

基于广义回归神经网络的边坡稳定性评价

兰海涛¹, 李 谦¹, 韩春雨²

(1. 中国地质大学 (武汉) 工程学院, 武汉 430074; 2. 中南大学 地学与环境工程学院, 长沙 410083)

摘 要: 边坡失稳是比较常见的地质灾害, 判定其稳定性的方法很多, 在使用过程中也暴露出了这些方法的缺陷。针对这些问题, 构建了适合于边坡稳定性评价的广义回归神经网络模型, 并运用 Matlab 的神经网络工具箱进行了分析和计算, 使用了相关数据来训练和测试该模型的可靠性和可行性。结果表明, 广义回归神经网络模型在使用过程中需选择合适的光滑因子, 而所得出的数据与实际结果较为相符, 解决了之前使用的 BP 神经网络模型的缺点, 具有很好的工程运用前景。

关 键 词: 广义回归神经网络; 边坡稳定性; 光滑因子; 神经网络模型

中图分类号: O 242

文献标识码: A

Slope stability evaluation based on generalized regression neural network

LAN Hai-tao¹, LI Qian¹, HAN Chun-yu²

(1. Engineering Faculty, China University of Geosciences, Wuhan 430074, China; 2. School of Geosciences and Environmental Engineering, Central South University, Changsha 410083, China)

Abstract: The slope failure is the common geological hazard and there are lots of methods to evaluate this geological hazard, which expose some disadvantages during the use process. In order to solve these problems, a model of generalized regression neural network is made to meet the slope stability evaluation, which uses the neural network tool kit in Matlab to analyze and calculate the input and output data. Then the reliability and feasibility of the model is trained and tested. It is concluded that the output data agrees well with the actual data by using the model that can overcome the disadvantage of BP neural network used before, if the smoothing factor is chosen appropriately. So the good engineering prospect will be expected when the slope stability evaluation is based on generalized regression neural network.

Key words: generalized regression neural network; slope stability; smoothing factor; neural network model

1 引 言

边坡失稳这一地质灾害比较复杂, 影响边坡失稳的因素很多, 判别边坡稳定性的方法也很多, 例如瑞典条分法、Bishop 法、Janbu 法等传统算法, 考虑的是刚体极限平衡算法, 至今还在应用^[1]。但由于这种算法人为假定的条件比较多, 与实际工程的差距和对安全系数的影响, 有待进行深入考证。近年来, 也有学者用时间序列方法、模糊数学方法、灰色预测方法、层次分析法或多种方法综合的组合预测等来判定边坡的稳定性。这些方法大部分都需要建立在对因果关系的回归模型和时间序列模型上来分析和解决问题, 往往不能反映所预测动态数据的内在结构和复杂特性的本质, 丢失了信息量。

人工神经网络 (artificial neural network, 简称为 ANN) 在最近几年发展迅猛, 通过模拟人脑的神经处理信息方式, 进行信息并行处理和非线性映射过程, 具有大规模计算的能力。人工神经网络的研究者进行了神经网络的数学研究, 建立了许多人工神经网络模型, 而其中的 BP 神经网络因功能强大, 算法简单、可行性强, 主要应用在函数逼近、模式识别、分类和对输入输出模型的建立上。在 BP 神经网络应用的同时也暴露出 BP 神经网络的一些缺点。①隐含层的数目难以确定, 各隐含层设立的神经元也难以确定, 往往需要根据设计者的经验和多次训练来确定。尽管出现了不少经验公式, 但不存在一个理想的解析式, 而其网络结构的构造又是 BP 神经网络工程应用成败的关键, 增大的网络

结构可以使系统误差减小, 但训练时效率不高; ②对于一些复杂问题, 训练时间长, 在实际过程中必须选取一个有限阶距的大小来收敛, 这一点也要根据实际情况来判断和确定; ③收敛值不能保证误差平面的全局最小值, 采用梯度下降法可能会产生多个局部最小值; ④学习和记忆具有不确定性, 调整参数多。

Broomhead 和 Lowe 在 1988 年率先使用了径向基函数, 提出了神经网络学习的一种新手段^[2]。广义回归神经网络是径向基网络的一种变化形式, 而广义回归神经网络与 BP 神经网络相比, 在处理这些问题上有较好的优势, 改正了 BP 神经网络的缺点。因此, 笔者将广义回归神经网络运用到边坡稳定性的评价中来, 通过相关数据建立广义回归神经网络的模型, 以此验证该方法的优势和适应性及其处理类似问题的可行性。

