

基于多视图加权聚类集成的高速列车工况识别

饶齐,杨燕*,滕飞

(西南交通大学信息科学与技术学院,四川成都 611756)

摘要:随着中国高速列车行业的快速发展,高速列车运行所产生的安全隐患问题引发了更多的关注。由于利用传感器所采集到的高速列车监测数据具有非线性、非平稳的特点,导致故障工况难以识别,为此提出一种基于加权非负矩阵的多视图聚类集成模型(weighted non-negative matrix factorization, WNMF)来对车体走行部的故障工况进行识别。首先,对振动信号进行频域、时频域、时域的分析,通过快速傅里叶变换、小波包能量、经验模态分解的近似熵和模糊熵、机械统计特征四个方面提取特征向量,构建四个特征视图;其次进行K-means聚类,得到每个视图的结果;再通过聚类成员的贡献度和相似度分别求取各视图的两种权值;最后进行加权的非负矩阵分解集成。实验结果表明,该模型能够有效地识别高速列车的故障工况。

关键词:高速列车;工况识别;多视图;聚类集成;特征提取

中图分类号: TP181 **文献标识码:** A doi: 10.3969/j.issn.0253-2778.2018.01.005

引用格式: 饶齐,杨燕,滕飞. 基于多视图加权聚类集成的高速列车工况识别[J]. 中国科学技术大学学报,2018,48(1):35-41.

RAO Qi, YANG Yan, TENG Fei. Condition recognition of high-speed train based on multi-view weighted clustering ensemble[J]. Journal of University of Science and Technology of China, 2018, 48(1):35-41.

Condition recognition of high-speed train based on multi-view weighted clustering ensemble

RAO Qi, YANG Yan*, TENG Fei

(School of Information Science and Technology, Southwest Jiaotong University, Chengdu 611756, China)

Abstract: With the rapid development of China's high-speed train industry, some safety problems arising from the high-speed train operation are attracting more attention. Since the monitoring signals of the high-speed trains collected by sensors are nonlinear and non-stationary, it is difficult to identify the fault conditions of high-speed train. Therefore, in this paper, a multi-view clustering ensemble model based on weighted non-negative matrix factorization (WNMF) is proposed to it. Firstly, the vibration signals are analyzed the frequency domain, time-frequency domain and time domain. And the multi-views are obtained by extracting the eigenvector from the four aspects of the vibration signal, which are fast Fourier transform, wavelet packet energy, approximate entropy and fuzzy entropy of empirical mode decomposition, and the mechanical statistical characteristics. And then the clustering result of each view is obtained by the K-means. Secondly, two kinds of weight of the views are generated respectively by the

收稿日期: 2017-05-29; 修回日期: 2017-06-22

基金项目: 国家自然科学基金项目(61572407, 61134002), 国家科技支撑计划课题(2015BAH19F02)资助。

作者简介: 饶齐,男,1992年生,硕士生,研究方向:数据挖掘。E-mail:rich7777@126.com

通讯作者: 杨燕,博士/教授,E-mail:yyang@swjtu.edu.cn

contribution and the similarity of the clustering partitions. Finally, the output results of multiple clustering and the weights are combined for WNMF to ensemble. The experimental results show that the model can better identify fault conditions of high-speed trains.

Key words: high-speed train; condition recognition; multi-view; clustering ensemble; feature extraction

0 引言

2009 年 12 月,原铁道部和科技部签署计划,共同研发的新一代高速列车京广高铁武广段成功试运行,自此中国高速列车行业不断地刷新轨道交通的新纪录,但随之而来的列车安全性也面临前所未有的挑战.因为高速列车在长时运行的状态下,它的某些部件就会出现性能衰退或者损坏.如空气弹簧失气、横向减振器失效、抗蛇形减振器发生故障等^[1].利用一些机器学习的手段,对这些高速列车的典型故障工况进行有效识别,成为目前保障中国高速列车行车安全、减少隐患的重要方法.

