

滑坡位移序列的支持向量机研究

摘 要

在我国，随着国民经济建设的发展，岩土工程建设规模急剧扩大，滑坡问题也越来越引起人们的重视，滑坡已经成为继地震、火山等之后对人类的生活和生产重大的灾害之一。其机理复杂，影响因素众多；由于边坡破坏方式、变形演化过程的复杂多变性，建立精确的数学模型来模拟边坡的稳定性及建立精确的预报模型来预测滑坡的时间、空间演化均存在很大困难。智能岩石力学的提出和发展为其预测提供新的途径，支持向量机和遗传算法的结合，对解决很难用数学模型描述的问题具有很好的适应性，并且具有很广泛的应用前景。本文在前人研究的基础上，将遗传算法和支持向量机结合起来，构成进化支持向量机，对滑坡的位移进行预测，本文主要工作如下：

(1) 利用支持向量机的具有处理小样本、高维数、非线性等优良特性，应用遗传算法，快速搜索支持向量机的核函数因子和惩罚因子等参数，可以避免人为选择支持向量机参数的盲目性；同时遗传算法搜索位移序列构成的维数，可以构成比较具有代表性的预测样本。

(2) 本文利用遗传算法和支持向量机理论，利用 VC++ 开发工具开发滑坡预测可视化系统的预测模块。

(3) 深入分析福建八尺门滑坡和广西龙滩水电站的位移监测数据，挖掘其中的规律；根据其监测位移数据构成进化支持向量机的学习样本，建立基于进化支持向量机的单位移时间序列模型，对八尺门滑坡位移进行预测。对于同样的数据利用神经网络进行构成学习样本，并进行预测，比较其结果

(4) 针对降雨量和地下水位等因素对滑坡变化产生的很大影响，深入研究福建八尺门的降雨量和地下水位数据，并和位移数据相关联起来，建立基于进化支持向量机的多因素（位移、降雨量和地下水位时间序列模型），对福建八尺门的位移数据进行预测，检查其预测效果。

关键词： 时间序列 统计学习理论 滑坡位移预测 支持向量机

Prediction of landslide displacement series by the support vector machine

ABSTRACT

With the country economy developing and enlargement of rock and soil engineering, the landslide problems lead to more and more recognition by people. Landslide has become serious geological hazardousness in our living and production after earthquake volcano that complex mechanism, influence many factors: on the base of landslide destruction mode, transmutation evolution process of complex levity. It is very difficult to establish precise mathematic model to simulate landslide stability and to establish prediction simulation to predict time and dimension evolution. The suggestion and advance of intelligent rock mechanics provide the landslide prediction with a new track. With the support vector machine (SVM) and the genetic algorithm (GA) being combined, it has better adaptability for the question that is difficult to be described by mathematic model and has also widely recent advances. The evolution SVM consists and the landslide displacement is predict with the the genetic algorithm and the support vector machine combined, in the basis of people beor. The primary tasks are stated as followed:

(1) The parameters of the support vector machine are searched speedily and the representational samples are speedily constituted, such as the core function and punishing parameters, which makes use of the best characteristic, for example, little samples, high dimensions, nonlinearity, and make use of the improved genetic algorithm.

(2) The predicting module of the visial and predicting landslide system is exploit vc++ developed tool with the theory of the support vector machines and the genetic algorithm.

(3) With the monitoring displacement data of Bachimen of Fujian and Longtan of Guangxi analysed thoroughly, the studying samples are consited according the corresponding displacement data. It is that the landslide displacement model of the one factor time series are established, and the displacement of the Bachimen landslid are predicted. The studying samples are consisted with NN for the same data, the prediction

is carried out, the result is compared with the support vector machine.

(4) The displacement data is related with the the rainfall and the level of underground water analysed thorouly, as to the greatly influence to the landslide evolution by the rainfall and the underground water. It is that the landslide displacement model of the many factors time series is established that are made up of the rainfall, the level of the underground water and the landslide displacement. The data of landslide displacement are predicted that are compared with the measured data.

Key words: time series; the theory of the statistic studying; prediction of landslide displacement; the support vector machine

独创性声明

本人声明所呈交的学位论文是在导师的指导下完成的。论文中取得的研究成果除加以标注和致谢的地方外，不包含其他人已经发表或撰写过的研究成果，也不包括本人为获得其他学位而使用过的材料。与我一同工作的同志对本研究所做的任何贡献均已在论文中作了明确的说明并表示谢意。

学位论文作者签名：刘天浩

日期：2004.12.25

学位论文版权使用授权书

本学位论文作者和指导教师完全了解东北大学有关保留、使用学位论文的规定：即学校有权保留并向国家有关部门或机构送交论文的复印件和磁盘，允许论文被查阅和借阅。本人授权东北大学可以将学位论文的全部或部分内容编入有关数据库进行检索、交流。

(如作者和导师同意网上交流，请在下方签名；否则视为不同意。)

学位论文作者签名：刘天浩

导师签名：冯启超

签字日期：2004.12.25

签字日期：2004.12.25

第一章 绪 论

1.1 引言

广义滑坡,即各类滑坡、崩塌、泥石流,可因多种外界因素的刺激而发生,如地震、火山、河流冲刷、融雪、降雨及不良人类活动等,其中以降雨诱发的滑坡(通常称为降雨滑坡)在世界上分布最广,发生频率最高,在诸类滑坡中给人类造成的危害最大^[1]。因而,各国政府和相关国际组织对滑坡的预测预报极为重视。为了使人类遭受滑坡的灾害减少到最少程度,及时做好有关方面的防范和预测措施,对滑坡变形破坏机制的研究就显得尤为重要,特别使滑坡灾害发生时间和空间的准确预测、预报工作占有举足轻重的地位^[2]。

滑坡滑动时间的预测预报是世界公认的尖端课题。由于滑坡地质过程、形成条件、诱发因素的复杂性、多样性及其变化的随机性、非稳定性、从而导致滑坡动态信息极难捕捉,加之滑坡动态监测技术的不成熟和滑坡理论的不完善。滑坡滑动时间的预测预报一直被认为是一项十分困难的前沿课题^[3]。迄今为止,滑坡变形及失稳时间预测预报尚处在统计分析阶段,由于实测数据的离散性,统计拟合只能保证有限的精度;考虑流变或几何非线性的有限元法虽是一个具有发展潜力的分析方法,但由于滑坡物理力学机制的复杂性,目前难以广泛应用于工程实际。因此,当滑坡出现加速蠕变,建立实时监测—预警系统是很有必要的此时,要求数学模型能够充分利用滑坡位移时间序列资料、跟踪和预测各种变形轨迹和复杂数据序列;以确保较高的预测精度^[4,5]。

但由于工程地质条件的复杂、自然条件的变化以及人类工程活动等因素的随机性和不可控制性,现阶段对滑坡作出准确可靠的预报还是十分困难的。从过去已经发生的滑坡地质灾害来看,当前绝大多数的滑坡都很难做到提前预报,边坡破坏方式、变形过程究其原因,主要在于:一方面是滑坡成灾机理的影响因素复杂,不确定性因素变形机制复杂多变,大大增加了预报的难度;另一方面是人们对滑坡危害性的认识不足和受到资金的限制,现在只有极少数的重大滑坡实施了长期监测,而大多数的滑坡未采取任何的工程措施,以致很多滑坡都是在没有任何监控的条件下突然发生的^[6]。

1.2 研究的意义

随着我国西部大开发的开展,以及水电、煤炭、石油等能源和资源的开发,工程建设的规模愈来愈大,地下硐室越挖越深,跨度越来越大,大坝越筑越高,边

第一章 绪 论

1.1 引言

广义滑坡,即各类滑坡、崩塌、泥石流,可因多种外界因素的刺激而发生,如地震、火山、河流冲刷、融雪、降雨及不良人类活动等,其中以降雨诱发的滑坡(通常称为降雨滑坡)在世界上分布最广,发生频率最高,在诸类滑坡中给人类造成的危害最大^[1]。因而,各国政府和相关国际组织对滑坡的预测预报极为重视。为了使人类遭受滑坡的灾害减少到最少程度,及时做好有关方面的防范和预测措施,对滑坡变形破坏机制的研究就显得尤为重要,特别使滑坡灾害发生时间和空间的准确预测、预报工作占有举足轻重的地位^[2]。

滑坡滑动时间的预测预报是世界公认的尖端课题。由于滑坡地质过程、形成条件、诱发因素的复杂性、多样性及其变化的随机性、非稳定性、从而导致滑坡动态信息极难捕捉,加之滑坡动态监测技术的不成熟和滑坡理论的不完善。滑坡滑动时间的预测预报一直被认为是一项十分困难的前沿课题^[3]。迄今为止,滑坡变形及失稳时间预测预报尚处在统计分析阶段,由于实测数据的离散性,统计拟合只能保证有限的精度;考虑流变或几何非线性的有限元法虽是一个具有发展潜力的分析方法,但由于滑坡物理力学机制的复杂性,目前难以广泛应用于工程实际。因此,当滑坡出现加速蠕变,建立实时监测—预警系统是很有必要的此时,要求数学模型能够充分利用滑坡位移时间序列资料、跟踪和预测各种变形轨迹和复杂数据序列;以确保较高的预测精度^[4,5]。

但由于工程地质条件的复杂、自然条件的变化以及人类工程活动等因素的随机性和不可控制性,现阶段对滑坡作出准确可靠的预报还是十分困难的。从过去已经发生的滑坡地质灾害来看,当前绝大多数的滑坡都很难做到提前预报,边坡破坏方式、变形过程究其原因,主要在于:一方面是滑坡成灾机理的影响因素复杂,不确定性因素变形机制复杂多变,大大增加了预报的难度;另一方面是人们对滑坡危害性的认识不足和受到资金的限制,现在只有极少数的重大滑坡实施了长期监测,而大多数的滑坡未采取任何的工程措施,以致很多滑坡都是在没有任何监控的条件下突然发生的^[6]。

1.2 研究的意义

随着我国西部大开发的开展,以及水电、煤炭、石油等能源和资源的开发,工程建设的规模愈来愈大,地下硐室越挖越深,跨度越来越大,大坝越筑越高,边

坡更深更陡，这些都给滑坡的研究者带来了机遇和挑战；同时，在城市建设中，建筑高度、建筑密度不断增加，基坑越来越深，周围建筑物离基坑越来越近，对基坑的开挖工作及其支护技术都提出了更高更严的要求，以保证邻近建筑物等的安全；所有这些都要求我们对滑坡的力学行为非常了解。

随着数值计算方法的发展，为求解复杂的滑坡工程问题提供了有力的手段。但是数值方法需要对滑坡的力学参数、本构关系等有非常清晰的了解。而滑坡的力学参数、等是数值方法是否成功的关键。试图从改进试验技术和采用新的试验手段解决有关滑坡工程的问题进展很慢。以现场监测信息为基础的反分析正是在这种情况下发展起来的一种实用手段，并在工程实践中取得成功的应用，引起国内外工程界的广泛重视；同时利用获得的监测信息进行滑坡力学行为的研究也受到工程领域和学术研究的重视。

由于滑坡的力学行为十分复杂，很难定量预测，即使是进行现场大型试验，往往也只能获得局部的尺度有限的力学参数，更大范围的宏观和平均意义的特性和参数几乎无法直接预测。用智能岩石力学的思想，对滑坡力学行为进行估计，由于智能方法的普适性，以及它不需对滑坡做过多的假设，因此具有广泛的应用前景。

支持向量机^[7] (Support Vector Machine) 是基于统计学习理论的一种新的通用机器学习方法，它是建立在一套较好的有限样本机器学习的理论框架和通用方法之下，其基本思想是通过用内积函数定义的非线性变换将输入空间变换到一个高维空间，在这个高维空间中寻找输入变量和输出变量之间的一种非线性关系。支持向量机采用结构风险最小化原则，比采用经验风险最小化原则的神经网络具有更好的泛化能力；与传统的统计学相比，统计学习理论是一种专门研究小样本(有限样本)情况下的机器学习规律的理论，而支持向量机的理论基础就是统计学习理论；因此，支持向量机方法既有严格的理论基础，又能较好地解决小样本、高维数、非线性和局部极小点等实际问题。

将支持向量机方法应用于滑坡力学行为的研究，通过对有限样本的学习，建立滑坡力学行为非线性关系的支持向量机模型，从而达到对滑坡的力学行为进行辨识和预测，这对于滑坡理论的发展和滑坡工程施工都具有重要的理论意义和实际意义^[10,12]。

1.3 国内外研究现状

滑坡测预报研究至今已有 50 余年约的历史，这期间国内外许多滑坡专家潜心研究，不断探索，使滑坡预报的理论和方法有了较大的发展，纵观其发展过程大致可分为 3 个阶段，现象预报和经验式预报，这一阶段处于 20 世纪 60~70 年代，

坡更深更陡，这些都给滑坡的研究者带来了机遇和挑战；同时，在城市建设中，建筑高度、建筑密度不断增加，基坑越来越深，周围建筑物离基坑越来越近，对基坑的开挖工作及其支护技术都提出了更高更严的要求，以保证邻近建筑物等的安全；所有这些都要求我们对滑坡的力学行为非常了解。

随着数值计算方法的发展，为求解复杂的滑坡工程问题提供了有力的手段。但是数值方法需要对滑坡的力学参数、本构关系等有非常清晰的了解。而滑坡的力学参数、等是数值方法是否成功的关键。试图从改进试验技术和采用新的试验手段解决有关滑坡工程的问题进展很慢。以现场监测信息为基础的反分析正是在这种情况下发展起来的一种实用手段，并在工程实践中取得成功的应用，引起国内外工程界的广泛重视；同时利用获得的监测信息进行滑坡力学行为的研究也受到工程领域和学术研究的重视。

由于滑坡的力学行为十分复杂，很难定量预测，即使是进行现场大型试验，往往也只能获得局部的尺度有限的力学参数，更大范围的宏观和平均意义的特性和参数几乎无法直接预测。用智能岩石力学的思想，对滑坡力学行为进行估计，由于智能方法的普适性，以及它不需对滑坡做过多的假设，因此具有广泛的应用前景。

支持向量机^[7] (Support Vector Machine) 是基于统计学习理论的一种新的通用机器学习方法，它是建立在一套较好的有限样本机器学习的理论框架和通用方法之下，其基本思想是通过用内积函数定义的非线性变换将输入空间变换到一个高维空间，在这个高维空间中寻找输入变量和输出变量之间的一种非线性关系。支持向量机采用结构风险最小化原则，比采用经验风险最小化原则的神经网络具有更好的泛化能力；与传统的统计学相比，统计学习理论是一种专门研究小样本(有限样本)情况下的机器学习规律的理论，而支持向量机的理论基础就是统计学习理论；因此，支持向量机方法既有严格的理论基础，又能较好地对解决小样本、高维数、非线性和局部极小点等实际问题。

将支持向量机方法应用于滑坡力学行为的研究，通过对有限样本的学习，建立滑坡力学行为非线性关系的支持向量机模型，从而达到对滑坡的力学行为进行辨识和预测，这对于滑坡理论的发展和滑坡工程施工都具有重要的理论意义和实际意义^[10,12]。

1.3 国内外研究现状

滑坡测预报研究至今已有 50 余年约的历史，这期间国内外许多滑坡专家潜心研究，不断探索，使滑坡预报的理论和方法有了较大的发展，纵观其发展过程大致可分为 3 个阶段，现象预报和经验式预报，这一阶段处于 20 世纪 60~70 年代，

滑坡预报主要以现象预报和经验预报为主。人们利用滑坡的一些变形破坏现象和失稳的宏观前兆现象。对滑坡失稳进行推断。显然这种方法只适用于有明显前兆的滑坡，预测精度也不高。1968年日本学者斋藤通过大量的实验，提出了蠕变破坏三阶段理论，建立加速蠕变的微分方程^[11]，模型曾于1970年对日本的高汤山滑坡进行了成功的预报。此后，E. Hoek 根据智利的huquicamata矿滑坡监测时——位移曲线提出了利用滑坡变形曲线的形态和趋势并进行外延并推求滑动时间的外延法^[12]，其预报的理论依据与斋藤是相同的。由于这些方法是在一定条件下建立的经验模式，所求得的蠕变破坏时间属于概算，预报精度受到一定的限制，仅适用于中短期预报和临滑预报。

位移—时间统计预测阶段。进入80年代，国内外许多学者大量引入各种数学方法与理论模型，用于拟合不同滑坡的位移—时间曲线。根据所建的模型作外推预报。1984年，王思敬教授提出边坡失稳前总变形量和位移速率的综合预报方法^[13]。1988年，陈明东、王兰生教授首次将灰色系统理论中的GM(1, 1)模型引入滑坡位移—时间曲线的拟合外推，提出利用滤波灰色分析法进行滑坡的中期预报^[14]。晏同珍教授根据滑坡孕育、发展和发生的过程特征，提出了二次曲线回归拟合和灰色理论中Verhulst生物繁衍的动态模型预测方法^[15]。此外，还有不少学者尝试了马尔科夫预报、模糊数学方法预报、泊松旋回预报和图解法等多种方法，使滑坡预报方法向定量化方向迈进一大步。但是，这一阶段学者主要注重预报方法的探讨对与滑坡密切相关的一些基本问题，如观测数据的分析、处理、预报时序资料的选择、干扰信息的剔除与有用信息的增强等还认识不足；对滑坡基础研究与预报相结合方面的探讨也较少，也很少在利用上述先进理论和方法的同时，将预报参数与斜坡变形破坏和演变机制联系起来考虑，从而大大的影响了预报精度。

综合预报模型及预报判据研究阶段。随着滑坡研究的深入发展，20世纪90年代人们认识到滑坡位移—时间曲线的拟合常常只能对滑坡近期行为趋势作出有限预测，在众多因素中，尤其是非线性因素的作用下，要准确可靠地预报滑坡的长期行为是困难的。因此，学者们逐步形成了跟踪预报的思想。李天斌、余宏明等对此作了有益的探索，利用滑坡动态数据的时间序列分析法建模的思想，提出了滑坡动态跟踪预测的观点^[16]。

另一方面，由于系统科学和非线性科学的发展，人们认识到滑坡是一个开放系统。滑坡预报不仅仅是一个纯方法问题，要实现较为准确的预报，必须将斜坡变形破坏机制分析与定量预报相结合，必须对与滑坡密切相关的基本问题进行研究，运用系统分析、系统模拟的方法对滑坡系统进行识别、模拟及预测预报。因此人们开始重视对滑坡宏观前兆和宏观判据的研究，并着重从物理现象和物理模型分析入手进行滑坡预报的探索。1993年，秦四清以非线性动力学理论为基础，提出

滑坡孕育的非线性动力学模型,进而预报滑坡发生时间^[17]。1994年,廖小平 据弹塑力学原理提出了滑坡预测的功率模型^[18]。

综上所述,滑滑坡灾害预测已进入了多类多种预测模型并存发展阶段。无论是理论分析,还是实践检验,灰色预测模型均已趋于成熟^[19],故已成为目前滑坡灾害预测的主导模型,并具有广泛的应用前景。Polemio (2000) 建立了2000年以前公开文献中具有参考价值的降雨滑坡文献数据库,库内收录了世界各国学者的138篇研究论文。初步统计全球至少有23个国家和地区的学者对降雨滑坡进行了不同程度的研究,以美国、意大利、香港(地区)、日本、英国、澳大利亚和新西兰学者发表的研究论文最多,研究水平明显领先于其它各国的同类研究。在Polemio建立的数据库中,69%的论文研究群发性降雨滑坡,其余31%研究单个或数个滑坡;在单体滑坡研究中,40%的论文研究深层滑坡(滑坡厚度达于10米),包括复活型深层滑坡,其余研究浅层或表层滑坡。随着我国政府对滑坡灾害预测预报工作的重视,特别是汛期滑坡灾害预测预报的起步,了解、掌握降雨滑坡预测预报的国外动态、研究现状与发展趋势,对提高我国该类滑坡的预测预报能力。

1995年,在“减灾十年”行动中,联合国会员大会要求“国际减灾十年计划”秘书处分析全球及各国对包括滑坡在内的各类自然灾害的早期预警能力,提出开展相关的国际合作研究的建议与计划,进而促进、提高全球对自然灾害的预测预报能力和研究水平。为此,“国际减灾十年秘书处”成立了包括地质灾害在内的6个专家工作小组。1997年专家工作组提交了“国家及局部地区灾害早期预警能力评述报告”,报告提出了建立国家和局部地区不同层次上有效的早期预警系统的指导原则。专家组报告指出,有效的、不同层次的早期预警系统必须建立在科学的、不同层次的灾害危险性评价基础上,其中包括灾害敏感性、危险性和易损性分区评价等。只有这样,灾害早期预警才有实际意义,才能真正为不同层次的决策者制定减灾对策提供科学依据。对于滑坡灾害,专家报告指出,由于滑坡类型多样、发育条件复杂、诱发因素变化多端,所以准确的滑坡预测预报非常困难。以目前的研究水平而言,从长、中、短三个时段进行滑坡预测预报可能较为现实。各种类型的滑坡灾害图,如滑坡分布图、易发性分区图、危险性分区图、风险性分区图等可预测灾害的长期发展趋势。对区域性的降雨滑坡,在深入、详细的前期研究和大量的资料积累基础上,建立滑坡、降雨统计关系,根据天气演变模式和降雨强度、降雨持续时间变化,可进行该类滑坡的中期和短期预报。专家组报告提醒:(1)由于滑坡发育、分布和气象条件都具有很大的局部性特点,降雨滑坡预报判据应因地制宜;(2)深入的滑坡形成机理和活动过程研究,不仅有助于建立更加准确的滑坡、降雨统计关系,而且是建立滑坡、降雨理论关系模型的基础。

1.4 存在的问题

目前滑坡预测预报取得了巨大的成就。空间预测从传统的安全系数法到现在的模糊理论综合评判的方法,时间预报从斋滕法到现在的人工智能的引入,而且在实际工程中都得到了很好的验证。但由于工程地质条件的复杂、自然条件的变化以及人类工程活动等因素的随机性和不可控制性,现阶段对滑坡作出准确可靠的预报还是十分困难的。从过去已经发生的滑坡地质灾害来看,当前绝大多数的滑坡都很难做到提前预报,究其原因,主要在于:一方面是滑坡成灾机理的影响因素复杂,不确定性因素较多,边坡破坏方式、变形过程和变形机制复杂多变,大大增加了预报的难度;另一方面是人们对滑坡危害性的认识不足和受到资金的限制,现在只有极少数的重大滑坡实施了长期监测,而大多数的滑坡未采取任何的工程措施,以致很多滑坡都是在没有任何监控的条件下突然发生的;还有人认为滑坡空间预测较为容易,而时间预测较为困难,因而大力发展时间预测却忽略空间预测。这些均是目前滑坡治理中存在的问题。

应该肯定,边坡的监测是确保工程安全,进行预测预报和掌握滑坡体失稳机理最重要的手段之一。由于边坡本身具有的复杂性及目前边坡稳定性研究水平,边坡监测是边坡稳定性分析中不可缺少的,也是至关重要的研究内容。目前这方面取得了很大的成就:一方面各种先进的监测仪器不断涌出,尤其是自动化程度高的遥测系统,如GPS监测系统,遥感地质及探地雷达在滑坡调查中的应用等;另一方面是监测设计方法的优化及监测数据处理的进步,如立体监测方法的出现及应用灰色理论、神经网络、专家系统进行监测预报等。

综上所述,目前要达到用精确的数学模型来模拟边坡稳定性问题和用精确的预报模型来预测滑坡的时间和空间问题,还相当困难。在目前的研究阶段,解决实际问题在很大程度上靠各种经验与事实的类比。因此,我们首先必须大力加强边坡的监测工作,做到理论与实际监测数据相一致;应该对长期以来边坡研究积累的大量现场资料 and 实践经验进行系统研究,建立有效的专家系统,作为“知识库”;必须大力开展重点国土开发区的滑坡预测,做到空间预测和时间预报相结合;必须加强现场实验和模型实验相结合的方法来确定岩体力学参数;在滑坡预报时,把宏观观测和微观监测的方法结合起来,用微观监测方法进行早期观测预报,用宏观监测方法进行近期预报。近年来,人工智能方法在滑坡预报方面取得了很大的进展,它不仅可用于空间预测,而且还可用于时间预报,这种方法与一般统计学方法相比有很多优点,具有广阔的发展前景。

由于边坡系统是复杂的动态系统,仅仅用一种或两种方法是很难达到预期的精度和效果。因此,在进行预测预报时应该综合多种有效的方法进行对比研

究，把模型实验与理论模型相结合，并选择最适合的模型来预测某一具体的边坡。

1.5 本文的主要工作

目前要达到用精确的数学模型来模拟边坡稳定性问题和用精确的预报模型来预测滑坡的时间和空间问题，还相当困难。在目前的研究阶段，解决实际问题在很大程度上靠各种经验与事实的类比。因此采用基于遗传算法的支持向量机预测，可以建立相应的模型，来处理滑坡预测。本文按照智能岩石力学的思想，将支持向量机和遗传算法应用滑坡位移的预测，构成单位移和多因素时间序列。主要工作如下：

(1) 利用支持向量机的具有处理小样本、高维数、非线性等优良特性，应用遗传算法，快速搜索支持向量机的参数，并快速构成较具代表性的样本。

(2) 建立滑坡位移的单位移时间序列模型，并和神经网络进行比较，进化支持向量机具有较好的学习能力和更强的推广能力。

(3) 建立滑坡位移多因素时间序列模型。针对降雨量对滑坡产生的很大影响，建立含有降雨量和滑坡位移的时间序列模型，对实际测量数据进行预测。由于地下水位对滑坡的位移变化有较大的影响，建立含有降雨量、地下水位和滑坡位移的时间序列支持向量机模型，并对实际测量数据进行预测。

究，把模型实验与理论模型相结合，并选择最适合的模型来预测某一具体的边坡。

1.5 本文的主要工作

目前要达到用精确的数学模型来模拟边坡稳定性问题和用精确的预报模型来预测滑坡的时间和空间问题，还相当困难。在目前的研究阶段，解决实际问题在很大程度上靠各种经验与事实的类比。因此采用基于遗传算法的支持向量机预测，可以建立相应的模型，来处理滑坡预测。本文按照智能岩石力学的思想，将支持向量机和遗传算法应用滑坡位移的预测，构成单位移和多因素时间序列。主要工作如下：

(1) 利用支持向量机的具有处理小样本、高维数、非线性等优良特性，应用遗传算法，快速搜索支持向量机的参数，并快速构成较具代表性的样本。

(2) 建立滑坡位移的单位移时间序列模型，并和神经网络进行比较，进化支持向量机具有较好的学习能力和更强的推广能力。

(3) 建立滑坡位移多因素时间序列模型。针对降雨量对滑坡产生的很大影响，建立含有降雨量和滑坡位移的时间序列模型，对实际测量数据进行预测。由于地下水位对滑坡的位移变化有较大的影响，建立含有降雨量、地下水位和滑坡位移的时间序列支持向量机模型，并对实际测量数据进行预测。

第二章 理论基础

2.1 引言

机器学习研究从观测数据出发寻找规律, 利用这些规律对未来数据或无法观测的数据进行预测。机器学习是基于数据的现代智能技术中的重要方面, 现有机器学习方法(包括模式识别、神经网络等)共同的重要理论基础之一是统计学。传统统计学研究的是样本数目趋于无穷大时的渐进理论, 现有学习方法也多是基于此假设。但在实际问题中, 样本数往往是有限的, 因此一些理论上很优秀的学习方法实际中表现却可能不尽人意。

与传统统计学相比, 统计学习理论(Statistical Learning Theory)是一种专门研究小样本情况下机器学习规律的理论。V.Vapnik 等人从六、七十年代开始致力于此方面的研究, 到九十年代中期, 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。

统计学习理论是建立在一套较坚实的理论基础之上的, 为解决有限样本学习问题提供了一个统一的框架。这一理论不仅圆满地回答了人工神经网络研究与应用中提出的一系列理论性问题, 而且构造出一种能克服人工神经网络局限性的学习方法—支持向量机(Support Vector Machines), 它已初步表现出很多优于已有方法的性能。一些学者认为, 统计学习理论和支持向量机正在成为继神经网络研究之后新的研究热点, 并将有力地推动机器学习理论和技术的发展。我国早在八十年代末就有学者注意到统计学习理论的基础成果^[20], 目前只有少部分学者认识到这个重要的研究方向。下面将就统计学习理论、支持向量机及其算法作一简单的介绍。

2.2 统计学习理论简介

机器学习是根据给定的训练样本求对某系统输入输出之间依赖关系的估计, 使它能够对未知输出作出尽可能准确的预测^[20]。可以一般地表示为: 变量 y 与 x 存在一定的未知依赖关系。即遵循某一未知的联合概率 $F(x,y)$, (x 和 y 之间的确定性关系可以看作是其特例), 机器学习问题就是根据 n 个独立同分布观测样本

$$(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n). \quad (2.1)$$

在一组函数 $\{f(x, w)\}$ 中求一个最优的函数 $f(x, w_0)$ 对依赖关系进行估计, 使期望风险

第二章 理论基础

2.1 引言

机器学习研究从观测数据出发寻找规律，利用这些规律对未来数据或无法观测的数据进行预测。机器学习是基于数据的现代智能技术中的重要方面，现有机器学习方法（包括模式识别、神经网络等）共同的重要理论基础之一是统计学。传统统计学研究的是样本数目趋于无穷大时的渐进理论，现有学习方法也多是基于此假设。但在实际问题中，样本数往往是有限的，因此一些理论上很优秀的学习方法实际中表现却可能不尽人意。

与传统统计学相比，统计学习理论（Statistical Learning Theory）是一种专门研究小样本情况下机器学习规律的理论。V.Vapnik 等人从六、七十年代开始致力于此方面的研究，到九十年代中期，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。

统计学习理论是建立在一套较坚实的理论基础之上的，为解决有限样本学习问题提供了一个统一的框架。这一理论不仅圆满地回答了人工神经网络研究与应用中提出的一系列理论性问题，而且构造出一种能克服人工神经网络局限性的学习方法—支持向量机（Support Vector Machines），它已初步表现出很多优于已有方法的性能。一些学者认为，统计学习理论和支持向量机正在成为继神经网络研究之后新的研究热点，并将有力地推动机器学习理论和技术的发展。我国早在八十年代末就有学者注意到统计学习理论的基础成果^[20]，目前只有少部分学者认识到这个重要的研究方向。下面将就统计学习理论、支持向量机及其算法作一简单的介绍。

2.2 统计学习理论简介

机器学习是根据给定的训练样本求对某系统输入输出之间依赖关系的估计，使它能够对未知输出作出尽可能准确的预测^[20]。可以一般地表示为：变量 y 与 x 存在一定的未知依赖关系。即遵循某一未知的联合概率 $F(x,y)$ ，（ x 和 y 之间的确定性关系可以看作是其特例），机器学习问题就是根据 n 个独立同分布观测样本

$$(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n). \quad (2.1)$$

在一组函数 $\{f(x, w)\}$ 中求一个最优的函数 $f(x, w_0)$ 对依赖关系进行估计，使期望风险

$$R(w) = \int L(y, f(x, w)) dF(x, y) \quad (2.2)$$

最小。其中 $\{f(x, w)\}$ 称作预测函数集， w 为函数的广义参数， $\{f(x, w)\}$ 可以表示任何函数集； $L(y, f(x, w))$ 为由于用 $f(x, w)$ 对 y 进行预测而造成的损失，不同类型的学习问题有不同形式的损失函数。

有三类基本的机器学习问题，即模式识别、函数逼近和概率密度估计。对模式识别问题，输出 y 是类别标号，两类情况下 $y = \{0, 1\}$ 或 $\{1, 1\}$ ，预测函数称作指示函数，损失函数可以定义为

$$L(y, f(x, w)) = \begin{cases} 0, & \text{if } y = f(x, w) \\ 1, & \text{if } y \neq f(x, w) \end{cases} \quad (2.3)$$

使风险最小就是 Bayes 决策中使错误率最小，在函数逼近问题中， y 是连续变量（这里假定为单值函数），损失函数可定义为

$$L(y, f(x, w)) = (y - f(x, w))^2 \quad (2.4)$$

即采用最小平方误差准则，而对概率密度估计问题，学习的目的是根据训练样本确定 x 的概率密度，记估计的密度函数为 $p(x, w)$ ，则损失函数可以定义为

$$L(p(x, w)) = -\log p(x, w) \quad (2.5)$$

在上面的问题表述中，学习的目标在于使期望风险最小化，但是，由于我们可以利用的信息只有样本 2.1, 2.2 式的期望风险并无法计算，因此传统的学习方法中采用了所谓经验风险最小化 (ERM) 准则，即用样本定义经验风险

$$R_{emp}(w) = \frac{1}{n} \sum_{i=1}^n L(y_i, f(x_i, w)) \quad (2.6)$$

作为对 2.2 式的估计，设计学习算法使它最小化，对损失函数 2.3，经验风险就是训练样本错误率；对 2.4 式的损失函数，经验风险就是平方训练误差；而采用 2.5 式损失函数的经验风险最小化准则就等价于最大似然方法。

事实上，用经验风险最小化准则代替期望风险最小化并没有经过充分的理论论证，只是直观上合理的想当然做法，但这种思想却在多年的机器学习方法研究中占据了主要地位。人们多年来将大部分注意力集中到如何更好地最小化经验风险上，而实际上，即使可以假定当 n 趋向于无穷大时 2.6 式趋近于 2.2 式，在很多问题中的样本数目也离无穷大相去甚远，那么在有限样本下经验风险最小化准则得到的结果未必能使真实风险也较小^[21]。

