

# 岩体爆破效应预测的一种新方法

苏国韶<sup>1,2</sup>, 宋咏春<sup>3</sup>, 燕柳斌<sup>1</sup>

(1. 广西大学 土木建筑工程学院, 广西 南宁 530004; 2. 中国科学院 岩土力学重点实验室, 湖北 武汉 430071;

3. 广西大学 机械工程学院, 广西 南宁 530004)

**摘要:** 高斯过程是一种最近发展起来新的机器学习技术, 对处理非线性复杂问题具有很好的适应性。岩体爆破效应与其影响因素之间是复杂的非线性关系, 针对传统方法的局限性, 提出一种基于高斯过程的岩体爆破效应预测的新方法, 建立相应的岩体爆破效应预测模型, 并应用于三峡工程坝区岩体爆破振动速度、爆破损伤深度与损伤半径的预测。通过三峡现场爆破试验数据, 建立训练数据集和测试数据集, 采用高斯过程方法建立爆破效应与影响因素之间的各影响因素之间的非线性映射关系。研究表明, 岩体爆破振动速度、爆破损伤深度与损伤半径的预测结果与现场试验结果比较吻合, 用高斯过程方法预测岩体爆破效应是科学可行的。与神经网络方法相比, 高斯过程方法具有算法参数自适应化的特点, 且适用于小样本问题, 预测精度高, 并易于实现, 具有良好的工程应用前景。

**关键词:** 岩石力学; 高斯过程; 机器学习; 爆破效应; 预测

**中图分类号:** TU 45

**文献标识码:** A

**文章编号:** 1000 - 6915(2007)增 1 - 3509 - 06

## A NEW METHOD FOR FORECASTING OF BLASTING EFFECT IN ROCK MASS

SU Guoshao<sup>1, 2</sup>, SONG Yongchun<sup>3</sup>, YAN Liubin<sup>1</sup>

(1. *College of Civil and Architecture Engineering, Guangxi University, Nanning, Guangxi 530004, China;*

2. *Key Laboratory of Rock and Soil Mechanics, Chinese Academy of Sciences, Wuhan, Hubei 430071, China;*

3. *Mechanical Engineering College, Guangxi University, Nanning, Guangxi 530004, China)*

**Abstract:** Gaussian process(GP) is a newly developed machine learning technology based on statistical theoretical fundamentals. It has become a powerful tool for solving highly nonlinear problems. Conventional methods for forecasting of blasting effect in rock mass often meet great difficulty since relationship between blasting effect and its influencing factors is highly complicated nonlinear one. A new method based on GP is proposed for forecasting of blasting effect in rock mass. The method is applied to blasting engineering of the Three Gorges project in China for forecasting of vibration speed, damage depth and damage radius in rock mass. The field experiments of rock blasting are preformed to obtain the training samples and test samples. Nonlinear mapping relationship between blasting effect and its influencing factors can be constructed by GP learning with the training samples. The prediction results for vibration speed, damage depth and damage radius in rock mass using the method are in good agreement with observations. The results of case studies show that the method is feasible, effective and simple to implement for forecasting of blasting effect prediction in rock mass. It has merits of self-adaptive parameters determination and better capacity for solving nonlinear small sample problems comparing with the artificial neural

**收稿日期:** 2007 - 04 - 18; **修回日期:** 2007 - 05 - 28

**基金项目:** 中国科学院岩土力学重点实验室开放研究基金资助项目(Z110601); 广西大学科研基金资助项目(X017019)

**作者简介:** 苏国韶(1973 -), 男, 博士, 1995年毕业于广西大学水利水电工程建筑专业, 现为讲师, 主要从事岩土工程与水利水电工程方面的教学与研究。E-mail: suguoshao@163.com

networks method. The good performance of GP model makes it very attractive for a wide range of application in geotechnical engineering.

