

文章编号: 1008-2786-(2019)6-868-11

DOI:10.16089/j.cnki.1008-2786.000477

## 基于宽度学习模型的泥石流灾害预报

徐根祺,李丽敏\*,温宗周,刘德阳,程少康

(西安工程大学 电子信息学院,西安 710048)

**摘 要:**在泥石流灾害预报模型研究中,科学确定泥石流灾害影响因子及保证模型较高的预报准确率和快速的训练速度是关键问题,也是泥石流灾害预报预警和防灾减灾的重要基础。本研究针对目前泥石流预报模型输入数据维度较大和训练时间较长的问题,采用快速多个主成分并行提取算法(Fast multiple principle components extraction algorithm, FMPCE),选取 6 个泥石流灾害影响因子,包括降雨量、山坡坡度、沟床比降、相对高差、土壤含水率和孔隙水压力。基于宽度学习(Broad learning, BL)算法,以泥石流影响因子为输入,泥石流发生概率为输出,构建了泥石流预报模型,并用矩阵随机近似奇异值分解(矩阵随机近似 SVD)对模型进行了优化,将优化后宽度学习模型的预报结果与梯度下降法优化的 BP 神经网络预报模型(GD-BP)、基于支持向量机的预报模型(SVM)、宽度学习预报模型(BL)的结果进行对比,同时,通过输入数据集的扩展,从训练时间上对不同模型进行比较。结果表明,优化宽度学习泥石流灾害预报模型的预报准确率为 93.52%,较 GD-BP 模型、SVM 模型和 BL 模型的预报准确率分别高出 1.60%、1.15% 和 0.03%;优化宽度学习泥石流灾害预报模型的训练时间为 0.9039s,较 GD-BP 模型、SVM 模型和 BL 模型的训练时间分别节省了 25.3867 s、17.2620 s 和 0.8974 s。本研究说明宽度学习算法可以用于对泥石流灾害的发生概率进行预报,同时也可对泥石流预报的实际应用提供新的思路。

**关键词:**宽度学习算法;泥石流;预报模型;奇异值分解

**中图分类号:** P642

**文献标志码:** A

泥石流是我国主要地质灾害之一<sup>[1]</sup>。我国幅员辽阔,自然环境复杂多变,山区地质构造活动强烈,此外随着随意改造山林等不合理建设活动的增加,也极易引发泥石流灾害<sup>[2-5]</sup>。近年来,频繁爆发的泥石流灾害引起了国家政府部门的高度关注,为降低泥石流灾害的危害程度,有关部门加强了调查与防治工作,对泥石流易发区进行了调查和探究。泥石流预报问题已成为自然灾害领域研究的一项前沿课题,能否提供有效的泥石流灾害预报方法成为防灾减灾的关键点<sup>[6]</sup>。

早在 20 世纪 70 年代,该领域研究者们便对泥石流展开了系统的研究。自上世纪 90 年代以来,随着交叉学科的兴起,各种数学模型开始在这一研究领域中得到广泛应用<sup>[7-8]</sup>。研究者们根据泥石流形成的特点,提出了多种泥石流灾害预报方法。有研究者结合模糊系统理论和人工神经网络对泥石流危险性进行评价<sup>[9]</sup>,然而模糊系统计算复杂度大,确定泥石流指标权重向量时过于主观,虽然人工神经网络的加入较好地克服了这一缺陷,但人工神经网络在训练过程中,模型本身易陷入局部极小值,因

**收稿日期**(Received date):2019-06-13;改回日期(Accepted date):2020-01-02

**基金项目**(Foundation item):陕西省自然科学基金基础研究计划资助项目(2019JQ-206)。[Natural Science Basic Research Plan in Shaanxi Province of China(2019JQ-206)]

**作者简介**(Biography):徐根祺(1984-),男,陕西西安人,硕士研究生,工程师,主要研究方向:人工智能算法。[XU Genqi(1984-), male, born in Xi'an, Shanxi province, M. Sc. candidate, engineer, research on artificial intelligence algorithms A1] E-mail: 2017041028@stu.xpu.edu.cn

**\* 通讯作者**(Corresponding author):李丽敏(1985-),女,内蒙古自治区赤峰人,博士,讲师,主要研究方向:人工智能算法。[LI Limin(1985-), female, born in Chifeng, Inner Mongolia Autonomous Region, Ph. D., lecture, research on artificial intelligence algorithms] E-mail: liliminxiaomi@126.com

此,该方法精度不高;有研究者将层次分析法分别用于对泥石流发生概率进行预警<sup>[10]</sup>和泥石流易发性评价<sup>[11]</sup>,均取得了一定的成果,但层次分析法依赖于专家系统的支持,往往标度工作量大,数据维度较多;也有学者依据当地泥石流的启动机理,分别运用沟床起动型泥石流 10 min 降雨预报公式与浅层滑坡汇集型沟谷泥石流的预报公式进行泥石流预警<sup>[12]</sup>,在泥石流降雨临界值预报中获得了良好效果,然而未深入考虑其它相关影响因素,在一定程度上可能会影响预报准确性;还有学者将逻辑回归模型运用于泥石流灾害易发性评价研究中<sup>[13]</sup>,综合多种指标进行分析,在精确度方面得到了一定提高,但逻辑回归属于广义线性回归模型,受到多重共线性问题的影响较大;最近又有学者提出了一种基于 RBF 神经网络的泥石危险性评价模型并取得了较好的效果<sup>[14]</sup>,但缺乏对指标之间相关性的分析,可能造成信息相互叠加,容易引起维度灾难。

为了解决上述方法中数据维度过大和训练时间过长的问題,本文结合 BL 算法<sup>[15]</sup>和 FMPCE 算法<sup>[16]</sup>建立泥石流灾害概率预报模型。利用 FMPCE 算法提取出泥石流灾害影响因子以取代初始的高维影响因子,其目的是为了改善传统方法所造成的维度灾难问题;采用 BL 算法对泥石流发生概率进行预测,旨在弥补深度学习由于需要计算大量的隐层权值而导致的训练时间过长的缺陷,同时也是为了提高模型的在线更新能力;使用矩阵随机近似 SVD<sup>[17]</sup>对模型进行优化,以解决因模型初始化不佳而引起的输入矩阵结构冗余问题。

## 1 研究区概况介绍

### 1.1 研究区地形地貌

研究区位于秦岭山脉及商洛东南部的山阳县,地理位置优越,东边相邻商南、西边是柞水,南边紧挨湖北省,北边连着商州区,同时具有“三山夹两川”称号。山阳县境内北边与流岭接壤,南边郧岭,中间经过鹃岭,流经河流包括金钱河、谢家河等河流,隶属于长江、汉江分支,河流长分别为 40 km、80 km,流域面积为 600 km<sup>2</sup>、2400 km<sup>2</sup>。海拔范围为 800 ~ 1500 m,因其地处秦岭山下,山脉沟壑众多,属于中、低山地形,山体土石量多达 180 万 m<sup>3</sup>,占地高达 80% 以上,形成地势差异较大的峡谷地区,同时