经验风险最小化准则不成功的一个例子是神经网络的过学习问题，开始很多

注意力都集中在如何使经验风险更小，但很快就发现，训练误差小并不总能导致好的预测效果。某些情况下，训练误差过小反而会导致推广能力的下降，即真实风险的增加，这就是过学习问题。之所以出现过学习现象，一是因为样本不充分，二是学习机器设计不合理，这两个问题是互相关联的。究其原因，是试图用一个十分复杂的模型去拟合有限的样本，导致丧失了推广能力，在神经网络中若对有限的样本来说网络学习能力过强，足以记住每个样本，此时经验风险很快就可以收敛到很小甚至零，但却根本无法保证它具有很好的推广能力^[23]。

由此可见，有限样本情况下，（1）经验风险最小并不一定意味着期望风险最小；（2）学习机器的复杂性不但应与所研究的系统有关，而且要和有限数目的样本相适应。我们需要一种能够指导我们在小样本情况下建立有效的学习和推广方法的理论，统计学习理论就是针对这些问题提出的。

2.2.2 统计学习理论的核心内容

统计学习理论就是研究小样本统计估计和预测的理论^[20, 22, 23]，主要包括四个方面：

- （1）经验风险最小化准则下统计学习一致性的条件；
- （2）在这些条件下关于统计学习方法推广性的界的结论；
- （3）在这些界的基础上建立的小样本归纳推理准则；
- （4）实现新的准则的实际方法。

其中，最有指导性的理论结果是推广性的界，与此相关的一个核心概念是 VC 维。

为了研究学习过程一致收敛的速度和推广性，统计学习理论定义了一系列有关函数集学习性能的指标，其中最重要的是 VC 维 (Vapnik-Chervonenkis Dimension)。模式识别方法中 VC 维的直观定义是：对一个指示函数集，如果存在 h 个样本能够被函数集中的函数按所有可能的 2^h 种形式分开，则称函数集能够把 h 个样本打散；函数集的 VC 维就是它能打散的最大样本数目 h 。若对任意数目的样本都有函数能将它们打散，则函数集的 VC 维是无穷大。有界实函数的 VC 维可以通过用一定的阈值将它转化成指示函数来定义。

VC 维反映了函数集的学习能力，VC 维越大则学习机器越复杂（容量越大）。遗憾的是，目前尚没有通用的关于任意函数集 VC 维计算的理论，只对一些特殊的函数集知道其 VC 维，比如在 n 维实数空间中线性分类器和线性实函数的 VC 维是 $n+1$ 。对于一些比较复杂的学习机器，其 VC 维除了与函数集有关外，还受学习算法等的影响，其确定更加困难，对于给定的学习函数集，如何计算其 VC 维是当前统计学习理论中有待研究的一个问题。

统计学习理论系统地研究了对于各种类型的函数集，经验风险和实际风险之

注意力都集中在如何使经验风险更小，但很快就发现，训练误差小并不总能导致好的预测效果。某些情况下，训练误差过小反而会导致推广能力的下降，即真实风险的增加，这就是过学习问题。之所以出现过学习现象，一是因为样本不充分，二是学习机器设计不合理，这两个问题是互相关联的。究其原因，是试图用一个十分复杂的模型去拟合有限的样本，导致丧失了推广能力，在神经网络中若对有限的样本来说网络学习能力过强，足以记住每个样本，此时经验风险很快就可以收敛到很小甚至零，但却根本无法保证它具有很好的推广能力^[23]。

由此可见，有限样本情况下，（1）经验风险最小并不一定意味着期望风险最小；（2）学习机器的复杂性不但应与所研究的系统有关，而且要和有限数目的样本相适应。我们需要一种能够指导我们在小样本情况下建立有效的学习和推广方法的理论，统计学习理论就是针对这些问题提出的。

2.2.2 统计学习理论的核心内容

统计学习理论就是研究小样本统计估计和预测的理论^[20, 22, 23]，主要包括四个方面：

- （1）经验风险最小化准则下统计学习一致性的条件；
- （2）在这些条件下关于统计学习方法推广性的界的结论；
- （3）在这些界的基础上建立的小样本归纳推理准则；
- （4）实现新的准则的实际方法。

其中，最有指导性的理论结果是推广性的界，与此相关的一个核心概念是 VC 维。

为了研究学习过程一致收敛的速度和推广性，统计学习理论定义了一系列有关函数集学习性能的指标，其中最重要的是 VC 维 (Vapnik-Chervonenkis Dimension)。模式识别方法中 VC 维的直观定义是：对一个指示函数集，如果存在 h 个样本能够被函数集中的函数按所有可能的 2^h 种形式分开，则称函数集能够把 h 个样本打散；函数集的 VC 维就是它能打散的最大样本数目 h 。若对任意数目的样本都有函数能将它们打散，则函数集的 VC 维是无穷大。有界实函数的 VC 维可以通过用一定的阈值将它转化成指示函数来定义。

VC 维反映了函数集的学习能力，VC 维越大则学习机器越复杂（容量越大）。遗憾的是，目前尚没有通用的关于任意函数集 VC 维计算的理论，只对一些特殊的函数集知道其 VC 维，比如在 n 维实数空间中线性分类器和线性实函数的 VC 维是 $n+1$ 。对于一些比较复杂的学习机器，其 VC 维除了与函数集有关外，还受学习算法等的影响，其确定更加困难，对于给定的学习函数集，如何计算其 VC 维是当前统计学习理论中有待研究的一个问题。

统计学习理论系统地研究了对于各种类型的函数集，经验风险和实际风险之

间的关系，即推广性的界。关于两类分类问题，结论是：对指示函数集中的所有函数（包括使经验风险最小的函数），经验风险 $R_{emp}(w)$ 和实际风险 $R(w)$ 之间以至少 $1 - \eta$ 的概率满足如下关系：

$$R(w) \leq R_{emp}(w) + \sqrt{\left(\frac{h(\ln(2n/h) + 1) - \ln(\eta/4)}{n} \right)} \quad (2.7)$$

其中 h 是函数集的 VC 维， n 是样本数。

这一结论从理论上说明了学习机器和实际风险是由两部分组成的：一是经验风险（训练误差），另一部分称作置信范围，它和学习机器的 VC 维及训练样本数有关。可以简单地表示为

$$R(w) \leq R_{emp}(w) + \phi(h/n) \quad (2.8)$$

它表明，在有限训练样本下，学习机器的 VC 维越高（复杂性越高）则置信范围越大，导致真实风险与经验风险之间可能的差别越大，这就是为什么会出现过学习现象的原因。机器学习过程不但要使经验风险最小，还要使 VC 维尽量小以缩小置信范围，才能取得较小的实际风险，即对未来样本有较好的推广性。

需要指出，推广性的界是对于最坏情况的结论，在很多情况下是轻松的，尤其当 VC 维较高时更是如此。而且，这种界只在对同一类学习函数进行比较时有效，可以指导我们从函数集中选择最优的函数，在不同函数集之间比较却不一定成立。Vapnik 指出，寻找更好地反映学习机器能力的参数和得到更紧的界是学习理论今后的研究方向之一。

经验风险最小化原则在样本有限时是不合理的，我们需要同时最小化经验风险和置信范围。其实，在传统方法中，选择学习模型和算法的过程就是调整置信范围的过程，如果模型比较适合现有的训练样本（相当于 h/n 值适当），则可以取得比较好的效果。但因为缺乏理论指导，这种选择只能依赖先验知识和经验，造成了如神经网络等方法对使用者“技巧”的过分依赖。

统计学习理论提出了一种新的策略，即把函数集构造为一个函数子集序列，使各个子集按照 VC 维的大小排列；在每个子集中寻找最小经验风险，在子集间折衷考虑经验风险和置信范围，取得实际风险的最小，如图 2.1 所示。这种思想称作结构风险最小化（Structural Risk Minimization）即 SRM 准则。统计学习理论还给出了合理的函数子集结构应满足的条件及在结构风险最小化准则下实际风险收敛的性质。

实现结构风险最小化原则可以有两种思路，一是在每个子集中求最小经验风险，然后选择使最小经验风险和置信范围之和最小的子集。显




图 2.1 结构风险最小化示意图

Fig 2.1 The sketch map of SRM

然而这种方法比较费时，当子集数目很大甚至是无穷大时不可行。因此有第二种思路，即设计函数集的某种结构使每个子集中都能取得最小的经验风险（如使训练误差为 0），然后只需选择适当的子集置信范围最小，则这个子集中使经验风险最小的函数就是最优函数。支持向量机方法实际上就是这种思想的具体实现。

由于统计学习理论建立了一套较好的有限样本下机器学习的理论框架和通用方法，较好地解决了小样本、非线性、高维数和局部极小点等实际问题，因此，成为 90 年代末发展最快的研究方向之一，其核心思想就是学习机器要与有限的训练样本相适应。

2.3 支持向量机及其学习算法

支持向量机简称 SVM，是统计学习理论中最年轻的内容，也是最实用的部分，其核心内容是在 1992 到 1995 年间提出的，目前仍处在不断发展阶段^[22, 23]。

支持向量机是从线性可分情况下的最优分类面发展而来的，基本思想可用图 2.2 的两维情况说明。图中，实心点和空心点代表两类样本，H 为分类线， H_1 、 H_2 分别为过各类中离分类线最近的样本且平行于分类线的直线，他们之间的距离叫做分类间隔（margin）。所谓最优分类线就是




图 2.1 结构风险最小化示意图

Fig 2.1 The sketch map of SRM

然而这种方法比较费时，当子集数目很大甚至是无穷大时不可行。因此有第二种思路，即设计函数集的某种结构使每个子集中都能取得最小的经验风险（如使训练误差为 0），然后只需选择适当的子集置信范围最小，则这个子集中使经验风险最小的函数就是最优函数。支持向量机方法实际上就是这种思想的具体实现。

由于统计学习理论建立了一套较好的有限样本下机器学习的理论框架和通用方法，较好地解决了小样本、非线性、高维数和局部极小点等实际问题，因此，成为 90 年代末发展最快的研究方向之一，其核心思想就是学习机器要与有限的训练样本相适应。

2.3 支持向量机及其学习算法

支持向量机简称 SVM，是统计学习理论中最年轻的内容，也是最实用的部分，其核心内容是在 1992 到 1995 年间提出的，目前仍处在不断发展阶段^[22, 23]。

支持向量机是从线性可分情况下的最优分类面发展而来的，基本思想可用图 2.2 的两维情况说明。图中，实心点和空心点代表两类样本，H 为分类线， H_1 、 H_2 分别为过各类中离分类线最近的样本且平行于分类线的直线，他们之间的距离叫做分类间隔（margin）。所谓最优分类线就是




图 2.2 线性可分情况下的最优分类线

Fig2.2 Linear separating hyperplanes for the separable case

要求分类线不但能将两类正确分开（训练错误率为 0），而且使分类间隔最大。分类线方程为 $x \cdot w + b = 0$ 。我们可以对它进行归一化，使得对线性可分的样本集 $(x_i, y_i), i = 1, \dots, n, x \in R^d, y \in \{+1, -1\}$ ，满足

$$y_i [(w \cdot x_i) + b] - 1 \geq 0, i = 1, \dots, n. \quad (2.9)$$

此时分类间隔等于 $2/\|w\|$ ，使间隔最大等价于使 $\|w\|^2$ 最小，满足条件 2.9 且使 $\frac{1}{2}\|w\|^2$ 最小的分类面就叫做最优分类面， H_1 、 H_2 上的训练样本点就称作支持向量。

使分类间隔最大实际上就是对推广能力的控制，这是支持向量机的核心思想之一，统计学习理论指出，在 N 维空间中，设样本分布在一个半径为 R 的超球范围内，则满足条件 $\|w\| \leq A$ 的正则超平面构成的指示函数集 $f(x, w, b) = \text{sgn}\{(w \cdot x) + b\}$ （ $\text{sgn}()$ 为符号函数）的 VC 维满足下面的界

$$h \leq \min(\lfloor R^2 A^2 \rfloor, N) + 1 \quad (2.10)$$

因此使 $\|w\|^2$ 最小就是使 VC 维的上界最小，从而实现结构风险最小化准则中对函数复杂性的选择。

利用 Lagrang 优化方法可以把上述最优分类面问题转化为其对偶问题，即在约束条件

$$\sum_{i=1}^n y_i \alpha_i = 0 \quad (2.11a)$$

$$\text{和 } \alpha_i \geq 0, i = 1, \dots, n \quad (2.11b)$$

下，对 α_i 求解下列函数的最大值

$$Q(\alpha) = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j=1}^n \alpha_i \alpha_j y_i y_j (x_i \cdot x_j) \quad (2.12)$$

α_i 为与每个样本对应的 Lagrange 乘子, 这是一个不等式约束下二次函数寻优的问题, 存在唯一解。容易证明, 解中将只有一部分 (通常是少部分) α_i 不为零, 对应的样本就是支持向量。解上述问题后得到的最优分类函数就是

$$f(x) = \text{sgn}\{(w \cdot x) - b\} = \text{sgn}\left\{\sum_{i=1}^n \alpha_i^* y_i (x_i \cdot x) - b^*\right\} \quad (2.13)$$

式中的求和实际上只对支持向量进行, b^* 是分类阈值, 可以用任一个支持向量 (满足 2.9 式中的等号) 求得, 或通过两类中任意一对支持向量取中值求得。

在线性不可分的情况下, 可以在条件 2.9 中增加一个松弛项 $\xi_i \geq 0$, 成为

$$y_i [(w \cdot x_i) + b] - 1 + \xi_i \geq 0, i = 1, \dots, n \quad (2.14)$$

将目标改为求 $(w, \xi) = \frac{1}{2} \|w\|^2 + C \left(\sum_{i=1}^n \xi_i \right)$ 最小, 即折衷考虑最少错分样本和最大分类间隔, 就得到广义最优分类面, 其中, $C > 0$ 是一个常数, 它控制对错分样本惩罚的程度。广义最优分类面的对偶问题与线性可分情况下几乎完全相同, 只是条件 2.11b 变为

$$0 \leq \alpha_i \leq C, i = 1, \dots, n \quad (2.15)$$

2.3.1 支持向量机

对于 N 维空间中的线性函数, 其 VC 维为 $N+1$, 但根据式 2.10 的结论, 在 $\|w\| \leq A$ 的约束下其 VC 维可能大大减小, 即使在十分高维的空间中也可以得到较小 VC 维的函数集, 以保证有较好的推广性, 同时我们看到, 通过把原问题转化为对偶问题, 计算的复杂度不再取决于空间维数, 而是取决于样本数, 尤其是样本中的支持向量数, 这些特点使有效地对付高维问题成为可能。

对非线性问题, 可以通过非线性变换转化为某个高维空间中的线性问题, 在变换空间求最优分类面 (如图 2.3)。这种变换可能比较复杂, 因此这种思路在一般情况下不易实现。但是注意到, 在上面的对偶问题中, 不论是寻优函数 2.12 还是分类函数 2.13 都只涉及训练样本之间的内积运算 (x_i, x_j) , 这样, 在高维空间实际上只需进行内积运算, 而这种内积运算是可以用原空间中的函数实现的。我们没有必要知道变换的形式。根据泛函的有关理论, 只要一种核函数 $K(x_i, x_j)$ 满足 Mercer 条件, 它就对应某一变换空间中的内积。

$$Q(\alpha) = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j=1}^n \alpha_i \alpha_j y_i y_j (x_i \cdot x_j) \quad (2.12)$$

α_i 为与每个样本对应的 Lagrange 乘子, 这是一个不等式约束下二次函数寻优的问题, 存在唯一解。容易证明, 解中将只有一部分 (通常是少部分) α_i 不为零, 对应的样本就是支持向量。解上述问题后得到的最优分类函数就是

$$f(x) = \text{sgn}\{(w \cdot x) - b\} = \text{sgn}\left\{\sum_{i=1}^n \alpha_i^* y_i (x_i \cdot x) - b^*\right\} \quad (2.13)$$

式中的求和实际上只对支持向量进行, b^* 是分类阈值, 可以用任一个支持向量 (满足 2.9 式中的等号) 求得, 或通过两类中任意一对支持向量取中值求得。

在线性不可分的情况下, 可以在条件 2.9 中增加一个松弛项 $\xi_i \geq 0$, 成为

$$y_i [(w \cdot x_i) + b] - 1 + \xi_i \geq 0, i = 1, \dots, n \quad (2.14)$$

将目标改为求 $(w, \xi) = \frac{1}{2} \|w\|^2 + C \left(\sum_{i=1}^n \xi_i \right)$ 最小, 即折衷考虑最少错分样本和最大分类间隔, 就得到广义最优分类面, 其中, $C > 0$ 是一个常数, 它控制对错分样本惩罚的程度。广义最优分类面的对偶问题与线性可分情况下几乎完全相同, 只是条件 2.11b 变为

$$0 \leq \alpha_i \leq C, i = 1, \dots, n \quad (2.15)$$

2.3.1 支持向量机

对于 N 维空间中的线性函数, 其 VC 维为 N+1, 但根据式 2.10 的结论, 在 $\|w\| \leq A$ 的约束下其 VC 维可能大大减小, 即使在十分高维的空间中也可以得到较小 VC 维的函数集, 以保证有较好的推广性, 同时我们看到, 通过把原问题转化为对偶问题, 计算的复杂度不再取决于空间维数, 而是取决于样本数, 尤其是样本中的支持向量数, 这些特点使有效地对付高维问题成为可能。

对非线性问题, 可以通过非线性变换转化为某个高维空间中的线性问题, 在变换空间求最优分类面 (如图 2.3)。这种变换可能比较复杂, 因此这种思路在一般情况下不易实现。但是注意到, 在上面的对偶问题中, 不论是寻优函数 2.12 还是分类函数 2.13 都只涉及训练样本之间的内积运算 (x_i, x_j) , 这样, 在高维空间实际上只需进行内积运算, 而这种内积运算是可以用原空间中的函数实现的。我们没有必要知道变换的形式。根据泛函的有关理论, 只要一种核函数 $K(x_i, x_j)$ 满足 Mercer 条件, 它就对应某一变换空间中的内积。




图 2.3 映射到高维空间示意图

Fig2.3 The sketch map of map the training data nonlinearly into a higher dimensional feature space

因此, 在最优分类面中采用适当的内积函数 $K(x_i, x_j)$ 就可以实现某一非线性变换后的线性分类, 而计算复杂度却没有增加, 此时目标函数 2.12 变为

$$Q(\alpha) = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j=1}^n \alpha_i \alpha_j y_i y_j K(x_i, x_j) \quad (2.16)$$

而相应的分类函数也变为

$$f(x) = \text{sgn} \left(\sum_{i=1}^n \alpha_i^* y_i K(x_i, x_j) + b^* \right) \quad (2.17)$$

这就是支持向量机。

概括地说, 支持向量机就是首先通过用内积函数定义的非线性变换将输入空间变换到一个高维空间, 在这个空间中求 (广义) 最优分类面。支持向量机分类函数形式上类似于一个神经网络, 输出是中间节点的线性组合, 每个中间节点对应一个支持向量, 如图 2.4 所示。

支持向量机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三类, 一是多项式核函数

$$K(x, x_i) = [(x \cdot x_i) + 1]^q \quad (2.18)$$

所得到的是 q 阶多项式分类器; 二是径向基函数 (RBF)

$$K(x, x_i) = \exp \left\{ -\frac{|x - x_i|^2}{\sigma^2} \right\} \quad (2.19)$$

所得分类器与传统 RBF 方法的重要区别是, 这里每个基函数中心对应一个支持向量, 它们及输出权值都是由算法自动确定的, 也可以采用 Sigmoid 函数作为内积,

即

$$K(x, x_i) = \tanh(v(x, x_i) + c) \quad (2.20)$$

这时支持向量机实现的就是包含一个隐层的多层感知器，隐含层节点数是由算法自动确定的，而且算法不存在困扰神经网络方法的局部极小点问题。




图 2.4 支持向量机结构示意图

Fig.4 The sketch map of SVM

2.3.2 用于函数拟合的 SVM

支持向量机方法也可以很好地应用于函数拟合问题，其思路与在模式识别中十分相似。首先考虑用线性回归函数 $f(x) = w \cdot x + b$ 拟合数据 $\{x_i, y_i\}, i = 1, \dots, n, x_i \in R^d, y_i \in R$ 的问题，并假设所有训练数据都可以在精度 ϵ 下无误差地用线性函数拟合，即

$$\begin{cases} y_i - w \cdot x_i - b \leq \epsilon, \\ w \cdot x_i + b - y_i \leq \epsilon, \end{cases} \quad i = 1, \dots, n \quad (2.21)$$

与最优分类面中最大化分类间隔相似，这里控制函数复杂性的方法是使回归函数最平坦，它等价于最小化 $\frac{1}{2} \|w\|^2$ 。考虑到允许拟合误差的情况，引入松弛因子 $\xi_i \geq 0$ 和 $\xi_i^* \geq 0$ ，则条件 2.21 变成

$$\begin{cases} y_i - w \cdot x_i - b \leq \epsilon + \xi_i, \\ w \cdot x_i + b - y_i \leq \epsilon + \xi_i^* \end{cases} \quad i = 1, \dots, n \quad (2.22)$$

即

$$K(x, x_i) = \tanh(v(x, x_i) + c) \quad (2.20)$$

这时支持向量机实现的就是包含一个隐层的多层感知器，隐含层节点数是由算法自动确定的，而且算法不存在困扰神经网络方法的局部极小点问题。

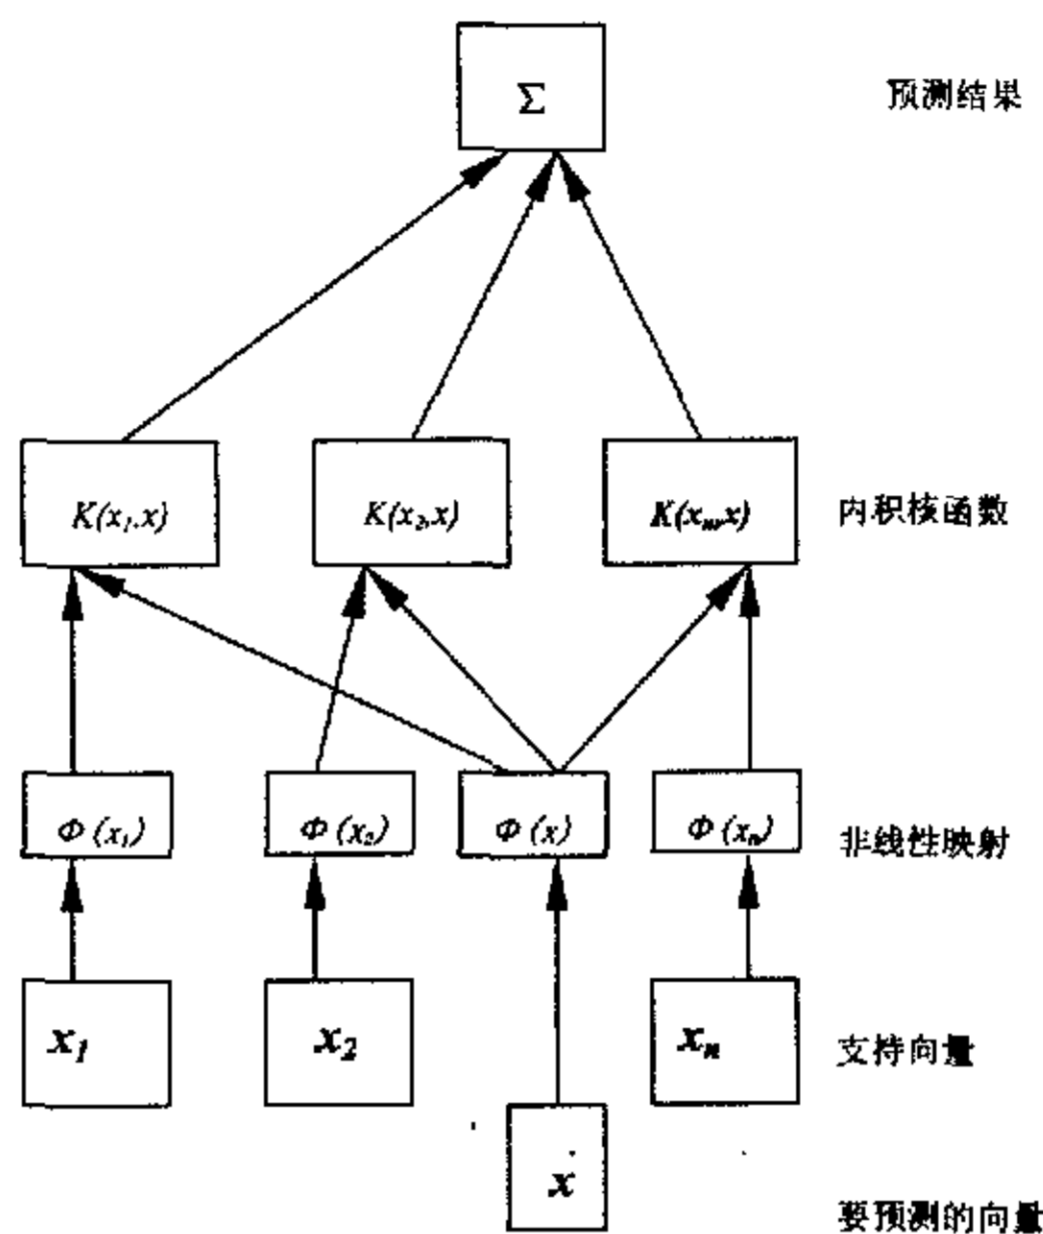


图 2.4 支持向量机结构示意图

Fig.4 The sketch map of SVM

2.3.2 用于函数拟合的 SVM

支持向量机方法也可以很好地应用于函数拟合问题，其思路与在模式识别中十分相似。首先考虑用线性回归函数 $f(x) = w \cdot x + b$ 拟合数据 $\{x_i, y_i\}, i = 1, \dots, n, x_i \in R^d, y_i \in R$ 的问题，并假设所有训练数据都可以在精度 ϵ 下无误差地用线性函数拟合，即

$$\begin{cases} y_i - w \cdot x_i - b \leq \epsilon, \\ w \cdot x_i + b - y_i \leq \epsilon, \end{cases} \quad i = 1, \dots, n \quad (2.21)$$

与最优分类面中最大化分类间隔相似，这里控制函数复杂性的方法是使回归函数最平坦，它等价于最小化 $\frac{1}{2} \|w\|^2$ 。考虑到允许拟合误差的情况，引入松弛因子 $\xi_i \geq 0$ 和 $\xi_i^* \geq 0$ ，则条件 2.21 变成

$$\begin{cases} y_i - w \cdot x_i - b \leq \epsilon + \xi_i, \\ w \cdot x_i + b - y_i \leq \epsilon + \xi_i^* \end{cases} \quad i = 1, \dots, n \quad (2.22)$$

优化目标变成最小化 $\frac{1}{2}\|w\|^2 + C\sum_{i=1}^n(\xi_i + \xi_i^*)$, 常数 $C>0$ 控制对超出误差 ε 的样本的惩罚程度, 采用同样的优化方法^[23]可以得到其对偶问题, 在条件

$$\begin{aligned} \sum_{i=1}^n(\alpha_i - \alpha_i^*) &= 0, \\ 0 \leq \alpha_i, \alpha_i^* &\leq C, i = 1, \dots, n \end{aligned} \quad (2.23)$$

下, 对 Lagrange 因子 α_i, α_i^* 最大化目标函数

$$W(\alpha, \alpha^*) = -\varepsilon \sum_{i=1}^n(\alpha_i^* + \alpha_i) + \sum_{i=1}^n y_i(\alpha_i^* - \alpha_i) - \frac{1}{2} \sum_{i,j=1}^n (\alpha_i^* - \alpha_i)(\alpha_j^* - \alpha_j)(x_i \cdot x_j) \quad (2.24)$$

得回归函数为

$$f(x) = (w \cdot x) + b = \sum_{i=1}^n (\alpha_i^* - \alpha_i)(x_i \cdot x) + b^* \quad (2.25)$$

与模式识别中的支持向量机方法一样, 这里 α_i, α_i^* 也将只有小部分不为 0, 他们对应的样本就是支持向量, 一般是在函数变化比较剧烈的位置上的样本, 而且这里也是只涉及内积运算, 只要用核函数 $K(x_i, x_j)$ 替代 2.24、2.25 中的内积运算就可以实现非线性函数拟合^[23]。

由于支持向量机方法较好的理论基础和它在一些领域应用中表现出来的优秀的推广性能, 近年来, 许多关于支持向量机方法的研究, 包括算法本身的改进和算法的实际应用, 都陆续提了出来。尽管支持向量机算法的性能在许多实际问题的应用中得到了验证, 但是该算法在计算上存在着一些问题, 包括训练算法速度慢、算法复杂而难以实现以及检测阶段运算量大等等。传统的利用标准二次型优化技术解决对偶问题的方法可能是训练算法慢的主要原因: 首先, 支持向量机方法需要计算和存储核函数矩阵, 当样本点数目较大时, 需要很大的内存; 其次, 支持向量机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。支持向量机方法的训练运算速度是限制它的应用的主要方面, 近年来人们针对方法本身的特点提出了许多算法来解决对偶寻优问题。大多数算法的一个共同的思想就是循环迭代: 将原问题分解成为若干子问题, 按照某种迭代策略, 通过反复求解子问题, 最终使结果收敛到原问题的最优解。根据子问题的划分和迭代策略的不同, 又可以大致分为两类, 一类是所谓的“块算法”(chunking algorithm), 另一类是固定样本数方法。固定工作样本集的方法和块算法的主要区别在于: 块算法的目标函数中仅包含当前工作样本集中的样本, 而固定工作样本集方法虽然优化变量仅包含工作样本, 其目标函数却包含整个训练样本集。而且固定工作样本集方法还涉及到一个确定换出样本的问题。

为了能在实际问题中应用支持向量机方法, 需要更有效学习算法, 近年

来许多研究者（其中 AT&T、微软等大公司）在这方面作了大量的工作，使支持向量机成为一项能在实际问题中应用的技术。

Vapnik 等人首先提出了一种解决支持向量机训练存储空间问题的方法，称为 Chunking 算法^[23]。对于支持向量机的二次优化问题，如果去掉与零拉格朗日乘子对应的行与列，其值不变。因此可将求解支持向量机的二次规划问题分解为一系列较小的二次规划问题，求解这些较小的二次规划问题的最终目标是确定所有的非零拉格朗日乘子，并去除所有的零拉格朗日乘子。Chunking 算法的主要步骤如下：

- (1) 取训练样本集合的任意一个子集作为工作集 B;
- (2) 用二次规划方法对 B 求解最优化问题，得到支持向量并构成一个分类器;
- (3) 用该分类器测试集合 N 中的样本，将其中不满足最优化条件者按其偏离最优的程度顺序排列为候补工作集 C，若 C 中所有样本均满足最优化条件或 C 为空集则结束程序，否则继续;
- (4) 剔除 B 中的非支持向量样本，添加 C 中排列在前面的若干个样本构成新的工作集 B，返回第 2 步。

在 Chunking 算法中，矩阵大小由 l^2 降低为 s^2 (s 为支持向量的数目)，从而大大降低了对内存的需求，在支持向量很少时能获得很好的结果。但是若所求解的问题中大部分拉格朗日乘子不为零，则对存储空间的需求仍会很大，难以求解。

Osuna 等人提出的分解算法也是将求解支持向量机的二次规划问题分解为一系列较小的二次规划问题，但是其工作集的大小保持不变，对内存的需求从与 s 呈平方关系变为线性关系，因而能克服 Chunking 算法存在的问题，可以轻松地处理样本点多达 11 万个、支持向量超过 10 万个的问题^[22-23]。分解算法的主要步骤如下：

- (1) 从训练样本集中取出 q 个样本构成工作集 B，将其余 $(l-q)$ 个样本组成集合记为 N;
- (2) 用二次规划方法对 B 求解最优化问题，得到支持向量并构成一个分类器;
- (3) 用该分类器测试集合 N 中的样本，若 N 中所有样本均满足最优化条件或 N 为空集则结束程序，否则继续;
- (4) 将 N 中至少一个不满足最优化条件的样本放入 B，同时从 B 中取出同样数目的样本，返回第 (2) 步。

分解算法的缺点是运算速度较慢。

在上述两种算法中都包含对分解后的子系统求解二次规划问题的内循环，虽然所求解的是比原问题规模较小的二次规划问题，但一般仍必须用数值法求解，

这往往会在计算精度和计算复杂性方面带来一些问题。Platt 提出的 SMO 算法也是一种分解算法，但是其工作空间选为只包含两个样本，即在每一步迭代中都只对两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。因此 SMO 算法中只需一段简洁的程序代码就可以解决二次规划问题，而不必在每一步迭代中都调用一次数值求解二次规划问题的复杂函数。这样，尽管在 SMO 中二次规划子问题增多了，但是总的计算速度反而大大提高。此外，这种算法完全不需要处理大矩阵，因而对存储空间没有额外的要求，很大的 SVM 训练问题也能用个人计算机进行运算。由于这些优点，SMO 是目前在实际问题中应用最为广泛的一种方法。本论文的 SVM 算法就采用 SMO 方法，下节将对此方法进行详细的叙述。

上述各种算法均是针对 SVM 的对偶问题而提出的数值求解方法。Keerthi 等人回到 SVM 原始的优化问题，并将其转化为一个等价的求两个凸壳之间的最近点的问题，然后综合两种已有的求最近点算法，经过改进得到 NPA 算法。经过一些标准数据库的测试，NPA 的性能与 SMO 相近，但它适用于模式识别中的 2 类划分问题。




图 2.5 支持向量机的三种训练方法的比较 a)块算法 b)Osuna 方法 c)SMO

Fig2.5 Three methods for training support vector machine a)Chunking b)Osuna's algorithm c) SMO

支持向量机的训练方法对支持向量机的推广应用具有很大的影响，除了上面介绍的方法外，还有很多的方法，如：内点算法、近邻算法、最小二乘法支持向量机 LS.SVM、几何方法以及我国的张学工的 CSVM。

