

刘振华, 范宏运, 朱宇泽, 等. 基于 BP 神经网络的溶洞规模预测及应用[J]. 中国岩溶, 2018, 37(1): 139-145.
DOI: 10. 11932/karst2018y03

基于 BP 神经网络的溶洞规模预测及应用

刘振华, 范宏运, 朱宇泽, 柳 尚
(山东大学岩土与结构工程研究中心, 济南 250061)

摘 要:复杂岩溶地区的溶洞发育规模受地质构造、地区岩性、地下水动力系统等多种因素的影响, 具有高度复杂性和非线性特征。通过对岩溶区溶洞的赋存规律研究, 确定影响溶洞发育规模的控制因素进行定量处理, 收集已探明溶洞的样本数据。为克服已有研究对溶洞发育规模定性描述的模糊性, 文章利用 BP(Back Propagation)神经网络对自组织、自适应特性对数据样本的非线性关系揭示的能力, 实现对溶洞发育规模的预测, 并基于 MATLAB 实现 BP 神经网络结构的设计、训练、预测, 其结果表明: BP 神经网络模型对溶洞规模预测的精度高、收敛性能好。

关键词:溶洞; 赋存规律; BP 神经网络; 规模预测

中图分类号: U452. 1; P642. 25 **文献标识码:** A **文章编号:** 1001—4810(2018)01—0139—07

0 引 言

中国是世界上岩溶分布面积最广、岩溶发育程度最高、类型最多的国家。溶洞是岩溶发育形态之一, 不同规模大小的溶洞常成为隧道施工突水突泥和隧道后期运营期地质灾害的重要灾害源。复杂岩溶地区的地质构造、地层岩性、地下水动力系统是岩溶发育规模的控制因素^[1]。在岩溶地区溶洞的规模统计数据与以上三种控制性因素直接相关, 因此, 对以上控制因素的总结以及定量描述能反映溶洞规模的客观规律。

溶洞发育系统具有复杂性和条件多变性等特点, 许多学者找到了岩溶发育的普遍规律^[2-3]。具有代表性的有, 张之淦通过对不同岩性岩溶发育机理研究, 总结了岩溶区大型溶洞的岩溶发育分异作用; 马栋等通过分析我国西南岩溶地区的综合情况, 提出岩组、地质构造和地下水系统是岩溶发育的物质基础等。这些研究主要集中在岩溶区发育的基本规律, 缺

乏针对溶洞发育的具体规律的揭示。为了进一步研究溶洞发育规律, 学者们研究了岩溶区岩性、地质构造等控制因素与溶洞发育的关系, 如沈继方根据岩溶洞穴形成主要受控于地层构造及岩性特征, 采用了数理理论建立了预测方程, 论证了数量化理论在岩溶定量研究中的适用性; 李文兴等研究了数字描述及分形计算在岩溶洞穴空间形态上的应用。

综合分析已有的研究成果, 本文选取影响溶洞发育的 6 个控制因素(岩石溶解度、岩层厚度、汇水面积、裂隙规模、构造部位、最大泉流量)^[4], 利用 BP 神经网络模型对量化处理后的因素与溶洞规模之间的客观规律进行揭示。BP 神经网络模型具有的自适应性、自组织及很强的学习、联想、容错和抗干扰能力, 对溶洞数据样本中所蕴含非线性关系的识别和预测具有很好的效果^[5]。并将已满足精度要求的 BP 网络模型用于实际工程中的预测检验, 进一步丰富对岩溶区溶洞的研究手段^[6]。

基金项目: 国家自然科学基金面上基金(51479106); 山东省自然科学基金(2014ZRE27303); 水文水资源与水利工程科学国家重点实验室开放研究基金(2016zd13); 华南理工大学亚热带建筑科学国家重点实验室开放研究项目(2016ZB07)
第一作者简介: 刘振华(1993—), 男, 研究生在读, 主要从事岩溶区隧道稳定性及数据挖掘研究。E-mail: sdliuzhenhua@163. com。
通信作者: 柳尚(1991—), 男, 研究生在读, 主要从事隧道风险评估与数据挖掘研究。E-mail: 790052137@qq. com。
收稿日期: 2017—02—18