地处两川中间,小河流域较多,水资源较丰富,夏秋季降雨量较多且潮湿,气温变化差异大,极易造成土质疏松。且该地区矿物质丰富,人类活动强度较大,从而增加了泥石流灾害的安全隐患点。

### 1.2 研究区泥石流灾害分布与规律

地质灾害发生类型多样,受到复杂的地形、气象及自身风化影响,但可以通过数据特征研究其发生空间及时间规律。根据近十年研究区域地质灾害发生的资料分析,泥石流多发生在河流与山区附近,沟壑多达 180 条,大多呈现条状分布,部分呈点状分布,占灾害总发生数目的 16%。

通过山阳县近年来泥石流灾害发生特点数据进行统计分析,得出大多数灾害在时间上与降雨强度及降雨的季节呈现一定的规律,部分与人类不合理的开采有关。降雨量的强度影响灾害的发生,然而降雨又与季节有关系,因此在时间上存在相应的关系。研究区是半湿润山地气候,夏季降雨比较丰富,特别是一些持续的强降雨为地质灾害提供了动力。据统计该区域在 5 月—10 月份降雨量累积较多,极易引发泥石流灾害。

对泥石流地质灾害的研究是一个复杂的非线性系统研究,其具有区域分布广泛、监测建模较难、数据量大及不稳定性等特点。只有对地质地貌规律及大量数据进行分析、研究,打好良好的数据基础,选取合适的成灾影响因子,并建立灾害预报模型,才能更有效地预防泥石流灾害的发生。

## 2 研究方法介绍

### 2.1 快速多个主成分并行提取算法(FMPCE)

在泥石流地质灾害中,诱发泥石流的因素有很多,包括降雨量、土壤含水率、孔隙水压力、流域发育程度、流域完整系数、植被覆盖率、山坡坡度、岩性因素、流域面积、相对高差、冲淤变幅、沟床比降、沿沟松散物储量、不良地质现象、新构造影响、补给段长度比和人为活动等,这使得对于预报模型的训练变得困难。下面采用 FMPCE 对泥石流灾害的预报影响因子进行筛选<sup>[16]</sup>。

对于线性神经网络模型:

$$\mathbf{y}(k) = \mathbf{W}^T(k)\mathbf{x}(k) \quad (1)$$

其中, $\mathbf{y}(k) \in \mathbf{R}^{r \times 1}$ 表示神经网络输出; $\mathbf{W}(k) \in \mathbf{R}^{n \times r}$ 表示神经网络权值矩阵; $\mathbf{x}(k) \in \mathbf{R}^{n \times 1}$ 表示神经网络

输入;  $n$  是输入向量维数,  $r$  是所要提取主成分的维数。

令输入的自相关矩阵  $\mathbf{R} = E[\mathbf{x}_k \mathbf{x}_k^T]$ ,  $\mathbf{R}$  对称正定矩阵, 其中  $\lambda_i$  为  $\mathbf{R}$  的特征值,  $\mathbf{u}_i$  为属于特征值  $\lambda_i$  的特征向量,  $i = 1, 2, \dots, n$ , 特征值  $\lambda_i > 0$ , 对  $\mathbf{R}$  进行特征值分解:

$$\mathbf{R} = \mathbf{U} \mathbf{\Lambda} \mathbf{U}^T \quad (2)$$

其中,  $\mathbf{U} = [\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_n]$ ;  $\mathbf{\Lambda} = \text{diag}\{\lambda_1, \lambda_2, \dots, \lambda_n\}$ , 且特征值满足:

$$\lambda_1 > \lambda_2 > \dots > \lambda_r > \dots > \lambda_n > 0 \quad (3)$$

属于这  $r$  个特征值的特征向量为矩阵  $\mathbf{R}$  的前  $r$  个主成分, 由这些主成分生成的空间称为主子空间。FMPCE 便是寻求合适的权值矩阵迭代更新方程, 使得权值矩阵能够收敛到矩阵  $\mathbf{R}$  的前  $r$  个主成分。其算法形式为:

$$\mathbf{W}(k+1) = \mathbf{W}(k) + \eta[\mathbf{W}(k)\mathbf{C}(k) + (\mathbf{E}(k)\mathbf{A}^2 - \mathbf{F}(k)\mathbf{A})] \quad (4)$$

其中, 矩阵  $\mathbf{A}$  为  $r \times r$  级对角阵, 对角线元素为  $a_1 > a_2 > \dots > a_r > 0$ ,  $\eta$  为学习速率;  $\mathbf{C}(k) = \mathbf{W}(k)(\mathbf{W}(k)^T \mathbf{W}(k))^{-1} - \mathbf{I}$  为非二阶矩阵,  $\mathbf{C}$  的引入既可以解决算法的不稳定问题, 又可以提升算法的收敛速度<sup>[16]</sup>;  $\mathbf{E}(k) = \mathbf{R}\mathbf{W}(k)\mathbf{W}^T \mathbf{W}(k)$ ;  $\mathbf{F}(k) = \mathbf{W}(k)\mathbf{A}\mathbf{W}^T(k)\mathbf{R}\mathbf{W}(k)$ 。

在实际应用中, 自相关矩阵并不是已知的, 而需要通过下式进行估计:

$$\hat{\mathbf{R}} = \left(1 - \frac{1}{k}\right) \alpha \hat{\mathbf{R}}(k-1) + \frac{\mathbf{x}_k \mathbf{x}_k^T}{k} \quad (5)$$

式中,  $\alpha$  为遗忘因子, 满足  $0 < \alpha < 1$ 。

显然当  $k \rightarrow \infty$  时, 矩阵  $\hat{\mathbf{R}}(k) \rightarrow \mathbf{R}$ 。使用式(5)

对自相关矩阵进行估计, 然后利用式(1)和式(4), 即可对输入的主成分进行提取。

注: 文中所有矩阵用粗体大写字母表示, 向量用粗体小写字母表示, 标量或函数用斜体表示。

## 2.2 宽度学习 (Broad learning, BL)

BL 首先将输入数据映射成特征节点矩阵, 再在此基础上, 经过增强变换形成增强节点矩阵。最后由特征映射节点和增强节点共同作为隐含层的输入, 利用伪逆求解隐含层与输出之间的权值矩阵。整个过程中, 只更新隐含层与输出之间的连接, 这使得训练过程十分简便。而且, 一旦特征映射节点和增强节点的数目无法满足所需精度时, BL 使用增量学习的方式, 可以快速重新训练。具体过程如下<sup>[15]</sup>。

