

文章编号:1000-8055(2011)03-0698-06

基于流形学习的涡轮泵海量数据异常识别算法

夏鲁瑞^{1,2}, 胡芑庆¹, 秦国军¹

(1. 国防科学技术大学 机电工程与自动化学院, 长沙 410073;

2. 装备指挥技术学院 航天装备系, 北京 101416)

摘 要: 为了获取海量试车数据中的信息以分析涡轮泵的健康状态, 提出一种基于流形学习的海量数据异常识别算法. 该算法将反映涡轮泵状态的振动数据重构到高维空间中, 利用扩散映射方法直接对其进行学习, 提取出数据内在的低维流形特征, 以可视化的方式直观地识别出涡轮泵数据中的异常状态. 仿真与试车数据验证结果表明了所提算法的可行性和有效性. 该算法克服了传统方法解决非线性问题不足的缺点, 为试车后涡轮泵的健康分析提供了一条新的途径.

关 键 词: 涡轮泵; 异常识别; 流形学习; 扩散映射; 海量数据

中图分类号: V434⁺. 21

文献标识码: A

Abnormal recognition algorithm based on manifold learning for turbopump mass data

XIA Lu-rui^{1,2}, HU Niao-qing¹, QIN Guo-jun¹

(1. College of Mechatronic Engineering and Automation,

National University of Defense Technology, Changsha 410073, China;

2. Department of Space Equipment,

Academy of Equipment Command and Technology, Beijing 101416, China)

Abstract: To extract the information from turbopump mass data and analyze its health condition, the paper presented a mass data abnormal recognition algorithm based on manifold learning. The algorithm reconstructed turbopump vibration data in high-dimensional space. Then, the diffusion map method was used to directly learn the high-dimensional data and extract intrinsic low-dimensional manifold feature in data set. The abnormal condition in turbopump mass data was discerned visually. The validation results of simulation and test data demonstrate the feasibility and effectiveness of the presented algorithm. The algorithm conquers the shortcoming of the traditional methods that are insufficient for nonlinear problems, and gives a new solution of turbopump post-test health analysis.

Key words: turbopump; abnormal recognition; manifold learning; diffusion map; mass data

涡轮泵是液体火箭发动机重要且复杂的部件之一, 由于工作环境极其恶劣, 它的故障概率相对

较高. 发动机地面试车是检验涡轮泵状态是否正常的主要手段. 历史试车积累下来的海量数据无

收稿日期: 2010-02-08; 修订日期: 2010-05-06

基金项目: 国家自然科学基金(50675219); 湖南省杰出青年科学基金(08JJ1008)

作者简介: 夏鲁瑞(1979—), 男, 山东聊城人, 博士生, 研究方向为液体火箭发动机健康监控与故障诊断.

E-mail: xlrui522@163.com

疑对分析涡轮泵的健康状态具有很高的使用价值。然而,涡轮泵是一个复杂的动力学系统,本质上具有很强的非线性特征。海量试车数据具有的“高维性”与“非线性”给涡轮泵健康信息的获取带来了困难。因此,如何针对涡轮泵试车数据的特点,研究有效的非线性高维数据处理方法,对海量试车数据中有用信息的提取以及涡轮泵健康状态的分析,具有重要的实际应用价值。

提取蕴含在高维数据内部的“有用”信息,也就是从数据中学习“知识”,这正是近代“机器学习”领域的研究热点。传统的主成分分析(principal component analysis,简称PCA)等方法对具有线性结构的数据集有较好的处理效果,但由于这些方法的线性本质使其无法揭示复杂的非线性流形结构。迫切需要研究适用于非线性数据的新理论和新方法。2000年,美国《Science》上发表了三篇有关流形学习的论文^[1-3],由于这种方法在非线性和高维数据处理方面具有强大的优势,一经提出便迅速成为一个新的研究热点^[4-7]。流形学习方法较之于传统方法,能够有效地发现非线性高维数据的本质结构,利于进行维数约简和非线性数据分析。扩散映射^[8-11](diffusion map,简称DM)正是这样一种典型的流形学习方法,它来源于图的分割方法,从高维映射到低维时对数据集有聚类效果,所以比较适于数据分类与识别。

本文提出使用流形学习方法从海量试车数据中提取涡轮泵健康信息的思路,针对高维非线性数据的处理困难,用扩散映射方法直接对高维数据集进行学习,提取出数据内在的低维流形特征,以可视化的方式识别出涡轮泵异常状态,为试车后涡轮泵的健康分析提供了一条新的途径。