1 溶洞发育控制因素及规模分类

岩溶发育地区,溶洞在空间分布排列和规模大小上遵循着一定规律。其中可溶岩的性质、地质构造特征、地下水动力系统为溶洞发育规模的控制性因素。

1.1 溶洞发育控制因素

1.1.1 可溶岩岩性因素

可溶岩是溶洞发育的先决条件,其在地下水长期溶蚀、冲刷和自身塌陷作用下形成不同规模的溶洞。同等条件下,岩石的溶解度越大,溶洞发育程度越高。综合实验数据常见的赋存溶洞的岩层中的岩石溶解度大小为:石灰岩>白云岩>硅质灰岩>泥质灰岩。同时,较大的岩层厚度为发育大型规模的溶洞提供了条件。因此可用岩层的溶解度和厚度作为指标反映溶洞发育的规模程度^[7]。

1.1.2 地质构造因素

孕育溶洞的地表多为地势平缓、排泄径流不畅的负地形。地表出露封闭负地形面积不仅反映了岩溶区的汇水面积,同时也反映出发育溶洞可能性的地貌单元面积比。因此,将岩溶区出露的封闭负地形面积作为预测溶洞规模的指标之一,岩溶区地表出露封闭负地形面积越大,越有可能发育出大型溶洞。

溶洞分布和发育程度受地层产状等组合因素控制。水平产状的可溶岩上覆盖着完整的非可溶岩时,基本不发育溶洞;当非可溶性岩地层分布在可溶性岩下部时,地下水透过可溶性岩层在底部受阻,使之在可溶性岩中流动,极易溶蚀形成溶洞。

断层构造使岩层产生大量裂隙,为岩溶水的运动和岩溶作用提供了极其有利的条件。张性断裂带裂隙率高、充填物结构松散,岩溶化程度最为强烈,溶洞发育多且规模相对较大;压性断裂带裂隙率低、胶结紧密,溶洞发育不强烈;扭性断裂带主要受剪应力作用,构造裂隙较张性断层少,溶洞发育相对较弱。因此,为了定量的表述不同的断层构造对溶洞发育的影响,选取裂隙规模作为不同断层带影响溶洞发育的定量指标。

褶皱各个部位的岩溶发育差异明显。在岩性相同的条件下,向斜岩溶发育强于背斜,褶皱轴部岩溶发育强于翼部。褶皱轴部在构造力作用下岩层破碎,裂隙度高,地下水活动频繁,岩溶作用强烈。可根据岩溶区所处的区域构造的部位来划分褶皱对溶洞发育的影响。

1.1.3 地下水动力系统

地下水是岩溶地区溶洞发育规模决定性因素之

一。岩溶地区地下水运动在垂直方向上具有明显的垂直动力分带,地下水的流速、流量、CO₂溶度是可溶性岩层中溶洞发育正反馈机制的重要控制因素。岩溶地下水系统是岩溶动力系统的一个子系统,是以水循环为主要形式的物质能量传输系统。在溶洞发育区域地下水系统具有完整的补给、径流、调蓄、排泄条件,系统内部水力联系紧密。岩溶泉系统是以个体泉的形式出露地表的岩溶地下水系统,岩溶泉没有明显的集中和运移的地下通道或空间,其分布主要受地质构造、地形等因素影响,能比较方便的反映岩溶区地下水系统。在已有的研究中,岩溶地区地下水系统按流量统计结果将岩溶泉的流量进行了统计,以流量小于 500 L·s⁻¹ 的岩溶泉为主。因此,以最大泉流量指标来反映地下水系统对溶洞发育规模的影响。

1.2 溶洞规模分类

溶洞可以根据形态、规模、充填特征以及地质构造等特征进行分类。在隧道工程中总结不同溶洞特征并对溶洞进行合理分类,隧道施工具有重要意义。溶洞体积是最直观的表现形态,体积规模对隧道的施工的影响十分明显,本文采用溶洞体积规模分类方式。

小型溶洞:溶洞发育规模小于 10 m³;

中型溶洞:溶洞发育规模 10~1 000 m³;

大型溶洞:溶洞发育规模大于 1 000 m³。

2 BP 神经网络

BP 神经网络(Back-Propagation Network,简称 BP 网络)是指基于误差反向传播网络对非线性可微分函数进行权值训练的多层前向神经网络。在 BP 网络训练学习的过程中,信号是向前传播的,误差是反向传播,通过不断调整网络权值和阈值,直到输出层的预测值达到期望精度要求,神经网络对输入模式响应正确率也不断上升^[8]。