目前对列车的监测数据处理方法主要采用频域、时频域、时域的特征提取.频域分析则通常采用傅立叶变换方法提取信号的频率特征,挖掘隐藏在时域中的特征信息.时频域分析方法则兼顾信号的时域和频域特征,可以有效分析复杂非平稳信号.常用的时频域分析方法有:经验模态分解(empirical mode decomposition, EMD)^[2]、短时傅立叶变换(short time fourier transform, STFT)^[3]等.时域分析通过提取振动信号的均方幅值、峰值、峭度等统计参数来获取信号的特征信息.赵晶晶等提出了一种基于 EMD 和模糊熵结合的特征提取方法,使用 BP 神经网络对高速列车进行故障识别^[4].刘林艳等对振动信号进行小波包分解,并计算重构频带信号后能量较大的小波包能量矩特征,将不同频带信号的小波包能量矩组成特征向量,最后用支持向量机进行故障识别^[5].

由于高速列车的振动信号比较复杂,而多视图学习能在学习过程中考虑到不同视图之间的交互作用,所以本文引入多视图学习的思想.根据学习任务的不同,多视图学习^[6]方法主要分为:多视图分类、多视图聚类、多视图特征选择三部分.

由于普通的单个聚类方法有一定的限制性和不稳定性^[7],而聚类集成(cluster ensembles)^[8]可以集成多种基聚类算法的优势.依聚类集成的过程,大致可以分为两个部分:生成聚类成员和构成一致性函数阶段.2009 年 Derek 等采用了 NMF 来做多视

图的聚类集成,并将此应用于文本聚类,取得了很好的效果^[9].

为了克服传统故障诊断方法计算量大、需要大量先验知识的缺陷,同时能集成不同视图的有效信息,对高速列车的典型工况进行有效识别,本文结合多视图与聚类集成,提出一种基于加权非负矩阵分解的多视图聚类集成模型,将此应用于高速列车走行部的故障工况识别中.其中采用两种方法计算视图的权值作为加权非负矩阵分解的权重矩阵输入.

1 高速列车工况识别模型

本文设计了一种多视图聚类集成模型(WNMF)来识别高速列车故障工况,如图 1 所示.

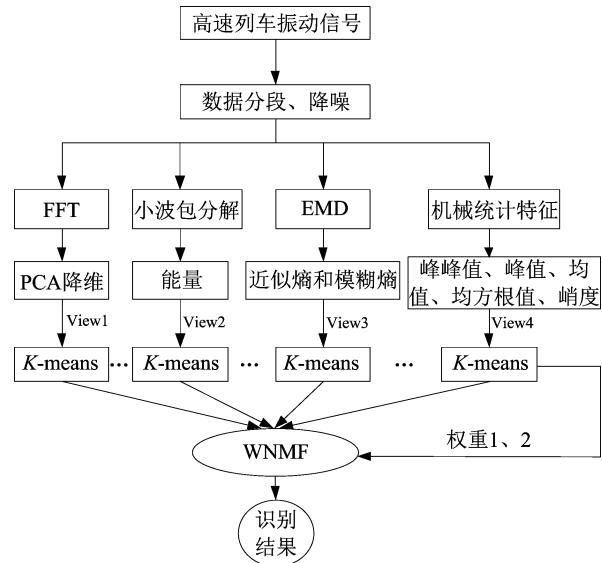


图 1 工况识别模型

Fig.1 A model for the condition recognition

其具体步骤如下:

(I) 数据预处理. 将原始的高速列车振动信号统一进行分段降噪处理, 280 个采样点为一个样本, 每种工况 52 个样本.

(II) 特征提取. 通过 FFT 得到相关系数, 采用 PCA 降维得到 View1 的特征向量; 采用小波包变换, 求取节点系数能量得到 View2 的特征向量; 采用 EMD 分解信号, 求其近似熵和模糊熵共同构成 View3 的特征向量; 最后提取信号的机械统计特征

参数来构造 View4 的特征向量。

(Ⅲ)对每个视图进行 K -means 聚类。 K -means 也叫快速聚类,能在最小化误差函数的基础上将数据划分为预定的类型数,原理简单,容易实现,运行速度快并且聚类结果稳定^[7].

