

赵刚, 黄汉明, 卢欣欣, 等. 基于 BP-Adaboost 方法的天然地震和人工爆炸事件波形信号分类识别研究[J]. 地震工程学报, 2017, 39(3): 0557-0562. doi: 10.3969/j.issn.1000-0844.2017.03.0557

ZHAO Gang, HUANG Han-ming, LU Xin-xin, et al. Research on the Classification of Seismic Wave Signals of Earthquakes and Explosion Events Based on BP-Adaboost[J]. China Earthquake Engineering Journal, 2017, 39(3): 0557-0562. doi: 10.3969/j.issn.1000-0844.2017.03.0557

## 基于 BP-Adaboost 方法的天然地震和人工爆炸事件波形信号分类识别研究<sup>①</sup>

赵 刚, 黄汉明, 卢欣欣, 郭世豪, 柴慧敏

(广西师范大学计算机科学与信息工程学院, 广西 桂林 541004)

**摘要:**BP 神经网络和支持向量机(SVM)是两种主流的分类识别方法,用于天然地震和人工爆炸事件波形信号分类识别时取得了较好的效果。但 BP 神经网络存在易陷入局部最优及隐层数和隐层节点数与训练样本数据密切相关而无法有效预先确定;而支持向量机(SVM)方法则缺乏有效手段来选取合适的核函数,从中不能很好地扩展到多分类。针对天然地震和人工爆炸事件波形信号的分类识别问题,文中将上述两种方法和集成学习——BP-Adaboost 方法进行了对比实验研究。据对所选用的地震、爆炸事件波形信号数据集的分类识别结果表明,BP-Adaboost 方法得到了 98% 以上的正确识别率,并且具有较好的泛化能力。相较于 BP 神经网络和 PCA-SVM 方法,BP-Adaboost 方法对于数据集的划分和识别结果具有更好的鲁棒性,应用于天然地震和人工爆炸事件波形信号分类识别时,可取得更好的识别效果。同时,结合 Adaboost 方法的原理,阐述了 BP-Adaboost 方法拥有更好分类结果和泛化能力的原因。

**关键词:**分类识别;地震波形信号;BP-Adaboost;集成学习;BP 神经网络;支持向量机(SVM)

中图分类号:P315

文献标志码:A

文章编号:1000-0844(2017)03-0557-07

DOI:10.3969/j.issn.1013-0019.2017.03.0557

## Research on the Classification of Seismic Wave Signals of Earthquakes and Explosion Events Based on BP-Adaboost

ZHAO Gang, HUANG Han-ming, LU Xin-xin, GUO Shi-hao, CHAI Hui-min

(College of Computer Science and Information Engineering, Guangxi Normal University, Guilin 541004, Guangxi, China)

**Abstract:** Back-propagation neural-networks (BP-NN) and the support vector machine (SVM) are the two mainstream methods for classification of seismic wave signals of earthquakes and explosion events used in this research. The two methods achieved accurate and effective results. However, when training the BP-NN, it is inevitable that it can be easily trapped in a local optimum; in addition, the optimal numbers of hidden layers and numbers of nodes in each layer are heavily dependent on the distribution configuration of the training samples data, and cannot be

① 收稿日期:2016-05-18

基金项目:国家自然科学基金(41264001)

作者简介:赵 刚(1991—),男,在读研究生,研究方向为机器学习与地震信号处理。E-mail:zhaogang\_gxnu@sina.com。

通信作者:黄汉明(1966—),男,教授,研究方向为模式识别、信号处理及生物特征识别。E-mail:huanghm@gxnu.edu.cn。

consistently determined in advance. Furthermore, when training the SVM, there is a shortage of effective means to select suitable kernel function(s); hence, the ordinary SVM cannot be easily extended to multiclass problems. Aiming at the classification of seismic wave signals of earthquakes and explosion events, this paper investigates and compares the BP-NN and the SVM, along with the BP-Adaboost ensemble learning method. Using the dataset of seismic wave signals of earthquakes and explosion events in the experiments of this paper, the classification results show that the BP-Adaboost method can achieve the overall correct recognition rate of not less than 98%, with excellent generalization ability. Compared with BP-NN and SVM, the two main traditional classification methods, it has been shown that the BP-Adaboost method is more robust for different dataset partitions and corresponding classification, which implies more robust generalizability and better classification of seismic wave signals of earthquakes and explosion events. In the meanwhile, the theory of the Adaboost method is applied to explain the reasons for the better classification results and the generalizability of the BP-Adaboost method.

