

基于流形学习方法的汽轮机组振动特征提取*

何青, 解芳芳, 李红, 蓝澜

(华北电力大学电站设备状态监测与控制教育部重点实验室 北京, 102206)

摘要 为了提高汽轮机振动故障信号的可分性和诊断正确率,应用流行学习方法对汽轮机振动信号进行故障特征提取。研究表明,应用流行学习方法可以有效地提取汽轮机振动故障的特征信息,将不同故障类型的特征信息有效地区分开来。运用流行学习方法进行故障特征提取后的诊断结果与小波包分析方法相比,诊断正确率明显提高。

关键词 汽轮机振动; 故障诊断; 特征提取; 流形学习方法; 局部线性嵌入法

中图分类号 U226.8⁺1; TH11

引言

汽轮机发电机组是火电厂的大型关键设备之一。作为典型的大型旋转机械,汽轮机发电机组轴系结构复杂、运行环境恶劣,时常出现各种故障。由于机组轴系振动信号中蕴含机组各种故障的特征信息,因此通过对汽轮发电机组轴系振动的监测分析,提取这些故障的特征信息,可以对机组出现的各种故障进行精密的诊断^[1-2]。由于汽轮发电机组的振动信号是含有各种噪声的复杂信号,因此有效提取振动信号中的故障特征信息是正确诊断的前提。随着现代信号处理与分析技术发展,需要提取的故障特征信息也越来越多。如何选择最有效的故障特征也是故障诊断中一个重要而又难以解决的问题^[2]。流形学习作为一种非线性的数据降维方法,能有效发现高维数据中蕴含的内在联系和规律,充分挖掘数据中有效信息和特征,为汽轮发电机组振动信号的故障特征提取提供了一个有效方法。

笔者基于流行学习原理,研究应用局部线性嵌入法对汽轮发电机组振动信号进行降维,从而实现在复杂的噪声信号中提取有效识别机组轴系振动故障的特征信息。

1 流形学习原理和局部线性嵌入法

1.1 流形学习原理

流形学习原理^[3-6]是:给定观测空间数据集 $\mathbf{X} = \{x_i, i = 1, 2, \dots, N\} \subset R^D$ 。假定 \mathbf{X} 中的样本 x_i

是由低维空间中的数据集 $\mathbf{Y} = \{y_i, i = 1, 2, \dots, N\} \subset R^d$ 中的 y_i 通过未知非线性变换 f 生成,即 $x_i = f(y_i)$,其中: $d \ll D$, $f: R^d \rightarrow R^D$ 为 C^∞ 的嵌入映射。流形学习就是根据观测数据 x_i 重构映射 f 和 y_i 。也就是说,假设数据均匀采样于高维欧氏空间中的高维流形上,流形学习就是从高维观测数据中发现低维流形结构,从而实现数据的维数约简,得到相应的映射关系。

1.2 局部线性嵌入法

自流形学习原理提出以后,出现了各种流形学习方法。一种典型的流行学习方法是局部线性嵌入法(locally linear embedding,简称LLE)。LLE法是一种典型的非线性降维方法,它主要是从局部入手,将非线性数据分割成具有局部线性结构的数据,通过欧氏距离以局部线形来保持整体拓扑结构,对非线性数据有很好的降维效果。

LLE法的主要过程^[6]如下。

1) 寻找每个样本点 x_i 的 k 个近邻。定义样本集矩阵 $\mathbf{X} = \{x_1, x_2, \dots, x_N\}$ 中样本点 x_i 与 x_j 的距离 d_{ij} 为

$$d_{ij} = \left[\sum_{m=1}^D |x_{mi} - x_{mj}|^p \right]^{\frac{1}{p}} \quad (1)$$

