

GA-SVM 和神经网络组合模型预测 充填钻孔寿命

张钦礼, 程健, 陈秋松, 胡威, 周碧辉

中南大学资源与安全工程学院, 长沙 410083

摘要 充填钻孔是充填料浆从地表输送到井下采场的咽喉工程,是矿山正常运转的保障,因此对矿山充填钻孔使用寿命进行预测十分重要。通过建立支持向量机(SVM)和BP神经网络组合预测模型,用训练集对模型进行训练,以验证集预测值的均方误差作为SVM适应度函数,通过遗传算法(GA)对SVM模型参数进行优化选择,应用优化得到的SVM模型进行预测,并结合BP神经网络进行残差修正,最终得到预测结果。以某矿为例,通过GA得到SVM模型最优参数:适应值(均方误差mse)=0.0111,惩罚系数 $C=47.0768$,核函数参数 $\sigma=2.2638$ 。通过优化的SVM模型,对预测集充填钻孔寿命进行预测,经BP神经网络残差修正,预测结果的相对误差均控制在3%左右。对比单一预测模型,组合预测模型预测结果更加理想,精度更高,在类似的预测工程中有良好的推广价值。

关键词 充填钻孔寿命;支持向量机;遗传算法;神经网络

中图分类号 TD853

文献标志码 A

doi 10.3981/j.issn.1000-7857.2013.34.006

Prediction of Backfill Drill-hole Life Based on Combined Model of GA-SVM and Neural Network

ZHANG Qinli, CHENG Jian, CHEN Qiusong, HU Wei, ZHOU Bihui

School of Resources and Safety Engineering, Central South University, Changsha 410083, China

Abstract The backfill of a drill-hole is a throat engineering process in which the filling slurry is transported to the underground stope from the surface to ensure the safety of the mine normal operation. To predict the service life of the mine backfill drill-hole, a combination forecasting model of the Support Vector Machine (SVM) and the BP neural network is established in this paper. The mean square error of the value is taken as a fitness function of the SVM. Then, the SVM model parameters are optimized through the Genetic Algorithm (GA). Then, the optimized SVM is applied to predict the prediction set. The final forecast result is obtained by means of the revision of the residual error through the BP neural network. A certain mine is taken as an example, its drill-hole life is predicted through the combination forecasting model, and the optimal parameters are obtained. The adaptive value (mean square error mse) is 0.0111; the penalty coefficient C is 47.0768; the kernel function parameter σ is 2.2638. The accuracy of the model is analyzed. The relative error of the predicted results is about 3%. Compared with the single prediction model, the combination forecasting model enjoys a higher accuracy.

Keywords backfill drill-hole life; support vector machine; genetic algorithm; neural network

0 引言


如何在环境不受破坏的前提下合理高效利用矿产资源,是当今社会各界的关注重点。在此情境下,充填采矿法应运而生。充填采矿法具有回收率高、贫化率低、可有效控制低压活动等优点,能安全环保、高效地回采矿产资源,并为回收难采矿产资源和边界经济矿产资源提供了可能^[1,2]。然而,在采

用充填采矿法的矿山(尤其是深井开采的矿山)势必会遇到充填钻孔使用寿命的问题。充填钻孔作为充填料浆的专属通道,承受了充填料浆的腐蚀与冲刷作用,容易造成破损堵塞,甚至钻孔报废。且充填钻孔一旦破坏,就很难再恢复。而充填钻孔的损坏会影响矿山充填和采矿工艺的衔接,甚至会影响矿山正常的生产。因此,对充填钻孔的寿命进行预测,提前对

收稿日期:2013-05-06;修回日期:2013-08-16

基金项目:国家科技支撑计划项目(2006BAB02A03,2006BA02B05)

