

## 基于核鲁棒流形非负矩阵分解和融合特征的柴油机故障诊断

刘弘毅, 王瑞, 吴贯锋, 张阳

### 引用本文

刘弘毅, 王瑞, 吴贯锋, 张阳. 基于核鲁棒流形非负矩阵分解和融合特征的柴油机故障诊断[J]. 计算机科学, 2023, 50(6A): 220400128-8.

LIU Hongyi, WANG Rui, WU Guanfeng, ZHANG Yang. Diesel Engine Fault Diagnosis Based on Kernel Robust Manifold Nonnegative Matrix Factorization and Fusion Features [J]. Computer Science, 2023, 50(6A): 220400128-8.

---

### 相似文献推荐 (请使用火狐或 IE 浏览器查看文章)

#### Similar articles recommended (Please use Firefox or IE to view the article)

#### [基于界面相似度的Android仿冒应用检测研究](#)

Study on Android Fake Application Detection Method Based on Interface Similarity  
计算机科学, 2023, 50(6A): 220300114-7. <https://doi.org/10.11896/jsjcx.220300114>

#### [基于深度学习的智能设备故障诊断研究综述](#)

Review of Intelligent Device Fault Diagnosis Based on Deep Learning  
计算机科学, 2023, 50(5): 93-102. <https://doi.org/10.11896/jsjcx.220500197>

#### [知识驱动的机械设备故障诊断](#)

Mechanical Equipment Fault Diagnosis Driven by Knowledge  
计算机科学, 2023, 50(5): 82-92. <https://doi.org/10.11896/jsjcx.221100160>

#### [基于深度学习的视觉多目标跟踪研究综述](#)

Deep Learning-based Visual Multiple Object Tracking: A Review  
计算机科学, 2023, 50(4): 77-87. <https://doi.org/10.11896/jsjcx.220300173>

#### [一种基于GRU的半监督网络流量异常检测方法](#)

Semi-supervised Network Traffic Anomaly Detection Method Based on GRU  
计算机科学, 2023, 50(3): 380-390. <https://doi.org/10.11896/jsjcx.220100032>

# 基于核鲁棒流形非负矩阵分解和融合特征的柴油机故障诊断

刘弘毅<sup>1,2</sup> 王瑞<sup>3</sup> 吴贯锋<sup>1,2</sup> 张阳<sup>1,2</sup>

1 西南交通大学数学学院 成都 611756

2 系统可信性自动验证国家地方联合工程实验室 成都 611756

3 中国航天电子技术研究院 北京 100094

(905759310@qq.com)

**摘要** 柴油发动机作为工业生产上的重要动力源之一,若其产生故障,将对工业生产的效率和安全造成巨大的影响,因此对柴油机进行故障诊断具有重要意义。针对柴油发动机气门故障诊断中特征提取困难和准确率不高的问题,提出一种基于核鲁棒流形非负矩阵分解方法和融合特征的柴油机故障诊断方法。首先,对压力信号进行时域分析,提取压力特征;其次使用短时傅里叶变换对振动信号进行时频分析;然后用核鲁棒流形非负矩阵分解提取振动信号中的特征;再融合压力信号中的特征与振动信号中的特征;最后使用支持向量机实现故障诊断。与传统方法相比,该方法在采集的数据集上故障诊断准确率可达100%,证明该方法可以有效提取特征并显著提高诊断准确率。

**关键词** 柴油机;故障诊断;非负矩阵分解;特征提取;融合特征

中图分类号 TP206

## Diesel Engine Fault Diagnosis Based on Kernel Robust Manifold Nonnegative Matrix Factorization and Fusion Features

LIU Hongyi<sup>1,2</sup>, WANG Rui<sup>3</sup>, WU Guanfeng<sup>1,2</sup> and ZHANG Yang<sup>1,2</sup>

1 School of Mathematics, Southwest Jiaotong University, Chengdu 611756, China

2 National-Local Joint Engineering Laboratory of System Credibility Automatic Verification, Chengdu 611756, China

3 China Academy of Aerospace Electronics Technology, Beijing 100094, China

**Abstract** The diesel engine is one of the important power sources in industrial production, its failure will cause a huge impact on the efficiency and safety of industrial production, it is of great significance to diagnose the fault of diesel engine. Aiming at the difficulty and low accuracy of feature extraction in diesel engine valve fault diagnosis, a diesel engine fault diagnosis method based on kernel robust manifold non-negative matrix factorization method and fusion feature is proposed. Firstly, the pressure signal is analyzed in the time domain to extract the pressure characteristics. Secondly, the time-frequency analysis of the vibration signal is carried out using the short-time Fourier transform(STFT), and the features of the vibration signal are extracted by the kernel robust manifold nonnegative matrix factorization. Then the features of the pressure signal and vibration signal are fused. Finally, support vector machine is used to realize fault diagnosis. Compared with the traditional method, the fault diagnosis accuracy of this method can reach 100% on the collected data set, which proves that it can effectively extract features and significantly improve the diagnosis accuracy.

**Keywords** Diesel engine, Fault diagnosis, Nonnegative matrix factorization, Feature extraction, Fusion feature

## 1 引言

柴油机是非常复杂的机械系统,其机理和运转模式都非常复杂。传统的诊断方法由于存在干扰、持久性差和缺乏实践经验等缺点而难以得到应用<sup>[1]</sup>。从间接的响应信号中反求潜在的故障源信号及其特征是柴油机科研机构与生产企业研究面临的主要问题。压力、振动信号是常用于分析柴油机状态的两类信号,由于柴油机运转时产生的振动信号中包含了丰富的工作状态信息,学者们通过分析振动信号寻找故障

特征来实现柴油机故障诊断<sup>[2]</sup>。振动信号属于典型的非线性、非平稳信号,基于振动信号的柴油机故障诊断的本质是模式识别问题,因此,如何从振动信号中准确提取出故障特征是问题的关键<sup>[3]</sup>。

在进行特征提取之前,需要对信号进行分析以表征不同类型的特征。常用柴油机信号分析方法有时域分析、频域分析和时频分析。在频域、时频分析中,广泛应用的信号分解方法有短时傅里叶变换、小波变换、S变换和魏格纳分布等。本文采用的是短时傅里叶变换(Short-time Fourier Transform,

基金项目:国家自然科学基金(62106206)

This work was supported by the National Natural Science Foundation of China(62106206).