**Key words:** classification; seismic wave signal; BP-Adaboost; ensemble learning; BP neural networks; support vector machine (SVM)

## 0 引言

天然地震和人工爆破引发的地震波形信号都能被附近或远处的地震台网记录到。如何快速、准确地识别天然地震和人工爆炸信号,即对所检测到的地震波的震源类型进行快速、准确的分类识别具有重要意义。根据地震波对震源类型进行分类识别,现在是地震学研究中的热点问题。最初科学家们采用统计学方法来进行天然地震和人工爆炸的分类识别研究<sup>[1]</sup>,这种方法利用人工爆炸的时间和地点较为固定,而地震则无明显时间规律的特点来进行分类,显然这类方法受数据干扰较大,可靠性不高。为了解决这类问题,不少研究者将神经网络技术应用到地震和人工爆炸信号的分类识别研究:遗传 BP 神经网络识别地震与爆破<sup>[2]</sup>首次将 BP 神经网络用于地震和爆破信号的识别,随后多层感知器神经网络方法<sup>[3]</sup>也应用到地震和水下爆炸的分类识别研究中,取得了 92% 的分类识别效果。Benbrahim 等<sup>[4]</sup>证明了神经网络对于地震类信号的分类器具有鲁棒性和灵活性。但是神经网络在地震和爆炸信号分类识别方面也存在其固有缺点,如极易陷入局部最优解、收敛速度慢等问题。支持向量机(SVM)方法因其快速识别率高等特点成为现在地震爆炸信号分类的主流方法:黄汉明等<sup>[5]</sup>采用小波提取特征然后用 SVM 作为分类识别器识别地震爆炸信号;毕明霞等<sup>[6]</sup>采用 HHT 变换提取特征后采用 SVM 作为分类识别验证等,这些采用 SVM 方法都取得了高于 90% 的分类效果,但方法无法有效选取核函数以及不适用于多分类问题也严重限制了其应用范围。

新的分类和识别方法<sup>[7-9]</sup>不断涌现,但鲜有对这些识别方法的综合性能评价。本文提出了一种基于 BP-Adaboost 方法的天然地震和人工爆炸信号分类识别方法,将现在流行的集成学习方法应用于地震和爆炸信号的识别。本文将 BP 神经网络、支持向量机(SVM)和集成学习方法在同一数据集上进行分类识别,进行效果比较及测试、评估。通过比较发现, BP-Adaboost 拥有较高的准确率和较快的识别速度,且具有良好的泛化能力,适用于地震爆炸信号分类。本文为选择合适的地震爆炸信号的分类识别算法提供了一个高效合理的新选项。

## 1 集成学习方法简介

### 1.1 集成学习方法

“三个臭皮匠,赛过诸葛亮”,集成学习的实质和这句古语不谋而合:产生数个简单的、结果比随机猜测略好的“弱分类器”,然后将它们按照一定的规则组合成为“强分类器”,以达到满意的分类效果。作为机器学习领域的后起之秀,集成学习方法在人脸识别、基因序列检测、计算机安全领域等许多方面取得了巨大成功。相比于 BP 神经网络、SVM 等方法,集成学习拥有许多优点:可以同时降低方差和偏差,拥有更好的泛化能力<sup>[10]</sup>,不易出现过拟合问题,且可以任意组合“弱分类器”来适应各种实际问题的需要,从而更好地求解实际问题。

