

# 基于半监督过采样非平衡学习的矿山微震信号识别

程 健<sup>1</sup>, 杨凌凯<sup>1</sup>, 王全魁<sup>2</sup>, 崔 宁<sup>1</sup>, 郭一楠<sup>1</sup>

(1. 中国矿业大学 信息与控制工程学院, 江苏 徐州 221116; 2. 华润电力控股有限公司 华东大区运营部, 山东 济南 250002)

**摘要:**为准确实现冲击矿压灾害的预防预警, 提出一种半监督过采样框架对煤矿微震数据进行模式识别, 采用主成分分析、小波变换和 Fisher 判别对微震数据集样本的多个信号通道进行特征提取; 并对提取到的特征数据进行半监督非平衡学习; 最后训练分类器进行模式识别。通过在兖矿集团微震数据集进行试验, 结果表明: 针对微震数据的半监督过采样框架可以有效提高微震数据的识别准确率。与只进行过采样的方法相比, 使用 CPLE 和 SELF 两种半监督学习的方法, 在 KNN、LR、FLD、RF、SVM 和 Adaboost 这 6 个分类器上有 5 个分类器上识别效果更好, 可以获得更好的回归率和 F1 的指标。此方法可以获得高维微震数据的压缩表达, 解决不平衡微震数据集的识别问题。

**关键词:**非平衡学习; 半监督学习; 模式识别; 矿山微震

中图分类号: TD67

文献标志码: A

文章编号: 0253-2336(2018)02-0213-06

## Mine microseismic signal recognition based on semi-supervised over-sampling imbalanced learning

CHENG Jian<sup>1</sup>, YANG Lingkai<sup>1</sup>, WANG Quankui<sup>2</sup>, CUI Ning<sup>1</sup>, GUO Yinan<sup>1</sup>

(1. School of Information and Control Engineering, China University of Mining and Technology, Xuzhou 221116, China

2. East China Region Operation Department, China Resources Power Holdings Company Limited, Jinan 250002, China)

**Abstract:** In order to improve the recognition accuracy of rock burst disaster, a semi-supervised over-sampling framework is proposed to recognize the microseismic signal. Principal component analysis (PCA), Wavelet transform and Fisher linear discriminant (FLD) are used to extract features of the multi-channel data set. Then, over-sampling method and semi-supervised learning method are used to construct a balanced data set based on the features. Furthermore, six classifiers are trained based on the balanced microseismic data set, and the original data set is from Yancon Group Company. Experimental results show that the semi-supervised over-sampling framework is actually able to improve the classification accuracy. Compared with the method which only uses over-sampling algorithm, the semi-supervised over-sampling framework can obtain higher values of recall and F1 score on 5 classifiers, with CPLE or SELF as the semi-supervised method. The six classifiers are KNN, LR, FLD, RF, SVM and Adaboost. Overall, this framework not only extracts the compressed representation of the high-dimensional data set, but also deals with the microseismic signal recognition problem based on a balanced data set.

**Key words:** imbalanced learning; semi-supervised learning; pattern recognition; mine microseismic

## 0 引 言

冲击矿压是一种典型的煤矿动力灾害, 严重威胁煤矿的高效生产和人员安全, 因此冲击矿压灾害的预防与预警至关重要<sup>[1]</sup>。冲击矿压指在高应力作用下, 聚集的能量突然释放, 造成煤岩体的冲击,

导致人员伤亡, 建筑物破坏的现象。而微震是采矿活动引起的诱发地震, 是煤岩介质在矿区应力作用下, 聚集的弹性应变能释放, 造成采掘空间周围岩体破裂的现象。因此, 通过监测煤矿微震来进行冲击矿压的预防预警是一种有效的手段<sup>[2]</sup>。微震监测的主要技术包括: 台网优化布置, 微震信号识别, 微

收稿日期: 2017-11-21; 责任编辑: 赵 瑞 DOI: 10.13199/j.cnki.cst.2018.02.031

基金项目: 国家重点研发计划资助项目(2016YFC0801406); 国家自然科学基金资助项目(61573361)

作者简介: 程 健(1974—), 男, 四川平昌人, 副教授, 博士。E-mail: chengjian@cumt.edu.cn

引用格式: 程 健, 杨凌凯, 王全魁, 等. 基于半监督过采样非平衡学习的矿山微震信号识别[J]. 煤炭科学技术, 2018, 46(2): 213-218, 202.