1 流形学习方法

流形学习方法是一种基于微分几何与拓扑学的非线性高维数据处理方法,采用该方法可能寻找到最能表征涡轮泵状态的特征数据,为正确分析涡轮泵的健康状态提供依据。

1.1 流形学习的数学描述

几何上研究的一般是连续可微的流形,而实际问题中,通常已知的是对象的高维观测数据集,数据变量可以用少量几个影响因素来表示,这种现象在几何学上表现为样本点散布在低维流形上,或者是在低维流形附近^[12]。流形学习就是要根据有限的离散样本数据学习和发现嵌入在高维数据空间中的低维光滑流形。

流形学习的数学描述为:给定高维观测数据集 $\mathbf{X} = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N\}$, 其中 $\mathbf{x}_i \in \mathbf{R}^D, i=1, 2, \dots, N$, 为独立同分布的随机样本, 散布在光滑的 d 维流形 $\mathbf{M} \subset \mathbf{R}^D$ 上, 即 $\mathbf{M}$ 为嵌入在 D 维欧氏空间中的 d 维流形, 定义嵌入映射 $f: \mathbf{M} \subset \mathbf{R}^D \rightarrow \mathbf{R}^D$, 这里 $d \ll D$ 。流形学习是在没有任何关于 $\mathbf{M}$ 和 d 的先验知识的条件下, 根据有限的观测数据集 $\mathbf{X}$ 发现未知嵌入映射 $f(\cdot)$, 并找到与高维观测数据一一对应的低维嵌入 $\mathbf{Y} = \{\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_N\}$, 其中 $\mathbf{y}_i \in \mathbf{R}^d, i=1, 2, \dots, N$ 。一般称 $\mathbf{M} \subset \mathbf{R}^D$ 为隐空间, $\mathbf{y}_i$ 为隐数据。流形学习的目标就是根据观测数据 $\mathbf{x}_i$ 重构未知映射 $f(\cdot)$ 和 $\mathbf{y}_i$ 。

1.2 流形学习的基本思想

高维数据空间中的点由少数独立变量的共同作用在高维空间张成一个流形。流形学习的基本思想是:设法展开高维空间卷曲的流形或发现内在的主要变量,即找到高维空间中的低维流形,并求出相应的嵌入映射,以实现维数约简或者数据可视化,它是从观测到的现象中去寻找事物的本质,找到高维数据集分布的内在规律。

将流形学习方法用于高维非线性数据样本的学习,获得数据的低维流形,可有效发现数据的内在本质特征,从而达到信息提取的目的,利于下一步的状态分类与识别。

1.3 扩散映射方法

扩散映射方法来源于动态系统理论,它根据数据点建立一个与之对应的图,在图上定义Markov随机路,通过一定时间步长的随机游走,得到任意两个数据点的距离函数,定义为扩散距离,以尽可能保持扩散距离为目标,来获取低维流形。

对一个给定的高维数据集 $\mathbf{X} = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N\}$, $\mathbf{x}_i \in \mathbf{R}^D$, 从中提取出一个 d 维($d < D$)的流形特征 $\mathbf{Y}$, 扩散映射方法的实现步骤如下。

首先,根据给定数据点 $\mathbf{x}_i$ 建立一个与之对应的图,使用高斯核函数定义图中边的权值,得到一个权值矩阵 $\mathbf{W}$,其元素为

$$w_{ij} = \exp\left[-\frac{\|\mathbf{x}_i - \mathbf{x}_j\|^2}{2\sigma^2}\right] \quad (1)$$

式中 σ 为高斯核的方差。 σ 越大,权值越大。

然后,通过归一化技术,将矩阵 $\mathbf{W}$ 的每行之和单位化为 1,可以得到归一化的权值矩阵 $\mathbf{P}^{(1)}$,其元素为

$$p_{ij}^{(1)} = \frac{w_{ij}}{\sum_k w_{ik}} \quad (2)$$

此矩阵的每行可看作是对应数据点随机游走到其他数据点的概率,则 $\mathbf{P}^{(1)}$ 为任意两个数据点之间的一步转移概率矩阵,经过 t 步随机游走,相应的转移概率矩阵为 $\mathbf{P}^{(t)} = (\mathbf{P}^{(1)})^t$,两点 $\mathbf{x}_i$ 与 $\mathbf{x}_j$ 之间 t 步后的扩散距离定义为

$$D^{(t)}(\mathbf{x}_i, \mathbf{x}_j) = \sqrt{\sum_k \frac{(p_{ik}^{(t)} - p_{jk}^{(t)})^2}{\varphi(\mathbf{x}_k)}} \quad (3)$$