2 广义神经网络的算法

广义神经网络 (generalized regression neural network, GRNN) 是径向基神经元和线性神经元的综合, 它包括两层, 中间层 (隐含层) 为径向基层, 输出层为线性层。

图 1 所示的广义回归神经网络 GRNN 有 Q 组输入向量, 每组向量的元素个数为 R 个, 即图 1 中的 $P(p_1, p_2, \dots, p_R)$ 。网络的第 1 层为径向基隐含层, 神经元个数等于训练样本数, 该层的权值函数为欧氏距离函数 $\|IW-P\| = \sqrt{\sum_{i=1}^R (IW_i - p_i)^2}$, 用 $\|dist\|$ 表示, 其作用为计算网络输入与第 1 层的权值 IW 之间的距离; b 为隐含层的阈值; 符号“ $\cdot$ ”表示 $\|dist\|$ 的输入与阈值 b 之间的关系, $n_1 = \|dist\| \cdot b$ 。




图 1 广义回归神经网络结构
Fig.1 GRNN architecture

隐含层的传递函数为径向基函数, 通常采用高斯函数作为网络传递函数:

$$a_1 = \text{radbas}(n_1) \quad (1)$$

式中: $\text{radbas}(n_1) = \exp(-n_1^2)$, 由于网络隐含层结点中的作用函数 (基函数) 采用高斯函数, 它作为一种局部分布对中心径向对称衰减的非负非线性函数, 在图 1 中以它的近似坐标图“ $\cap$ ”表示, 对输入信号将在局部产生响应, 即当输入信号靠近基函数的中央范围时, 隐含层结点将产生较大输出, 具有比较好的局部逼近能力, 这也是该网络之所以学习速度更快的原因。

在 Matab 神经网络工具箱中, $b = [-\ln(0.5)]^{0.5} / \sigma_i = 0.8326 / \sigma_i$, 从而得到:

$$a_1 = \exp(-0.8326^2 \times \frac{\|dist\|^2}{\sigma_i^2}) \quad (2)$$

式中: σ_i 决定了第 i 个隐含层位置中基函数的形状, 所以又被称为光滑因子。

网络的第 2 层为线性输出层, 其权函数为规范化点积权函数 (图 1 中用 $nprod$ 表示), 实现 LW 与 a_1 的归一化运算, 计算结果为 n_2 。它的每个元素就是向量 a_1 和权值矩阵 LW 每行元素的点积再除以向量 a_1 的各元素之和得到的。最后, 将结果 n_2 提供给线性传递函数, $a_2 = \text{purelin}(n_2)$ (图 1 中以“ $\nearrow$ ”表示), 神经元数等于输入样本数, 无阈值向量输入, 从而计算得到网络的输出数据。

在网络训练时, 从 0 个神经元开始训练, 通过检查输出误差, 使网络自动增加神经元。每次循环使用时, 使网络产生的最大误差所对应的输入向量作为权值 IW , 产生一个新的隐含层神经元, 然后检查新网络的误差, 重复此过程, 以此达到误差要求或所规定的最大隐含层神经元数为止, 从而使网络具有自适应性强、输出与初始值无关等特点, 解决了 BP 网络确定隐含层数目难的问题。

3 模型的建立

考虑到影响边坡稳定的因素很多, 即便是比较简单的极限平衡法, 都需要大量的计算工作。为简化计算工作量, 不少学者根据他们所掌握的大量计算资料, 整理出坡高 H 、坡角 α 、与土的抗剪强度指标 c 、 φ 和重度 γ 等参数对边坡稳定的影响^[1]。所以, 可考虑用以上指标作为输入量, 即设输入神经元数为 5 个; 输出变量为 1 个, 即稳定与否, 设 1.000 0 为破坏, 0.000 0 为稳定。数据主要采用文献 [5] 中的数据进行训练和测试, 训练样本为 14 个 (见表 1), 从中选取 5 个作为测试样本 (见表 2)。