CHENG Jian, YANG Lingkai, WANG Quankui, et al. Mine microseismic signal recognition based on semi-supervised over-sampling imbalanced learning[J]. Coal Science and Technology, 2018, 46(2): 213-218, 202.

震源定位,震源机制分析和微震活动预测等。其中微震信号识别是数据处理的基础,目前已有许多微震监测系统配置有微震信号识别功能,如澳大利亚的IMS、加拿大的ESG和波兰的SOS微震监测系统<sup>[3]</sup>。然而煤矿微震信号受背景噪声、机械振动等因素干扰,信号非常复杂,上述系统自动识别效果不能得到很好的保证。鉴于此,目前主要采用人工识别微震信号的方法,但人工识别的方式效率较低且由于操作人员的知识经验等问题,容易出现误处理和来不及等情况<sup>[4]</sup>。在煤矿开采过程中,冲击矿压危害巨大但很少发生,所以采集到的数据集是非平衡的。这种非平衡给机器学习来做识别的方法增加了困难。

为了解决非平衡情况下,矿山微震数据的识别问题,笔者对微震数据的特征提取做了相关研究,并提出一种针对微震数据集的半监督过采样框架,来提高非平衡微震数据集的微震信号识别准确率。使用本方法可以获得高维微震信号的低维压缩表达,避免“维度灾难”,提高微震数据不足情况下的识别准确率。

## 1 现有微震信号识别方法

目前,煤矿微震信号识别的方法主要有时频分析和机器学习方法。时频分析能有效分析微震波形频谱特征,常用方法包括傅里叶变换、小波变换、小波包变换和频率切片小波变换等<sup>[5]</sup>。曹安业等<sup>[6]</sup>利用傅里叶变换得到了矿山信号的幅频特征,为煤矿微震信号的辨识提供了依据。唐守锋等<sup>[7]</sup>分析了微震信号与噪声信号的能量分布特征,采用小波能谱系数的方法提取微震信号的特征。赵国彦等<sup>[8]</sup>采用频率切片小波变换识别煤矿微震信号。

时频域分析方法虽然可以有效分析煤矿微震信号频谱的特性,但是每个传感器产生的数据量很大,所以现场实时应用有不小的难度。因此结合机器学习方法来处理大量的数据问题会是一个很好地解决微震数据分析的方法。朱权洁等<sup>[9]</sup>将小波包与分形理论相结合提取微震信号特征,并采用SVM对特征向量进行分类。Vallejos等<sup>[10]</sup>应用逻辑回归和神经网络对矿震信号和爆炸信号进行了分类。Dong<sup>[11]</sup>使用Fisher分类器、朴素贝叶斯分类器和逻辑回归分析矿山地震和爆炸事件。

通过机器学习的方式对微震数据集建模,可以在时频特征的基础上提高识别的效果。但微震数据

与无微震数据相比一般较少,尤其是冲击矿压的真实数据更是极其罕见,因此微震数据集存在着天然的非平衡特性,如果不考虑数据集的非平衡特性直接建模,可能会影响机器学习算法的识别效果。

## 2 微震信号识别半监督过采样框架

笔者提出一种基于半监督过采样方法的矿山微震信号识别框架。采用主成分分析(PCA)、小波变换和Fisher线性判别(FLD)来提取多通道微震数据集的时频域特征。之后使用过采样的方法来解决微震数据集存在的非平衡问题,并使用半监督的方式解决线性采样存在的采样数据类别标注不准确的问题。

本文的数据是通过波兰的SOS微震监测系统采集的。每一个数据由井下20个传感器采集得到,采样周期4h。单通道传感器包含10240个采样点。因为20个通道的采集数据存在着强相关性,并且多传感器采集难免会受到噪声的干扰。所以主成分分析、小波变换和Fisher线性判别3种方法被用来做数据的特征提取。笔者提出的微震信号识别的半监督过采样框架(Semi-supervised over-sampling framework, SSOSF)流程如图1所示。