式中

$$\varphi(\mathbf{x}_i) = \frac{m_i}{\sum_j m_j}, \quad m_i = \sum_j p_{ij}$$

$\varphi(\mathbf{x}_i)$ 描述了图中高密度区的权值更大这一属性.从式(3)可以得出,图中点越密集,成对数据点之间的扩散距离越小,扩散距离考虑了连接两点所有边的贡献,所以比测地线距离的鲁棒性更强.

最后,在保持扩散距离的条件下,提取低维流形 $\mathbf{Y}$. 根据 Markov 随机路的谱图理论, $\mathbf{Y}$ 由式(4)的 d 个非平凡主特征向量构成

$$\mathbf{P}^{(t)} \mathbf{Y} = \lambda \mathbf{Y} \quad (4)$$

由于是全连接图,最大的特征值(即 $\lambda_1 = 1$)是平凡的,其对应的特征向量 $\mathbf{v}_1$ 应舍弃.低维流形 $\mathbf{Y}$ 由其余的 d 个主特征向量给出

$$\mathbf{Y} = \{\lambda_2 \mathbf{v}_2, \lambda_3 \mathbf{v}_3, \dots, \lambda_{d+1} \mathbf{v}_{d+1}\} \quad (5)$$

扩散映射来源于图的分割方法,从高维映射到低维时,以尽可能保持扩散距离为目标,对数据集有聚类效果,所以比较适于数据分类与识别.

2 基于扩散映射的海量数据异常识别

2.1 流形特征的描述

现实中的数据虽然纷繁复杂、特征各异,然而所关心的数据并不是充斥着整个高维空间.在获取这些数据的时候,总是带有一定的目的性,假设这些数据含有期望得到的知识,而这些知识或信息往往隐藏在高维空间中.如果通过对高维空间数据进行学习,能获得数据的低维结构,并保持数据的内在性质不变,就有望提取出所需要的信息或知识.

流形提供了对同类事物共性的一种新的表达方式,可以认为,同类事物的数据样本的共性可以由其所位于的流形的结构来表达.这种表达使得无序的高维数据变为有结构的数据集,便能够对相同性质的数据集做简单的推理,从而加深对数据本质的认识.

流形特征往往有利于后续聚类或者分类任务

的进行.这是由于属于同一事物但不同种类的样本会位于表征该事物的流形的不同区域.流形学习方法能够有效地逼近表征该事物的流形,从而使得流形上不同区域的差别在特征空间中得到体现.因此流形学习方法在提取特征时虽然没有用到样本的类别信息,但其所提取的特征仍然具有好的可分性质.这对于聚类或者分类任务来说都是非常有利的.

在某型液体火箭发动机的历史试车过程中,积累了有关涡轮增压器健康状态的大量正常数据和少量异常数据.反映涡轮增压器正常状态的数据样本具有相同或相似的性质,而反映涡轮增压器异常状态的数据样本也具有相同或相似的性质,但很明显这两类数据样本之间的性质是不同的,在特征空间中处于流形的不同区域.通过流形学习方法从涡轮增压器原始高维数据中提取出低维的流形特征后,可以利用在特征空间中体现的流形上不同区域的差别,实现涡轮增压器正常和异常的识别.因为对一次试车来说,大多数的数据样本正常,只有少量数据样本存在异常,如果在流形特征空间仅存在单一的区域,则可判定涡轮增压器状态正常;如果出现两个以上的区域或出现游离于主区域之外的数据点,则可判定涡轮增压器状态出现异常.

2.2 异常识别算法

试车数据中蕴含涡轮增压器的健康信息,通过识别海量数据中的异常情况,可对涡轮增压器的健康状态进行评估.识别过程可描述为:将原始数据组成的空间称为观测空间,把识别赖以进行的空间称作特征空间,通过变换,可把在维数较高的观测空间中表示的模式转化为维数较低的特征空间中表示的模式.对于任意的高维观测样本 $\mathbf{X} = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N\}$, $\mathbf{x}_i \in \mathbf{R}^D$,构成观测空间,经过特征提取得到的低维样本 $\mathbf{Y} = \{\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_N\}$, $\mathbf{y}_i \in \mathbf{R}^d$,构成特征空间,在低维特征空间即可进行数据的异常识别过程.