通信作者:吴贯锋(wgf1024@swjtu.edu.cn)

STFT), 通过时频分析获得时频图并得到信号的时频表征, 然后使用特征提取方法提取特征, 最后使用提取出的特征实现故障诊断。

经典的特征提取方法有主成分分析、线性判别分析、独立分量分析、局部线性嵌入、矢量量化和非负矩阵分解等。非负矩阵分解(Nonnegative Matrix Factor, NMF)是由 Lee 和 Seung 最先提出, 并发表在 Nature 上的一种矩阵分解方法, 它使分解后的所有分量均为非负值(要求纯加性的描述), 并且同时实现维数约减<sup>[4]</sup>。非负矩阵分解被广泛用于模式识别、机器学习、人工智能、数据挖掘、计算机视觉、生物信息学等很多领域。

在故障诊断领域中, 关于非负矩阵分解的研究有很多。使用非负矩阵分解进行特征提取, 其本质是在对时频图像数据降维的同时最大限度保留不同样本间的差异化信息<sup>[5]</sup>。文献[6]采用局部非负矩阵分解对振动信号时频谱图进行特征提取, 使得分解的基矩阵更具有局部的特征, 再将提取出的时频特征与振动信号的时域特征融合, 最终通过支持向量机实现了内燃机故障识别。文献[7]针对轴承信号复杂、信噪比低、数据冗余性较大等特点提出双约束非负矩阵分解, 将  $\beta$  约束与行列式约束相结合, 在提取特征的同时减少信号的冗余成分, 从而实现轴承的故障诊断。文献[8]考虑到机械设备的振动信号是非线性的而不像负矩阵分解算法那样本质上是线性的情况, 将核函数与非负矩阵分解相结合, 从而提取数据中的非线性特征, 成功实现故障诊断。虽然这些改进考虑到故障诊断中实际数据的一些特性, 但不够全面。柴油机振动信号是典型的非线性、非平稳信号, 在实际数据采集时, 噪声不可避免, 误差较大的离群点会影响分解结果。

综上, 针对柴油机故障诊断中的特征提取问题, 本文考虑柴油机振动信号非线性、非平稳以及数据噪声多等特点, 使用核函数来提取数据中的非线性特征, 利用  $L_{2,1}$  范数计算目标函数, 减少数据中噪声的影响, 并利用图正则项捕捉特征空间中几何结构, 提出了核鲁棒流形非负矩阵分解方法, 用于振动信号的时频特征提取。然后与压力信号的时域特征融合, 用于柴油机气门间隙故障的诊断。以采集到的实际数据为实验数据, 实验分析表明, 在柴油机气门间隙正常、气门漏气、气门间隙过小和气门间隙过大这 4 种工况的识别诊断上, 准确率可达 100%, 且提取到的特征向量维数低、效率高, 证明了该方法在柴油机气门故障诊断上的有效性。

## 2 相关工作

### 2.1 标准非负矩阵分解

NMF 的目标是将一个高维非负矩阵  $\mathbf{X} = R_+^{m \times n}$  分解为两个非负低秩矩阵  $\mathbf{W} = R_+^{m \times k}$  和  $\mathbf{H} = R_+^{k \times n}$ , 使得这两个矩阵的乘积无限逼近原矩阵。即满足:

$$\mathbf{X}_{m \times n} \approx \mathbf{W}_{m \times k} \mathbf{H}_{k \times n} \quad (1)$$

其中,  $\mathbf{X} = [x_1, \dots, x_n]$  为原始数据矩阵,  $\mathbf{W} = [w_1, \dots, w_k]$  为基矩阵,  $\mathbf{H} = [h_1, \dots, h_n]$  为系数矩阵,  $k \ll m$ 。

标准的 NMF 采用欧氏距离计算损失函数, 即:

$$\min_{\mathbf{W}, \mathbf{H}} \|\mathbf{X} - \mathbf{WH}\|_F^2 \quad \text{s. t. } \mathbf{W} \geq 0, \mathbf{H} \geq 0 \quad (2)$$

其中,  $\|\cdot\|_F$  为矩阵的 Frobenius 范数。Lee 等<sup>[4]</sup>给出了对应的乘性迭代更新规则:

$$\mathbf{W}_{mk} \leftarrow \mathbf{W}_{mk} \frac{(\mathbf{XH}^T)_{mk}}{(\mathbf{WHH}^T)_{mk}} \quad (3)$$

$$\mathbf{H}_{kn} \leftarrow \mathbf{H}_{kn} \frac{(\mathbf{W}^T \mathbf{X})_{kn}}{(\mathbf{W}^T \mathbf{WH})_{kn}} \quad (4)$$

### 2.2 核非负矩阵分解

核非负矩阵分解(Kernel Non-negative Matrix Factorization, KNMF)<sup>[9]</sup>将核方法与非负矩阵分解相结合, 通过核映射把非线性的数据从输入空间映射到高维的特征空间, 从而实现线性可分。其目标函数为:

$$\min_{\mathbf{W}, \mathbf{G}} \|\phi(\mathbf{X}) - \phi(\mathbf{X})\mathbf{WH}\|_F^2 \quad (5)$$

$$\text{s. t. } \mathbf{W} \geq 0, \mathbf{G} \geq 0$$

其中,  $\phi$  为映射:  $x_i \rightarrow \phi(x_i)$ ,  $x_i$  为原始数据空间  $\mathbf{X}$  的第  $i$  个样本点, 即  $\mathbf{X} \rightarrow \phi(\mathbf{X}) = [\phi(x_1), \dots, \phi(x_n)]$ ,  $\phi(\mathbf{X}) \in R^{a \times n}$ ,  $g \geq m$ 。

核的使用不显式地依赖映射函数  $\phi$ , 仅依赖于其内积  $\phi(x_i)^T \phi(x_j) = K$ ,  $K$  是一个核函数。常见的核函数如下<sup>[8]</sup>:

(1) 高斯核函数

$$K(\mathbf{x}, \mathbf{y}) = \exp\left(-\frac{\|\mathbf{x} - \mathbf{y}\|^2}{\sigma^2}\right) \quad (6)$$