图1 半监督过采样框架

Fig. 1 Semi-supervised over-sampling framework

### 2.1 特征提取

对数据集进行特征提取可以获得更好的数据表达,降低数据的维数,解决工业数据集常见的“维数灾难”问题,得到更好更快的模式识别效果<sup>[12]</sup>。

将观测空间数据集记为 $O$ ,样本数记为 $t$ 。 $O_i$ 为数据集 $O$ 中的第 $i$ 个样本, $i=1,2,\dots,t$ 。无微震数据为大类样本,记为 $m_1$ ;微震数据为小类样本,记为 $m_2$ 。每个样本包含 $n$ 个通道数据,每个通道有 $m$ 个采样点。即观测空间 $O$ 的数据规模为 $t \times m \times n$ 。

1) 主成分分析。主成分分析(Principal Component Analysis, PCA)<sup>[13]</sup>是一种常用于特征提取的多元统计分析方法,它可以从多维数据中提取出主要成分,从而简化复杂的问题。PCA将原始高

维数据投影到低维特征空间,并保持原有数据集信息丢失最小。

对数据集  $O$  中的每个样本单独执行 PCA 操作,将  $n$  个通道数据降为  $l$  维。所以在 PCA 特征提取之后,数据集  $O$  的数据规模变为  $t \times m \times l$ ,此时的数据集记为  $P$ 。

2)小波变换。小波变换(Wavelet Transform)继承和发展了傅里叶变换局部化的思想,同时又克服了傅里叶变换窗口大小不随频率变化的缺点,是进行信号时频分析和处理的理想工具<sup>[14]</sup>。小波变换的主要特点是:能够充分突出信号某些方面的特征;能对时间(空间)频率进行局部化分析;能通过伸缩平移运算对信号逐步进行多尺度细化,最终达到高频处时间细分,低频处频率细分的目的;能自动适应时频信号分析的要求,从而聚焦到信号的任意细节。

小波变换对数据集  $P$  中的每个样本的每个通道进行操作。记小波变换的分辨率为  $r$ 。对于单个通道的  $m$  个采样点经过小波变换后提取出  $r$  个频段,每个频段  $v$  个数据,  $m = r \times v$ 。因此,小波特征提取之后数据集  $P$  的数据规模变成了  $t \times l \times r \times v$ ,记数据集为  $D$ 。

3)Fisher 线性判别。Fisher 判别(Fisher Linear Discriminant,FLD)<sup>[15]</sup>与 PCA 不同是一种有监督的特征提取方法。FLD 在特征提取过程中,保持类内方差最小,类间距离最大。由于考虑了数据集样本的标签信息,所获得的低维特征通常更有利于后续模式识别的进行。

Fisher 判别是有监督的特征提取方法,因此,对每个通道  $l$ ,每个频段  $r$ ,进行特征提取。即将每个通道每个频段  $t \times v$  的数据提取出最重要的一维数据  $t$ ,此时数据集记为  $Y$ 。

综上,在经过 PCA,小波变换和 Fisher 判别 3 种特征提取方法之后,原本  $t \times m \times n$  的数据被压缩成了  $t \times l \times r$ 。一方面降低了数据体积,避免“维度灾难”。另一方面,一定程度上降低了数据的耦合,去除了一些离散噪声。

## 2.2 过采样

特征提取之后,SMOTE 方法(Synthetic Minority Over-sampling Technique)<sup>[16]</sup>用来对数据集  $Y$  进行过采样。SMOTE 在每个微震样本及其邻近的  $k$  个微震样本间插值,产生新的微震数据。

$$Y_{ij} = Y_i + \lambda(Y_j - Y_i) \quad (j = 1, 2, \dots, k) \quad (1)$$

其中: $Y_{ij}$  为第  $i$  个微震样本  $Y_i$  和其第  $j$  个近邻

的微震样本  $Y_j$  生成的微震数据; $\lambda$  为  $0 \sim 1$  的随机数。

## 2.3 半监督学习

通过 SMOTE 方法,可以获得一个平衡的数据集,但是由于 SMOTE 是一个线性插值的方法,在过采样非线性分布的数据集时,生成的小类样本的准确性难以保证。即非线性分布的工业数据集上,通过 SMOTE 生成的小类样本也许并不满足真实小类的数据特征。因此在过采样之后,使用半监督方法给新生成的数据添加更加准确的标签。使用 Contrastive Pessimistic Likelihood Estimation (CPL)<sup>[17]</sup> 和 Self learning 两种半监督方法<sup>[18]</sup>。