**Key words:** rock mechanics; Gaussian process(GP); machine learning; blasting effect; forecast

## 1 引言

开挖爆破产生的地震效应对基岩、围岩和岩质边坡的稳定性及其承载能力有着极大的影响, 岩体爆破效应与其影响因素(如离爆破点的距离、炸药参数、岩体结构与力学特征参数等等)之间存在极其复杂的非线性关系, 岩石爆破振动响应已成为岩石力学界和工程爆破界亟待解决的关键问题<sup>[1]</sup>。对于爆破振动速度的识别, 目前大多采用给定基函数形式下的回归分析方法, 如萨多夫斯基公式、兰格霍尔兹公式等。这些经验公式中基函数的形式与预测精度有直接关系, 而对于较复杂的爆破方式, 基函数的确定以及相应系数的求解往往较困难。对于爆破损伤范围, 目前难以建立相应爆破动力学模型进行爆破损伤范围的准确预测, 也没有实用的经验方法。为此, 一些学者将模糊评价法、灰色关联分析法、神经网络等软科学方法引入该研究领域, 并在工程应用中展示了可喜的前景<sup>[2~7]</sup>。但由于问题的复杂性, 这些方法本身还存在着一些不完善之处。如在模糊、灰色分析中, 虽然能考虑一些定性描述, 但权值、隶属度函数、功效函数的确定仍然无法摆脱人为因素的影响; 神经网络是基于大样本的一种机器学习方法, 它的优化目标是基于经验风险最小化, 这只能保证学习样本点的估计误差最小, 其推广能力有一定的局限性。因此, 有必要进一步开展岩体爆破效应预测的新方法研究。

高斯过程(Gaussian process, GP)是目前国际上人工智能与机器学习领域的研究热点<sup>[8~13]</sup>, 它有着严格的统计学习理论基础, 对处理高维数、小样本、非线性等复杂的问题具有很好的适应性。与人工神经网络相比, 就理论上而言, 高斯过程等同于无限多节点的神经网络, 并具有容易实现的优点。实际上, 高斯过程是一个具有概率意义的核学习机, 可对预测输出做出概率解释, 建模者能对模型预测输出的不确定性进行评价。此外, 高斯过程的另外一个优点就是灵活的非参数推断, 具有自适应参数获取的特点, 无需通过人为经验确定或不断试算获得。

本文将高斯过程机器学习方法引入岩体爆破工

程中, 提出一种基于高斯过程的岩体爆破效应的预测方法, 并通过工程应用验证该方法的可行性, 为岩体爆破效应的准确预测提供一条新的途径。

## 2 GP 基本原理

GP 是在贝叶斯学习原理与高斯随机过程与基础上新近发展起来的一种机器学习方法<sup>[14]</sup>, 其基本原理简介如下:

在统计理论中, GP 属随机过程中的一种, 其任意有限变量集合的分布都是高斯分布, 即对任意整数  $n \geq 1$  及任意的一族随机变量  $t_1, t_2, \dots, t_n \in T$ , 与其对应的  $t$  时刻的过程状态  $f(t_1), f(t_2), \dots, f(t_n)$  的联合概率分布服从  $n$  维高斯分布。GP 的全部统计特征完全由它的均值  $m(t)$  和协方差函数  $k(t, t')$  来确定, GP 可由下式定义:

$$f(t) \sim GP(m(t), k(t, t')) \quad (1)$$

假设有  $n$  个观察数据的训练集  $D = \{(x_i, y_i) | i = 1, 2, \dots, n, d \text{ 维输入矢量 } x_i \in \mathbf{R}^d, \text{ 相应的输出标量 } y_i \in \mathbf{R}\}$ 。如果  $X$  表示  $d \times n$  维输入矩阵,  $y$  表示输出矢量, 那么训练集  $D = (X, y)$

对于新的输入  $x_*$ , GP 模型的任务是根据先验知识预测出与  $x_*$  相对应的输出值  $y_*$ 。

假设观察目标值  $y$  被噪声腐蚀, 它与真实输出值  $t$  相差  $\varepsilon$ :

$$y = t + \varepsilon \quad (2)$$

式中:  $\varepsilon$  为独立的随机变量, 符合高斯分布, 均值为 0, 方差为  $\sigma_n^2$ , 即

$$\varepsilon \sim N(0, \sigma_n^2) \quad (3)$$

观察目标值  $y$  的先验分布为

$$y \sim N(0, K + \sigma_n^2 I) \quad (4)$$

式中:  $K$  为  $n \times n$  阶对称正定的协方差矩阵, 且  $K = K(X, X)$  矩阵中的任一项  $K_{ij}$  度量了  $x_i$  和  $x_j$  的相关性。