作者简介:张钦礼,教授,研究方向为采矿、充填及安全等,电子邮箱:zhangqinli@126.com



钻孔进行修复,是维护矿山正常生产的重要环节^[3]。

传统的预测分析方法主要有线性回归分析法、灰色关联法、时间序列分析法等。随着大型模拟计算软件的推广,支持向量机(SVM)和BP神经网络等方法也被广泛运用于分析预测。充填钻孔寿命的预测是一个复杂的系统工程,由于不同预测模型具有不同的信息、不同的假设条件和不同的预测范围,若单独采用一种预测模型,则可能无法全面反映实际情况,造成预测不够准确。而合理地多个预测模型进行组合,充分利用现有信息,能够提高预测的精度^[4]。鉴于此,本文针对充填钻孔寿命预测问题,将SVM和BP神经网络组合,建立SVM-BP神经网络预测模型,并结合遗传算法(GA)对SVM参数进行优化,以提高对充填钻孔寿命预测的准确性。

1 BP神经网络算法

1.1 BP神经网络处理信息的基本原理

BP神经网络^[5-7]是一种由信号前向传递和误差反向传递两个过程组成的多层前馈神经网络。前向传播时,产生输出信号,通过反向传播,缩小网络输出值与期望输出值之间的偏差,经反复学习训练,确定与最小误差相对应的网络参数。

1.2 BP神经网络学习算法

首先给网络输入一组样本,通过不断训练该网络,使其调整、修正各神经元的权值和阈值,直到网络输出能够准确地逼近给定训练样本的输出时,该网络完成训练过程。设给定 N 个样本对 $(X_k, Y_k) (k=1, 2, \dots, N)$, 从输入层到隐层及从隐层到输出层的传递函数 f 采用 Sigmoid 函数,即

$$f(x) = \frac{1}{1 + \exp(-x)} \quad (1)$$

对于第 l 层的第 i 个单元,当输入第 m 个样本时,正向传播的函数为

$$ne_{ij}^l = \sum_j W_{ij}^l O_m^j + \theta_j^l \quad (2)$$

式中, W_{ij}^l 为隐层第 j 个神经元与输入层第 i 个神经元之间的连接权值; O_m^j 为输入第 m 个样本时第 j 个神经元的输出值; θ_j^l 为隐层节点 j 的阈值。

BP网络的连接权值和阈值的调整过程就是误差的反向传播过程。定义误差函数为

$$E_k = \frac{1}{2} \sum_i (Y_{jk} - \bar{Y}_{jk})^2 \quad (3)$$

式中, Y_{jk} 、 \bar{Y}_{jk} 分别为输出层节点 k 的期望输出和实际输出。

总误差为

$$E = \frac{1}{2N} \sum_{k=1}^N E_k \quad (4)$$

任意选取权系数初值,隐层与输入层的权值 W_{ij} 调整量为

$$W_{ij} = W_{ij} - \mu \frac{\partial E}{\partial W_{ij}} \quad (5)$$

$$\frac{\partial E}{\partial W_{ij}} = \sum_{k=1}^N \frac{\partial E_k}{\partial W_{ij}} \quad (6)$$

式中, $\mu (0 \leq \mu \leq 1)$ 为学习速率。

同理可得隐层与输入层,及隐层与输出层之间的阈值调整量。重复上述正向和反向传播过程直到 $E < \varepsilon$ (ε 为给定精度)。

2 基于GA优化的SVM算法

2.1 支持向量机算法

SVM^[8-10]是由Vapnik等在结构风险最小和VC维理论等统计学理论原理的基础上提出的一种新的学习算法。该方法具有通用性强、计算简单、有效性和鲁棒性强等优点,可以实现对小样本高维、非线性系统准确的拟合,在手写识别、脸部识别、文本分类、回归建模与预测等方面运用较多并取得较好效果。

