

基于 ν -SVR 算法的边坡稳定性预测

余志雄, 周创兵, 李俊平, 史超

(武汉大学 水资源与水电工程科学国家重点实验室, 湖北 武汉 430072)

摘要: 提出基于一种改进支持向量机算法(ν -SVR)的边坡稳定性预测方法, 直接利用边坡的特征参数快速预测边坡稳定性。为解决算法中模型选择困难的问题, 用留一法设计预测模型, 用网格搜索法搜索最优参数。留一法可以避免传统方法中根据经验确定预测模型的缺点, 较为客观地获取合适的预测模型。网格搜索法可以保证搜索到合适的参数。计算结果显示, 联合运用这两种方法可以获得合适的预测模型。利用该预测模型对 82 个圆弧破坏边坡实例中的 71 个实例进行学习, 对另外 11 个实例进行推广预测, 取得了较好的效果, 其预测精度明显优于一种改进 BP 神经网络算法和常规 SVR 算法, 与 GA-BP 神经网络算法相近。在此基础上, 提出基于 ν -SVR 算法的边坡设计方法, 能够快速、准确的获取不同方案下的边坡安全系数, 评价其稳定性, 为选择经济合理的边坡设计方案提供决策依据。

关键词: 岩土工程; 支持向量机; 边坡稳定性; ν -SVR(support vector regression)预测; 边坡设计; 模型选择; 留一法; 网格搜索法

中图分类号: TU 413.6

文献标识码: A

文章编号: 1000-6915(2005)14-2468-08

PREDICTING SLOPE STABILITY BASED ON ν -SVR ALGORITHM

YU Zhi-xiong, ZHOU Chuang-bing, LI Jun-ping, SHI Chao

(State Key Laboratory of Water Resources and Hydropower Engineering Science, Wuhan University, Wuhan 430072, China)

Abstract: A slope stability predicting model based on ν -SVR algorithm, which uses only characteristic parameters of slopes, is put forward. To overcome the difficulty in model selection in the algorithm, leave-one-out method is used to design predicting model; and grid-search method is used to search suitable values of parameters of the predicting model. Leave-one-out method can select appropriate model objectively, avoiding the shortcoming of designing model by experience. The search result shows that with these two methods, the appropriate predicting model can be searched. Applying the predicting model to predict safety factors of 11 slopes after learning with other 71 samples; the result is satisfactory. It is more accurate than a modified BP algorithm and classical SVR; and it shows that the proposed model is effective. Moreover, a new method based on ν -SVR algorithm is presented to guide slope design. It can acquire slope safety factors of different schemes by characteristic parameters of slopes quickly and accurately, and evaluate the stability of slope, which will facilitate the determining of an economic and safe slope design scheme.

Key words: geotechnical engineering; support vector machine; slope stability; ν -SVR(support vector regression) prediction; slope design; model selection; leave-one-out method; grid-search method

收稿日期: 2004-04-05; 修回日期: 2004-06-10

作者简介: 余志雄(1977-), 男, 2000年毕业于武汉水利电力大学水工结构专业, 现为博士研究生, 主要从事数值计算、岩土工程试验及地质雷达无损检测应用方面的研究工作。E-mail: yzx41@163.com.

1 引言

天然或人工边坡常常由于自然因素或人为因素破坏其力学平衡,发生滑坡等现象,造成严重事故。滑坡发生过程实际上是斜坡从渐变式发展到突发宏观滑移的非线性复杂过程。由于边坡岩体的结构与物理力学性质表现出宏观和微观上的不连续性和高度的非线性等特点,因此,边坡工程可以看成是不确定的、非线性的、动态开放的复杂大系统,其稳定性受地质因素和工程因素等的综合影响。这些因素大部分具有随机性、模糊性、可变性等不确定性特点,它们对不同类型边坡岩体稳定性的影响权重也是变化的,这些因子之间具有复杂的非线性关系。对其稳定性做出准确有效的预测预报是岩土工程与工程地质领域亟待解决的课题之一^[1]。

目前在工程中用于边坡稳定性分析的方法主要有瑞典条分法、毕肖普法、沙尔玛法、图解法、有限元法等。这些分析方法考虑了影响边坡稳定的主要因素,如岩性、地形、地下水条件、坡体含水量、地震强度等,但这些方法计算冗长、繁琐,计算量大,往往难以准确描述这种复杂的非线性特征,因而运用该类边坡模型对大型复杂边坡稳定性进行准确预测预报尚存在一定的困难,以至不少研究者认为岩石力学目前尚处于“声誉很高,信誉尚低”的阶段^[2]。随着非线性科学的发展,人们开始认识到滑坡灾害的发生是系统内在要素通过一系列非平衡不稳定产生空间、时间、功能和结构的自组织过程,导致滑坡灾害发生的是系统远离平衡态的结果,因此,部分学者提出神经网络法,通过综合研究系统的不确定性和工程经验,来解决复杂的边坡工程设计问题。但是,这类方法最终解过于依赖初值,存在过学习现象,训练过程中存在局部极小问题,且收敛速度比较慢,网络的隐节点数难于确定等问题^[3]。

