

文章编号: 1000-7598-(2008) 04-943-06

基于 AdaBoost 组合学习方法的岩爆分类预测研究

葛启发^{1,3}, 冯夏庭^{1,2}

(1. 东北大学资源与土木工程学院, 沈阳 110004; 2. 中国科学院武汉岩土力学研究所 岩土力学与工程国家重点实验室, 武汉 430071;
3. 中国恩菲工程技术有限公司, 北京 100038.)

摘 要: 针对岩爆等级划分问题, 考虑了岩爆灾害发生的多种主要影响因素, 采用新的数据挖掘方法 AdaBoost (即 Adaptive Boosting) 的组合学习方法, 结合流行的人工神经网络 BP 算法, 构建了集成神经网络 AdaBoost—ANN (简称 AB—ANN) 的岩爆等级多分类预测模型。该模型克服了单一弱分类器的不稳定性, 提高了分类器精度, 实验结果表明, 预测的结果与实际值比较吻合, 证明了该方法的可行性。

关 键 词: 岩爆; 等级分类; 数据挖掘; AdaBoost; 神经网络

中图分类号: TU 324; TB 115

文献标识码: A

Classification and prediction of rockburst using AdaBoost combination learning method

GE Qi-fa¹, FENG Xia-ting^{1,2}

(1. School of Resources & Civil Engineering, Northeastern University, Shenyang 110004, China; 2. State Key Laboratory of Geomechanics and Geotechnical Engineering, Institute of Rock and Soil Mechanics, Chinese Academy of Sciences, Wuhan 430071, China)

Abstract: Rockburst is one of the most important geologic hazards. To solve the problem of classification and prediction of rockburst, the main factors of rockburst occurred and the effective classification methods should be considered. A new method is proposed based on combination of artificial neural networks (ANN) classifiers as weak classifiers by using AdaBoost algorithm in data mining. The AdaBoost-ANN models are established. Overcoming the instability of single classifier, the models can give more accurate and stable classification for the novel conditions. The results show that this method is reliable, constrictive and promising.

Key words: rockburst; classification; data mining; AdaBoost; ANN

1 引 言

岩爆是岩石工程中的一种重要的地质灾害, 它是处于高应力或极限平衡状态的岩体或地质结构体在开挖活动的扰动下, 其内部储存的应变能瞬间释放, 造成开挖空间周围部分岩石从母岩体中急剧、猛烈地突出或弹射出来的一种动态力学现象。随着矿山开采和地下工程规模的不断扩大, 岩爆问题日益突出, 世界上许多国家对其给予广泛重视和深入研究, 国内外学者运用各种理论, 对岩爆的发生机理、分类预测方法、数值模拟方法等方面进行了大量研究, 取得了可喜的成果^[1,2]。近年来, 国内外专家学者在总结了大量岩爆事例特征的基础上, 针对

岩爆等级分类预测问题, 提出了一些预测判据^[3], 总结出了岩爆发生所具备的主要条件, 并采取了許多方法和理论, 包括: 模糊综合评判方法、数值分析方法、人工神经网络方法、支持向量机方法等^[4~9]。但是, 针对岩爆等级分类的小样本情况, 单一分类器的不稳定性和分类器参数选取的复杂性问题, 对于模型的泛化能力是一种挑战。

Boosting 是最新的提高预测学习系统预测能力的数据挖掘方法。目前各种不同的 Boosting 算法很多, 但最具有代表性的是 AdaBoost 算法, 即自适应 Boosting 算法, 该算法在许多机器学习问题中都取得了成功应用, 尤其是应用于决策树^[11~13]。AdaBoost 算法不仅可以提升任意给定弱分类器的分类精度, 也可以提升强分类器的精度, 还能够解决样本空间

收稿日期: 2006-03-30

基金项目: 国家杰出青年科学基金 (No. 50325414)。

作者简介: 葛启发, 男, 1980 年生, 硕士研究生, 主要从事数据挖掘方法与专家系统及矿山设计等研究方面的工作。E-mail: geqifa@163.com