## 2.4 训练分类器

测试了 6 个不同的分类器分类结果,这 6 个分类器分别是  $k$  近邻( $k$  Nearest Neighbors, kNN)<sup>[19]</sup>、逻辑回归(Logistic Regression, LR)<sup>[20]</sup>、线性判别分析(FLD)、随机森林(Random Forest, RF)<sup>[21]</sup>、Linear SVM<sup>[22]</sup> 和 Adaboost<sup>[23]</sup>。

## 3 试验结果分析

首先介绍非平衡数据集常用的评价指标;展示了无微震数据和有微震数据的特征提取结果;最后分析了基于微震信号识别的半监督过采样框架(SSOSF)的效果。

### 3.1 非平衡问题的评价指标


非平衡问题常用的评价指标有总体准确率(OA)、精确率(Precision)、回归率(Recall)和 F1 值<sup>[24]</sup>。

### 3.2 特征提取


1)原始空间数据。为了验证本文方法的可行性,使用兖矿集团的部分微震数据进行试验。该数据集是利用 SOS 微震监测系统采集的,SOS 微震监测系统在矿井下布置了 20 个微震速度传感器(20 个通道),用来采集不同方位地震波通过传感器的速度,传感器采样频率为 500 Hz。此次试验共选取 235 个样本数据,每个样本包含 20 个通道的数据,每个通道采集时间约为 4 h,含有 10 240 个离散点。其中,具有冲击危险的样本数据有 35 个,无危险的样本数据有 200 个。一组无微震信号波形和微震信号波形如图 2 所示。对比图 2a、图 2b 可知,当有微震现象发生时监测到的震动幅度是正常情况下的 10 倍左右。

2)PCA 特征提取。原始数据共有 20 个微震传

传感器信号,如果不对数据加以处理直接使用,会增加计算成本,也会有数据的冗余。因此,使用PCA提取20个通道的主要特征,来提高计算速度并去除冗余。由于PCA是一种有损的信息压缩方法,在特征提取时不可避免地会造成信息丢失。因此对PCA的特征提取维度进行了试验,在保证整体信息基本不丢失的情况下尽可能降低数据维度,试验效果如图3所示。



(a) 无微震信号



(b) 微震信号

图2 原始信号波形

Fig. 2 Original signal




图3 PCA不同维度信息保存率


Fig. 3 Information preservation rate of PCA

统计了PCA将原始数据压缩到1—4维时的原始数据集信息的保存率。通过观察,可以很直观地发现当把数据压缩到1维时,会造成原始数据集信息的大量丢失,信息保存率只有70%左右,当增加保留维度后,信息保存率显著提升。当提取4维数据时,基本可以保留98%左右的原始信息,此时认为特征提取出的数据可以很好地代表总体数据。提取更高维数据时,保存率增加极其缓慢,反而会增加计算成本,所以选择将20个通道的数据压缩至4维。相比20个通道的数据,用4维度的数据不仅可


以简化计算,而且可以更好地表达整体数据特点。

3)小波特征提取。利用小波变换将时间序列排列的数据转换到频率域。因为频域数据能更好地表达微震数据的特征信息。选用尺度为6的小波进行特征分解,对于单一通道数据,经过变换后,原本10 240维度的数据转换成了64行160列的1个矩阵,其中64代表64个子频带,160代表每个频带下的数据点数。经过小波变换,将时序数据转换成了频域数据。

将无微震信号和微震信号进行小波变换的结果如图4、图5所示,包括SOS微震监测系统采集的原始信号和序列为(6,1)的小波信号。比较图4和图5可知,小波变换后,时序数据转变为频域数据,微地震速度波形的低频部分被有效地放大,微地震波中包含的有价值信息也被有效表达出来。



(a) 原始无微震数据



(b) 小波无微震数据

图4 无微震信号小波变换效果

Fig. 4 Wavelet transform effect on non-microseismic signal

4)Fisher特征提取。经过小波特征提取后,现在已经获得了包含微震大部分信息的多维数据集。如果此时对该数据集进行分类识别,由于数据的维度过高,计算起来会显得很复杂;另外,小波变换后的数据也存在特征相对集中在一些子频率带里,而其中有一些子频带对于识别是没有价值的,反而会增加计算量。所以,使用FLD对小波变换后的数据进行特征提取。