2.1 BP 神经网络结构

BP 神经网络的基本结构如图所示,包含输入层、隐含层、输出层三层神经网络。每一个神经元用一个节点表示,其中隐层可以为如图所示的一层,也可以为多层,前层到后层的节点通过权值联结。输入层中输入变量为 $X_i(p)$ ($i=1,2,\dots,n$),数层层节点数为 n ;隐含层节点数为 l ,输入层与隐层节点间的连接权值为 w_{ji} ($i=1,2,\dots,n;j=1,2,\dots,l$),隐层节点的阈值为 θ_j ($j=1,2,\dots,l$),隐含层节点输出为 $H_j(p)$;输出层节点数为 m ,隐层节点与输出层节点

间的连接权值为 $v_{kj} (j=1,2,\cdots,l;k=1,2,\cdots,m)$, 输出层节点的阈值为 $\varphi_k (k=1,2,\cdots,m)$, 输出层节点变量为 $O_k(p)$ 。




图 1 BP 神经网络拓扑结构图

Fig. 1 Topological structure of BP neural network model

2.2 BP 神经网络训练步骤

BP 神经网络预测首先要训练网络,通过训练使网络具有联想记忆和预测能力。BP 神经网络的训练过程包括以下几个步骤。

步骤 1:BP 网络初始化。根据研究系统输入输出序列 (x,y) 确定网络输入层节点数 n 、隐含层节点数 l 、输出层节点数 m 。初始化输入层与隐含层神经、隐含层与输出层神经元之间的连接权值 ω_{ji}, ν_{kj} 。

步骤 2:隐含层输出计算。根据输入向量 x , 输入层和隐含层神经元连接权值 ω_{ji} , 以及隐含层节点的阈值 θ_j , 采用式(1)计算隐含层输出 H_j 。

$$H_j = f(\sum_{j=1}^l \omega_{ji} x_i - \theta_j) \tag{1}$$

式中: f 为传递函数,起到了对输入输出进行函数转换的作用。常见的传递函数有阈值函数、线性函数、对数 Sigmoid 函数、正切 Sigmoid 函数。本文中采用 S 型函数,式(2)。

$$f(x) = \frac{1}{1 + e^{-x}} \tag{2}$$

步骤 3:输出层输出计算。隐含层的输出值作为输出层的输入变量,连接权值 ν_{kj} 和阈值 $\varphi_k (k=1,2,\cdots,m)$, 根据式(3),计算出 BP 神经网络预测值输出 $O_k(p)$ 。

$$O_k = f(\sum_{k=1}^m H_j \nu_{kj} - \varphi_k) \tag{3}$$

步骤 4:误差计算。根据网络预测输出 $O_k(p)$ 和期望输出 y , 计算网络预测误差 e 。

步骤 5:权值和阈值更新。为了减小误差达到所需精度,根据网络预测产生的预测误差 e , 更新网络连接的权值 ω_{ji}, ν_{kj} , 以及网络节点阈值 θ_j, φ_k 。

对连接权值的调整采用式(4)、(5)。

$$\omega_{ji} = \omega_{ji} + \eta H_j (1 - H_j) x(i) \sum_{k=1}^m \nu_{kj} e_k \tag{4}$$

$$\nu_{kj} = \nu_{kj} + \eta H_j e_k \tag{5}$$

对网络节点阈值的调整采用式(6)、(7)。

$$\theta_j = \theta_j + \eta H_j (1 - H_j) \sum_{k=1}^m \nu_{kj} e_k \tag{6}$$

$$\varphi_k = \varphi_k + e_k \tag{7}$$

步骤 6:判断算法迭代是否结束。根据训练误差性能曲线判断算法迭代是否达到目标误差,否则重复步骤 2 直至达到所预设的计算精度。

经过以上 6 个步骤训练后的 BP 神经网络,具备了识别和预测样本数据中的隐含的非线性关系。训练完成的网络将用来预测结果。

2.3 溶洞预测的 BP 网络模型建立

在溶洞规模问题 BP 神经网络结构的建立中,输入层节点个数为评价的影响因素即溶洞发育的控制因素个数,本文选取岩石溶解度、岩层厚度、汇水面积、裂隙规模、构造部位、最大泉流量六个控制因素,故输入层节点数为 6 个。

输出层为溶洞的不同规模。根据已说明溶洞的分类,输出层节点数设为 1 个,将 3 种溶洞规模对应 $[1,2,3]$ 三个数表示。

关于隐含层节点数的确定,隐含层单元数太少不能学习出来,且容错性差;隐含层单元数太多又使学习时间太长,误差情况不一定最佳。参考式 8 所示,采用“试错法”,找出最优隐含层单元数。

$$l = \sqrt{m + n} + a \tag{8}$$

式中: l 为隐含层节点数, m, n 分别为输入节点数和输出节点数, a 为 1~10 间的参数。根据上述分析,建立一个含有 6 个输入神经元,4 个隐含层神经元和 1 个输出神经元的 BP 神经网络(图 2)。