支持向量机应用的重要方面是其算法的具体实施与应用，下面给出其算法的具体步骤和框图。

- (1) 获取学习样本 $(x_i, y_i), i = 1, \dots, n.$

- (2) 选择进行非线性变换的核函数(式 2.18、2.19 或 2.20)及对错分(误差)进行惩罚的惩罚因子 C ;
- (3) 形成二次优化问题(分类问题为式 2.11a、2.15、2.16 构成的二次优化,拟合问题为式 2.23、2.24 构成的二次优化);
- (4) 用优化方法(如: Chunking、内点算法、SMO 算法)解获得的优化问题,本文采用的优化方法为 SMO(具体算法见下节);
- (5) 获得 α 、 (α^*) 及 b 的值,代入式 2.17 或 2.25 中,获得分类或函数拟合的支持向量机;
- (6) 需预测或分类的数据代入支持向量机 2.17 或 2.25 中获得结果。

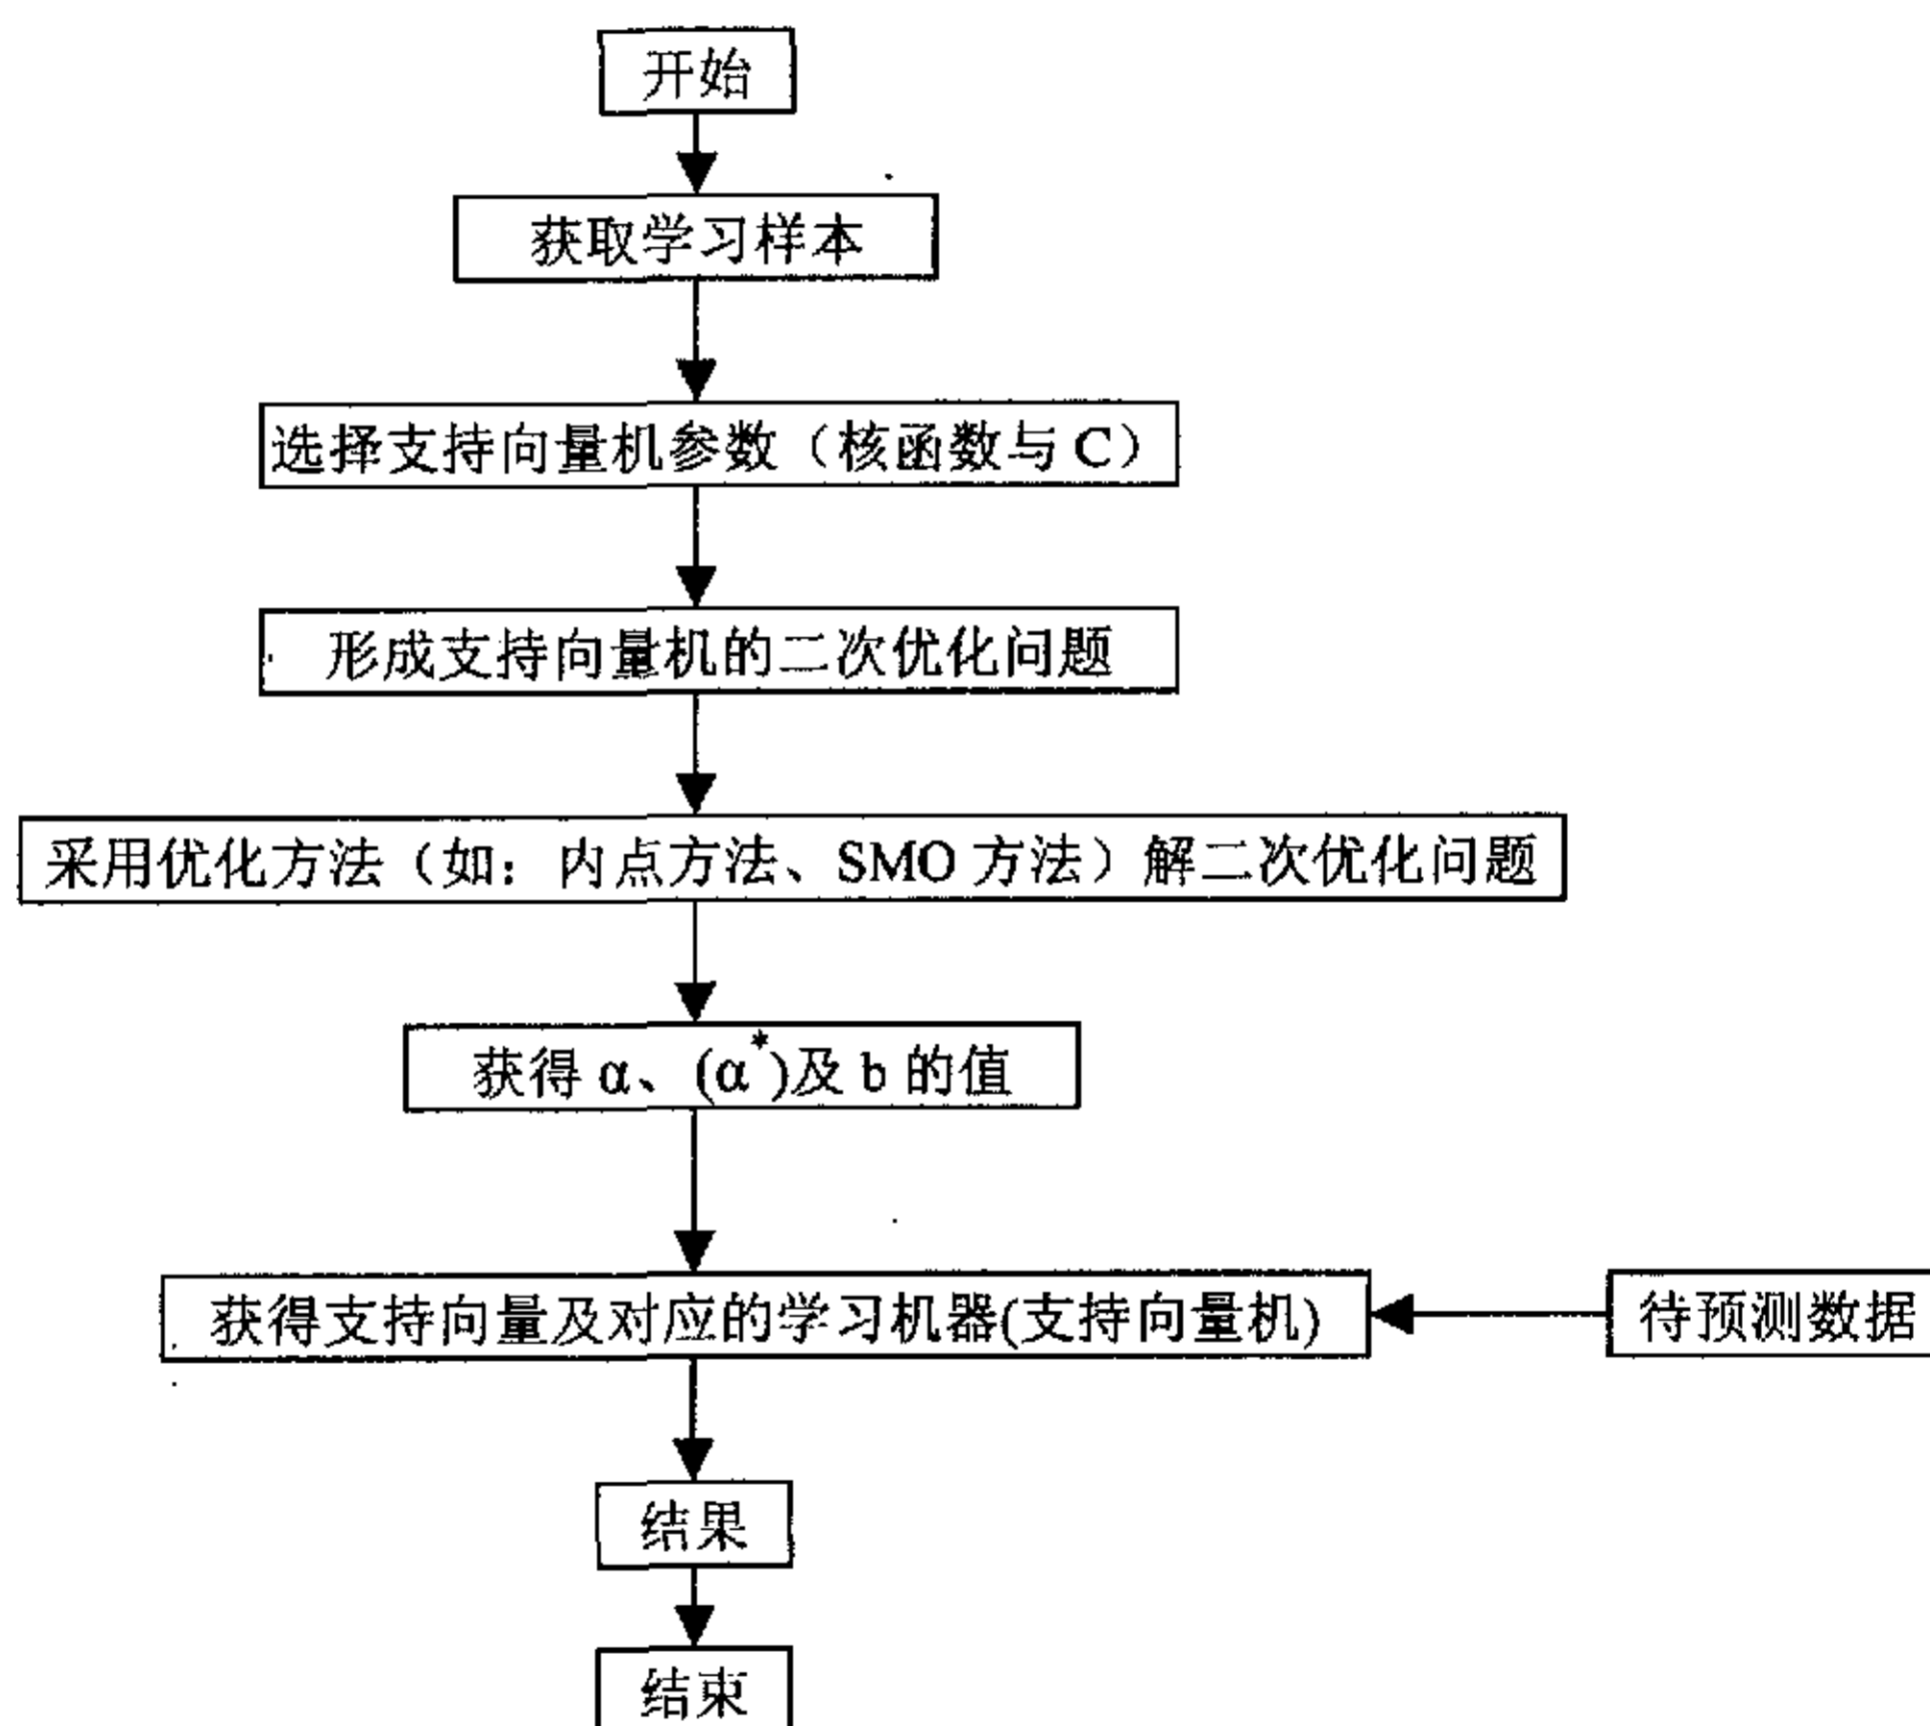


图 2. 6 支持向量机算法框图

Fig2.6 The flow chart of the SVM algorithm

1995 年 Cortes 和 Vapnik 发表了文章“support vector network”,这是支持向量机出现的标志,支持向量机一出现就引起了人们的极大关注,目前已成为数学和计算机研究的热点领域。1998 年 J.C.Burges 用支持向量机对模式识别问题进行了系统的研究^[23],同一年 Alex J.Amola 用支持向量机方法对函数拟合问题进行了深入的研究^[22];针对支持向量机研究中出现的二次规划问题,1999 年 Platt 提出了

Sequential Minimal Optimization(SMO)方法^[24], 使支持向量机的效率得到了提高, 同年, S.K.Snerade 和 S.S.Keerthi 分别针对函数拟合和模式识别问题对 SMO 方法进行了改进, 提出了改进的 SMO 方法^[25], 2000 年 Ronan Collobert 对基于支持向量机的大规模函数拟合问题进行了研究^[26], 2001 年 Steinwart 等对支持向量机的参数对推广能力的影响进行了大量的研究^[27]。目前支持向量机已在遥感图象识别 (2001.Yonas B.Dibike etc)、降雨径流量估计 (2001.Yonas B.Dibike etc)、环境和污染数据分析 (2000, Mikhail Kanovski)^[28]、汉字识别(2000.田盛丰等)、雷达目标识别、测井数据分类、计算机化学等领域有着成功的应用。作者和冯夏庭教授对支持向量机在滑坡工程中的应用进行了一些尝试, 如支持向量机的岩爆预测、支持向量机的边坡稳定性估计等, 得到了一些很好的结果。

2.3.3 序列最小优化 SMO(Sequential Minimal Optimization)

SMO 方法一种简单的算法, 它能快速地解支持向量机的二次规划问题^[24]。按照 Osuna 的理论, 在保证收敛的情况下, 把支持向量机的二次规划问题分解成一系列子问题来解决。和其它的算法相比, SMO 方法在每一步选择一个最小的优化问题来解。对标准的支持向量机优化问题来说, 最小的优化问题就是只有两个拉格朗日乘子的优化问题。在每一步, SMO 方法选择两个拉格朗日乘子进行优化, 然后再更新拉格朗日乘子以反映新的优化值。

SMO 方法的优点在于, 优化问题只有两个拉格朗日乘子, 它用解析的方法即可解出, 从而完全避免了复杂的数值解法。另外, 它根本不需要巨大的矩阵存储, 这样, 即使是很大的支持向量机学习问题, 也可在 PC 机上实现。

SMO 方法包括两个步骤: 一是用解析的方法解一个简单的优化问题, 二是选择待优化的拉格朗日乘子的策略。

为了解只有两个乘子的优化问题, SMO 方法首先计算它的约束, 然后再解带有约束的最小化问题。为了方面, 下标 1 表示第一个乘子, 下标 2 表示第二个乘子。因为只有两个乘子, 在二维情况下的约束很容易表示出来。(见图 2.7) 边界约束使的乘子在方框内, 而线性等式约束使的乘子的对角线上^[26]。

对于支持向量机中的二次优化问题, 考虑只有两个乘子的情况, 即 (i, j) 。定义辅助变量 $s=y_i y_j$ 对于模式识别问题来说 $y_i \in \{1, -1\}$ 。对于函数拟和问题, 必须区分四种不同的情况: (α_i, α_j) , (α_i, α_j^*) , (α_i^*, α_j) , (α_i^*, α_j^*) 。对于 (α_i, α_j) 和 (α_i^*, α_j^*) 两种情况下, 令 $s=1$, 对另外两种情况下, 令 $s=-1$ 。这样, 对于模式识别问题, 可以得到如下的约束:

Sequential Minimal Optimization(SMO)方法^[24], 使支持向量机的效率得到了提高, 同年, S.K.Snerade 和 S.S.Keerthi 分别针对函数拟合和模式识别问题对 SMO 方法进行了改进, 提出了改进的 SMO 方法^[25], 2000 年 Ronan Collobert 对基于支持向量机的大规模函数拟合问题进行了研究^[26], 2001 年 Steinwart 等对支持向量机的参数对推广能力的影响进行了大量的研究^[27]。目前支持向量机已在遥感图象识别 (2001.Yonas B.Dibike etc)、降雨径流量估计 (2001.Yonas B.Dibike etc)、环境和污染数据分析 (2000, Mikhail Kanovski)^[28]、汉字识别(2000.田盛丰等)、雷达目标识别、测井数据分类、计算机化学等领域有着成功的应用。作者和冯夏庭教授对支持向量机在滑坡工程中的应用进行了一些尝试, 如支持向量机的岩爆预测、支持向量机的边坡稳定性估计等, 得到了一些很好的结果。

2.3.3 序列最小优化 SMO(Sequential Minimal Optimization)

SMO 方法一种简单的算法, 它能快速地解支持向量机的二次规划问题^[24]。按照 Osuna 的理论, 在保证收敛的情况下, 把支持向量机的二次规划问题分解成一系列子问题来解决。和其它的算法相比, SMO 方法在每一步选择一个最小的优化问题来解。对标准的支持向量机优化问题来说, 最小的优化问题就是只有两个拉格朗日乘子的优化问题。在每一步, SMO 方法选择两个拉格朗日乘子进行优化, 然后再更新拉格朗日乘子以反映新的优化值。

SMO 方法的优点在于, 优化问题只有两个拉格朗日乘子, 它用解析的方法即可解出, 从而完全避免了复杂的数值解法。另外, 它根本不需要巨大的矩阵存储, 这样, 即使是很大的支持向量机学习问题, 也可在 PC 机上实现。

SMO 方法包括两个步骤: 一是用解析的方法解一个简单的优化问题, 二是选择待优化的拉格朗日乘子的策略。

为了解只有两个乘子的优化问题, SMO 方法首先计算它的约束, 然后再解带有约束的最小化问题。为了方面, 下标 1 表示第一个乘子, 下标 2 表示第二个乘子。因为只有两个乘子, 在二维情况下的约束很容易表示出来。(见图 2.7) 边界约束使的乘子在方框内, 而线性等式约束使的乘子的对角线上^[26]。

对于支持向量机中的二次优化问题, 考虑只有两个乘子的情况, 即 (i, j) 。定义辅助变量 $s=y_i y_j$ 对于模式识别问题来说 $y_i \in \{1, -1\}$ 。对于函数拟和问题, 必须区分四种不同的情况: (α_i, α_j) , (α_i, α_j^*) , (α_i^*, α_j) , (α_i^*, α_j^*) 。对于 (α_i, α_j) 和 (α_i^*, α_j^*) 两种情况下, 令 $s=1$, 对另外两种情况下, 令 $s=-1$ 。这样, 对于模式识别问题, 可以得到如下的约束:

$$s\alpha_i + \alpha_j = s\alpha_i^{old} + \alpha_j^{old} = \gamma \quad (2.26)$$

对于函数拟合问题，约束为：

$$(\alpha_i - \alpha_i^*) + (\alpha_j - \alpha_j^*) = (\alpha_i^{old} - \alpha_i^{*old}) + (\alpha_j^{old} - \alpha_j^{*old}) = \gamma \quad (2.27)$$

利用 $\alpha_j^{(*)} \in [0, C_j^{(*)}]$ ，可以得到 $\alpha_i^{(*)} \in [L, H]$ ，其中，L, H 由表 2.1 和表 2.2 定义。




图 2.7 两个乘子的优化问题的约束示意图

Fig2.7 The sketch map of optimal problem with two multiplier

表 2.1 模式识别下的可行解边界

Table2.1 The boundary of feasible regions for pattern recognition

	$y_i=y_j$	$y_i \neq y_j$
α_i	$L = \max(0, \gamma - C_j)$ $H = \min(C_i, \gamma)$	$L = \max(0, \gamma)$ $H = \min(C_i, \gamma + C_j)$

表 2.1 为模式识别下的可行解的边界，表 2.2 为函数拟合下的可行性解的界，根据这两个表可以分别确定两个有两个样本的优化问题的参数值的范围。无论是模式识别，还是函数拟合问题，这样问题就得到很大简化，算法的复杂性大大降低，对机器的要求也就变的比较低。函数拟合问题比模式识别的问题要复杂，由于基于同样的方法求解支持向量，函数拟合问题并不比模式识别复杂很多。函数拟合问题的支持向量比模式识别问题的支持向量要多。序列最小优化方法，比近邻法等方法，具有很大的优势，因为求解问题转化为对两个输入样本的运算。根据式 2.28、2.29 和 2.30 等可以求解出非约束下最大化问题的支持向量，然后解出两个乘子，根据 KTT 条件，更新样本，进行优化。

表 2.1 函数拟合下的可行解边界

Table 2.1 The boundary of feasible regions for regression

	α_j	α_j^*
α_i	$L = \max(0, \gamma - C_j)$ $H = \min(C_i, \gamma)$	$L = \max(0, \gamma)$ $H = \min(C_i, \gamma + C_j^*)$
α_i^*	$L = \max(0, \gamma)$ $H = \min(C_i^*, -\gamma + C_j)$	$L = \max(0, -\gamma - C_j^*)$ $H = \min(C_i^*, -\gamma)$

接下来，我们就可以用分析的方法解只有两个样本的优化问题，对函数拟合的支持向量机其实有四个变量 $(\alpha_i, \alpha_j, \alpha_i^*, \alpha_j^*)$ 。定义：

$$\begin{aligned} v_i &= y_i - \sum_{\alpha \neq i, j} (\alpha_a - \alpha_a^*) K_{ia} + b \\ &= \varphi_i + (\alpha_i^{old} - \alpha_i^{*old}) K_{ii} + (\alpha_j^{old} - \alpha_j^{*old}) K_{ij} \end{aligned} \quad (2.28)$$

$$\text{所以 } v_i - v_j - \gamma(K_{ij} - K_{jj}) = \varphi_i - \varphi_j + (\alpha_i^{old} - \alpha_i^{*old})(K_{ii} + K_{jj} - 2K_{ij})$$

因此只有两个样本 (i, j) 可优化问题可表示为下面的形式：

$$\begin{aligned} \text{maximize } & \begin{cases} -\frac{1}{2} \begin{pmatrix} \alpha_i - \alpha_i^* \\ \alpha_j - \alpha_j^* \end{pmatrix}^T \begin{pmatrix} K_{ii} & K_{ij} \\ K_{ji} & K_{jj} \end{pmatrix} \begin{pmatrix} \alpha_i - \alpha_i^* \\ \alpha_j - \alpha_j^* \end{pmatrix} \\ + v_i (\alpha_i - \alpha_i^*) + v_j (\alpha_j - \alpha_j^*) - \varepsilon (\alpha_i + \alpha_i^* + \alpha_j + \alpha_j^*) \end{cases} \\ \text{subject to } & \begin{cases} (\alpha_i - \alpha_i^*) + (\alpha_j - \alpha_j^*) = \gamma \\ \alpha_i, \alpha_i^*, \alpha_j, \alpha_j^* \in [0, C] \end{cases} \end{aligned} \quad (2.29)$$

通过利用前面的约束，可得到下面的优化问题

$$\text{maximize } \begin{cases} -\frac{1}{2} (\alpha_i - \alpha_i^*)^2 (K_{ii} + K_{jj} - 2K_{ij}) - \varepsilon (\alpha_i + \alpha_i^*) (1-s) \\ + (\alpha_i - \alpha_i^*) (v_i - v_j - \gamma (K_{ii} - K_{ij})) \end{cases} \quad (2.30)$$

$$\text{subject to } \alpha_i^{(*)} \in [L^{(*)}, H^{(*)}]$$

对于上面的关于 α_i, α_i^* 的优化问题，由表 2.3 可以解出。

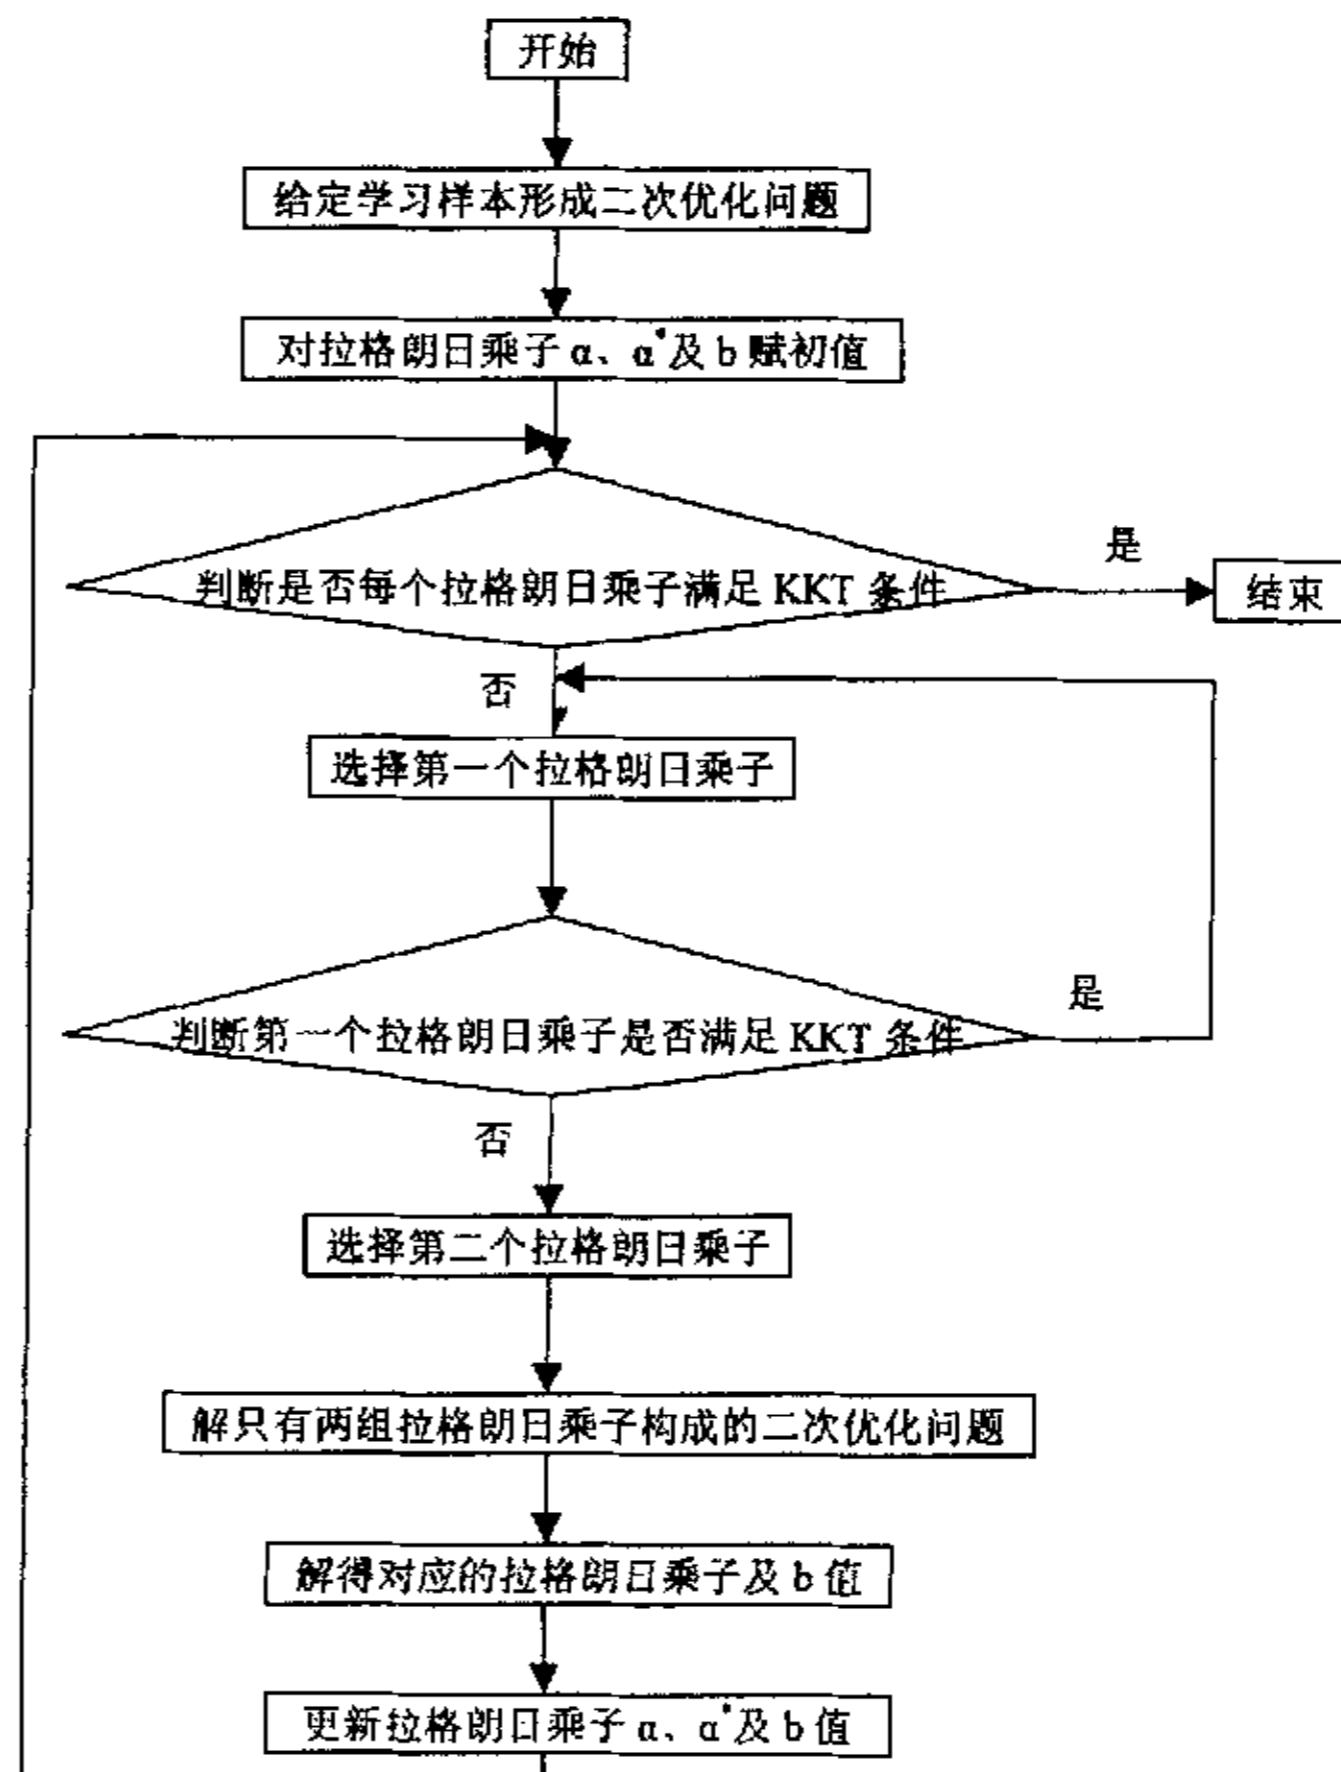
表 2.3 非约束最大化问题的解

Table2.3 Unconstrained maximum of the quadratic programming problem

α_i, α_j	$\frac{v_i - v_j - \gamma(K_{ij} - K_{jj})}{\eta} = \alpha_i^{old} + \frac{\varphi_i - \varphi_j}{\eta}$
α_i, α_j^*	$\frac{v_i - v_j - \gamma(K_{ij} - K_{jj}) - 2\varepsilon}{\eta} = \alpha_i^{old} + \frac{\varphi_i - \varphi_j - 2\varepsilon}{\eta}$
α_i^*, α_j	$\frac{v_j - v_i + \gamma(K_{ij} - K_{jj}) - 2\varepsilon}{\eta} = \alpha_i^{*old} - \frac{\varphi_i - \varphi_j + 2\varepsilon}{\eta}$
α_i^*, α_j^*	$\frac{v_j - v_i + \gamma(K_{ij} - K_{jj})}{\eta} = \alpha_i^{*old} - \frac{\varphi_i - \varphi_j}{\eta}$

在上面的表 3 中 $\eta = K_{ii} + K_{jj} - 2K_{ij}$ ，如果 $\eta = 0$ ，则 $\alpha_i = L$ 或 $\alpha_i = H$ 。

SMO 解出只有两个乘子的问题后，在每一步更新拉格朗日乘子。为了加快收敛，SMO 用如下的策略选择拉格朗日乘子^[30]。



2.8 SMO 算法框图

Fig2.8 The flow chart of SMO

对两个拉格朗日乘子分别采用不同的策略，第一个乘子的选择，在 SMO 算法中通过外层的一个循环实现。外层循环在整个训练集上搜索，决定是否每一个样本都不满足 KKT 条件，如果有一个不满足 KKT 条件，那它就被选择进行优化。训练集中的样本都满足上述条件后，再检查训练集中的所有位于边界的样本是否满足 KKT 条件，若有不满足的，即被选择进行优化。重复进行，直到所有的样本都满足 KKT 条件。接下来进行第二个乘子的选择，SMO 选择是目标函数值最小的乘子作为第二个乘子进行优化。如果这种方法失败，那么 SMO 在所有的非边界样本上进行搜索，寻找使目标函数值最小的乘子；若失败，则在整个训练集上搜索，寻找使目标函数值最小的乘子^[29]。

SMO 算法对于支持向量机的二次优化问题具有较好的效率，是目前图 2.8 在支持向量机算法中广泛采用的一种二次优化方法，其具体的步骤及框图如下：

- (1) 根据支持向量机算法构造对应的二次优化问题；
- (2) 对所有的拉格朗日乘子赋初值；
- (3) 判断所有的拉格朗日乘子是否满足 KKT 条件，若都满足，则此时的拉格朗日乘子及 b 值就是二次优化问题的解，结束，否则，转第 4 步；
- (4) 选择第一个拉格朗日乘子，并判断其是否满足 KKT 条件，若满足则重新选择，否则选为第一个乘子；
- (5) 选择第二个拉格朗日乘子，并解只有两组乘子构成的二次优化问题（式 2.30），由表 2.3 获得对应的拉格朗日乘子
- (6) 更新拉格朗日乘子及 b 值，转（3）；

