大大提高故障的识别率。

## 4 结论

(1) 本文将流形学习中的拉普拉斯特征映射算法引入轴承故障诊断中进行特征提取, 并一类支持向量机结合, 实现了轴承早期故障识别。首先对故障信号提取 9 个时域参数构成原始特征空间, 然后采用拉普拉斯特征映射法从中提取出敏感特征, 对于特征压缩后的样本, 分别以不同状

态的训练样本采用一类支持向量机实现故障分类识别,同时采用网格搜索法结合交叉验证的方式对相关参数进行寻优。

(2)为了验证本文方法的有效性,将其与主成分分析法进行了比较,利用实测滚动轴承故障数据进行了验证。结果表明,采用拉普拉斯特征映射法方法能够有效提取出故障样本的非线性特征,达到特征空间信息的有效融合从而提取敏感特征,实现了轴承早期故障的智能识别。

需要指出的是,将拉普拉斯特征映射法这种新的非监督学习方法应用于轴承故障诊断领域,涉及的邻域参数、嵌入维数的选择等不确定问题还需进一步研究。

参考文献:

[1] 陈果. 滚动轴承早期故障的特征提取与智能诊断[J]. 航空学报, 2009, 30(2): 362-267.  
Chen Guo. Feature Extraction and Intelligent Diagnosis for Ball Bearing Early Faults[J]. Acta Aeronautica et Astronautica Sinica, 2009, 30(2): 362-267.

[2] Huang N E, Shen Z, Long S R. The Empirical Mode Decomposition and the Hilbert Spectrum for Nonlinear and Non-Stationary Time Series Analysis[C]// Proceedings of the Royal Society. London, 1998: 903-995.

[3] Seung H S, Daniel D L. The Manifold Ways of Perception[J]. Science, 2000, 290(5500): 2268-2269.

[4] Roweis S, Saul L. Nonlinear Dimensionality Reduction by Locally Linear Embedding [J]. Science, 2000, 290(5500): 2323-2326.

[5] Tenenbaum J, Silva D D, Langford J. A Global Geometric Framework for Nonlinear Dimensionality Reduction[J]. Science, 2000, 290(5500): 2319-2323.

[6] 罗四维, 赵连伟. 基于谱图理论的流形学习算法[J]. 计算机研究与发展, 2006, 43(7): 1173-1179.  
Luo Siwei, Zhao Lianwei. Manifold Learning Algorithms Based on Spectral Graph Theory[J]. Journal of Computer Research and Development, 2006, 43(7): 1173-1179.

[7] 栗茂林, 王孙安, 梁霖. 利用非线性流形学习的轴承早期故障特征提取方法[J]. 西安交通大学学报, 2010, 44(5): 45-49.  
Li Maolin, Wang Sun'an, Liang Lin. Feature Extraction for Incipient Fault Diagnosis of Rolling Bearings Based on Nonlinear Manifold Learning[J]. Journal of Xi'an Jiaotong University, 2010, 44(5): 45-49.

[8] Juszczak P. Learning to Recognise: a Study on One-class Classification and Active Learning [D]. Delft: Delft University of Technology, 2006.

[9] 谭真臻, 陈果, 陈立波, 等. 基于图像分析和野点检测的航空发动机磨损状态识别[J]. 中国机械工程, 2010, 21(7): 827-831.  
Tan Zhenzhen, Chen Guo, Chen Libo, et al. Aero-engine Wear State Recognition Based on Image Analysis and Novelty Detection [J]. China Mechanical Engineering, 2010, 21(7): 827-831.

[10] 杨洁明, 田英. 基于 EMD 和球结构 SVM 的滚动轴承故障诊断[J]. 振动、测试与诊断, 2009, 29(2): 155-158.  
Yang Jieming, Tian Ying. Roller Bearing Fault Diagnosis by Using Empirical Mode Decomposition and Sphere-Structured Support Vector Machine[J]. Journal of Vibration, Measurement & Diagnosis, 2009, 29(2): 155-158.

[11] Belkin M, Niyogi P. Laplacian Eigenmaps and Spectral Techniques for Embedding and Clustering [C]// Advances in NIPS 14. Cambridge, 2001: 585-591.

[12] Belkin M, Niyogi P. Laplacian Eigenmaps for Dimensionality Reduction and Data Representation [J]. Neural Computation (S0899-7667), 2003, 15(6): 1373-1396.

[13] 蒋全胜, 贾民平, 胡建中, 等. 基于拉普拉斯特征映射的故障模式识别方法[J]. 系统仿真学报, 2008, 20(20): 5710-5713.  
Jiang Quansheng, Jia Minping, Hu Jianzhong, et al. Method of Fault Pattern Recognition Based on Laplacian Eigenmaps[J]. Journal of System Simulation, 2008, 20(20): 5710-5713.

[14] 李良敏, 屈梁生. 遗传编程在无量纲指标构建中的应用[J]. 西安交通大学学报, 2002, 36(7): 735-739.  
Li Liangmin, Qu Liangsheng. Genetic Programming for Dimensionless Parameters Construction [J]. Journal of Xi'an Jiaotong University, 2002, 36(7): 735-739.

[15] 易良桀. 简易振动诊断现场实用技术[M]. 北京: 机械工业出版社, 2003.

[16] The Case Western Reserve University Bearing Data Center. Bearing Data Center Fault Test Data [EB/OL]. [2009-10-01]. <http://www.eecs.cwru.edu/laboratory/bearing/>.

[17] Tax D, Duin R. Support Vector Data Description [J]. Machine Learning, 2004, 54(1): 45-66.

(编辑 陈 勇)

作者简介: 刘丽娟, 女, 1986 年生。南京航空航天大学民航学院硕士研究生。主要研究方向为图像处理与模式识别、智能故障诊断。陈 果, 男, 1972 年生。南京航空航天大学民航学院教授、博士研究生导师。郝腾飞, 男, 1983 年生。南京航空航天大学民航学院博士研究生。