### (1) 宽度学习初始结构

BL 结构如图 1 所示。

用  $\Phi_i(\mathbf{X}\mathbf{W}_{e_i} + \beta_{e_i})$  表示第  $i$  个特征映射  $\mathbf{Z}_i$ ,  $\xi_j(\mathbf{Z}^i \mathbf{W}_{h_j} + \beta_{h_j})$  表示第  $j$  个增强节点  $\mathbf{H}_j$ , 其中  $\mathbf{W}_{e_i}$  为随机初始权值, 定义  $\mathbf{Z}^i = [\mathbf{Z}_1, \mathbf{Z}_2, \dots, \mathbf{Z}_i]$ ,  $\mathbf{H}^j = [\mathbf{H}_1, \mathbf{H}_2, \dots, \mathbf{H}_j]$ 。为了简便, 后面均省略第  $i$  个映射  $\Phi_i$  和第  $j$  个映射  $\xi_j$  的下标。

对于  $n$  个特征映射, 每个映射节点生成  $k$  个增强节点, 用下式表示:

$$\mathbf{Z}_i = \Phi(\mathbf{X}\mathbf{W}_{e_i} + \beta_{e_i}), i = 1, 2, \dots, n \quad (6)$$

于是, 宽度学习模型表示如下:

$$\begin{aligned} \mathbf{Y} &= [\mathbf{Z}_1, \dots, \mathbf{Z}_n | \xi(\mathbf{Z}^n \mathbf{W}_{h_1} + \beta_{h_1}), \\ &\quad \dots, \xi(\mathbf{Z}^n \mathbf{W}_{h_m} + \beta_{h_m})] \mathbf{W}^m \\ &= [\mathbf{Z}^n | \mathbf{H}^m] \mathbf{W}^m \end{aligned} \quad (7)$$

其中,  $\mathbf{W}^m = [\mathbf{Z}^n | \mathbf{H}^m]^+ \mathbf{Y}$  是连接权值,  $[\mathbf{Z}^n | \mathbf{H}^m]^+$  可

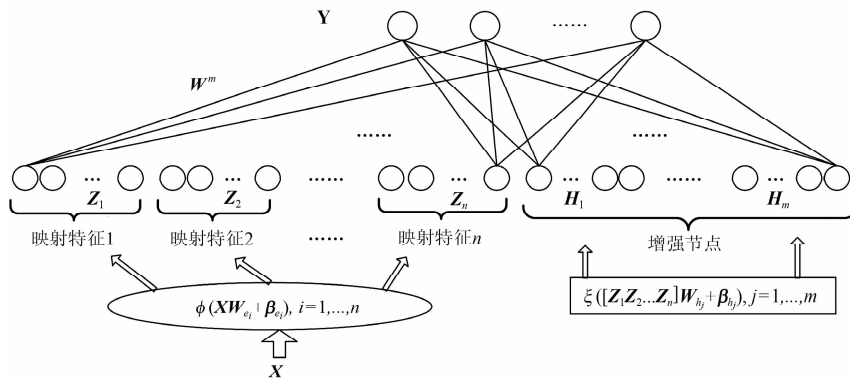


图 1 宽度学习初始结构

Fig. 1 Initial structure of broad learning model

以由式(8)(伪逆岭回归近似算法)得到:

$$\mathbf{A}^+ = \lim_{\lambda \rightarrow 0} (\lambda \mathbf{I} + \mathbf{A}\mathbf{A}^T)^{-1} \mathbf{A}^T \mathbf{Y} \quad (8)$$

(2) 插入新的增强节点

设插入  $p$  个增强节点, 令  $\mathbf{A}^m = [\mathbf{Z}^n | \mathbf{H}^m]$ , 定义  $\mathbf{A}^{m+1} = [\mathbf{A}^m | \mathbf{H}^{m+1}]$ 。根据 RVFLNN 的动态更新算法, 可求出新的输入矩阵  $\mathbf{A}^{m+1}$  的伪逆为:

$$(\mathbf{A}^{m+1})^+ = \begin{bmatrix} (\mathbf{A}^m)^+ - \mathbf{D}\mathbf{B}^T \\ \mathbf{B}^T \end{bmatrix} \quad (9)$$

新的权值  $\mathbf{W}^{m+1}$  为:

$$\mathbf{W}^{m+1} = \begin{bmatrix} \mathbf{W}^m - \mathbf{B}\mathbf{D}^T \mathbf{Y} \\ \mathbf{B}^T \mathbf{Y} \end{bmatrix} \quad (10)$$

以上所有的伪逆均通过式(8)计算得到, 也就是说, 该算法无需计算所有的增强节点, 而只需计算新插入的增强节点的伪逆, 从而实现快速增量学习。

类似地, 还可以对新的特征映射节点和新的输入数据进行更新。宽度学习更新结构如图2所示。

### 2.3 宽度学习优化(SVDBL)

学习过程中, 可能由于初始化效果不佳导致隐含层输入矩阵结构冗余, 一般可以通过低秩近似的方法优化矩阵结构。本节使用矩阵随机近似 SVD 方法对上述宽度学习算法进行优化。

从具有  $n$  组映射特征节点的随机初始化网络出发, 优化过程如下:

$$\mathbf{Y} = [\mathbf{Z}_1, \dots, \mathbf{Z}_n] \mathbf{W}_n^0 \quad (11)$$

定义  $\mathbf{A}_n^0 = [\mathbf{Z}_1, \dots, \mathbf{Z}_n]$ , 于是  $\mathbf{Y} = \mathbf{A}_n^0 \mathbf{W}_n^0$ 。

矩阵分解的目的是为了减少节点数目以简化计算。对于  $\mathbf{Z}_i$  采用矩阵随机近似 SVD<sup>[17]</sup> 进行分解。

由  $\mathbf{Z}_i$  的列空间的一组正交基构造一个矩阵  $\mathbf{Q}$ , 使得  $\mathbf{Z}_i \approx \mathbf{Q}\mathbf{Q}^* \mathbf{Z}_i$ , 则  $\mathbf{Q}$  为  $\mathbf{Z}_i$  的一个近似子矩阵,  $\mathbf{Q}\mathbf{Q}^* \mathbf{Z}_i$  是  $\mathbf{Z}_i$  所构成子空间的低秩近似。根据  $\mathbf{Q}$ , 可以很容易地求出  $\mathbf{Z}_i$  的近似矩阵。然后通过  $\mathbf{Z}_i$  的近似矩阵对  $\mathbf{Z}_i$  进行奇异值分解。

$$\mathbf{Z}_i = \mathbf{U}_{\mathbf{Z}_i} \boldsymbol{\Sigma}_{\mathbf{Z}_i} \mathbf{V}_{\mathbf{Z}_i}^T = \mathbf{Z}_i^P + \mathbf{Z}_i^Q \quad (12)$$

