

边坡角设计的支持向量机建模与精度影响因素研究

刘开云¹, 乔春生¹, 田盛丰², 滕文彦³

(1. 北京交通大学 土木建筑工程学院, 北京 100044; 2. 北京交通大学 计算机与信息技术学院, 北京 100044;
3. 石家庄铁路工程职业技术学院 土木系, 河北 石家庄 050041)

摘要: 运用人工智能领域最新的基于结构风险最小化原理的机器学习算法——支持向量机(SVM)算法, 采用线性 Linear 和径向基函数 RBF 两种核函数以及 ε 不敏感和 Quadratic 两种损失函数, 并且考虑惩罚参数 C 的不同, 编写了相应的程序对影响边坡角设计的诸多因素进行了机器学习, 经过反复调整相关参数和计算对比, 找到了拟合精度很高的支持向量机网络, 并以此网络对测试样本作预测检验模型的可靠性; 对影响支持向量机建模精度的各种影响因素作了计算和分析, 在此基础上, 初步确定了各参数对 SVM 模型精度影响大小的顺序, 为 SVM 在类似工程上的应用提供了借鉴。

关键词: 边坡工程; 边坡角设计; 支持向量机建模; 机器学习与预测; 参数分析

中图分类号: TU 413.6⁺2

文献标识码: A

文章编号: 1000-6915(2005)02-0328-08

RESEARCH ON MODEL CONSTRUCTION OF SUPPORT VECTOR MACHINE AND PRECISION-INFLUENCING FACTORS OF SLOPE ANGLE DESIGN

LIU Kai-yun¹, QIAO Chun-sheng¹, TIAN Sheng-feng², TENG Wen-yan³

(1. School of Civil Engineering and Architecture, Beijing Jiaotong University, Beijing 100044, China;

2. School of Computer and Information Technology, Beijing Jiaotong University, Beijing 100044, China;

3. Department of Civil Engineering, Shijiazhuang Institute of Railway Engineering, Shijiazhuang 050041, China)

Abstract: Based on the structural risk minimization principle, a support vector machine(SVM) algorithm, the best machine learning algorithm in the artificial intelligence field today, is introduced. Two kinds of kernel functions(linear and radial basis function) and two kinds of loss functions (ε -insensitive and quadratic) and different penalty parameter C are adopted to program a SVM routine in Matlab. Using the developed SVM model, many influencing factors of slope angle design are analyzed. With continued parameter modification and comparative calculations, a SVM network model with high accuracy of fitting was established. The reliability of this SVM network model is verified by sample testing, where many kinds of accuracy influencing factors of the SVM model are considered. The precision influencing sequence of these parameters is confirmed based on the calculation results, providing reference for similar engineering applications.

Key words: slope engineering; slope angle design; model construction of SVM; machine learning and forecast; parameter analysis

收稿日期: 2003-06-25; **修回日期:** 2003-08-14

基金项目: 国家自然科学基金资助项目(50078002)

作者简介: 刘开云(1971-), 男, 1995年毕业于山东矿业学院采矿工程, 现为博士研究生, 主要从事岩土工程支护设计理论方面的研究。E-mail: kyliu316@sohu.com.

1 引言

随着岩石工程的规模越来越大，岩石边坡的稳定性问题越来越引起工程界的注意。边坡设计的关键问题就是边坡角的设计。影响岩石边坡角设计的因素众多，关系复杂，其中有些因素还具有相当程度的不确定性，很难用一个固定的关系方程来对边坡角进行计算，必须另外寻找别的途径解决。文[1]把人工神经网络引入到本领域，取得了非常不错的设计成果^[1]。由于自身理论上的缺陷，人工神经网络存在着大样本、过学习和局部优化的缺点。近年来发展的一种全新的机器学习算法——支持向量机(support vector machine, 简称 SVM)越来越引起人工智能领域专家的注意。这种算法有别于其他优化算法的区别是以结构风险最小化原则为基础，特别适用于小样本情况，在样本数量很大时，也不会陷入“维数灾难”，且泛化性能强，得到的解也是全局最优解^[2, 3]。