目前有三种主流的集成学习方法:Bagging 算法、Boosting 算法及 Stacking 算法。集成学习方法的框图如图 1 所示。

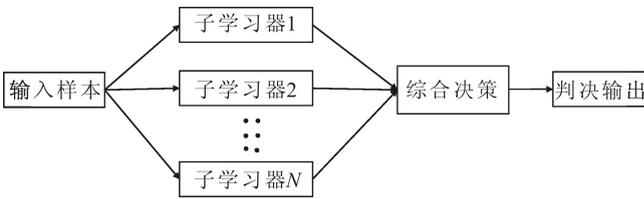


图 1 集成学习方法结构框图

Fig.1 Structure diagram of ensemble learning method

1.2 BP-Adaboost 方法

BP-Adaboost 方法是将 BP 神经网络作为“弱分类器”,通过 Adaboost 方法组合成“强分类器”。由于 Adaboost 方法使用贪心策略,并不需要考虑弱分类器的形式,而且算法本身可以适应“弱分类器”各自的训练误差<sup>[10]</sup>,因此本文选取的 BP 神经网络甚至可以是单隐层网络,不需要严格考虑 BP 神经网络的隐层层数和各隐层节点数等问题,大大简化了模型的构建。BP-Adaboost 方法的结构如图 2 所示。

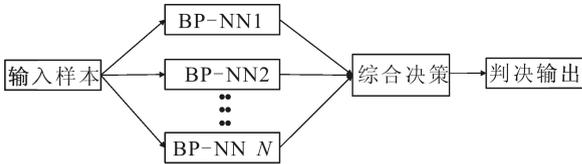


图 2 BP-Adaboost 方法结构框图

Fig.2 Structure diagram of BP-Adaboost method

BP-Adaboost 的算法过程如下:

(1) 数据选择:随机选取  $m$  个训练样本,初始化权重分布为:

$$\Theta_{i(i)} = 1/m \quad (1)$$

(2) 初始化 BP 神经网络:依据实验特性初始化 BP 神经网络,可使网络设置尽可能简单,简化模型参数;

(3) 弱分类器训练:训练第  $t$  个“弱分类器”时,用训练数据训练 BP 网络并预测输出,得到预测序列  $g(t)$  的预测误差和  $e(t)$ :

$$e(t) = \sum_i \Theta_{i(i)}, i = 1, 2, \dots, m [g(t) \neq y] \quad (2)$$

(4) 计算预测序列权重  $a_t$ :

$$a_t = \frac{1}{2} \ln \left( \frac{1 - e^t}{e^t} \right) \quad (3)$$

(5) 权重迭代调整:根据  $a_t$  迭代调整下一轮训练样本的权重:

$$\Theta_{t+1(i)} = \frac{\Theta_{i(i)}}{B_i} * \exp[-a_t y_i g_t(x_i)], i = 1, 2, \dots, m \quad (4)$$

其中:  $B_i$  为归一化系数。

(6) 强分类器输出:由  $T$  组弱分类函数  $f(g_t, a_t)$  组合得到强分类器:

$$h(x) = \text{sign} \left[ \sum_{t=1}^T a_t * f(g_t, a_t) \right] \quad (5)$$

2 实验与结果分析

2.1 实验数据

实验数据集来自地震科学数据中提供的 656 条天然地震和人工爆炸信号波形记录数据<sup>[5-6]</sup>,其中天然地震波形记录为 138 条,人工爆炸波形记录数据为 518 条,从每条波形记录提取相应的波形特征数据,这样每条波形记录可得到相应的特征数据点,每个数据点包含 27 维特征,分别代表波形时域特征(标准差、均值、中位数、最大值、最小值、峰度及偏斜度)、小波变换特征(能量比、香农熵及对数能量比)、 $A_{P1}, A_{Sm}, A_{Pm}, A_{P1}/A_{Sm}, A_{Pm}/A_{Sm}, A_{Pm}/T_{me}, A_{Sm}/T_{me}, A_{Pm}/A_{Lm}, m_b/M_s, m_b - M_s, L_c, T_{me}, P/Lg$ 、相关性,波形复杂性、谱比及  $P$  波初动方向等,表 1 列出上述符号的具体含义:

表 1 特征参数的含义

Table 1 Meaning of characteristic parameters

符号	含义
$A_{P1}$	时域波形中的 P 波初至幅值
$A_{Sm}$	时域波形中的 S 波群最大幅值
$A_{Pm}$	频域波形中的 S 波群最大幅值
$T_{me}$	时域波形中的最大幅值之后有效波形持续时长(单位:s)
$A_{Lm}$	时域波形中的勒夫波群最大幅值
$m_b$	事件的体波震级
$M_s$	事件的里氏震级