$n$  个训练样本输出  $y$  和 1 个测试样本输出  $y_*$  所形成的联合高斯先验分布为

$$\begin{Bmatrix} y \\ y_* \end{Bmatrix} \sim \begin{bmatrix} K(X, X) + \sigma_n^2 I & K(X, x_*) \\ K\{X, x_*\}^T & k(x_*, x_*) \end{bmatrix} \quad (5)$$

式中:  $\mathbf{K}(\mathbf{X}, \mathbf{x}_*)$  为测试点输入  $\mathbf{x}_*$  与训练集的所有输入点  $\mathbf{X}$  的  $n \times 1$  阶协方差矩阵,  $\mathbf{k}(\mathbf{x}_*, \mathbf{x}_*)$  为测试点输入  $\mathbf{x}_*$  自身的协方差。

GP 模型根据贝叶斯学习原理在训练集的基础上预测出与  $\mathbf{x}_*$  对应的最可能的输出值。贝叶斯分析的目的在于利用观察到的特定数据的基础上更新分布, 即给定新的输入  $\mathbf{x}_*$ 、训练集的输入值  $\mathbf{X}$  和观察目标值  $\mathbf{y}$  的条件下, 推断出  $\mathbf{y}_*$  的最大可能的预测分布  $p(\mathbf{y}_* | \mathbf{x}_*, \mathbf{X}, \mathbf{y})$ 。根据贝叶斯方法, 可获得  $n$  个训练样本输出  $\mathbf{y}$  和测试样本输出  $\mathbf{y}_*$  的联合高斯后验分布。在获得训练集的观察目标值  $\mathbf{y}$  的条件下, 预测分布是高斯型的, 即

$$\mathbf{y}_* | \mathbf{x}_*, \mathbf{X}, \mathbf{y} \sim N(\hat{\mathbf{y}}(\mathbf{x}_*), \hat{\sigma}(\mathbf{x}_*)) \quad (6)$$

则  $\mathbf{y}_*$  的均值和方差为

$$\hat{\mathbf{y}}(\mathbf{x}_*) = \mathbf{k}^\top(\mathbf{x}_*)(\mathbf{K} + \sigma_n^2 \mathbf{I})^{-1} \mathbf{y} \quad (7)$$

$$\hat{\sigma}(\mathbf{x}_*) = \mathbf{k}(\mathbf{x}_*, \mathbf{x}_*) - \mathbf{k}^\top(\mathbf{x}_*)(\mathbf{K} + \sigma_n^2 \mathbf{I})^{-1} \mathbf{k}(\mathbf{x}_*) \quad (8)$$

式中:  $\mathbf{k}(\mathbf{x}_*)$  为  $n \times 1$  阶协方差矩阵,  $\mathbf{k}(\mathbf{x}_*) = \mathbf{K}(\mathbf{X}, \mathbf{x}_*)$ , 即  $\{\mathbf{k}(\mathbf{x}_1, \mathbf{x}_*), \dots, \mathbf{k}(\mathbf{x}_n, \mathbf{x}_*)\}^\top$ 。

GP 可选择不同的协方差函数。协方差函数需要满足: 对任一点集都能够保证产生一个非负正定协方差矩阵。采用的协方差函数如下:

$$k_y(x_p, x_q) = \sigma_f^2 \exp\left[-\frac{1}{2l^2}(x_p - x_q)^2\right] + \sigma_n^2 \delta_{pq} \quad (9)$$

式中:  $\sigma_f$ ,  $l$ ,  $\sigma_n$  均为超参数, 这与神经网络中的超参数含义类似。协方差函数由 2 部分组成: 第 1 部分用来表示 2 个数据点的距离相关性: 如果它们的距离相对于距离尺度  $l$  很小, 即两个数据点高度相关, 指数项就趋于 1; 反之, 如果它们的距离相对于距离尺度  $l$  很大, 即为两个数据点低度相关, 指数项就趋于 0。这一点与自动相关测定(automatic relevant determination)的思想一致。参数  $\sigma_f^2$  用来控制局部相关性的程度。第 2 部分用来考虑数据中的噪声, 其中  $\sigma_n^2$  用来表示噪声的方差。超参数可通过训练样本的对数似然的极大化(最大后验分布)获得, 即通过似然函数求超参数偏导, 再采用共轭梯度优化方法搜索出超参数的最优解, 优化过程中, 为避免陷入局部最优, 随机产生若干个初始值进行试算。其中, 似然函数的对数形式为