2.4 遗传算法简介

遗传算法（Genetic algorithm, GA）最早由 Holland 教授提出，是一种新兴的模拟自然界生物进化机制的搜索寻优技术。自然界的生物通过自身的演化就能使问题得到完美的解决，遗传算法就仿效生物的进化与遗传，从某一初始值群体出发，根据达尔文进化论中的“生存竞争”和“优胜劣汰”的原则，借助复制、杂交、变异等操作，不断迭代计算，经过若干代的演化后，群体中的最优值逐步逼近最优解，直至最后达到全局最优。目前，遗传算法已经有了很大的发展，并开始渗透到人工智能、神经网络、机器人和运筹学等领域。遗传算法是多学科相互组合与渗透的产物，它已发展成为一种自组织、自适应的综合技术，广泛应用于计算机、工程技术、管理科学和社会科学等领域^[31, 32]。

自然界是一个自适应的大系统，自然系统中的大多数生物体通过自然选择和两性生殖这两种基本过程进行自身的演化，使自己逐步达到完美来适应自然界。遗传算法受生物进化和遗传的启发，形成一种独特的优化方式，遗传算法的运算原

对两个拉格朗日乘子分别采用不同的策略，第一个乘子的选择，在 SMO 算法中通过外层的一个循环实现。外层循环在整个训练集上搜索，决定是否每一个样本都不满足 KKT 条件，如果有一个不满足 KKT 条件，那它就被选择进行优化。训练集中的样本都满足上述条件后，再检查训练集中的所有位于边界的样本是否满足 KKT 条件，若有不满足的，即被选择进行优化。重复进行，直到所有的样本都满足 KKT 条件。接下来进行第二个乘子的选择，SMO 选择是目标函数值最小的乘子作为第二个乘子进行优化。如果这种方法失败，那么 SMO 在所有的非边界样本上进行搜索，寻找使目标函数值最小的乘子；若失败，则在整个训练集上搜索，寻找使目标函数值最小的乘子^[29]。

SMO 算法对于支持向量机的二次优化问题具有较好的效率，是目前图 2.8 在支持向量机算法中广泛采用的一种二次优化方法，其具体的步骤及框图如下：

- (1) 根据支持向量机算法构造对应的二次优化问题；
- (2) 对所有的拉格朗日乘子赋初值；
- (3) 判断所有的拉格朗日乘子是否满足 KKT 条件，若都满足，则此时的拉格朗日乘子及 b 值就是二次优化问题的解，结束，否则，转第 4 步；
- (4) 选择第一个拉格朗日乘子，并判断其是否满足 KKT 条件，若满足则重新选择，否则选为第一个乘子；
- (5) 选择第二个拉格朗日乘子，并解只有两组乘子构成的二次优化问题（式 2.30），由表 2.3 获得对应的拉格朗日乘子
- (6) 更新拉格朗日乘子及 b 值，转（3）；

2.4 遗传算法简介

遗传算法（Genetic algorithm, GA）最早由 Holland 教授提出，是一种新兴的模拟自然界生物进化机制的搜索寻优技术。自然界的生物通过自身的演化就能使问题得到完美的解决，遗传算法就仿效生物的进化与遗传，从某一初始值群体出发，根据达尔文进化论中的“生存竞争”和“优胜劣汰”的原则，借助复制、杂交、变异等操作，不断迭代计算，经过若干代的演化后，群体中的最优值逐步逼近最优解，直至最后达到全局最优。目前，遗传算法已经有了很大的发展，并开始渗透到人工智能、神经网络、机器人和运筹学等领域。遗传算法是多学科相互组合与渗透的产物，它已发展成为一种自组织、自适应的综合技术，广泛应用于计算机、工程技术、管理科学和社会科学等领域^[31, 32]。

自然界是一个自适应的大系统，自然系统中的大多数生物体通过自然选择和有性生殖这两种基本过程进行自身的演化，使自己逐步达到完美来适应自然界。遗传算法受生物进化和遗传的启发，形成一种独特的优化方式，遗传算法的运算原

理常常与生物进化及遗传学相吻合，而且术语也仿照生物学的术语。遗传算法的

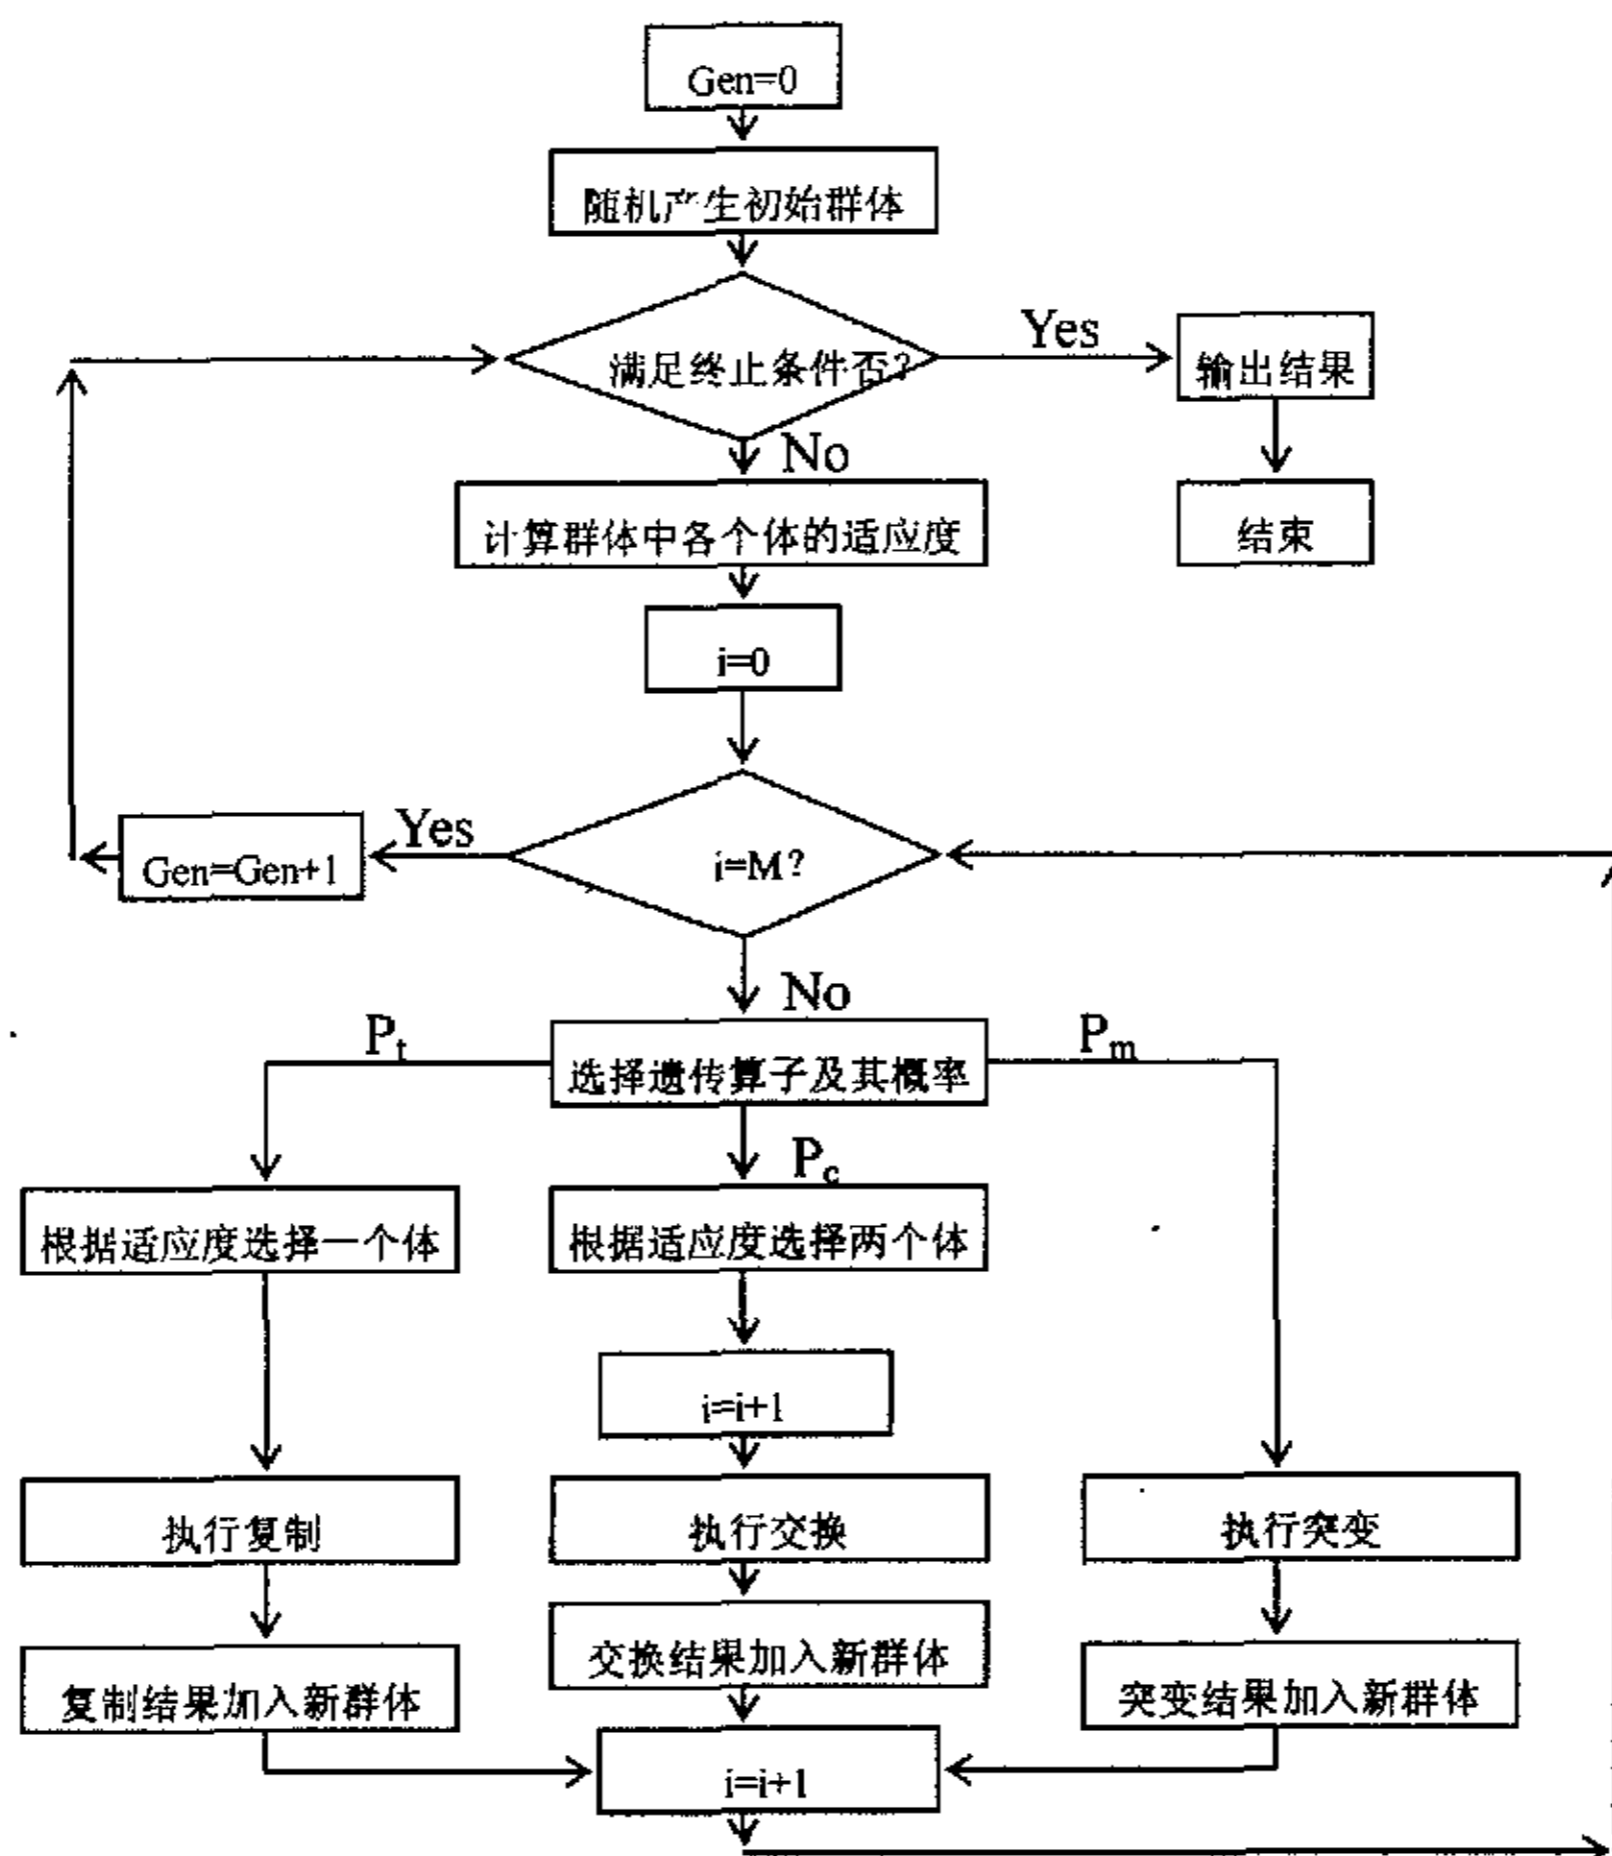


图 2.10 遗传算法工作流程图

Fig2.10 The flow chart of genetic algorithm

运算基础是字符串，先将搜索对象编码为字符串形式，字符串就相当于生物学中的染色体，由一系列字符组成，每个字符都有特定的含义，反映所解决问题的某个特征，这就相当于基因，即染色体 DNA 的片段，每个字符串结构被称为个体，每个个体都可以通过问题本身所具有的适应值来计算反映其适应性好坏的适应值，然后对一组字符串结构（被称为一个群体）进行循环操作。每次循环操作被称为一代，其中的遗传操作包括：保存字符串组中适应性较好的那些字符串到下一代，使上一代中的优良个体得以生存下去，这类似于生物进化论中的自然选择；通过有组织的然而却是随机的字符串间的信息交换来重新结合那些适应性好的字符串，在每一代中，利用上一代字符串结构中尝试新的位和段来替代原来的部分。

遗传算法是一类随机算法，但它不是简单的随机走动，它可以有效地利用已有的信息来搜寻那些有希望改善解质量的字符串。类似于自然进化，遗传算法通过作用于染色体上的基因，寻找好的染色体来求解问题。与自然界类似，遗传算法

对求解问题的本身一无所知，它需要的仅是对算法所产生的每个染色体进行评价，并基于适应值来选择染色体，使适应性好的染色体有更多的繁殖机会。

遗传算法的实施过程中包括编码、产生群体、计算适应度和遗传操作。图 2.10 给出了遗传算法的详细工作流程。图中 Gen 代表遗传的代次，M 表示群体中拥有的个体数目，i 表示已处理完个体的累计数，当累计数 i 等于总数 M，说明这一代的个体已全部处理完毕，需要转入下一代群体。概括地看，遗传算法主要执行以下四步：

- (1) 随机地建立由字符串组成的初始群体；
- (2) 计算各个体的适应度；
- (3) 根据遗传概率，利用遗传操作产生新群体：
 - 1) 复制。将已有的优良个体复制加入到新群体中，删除劣质个体；
 - 2) 交换。将选出的两个个体进行交换，所产生的新个体假如到新群体中；
 - 3) 突变。随机地改变某一个体的某个字符后加入新群体中；
- (4) 反复执行 (2)、(3) 后，一旦达到终止条件，选择最佳个体作为遗传算法的结果。

遗传算法利用简单的编码技术和繁殖机制来表现复杂的现象，从而解决非常困难的问题。特别是由于它不受搜索空间的限制性假设的约束，不必要求诸如连续性、导数存在和单峰等假设，它能从离散的、多极值的、含有噪声的高维问题中以很大的概率找到全局最优解。遗传算法目前已经在优化、机器学习和并行处理等领域得到广泛的应用。与传统的优化算法相比，遗传算法主要有以下特点：

- (1) 遗传算法不是直接作用在参变量上，而是利用参变量的某种编码；
- (2) 遗传算法不是从单个点，而是从一群点开始搜索；
- (3) 遗传算法利用适应值信息，无需导数或其它辅助信息；
- (4) 遗传算法利用概率转移规则，而非确定性规则。

遗传算法的优越性主要表现在：首先，它在搜索过程中不容易陷入局部最优，即使是在所定义的适应函数上是不连续的、非规则的或有噪声的情况下，它也能以很大的概率找到整体最优解；其次，由于它固有的并行性，遗传算法非常适用于大规模并行计算。

第三章 滑坡位移时间序列预测

3.1 时间序列的传统预测方法

时间序列指社会经济活动中，某一变量或指标的数值或观察值，按其出现时间的先后次序，且间隔时间相同而排列的一系列数值。时间序列预测是用被预测事物过去和现在的观测数据，构造依时间变化的序列模型，并借助一定规则来推测未来。时间序列预测方法是预测方法体系中的重要组成部分。

一般来说，时间序列是受趋势变化因素、季节变化因素、循环变化因素与不规则因素等四种因素的影响。70年代，由于Box-Jenkins模型的提出，使得时间序列方法得以迅速发展，并很快成为预测领域的主要方法之一。其主要的方法如下^[33-35]：

移动平均是预测技术中的一种古老方法。它对一组给定的历史数据，计算其平均值，并将这一平均值作为下一时期的预测值。移动平均分为移动算术平均与移动几何平均以及移动加权平均。这种方法非常简单但其预测精度是比较低的。

分解方法也是一种历史悠久的方法。它的基本思想是将预测数据分解为季节因子、趋势因子、循环因子和误差或随机因子。这种方法单独使用效果并不好。但是它作为识别数据特性的一种方法，仍然有其深刻的影响力。目前的一些调整方法可视为是其思想上的延伸。

指数平滑方法是一种较为实用的方法。最具代表性的是Holt-Winters的线性趋势平滑模型。它分为一次指数平滑，二次指数平滑与多次指数平滑。平滑方法是一种低费用、简单和不精致的方法，但其预测精度却可以与许多精致的、更具统计基础的方法相比拟。

周期性演变的活动是常见的事情。随着季节变化而发生的周期性的需求变化就是代表。例如水果、蔬菜、四季服装、啤酒冷饮的销售量、火车乘客、旅游观光的人数等。反映在时间序列上，统计数据呈现明显的有规律的季节变动。季节系数法就是根据这一规律进行预测的方法，在实际预测时，要用季节系数修正没有考虑季节影响的预测值。

由于Box和Jenkins的开拓性工作，自回归移动平均（ARIMA）模型仍是时间序列分析的中心课题，Box和Jenkins的著作，《Time series Analysis: Forecasting and Control》，曾一度成为时间序列分析的主要方法。Box-Jenkins方法在统计学上是完善的，有牢固的理论基础，有一套完整的程序化的建模方法。但同时这种方法是复杂的，对数据的性质也有一定的要求。另外它还要求研究者有较高的

第三章 滑坡位移时间序列预测

3.1 时间序列的传统预测方法

时间序列指社会经济活动中，某一变量或指标的数值或观察值，按其出现时间的先后次序，且间隔时间相同而排列的一系列数值。时间序列预测是用被预测事物过去和现在的观测数据，构造依时间变化的序列模型，并借助一定规则来推测未来。时间序列预测方法是预测方法体系中的重要组成部分。

一般来说，时间序列是受趋势变化因素、季节变化因素、循环变化因素与不规则因素等四种因素的影响。70年代，由于Box-Jenkins模型的提出，使得时间序列方法得以迅速发展，并很快成为预测领域的主要方法之一。其主要的方法如下^[33-35]：

移动平均是预测技术中的一种古老方法。它对一组给定的历史数据，计算其平均值，并将这一平均值作为下一时期的预测值。移动平均分为移动算术平均与移动几何平均以及移动加权平均。这种方法非常简单但其预测精度是比较低的。

分解方法也是一种历史悠久的方法。它的基本思想是将预测数据分解为季节因子、趋势因子、循环因子和误差或随机因子。这种方法单独使用效果并不好。但是它作为识别数据特性的一种方法，仍然有其深刻的影响力。目前的一些调整方法可视为是其思想上的延伸。

指数平滑方法是一种较为实用的方法。最具代表性的是Holt-Winters的线性趋势平滑模型。它分为一次指数平滑，二次指数平滑与多次指数平滑。平滑方法是一种低费用、简单和不精致的方法，但其预测精度却可以与许多精致的、更具统计基础的方法相比拟。

周期性演变的活动是常见的事情。随着季节变化而发生的周期性的需求变化就是代表。例如水果、蔬菜、四季服装、啤酒冷饮的销售量、火车乘客、旅游观光的人数等。反映在时间序列上，统计数据呈现明显的有规律的季节变动。季节系数法就是根据这一规律进行预测的方法，在实际预测时，要用季节系数修正没有考虑季节影响的预测值。

由于Box和Jenkins的开拓性工作，自回归移动平均（ARIMA）模型仍是时间序列分析的中心课题，Box和Jenkins的著作，《Time series Analysis: Forecasting and Control》，曾一度成为时间序列分析的主要方法。Box-Jenkins方法在统计学上是完善的，有牢固的理论基础，有一套完整的程序化的建模方法。但同时这种方法是复杂的，对数据的性质也有一定的要求。另外它还要求研究者有较高的

专业知识和对问题有深刻的认识。关于Box-Jenkins 方法的预测精度。对于不同的运用环境有着不同的结论。

在Box-Jenkins 方法的基础上,很多学者定义作了进一步的探讨。比如,Parzen 的 ARARMA 模型,Tsay 等人的一系列研究等。此外,值得重视的方法还有 Granger, Anderson 以及 Subba Rao 和 Gabr 对双线性模型的分析,Nicholls 和 Quinn 对随机系数自回归模型的讨论。Haggan, Qzaki 关于指数自回归模型的讨论,Tong 关于门回归模型及阈值自回归模型的研究。Priestley 的状态依赖模型以及 Kalman 滤波和 Bayesian 方法等。由于 Aoki 等人的杰出工作,使工程控制论中的一些方法被引入到预测领域。必须指出,这些方法大都侧重于理论研究,追求理论上的完善。以至于许多方法很不实用,真正能够用之解决实际问题的很少。结构的复杂给应用上带来了许多困难,在预测效果上也未有一致性的进展。因此,近年来学者们更加注意解决在实际中存在的实际问题,而非理论上的空谈。

3.2 滑坡预测的影响因素

发生滑坡的原因决定于内部因素和外部因素。内部因素即斜坡本身所具有的内部特征,它是滑坡产生的根本原因,主要是组成斜坡体的地层岩性、内部结构及有效临空面等,而外部因素则是滑坡产生的触发因素,它通过内部因素起作用。主要有地下水、地表水、振动、加载、坡脚淘蚀或开挖等。

滑坡内部因素的认识乃至基于大量野外滑坡调查测绘,从区域上确定易滑岩组、易滑构造带等宏观控制条件,现依大量滑坡野外调查的浅变质岩区和陆相沉积岩区加以说明。浅变质岩区的片岩和千枚岩岩组是该区易滑岩组类型,滑坡沿该易滑岩组分布条带密集发育,该易滑岩组的易滑性与岩性结构以及片状矿物的优选排列方位和含量有关。规模较大的滑坡其产出与分布多与区域大断裂构造线延伸方向一致,尤其与活动性断裂紧密相关。

陆相沉积岩区规模巨大的砂泥岩组滑坡,其分布规律与侏罗山式“浮褶带”,即隔档式褶皱构造或脱顶滑动构造紧密相关。当切割面(如江河等临空面)走向平行并临近向斜轴线时,滑坡即大量发生。这种层面由背斜陡倾,并逐步过度到开阔平缓向斜轴部的弧形结构面,即为易滑地质结构面。由该易滑面所组成条带状地带称其为易滑构造带,滑坡易密集于该带并延伸发育。沟谷切割深度与密度可以控制滑坡的空间集中性。此外,不同的斜坡水文地质结构往往可导致不同的滑坡。对斜坡上部为相对透水的多裂隙厚层块状砂岩或板岩,而其下部为隔水层泥岩或变火山岩时,滑坡发生区常与暴雨区分布相近一致。

滑坡的外部主要为人为因素,包括人们自觉不自觉的破坏,如破坏植被,过度使用地下水,最直接的破坏是进行各种施工,开挖山体,采掘矿产资源,这些大

专业知识和对问题有深刻的认识。关于Box-Jenkins 方法的预测精度。对于不同的运用环境有着不同的结论。

在Box-Jenkins 方法的基础上,很多学者定义作了进一步的探讨。比如,Parzen 的 ARARMA 模型,Tsay 等人的一系列研究等。此外,值得重视的方法还有 Granger, Anderson 以及 Subba Rao 和 Gabr 对双线性模型的分析,Nicholls 和 Quinn 对随机系数自回归模型的讨论。Haggan, Qzaki 关于指数自回归模型的讨论,Tong 关于门回归模型及阈值自回归模型的研究。Priestley 的状态依赖模型以及 Kalman 滤波和 Bayesian 方法等。由于 Aoki 等人的杰出工作,使工程控制论中的一些方法被引入到预测领域。必须指出,这些方法大都侧重于理论研究,追求理论上的完善。以至于许多方法很不实用,真正能够用之解决实际问题的很少。结构的复杂给应用上带来了许多困难,在预测效果上也未有一致性的进展。因此,近年来学者们更加注意解决在实际中存在的实际问题,而非理论上的空谈。

3.2 滑坡预测的影响因素

发生滑坡的原因决定于内部因素和外部因素。内部因素即斜坡本身所具有的内部特征,它是滑坡产生的根本原因,主要是组成斜坡体的地层岩性、内部结构及有效临空面等,而外部因素则是滑坡产生的触发因素,它通过内部因素起作用。主要有地下水、地表水、振动、加载、坡脚淘蚀或开挖等。

滑坡内部因素的认识乃至基于大量野外滑坡调查测绘,从区域上确定易滑岩组、易滑构造带等宏观控制条件,现依大量滑坡野外调查的浅变质岩区和陆相沉积岩区加以说明。浅变质岩区的片岩和千枚岩岩组是该区易滑岩组类型,滑坡沿该易滑岩组分布条带密集发育,该易滑岩组的易滑性与岩性结构以及片状矿物的优选排列方位和含量有关。规模较大的滑坡其产出与分布多与区域大断裂构造线延伸方向一致,尤其与活动性断裂紧密相关。

陆相沉积岩区规模巨大的砂泥岩组滑坡,其分布规律与侏罗山式“浮褶带”,即隔档式褶皱构造或脱顶滑动构造紧密相关。当切割面(如江河等临空面)走向平行并临近向斜轴线时,滑坡即大量发生。这种层面由背斜陡倾,并逐步过度到开阔平缓向斜轴部的弧形结构面,即为易滑地质结构面。由该易滑面所组成条带状地带称其为易滑构造带,滑坡易密集于该带并延伸发育。沟谷切割深度与密度可以控制滑坡的空间集中性。此外,不同的斜坡水文地质结构往往可导致不同的滑坡。对斜坡上部为相对透水的多裂隙厚层块状砂岩或板岩,而其下部为隔水层泥岩或变火山岩时,滑坡发生区常与暴雨区分布相近一致。

滑坡的外部主要为人为因素,包括人们自觉不自觉的破坏,如破坏植被,过度使用地下水,最直接的破坏是进行各种施工,开挖山体,采掘矿产资源,这些大

部分都对的滑坡的产生产生了推动作用,有些直接构成新的滑坡。人为因素,大部分破坏原有山体的平衡,加速或者加剧滑坡的产生,因此对滑坡产生机理的研究和滑坡演化规律的研究随着开发西部以及高层建筑的广泛崛起,显的尤为重要。

滑坡系统动态规律研究包括其演化过程中各阶段的特点以及其运动学和动力学变化规律。它基本受控于动态因素作用的方式、强度和历时,其作用又常具有周期性的旋回趋势。目前对其研究多集中于气候因素尤其是降雨的影响。滑坡动态因素的多变性和其运动过程的复杂性决定了其动态规律揭示的困难性。滑坡系统的动态规律有如下几点:滑坡单体系统的全程演化规律,具有类似于生物生态机理的时间阶段性过程,因而完全有可能将非生物的滑坡于以生物化。滑坡动态过程可借助于有关描述生物形为特征的数学生物动态模型去推演,如灰色控制系统中的 Verhulst 模型,而且也可采非线性的统计模型如泊松旋回方程去描述。区域滑坡群体的动态则有一系列滑坡单体所组成的族群特征去反映。由于某些动态因素的区域性变化的相对均一性,可导致滑坡单体个性组合表现出区域上的共性。一般,区域性滑坡群体的动态是一种盛衰周期反复旋回的过程,而一定范围内滑坡的消亡现象则是相对遥远的事件。地下水动态是影响斜坡稳定性系数的敏感性因素,降水或人类工程生活废水是滑坡地下水变化的主因。区域性滑坡动态随降雨量的变化而变化,其统计结果表明:滑坡活跃期与当地的降雨量丰年或特大暴雨季节相对应。用同一地区同一机理类型的多个滑坡位移检测数据所建立的位移—降雨量关系统计模型表明:一般强度的降雨对蠕动性滑坡的运动有加速作用,且其位移量随降雨量的增大成线性增长。

易滑坡地层所指的是已有滑坡的滑体及滑带所处的地层层位及其基本岩性组成。小贯义男曾将日本各地质时代的易滑坡地层作过分析。马克尼也曾指出了美国一系列易滑坡地层单位。我国铁道部门曾对部分地区主要类型滑坡分布与地层结构的关系作了概略性探讨。我国部分地区易滑坡地层揭示了滑坡空间分布的某些规律:一定地区的滑坡发生于一定的地层中;滑坡地层与滑坡主要类型多有对应关系,滑坡地层在不同地区的发育不同,其相适应的滑坡发育分布强度及类型也多有所差异;滑坡多发生于近代或上中更新世。

表3.1 我国滑坡滑坡组合类型及其地层分布简表

Table 3.1 Types of easy sliding soil.rock formation and the ir stra tigraphical distribution

滑坡物质类型	滑坡结构类型	主要滑坡组合类型	主要滑坡地层系统	滑坡主要分布地区
岩石滑坡	层状结构岩滑坡	1 砂、页、泥岩组滑坡 包括煤系地层中碳质、铝土质页岩及含盐地层中岩盐、石膏、泥灰岩薄层	新生界第四系 下更新统 第三系 中生界 各系古生界 二叠 石炭系	西南、华北、西北及部分东南地区
		2 碳酸盐岩组滑坡 夹砂、页岩、泥灰岩	中生界 三叠系 古生界 各系	西南、中南及部分华北地区
		3 凝灰岩组滑坡 夹蚀变斑脱岩及其它碎屑岩与页岩	新生界 第三系 中生界 白垩系 侏罗系	东北、内蒙古及京广铁路以东部分地区
	板片状结构岩滑坡	4 板、片岩组滑坡 包括千枚岩及绿泥石化、绢云母化、石墨化以及钙质、硅质岩	中下古生界各系及其以下岩层	秦岭、南岭纬向构造带以及东南、中南部分地区
	块状结构岩滑坡	5 玄武岩组滑坡 包括滑石化、蛇纹石化及蒙脱石化的岩体或薄层	中生界 侏罗、白垩系 古生界 二叠系上统	西南

续表3.1 我国滑坡滑坡组合类型及其地层分布简表

ConTab 3.1 Types of easy sliding soil.rock formation and the ir stragtical distribution

		混 合 结构岩 滑 坡	6 混合岩组滑坡 各种侵入岩体边缘带及围岩和裂隙充填软弱结构带岩石	不同的层系及侵入时代	不同构造单元或体系的接触带
		破 碎 结构岩 滑 坡	7 破碎岩组滑坡 各类构造破裂及揉皱带岩石或其风化岩	不同的层系	不同构造破碎带及揉皱带
土 滑 坡	堆 积 土 滑 坡	层 状 结构土 滑 坡	8 堆积土(层)组滑坡 坡积物、洪积物、残积物及部分冲积物。成分：亚粘土、亚砂土细屑层	新生界 第四系	各河谷缓坡地带
	黄 土 滑 坡	节 理 结构土 滑 坡	9黄土组滑坡 含钙亚粘土、亚砂土、粘土(古土壤)及砂砾层	新生界 第四系	黄河流域中游及局部上、下游地区
	粘 质 土 滑 坡	裂 隙 结 构 土 滑 坡	10 粘土组滑坡 含砂砾、亚粘土或泥灰层	新生界 第四系 第三系上统	长江流域中下游
		块 状 结 构 土 滑 坡	11 红土组滑坡 同上，成分以亚粘土、粘土为主	新生界 第四系	长江以南

续表3.1 我国滑坡组合类型及其地层分布简表

ConTab 3.1 Types of easy sliding soil-rock formation and the its stratigraphical distribution

堆填土滑坡	扰动结构土滑坡	12 人工堆积、填筑土组滑坡 各种岩、土或其混合物	现代	交通及工矿等部门的建设场地
-------	---------	---------------------------	----	---------------

3.3 滑坡的时间预测方法

时间预报是指对滑坡发生的具体时间的预报, 即对已获取的监测数据, 通过数学模型来预测未来某一时刻坡体的状态。目前常用的方法有:

斋滕法是国内外系统研究滑坡预测预报的初始理论。该方法以土体的蠕变理论为基础。土体的蠕变分为三个阶段(图 1), 第 I 阶段是减速蠕变阶段(AB 段), 第 II 阶段是稳定

蠕变阶段(BC 段), 第 III 阶段是加速蠕变阶段(CE)。

1965 年, 斋滕迪孝根据室内实验和仪器监测的结果, 提出以第 II 蠕变阶段和第 III 蠕变阶段的应变速率为基本参数的预测预报经验公式, 认为在稳定蠕变阶段, 各时刻的应变速率与该时刻距破坏时刻的时间的对数成反比, 相应计算公式为:




图 3.1 岩体蠕变曲线图

Figure 3.1 rock rheology

$$\lg t_r = 2.33 - 0.916 \times \lg \epsilon \pm 0.59 \tag{3.1}$$

在加速蠕变阶段, 取期间变形量相等的 t_1 、 t_2 、 t_3 三个时间来计算最后破坏时间, 相应计算公式为:

$$t_r = t_1 + \frac{(t_2 - t_1)^2 / 2}{(t_2 - t_1) - (t_3 - t_1) / 2} \tag{3.2}$$

续表3.1 我国滑坡组合类型及其地层分布简表

ConTab 3.1 Types of easy sliding soil.rock formation and the ir strati gographical distribution

堆填土滑坡	扰动结构土滑坡	12 人工堆积、填筑土组滑坡 各种岩、土或其混合物	现代	交通及工矿等部门的建设场地
-------	---------	---------------------------	----	---------------

3.3 滑坡的时间预测方法

时间预报是指对滑坡发生的具体时间的预报, 即对已获取的监测数据, 通过数学模型来预测未来某一时刻坡体的状态。目前常用的方法有:

斋滕法是国内外系统研究滑坡预测预报的初始理论。该方法以土体的蠕变理论为基础。土体的蠕变分为三个阶段(图 1), 第 I 阶段是减速蠕变阶段(AB 段), 第 II 阶段是稳定

蠕变阶段(BC 段), 第 III 阶段是加速蠕变阶段(CE)。

1965 年, 斋滕迪孝根据室内实验和仪器监测的结果, 提出以第 II 蠕变阶段和第 III 蠕变阶段的应变速率为基本参数的预测预报经验公式, 认为在稳定蠕变阶段, 各时刻的应变速率与该时刻距破坏时刻的时间的对数成反比, 相应计算公式为:




图 3.1 岩体蠕变曲线图

Figure 3.1 rock rheology

$$\lg t_r = 2.33 - 0.916 \times \lg \epsilon \pm 0.59 \tag{3.1}$$

在加速蠕变阶段, 取期间变形量相等的 t_1 、 t_2 、 t_3 三个时间来计算最后破坏时间, 相应计算公式为:

$$t_r = t_1 + \frac{(t_2 - t_1)^2 / 2}{(t_2 - t_1) - (t_3 - t_1) / 2} \tag{3.2}$$

公式中, t_r 为边坡最终破坏时间。

运用这种方法, 我国学者对 1983 年 7 月 9 日发生的金川露天矿采石场滑坡和 1985 年 6 月 12 日发生的湖北新滩滑坡等进行了成功的预报。

灰色模型是根据德国数学及生物学家 Verhulst 用灰色系统理论建立的用于生物繁殖量的预测模型演变过来的滑坡时间预测预报模型。灰色理论的预测是趋势性预测, 在实际使用中, 为了保证预测的现实逼近性, 通常需要用最新的实测数据进行建模。预测模型为:

$$t_r = -\frac{\Delta t}{a} \ln\left(\frac{bx_1}{a - bx_1}\right) + t_1 \quad (3.3)$$

其中 a, b 为与滑坡位移原始监测数据有关的参数。

非线性动力学模型预测

非线性动力学模型是按照非线性动力学的观点并运用耗散结构理论和协同学的宏观研究方法从时间序列数据中建立的边坡系统动力学模型。

选取多种参数, 预测滑坡发生时间。美国学者 B. Voight 于 1989 年提出多参数预报经验公式:

$$t_f - t_x = (\Omega_x^{1-\alpha} - \Omega_f^{1-\alpha}) / A(\alpha - 1) \quad (3.5)$$

式中: Ω ——任意参数, 位移, 剪应力, 地面倾角等。 Ω_x ——初始值, Ω_f ——预报值, α, A ——经验常数。

和神经网络用于空间预测预报中一样, 时间预报是用监测到的原始位移建立网络模型, 属于一种非参数预报方法。该预报方法无须事先假设边坡的破坏模型, 避免事先假设模型所带来的误差。

3.4 滑坡的空间预测方法

空间预测是指对滑坡发生的地点、规模等的预测, 目前使用较多的方法有以下几种:

稳定系数预测法是最早的滑坡空间预测的方法。该法通过计算滑坡体的安全系数 F_s 来预测某一具体边坡的稳定性。

$$F_s = F_{抗滑力} / F_{下滑力} \quad (3.6)$$

- 当 $F_s < 1.0$ 边坡处于不稳定状态
- 当 $F_s = 1.0$ 边坡处于临界状态
- 当 $F_s > 1.0$ 边坡处于稳定状态

公式中, t_r 为边坡最终破坏时间。

运用这种方法, 我国学者对 1983 年 7 月 9 日发生的金川露天矿采石场滑坡和 1985 年 6 月 12 日发生的湖北新滩滑坡等进行了成功的预报。

灰色模型是根据德国数学及生物学家 Verhulst 用灰色系统理论建立的用于生物繁殖量的预测模型演变过来的滑坡时间预测预报模型。灰色理论的预测是趋势性预测, 在实际使用中, 为了保证预测的现实逼近性, 通常需要用最新的实测数据进行建模。预测模型为:

$$t_r = -\frac{\Delta t}{a} \ln\left(\frac{bx_1}{a - bx_1}\right) + t_1 \quad (3.3)$$

其中 a, b 为与滑坡位移原始监测数据有关的参数。

非线性动力学模型预测

非线性动力学模型是按照非线性动力学的观点并运用耗散结构理论和协同学的宏观研究方法从时间序列数据中建立的边坡系统动力学模型。

选取多种参数, 预测滑坡发生时间。美国学者 B. Voight 于 1989 年提出多参数预报经验公式:

$$t_f - t_x = (\Omega_x^{1-\alpha} - \Omega_f^{1-\alpha}) / A(\alpha - 1) \quad (3.5)$$

式中: Ω ——任意参数, 位移, 剪应力, 地面倾角等。 Ω_x ——初始值, Ω_f ——预报值, α, A ——经验常数。

和神经网络用于空间预测预报中一样, 时间预报是用监测到的原始位移建立网络模型, 属于一种非参数预报方法。该预报方法无须事先假设边坡的破坏模型, 避免事先假设模型所带来的误差。

3.4 滑坡的空间预测方法

空间预测是指对滑坡发生的地点、规模等的预测, 目前使用较多的方法有以下几种:

稳定系数预测法是最早的滑坡空间预测的方法。该法通过计算滑坡体的安全系数 F_s 来预测某一具体边坡的稳定性。

$$F_s = F_{抗滑力} / F_{下滑力} \quad (3.6)$$

- 当 $F_s < 1.0$ 边坡处于不稳定状态
- 当 $F_s = 1.0$ 边坡处于临界状态
- 当 $F_s > 1.0$ 边坡处于稳定状态

计算稳定性系数的方法有多种,如基于极限平衡理论的条分法、瑞典法、数值分析法等。在计算中,参数的选取直接影响到分析结果的正确性。

神经网络能通过对已知样本的学习,掌握输入与输出间复杂的非线性映射关系,并对这种关系进行存储记忆,直接为预测提供知识库,同时,还具有高速的运行处理能力、自组织学习能力、高速的容错性、灵活性和适应性等优点。

神经网络对斜坡稳定性空间预测是用研究程度较高的斜坡地段作为已知样本对网络进行训练,直到网络掌握数据间的非线性映射关系为止,然后用该地区其它稳定性未知的地段作为预测样本,输入已经学习好的网络,通过网络的联想记忆功能直接预测稳定性。

在用神经网络进行预测预报中,可以把各种可能对边坡稳定性有影响的因素作为网络的输入,而提高预测的精度。许强等运用此方法预测了黄河某水电站库区和三峡某些典型斜坡地段的稳定性,预测精度达到 90%^[36]。

信息模型法把各种滑坡因素在滑坡作用过程中所起作用的大小程度用信息量表达。殷坤龙认为滑坡现象受多种因素的影响,且各种因素的作用性质不相同,对某一具体滑坡而言,总会存在“最佳因素组合”,基于此理论,信息模型主要研究“滑坡因素组合”,而不是停留在单个因素上,所以预测精度较高。殷坤龙等用此方法成功地对重庆市的斜坡稳定性进行了预测^[37]。

计算边坡的稳定系数需要涉及到滑坡的计算参数,由于滑坡性质的不确定性和离散性,使得同一边坡采用不同的计算参数得出差别较大结果,甚至得出相反的结论。采用灾变理论避开了这些不确定性的参数的影响,它假定系统在任何时刻的状态都可完全由给定的几个状态内部量(x_1, x_2, \dots, x_n)的值来确定,同时系统还受到 m 个独立的控制量(u_1, u_2, \dots, u_m)的控制,通过数学方法,研究系统状态的稳定与否与各量值的关系。该方法综合考虑了各种边坡要素对边坡稳定性的不同程度的影响,能较真实地描绘边坡系统的状态。吴文德等运用尖点灾变模型对某一中型露天矿山的稳定性进行了预测,得出了与现场实际相吻合的结果。

边坡的稳定性受诸多因素的影响,很难用一个确定的结论来表述其稳定还是不稳定,往往用模糊概念来表述,如把边坡的稳定等级分为“危险区”、“不稳定区”、“较不稳定”、“稳定区”等。模糊综合评判方法就是对边坡稳定性等级进行分类,并通过专家评分或构造隶属函数确定对同一等级各因素以及某一因素在不同等级中对边坡稳定性的影响程度(隶属度),建立模糊评判矩阵,确定边坡的稳定性对各等级的隶属程度,最后按择优原则预测边坡的稳定性。该方法的最终结果是否可靠,受单因素的选择和隶属度的确定影响较大。

3.5 支持向量机的预测方法

3.5.1 引言

位移是滑坡演化过程中反馈出的重要信息之一。用监测的位移进行建模可以对滑坡结构的未来演化规律、发展趋势等进行预测,及时掌握滑坡结构的变化规律,在工程上具有重要的意义。目前用于位移时间序列的主要方法是传统的时间序列分析方法和智能岩石力学的神经网络等方法,传统的时间序列分析方法是利用观测的历史位移建立预测的统计模型,这种模型无需知道滑坡结构中的力学过程和机理,具有一定的优点;但是这种统计模型一般当因变量和自变量之间是线性关系或一些简单的函数关系时才使用,同时当数据太少时不具有统计意义;智能岩石力学的神经网络方法也是基于大样本的一种学习方法。由于滑坡结构的复杂性,所涉及的工程地质条件及滑坡特性参数通常是不确定的、模糊的,影响滑坡力学特性的各要素之间存在着非常复杂的非线性关系,很难用确定的数学模型描述,这使传统的方法存在不足。最近发展起来的支持向量机方法是基于统计学习理论的新学习方法,用它建模不必知道因变量和自变量之间的关系,通过对样本的学习即可获得因变量和自变量之间非常复杂的非线性映射关系;同时,它是基于小样本的一种学习方法,不必知道太多的数据即可建模。由于支持向量机的推广预测能力很大程度上,依赖于支持向量机的核函数和参数,因此他们的合理确定是至关重要的。遗传算法是一种模拟生物界自然进化过程的优化方法,具有全局最优性、并行性等优点^[1]因此作者将遗传算法和支持向量机进行有机结合,提出了一种用于滑坡工程位移预测预报的新方法——进化支持向量机方法。

3.5.2 基于进化支持向量机的滑坡位移预测方法

遗传算法是一种全局最优化方法,它模拟了自然界生物进化过程中的“优胜劣汰,适者生存”的法则,将复制、杂交、变异等引入到算法中,通过构造一定规模的初始可行解群体并对其进行遗传操作,直至搜索到最优解。它克服了传统优化方法的缺点,具有隐含并行性,可以较快地搜索到全局最优解。

支持向量机是基于统计学习理论的一种小样本的学习方法,它采用结构风险最小化原则,通过对有限样本的学习,就可获得很好的推广能力;同时,通过核函数的思想很好地解决了高维问题;并且支持向量的获得是通过解凸规划问题获得的,保证找到的解是全局最优解。支持向量机参数对支持向量机的推广能力有很大的影响,通常支持向量机参数的选择是人工试算获得的,通过将遗传算法和支持向量机结合,改进了支持向量机的参数选择。

3.5 支持向量机的预测方法

3.5.1 引言

位移是滑坡演化过程中反馈出的重要信息之一。用监测的位移进行建模可以对滑坡结构的未来演化规律、发展趋势等进行预测,及时掌握滑坡结构的变化规律,在工程上具有重要的意义。目前用于位移时间序列的主要方法是传统的时间序列分析方法和智能岩石力学的神经网络等方法,传统的时间序列分析方法是利用观测的历史位移建立预测的统计模型,这种模型无需知道滑坡结构中的力学过程和机理,具有一定的优点;但是这种统计模型一般当因变量和自变量之间是线性关系或一些简单的函数关系时才使用,同时当数据太少时不具有统计意义;智能岩石力学的神经网络方法也是基于大样本的一种学习方法。由于滑坡结构的复杂性,所涉及的工程地质条件及滑坡特性参数通常是不确定的、模糊的,影响滑坡力学特性的各要素之间存在着非常复杂的非线性关系,很难用确定的数学模型描述,这使传统的方法存在不足。最近发展起来的支持向量机方法是基于统计学习理论的新学习方法,用它建模不必知道因变量和自变量之间的关系,通过对样本的学习即可获得因变量和自变量之间非常复杂的非线性映射关系;同时,它是基于小样本的一种学习方法,不必知道太多的数据即可建模。由于支持向量机的推广预测能力很大程度上,依赖于支持向量机的核函数和参数,因此他们的合理确定是至关重要的。遗传算法是一种模拟生物界自然进化过程的优化方法,具有全局最优性、并行性等优点^[1]因此作者将遗传算法和支持向量机进行有机结合,提出了一种用于滑坡工程位移预测预报的新方法——进化支持向量机方法。

3.5.2 基于进化支持向量机的滑坡位移预测方法

遗传算法是一种全局最优化方法,它模拟了自然界生物进化过程中的“优胜劣汰,适者生存”的法则,将复制、杂交、变异等引入到算法中,通过构造一定规模的初始可行解群体并对其进行遗传操作,直至搜索到最优解。它克服了传统优化方法的缺点,具有隐含并行性,可以较快地搜索到全局最优解。

支持向量机是基于统计学习理论的一种小样本的学习方法,它采用结构风险最小化原则,通过对有限样本的学习,就可获得很好的推广能力;同时,通过核函数的思想很好地解决了高维问题;并且支持向量的获得是通过解凸规划问题获得的,保证找到的解是全局最优解。支持向量机参数对支持向量机的推广能力有很大的影响,通常支持向量机参数的选择是人工试算获得的,通过将遗传算法和支持向量机结合,改进了支持向量机的参数选择。

统计学习理论作为支持向量机的理论基础,国外已对其进行了深入的研究,但是支持向量机作为统计学习理论的一项核心内容,其应用远未达到其理论期望的效果。究其原因,一是支持向量机算法研究的深度和计算的效率不够;二是支持向量机的核函数和参数 C 的选择也是影响其应用的重要原因。但是支持向量机在实际应用中,关于参数选择的问题仍然没有得到很好地解决。例如,多项式学习机器的阶数问题、径向基机器中的函数宽度,以及 Sigmoid 机器中函数的宽度和偏移等。统计学习理论目前对这些问题给出了一些建议和解释,但还没有给出实际可行的方案。因此,在使用支持向量机进行分类和预测时,如何选择适当的参数就成了一个非常重要的问题。

支持向量机的参数(核函数和 C)对算法的效率和推广预测能力有很大的影响,他们的选择是建立一个支持向量机模型的重要内容。遗传算法的出现,使其成为可能。遗传算法是模拟生物界自然进化过程的优化方法,具有全局最优性、隐含并行性、算法的高度稳定性和广泛的可用性等优点。将遗传算法用于搜索支持向量机的核函数和参数 C ,将减少人为选择的盲目性,提高支持向量机的推广预测能力。

建立基于遗传算法的进化支持向量机方法,用遗传算法来搜索支持向量机的最优的核函数和参数 C ,其具体步骤和算法如下。

(1) 对进化支持向量机进行初始化设置,包括设置进化代数、群体规模、核函数和参数 C 的搜索范围、杂交率和变异率等。

(2) 随机产生一组可能的值作为父代,其中每个个体代表一个支持向量机模型,该模型对应不同的支持向量机参数(包括核函数和 C)。

(3) 用每一个个体决定了一个支持向量机模型(具体算法见第 2 章 2.3.6 和 2.4),用它预测测试样本的位移值,计算每个个体的适应值 $f(x)$,以反映本支持向量机模型的推广预测能力,适应值函数如下:

$$f(x) = \min(\sum (x_i - x_i')^2, i = 1, 2, \dots, n) \quad (3.7)$$

式中, x_i 为第 i 个测试样本的位移预测值; x_i' 为第 i 个测试样本的实测值; $i = 1, 2, \dots, n$, n 为测试样本的个数。

(4) 随机选择两个适应值低于平均适应值的父代个体 i_1 、 i_2 ,对 i_1 、 i_2 进行杂交操作,产生两个新的个体

(5) 按照突变概率随机选择一父代个体进行突变操作,以产生新的个体。

(6) 重复步骤(4)、(5),直到生成一子代群体;

(7) 将父代中最好的个体随机置换子代中一个个体，将子代转化为父代，计算每一个个体的适应值，然后重复 (3) ~ (6)，直至得到满意的支持向量机模型（最优核函数和参数 C 对应的模型）。

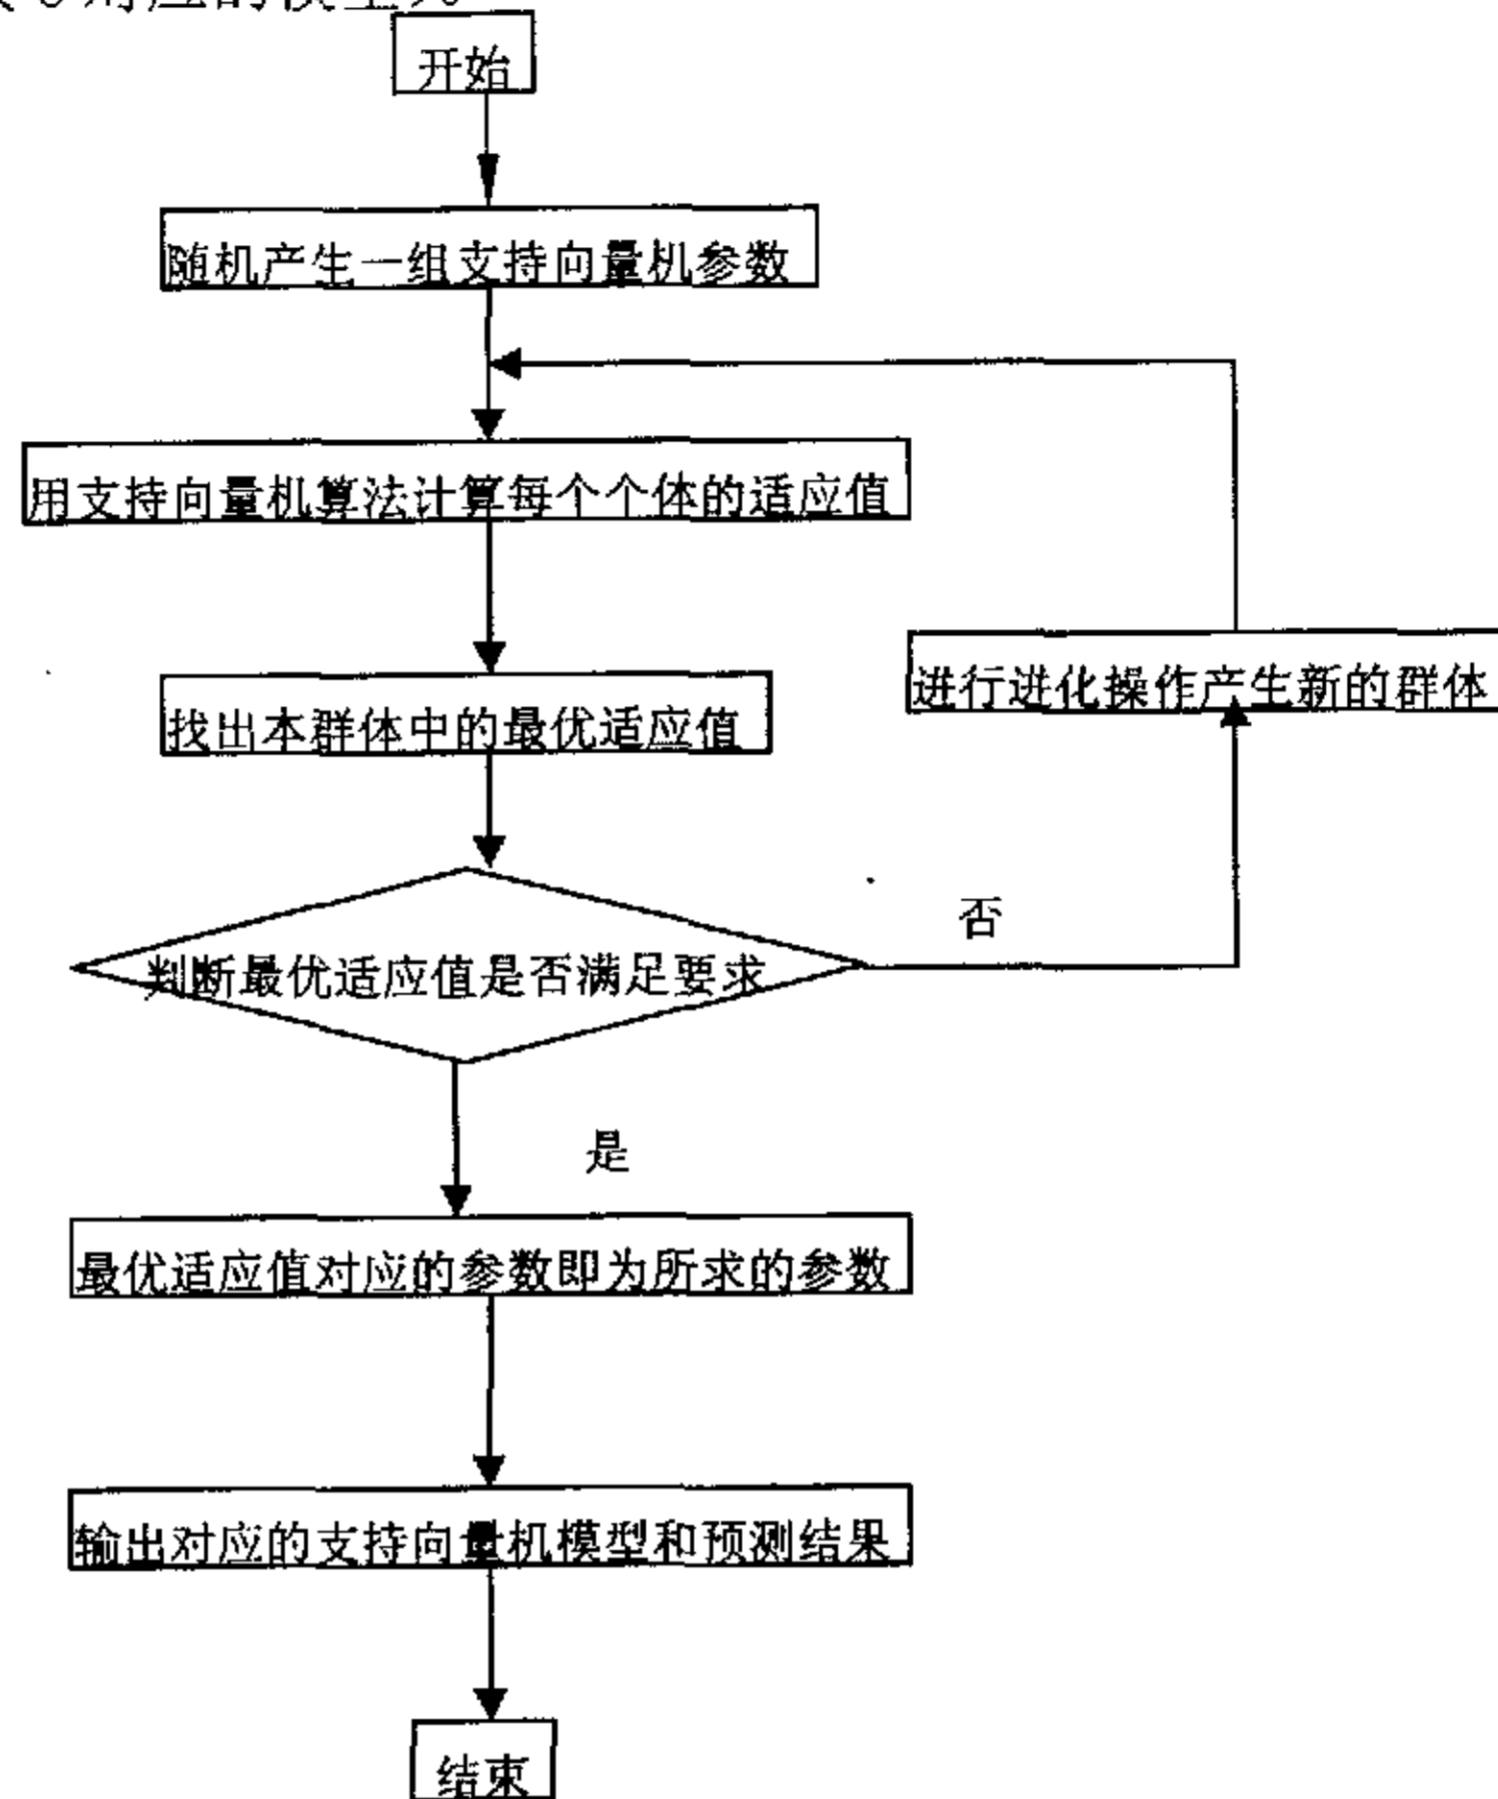


图 3.2 进化支持向量机算法

Fig3.2 The algorithm of Evolutionary Support Vector Machine

3.5.3 非线性位移时间序列的支持向量机表达

支持向量机 (Support Vector Machine) 是基于统计学习理论的一种新的通用学习方法，它是建立在一套较好的有限样本下机器学习的理论框架和通用方法之下，它既有严格的理论基础，又能较好地解决小样本、非线性、高维数和局部极小点等实际问题，其核心思想就是学习机器要与有限的训练样本相适应。支持向量机中的支持向量是通过解一个凸二次优化问题获得的，它保证找到的解是全局最优解，在支持向量机算法中解二次优化的方法主要有：*SMO* 方法、内点算法^[48]、子集选择方法等。

对于一个非线性位移时间序列，通过监测获得其位移随时间变化的一个时间序列 $\{x_i\} = \{x_1, x_2, \dots, x_n\}$ ，对这个非线性位移序列进行预测，就是要寻找在 $i+p$ 时刻

(7) 将父代中最好的个体随机置换子代中一个个体，将子代转化为父代，计算每一个个体的适应值，然后重复 (3) ~ (6)，直至得到满意的支持向量机模型（最优核函数和参数 C 对应的模型）。




图 3.2 进化支持向量机算法

Fig3.2 The algorithm of Evolutionary Support Vector Machine

3.5.3 非线性位移时间序列的支持向量机表达

支持向量机 (Support Vector Machine) 是基于统计学习理论的一种新的通用学习方法，它是建立在一套较好的有限样本下机器学习的理论框架和通用方法之下，它既有严格的理论基础，又能较好地解决小样本、非线性、高维数和局部极小点等实际问题，其核心思想就是学习机器要与有限的训练样本相适应。支持向量机中的支持向量是通过解一个凸二次优化问题获得的，它保证找到的解是全局最优解，在支持向量机算法中解二次优化的方法主要有：*SMO* 方法、内点算法^[48]、子集选择方法等。

对于一个非线性位移时间序列，通过监测获得其位移随时间变化的一个时间序列 $\{x_i\} = \{x_1, x_2, \dots, x_n\}$ ，对这个非线性位移序列进行预测，就是要寻找在 $i+p$ 时刻

的位移值 x_{i+p} 与前 p 个时刻的位移值 $x_i, x_{i+1}, \dots, x_{i+p-1}$ 的关系, 即 $x_{i+p} = f(x_i, x_{i+1}, \dots, x_{i+p-1})$, $f()$ 为一个非线性函数, 表示位移时间序列之间的非线性关系。

根据支持向量机理论^[47, 48], 上述的非线性关系可以用支持向量机对 n 个实测位移的学习来获得, 也就是通过对 $n-p$ 个位移时间序列 $X_i, X_{i+1}, \dots, X_{i+p-1}, i=1, \dots, n-p$, 的学习, 来获得位移时间序列之间的非线性关系,

$$f(X_{n+m}) = \sum_{i=1}^{n-p} (\alpha_i - \alpha_i^*) K(X_{n+m}, X_i) + b \quad (3.8)$$

式中: $f(x_{n+m})$ 表示第 $n+m$ 时刻的位移值; X_{n+m} 表示 $n+m$ 时刻前 p 个时刻的位移值, $X_{n+m} = (x_{n+m,p}, x_{n+m,p+1}, \dots, x_{n+m,l})$, X_i 表示第 $p+i$ 时刻前 p 个时刻的位移值, $X_i = (x_i, x_{i+1}, \dots, x_{i+p-1})$; $K()$ 是核函数; α, α^* 和 b 是通过解如下的二次规划问题获得的,

$$\begin{aligned} \text{MAX: } W(\alpha, \alpha^*) &= -\frac{1}{2} \sum_{i,j=1}^{n-p} (\alpha_i - \alpha_i^*)(\alpha_j - \alpha_j^*) K(X_i, X_j) + \sum_{i=1}^k X_{i+p} (\alpha_i - \alpha_i^*) - \varepsilon \sum_{i=1}^{n-p} (\alpha_i + \alpha_i^*) \\ \text{s. t } &\begin{cases} \sum_{i=1}^{n-p} (\alpha_i - \alpha_i^*) = 0, \\ 0 \leq \alpha_i, \alpha_i^* \leq C, i = 1, 2, \dots, n-p \end{cases} \end{aligned} \quad (3.9)$$

按上述方法将变形表示为时间序列后, 采用进化支持向量机方法求出最优的支持向量机, 就可确定出 4.2 式表示的滑坡非线性变形时间序列分析的支持向量机。

3.5.4 滚动预测方法

在利用进化支持向量机方法进行位移时间序列预测时, 为了充分利用最新的信息, 提高预测的准确性, 采用了滚动预测的方法。其基本思想是, 假设要对时间序列 $\{x_t\}$ 进行预测, 最佳历史点数为 p , 预测的步数

为 m (p, m 根据实际问题确定); 目前已经获得 n 个时间序列 $\{x_0, x_1, \dots, x_{n-1}\}$, 滚动预测的第一步是, 用 n 个时间序列的 $\{X_i, X_{i+1}, \dots, X_{i+p-1}, X_{i+p}\} (i=0, 1, 2, \dots, n-p-1)$ $n-p$ 组时序预测 n 时刻后的 $\{X_n, X_{n+1}, \dots, X_{n+m-1}\}$ m 个时序; 随着后面 m 个时序的获得, 用 m 个新的时序替代前面的 $\{X_0, X_1, \dots, X_{m-1}\}$ m 个时序进行下一步的预测, 得到下一次的 m 个预测值, 依次类推。

的位移值 x_{i+p} 与前 p 个时刻的位移值 $x_i, x_{i+1}, \dots, x_{i+p-1}$ 的关系, 即 $x_{i+p} = f(x_i, x_{i+1}, \dots, x_{i+p-1})$, $f()$ 为一个非线性函数, 表示位移时间序列之间的非线性关系。

根据支持向量机理论^[47, 48], 上述的非线性关系可以用支持向量机对 n 个实测位移的学习来获得, 也就是通过对 $n-p$ 个位移时间序列 $X_i, X_{i+1}, \dots, X_{i+p-1}, i=1, \dots, n-p$, 的学习, 来获得位移时间序列之间的非线性关系,

$$f(X_{n+m}) = \sum_{i=1}^{n-p} (\alpha_i - \alpha_i^*) K(X_{n+m}, X_i) + b \quad (3.8)$$

式中: $f(x_{n+m})$ 表示第 $n+m$ 时刻的位移值; X_{n+m} 表示 $n+m$ 时刻前 p 个时刻的位移值, $X_{n+m} = (x_{n+m,p}, x_{n+m,p+1}, \dots, x_{n+m,l})$, X_i 表示第 $p+i$ 时刻前 p 个时刻的位移值, $X_i = (x_i, x_{i+1}, \dots, x_{i+p-1})$; $K()$ 是核函数; α, α^* 和 b 是通过解如下的二次规划问题获得的,

$$\begin{aligned} \text{MAX: } W(\alpha, \alpha^*) &= -\frac{1}{2} \sum_{i,j=1}^{n-p} (\alpha_i - \alpha_i^*)(\alpha_j - \alpha_j^*) K(X_i, X_j) + \sum_{i=1}^k X_{i+p} (\alpha_i - \alpha_i^*) - \varepsilon \sum_{i=1}^{n-p} (\alpha_i + \alpha_i^*) \\ \text{s. t } &\begin{cases} \sum_{i=1}^{n-p} (\alpha_i - \alpha_i^*) = 0, \\ 0 \leq \alpha_i, \alpha_i^* \leq C, i = 1, 2, \dots, n-p \end{cases} \end{aligned} \quad (3.9)$$

按上述方法将变形表示为时间序列后, 采用进化支持向量机方法求出最优的支持向量机, 就可确定出 4.2 式表示的滑坡非线性变形时间序列分析的支持向量机。

3.5.4 滚动预测方法

在利用进化支持向量机方法进行位移时间序列预测时, 为了充分利用最新的信息, 提高预测的准确性, 采用了滚动预测的方法。其基本思想是, 假设要对时间序列 $\{x_t\}$ 进行预测, 最佳历史点数为 p , 预测的步数

