

GRNN 在边坡稳定预测分析中的应用

狄圣杰¹ 李晓敏² 魏 樯³

(1. 河海大学岩土力学与堤坝工程教育部重点实验室, 江苏 南京 210098 ;

2. 郑州科技学院土木与建筑工程系, 河南 郑州 450000 ; 3. 中国水电顾问集团昆明勘测设计研究院, 云南 昆明 650051)

摘要 :介绍广义回归神经网络(GRNN)的原理和影响因素,论述光滑因子的影响和选择。采用 LOO 交叉验证方法遍历所有样本,搜索出合适的光滑因子,结果表明合适的光滑因子能够较大幅度地提高网络泛化能力。应用收集到的 82 个圆弧滑面边坡稳定状态的实例资料,将 GRNN 模型应用于边坡稳定性评价,计算结果表明,在边坡稳定状态分析及预测方面,GRNN 模型比 BPNN 模型更加精准简捷。

关键词 :广义回归神经网络;光滑因子;边坡稳定预测

中图分类号 :TU452 **文献标识码** :A **文章编号** :1006-7647(2011)03-0080-04

Application of generalized regression neural network in prediction and analysis of slope stability//DI Sheng-jie¹, LI Xiao-min², WEI Qiang³(1. Key Laboratory of Ministry of Education for Geomechanics and Embankment Engineering, Hohai University, Nanjing 210098, China ; 2. Department of Civil Engineering and Architecture, Zhengzhou University for Science & Technology, Zhengzhou 450000, China ; 3. Kunming Investigation and Design Institute, China Hydropower Engineering Consulting Group Co., Kunming 650051, China)

Abstract : The principles and influence factors of the algorithm of generalized regression neural network (GRNN) were introduced. The influence and choice of the spread were discussed. The suitable value of the spread was searched out from all the samples according to the LOO across validity method. It was proved that the suitable value of the spread could greatly improve the generalization ability of the network. The method of GRNN was applied to the evaluation of slope stability of 82 examples. The results show that the GRNN model is simpler and more accurate than the BPNN models in prediction and analysis of slope stability.

Key words : generalized regression neural network ; spread ; prediction of slope stability

岩土体具有复杂的结构和机理,破坏过程是渐变性的,是变形积累到一定程度表现出宏观滑移的一个非线性复杂过程,如边坡滑动蠕变或挡土墙后楔形岩土体的开裂滑动,岩土体物理力学特征和地质环境因素对其都有影响,这些影响因素有的是确定的,有的是随机的,它们对不同类型边坡稳定性的影响权重也是不同的,之间又有复杂的非线性关系^[1-2]。运用现代智能方法如人工神经网络已成为预测边坡稳定性的一种较有效的手段,其特点是智能性、综合性、集成性和非线性。

常用的 BPNN(误差反向传播神经网络)及其改进方法无法自动调整结构组成,性能优良的 BPNN 需要优化网络结构,优化权值、阈值等参数,选择合适的计算方法和学习参数。这些都用到相关的优化算法,例如用遗传或粒子群算法对未知参数寻优,

必要时还要扩展网络结构以减小系统误差,同时收敛速度较慢,这会限制它在实际中的应用和推广。广义回归神经网络(GRNN)结构设计简单,收敛速度快,所需训练样本少,对被建模对象的先验知识要求不多,具有全局逼近性和最佳逼近性质,鲁棒性及非线性处理能力强,能根据样本数据反映其中隐含的映射关系,且不存在局部最小问题,目前已在工程中得到了应用^[3-4]。

GRNN 唯一需要调整的参数是光滑因子,它的选择对于网络性能优劣有较大影响,光滑因子越小,拟合程度越好,但过小会导致过拟合。文献[5-7]选取了光滑因子试算范围内的最小值,因为最小值不等于最优值,故直接应用某范围内的最小值是不准确的,会导致网络泛化能力差。笔者应用遍历样本的交叉验证方法,可以合理地选择光滑因子值,改善

1 GRNN 基本理论

GRNN 是一种建立在非参数估计基础上的非线性回归的径向基神经网络,不需要事先确定方程形式,而以概率密度函数代替固有的方程形式,直接计算出因变量对自变量的回归值。其优势在于不需要重复训练,网络建成的同时训练即完成,网络的训练过程实际上就是确定光滑因子的过程,并且在网络数据稀少时效果也较好,能够收敛于样本量聚类较多的优化回归面。网络输入层只传递输入向量到径向基层,隐含层中神经元个数由所描述的问题而定,通常传递函数采用高斯函数 radbas:

$$a_j = \text{radbas}[\text{nprod}(\| \text{dist} \|_j b_j)] = \exp\left[-\frac{(\| \text{dist} \|_j b_j)^2}{2\sigma_j^2}\right] \quad (1)$$

式中: a_j 为经过高斯函数传递后的网络输出; nprod 为规范化点积权函数,是线性输出层的权值函数; $\| \text{dist} \|$ 为欧氏距离函数,即该层权值函数; b_j 为第 j 个隐含层与光滑因子有关的阈值; σ_j 为光滑因子(spread),它决定第 j 个隐含层位置处基函数的形状, σ_j 越大基函数越平滑。