$$L = \lg p(\mathbf{y} | \mathbf{X}) = -\frac{1}{2} \mathbf{y}^\top (\mathbf{K} + \sigma_n^2 \mathbf{I})^{-1} \mathbf{y} - \frac{1}{2} \lg |\mathbf{K} + \sigma_n^2 \mathbf{I}| - \frac{n}{2} \lg(2\pi) \quad (10)$$

由于 GP 方法中协方差函数在所有输入点的有限集上是正定的要求与 Mercer 核的性质吻合, 故协方差函数等价于核函数。设  $\mathbf{a} = (\mathbf{K} + \sigma_n^2 \mathbf{I})$ , 式(7)可写核函数的形式:

$$\hat{\mathbf{y}}(\mathbf{x}_*) = \sum_i^n \alpha_i \mathbf{k}(\mathbf{x}_i, \mathbf{x}_*) \quad (11)$$

式(11)表明, 预测值的均值是核函数  $\mathbf{k}(\cdot)$  的线性组合。核函数的作用是将非线性关系的数据映射到特征空间后转换成为为线性关系的数据, 从而使复杂非线性问题转化为容易处理的线性问题。因此, GP 也可被理解成为一种有概率意义的核学习机。

### 3 岩体爆破效应预测的 GP 模型

#### 3.1 岩体爆破效应的影响因素

岩体爆破效应受多种控制因素的影响, 根据工程经验, 爆破振动速度主要受爆破距离和爆破药量的影响, 而爆破损伤范围(损伤半径和损伤深度)主要受爆破药量、抵抗线、岩体抗拉强度、岩体弹性模量、岩体平均波速等诸多因素的影响。

#### 3.2 建立岩体爆破效应预测的 GP 模型

(1) 根据实地爆破测量多个爆破实例作为训练样本。GP模型的输入样本对可记为:  $(\mathbf{x}_i, y_i)$ ,  $i = 1, 2, \dots, k$ ,  $\mathbf{x}_i \in \mathbf{R}^n$ 。其中,  $\mathbf{x}_i$  为模型的  $n$  维输入矢量, 代表爆破效应的若干个影响因素;  $y_i$  为与  $\mathbf{x}_i$  相对应的标量, 代表爆破效应特征;  $\mathbf{R}^n$  为影响爆破效应的因素集。

(2) 当影响爆破效应的各因素间的数量级相差较大或同一控制因素的离散性较大时, 将不利于 GP 的学习, 需要对参与学习的样本数据和预测样本数据进行标准化处理:

$$p_i = x_i / s \quad (12)$$

式中:  $x_i$  为第  $i$  个指标;  $p_i$  为标准化后的值;  $s =$

$$\left( \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2 \right)^{\frac{1}{2}}, \quad \bar{x} = \frac{1}{n} \sum_{i=1}^n x_i。$$

(3) 对训练样本进行学习, 通过训练样本对数似然(式(10))的极大化获得最优的超参数。

(4) 将最优超参数代入式(9), 根据式(7)或(11)可获得测试样本  $\mathbf{x}_*$  (不同的爆破条件) 相对应的爆破效应的预测值  $\mathbf{y}_*$ 。

根据上述模型的建立步骤, 采用 MATLAB 语言编制了相应的计算程序。

## 4 工程应用研究

为验证本文方法的可行性, 根据三峡工程左岸坝区现场爆破试验的实测资料<sup>[15]</sup>, 采用岩体爆破效应的 GP 模型, 分别进行爆破振动速度预测以及爆破损伤深度和损伤半径预测的工程应用研究。

### 4.1 爆破振动速度预测

在三峡工程坝区共进行 6 次实地爆破, 每次爆破设有距离不同的 6 个测点, 共获得 36 个样本, 其中前 30 个样本作为 GP 预测模型的训练样本, 如表 1 所示; 后 6 个作为预测样本, 如表 2 所示。

表 1 三峡坝区爆破振动速度的实测资料

Table 1 Vibration speed measured from blasting experiments in the Three Gorges dam region