其中:通常取 $p=2$,即采用欧氏距离。

根据式(1)计算得到样本点 x_i 的 k 个距离最近的点作为 g_j 的 k 个近邻点。

2) 计算样本点局部重构的权值矩阵 \mathbf{W} 。定义误差函数为

* 中央高校基本科研业务费专项资金资助项目(11QX49)
收稿日期:2013-02-23;修回日期:2013-06-25

$$\min_{\mathbf{W}} \epsilon(\mathbf{W}) = \sum_{i=1}^N \left(\mathbf{x}_i - \sum_{j=1}^k \omega_{ij} \mathbf{g}_j \right)^2 \quad (2)$$

其中: $\mathbf{g}_j (j=1, 2, \dots, k)$ 为 \mathbf{x}_i 的 k 个近邻点; ω_{ij} 为 \mathbf{x}_i 与 \mathbf{g}_j 之间的权值系数, 且满足

$$\sum_{j=1}^k \omega_{ij} = 1 \quad (3)$$

将式(3)代入式(2), 得到

$$\begin{aligned} \min_{\mathbf{W}} \epsilon(\mathbf{W}) &= \sum_{i=1}^N \left[\sum_{j=1}^k \omega_{ij} (\mathbf{x}_i - \mathbf{g}_j) \right]^2 = \sum_{i=1}^N [(\mathbf{x}_i - \mathbf{g}_j) \mathbf{w}_i]^2 \\ &= \sum_{i=1}^N [(\mathbf{x}_i - \mathbf{g}_j) \mathbf{w}_i]^T [(\mathbf{x}_i - \mathbf{g}_j) \mathbf{w}_i] = \\ &= \sum_{i=1}^N \mathbf{w}_i^T (\mathbf{x}_i - \mathbf{g}_j)^T (\mathbf{x}_i - \mathbf{g}_j) \mathbf{w}_i = \sum_{i=1}^N \mathbf{w}_i^T \mathbf{z}_i \mathbf{w}_i \quad (4) \end{aligned}$$

其中: $\mathbf{z}_i = (\mathbf{x}_i - \mathbf{g}_j)^T (\mathbf{x}_i - \mathbf{g}_j)$ 为第 i 个样本点的局部协方差矩阵; $\mathbf{w}_i = \{\omega_{i1}, \omega_{i2}, \dots, \omega_{ik}\}^T$ 为第 i 个样本点的局部重建权值向量。

求解式(4)是一个约束最小二乘问题。

3) 将所有样本点映射嵌入到低维空间中。映射嵌入满足

$$\min_{\mathbf{Y}} \varphi(\mathbf{Y}) = \sum_{i=1}^N \left(\mathbf{y}_i - \sum_{j=1}^k \tau_{ij} \mathbf{h}_j \right)^2 \quad (5)$$

其中: $\varphi(\mathbf{Y})$ 为损失函数; \mathbf{y}_i 为 \mathbf{x}_i 的输出向量。

$\mathbf{h}_j (j=1, 2, \dots, k)$ 为 \mathbf{y}_i 的 k 个近邻点, 且满足

$$\begin{cases} \sum_{i=1}^N \mathbf{y}_i = \mathbf{0} \\ \frac{1}{N} \sum_{i=1}^N \mathbf{y}_i \mathbf{y}_i^T = \mathbf{I} \end{cases} \quad (6)$$

其中: \mathbf{I} 为 $d \times d$ 的单位矩阵。

$\mathbf{w}_{ij} (i=1, 2, \dots, N)$ 可以存储在 $N \times N$ 的稀疏矩阵 \mathbf{W} 中。当 \mathbf{x}_j 是 \mathbf{x}_i 的近邻点时, $\mathbf{W}_{ij} = \omega_{ij}$; 否则 $\mathbf{W}_{ij} = 0$ 。用 \mathbf{W}_i 表示 \mathbf{W} 矩阵的第 i 列, \mathbf{I}_i 表示单位矩阵的第 i 列, \mathbf{Y} 表示输出向量, 即 $\mathbf{Y} = [\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_N]$, 则式(5)可写为