已知给定样本集 $S = \{(x_1, y_1), (x_2, y_2), \dots, (x_l, y_l)\}$, l 为样本数目, x_i 和 y_i 分别为输入向量和对应的输出向量, $x_i \in R^n$, $y_i \in R (i=1, 2, \dots, l)$, n 为 x_i 向量维数, R 为实数集。对于非线性问题,首先通过非线性变换将样本集中的输入向量映射到高维特征空间,再在高维特征空间内构造最优的线性回归函数,即

$$f(x, \alpha) = \omega x + b \quad (7)$$

使得 $|y_i - f(x_i)| \leq \varepsilon (i=1, 2, \dots, l)$, ε 为任意小的数, α 为拉格朗日乘子, ω 为权向量, b 为偏置量,成立。 S 中的点到 $f(x)$ 的距离 d_i 为

$$d_i = \frac{|\langle \omega, x_i \rangle + b - y_i|}{\sqrt{1 + \|\omega\|^2}} \quad (8)$$

于是有

$$d_i \leq \frac{\varepsilon}{\sqrt{1 + \|\omega\|^2}} \quad (i=1, 2, \dots, l) \quad (9)$$

所以通过最大化 d_i , 即最小化 $\|\omega\|^2$, 就可得到最优 $f(x)$, 此时回归问题转化为优化问题,考虑到可能误差,引入松弛变量 $\xi_i, \xi_i^* \geq 0 (i=1, 2, \dots, l)$, 优化方程为

$$\min \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^l (\xi_i + \xi_i^*) \quad (10)$$

约束为

$$f(x_i) - y_i \leq \xi_i + \varepsilon \quad (i=1, 2, \dots, l) \quad (11)$$

$$y_i - f(x_i) \leq \xi_i + \varepsilon \quad (i=1, 2, \dots, l) \quad (12)$$

$$\xi_i, \xi_i^* \geq 0 \quad (i=1, 2, \dots, l) \quad (13)$$

式中, C 为惩罚因子。

引入拉格朗日函数

$$L(\omega, b, \xi) = \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^l (\xi_i + \xi_i^*) -$$

$$\sum_{i=1}^l \alpha_i [\xi_i + \varepsilon - y_i + \langle \omega, x_i \rangle + b] -$$

$$\sum_{i=1}^l \alpha_i^* [\xi_i^* + \varepsilon + y_i - \langle \omega, x_i \rangle - b]$$

$$\sum_{i=1}^l (\gamma_i \xi_i + \gamma_i^* \xi_i^*) \quad (14)$$

式中, γ 为拉格朗日乘子。

式(8)分别对 ω, ξ, b 求偏微分, 可得

$$\begin{cases} \omega = \sum_{i=1}^l (\alpha_i - \alpha_i^*) x_i \\ \sum_{i=1}^l (\alpha_i - \alpha_i^*) x_i = 0 \\ C - \alpha_i - \gamma = 0 \quad (i=1, 2, \dots, l) \\ C - \alpha_i - \gamma_i^* = 0 \quad (i=1, 2, \dots, l) \end{cases} \quad (15)$$

消去 ω, γ , 求出 α 后, 可得 $f(x)$ 的表达式为

$$f(x) = \sum_{i=1}^l (\alpha_i - \alpha_i^*) [h(x)h(x_i)] + b \quad (16)$$

由于仅需计算特征空间中的向量之间的内积, 故根据 Hilbert-Schmidt 理论, 引入核函数 $K(x, x_i) = h(x)h(x_i)$ ^[11], 代入式(16)得到 $f(x)$ 的表达式

$$f(x) = \sum_{i=1}^l (\alpha_i - \alpha_i^*) K(x, x_i) + b \quad (17)$$

这就避免了造成“维数灾难”。目前常用的核函数有 10 多种, 而高斯核函数 (RBF): $k(x, x_i) = \exp(-\|x - x_i\|^2 / 2\sigma^2)$, σ 为核函数参数, 经验证, 可使 SVM 获得非常平滑的估计。

