

文章编号 :1001 - 2486(2004)01 - 0089 - 06

主成分分析在铁谱磨粒识别中的应用研究^{*}

李 岳 , 吕克洪

(国防科技大学机电工程与自动化学院 湖南 长沙 410073)

摘要 介绍了主成分分析(PCA)基本原理与算法,提出了主成分分析用于铁谱磨粒识别的基本思路和方法,给出了具体的应用步骤,并通过实例对基于主成分分析的铁谱磨粒识别方法有效性进行了分析和验证,结果表明,该方法在减少铁谱磨粒识别工作量和提高识别准确率方面效果良好。

关键词 主成分分析,铁谱磨粒,识别

中图分类号 :TP277 文献标识码 :A

The Application of the Principal Components Analysis (PCA) to Debris Recognition

LI Yue ,Lü Ke-hong

(College of Mechatronics Engineering and Automation , National Univ. of Defense Technology , Changsha 410073 , China)

Abstract The basic principle and algorithm of the Principal Components Analysis(PCA) are introduced in detail. The debris recognition approach based on the PCA is presented, and the process of using this approach to deal with the debris recognition is described. The validity of the approach is proved and the satisfying effects on improving the veracity of recognising and decreasing the workload of calculation are also demonstrated by the experiment of classifying a group of typical examples.

Key words Principal Components Analysis(PCA),debris,recognition

铁谱分析作为一种不解体的故障诊断方法,广泛应用于机械设备状态监测与故障诊断领域。铁谱分析的关键在于磨粒识别,以计算机为核心的铁谱磨粒识别技术已越来越为学术界和工程界所关注,目前常用的磨粒识别方法有图像匹配、神经网络等。由于磨粒形貌特征非常复杂,对各类磨粒的描述往往需要采用多项参数指标,而这些参数指标又可能存在较强的相关性,因此,降低磨粒参数维数和去除参数间的相关性有助于减少识别工作量和提高识别准确率。本文提出采用多元统计分析中的主成分分析(Principal Components Analysis,PCA)进行铁谱的磨粒识别,为解决这一问题提供了一种较为有效的手段。

1 主成分分析(PCA)的基本原理及算法^[1,2]

1.1 基本原理

主成分分析(PCA)是一种将多个相关变量化为少数几个不相关变量的一种多元统计分析方法。其原理可描述为:

设有 n 个样本,每个样本有 p 个变量,这样就构成了一个 $n \times p$ 阶矩阵:

$$X = \begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1p} \\ x_{21} & x_{22} & \cdots & x_{2p} \\ \vdots & \vdots & & \vdots \\ x_{n1} & x_{n2} & \cdots & x_{np} \end{bmatrix} \quad (1)$$

从多变量出发,研究问题的内在规律性,需在 p 维空间中加以考察,随着样本数 n 和样本维数 p 的增

^{*} 收稿日期 2003 - 08 - 20

作者简介 李岳(1964—),男,副教授,在职博士生。

加,处理问题的工作量和复杂度随之加大。若能用较少的几个综合变量来代替原来较多的变量(即降维处理),处理问题将会变得简单。但是在降维处理时,所选取综合变量必须能尽量多地反映原来多变量所包含的信息,同时,它们之间又需相互独立。显然,最简单的处理方式就是取原多变量指标的线性组合,适当调整组合系数,使新变量指标之间的相互独立及代表性最好。记原来的变量指标为 x_1, x_2, \dots, x_p ,它们的综合指标(新变量)为 z_1, z_2, \dots, z_m ($m \leq p$),则:

$$\begin{cases} z_1 = l_{11}x_1 + l_{12}x_2 + \dots + l_{1p}x_p \\ z_2 = l_{21}x_1 + l_{22}x_2 + \dots + l_{2p}x_p \\ \vdots \\ z_m = l_{m1}x_1 + l_{m2}x_2 + \dots + l_{mp}x_p \end{cases} \quad (2)$$

在(2)式中,系数 l_{ij} 由下列原则来决定:

(1) z_i 与 z_j ($i \neq j$; $i, j = 1, 2, \dots, m$) 相互无关;