$$\begin{aligned} \min_{\mathbf{Y}} \varphi(\mathbf{Y}) &= \sum_{i=1}^N (\mathbf{Y} \mathbf{I}_i - \mathbf{Y} \mathbf{W}_i)^2 = \sum_{i=1}^N [\mathbf{Y} (\mathbf{I}_i - \mathbf{W}_i)]^2 = \\ &= [\mathbf{Y} (\mathbf{I} - \mathbf{W})]^2 = [\mathbf{Y}^T (\mathbf{I} - \mathbf{W})^T]^2 = \\ &= \mathbf{Y} (\mathbf{I} - \mathbf{W}) (\mathbf{I} - \mathbf{W})^T \mathbf{Y}^T = \mathbf{Y} \mathbf{M} \mathbf{Y}^T \quad (7) \end{aligned}$$

其中: $\mathbf{M} = (\mathbf{I} - \mathbf{W}) (\mathbf{I} - \mathbf{W})^T$ 。

结合约束条件, 利用 Lagrange 乘子有

$$L(\mathbf{Y}) = \mathbf{Y} \mathbf{M} \mathbf{Y}^T + \lambda (\mathbf{Y} \mathbf{Y}^T - \mathbf{N} \mathbf{I}) \quad (8)$$

为使损失函数 $L(\mathbf{Y})$ 最小, 则

$$\frac{\partial L}{\partial \mathbf{Y}} = 2\mathbf{M} \mathbf{Y}^T + 2\lambda \mathbf{Y}^T = 0 \quad (9)$$

将 \mathbf{M} 的特征值按从小到大顺序排列, \mathbf{Y} 取 \mathbf{M} 的最小 d 个非零特征值所对应的特征向量。一般地, \mathbf{M} 的第 1 个特征值几乎等于零。因此, 取 $2 \sim (d+1)$ 个特征值所对应的特征向量作为低维嵌入 \mathbf{Y} 。

由上述过程可以看出, LLE 法的主要参数是近邻数 k 和嵌入维数 d 。

2 机组轴系振动及其故障特征提取

汽轮发电机组轴系振动信号中包含着丰富的信息, 特别是当轴系出现故障时故障的特征信息也会反映在轴系振动信号中。因此, 通过对机组轴系振动信号的监测与分析是汽轮发电机组转子故障诊断的重要方法之一。由于机组故障的多样性和机组振动信号的复杂性, 常常难以从机组轴系的振动信号中准确地诊断出故障的类型、严重程度以及发生部位。应用机组振动信号进行故障诊断的困难还表现在, 一方面当故障出现时转子系统呈现非线性特性, 另一方面现场实测振动信号是包括噪声在内的各种因素综合影响的结果, 呈现出显著的高维特性。

鉴于以上分析, 笔者基于流形学习原理, 首先, 应用 LLE 法对汽轮发电机组轴系振动信号中进行降维, 根据降维结果对振动信号进行特征提取; 然后, 对各种典型振动故障的特征提取结果进行分析, 得到用于机组轴系振动故障诊断的特征模式。

2.1 机组典型故障的振动

文献[2]在转子实验台上分别模拟了 4 种常见的机组轴系故障, 包括转子质量不平衡、碰磨、不对中和轴承座松动, 并在各种故障下采集多组振动信号。为了提高信号频谱分析的幅值和相位精度, 采用了多通道同步采集方式并对采集的信号进行整周期截取。通过小波去噪后进行时域和频域分析, 获得所有信号的时域特征参数和频域特征参数, 由此构成诊断所需的观测空间。时域特征参数包括波形指标、脉冲指标、峰值指标、裕度指标、歪度指标和峭度指标等 6 个无量纲参数。频域特征参数^[7]包括 $(0.01 \sim 0.49)X$, $0.5X$, $1X$, $2X$, $3X$, $(3 \sim 5)X$, $(5 \sim 10)X$ 和 $\text{odd } X$ 等 8 个频率或频段的频谱幅值或频谱幅值和。其中: X 表示谐波; $\text{odd } X$ 表示奇数倍谐波。这样, 每个样本空间都由这 14 个特征参数构成。