2 支持向量机及其回归算法

支持向量机理论基础是统计学习理论^[2~4]。本文主要利用支持向量机回归算法，下面作一简单介绍^[5~10]。回归问题，就是考虑用函数 $f(x) = w \cdot x + b$ 拟合数据 $\{x_i, y_i\}, i = 1, 2, \dots, k, x_i \in R^d, y_i \in R$ 的问题，考虑到允许拟合误差的情况，引入松弛因子 $\xi_i \geq 0, \xi_i^* \geq 0$ ，优化问题是最小化函数为

$$R(W, \xi, \xi^*) = \frac{1}{2} w \cdot w + C \sum_{i=1}^k (\xi_i + \xi_i^*) \quad (1)$$

$$\left. \begin{array}{l} f(x_i) - y_i \leq \xi_i^* + \varepsilon \\ y_i - f(x_i) \leq \xi_i + \varepsilon \\ \xi_i, \xi_i^* \geq 0 \end{array} \right\} \quad (2)$$

采用优化方法即可得优化问题的对偶形式，最大化函数为

$$W(\alpha, \alpha^*) = -\frac{1}{2} \sum_{i,j=1}^k (\alpha_i - \alpha_i^*)(\alpha_j - \alpha_j^*)(x_i, x_j) + \sum_{i=1}^k (\alpha_i - \alpha_i^*)y_i - \sum_{i=1}^k (\alpha_i + \alpha_i^*)\varepsilon \quad (3)$$

约束条件为

$$\left. \begin{array}{l} \sum_{i=1}^k (\alpha_i - \alpha_i^*) = 0 \\ 0 \leq \alpha_i, \alpha_i^* \leq C \end{array} \right\} \quad (4)$$

由式(4)即可得到支持向量机拟合函数为

$$f(x) = w \cdot x + b = \sum_{i=1}^k (\alpha_i - \alpha_i^*)(x, x_i) + b \quad (5)$$

非线性回归使用非线性映射把数据映射到一个高维特征空间进行线性回归，在高维特征空间用核函数来代替线性问题中的内积运算，即

$$K(x_i, x_j) = \varphi(x_i)\varphi(x_j)$$

经过与上面相同的推导，最后得到的支持向量机拟合函数为

$$f(x) = \sum_{i=1}^k (\alpha_i - \alpha_i^*)K(x, x_i) + b \quad (6)$$

令 $\beta_i = \alpha_i - \alpha_i^*$ ，则训练样本中 β_i 不为 0 的样本就是支持向量^[2]。

支持向量机训练的本质是解决一个二次规划(QP)问题，其算法复杂度由具有非零权值的样本即支持向量的个数决定，如训练集规模不大，内点算法可以高效地解决。Chunking 算法通过删除矩阵中所有 Lagrange 乘子为 0 的行和列将大型 QP 问题分解为一系列较小规模的 QP 问题。在算法的每一步 Chunking 都解决一个 QP 问题，其样本为上一步所剩的具有非零 Lagrange 乘子的样本以及 M 个不满足 Kuhn-Tucker 条件的最差样本。每个 QP 子问题都采用上一个 QP 子问题的结果作为初始值。在算法进行到最后一步时所有非零 Lagrange 乘子都被找到，从而解决初始大型 QP 问题。这种算法将矩阵规模从训练样本数的平方减少到具有非零 Lagrange 乘子的样本数的平方。但 Chunking 算法在训练集的支持向量数很大时仍然无法将矩阵放入内存中^[11, 12]。

Osuna 算法是 Chunking 算法的推广改进，这种算法先建立一个工作集，保持其大小不变，在解决每个 QP 子问题时，先从工作集中移走一个样本，并加入一个不满足 Kuhn-Tucker 条件的样本再进行优化。该算法存在效率问题^[12]。