$$\mathbf{Z}_i^P \mathbf{V}_i^P = \mathbf{Z}_i \mathbf{V}_i^P \quad (13)$$

令  $\mathbf{W}_n^0 = [\mathbf{W}_{\mathbf{Z}_1}^{0,n} | \dots | \mathbf{W}_{\mathbf{Z}_n}^{0,n}]^T$ , 则

$$\begin{aligned} \mathbf{Y} &= \mathbf{A}_n^0 \mathbf{W}_n^0 = [\mathbf{Z}_1, \dots, \mathbf{Z}_n] \mathbf{W}_n^0 \\ &= [\mathbf{Z}_1 \mathbf{V}_{\mathbf{Z}_1}^P, \dots, \mathbf{Z}_n \mathbf{V}_{\mathbf{Z}_n}^P] \begin{bmatrix} \mathbf{V}_{\mathbf{Z}_1}^{P^T} \mathbf{W}_{\mathbf{Z}_1}^{0,n} \\ \dots \\ \mathbf{V}_{\mathbf{Z}_n}^{P^T} \mathbf{W}_{\mathbf{Z}_n}^{0,n} \end{bmatrix} \\ &= \mathbf{A}_F^{[0,n]} \mathbf{W}_F^{[0,n]} \end{aligned} \quad (14)$$

模型可定义为:  $\mathbf{Y} = \mathbf{A}_F^{[0,n]} \mathbf{W}_F^{[0,n]}$ , 其中,  $\mathbf{W}_F^{[0,n]} = (\mathbf{A}_F^{[0,n]})^+ \mathbf{Y}$ 。

对于插入  $P$  个增强节点的优化结果如下:

$$(\mathbf{A}_F^{[m+1,n]})^+ = \begin{bmatrix} (\mathbf{A}_F^{[m,n]})^+ - \mathbf{D}\mathbf{B}^T \\ \mathbf{B}^T \end{bmatrix} \quad (15)$$

$$\mathbf{W}_F^{[m+1,n]} = \begin{bmatrix} \mathbf{W}_F^{[m,n]} - \mathbf{D}\mathbf{B}^T \mathbf{Y} \\ \mathbf{B}^T \mathbf{Y} \end{bmatrix} \quad (16)$$

宽度学习完成后, 仍需要去除更小的奇异值来进一步优化。优化结果如下:

$$\begin{aligned} \mathbf{A}_F^{[m,n]} &= \mathbf{U}_F \boldsymbol{\Sigma}_F \mathbf{V}_F^T \\ &= \mathbf{U}_F \cdot [\boldsymbol{\Sigma}_F^P | \boldsymbol{\Sigma}_F^Q] \cdot [\mathbf{V}_F^P | \mathbf{V}_F^Q]^T \\ &= \mathbf{A}_F^{[m,n]^P} + \mathbf{A}_F^{[m,n]^Q} \end{aligned} \quad (17)$$

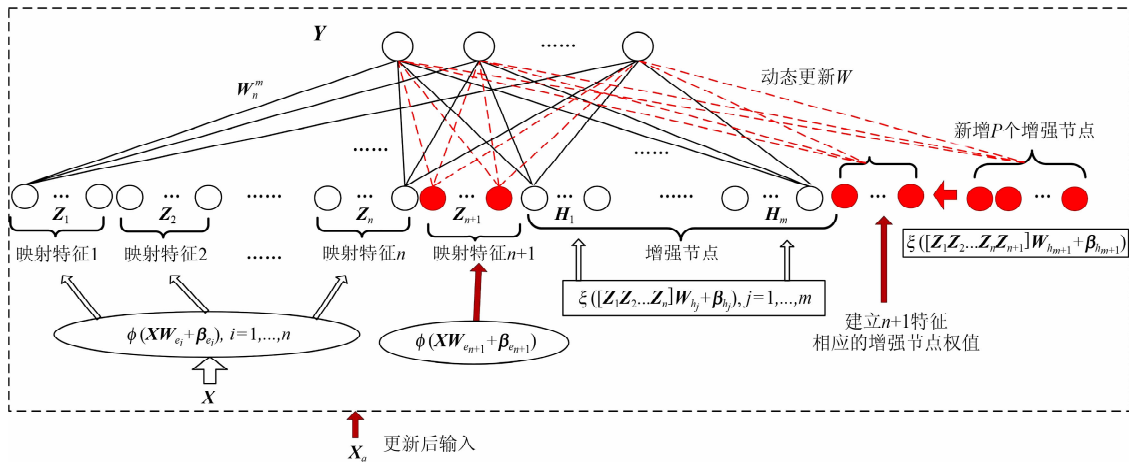


图2 宽度学习更新结构

Fig. 2 Updated structure of broad learning model

令  $A_F = A_F^{[m,n]} V_F^P$ , 则  $Y = A_F W_F$ , 其中  $W_F = A_F^+ Y$ 。

### 3 建模过程和结果分析

#### 3.1 泥石流概率预报模型建立

为了客观准确地对泥石流发生的概率进行预报, 本文提出了一种泥石流灾害预报模型, 如图 3 所示。该模型的结构包括 4 个模块, 分别为数据模块、技术模块、算法模块和预报模块。各模块的主要功能如下:

(1) 数据模块。该模块主要负责泥石流灾害的历史数据, 包括数据的采集、存储、更新、提取等操作。考虑到诱发泥石流的各因素随着环境的变化而不断改变, 因此采用开放性模块, 以便于实时地对数据进行更新和维护。

(2) 技术模块。由于泥石流影响因子众多, 数

据庞大, 有些数据对预报的结果影响并不明显, 需要对数据进行筛选, 该模块采用 FMPCE 算法以达成上述目的。

(3) 算法模块。泥石流的影响因素十分复杂, 且往往具有随机性和模糊性。为了弥补现有方法中速度较慢的缺陷, 该模块采用宽度学习算法对数据进行训练, 可大幅缩减训练时间, 同时在在线更新模型方面具有显著优势。

(4) 预报模块。令训练样本  $X = \{x_1, x_2, x_3, x_4, x_5, x_6\}$ , 其中,  $x_1$  为降雨量,  $x_2$  为山坡坡度,  $x_3$  为沟床比降,  $x_4$  为相对高差,  $x_5$  为土壤含水率,  $x_6$  为孔隙水压力。输出  $Y$  为泥石流灾害发生概率。基于技术模块实现对主要影响因子的快速筛选, 再经过算法模块的计算, 最终由该模块准确快速地预报出泥石流的发生概率。以下给出了基于 SVDBL 算法的泥石流预报的伪代码。

