DOI:10.14048/j.issn.1671－2579.2019.03.001

基于自然选择策略的PSO－BP神经网络的滑坡可靠性评价方法

王彪龙[1]，孟凡利[2]，曾超[2]，郭将[1]，刘晓[1*]
（1.中国地质大学（武汉）教育部长江三峡库区地质灾害研究中心，湖北 武汉 430074；
2.中交第二公路勘察设计研究院有限公司）

摘要：将BP神经网络良好的非线性函数拟合能力，以及粒子群算法（PSO）良好的非线性优化性能相结合，提出一种基于自然选择策略的PSO－BP神经网络的滑坡可靠性评价新方法。新方法的整体布局是以BP神经网络作为滑坡可靠性分析的响应面函数，在内部实现细节上，针对传统BP神经网络权值和阈值更新过程中容易陷入局部最优特点，采用自然选择粒子群算法来替代标准BP神经网络内置的最速梯度下降法，以达到进一步优化网络的目的。以贵州省马达岭HP1滑坡为例，验证该方法的优越性，结果证明：① 该文提出的自然选择PSO－BP算法全局拟合能力更强，构造出的响应面误差更小；② 降雨对于该边坡可靠性的影响小于地震，敏感性低；③天然工况下的HP1处于稳定状态，饱和、天然地震工况下处于低危险状态。

关键词：BP神经网络；自然选择粒子群算法；蒙特卡洛法；可靠性；敏感性

1 引言

在边（斜）坡稳定性评价中，由于岩土体参数（如黏聚力c、内摩擦角φ等）存在着不确定性，而传统的确定性分析往往难以满足实际的需要，所以应综合考虑各种不确定性因素，对其进行可靠性分析。传统的可靠性求解方法有蒙特卡洛法（Monte Carlo Simulation，MCS）、一次二阶矩法（First Order Second Moment Method，FOSM）等，其中蒙特卡洛法需大量抽样，而每一次抽样均需对应一次完整的边坡稳定性分析隐式过程，因此总体计算量大，但其优点在于概念明确，可用来检验其他计算方法的精度。

响应面法包括多项式函数、支持向量机、BP（Back Propagation）神经网络等。其中BP神经网络具有较高的拟合精度和自适应性，在函数拟合、数据预测方面运用广泛。但是，基本BP神经网络容易陷入局部极值点，同时收敛速度也较慢。为此，众多学者对基本BP神经网络进行了改进，如将粒子群算法用于BP神经网络权值和阈值的寻优，主要包括：① 运用粒子群算法先优化得到一组较好的权值和阈值，作为BP神经网络的初始权值和阈值，而后采用BP神经网络内置的最速梯度下降法继续寻优，得到最优权值和阈值。该类方法由于梯度下降法是一种局部优化方法，最后所得的权值和阈值并非全局最优；② 将粒子群优化算法完全替换BP神经网络内置的最速梯度下降法，以期得到BP神经网络的最优权值和阈值。相比于第①类方法，第②类方法充分发挥了粒子群算法的全局寻优能力，可以以更小的误差搜索到最优权值和阈值。但是基本粒子群算法本身也存在不足，容易过早地收敛于局部最优解，此时的权值和阈值只是局部极小值点，并非全局最小值点。

鉴于此，该文在第②类方法的基础上做进一步改进，在基本粒子群算法中引入自然选择算子，按照自然选择机理，将粒子群体的目标函数值从小到大排序，并将前半部分粒子的位置和速度赋予后半部分粒子，对

收稿日期：2018－05－09
基金项目：国家自然科学基金资助项目（编号：41572279）；中国博士后科学基金特别资助项目（编号：2014T70758）；中国博士后科学基金资助项目（编号：2012M521500）；中央高校基本科研业务费专项资金资助项目（编号：CUGL170212）
作者简介：王彪龙，男，硕士研究生.Email：wblstudycug@yeah.net
*通信作者：刘晓，男，博士，副研究员.E－mail：liuxiao@china.com

粒子群算法进行改进，用于 BP 神经网络权值和阈值的更新，搜索其最优解，从而形成基于自然选择 PSO－BP 神经网络算法，用于拟合自变量（黏聚力、内摩擦角）和因变量（稳定系数）的近似函数关系，构造功能函数，同时将上述神经网络算法和蒙特卡洛法相结合，求取可靠度指标 β 和失效概率 P_f。最后以贵州省马达岭 HP1 滑坡为例，验证上述理论和方法的有效性。

2 BP 神经网络的改进策略

2.1 BP 神经网络基本原理

BP 神经网络是一种信号向前传播、误差反向传播的多层前馈神经网络。基本的 BP 神经网络有 3 层，即输入层、输出层和隐含层，其拓扑结构如图 1 所示。

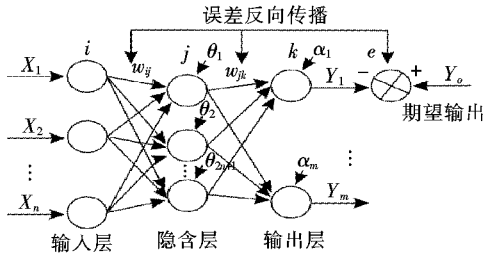

图 1 3 层 BP 神经网络拓扑结构

图中：$2n+1$ 为隐含层的节点数；w_{ij}（$i=1,2,\cdots,n$；$j=1,2,\cdots,2n+1$）为输入层到隐含层的连接权值；w_{jk}（$j=1,2,\cdots,2n+1$；$k=1,2,\cdots,m$）为隐含层到输出层的连接权值；θ_j 为隐含层的阈值；α_k 为输出层的阈值；$X=[X_1,X_2,\cdots,X_n]^{\mathrm{T}}$ 为输入变量组成的向量；$Y=[Y_1,Y_2,\cdots,Y_m]^{\mathrm{T}}$ 为输出向量；e 为预测输出与期望输出的误差。