SVM^{light} 是 Osuna 算法的推广，基本思想是如果存在不满足 Kuhn-Tucker 条件的样本，则以某种方式选择 q 个样本作为工作集，其他样本保持不变，

在这个工作集上解决 QP 问题。重复这一过程直至所有样本都满足 Kuhn-Tucker 条件^[12]。

SMO(sequential minimal optimization)算法将一个大型 QP 问题分解为一系列最小规模的 QP 子问题，即仅具有 2 个 Lagrange 乘子的 QP 问题，从而使得原问题可以通过分析的方法解决，避免了在内循环中使用数值分析中的 QP 软件包，该算法在训练线性 SVM 时有非常好的性能^[12-14]。

SVM 中不同的内积核函数将形成不同的算法，目前研究最多的核函数主要有以下几类。

(1) 多项式核函数(Polynomial 核函数)

$$K(x, y) = (x \cdot y + 1)^d \quad d = 1, 2, \dots, n \quad (7)$$

(2) 径向基函数核函数(RBF 核函数)

$$K(x, y) = \exp\left(-\frac{\|x - y\|^2}{2\sigma^2}\right) \quad (8)$$

(3) Sigmoid 核函数

$$K(x, y) = \tanh[v(x \cdot y) + c] \quad (9)$$

(4) 线性核函数(Linear 核函数)

$$K(x, y) = x \cdot y \quad (10)$$

3 边坡角设计影响因素及支持向量机建模

许多工程实践表明,在一定的开挖条件下,岩石边坡角与边坡高度、安全系数、岩石粘聚力、内摩擦角、岩石单轴抗压强度、可能的破坏类型、地下水、结构面倾角、结构面与边坡面的位置关系以及岩体结构类型这 10 个因素有关^[1]。假设有如下边坡角设计的实例数据 (x_i, y_i) , $i = 1, 2, \dots, k$, $x_i \in R^n$ 为影响因素, $y_i \in R$ 表示边坡角, 建立边坡角设计的支持向量机模型, 即为寻找函数关系为

$$\left. \begin{aligned} y_i &= f(x_i) \\ f: R^n &\rightarrow R \end{aligned} \right\} \quad (n=10) \quad (11)$$

结合上述的支持向量机回归算法, 建立边坡角设计的支持向量机智能模型, 也即为建立表达式为

$$f(x) = \sum_{i=1}^k (\alpha_i - \alpha_i^*) K(x, x_i) + b \quad (12)$$

式中: x 为要预测的边坡工程的影响因素; x_i 为第 i 个样本的影响因素; $K(x, x_i)$ 为核函数; α_i, α_i^*, b 可以通过求解式(3)和(4)联合组成的 QP 问题得到。

文[1]从国内外相关工程与文献中收集到 26 个边坡工程实例, 本文以其中的 21 个作为学习样本集, 5 个作为检验支持向量机模型预测能力的待设计样本。为了支持向量机建模的需要, 对其中的一些定性影响因素取如表 1 的输入计算值, 地下水条件按原文献作简化处理, 如 5H 记为 5, 4H 记为 4 等。得到如表 2 所示的学习和测试样本集(表 2 的前 21 个样本为学习样本, 后 5 个为待设计的测试样本)。

支持向量机建模的控制途径有 3 种^[15]: (1)核函数类型及其参数选择; (2)损失函数类型及其参数选择; (3)C 值的选择。

表 1 影响因素的输入计算值
Table 1 Input values of influencing factors

影响因素	类型	输入值
岩体结构类型	薄层镶嵌结构	1
	层状结构	2
	块状镶嵌结构	3
	似层状结构	4
	块状结构	5
	层状-块状结构	6
可能的破坏类型	圆弧破坏	1
	平面-圆弧破坏	2
	双滑块折线破坏	3
	折线形破坏	4
结构面与边坡面的位置关系	平行	0
	斜交(含 45°斜交)	0.5
	垂直	1

4 算法实现与计算结果分析^[15-18]