图 2 溶洞规模预测 BP 神经网络拓扑结构图

Fig. 2 Topological structure of the BP neural network model for caves scale prediction

3 BP 神经网络模型的溶洞规模预测

3.1 样本数据来源及处理

训练样本集中样本数量对于神经网络模型的训练效果有很大的影响。本文通过已有文献记录及工

程项目报告资料,收集整理出一批溶洞的数据资料。将其中一部分用于对神经网络进行训练样本,另一部分数据作为对神经网络的分类效果的验证样本,实现对溶洞规模的预测效果的检验。表 1 为 BP 神经网络对溶洞规模预测的训练样本。表 2 为 BP 神经网络对溶洞规模预测效果的检验样本。

表 1 BP 神经网络溶洞规模训练样本数据

Table 1 Sample testing data of the BP neural network model for determining the size of karst caves

样本	岩石溶解度	岩层厚度	汇水面积/km ²	裂隙张开度/mm	构造部位	最大泉流量/L·s ⁻¹	溶洞规模
1	不溶岩	中厚岩	25.39	0.44	向斜轴部	23.3	小型溶洞
2	不溶岩	薄层岩	18.34	0.4	背斜轴部	15.7	小型溶洞
3	可溶岩	中厚岩	14.73	1.1	背斜轴部	10.9	小型溶洞
4	可溶岩	薄层岩	9.89	0.18	背斜轴部	24.2	小型溶洞
5	不溶岩	中厚岩	6.58	0.4	向斜轴部	3.0	中型溶洞
6	不溶岩	中厚岩	7.83	0.38	向斜轴部	4.6	中型溶洞
7	不溶岩	中厚岩	8.56	0.38	背斜轴部	6.5	中型溶洞
8	不溶岩	薄层岩	9.13	1.05	背斜轴部	8.2	中型溶洞
9	不溶岩	薄层岩	10.11	0.36	背斜轴部	2.7	中型溶洞
10	可溶岩	巨厚岩	8.52	0.36	向斜轴部	4.8	中型溶洞
11	可溶岩	中厚岩	96.32	0.4	向斜轴部	3.7	中型溶洞
12	不溶岩	巨厚岩	7.02	0.4	向斜翼部	0.8	大型溶洞
13	不溶岩	巨厚岩	3.59	1.07	向斜轴部	1.1	大型溶洞
14	不溶岩	中厚岩	5.6	1.06	背斜轴部	0.5	大型溶洞
15	不溶岩	中厚岩	3.05	1.1	背斜轴部	0.4	大型溶洞
16	不溶岩	中厚岩	1.56	1.08	背斜轴部	0.3	大型溶洞
17	强溶岩	巨厚岩	1.29	0.34	背斜轴部	0.7	大型溶洞
18	不溶岩	巨厚岩	4.75	0.67	向斜轴部	1.2	大型溶洞

注:表中指标用 1、2、3、4 来表示分类,岩石溶解度中:1—不溶岩 2—中厚岩 3—强溶岩;岩层厚度中:1—薄层岩 2—中厚岩 3—巨厚岩;构造部位中:1—向斜轴部 2—向斜翼部 3—背斜轴部;溶洞规模中:1—小型溶洞 2—中型溶洞 3—大型溶洞

表 2 BP 神经网络溶洞规模检验样本数据

Table 2 Sample verifying data of the BP neural network model

样本	岩石溶解度	岩层厚度	汇水面积/km ²	裂隙张开度/mm	构造部位	最大泉流量/L·s ⁻¹	溶洞规模
1	不溶岩	薄层岩	18.34	0.4	背斜轴部	15.7	小型溶洞
2	不溶岩	中厚岩	8.56	0.38	背斜轴部	6.5	中型溶洞
3	不溶岩	薄层岩	10.11	0.36	背斜轴部	2.7	中型溶洞
4	可溶岩	中厚岩	96.32	0.4	向斜轴部	3.7	中型溶洞
5	不溶岩	中厚岩	6.58	0.4	向斜轴部	3.0	中型溶洞

注:表中指标说明同上表。

在 BP 神经网络中样本矩阵的输入维数代表特征,在溶洞规模预测的输入数据选择了 6 个特征,故输入数据为一个 6 维的矩阵。当这些代表不同特征的数据之间相差较大,进行数据归一化处理为比较理想的处理方法。归一化处理可以防止某些数值低的特征被淹没,同时加快了 BP 神经网络的学习速度。