(Ⅳ)通过聚类成员的贡献度和相似度求取视图的两种权值。

(Ⅴ)将聚类结果和权值矩阵输入 WNMF 集成,得到最终的高速列车工况识别结果。

2 视图的建立

从学习任务角度来看,本文的多视图构建主要采用特征提取的方法。特征提取是故障诊断的重要手段,通过特征提取能够降低数据维度,提高工况识别效率。由于快速傅里叶变换能够将信号从时域转变为频域^[3],小波包分解可以对信号进行多分辨分析^[10],经验模态分解得到的近似熵和模糊熵可以构成多尺度复杂性度量的特征向量^[4],机械统计特征的提取有速度快、操作简单等优点^[11],所以本文采用 4 种特征提取方法。

2.1 快速傅里叶变换

快速傅里叶变换 (fast fourier transform, FFT) 是信号处理和数据分析领域最重要的算法之一^[3]。它本身就是离散傅里叶变换(discrete fourier transform, DFT)的快速算法,DFT 的定义为

$$X(k) = \sum_{n=0}^{N-1} x(n)W_N^{kn}R_N(k) \quad (1)$$

计算过程需要在 W_N^{kn} 的基础上进行 N 次复数乘法和 $N - 1$ 次复数加法,FFT 的基本思想是将 DFT 分解为若干个小组合,从而减少运算量,这使得算法复杂度由原来的 $O(N^2)$ 变为 $O(N \log N)$ 。

传感器采集的高铁振动数据是一些时间离散序列,通过 FFT 以后,便于分析信号不同频率分量的特征。为了提升诊断的准确率,还采用了主成分分析对 FFT 后的数据进行适当的降维处理。

2.2 小波包能量

小波变换是一种时频域局部变化的方法,在低频部分具有时间分辨率低和频率分辨率高的特点,由于对信号有较好的自适应性,因此被广泛用于信号处理中^[10]。而小波包是为了克服小波分解在高频段的频率分辨率较差提出的。

通过求取小波包能量作为 View2 的特征输入,其过程如下:

(Ⅰ)将信号进行 N 层小波包分解,给定一个 Shannon 标准计算最佳树,得到从低频到高频的节点系数。

(Ⅱ)根据分解后的第 1 ~ N 层低频节点系数和从 E 层的高频节点系数进行重构,得到不同频段信号向量。

(Ⅲ)对计算各频段内的信号能量如下:

$$E_i = \int_{-\infty}^{\infty} |f(t)|^2 dt \quad (2)$$

归一化各频带信号能量得到小波能量的特征向量 X 。

$$X = [E_1, E_2, \dots, E_n] / \sum_{i=1}^n E_i \quad (3)$$

2.3 经验模态分解部分熵

EMD 方法可以将一系列复杂信号分解成一些简单的内禀模态函数 (intrinsic mode function, IMF),EMD 的实质就是将复杂信号自适应分解为若干个 IMF 的和^[4]。信息熵 (information entropy) 是用来衡量一个随机变量出现的期望值,它可以用来度量信息源所蕴含的平均信息量以及信号输出信息的不确定性和时间发生的随机性。

近似熵 (approximate entropy) 是一种线性指标,通常用来衡量时间序列复杂度,它具有较高的抗噪性和抗干扰能力。相较于近似熵,模糊熵 (fuzzy entropy) 则是通过指数函数来定义相似性的一种熵特征,它可以将相似性度量公式模糊化。

2.4 机械统计特征

由于振动信号在时域中也具有一些特征参数,如均方幅值、频率方差、偏斜度、峭度、峰峰值、波形指标、峰值指标、脉冲指标、裕度指标等。本文通过经验选取峰峰值、峰值、均值、均方根值、峭度这 5 个特征构成 View4 的特征向量。

3 加权的非负矩阵分解集成

传统的非负矩阵分解集成,其结果不会出现负数,具有很好的可解释性和物理意义^[12-13]。由于普通的 NMF 集成受每个视图结果影响较大,所以考虑加入视图的权重来获得更稳定的结果,改进为基于加权非负矩阵分解的多视图聚类集成。

设多视图 $\{V_1, V_2, \dots, V_k\}$ 的一组聚类结果为 $\{C_1, C_2, \dots, C_k\}$, 第 i 个视图 V_i 的聚类结果为 $\{C_1^i, C_2^i, \dots, C_n^i\}$, 其中 k 为视图数, n 为样本数。第一种求取多视图权值的方法如下:

(I) 将多视图的聚类结果表示成一个非负的邻接矩阵 $\mathbf{X}_{m \times n}$, 则可以找到两个非负矩阵 \mathbf{U} 和 \mathbf{V} , 使得

$$\mathbf{X} \approx \mathbf{U} \times \mathbf{V}^T \quad (4)$$

(II) 其基于欧氏距离的目标函数定义为

$$\|\mathbf{X} - \mathbf{UV}^T\|^2 = \sum_{ij} (\mathbf{X}_{ij} - (\mathbf{UV}^T)_{ij})^2 \quad (5)$$

(III) 通过乘法更新规则, 不断迭代, 可求得基矩阵 \mathbf{U} 和系数矩阵 \mathbf{V} .

$$\mathbf{V}_{ij} \leftarrow \mathbf{V}_{ij} \frac{(\mathbf{X}^T \mathbf{U})_{ij}}{(\mathbf{V} \mathbf{U}^T \mathbf{U})_{ij}} \quad (6)$$

$$\mathbf{U}_{ij} \leftarrow \mathbf{U}_{ij} \frac{(\mathbf{X} \mathbf{V})_{ij}}{(\mathbf{U} \mathbf{V}^T \mathbf{V})_{ij}} \quad (7)$$

(IV) 基于基矩阵的值, 可以计算视图的贡献度, 即为视图的权值 w .

$$w_{hf} = \frac{\sum_{f \in C_i} c_f^i}{\sum_{g=1}^l \mathbf{U}_{gf}} \quad (8)$$

式中, w_{hf} 为视图 \mathbf{V}_h 的权重, c_f^i 为分解维度.

(V) 通过对 w 向量进行归一化和对角化, 得到一个 $k \times k$ 的对角矩阵 \mathbf{W} , 其中对角线上的元素集合即为 $\{w_1, w_2, \dots, w_k\}$.

第二种计算权值的方法如下:

(I) 对于 k 个视图 \mathbf{V} 的聚类结果 $\{C_1, C_2, \dots, C_k\}$, 可以计算它的关系矩阵 $\{P_1, P_2, \dots, P_k\}$.

$$P_i(a, b) = \begin{cases} 1, & \text{if } P_i(a) = P_i(b) (1 \leqslant a, b \leqslant n) \\ 0, & \text{otherwise} \end{cases} \quad (9)$$

(II) 初始化聚类集成的结果也可以得到一个关系矩阵为 \mathbf{P}^* .

(III) 对于任意的视图, 可以通过计算对应关系矩阵的欧氏距离 $\text{dist}(\mathbf{P}_i, \mathbf{P}^*)$, 来获得权值 w .

$$w_i = \frac{\text{dist}(\mathbf{P}_i, \mathbf{P}^*)}{k} = \frac{\sqrt{\sum_{i=1}^k |\mathbf{P}_i - \mathbf{P}^*|^2}}{k} \quad (10)$$

(IV) 通过对 w 向量进行归一化和对角化, 也得到了一个 $k \times k$ 的对角矩阵 $\mathbf{W} = \{w_1, w_2, \dots, w_k\}$, 其中对角线上的元素集合即为权值向量.

当完成基聚类结果的权值求取以后, 则可以进入聚类集成的一致性函数阶段, 第一种加权集成算法简称 WNMF1、第二种加权集成算法简称 WNMF2, 二者主要区别仅 \mathbf{W} 矩阵的值不同, 具体流

程如下:

(I) 如上所述视图的权重矩阵为 $\mathbf{W} = \{w_1, w_2, \dots, w_k\}$.