传统的 BP 神经网络基于最速梯度下降法来调整网络的权值和阈值，使得网络的预测输出不断地逼近期望输出，误差最小。

2.2 采用更高阶方法调整权值和阈值的可行性

由于 BP 神经网络对其权值和阈值的初始设置较为敏感，并且可能因为初始参数设置的随机性而造成误差较大。本质上 BP 神经网络权值和阈值的调整是一个最优化问题，可表示为：

$$\min G(w,\theta,\alpha)=\frac{1}{n}\sum_{s=1}^{n}\sum_{k=1}^{m}(Y_k^s-\overline{Y}_k^s)^2 \tag{1}$$

式中：

$$w=[w_{11},w_{12},\cdots,w_{ij},w_{11},w_{12},\cdots,w_{jk}]^{\mathrm{T}}\quad w\subset R \tag{2}$$

$$\theta=[\theta_1,\theta_2,\cdots,\theta_{2n+1}]^{\mathrm{T}}\quad \theta\subset R \tag{3}$$

$$\alpha=[\alpha_1,\alpha_2,\cdots,\alpha_m]^{\mathrm{T}}\quad \alpha\subset R \tag{4}$$

$$\overline{Y}_k^s=f_2\Big[\sum_{j=1}^{2n+1}w_{jk}\times f_1\Big(\sum_{i=1}^{n}w_{ij}X_i-\theta_j\Big)-\alpha_k\Big] \tag{5}$$

式中：f_1、f_2 为隐含层、输出层节点的传递函数；Y_k^s 为网络的期望输出。

虽然 BP 神经网络内置的最速梯度下降法也是一种通用的非线性优化方法，然而当前在非线性优化方法领域，一系列智能算法显示出更好的全局寻优性能。因此，基于模块化的理论，采用更高阶的优化方法来替换传统 BP 神经网络内置的最速梯度下降法，进行算法升级，以期获得更佳的性能，这是一个可行的方案。

3 采用自然选择策略的粒子群算法优化 BP 神经网络的权值和阈值

3.1 粒子群算法基本原理

对形如式(1)的优化问题，其以 BP 神经网络的权值和阈值为自变量，以 BP 神经网络的预测输出和期望输出的误差平方和为目标函数，通过寻找 BP 神经网络权值和阈值的最优组合，使目标函数达到最小。鉴于粒子群算法具有很好的全局搜索能力，该文选用粒子群算法寻优。在 D 维搜索空间中，假定粒子 i 的位置为 $X_i=(x_{i1},x_{i2},\cdots,x_{iD})$，速度 $V_i=(v_{i1},v_{i2},\cdots,v_{iD})$，通过粒子个体最优位置 *pbest* 和粒子群体最优位置 *gbest* 的比较，粒子 i 更新自己的位置和速度：

$$V_{i,j}(t+1)=w\times V_{i,j}(t)+c_1r_1[pbest-X_{i,j}(t)]+c_2r_2[gbest-X_{i,j}(t)] \tag{6}$$

$$X_{i,j}(t+1)=X_{i,j}(t)+V_{i,j}(t+1) \tag{7}$$

$$w=w_{\max}-(t-1)(w_{\max}-w_{\min})\times(maxgen-1) \tag{8}$$

式中：w 为惯性权重，$w_{\max}=0.9$，$w_{\min}=0.4$；t 为当前迭代次数；*maxgen* 为最大迭代次数；c_1，c_2 为学习因子，$c_1=c_2=2$；r_1，r_2 为[0，1]之间的随机数。

3.2 基于自然选择策略的算法改进

基本粒子群算法在寻优过程中如若搜索到一个局部最优解，则剩余所有粒子往往向其靠拢，出现过早收敛局部最优的情况。借鉴遗传算法中的选择思想，在基本粒子群算法之上引入自然选择算子，按照自然选择机理，在每次迭代寻优过程中，将粒子群体的目标函数值从小到大排序，并将其中前半部分粒子对应的位置和速度赋予后半部分粒子，且每个粒子保留以往的最优函数值，这样即可增加粒子群体中靠近最优解粒

子所占的百分比，使每次迭代的粒子都具有较好的性能，提高收敛速度，从而形成基于自然选择策略的混合粒子群算法。对于当前迭代次数 t，将所有粒子的目标函数值排序：

$$[a,b]=sort(G) \tag{9}$$

$$Index=round[(N-1)/2] \tag{10}$$

$$X\{b[(N-Index+1):N]\}=X[b(1:N)] \tag{11}$$

$$V\{b[(N-Index+1):N]\}=V[b(1:N)] \tag{12}$$

式中：$sort$ 为升序排列函数；N 为粒子的个数。

3.3　自然选择粒子群算法优化权值和阈值

采用自然选择粒子群算法对式(1)的优化目标函数进行优化。将 BP 神经网络的权值和阈值作为待优化的变量，其构成的向量表示成粒子 i 的位置向量 $X_i=(x_{i1},x_{i2},\cdots,x_{iD})$，$D$ 为 BP 神经网络权值和阈值的总个数，式(1)作为自然选择粒子群算法待优化的目标函数。对于 n 个训练样本(输入变量为黏聚力、内摩擦角，输出变量为稳定系数)，在确定 BP 网络的拓扑结构后，可将粒子群算法产生的初始位置(权值和阈值)赋予 BP 神经网络，并依据训练样本数据，BP 神经网络计算式(1)所示的目标函数，将该值返回给粒子群算法中的粒子，粒子通过目标函数值的比较，确定当前粒子群体中的全局最小值及最优位置，并判断是否达到最大迭代次数。若未达到最大迭代次数，粒子依据式(6)～(12)，进行位置(权值和阈值)更新，并将其赋予 BP 神经网络的权值和阈值，继续计算式(1)的目标函数，返回给粒子。如此循环，直至达到最大迭代次数。将此时自然选择粒子群算法搜索到的最优权值和阈值赋予 BP 神经网络。