的小样本问题。其中,该算法扩展的 AdaBoost.M2 算法用于解决多类分类问题,本文采用 AdaBoost.M2 算法和人工神经网络结合的方法对提高岩爆等级分类模型的泛化能力起到了重要作用。基于这种思想,利用 AdaBoost 和人工神经网络 (ANN) 相结合的 AdaBoost—ANN (简称 AB-ANN) 组合学习方法对岩爆样本进行岩爆等级分类预测。

2 岩爆发生特点及影响因素分析

岩爆发生与其影响因素之间是一种复杂的非线性动力学现象,对于岩爆发生机理的认识目前还未形成统一的理论,但是研究表明,岩爆发生的必要条件有:一是岩体中具有较高的地应力,且其大小超过岩石本身的强度;二是岩石具有较高的脆性度和弹性。岩体在变形破坏过程中由于变形和破裂所消耗掉部分弹性能后,剩余能量转化为动能,并以岩体弹射或突然飞崩的形式释放,形成岩爆^[10]。它是岩体本身力学性质(内在因素)和外界影响因素(诱发因素)组合的结果。为了研究岩爆发生的各种因素,首先从研究国内外岩爆的现象入手,根据岩爆发生的强弱程度,归纳出岩爆发生的主要特点如下:

(1) 从无岩爆到轻微岩爆:围岩由稳定到逐渐变形、劈裂、剥落或偏帮,有轻微声响,无弹射现象,属于岩爆的初级阶段。

(2) 中等岩爆:围岩变形破裂,有相当数量的岩片弹射、松脱和突然性破坏发生,伴有清脆的爆裂声音。多产生在隧洞局部周边围岩,是对岩爆的常规认识,也成为表面型岩爆。

(3) 从强烈岩爆到剧烈岩爆:围岩强烈爆裂,甚至顶板和侧壁围岩发生严重的岩片弹射和巨石抛射,严重者可摧毁整个工程,对建筑物和人生安全造成很大的影响。

根据岩爆发生的特点和成因,本文考虑的主要因素包括有:岩体最大初始地应力 σ_1 ,围岩切向应力 σ_θ ,岩石的单轴抗压强度 σ_c ,岩石的单轴抗拉强度 σ_t ,围岩切向应力与岩块单轴抗压强度的比值 σ_θ/σ_c ,岩石脆性指数 $\sigma_\theta/\sigma_c = \sigma_c/\sigma_t$ 以及岩石在单轴下的弹性能量指数 W_{el} 等。在这些因素中,选取相互独立的主要因素: $\sigma_\theta = \sigma_1 \times 2$ (应力集中系数取 2.0), σ_θ/σ_c , n_b 和 W_{el} 。

本文考虑岩爆发生的强弱程度和主要影响因素,将岩爆分为 4 类,分别为:无岩爆(或者无明显岩爆)、轻微岩爆、中等岩爆、强岩爆。

3 AB-ANN 算法

3.1 AdaBoost 基本思想及泛化形式

Boosting 算法的基本思想就是试图产生数个简单的、精度比随机猜测略好的弱规则,再将这些规则集成构造一个高精度的强规则,这种思想起源于 Valiant 提出的 PAC 学习模型^[12]。

Boosting 算法最初是由 Freund 和 Schapire 于 1990 年提出,以及后来出现的 Freund 的 Boost-by-majority 算法,但是,在解决实际问题时存在一个重大缺陷,即它们要求事先知道弱学习器学习的正确率的下限,但这在实际问题中难以做到,不具有实用性。于是, Freund 和 Schapire 于 1995 年提出了 AdaBoost 算法,即自适应 Boosting 算法^[11~14,18,19]。

下面对 AdaBoost 算法的泛化形式作一下简单的介绍。

设定训练样本 $S = \{(x_1, y_1), \dots, (x_i, y_i), \dots, (x_n, y_n)\}$ $x_i \in X$, $y_i \in Y$, 其中, X 表示特征集空间, Y 为标签集, $Y \in \{-1, +1\}$, 弱学习器 h , D 为定义在输入训练样本上的一系列权重分布,初始状态 $D_1(i) = 1/n$, 以及循环代数 T 。通过 AdaBoost 方法,在一系列循环 $t = 1, \dots, T$ 次中反复调用弱学习器 h_t , 每次都根据权值 $D_t(i)$ 对训练集进行有放回随机抽样,生成新的训练样本集, T 次迭代后,用加权多数票把 T 个弱分类器组合成最后的强分类器 H 。其中,弱分类器 h_t 目标就是最小化在 D 分布下的新样本集的分类错误率 ε_t :