在 BP 神经网络中,一般将数据映射到[0,1]或[-1,1]。当数据归一化处理为[0,1]时,传递函数宜用对数 Sigmoid 函数;当数据归一化处理为[-1,1]时,传递函数宜用正切 Sigmoid 函数。常用的归一化处理的公式有如下几种:

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \tag{9}$$

式中： x 为样本数据， $x_{\max}$ 、 $x_{\min}$ 分别为样本数据的最大值和最小值， x' 为归一化的样本值。这种归一化处理后将样本数据映射到 $[0,1]$ 之间。

$$x' = \frac{2(x - x_{\min})}{x_{\min} - x_{\max}} - 1 \tag{10}$$

在对溶洞规模预测中所选取的 6 个特征参量中，考虑到不同特征对预测溶洞发育规模的影响的程度，选用式(10)将样本数据映射到 $[-1,1]$ 之间。表 3 为经过归一化处理后的训练样本的数据，表 4 为经过归一化处理后的试验样本数据。

表 3 归一化处理训练样本数据

Table 3 Normalization processing of training samples data

样本	岩石溶解度	岩层厚度	汇水面积/km ²	裂隙张开度	构造部位	最大泉流量/L·s ⁻¹	溶洞规模
1	-1	0	1.000	-0.435	-1	0.925	-1
2	-1	-1	0.415	-0.522	1	0.289	-1
3	0	0	0.115	1.000	1	-0.113	-1
4	0	-1	-0.286	-1.000	1	1.000	-1
5	-1	0	-0.561	-0.522	-1	-0.774	0
6	-1	0	-0.457	-0.587	-1	-0.640	0
7	-1	0	-0.397	-0.565	1	-0.481	0
8	-1	-1	-0.349	-0.565	1	-0.339	0
9	-1	-1	-0.268	0.891	1	-0.799	0
10	0	1	-0.400	-0.609	-1	0.623	0
11	0	0	-0.583	-0.609	-1	-0.715	0
12	-1	1	-0.524	-0.522	0	-0.958	1
13	-1	1	-0.809	-0.522	-1	-0.933	1
14	-1	0	-0.642	0.935	1	-0.983	1
15	-1	0	-0.854	0.913	1	-0.992	1
16	-1	0	-0.978	1.000	1	-1.000	1
17	1	1	-1.000	0.957	1	-0.967	1
18	-1	1	-0.713	-0.652	-1	-0.925	1

表 4 归一化处理验证样本数据

Table 4 Normalization processing of the sample verifying data

样本	岩石溶解度	岩层厚度	汇水面积/km ²	裂隙张开度	构造部位	最大泉流量/L·s ⁻¹	溶洞规模
1	-1	-1	0.415	-0.522	1	0.289	-1
2	-1	0	-0.561	-0.522	-1	-0.774	0
3	-1	-1	-0.268	0.891	1	-0.799	0
4	0	0	-0.583	-0.609	-1	-0.715	0
5	1	1	-1.000	0.957	1	-0.967	1

根据归一化处理后的数据，Ⅰ类、Ⅱ类、Ⅲ类溶洞分别用数值 $[-1,0,1]$ 表示。

3.2 BP 神经网络程序设计的 MATLAB 实现功能

用 MATLAB R2012a 软件编程实现基于 BP 神经网络的非线性拟合法。

BP 神经网络创建调用函数格式为：

$$\text{net} = \text{newff}(P, T, [S_1 \ S_2 \cdots S_{(N-1)}], \{TF_1 \ TF_2 \cdots TF_N\}) \tag{11}$$

式中： P, T 分别为输入样本和期望响应； S_i 为网络各层的神经元数目； TF_i 为网络各层的传递函数类型。默认情况下，网络隐含层采用 tansig 函数，输出层采用 purelin 函数。函数执行的结果是返回一个 N

层前向型的 BP 神经网络。

运行上面程序,创建的 BP 神经网络如图 3,其中,隐含层中神经元的数量为 4 个。网络拟合计算过程中误差性能变化曲线如图 4。




图 3 BP 神经网络结构及训练过程

Fig. 3 BP neural network structure and testing process




图 4 网络训练误差曲线

Fig. 4 Error curve of network training

通过误差性能曲线发现,样本数据在训练迭代 7 次以后到达误差性能目标。利用验证样本对训练完成的网络进行检测。期望输出、预测结果以及预测误差

差输出如表 5。

表 5 溶洞规模验证预测结果

Table 5 Results of karst cave scale prediction and verification

验证样本	期望输出值	预测输出值	绝对误差	溶洞类型
1	-1	-1.095 34	0.095 34	I 类
2	0	0.004 18	0.004 18	II 类
3	0	-0.002 3	0.002 30	II 类
4	0	0.005 6	0.005 06	II 类
5	1	0.979 06	0.020 93	III 类