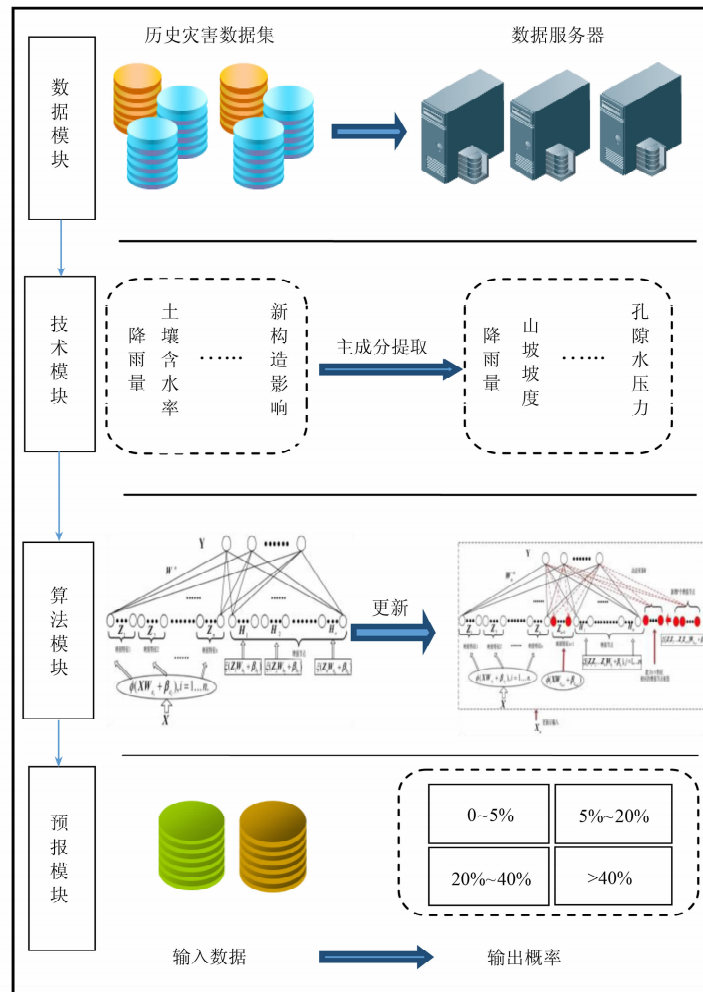


图 3 泥石流灾害预报模型

Fig. 3 Debris flow disaster prediction model

基于 SVDBL 算法的泥石流预报

输入:训练样本 $(X,Y)$ 和实际输入 $\hat{X}$   
输出:泥石流发生概率 $\hat{Y}$

```
1  for  $i=0; i\leq n$  do
2      初始化  $W_{e_i}$  和  $\beta_{e_i}$ ;
3      计算  $Z_i = \Phi(XW_{e_i} + \beta_{e_i})$ ;
4      计算  $V_{Z_i}^P$ ;
5  end
6  for  $j=0; j\leq m$  do
7      初始化  $W_{h_j}$  和  $\beta_{h_j}$ ;
8      计算  $H_j = \xi([Z_1 V_{Z_1}^P, \dots, Z_n V_{Z_n}^P] W_{h_j} + \beta_{h_j})$ ;
9      计算  $V_{H_j}^P$ ;
10 end
11 令  $A^{[m,n]} = [Z_1 V_{Z_1}^P, \dots, Z_n V_{Z_n}^P | H_1 V_{H_1}^P, \dots, H_m V_{H_m}^P]$ 
12 利用式(8)计算  $(A^{[m,n]})^+$ ;
13 while 训练精度不满足要求 do
14     初始化  $W_{h_{m+1}}$  和  $\beta_{h_{m+1}}$ ;
15     计算  $H_{m+1} = \xi([Z_1 V_{Z_1}^P, \dots, Z_n V_{Z_n}^P] W_{h_{m+1}} + \beta_{h_{m+1}})$ ;
16     更新  $A_n^{m+1}$ ;
17     计算  $V_{H_{m+1}}^P$ ;
18     更新  $A^{[m+1,n]}$ ;
19     利用式(15)和(16)计算  $(A_F^{[m+1,n]})^+$  和  $W_F^{[m+1,n]}$ ;
20      $m = m + 1$ 
21 end
22 计算  $V_F^P$ ;
23 计算  $A_F = A_F^{[m,n]} V_F^P$ ;
24 利用式(8)计算  $A_F^+$  和  $W_F = A_F^+ Y$ ;
25 令  $W = W_F$ ;
26 计算泥石流发生概率  $\hat{Y} = \hat{X}W$ ;
```

3.2 确定影响因子及数据来源

根据《泥石流灾害防治工程勘察规范》(DZ/T 0220—2006),参照文献并结合实地勘测和野外考察资料,通过对研究区泥石流形成的环境背景和发育特征的分析,选取 16 个影响因子(详见表 1),利用技术模块中的 FMPCE 算法,分别选取 1 到 16 个因子,再在算法模块中对模型进行训练并验证(图 4),最后由预报模块输出结果。分别选取不同维度的影响因子,对预报结果进行比较,最终选取出 6 个影响因子。

表 1 影响因子列表

Tab. 1 Influence factors list

序号	影响因子
①	降雨量
②	土壤含水率
③	孔隙水压力
④	流域发育程度
⑤	流域完整系数
⑥	植被覆盖率
⑦	山坡坡度
⑧	岩性因素
⑨	流域面积
⑩	相对高差
⑪	冲淤变幅
⑫	沟床比降
⑬	补给段长度比
⑭	沿沟松散物储量
⑮	不良地质现象
⑯	新构造影响




图 4 影响因子维度与预报准确率的关系

Fig. 4 Relationship between influence factor dimensions and forecast accuracy

从图 4 明显看出,随着泥石流影响因子维度的增加,模型预报准确率逐步提高,当维度达到 6 时,模型的预报准确率基本稳定,继续增加影响因子对模型预报的准确率并无明显改变,因此选取影响因子维度为 6。根据前文提到的 FMPCE 算法进行主成分提取,最终提取出的影响因子包括:降雨量、山坡坡度、沟床比降、相对高差、土壤含水率、孔隙水压力。通过对多地区泥石流灾害相关参数变化的研究<sup>[18-20]</sup>,总结出各影响因子与泥石流发生概率的关系及表征意义,如表 2 所示。

表 2 影响因子表征意义及分级  
Tab.2 Significance and classification of influence factors

影响因子	表征意义	泥石流发生概率/%			
		0 ~ 5	5 ~ 20	20 ~ 40	> 40
降雨量/mm	泥石流形成所需的水源条件,采用日综合降雨量表示	< 40	40 ~ 55	55 ~ 75	> 75
山坡坡度/%	松散固体物质汇集所需的势能条件,以 25 ~ 45° 面积占流域面积的比例进行量化	< 0.05	0.05 ~ 0.1	0.1 ~ 0.2	> 0.2
沟床比降/‰	泥石流形成所需的势能条件	< 50	50 ~ 100	100 ~ 400	> 400
相对高差/m	泥石流形成过程的地形因素	< 20	20 ~ 40	40 ~ 80	> 80
土壤含水率/%	土壤中所含水分的数量	< 10	10 ~ 19	19 ~ 29	> 29
孔隙水压力/MPa	土壤或岩石中地下水的压力,该压力作用于微粒或孔隙之间	< 10	10 ~ 30	30 ~ 60	> 60