(II) 目标函数变成

$$\min \|\mathbf{X} - \mathbf{UV}^T\|^2 * \mathbf{W}_{ii} = \min \sum_{ij} (\mathbf{X}_{ij} - (\mathbf{UV}^T)_{ij})^2 * \mathbf{W}_{ii} \quad (11)$$

(III) 输入由多视图的结果所构建的超图邻接矩阵 $\mathbf{X}_{m \times n}$ 和划分数目 K , 并随机初始化矩阵 \mathbf{U} 、 \mathbf{V} ;

(IV) 当固定 \mathbf{U} 时, 计算 \mathbf{V} , 通过迭代规则

$$\mathbf{V}_{ij} \leftarrow \mathbf{V}_{ij} \frac{(\mathbf{X}^T \mathbf{W} \mathbf{U})_{ij}}{(\mathbf{V} \mathbf{U}^T \mathbf{W} \mathbf{U})_{ij}} \quad (12)$$

(V) 当固定 \mathbf{V} 时, 计算 \mathbf{U} , 通过迭代规则

$$\mathbf{U}_{ij} \leftarrow \mathbf{U}_{ij} \frac{(\mathbf{W} \mathbf{X} \mathbf{V})_{ij}}{(\mathbf{W} (\mathbf{U} \mathbf{V}^T) \mathbf{V})_{ij}} \quad (13)$$

(VI) 检查 \mathbf{V} 的每一列 $\mathbf{V}_{:,j}$, 将簇标签 label 指派为该列中最大元素所在的行

$$l_i = \arg \max_i \mathbf{V}_{ij} \quad (14)$$

式中, $1 \leqslant l \leqslant k$;

(VII) 最终识别结果 $l = \{l_1, l_2, \dots, l_k\}$.

WNMF 算法的具体实现过程如算法 3.1 所示.

算法 3.1 weighted non-negative matrix factorization

输入: 聚类结果的超图邻接矩阵 \mathbf{X} , 权重矩阵 \mathbf{W} , 簇个数 K

输出: 数据对象标签 l

(1) 初始化 \mathbf{U} 和 \mathbf{V}

(2) 输入 \mathbf{X}, \mathbf{W} 和 K

(3) Repeat

(4) 根据公式(12)求 \mathbf{V} ;

(5) 根据公式(13)求 \mathbf{U} ;

(6) Until 目标函数收敛;

(7) 根据公式(14)求 l .

End

4 实验与结果

4.1 实验数据

高速列车车体有两个转向架, 每个转向架包括空气弹簧, 横向减振器, 抗蛇形减振器等部件, 本文使用的数据为某重点实验室中利用传感器采集的实验室数据. 传感器采样频率为 243 Hz.

4.2 数据集划分

实验室数据为列车按 120、140、160、200、220 km/h 速度递增的情况下, 4 种工况组成分别为正常工况、空气弹簧失气、横向减振器失效和抗蛇形减振

器故障.图2是200 km/h下,4种工况的时域图,图3为对应的频域图.

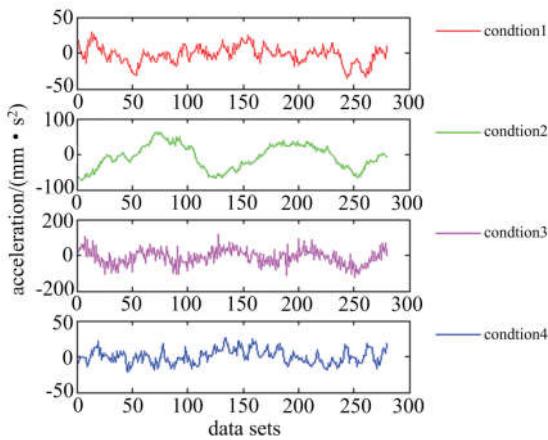


图2 200 km/h 实验室数据时域图

Fig.2 Time domain of laboratory at the speed of 200 km/h

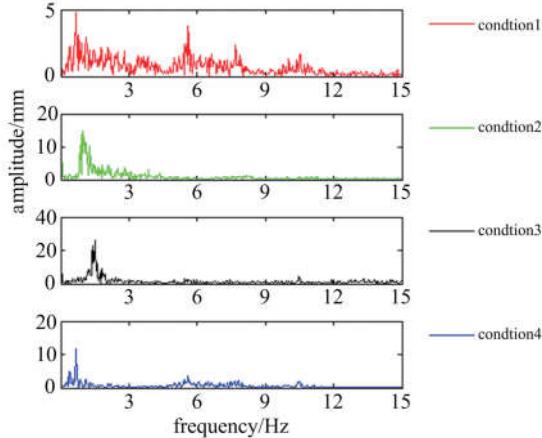


图3 200 km/h 实验室数据频谱特征

Fig.3 Spectral feature of laboratory at the speed of 200 km/h

4.3 收敛证明

WNMF 算法基于乘法更新规则以达到目标函数最小化,通过验证目标函数的收敛性可以选出适合的初始化迭代参数,使 WNMF 分解的误差趋于平稳,减小对最终集成结果的影响.图4所示为实验室数据集在不同迭代次数试验下的目标函数误差值.由图4可见,共识函数在迭代30次以内就能迅速收敛,50次以后就开始趋于稳定,所以选择初始化的迭代参数为50~100之间的值较为合理.