为了取消各维数据间数量级差别,避免因为输入输出数据数量级差别较大而引起的训练误差,在本文中所有的输入数据均进行了如下归一化处理,将数据归一化到  $[0, 1]$  区间:

$$x_k = (x_k - x_{\min}) / (x_{\max} - x_{\min}) \quad (6)$$

其中:  $x_{\min}$  为数据序列中的最小值;  $x_{\max}$  为数据序列中的最大值。

2.2 分类性能比较

为了验证 BP-Adaboost 方法的有效性,本文选取 BP 神经网络和 PCA-SVM 方法来进行对比验证。首先采用 BP 神经网络,为增强网络分类性能,采用双隐层结构,每个隐层包含 4 个节点,网络迭代次数为 100 次,学习率为 0.1,训练误差设置为  $10^{-5}$ ;然后采用 SVM 方法,为增强 SVM 分类效果,首先对数据进行主成分分析(PCA)处理,保留能量

为 95%，然后再进行 SVM 分类；最后采用 BP-Adaboost 方法，为减弱 BP 网络分类性能，使之成为“弱分类器”，采用单隐层 BP 结构，隐含层包含 3 个节点，网络迭代次数为 5 次，其余设置与 BP 神经网络相同，共有 10 个“弱分类器”组成“强分类器”。程序运行环境为：MATLAB R2010b, windows 7 系统。

### 2.2.1 不同数据集样本划分实验结果

对数据集采用非重叠的随机选取划分策略，使训练样本和测试样本完全独立。分别选取 10%~100% (其中 100%，是指全部的数据样本既作为训练集，同时也作为测试集)，以 10% 为间隔进行样本划分 (如随机选取训练样本比例为 10%，则余下 90% 为测试样本)，三种分类器各运行 10 次的错分样本数在表格 2 中列出。将表格 2 中的每次训练错分样本数目的按训练样本比例平均，得到平均错分样本数，结果如图 3 所示。

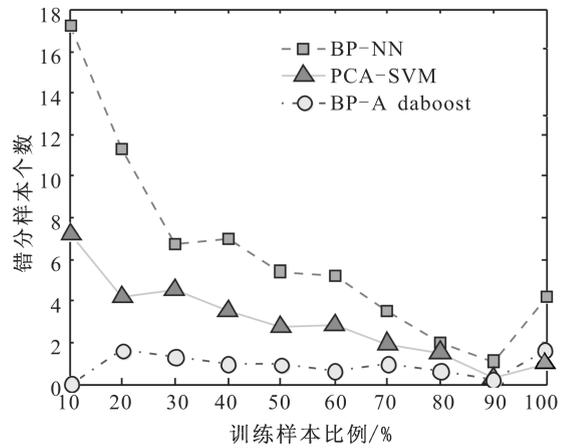


图 3 三种分类器不同数据集样本划分 10 次训练平均错分样本个数

Fig.3 Three different classifiers for different data sets are divided into 10 training mean and the number of samples

表 2 不同数据集样本划分实验结果 (错分样本数)

Table 2 Experimental results on different data sets (misclassified numbers)