本文以陕西省山阳县国家重点地灾监测项目的 12 个监测站的历史数据作为样本,从山阳县泥石流灾害历史数据中按时间序列选取 2000 组数据,分别将其中 1800 组和 1900 组数据作为训练样本,剩余数据作为验证样本,对该模型进行训练和验证。

3.3 数据预处理

由于环境因素影响,用于泥石流监测的传感器,不可避免会出现数据缺失、离群和不统一的现象,因此需要对数据进行预处理。

(1) 缺失值处理

数据遗漏或出现离群点是常见的情况,对遗漏的传感器数据按属性进行统计,得到缺失率  $q$ ,若  $q \geq 90\%$ ,则将该列数据剔除;若  $40\% \leq q < 90\%$ ,则采用相邻属性加权填充;若  $20\% \leq q < 40\%$ ,则使用均值作为填充值;若  $q < 20\%$ ,则采用众数进行填充。

(2) 离群值处理

对于某些相距均值的距离在 3 倍以上或达到 5 倍标准差的数值都是离群值,需要剔除。

(3) 归一化

所需数据不仅种类众多而且数量庞大,不同种类的数据有不同的量纲,数据的多样化会导致数据不平衡,这将在极大程度上影响预报模型的准确率。可通过式 (18) 对数据进行归一化处理:

$$R' = \frac{R - R_{\min}}{R_{\max} - R_{\min}} \quad (18)$$

其中,  $R'$  为归一化处理后的数据;  $R$  为原始数据;  $R_{\max}$  和  $R_{\min}$  为最大值和最小值。

分别对预处理之前和预处理之后的数据,使用矩

阵随机近似 SVD 优化的宽度学习 (SVDBL) 模型进行仿真,图 5 和表 3 为数据预处理前后的结果对比。




图 5 数据预处理前后预报结果对比

Fig.5 Comparison of forecast results before and after data preprocessing

表 3 数据预处理前后预报结果对比

Tab.3 Comparison of forecast results before and after data preprocessing

	增强节点数/个	准确率/%	训练时间/s
数据预处理前	7000	79.64	2.9012
数据预处理后	2000	93.58	0.9037

注:本文仿真均在 CPU2.4GHz,内存 8G 的机器上使用 Matlab 进行。

从图 5 和表 3 可以看出,对于未经过预处理的数据,当模型的增量节点数增加到 7000 个左右时,预报准确率才渐趋稳定,最终达到 79.64%,训练时间为 2.9012 s。然而,对于经过预处理的数据,输入



模型之后,当模型的增量节点数达到 2000 个以上时,其预报准确率就已经趋于稳定,最终达到 93.58%,训练时间为 0.9037 s。仿真结果表明,对数据进行预处理是必要的,且本节中所述的数据预处理方式可以有效提升预报准确率。

3.4 仿真验证及结果分析

在数据模块中,从服务器中调取历史数据,通过技术模块对影响因子进行提取,再经过算法模块进行计算,最后由预报模块得出结果,并利用十折交叉检验法对模型进行验证。分别对比了比较常用的梯度下降法优化 BP 神经网络(GD-BP)模型、支持向量机(SVM)模型、宽度学习(BL)模型和矩阵随机近似 SVD 优化的宽度学习(SVDBL)模型的平均预报准确率和平均训练时间,如表 4 所示。各模型在验证集中的部分预报结果如表 5 所示。

表 4 各模型平均预报准确率和平均训练时间对比

Tab. 4 Comparison of average forecast accuracy and average training time of each model

模型	GD-BP	SVM	BL	SVDBL
平均准确率/%	91.92	92.37	93.49	93.52
平均训练时间/s	26.2906	18.1659	1.8013	0.9039

表 5 四种模型部分预报结果

Tab. 5 Partial forecast results of four models

样本	1	2	3	4	5	...	200
GD-BP	1.64	2.50	3.88	4.21	6.70	...	86.99
SVM	1.63	1.93	3.85	4.31	5.69	...	88.89
BL	1.52	2.33	3.96	4.02	5.17	...	88.65
SVDBL	1.50	2.44	3.90	4.17	5.24	...	88.30
实际结果/%	1.58	2.41	3.88	4.27	5.19	...	88.53

结合表 4 和表 5 不难看出,在预报准确率方面,SVDBL 比 GD-BP 高出 1.60%,比 SVM 高出 1.15%,和 BL 相比基本持平。从训练时间上看,SVDBL 比 GD-BP 快 25.3867 s,比 SVM 快 17.2620 s,比 BL 快 0.8974s。由此可见,SVDBL 能够正确预报泥石流灾害发生的概率,同时在训练时间上 SVDBL 比其他模型快很多。

另外,通过 ROC 曲线(接受者操作特征曲线)对模型进行验证,如图 6 和表 6 所示,本文提出的模型平均 AUC 值为 93.18%,比 GD-BP 模型和 SVM

模型的 AUC 值高。和 BL 模型相比,优化后的 SVDBL 模型的 AUC 值更高,测试时间上也优于 BL 模型。可见,将 SVDBL 模型用于泥石流灾害预报是可行的,且具有良好的预报效果和运行速度。




图 6 四种模型平均 ROC 曲线

Fig. 6 Average ROC curves of four models

表 6 平均 ROC 曲线对比

Tab. 6 Comparison of average ROC curves

模型	平均 AUC 值/%	平均测试时间/s
GD-BP	91.44	0.0818
SVM	91.59	0.0048
BL	92.52	0.0024
SVDBL	93.18	0.0011

为了验证 SVDBL 模型的在线训练能力,将训练样本在原先 1800 组数据的基础上,扩充至 1900 组,重新对各模型进行训练,并对训练结果进行了比较(见表 7)。表 7 的对比结果显示,训练样本扩展之后,GD-BP 模型的平均训练时间增加了 4.7136 s, SVM 模型增加了 2.6927 s, BL 模型增加了 0.2022 s, SVDBL 仅增加了 0.0047 s。SVDBL 模型在训练样

表 7 训练样本扩展前后结果对比

Tab. 7 Comparison of results before and after training sample expansion

模型	训练样本扩展前 训练时间/s	训练样本扩展后 训练时间/s
GD-BP	26.2475	30.9594
SVM	18.2962	20.9901
BL	1.8023	2.0041
SVDBL	0.9037	0.9083



本扩展之后,其平均训练时间几乎没有变化。这表明,优化后的 SVDBL 模型拥有强大的在线训练能力,以上数据只是在样本扩展了 100 个数据集情况下的结果,当训练样本的规模进一步扩大时,SVDBL 的优势将更加明显。