4　采用基于自然选择 PSO－BP 神经网络构造功能函数

滑坡可靠性分析的重点之一是提取功能函数 $g(X)$，这是从物理模型到数学模型概化的关键一步。假设可靠性分析中存在 n 个随机变量，稳定系数 fos 是 n 个随机变量 $x_1,x_2,\cdots,x_n$ 的函数，令 $X=[x_1,x_2,\cdots,x_n]^{\mathrm{T}}$，记为 $fos(X)$。则功能函数可表示为 $g(X)=fos(X)-1$。上述功能函数 $g(X)$ 是隐式的，且具有显著的非线性。针对这一情况，该文采用自然选择 PSO－BP 神经网络构造功能函数。将可靠性分析的随机变量(如黏聚力、内摩擦角)作为输入变量，$g(X)$ 作为输出变量。基于均匀设计法取样，构造功能函数。

5　基于自然选择 PSO－BP 神经网络滑坡可靠性计算流程

采用自然选择 PSO－BP 神经网络构造功能函数，并和蒙特卡洛法(MCS)相结合，计算滑坡的可靠度指标 β 和失效概率 P_f。基本步骤如下：

(1) 数据预处理。确定滑坡可靠性分析随机变量(如黏聚力、内摩擦角)的个数，采用均匀设计法构造 n 个样本。基于此样本，采用 SLOPE/W(稳定性计算方法为 Morgenstern－Price 法)计算 n 个样本的稳定系数 fos，并将其数值减一。将上述样本作为训练样本，为消除各变量之间数据的量级影响，采用 mapminmax 函数统一进行标准化。

(2) 初始化 BP 神经网络。确定 BP 网络的拓扑结构、神经元传递函数。该文采用 $n-2n+1-m$ 的三层神经网络，则粒子的维度 D 采用下式计算：

$$D=n\times(2n+1)+(2n+1)\times m+(2n+1)+m \tag{13}$$

对于该 BP 神经网络，输入层至隐含层的传递函数选用 logsig 函数，隐含层至输出层的传递函数选用 purelin 函数。

$$\mathrm{logsig}(x)=\frac{1}{1+\mathrm{e}^{-x}} \tag{14}$$

$$\mathrm{purelin}(x)=x \tag{15}$$

(3) 确定粒子群的基本参数。包括粒子数 N、迭代次数 $maxgen$ 等，并同时初始化各粒子的飞行速度和位置(权值和阈值组成的向量)。

(4) 将粒子初始位置赋予 BP 神经网络，并计算式(1)的目标函数，将其赋予粒子 i，同时将粒子当前个体最优位置赋予 $pbest$，整个粒子群当前最优位置赋值于 $gbest$，全局最小目标函数值赋予 $fitnessbest$。

(5) 判断是否达到最大迭代次数。若满足，则将此时的权值和阈值赋予 BP 神经网络，执行步骤(9)～(10)。否则，执行步骤(6)～(8)。

(6) 对于粒子 i，依据式(6)、(7)更新其速度和位置。

(7) 将粒子 i 新目标函数值和以往最小目标函数值相比较，若新目标函数值较小，则将其替换以往目标函数值，并将此时的最优位置替代 $pbest$。同时，将新目标函数值和以往全局最小目标函数值 $fitnessbest$ 相比较，若新目标函数值较小，则将其作为新的 $fitnessbest$，并将此时的位置替换 $gbest$。

(8) 依据自然选择机理，将当前所有粒子的新目标函数值按从小到大排序，并将前半部分粒子对应的位置和速度赋予后半部分粒子，且每个粒子保留当前的最优函数值，并返回步骤(5)。

(9) 据随机变量的分布形式，随机生成 Q 组数据用于测试 BP 神经网络，并计算期望输出与预测输出的绝对误差和，进行拟合精度分析。

(10) 基于训练好的 BP 神经网络，依据随机变量的分布形式，生成 M 组随机变量，并将其运用于神经网络的输出计算，统计其中小于零的个数 P。当 M 足够大时，依据式(16)、(17)计算失效概率 P_f 和 β。