FLD可以找到一个最好的投影方向,使样本在这个方向上的投影能最大程度地分开。这样不仅能有效降低数据维数,而且数据在低维按类别最大程度地分开,有利于后续使用合适的分类器对数据进




图5 微震信号小波变换效果

Fig. 5 Wavelet transform effect on microseismic signal

行分类识别。

试验中,将经过小波变换的单一通道数据由 64 行 160 列的矩阵转换为 1 行 64 列的矩阵。至此,通过使用 3 种特征提取方法,将单个原始样本数据结构由 20 行 10 240 列组成的数据转变为 4 行 64 列的数据,数据维度和数据量大幅降低。

综上,在使用 PCA、Wavelet 和 FLD 三种特征提取方法之后,将原始的 20 通道,每个通道 235 个 10 240 维度的数据提取成 4 通道,单通道 235 个 64 维度的数据。这大幅减少了数据量,且获得了原始高维时序数据的低维频率特征表达。之后的试验中,把 4 个通道的数据视为 4 组独立的数据,分别训练 4 个模型,最终 4 个模型投票确定最终的分类结果。只要超过 2 个模型判断是微震数据,这个数据就被标记为微震数据。

### 3.3 半监督过采样框架识别效果

对原始高维时序数据集进行特征提取之后,进行无微震和微震信号的模式识别。因为原始数据集中无微震数据只有 35 个,微震数据 200 个,存在明显的非平衡问题。在这种非平衡情况下,传统的分类算法普遍表现较差,所以,对经过特征提取的数据进行半监督过采样学习,期望获得较好的分类性能。

在特征空间数据集上,随机抽取 180 个无微震的样本和 25 个微震样本组成训练集。剩下的 20 个安全样本和 10 个微震样本组成测试集。

对比了经过 SMOTE 过采样形成的数据集直接分类和经过 CPLE、SELF 半监督重新添加标签后分类的效果,试验了半监督方法的有效性;同时对比了 6 种不同分类器的分类性能。试验结果见表 1。

表 1 半监督过采样框架微震信号模式识别效果

Table 1 Recognition effect of microseismic signal based on semi-supervised over-sampling framework

方法	分类器	总正确率	精确率	回归率	评价指标 F1 值
SMOTE	KNN	0.733 3	1.0	0.2	0.333 3
	LR	0.800 0	1.0	0.4	0.571 4
	FLD	0.866 6	1.0	0.6	0.750 0
	RF	0.833 3	1.0	0.5	0.666 7
	SVM	0.766 6	1.0	0.3	0.461 5
	Adaboost	0.866 6	1.0	0.6	0.750 0
CPLE	KNN	0.766 6	1.0	0.3	0.461 5
	LR	0.833 3	1.0	0.5	0.666 7
	FLD	0.900 0	1.0	0.7	0.823 5
	RF	0.866 6	1.0	0.6	0.750 0
	SVM	0.766 6	1.0	0.3	0.461 5
SELF	Adaboost	0.933 3	1.0	0.8	0.888 9
	KNN	0.800 0	1.0	0.4	0.571 4
	LR	0.866 6	1.0	0.6	0.750 0
	FLD	0.833 3	1.0	0.5	0.666 7
	RF	0.900 0	1.0	0.7	0.823 5
	SVM	0.800 0	1.0	0.4	0.571 4
	Adaboost	0.900 0	1.0	0.7	0.823 5

观察表 1 可知,所有模型预测结果的精确率都是 1,这说明一个数据如果被预测为微震,那么这个数据一定是微震数据。但是回归率不为 1,有些模型的回归率甚至在 0.5 以下,这意味着,对于一个真实的微震数据,有很大的概率会被模型预判成无危险数据,这对煤矿安全是非常危险的。由于精确率相同,因此总正确率和 F1 的值也是由回归率决定的,因此着重分析回归率这一指标。