设置光滑因子 σ_i , 即基函数对 GRNN 网络性能的影响, 需要尝试来确定其值。理论上说, σ_i 值

越小,对函数的逼近就越精确,但所需的训练时间就越长; σ_i 值越大,逼近误差就会越大。在用 MATLAB 编程时为了测试和比较,同时为了证明 GRNN 神经网络使用时的方便,根据编程时的循环关系,设其 σ_i 值为 0.1、0.2、0.3,以此来比较与实际值的误差,确定所使用的 σ_i 值。

表 1 训练样本输入参数与实际值

Table 1 Training sample input data and actual results

编号	重度 /(kN/m ³)	黏聚力 /kPa	摩擦角 /(°)	边坡角 /(°)	边坡高度 /m	稳定评价的 实际结果
1	25.00	120.00	45.00	35.00	120.00	0.000 0
2	16.50	11.49	0.00	30.00	3.66	1.000 0
3	18.84	57.46	20.00	20.00	30.50	0.000 0
4	18.84	14.36	25.00	20.00	30.50	0.000 0
5	28.44	29.42	35.00	35.00	100.00	0.000 0
6	28.44	39.23	38.00	35.00	100.00	0.000 0
7	20.60	16.28	26.50	30.00	40.00	1.000 0
8	14.80	0.00	17.00	20.00	50.00	1.000 0
9	14.00	11.97	26.00	30.00	88.00	1.000 0
10	18.68	26.34	15.00	35.00	8.23	1.000 0
11	16.00	70.00	45.00	40.00	115.00	1.000 0
12	20.41	24.90	20.00	22.00	10.67	0.000 0
13	19.63	11.97	13.00	22.00	12.19	1.000 0
14	21.83	8.62	20.00	28.00	12.80	1.000 0

表 2 测试样本输入参数与实际值

Table 2 Test ing sample input data and actual results

编号	重度 /(kN/m ³)	黏聚力 /kPa	摩擦角 /(°)	边坡角 /(°)	边坡高度 /m	稳定评价的 实际结果
15	25.00	120.00	45.00	35.00	120.00	0.00
16	16.50	11.49	0.00	30.00	3.66	1.00
17	18.84	14.36	25.00	20.00	30.50	0.00
18	18.84	57.46	20.00	20.00	30.50	0.00
19	28.44	29.42	35.00	35.00	100.00	0.00

通过 MATLAB 神经网络工具箱进行编程处理,其中核心部分:

for $i=1:3$

net = newgrnn (P_train, T_train, i/10)

把训练样本和相对应的实际结果输入建立 GRNN 神经网络模型,即通过训练建立相应的函数关系,进行网络对训练数据的逼近。 P_train 为输入的训练样本, T_train 为实际结果。其中 σ_i 值设为 0.1、0.2、0.3。

…… (其他编程语句省略)

temp = sim(net, P_test)

给定测试样本,根据训练时建立的函数关系得到预测结果赋予 temp 变量。

…… (其他编程语句省略)

end

通过训练得到函数关系后,得到其预测值,具体结果见表 3,与实际结果的逼近误差见图 2。测试样本得到的预测值见表 4,与实际结果的逼近误差见图 3。

表 3 基于不同 σ_i 的训练结果和实际值Table 3 Training results based on different σ_i and actual result

编号	σ_i 值			稳定评价的 实际结果
	0.1	0.2	0.3	
1	0.000 0	0.000 1	0.016 0	0.000 0
2	1.000 0	0.997 2	0.929 5	1.000 0
3	0.002 5	0.244 0	0.451 1	0.000 0
4	0.000 1	0.099 0	0.333 9	0.000 0
5	0.000 0	0.000 2	0.021 2	0.000 0
6	0.000 0	0.000 1	0.014 4	0.000 0
7	0.999 6	0.856 2	0.711 8	1.000 0
8	0.999 9	0.885 1	0.715 0	1.000 0
9	1.000 0	0.994 5	0.901 7	1.000 0
10	1.000 0	0.975 4	0.862 3	1.000 0
11	1.000 0	0.999 9	0.980 0	1.000 0
12	0.090 7	0.379 6	0.496 8	0.000 0
13	0.914 8	0.611 9	0.601 1	1.000 0
14	0.986 4	0.789 7	0.699 3	1.000 0




图 2 训练样本的逼近误差

Fig.2 The approximate error of training sample

表 4 基于不同的 σ_i 的测试结果和实际值Table 4 Testing results based on different σ_i and actual result