GP 预测模型序号	距离/m	药量/kg	振动速度/(cm · s <sup>-1</sup> )
1	2.80	1.00	3.85
2	5.80	1.00	0.77
3	8.95	1.00	0.47
4	12.00	1.00	0.25
5	14.80	1.00	0.09
6	17.80	1.00	0.04
7	2.14	1.40	12.55
8	8.34	1.40	1.39
9	11.34	1.40	0.59
10	14.14	1.40	0.40
11	17.20	1.40	0.30
12	20.20	1.40	0.21
13	2.00	0.80	11.4
14	5.00	0.80	1.70
15	8.00	0.80	0.83
16	11.00	0.80	0.25
17	14.00	0.80	0.15
18	17.00	0.80	0.11
19	2.10	1.80	11.89
20	5.10	1.80	1.58
21	8.10	1.80	0.80
22	11.80	1.80	0.21
23	13.90	1.80	0.11
24	17.00	1.80	0.09
25	2.10	2.60	16.18
26	5.20	2.60	6.02
27	8.30	2.60	2.39
28	11.11	2.60	0.82
29	14.00	2.60	0.36
30	17.00	2.60	0.26

对训练样本进行学习, 以训练样本的极大似然为目标, 设超参数初始值为  $l=(1, 1)$ ,  $\sigma_f=0.1$ ,  $\sigma_n=0.1$ , 采用共轭梯度优化算法搜索最优超参数。收敛标准设为最大迭代步数为 200 或迭代步之间的目标值的差值(取绝对值)小于  $1.0 \times 10^{-6}$ 。

GP 模型预测样本的预测结果见表 2。表 2 中还分别列举了萨氏公式, 回归分析方法、BP 神经网络算法、前馈神经网络算法的预测结果及其相对误差<sup>[15]</sup>。

从表 2 中可以看出, GP 模型的平均相对误差为 3.6%, 预测精度明显优于萨氏公式、回归分析法和 BP 神经网络法, 稍稍优于前馈神经网络法。值得一提的是, 前馈神经网络方法的隐含层节点数目对网络的预报精度和学习性能有明显的影 响, 当隐含层节点数小于 10 时, 学习达不到预定精度, 预测结果亦不及回归分析法<sup>[15]</sup>, 凭经验得到的隐含层节点数不能保证是最优值。相反, GP 方法具有超参数自适应化特点, 无需人工设置超参数值。因此, 总的来说, GP 方法的预测性能优于前馈神经网络方法。

### 4.2 爆破损伤范围预测

三峡工程坝区现场爆破试验的岩体损伤深度与损伤半径的实测资料<sup>[15]</sup>如表 3 所示。

取表 3 中前 5 个样本作为 GP 模型的训练样本, 第 6 个样本作为预测样本。岩体爆破效应的 GP 模型中, 以爆破药量、抵抗线、岩体抗拉强度、岩体弹性模量、岩体平均波速等影响因素作为输入值, 以岩体损伤深度或岩体损伤半径为输出值, 超参数初始值均设为  $l=(1, 1)$ ,  $\sigma_f=0.1$ ,  $\sigma_n=0.1$ , 收敛标准设为最大迭代步数为 200 或迭代步之间的目标值的差值(取绝对值)小于  $1.0 \times 10^{-6}$ 。

不同方法的预测结果见表 4。从表 4 可以看出, 无论是岩体损伤深度还是岩体损伤半径的预测值, 与 BP 神经网络与前馈神经网络方法相比, GP 模型的预测相对误差均较小。其中, 对于岩体损伤深度的预测, BP 神经网络与前馈神经网络的预测相对误差分别为 23.4%和 14.8%, 而 GP 模型的预测相对误差较低为 10.7%; 特别是对于岩体损伤半径的预测, 由于学习样本较少, BP 神经网络与前馈神经网络的预测误差均高于 10.0%, 而 GP 模型的相对误差仅为 1.7%, 由此说明, 对于小样本问题, GP 模型的预测精度明显高于神经网络方法。

表 2 岩体爆破振动速度的不同方法预测结果对比

Table 2 Comparison of forecasting results of vibration speed in rockmass among different methods