(2) z_1 是 x_1, x_2, \dots, x_p 的所有线性组合中方差最大者; z_2 是与 z_1 不相关的 x_1, x_2, \dots, x_p 的所有线性组合中方差最大者; \dots ; z_m 是与 z_1, z_2, \dots, z_{m-1} 都不相关的 x_1, x_2, \dots, x_p 的所有线性组合中方差最大者。这样得到的新变量指标 z_1, z_2, \dots, z_m 分别称为原变量指标 x_1, x_2, \dots, x_p 的第一,第二, ..., 第 m 主成分。其中, z_1 在总方差中占的比例最大, z_2, z_3, \dots, z_m 的方差依次递减。在实际问题的分析中,常挑选前几个最大的主成分,这样既减少了变量的数目,又抓住了主要矛盾,简化了变量之间的关系。

1.2 主成分分析算法

(1) 计算相关系数矩阵

$$\mathbf{R} = \begin{bmatrix} r_{11} & r_{12} & \dots & r_{1p} \\ r_{21} & r_{22} & \dots & r_{2p} \\ \vdots & \vdots & & \vdots \\ r_{p1} & r_{p2} & \dots & r_{pp} \end{bmatrix} \quad (3)$$

式(3)中, r_{ij} ($i, j = 1, 2, \dots, p$) 为原来变量 x_i 与 x_j 的相关系数,其计算公式为:

$$r_{ij} = \frac{\sum_{k=1}^n (x_{ki} - \bar{x}_i)(x_{kj} - \bar{x}_j)}{\sqrt{\sum_{k=1}^n (x_{ki} - \bar{x}_i)^2 \sum_{k=1}^n (x_{kj} - \bar{x}_j)^2}} \quad (4)$$

其中, \bar{x}_i, \bar{x}_j 分别为矩阵 X 的第 i, j 列的均值,因为 \mathbf{R} 是实对称矩阵(即 $r_{ij} = r_{ji}$),所以只需计算其上三角元素或下三角元素即可。

(2) 计算特征值与特征向量

解特征方程 $|\lambda\mathbf{I} - \mathbf{R}| = 0$ 求出特征值 λ ($i = 1, 2, \dots, p$),并使其按大小顺序排列,即 $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_p \geq 0$ 再分别求出对应于特征值 λ_i 的标准特征向量 e_i (j ($i = 1, 2, \dots, p$); $j = 1, 2, \dots, p$)。

(3) 计算主成分贡献率及累计贡献率

主成分 z_i 贡献率: $a_i = \lambda_i / \sum_{j=1}^p \lambda_j$, 累计贡献率: $AC = \sum_{i=1}^m a_i$ 。

一般取累计贡献率达 80% ~ 95% 的特征值 $\lambda_1, \lambda_2, \dots, \lambda_m$ 所对应的第一,第二, ..., 第 m ($m \leq p$) 个主成分。

(4) 计算主成分

第 h ($h = 1, 2, \dots, m$) 主成分 z_h 为: $z_h = e'_h \times X'$ (5)

由(5)式可以看出, z_h 是原变量 x_j ($j = 1, 2, \dots, p$) 的线性组合,而组合系数恰为 $e'_h = (e_h(1), e_h(2), \dots, e_h(p))$,由此可以进一步计算主成分得:

$$\mathbf{Z} = (z'_1 \ z'_2 \ \dots \ z'_m) = \begin{bmatrix} z_{11} & z_{12} & \dots & z_{1m} \\ z_{21} & z_{22} & \dots & z_{2m} \\ \vdots & \vdots & & \vdots \\ z_{n1} & z_{n2} & \dots & z_{nm} \end{bmatrix} \quad (6)$$

(5) 数据还原

为了进行比较,有时需要将主成分空间中的数据还原到原始空间中去,得到在原始数据空间下的新综合变量矩阵 $\hat{\mathbf{X}}$,由 $(\hat{\mathbf{X}}) = (\mathbf{E}')^{-1} \mathbf{Z}'$ (其中 $\mathbf{E}' = (e_1 \ e_2 \ \dots \ e_m)$ 为选取的 m 个主成分所对应的标准特征向量)可得出:

$$\hat{\mathbf{X}} = \mathbf{Z} \times \mathbf{E}^{-1} = \mathbf{Z} \times \mathbf{E} \quad (7)$$

2 主成分分析(PCA)应用于铁谱磨粒识别的方法与步骤

2.1 磨粒的特征参数描述

铁谱磨粒是由摩擦副间的相互作用产生的,其形态各异、不尽相同。因此,仅用几个参数对磨粒进行描述是十分困难的。为了能够尽可能多地将磨粒自身特征信息反映出来,描述磨粒的特征参数可以多达数十个。一般地,描述磨粒形态的主要参数包括^[3],