其中,  $\sigma$  为高斯核参数。

(2) 多项式核函数

$$K = (\mathbf{X}^T \mathbf{X})^d \quad (7)$$

当  $d=1$  时,  $K$  是线性核函数。

(3) Sigmoid 核函数

$$K = \tanh(\alpha(\mathbf{X}^T \mathbf{X}) + \beta) \quad (8)$$

其中,  $\alpha, \beta$  为 Sigmoid 核函数参数。

设  $\phi(x_i)^T \phi(x_j) = K$ , KNMF 的更新规则为:

$$\mathbf{W}_{nk} \leftarrow \mathbf{W}_{nk} \frac{(\mathbf{KH}^T)_{nk}}{(\mathbf{KWHH}^T)_{nk}} \quad (9)$$

$$\mathbf{H}_{nk}^T \leftarrow \mathbf{H}_{nk}^T \frac{(\mathbf{KW})_{nk}}{(\mathbf{H}^T \mathbf{W}^T \mathbf{KW})_{nk}} \quad (10)$$

### 2.3 鲁棒非负矩阵分解

鲁棒非负矩阵分解(Robust Non-negative Matrix Factorization, RNMF)<sup>[10]</sup>使用  $L_{2,1}$  范数计算误差, 使得误差较大的离群点产生的影响减少, 从而具备鲁棒性。鲁棒非负矩阵分解的目标函数为:

$$\min_{\mathbf{W}, \mathbf{H}} \|\mathbf{X} - \mathbf{WH}\|_{2,1} \quad \text{s. t. } \mathbf{W} \geq 0, \mathbf{H} \geq 0 \quad (11)$$

关于矩阵的  $L_{2,1}$  范数最初由文献[11]提出, 其定义为:

$$\|\mathbf{X}\|_{2,1} = \sum_i \sqrt{\sum_j X_{ji}^2} = \sum_i \|\mathbf{x}_i\| \quad (12)$$

其中,  $\|\cdot\|_{2,1}$  为  $L_{2,1}$  范数,  $x_i$  为  $\mathbf{X}$  的第  $i$  个向量。

其更新规则如下:

$$\mathbf{W}_{mk} \leftarrow \mathbf{W}_{mk} \frac{(\mathbf{XDH}^T)_{mk}}{(\mathbf{WHDH}^T)_{mk}} \quad (13)$$

$$\mathbf{H}_{kn} \leftarrow \mathbf{H}_{kn} \frac{(\mathbf{W}^T \mathbf{XD})_{kn}}{(\mathbf{W}^T \mathbf{WHD})_{kn}} \quad (14)$$

其中,  $\mathbf{D}$  是对角矩阵, 且满足:

$$D_{ii} = 1 / \sqrt{\sum_j (\mathbf{X} - \mathbf{WH})_{ji}^2} = 1 / \|\mathbf{x}_i - \mathbf{Wh}_i\| \quad (15)$$

### 2.4 流形(图正则)非负矩阵分解

基于流形学习理论, 文献[12]提出图正则非负矩阵分解(Graph Regularized Nonnegative Matrix Factorization, GNMF), GNMF 使得高维空间中相邻的数据点在低维流形空间中保持相邻。其图形几何结构示意图如图 1 所示。

GNMF 的目标函数为:

$$\min_{\mathbf{W}, \mathbf{H}} \|\mathbf{X} - \mathbf{FH}\|_F^2 + \lambda \text{Tr}(\mathbf{HLH}^T) \quad (16)$$

$$\text{s. t. } \mathbf{F} \geq 0, \mathbf{H} \geq 0$$

其中,  $\lambda$  是非负正则化参数,  $Tr(\cdot)$  是矩阵的迹,  $\mathbf{L}$  是拉普拉斯矩阵,  $\mathbf{L}=\mathbf{V}-\mathbf{W}$ ,  $\mathbf{V}$  是对角矩阵, 满足  $\mathbf{V}_{ii}=\sum_j \mathbf{W}_{ij}$ .  $\mathbf{W}$  是邻接矩阵, 其定义为:

$$\mathbf{W}_{ij} = \begin{cases} 1, & x_i \in N_a(x_j) \text{ or } x_j \in N_a(x_i) \\ 0, & \text{其他} \end{cases} \quad (17)$$

其中,  $N_a(x)$  表示一组与样本  $x$  最近的  $a$  个数据样本. 任意两个数据样本之间的距离定义为:

$$d(x_i, x_j) = \sqrt{\sum_{l=1}^m (x_{il} - x_{jl})^2} \quad (18)$$

GNMF 的更新规则为:

$$\mathbf{F}_{mk} \leftarrow \mathbf{F}_{mk} \frac{(\mathbf{X}\mathbf{H})_{mk}}{(\mathbf{F}\mathbf{H}\mathbf{H}^T)_{mk}} \quad (19)$$

$$\mathbf{H}_{nk}^T \leftarrow \mathbf{H}_{nk}^T \frac{(\mathbf{X}^T \mathbf{F} + \lambda \mathbf{W}\mathbf{H}^T)_{nk}}{(\mathbf{H}^T \mathbf{F}^T \mathbf{F} + \lambda \mathbf{V}\mathbf{H}^T)_{nk}} \quad (20)$$




图1 几何结构示意图  
Fig. 1 Geometric schematic

### 3 核鲁棒流形非负矩阵分解

#### 3.1 核鲁棒流形非负矩阵分解算法模型

柴油机的压力信号、振动信号数据值是非负的, 与非负矩阵分解吻合. 非负矩阵分解具备易操作、可解释性强的特点, 适用于柴油机故障诊断. 一般地, 非负矩阵分解算法的损失函数会根据处理的数据类型和应用场景选取. 由于柴油机信号是非线性、非平稳的信号, 且数据含有噪声会影响分解结果, 本文针对这些特点提出了核鲁棒流形非负矩阵分解(Kernel Robust Manifold Non-negative Matrix Factorization, KRMNMF), 通过核函数来提取数据中的非线性特征, 利用  $L_{2.1}$  范数计算目标函数, 减小数据中噪声的影响, 并利用图正则项捕捉特征空间中几何结构.