为 m (p, m 根据实际问题确定); 目前已经获得 n 个时间序列 $\{x_0, x_1, \dots, x_{n-1}\}$, 滚动预测的第一步是, 用 n 个时间序列的 $\{X_i, X_{i+1}, \dots, X_{i+p-1}, X_{i+p}\} (i=0, 1, 2, \dots, n-p-1)$ $n-p$ 组时序预测 n 时刻后的 $\{X_n, X_{n+1}, \dots, X_{n+m-1}\}$ m 个时序; 随着后面 m 个时序的获得, 用 m 个新的时序替代前面的 $\{X_0, X_1, \dots, X_{m-1}\}$ m 个时序进行下一步的预测, 得到下一次的 m 个预测值, 依次类推。

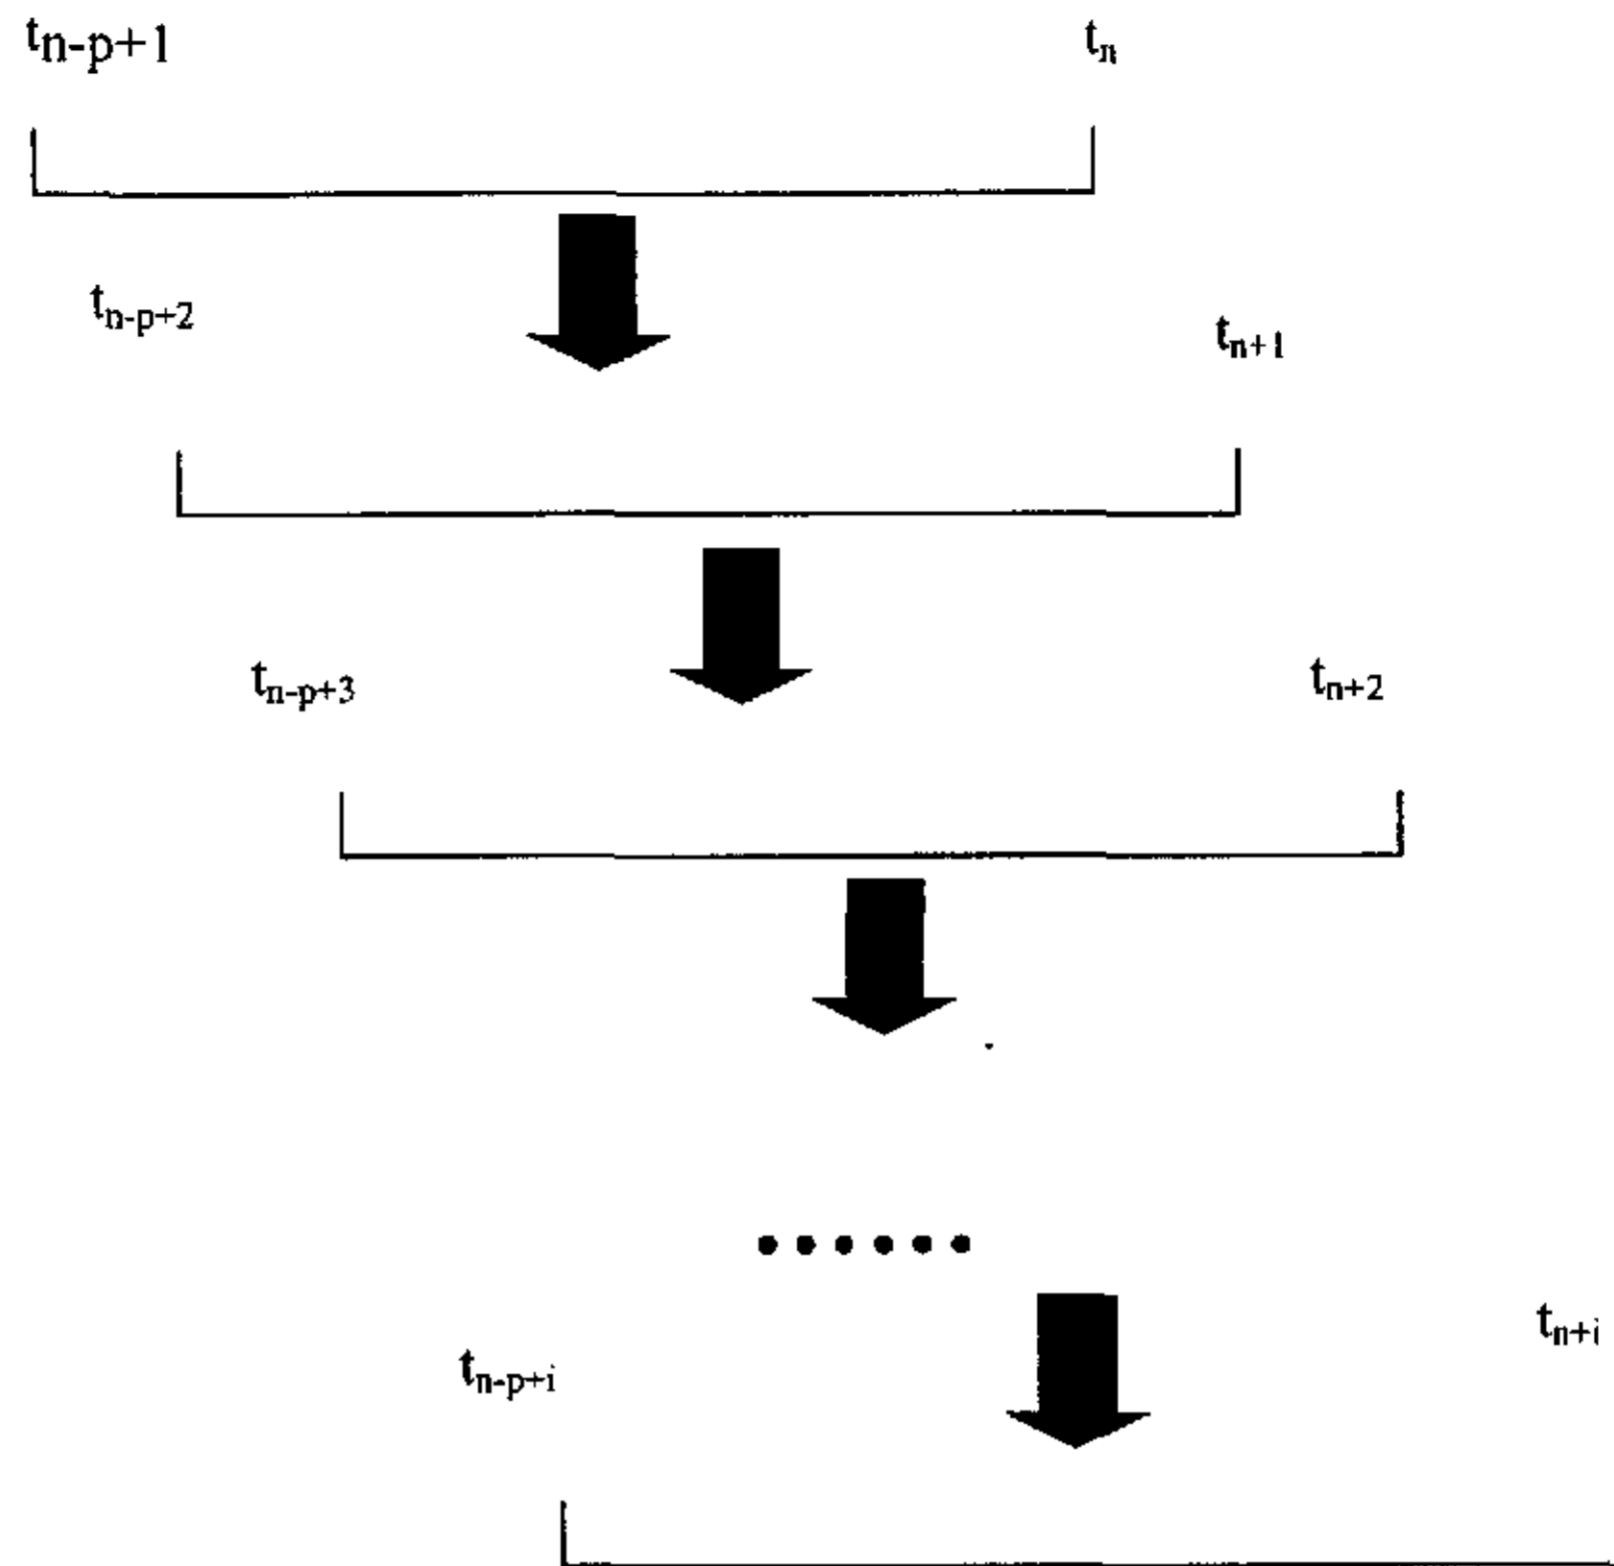


图 3.3 滚动预测图

Figure 3.3 rolling prediction

从以上可以看出，进化支持向量机方法既利用了支持向量机的非线性映射、有限样本和较好的推广预测能力，又利用了遗传算法的全局优化特性；而滚动预测方法每次利用了最新的观测数据。因此，它作为一种新的非线性智能识别方法，具有广泛的应用前景。

3.5.5 单因素滑坡时间序列的预测

滑坡是一个受地质条件、地下水、地震和人类工程活动等多种因素影响而发展演化的多维非线性混沌系统。时间序列是动态系统的观察和抽样，它应反映动态系统的真实面目，进而由时间序列估计和建立动态模型。在工程实际中，很容易得到滑坡体某一监测点的位移时间序列，这也是反映滑坡动态规律最重要的一个变量。而影响滑坡变形破坏的其它因素的时间序列则不易直接得到，往往需要预测。因此，如何不利用其它因素的数据序列，只用所观察到的位移时间序列 x_1, x_2, \dots, x_n ，建立恰当的动态模型来预测 x_{n+1} ，是具有十分重要应用价值。本文利用监测点所得的数据组成学习样本，进行学习后，得到支持向量机的映像模型，

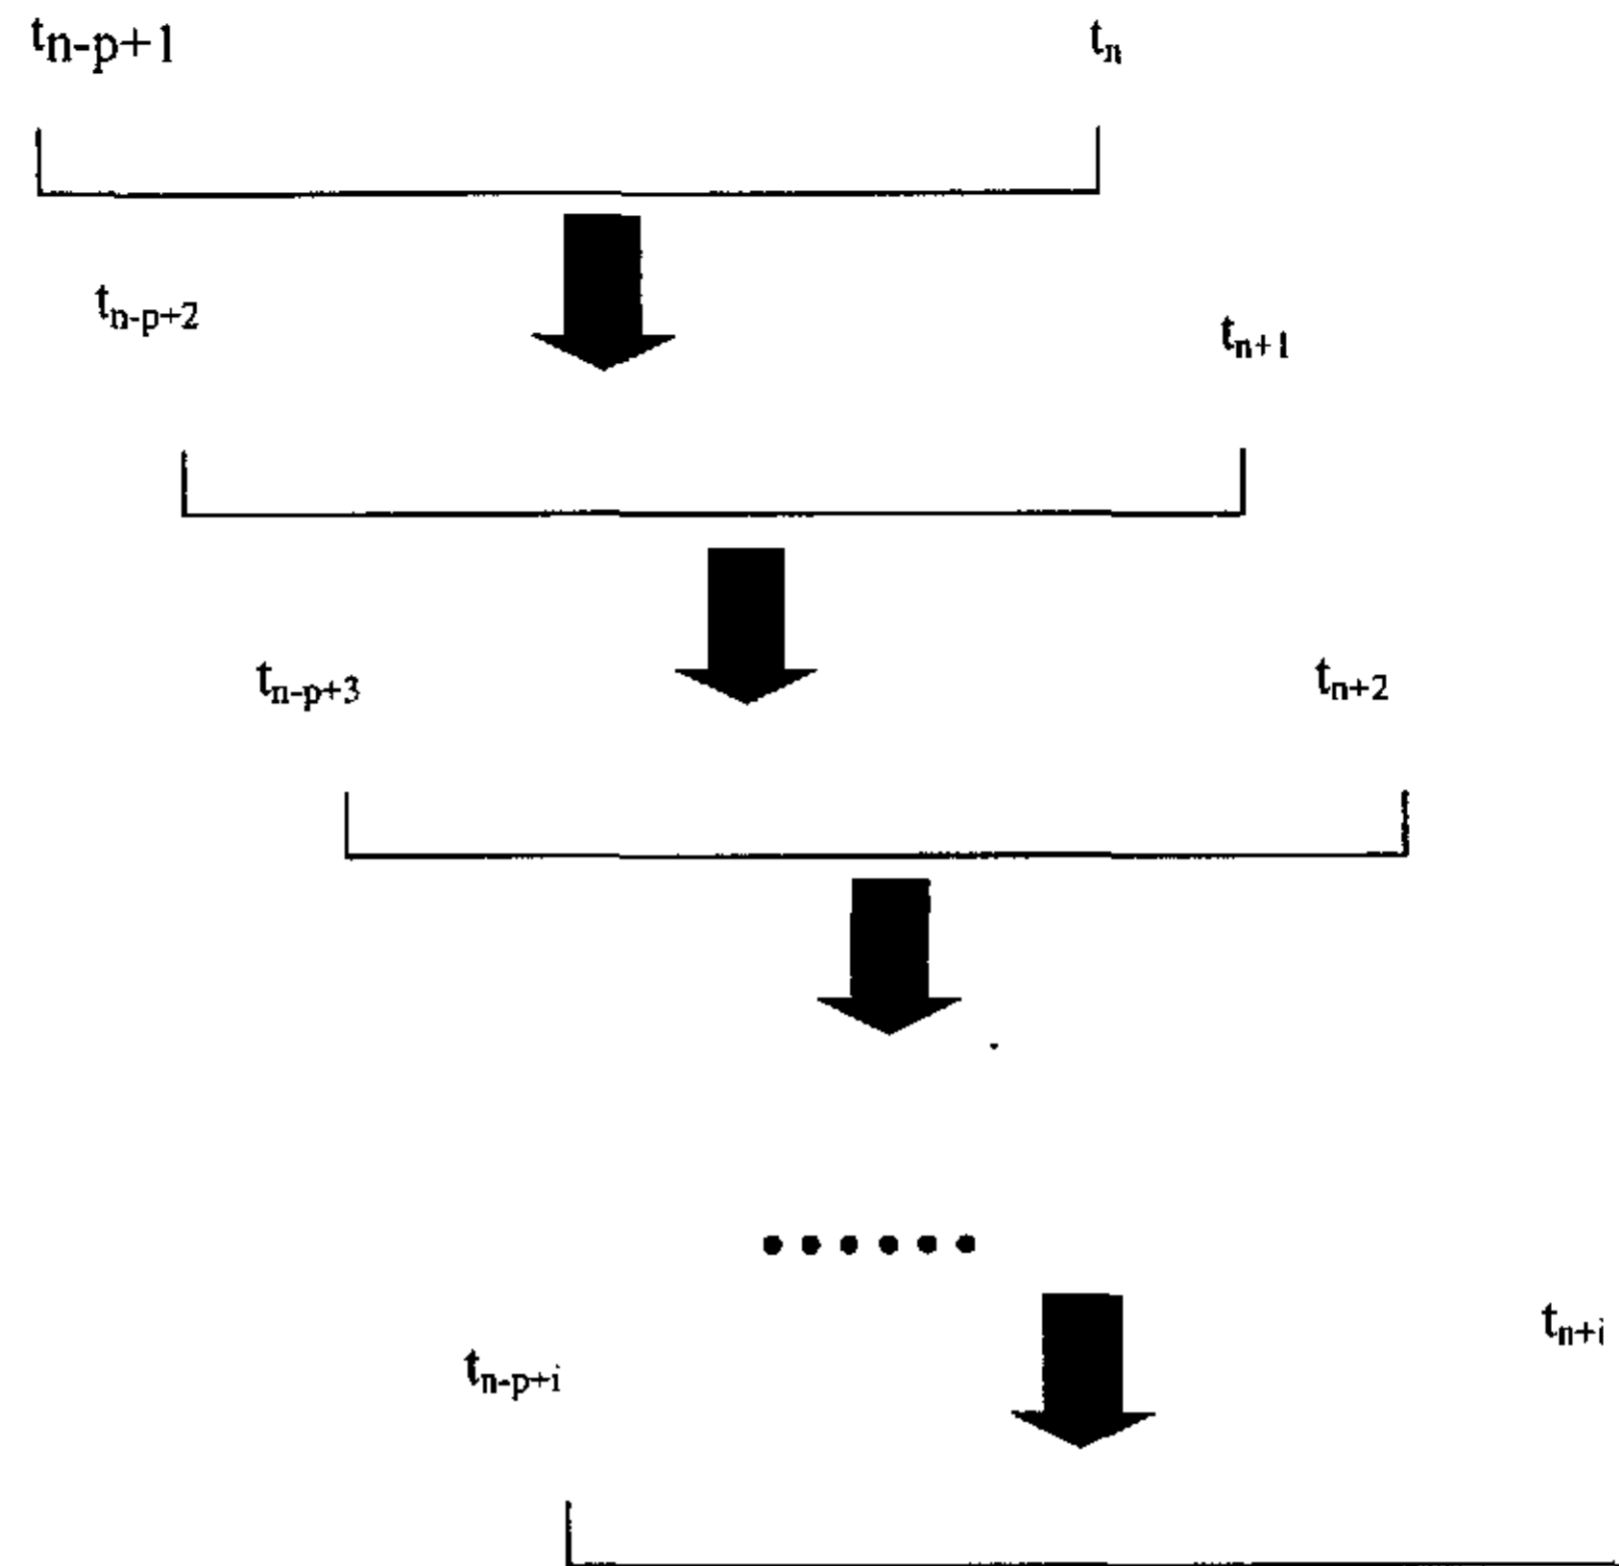


图 3.3 滚动预测图

Figure 3.3 rolling prediction

从以上可以看出，进化支持向量机方法既利用了支持向量机的非线性映射、有限样本和较好的推广预测能力，又利用了遗传算法的全局优化特性；而滚动预测方法每次利用了最新的观测数据。因此，它作为一种新的非线性智能识别方法，具有广泛的应用前景。

3.5.5 单因素滑坡时间序列的预测

滑坡是一个受地质条件、地下水、地震和人类工程活动等多种因素影响而发展演化的多维非线性混沌系统。时间序列是动态系统的观察和抽样，它应反映动态系统的真实面目，进而由时间序列估计和建立动态模型。在工程实际中，很容易得到滑坡体某一监测点的位移时间序列，这也是反映滑坡动态规律最重要的一个变量。而影响滑坡变形破坏的其它因素的时间序列则不易直接得到，往往需要预测。因此，如何不利用其它因素的数据序列，只用所观察到的位移时间序列 x_1, x_2, \dots, x_n ，建立恰当的动态模型来预测 x_{n+1} ，是具有十分重要应用价值。本文利用监测点所得的数据组成学习样本，进行学习后，得到支持向量机的映像模型，

如图 4.3 所示。所得到的支持向量机映像模型，由公式(3.10)中 $f(x_i, x_{i+1}, \dots, x_{i+p-1})$ 表达出来，其中 x_i 代表一个位移序列， x_{i+p} 代表要预测的位移序列。根据图 4.4 输入预测样本，应用所得到的支持向量机模型进行预测，的到所需要的位移结果。

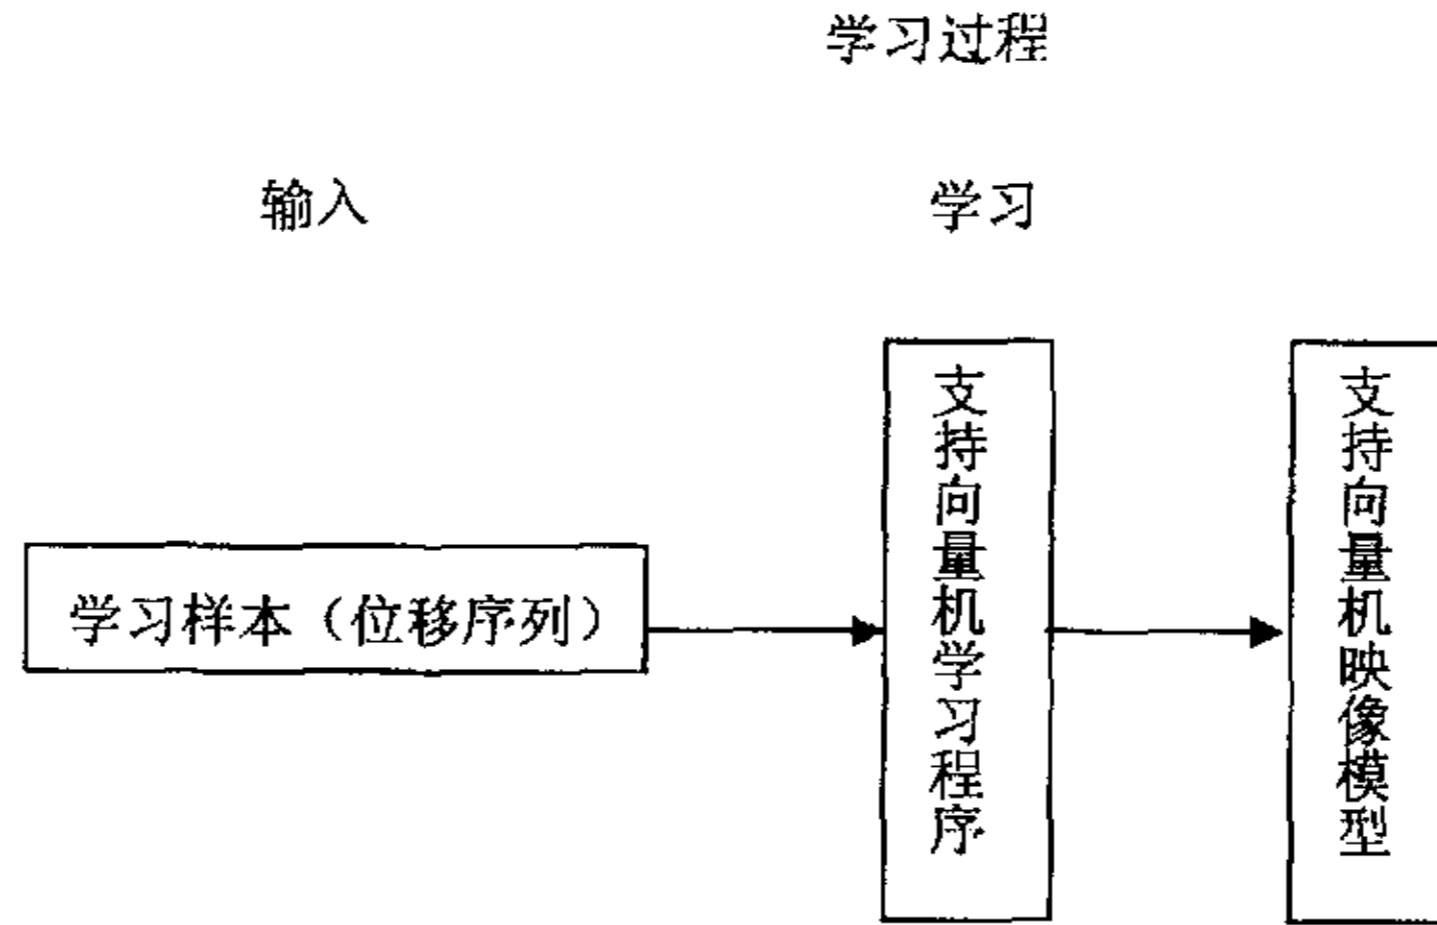


图 3.4 单因素序列向量机学习过程图
Figure 3.4 one factor series SVM studying process

$$x_{i+p} = f(x_i, x_{i+1}, \dots, x_{i+p-1}) \quad (i = 1, 2, \dots, n) \quad (3.10)$$

其中 x_{i+p} 为待预测数据， x_i 为输入的位移数据， f 为支持向量机表达式




图 3.5 单因素序列向量机预测过程图
Figure 3.5 one factor series SVM predicting process

3.5.6 多因素滑坡位移时间序列的预测

3.5.6.1 水对滑坡的影响

滑坡产生的根本原因取决于组成斜坡的土石体性质和结构，但外界条件因素

如图 4.3 所示。所得到的支持向量机映像模型，由公式(3.10)中 $f(x_i, x_{i+1}, \dots, x_{i+p-1})$ 表达出来，其中 x_i 代表一个位移序列， x_{i+p} 代表要预测的位移序列。根据图 4.4 输入预测样本，应用所得到的支持向量机模型进行预测，的到所需要的位移结果。




图 3.4 单因素序列向量机学习过程图
Figure 3.4 one factor series SVM studying process

$$x_{i+p} = f(x_i, x_{i+1}, \dots, x_{i+p-1}) \quad (i = 1, 2, \dots, n) \quad (3.10)$$

其中式中 x_{i+p} 为待预测数据， x_i 为输入的位移数据， f 为支持向量机表达式

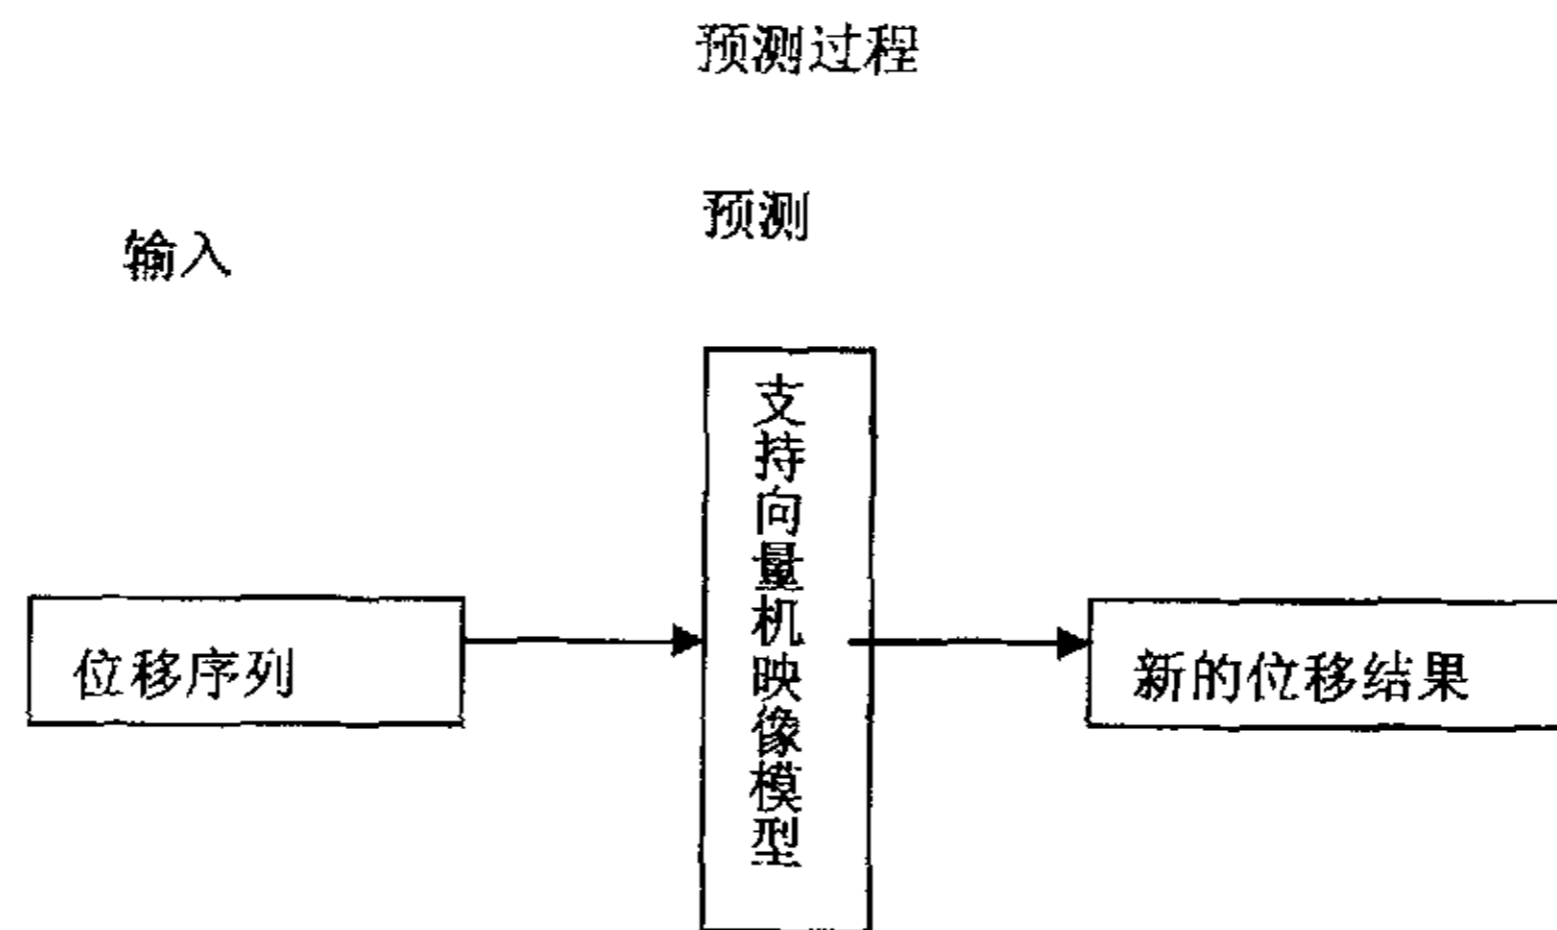


图 3.5 单因素序序列向量机预测过程图
Figure 3.5 one factor series SVM predicting process

3.5.6 多因素滑坡位移时间序列的预测

3.5.6.1 水对滑坡的影响

滑坡产生的根本原因取决于组成斜坡的土石体性质和结构，但外界条件因素

如水的作用、地震、人为因素等的作用不能忽视，它们是滑坡产生的诱发因素，它们的作用可改变斜坡土石体的性质、强度、结构和状态，有时还可改变斜面坡的外形，其结果是引起斜坡的变形和破坏。

(1) 滑坡的产生和发育形成过程通常分为三个阶段：蠕变变形阶段、滑动破坏阶段和渐趋稳定阶段。

1) 蠕变变形阶段 斜坡在发生滑动之前通常是稳定的，在水的作用下，可以使斜坡土石体强度逐渐降低，滑坡出口附近渗水混浊，水在此过程中起到了催化剂的作用。

2) 滑动破坏阶段 滑坡在整体往下滑动的时候，滑坡滑动过程中滑动面附近湿度增大，加之重复剪切，土石体结构进一步降低，促使滑坡加速滑动，水在此过程中起了润滑剂的作用。

3) 渐趋稳定阶段 滑坡停止后，形成特殊的滑坡地形，在岩性、构造和水文地质条件等方面都相继发生了变化，地层的整体性已被破坏，岩石变得松散破碎，透水性增强，含水量增高。滑坡前缘无水渗出或流出清晰的泉水时，表明滑坡已基本趋于稳定。

(2) 不同水的作用

从地层岩性分析，碎石类土不易产生滑坡，粘性土在受水作用后易产生滑坡，基岩中页岩、泥岩、千枚岩、泥灰岩、云母片岩易风化及遇水软化，易产生滑坡。不同性质的土石体对水的作用的反应也是不一样的，如岩浆岩、沉积岩中的砾岩和砂岩，以及变质岩中花岗片麻岩、石英岩等，几乎与水不起作用，是抗水的物质，它们在水的作用下抗剪强度不发生很大的变化，因而由这些岩石组成的斜坡稳定性与水的关系并不密切。而各种页岩、泥岩和地表覆盖层都是亲水的，由亲水性物质组成的斜坡在雨季或侵水后塑性增大，抗剪强度显著降低，极易产生滑坡。各种松散无联结的砂性土层容易被潜蚀，在地下动水压力的作用下，结构和强度不断变化，斜坡的稳定性逐渐降低。滑坡的产生与水的作用有密切关系，水的作用包括降雨、地表水和地下水等三个方面的作用。

1) 降雨的影响

实践证明，滑坡多集中在降雨量多的年份发生，而且很多滑坡是在雨季发生的，不少滑坡具有“大雨大滑，小雨小滑，无雨不滑”的特点，因为降雨尤其是长期的绵绵细雨使斜坡土石逐渐饱和，甚至在隔水层上形成暂时的含水层，这样一方面增大了斜坡土石体的容重和降低了土石体的内聚力，另一方面还产生了动水压力和静水压力，使斜坡的稳定性急剧降低而产生滑坡。

2) 地表水的影响

地表水下渗增加了斜坡土体的含水量，使土达到塑性状态，降低了土体的稳定

性。当水渗入隔水层时使层面间摩擦力和内聚力降低；造成斜面坡失稳而下滑。地表水系中水流不断冲刷和切割岸坡，使岸坡增高变陡，有时水流的冲蚀淘空岸坡的完整岩层，暴露出斜坡内部的软弱面，河水水位的上升下降引起与地下水补给关系的变化，在斜坡内形成很大的动水压力，所有这些作用都造成斜坡稳定性降低，有利于滑坡的产生。

3) 地下水的影响

地下水浸湿斜坡，使土石体的容重增加，浸湿范围加大，浸湿程度加剧，就显着地降低了土石体的抗剪强度，地下水位的升降，还会产生很大的动水压力与静水压力，地下水还能溶解土石体中易溶物质，使组成斜坡的土石体成份和结构发生变化，导致滑坡的产生。