2.2 SVM 参数优化

Vapnik 等在研究中发现, 核函数的参数 σ 和惩罚因子 C 是影响 SVM 模型性能的关键因素。因为核函数参数 σ 影响样本数据在高维特征空间, 惩罚因子 C 则在特征空间中调节 SVM 的置信范围和经验风险的比例^[12], 而交叉概率 p 影响算法的收敛速度及结果的随机性。换言之, SVM 模型的性能依赖于参数之间的相互作用, 需同时优化全部参数。

遗传算法 (Genetic Algorithm, GA) 是一类借鉴生物界的进化规律 (适者生存, 优胜劣汰遗传机制) 演化而来的随机化搜索方法。它由美国科学家 Holland 1975 年首先提出, 其主要特点是: 直接以函数值作为目标进行搜索, 从而提高了搜索效率; 同时对多个点进行搜索; 具有内在的隐并行性和强大的获得全局最优解能力^[13, 14]。基于上述特点, 运用 GA 对所建 SVM 模型进行参数优选, 确定以预测值的均方误差作为遗传寻优的适应度函数, 适应度越小预测值越精确, 寻找到的 SVM 模型参数就越优, 模型就越好。

具体优化步骤如下:

- (1) 采用通用的二进制编码法, 将 SVM 相关参数的二进制编码随机组合构成 n 组染色体;
- (2) 选择合适的参数, 包括群体大小 M (一般取 20~100), 遗传代数 T (一般取 100~500), 依据实际数据复杂程度进行选择;
- (3) 确定适应值函数: 根据 SVM 回归预测模型, 要想得到精度高的回归函数, 必须使预测值与实际值的误差尽量小, 使回归曲线与实际曲线贴近, 因此确定把均方误差作为适应值函数。显然, 适应值越小, 模型越精确;

- (4) 随机生成群体;
- (5) 进行遗传迭代, 直到满足停止条件, 得到最优 SVM 参数。整个算法流程如图 1 所示。

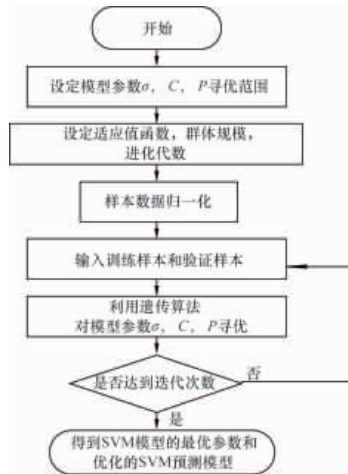


图 1 GA-SVM 流程
Fig. 1 Flowchart of GA-SVM

3 组合预测模型建立

虽然 SVM 模型和 BP 神经网络模型在预测分析方面都得到了很好的运用, 但由于不同模型都包含了一定的样本信息, 单独一个模型难以全面反映变量的变化规律, 所预测的结果精度不够。而将两种模型进行有机组合, 充分利用现有信息, 能全面地反映系统的变化规律, 减少随机性, 提高预测的精度。

经 GA 优化的 SVM 和 BP 神经网络所组合成的预测模型实质上是一种残差修正型预测模型, 其结构如图 2 所示。模型建立和预测的具体步骤如下:

- (1) 将原始样本数据中的输入因素和输出因素代入式 (1) 和式 (16) 进行训练, 得到单独的 SVM 模型和 BP 神经网络模型, 并对 SVM 模型进行参数优选。
- (2) 用得到的 SVM 模型对给定样本数据进行处理, 得到预测结果 z_i 。
- (3) 将预测结果 z_i 与原始数据相减得到残差序列 e_i , 并利用 BP 神经网络模型对 e_i 序列进行预测分析, 得到修正后的残差序列 e'_i 。
- (4) 最终预测数据由 SVM 模型预测的结果和 BP 神经网络模型得到的修正残差序列相加得到, 即 $y = z_i + e'_i$ 。



图 2 组合预测模型结构
Fig. 2 Structure of combination forecasting model



4 工程实例

充填钻孔寿命的大小是由充填管道的磨损程度反应的,一般用钻孔报废时的累计充填量衡量其大小。而影响充填钻孔磨损程度的因素有料浆特性、管道参数(包括材质、壁厚和内径)、偏斜率和充填倍线等^[5]。