GRNN 的每次训练都会自动检查输出误差,所产生的最大误差对应的输入向量会作为权值产生一个新的隐含层神经元,然后,新网络会循环检查误差直至神经元数量达到最大或达到一定精度为止。

初始化即训练样本的学习过程,学习样本确定了,则相应的网络结构和各神经元之间的连接权值也随之自动确定,网络训练过程实际上是确定光滑因子的过程。较 BPNN 而言,GRNN 的人为调节参数仅为 1 个,网络学习全部依赖于数据样本,这就决定了网络得以最大限度地避免人为主观假定对计算结果的影响。同时 GRNN 解决了 BPNN 训练时间长且确定隐含层数目难的问题,能稳定地描述系统的特征。

2 光滑因子的影响分析与选取方法

2.1 光滑因子的影响

一般情况下,训练能力差时网络的预测能力也差,并且在一定程度上随着训练能力的提高预测能力也会提高,但这种趋势有一个极限,达到此极限后,随着训练能力的提高,预测能力反而下降,即出现所谓过适性,也称为过拟合,此时网络学习了过多的样本细节而不能反映样本内在的规律。泛化能力差会造成不适性,过适性和不适性的网络都属于不成熟网络,仿真效果较差^[8]。

创建输入输出样本和广义回归神经网络,输入

样本在 $[-1, 1]$ 区间内均匀地取 21 个点,21 个数据点坐标如图 1 所示。当光滑因子取较小值 0.02 时,用步长 0.01 来检验拟合效果,观察所选光滑因子是否能够体现出所给样本内在的规律性。从图 1(a)中可以看出,网络记住了训练样本细节,甚至个别噪声,曲线较陡,在原始样本点处形成平台,附近的数值向其值靠拢。当光滑因子取较大值 0.2 时,从图 1(b)可以看出,网络进行函数逼近时拟合效果较差,出现了不适性。总体来说,光滑因子值越小,拟合越好,曲线越不光滑,但光滑因子太小时不能学习到真正的规律性,这样就对测试样本或仿真样本不敏感,即表现出过适性,以此网络来推广仿真势必会造成较大的误差。




图 1 训练样本的过适性与不适性

2.2 光滑因子的选取

采用 LOO 交叉验证方法评估模型的预测能力,即在一定范围内以某一步长递增变化,在学习样本中以 1 个样本作为估计样本,剩余的样本采用构造的 GRNN 对估计样本仿真,对所有样本都遍历 1 次,得到预测值与样本值之间的误差序列,以序列均方误差值作为网络的评价指标,将最小误差对应的光滑因子作为最终所选值。光滑因子的确定过程符合整体偏差最小原则^[9-11]。

$$E = \frac{1}{n} \sum_{i=1}^n [Y_i'(X_i) - Y_i]^2 \quad (2)$$

式中: E 为预测值与样本期望值的方差; X_i 为第 i 个样本对应的输入值; $Y_i'(X_i)$ 为第 i 个样本的预测值; Y_i 为样本期望值; n 为样本个数。

训练样本中选择某列数组作为估计样本,用剩余的样本构造学习样本,依次对所有样本遍历 1 次,具体表达如式(3)、式(4)所示:

a = [P(: 1 : j - 1) , P(: j + 1 : k)] (3)

b = [T(: 1 : j - 1) , T(: j + 1 : k)] (j = 1 2 ... k) (4)

式中 : a , b 分别为训练样本和期望样本 ; P 为输入样本 ; T 为输出样本 ; k 为输入或输出数组的列数 , 可以控制光滑因子的精度。

应用上面所示的样本可以求得光滑因子迭代值 , 其中用训练样本 a 代替输入样本 P , 用期望样本 b 代替输出样本 T , 即依次取出 j 列作为测试样本 , 剩余所有列作为训练样本 , 仿真后与理论值或实测值比较。

在确定平滑因子的过程中 , 初始值选取太小 , 式 (4) 可能出现除数为零的情况 , 文献 [3] 给出了初始值的计算公式 :

σ_min = √ [- D_min^2 / (2 ln ε)] (5)

式中 : σ_min 为光滑因子选取区间的初始值 ; D_min 为学习样本中各输入样本之间 Euclid 距离的最小值 ; ε 为计算机能够表达的最小正数。

以步长为 0.01 检验网络的拟合情况 , 选用误差最小时对应的光滑因子 (此时光滑因子为 0.058) , 网络仿真与训练样本如图 2 所示 , 拟合效果较好。对于一般问题 , 按照上述方法确定的平滑参数即可满足要求 , 也可建立优化问题模型 , 并应用传统和新型优化方法解决该问题。