核鲁棒流形非负矩阵分解的目标函数定义为:

$$\min_{\mathbf{F}, \mathbf{H}} \|\phi(\mathbf{X}) - \phi(\mathbf{X})\mathbf{F}\mathbf{H}\|_{2.1} + \lambda Tr(\mathbf{H}\mathbf{L}\mathbf{H}^T) \quad (21)$$

s. t.  $\mathbf{F} \geq 0, \mathbf{H} \geq 0$

其中,  $\mathbf{X} \in R^{m \times n}$ ,  $\mathbf{W} \in R^{m \times k}$ ,  $\mathbf{H} \in R^{k \times n}$ ,  $\phi$  为映射:  $x_i \rightarrow \phi(x_i)$ ,  $x_i$  为原始数据空间  $\mathbf{X}$  的第  $i$  个样本点, 即:  $\mathbf{X} \rightarrow \phi(\mathbf{X}) = [\phi(x_1), \dots, \phi(x_n)]$ ,  $\phi(\mathbf{X}) \in R^{g \times n}$ ,  $g \geq m$ ,  $\lambda$  是非负正则化参数,  $Tr(\cdot)$  是矩阵的迹,  $\mathbf{L}$  是拉普拉斯矩阵, 定义为  $\mathbf{L}=\mathbf{V}-\mathbf{W}$ .  $\mathbf{V}$  是对角矩阵,  $\mathbf{V}_{ii}=\sum_j \mathbf{W}_{ij}$ ,  $\mathbf{W}$  定义为式(17).

#### 3.2 模型求解

KRMNMF 的目标函数(21)对于  $\mathbf{F}, \mathbf{H}$  不是联合凸的, 当固定其他变量时, 单独的变量是凸的, 于是本文采用拉格朗日乘数法求解.

目标函数(21)等价于:

$$\min_{\mathbf{F}, \mathbf{H}} Tr((\phi(\mathbf{X}) - \phi(\mathbf{X})\mathbf{F}\mathbf{H})\mathbf{D}(\phi(\mathbf{X}) - \phi(\mathbf{X})\mathbf{F}\mathbf{H})^T) + \lambda Tr(\mathbf{H}\mathbf{L}\mathbf{H}^T) \quad (22)$$

其中,  $\mathbf{D}$  是对角矩阵且满足:

$$\mathbf{D}_{ii} = (\sum_{j=1}^n (\phi(\mathbf{X}) - \phi(\mathbf{X})\mathbf{F}\mathbf{H})_{ji}^2)^{-\frac{1}{2}} \quad (23)$$

设  $\phi(x_i)^T \phi(x_i) = \mathbf{K}$ , 则:

$$\mathbf{D}_{ii} = [(\mathbf{I} - \mathbf{F}\mathbf{H})^T \mathbf{K} (\mathbf{I} - \mathbf{F}\mathbf{H})]_{ii}^{-\frac{1}{2}} \quad (24)$$

其中,  $\mathbf{I}$  为单位矩阵. 式(22)等价于:

$$\min_{\mathbf{F}, \mathbf{H}} Tr(\phi(\mathbf{X})\mathbf{D}\phi(\mathbf{X})^T) - 2Tr(\phi(\mathbf{X})\mathbf{D}\mathbf{H}^T \mathbf{F}^T \phi(\mathbf{X})^T) + Tr(\phi(\mathbf{X})\mathbf{F}\mathbf{H}\mathbf{D}\mathbf{H}^T \mathbf{F}^T \phi(\mathbf{X})^T) + \lambda(\mathbf{H}\mathbf{L}\mathbf{H}^T) \quad (25)$$

设  $\Psi, \Omega$  为  $\mathbf{F}, \mathbf{H}$  的拉格朗日乘数, 则关于目标函数的拉格朗日函数为:

$$\mathbf{L} = \min_{\mathbf{F}, \mathbf{H}} Tr(\phi(\mathbf{X})\mathbf{D}\phi(\mathbf{X})^T) - 2Tr(\phi(\mathbf{X})\mathbf{D}\mathbf{H}^T \mathbf{F}^T \phi(\mathbf{X})^T) + Tr(\phi(\mathbf{X})\mathbf{F}\mathbf{H}\mathbf{D}\mathbf{H}^T \mathbf{F}^T \phi(\mathbf{X})^T) + \lambda(\mathbf{H}\mathbf{L}\mathbf{H}^T) + Tr(\Psi^T \mathbf{F}) + Tr(\Omega^T \mathbf{H}) \quad (26)$$

分别对  $\mathbf{F}, \mathbf{H}$  求偏导数可得:

$$\frac{\partial \mathbf{L}}{\partial \mathbf{F}} = -2\phi(\mathbf{X})^T \phi(\mathbf{X})\mathbf{D}\mathbf{H}^T + 2\phi(\mathbf{X})^T \phi(\mathbf{X})\mathbf{F}\mathbf{H}\mathbf{D}\mathbf{H}^T + \Psi \quad (27)$$

$$\frac{\partial \mathbf{L}}{\partial \mathbf{H}} = -2\mathbf{F}^T \phi(\mathbf{X})^T \phi(\mathbf{X})\mathbf{D} + 2\mathbf{H}\phi(\mathbf{X})^T \phi(\mathbf{X})\mathbf{D}\mathbf{F}\mathbf{F}^T + 2\lambda\mathbf{H}\mathbf{V} - 2\lambda\mathbf{H}\mathbf{W} + \Omega \quad (28)$$

由 KKT 条件:  $\Psi_{nk} \mathbf{F}_{nk} = 0, \Omega_{kn} \mathbf{H}_{kn} = 0$  可得:

$$(-2\phi(\mathbf{X})^T \phi(\mathbf{X})\mathbf{D}\mathbf{H}^T + 2\phi(\mathbf{X})^T \phi(\mathbf{X})\mathbf{F}\mathbf{H}\mathbf{D}\mathbf{H}^T)_{nk} \mathbf{F}_{nk} + \Psi_{nk} \mathbf{F}_{nk} = 0 \quad (29)$$

$$(-2\mathbf{F}^T \phi(\mathbf{X})^T \phi(\mathbf{X})\mathbf{D} + 2\mathbf{H}\phi(\mathbf{X})^T \phi(\mathbf{X})\mathbf{D}\mathbf{F}\mathbf{F}^T + 2\lambda\mathbf{H}\mathbf{V} - 2\lambda\mathbf{H}\mathbf{W})_{kn} \mathbf{H}_{kn} + \Omega_{kn} \mathbf{H}_{kn} = 0 \quad (30)$$

综上可得  $\mathbf{F}, \mathbf{H}$  的更新规则:

$$\mathbf{F}_{kn} \leftarrow \mathbf{F}_{kn} \frac{(\phi(\mathbf{X})^T \phi(\mathbf{X})\mathbf{D}\mathbf{H}^T)_{kn}}{(\phi(\mathbf{X})^T \phi(\mathbf{X})\mathbf{F}\mathbf{H}\mathbf{D}\mathbf{H}^T)_{kn}} \quad (31)$$

$$\mathbf{H}_{kn} \leftarrow \mathbf{H}_{kn} \frac{(\mathbf{F}^T \phi(\mathbf{X})^T \phi(\mathbf{X})\mathbf{D} + \lambda\mathbf{H}\mathbf{V})_{kn}}{(\mathbf{H}\phi(\mathbf{X})^T \phi(\mathbf{X})\mathbf{D}\mathbf{F}\mathbf{F}^T + \lambda\mathbf{H}\mathbf{V})_{kn}} \quad (32)$$