4.4 评价标准

聚类分析是以相似度为基础,根据数据样本自身来进行分组.其目标是使簇内的对象更相似,不同簇间的对象更相离.类内距离越小,类间距离越大,效果就越好^[14].本文采用 normalized mutual information(NMI) 标准和 F-measure 评价法来

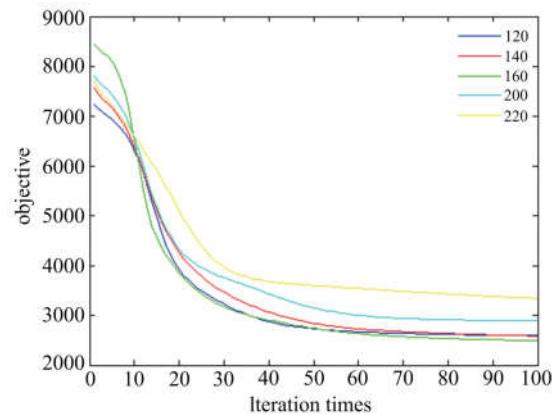


图4 不同迭代次数下的目标函数误差

Fig.4 Objective function errors of different iteration times
评价.

NMI 值越接近 1 表示划分越准确,计算公式如下:

$$NMI(A, B) = \frac{2 * I(A, B)}{(H(A) + H(B))} \quad (15)$$

式中, $I(A, B)$ 是 mutual information, $H(A)$ 和 $H(B)$ 是信息熵.

F -measure 是 Precision 和 Recall 加权调和平均,值越接近 1 表示该方法越有效.计算公式如下:

$$F_a = \frac{(1 + \alpha^2)pr}{\alpha^2 p + r} \quad (16)$$

式中, $p = \frac{R}{R + M}$, $r = \frac{R}{R + D}$. R 指被正确聚类的数目, M 表示不应该在一个簇的对象被错误地放在一起, D 表示不应该分开的对象错误地被分开.

4.5 实验结果

表1、2 为实验室数据经过模型识别后不同视图的 NMI 值和 F -measure 值,其中还画出了 200 km/h 速度下部件全拆各视图聚类 10 次的 NMI 曲线,如图5 所示.表3、4 为实验室数据下几种不同的多视图聚类算法和 WNMF 的结果对比,其中 RMKMC 是一种对视图加权的鲁棒性多视图 K-means 算法^[15];KASC 是一种基于核矩阵的谱聚类算法^[16];CRMS 算法是共正则化的谱聚类算法,它把多视角之间的约束当作每一个视角的正则化约束^[17];RMSC 算法是一种基于矩阵低秩分解和稀疏分解的多视图子空间聚类算法^[18].由表1~4 和图5 可以看出:

(I) NMF 集成相对于单个视图的基聚类结果有一定的提升,每组工况 NMI 和 F -measure 最高值都为加权集成算法 WNMF1 和 WNMF2,这得益于

于不同的视图所赋予的权值不同,使得最终的聚类结果更为准确,但是 View4 的 NMI 值偏低的情况下,NMF 的值也随之下降,如表 2 中所示.反观两个加权集成的 NMI 值则影响较小.在同等情况下,两种 WNMF 的结果也比几种多视图聚类算法的结果更加稳定.

(Ⅱ)由图 5 中所画出的 200 km/h 速度下,部件全拆的各视图聚类 10 次的 NMI 曲线可以观察到,3 种集成的结果均明显好于单个聚类结果.某一次 NMF 也会出现比 WNMF 更高的情况,这可能是受一些初始化参数的影响而存在一定的偶然性,但是两种 WNMF 的多次结果都基本稳定在 0.9 以上.