$$\varepsilon_t = Pr_{i \sim D_t}[h_t(x_i) \neq y_i] \quad (1)$$

Freund 和 Schapire 分析并证明了 Boosting 的最终预测函数 H 的训练分类错误率上界理论上为^[12]

$$\frac{1}{n} |\{i: H(x_i) \neq y_i\}| \leq \prod_{i=1}^T \sqrt{1 - 4\gamma_i^2} \leq \exp(-2 \sum_{i=1}^T \gamma_i^2) \quad (2)$$

对于 AdaBoost 算法的泛化形式,式(2)必须满足条件:

$$\gamma_t = 0.5 - \varepsilon_t \quad (3)$$

$$\varepsilon_t \leq 0.5 \quad (4)$$

从式(2)可以看出,随着弱分类数目 T 的增加, H 的分类训练错误率成指数下降。在 AdaBoost 之前提出 Boosting 算法要求事先知道 γ_t 的下限,但这一点在实际问题中很难做到,而 AdaBoost 却没有这样的要求。

3.2 AdaBoost.M2 方法

针对多分类问题,若直接运用 AdaBoost 算法

的泛化形式, 式 (1) 的中弱分类器 h_t 错误率 ε_t 可能大于 0.5, 不能满足式 (4), 将会出现不收敛现象, 故本文选用用于解决多分类问题的 AdaBoost 的扩展算法, 即 AdaBoost.M2 算法。

在 AdaBoost.M2 算法中, 对于弱分类器 h_t 在第 t 次迭代中的训练误差采用“伪误差”来评价弱分类器的性能好坏, 其计算公式如下^[15]:

$$\varepsilon_t = \frac{1}{2} \sum_{i=1}^N D_t(i)(1 - h_t(x_i, y_i) + \sum_{y \neq y_i} q_t(i, y) h_t(x_i, y)) \quad (5)$$

式中 $h_t(x_i, y)$ 表示弱分类器 h_t 将样本 x_i 分类为 y 的置信度, 即 $h_t: X \rightarrow [0, 1]$ 。需要说明的是 $q_t(i, y)$ 被称为标签加权函数, 表示弱分类器 h_t 将样本 x_i 错误分类为 y 的可能性, 该值越大表明样本 x_i 越需要重点学习, 通过不断地循环迭代, 找到合适的分类组合方式, 以提高弱分类器的学习能力和泛化能力。

3.3 AB-ANN 算法

利用 AdaBoost.M2 算法与弱分类器人工神经网络 BP 算法结合起来, 构建了用于解决多分类问题的集成神经网络 AB-ANN 强分类器模型。其算法实现步骤如下:

(1) 输入: 给定 N 个训练样本: $S = \{(x_1, y_1), \dots, (x_N, y_N)\}$, 其中类标签 $y_i \in Y = \{1, \dots, k\}$, i 为样本标号, k 表示类别数。

(2) 模型初始化

弱分类器 h : 基于 BP 算法人工神经网络;

权值初始化: 样本分布权重和分类权重向量:

$$D_1(i) = 1/N \quad (6)$$

$$W_{i,y}^1 = D_1(i)/(k-1) \quad (7)$$

式中权重向量 D 和 w 的上标 1 为第 1 次迭代, i 为样本号, y 为不包含 y_i 的所有类标签, 即 $y \neq y_i$;

设定最大迭代次数 T 。

(3) 采用 AdaBoost.M2 方法调用 ANN 的主循环过程($t = 1, 2, \dots, T$), 第 t 次循环时:

① 令 $W_i^t = \sum_{y \neq y_i} w_{i,y}^t$, 那么标签加权函数和样本分布权重:

$$q_t(i, y) = w_{i,y}^t / W_i^t \quad (8)$$

$$D_t(i, y) = W_i^t / \sum_{i=1}^N W_i^t \quad (9)$$

其中 $y \neq y_i$;

② 根据样本分布 D_t 选择新样本训练 BP 神经网络 ANN, 得到弱分类器 $h_t: X \times Y \rightarrow [0, 1]$;