20 世纪 70 年代, Vapnik 等人提出统计学习理论,为有限样本,尤其是小样本情况下机器学习提供了有力的理论依据。到 20 世纪 90 年代中期,随着其理论的不断发展和成熟,也由于神经网络等学习方法在理论上缺乏实质性进展,统计学习理论开始受到越来越广泛的重视,并在此理论框架下产生了支持向量机(support vector machine, SVM)这一新的通用机器学习方法^[4]。SVM 有严格的理论基础,是基于结构风险最小化原则的方法,明显优于传统的基于经验风险最小化原则的常规神经网络方法。

其算法是一个凸二次优化问题,保证找到的解是全局最优解,能较好的解决小样本、非线性、高维数等实际问题,问题的复杂度不取决于特征的维数,且具有良好的推广能力,正在成为继神经网络研究之后的研究热点。目前, SVM 已经在模式识别中取得了良好的应用效果,广泛应用于文本识别等领域。近年来,人们又发展了回归型支持向量机(support vector regression, SVR),它可以任意精度逼近非线性函数,具有全局极小值点,收敛速度快,被应用于电力系统短期负荷预测^[3]、地下水位预报^[5]等领域,解决了实际工程问题。文[6]首先将 SVR 算法引入到边坡稳定性估计中,取得了较好的成果。与人工神经网络方法相比, SVR 不存在容易陷入局部最优等问题,提高了泛化能力,因此有较大的优越性。

为了能够更容易的选择参数值,文[7]提出了一种改进的 SVR,即 ν -SVR 方法^[7]。 ν -SVR 使用起来更方便,计算结果也比 SVR 更准确。

为了解决边坡稳定性预测问题,本文在介绍了 ν -SVR 的基本原理^[7]之后,将提出一种基于 ν -SVR 算法的边坡稳定性预测模型,运用留一法和网格搜索法选择合适的预测模型,并对实际边坡稳定性进行预测预报。此后,本文进一步提出了基于 ν -SVR 算法的边坡设计方法,为快速设计经济安全的边坡提供了一种全新的思路。

2 ν -SVR 算法原理

2.1 ν -SVR 算法数学模型

对于训练样本集 $\{x_i, y_i\}_{i=1}^l$, $x_i \in R^n$ 为输入变量的值, $y_i \in R$ 为相应的输出值, l 为训练样本个数,回归问题就是寻找一个从输入空间到输出空间的映射 $f: R^n \rightarrow R$,使得 $f(x) = y$ 。 ν -SVR 的目标是寻求回归函数:

$$y = f(x) = wx + b \quad (1)$$

式中: $w, x \in R^n$; $b \in R$ 。对于线性问题,根据统计学习理论, ν -SVR 通过极小化目标函数来确定回归函数,即求下式的最小值:

$$\tau(w, \xi^{(*)}, \varepsilon) = \frac{1}{2} \|w\|^2 + C \left[\nu \varepsilon + \frac{1}{l} \sum_{i=1}^l (\xi_i + \xi_i^*) \right] \quad (2)$$

约束条件为

$$(ax_i + b) - y_i \leq \varepsilon + \xi_i \quad (3)$$

$$y_i - (\omega x_i + b) \leq \varepsilon + \xi_i^* \quad (4)$$

$$\xi_i^* \geq 0, \varepsilon \geq 0 \quad (5)$$

式(2)~(5)中： C 为用来平衡模型复杂性项 $\frac{1}{2}\|w\|^2$ 和训练误差项的权重参数， ε 为不敏感损失函数， ξ 为松弛因子。如图1所示。

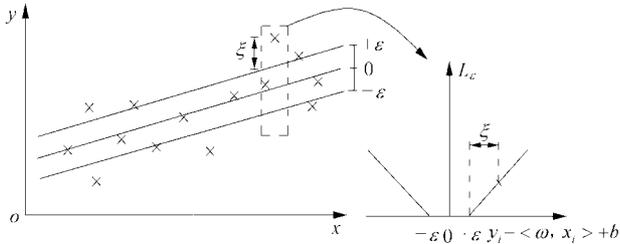


图1 nu-SVR 算法原理图
Fig.1 Principle of nu-SVR algorithm

对于约束条件，引入相应的乘子 $\alpha_i^{(*)}$ ， $\eta_i^{(*)}$ ， $\beta \geq 0$ ，通过拉格朗日算法，得出下式：

$$L(\omega, b, \alpha^{(*)}, \beta, \xi^{(*)}, \varepsilon, \eta^{(*)}) = \frac{1}{2}\|w\|^2 + C\nu\varepsilon + \frac{C}{l} \sum_{i=1}^l (\xi_i + \xi_i^*) - \beta\varepsilon - \sum_{i=1}^l (\eta_i \xi_i + \eta_i^* \xi_i^*) - \sum_{i=1}^l \alpha_i (\xi_i + y_i - \omega x_i - b + \varepsilon) - \sum_{i=1}^l \alpha_i^* (\xi_i^* + \omega x_i + b - y_i + \varepsilon) \quad (6)$$