编号	σ_i 值			稳定评价的 实际结果
	0.1	0.2	0.3	
15	0.000 0	0.000 1	0.016 0	0.000 0
16	1.000 0	0.997 2	0.929 5	1.000 0
17	0.002 5	0.244 0	0.451 1	0.000 0
18	0.000 1	0.099 0	0.333 9	0.000 0
19	0.000 0	0.000 2	0.021 2	0.000 0




图 3 测试样本的预测误差

Fig.3 The forecast error of testing sample

经过训练和测试发现, σ_i 值的设置对结果的影响符合理论情况, σ_i 值为 0.2、0.3 时, 在精度上远不及 σ_i 值为 0.1 时。而 σ_i 值为 0.1 时, 除训练样本编号 12、13 有较大误差外, 其他都与实际情况符合, 训练时间也比较短。在用测试样本进行测试时, 结果令人满意。

在实际工作中, 可根据之前的地质资料, 整理出坡高 H 、坡角 α 、土的抗剪强度指标 c 、 φ 和重度 γ 等参数。通过模型建立这些输入量与输出量(即边坡稳定与否)之间的映射关系, 建立训练样本。在遇到新数据时, 可以把这些数据作为测试样本, 根据已建立起的模型, 调整合适的 σ_i , 预测出输出量, 为相关人员提供比较基本和简单的可供判断与评价的依据。

4 结 论

(1) GRNN 网络能很好地控制局部误差, 不用像 BP 神经网络一样要根据经验、训练或测试结果而改变隐含层的数目和隐含层的神经元个数, GRNN 网络运算速度更快。

(2) 选择合适的光滑因子能在网络运算中起到很好的效果, 因为调整的参数只有 σ_i 值, 所以能很快找到合适的网络, 与 BP 神经网络相比, 有较大的计算优势。

(3) 在工程实际运用中建立 GRNN 模型更方便、更有效率, 与实际结果更相符, 可作为评价边坡稳定与否的一个比较基本和实用的工具。

参 考 文 献

- [1] 陈仲颐, 周景星, 王洪瑾. 土力学[M]. 北京: 清华大学出版社, 2007: 39—273.
- [2] BROOMHEAD D S, LOWE D. Multivariable functional interpolation and adaptive networks[J]. **Complex System**, 1988, 2: 321—355.
- [3] 葛哲学, 孙志强. 神经网络理论与 MATLAB R2007 实现[M]. 北京: 电子工业出版社, 2007.
- [4] 胡伍生. 神经网络理论及其工程应用[M]. 北京: 测绘出版社, 2006.
- [5] 王文喜, 姚文清, 杨子荣. MATLAB 的 BP 神经网络在边坡稳定性评价中的应用[J]. 西部探矿工程, 2006, (11): 273—274.
- [6] 刘浩, 白振兴. BP 网络 Matlab 实现及应用研究[J]. 现代电子技术, 2006, (2): 49—51.
LIU Hao, BAI Zhen-xing. Realization and applications of BP network on Matlab[J]. **Modern Electronics Technique**, 2006, (2): 49—51.
- [7] 周建萍, 闫澍旺. 广义回归神经网络预测加筋土挡结构高度[J]. 岩土力学, 2002, 23(4): 486—490.
ZHOU Jian-ping, YAN Shu-wang. Generalized regression neural networks for predicting design height of GRW[J]. **Rock and Soil Mechanics**, 2002, 23(4): 486—490.
- [8] BASHEER I A, HAJMEER M. Artificial neural networks: fundamentals, computing, design and application[J]. **Journal of Microbiological Methods**, 2000, 43(1): 3—31.
- [9] SPECHT D F. A general regression neural network[J]. **IEEE Transactions on Neural Networks**, 1991, 2(6): 568—576.
- [10] SPECHT D F, ROMSDAHL H. Experience with adaptive probabilistic neural networks and adaptive general regression neural networks[C]//Proceedings of the IEEE World Congress on Computational Intelligence. Orlando: [s. n.], 1994: 1203—1208.
- [11] KIEFA M A ABU. General regression neural networks for driven piles in cohesionless soils[J]. **Journal of Geotechnical and Geoenvironmental Engineering**, 1998, 124(12): 1177—1185.