训练样本比例	BP 神经网络	Avg	PCA-SVM	Avg	BP-Adaboost	Avg
10%	13,14,9,10,28,11,18,23,38,8	17.2	4,7,5,8,6,5,20,3,5,9	7.2	0,0,0,0,0,0,0,0,0,0	0
20%	19,8,10,9,8,12,10,11,19,7	11.3	3,6,6,7,4,4,4,2,4,2	4.2	0,8,0,0,0,0,1,7,0,0	1.6
30%	6,9,8,5,4,7,8,5,6,9	6.7	2,4,7,3,7,5,5,4,5,3	4.5	0,0,0,4,0,0,5,4,0,0	1.3
40%	8,6,5,8,6,6,10,6,6,9	7.0	3,2,3,5,1,4,4,4,5,4	3.5	2,0,3,0,3,0,2,0,0,0	1.0
50%	4,6,3,13,7,4,3,2,6,6	5.4	3,1,3,3,2,3,3,2,4,3	2.7	0,3,0,0,0,5,0,1,0,0	0.9
60%	3,4,7,3,6,5,10,3,6,5	5.2	2,2,2,3,3,4,4,3,3,2	2.8	2,0,0,0,0,0,2,0,1,1	0.6
70%	4,5,4,2,3,4,2,2,6,3	3.5	2,3,1,1,3,2,1,2,2,2	1.9	0,0,2,2,0,2,1,2,0,1	1.0
80%	2,2,0,4,1,3,2,1,2,3	2.0	3,1,0,1,2,3,2,0,1,2	1.5	1,1,0,1,0,0,0,1,2,0	0.6
90%	3,0,0,3,0,0,2,1,0,2	1.1	0,0,0,2,0,0,0,0,0,1	0.3	1,0,0,0,0,0,1,0,0,0	0.2
100%	3,3,4,3,3,14,3,3,2,4	4.2	1,1,1,1,1,1,1,1,1,1	1.0	2,1,2,2,2,2,2,1,1,1	1.6

由图 3 可知：

(1) BP-Adaboost 方法对于数据集的划分具有很强的鲁棒性，即训练样本的数量多少基本上对于训练错分样本个数没有影响；而 BP 神经网络和 PCA-SVM 对于训练集的划分则较为敏感，随训练集样本数的增加错分样本数也有显著下降；

(2) 在数据样本较少时，更应该选用 BP-Adaboost 方法来得到可靠的分类结果。

### 2.2.2 特定数据集样本划分实验结果

随机选取地震和人工爆炸各 70% 数据样本作为训练集，其余 30% 作为测试集。表 3 为三种分类器分别运行 10 次后的最低分类准确率、最高分类准确率和平均分类准确率。

三种分类器分别运行 10 次每次对应的分类准确率如图 4 所示。

表 3 三种分类器分类准确率

Table 3 Classification accuracy of three classifiers

分类算法	最低分类准确率/%	最高分类准确率/%	平均分类准确率/%
BP 神经网络	96.92	98.97	98.21
PCA-SVM	98.46	99.49	99.23
BP-Adaboost	98.97	100	99.49

通过表 3 和图 4 可以知道：

(1) 从表 3 中可看出，在总体的分类效果上，BP-Adaboost 和 PCA-SVM 分类识别效果要优于 BP 神经网络，原因在于 BP 神经网络基于经验风险最小化原则来进行网络训练，而 PCA-SVM 则先进行了特征选择，剔除了对于分类贡献较小的特征，并且 SVM 基于结构风险最小化原则来进行网络训练，因而训练结果要优于 BP 神经网络；BP-Ada-

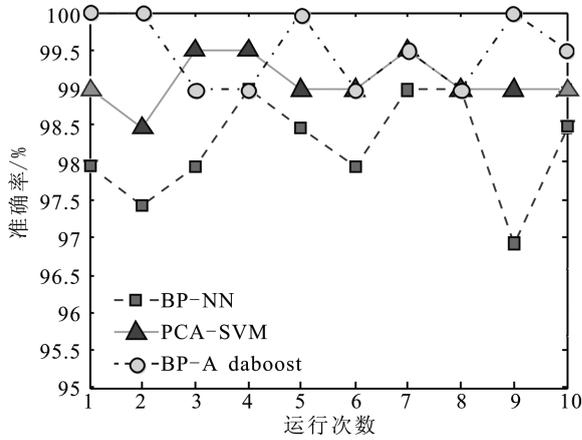


图 4 三种分类器运行 10 次准确率对比图

Fig.4 Three kinds of classifiers are running 10 times accuracy comparison char

boost 虽然和 BP 神经网络训练机制类似,但是由于采用组合策略,故而大大减小了单个分类器所存在的误差,从而取得了更好的分类效果。

(2) 从图 4 中可以看出,BP 神经网络的训练结果具有极大的不稳定性,这是由于网络的初始权值为随机选取;PCA-SVM 的网络训练结果较为稳定;BP-Adaboost 的训练结果也有波动,但相较 BP 神经网络来说稳定性有了较大提高。

