

基于稀疏性非负矩阵分解和支持向量机的时频图像识别

蔡 蕾¹ 朱永生¹

摘要 针对机械故障诊断领域对反映设备运行状态的图像识别困难以及选择和提取敏感特征困难的问题, 将基于图像的机械设备运行状态判别问题当作图像的识别问题来处理, 提出使用稀疏性非负矩阵分解 (Sparse non-negative matrix factorization, SNMF) 和支持向量机 (Support vector machine, SVM) 对时频图像进行识别进而判断机器运行状态, 从而避免特征的选择和提取。稀疏性非负矩阵分解在对时频图像进行大规模压缩的同时, 能够很好地保留图像的隐含特征, 从而大大减少自动识别时频图像的计算复杂度, 并有效地提高支持向量机的识别精度。此外, 本文还对影响识别率的稀疏性非负矩阵分解的各参数进行了讨论。实验结果表明, 该方法对时频处理方法依赖性低, 在大多数情况下都能获得较传统方法高的识别率。

关键词 时频图像, 稀疏性非负矩阵分解, 支持向量机, 模式识别

中图分类号 TP39

Time-frequency Spectra Recognition Based on Sparse Non-negative Matrix Factorization and Support Vector Machine

CAI Lei¹ ZHU Yong-Sheng¹

Abstract In the field of mechanical fault diagnosis, it is difficult to recognize the running condition of machines by human based on images corresponding to the condition such as time-frequency spectra, orbit, power spectra, and so on. The most meaningful features required by learning machines, which can reorganize running condition of machines automatically, are always difficult to select and extract from the images. In this paper, the problem of machine running condition recognition based on images is treated purely as image recognition problem, so the procedure of meaningful features selection and extraction can be avoided. Sparse non-negative matrix factorization (SNMF) and support vector machine (SVM) are introduced to recognize the time-frequency spectra and therefore the corresponding running condition of machine automatically. After applying SNMF to image, the dimension is reduced obviously while the connotative and main features of image are reserved, therefore the computation cost of image recognition with SVM is saved and the recognition accuracy is possibly improved. Experimental results show that the proposed method can obtain higher recognition accuracy than conventional method and is dependent only weakly on the time-frequency analysis method.

Key words Time-frequency spectra, sparse non-negative matrix factorization (SNMF), support vector machine (SVM), pattern recognition

机械设备故障诊断领域存在大量可以以图像表达的信息, 如振动波形、频谱图、轴心轨迹、时频图像等。目前, 主要有两种基本的方法实现基于图像的设备运行状态判别: 一是人工诊断方法, 其依赖于个人经验, 因而准确性和效率比较低; 二是计算机自动诊断方法, 即采用某种学习机器对图像作出类别判断。为了提高计算速度、识别精度或避免“维数灾难”问题^[1], 在利用学习机器识别设备运行

状态时, 需要从状态图像中提取和选择对设备运行状态变化敏感的特征。如同从监测数据中获得敏感特征一样, 从高维状态图像中获取敏感特征也是当前故障诊断领域中面临的一个瓶颈问题, 敏感特征的选择和获取成为目前各种故障诊断系统诊断准确性能否令人满意的主要原因之一。针对从故障图像中提取敏感特征困难的问题, 将基于图像的设备运行状态判别问题当作单纯的图像识别问题来处理, 这样敏感特征提取问题就可以被转换为对图像本身的压缩和降维问题, 从而避免了从图像中确定与设备运行状态相对应的敏感特征难题。本文以时频图像为例, 探讨了所提出方法的可行性。首先采用稀疏性非负矩阵分解 (Sparse non-negative matrix factorization, SNMF) 对时频图像进行处理, 使其维数从 330×630 降低到数十维, 然后利用支持向量机 (Support vector machine, SVM) 适合解决有限样本问题的特点, 对降维后的数据直接进行识别, 取

收稿日期 2008-06-03 收修改稿日期 2009-01-05

Received June 3, 2008; in revised form January 5, 2009

国家高技术研究发展计划 (863 计划) (2006AA04Z420), 国家自然科学基金 (50575179) 资助

Supported by National High Technology Research and Development Program of China (863 Program) (2006AA04Z420) and National Natural Science Foundation of China (50575179)

1. 西安交通大学现代设计及转子轴承系统教育部重点实验室 西安 710049

1. Key Laboratory of Education of Ministry for Modern Design and Rotor-Bearing System, Xi'an Jiaotong University, Xi'an 710049