$$P_f=\frac{P}{M} \tag{16}$$

$$\beta=\Phi^{-1}(1-P_f) \tag{17}$$

式中：Φ 为标准正态分布函数。

自然选择 PSO－BP 神经网络可靠度计算流程见图 2。

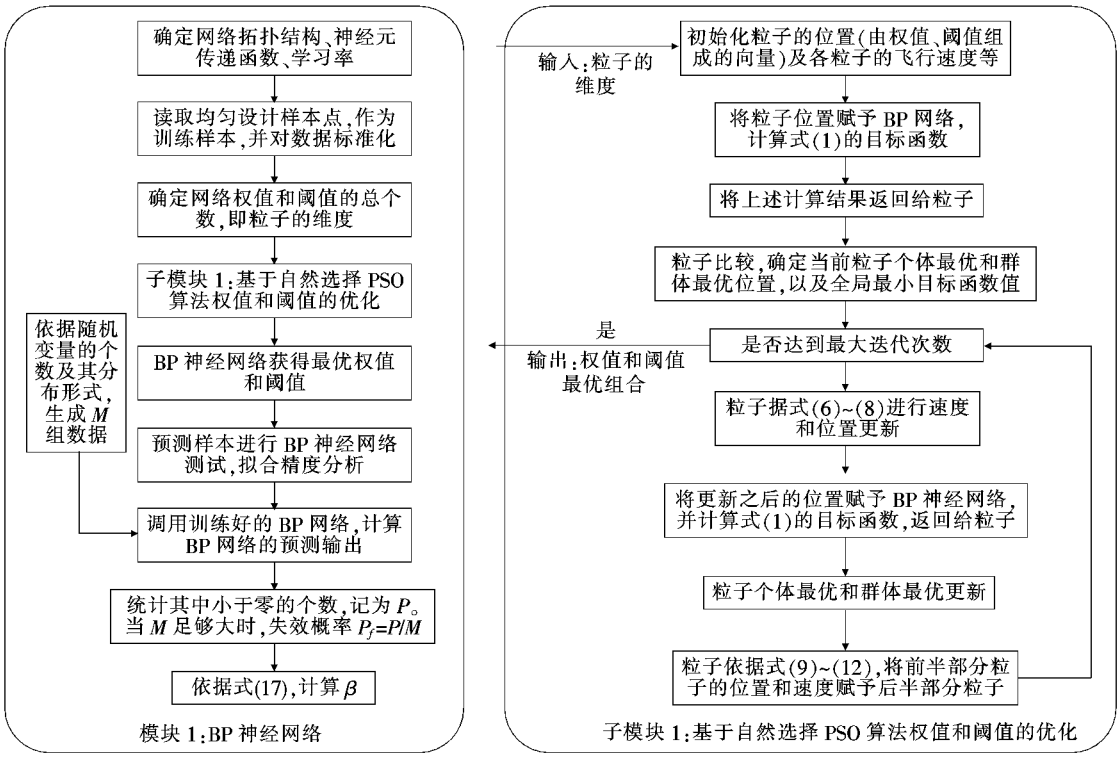

图 2 自然选择 PSO－BP 神经网络可靠度计算流程图

6 实例分析

为验证基于自然选择策略 PSO－BP 神经网络的全局拟合能力，采用贵州省马达岭 HP1 滑坡为例进行分析。基于自然选择 PSO－BP 神经网络构造功能函数，并结合蒙特卡洛法，计算该滑坡 4 种工况下的可靠性指标，而后对其稳定状态做出评价。

6.1 马达岭滑坡基本特征

马达岭滑坡位于贵州省都匀市南西方向，直线距离约 24 km，地理坐标为东经 107°17′48″，北纬 26°11′01″。依据斜坡变形破坏特征，将斜坡区域分为已滑滑坡 HP1、HP1 滑坡堆积体经降雨搬运后的泥石流 NSL1 区域、滑坡隐患 DY208－1 三部分。

斜坡为一平缓反倾斜横向坡，上陡下缓。岩层近南北走向，缓倾向坡内，呈软硬互层结构。斜坡上覆第四纪残坡积土，陡崖下部分布有以砂岩、泥岩为主的崩坡积物，冲沟中为第四纪冲洪积层。基岩出露地层自上而下分别为细粒石英砂岩、炭质页岩和煤层，灰色中厚层状粗晶生物灰岩夹细粒石英砂岩，细晶灰岩和泥盆系上统高坡场组细晶白云岩。

马达岭滑坡位于都匀至香格里拉高速公路原有规划线上，且该滑坡前缘距离规划线路较近。由于滑坡主要物质成分为砂岩、页岩及煤层，结构松散，且由于煤层开采，在坡顶形成裂缝，变形严重，在极端降雨条件下滑坡可能失稳，对原有线路造成威胁。为此该文

取 HP1 滑坡为可靠性分析对象，其地质剖面如图 3 所示。

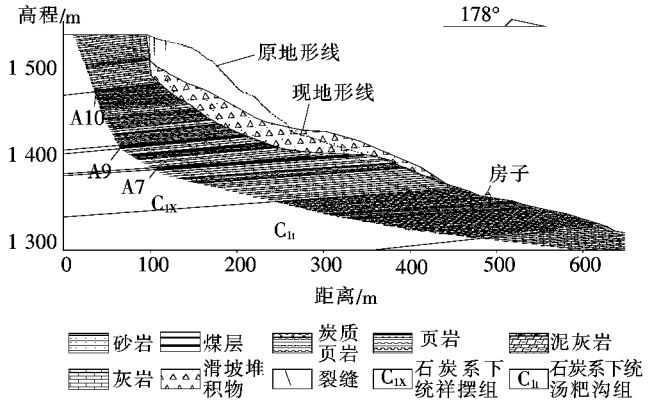

图 3　马达岭 HP1 滑坡地质剖面

6.2　马达岭滑坡岩土体物理力学参数

结合已有研究成果和现场调查，将岩土体参数进行一定折减，得马达岭滑坡 HP1 各个层位岩土体的物理力学参数值，见表 1。

表 1　HP1 滑坡岩土体物理力学参数

岩土体	天然/饱和			变异系数
	黏聚力/kPa	内摩擦角/(°)	重度/(kN·m^{-3})	
碎石土	20/18	22/20	25/26	$\delta_c=\delta_\varphi=0.1$
石英砂岩	500/400	25/24	25/26	$\delta_c=\delta_\varphi=0.1$
炭质页岩	200/160	16/15	24/25	$\delta_c=\delta_\varphi=0.1$
煤层	150/120	16/15	20/21	$\delta_c=\delta_\varphi=0.1$
基岩	2 000/1 900	35/34	26/27	$\delta_c=\delta_\varphi=0.1$