传统的识别方法对于线性问题能在一定程度上取得较为满意的效果,但对于涡轮增压器这样的复杂系统,识别效果不理想.扩散映射方法具有良好的学习非线性复杂数据内在流形结构的能力,在此基础上,本文提出一种基于扩散映射的涡轮增压器试车数据异常识别算法,旨在寻找数据样本蕴涵的流形作为特征,进而识别海量数据中的异常情况,对涡轮增压器的健康状态进行评估.该识别算法的流程如图1所示.




图1 涡轮泵数据异常识别算法流程图

Fig. 1 Flowchart of abnormal recognition algorithm with turbopump data

涡轮泵数据异常识别算法的具体步骤如下:

1) 对涡轮泵原始振动数据进行预处理,构建高维观测样本 $\mathbf{X} = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N\}$, $\mathbf{x}_i \in \mathbf{R}^D$, 形成观测空间;

2) 选择高斯核函数的方差 σ , 以及约简的目标维数 d (一般为 2 或 3);

3) 使用扩散映射方法对观测样本进行流形学习, 将高维的观测空间转化为低维的特征空间, 获得其内在的流形特征 $\mathbf{Y} = \{\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_N\}$, $\mathbf{y}_i \in \mathbf{R}^d$;

4) 在低维的特征空间, 利用流形上不同区域的差别, 实现涡轮泵状态正常或异常的识别。

在算法实现过程中, 基于流形特征的涡轮泵健康状态决策策略为: 如果在流形特征空间仅存在单一的区域, 则判定涡轮泵状态正常; 如果出现两个以上的区域或出现游离于主区域之外的数据点, 则判定涡轮泵状态出现异常。

通常的异常识别是建立在特征已知的基础之上, 并且特征的提取过程较为复杂。本文算法的最大优点是直接对原始高维数据进行学习, 提取数据内在的低维流形特征, 无须再进行特征量提取, 大大降低了识别的难度。同时, 由于将数据样本维数降至低维 (一般为 3 维以下), 利于实现样本集的可视化表达, 使识别过程直观易理解。

3 仿真与试车数据验证

首先利用三维聚类仿真数据 $\mathbf{X}$, 直观验证本文提出算法的有效性。随机产生 800 个样本点, 分

成互不重合的三簇, 如图 2 所示。坐标 X_1, X_2, X_3 表示数据的维数。

算法参数 σ 用来设定高斯核的方差, σ 越大, 图 2 中边的权值越大, 流形特征聚集性越好。此外, 为了便于可视化, 目标维数 d 一般为 2 或 3。这里选择 $\sigma=4$, $d=2$, 使用本文算法对仿真数据进行处理, 转化到低维空间, 提取出二维流形特征 $\mathbf{Y}$, 结果如图 3 所示。坐标 Y_1, Y_2 表示数据的维数。




图2 仿真数据

Fig. 2 Simulation data




图3 仿真数据的处理结果

Fig. 3 Result of simulation data processing

从图 2 和图 3 可以看出, 本文算法将仿真数据从三维空间映射到二维空间时, 很好地保持了数据内在的几何结构, 即数据点之间的邻近关系, 而且提取的低维流形对数据还进一步聚类, 所以比较适于数据分类与识别。

使用某次试车燃料涡轮泵轴向振动出现异常的数据, 验证本文提出的异常识别算法, 并与传统的 PCA 方法进行比较。首先构建高维观测样本。在涡轮泵轴向振动数据中, 截取一段长度为 L 的数据, 将数据划分为 N 个子数据向量, 每个向量的维数 $D=L/N$, 这样就构成了一个高维观测样本 $\mathbf{X} = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N\}$, $\mathbf{x}_i \in \mathbf{R}^D$ 。取 $L=800\ 000$, $N=800$, 则 $D=1\ 000$ 。涡轮泵是一个本质非线性动力学系统, 其高维观测样本数据蕴含较强的非

线性特征.