DOI: 10.3724/SP.J.1004.2009.01272

得了较好的识别率, 证明了从图像直接识别故障方法的可行性。另外, 本文还研究了参数对 SNMF 结果以及识别率的影响。

1 稀疏性非负矩阵分解和支持向量机

1.1 稀疏性非负矩阵分解

非负矩阵分解 (Non-negative matrix factorization, NMF) 是 Lee 和 Seung 于 1999 年提出的一种多变量分析方法, 其本质是一种矩阵分解和投影技术。其基本原理如下: 假设需要处理 m 个 n 维样本数据, 它们可以用矩阵 $V_{n \times m}$ 表示, 该矩阵中各个元素都是非负的, 对矩阵 $V_{n \times m}$ 进行线性分解, 有 $V_{n \times m} \approx W_{n \times r} H_{r \times m}$, 其中 $W_{n \times r}$ 称为基矩阵, 也称为特征矩阵, $H_{r \times m}$ 为系数矩阵^[2]。 W, H 均要求非负。非负性要求在实际的物理系统中有重要的意义, 以图像为例 (见图 1), 原始图像可以表示为特征图像 W 和系数矩阵 H 的乘积。其中 W 的每一列代表一个标准的特征图像, W 的非负性避免了图像像素为负这种无明确物理含义的现象; 而系数矩阵 H 的非负性则避免了特征图像像素相减这种在物理上无法解释的情况。另外, 对于所有的图像, 特征矩阵 W 是共用的, 图像之间的差别仅体现在相应的系数上, 因此可以仅使用系数向量对图像进行表征和识别, 使得后续的模式识别工作复杂度大大减少。SNMF 是对系数矩阵 H 添加稀疏性约束条件而发展起来的一种非负矩阵分解算法。和传统的 NMF 方法相比, 该算法能够更好地发现稳定、直观的局部特征, 并且能自由地控制分解后矩阵的稀疏度, 具有求解收敛速度快、特征矩阵和系数矩阵相关性小等特点^[3], 因而各类样本经 SNMF 分解后的系数向量可分性好, 因此本文选用此方法。目前, 非负矩阵分解已应用在图像处理、语音识别等方面。尤其是在图像处理与识别方面已有不少成功的应用案例。如: 图像融合^[4]、人脸识别^[5]、图像检索与匹配^[6] 等。




图 1 NMF 示意图

Fig. 1 The diagrams of NMF objects

1.2 支持向量机

支持向量机是基于统计学习理论的一种新的学习机器。与传统学习机器如神经网络比较, SVM 具有以下优点: 具有更坚实的理论基础; 算法以结构风险最小化原则为出发点, 在现有样本基础上进行训练的过程中就已经考虑了在未知样本上的推广能力; 是基于小样本的一种学习机器, 可以在有限样本上获得和样本相适应的最好的推广能力等。因而 SVM 在理论上和实际的应用中都体现出了较传统学习机器更好的推广能力 (泛化能力)。近年来, SVM 在机械故障的诊断领域也得到了广泛的应用, 并取得了良好的效果。例如: 旋转机械的故障诊断^[7-8]、某些关键设备零部件的故障诊断^[9] 等。在实现原理上, SVM 首先采用非线性映射, 将非线性可分的样本映射到一个高维伪线性空间 (特征空间), 然后在此空间中构造分类面^[10]。高维特征空间中的运算被转化为低维输入空间中的核函数运算, 因而 SVM 对输入数据的维数不敏感, 有效地解决了传统方法面临的数据灾难问题。基于 SVM 具有适合小样本学习、推广能力好、对数据维数不敏感等优点, 本文选择 SVM 作为对设备运行状态判别的智能学习机器^[10]。

2 基于图像的设备运行状态识别模型

基于图像的设备运行状态识别的模型如图 2 所示, 大致可分为如下几个步骤: 1) 从反映机械设备不同运行状况的图像中随机选择一部分 (或全部) 组成样本集 V , 并对 V 应用 SNMF 进行处理, 得到标准图像集 W ; 2) 将所有图像向标准样本集投影, 得到每一幅图像对应的系数向量, 这些系数向量共同形成降维后的样本集 H ; 3) 应用 H 训练 SVM; 4) 对于未知的状态, 将其对应的图像向标准样本集 W 投影, 得到系数向量 H' , 然后将 H' 送入训练好的 SVM 中, 获得对状态的判定。