采用 Matlab 语言编程, 考虑 ϵ -insensitive 和 Quadratic 两种损失函数, 以表 2 所示的 21 个学习样本输入机器, 经机器学习找出最佳的支持向量机网络, 利用此网络对表 3 的 5 个测试样本作出预测。

ϵ -insensitive 损失函数为

$$(y) = \begin{cases} 0 & (|f(x) - y| \leq \epsilon) \\ |f(x) - y| - \epsilon & (|f(x) - y| > \epsilon) \end{cases} \quad (13)$$

Quadratic 损失函数为

表 2 学习样本集^[1]
Table 2 The set of learning samples^[1]

编号	单轴抗压强度/MPa	结构面倾角/(°)	结构面与边坡面的位置关系	地下水条件	岩体结构类型	可能的破坏类型	粘聚力 /10 ³ Pa	内摩擦角/(°)	边坡高度/m	安全系数	边坡角/(°)
1	106.3	50	0.0	5	1	1	5.0	37.5	496	1.20	39.5
2	78.0	70	1.0	4	2	1	8.2	39.0	496	1.15	37.5
3	38.2	70	0.5	5	3	2	3.8	37.5	494	1.25	37.0
4	154.9	50	0.5	3	4	3	5.7	36.0	480	1.15	42.0
5	154.8	47	0.5	3	5	3	5.0	38.0	292	1.15	45.0
6	67.7	62	0.5	3	5	3	4.5	36.0	365	1.15	46.0
7	67.7	62	0.5	3	4	1	6.4	35.0	382	1.15	46.0
8	67.7	62	0.5	3	6	4	6.0	39.0	645	1.15	37.0
9	72.0	65	0.5	4	6	4	7.2	38.0	130	1.20	50.0
10	64.2	65	0.5	7	2	1	6.8	35.0	108	1.20	55.0
11	46.2	45	0.5	7	2	1	6.8	35.0	200	1.20	55.0
12	64.8	45	0.5	5	6	4	9.0	39.0	375	1.25	49.0
13	64.8	45	0.5	5	6	4	7.0	37.0	231	1.25	52.5
14	59.0	80	0.5	2	6	4	4.8	37.0	218	1.20	39.5
15	82.1	60	0.5	5	5	3	4.1	38.0	138	1.20	48.0
16	82.1	50	0.5	5	5	3	4.2	37.0	115	1.20	57.5
17	82.1	45	1.0	5	5	3	2.9	34.0	123	1.20	52.5
18	82.1	45	1.0	5	5	3	4.0	36.0	110	1.20	57.5
19	147.4	67	0.5	5	3	2	9.9	36.0	198	1.20	48.0
20	147.4	45	0.5	5	3	2	8.5	36.0	142	1.20	52.5
21	124.8	60	0.5	5	3	2	9.0	35.5	182	1.20	52.5
22	67.7	65	0.0	3	2	4	6.0	34.0	462	1.15	43.0
23	72.0	65	0.5	7	3	1	7.0	37.0	154	1.20	50.0
24	64.2	65	0.5	7	3	1	6.4	35.0	138	1.20	52.0
25	82.1	50	0.5	5	2	1	4.1	36.0	100	1.20	57.0
26	147.4	45	0.5	5	2	1	9.0	37.0	137	1.20	54.0

$$L(y) = (f(x) - y)^2 \quad (14)$$

本文的二次规划问题采用内点算法^[16], 优化问题的矩阵表示为

$$g(x) = \min_x \frac{1}{2} \mathbf{x}^T \mathbf{H} \mathbf{x} + \mathbf{c}^T \mathbf{x} \quad (15)$$

这里: $\mathbf{H} = \begin{bmatrix} XX^T & -XX^T \\ -XX^T & XX^T \end{bmatrix}$, $\mathbf{c} = \begin{bmatrix} \varepsilon + Y \\ \varepsilon - Y \end{bmatrix}$, $\mathbf{x} = \begin{bmatrix} \alpha \\ \alpha^* \end{bmatrix}$