为了验证本文提出的模型中引入 FMPCE 算法的有效性,通过人为的方式分别选取 4 组不同的影响因子(见表 8,表中序号表示的影响因子详见 3.2 小节)对模型的预报结果进行仿真验证,部分结果如图 8 所示。

表 8 影响因子与图 7 中的曲线对应关系

Tab. 8 Correspondence between the influence factor and the curve in Fig. 7

人为选取的影响因子	图 7 中对应曲线
①、②、③、⑦、⑧、⑫	b
①、②、③、④、⑤、⑦	c
①、②、⑦、⑩、⑫、⑭	d
①、③、⑥、⑦、⑩、⑭	e

图 7 中,曲线 a 表示实际结果,曲线 f 表示通过 FMPCE 算法提取影响因子的预报结果,其余预报结果曲线对应的影响因子如表 8 所示。通过对图 7 中各曲线的对比可见,曲线 f 相对于曲线 b、c、d、e 而言更接近于曲线 a,即由 FMPCE 算法提取的影响因子比人为选取影响因子的预报结果更接近实际值,这也表明本文所采用的提取影响因子的方法能够克服人们主观因素的影响,比仅仅通过人为方式选取影响因子的方法更加有效。




图 7 不同影响因子预报结果对比

Fig. 7 Comparison of forecast results of different influence factors

4 结论与讨论

本文基于 FMPCE 算法和宽度学习建立了泥石流灾害预报模型,对泥石流的发生概率进行预报。分析了泥石流成灾因子与灾害发生概率之间的关系,并进行了仿真验证,同时将本文所采用的算法与梯度下降法优化的 BP 神经网络预报模型、基于支持向量机的预报模型、基于宽度学习预报模型的结果分别进行了对比。

(1)从不同维度的影响因子对模型预报准确率的影响可以看出:泥石流形成过程中,影响其发生概率的主要因素除了常见的山坡坡度、沟床比降和相对高差等地形因素之外,同时还与传感器采集的降雨量、土壤含水率和孔隙水压力等因素密切相关。

(2)泥石流灾害是在降雨、地理因素、人文因素等多种因素共同作用下形成的具有显著非线性特性的复杂系统。所以,将 FMPCE 算法和宽度学习模型相结合的方法应用到泥石流灾害预报模型中,相比以往单一运用神经网络、层次分析和模糊可拓理论等方法而言,不仅可以揭示各影响因子间的复杂性和模糊性,而且能较为客观地反映出各影响因子与泥石流灾害的联系,最大限度地降低主观因素的影响。

(3)矩阵随机近似 SVD 优化了宽度学习的隐含层输入矩阵,有效地避免了随机初始化可能造成的矩阵结构冗余的不足,极大提升了泥石流预报模型的训练速度,为实际应用中的泥石流灾害预警系统的在线训练提供了有效支持。

(4)通过验证样本集进行了验证,较高的准确率和 AUC 值,以及快速的训练和预报速度,都表明将该模型用于泥石流灾害的概率预报是可行的,并且为泥石流预报在实际应用方面提供了新的思路。

(5)由于形成泥石流的自然环境和地区有较大的联系,因此,本文所提出的模型还需要进一步优化和完善,以便更好地应用于其它泥石流地区。

参考文献 (References)

[1] 刘永奎,第宝锋,詹宇,等. 基于随机森林模型的泥石流易发性评价—以汶川地震重灾区为例[J]. 山地学报,2018,36(5): 765–773. [LIU Yongyao, DI Baofeng, ZHAN Yu, et al. Debris flows susceptibility assessment in Wenchuan earthquake areas based