对马达岭 HP1 滑坡地质剖面进行简化，不考虑裂缝的影响，选取表 1 各土层天然状态下的物理力学参数作为材料参数，采用 SLOPE/W（计算方法为 M－P 法）进行计算，预置搜索的滑面为 10 000 条。经计算，得临界滑动面的位置（图 4），滑面为近似圆弧形，据此滑面作可靠性分析。

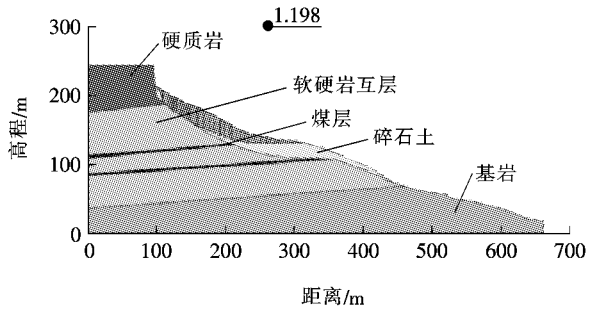

图 4　马达岭 HP1 滑坡临界滑动面计算结果

为考虑地震对 HP1 滑坡稳定性的影响，结合地震相关规范和现场调查，取地震动水平加速度为 0.05g，相应的地震基本烈度为Ⅵ度，采用拟静力法对其进行分析。分别计算 HP1 滑坡在天然、天然＋地震、饱和、饱和＋地震 4 种工况下的可靠度指标 β 和失效概率 P_f。

6.3　基于均匀设计法取样

将碎石土的黏聚力 c 值和内摩擦角 φ 值考虑为随机变量，且服从独立正态分布，其均值和变异系数采用表 1 的数据，而其余变量视为确定性变量。依据随机变量的取值区间[$\mu-3\sigma$，$\mu+3\sigma$]生成 20 组样本，并基于均匀设计法取样，而后将上述样本点采用 SLOPE/W 计算稳定性系数 fos，计算方法为 M－P 法，假设土体的破坏服从 Mohr－Coulomb 准则，同时将其数值减 1，得 20 组训练样本，如表 2 所示。

表 2　均匀设计样本

序号	黏聚力 c/kPa	内摩擦角 φ/(°)	$fos-1$ 工况Ⅰ	$fos-1$ 工况Ⅱ	序号	黏聚力 c/kPa	内摩擦角 φ/(°)	$fos-1$ 工况Ⅲ	$fos-1$ 工况Ⅳ
1	14.00	20.96	0.096	−0.031	1	12.60	19.05	−0.016	−0.130
2	14.63	27.21	0.438	0.270	2	13.17	24.74	0.285	0.135
3	15.26	19.57	0.035	−0.084	3	13.74	17.79	−0.070	−0.178
4	15.89	25.82	0.370	0.211	4	14.31	23.47	0.225	0.083
5	16.53	18.18	−0.024	−0.137	5	14.87	16.53	−0.123	−0.224
6	17.16	24.43	0.304	0.153	6	15.44	22.21	0.168	0.032
7	17.79	16.79	−0.082	−0.188	7	16.01	15.26	−0.176	−0.271
8	18.42	23.04	0.240	0.097	8	16.58	20.95	0.111	−0.018
9	19.05	15.40	−0.139	−0.238	9	17.15	14.00	−0.227	−0.316
10	19.68	21.65	0.177	0.041	10	17.72	19.68	0.055	−0.067
11	20.32	27.91	0.523	0.347	11	18.28	25.37	0.359	0.201

续表 2

序号	黏聚力 c/kPa	内摩擦角 φ/(°)	$fos-1$ 工况Ⅰ	$fos-1$ 工况Ⅱ	序号	黏聚力 c/kPa	内摩擦角 φ/(°)	$fos-1$ 工况Ⅲ	$fos-1$ 工况Ⅳ
12	20.95	20.26	0.116	−0.012	12	18.85	18.42	0.001	−0.115
13	21.58	26.52	0.455	0.286	13	19.42	24.11	0.299	0.149
14	22.21	18.87	0.056	−0.065	14	19.99	17.16	−0.053	−0.162
15	22.84	25.13	0.388	0.228	15	20.56	22.84	0.240	0.097
16	23.47	17.48	−0.003	−0.117	16	21.13	15.89	−0.106	−0.208
17	24.11	23.74	0.323	0.170	17	21.69	21.58	0.183	0.047
18	24.74	16.09	−0.060	−0.168	18	22.26	14.63	−0.158	−0.254
19	25.37	22.35	0.260	0.115	19	22.83	20.32	0.127	−0.003
20	26.00	28.60	0.609	0.423	20	23.40	26.00	0.433	0.267

注：Ⅰ、Ⅱ、Ⅲ、Ⅳ分别代表天然工况、天然＋地震工况、饱和工况、饱和＋地震工况。

6.4 误差分析

为分析 PSO－BP 神经网络在引入自然选择算子后的有效性，需对 BP 神经网络和 PSO 算法参数进行设置：

(1) BP 神经网络：网络的拓扑结构为 2－5－1；训练函数为 traingd；学习函数为 learngd；学习率为0.01；输入层至隐含层的传递函数为 logsig，隐含层至输出层的传递函数为 purelin。