约束条件为

$$\mathbf{x} \cdot (1, \dots, 1, -1, \dots, -1)^T = 0, \alpha_i, \alpha_i^* \geq 0, i = 1, 2, \dots, n$$

为了衡量支持向量机网络拟合与预测的精度高

低, 在此定义如下函数作为评定指标

$$s = \sum_{i=1}^n (Y'_i - Y_i)^2 / (n-1) \quad (16)$$

定义一个量化指标——平均相对误差为

$$e = \frac{1}{n} \sum_{i=1}^n |Y'_i - Y_i| \times 100 / Y_i$$

式中: Y'_i 为拟合时第 i 个学习样本的拟合值或预测时第 i 个测试样本的预测值, Y_i 为拟合时第 i 个学习样本的样本值或预测时第 i 个测试样本的样本值。

经过对多种核函数计算结果的对比分析, 采用 RBF 核函数和 Linear 核函数时精度较高。采用 ε -insensitive 损失函数和 RBF 核函数的 SVM 模型学习样本的 β_i 如表 3 所示, 从表 4 对学习样本的拟合

结果可见，损失函数相同，核函数不同时，无论是从 s 值还是 e 值来看，Linear 核函数的结果都接近于 RBF 核函数的 3 倍。核函数相同但损失函数不同， s 值和 e 值都非常接近，这说明核函数比损失函数对拟合精度的影响更大。从表 5 的预测结果来看，损失函数相同时，RBF 核函数的结果明显比 Linear 核函数好，尤其是采取 ϵ -insensitive 损失函数时相

差 2 倍左右。损失函数不同而核函数相同时预测精度相差不大，这也说明核函数比损失函数对预测精度的影响更大。从表 4, 5 可见，拟合最大相对误差都在 8.5% 以内，绝大多数都在 4% 以内，拟合最大平均相对误差仅为 3.88%，最小为 1.3%；预测最大相对误差不超过 8.1%，最大平均相对误差仅为 3.03%，最小为 1.96%，完全满足工程上的需要。

表 3 SVM 模型学习样本的 β_i 值 ($C=150, \epsilon=0.5, \sigma=80$)

Table 3 The β_i values of the learning samples of the SVM model ($C=150, \epsilon=0.5, \sigma=80$)

序号	β_i	序号	β_i	序号	β_i	序号	β_i	序号	β_i
1	-12.062	5	23.603	9	-137.84	13	-55.582	17	-150
2	-29.653	6	0	10	150	14	-27.667	18	66.728
3	42.665	7	-29.292	11	145.11	15	-150	19	-43.628
4	45.611	8	33.822	12	59.989	16	150	20	24.236
								21	124.76