- (1) 尺寸参数: 面积(A)、当量直径(D)、长轴长度(a)、短轴长度(b)、磨粒周长(L)等;
- (2) 形状参数: 圆形度(Rd)、长宽比(R_l)、凹度(C_v)、边界粗造度等;
- (3) 结构参数: 孔洞率(E'')等;
- (4) 灰度参数: 灰度平均值(G_m)、灰度变化率(G_v)等;
- (5) 边缘参数: 边缘结构函数($H(r)$)、边缘转向度(A_n)等;
- (6) 不规则形状参数: 灰度纹理(F_{gt})、灰度结构(F_{gs})、边缘细节(F_{pt})、边缘结构(F_{ps})等。

为了识别某个磨粒,就必须在上述参数空间中进行分析,而这个参数空间是一个典型的高维空间,使得磨粒的分析识别工作变得复杂。由于在一个低维空间中进行磨粒识别要比在一个高维空间中容易得多,所以对原参数空间进行降维处理将有助于减少识别工作量和提高识别的准确率。

2.2 各类标准磨粒样本的主成分提取

根据机械零件之间的磨损模式不同,可将磨粒分为正常滑动磨粒、严重滑动磨粒、切削磨粒、疲劳剥块、层状磨粒、球状磨粒及氧化物磨粒等七类^[4]。但由于磨粒的自身特点,具有相同磨损模式的磨粒其具体特征参数也不尽相同。为了能够提取出相同磨损模式磨粒具有代表性的一组或几组特征参数数据,本文采用主成分分析法对具有相同磨损模式的许多标准磨粒样本数据进行主成分提取。具体方法为:

(1) 某磨损模式磨粒(l 如切削磨粒)的 p 个标准样本中,每一个样本 y^i_l ($k = 1, 2, \dots, p$) 包括 n 个数据值(n 为参数个数),是一个 n 维向量,这些样本数据构成一个矩阵 \mathbf{Y}^i 。

$$\mathbf{Y}^i = \begin{bmatrix} y_{11}^i & y_{12}^i & \dots & y_{1p}^i \\ y_{21}^i & y_{22}^i & \dots & y_{2p}^i \\ \vdots & \vdots & & \vdots \\ y_{n1}^i & y_{n2}^i & \dots & y_{np}^i \end{bmatrix} \quad (8)$$

(2) 对该矩阵提取主成分,得到主成分空间中的主成分 \mathbf{T}_m (m 个主成分)。

$$\mathbf{T}_m = \begin{bmatrix} t_{11} & t_{12} & \dots & t_{1m} \\ t_{21} & t_{22} & \dots & t_{2m} \\ \vdots & \vdots & & \vdots \\ t_{n1} & t_{n2} & \dots & t_{nm} \end{bmatrix} \quad (9)$$

(3) 将主成分数据还原到原数据空间,得到在原始空间中的低维数据 \mathbf{T}^i 。这些数据其实是原始数据在主成分方向上的投影(\mathbf{T}^i 为 $n \times m$ 维矩阵)。

$$\mathbf{T}^i = \begin{bmatrix} t_{11}^i & t_{12}^i & \dots & t_{1m}^i \\ t_{21}^i & t_{22}^i & \dots & t_{2m}^i \\ \vdots & \vdots & & \vdots \\ t_{n1}^i & t_{n2}^i & \dots & t_{nm}^i \end{bmatrix} \quad (10)$$

2.3 标准磨粒参数的主成分提取

各类标准磨粒样本经过上面的降维处理后,得到一系列能充分反映各类磨粒参数特征的综合样本 T^i ,但是这样处理只是减少了同一类磨粒的样本数据量,而磨粒数据的参数个数并未得到减少,为了能在低维空间中识别磨粒,就必须对参数进行降维处理。具体方法如下:

(1) 将经数据降维得到的各类磨粒的新数据组成矩阵 X 。 $(l$ 为各类磨粒样本数据通过数据降维而选取的主成分个数之和)

$$X = (\mathbf{T}^a \quad \mathbf{T}^b \quad \dots \quad \mathbf{T}^i)' = \begin{bmatrix} t_{11}^a & t_{12}^a & \dots & t_{1m}^a & t_{1(m+1)}^b & \dots & t_{1l}^i \\ t_{21}^a & t_{22}^a & \dots & t_{2m}^a & t_{2(m+1)}^b & \dots & t_{2l}^i \\ \vdots & \vdots & & \vdots & \vdots & & \vdots \\ t_{n1}^a & t_{n2}^a & \dots & t_{nm}^a & t_{n(m+1)}^b & \dots & t_{nl}^i \end{bmatrix}' \quad (11)$$