(3) Adaboost 可看作是通过最大化训练样本的分类间隔来提高分类器的泛化能力<sup>[11]</sup>,实验结果说明 BP-Adaboost 方法相较于 SVM 方法在此数据集上拥有更好的分类间隔,从而提高了分类性能。

以上实验结果说明 PCA-SVM 和 BP-Adaboost 的分类准确率要好于 BP 神经网络,并且网络的泛化能力要明显优于 BP 网络。

为了进一步探究三种分类器对于地震爆炸信号的分类性能,分别选取三种分类器 10 次运行结果的平均分类结果为参考依据,且均选取最接近平均分类准确率的运行结果制作三种分类器的混淆矩阵,结果如表 4 所列。

基于上述混淆矩阵,可以得到评价分类器性能的四个评价指标:准确率(Precision)、召回率(Recall)、 $F$  值和精确率(Accuracy),对应的计算公式为:(1) 准确率=预测正确的某类别个数/预测为该类别数,即

$$P_1 = \frac{TP}{TP + FP}, \quad P_2 = \frac{TN}{TN + FN} \quad (7)$$

(2) 召回率=预测正确的某类别个数/测试集

中该类别个数,即

$$R_1 = \frac{TP}{TP + FN}, \quad R_2 = \frac{TN}{FP + TN} \quad (8)$$

表 4 三种分类结果的混淆矩阵

Table 4 Confusion matrix of the three classification results

分类方法		实际“1”类	实际“0”类
BP 神经网络	预测	TP	FP
	“1”类	40	3
	预测	FN	TN
PCA-SVM	“0”类	1	151
	预测	TP	FP
	“1”类	40	1
BP-Adaboost	预测	FN	TN
	“0”类	1	153
	预测	TP	FP
BP-Adaboost	“1”类	41	1
	预测	FN	TN
	“0”类	0	153

(3)  $F$  值 =  $2 \times$  准确率  $\times$  召回率 / (准确率 + 召回率), 即

$$F_1 = \frac{2 \times P_1 \times R_1}{P_1 + R_1}, \quad F_2 = \frac{2 \times P_2 \times R_2}{P_2 + R_2} \quad (9)$$

(4) 精确率 = 正确预测的所有个数 / 总样本个数, 即

$$A = \frac{TP + FN}{P + N} \quad (10)$$

式中:下标 1 表示对于“1”类(地震)的结果,下标 2 表示对于“0”类(人工爆炸)的结果。

则可根据上述公式和混淆矩阵分别计算出三种机器学习方法对应的分类性能评价指标,由表 5 给出,并且得到三种分类器的平均运行时间,如表 6 所列。

由表 5 和表 6 可以得出如下结论:

(1) BP-Adaboost 方法在准确率、召回率、 $F$  值以及精确率等方面均优于 BP 神经网络和 PCA-SVM 方法,且拥有 2% 以上的性能提升。考虑到文中所用 BP 神经网络和 SVM 方法均为其加强形式,BP-Adaboost 性能提升还是较为明显的。

(2) PCA-SVM 和 BP-Adaboost 方法在某些分类性能评价指标较为接近,若要求实时性,则训练速度更快的 PCA-SVM 方法更符合需求,但如果要求更高的预测精度,则 BP-Adaboost 方法更为合适。

(3) 注意到本文所用分类的地震爆炸数据集为不平衡数据集,而曹莹等<sup>[10]</sup>证明 Adaboost 方法对

表5 三种分类器分类性能评价指标

Table 5 Three kinds of classifiers Performance Evaluation

分类算法	$P_1/\%$	$P_2/\%$	$R_1/\%$	$R_2/\%$	$F_1/\%$	$F_2/\%$	ACC/%
BP神经网络	93.02	99.34	97.56	98.05	95.24	98.69	97.95
PCA-SVM	97.56	99.35	97.56	99.35	97.56	95.35	98.97
BP-Adaboost	97.56	<b>100</b>	<b>100</b>	99.35	<b>98.76</b>	<b>99.67</b>	<b>99.49</b>