(2) PSO 算法：粒子数 $N=30$；粒子的飞行速度区间范围为[－1，1]，当其飞行速度超过该区间的上下限时，分别将上下限赋予该粒子；初始化权值和阈值的区间范围为[－5，5]；天然、天然＋地震、饱和、饱和＋地震工况下的最大迭代次数 $maxgen$ 分别为 2 000、2 600、3 600、3 300。

基于上述基本参数，采用生成的均匀设计样本点分别对传统 BP 神经网络、PSO－BP 神经网络和基于自然选择策略的 PSO－BP 神经网络进行训练，并依据变量的分布形式随机生成 15 组样本用于测试网络，经计算，得到 3 种网络的训练误差曲线及误差如图 5～8 及表 3 所示。

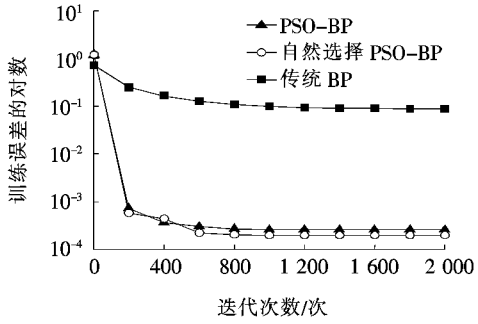

图 5 天然工况下训练误差

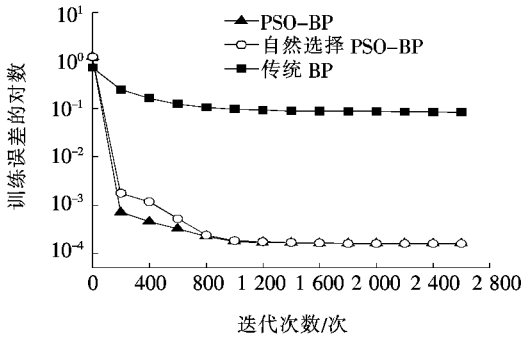

图 6 天然＋地震工况下训练误差

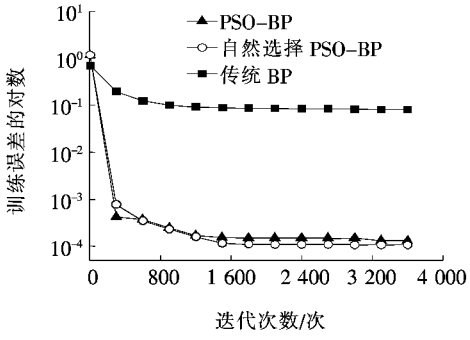

图 7 饱和工况下训练误差

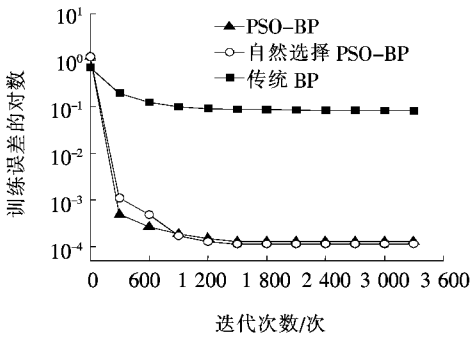

图 8 饱和＋地震工况下训练误差

表 3　网络误差结果

工况	训练误差			预测绝对误差和		
	传统 BP	PSO－BP	自然选择 PSO－BP	传统 BP	PSO－BP	自然选择 PSO－BP
天然	8.71×10^{-2}	2.57×10^{-4}	1.98×10^{-4}	1.097	0.076	0.065
天然＋地震	8.46×10^{-2}	1.62×10^{-4}	1.60×10^{-4}	0.995	0.051	0.051
饱和	8.09×10^{-2}	1.32×10^{-4}	1.06×10^{-4}	1.247	0.045	0.041
饱和＋地震	8.18×10^{-2}	1.27×10^{-4}	1.14×10^{-4}	1.108	0.040	0.038

6.5　HP1 滑坡可靠性分析

基于上述训练好的 BP 神经网络，依据变量的分布形式随机生成 100 万组数据作为输入变量，并驱动上述训练好的 BP 神经网络，计算相应的输出（$fos-1$），同时据式(16)、(17)计算 P_f 和 β。为检验上述 BP 神经网络的精度，以直接蒙特卡洛法（MCS）抽样 100 万次的计算结果为基准，稳定性计算方法为 M－P 法。4 种方法计算结果如表 4 所示。

表 4　可靠度指标计算结果

项目	天然		天然＋地震		饱和		饱和＋地震	
	β	P_f/%	β	P_f/%	β	P_f/%	β	P_f/%
直接 MCS(Ⅰ)	1.753	3.98	0.589	27.78	0.726	23.40	－0.555	71.04
BP－MCS(Ⅱ)	2.150	1.58	1.437	7.53	1.467	7.11	0.708	23.94
PSO－BP－MCS(Ⅲ)	1.730	4.18	0.638	26.17	0.753	22.56	－0.526	70.06
自然选择 PSO－BP－MCS(Ⅳ)	1.738	4.11	0.632	26.36	0.753	22.56	－0.542	70.60
绝对误差(Ⅰ－Ⅱ)	－0.397	2.40	－0.848	20.25	－0.741	16.29	－1.263	47.10
绝对误差(Ⅰ－Ⅲ)	0.023	－0.20	－0.049	1.61	－0.027	0.84	－0.029	0.98
绝对误差(Ⅰ－Ⅳ)	0.015	－0.13	0.043	1.42	－0.027	0.84	－0.013	0.44