(Ⅲ)不同视图下,工况的聚类结果是不同的,整体来说 View1 的频域聚类结果和 View2、View3 的时频域聚类结果要明显好于 View4 的时域聚类结

果,这和高速列车信号在时域环境下复杂的信号成分有关.

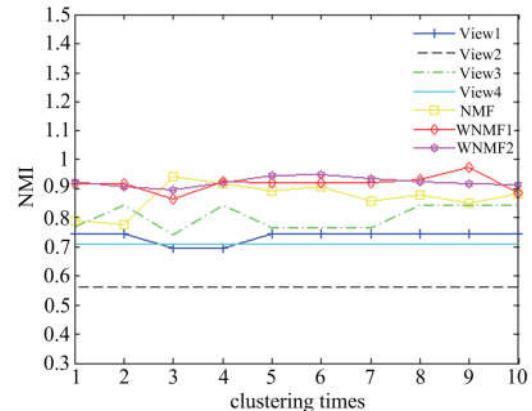


图 5 200 km/h 速度下各视图聚类 10 次的 NMI 曲线

Fig.5 NMI of every views at the different speed

表 1 不同速度下的各视图的 NMI 值

Tab.1 NMI of every views at the different speed

Speed	View1	View2	View3	View4	NMF	WNMF1	WNMF2
120 km/h	0.866 0	0.711 2	0.762 5	0.629 8	0.898 7	0.909 4	0.933 3
140 km/h	0.793 7	0.685 2	0.808 2	0.643 3	0.892 1	0.922 2	0.932 4
160 km/h	0.826 0	0.668 6	0.736 8	0.762 5	0.884 7	0.929 4	0.903 9
200 km/h	0.732 7	0.559 7	0.801 1	0.709 8	0.868 6	0.916 8	0.921 5
220 km/h	0.855 5	0.639 2	0.679 6	0.652 5	0.865 6	0.895 7	0.915 7

表 2 不同速度下的各视图的 F-measure 值

Tab.2 F-measure of every views at the different speed

Speed	View1	View2	View3	View4	NMF	WNMF1	WNMF2
120 km/h	0.824 5	0.739 3	0.758 6	0.708 4	0.893 3	0.955 9	0.958 8
140 km/h	0.801 7	0.791 9	0.813 7	0.779 9	0.881 0	0.959 7	0.967 6
160 km/h	0.825 7	0.718 6	0.799 3	0.805 5	0.900 8	0.904 9	0.915 1
200 km/h	0.784 7	0.630 1	0.800 1	0.746 0	0.879 2	0.904 7	0.946 3
220 km/h	0.815 7	0.682 1	0.842 9	0.731 6	0.905 2	0.946 2	0.914 7

表 3 不同速度下的多视图算法的 NMI 值

Tab.3 NMI of multi-view algorithms at the different speed

Speed	RMKMC	KASC	CRMS	RMSC	NMF	WNMF1	WNMF2
120 km/h	0.716 6	0.806 5	0.871 6	0.785 4	0.898 7	0.909 4	0.933 3
140 km/h	0.701 2	0.866 4	0.927 8	0.828 7	0.892 1	0.922 2	0.932 4
160 km/h	0.667 1	0.820 1	0.887 3	0.818 1	0.884 7	0.929 4	0.903 9
200 km/h	0.549 2	0.883 4	0.938 9	0.744 8	0.868 6	0.916 8	0.921 5
220 km/h	0.486 6	0.918 5	0.932 2	0.745 3	0.865 6	0.895 7	0.915 7

表4 不同速度下的多视图算法的F-measure值

Tab.4 F-measure of multi-view algorithms at the different speed

Speed	RMKMC	KASC	CRMS	RMSC	NMF	WNMF1	WNMF2
120 km/h	0.690 2	0.771 6	0.849 0	0.759 8	0.893 3	0.955 9	0.958 8
140 km/h	0.679 3	0.832 1	0.939 8	0.837 9	0.881 0	0.959 7	0.967 6
160 km/h	0.648 3	0.787 8	0.890 9	0.804 1	0.900 8	0.904 9	0.915 1
200 km/h	0.605 4	0.892 4	0.944 5	0.730 4	0.879 2	0.904 7	0.946 3
220 km/h	0.576 1	0.892 8	0.960 7	0.734 9	0.905 2	0.946 2	0.914 7