表 4 学习样本拟合计算结果表

Table 4 The results of learning sample fitting

编号	样本值 $f(\theta)$	Quadratic 损失函数				ϵ -insensitive 损失函数			
		Linear 核函数		RBF 核函数		Linear 核函数		RBF 核函数	
		$C=0.05$	相对误差 /%	$C=150$ $\sigma=105$	相对误差 /%	$C=5$ $\epsilon=3$	相对误差 /%	$C=150$ $\epsilon=0.5$ $\sigma=80$	相对误差 /%
1	39.5	41.39	4.78	39.68	0.45	41.50	5.06	40.00	1.26
2	37.5	38.01	1.37	37.69	0.51	37.49	0.03	38.00	1.33
3	37.0	38.07	2.90	36.80	0.55	37.81	2.18	36.50	1.35
4	42.0	41.16	2.00	41.74	0.61	41.20	1.90	41.50	1.19
5	45.0	46.12	2.48	45.01	0.03	46.91	4.24	44.50	1.11
6	46.0	43.72	4.96	46.08	0.17	43.05	6.41	45.89	0.25
7	46.0	44.91	2.37	46.05	0.11	43.03	6.45	46.50	1.09
8	37.0	35.09	5.15	36.88	0.34	34.00	8.11	36.50	1.35
9	50.0	50.20	0.40	50.08	0.16	49.94	0.12	50.50	1
10	55.0	52.88	3.85	54.45	0.99	52.00	5.45	54.17	1.50
11	55.0	56.12	2.03	53.85	2.09	55.11	0.20	54.50	0.91
12	49.0	49.47	0.97	48.74	0.53	48.27	1.49	48.50	1.02
13	52.5	53.50	1.91	53.06	1.07	52.67	0.32	53.00	0.95
14	39.5	42.86	8.49	39.74	0.59	42.50	7.59	40.00	1.27
15	48.0	49.53	3.19	50.27	4.74	50.90	6.04	51.61	7.52
16	57.5	53.37	7.18	55.25	3.91	54.50	5.22	55.93	2.73
17	52.5	55.31	5.34	54.87	4.51	55.50	5.71	56.20	7.04
18	57.5	55.25	3.91	56.66	1.47	56.05	2.51	57.00	0.87
19	48.0	47.71	0.61	48.53	1.11	46.63	2.86	48.50	1.04
20	52.5	54.32	3.47	52.60	0.18	54.53	3.87	52.00	0.95
21	52.5	50.51	3.78	50.82	3.20	49.50	5.71	52.00	0.95
s		3.75		1.10		4.88		1.70	
e			3.39		1.30		3.88		1.75

表 5 测试样本预测计算结果表
Table 5 The results of testing sample forecast

编号	样本值 f_i (°)	Quadratic 损失函数				ε -insensitive 损失函数					
		Linear 核函数		RBF 核函数		Linear 核函数		RBF 核函数			
		$C = 0.05$	相对误差/%	$C = 150$	$\sigma = 105$	相对误差/%	$C = 5$	$\varepsilon = 3$	相对误差/%	$C = 150$	$\varepsilon = 0.5$
1	43	41.11	4.39	41.07	4.49	39.52	8.09	42.08	2.14		
2	50	50.64	1.27	48.88	2.23	50.26	0.52	49.77	0.46		
3	52	52.04	0.08	50.06	3.73	50.86	2.18	50.8	2.32		
4	57	53.94	5.36	57.86	1.51	55.52	2.59	57.52	0.91		
5	54	54.18	0.34	52.90	2.02	54.97	1.79	51.86	3.96		
s		3.34		2.68		4.15		1.79			
e			2.29		2.80		3.03		1.96		

5 讨论

(1) 选用 Quadratic 损失函数

采用 Linear 核函数, 由如图 1 所示的精度曲线可知, 随 C 的增大, 拟合精度随之提高, 且逐渐稳定于 3, 而预测精度却随之降低, C 进一步增大, 精度还将降到更低, 比较好的 C 值范围应为 0.05 ~ 1.0, 此时拟合与预测的 S 值在 3 左右。




图 1 C 改变时精度曲线

Fig.1 The precision curves with different C

选用 RBF 核函数, 影响因素有两个: C 和 σ 。当 C 不变而 σ 改变时, 由如图 2(a) 所示精度曲线可见, 拟合精度随 σ 增大而降低, 预测精度相反有所提高, 比较合适的 σ 应为 100 ~ 120 之间, 此时 S 在 1 ~ 3 之间; 当 σ 不变而 C 改变时, 由图 2(b) 精度曲线可见, 拟合精度随 c 增大而提高, 预测精度在 2.4 ~ 2.6 之间变动, 比较合适的 C 在 130 ~ 150 之间。

(2) 选用 ε -insensitive 损失函数

采用 Linear 核函数, 影响因素有两个: C 和 ε 。从图 3(a) 可见, c 不变时随 ε 增大拟合和预测精度都有很大变化, 且随 ε 继续增大, 拟合与预测精度