以某矿为例,运用组合预测模型对矿山充填钻孔寿命进行预测。由于该矿不同矿区充填原料及充填配比、围岩条件基本相同,使得充填料浆特性、管道的材质和壁厚等因素对不同充填钻孔使用寿命的影响相同,故在建立模型时,仅分

析钻孔直径、钻孔偏斜率以及充填倍线这 3 个主要影响因素,以减少分析工作量、提高预测精度。

4.1 数据处理

选取该矿典型的 20 个钻孔资料建立样本数据(表 1),由于样本指标各不相同,原始样本中各向量的数量级差别很大,为了计算方便,需对样本数据进行归一化处理,归一化公式为

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}}$$

归一化结果见表 2。

表 2 归一化后的无量纲样本数据

Table 2 Normalized dimensionless sample data

钻孔编号	管道内径	偏斜率	充填倍线	累计充填量
1	0.626	0.549	0.000	0.983
2	0.626	0.149	0.000	1.000
3	0.140	1.000	0.022	0.193
4	0.252	0.460	0.319	0.185
5	0.252	0.123	0.269	0.298
6	0.065	0.305	0.194	0.111
7	0.065	0.699	0.194	0.098
8	0.000	0.015	1.000	0.367
9	0.000	0.000	0.994	0.218
10	0.000	0.024	0.989	0.267
11	0.000	0.333	0.585	0.040
12	0.000	0.389	0.585	0.107
13	1.000	0.327	0.000	0.863
14	0.140	0.748	0.022	0.223
15	0.252	0.397	0.519	0.136
16	0.065	0.454	0.475	0.000
17	0.140	0.726	0.585	0.207
18	0.626	0.279	0.050	0.923
19	0.065	0.699	0.272	0.194
20	0.252	0.565	0.843	0.236

表 1 学习样本数据

Table 1 Learning sample data

钻孔编号	管道内径/mm	偏斜率/%	充填倍线	累计充填量/万 m ³
1	219	2.497	1.920	148.800
2	219	0.835	1.920	150.510
3	167	4.368	2.010	69.550
4	179	2.125	3.200	68.800
5	179	0.727	3.000	80.124
6	159	1.481	2.700	61.348
7	159	3.117	2.700	60.061
8	152	0.278	5.931	87.000
9	152	0.215	5.908	72.099
10	152	0.316	5.885	77.000
11	152	1.600	4.267	54.233
12	152	1.831	4.267	60.942
13	259	1.572	1.920	136.820
14	167	3.320	2.010	72.640
15	179	1.863	4.000	63.880
16	159	2.100	3.827	50.233
17	167	3.230	4.267	70.942
18	219	1.372	2.120	142.820
19	159	3.120	3.010	69.640
20	179	2.563	5.300	73.880

4.2 组合预测模型确立

4.2.1 SVM 模型确立和参数优化

将表 2 中前 10 个钻孔数据作为训练集(用于 SVM 建模),11~15 号钻孔数据作为验证集(用来对 SVM 模型的核函数的参数进行优选),最后 5 个钻孔数据作为预测集。根据 SVM 原理,以管道内径、偏斜率、充填倍线作为输入因素,累计充填量作为输出因素,将训练集代入式(16),求出公式中参数,得到确定的 SVM 模型。

运用遗传算法对得到的 SVM 模型进行参数优化选择,以验证集的均方误差作为 GA 的适应度函数,其他参数为:种群规模为 40,进化代数 200,核函数参数 σ 、惩罚系数 C 寻优范围为(0,100),交叉概率范围 $p(0,1)$ 。按照流程图(图 1),运用 Matlab 计算得到 GA-SVM 模型最优参数:适应值(均方误差 mse)=0.0111,惩罚系数 $C=47.0768$,核函数参数 $\sigma=2.2638$,交叉变异概率 $p=0.04526$ 。