5 结论

本文提出了一种基于多视图的加权非负矩阵分解集成的方法,将此模型应用于高速列车走形部的工况识别,并且通过不同速度不同种类的数据集进行验证,最终结果表明,该方法具有一定的效果改善。由于在构造多视图的过程中所采用的特征提取的角度和方法不同,对于单个聚类结果都有很大的差异,所以后期的工作我们可以继续在这方面做改进,找到一些能更好体现高速列车振动信号的特征视图,让最终的识别结果更加准确。

参考文献(References)

- [1] GUO C, YANG Y, PAN H, et al. Fault analysis of high speed train with DBN hierarchical ensembles [C]// Proceedings of the International Joint Conference on Neural Networks. Vancouver: IEEE Press, 2016: 2552-2559.
- [2] HUANG N E, SHEN Z, LONG S R, et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis[C]// Proceedings of the Royal Society of London A: Mathematical, Physical and Engineering Sciences. London: The Royal Society, 1998, 454(1971): 903-995.
- [3] 李智敏,苟先太,秦娜,等.高速列车振动监测信号的频率特征[J].仪表技术与传感器,2015,(5): 99-103.
- [4] ZHAO J, YANG Y, LI T, et al. Application of Empirical Mode Decomposition and Fuzzy Entropy to High-Speed Rail Fault Diagnosis[M]. Foundations of Intelligent Systems. Springer Berlin Heidelberg, 2014: 93-103.
- [5] 刘林艳,金炜东,余志斌.基于小波分析的高速列车车体运行状态估计[J].计算机应用研究,2013, 30(10): 2948-2950.
- [6] XU C, TAO D, XU C. A survey on multi-view learning [EB/OL]. [2017-05-10] <https://arxiv.org/pdf/1304.5634v1.pdf>.
- [7] ROKACH L. A survey of clustering algorithms[J]. Data Mining and Knowledge Discovery Handbook, 2009, 16(3): 269-298.
- [8] STREHL A, GHOSH J. Cluster ensembles: A knowledge reuse framework for combining partitionings[C]// Proceedings of the 8th National Conference on Artificial Intelligence. Edmonton, Canada: ACM Press, 2002: 93-99.
- [9] GREENE D, CUNNINGHAM P. A matrix factorization approach for integrating multiple data views[C]// Joint European Conference on Machine Learning and Knowledge Discovery in Databases. Springer, 2009: 423-438.
- [10] 黄采伦,樊晓平,陈春阳,等.基于小波系数据提取及离散余弦包络分析的机车牵引齿轮故障诊断方法[J].铁道学报,2008, 30(2): 98-102.
- [11] 张乾.基于振动信号的轴承状态监测和故障诊断方法研究[D].长沙:中南大学,2012.
- [12] SRA S, DHILLON I S. Nonnegative matrix approximation: Algorithms and applications[EB/OL]. [2017-04-28] <http://www.cs.utexas.edu/ftp/techreports/tr06-27.pdf>.
- [13] 李乐,章毓晋.非负矩阵分解算法综述[J].电子学报,2008, 36(4): 737-743.
- [14] 杨燕,靳蕃,KAMEL M.聚类有效性评价综述[J].计算机应用研究,2008, 25(6): 1630-1632.
- [15] CAI X, NIE F, HUANG H. Multi-view k -means clustering on big data[C]// Proceedings of the 23th International Joint Conference on Artificial Intelligence. Beijing: IEEE Press2013: 2598-2604.
- [16] XIA R, PAN Y, DU L, et al. Robust multi-view spectral clustering via low-rank and sparse decomposition[C]// Proceedings of the 28th AAAI Conference on Artificial Intelligence. Québec, Canada: ACM Press, 2014: 2149-2155.
- [17] KUMAR A, RAI P, DAUMÉ H. Co-regularized multi-view spectral clustering[C]// Proceedings of the 24th International Conference on Neural Information Processing Systems. Granada, Spain: ACM Press, 2011: 1413-1421.