样本序号	距离 /m	药量 /kg	实测振动速度 / $(\text{cm} \cdot \text{s}^{-1})$	萨氏公式 <sup>[15]</sup>		回归分析 <sup>[15]</sup>		BP 神经网络 <sup>[15]</sup>		前馈神经网络 <sup>[15]</sup>		GP 模型	
				预测振动速度 / $(\text{cm} \cdot \text{s}^{-1})$	相对误差/%	预测振动速度 / $(\text{cm} \cdot \text{s}^{-1})$	相对误差/%	预测振动速度 / $(\text{cm} \cdot \text{s}^{-1})$	相对误差/%	预测振动速度 / $(\text{cm} \cdot \text{s}^{-1})$	相对误差/%	预测振动速度 / $(\text{cm} \cdot \text{s}^{-1})$	相对误差/%
31	2.00	1.20	12.32	15.66	28.1	12.10	1.8	12.50	2.2	12.17	1.0	12.20	1.0
32	5.00	1.20	2.21	1.75	20.8	2.47	11.8	1.80	18.5	2.05	7.2	2.11	4.5
33	8.00	1.20	0.59	0.16	3.4	0.67	13.6	0.63	6.8	0.61	3.4	0.57	4.2
34	11.00	1.20	0.42	0.27	35.7	0.38	9.5	0.45	7.1	0.40	4.8	0.45	7.1
35	14.00	1.20	0.18	0.15	16.7	0.20	11.1	0.20	11.1	0.19	5.6	0.17	5.6
36	17.00	1.20	0.05	0.09	80.0	0.05	0.0	0.09	80.0	0.05	0.0	0.05	0.0
平均相对误差/%					30.8		8.0		21.0		3.7		3.6

表 3 三峡坝区岩体爆破深度和损伤半径的实测资料

Table 3 Damage depth and damage radius in rock mass measured in the Three Gorges dam region

样本序号	药量/kg	抵抗线/m	抗拉强度/MPa	弹性模量/MPa	平均滤波速度/ $(\text{cm} \cdot \text{s}^{-1})$	损伤深度/cm	损伤半径/m
1	1.0	1.8	1.5	40	3 092	30	1.4
2	1.4	1.8	1.5	40	3 464	45	1.7
3	0.8	1.7	1.2	35	3 317	20	1.6
4	1.2	2.2	1.2	35	3 415	35	1.7
5	2.6	2.0	1.2	35	3 375	70	2.0
6	1.8	1.8	1.2	35	3 242	50	1.8

表 4 岩体爆破损伤深度与损伤半径的不同方法预测结果对比

Table 4 Comparison of forecasting results of damage depth and damage radius in rock mass among different methods

方法	损伤深度		损伤半径	
	预测值/cm	相对误差/%	预测值/m	相对误差/%
BP 神经网络	61.70	23.4	1.54	14.4
前馈神经网络	57.40	14.8	1.61	10.6
GP 模型	55.37	10.7	1.83	1.7

### 5 结 论

(1) 岩体爆破效应与其影响因素之间的关系是高维度的复杂非线性关系, 用传统的理论分析或数值建模方法很难处理。GP 模型能很好地处理这种关系, 本文将高斯方法引入该领域的研究, 提出了基于 GP 模型的岩体爆破效应预测的新方法。工程

应用结果表明, 该方法是科学可行的, 预测精度高。

(2) 与神经网络方法相比, GP 模型具有算法参数自适应化的特点, 算法更简洁且易于实现, 且适用于小样本问题, 克服了神经网络方法最优隐含层及其节点数难以确定的不足, 有效地提高了岩体爆破效应预测的精度和效率。

(3) GP模型具有严格的统计学习理论基础、优秀的自学习和推广预测功能、实现容易等优点, 使得GP在处理非线性问题方面具有良好的适应性, 鉴于岩石动力学中大量存在的尚未得到很好解决的非线性问题, GP模型在岩石动力学方面具有良好的应用前景。

### 参考文献(References):

[1] 黄理兴, 陈奕柏. 我国岩石动力学研究状况与发展[J]. 岩石力学与工程学报, 2003, 22(11): 1 881 - 1 886.(HUANG Lixing, CHEN Yibai. Rock dynamics in China: past, present and future[J]. Chinese Journal