图 2(a) C 不变而 σ 改变的精度曲线

Fig.2(a) The precision curves with constant C and different σ values




图 2(b) σ 不变而 C 改变精度曲线

Fig.2(b) The precision curves with constant σ and different C values




图 3(a) C 不变而 ε 改变的精度曲线

Fig.3(a) The precision curves with constant C and different ε values




图 3(b) ε 不变而 C 改变的精度曲线

Fig.3(b) The precision curves with constant ε and different C values

还将进一步下降,比较适宜的 ε 值应在 3 左右;ε 不变时,由图 3(b)可见,随 C 的增大,拟合与预测精度都趋于稳定,可见此时精度对 C 的变化不敏感。

采用 RBF 核函数,影响因素有 3 个: C, ε。

由图 4(a)可见: C, ε 不变而 σ 改变时拟合与预测的精度变化趋势基本一致。当 σ < 70 时,精度有下降的趋势,比较合适的 σ 值应为 70 ~ 85。由图 4(b)可见: σ, ε 不变而 C 增大时,拟合与预测精度都有所提高,两者变化趋势基本一致,较适宜的 C 应大于等于 150。图 4(c)中 σ, C 不变而 ε 增大,拟合与预测精度相应都下降,两者变化趋势一致,较好的 ε 值应为 0 ~ 0.5。由以上讨论结果得出了如表 4, 5 所示的支持向量机网络并由此给出了计算结果。

拟合精度高的网络,其预测精度也应当高,反之,拟合精度低的网络,其预测精度也应当低,即二者的变化趋势应该是一致的,这是机器学习和预测必须满足的前提条件。从这一点看,以上所取的各种建模方法及其参数只有最后一种满足这个条件,即取 RBF 核函数,ε-insensitive 损失函数的支持向量机网络是最好的 SVM 网络。

从以上的计算分析可见,在影响 SVM 模型精度的三个因素中,核函数类型是影响最大的因素。从本例的计算结果来看,在采用 Quadratic 损失函数和 RBF 核函数时 σ 比 C 对精度的影响更大。采用 ε-insensitive 损失函数和 Linear 核函数时 ε 比 C 对精度的影响更大;采用 RBF 核函数 ε 比 σ 和 C 对精度的影响都要大,σ 比 C 对精度的影响又要大。迄今为止,尚没有关于精度影响因素的一般性结论。以上结论仅仅是从本例的计算结果得出,并不能外推到其他情况。




图 4(a) C, ε 不变而 σ 改变的精度曲线

Fig.4(a) The precision curves with constant C, ε and different σ values




图 4(b) σ, ε 不变而 C 改变的精度曲线

Fig.4(b) The precision curves with constant σ, ε and different C values




图 4(c) σ, C 不变而 ε 改变的精度曲线

Fig.4(c) The precision curves with constant σ, C and different ε values

6 结 论

本文把支持向量机应用于边坡角设计问题,经过研究发现,对于此问题,采用 RBF 核函数和 ε-insensitive 损失函数的支持向量机网络是较好的 SVM 网络,其设计结果具有相当理想的精度,完全可满足工程要求。

到目前为止,对核函数及其参数、C 以及损失函数的选择尚没有确定的方法和结论,更多的要依靠使用者的经验和直觉,采取不断试算的途径寻求

较好的解^[15, 18],不但费时,而且往往难以找到全局最优解,文[10]提出运用遗传算法来优化支持向量神经网络,这是一种不错的尝试,彻底的解决方法还有待于进一步研究。

参考文献(References):