为了最小化式(2)，需要求出式(6)的鞍点，也就是最小化变量 $w, \varepsilon, b, \xi_i^*$ 并且最大化变量 $\alpha_i^{(*)}, \beta, \eta_i^{(*)}$ 。因此可以得到以下4个方程：

$$w = \sum_i (\alpha_i^* - \alpha_i) x_i \quad (7)$$

$$C\nu - \sum_i (\alpha_i + \alpha_i^*) \beta = 0 \quad (8)$$

$$\sum_{i=1}^l (\alpha_i - \alpha_i^*) = 0 \quad (9)$$

$$\frac{C}{l} - \alpha_i^{(*)} - \eta_i^{(*)} = 0 \quad (10)$$

求解上述问题，可得到nu-SVR的回归函数：

$$f(x) = \sum_{i=1}^l (\alpha_i^* - \alpha_i)(x_i, x) + b \quad (11)$$

对于非线性问题，可以通过非线性变换将原问题映射到某个高维特征空间中的线性问题上进行求解。在高维特征空间中，线性问题中的内积运算可以用核函数来代替，即

$$K(x_i, x_j) = \phi(x_i)\phi(x_j) \quad (12)$$

核函数可以用原空间中的函数实现，没有必要知道非线性变换的具体形式。因此非线性问题的回归方程为

$$f(x) = \sum_{i=1}^l (\alpha_i^* - \alpha_i)K(x_i, x) + b \quad (13)$$

根据支持向量机回归函数的性质，只有少数 $(\alpha_i^* - \alpha_i)$ 不为0，这些参数对应的向量称为支持向量，回归函数 $f(x)$ 完全由其决定。图2为nu-SVR结构示意图^[6]。

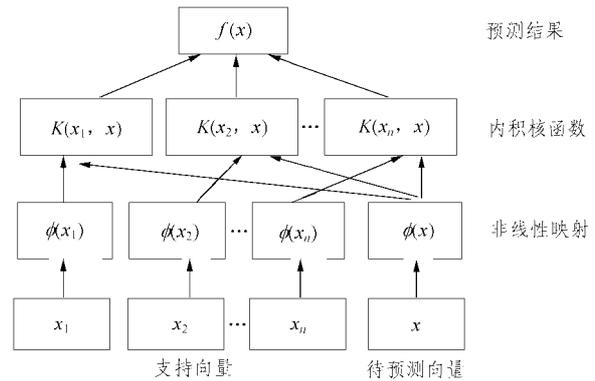


图2 nu-SVR 结构示意图^[6]
Fig.2 Sketch of nu-SVR structure^[6]

2.2 二次优化问题的求解算法

由于nu-SVR对偶问题的求解过程相当于解一个线性约束的二项规划问题，需要计算和存储核函数矩阵，其大小与训练样本数的平方相关，因此，随着样本数目的增多，所需的内存也就增大。其次，nu-SVR在二次型寻优过程中要进行大量的矩阵运算，多数情况下，寻优算法是占用算法时间的主要部分。因此，部分学者提出了块处理算法(chunking algorithm)、分解算法、序贯最小优化算法(sequential minimal optimization, SMO)、最近点快速迭代算法(nearest point algorithm, NPA)等算法^[8]。其中，SMO是目前在实际问题中应用最为广泛的算法。本文选用SMO算法来求解对偶问题。

SMO算法是分解算法的一个特例，在其工作空间只包含2个样本，即在每一步迭代中只对2个拉格朗日乘子进行优化。由于对拉格朗日乘子的线性等式约束，这是可能达到的最小优化问题，可以求出二次规划问题的解析解，从而避免了多样本情形下的数值解不稳定及耗时问题。因此，SMO算法思路简单，易于实现，可以用简洁的程序代码解决二次规划问题，不需要处理大矩阵，效率高，对存储

空间没有额外要求, 特别适合稀疏样本。此外, SMO 采用 2 层嵌套循环分别进入工作样本集的样本, 这种启发式策略大大加快了算法的收敛速度。SMO 算法的具体过程可以参见文[9]。

2.3 常用核函数类型

目前, 人们构造了十多种核函数, 其中常用的核函数有以下几种:

(1) 多项式核函数

$$K(x_i, x_j) = (x_i x_j + 1)^d, \quad d = 1, 2, \dots$$

(2) 径向基核函数

$$K(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{\sigma^2}\right)$$

(3) sigmoid 核函数

$$K(x_i, x_j) = \tanh[b(x_i x_j) - C]$$

(4) 线性核函数

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

3 模型选择

模型选择包括核函数的类型选取和相关参数取值。模型选择是 SVM 算法的一个难点, 目前还没有从理论上很好地解决这个问题。在实际工程中, 研究者主要依靠经验和有限的试验来选取模型, 而不去讨论模型确定的合理性。模型中核函数的类型和参数的大小对预测效果影响非常大, 而且对于不同的具体工程, 合适的预测模型的核函数形式和参数取值往往有很大区别。文[6]以实际工程为例, 分析了参数选取对预测结果的影响。结果显示, 参数取值显著影响预测效果。因此, 核函数类型的确定和参数的合理取值是成功确立预测模型的一个关键因素。本文采用留一法和网格搜索法进行模型选择。