(2) 计算矩阵 X 的主成分 Z 。

通过运算得到矩阵 X 的特征向量为 $E = (e_1 \quad e_2 \quad \dots \quad e_n)'$,设选取主成分数量为 m (主成分数量通过累计贡献率的大小选取),则

$$Z = \begin{bmatrix} z_{11} & z_{12} & \dots & z_{1m} \\ z_{21} & z_{22} & \dots & z_{2m} \\ \vdots & \vdots & & \vdots \\ z_{k1} & z_{k2} & \dots & z_{km} \end{bmatrix} \quad (12)$$

这个新的 m 维综合参数空间的获得,大大降低了原来磨粒参数空间的维数,而保持了各标准磨粒的大部分信息,这为新样本的识别提供了方便。

2.4 待检磨粒样本的识别

对于一个未知类型的铁谱磨粒,可以得到它在原始数据空间内的一组数据 W ,即, $W = (w_1 \quad w_2 \quad \dots \quad w_n)$ (n 为参数个数),为了进行识别,将该组数据转化到主成分空间,得到新的综合参数 \tilde{W} ,计算式为:

$$\tilde{W} = W \times E' = (\tilde{w}_1 \quad \tilde{w}_2 \quad \dots \quad \tilde{w}_m) \quad (13)$$

待检磨粒的这个综合参数,与原标准磨粒样本的综合参数(主成分 Z)在主成分空间中都表示一系列的样本点。在这个低维空间(如二维、三维)中的待检磨粒识别就变得相对容易,可以采用最小距离或模糊聚类等方法。

3 实例与分析

3.1 实例过程

本文提出的基于主成分分析的铁谱磨粒识别方法已应用于某型履带式车辆的柴油发动机故障检测与分析系统。其应用过程为:从发动机滑油系统采集油样,将油样送入颗粒制谱仪制取谱片,通过基于微机控制的铁谱显微镜进行磨粒图像捕捉和采集,计算磨粒参数,采用主成分分析提取主要特征,最后送入分类器进行磨粒识别(与标准磨粒样本库比较)。

应用中,系统的标准磨粒样本库由 115 个磨粒样本组成,分为 7 类磨粒,对每个磨粒样本分别选取了 53 个特征量,如表 1 所示。其中,样本 1 ~ 49 代表正常滑动磨损微粒,样本 50 ~ 63 代表严重滑动磨粒;样本 64 ~ 79 代表切削磨粒,样本 80 ~ 95 代表疲劳块状磨粒,样本 96 ~ 106 代表层状磨粒,样本 107 ~

115 代表球状磨粒。本例应用的待检样本 1、待检样本 2 和待检样本 3 为由某次送检油样所制成铁谱片上捕捉到的未知磨粒样本。

表 1 磨粒样本的特征数据

Tab. 1 The characteristic data of debris samples

样本号	参数 1	参数 2	参数 52	参数 53
	面积	等效直径	磨粒孔隙率	对比度
标准样本 1	7.8488	4.1958	0.0688	10.264
标准样本 2	7.4292	6.8369	0.0194	32.263
.....
标准样本 114	82.881	10.321	0.0021	31.232
标准样本 115	40.195	9.5544	0.0002	13.091
待检样本 1	93.5695	6.3455	0.0117	9.6801
待检样本 2	5.59432	2.6732	0.0032	12.583
待检样本 3	28.3423	4.6876	0.0463	8.3247

磨粒特征参数经主成分分析(取三个主成分,其累计贡献率为:AC = 0.85)结果如表2所示,其中待检磨粒1与第24个标准磨粒样本距离最小(距离为0.0928),说明待检样本磨粒的特征信息与第24个标准磨粒样本最接近,由此可判定该磨粒与第24个标准磨粒同类,属于正常滑动磨损微粒;同理,待检样本2与第93个标准磨粒同类,属于疲劳块状磨粒;待检样本3与第76个标准磨粒同类,属于切削磨粒。