2.2 机组振动特征提取

由 14 个特征参数构成的机组振动信号的特征样本 \mathbf{x}_i 难以直接用于诊断。为便于诊断识别, 将这 14 个特征参数所包含的故障信息进行浓缩, 即在保持样本整体信息的基础上对这些特征属性的数量进行缩减, 即维数缩减。

流形学习正是这样一种维数缩减工具, 能够在保存样本非线性信息的情况下对特征信息进行压

缩。笔者以文献[2]的实验分析结果为原始数据,将这些样本作为LLE算法的输入,分别取嵌入维数 d 为1,2,3,4进行流形学习。根据LLE结果,当嵌入维数 $d=2$ 时对上述4种转子故障具有最佳的识别效果,且结果表达也最为直观。因此,选择嵌入维数 $d=2$,最佳近邻数 k 则通过分析来确定。经过LLE特征提取后,每个振动信号的特征参数都由原来的14维样本 x_i 嵌入映射到2维样本 y_i ,构成2维特征矩阵 Y 。显然,特征矩阵 Y 的每个列向量都是一个2维样本点 y_i ,这些样本点 y_i 可以用平面坐标系中的一个点来表示,由此可以得到表示机组轴系振动故障的一个2维图形。

3 诊断结果与分析

3.1 最佳近邻数确定

分别取近邻数 $k=5,6,7$ 对样本数据进行流形学习,得到不同近邻数时的故障特征提取结果如图1所示,图中: u, v 为2维样本 y 的坐标值。由图1可知,当 k 取不同值时4类故障的区分程度是不同的,比较可见其最佳邻域数 $k=6$ 。由图1(b)可以得到4种典型故障的样本点分布情况如下:a. 碰磨故障样本分布在 $u=-1.0$ 竖直线附近,且 v 在 $-1.5 \sim 0.5$ 中间;b. 不对中故障样本分布在 $u=1.0$ 竖直线附近,且 v 在 $-2.0 \sim 1.5$ 之间;c. 不平衡故障样本分布在 $v=1.0$ 水平直线附近,且 u 在 $-2.0 \sim 1.5$ 之间;d. 轴承座松动样本分布在 $v=-1.0$ 的水平直线附近, u 在 $-1.5 \sim 1.0$ 之间。可见,在最佳近邻数情况下,通过流形学习提取的不同故障特征样本点分布在2维平面 (u, v) 的不同区域内,具有很高的区分度,因而识别其故障类型非常方便,由此可以大大提高故障诊断的确诊率和诊断的正确率。

3.2 诊断结果的比较与分析

为了便于比较,对文献[2]中实验数据分别采用流形学习方法和小波包分析方法[8]提取信号特征参数,用支持向量机分类器[9]进行诊断,并对诊断结果进行分析比较。首先,将4种典型故障进行状态编码,其中:0表示无故障;1表示不平衡故障;2表示不对中故障;3表示轴承座松动故障;4表示碰磨故障。然后,对每种状态从其特征样本中抽取50组数据组成学习样本,对分类器进行训练。训练完成后,再从每种故障状态的特征样本中抽取20组数据组成测试样本,对分类器进行测试。两种方法的诊断





图1 不同近邻数时提取的样本特征

Fig. 1 Specimen features extracted under different number of near points


结果如图2所示。由图2可见,用支持向量机分类器对流形学习方法提取的80组故障信号特征进行诊断,其诊断结果中只有不对中和轴承座松动两种故障的1个样本出现了误诊,其诊断正确率为 $78/80=97.5\%$ 。同样的支持向量机分类器对小波包分析方法提取的80组故障信号特征进行诊断,其诊断结果中不平衡故障中有1个样本,不对中故障中有2个样本,轴承座松动故障中有1个样本,碰磨故障