4.2.2 BP 神经网络模型确立

(1) 网络拓扑结构确定。采用常用的前馈型 BP 网络,包括输入层、隐含层和输出层,其中输入层和输出层节点数由输入因素和输出因素个数确定,分别为 3 个和 1 个。隐含层节点数的确定比较复杂,通常参考经验公式,一般在 3~15 个之间比较合适,经过实际比较,隐含层节点选取 9、11、13 个时,分别要经过 122、366、119 步达到精度要求,训练平均相对误差为 3.7%、7.9%、6.6%,综合考虑后确定隐含层的节点数选取 9 个,故构建 3-9-1 神经网络模型。

(2) 模型训练。以表 2 中前 15 组数据作为训练样本进行训练,训练时模型精度取 0.001,学习率为 0.7,动量因子为 0.9。

4.3 组合预测模型应用

将得到的组合预测模型按图 2 流程对预测集进行预测,将预测集输入因素输入模型,得到累计充填量预测结果(表 3)。从表 3 可以看出,组合模型的拟合结果良好,经组合模

型预测所得结果与实际值误差较小,均控制在5%以内,并且大多数误差控制在3%左右,模型预测精度较高。

表3 模型预测结果与分析

Table 3 Results and analyses of the model predictions

钻孔编号	实际值/万m ³	组合预测值/万m ³	相对误差/%
16	50.233	51.536	2.6
17	70.942	73.283	3.3
18	142.820	140.821	1.4
19	69.640	72.477	4.1
20	73.880	74.952	1.5

4.4 模型比较

为了说明组合模型的优越性,将其与单独的SVM模型和BP神经网络模型进行对比。两种模型选取上述确定模型,对最后5组钻孔数据进行预测,预测结果从表4可以看出,神经网络预测结果误差波动较大(4.8%~13.6%),SVM预测结果较好,误差波动相对较小。

表4 单独模型预测结果

Table 4 Results of the single model predictions

钻孔编号	实际值/m ³	SVM预测值/m ³	相对误差/%	BP预测值/m ³	相对误差/%
16	50.233	48.326	3.8	55.326	10.1
17	70.942	74.553	5.1	78.553	10.7
18	142.820	137.478	3.7	130.478	8.6
19	69.640	75.639	8.6	79.097	13.6
20	73.880	70.452	4.6	77.452	4.8

3种模型预测结果分析如表5所示。虽然三者误差相差不大,但从平均相对误差和平均绝对误差可以看出,组合模型预测的结果更稳定也更精确。

表5 模型精度分析

Table 5 Accuracy of models

模型	最大相对误差/%	平均相对误差/%	平均绝对误差	最大绝对误差
组合模型	4.1	2.58	1.911	2.837
SVM模型	8.6	5.2	4.057	5.999
神经网络模型	13.6	9.6	7.615	12.342

5 结论

(1) 根据SVM和BP神经网络原理,建立以管道内径、偏斜率和充填倍线为输入,以充填钻孔寿命(累计充填量)为输出的残差修正型组合预测模型。结合遗传算法得到SVM最优参数($C=47.0768, \sigma=2.2638$),并选择3-9-1神经网络模型,提高了组合预测模型的准确性。

(2) 运用经GA优化的SVM和BP神经网络组合预测模型对某矿充填钻孔进行寿命预测,预测结果与实际值误差很小,相对误差均控制在3%左右。对于环境和影响因素复杂的充填钻孔,精度很高,足以提前保护和维修钻孔提供依据。

(3) 通过对比组合预测模型和单一预测模型可知,组合预测模型能更好地对数据拟合,预测精度更高,与实际值更

相近,在其他类似工程中有良好的推广价值。

参考文献 (References)