表6 三种分类器平均运行时间

Table 6 Three kinds of classifiers average running time

分类算法	平均运行时间/s
BP神经网络	1.572 477
PCA-SVM	0.353 826
BP-Adaboost	6.242 371

于不平衡分类问题是有效的,且通常情况下会有更好的分类效果。对于 BP-Adaboost 方法,在增加合适的“弱分类器”数量或者增强 BP“弱分类器”性能后,对于此问题可以达到 100% 的准确率。

(4) BP-Adaboost 方法采用贪心策略以迭代方式在函数空间优化特定的损失函数,可有效解释该算法的原理和 BP-Adaboost 拥有良好的泛化能力<sup>[12]</sup>,为该方法应用于地震波形分类识别提供了良好的理论基础。

### 2.3 其他数据集分类结果验证

为了进一步验证本文提出的识别方法,选取首都圈 35 个地震和 27 个爆炸事件三个地震台站检测的地震波形信号的经验模态分解的能量比特特征进行分类识别验证。数据集大小为  $186 \times 7$ ,数据第一列为样本标签,其余六列为每个波形前六个经验模态分解(EMD)能量比特特征,随机选取 70% 的数据作为训练集,余下的 30% 作为测试集,三种分类器均训练 10 次,结果如图 5 所示。

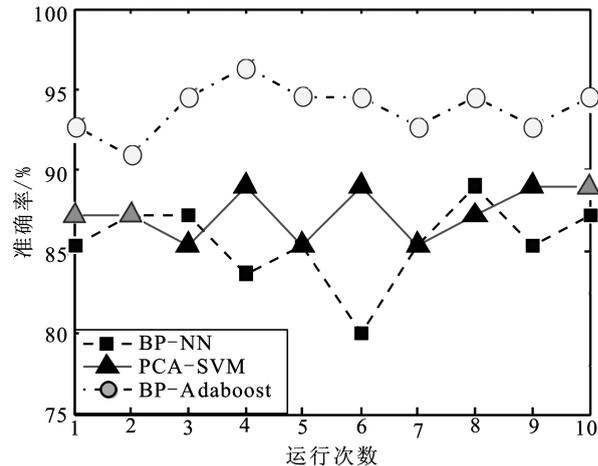


图5 三种分类器运行 10 次准确率对比图

Fig.5 Three kinds of classifiers are running 10 times accuracy comparison chart

由图 5 可知, BP-Adaboost 方法对于该数据集的分类效果明显优于 BP 神经网络和 PCA-SVM 方法,说明 BP-Adaboost 方法对地震波形数据集和特征的选取具有一定的鲁棒性,有较好的分类稳定性,可用于其数据集,从而取得较好的分类效果。

### 3 结束语

本文选取了 BP-Adaboost 方法对于天然地震和人工爆炸信号进行分类识别研究,并将其与目前主流的 BP 神经网络和 SVM 方法进行对比。通过实验表明: BP-Adaboost 方法较 BP 神经网络和 SVM 方法取得了更好的分类结果,且 BP-Adaboost 方法拥有更好的泛化能力,所以更适合用于地震爆炸信号的分类识别研究。此外,考虑到 PCA-SVM 和 BP-Adaboost 方法的各自特点,建议在进行快速识别和实时检测时采用 PCA-SVM 方法,而在要求更高识别率时,采用 BP-Adaboost 方法。同时,本文还引入了相关 Adaboost 理论,从理论上阐述了 BP-Adaboost 方法获得更优分类结果和更好的泛化能力的原因,为该方法在地震数据集上的应用提供了坚实的理论基础。

新的机器学习方法不断涌现,但如 Manuel Fernandez-Delgado<sup>[13]</sup>所言:我们真的需要如此多的分类器来进行分类研究吗?如何能找到既迅速又准确的分类识别方法来进行地震爆炸信号的分类识别研究,仍是值得研究的问题。