3.5.6.2 多因素序列的预测步骤

根据福建八尺门的地质资料和滑动监测所得位移数据，深入分析，利用测斜孔的位移数据、降雨量数据和地下水位，建立两个因素的时间序列。

$$x_{i+p} = f(x_{i+1}, x_{i+2}, \dots, x_{i+p-1}, y_{i+1}, y_{i+2}, \dots, y_{i+p-1}, z) \quad (i = 1, 2, \dots, n) \quad (3.11)$$

x_i 为位移数据， y_i 为降雨量， z 地下水位序列。

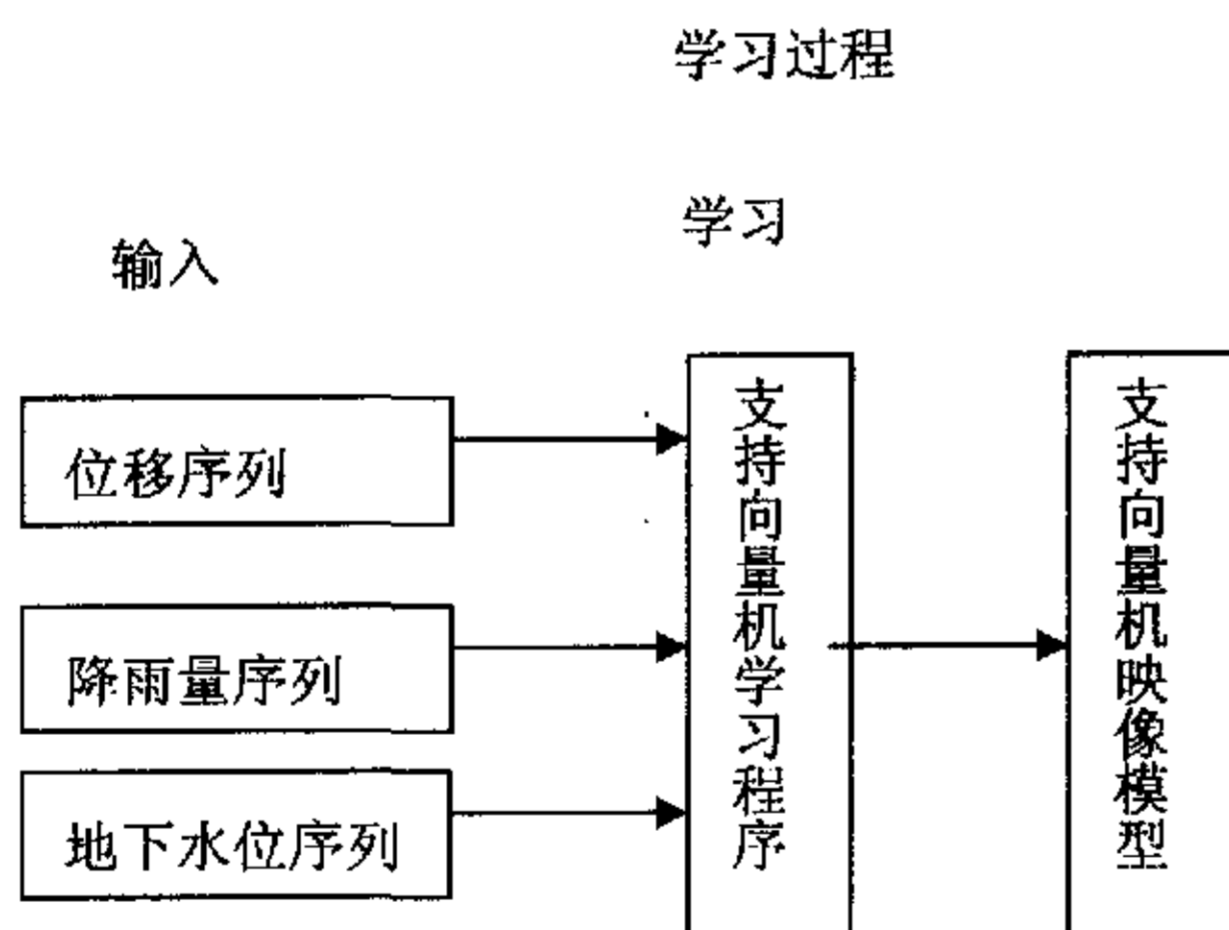


图 3.6 多因素序列学习过程图

Figure 3.6 many factors series studying process

根据监测点的位移数据、降雨量数据和地下水位数据，构成位移序列、降雨量序列和地下水位序列，然后应用遗传算法构成学习样本，根据图进行进化支持向量机的学习，得到支持向量机映像模型。

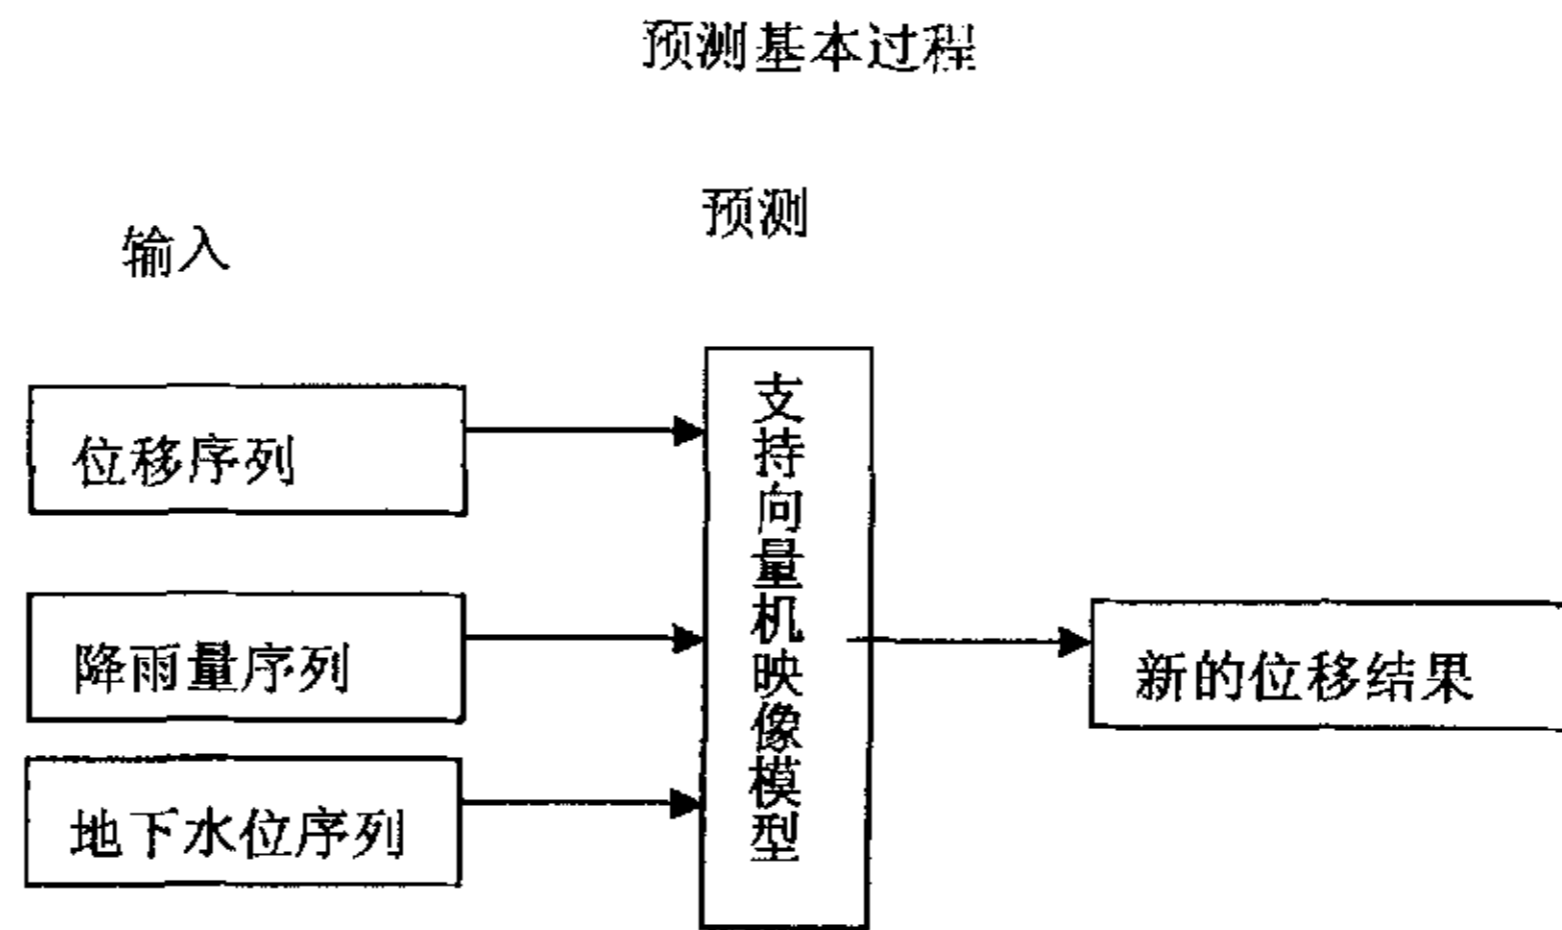


图 3.7 多因素序列预测过程图

Figure 3.7 many factors series predicting process

第四章 工程实例

4.1 八尺门工程背景

八尺门互通区滑坡位于福建省福鼎市白岩村马坪及古井头一带, 根据现场调查及当地居民反映, 沙吕线一带滑坡起始于一九九三年, 以后多年均有不同程度的滑移, 因该处地表植被发育, 且坡度较缓, 故未造成较大的破坏。随着福宁高速公路建设进程的加快, 本滑坡的危害性日益明显^[39]。在 2000 年六月份, 由于连续的暴雨, 导致沙吕线与改线 BCK0+400~450 之间的山体边坡出现滑移、开裂等现象, 最大裂隙度达 1.6m, 导致现使用的沙吕线路面下降约 1.5m。随着主线拉槽施工的进展, 在右侧古井头山坡方向也出现了裂隙^[40]。

八尺门滑坡所在的八尺门互通区地处丘陵、滨海滩涂地貌。滑坡所在地貌为丘陵坡积裙地貌单元。地形起伏较大, 高低处高差约 60m。滑坡区位于福鼎白垩世火山喷发盆地东南沿, 福鼎-霞浦断裂带东侧。地层主要分布为坡积成因碎石土, 残积成因的残积土, 下伏为石帽山群下组下段英安质晶质屑凝灰岩, 局部为凝灰岩。

古滑坡区占地面积约 6000m², 区内“孤石”发育, 地下水丰富, 泉点发育。古滑坡下游已出现复活现象, 并且对福宁高速公路建设已起到制约性影响。在主线 K23+976 上方的古井头一带, 村民的房屋已出项开裂, 地面也出现裂缝。蓄水池因地表的开裂而产生漏水以至无法使用。这些极可能是古滑坡复活的前兆。在主线及沙吕线改线之间已复活的滑坡体上, 地表开裂, 最大裂缝达 1.6m 宽, 旧沙吕线路面下沉约 1.5m, 土质松散, 坡角泉点发育, 有向上游发展的趋势。

滑坡内水文地质条件复杂, 地表水体不发育, 地下水丰富。地下水层主要有两层, 第一层为亚粘土(1)内含水, 该层孔隙较大, 连通性好, 经本次钻探在 ZK22、ZK26、ZK35 提桶抽水试验, 其涌水量分别为 24T/d、5.2T/d、1.3T/d, 地下水类型为第四纪孔隙型潜水, 其补给来源于大气降水。径流方向收地表控制。排泄以地表蒸发为主。第二层为亚粘土(残积土)(2)及其以下土层内含水, 为弱承压型潜水, 其补给来源于大气降雨的垂直渗透。径流方向受地形控制, 排泄以泉点的形式排泄。滑坡区泉点流量对在 0.01.2.2L/s 之间。

滑坡区内古滑坡及新滑坡形态程轮椅状, 在钻孔过程中, 古滑坡面处土质松软, 并见有擦痕, 擦痕大致走向为北东 60°, 倾角 19°, 主轴面为 III. III 剖面。新滑动面上土质较杂, 而且松软, 含水量较大, 大约在 45% 左右, 钻进进尺较快, 其主轴面为 II. II 剖面。

第四章 工程实例

4.1 八尺门工程背景

八尺门互通区滑坡位于福建省福鼎市白岩村马坪及古井头一带, 根据现场调查及当地居民反映, 沙吕线一带滑坡起始于一九九三年, 以后多年均有不同程度的滑移, 因该处地表植被发育, 且坡度较缓, 故未造成较大的破坏。随着福宁高速公路建设进程的加快, 本滑坡的危害性日益明显^[39]。在 2000 年六月份, 由于连续的暴雨, 导致沙吕线与改线 BCK0+400~450 之间的山体边坡出现滑移、开裂等现象, 最大裂隙度达 1.6m, 导致现使用的沙吕线路面下降约 1.5m。随着主线拉槽施工的进展, 在右侧古井头山坡方向也出现了裂隙^[40]。

八尺门滑坡所在的八尺门互通区地处丘陵、滨海滩涂地貌。滑坡所在地貌为丘陵坡积裙地貌单元。地形起伏较大, 高低处高差约 60m。滑坡区位于福鼎白垩世火山喷发盆地东南沿, 福鼎-霞浦断裂带东侧。地层主要分布为坡积成因碎石土, 残积成因的残积土, 下伏为石帽山群下组下段英安质晶质屑凝灰岩, 局部为凝灰岩。

古滑坡区占地面积约 6000m², 区内“孤石”发育, 地下水丰富, 泉点发育。古滑坡下游已出现复活现象, 并且对福宁高速公路建设已起到制约性影响。在主线 K23+976 上方的古井头一带, 村民的房屋已出项开裂, 地面也出现裂缝。蓄水池因地表的开裂而产生漏水以至无法使用。这些极可能是古滑坡复活的前兆。在主线及沙吕线改线之间已复活的滑坡体上, 地表开裂, 最大裂缝达 1.6m 宽, 旧沙吕线路面下沉约 1.5m, 土质松散, 坡角泉点发育, 有向上游发展的趋势。

滑坡内水文地质条件复杂, 地表水体不发育, 地下水丰富。地下水层主要有两层, 第一层为亚粘土(1)内含水, 该层孔隙较大, 连通性好, 经本次钻探在 ZK22、ZK26、ZK35 提桶抽水试验, 其涌水量分别为 24T/d、5.2T/d、1.3T/d, 地下水类型为第四纪孔隙型潜水, 其补给来源于大气降水。径流方向收地表控制。排泄以地表蒸发为主。第二层为亚粘土(残积土)(2)及其以下土层内含水, 为弱承压型潜水, 其补给来源于大气降雨的垂直渗透。径流方向受地形控制, 排泄以泉点的形式排泄。滑坡区泉点流量对在 0.01.2.2L/s 之间。

滑坡区内古滑坡及新滑坡形态程轮椅状, 在钻孔过程中, 古滑坡面处土质松软, 并见有擦痕, 擦痕大致走向为北东 60°, 倾角 19°, 主轴面为 III. III 剖面。新滑动面上土质较杂, 而且松软, 含水量较大, 大约在 45% 左右, 钻进进尺较快, 其主轴面为 II. II 剖面。

八尺门互通区已复活的局部古滑坡主要表现在主线及新沙吕线之间,其最早复活始于一九九三年,本次发生较大的滑移,主要原因有两个,一是地下水影响,区内地下水是导致本古滑坡舌复活主要原因,在2000年6月份,恰逢雨季,降雨使地下水位升高,以致滑动面上的土体孔隙水压力增大,土体的强度降低,抗滑阻力降低;又因地下水位的抬升,增强了土体内的管涌作用,也使滑体的重度增大,增加了下滑力;二是人为因素的影响,在古滑坡下游有沙吕线改线线路通过,工程建设使古滑舌的天然边坡得以破坏,从而破坏了斜坡的天然应力平衡,致使出现新的滑移。

4.2 广西龙滩工程背景

龙滩水电站坝址位于广西壮族自治区天峨县境内,下游距县城约15km。坝址以上流域面积98500km²,坝址处多年平均流量1610m³/s,多年平均径流量508亿m³。龙滩水电站按正常蓄水位400m设计,初期建设正常蓄水位375m,最大坝高192m,装机容量7×600MW,水库总库容162.1亿m³;后期正常蓄水位400m,最大坝高216.5m,装机容量9×600MW,水库总库容272.7亿m³。枢纽主要建筑物包括:碾压混凝土重力坝及其泄水建筑物、左岸地下厂房及其输水系统、右岸通航建筑物。施工导流采用上、下游碾压混凝土过水围堰,左、右岸隧洞导流。

坝址河谷为较宽坦的“V”型谷,宽高比3.5左右。河流流向S30°E,至坝址处转向S80°E。枯水期河水面高程219m,水面宽90~100m,水深13~19.5m。河床砂、卵砾石层厚0~6m,局部17m(Z₁₂₈孔),基岩面高程一般为200m左右,最低点191m,河床两侧均有基岩礁滩裸露,左岸宽10m,右岸宽40~70m。

左岸地形整齐,山体宽厚,右岸受冲沟切割,地形完整程度稍逊左岸。两岸山顶高程600m左右,岸坡坡度32°~42°,残坡积层厚0.5~2m,局部厚8~25m。

坝址地层为三叠系下统罗楼组(出露于坝址上游地段)和三叠系中统板纳组(出露于坝址及其下游地段),均为轻微变质的浅海深水相碎屑岩组。罗楼组以薄层、中厚层硅质泥板岩、硅质泥质灰岩为主,夹少量粉砂岩互层岩组;板纳组由厚层钙质砂岩、粉砂岩、泥板岩互层夹少量层凝灰岩、硅质泥质灰岩组成,均属坚硬或中硬岩石,板纳组是坝址主要建筑物基(围)岩。各组岩性组合见表2.1和2.2。板纳组在坝址出露T_{2b}¹至T_{2b}⁵²层,总厚度1219.07m,由厚层钙质砂岩、粉砂岩、泥板岩互层夹少量层凝灰岩、硅泥质灰岩组成,其中砂岩、粉砂岩占68.2%,泥板岩占30.8%,灰岩占1%。T_{2b}^{2~4}、T_{2b}¹⁸、T_{2b}⁵²层泥板岩厚度大,含量高,占70%以上,是板纳组中强度相对较低的岩层。

八尺门互通区已复活的局部古滑坡主要表现在主线及新沙吕线之间,其最早复活始于一九九三年,本次发生较大的滑移,主要原因有两个,一是地下水影响,区内地下水是导致本古滑坡舌复活主要原因,在2000年6月份,恰逢雨季,降雨使地下水位升高,以致滑动面上的土体孔隙水压力增大,土体的强度降低,抗滑阻力降低;又因地下水位的抬升,增强了土体内的管涌作用,也使滑体的重度增大,增加了下滑力;二是人为因素的影响,在古滑坡下游有沙吕线改线线路通过,工程建设使古滑舌的天然边坡得以破坏,从而破坏了斜坡的天然应力平衡,致使出现新的滑移。

4.2 广西龙滩工程背景

龙滩水电站坝址位于广西壮族自治区天峨县境内,下游距县城约15km。坝址以上流域面积98500km²,坝址处多年平均流量1610m³/s,多年平均径流量508亿m³。龙滩水电站按正常蓄水位400m设计,初期建设正常蓄水位375m,最大坝高192m,装机容量7×600MW,水库总库容162.1亿m³;后期正常蓄水位400m,最大坝高216.5m,装机容量9×600MW,水库总库容272.7亿m³。枢纽主要建筑物包括:碾压混凝土重力坝及其泄水建筑物、左岸地下厂房及其输水系统、右岸通航建筑物。施工导流采用上、下游碾压混凝土过水围堰,左、右岸隧洞导流。

坝址河谷为较宽坦的“V”型谷,宽高比3.5左右。河流流向S30°E,至坝址处转向S80°E。枯水期河水面高程219m,水面宽90~100m,水深13~19.5m。河床砂、卵砾石层厚0~6m,局部17m(Z₁₂₈孔),基岩面高程一般为200m左右,最低点191m,河床两侧均有基岩礁滩裸露,左岸宽10m,右岸宽40~70m。

左岸地形整齐,山体宽厚,右岸受冲沟切割,地形完整程度稍逊左岸。两岸山顶高程600m左右,岸坡坡度32°~42°,残坡积层厚0.5~2m,局部厚8~25m。

坝址地层为三叠系下统罗楼组(出露于坝址上游地段)和三叠系中统板纳组(出露于坝址及其下游地段),均为轻微变质的浅海深水相碎屑岩组。罗楼组以薄层、中厚层硅质泥板岩、硅质泥质灰岩为主,夹少量粉砂岩互层岩组;板纳组由厚层钙质砂岩、粉砂岩、泥板岩互层夹少量层凝灰岩、硅质泥质灰岩组成,均属坚硬或中硬岩石,板纳组是坝址主要建筑物基(围)岩。各组岩性组合见表2.1和2.2。板纳组在坝址出露T_{2b}¹至T_{2b}⁵²层,总厚度1219.07m,由厚层钙质砂岩、粉砂岩、泥板岩互层夹少量层凝灰岩、硅泥质灰岩组成,其中砂岩、粉砂岩占68.2%,泥板岩占30.8%,灰岩占1%。T_{2b}^{2~4}、T_{2b}¹⁸、T_{2b}⁵²层泥板岩厚度大,含量高,占70%以上,是板纳组中强度相对较低的岩层。

坝址位于近 SN 向八奈背斜东翼和龙滩向斜西翼。岩层为单斜构造, 走向 $N5^{\circ} \sim 20^{\circ} W$, 与河流流向夹角约 70° , 倾向 NE(下游偏左岸), 倾角 $55^{\circ} \sim 63^{\circ}$ 。坝址下游, F75 断层以下地段岩层倾角逐步变缓至 40° 左右。

坝区共揭露断层 500 余条, 规模较大者 50 余条, 多分布在两岸, 河床无大顺河断层, 缓倾角断层不发育。多数断裂特别是主要断裂都经历再次活动, 由断层泥、断层泥夹岩屑、角砾岩和压碎岩组成的断层破碎带未胶结, 同一断层的力学属性前后期也有转化。

坝址岩体风化受岩性、构造破坏程度及地形影响, 表现为面状风化层状风化和沿断层、夹层的楔状(带状)风化, 厚层砂岩尚见球状风化。

坝址岩体面状风化深度见。一般情况下, 罗楼组抗风化能力稍次于板纳组; 泥板岩为主的岩层较砂岩为主的岩层风化强烈; 右岸构造破碎程度较左岸强, 故风化深度略大于左岸, 谷肩部位风化深度亦大于谷坡部位沿主要断层、层间错动及其交汇带呈楔状风化, 如 D_{54} 平洞内, F_{89} 断层带在地表以下 35m, 楔状强风化带的宽度仍达 12~15m。

在强、弱风化带内, 岩体卸荷松弛, 节理张开, 连通性好, 次生夹泥裂隙较发育。微风化或新鲜基岩内节理面多闭合干净, 结合紧密, 或为方解石、石英脉充填, 夹泥裂隙罕见。

罗楼组中的泥质灰岩夹层, 受风化淋滤作用, 在强、弱风化带内常形成众多的风化泥化夹层, 泥化夹层的水平发育深度一般达 35~40m。

坝址岩层主要为砂岩、泥板岩互层, 构成不均匀的裂隙含水层, 受断层切割, 各层间有密切的水力联系。地下水受大气降水补给, 一般呈无压状态, 向红水河顺层排泄为主。地下水位埋深因地而异, 枯水期岸坡地带低于地表 20~60m, 近山顶一带埋深 80~100m, 洪、枯期地下水位变幅 10~20m, 最大可达 50m 各钻孔地下水位观测成果见表 5.1, 两岸地下水位均高于设计蓄水位, 坡降 0.5~0.6。

断层是岩体中渗漏的主要通道, 由于坝址断层多呈压扭性, 破碎带透水性较弱, 两侧影响带内节理发育, 透水性较强, 地下水活动强烈。如 D_{23} 平洞揭露的 F_{60} 断层带, 集中渗流量达 42L/min, 过河平洞内小断层带渗流总量达 120L/min, 坝址其它断层亦有不同程度的渗水现象。

罗楼组和板纳组 T_{26}^{2-4} 、 T_{26}^{30} 层等灰岩夹层集中的层位内, 在微风化带以上, 地下水位附近常有顺层发育的小型溶蚀洞穴, 其渗透性较强, 钻孔压水试验时, 水平渗流距离可达 100m 以上。

岩体的透水性 with 岩体风化完整程度、岩体的埋藏深度等因素密切相关、表岩

体透水性随岩体埋藏深度增加明显降低,地表以下岩石,60m以上岩体透水性较强,100m以下透水性微弱,相对不透水层($\omega \leq 0.01\text{L}/\text{min} \cdot \text{m} \cdot \text{m}$,相当于1Lu)顶板埋深宜控制在地表以下100m左右,但在主要断层及其交汇带,局部可以达到130~180m。

断层破碎带中的充填物矿物成分以石英、伊利石和高岭土为主,但主要的切层断层中含15%~28%的钙基蒙脱石,是岩体深部断层仍然夹泥的主要原因之一。化学成分以稳定性好的 SiO_2 为主, SO_3 等有害成分含量极微。充填物均一性差(不均匀系数15.7~1375),以岩屑为主,粉、粘粒含量一般为3%~25%,但随风化强度增大而明显增加,且密实性降低。断层泥的总比表面积 $91 \sim 144\text{m}^2/\text{g}$,亲水性差或较差,属非分散性土。现场管涌比降试验表明,在高压渗流作用下,软弱结构面内充填的细微颗粒,有被冲刷淘出或节理面被扩开张裂的可能性,断层泥与夹泥节理水力临界比降1.7~3.4,具黄褐色锈膜的闭合节理,当水力比降达5~6时,产生明显水力联系,断层带附近的充填方解石、石英脉的节理,当水力比降达15~16时,节理面呈现弹性扩张特征。

坝区河水、溪沟水和地下水均属重碳酸钙型水。总离子含量 $167 \sim 566\text{mg}/\text{L}$,暂时硬度 $6.8 \sim 16.3$ 德度,PH值 $7.1 \sim 8.3$,游离 CO_2 $2.42 \sim 33.88\text{mg}/\text{L}$,镁盐和硫酸盐含量极少,对混凝土无侵蚀性。坝区岩体中的灰岩夹层和钙质砂岩、泥板岩中的碳酸钙,随地下水活动,沿断层带、层间错动和节理面析出,勘探平洞中常见形成钙化沉淀,设计应考虑其对坝基围岩排水孔长期运行的不利影响。

4.3 工程实例

4.3.1 福建八尺门2号滑坡 pm47 监测点实例

根据福建八尺门2号滑坡 PM47 监测点监测数据如下表所示,选取2001年8月到2002年11月的监测点位移作为学习样本,后面的作为预测样本的核对值。按照第三章图3.4所示的学习流程,进行学习得到:惩罚因子 $C=290.625$,核函数选择高斯核函数核函数因子 $\sigma=341$,支持向量的 α 、 α' 如表4.2所示,建立支持向量机模型。然后建立支持向量机映射模型,按照第三章的图3.5所示的预测流程,进行预测,得到预测结果和监测值进行比较,取得比较满意的结果,如表4.3所示,绘制成直观曲线图如4.1所示。

体透水性随岩体埋藏深度增加明显降低,地表以下岩石,60m 以上岩体透水性较强,100m 以下透水性微弱,相对不透水层 ($\omega \leq 0.01\text{L}/\text{min} \cdot \text{m} \cdot \text{m}$, 相当于 1Lu) 顶板埋深宜控制在地表以下 100m 左右,但在主要断层及其交汇带,局部可以达到 130~180m。

断层破碎带中的充填物矿物成分以石英、伊利石和高岭土为主,但主要的切层断层中含 15%~28%的钙基蒙脱石,是岩体深部断层仍然夹泥的主要原因之一。化学成分以稳定性好的 SiO_2 为主, SO_3 等有害成分含量极微。充填物均一性差(不均匀系数 15.7~1375),以岩屑为主,粉、粘粒含量一般为 3%~25%,但随风化强度增大而明显增加,且密实性降低。断层泥的总比表面积 $91 \sim 144\text{m}^2/\text{g}$,亲水性差或较差,属非分散性土。现场管涌比降试验表明,在高压渗流作用下,软弱结构面内充填的细微颗粒,有被冲刷淘出或节理面被扩开张裂的可能性,断层泥与夹泥节理水力临界比降 1.7~3.4,具黄褐色锈膜的闭合节理,当水力比降达 5~6 时,产生明显水力联系,断层带附近的充填方解石、石英脉的节理,当水力比降达 15~16 时,节理面呈现弹性扩张特征。

坝区河水、溪沟水和地下水均属重碳酸钙型水。总离子含量 $167 \sim 566\text{mg}/\text{L}$,暂时硬度 6.8~16.3 德度,PH 值 7.1~8.3,游离 CO_2 $2.42 \sim 33.88\text{mg}/\text{L}$,镁盐和硫酸盐含量极少,对混凝土无侵蚀性。坝区岩体中的灰岩夹层和钙质砂岩、泥板岩中的碳酸钙,随地下水活动,沿断层带、层间错动和节理面析出,勘探平洞中常见形成钙化沉淀,设计应考虑其对坝基围岩排水孔长期运行的不利影响。

4.3 工程实例

4.3.1 福建八尺门 2 号滑坡 pm47 监测点实例

根据福建八尺门 2 号滑坡 PM47 监测点监测数据如下表所示,选取 2001 年 8 月到 2002 年 11 月的监测点位移作为学习样本,后面的作为预测样本的核对值。按照第三章图 3.4 所示的学习流程,进行学习得到: 惩罚因子 $C=290.625$,核函数选择高斯核函数 核函数因子 $\sigma=341$,支持向量的 α 、 α' 如表 4.2 所示,建立支持向量机模型。然后建立支持向量机映射模型,按照第三章的图 3.5 所示的预测流程,进行预测,得到预测结果和监测值进行比较,取得比较满意的结果,如表 4.3 所示,绘制成直观曲线图如 4.1 所示。

体透水性随岩体埋藏深度增加明显降低,地表以下岩石,60m 以上岩体透水性较强,100m 以下透水性微弱,相对不透水层 ($\omega \leq 0.01\text{L}/\text{min} \cdot \text{m} \cdot \text{m}$, 相当于 1Lu) 顶板埋深宜控制在地表以下 100m 左右,但在主要断层及其交汇带,局部可以达到 130~180m。

断层破碎带中的充填物矿物成分以石英、伊利石和高岭土为主,但主要的切层断层中含 15%~28%的钙基蒙脱石,是岩体深部断层仍然夹泥的主要原因之一。化学成分以稳定性好的 SiO_2 为主, SO_3 等有害成分含量极微。充填物均一性差(不均匀系数 15.7~1375),以岩屑为主,粉、粘粒含量一般为 3%~25%,但随风化强度增大而明显增加,且密实性降低。断层泥的总比表面积 $91 \sim 144\text{m}^2/\text{g}$,亲水性差或较差,属非分散性土。现场管涌比降试验表明,在高压渗流作用下,软弱结构面内充填的细微颗粒,有被冲刷淘出或节理面被扩开张裂的可能性,断层泥与夹泥节理水力临界比降 1.7~3.4,具黄褐色锈膜的闭合节理,当水力比降达 5~6 时,产生明显水力联系,断层带附近的充填方解石、石英脉的节理,当水力比降达 15~16 时,节理面呈现弹性扩张特征。

坝区河水、溪沟水和地下水均属重碳酸钙型水。总离子含量 $167 \sim 566\text{mg}/\text{L}$,暂时硬度 6.8~16.3 德度,PH 值 7.1~8.3,游离 CO_2 $2.42 \sim 33.88\text{mg}/\text{L}$,镁盐和硫酸盐含量极少,对混凝土无侵蚀性。坝区岩体中的灰岩夹层和钙质砂岩、泥板岩中的碳酸钙,随地下水活动,沿断层带、层间错动和节理面析出,勘探平洞中常见形成钙化沉淀,设计应考虑其对坝基围岩排水孔长期运行的不利影响。

4.3 工程实例

4.3.1 福建八尺门 2 号滑坡 pm47 监测点实例

根据福建八尺门 2 号滑坡 PM47 监测点监测数据如下表所示,选取 2001 年 8 月到 2002 年 11 月的监测点位移作为学习样本,后面的作为预测样本的核对值。按照第三章图 3.4 所示的学习流程,进行学习得到: 惩罚因子 $C=290.625$,核函数选择高斯核函数 核函数因子 $\sigma=341$,支持向量的 α 、 α' 如表 4.2 所示,建立支持向量机模型。然后建立支持向量机映射模型,按照第三章的图 3.5 所示的预测流程,进行预测,得到预测结果和监测值进行比较,取得比较满意的结果,如表 4.3 所示,绘制成直观曲线图如 4.1 所示。

表 4.1 八尺门 2# 滑坡 pm47 监测点

Table 4.1 The pm47 monitoring data of Bachimen No.2 slideslope

年	2001 年						2002 年						
月日	8.30	9.30	10.30	11.30	12.30	1.30	2.29	3.30	4.30	5.30	6.30	7.30	8.30
位移/mm	9.3	18	25	36.6	39.7	33.9	36.9	39.4	35.2	70	76.5	76.8	88.6

年	2002 年					2003 年				
月日	9.30	10.30	11.30	12.30	1.30	2.28	3.30	4.30	5.30	6.30
位移/mm	89	87.9	90.8	92.3	92.3	88.7	88.7	91.1	91.1	92.1

表 4.2 pm47 点模型的支持向量相应的 α 、 α^* 值

Table 4.2 The support vectors and α 、 α^* 值 of the pm47 motoring point

序号	α	α^*
1	0	821.75
2	0	753.50
3	0	236.50
4	531.25	0
5	0	531.25
6	236.75	0
7	0	236.7
8	193.25	0
9	0	193.25
10	25.75	0
11	0	025.75