3.1 留一法

通常设计预测模型的方法有 2 种: (1) 用全部 N 个样本作为设计集设计预测模型, 并将所有样本作为验证集代入该模型中, 计算相应的预测误差, 以此为评价模型预测效果的依据, 来调整模型参数, 直到得到预测误差最小的模型, 作为最优预测模型。(2) 将全部 N 个样本分为 2 份, 其中一份样本作为设计集建立预测模型, 另外一份样本作为验证集代入该模型中, 计算预测误差, 以此为评价模型预测效果的依据, 来调整模型参数, 直到得到预测误差

最小的模型, 作为最优预测模型。前一种方法将所有样本既作为设计集, 又作为验证集, 容易出现过拟合现象, 产生偏于乐观的假象, 即该模型不能真实反映实际情况, 在样本附近预测精度非常高, 在其他地方预测精度较低。后一种方法不能充分利用所有样本, 尤其是在样本较小的情况下, 预测效果不佳。基于此, 本文提出采用留一法设计预测模型。

留一法是交互验证方法的特例。交互验证就是将全部 N 个样本随机均匀分为 L 份, 首先取出其中一份, 用剩下的 $L-1$ 份作为设计集来设计预测模型, 然后用取出的那份样本作为验证集进行验证, 计算相应的预测误差; 再把取出的那份样本放回原样本集中, 取出另外一份, 用剩下的 $L-1$ 份作为设计集来设计预测模型, 然后用取出的那份样本作为验证集进行验证, 计算相应的预测误差。这样一共重复设计模型 L 次, 检验 L 次, 并计算平均预测误差, 以此为评价模型预测效果的依据, 来调整模型参数, 直到得到预测误差最小的模型, 作为最优预测模型。有关交互验证的理论见文[10]。留一法是交互验证的极端情况, 就是将全部 N 个样本分为 N 份, 每份一个, 然后进行交互验证。留一法的优点是充分地利用了 N 个样本, 是评价模型稳定性和对外部样本预测能力最重要也最有效的方法之一, 能有效避免过拟合现象的出现。留一法比较适用于样本数 N 较小的情况, 缺点是需要计算 N 次预测模型, 计算量大。文[11, 12]运用留一法进行支持向量机模型选择, 效果较好。

3.2 网格搜索法

ν -SVR 模型本身有 2 个参数 C 和 ν , 核函数也有自己的参数。因此在多个参数中盲目搜索最优参数是非常浪费时间的。文[13, 14]的相关计算表明, 模型预测误差在参数预测误差平面图上有一定的规律: 随着预测误差的减小, 预测误差等值线所围成的面积逐渐减小, 并且位于较大的预测误差形成的等值线内部。因此, 文[11]提出运用网格搜索法来确定模型参数取值。网格搜索法就是首先确定每个参数的取值范围, 然后对每个参数取值范围按照一定规律插值, 得出若干组参数组合。对每组参数组合进行一次计算, 应用留一法计算其预测误差均方根。对应于预测误差均方根最小的参数组合, 就是最优的参数取值。由于参数与预测误差之间存在上文所述的规律, 采用网格搜索法可以保证搜索到最优参数。网格搜索法的优点在于: 可以安全地搜索到最优参数组合; 在只有 3, 4 个参数的情况下,

网格搜索法不比其他高级搜索方法费时；用网格搜索法能够很容易地进行平行搜索^[14]。在采用网格搜索法的时候，还可以采用粗细网格结合的方法，首先采用粗网格确定最优参数的区域，然后采用细网格确定最优参数组合^[14]。

3.3 模型选择流程

本文首先按照一定规律在参数空间进行网格划分，网格中的每个结点代表一个参数组合。然后应用留一法对每一个参数组合进行计算，求出相应的误差均方根。用网格搜索法对上述计算结果进行搜索，找出最小的误差均方根对应的参数组合，就是所要搜索的最优参数。具体搜索流程如图 3 所示。