分别用 PCA 和 DM 方法对高维观测样本 $\mathbf{X}$ 进行学习, 提取出低维流形特征 $\mathbf{Y}$, 进行数据异常识别. 为了实现流形特征的良好聚集和可视化, 设定高斯核函数的方差 $\sigma=10$, 目标维数 $d=2$. 结果如图 4 和图 5 所示.




图 4 轴向振动数据的 PCA 识别结果

Fig. 4 Result of PCA for axial vibration data recognition




图 5 轴向振动数据的 DM 识别结果

Fig. 5 Result of DM for axial vibration data recognition

从图 4 和图 5 可以看出, PCA 方法不能对轴向振动数据中的异常情况进行有效识别, 而 DM 方法有效地克服了 PCA 解决非线性问题不足的缺点, 在处理高维非线性数据时, 能清晰地将游离于主区域之外的异常数据点识别出来.

从数据量约简的角度对本文算法进行分析如下: 原始的轴向振动数据量为 3 530 kb, 用于识别的特征数据(流形)的大小仅为 12.3 kb, 也就是说, 只需要 0.35% 的数据量即可对原来大量数据的异常情况进行识别, 大大约简了数据量, 从而实现了海量数据的异常识别.

下面使用本文提出的异常识别算法, 对某次试车燃料涡轮泵径向振动和切向振动的数据进行异常识别. 高维观测样本的构建以及算法参数的选择与上述相同. 识别结果如图 6 和图 7 所示.




图 6 径向振动数据的识别结果

Fig. 6 Result of radial vibration data recognition




图 7 切向振动数据的识别结果

Fig. 7 Result of tangential vibration data recognition

从图 5、图 6 和图 7 可以看出, 在算法得到的流形特征空间中, 出现了一些游离于主区域之外的数据点, 根据 2.2 节的健康状态决策策略, 判定燃料涡轮泵轴向振动、径向振动和切向振动的数据出现了异常, 从而说明燃料涡轮泵出现故障.

4 结 论

针对高维非线性数据的处理困难, 本文提出一种基于流形学习的海量数据异常识别算法, 用扩散映射方法直接对高维数据集进行学习, 提取出数据内在的低维流形特征, 以可视化的方式识别出涡轮泵异常状态, 为试车后涡轮泵的健康分析提供了一条新的途径. 仿真和试车数据验证了所提算法的可行性和有效性.

参考文献:

- [1] Seung H S, Daniel D L. The manifold ways of perception[J]. Science, 2000, 290(5500): 2268-2269.
- [2] Tenenbaum J B, de Silva V, Langford J C. A global geometric framework for nonlinear dimensionality reduction[J]. Science, 2000, 290(5500): 2319-2323.
- [3] Roweis S T, Saul L K. Nonlinear dimensionality reduction by locally linear embedding[J]. Science, 2000, 290(5500): 2323-2326.

- [4] Saul L K, Roweis S T. Think globally, fit locally: unsupervised learning of low dimensional manifolds[J]. Journal of Machine Learning Research, 2003, 4: 119-155.
- [5] Balasubramanian M, Schwartz E L, Tenenbaum J B. The isomap algorithm and topological stability[J]. Science, 2002, 295(5552): 7.
- [6] Belkin M, Niyogi P. Laplacian eigenmaps for dimensionality reduction and data representation[J]. Neural Computation, 2003, 15(6): 1373-1396.
- [7] ZHANG Zhenyue, ZHA Hongyuan. Principal manifolds and nonlinear dimensionality reduction via tangent space alignment[J]. SIAM Journal of Scientific Computing, 2005, 26(1): 313-338.
- [8] Coifman R R, Lafon S, Lee A B. Geometric diffusions as a tool for harmonic analysis and structure definition of data: Part I — Diffusion maps[J]. Proceedings of the National Academy of Sciences, 2005, 102(21): 7426-7431.
- [9] Coifman R R, Lafon S. Diffusion maps[J]. Applied and Computational Harmonic Analysis, 2006, 21(1): 5-30.
- [10] Lafon S, Lee A B. Diffusion maps and coarse-graining: a unified framework for dimensionality reduction, graph partitioning, and data set parameterization[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2006, 28(9): 1393-1403.
- [11] Nadler B, Lafon S, Coifman R R, et al. Diffusion maps, spectral clustering and reaction coordinates of dynamical systems[J]. Applied and Computational Harmonic Analysis, 2006, 21(1): 113-127.
- [12] 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. (in Chinese)