- [1] 王新民,肖卫国,张钦礼.深井矿山充填理论与技术[M].长沙:中南大学出版社,2005.
Wang Xinmin, Xiao Weigu, Zhang Qinli. The theory and technology of deep mine filling [M]. Changsha: Central South University Press, 2005.
- [2] 周爱民,古德生.基于工业生态学的矿山充填模式[J].中南大学学报:自然科学版,2004,35(3):468-472.
Zhou Aimin, Gu Desheng. Journal of Central South University: Natural Science Edition, 2004, 35(3): 468-472.
- [3] 张德明,王新民,郑晶晶,等.深井充填钻孔内管道磨损机理及成因分析[J].武汉理工大学学报,2010,32(13):100-105.
Zhang Deming, Wang Xinmin, Zheng Jingjing, et al. Journal of Wuhan University of Technology, 2010, 32(13): 100-105.
- [4] 田丽,曹安照,王蒙,等.基于SVM和神经网络组合预测模型物流需求预测[J].重庆工商大学学报:自然科学版,2012,29(9):61-64.
Tian Li, Cao Anzhao, Wang Meng, et al. Journal of Chongqing Technology and Business University: Natural Science Edition, 2012, 29(9): 61-64.
- [5] Desai V S, Crook J N, Overstreet G A. A comparison of neural networks and linear scoring models in the credit union environment[J]. European Journal of Operational Research, 1996, 95(1): 24-37.
- [6] Piramuthu S. Financial credit risk evaluation with neural and neurofuzzy systems[J]. European Journal of Operational Research, 1999, 112(2): 310-321.
- [7] 李蒙,郭鑫,谭显东,等.基于改进BP神经网络和工业重构理论的用电增长预测方法[J].中南大学学报:自然科学版,2007,38(1):143-147.
Li Meng, Guo Xin, Tan Xiandong, et al. Journal of Central South University: Natural Science Edition, 2007, 38(1): 143-147.
- [8] 李伟超,宋大猛,陈斌.基于遗传算法的人工神经网络[J].计算机工程与设计,2006,27(2):316-318.
Li Weichao, Song Dameng, Chen Bin. Compute Engineering and Design, 2006, 27(2): 316-318.
- [9] 金宝强,童凯军,孙红杰,等.一种时变耦合模型在油井产量预测中的应用[J].科技导报,2010,28(17):72-76.
Jin Baoqiang, Tong Kaijun, Sun Hongjie, et al. Science & Technology Review, 2010, 28(17): 72-76.
- [10] Min J H, Lee Y C. Bankruptcy prediction using support vector machine with optimal choice of kernel function parameters[J]. Expert Systems with Application, 2005, 28(4): 603-614.
- [11] Suykens J A K, Vandewalle J, De Moor B. Optimal control by least squares support vector machines[J]. Neural Networks, 2001, 14(1): 23-25.
- [12] 李蓓智,李立强,杨建国,等.基于GA-SVM的质量预测系统设计和实现[J].计算机工程,2011,37(1):167-169.
Li Beizhi, Li Liqiang, Yang Jianguo, et al. Computer Engineering, 2011, 37(1): 167-169.
- [13] 郑春红,焦李成,郑贵文.基于GA的遥感图像目标SVM自动识别[J].控制与决策,2005,20(11):1212-1215.
Zheng Chunhong, Jiao Licheng, Zheng Guiwen. Control and Decision, 2005, 20(11): 1212-1215.
- [14] 杨宏辉,孙进才,袁骏.基于支持向量机和遗传算法的水下目标特征选择算法[J].西北工业大学学报,2005,23(4):512-515.
Yang Honghui, Sun Jincai, Yuan Jun. Journal of North Western Polytechnical University, 2005, 23(4): 512-515.
- [15] 郑晶晶,张钦礼,王新民.基于BP神经网络的充填钻孔使用寿命预测[J].湘潭师范学院学报:自然科学版,2008,30(4):40-44.
Zheng Jingjing, Zhang Qinli, Wang Xinmin. Journal of Xiangtan Normal University: Natural Science Edition, 2008, 30(4): 40-44.

(责任编辑 王媛媛)