7　结果分析

7.1　神经网络预测误差分析

由图 5～8、表 4 可知：① 相对于传统 BP 神经网络，PSO－BP 神经网络和基于自然选择策略的 PSO－BP 神经网络的训练误差和预测绝对误差和都比其要小。就训练误差而言，它们相差两个量级，可见基于最速梯度下降法搜索最优权值和阈值能力有限，容易收敛局部最优，而基于智能算法（PSO）优化权值和阈值，能够收敛于更优的权值和阈值，使得训练误差更小。就预测误差而言，饱和工况下，传统 BP 神经网络的预测绝对误差和为1.247，而 PSO－BP 神经网络和自然选择 PSO－BP 神经网络的误差分别为0.045、0.041，可见采用智能算法（PSO）优化的 BP 神经网络预测结果更为精确，误差更小；② 基于自然选择 PSO－BP 神经网络其 4 种工况下的训练误差和预测绝对误差和比 PSO－BP 神经网络都要小，其中饱和＋地震工况下的训练误差和预测绝对误差和最小，PSO－BP 神经网络、自然选择 PSO－BP 神经网络的训练误差分别为1.27×10^{-4}、1.14×10^{-4}，而预测绝对误差和仅为0.040、0.038。可见自然选择算子的引入，能够防止基本粒子群算法过早收敛于局部最优，从而达到全局最优，使改进后的网络有更好的全局拟合能力。

7.2　可靠性精度分析

由表 4 可知：基于自然选择 PSO－BP 神经网络和 PSO－BP 神经网络计算的可靠度指标与直接 Monte Carlo 法的绝对误差都比传统的 BP 神经网络要小，其中基于自然选择 PSO－BP 神经网络和 Monte Carlo 法相结合计算得到的可靠度指标与直接 Monte Carlo 法计算结果非常接近，β 的最大绝对误差仅为 0.043，失效概率最大误差仅为 1.42%。可见，基于自然选择 PSO－BP 神经网络和蒙特卡洛法相结合的方法具有较好的计算精度，可以得到较小误差的可靠度指标。而相对于 PSO－BP 神经网络的计算结果，基于自然选择 PSO－BP 神经网络计算结果误差

都比其要小。此外，针对该案例 4 种工况下的计算结果，基于自然选择 PSO－BP 神经网络与 PSO－BP 神经网络的结果相差并不是太大，这或许是随机变量个数较少的原因，当变量个数逐渐增加时，其权值和阈值的个数必然增加，从而优化问题也将变得复杂，基于自然选择 PSO－BP 神经网络的优越性势必也将凸显，这是今后进一步研究的方向。

7.3 影响因素敏感性分析

由表 4 可知：对比天然＋地震、饱和两种工况下的可靠性计算结果，饱和工况下的可靠度指标 β 明显大于天然＋地震工况下的计算结果，且该值和天然工况下的计算结果相对接近，故降雨对该滑坡可靠性的影响较小，敏感性低，而地震的影响较大，敏感性更高。

7.4 马达岭滑坡对公路线路的影响

鉴于马达岭滑坡前缘距离原规划路线较近，而 HP1 滑坡饱和＋地震工况下的失效概率为 71.04%，依据表 5，可知其处于高危险状态，将对原有线路构成威胁。为减小滑坡对线路的影响，在后期施工图设计阶段，选取了防御绕避的措施，在滑坡影响区以南 2 km 修筑隧道穿过滑坡可能影响的范围。

表 5 边坡稳定性等级

稳定性描述	破环概率(100%)	稳定等级
必然破坏	＞90	1
高危险	60～90	2
中等危险	30～60	3
低危险	5～30	4
稳定	＜5	5

8 结论

(1) 对于极限状态方程为隐式情况，采用 BP 神经网络对其进行拟合，由传统的 BP 神经网络容易陷入局部最优，采用基于自然选择 PSO 算法优化 BP 神经网络的权值和阈值，而后进行回归预测，结果表明基于自然选择 PSO－BP 神经网络具有更高的拟合精度，误差更小，能够应用于边坡可靠性分析。同时，改进后的网络期待在更加复杂案例中的运用。

(2) 对于该滑坡可靠性计算结果可知，降雨对可靠性的影响要小于地震。

(3) 据边坡稳定性等级划分，可知天然工况下的 HP1 滑坡处于稳定状态，饱和、天然地震工况下处于低危险状态，而饱和地震工况下处于高危险状态，所得结果有一定参考性。

参考文献：

[1] 张璐璐，张洁，徐耀，等.岩土工程可靠度理论[M].上海：同济大学出版社，2011.

[2] 贺志勇，戴少平.高速公路运营期软基沉降预测分析[J].中外公路，2011(1).

[3] 朱伟，石超峰，李楠.基于遗传算法优化支持向量机的再生混凝土抗压强度预测模型[J].中外公路，2014(1).

[4] 谢颖，高犁难，石振武.基于最小二乘支持向量机的公路工程造价预测模型[J].中外公路，2007(3).

[5] Cardoso J B，Almeida J R D，Dias J M，et al. Structural Reliability Analysis Using Monte Carlo Simulation and Neural Networks[J].Advances in Engineering Software，2008，39(6)：505－513.

[6] Elhewy A H，Mesbahi E，Pu Y. Reliability Analysis of Structure Using Neural Network method[J].Probabilistic Engineering Mechanics，2006，21(1)：44－53.

[7] 江龙艳.基于 PSO－BP 神经网络的边坡稳定性模型研究[J].有色金属(矿山部分)，2013(6).

[8] 胡泽涛，高文华，姜晓日.PCA－PSOBP 在边坡稳定性评价中的应用[J].采矿技术，2013(2).

[9] 胡卫东，曹文贵.基于改进粒子群算法的 BP 神经网络在边坡稳定性评价中的应用[J].湖南理工学院学报：自科版，2014(2).