设  $\phi(x_i)^T \phi(x_i) = \mathbf{K}$ , 即:

$$\mathbf{F}_{nk} \leftarrow \mathbf{F}_{nk} \frac{(\mathbf{K}\mathbf{D}\mathbf{H}^T)_{nk}}{(\mathbf{K}\mathbf{F}\mathbf{H}\mathbf{D}\mathbf{H}^T)_{nk}} \quad (33)$$

$$\mathbf{H}_{kn} \leftarrow \mathbf{H}_{kn} \frac{(\mathbf{F}^T \mathbf{K}\mathbf{D} + \lambda\mathbf{H}\mathbf{V})_{kn}}{(\mathbf{H}\mathbf{K}\mathbf{D}\mathbf{F}^T + \lambda\mathbf{H}\mathbf{V})_{kn}} \quad (34)$$

#### 3.3 KRMNMF 模型收敛性证明

由上述更新规则, 有定理 1 成立.

**定理 1** KRMNMF 的目标函数(21)在式(33)、式(34)更新规则下不递增.

参考标准 NMF 的收敛性证明, 构造辅助函数证明定理 1<sup>[4]</sup>. 首先给出辅助函数的定义.

**定义 1**  $Q(h, h')$  是  $R(h)$  的辅助函数, 如果满足以下条件:

$$Q(h, h') \geq R(h) \quad (35)$$

$$Q(h, h) = R(h) \quad (36)$$

**引理 1** 如果  $G$  是  $R$  的辅助函数, 则  $R$  在下面的更新规则下不递增.

$$h^{(t+1)} = \arg \min_h Q(h, h^{(t)}) \quad (37)$$

证明:

$$R(h^{(t+1)}) \leq Q(h^{(t+1)}, h^{(t)}) \leq Q(h^{(t)}, h^{(t)}) = R(h^{(t)}) \quad (38)$$

下面说明  $\mathbf{H}$  的更新步骤正是引理 1 中具有辅助函数的更新.

首先, 考虑  $\mathbf{H}$  中的任意元素  $h_{ab}$ ,  $R_{ab}$  表示目标函数(21)中仅与  $h_{ab}$  相关的部分. 有:

$$R'_{ab} = (2HKDF\mathbf{F}^T - 2\mathbf{F}^T\mathbf{K}\mathbf{D} + 2\lambda\mathbf{H}\mathbf{L})_{ab} \quad (39)$$

$$R''_{ab} = (2\mathbf{K}\mathbf{D}\mathbf{F}\mathbf{F}^T)_{bb} + (2\lambda\mathbf{L})_{bb} \quad (40)$$

引理 2  $Q(h, h_{ab}^{(t)})$  是  $R_{ab}$  的一个辅助函数,  $Q(h, h_{ab}^{(t)})$  定义如下:

$$Q(h, h_{ab}^{(t)}) = R_{ab}(h_{ab}^{(t)}) + R'_{ab}(h_{ab}^{(t)})(h - h_{ab}^{(t)}) + \frac{(HKDF\mathbf{F}^T + \lambda\mathbf{H}\mathbf{V})_{ab}}{h_{ab}^{(t)}}(h - h_{ab}^{(t)})^2 \quad (41)$$

证明:  $Q(h, h) = R(h)$  显然成立, 下面证明  $Q(h, h_{ab}^{(t)}) \geq R_{ab}(h)$ .

由泰勒公式:

$$R_{ab}(h) = R_{ab}(h_{ab}^{(t)}) + R'_{ab}(h_{ab}^{(t)})(h - h_{ab}^{(t)}) + [(KDF\mathbf{F}^T)_{bb} + (\lambda\mathbf{L})_{bb}] + (h - h_{ab}^{(t)})^2 \quad (42)$$

比较可得,  $Q(h, h_{ab}^{(t)}) \geq R_{ab}(h)$  等价于:

$$\frac{(HKDF\mathbf{F}^T + \lambda\mathbf{H}\mathbf{V})_{ab}}{h_{ab}^{(t)}} \geq [(KDF\mathbf{F}^T)_{bb} + (\lambda\mathbf{L})_{bb}] \quad (43)$$

由于

$$\begin{aligned} (HKDF\mathbf{F}^T + \lambda\mathbf{H}\mathbf{V})_{ab} &= \sum_l \mathbf{H}_{al} (\mathbf{K}\mathbf{D}\mathbf{F}\mathbf{F}^T)_{lb} + \lambda \sum_l \mathbf{H}_{al} \mathbf{V}_{lb} \\ &\geq h_{ab}^{(t)} (\mathbf{K}\mathbf{D}\mathbf{F}\mathbf{F}^T)_{bb} + \lambda h_{ab}^{(t)} \mathbf{V}_{bb} \\ &\geq h_{ab}^{(t)} (\mathbf{K}\mathbf{D}\mathbf{F}\mathbf{F}^T)_{bb} + \lambda h_{ab}^{(t)} \mathbf{V}_{bb} - \lambda h_{ab}^{(t)} \mathbf{W}_{bb} \end{aligned} \quad (44)$$

即,  $Q(h, h_{ab}^{(t)}) \geq R_{ab}(h)$ .

综上,  $Q(h, h_{ab}^{(t)})$  是  $R_{ab}$  的一个辅助函数.

定理 1 证明: 替换  $h^{(t+1)} = \arg \min_h Q(h, h^{(t)})$  中的  $Q(h, h_{ab}^{(t)})$ , 有:

$$\begin{aligned} h_{ab}^{(t+1)} &= h_{ab}^{(t)} - \frac{h_{ab}^{(t)}}{2(HKDF\mathbf{F}^T + \lambda\mathbf{H}\mathbf{V})_{ab}} \\ R'_{ab}(h_{ab}^{(t)}) &= h_{ab}^{(t)} \frac{(\mathbf{F}^T\mathbf{K}\mathbf{D} + \lambda\mathbf{H}\mathbf{W})_{ab}}{(HKDF\mathbf{F}^T + \lambda\mathbf{H}\mathbf{V})_{ab}} \end{aligned} \quad (45)$$

由此, 定理 1 证得.