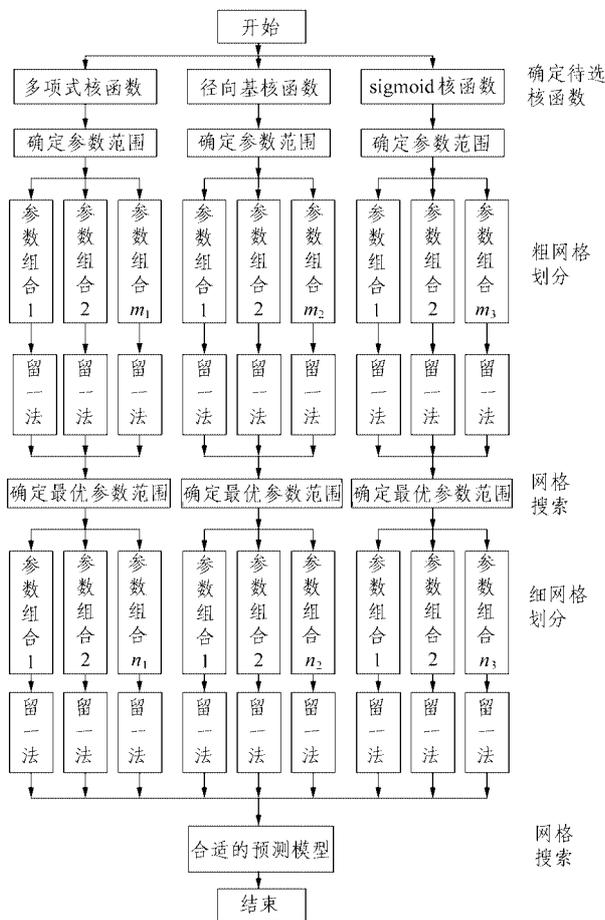


图 3 模型选择流程

Fig.3 Flow chart of model selection

采用留一法评价模型的预测效果，同时应用网格搜索法搜索合适的参数值，可以较为可靠的得到合适的预测模型，避免了传统方法中人为确定预测模型的缺点。另外，留一法和网格搜索法思路清晰，很容易用简洁的程序代码实现。利用简短的程序实现模型选择，比手工试验人为确定模型更快。

4 边坡稳定性预测

4.1 边坡稳定性影响因子的确定

影响边坡稳定性的因素较多，定量的因素有岩石重度 γ 、粘聚力 c 、内摩擦角 ϕ 、边坡角 ϕ_f 、边坡高度 H 、孔隙压力比 r_u 、地震烈度 q 等^[1, 6, 15-17]，定性的信息有岩性、破坏模式、岩土体结构类型、节理、节理面与边坡角的关系、地下水、岩体质量类别等^[6, 15]。影响边坡稳定性的指标有安全系数 F 、边坡稳定性状态等^[6]。本文主要计算边坡的安全系数。由于要进行定量计算，定性的指标转化为定量的数值存在一定的困难，因此，本文主要考虑岩石重度 γ 、粘聚力 c 、内摩擦角 ϕ 、边坡角 ϕ_f 、边坡高度 H 、孔隙压力比 r_u 等 6 个定量的影响因素。

4.2 边坡稳定性 ν -SVR 预测模型

类似文[6]，本文以边坡安全系数作为评价边坡稳定性的指标，建立数学模型对边坡的安全系数进行预测。现假设有若干边坡稳定性实例作为样本，记为 $\{x_i, y_i\}_{i=1}^l$ ， $x_i \in R^n$ 为影响边坡稳定性的定量因素，在本文中依次为岩石重度 γ 、粘聚力 c 、内摩擦角 ϕ 、边坡角 ϕ_f 、孔隙压力比 r_u 和边坡高度 H ； $y_i \in R$ 为相应的边坡安全系数，则可以建立如下关系：

$$y_i = f(x_i) \tag{14}$$

其中， $f: R^n \rightarrow R$ 。相应的边坡稳定性预测模型为

$$f(x) = \sum_{i=1}^l (\alpha_i^* - \alpha_i) K(x_i, x) + b \tag{15}$$

4.3 学习样本和预测样本的选取

本文以文[17]中收集到的 82 个危险圆弧破坏实例作为学习样本和预测样本。在这 82 个实例中，有 44 个破坏实例，38 个稳定实例。为了便于与其他计算方法的计算结果比较，本文类似文[17]，选取表中所列举的前 71 个实例作为学习样本，后 11 个实例作为预测样本，来检验模型预测效果。在文[17]中，大部分实例的孔隙压力未知。对于这些实例，其孔隙压力以文[17]中已经给出孔隙压力的实例的孔隙压力平均值 0.309 代替。

4.4 模型选择

为了获得合适的预测模型，本文分别选取多项式核函数、径向基核函数和 sigmoid 核函数等常用核函数进行测试。由于本次计算样本较小，可以采用留一法和网格搜索法进行模型选择。本次计算出最适合测试样本集的核函数为径向基核函数，最

优参数为 $C = 1.05$, $\nu = 0.68$, $\sigma^2 = 1.47$ 。利用径向基核函数与最优参数以及随机选取的几组参数分别建立边坡安全系数 ν -SVR 预测模型, 对 11 个未学习的样本分别进行预测, 其预测结果如表 1 所示。由表 1 可以看出, 利用最优参数建立的预测模型的预测效果最佳。因此, 本文利用径向基核函数与参数 $C = 1.05$, $\nu = 0.68$, $\sigma^2 = 1.47$ 建立边坡安全系数 ν -SVR 预测模型。