- of Rock Mechanics and Engineering, 2003, 22(11): 1 881 - 1 886.(in Chinese))
- [2] 陈超, 甘德清, 张云鹏. 预裂爆破效果的综合模糊评价模型[J]. 河北理工学院学报, 2001, 23(4): 14 - 18.(CHEN Chao, GAN Deqing, ZHANG Yunpeng. The fuzzy synthesise model of evaluating blasting effect[J]. Journal of Hebei Institute of Technology, 2001, 23(4): 14 - 18.(in Chinese))
- [3] 杨溢, 张智宇, 庙延钢, 等. 灰色关联分析在预裂爆破振动分析中的应用[J]. 云南冶金, 2001, 30(5): 1 - 3.(YANG Yi, ZHANG Zhiyu, MIAO Yangang, et al. Application of gray association analysis for analyzing vibration in presplitting blasting[J]. Yunnan Metallurgy, 2001, 30(5): 1 - 3.(in Chinese))
- [4] ZHU H B, WU L. Application of gray correlation analysis and artificial neural network in rock mass blasting[J]. Journal of Coal Science and Engineering, 2005, 11(1): 44 - 47.
- [5] 许全军, 刘强, 聂渝军, 等. 爆破地震峰值预报神经网络研究[J]. 爆炸与冲击, 1999, 19(2): 133 - 138.(XU Quanjun, LIU Qiang, NIE Yujun, et al. Study on neural network prediction on peak particle amplitude of blasting ground vibration[J]. Explosion and Shock Waves, 1999, 19(2): 133 - 138.(in Chinese))
- [6] 陈德志, 朱瑞庚, 徐顺香. 基于BP神经网络的路堑爆破对邻近民房安全预测的研究[J]. 岩石力学与工程学报, 2002, 21(增2): 2 554 - 2 557(CHEN Dezhi, ZHU Ruigeng, XU Shunxiang. BP neural network study on safety prediction for civil houses adjacent to roadcut blasting[J]. Chinese Journal of Rock Mechanics and Engineering, 2002, 21(Supp.2): 2 554 - 2 557.(in Chinese))
- [7] 王长友, 唐又驰, 刘涛. 光面爆破效果BP神经网络预测[J]. 辽宁工程技术大学学报, 2005, 24(1): 73 - 75.(WANG Changyou, TANG Youchi, LIU Tao. Study on forecasting smooth-surface blasting effects based on BP neural network[J]. Journal of Liaoning Technical University, 2005, 24(1): 73 - 75.(in Chinese))
- [8] MACKAY D J C. Introduction to Gaussian processes[R]. Cambridge: Cavendish Laboratory, Cambridge University, UK, 1998.
- [9] WILLIAMS C K I. Prediction with Gaussian processes: from the linear regression to linear prediction and beyond[C]// Learning and Inference in Graphical Models.[S. l.]: Kluwer Academic Press, 1998: 599 - 621.
- [10] SEEGER M. Gaussian processes for machine learning[J]. International Journal of Neural System, 2004, 14(2): 69 - 106.
- [11] CASTO L, OPPER M. Sparse online Gaussian process[J]. Neural Computation, 2002, 14(3): 641 - 668.
- [12] BRAHIM-BELHOUARI S, BERMAK A. Gaussian process for nonstationary times series prediction[J]. Computational Statistics and Data Analysis, 2004, 47(4): 705 - 712.
- [13] 熊志化, 张继承, 邵惠鹤. 基于高斯过程的软测量建模[J]. 系统仿真学报, 2005, 17(4): 793 - 794, 800.(XIONG Zhihua, ZHANG Jicheng, SHAO Huihe. GP-based soft sensor modeling[J]. Journal of System Simulation, 2005, 17(4): 793 - 794, 800.(in Chinese))
- [14] RASMUSSEN C E, WILLIAMS K I. Gaussian processes for machine learning[M]. Massachusetts: MIT Press, 2006.
- [15] 蔡德所. 基于前馈网络的岩体爆破效应预测研究[J]. 岩土工程学报, 1997, 19(1): 43 - 49.(CAI Desuo. Forecast research on effect of vibration and damage in rock mass blasting[J]. Chinese Journal of Geotechnical Engineering, 1997, 19(1): 43 - 49.(in Chinese))