### 3.4 KRMNMF 算法方案

由上述分析, 给出 KRMNMF 算法描述.

#### 算法 1 KRMNMF

输入: 数据矩阵  $\mathbf{x} \in \mathbb{R}^{m \times n}$ , 参数  $a, \lambda, \mathbf{k}$ .

输出: 矩阵  $\mathbf{F} \in \mathbb{R}^{m \times k}$ ,  $\mathbf{H} \in \mathbb{R}^{k \times n}$ .

1. 随机生成  $\mathbf{F} \in \mathbb{R}^{m \times k}$ ,  $\mathbf{H} \in \mathbb{R}^{k \times n}$ .
2. 计算  $\mathbf{W}, \mathbf{V}, \mathbf{L}$  矩阵.
3. 判断目标函数(21)是否收敛.
4. 根据式(33)更新  $\mathbf{F}$ .
5. 根据式(34)更新  $\mathbf{H}$ .
6. 直至收敛.

## 4 基于 KRMNMF 的柴油机故障诊断

### 4.1 故障诊断流程

基于的 KRMNMF 和融合压力、振动信号特征的柴油机故障流程: 首先采集柴油机在 4 种工况下运行时产生的压力和振动信号, 然后对信号数据进行预处理, 再分别对压力信号和振动信号进行时域分析和时频分析, 之后利用 KRMNMF 提取振动信号的时频特征, 再将压力信号的时域特征和振动信号的时频特征进行融合, 最后使用支持向量机进行分类识别, 完成柴油机气门故障诊断. 流程如图 2 所示.

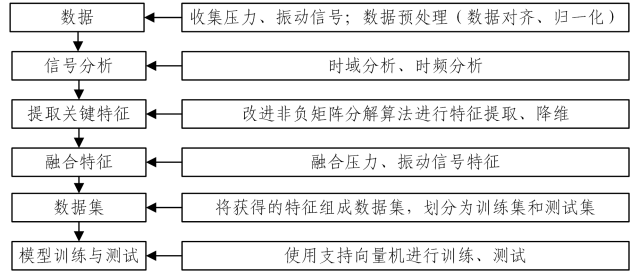


图 2 柴油机故障诊断流程

Fig. 2 Flow chart of diesel engine fault diagnosis

### 4.2 实验数据分析

以航天电子技术研究院某项目柴油机为实验对象, 通过调整柴油机气门间隙来模拟柴油机气门故障, 在采样频率为 25kHz 的情况下, 收集气门间隙正常 (Normal)、气门漏气 (Leakage)、气门间隙过小 (Small) 和气门间隙过大 (Large) 4 种工况的压力、振动信号各 40 组. 一组信号为柴油机一个工作周期产生的信号, 分别对压力信号和振动信号进行分析, 提取特征.

为了避免维数不一致和方便运算, 对原始数据进行数据对齐和归一化的预处理. 原始数据中的样本是采集设备一个工作周期的序列数据, 不同样本的序列长度略有差异, 这种差异会导致后续特征提取的维度不一致, 进而导致无法建立分类模型, 因此需要对数据进行对齐处理. 经过分析观察, 大部分样本序列长度在 1900 左右, 压力信号基本以峰值为中心对称, 以峰值为中心, 两端取 950 点数据, 超过则截断, 不足则使用两端均值补充. 对于振动信号, 不足的使用整体均值补充. 其次对原始数据进行归一化操作, 使数据被限制在 0~1 之间.

(1) 根据压力信号生成压力时域图像, 然后提取压力信号特征.

从原始数据中选取 4 种工况的压力信号各一组, 使用不同线条表示不同工况, 画出的压力时域图如图 3 所示. 时域分析是以时间为变量, 描绘出信号的波形. 常见的时域特征有: 最大值、最小值、峰值、方差、峭度、偏度等. 从图 3 的时域图可以观察到, 不同工况的压力信号峰值和端部有显著的区别, 因而考虑提取压力信号的峰值和端部平均值作为压力信号的时域特征.




图 3 压力时域图

Fig. 3 Pressure time domain diagram

(2) 根据振动信号生成振动时频图像, 然后提取振动信号特征.

使用经典的 STFT 对振动信号进行时频分析, 当分解的

分段长度取 80 时,图像纹理特征描述最理想,如图 4

所示是选取两组 4 种工况的振动信号的时频图像。




图 4 4 种工况的振动信号的时频图像

Fig. 4 Time-Frequency images of vibration signals under four working conditions

从图 4 的时频图可以观察到不同工况的时频能量分布存在显著的区别,并且同类工况的时频图像的能量分布相对一致,因此可以利用对时频图像的分类来实现故障诊断。将每一组振动信号的时频图谱平铺为一维向量,并组成一个原始数据矩阵,即为核鲁棒流形非负矩阵分解算法中的  $X$  矩阵。

#### 4.3 参数选取、实验比较及结果分析

本节介绍 KRMNMF 算法在对时频图谱进行特征提取涉及的参数选取和相关实验的比较。实验环境为 MATLAB R2021a, AMD R7 5800H 处理器, CPU 主频率 3.20 GHz, 内存 16.0 GB, 操作系统为 Windows 10。

由于数据样本量小,为避免过拟合,采用  $K$  折交叉验证,  $K$  折交叉验证划分参数取值为 2~5。选取支持向量机作为分类模型进行训练、测试,识别的结果可作为故障诊断的准确率。实验中每个算法均运行 5 次,计算 5 次结果的平均值作为实验结果。

除了为 KRMNMF 算法选取合适的参数以达到最好的

准确率,为了更好地测试本文算法的有效性,选取已有的经典的非负矩阵分解算法(NMF)、核非负矩阵分解算法(KNMF)、鲁棒非负矩阵分解算法(RNMF)、流形非负矩阵分解算法(GNMF)和近年来用于故障诊断的局部非负矩阵分解(Local Non-negative Matrix Factorization, LNMF)<sup>[6]</sup>、核鲁棒非负矩阵分解(Kernel Robust Non-negative Matrix Factorization, KRNMf)<sup>[13]</sup>、稀疏非负矩阵分解(Sparse Non-negative Matrix Factorization, SNMF)<sup>[14]</sup>进行对比,从特征提取的维数和准确率两个方面进行比较说明。