1) 通过有无半监督方法的对比可以发现,不管是 CPLE 还是 SELF,相比于 SMOTE 直接分类的方法,回归率指标都有较为明显的提升。对于 CPLE,除了 SVM 的效果差于 SMOTE 外,其余的模型准确率均有提升。SELF 方法中,只有 FLD 差于 SMOTE。这表明了半监督方法确实可以通过为过采样数据添加更加准确的标签来提高最终分类器的性能。

2) 通过不同分类器的对比可以发现,基于简单统计规律的 KNN 效果最差;FLD、LR 和 SVM 表现较

好; Adaboost 和随机森林这 2 种集成学习的方法可以取得最好的效果。这可能是因为集成学习的鲁棒性和适应性更好。因此在微震数据监测的半监督过采样框架中使用集成学习作为分类器最为合理。

## 4 结 语

提出一种半监督过采样的框架(SSOSF)来对煤矿微震数据进行模式识别,实现冲击矿压灾害的预防预警。试验结果表明,在对原始数据进行 PCA 特征提取时,提取 4 维特征可以最大程度保留原始数据的信息。利用小波变换对 PCA 提取的低维特征数据进行时频分析,将数据转换到频率域进行分析。使用 FLD 对 64 个子频带进行特征提取。特征提取之后,使用半监督过采样分类器来进行微震信号的模式识别。一方面,使用多种特征提取方法来提取微震数据集的特征,可以更好地表达微震数据集,在此基础上可以提高算法的处理速度,并获得更好地模式识别效果。另一方面,使用过采样的方法来处理微震数据集中存在的微震数据样本不足的问题,并使用半监督学习的方式来提高过采样数据的标注准确度。

但是在试验过程中,没有对 FLD 特征提取进行提取维度的研究,只是简单地将高维数据降到了 1 维,这是欠考虑的,因为可能存在一个合适的低维结构可以更好地代表原始高维数据信息,而不是 1 维特征,这样也许可以提高模式识别的准确率。

## 参考文献(References):

[1] 曹安业,井广成,窦林名,等.孤岛面开采强矿震异常区的被动声波探测技术及应用[J].采矿与安全工程学报,2015,32(1):20-27.  
CAO Anye, JING Guangcheng, Dou Linming, *et al.* Seismic hazard assessment in complex island coalface by computed tomography [J]. *Journal of Mining & Safety Engineering*, 2015, 32(1): 20-27.

[2] 杨纯东, 巩思园, 马小平, 等. 基于微震法的煤矿冲击危险性监测研究[J]. 采矿与安全工程学报, 2014, 31(6): 863-868.  
YANG Chundong, GONG Siyuan, MA Xiaoping, *et al.* Rock burst danger monitoring based on microseismic method [J]. *Journal of Mining & Safety Engineering*, 2014, 31(6): 863-868.

[3] 李健, 吴顺川, 高永涛, 等. 露天矿边坡微地震监测研究综述[J]. 岩石力学与工程学报, 2014, 33(S2): 3998-4013.  
LI Jian, WU Shunchuan, GAO Yongtao, *et al.* Review of slope microseismic monitoring in open-pit mine [J]. *Chinese Journal of Rock Mechanics and Engineering*, 2014, 33(S2): 3998-4013.

[4] 柳云龙, 田有, 冯晖, 等. 微震技术与应用研究综述[J]. 地球物理学进展, 2013, 28(4): 1801-1808.  
LIU Yunlong, TIAN You, FENG Xuan, *et al.* Review of microseism technology and its application [J]. *Progress in Geophysics*, 2013, 28(4): 1801-1808.

[5] DEBNATH L. Wavelet transforms and their applications [J]. *Physics Today*, 2003, 56(4): 68-68.

[6] 曹安业, 窦林名, 秦玉红, 等. 高应力区微震监测信号特征分析[J]. 采矿与安全工程学报, 2007, 24(2): 146-149.  
CAO Anye, DOU Linming, QIN Yuhong, *et al.* Characteristic of microseismic monitoring signal in high stressed zone [J]. *Journal of Mining & Safety Engineering*, 2007, 24(2): 146-149.