在上述流程中, 特别是在 SNMF 处理过程中, 不需要考虑图像中哪些特征属于对状态敏感的特征, 也不需要明确每一个特征的确切物理含义 (如是否是倍频, 是低频还是高频), 分解算法会自动最大化地保留图像所包含的有用信息, 从而可以将 SNMF 处理简单地理解为对图像的降维。因此该方法完全避免了传统故障诊断方法中的特征选择难题。

3 实验验证

3.1 实验方法

实验采用的数据为 6135 柴油机 8 种状态下的振动加速度信号^[10]。实验在柴油机的第 2 缸上进行, 通过人为调整进气阀和出气阀的间隙, 以及在排

气阀上开不同大小的口, 模拟了气阀机构间隙调整过大、间隙调整过小、磨损严重、漏气等7种常见的典型故障(加上正常工作状态, 共8种状态信号). 对每一种状态, 重复采样获得38个信号, 然后采用S变换、Wigner-Ville分布、锥形核分布等13种时频分析方法分别处理, 相应得到 330×630 个像素点的时频图像(时频矩阵). 本文对每一类时频图像的8种状态采用图2所示的方法进行处理, 以验证本文提出的方法, 并比较不同时频分析方法对分类效果的影响. 计算流程如下: 1) 对任意一种时频分析方法, 通过矩阵重排操作, 将每一幅时频矩阵由 330×630 维变形为 207900×1 维列向量, 并对其进行归一化处理; 2) 从每一类图像中随机抽取3幅图像, 组成SNMF样本集, 其维数为 207900×24 ; 3) 对 V 进行SNMF分解, 获得特征矩阵 W , 其维数为 $207900 \times r$, 其中 r 表示特征维数, 其取值影响SNMF分解的结果及后续的识别精度; 4) 将所有304幅时频图像向基矩阵 W 投影, 得到304个系数向量 H , 其维数为 $r \times 1$, 则每一幅时频图像可以用相应的系数向量 H 表示; 5) 从每一类中随机选出10个 H , 共80个系数向量组成训练样本集合训练SVM. SVM的参数采用5重交叉检验方法确定. 最后对剩余的224个系数向量用训练好的SVM进行分类测试, 以识别正确率作为指标评价本文方法的性能.




图2 基于图像的设备运行状态识别模型

Fig. 2 The model to reorganize running condition of machines based on images

3.2 实验结果

鉴于SNMF分解中涉及多个参数, 实验首先研究了SNMF主要参数, 如特征维数、稀疏性因子以及迭代次数等对最终识别效果的影响^[11], 然后在上述研究的基础上选用合适的参数, 对所有每一种时频分析方法所对应的8种图像进行分类.

1) 特征维数的影响

通过对5种时频分析方法采用不同的特征维数进行SNMF分解, 研究了特征维数的影响, 其中SNMF分解的迭代次数为200, 稀疏性因子为0.2, 结果如图3所示. 由图3可以看出, 一方面, 在相同的特征维数时, 不同的时频分析方法对应的分类准确率不同, 这说明不同时频分析方法对8种状态的表征能力不同; 另一方面, 当特征维数较小($r \leq 4$)时, 5种时频图像均不能获得高的识别准确率, 而当特征维数大于一定值($r \geq 24$)时, 5种时频图像都获得了较高的识别准确率. 原因简单分析如下: 从式(1)可知, 特征维数 r 的大小反映了用于表达原始图像的特征图像的多少. 对于特定的数据集, 隐藏在其中的特征空间的维数是确定的, 当特征维数的选取与实际的特征空间的维数相一致时, 得到的特征空间的基最有意义. 当选择的特征维数小于实际的特征维数时, 得到的基不足以描述整个空间, 因而向基投影后部分信息丢失, 导致识别率降低. 只有当选择的特征维数等于或大于实际的特征维数, 才有可能得到对特征空间的完整描述, 使得识别率提高. 然而过大的特征维数, 则有可能带入过多的冗余信息或噪声, 使得分类准确率降低. 由图3可以看出, 当 r




图3 特征维数对识别率的影响

Fig. 3 The impact of characteristic dimension on recognition accuracy

= 4 时, 得到的基向量远远不足以描述整个空间, 因而在 5 种时频分析方法上平均识别率低; 随着 r 的增大, 识别率有所提高, $r = 24$ 时平均识别率达到最大, 然后随着 r 的增加又有所减少。本次实验结果说明, 实际应用中选择大的特征维数比选择小的特征维数风险小。