表 1 不同模型预测效果比较

Table 1 Results of slope safety factors predicted by different models

组号	C	ν	σ^2	平均相对误差/%	样本相对标准差/%
1	1.05	0.68	1.47	4.816	6.340 0
2	10.00	0.50	0.25	7.518	10.347 2
3	2.00	0.30	4.00	11.012	12.923 1
4	0.30	0.80	1.00	6.283	7.898 9
5	0.10	0.10	0.10	13.475	17.914 5
6	50.00	0.40	5.00	8.695	10.707 4

本次计算采用留一法和网格搜索法在 PC 机上搜索最优预测模型。因为样本较小, 整个过程总共花费了将近 8 h。相对于随机搜索算法, 该方法速度稍慢一些, 但是考虑到能够得到较为客观可靠的模型参数, 该计算成本是值得的。况且, 在以后的工作中, 可以直接利用该预测模型迅速预测出其他边坡的安全系数, 或者进行边坡设计(见本文节 5)。如

果样本数据量较大, 也可以首先采用常规的交互验证法, 将所有样本分为 5~10 份进行交互验证, 初步确定参数范围, 然后用留一法精确确定参数值。采用这种方法可以较大程度的减少计算量, 显著提高计算速度。

4.5 预测成果分析

根据已经确定的边坡稳定性 ν -SVR 预测模型, 对文[17]中的后 11 个边坡实例进行计算, 得出相应的预测安全系数, 如表 2 所示。从表 2 可以看出, 除了样本 73 的相对误差达到 13.565% 之外, 其他样本的相对误差均较小, 在 9% 以内; 平均相对误差为 4.816%, 小于 5%。这表明用 ν -SVR 进行边坡安全系数预测是合理可靠的。虽然与文[6]所采用的样本不同, 但本文预测的平均相对误差明显小于文[6]用 SVR 预测的 7.842% 的平均相对误差。这表明用 ν -SVR 算法进行边坡安全系数预测精度明显高于传统的 SVR 算法。下面提到的一些因素将影响预测精度, 它们是: 大部分样本没有给出参数孔隙压力比 r_u 的具体数值, 计算时这些样本的孔隙压力取已知样本的平均值 0.309; 样本的部分参数如粘聚力 c 、内摩擦角 φ 本身在测量过程中也不可避免存在一定的误差; 样本的安全系数虽然都是由采用极限平衡法计算得出的, 但具体的计算方法还是存在差别; 极限平衡法本身也没有充分考虑各种因素; 由于极限平衡法不能充分表达影响边坡稳定的因素与安全系数之间的关系, 计算结果也不可避免存在一定的误差; 其他一些影响因素如地震烈度 q 等由

表 2 基于 ν -SVR 算法的边坡安全系数预测成果Table 2 Results of slope safety factors predicted by ν -SVR algorithm

样本号	$\gamma/(\text{kN} \cdot \text{m}^{-3})$	c/kPa	$\varphi/(\circ)$	$\varphi_r/(\circ)$	H/m	r_u	实际安全系数	预测安全系数	绝对误差	相对误差/%
72	20.0	20.0	36	45.0	50	-	0.96	1.029 5	0.069 50	7.240
73	27.0	40.0	35	47.1	292	-	1.15	1.306 0	0.156 00	13.565
74	25.0	46.0	35	50.0	284	-	1.34	1.342 0	0.002 00	0.149
75	31.3	68.0	37	46.0	366	-	1.20	1.154 5	0.045 50	3.792
76	25.0	46.0	36	44.5	299	-	1.55	1.414 2	0.135 80	8.761
77	27.3	10.0	39	50.0	480	-	1.45	1.403 4	0.046 60	3.214
78	25.0	46.0	35	46.0	393	-	1.31	1.321 1	0.011 10	0.847
79	25.0	48.0	40	49.0	330	-	1.49	1.445 5	0.044 50	2.987
80	31.3	68.6	37	47.0	305	-	1.20	1.157 2	0.042 80	3.567
81	25.0	55.0	36	45.5	299	-	1.52	1.435 5	0.084 50	5.559
82	31.3	68.0	37	47.0	213	-	1.20	1.239 5	0.039 50	3.292
平均值									0.061 62	4.816
最大值									0.156 00	13.565

于样本本身的原因没有考虑。因此，可以说样本本身存在一定的误差。在这种条件下，能够得出本文的预测精度是完全可以接受的。

表 3 分别列举了基于改进 BP 神经网络算法、GA-BP 神经网络算法^[17]和 ν -SVR 算法预测的边坡安全系数及其误差。经比较， ν -SVR 算法预测结果的平均相对误差和相对误差标准差明显小于改进 BP 神经网络算法。与 GA-BP 神经网络算法相比较， ν -SVR 算法的平均相对误差稍大一点，相对误差标准差非常接近，最大相对误差略小一点。由此可见， ν -SVR 算法与 GA-BP 神经网络算法的精度在同一水平。考虑到 ν -SVR 算法的计算结果稳定，不像改进 BP 神经网络算法和 GA-BP 神经网络算法具有一定的随机性，而且 ν -SVR 算法不会陷入局部最优值。因此，可以说， ν -SVR 算法明显优于改进的 BP 神经网络算法和传统的 SVR 算法。与 GA-BP 神经网络算法相比，两者各有特色， ν -SVR 算法稍有优势。