③ 按 3.2 节式 (5) 计算 h_t 的“伪误差” ε_t , 若 $\varepsilon_t \geq 0.5$, 设置 $T = t - 1$, 转入 (4);

⑤ 计算

$$\beta_t = \varepsilon_t / (1 - \varepsilon_t) \quad (10)$$

⑥ 更新分类权重向量:

$$w_{i,y}^{t+1} = w_{i,y}^t \beta_t^{\frac{1}{2}(1+h_t(x_i, y_i) - h_t(x_i, y))} \quad (11)$$

(4) 输出: T 次循环后, 得到最终分类器 H :

$$H(x) = h_t(x) = \arg \max_{y \in Y} \sum_{t=1}^T \left(\log \frac{1}{\beta_t} \right) h_t(x, y) \quad (12)$$

注: 以上 AB-ANN 模型的基本算法, 得到了可靠性的验证。

4 岩爆等级分类预测模型

应用集成神经网络的 AB-ANN 算法来解决岩爆等级多分类问题, 构建了 AB-ANN 岩爆等级分类的强分类器模型。

4.1 模型构建

本文研究的对象是岩爆等级分类问题。通过分析岩爆发生的影响因素, 本文选用围岩切向应力 σ_θ 、围岩切向应力与岩块单轴抗压强度的比值 σ_θ/σ_c 、岩石脆性指数 σ_θ/σ_c 和岩石在单轴下的弹性能量指数 W_{et} 等参数作为岩爆等级分类的特征输入向量。岩爆等级强、中、弱、无 4 类, 作为输出向量, 类别编码采用第 i 类输出为 1, 其余为 0 的方式, 如编码 (0, 0, 1, 0) 表示该样本属于第 2 类。采用此种编码方式后, 每次经过 AdaBoost 调用神经网络后, 得到样本属于第 i 类的置信度。

理论上可以证明: 对于 3 层的 BP 网络, 当神经元的激活函数采用 S 型函数, 通过调整隐含层神经元, 可以任意逼近 n 维映射。所以, 本文选用 3 层 BP 网络 4— n_h —4 结构, 两个激活函数都为正切 S 型函数, 其中, n_h 为神经网络的隐含层神经元数目, 根据神经网络个体生成理论, 提高弱分类器间的差异性^[17], 随机选取 n_h 取值范围为 [5, 20]。集成传统的神经网络 BP 算法的 AB-ANN 模型如图 1 所示, 其中模型中的弱分类器为神经网络, 样本分布 D 和加权函数 q 在 AB-ANN 算法有论述。




图 1 AB-ANN 岩爆等级分类模型

Fig.1 AB-ANN model for rockburst classification

4.2 算例

(1) 数据准备

依据前面的分析, 考虑岩爆发生的主要特点和

主要因素,本文以搜集到的国内外的 36 个岩爆事例^[5~10]作为 AB-ANN 模型的样本空间,在这些岩爆事例样本中,36 个数据样本具有完整的独立 3 因素(包括 σ_b/σ_c , σ_c/σ_t 和 W_{et})数据,26 个数据样本具有完整的独立 4 因素(包括 σ_b , σ_b/σ_c , σ_c/σ_t 和 W_{et})数据,原始数据如表 1 所示。