上述现象可以从图 4 所示的 RGKBD 分析方法样本间距离更直接地观察到。为了更好地在图形中显示, 对每一种状态, 只从投影后的系数矩阵 H 中选择 10 个样本, 共 80 个样本来计算它们相互之间的距离。要获得好的分类效果, 则类内距离(图 4 左下角到右上角 10×10 大小的子矩阵)应该尽量小, 而类间距(图 4 其他位置)应该尽量大。由图 4 可见, 在 $r \leq 4$ 时, 大部分样本类间距离都较小, 与类内距离相差不大, 因而可分性差; 而在 $r \geq 24$ 时, 8 类样本类内距离明显小于类间距离, 样本可分性明显增强。





图 4 特征维数对样本间距离的影响


Fig. 4 The impact of characteristic dimension on inter-distance of sample

2) 稀疏性因子与迭代次数的影响

稀疏性因子是在矩阵分解的过程中控制系数矩阵稀疏性的一个参数, 本文以 IGRKBD 时频图像为例来测试稀疏性因子对识别率和 SNMF 分解误差(定义为 $\varepsilon = \|V_{n \times m} - W_{n \times r} \times H_{r \times m}\|^2$)的影响, 特征维数为 24, 迭代次数为 200, 结果如图 5 所示。随着稀疏性因子的增加, 得到的系数矩阵越来越稀疏。而同时, 由图 5 (a) 可见, 目标函数的误差也有所增加, 说明随着稀疏性因子的增加, 对原始图像的信息损失也越来越大。但从图 5 (b) 的识别率来看, 识别率随稀疏性因子变化是一个上凸曲线, 也就是太小或太大的稀疏性因子都不能获得好的识别率。 H 矩阵稀疏性小表明对于任一幅时频图像, 参与重构的特征图像数量多, 则有可能将和目标图像不相关的特征图像引入, 从而使最终的识别率较低。这说明



(a) 对误差的影响
(a) The impact of sparse variable on error



(b) 对识别率的影响
(b) The impact of sparse variable on accuracy
图 5 稀疏性因子对误差和识别率的影响
Fig. 5 The impact of sparse variable on error and accuracy

利用稀疏性因子有望滤除原图像中的噪声,使得其主要特征更明显,从而提高辨识准确性。但如稀疏性因子太大则有可能剔除掉一些有用信息,因此应用SNMF时根据数据来选择合适的稀疏性因子非常关键。在本次实验中,稀疏性因子取0.2获得了最好的识别准确率。

通过计算,迭代次数的增大对SNMF分解误差以及最终识别效果的影响不太明显,在迭代次数为50次以上时,识别率并不随着迭代次数的增加而增加,因此在应用中适当选取一个较大的迭代次数或依照识别率变化情况自动终止计算都是可行的。

3) 在所有样本上的实验结果

通过前述研究,最终选取特征维数为24,迭代次数为200,稀疏性因子为0.2,依照第3.1节描述的流程对13种不同时频方法得到的时频图像进行识别,并与文献[10]的结果进行比较。文献[10]首先将每一幅时频图像划分为 42×44 个同等大小格子,对每一个格子中间的像素做平均,以此平均像素值作为此方格的像素值,从而将图像从 630×330 降维至 42×44 ,然后用概率神经网络(Probabilistic neural networks, PNN)对降维后的时频图像识别。本文方法和文献[10]方法的结果对比如图6所示。由图6可以看出,本文方法在13种时频图像上的识别率都高于文献[10],尤其是对于文献[10]识别率

较低的RGKBD和IRGKBD方法,本文方法都获得了97%以上的识别率。这说明本文方法在提取隐含特征信息方面,比简单平均降维方法有了很大的提高。另外,本文方法在多种时频分析方法上对柴油机8种状态的识别都取得100%的识别率,因此降低了使用中对时频分析方法选择的要求,有较好的通用性。对数据压缩的效果而言,本文方法采用24个特征表征一幅时频图像,而文献[10]采用了924个特征,因而本文方法对学习机器的训练和测试计算量明显减少。

4 结论

1) 提出了基于图像识别的设备运行状态识别方法,该方法可避免对敏感特征的选择和提取难题,实验证实了该方法的可行性;2) 初步研究了SNMF中各个参数的影响,结果表明只要参数选择合理,SNMF能够在保留图像有用信息的前提下,对数据进行非常有效的降维,如在本文中图像由207900维压缩为24维,大大降低了识别的复杂度;3) 所提出的方法可适用于反映设备运行状态的各种图像识别中,我们将在时域波形、轴心轨迹、频谱图上进一步验证该方法。