5 基于 ν -SVR 算法的边坡设计方法

由于 ν -SVR 具有较强的学习能力，通过对少量已知边坡安全系数的实例进行学习，能够在提供相应的影响因子数值的基础之上，给出精度较高的边

坡安全系数预测值。因此，本文提出基于 ν -SVR 算法的边坡设计方法。在进行边坡设计时，可以根据已经训练好的边坡稳定性 ν -SVR 预测模型，快速准确的设计出安全、经济的边坡形状。设计程序如下：

- (1) 收集边坡稳定性判断实例及其相关资料和已计算出的安全系数。
- (2) 利用 ν -SVR 对搜集到的边坡稳定性实例进行训练，求出相应的边坡稳定性 ν -SVR 预测模型。
- (3) 根据边坡所处位置的实际情况，提出若干组既能反映边坡形状又符合工程实际的方案，给出相应的参数，如边坡角 ϕ_r 、边坡高度 H ，并分别与其他已知的影响因子如岩石重度 γ 、粘聚力 c 、内摩擦角 ϕ 、孔隙压力比 r_u 、地震烈度 q 等一起输入边坡安全系数 ν -SVR 预测模型中，计算出相对应的边坡安全系数。
- (4) 从计算结果中选择出既能保证边坡安全、又经济的 2, 3 个方案，利用传统的极限平衡法加以验证。
- (5) 利用计算出的最佳边坡方案指导设计。

在这个设计程序中，第(1)，(2)步可以在进行设计以前完成。在确定了边坡稳定性 ν -SVR 预测模型以后，完成第(3)步非常简单快捷，只要将相关的参

表 3 基于改进 BP 神经网络算法、GA-BP 神经网络算法和 ν -SVR 算法的边坡安全系数预测成果比较

Table 3 Comparison of prediction results of slope safety factors by BP neural network algorithm, GA-BP neural network algorithm and ν -SVR algorithm

样本号	极限平衡法安全系数	安全系数预测误差								
		改进 BP 神经网络算法			GA-BP 神经网络算法			ν -SVR 算法		
		安全系数	绝对误差	相对误差/%	安全系数	绝对误差	相对误差/%	安全系数	绝对误差	相对误差/%
72	0.96	1.03	0.070 0	7.290	1.092 8	0.132 8	13.835	1.044 7	0.069 5	7.240
73	1.15	1.16	0.010 0	0.870	1.254 3	0.104 3	9.069	1.314 3	0.156 0	13.565
74	1.34	1.44	0.100 0	7.460	1.221 8	0.118 2	8.822	1.348 1	0.002 0	0.149
75	1.20	1.14	0.060 0	5.000	1.202 2	0.002 2	0.183	1.174 4	0.045 5	3.792
76	1.55	1.62	0.070 0	4.520	1.500 5	0.049 6	3.197	1.419 7	0.135 8	8.761
77	1.45	1.41	0.040 0	2.760	1.457 0	0.006 9	0.479	1.421 8	0.046 6	3.214
78	1.31	1.47	0.160 0	12.210	1.267 8	0.042 2	3.223	1.313 0	0.011 1	0.847
79	1.49	1.60	0.110 0	7.380	1.559 4	0.069 4	4.659	1.462 1	0.044 5	2.987
80	1.20	1.18	0.020 0	1.670	1.197 7	0.002 3	0.190	1.165 8	0.042 8	3.567
81	1.52	1.64	0.120 0	7.900	1.488 3	0.031 7	2.086	1.438 3	0.084 5	5.559
82	1.20	1.14	0.060 0	5.000	1.206 3	0.006 3	0.527	1.220 4	0.039 5	3.292
平均值			0.075 0	5.642		0.051 0	4.206		0.061 6	4.816
样本标准差			0.090 1	6.755		0.072 6	6.314		0.080 3	6.340
最大值			0.160 0	12.210		0.132 8	13.835		0.156 0	13.565

数输入 ν -SVR 预测模型立刻可以输出安全系数, 判断该方案的稳定性, 整个过程只要几分钟。

基于 ν -SVR 算法的边坡设计方法能够考虑影响边坡的多个因素, 获得成果的精度较高, 而且计算简单快捷, 工作量小, 易于被包括基层技术人员在内的各种层次的技术人员掌握。因此, 它是一种行之有效的边坡设计方法。

6 结 语

(1) 本文提出的基于 ν -SVR 算法的边坡稳定性预测方法, 不仅能够考虑边坡多因素的影响, 评价边坡稳定性, 获得精度较高的预测成果, 而且计算简单, 工作量小。

(2) 本文提出一种基于 ν -SVR 算法的边坡设计方法, 能够快速、准确获取不同方案的边坡安全系数, 评价其稳定性, 为经济合理地选择边坡设计方案提供可靠的保障。该方法简单易行, 易于被包括基层技术人员在内的各种层次的技术人员掌握。