在 KRMNMF 算法中涉及的参数变量主要包括:核函数( $K$ )的选取、边邻接矩阵( $W$ )使用最近邻样本点的数目  $a$ , 正则化参数  $\lambda$  以及分解矩阵选取的维数  $k$ 。本文在选定多项式核函数的情况下比较其他参数对 KRMNMF 算法的影响,  $a$  的取值范围为 1~15,  $\lambda$  的取值范围为 {0.0001, 0.001, 0.01, 0.1, 1, 10, 100},  $k$  选取的范围为 5~100。

经过实验,设定最近邻样本点的数目  $a=10$ , 参数  $\lambda=1$ , KRMNMF 算法的故障诊断结果随维数  $k$  变化如图 5 所示。




图 5 KRMNMF 算法与维数  $k$  的关系

Fig. 5 Relation between KRMNMF algorithm and dimension  $k$

设定最近邻样本点的数目  $a=10$ , 维数  $k=24$ , KRMNMF 算法的故障诊断结果随参数  $\lambda$  的变化如图 6 所示。




图 6 KRMNMF 算法与参数  $\lambda$  的关系

Fig. 6 Relation between KRMNMF algorithm and parameter  $\lambda$

设定参数  $\lambda=1$ , 维数  $k=24$ , KRMNMF 算法的故障诊断结果随最近邻样本点数目  $a$  的变化如图 7 所示。




图 7 KRMNMF 算法与最近邻样本点的数目  $a$  的关系

Fig. 7 Relation between KRMNMF algorithm and the number of nearest neighbor sample point  $a$

从图 5—图 7 可以看出 KRMNMF 算法的性能随不同参数的变化的趋势, 当维数  $k$  取  $\{14, 24, 28\}$ ,  $\lambda$  取  $\{0.1, 1\}$  和  $a$  取  $\{9, 10\}$  时, KRMNMF 算法的性能较好, 且当  $\lambda$  为 0.1、 $a$  为 10 和维数  $k$  为 14 时, KRMNMF 算法的准确率可达到 99%。

图 8 给出了 NMF, KNMF, RNMF, KRNMf, SNMF, LNMF, GNMF, KRMNMF 算法的准确率随维数  $k$  的变化情况。

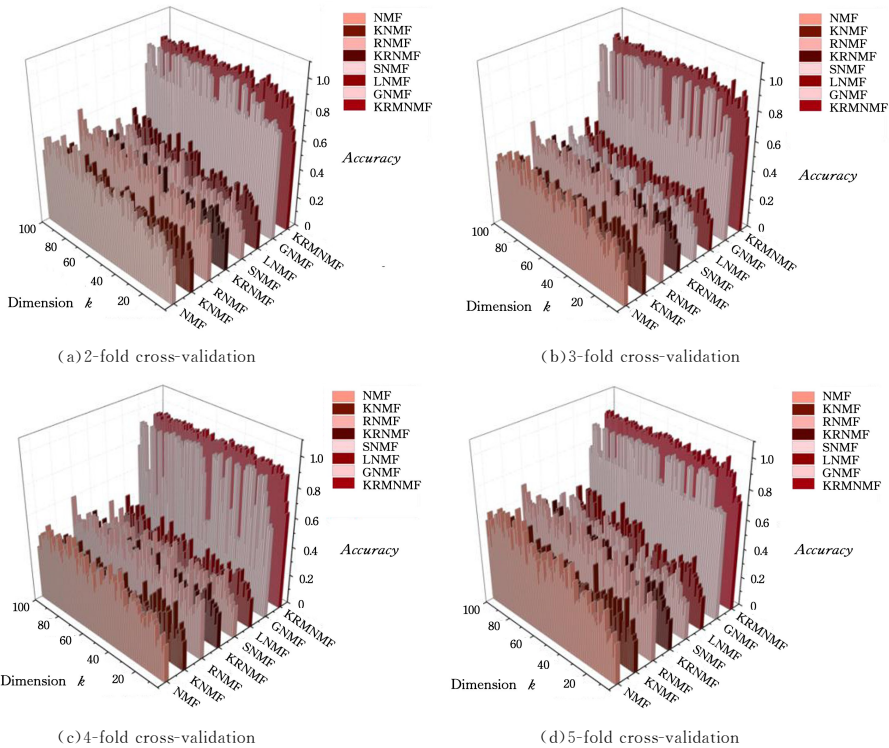


图 8 8 种算法的准确率

Fig. 8 Accuracy of eight algorithms

8 种算法在数据集上的最高准确率(5 折交叉验证)及最高准确率对应的维数  $k$  如表 1 所列。

表 1 算法准确率与维数

Table 1 Algorithm accuracy and dimension

Algorithm	Accuracy	Dimension
NMF	0.76	74
KNMF	0.56	32
RNMF	0.69	100
GNMF	0.95	38
KRNMF	0.57	90
SNMF	0.55	87
LNMF	0.58	63
KRMNMF	0.99	14

从图 8 和表 1 可以看出, NMF, KNMF, RNMF, GNMF, KRNMf, SNMF, LNMF 算法随维数的变化准确率波动较大, 与 KRMNMF 算法相比, KRMNMF 算法的准确率更高、维数更低并且更稳定, 说明 KRMNMF 算法可以提取更少维数的特征量来表征柴油机振动信号的时频谱且准确率更高。

#### 4.4 融合特征及结果分析

本节将对对比 KRMNMF 算法提取出的振动信号时频特征与压力时域特征结合前后的准确率变化, 以此检验融合压力时域特征和频率时频特征的故障诊断方法有效性。

通过压力信号的特征提取和使用 KRMNMF 算法对振动信号进行时频特征提取,可以获得不同工况的数据的振动时频特征和压力时域特征,二者都是低维特征向量,将它们拼接成一条向量,即融合特征向量。将全部融合特征向量放在一起组成数据集,使用支持向量机进行实验测试。KRMNMF 算法提取的振动信号时频特征与压力信号时域特征融合后的准确率变化如图 9 所示。从图 9 可以看到,时频特征维数较低时,融合压力时域特征故障诊断准确率显著提升,其他

维数的时频特征融合压力时域特征时故障诊断准确率也有一定的提升。说明压力信号时域特征具备一定的区别度,在诊断信号时频特征的区别度不够时,压力信号时域特征对故障诊断准确率的提升更为明显。经过实验,当  $\lambda$  取 0.1、 $a$  取 10 和维数  $k$  为 14 时,算法的准确率可达到 100%。并且,压力信号时域特征只有 2 维,融合压力信号时域特征对特征维数的影响不大,但可以帮助提升故障诊断的准确率。综上,融合振动信号时频特征和压力信号时域特征具有一定的实用意义。