表 1 样本数据
Table 1 Data set of samples

编号	σ_b/MPa	σ_b/σ_c	σ_c/σ_t	W_{et}	等级			
					IV	III	II	I
1	48.75	0.271	21.7	5	0	1	0	0
2	75	0.417	21.7	5	0	1	0	0
3	62.5	0.357	24	5	0	1	0	0
4	50	0.385	21.7	5	0	1	0	0
5	80	0.444	26.9	5.5	0	0	1	0
6	57	0.317	21.7	5	0	1	0	0
7	60	0.3	20.4	5	0	0	1	0
8	89	0.377	28.4	5	1	0	0	0
9	108.4	0.774	17.5	5.5	1	0	0	0
10	90	0.409	29.7	7.3	0	0	1	0
11	30	0.338	24	6.6	0	1	0	0
12	18.8	0.105	31.2	7.4	0	0	0	1
13	90	0.529	15	9	0	1	0	0
14	62.6	0.379	17.6	9	0	0	1	0
15	11	0.096	23	5.7	0	0	0	1
16	43.4	0.353	20.5	5	0	0	1	0
17	55.4	0.315	24.1	9.3	0	1	0	0
18	98.6	0.822	17.6	3.8	0	1	0	0
19	34	0.227	27.8	7.8	0	0	0	1
20	48	0.4	80	5.8	0	1	0	0
21	49.5	0.45	73.3	5.7	0	1	0	0
22	63	0.548	76.7	5.7	0	1	0	0
23	56.1	0.43	13.98	7.44	0	1	0	0
24	60.7	0.54	14.19	6.16	1	0	0	0
25	54.2	0.40	14.74	7.08	0	1	0	0
26	70.3	0.55	14.72	6.43	0	1	0	0
27	*	0.45	18	5	0	0	1	0
28	*	0.25	20.8	3.8	0	0	0	1
29	*	0.15	20.8	3.8	0	0	0	1
30	*	0.15	14.1	1.3	0	0	0	1
31	*	0.3	14.1	1.3	0	0	0	1
32	*	0.65	14.1	1.3	0	0	0	1
33	*	0.8	10	6	1	0	0	0
34	*	0.7	14.5	5	1	0	0	0
35	*	0.6	20.6	4.25	0	1	0	0
36	*	0.5	26.7	3.5	0	1	0	0

注:表中*表示缺失数据;岩爆“等级”中的 I, II, III, IV, 分别表示无岩爆、轻微岩爆、中度岩爆和强岩爆。

(2) 算例样本的确定


在这些岩爆事例样本中,按照类别选取样本,每类岩爆事例的 85 % 的分类样本作为训练和验证样本,其中,验证样本采用“留一法”交叉验证方式得到,另外 15 % 的分类样本不参与模型的学习和训练直接作为测试样本检验模型的预测能力和推广能力。该模型误差计算采用常用的均方误差 MSE (Mean-Square Error) 的计算式:

$$MSE = \sum_{i=1}^n \sum_{j=1}^m (Y_{ij} - \hat{Y}_{ij})^2 / n \quad (13)$$


式中 Y_{ij} , $\hat{Y}_{ij}$ 分别为第 i 个样本中第 j 类实际值和预测值 ($i = 1, 2, \dots, n$, $j = 1, 2, \dots, m$)。

(3) 算例结果

选取两组数据集分别是 3 因素的 36 个岩爆样本和 4 因素的 26 个岩爆样本,按照步骤 (2) 进行样本的确定,设定最大迭代次数 T 为 40。第 1 次迭代选取了所有的训练样本进行训练,然后采用重采样技术,选取样本作为新的神经网络的训练样本,在迭代过程中,随着集成神经网络数目的增多,岩爆样本的训练和测试误差呈逐渐减小的趋势如图 2 所示,其中图 2(a) 和(b) 分别表示在 AB-ANN 模型中 3 因素和 4 因素两组样本误差随迭代次数增加的变化情况。



(a) 3 因素岩爆样本



(b) 4 因素岩爆样本

图 2 AB-ANN 模型的训练和测试误差变化

Fig.2 The behavior of MSE over training and testing cases in two sets of rockburst samples respectively

经过分析,与单一神经网络相比,AB-ANN 模型误差有很大的减小,分类精度很大提升,如表 2 所示,最大能提升 50%以上,测试误差足够满足实际要求,说明了该模型具有良好的分类精度提升能力。其中分类精度提升 el 计算公式为

$$el = \frac{\text{ERROR_1NN} - \text{ERROR_ABNN}}{\text{ERROR_1NN}} \times 100\% \quad (14)$$

式中 ERROR_1NN 和 ERROR_ABNN 分别为单一神经网络误差和 AB-ANN 模型的误差。

表 2 分类器对样本的训练与测试误差比较

Table 2 The compare for MSE over training and testing cases

样本		样本 数目	单一神经 网络 MSE	AB-ANN MSE	精度提升 / %
3 因素	训练样本	31	0.229	0.101	55.8
	测试样本	5	0.151	0.112	25.9
4 因素	训练样本	23	0.170	0.122	28.3
	测试样本	3	0.254	0.122	52.1