- [1] 冯夏庭. 智能岩石力学导论[M]. 北京: 科学出版社, 2000.(Feng Xiating. Introduction of Intelligent Rock Mechanics[M]. Beijing: Science Press, 2000.(in Chinese))
- [2] Vladimir N Vapnik. The Nature of Statistical Learning Theory[M]. New York: Springer, 1995.
- [3] 边肇祺, 张学工. 模式识别(第二版)[M]. 北京: 清华大学出版社, 2000.(Bian Zhaoqi, Zhang Xuegong. Pattern Recognition (Second Edition)[M]. Beijing: Tsinghua University Press, 2000.(in Chinese))
- [4] Nello Cristianini, John Shawe-Taylor. An Introduction to Support Vector Machines and Other Kernel-based Learning Methods[M]. England: Cambridge University Press, 2000.
- [5] 冯夏庭, 赵洪波. 岩爆预测的支持向量机[J]. 东北大学学报, 2002, 23(1): 57-59.(Feng Xiating, Zhao Hongbo. Prediction of rockburst using support vector machine[J]. Journal of Northeastern University, 2002, 23(1): 57-59.(in Chinese))
- [6] 阎辉, 张学工, 李衍达. 应用 SVM 方法进行沉积微相识别[J]. 物探计算技术, 2000, 22(2): 158-164.(Yan Hui, Zhang Xuegong, Li Yanda. Support vector machine methods in pattern recognition of sedimentary facies[J]. Computing Techniques for Geophysical and Geochemical Exploration, 2000, 22(2): 158-164. (in Chinese))
- [7] 田盛丰, 黄厚宽. 基于支持向量机的数据库学习算法[J]. 计算机研究与发展, 2000, 37(1): 17-22.(Tian Shengfeng and Huang Houkuan. Database learning algorithms based on support vector machine[J]. Journal of Computer Research and Development, 2000, 37(1): 17-22.(in Chinese))
- [8] 田盛丰, 黄厚宽. 支持向量机多专家决策算法[J]. 模式识别与人工智能, 2000, 13(2): 165-169.(Tian Shengfeng, Huang Houkuan. A multi-expert decision-making algorithm based on support vector machine[J]. PR & AI, 2000, 13(2): 165-169.(in Chinese))
- [9] Gavin C Cawley, Nicola L C. Talbot. Improved sparse least-squares support vector machines[J]. Neurocomputing, 2002, 48: 1 025-1 031.
- [10] 赵洪波, 冯夏庭. 支持向量机函数拟合在边坡稳定性估计中的应用[J]. 岩石力学与工程学报, 2003, 22(2): 241-245.(Zhao Hongbo, Feng Xiating. Application of support vector machines function fitting in slope stability evaluation[J]. Chinese Journal of Rock Mechanics and Engineering, 2003, 22(2): 241-245.(in Chinese))
- [11] Cortes C, Vapnik V. Support vector networks [J]. Machine Learning, 1995, 20: 273-297.
- [12] 崔伟东, 周志华, 李星. 支持向量机研究[J]. 计算机工程与应用, 2001, 37(1): 58-61.(Cui Weidong, Zhou Zhihua, Li Xing. Research of support vector machines[J]. Computer Engineering and Application, 2001, 37(1): 58-61.(in Chinese))
- [13] John C.Platt. Using analytic QP and sparseness to speed training of support vector machines[A]. In: Kearns M S, Solla S A, Cohn D A, eds. Advances in Neural Information Processing Systems (Volume II)[C]. Cambridge: MIT Press, 1999.
- [14] Platt J C. Fast training of SVMs using sequential minimal optimization [A]. In: Scholkopf B, Burges C J C, Smola A J, eds. Advances in Kernel Methods-Support Vector Learning, Cambridge[C]. Cambridge: MIT Press, 1998. 185-208.
- [15] Steve R Gunn. Support vector machines for classification and regression[R]. England: University of Southampton, 1998.
- [16] 王沫然. Matlab6.0 与科学计算[M]. 北京: 电子工业出版社, 2001.(Wang Moran. Matlab 6.0 and Scientific Calculation[M]. Beijing: Publishing House of Electronics Industry, 2001.(in Chinese))
- [17] 苏金明, 阮沈勇. Matlab6.1 实用指南(上、下册)[M]. 北京: 电子工业出版社, 2002.(Su Jinming, Ruan Shenyong. Guide of Matlab 6.1 Utility [M]. Beijing: Publishing House of Electronics Industry, 2002.(in Chinese))
- [18] Amari S, Wu S. Improving support vector machine classifiers by modifying kernel functions[J]. Neural Networks, 1999, 12: 783-789.