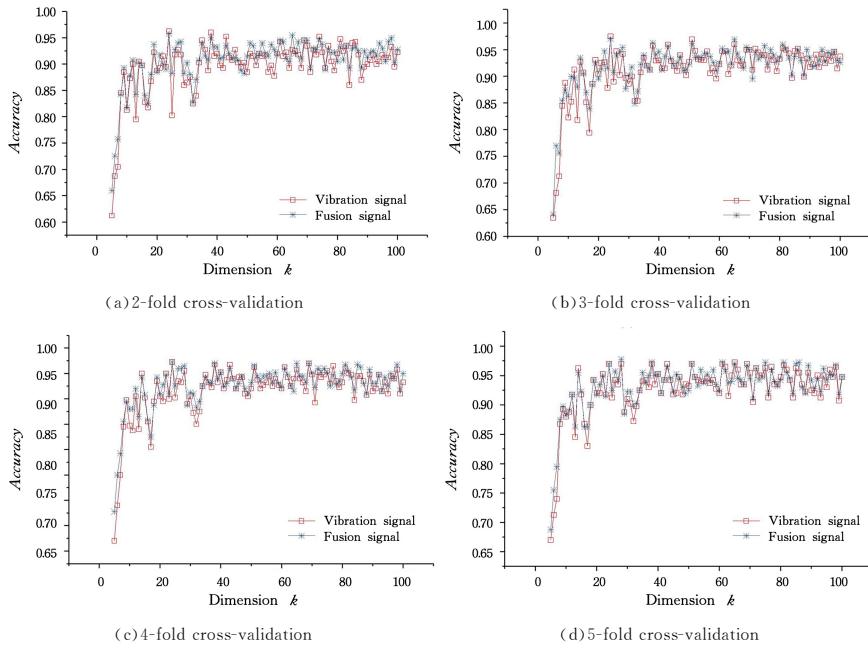


图 9 KRMNMF 算法融合压力信号

Fig. 9 KRMNMF algorithm fuses pressure signals

**结束语** 本文提出了一种新的基于核鲁棒流形非负矩阵分解和融合特征的柴油机气门故障诊断方法。该方法构建了完整的柴油机气门故障诊断框架,实现了故障诊断。考虑到柴油机振动信号数据非线性、非平稳、有噪声的特点,通过核鲁棒流形非负矩阵分解方法消除这些问题的影响,并结合流形学习理论,捕捉特征空间中的几何结构,相比传统的特征提取方法,本文算法有较强的特征提取能力,能较好地挖掘振动信号中存在的时频特征。针对柴油机气门故障的 4 种工况,通过融合振动信号时频特征和压力信号时域特征,在采集的数据集上故障诊断率可达 100%,说明本文提出的柴油机故障诊断方法具备一定的可行性、有效性。

## 参考文献

[1] LV S G, YANG L, YANG Q. Research on the applications of infrared technique in the diagnosis and prediction of diesel engine exhaust fault[J]. *Journal of Thermal Science*, 2011, 20(2): 189-194.

[2] YANG T T. Investigation into the condition monitoring of in-cylinder combustion behaviours of diesel engines based on time-frequency analysis of vibration signals[D]. Taiyuan: Taiyuan University of Technology, 2019.

[3] YUE Y J, WANG X, CAI Y P, et al. A novel fault feature extraction scheme for diesel engine valves based on feature reduction of time-frequency images[J]. *Automotive Engineering*,

2018, 40(1): 114-120, 126.

[4] LEE D D, SEUNG H S. Learning the parts of objects by non-negative matrix factorization[J]. *Nature*, 1999, 401(6755): 788-791.

[5] WANG X, YUE Y J, CAI Y P. Fast sparse decomposition and two-dimensional feature encoding recognition method of diesel engine vibration signal[J]. *Journal of Vibration, Measurement & Diagnosis*, 2019, 39(1): 114-122, 225.

[6] CAI Y P, FAN Y, CHEN W, et al. Application of improved time-frequency analysis and feature fusion in fault diagnosis of IC engines[J]. *China Mechanical Engineering*, 2020, 31(16): 1901-1911.

[7] WANG H Q, WANG M Y, SONG L Y, et al. Method of compound fault signal separation using double constraints non-negative factorization[J]. *Journal of Vibration Engineering*, 2020, 33(3): 590-596.

[8] MA C P, LIANG L, CHEN Y M, et al. Feature extraction for fault diagnosis of machine based on kernel nonnegative matrix factorization[C]// 2020 IEEE 4th Information Technology, Networking, Electronic and Automation Control Conference (IT-NEC). IEEE, 2020: 1412-1416.

[9] ZHANG D, ZHOU Z H, CHEN S. Non-negative matrix factorization on kernels[C]// Pacific Rim International Conference on Artificial Intelligence. Berlin: Springer, 2006: 404-412.

[10] KONG D, DING C, HUANG H. Robust nonnegative matrix fac-

torization using l21-norm[C]// Proceedings of the 20th ACM International Conference on Information and Knowledge Management, 2011:673-682.

[11] DING C, ZHOU D, HE X F, et al. R1-pca: rotational invariant l1-norm principal component analysis for robust subspace factorization[C]// Proceedings of the 23rd International Conference on Machine Learning, 2006:281-288.

[12] CAI D, HE X F, HAN J W, et al. Graph regular-ized nonnegative matrix factorization for data representation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2010, 33(8):1548-1560.

[13] WANG Y S, SUN T S, DING M T, et al. Actuator dynamic process fault detection using kernel robust non-negative matrix factorization[J/OL]. Control Theory & Applications: 1-9. <http://kns.cnki.net/kcms/detail/44.1240.TP.20211117.1453.026.html>.

[14] ZHU X J. Fault diagnosis of beards compound fault based on sparse non-negative matrix factorization[J]. Chinese Journal of Construction Machinery, 2018, 16(6):553-558.



**LIU Hongyi**, born in 1998, postgraduate, is a member of China Computer Federation. His main research interests include machine learning and fault diagnosis.



**WU Guanfeng**, born in 1986, Ph.D, is a member of China Computer Federation. His main research interests include intelligent information processing and parallel computing.