- on random forest algorithm model [J]. Mountain Research, 2018, **36** (5): 765 - 773]
- [2] 李璐, 温宗周, 张阳阳, 等. 基于 RBF 神经网络滑坡灾害发生概率预报方法[J]. 西安工程大学学报, 2017, **31** (4): 521 - 526. [LI Lu, WEN Zongzhou, ZHANG Yangyang, et al. Probability prediction method of landslide disaster based on RBF neural network [J]. Journal of Xi'an Polytechnic University, 2017, **31** (4): 521 - 526]
- [3] 屈永平, 肖进, 潘义为. 藏东南地区冰川泥石流形成条件初步分析—以天摩沟冰川泥石流为例[J]. 水利水电技术, 2018, **49** (12): 177 - 184. [QU Yongping, XIAO Jin, PAN Yiwei. Preliminary analysis on formation conditions of glacier debris flow in Southeast Tibet—a case of glacial debris flow in Tianmo Gully [J]. Water Resources and Hydropower Engineering, 2018, **49** (12): 177 - 184]
- [4] 冯杭建, 周爱国, 唐小明, 等. 浙江省泥石流灾害发育分布规律及区域预报[J]. 地球科学, 2016, **41** (12): 2088 - 2099 [FENG Hangjian, ZHOU Aiguo, TANG Xiaoming, et al. Development and distribution characteristics of debris flow in Zhejiang Province and Its Regional Forecast [J]. Earth Science, 2016, **41** (12): 2088 - 2099]
- [5] 王高峰, 杨强, 田运涛, 等. 泥石流易发性评价模型的构建—以白龙江流域石门乡羊汤河段为例[J]. 干旱区研究, 2019, **36** (3): 761 - 770. [WANG Gaofeng, YANG Qing, TIAN Yuntao, et al. Establishment of assessment model for debris flow susceptibility: a case study along the Yangtang River Reach in Shimen township in the Bailong River Basin [J]. Arid Zone Research, 2019, **36** (3): 761 - 770]
- [6] 李丽敏, 程少康, 温宗周, 等. 基于改进 KPCA 与混合核函数 LSSVR 的泥石流预测[J]. 信息与控制, 2019, **48** (5): 536 - 544 [LI Limin, CHENG Shaokang, WEN Zongzhou, et al. A debris flow prediction model based on the improved KPCA and Mixed Kernel function LSSVR [J]. Information and Control, 2019, **48** (5): 536 - 544]
- [7] 李秀珍, 孔纪名, 李朝凤. 多分类支持向量机在泥石流危险性区划中的应用[J]. 水土保持通报, 2010, **30** (5): 128 - 133 + 157. [LI Xiuzhen, KONG Jiming, LI Chaofeng. Application of multi-classification support vector machine in regionalization of debris flow hazards [J]. Bulletin of Soil and Water Conservation, 2010, **30** (5): 128 - 133 + 157]
- [8] 张晨, 王清, 张文, 等. 基于神经网络对泥石流危险范围的研究[J]. 哈尔滨工业大学学报, 2010, **42** (10): 1642 - 1645. [ZHANG Chen, WANG Qing, ZHANG Wen, et al. Prediction on hazardous areas of debris flow based on neural network [J]. Journal of Harbin Institute of Technology, 2010, **42** (10): 1642 - 1645]
- [9] 曹禄来, 徐林荣, 陈舒阳, 等. 基于模糊神经网络的泥石流危险性评价[J]. 水文地质工程地质, 2014, **41** (2): 143 - 147. [CAO Lulai, XU Linrong, CHEN Shuyang, et al. Debris flow risk assessment based on fuzzy neural network [J]. Hydrogeology and Engineering Geology, 2014, **41** (2): 143 - 147]
- [10] 谢涛, 尹前鋒, 高贺, 等. 基于激发条件和堆积体稳定性的冰川降雨型泥石流预警模型研究[J]. 冰川冻土, 2019, **41** (4): 884 - 891. [XIE Tao, YIN Qianfeng, GAO He, et al. Study on early warning model of glacial-rainfall debris flow based on excitation condition and stability of accumulation body [J]. Journal of Glaciology and Geocryology, 2019, **41** (4): 884 - 891]
- [11] 郭瑞, 彭杨宏, 王其杰, 等. 基于灰色关联法的泥石流灾害易发性影响因素分析—以甘肃舟曲瓜哇沟泥石流为例[J]. 地质论评, 2018, **64** (6): 1481 - 1488 [GUO Rui, PENG Yanghong, WANG Qijie, et al. analysis on hazard evaluation of debris flow based on grey relational theory—a case study on the debris flow in Guaza Gully, Zhouqu, Gansu [J]. Geological Review, 2018, **64** (6): 1481 - 1488]
- [12] 刘双, 余斌, 马二龙, 等. 山西省平定县寨坪沟泥石流灾害特征及预警[J]. 泥沙研究, 2018, **43** (6): 61 - 66. [LIU Shuang, YU Bin, MA Erlong, et al. Study on early warning of debris flow disaster in Zhaiping Gully in Shanxi Province [J]. Journal of Sediment Research, 2018, **43** (6): 61 - 66]
- [13] 吴赛儿, 陈剑, ZHOU Wendy, 等. 基于逻辑回归模型的泥石流易发性评价与检验: 以金沙江上游奔子栏—昌波河段为例[J]. 现代地质, 2018, **32** (3): 611 - 622. [WU Saier, CHEN Jian, WENDY Zhou, et al. Debris-flow susceptibility assessment and validation based on logistic regression model: an example from the Benzilan-Changbo segment of the upper Jinshajiang River [J]. Geoscience, 2018, **32** (3): 611 - 622]
- [14] 黄启乐, 陈伟, 傅旭东. 斜坡单元支持下区域泥石流危险性 AHP-RBF 评价模型[J]. 浙江大学学报(工学版), 2018, **52** (9): 1667 - 1675. [HUANG Qile, CHEN Wei, FU Xudong. AHP-RBF assessment model of regional debris flow hazard supported by unit slope [J]. Journal of Zhejiang University (Engineering Science), 2018, **52** (9): 1667 - 1675]
- [15] CHEN C L P, LIU Zhulin. Broad learning system: an effective and efficient incremental learning system without the need for deep architecture. IEEE Transactions on Neural Networks and Learning Systems, 2018, **29** (1): 10 - 24.
- [16] 孔令智, 高迎彬, 李红增, 等. 一种快速的多个主成分并行提取算法[J]. 自动化学报, 2017, **43** (5): 835 - 842. [KONG Lingzhi, GAO Yingbin, LI Hongzeng, et al. A fast parallel extraction algorithm for multiple principal components [J]. Acta Automatica Sinica, 2017, **43** (5): 835 - 842]
- [17] HALKO N, MARTINSSON P G. TROPP J A. Finding structure with randomness: stochastic algorithms for constructing approximate matrix decompositions [J]. Journal SIAM Review, 2011, **53**: 217 - 288.
- [18] 彭贵芬, 刘盈曦. 基于模糊信息概率区间数的突发地质灾害降水因子评价研究[J]. 灾害学, 2015, **30** (1): 1 - 4. [CHEN Guifen, LIU Yingbiao. Evaluation of precipitation factors of sudden geological disasters based on probability interval number of fuzzy information [J]. Journal of Catastrophology, 2015, **30** (1): 1 - 4]

- [19] 赵岩. 流域发育程度遥感反演及其在泥石流预报中的应用 [D]. 中国科学院大学, 2012: 15 – 30. [ZHAO Yan. Remote sensing inversion of watershed development degree and its application in debris flow forecasting [D]. University of Chinese Academy of Sciences, 2012: 15 – 30]
- [20] 方成杰, 钱德玲, 徐士彬, 等. 基于云模型的泥石流易发性评价 [J]. 合肥工业大学学报 (自然科学版), 2017, **40**(12): 1659 – 1665. [FANG Chengjie, QIAN Deling, XU Shibin, et al. Evaluation of debris flow susceptibility based on cloud model [J]. Journal of Hefei University of Technology (Natural Science), 2017, **40**(12): 1659 – 1665]

## Debris Flow Disaster Prediction Based on Broad Learning Model

XU Genqi, LI Limin<sup>\*</sup>, WEN Zongzhou, LIU Deyang, CHENG Shaokang

(College of Electronic Information, Xi'an Polytechnic University, Xi'an 710048, China)

**Abstract:** In the study of debris flow disaster forecasting model, it is a key problem to scientifically determine the influencing factors of debris flow disasters and ensure the higher forecast accuracy and fast training speed of the model, which is also an important foundation for debris flow disaster forecasting and early warning and disaster prevention and mitigation as well. Aiming at the problems of large dimension of input data and long training time of current debris flow prediction models, this paper used a fast-multiple principle components extraction algorithm (FMPCE) to select 6 influence factors of debris flow disaster, including rainfall volume, hillside slope, ditch bed ratio, relative height difference, soil moisture content and pore water pressure. Based on the broad learning (BL) algorithm, the influence factors of debris flow were taken as inputs and debris flow occurrence probability as output to construct a debris flow forecasting model, and the model was optimized by using matrix random approximate singular value decomposition (matrix random approximation SVD). The prediction results of the optimized broad learning model were compared with the results of the BP neural network prediction model (GD-BP) optimized by the gradient descent method, the support vector machine-based prediction model (SVM), and the broad learning prediction model (BL). At the same time, through the expansion of the input data set, different models were compared from the training time. The results showed that the prediction accuracy of the optimized broad learning debris flow disaster prediction model was 93.52%, which was 1.60%, 1.15%, and 0.03% higher than the prediction accuracy of the GD-BP model, the SVM model, and the BL model; The training time of the optimized broad learning debris flow disaster prediction model was 0.9039 s, which saved 25.3867 s, 17.2620 s, and 0.8974 s compared with the training time of the GD-BP model, SVM model, and BL model, respectively, which showed that the broad learning algorithm can be used to predict the occurrence probability of debris flow disasters, and provided a new idea for the practical application of debris flow prediction as well.

**Key words:** broad learning algorithm; debris flow; forecasting model; singular value decomposition