[7] 唐守锋, 童敏明, 潘玉祥, 等. 煤岩破裂微震信号的小波特征能谱系数分析法[J]. 仪器仪表学报, 2011, 32(7): 1521-1527.  
TANG Shoufeng, TONG Minming, PAN Yuxiang, *et al.* Energy spectrum coefficient analysis of wavelet features for coal rupture microseismic signal [J]. *Chinese Journal of Scientific Instrument*, 2011, 32(7): 1521-1527.

[8] 赵国彦, 邓青林, 马举. 基于 FSWT 时频分析的矿山微震信号分析与识别[J]. 岩土工程学报, 2015, 37(2): 306-312.  
ZHAO Guoyan, DENG Qinglin, MA Ju. Recognition of mine microseismic signals based on FSWT time-frequency analysis [J]. *Chinese Journal of Geotechnical Engineering*, 2015, 37(2): 306-312.

[9] 朱权洁, 姜福兴, 尹永明, 等. 基于小波分形特征与模式识别的矿山微震波形识别研究[J]. 岩土工程学报, 2012, 34(11): 2036-2042.  
ZHU Quanjie, JIANG Fuxing, YIN Yongming, *et al.* Classification of mine microseismic events based on wavelet-fractal method and pattern recognition. [J]. *Chinese Journal of Geotechnical Engineering*, 2012, 34(11): 2036-2042.

[10] VALLEJOS J A, MCKINNON S D. Logistic regression and neural network classification of seismic records [J]. *International Journal of Rock Mechanics & Mining Sciences*, 2013, 62(9): 86-95.

[11] DONG L, WESSELOO J, POTVIN Y, *et al.* Discrimination of mine seismic events and blasts using the fisher classifier, naive bayesian classifier and logistic regression [J]. *Rock Mechanics and Rock Engineering*, 2016, 49(1): 183-211.

[12] DING S, ZHU H, JIA W, *et al.* A survey on feature extraction for pattern recognition [J]. *Artificial Intelligence Review*, 2012, 37(3): 169-180.

[13] ABDI H, WILLIAMS L J. Principal component analysis [J]. *Wiley Interdisciplinary Reviews Computational Statistics*, 2010, 2(4): 433-459.

[14] GILLES J. Empirical wavelet transform [J]. *IEEE Transactions on Signal Processing*, 2013, 61(16): 3999-4010.

[15] YANG J, YANG J Y, YE H. Theory of fisher linear discriminant analysis and its application [J]. *Acta Automatica Sinica*, 2003, 29(4): 481-493.

[16] CHAWLA N V, BOWYER K W, HALL L O, *et al.* SMOTE: synthetic minority over-sampling technique [J]. *Journal of*

(下转第 202 页)