表 4.3 监测值与预测值的对比

Table 4.3 The comparison of measured and predicted displacements

时间	监测值	预测值	绝对误差	相对误差(百分)
02.12.30	92.3	90.88	1.42	1.53
03.1.30	92.3	91.42	0.88	0.95
03.2.28	88.7	91.42	2.72	3.06
03.3.30	88.7	90.13	1.43	1.61
03.4.30	91.1	90.13	0.97	1.06
03.5.30	91.1	90.99	0.11	0.12
03.6.30	92.1	90.95	1.15	1.25




图 4.1 位移预测值和观测值的关系曲线

Figure 4.1 The comparison of measured and predicted displacements

4.3.2 龙滩 620.01 监测点实例

根据广西龙滩 620.01 监测点监测数据如下表所示，选取 2002 年 1 月到 2003 年 6 月的监测点位移作为学习样本，后面的作为预测样本的核对值。按照第三章图 3.4 所示的学习流程，进行学习得到：惩罚因子 $C=456.1250$ ，核函数选择多项式核函数，核函数因子 $d=52$ ，支持向量的 α 、 α^* 如表 4.5 所示，建立支持向量机模型。然后建立支持向量机映射模型，按照第三章的图 3.5 所示的预测流程，进行预测，得到预测结果和监测值进行比较，取得比较满意的结果，如表 4.6 所示，绘制成直观曲线图如 4.2 所示。

表 4.4 龙滩 620.01 监测点数据

Table 4.4 The 620.01 monitoring point data of Longtan

年	2002 年											
月日	1.19	2.1	3.13	4.13	5.20	6.15	7.13	8.13	9.13	10.13	11.19	12.14
位移/mm	0	10.37	10.36	23.92	27.99	34.30	41.08	56.01	62.64	69.87	68.69	71.96
年	2003 年											
月日	1.11	2.28	4.3	5.9	6.5	7.6	8.10	9.14	10.13	11.12	12.5	
位移/mm	73.43	73.48	67.93	69.12	69.82	73.26	72.92	72.63	72.39	76.35	79.34	




图 4.1 位移预测值和观测值的关系曲线

Figure 4.1 The comparison of measured and predicted displacements

4.3.2 龙滩 620.01 监测点实例

根据广西龙滩 620.01 监测点监测数据如下表所示，选取 2002 年 1 月到 2003 年 6 月的监测点位移作为学习样本，后面的作为预测样本的核对值。按照第三章图 3.4 所示的学习流程，进行学习得到：惩罚因子 $C=456.1250$ ，核函数选择多项式核函数，核函数因子 $d=52$ ，支持向量的 α 、 α^* 如表 4.5 所示，建立支持向量机模型。然后建立支持向量机映射模型，按照第三章的图 3.5 所示的预测流程，进行预测，得到预测结果和监测值进行比较，取得比较满意的结果，如表 4.6 所示，绘制成直观曲线图如 4.2 所示。

表 4.4 龙滩 620.01 监测点数据

Table 4.4 The 620.01 monitoring point data of Longtan

年	2002 年											
月日	1.19	2.1	3.13	4.13	5.20	6.15	7.13	8.13	9.13	10.13	11.19	12.14
位移/mm	0	10.37	10.36	23.92	27.99	34.30	41.08	56.01	62.64	69.87	68.69	71.96
年	2003 年											
月日	1.11	2.28	4.3	5.9	6.5	7.6	8.10	9.14	10.13	11.12	12.5	
位移/mm	73.43	73.48	67.93	69.12	69.82	73.26	72.92	72.63	72.39	76.35	79.34	

表 4.5 620.01 模型的支持向量相应的 α 、 α^* 值

Table 4.5 The support vectors and α 、 α^* 值 of the 620.01 motoring point

序号	α	α^*
1	0	116.8029
2	57.0092	0
3	34.8066	0
4	8.3237	0
5	3.1788	0
6	4.939	0
7	1.8692	0
8	6.6763	0

表 4.6 监测值与预测值的对比

Table4.6 The comparison of measured and predicted displacements

时间	监测值	预测值	绝对误差	相对误差(百分)
03.7.6	73.26	71.52	1.74	2.37
03.8.10	72.92	72.95	0.02	0.03
03.9.14	72.63	71.26	1.37	1.88
03.10.13	72.39	69.61	2.78	3.84
03.11.12	76.35	72.89	3.46	4.53
03.12.5	79.34	73.88	5.45	6.87

表 4.7 神经网络监测值与预测值的对比

Table4.7 The comparison of measured and predicted displacements by NN

时间	监测值	预测值	绝对误差	相对误差(百分)
03.7.6	73.26	70.63	2.63	3.59
03.8.10	72.92	73.94	1.02	1.40
03.9.14	72.63	69.36	3.27	4.50
03.10.13	72.39	68.24	4.15	5.73
03.11.12	76.35	71.57	4.78	6.26
03.12.5	79.34	71.46	7.88	9.93

表 4.7 为神经网络用同样的样本进行学习，预测同样的步数，所得到的预测值、监测值、绝对误差、相对误差。对比表 4.6 和表 4.7 可以看到，进化支持向量

表 4.9 630.02 模型的支持向量相应的 α 、 α^* 值

Table 4.9 The support vectors and α 、 α^* 值 of the 630.02 motoring point

序号	α	α^*
1	0	2.375
2	0	2.375
3	582.250	0
4	0	582.250
5	0	134.50
6	134.50	0
7	56.125	0
8	0	56.125
9	0	137.25

表 4.10 监测值与预测值的对比

Table4.10 The comparison of measured and predicted displacements

时间	监测值	预测值	绝对误差	相对误差(百分)
03.6.5	73.26	67.93	5.33	7.27
03.7.6	72.92	69.12	3.81	5.22
03.8.10	72.63	69.82	2.81	3.87
03.9.14	72.39	73.26	0.87	1.20
03.10.13	76.35	72.92	3.43	4.49
03.11.12	79.34	72.63	6.71	8.45
03.12.5	81.53	74.59	6.94	8.52

表 4.11 神经网络的监测值与预测值的对比

Table4.11 The comparison of measured and predicted displacements by NN

时间	监测值	预测值	绝对误差	相对误差(百分)
03.6.5	73.26	72.46	0.97	1.32
03.7.6	72.92	72.09	1.34	1.84
03.8.10	72.63	71.80	1.63	2.24
03.9.14	72.39	71.38	2.05	2.83
03.10.13	76.35	72.46	0.97	1.27
03.11.12	79.34	76.26	2.83	3.56
03.12.5	81.53	78.29	4.86	5.96

福建八尺门 2cx05 监测点, 龙潭边坡 62001 监测点 63002 监测点, 位移数据大致为一个月左右滑坡本身所产生的位移累积变化之和, 这可以说是一种比较中期滑坡定量预测。利用滑坡位移构成的时间序列, 遗传算法和支持向量机学习得到其非线性映射关系, 进行一段时间的滑坡位移预测。对于传统的时间序列学习

方法，不能准确得到位移之间的关系，无法建立合理的时间序列模型，进化支持向量机避免传统建立精确时间模型的弊端，应用类似神经网络，但是比神经网络更好的方法。

神经网络存在“过学习”的现象，本文在运用神经网络预测位移时，与支持向量机进行比较，也出现这种现象，这必然导致神经网络外推产生较大的误差。由于支持向量机有着坚实的理论基础，对于样本的学习，对于“过学习”现象，理论不会存在，还是有些样本不能进行学习，支持向量机并不能完全得到所有的模型。对于作者所研究的神经网络可以学习预测的样本，支持向量机可以取得更好的学习效果。表 4.11 为神经网络用同样的样本进行学习，预测同样的步数，所得到的预测值、监测值、绝对误差、相对误差。对比表 4.10 和表 4.11 可以看到，进化支持向量机预测精度比较高。




图 4.3 位移预测值和观测值的关系曲线

Figure 4.3 The comparison of measured and predicted displacements

通过以上三个工程实例的，可以得出以下几点：

(1) 采用进化支持向量机方法，可以避免人为选择支持向量机模型的盲目性，提高了支持向量机预测的精度和推广预测能力。

(2) 用进化支持向量机方法，可不断根据新的监测资料对位移进行滚动预测，这种预测具有实时性和较高的精度，为滑坡工程的设计和施工提供了很好的途径。

(3) 进化支持向量机作为一种新的变形演化规律的方法，由于它的优良特性，不仅适合于非线性位移时间序列预测，还适合于滑坡力学与工程中的很多方面，因此基于统计学习理论的支持向量机方法在滑坡工程中具有广泛的应用前景。

4.4 多因素滑坡位移时间序列的预测

4.4.1 非线性位移时间序列的支持向量机表达

根据福建八尺门的地质资料、气象资料、施工进度资料和滑动监测所得位移数据等，建立如下时间序列表达式

$$x_{i+p} = f(x_{i+1}, x_{i+2}, \dots, x_{i+p-1}, y_{i+1}, y_{i+2}, \dots, y_{i+p-1}, z, \dots) \quad (i = 1, 2, \dots, n) \quad (4.5)$$

其中 f 为支持向量机表达式， x_i 为位移数据， y_i 为降雨量， z 地下水水位序列。随着降雨量的增加，地下水水位同时升高，降雨量和地下水水位存在着一定的相关性，本文用如下的表达式来表示：

$$z = f(y) \quad (4.6)$$

其中 f 为支持向量机表达式， y 为降雨量， z 地下水水位序列，取不同的数据。

首先用支持向量机进行学习降雨量和地下水水位的关系，降雨量和地下水水位可以很容易得到，但是滑坡位移数据需要布置测斜孔利用一定的仪器才能得到，根据学习的结果来判断其相关性。根据支持向量的结果来判断，是否具有很好的关系。




图 4.4 线性可分情况下的最优分类线

Fig4.4 Linear separating hyperplanes for the separable case

当预测的数据比较好的分开，位于直线左下侧的数据大部分为黑色所代表的点代表的降雨量数据，位于直线右下侧大部分的数据为白色所代表的地下水水位，就表示降雨量数据和地下水水位数据有着比较的线性或者非线性关系，反之，就表示降雨量数据和地下水水位数据具有不可分性。

从表 4.10 和表 4.12 很明显可以看出，随着降雨量的突然增大，位移也是大幅度的增加，同样可以通过图 4.4 和图 4.5 直观的进行表示出来。从表 4.10 可以看到从 2001 年 7 月 29 日到 2001 年 8 月 12 日降雨量高达 250mm，另外根据气象局记

4.4 多因素滑坡位移时间序列的预测

4.4.1 非线性位移时间序列的支持向量机表达

根据福建八尺门的地质资料、气象资料、施工进度资料和滑动监测所得位移数据等，建立如下时间序列表达式

$$x_{i+p} = f(x_{i+1}, x_{i+2}, \dots, x_{i+p-1}, y_{i+1}, y_{i+2}, \dots, y_{i+p-1}, z, \dots) \quad (i = 1, 2, \dots, n) \quad (4.5)$$

其中 f 为支持向量机表达式， x_i 为位移数据， y_i 为降雨量， z 地下水水位序列。

随着降雨量的增加，地下水水位同时升高，降雨量和地下水水位存在着一定的相关性，本文用如下的表达式来表示：

$$z = f(y) \quad (4.6)$$

其中 f 为支持向量机表达式， y 为降雨量， z 地下水水位序列，取不同的数据。

首先用支持向量机进行学习降雨量和地下水水位的关系，降雨量和地下水水位可以很容易得到，但是滑坡位移数据需要布置测斜孔利用一定的仪器才能得到，根据学习的结果来判断其相关性。根据支持向量的结果来判断，是否具有很好的关系。




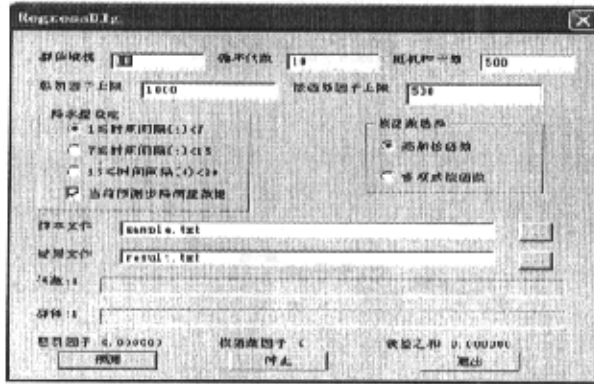
图 4.4 线性可分情况下的最优分类线

Fig4.4 Linear separating hyperplanes for the separable case

当预测的数据比较好的分开，位于直线左下侧的数据大部分为黑色所代表的点代表的降雨量数据，位于直线右下侧大部分的数据为白色所代表的地下水水位，就表示降雨量数据和地下水水位数据有着比较的线性或者非线性关系，反之，就表示降雨量数据和地下水水位数据具有不可分性。

从表 4.10 和表 4.12 很明显可以看出，随着降雨量的突然增大，位移也是大幅度的增加，同样可以通过图 4.4 和图 4.5 直观的进行表示出来。从表 4.10 可以看到从 2001 年 7 月 29 日到 2001 年 8 月 12 日降雨量和高达 250mm，另外根据气象局记

录资料 2001 年 7 月 31 日降雨量高达 98.9mm, 2001 年 8 月 6 日降雨量高达 72.4mm, 这样的高强度降雨引发滑坡位移大幅度增加。2001 年 8 月 5 日的滑坡位移和为 4.56mm, 2001 年 8 月 12 日滑坡位移和为 15.8mm, 2001 年 8 月 19 日滑坡位移和为 21.22mm, 而到 2001 年 9 月 2 日滑坡位移为 21.95mm, 从这个三位移值, 大致可以得出当发生大规模降雨时, 24 小时内降雨量超过 150 毫米, 或者 15 日降雨量超过 350 毫米, 滑动位移明显加剧, 同时降雨量引起滑坡位移的变化滞后降雨量的发生大概 7 天左右, 过后滑坡位移的变化比较缓慢, 这个粗糙的结论。同样可以从 2 号滑坡 6 号测斜孔可以发现这样的现象。我把这个结论应用支持向量机模型的预测中, 程序参数设置界面如图 4.5 所示, 可以看到关于降雨量的选择。当降雨量时间间隔选择不同的时候, 对应所构成的样本也是不同, 采用不同的处理函数去处理相应的数据。



4.5 参数选取图

Figure 4.5 chose the parameter

根据降雨量数据和地下水位数据的是否具有可分性, 确定表达式 4.5 中的 y 和 z 所构成的数据格式。如果具有可分性, 程序机算中把地下水位数据通过表达式 4.6 表示出来, 反之, 程序机算中直接输入地下水位序列, 进行支持向量机的学习。

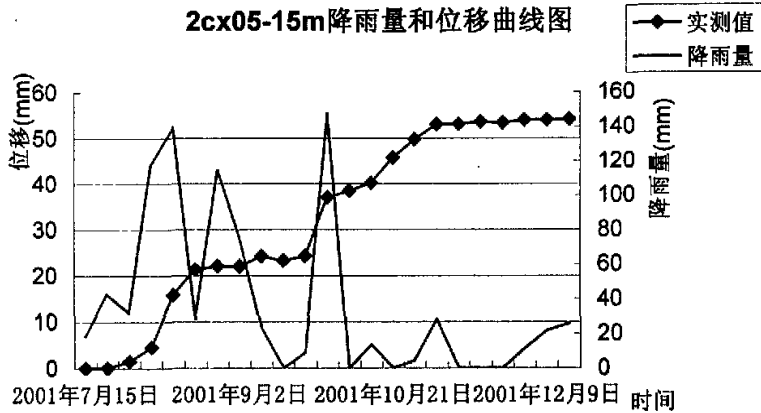


图 4.6 测点 2cx05.15 降雨量和位移图

Figure 4.6 The rainfall and displacement data of 2cx05.15 motoring point




图 4.7 测点 2cx06 降雨量和位移图

Figure 4.7 The rainfall and displacement data of 2cx06 motoring point

4.4.2 福建八尺门 2 号滑坡 05 测斜孔实例

据福建八尺门龙滩 2cx05 监测点监测数据如表 4.10 所示,选取 2001 年 7 月 15 日到 20031 年 10 月 28 日的监测点位移作为学习样本,后面的作为预测样本的核对值。按照第三章图 3.6 所示的学习流程,进行学习得到: 惩罚因子 $C=821.150$,核函数选择高斯核函数,核函数因子 $\sigma=375$,支持向量的 α 、 α^* 如表 4.11 所示,建立支持向量机模型。然后建立支持向量机映射模型,按照第三章的图 3.7 所示的




图 4.6 测点 2cx05.15 降雨量和位移图

Figure 4.6 The rainfall and displacement data of 2cx05.15 motoring point




图 4.7 测点 2cx06 降雨量和位移图

Figure 4.7 The rainfall and displacement data of 2cx06 motoring point

4.4.2 福建八尺门 2 号滑坡 05 测斜孔实例

据福建八尺门龙滩 2cx05 监测点监测数据如表 4.10 所示, 选取 2001 年 7 月 15 日到 20031 年 10 月 28 日的监测点位移作为学习样本, 后面的作为预测样本的核对值。按照第三章图 3.6 所示的学习流程, 进行学习得到: 惩罚因子 $C=821.150$, 核函数选择高斯核函数, 核函数因子 $\sigma=375$, 支持向量的 α 、 α^* 如表 4.11 所示, 建立支持向量机模型。然后建立支持向量机映射模型, 按照第三章的图 3.7 所示的

预测流程, 进行预测, 得到预测结果和监测值进行比较, 取得比较满意的结果, 如表 4.11 所示, 绘制成直观曲线图如 4.8 所示。

福建八尺门 2cx05 监测点的监测数据如表 4.10 所示, 大致上每隔 7 天作为位移序列一个位移值, 降雨量有着相应的构成方式, 从图 4.5 上可以看到有关降雨量的设定, 当选择了时间间隔小于等于 7 天的选项, 程序机算中, 相应的位移序列构成方式, 这个时间的一个位移和这个时间段的 2 个降雨量构成相应的序列, 其中为前一个时间段的降雨量, 另一个为这个时间的段的位移, 符合上节那粗糙的结论。

表 4.10 八尺门 2# 滑坡 05 监测点

Table 4.10 The 05 monitoring data of Bachimen No.2 slideslope

年	2001 年										
月日	7.15	7.22	7.29	8.5	8.12	8.19	9.2	9.9	9.16	9.23	9.30
位移/mm	0	0.05	1.5	4.56	15.8	21.22	21.95	24.13	23.24	24.2	37.04
降雨量/mm	18.6	42.5	32	117.6	139.4	28.7	114.6	74.8	22.8	0	9.1
地下水位/m	3	3.6	4	4	4	5	4.5	4	4	4	4
年	2001 年										
月日	10.7	10.14	10.21	10.28	11.4	11.11	11.18	11.25	12.2	12.9	12.16
位移/mm	38.4	40.16	45.63	49.7	52.93	52.95	53.55	53.26	53.87	53.9	54.04
降雨量/mm	147.2	0	13.5	0	4.6	28	0.1	0	0	11.3	21.8
地下水位/m	6.7	3.6	4.4	4.3	4.2	4.5	5	4.4	4.9	4.7	4.6

4.11 监测值与预测值的对比

时间	监测值	预测值	绝对误差	相对误差(百分)
2001.11.4	52.93	50.6591	2.2709	4.29
2001.11.11	52.95	51.7344	1.2156	2.29
2001.11.18	53.55	51.2732	2.2768	4.25
2001.11.25	53.26	50.7179	2.5421	4.77
2001.12.2	53.87	52.985	0.885	1.64
2001.12.9	53.90	52.1542	1.7458	3.23
2001.12.16	54.04	52.8631	1.1769	2.17

Table4.11 The comparison of measured and predicted displacements

表 4.12 2cx05 模型的支持向量相应的 α 、 α^* 值

Table 4.12 The support vectors and α 、 α^* 值 of the 2cx05 motoring point

序号	α	α^*
1	0.000	283.668
2	0.000	145.283
3	39.370	0.000
4	764.092	0.000
5	0.000	821.625
6	447.115	0.000
7	256.145	0.000
8	0.000	682.340
9	23.563	0.000

从预测值和监测值对比表可以看出，预测曲线的趋势和实测值的曲线有着比较吻合。




图 4.8 测点 2cx06 降雨量和位移图

Figure 4.8 The rainfall and displacement data of 2cx05 motoring point

4.4.3 福建八尺门 2 号滑坡 06 号测斜孔实例

据福建八尺门龙滩 2cx06 监测点监测数据如下表所示，选取 2001 年 9 月 10 日到 2002 年 2 月 1 日的监测点位移作为学习样本，后面的作为预测样本的核对值。

表 4.12 2cx05 模型的支持向量相应的 α 、 α^* 值

Table 4.12 The support vectors and α 、 α^* 值 of the 2cx05 motoring point

序号	α	α^*
1	0.000	283.668
2	0.000	145.283
3	39.370	0.000
4	764.092	0.000
5	0.000	821.625
6	447.115	0.000
7	256.145	0.000
8	0.000	682.340
9	23.563	0.000

从预测值和监测值对比表可以看出，预测曲线的趋势和实测值的曲线有着比较吻合。




图 4.8 测点 2cx06 降雨量和位移图

Figure 4.8 The rainfall and displacement data of 2cx05 motoring point

4.4.3 福建八尺门 2 号滑坡 06 号测斜孔实例

据福建八尺门龙滩 2cx06 监测点监测数据如下表所示，选取 2001 年 9 月 10 日到 2002 年 2 月 1 日的监测点位移作为学习样本，后面的作为预测样本的核对值。

按照第三章图 3.6 所示的学习流程, 进行学习得到: 惩罚因子 $C=288.120$, 核函数选择多项式核函数, 核函数因子 $d=90$, 支持向量的 α 、 α^* 如表 4.13 所示, 建立支持向量机模型。然后建立支持向量机映射模型, 按照第三章的图 3.7 所示的预测流程, 进行预测, 得到预测结果和监测值进行比较, 取得比较满意的结果, 如表 4.14 所示, 绘制成直观曲线图如 4.9 所示。

表 4.12 八尺门 2# 滑坡 05 监测点

Table 4.12 The 05 monitoring data of Bachimen No.2 slideslope

年	2001 年										
月日	9.10	9.20	10.30	11.10	11.20	11.30	12.10	12.20	12.30	1.10	1.20
位移/mm	0	7.85	9.41	12.58	18.64	19.24	19.77	20.38	19.22	19.22	21.69
降雨量/mm	43.2	9.1	165.3	28.1	0	10.5	3.1	62.6	3.4	0	39.1
地下水位/m	7	7.7	9.4	8	8.1	8.1	7.3	6.2	6.3	5.7	4.9

年	2002 年									
月日	2.1	2.10	2.20	3.1	3.12	3.20	3.29	4.10	4.16	4.30
位移/mm	21.59	21.39	22.95	22.78	23.94	24.14	27.51	30.51	32.51	33.43
降雨量/mm	63.2	10.4	0.7	4.9	0.7	54.2	50	40.3	39	73.6
地下水位/m	4.5	4.1	4.1	4	3.9	3.9	4.3	4.6	7.1	12.6

表 4.13 pm47 点模型的支持向量相应的 α 、 α^* 值

Table 4.13 The support vectors and α 、 α^* 值 of the pm47 motoring point

序号	α	α^*
1	0	130.3
2	1.6763	0
3	2.0605	0
4	4.055	0
5	22.0013	0
6	2.806	0
7	6.3812	0
8	27.5148	0
9	14.4272	0
10	56.6707	0

表 4.14 监测值与预测值的对比
Table4.14 The comparison of measured and predicted displacements

时间	监测值	预测值	绝对误差	相对误差(百分)
2002.2.10	21.39	19.99	1.40	6.56
2002.2.20	22.95	21.37	1.58	6.89
2002.3.1	22.78	23.39	0.61	2.68
2002.3.12	23.94	24.67	0.73	3.06
2002.3.20	24.14	24.36	0.22	0.92
2002.3.29	27.51	26.78	0.73	2.66
2002.4.10	30.51	28.94	1.57	5.14
2002.4.16	32.51	31.13	1.38	4.24
2002.4.30	33.43	31.29	2.14	6.40




图 4.9 测点 2cx06 降雨量和位移图
Figure 4.9 the rainfall and displacement data of 2cx05 motoring point

滑坡多集中在降雨量多的年份发生，而且很多滑坡是在雨季发生的，不少滑坡具有“大雨大滑，小雨小滑，无雨不滑”的特点，降雨对滑坡起着很大推动作用。从图 4.6 和图 4.7 可以明显的表现出来。当发生大规模降雨，特别是暴雨时，滑坡位移将会大幅度增加，甚至造成崩塌，有可能造成巨大的损失。因此在福建八尺门滑坡工程的两个实例中，在预测序列加入降雨量和地下水位序列，形成三个序列的学习样本，通过一定的规则来构成程序中运算的样本，学习后所得到的支持向量机模型更加符合客观实际，所构成的时间序列预测样本包含了更多的滑坡信息，所得到的结果更加准确。但是对于怎么删除这三个序列中的冗余信息，还需要更深一步的讨论，另外三个序列并不能完整的表达出所有信息，如何尽可能

表示出更多信息，形成更加完备的模型，仍需要进一步研究。

第五章 结论与展望

滑坡成灾机理的影响因素复杂,不确定性因素较多,边坡破坏方式、变形过程和变形机制复杂多变,大大增加了预报的难度。但随着人们对滑坡机理的进一步认识以及现代数理力学理论和计算机技术的迅速发展,各种预测预报方法不断涌现,且取得较好的预测结果。本文采用基于遗传算法的支持向量机建立滑坡位移时间序列,取得一定的效果。本文总结如下:

(1) 将遗传算法和支持向量机相结合建立进化支持向量机,采用遗传算法搜索支持向量机的核函数的参数因子及惩罚因子,具有较快的搜索速度和更好的全局优化能力。遗传算法优化后的时间序列模型能够为支持向量机生成的更具代表性的学习样本。

(2) 基于所建立的滑坡位移的单因素时间序列模型,采用进化支持向量机对滑坡位移进行预测,预测结果和神经网络的预测结果相比,更接近工程实际观测值,说明进化支持向量机比神经网络具有更好的学习能力和更强的泛化能力。

(3) 利用进化支持向量机建立考虑降雨量、地下水位等影响因素的多因素时间序列模型,基于该模型的滑坡位移预测结果符合工程实际且较单因素时间序列具有更高的精度。同时,预测结果也表明,降雨量,地下水位对滑坡位移具有较大的影响。

由于滑坡机理的复杂性,本文所做的工作只是滑坡位移时间序列预测,利用基于遗传算法的支持向量机进行尝试,从而得出一些结果,还有很多地方需要深入研究。主要有以下两方面需要改进:

(1) 滑坡位移时间序列模型进一步优化,建立更加符合实际的时间序列模型,从而提高预测精度,为施工提供更好的保障。

(2) 支持向量机和遗传算法需要更进一步的改进,采用更好的遗传算法和支持向量机算法,提高其学习能力和外推能力。

(3) 由于支持向量机有着坚实的小样本统计学习理论,结合遗传算法可以比较好的得到滑坡参数之间的非线性关系,对于研究滑坡问题有着很大的帮助。

参考文献

1. 晏同珍, 杨顺安, 方云. 滑坡学[M], 中国地质大学出版社. 2000
2. 孙建华, 王建华. 我国地质灾害防治工作综述[J], 西部探矿工程, Vol. 10, No3, 1998
3. 张建永. 滑坡研究现状综述[J], 中国岩溶, Vol. 18, 1999
4. 黄昌乾, 丁恩保. 边坡工程常用稳定性分析方法[J]. 水电站设计, Vol. 15, No1, 1999
5. 王元汉. 边坡稳定性的 Fuzzy 综合评判法[J]. 华中理工大学学报, Vol. 26, 1998
6. 周翠英. 滑坡灾害的复杂性理论研究[D]. 博士学位论文, 1992
7. 张治强. 岩体力学参数与变形特征的智能识别研究[D]. 东北大学博士学位论文, 2000
8. 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(1), 57—59
9. 赵洪波, 冯夏庭. 支持向量机函数拟合的边坡稳定性估计[J]. 岩石力学与工程学报, 2003, 22(2), 241—245
10. 赵洪波, 冯夏庭. 基于支持向量机的岩体工程分级[J]. 滑坡力学, 2002, 23(1), 698—701
11. 山田刚二, 渡正亮, 小岛澄治. 滑坡和斜坡崩塌及其防治[M]. 北京: 科学出版社, 1980
12. 伍法权, 王年生. 一种滑坡位移动力学预报探讨[J], 中国地质灾害与防治学报, 1996, 7(增刊): 38—41
13. 王思敬. 工程地质学新进展[M]. 见: 第六届国际滑坡学术讨论会评述. 北京: 科学技术出版社, 1991: 34—43
14. 陈明东, 王兰生. 边坡变形破坏的灰色预报方法[M]. 见: 全国第三次工程地质大会 论文选集(下). 成都: 成都科技大学出版社, 1988: 1226—1240
15. 晏同珍. 滑坡动态规律及预测应用[M]. 见: 全国第三次工程地质大会论文选集(下). 成都: 成都科技大学出版社, 1988: 707—713
16. 李天斌, 陈明东, 王兰生. 滑坡实时跟踪预报[M]. 成都: 成都科技大学出版社, 1999. 4. 11
17. 秦四清, 张倬元, 黄润秋. 滑坡灾害预报的非线性动力学方法[J]. 水文地质工程地质, 1993, 5: 1—4

18. 廖小平. 滑坡破坏时间预报新理论探讨[J], 地质灾害与环境保护, 1994, 5(3)
19. 殷坤龙. 滑坡灾害预测研究概况[J], 地质科技情报, 1992 (4)
20. 张学工. 关于统计学习理论与支持向量机[J], 自动化学报, 2000
21. 谭东宁, 谭东汉. 小样本机器学习理论[M]: 统计学习理论. 南京理工大学学报, 2001, 25(1), 108-112
22. Alex J. Smola, Bernhard Schoelkopf. A Tutorial on Support Vector Regression [J], Neuro COLT2 Technical Report Series NC2-TR-1998030, October, 1998
23. Burge. CJC. A Tutorial on Support Vector Machines for Pattern Recognition[J]. Data Mining and Knowledge Discovery 2, 121-167, 1998
24. John C. Platt. Sequential Minimal Optimization: A Fast Algorithm for training Support Vector machines [J], Technical Report MSR.TR.98 14, April 21, 1998.
25. Shevade S K, Keerthi S S, Bhattacharyya C, Murthy K R K. Improvements to the SMO algorithm for SVM regression[J]. IEEE Transactions on Neural Networks, 2000, 11(5): 1188-1193
26. Joachims T. Making large-scale SVM Learning Practical [R] .LS8.Report, 24, University Dortmund, LS VIII.Report, 1998
27. Amari Swum S. Improving support vector machine classifiers by modifying kernel functions[J]. Neural Networks, 1999, 12(6): 783-789
28. Mikhail Kanevski, Stephance Canu. Spatial data mapping with support vector regression[R]. IDIAP.RR. 00-09, May, 2000
29. Keerthi S S, et al. Improvements to Platt's SMO Algorithm for SVM Classifier Design[R]. CD.99 .14, Dept of Mecha and Prod. Engin. National Uni of ingapore, 1999
30. A. J. Smola. Learning with Kernel. PhD thesis, Technische Universitat Berlin, 1998
31. 刘勇, 康立山, 陈毓屏. 非数值并行算法(第二册)——遗传算法[M]. 北京: 科学出版社, 1997
32. 云庆夏, 黄光球, 王战权. 遗传算法和遗传规划[M]. 北京: 冶金工业出版社, 1997
33. 马超群, 高仁祥. 现代预测理论与方法[M], 长沙: 湖南大学出版社, 1999
34. 孙明玺. 现代预测学[M], 杭州: 浙江教育出版社, 1998: 1-23
35. 盛昭瀚, 王涛, 刘德林. 非线性时间序列模型的稳定性分析[M], 北京: 科学出版社, 1993
36. 许强, 黄润秋, 李秀珍. 滑坡时间预测预报研究进展[J], 2004, Vol. 19(13) 地球科学进展
37. 周超海, 梁永国, 殷坤龙. 非线性时间序列滑坡分析, 西部探矿工程[J] 2004, 16(6): 191-193

38. 冯夏庭. 智能岩石力学及其在滑坡工程中的应用, 滑坡力学新计算方法讲义 [J]. 中国科学院武汉滑坡力学研究所, 1999, 10
39. 福宁高速公路福鼎分水关至福安湾坞段 A3 标段八尺门互通区滑坡工程地质勘察报告[R], 福建省闽东工程勘察院, 2001, 3
40. 同三国道主干线福鼎至宁德高速公路 A3 标段八尺门互通区滑坡监测工程月报 [R] (2001.8-2002.5), 中国科学院武汉滑坡力学研究所

致谢

本论文是在冯夏庭教授的悉心指导下完成的。在整个研究生期间，冯老师以其严谨的学风、诲人不倦的治学态度，给予我终身难忘的教诲和培养，使我能顺利地完成学业，并在学习、工作和生活中取得进步。可以说，我的每一点成绩的取得，无不浸润着冯老师的巨大心血。在论文的完成过程中，李邵君老师自始至终给予我悉心的指导，李邵君老师艰苦朴素的生活作风，严谨的治学态度令人终生难忘。同时，本论文在撰写过程中，还得到了杨成祥老师，陈炳瑞、姜谔南和茹忠亮等同学的帮助。

感谢中国科学院岩土力学所智能岩石力学组组长周辉老师、刘建老师、刘建军、何翔、熊俊，康志强、胡斌、张传庆、苏国韶以及众多同学的帮助，还有感谢在撰写论文期间所有帮助过我的老师和同学，他们给我提出了大量宝贵的意见，使得我的论文工作进展顺利，完成得较为成功。