(3) 在建立 ν -SVR 预测模型过程中, 模型选择是一个关键问题。通常采用经验的方法选取核函数和相关参数, 具有一定的随意性。留一法和网格搜索法相结合, 能够客观可靠的获得合适的预测模型。本文采用这种方法, 搜索到了较优的预测模型, 提高了预测的精度。

参考文献(References) :

- [1] 付义祥, 刘世凯, 刘大鹏. RBF 神经网络在边坡岩体稳定性中的预测研究[J]. 武汉理工大学学报(交通科学与工程版), 2003, 27(2): 170-173.(Fu Yixiang, Liu Shikai, Liu Dapeng. Prediction models to estimate stability of rock slope based on RBF neural network[J]. Journal of Wuhan University of Technology (Transportation Science & Engineering), 2003, 27(2): 170-173.(in Chinese))
- [2] 冯夏庭, 王泳嘉, 卢世宗. 边坡稳定性的神经网络估计[J]. 工程地质学报, 1995, 3(4): 54-61.(Feng Xiating, Wang Yongjia, Lu Shizong. Neural network estimation of slope stability[J]. Journal of Engineering Geology, 1995, 3(4): 54-61.(in Chinese))
- [3] 赵登福, 王蒙, 张讲社, 等. 基于支撑向量机方法的短期负荷预测[J]. 中国电机工程学报, 2002, 22(4): 26-30.(Zhao Dengfu, Wang Meng, Zhang Jiangshe, et al. A support vector machine approach for short term load forecasting[J]. Proceedings of the CSEE, 2002, 22(4): 26-30.(in Chinese))
- [4] Vapnik V N. 统计学习理论的本质[M]. 张学工译. 北京: 清华大学出版社, 2000.(Vapnik V N. The Nature of Statistical Learning Theory(2nd Edition)[M]. Translated by Zhang Xuegong. Beijing: Tsinghua University Press, 2000.(in Chinese))
- [5] 王景雷, 吴景社, 孙景生, 等. 支持向量机在地下水位预报中的应用研究[J]. 水利学报, 2003, (5): 122-128.(Wang Jinglei, Wu Jingshe, Sun Jingsheng, et al. Application of support vector machine method to prediction of ground water level[J]. Journal of Hydraulic Engineering, 2003, (5): 122-128.(in Chinese))
- [6] 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 to slope stability evaluation[J]. Chinese Journal of Rock Mechanics and Engineering, 2003, 22(2): 241-245.(in Chinese))
- [7] Schölkopf B, Smola A, Williamson R C, et al. New support vector algorithms[J]. Neural Computation, 2000, 12(5): 1207-1245.
- [8] 柳回春, 马树元. 支持向量机的研究现状[J]. 中国图像图形学报, 2002, 7(6): 618-623.(Liu Huichun, Ma Shuyuan. Research progress of support vector machines[J]. Journal of Image and Graphics, 2002, 7(6): 618-623.(in Chinese))
- [9] Platt J. Fast training of support vector machines using sequential minimal optimization[A]. In: Advances in Kernel Methods—Support Vector Learning [C]. Cambridge, MA: MIT Press, 1999. 185-208.
- [10] Browne M W. Cross-validation methods[J]. Journal of Mathematical Psychology, 2000, 44(1): 108-132.
- [11] Xie Z J, Wong H, Ip W C, et al. Artificial neural network and its application to financial forecasting[J]. Acta Scientiarum Naturalium Universitatis Pekinensis, 2001, 37(3): 421-425.
- [12] Gold C, Sollich P. Model selection for support vector machine classification[J]. Neurocomputing, 2003, 55(1/2): 221-249.
- [13] Chalimourda A, Schölkopf B, Smola A J. Experimentally optimal ν in support vector regression for different noise models and parameter settings[J]. Neural Networks, 2004, 17(1): 127-141.
- [14] Chang C C, Lin C J. LIBSVM: a library for support vector machines[R]. Technical Report, Department of Computer Science and Information Engineering, National Taiwan University, 2001.
- [15] 贺可强, 雷建和. 边坡稳定性的神经网络预测研究[J]. 地质与勘探, 2001, 37(6): 72-75.(He Keqiang, Lei Jianhe. A prediction of the slope stability based on neural network[J]. Geology and Prospecting, 2001, 37(6): 72-75.(in Chinese))
- [16] 张吉萍, 陈虬. BP 网络在边坡稳定性分析中的应用[J]. 西南交通大学学报, 2001, 36(6): 648-650.(Zhang Jiping, Cheng Qiu. Application of BP networks to the stability analysis of slopes[J]. Journal of Southwest Jiaotong University, 2001, 36(6): 648-650.(in Chinese))
- [17] 冯夏庭. 智能岩石力学导论[M]. 北京: 科学出版社, 2000.(Feng Xiating. Introduction to Intelligent Rock Mechanics[M]. Beijing: Science Press, 2000.(in Chinese))