[10] 胡卫东，曹文贵.基于粒子群 BP 网络混合算法的边坡稳定性评价[J].铁道科学与工程学报，2015(1).

[11] Suresh S，Sujit P B，RAO A K. Particle Swarm Opti－Mization Approach for Multi－Objective Composite Box－Beam Design[J].Composite Structures，2008，81(4)：598－605.

[12] 程跃，程文明，郑严，等.基于混沌粒子群算法的结构可靠性优化设计[J].中南大学学报：自然科学版，2011(3).

[13] Wei B W，Xu Z K，Li H K，et al. Optimization Inversion for Mechanical Parameters of Concrete Dam Based on GA－APSO Mixed Penalty Model[J].Journal of Central South University(Science and Technology)，2015.

[14] MATLAB 中文论坛.MATLAB 神经网络 30 个案例分析[M].北京：北京航空航天大学出版社，2010.

[15] 王德明，王莉，张广明.基于遗传 BP 神经网络的短期风速预测模型[J].浙江大学学报：工学版，2012(5).

[16] 龚纯，王正林.精通 MATLAB 最优化计算[M].北京：电子工业出版社，2009.

[17] Al－Betar M A，Awadallah M A，Faris H，et al. Batin-spired Algorithms with Natural Selection Mechanisms for Global Optimization[J].Neurocomputing，2017，273：448－465.

DOI:10.14048/j.issn.1671－2579.2019.03.002

基于FLAC^{3D}错落体稳定性分析及治理效果评价

余和广，张俊德
（中铁西北科学研究院有限公司，甘肃 兰州 730000）

摘要：以山区公路左侧错落体受路基开挖直接影响沿软弱夹层发生滑动变形为例，通过宏观上分析错落体变形特征、地层岩性、结构面特性，建立切合实际的计算模型，合理选取模型参数，采用有限差分软件FLAC^{3D}计算错落体稳定性，并与传统的极限平衡理论计算结果对比。通过FLAC^{3D}计算分析治理前、后边坡位移、稳定系数及软弱夹层剪切强度，说明预应力锚索框架加固方案是安全可靠的。数值分析方法及设计经验可为含软弱夹层岩质边坡稳定性分析和治理方案提供借鉴。

关键词：山区公路；错落体；FLAC^{3D}；稳定性分析；效果评价；数值分析

错落是山区公路建设中遇到的一种特殊的岩质边坡变形类型，指被陡倾角的构造面与后山完整岩体分开的风化破碎的岩体，因坡脚受冲刷或人工开挖而被压缩，引起的坡体以垂直下错为主的变形现象。错落病害常位于路基挖方边坡、隧道进出口边坡。文献[2]指出了错落依附的地质基础条件、外貌特征、演变过程及变形特征；田义斌等研究了错落体稳定性与滑坡转化关系；文献[4]、[5]采用有限差分软件FLAC^{3D}分析了岩质边坡稳定性；文献[6]－[8]进行了预应力锚索框架加固边坡数值分析及性能研究。该文针对青海某公路K8错落病害，通过建立地质边坡模型、预应力锚索框架结构模型，根据有限差分软件FLAC^{3D}计算结果，采取必要的加固措施，以提高错落体的稳定性，保证错落体下方公路的长期安全运营。

1 工程背景

1.1 病害概况

K8错落体位于青海省某在建公路左侧，为南北走向高达200 m山脊的一部分，错落体由白垩系河口群厚层砾岩、粉砂质泥岩夹薄层砂岩组成，产状NE60°∠70°/NW14°∠18°，通过出露岩层显示，在路基面以上70 m高范围内发育9组砾岩、砂岩互层，其中6组发育于后部稳定岩层，3组发育于外侧错落体，错落体与稳定岩层之间以宽10 m的断层破碎带断开，如图1所示。公路选线时未发现该错落病害，原设计公路在错落体前部以路堑形式通过，路堑开挖过程中，本已压实到位的错落体再次出现整体滑动变形，错落

[18] Bai J Q, Yin G L, Sun Z W. Random Weighted Hybrid Particle Swarm Optimization Algorithm Based on S－Econd Order Oscillation and Natural Selection[J]. Control & Decision, 2012, 27(10): 1 459－1 464.

[19] Tang R, Song Q, Fong S, et al. Improving Metaheuristics by Natural Selection[C]. Iiai International Congress on Advanced Applied Informatics. IEEE Computer Society, 2016: 588－592.

[20] Liu H F, Chu Y, Lu Z Y, et al. Emergency Rescue Platform of Electric Vehicles Based on Natural Selection PSO[J]. Applied Mechanics & Materials, 2013, 278－280: 1 941－1 944.

[21] 王玉川.缓倾煤层采空区上覆山体变形破坏机制及稳定性研究[D].成都理工大学硕士学位论文，2013.

[22] 贵州省地质环境监测院.贵州省重点地区重大地质灾害隐患详细调查——都匀市专题报告[R]，2012.

[23] SL 203－1997 水工建筑物抗震设计规范[S].

[24] 徐卫亚，张志腾.滑坡失稳破坏概率及可靠度研究[J].灾害学，1995(4).

[25] 张红日，王桂尧，兰素恋，等.坡顶建筑与顺层软岩共同作用的滑坡机制及抢险处治研究[J].中外公路，2018(2).

[26] 韩叙领.平岭大型滑坡稳定性分析及治理方案研究[J].中外公路，2016(5).

收稿日期：2018－09－25

作者简介：余和广，男，大学本科，工程师.E－mail:876003356@qq.com