表 2 主成分分析计算结果

Tab. 2 The computed result by PCA

样本	第一	第二	第三	待检样本 1 与各	待检样本 2 与各	待检样本 3 与各
	主成分	主成分	主成分	样本间的距离	样本间的距离	样本间的距离
标准样本 1	-3.0779	0.3676	0.4471	1.1224	2.8388	1.9923
标准样本 2	-3.2683	-1.5141	0.9486	2.1620	3.0189	0.7001
.....
标准样本 24	-3.6316	0.0418	-0.5110	0.0928	1.9737	1.9431
.....
标准样本 76	-3.8635	-1.4358	0.6897	1.9410	2.8454	0.0875
.....
标准样本 93	-2.6364	-0.9986	-1.9976	2.0194	0.3439	3.0579
.....
标准样本 114	-2.4559	0.5586	-0.8190	1.2349	2.0826	2.9148
标准样本 115	-5.7225	0.1274	-0.9836	2.2321	3.1726	2.9267
待检样本 1	-3.5397	0.0456	-0.5239	0.0000	1.9372	1.9704
待检样本 2	-2.9689	-1.0863	-1.9888	1.9372	0.0000	2.9134
待检样本 3	-3.9297	-1.4130	0.7422	1.9704	2.9134	0.0000

3.2 实例分析

本例中,待检谱片上的沉积磨粒很多,限于篇幅,仅选择了三个具有代表性的磨粒(正常滑动磨损、切削磨粒、疲劳块状磨粒)来对主成分分析法在磨粒识别中的应用效果进行了验证。其结果表明,利用

该方法进行磨粒识别的准确率较高,三个待检样本都较好地分到所属的磨粒类别中。同时还可以看出,描述磨粒的特征参数经主成分分析后,磨粒的描述空间由原来的高维空间(53个参数)转换到低维空间(3个参数),这种处理的结果是降低了识别的难度,使效率得到提高。

主成分分析在用于铁谱磨粒识别的过程中,其识别的准确率与标准样本的数量及标准样本自身的代表性等因素有关。同一类磨粒具有代表性的标准样本越多,代表性越好,识别准确率就会越高,因此该方法用于磨粒识别时必须建立一个标准磨粒样本库。

由于磨粒的原特征空间是一个高维的数据空间(53个参数),各磨粒样本点无法直观表示。经PCA分析后,各样本的特征参数化为三个综合参数,这为磨粒样本的直观表示创造了条件。如图1所示为部分磨粒样本点在主成分空间的分布,由PCA的基本原理可知,这些主成分数据是原数据在其变化最大的方向上的投影,反映了原始数据的主要信息。

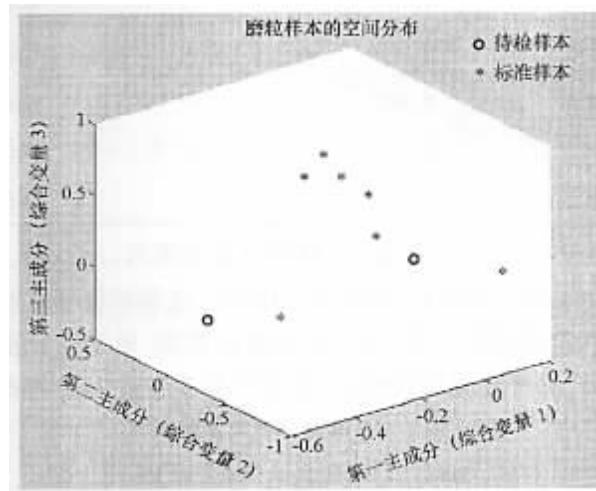


图1 磨粒样本在主成分空间的分布

Fig.1 The distribution of debris samples in the principal components space

4 结论

常用的铁谱磨粒识别方法需要在高维空间内对数据进行分析,本文采用主成分分析法(PCA)对磨粒特征参数进行主成分提取,将磨粒的原众多特征参数化为几个综合参数,为磨粒分析识别工作在低维空间中进行创造了条件。

参考文献:

- [1] Smith L I. A Tutorial on Principal Components Analysis [R]. <http://www.cs.otago.nz/>.
- [2] 任若恩,王惠文.多元统计数据分析[M].北京:国防工业出版社,1997:92~109.
- [3] Li Yanjun, Zuo Hongfu, Wu Zhengfeng. Debris Monitoring and Analyzing System and Its Application in Aeroengines[J]. Transaction of Nanjing University of Aeronautics & Astronautics, 2001, 18(2).
- [4] Anderson D P. 磨粒图谱[M].金元生,扬其明,译.北京:机械工业出版社,1987:1~14.