中有2个样本,共计6个样本出现了误诊,诊断正确率为 $74/80=92.5\%$ 。流形学习方法的诊断正确率较小波包分析方法高出5%。



(a) 流形学习特征提取的诊断结果

(a) Diagnosis with features extracted by manifold learning



(b) 小波包分析特征提取的诊断结果

(b) Diagnosis with features extracted by wavelet packet

图2 流形学习与小波包分析特征提取的诊断结果比较
Fig.2 Comparison of diagnosis with features extracted by manifold learning and wavelet packet

可见,通过流形学习方法提取的机组振动信号特征样本保存了原始的整体几何特征,有效地反映了信号特征与故障之间的关系,从而可以有效提高故障诊断的正确率。另外,由于流形学习方法对信号特征属性进行了有效约简,也使得诊断程序的执行效率得到较大的提高。

4 结束语

笔者基于流形学习方法,研究了基于流形学习的振动故障信号特征提取方法,并将该方法应用于汽轮机典型故障时振动信号的特征提取。研究表明,基于流形学习方法的故障特征提取方法能够从复杂的机组振动信号中提取各种故障特征信息,从而提高对汽轮机振动故障的分类与识别能力,诊断精度得到了显著提高,大大降低故障诊断的计算量。

参 考 文 献

- [1] 戈志华,刘永凯,黎瑜春. 基于流形学习的汽轮机转子振动故障特征提取[J]. 汽轮机技术, 2012, 4(4): 283-285, 289.
Ge Zhihua, Liu Yongkai, Li Yuchun. Turbine vibration fault feature extraction based on manifold learning [J]. Turbine Technology, 2012, 4(4): 283-285, 289. (in Chinese)
- [2] 刘永凯. 基于流形学习的汽轮机转子振动故障诊断[D]. 北京: 华北电力大学, 2012.
- [3] Seung H S, Lee D D. The manifold ways of perception [J]. Science, 2000, 290: 2268-2269.
- [4] Roweis S T, Saul L K. Nonlinear dimensionality reduction by locally linear embedding [J]. Science, 2000, 290: 2323-2326.
- [5] Tenenbaum J B, Silva V D, Langford J C. A global geometric framework for nonlinear dimensionality reduction [J]. Science, 2000, 290: 2319-2323.
- [6] 陈高曙,曾庆宁. 基于LLE算法的人脸识别方法[J]. 计算机应用研究, 2007, 24(10): 176-178.
Chen Gaoshu, Zeng Qingning. Face recognition method based on LLE algorithm [J]. Application Research of Computers, 2007, 24(10): 176-178. (in Chinese)
- [7] 钟秉林,黄仁. 机械故障诊断学[M]. 北京: 机械工业出版社, 1997: 129-130.
- [8] 李健宝,彭涛. 基于小波包参数模型的滚动轴承智能故障诊断[J]. 振动、测试与诊断, 2012, 32(2): 362-365.
Li Jianbao, Peng Tao. Intelligent fault diagnosis of rolling bearing based on wavelet packet autoregressive model [J]. Journal of Vibration, Measurement & Diagnosis, 2012, 32(2): 362-365. (in Chinese)
- [9] 全睿,全书海,黄亮,等. 基于支持向量机的车用燃料电池系统故障诊断[J]. 振动、测试与诊断, 2012, 32(1): 19-22.
Quan Rui, Quan Shuhai, Huang Liang, et al. Fault diagnosis of automotive fuel cell system based on support vector machine [J]. Journal of Vibration, Measurement & Diagnosis, 2012, 32(1): 19-22. (in Chinese)



第一作者简介:何青,男,1962年10月生,教授、博士生导师。主要研究方向为振动工程与测试技术、状态监测与故障诊断。曾发表《基于CAN总线远程振动监测系统研究》(《振动、测试与诊断》2009年第29卷第4期)等论文。

E-mail: hqng@163.com