(4) 讨论

①小数据集问题的处理办法

研究表明,对于传统神经网络算法,学习样本数量越大,测试的效果可能越好;而对于小数据集问题,传统的神经网络,测试效果可能不佳,且不稳定,表现一定的局限性。通过表 2 可以看出,本

文采用 AdaBoost 算法,较好地克服了小数据集对单一神经网络处理效果不佳的问题,分类精度得到了显著提高。

②神经网络“过学习”问题的解决

为了防止在每次迭代过程中神经网络过学习现象的出现,采用“留一法”对有放回的重采样数据集进行交叉验证^[16],实现神经网络的“早停规则”,避免了神经网络“过度学习”的现象,同时选取误差最小的网络作为所有训练样本的仿真输出,以此保证每次网络训练的优越性。

③样本的重采样技术

在试验过程中,对于一些难学习的样本分布权重会太大,而其他的学习样本相对就太小了,出现了“权值扩张”问题,因此必须对权值进行合理的控制。本文将高于 0.5 的样本分布权值变为平均权重,并对重采样获得的样本的重度进行控制,保证网络学习的有效性。本文算例中经过 40 次迭代后样本数据被重复采样频数状态如图 4 所示,可见,有些样本被选中的重复率比较高,为重点学习的样本,而有些样本相对较低,为最富信息样本,由于对权值进行了合理的控制,没有出现某些样本“频数过高”的现象。

④迭代次数 T 的确定


按照本文前面叙述,随着算法的迭代次数 T 的增加,其误差成指数下降,但实际试验中可以看出,随着迭代次数 T 的增加,训练样本的误差逐渐下降,开始的时候误差变化比较大,经过一定的迭代次数,绝大部分情况下,测试样本的误差变化不会有太大变化,基本趋于稳定状态,但是在少数情况下也会出现“过拟合”的状态,可能是弱分类器本身的不稳定性和学习样本集的选取的原因。由于数据样本比较少,在文中 T 取 40 次,可以得到比较满意的结果。

⑤结果输出的后处理


经过不断的迭代,若采用简单的加权方法将弱分类器输出线性组合,会导致结果偏小。根据组合算法中最后选取具有最大权重的分类作为最后输出结果的原则,对于输出的结果处理,不是简单的加权,而是采用激活函数输出的办法,其中采用下面的激活函数如下,这使最后输出结果在 $[0, 1]$ 间。

$$g(x) = \frac{1}{1 + 0.001 \times x^{-5}} \quad (15)$$

同时保证了实际分类结果的差异性,更好地说明分类结果的好坏及其得出正确分类与错误分类的可能性大小。



(a) 3 因素岩爆训练样本



(b) 4 因素岩爆训练样本

图 3 AB-ANN 模型中训练样本重复采样频数分布图

Fig.3 The resampled frequency of training samples in AB-ANN models

5 结 语

针对岩爆事例等级分类问题, 现有分类模型对于小样本数据集处理效果欠佳, 本文提出了一种岩爆事例等级分类的多神经网络集成的 AdaBoost 组合学习的数据挖掘新方法。该方法建模思路清晰、易操作, 建立的岩爆等级分类的预测模型弥补了传统的神经网络模型在学习过程中容易陷入局部极小和不稳定性缺点, 提高了分类预测的泛化能力和精度。同时, 在每次迭代过程中, 采用交叉验证的方法, 避免了神经网络“过学习”的现象, 保证了每次网络训练的优越性。经过多次试验表明, 岩爆训练和测试样本的分类精度能够得到很大的提升, 结果与实际比较吻合, 该方法具有较好推广能力和应用前景。

本文在收集岩爆事例数据时, 出现了部分数据缺失的现象, 在分类预测问题上对缺失数据岩爆事例样本如何处理亟待解决; 另外, AdaBoost 方法应用在其他异类型分类器的非线性组合的问题也有待实现。