### 参考文献(References)

- [1] Walter W, Harris D, Myers S. Seismic Discrimination between Earthquakes and Explosions in the Middle East and North Africa [C]// Proceedings 19<sup>th</sup> Seismic Research Symposium on Monitoring a CTBT, Orlando, Florida, 1997: 10.
- [2] 边银菊. 遗传 BP 网络在地震和爆破识别中的应用[J]. 地震学报, 2002, 24(5): 516-524.  
BIAN Yin-ju. Application of Genetic BP Network to Discriminating Earthquake and Explosions [J]. Acta Seismologica Sinica, 2002, 24(5): 516-524. (in Chinese)
- [3] Del Pezzo E, Esposito A, Guidici Pietro F, et al. Discrimination of Earthquakes and Underwater Explosions Using Neural Networks [J]. Bulletin of the Seismological Society of America,

- 2003,93:215-223.
- [4] Benbrahim M, Daoudi A, Benjelloun K, et al. Discrimination of Seismic Signals Using Artificial Neural Networks[J]. Transactions on Engineering, Computing and Technology, 2005, 4: 4-7.
- [5] 黄汉明, 边银菊, 卢世军, 等. 天然地震与人工爆破的波形小波特征研究[J]. 地震学报, 2010, 32(3): 270-276.  
HUANG Han-ming, BIAN Yin-ju, LU Shi-jun, et al. A Wavelet Feature Research on Seismic Waveforms of Earthquakes and Explosions[J]. Acta Seismologica Sinica, 2010, 32(3): 270-276. (in Chinese)
- [6] 毕明霞, 黄汉明, 边银菊, 等. 天然地震与人工爆破波形信号 HHT 特征提取和 SVM 识别研究[J]. 地球物理学进展, 2011, 26(4): 1157-1164.  
BI Ming-xia, HUANG Han-ming, BIAN Yin-ju, et al. A Study on Seismic Signal HHT Features Extraction and SVM Recognition of Earthquake and Explosion [J]. Progress in Geophys. 2011, 26(4): 1157-1164. (in Chinese)
- [7] 张博, 边银菊, 王婷婷. 用逐步代价最小决策法识别地震与爆破[J]. 地震学报, 2014, 36(2): 233-243.  
ZHANG Bo, BIAN Yin-ju, WANG Ting-ting, et al. Discrimination of Earthquakes and Explosions by SAML Decision Method[J]. Acta Seismologica Sinica, 2014, 36(2): 233-243. (in Chinese)
- [8] 田野, 黄汉明, 边银菊, 等. 区分天然地震和人工爆炸的可视化方法[J]. 地球科学前沿, 2014(4): 136-146.  
TIAN Ye, HUANG Han-ming, BIAN Yin-ju, et al. Visualization Methods for Discriminating between Earthquakes and Explosions [J]. Advances in Geosciences, 2014(4): 136-146. (in Chinese)
- [9] 张晓煜, 李向. 基于粒子群算法的地震预报方法研究[J]. 地震工程学报, 2014, 36(1): 69-74.  
ZHANG Xiao-yu, LI Xiang. Earthquake Prediction Method Based on Particle Swarm Optimization [J]. China Earthquake Engineering Journal, 2014, 36(1): 69-74. (in Chinese)
- [10] 曹莹, 苗启广, 刘家辰, 等. AdaBoost 算法研究进展与展望[J]. 自动化学报, 2013, 39(6): 745-758.  
CAO Ying, MIAO Qi-guang, LIU Jia-chen, et al. Advance and Prospects of Adaboost Algorithm [J]. Acta Automatica Sinica, 2013, 39(6): 745-758. (in Chinese)
- [11] Friedman J, Hastie T, Tibshirani R. Additive logistic Regression: a Statistical View of Boosting (with Discussion and Rejoinder by the Authors)[J]. Annals of Statistics, 2000, 28(2): 337-407.
- [12] Mason L, Baxter J, Bartlett P L, Frean M. Functional Gradient Techniques for Combining Hypotheses. Advances in Large Margin Classifiers[M]. Cambridge, MA: MIT Press, 2000: 221-247.
- [13] Manuel Fernandez-Delgado, Eva Cernadas, Senen Barro. Do We Need Hundreds of Classifiers to Solve Real World Classification Problems[J]. Journal of Machine Learning Research, 2014, 15: 3113-3181.