References




图6 SNMF和PNN的识别率比较

Fig. 6 The comparison of accuracies of
SNMF and PNN

- Zou Shu-Xue, Wang Yan, Huang Yan-Xin, Zhou Chun-Guang. Fuzzy classification system based on support vector machine. *Mini-Micro Systems*, 2006, **27**(4): 701–705
(邹淑雪, 王岩, 黄艳新, 周春光. 一种基于支持向量机的模糊分类系统研究. 小型微型计算机系统, 2006, **27**(4): 701–705)
- Lee D D, Seung H S. Learning the parts of objects by nonnegative matrix factorization. *Nature*, 1999, **401**(6755): 788–791
- Hoyer P O. Non-negative matrix factorization with sparseness constraints. *The Journal of Machine Learning Research*, 2004, **5**(11): 1457–1469
- Miao Qi-Guang, Wang Bao-Shu. A novel algorithm of multi-sensor image fusion using non-negative matrix factorization. *Journal of Computer-Aided Design and Computer Graphics*, 2005, **17**(9): 2029–2032
(苗启广, 王宝树. 图像融合的非负矩阵分解算法. 计算机辅助设计与图形学学报, 2005, **17**(9): 2029–2032)
- Song Xing-Guang, Xia Li-Min, Zhao Gui-Min. Local non-negative matrix factorization based face recognition. *Computer Engineering and Applications*, 2005, **41**(5): 42–44
(宋星光, 夏利民, 赵桂敏. 基于LNMF分解的人脸识别. 计算机工程与应用, 2005, **41**(5): 42–44)
- Liang Dong, Yang Jie, Lu Jin-Jun, Chang Yu-Chou. The latent semantic image retrieval based on non-negative ma-

- trix factorization. *Journal of Shanghai Jiaotong University*, 2006, **39**(4): 578–581
 (梁栋, 杨杰, 卢进军, 常宇畴. 基于非负矩阵分解的相关反馈图像检索算法. 上海交通大学学报, 2006, **39**(4): 578–581)
- 7 He Xue-Wen, Zhao Hai-Ming. Support vector machine and its application to machinery fault diagnosis. *Journal of Central South University (Science and Technology)*, 2005, **36**(1): 97–101
 (何学文, 赵海鸣. 支持向量机及其在机械故障诊断中的应用. 中南大学学报(自然科学版), 2005, **36**(1): 97–101)
- 8 Wang Bing-Ren, Liu Zhao-Yang, Zhang Jia-Wei, Tian Li-Jie. Researched non-linear fault diagnosis of rotating machine on support vector machine. *Coal Mine Machinery*, 2005, (2): 122–123
 (王秉仁, 刘兆阳, 张家伟, 田丽洁. 基于支持向量机的旋转机械非线性故障诊断研究. 煤矿机械, 2005, (2): 122–123)
- 9 Vaseghi S V. State duration modeling in hidden Markov models. *Signal Processing*, 1995, **41**(1): 31–41
- 10 Wang Cheng-Dong. Investigation on Time-Frequency Images and Its Application to Automatic Fault Diagnosis of Mechanical Equipment [Ph. D. dissertation], Xi'an Jiaotong University, China, 2004
 (王成栋. 时频图像及其在机械设备故障自动诊断中的应用研究[博士学位论文], 西安交通大学, 中国, 2004)
- 11 Liu Wei-Xiang, Zheng Nan-Ning, You Qu-Bo. Non-negative matrix factorization and its application in pattern recognition. *Chinese Science Bulletin*, 2006, **51**(3): 241–250
 (刘维湘, 郑南宁, 游屈波. 非负矩阵分解及其在模式识别中的应用. 科学通报, 2006, **51**(3): 241–250)



蔡 蕾 西安交通大学润滑理论与轴承研究所硕士研究生. 主要研究方向为机械故障诊断和模式识别. 本文通信作者.

E-mail: xinyu316@163.com

(CAI Lei Master student at Xi'an Jiaotong University. Her research interest covers method of mechanical equipment faults diagnosis, pattern recognition and related area. Corresponding author of this paper.)



朱永生 西安交通大学副教授. 主要研究方向为机械设备运行故障诊断状态监测和故障诊断, 新型抛光材料及工艺.

E-mail: yszhu@mail.xjtu.edu.cn

(ZHU Yong-Sheng Associate professor at Xi'an Jiaotong University. His research interest covers running condition monitoring and fault diagnosis of mechanical equipment, new polishing materials and technology.)