## 参考文献 (References):

- [1] 陈世建. 煤矿风井防爆门改进[J]. 煤矿机械, 2007, 28(6): 140-141.  
CHEN Shijian. Improvement of coal mine explosion-proof door [J]. Coal Machinery, 2007, 28(6): 140-141.
- [2] 王德明. 矿井通风与安全[M]. 徐州: 中国矿业大学出版社, 2012: 56-280.
- [3] 荀洪菲. 关于煤矿现有回风立井防爆盖存在问题的改进[J]. 中国煤炭, 2011, 37(10): 68-69.  
XUN Hongfei. Improvement of explosion-proof door for return shaft in coal mine [J]. China Coal, 2011, 37(10): 68-69.
- [4] 王忠龙. 可快速更换的立井防爆盖及其配套设备设计研究[D]. 徐州: 中国矿业大学, 2014: 1-80.
- [5] 荀洪菲, 白宏峰, 王克智, 等. 煤矿自复式防爆盖的设计[J]. 煤, 2011, 12(12): 59-60.  
XUN Hongfei, BAI Hongfeng, WANG Kezhi, et al. Design of coal mine self-entry explosion proof cover [J]. Coal, 2011, 12(12): 59-60.
- [6] 余明高, 纪文涛, 温小萍, 等. 具有自动复位功能的立风井防爆门; 中国, CN203335112U [P]. 2013-12-11.
- [7] 杜欣. 立风井防爆门快速启闭及锁扣装置在矿井主通风机上的应用和分析[J]. 科技创业家, 2014, 4(8): 113.  
DU Xin. The application and analysis of the rapid opening and closing of the flameproof door and locking device in the main ventilator of mine shaft [J]. Technological Pioneers, 2014, 4(8): 113.
- [8] 温建东, 赵德方, 范明训, 等. 快速复位的立风井防爆门; 中国, 200910016098.9 [P]. 2011-01-12.
- [9] 曹宏伟, 刘荣第. 一种用于立井防爆门的电(液)动反风装置[J]. 煤矿安全, 2003, 34(8): 37-39.  
CAO Hongwei, LIU Rongdi. An electric (liquid) anti-wind device used for Shaft explosion-proof door [J]. Safety in Coal Mines, 2003, 34(8): 37-39.
- [10] 王岸泓, 沈斌, 秦宪礼. 立风井防爆井盖自动运行技术研究[J]. 价值工程, 2012, 25(34): 122-134.  
WANG Anhong, CHEN Bin, QIN Xianli. Research of automatically run technologies of shaft anti-explosion manhole cover [J]. Value Engineering, 2012, 25(34): 122-134.
- [11] 邹国华, 宋清源, 万洪志. 爆炸波释放卸压后自动复位的立风井防爆门; 中国, CN102410044A [P]. 2012-04-11.
- [12] 何军, 陈伟, 王其龙, 等. 泄压式自动复位风井防爆盖; 中国, CN103953382A [P]. 2014-07-30.
- [13] 李亚奇, 闫自强, 杨守岗, 等. 平井和斜井自行复位防爆门; 中国, CN102352775A [P]. 2012-02-15.
- [14] 张新杰. 工程机械电控系统平台设计与应用[D]. 济南: 山东大学, 2012: 45-48.
- [15] 李学民. 分配泵电控系统的开发及在车用柴油机上的应用研究[D]. 长春: 吉林大学, 2005: 12-67.
- [16] 张宇. 煤矿事故应急救援能力评价体系的构建研究[D]. 大连: 大连交通大学, 2011: 5-63.
- [17] 张军波. 煤矿瓦斯爆炸应急救援组织管理研究[D]. 北京: 中国矿业大学(北京), 2013: 6-55.
- [18] 苏桂虎, 邢强. 关于煤矿应急救援系统的研究[J]. 山东煤炭科技, 2012, 56(2): 202-203.  
SU Guihu, XING Qiang. Research on coal mine emergency rescue system [J]. Shandong Coal Science and Technology, 2012, 56(2): 202-203.
- [19] 黄军利. 国外煤矿应急救援技术装备综述[J]. 煤矿安全, 2016, 47(9): 233-236.  
HUANG Junli. A review of foreign technical equipment on coal mine emergency rescue [J]. Safety in Coal Mines, 2016, 47(9): 233-236.
- [20] 秦宪礼. 安全监测监控原理[M]. 北京: 煤炭工业出版社, 2015: 20-265.
- [21] 高洪亮, 刘章现, 徐义勇. 安全监测监控技术[M]. 北京: 中国劳动社会保障出版社, 2009: 53-304.
- [21] BREIMAN L. Random forests [J]. Machine Learning, 2001, 45(1): 5-32.
- [22] CORTES C, VAPNIK V. Support-vector networks. [J]. Machine Learning, 1995, 20(3): 273-297.
- [23] ZHU J, ZOU H, ROSSET S, et al. Multi-class AdaBoost [J]. Statistics & Its Interface, 2006, 2(3): 349-360.
- [24] HE H, BAI Y, GARCIA E A, et al. ADASYN: adaptive synthetic sampling approach for imbalanced learning [C]. 2008 International Joint Conference on Neural Networks, 2008: 1322-1328.

(上接第218页)

Artificial Intelligence Research, 2011, 16(1): 321-357.

- [17] LOOG M. Contrastive pessimistic likelihood estimation for semi-supervised classification [J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2016, 38(3): 462-475.
- [18] LI Y, GUAN C, LI H, et al. A self-training semi-supervised SVM algorithm and its application in an EEG-based brain computer interface speller system [J]. Pattern Recognition Letters, 2008, 29(9): 1285-1294.
- [19] WONG W K, CHEUNG W L, KAO B, et al. Secure kNN computation on encrypted databases [C]. ACM SIGMOD International Conference on Management of Data. ACM, 2009: 139-152.
- [20] KEATING K A, CHERRY S. Use and Interpretation of logistic re-