从表 5 可以看出,用于验证的五个溶洞样本相对误差均小于 10%,均可以准确的判断出溶洞的类型。上述结果表明设计的 BP 神经网络预测模型,以 6 个主要控制因素作为输入数组数据,可以准确的预测不同规模的溶洞预测。随着对溶洞样本数据的进一步统计,对该 BP 神经网络进行训练,使该神经网络对复杂岩溶区的不同因素与溶洞发育规模之间的复杂非线性关系揭示的更加准确。

4 结 论

(1)复杂岩溶区溶洞发育的规模与可溶岩岩性、地质构造特征、地下水系统三个主要因素有关。依据溶洞的赋存规律,总结出岩石溶解度、岩层厚度、汇水面积、裂隙规模、构造部位、最大泉流量 6 个因素作为影响溶洞发育规模的控制性变量。

(2)在 BP 神经网络的设计和训练过程中,样本数据的初始化处理、样本容量的大小对预测结果有显著的影响,因此,引用合适的传递函数和数据初始化处理方法,以及丰富样本容量是实现网络降低误差的重要途径。

(3)研究结果表明,BP 神经网络自组织、自适应特性可以较好的揭示溶洞样本数据中隐藏的非线性关系,实现了基于已有样本数据训练对溶洞发育规模的准确预测。

参考文献

[1] 陈凯,黄蕾,方强. 遗传神经网络在累积性环境风险评价中的应用[J]. 环境监测与预警, 2012,4(2):1-6.

[2] 袁永才,李术才,李利平,等. 岩溶隧道施工过程中大型溶洞的综合预报及治理方案研究[J]. 现代隧道技术, 2015, 52(2): 192-197.

[3] 李奎,高波.岩溶区隧道岩溶发育规律与岩溶洞穴探测[J].西部探矿工程,2005(10):107-110.

[4] 李术才,刘斌,孙怀凤,等.隧道施工超前地质预报研究现状及发展趋势[J].岩石力学与工程学报,2014,33(6):1090-1113.

[5] 何晓群.多元统计分析[M].北京:中国人民大学出版社,2012:135.

[6] 韩力群.人工神经网络教程[M].北京:北京邮电大学出版社,2006:58-75.

[7] 葛颜慧,李术才,张庆松,等.基于风险评价的隧道综合超前地质预报技术研究[J].岩土工程学报,2010,32(7):1124-1130.

[8] 陈小前,罗世彬,王振国,等.BP神经网络应用中的前后处理过程研究[J].系统工程理论与实践,2004,22(1):65-70.

[9] 王永刚,李辉.基于灰色神经网络的民航事故征候预测模型研究[J].中国安全科学学报,2012,22(3):10-15.

[10] 陈伟,马如雄,郝艳红.基于 MATLAB 的 BP 人工神经网络设计[J].智能计算机与应用,2005(2):30-31.

Prediction model for the scale of karst cave based on back propagation artificial neural network and its application

LIU Zhenhua, FAN Hongyun, ZHU Yuze, LIU Shang

(Geotechnical & Structural Engineering Research Center, Shandong University, Ji'nan, Shandong 250061, China)

Abstract In complex karst region, the size of karst cave is affected by many factors, such as geological structure, properties of soluble rock and groundwater hydrodynamic system and so on, which is characterized by high complexity and nonlinearity. Through the study of the occurrence and development of karst caves in karst area, the control factors affecting the scale of karst cave are determined and quantitatively analyzed, for which the data of proved caves are collected. In order to solve the problem with data fuzziness and descriptive formation of the karst caves, in this paper, the method of Back Propagation (BP) artificial neural network is employed to achieve the prediction of the scale of karst caves. As a BP neural network model is self-organization and self-adaptive, it is expected to handle the nonlinearity of sample data. The model is designed, tested, and applied, based on the MATLAB R2012a software. The results show that BP artificial neural network prediction model for the scale of karst cave is of high accuracy with its algorithm of good convergence.

Key words karst cave, occurrence regularity, BP neural network, scale prediction

(编辑 张玲)