参 考 文 献

- [1] BOARD M, FAIRHURST C. Rockbursts: Prediction and Control [M]. London: The Institution of Mining and Metallurgy, 1983: 81—90.
- [2] 冯夏庭. 智能岩石力学导论[M]. 北京: 科学出版社, 2000.
- [3] 宋建波, 张倬元, 于远忠, 等. 岩体经验强度准则及其在地质工程中的应用[M]. 北京: 地质出版社, 2002: 101—103.
- [4] 冯夏庭. 地下峒室岩爆预报的自适应模式识别方法[J]. 东北大学学报, 1994, 15(5): 471—475.
FENG Xia-ting. Adaptive pattern recognition to predict rockbursts in underground openings [J]. **Journal of Northeastern University**, 1994, 15(5): 471—475.
- [5] 王元汉, 李启光. 岩爆预测的模糊数学综合评判方法[J]. 岩石力学与工程学报, 1998, 17(5): 493—501.
WANFG Yuan-han, LI Qi-guang. Method of fuzzy comprehensive evaluations for rockburst prediction [J]. **Chinese Journal of Rock Mechanics and Engineering**, 1998, 17(5): 493—501.
- [6] 丁向东, 吴继敏, 李健, 等. 岩爆分类的人工神经网络预测方法[J]. 河海大学学报(自然科学版), 2003, 31(4): 424—427.
DING Xiang-dong, WU Ji-min, LI Jian, et al. Artificial neural network for forecasting and classification of rockbursts [J]. **Journal of Hohai University** (Natural Science), 2003, 31(4): 424—427.
- [7] 董志高, 吴继敏, 刘成君. 地下洞室岩爆预测计算方法综述[J]. 地质灾害与环境保护, 2002, 13(2): 6—9, 16.
DONG Zhi-gao, WU Ji-min, LIU Cheng-jun. Summary of computing methods of rockburst prediction of underground caverns [J]. **Journal of Geological Hazards and Environment Preservation**, 2002, 13(2): 6—9, 16.
- [8] 杨涛, 李维国. 基于先验知识的岩爆预测研究[J]. 岩石力学与工程学报, 2000, 19(4): 429—431.
YANG Tao, LI Wei-guo. Study on rockburst prediction method based on the prior knowledge [J]. **Chinese Journal of Rock Mechanics and Engineering**, 2000, 19(4): 429—431.
- [9] 冯夏庭, 赵洪波. 岩爆预测的支持向量机[J]. 东北大学学报(自然科学版), 2002, 23(1): 57—59.
FENG Xia-ting, ZHAO Hong-bo. Prediction of rockburst using support vector machine [J]. **Journal of Northeastern University** (Natural Science), 2002, 23(1): 57—59.
- [10] <http://cnki.whlib.ac.cn>.
- [11] BREMAN L. Bagging predictors [J]. **Machine Learning**, 1996, 26(2): 123—140.
- [12] FREUND Y, SCHAPIRE R E. A short introduction to boosting [J]. **Journal of Japanese Society for Artificial Intelligence**, 1999, 14(5): 771—780.
- [13] FREUND Y, IYER R, SCHAPIRE R E. et al. An Efficient Boosting Algorithm for Combining Preferences [J]. **Journal of Machine Learning Research**, 2003, (4): 933—969.
- [14] <http://www.boosting.org>.
- [15] 王新, 沈峥. Boosting 及其在数据挖掘中的应用[J]. 云南民族大学学报(自然科学版), 2004, 13(2): 91—94.
WANG Xin, SHEN Zheng. Boosting and its application in data mining [J]. **Journal of Yunnan Nationalities University** (Natural Sciences Edition), 2004, 13(2): 91—94.
- [16] SCHWENK H, BENGIO Y. Boosting Neural networks [J]. **Neural Computation**, 2000, 12(8): 1 869—1 887.
- [17] 周志华, 陈世福. 神经网络集成[J]. 计算机学报, 2002, 25(1): 1—8.
ZHOU Zhi-Hua, CHEN Shi-Fu. Neural network ensemble [J]. **Chinese Journal of Computers**, 2002, 25(1): 1—8.
- [18] MAGHOOLI K, MOIN M S. A new approach on multimodal biometrics based on combining neural networks using adaboost [J]. **European Conference on Computer Vision**, 2004: 332—341.
- [19] 于玲, 吴铁军. 集成学习: Boosting算法综述[J]. 模式识别与人工智能, 2004, 17(1): 52—59.
YU Ling, WU Tie-jun. Assemble learning: A survey of boosting algorithms [J]. **Pattern Recognition and Artificial Intelligence**, 2004, 17(1): 52—59.