图 2 GRNN 的逼真函数

3 应用实例及模型对比分析

为了得到比较好的预测效果 , 一般在网络训练前应对原始数据作预处理 , 包括剔除离散性较大的值 , 对数量级差别较大的数据作归一化或标准化处理 , 对输出向量作反处理变换至原单位 (如不存在相对于其他输入样本特别大或特别小的样本矢量可不进行归一化) 。归一化时对输入输出向量正则化处理 , 使其落入 [- 1 , 1] 区间 , 或归一到其单位方差和零均值 , 计算完毕后需要对结果数据还原。简单归一化和反归一化方法处理见式 (6) 式 (7) :

M'_i = (M_i - V_min) / (V_max - V_min) (6)

N_i = V_min + N_pi (V_max - V_min) (7)

式中 : M_i 为原始输入值 ; M'_i 为归一化后的网络输入值 ; N_pi 为在 [0 , 1] 区间的预测值 ; N_i 为预测值的还原值 ; V_min 和 V_max 分别为样本最小值和最大值。

算例 对 82 个实际工程边坡的极限平衡分析统计资料和边坡对应状态 (表 1) 分析可以发现 , 由于分析信息的模糊性、不确定性 , 即使计算安全系数大于 1.6 , 也有部分边坡最终发生失稳破坏。训练样本为密度 ρ 、黏聚力 c 、摩擦角 φ 、残余摩擦角 ψ 及坡高 H , 目标样本为安全系数和稳定状态。边坡稳定状态为 0 代表破坏 , 1 代表稳定 , 利用 GRNN 具备的聚类分类原理可以初步评判边坡稳定状态。

表 1 82 个实际工程边坡的统计资料与边坡稳定状态

样本编号	ρ / (kg · m ⁻³)	c / kPa	φ / (°)	ψ / (°)	H / m	安全系数	稳定状态
1	1200	0	30.0	35.0	8.00	0.86	0
2	2347	0	32.0	37.0	214.00	1.08	0
3	1600	70.00	20.0	40.0	115.00	1.11	0
4	2041	24.91	13.0	22.0	10.67	1.40	1
5	1963	11.97	20.0	22.0	12.19	1.35	0
6	2182	8.62	32.0	28.0	12.80	1.03	0
7	2041	33.52	11.0	16.0	45.72	1.28	0
8	1884	15.32	30.0	25.0	10.67	1.63	1
9	1884	0	20.0	20.0	7.62	1.05	0
10	2500	120.00	45.0	53.0	120.00	1.30	1
41	2000	0	36.0	45.0	50.00	0.67	0
42	2200	0	40.0	33.0	8.00	1.45	0
43	2400	0	40.0	33.0	8.00	1.58	0
44	2000	0	24.5	20.0	8.00	1.37	1
45	1800	5.00	30.0	26.0	8.00	2.05	0
79	2500	48.00	40.0	49.0	330.00	1.49	1
80	3130	68.60	37.0	47.0	305.00	1.20	0
81	2500	55.00	36.0	45.5	299.00	1.52	1
82	3130	68.00	37.0	47.0	213.00	1.20	0

样本 1 ~ 79 作为训练样本 , 样本 80 ~ 82 作为测试样本。对样本归一化处理后 GRNN 迭代搜索出的平滑因子值为 0.143 , 安全系数预测结果为 1.200 0 , 1.519 5 , 1.200 0 ; BPNN 的预测结果为 1.206 3 , 1.530 4 , 1.158 4 , 模型的预测结果如表 2 所示。从表 2 可以看出 , 即使存在安全系数大于 1.6 而产生破坏的干扰样本 (表 1 中样本 45) , 但总体预测情况仍然是良好的 , GRNN 预测的安全系数误差很小 , 最大为 0.03% , 而 BPNN 预测的安全系数最大误差

表 2 不同模型的预测值对比

样本 编号	理论 值	安全系数				状态的 理论值	稳定状态的 预测值	
		预测值		预测误差 / %			GRNN	BPNN
		GRNN	BPNN	GRNN	BPNN			
80	1.20	1.2000	1.2063	0	0.53	0	0	0.0107
81	1.52	1.5195	1.5304	0.03	0.68	1	0.9640	0.7797
82	1.20	1.2000	1.1584	0	3.47	0	0	0.0477

超过 3.5%。另外 GRNN 在计算过程中的快捷更显示了其优越性。

4 结 语

a. 讨论了 GRNN 网络中光滑因子的影响,光滑因子选取不当会造成网络的泛化能力差。根据光滑因子的初值,提出使用 LOO 交叉验证方法将得到的序列均方误差值作为网络的评价指标,最小误差对应的光滑因子即为所选值,并验证了该方法的合理性。

b. 搜集了 82 个圆弧滑动边坡稳定性样本,由于分析信息的模糊性、不确定性,即使计算安全系数大于 1.6 也有部分边坡最终发生失稳破坏。结合本文提出的光滑因子选取方法,应用 GRNN 模型进行预测分析,吻合效果较好,反演精度较高,网络操作简捷,易为工程人员接受,可在工程实际中应用。

c. 由于 GRNN 具有较强的函数拟合和逼近能力,其对样本依赖性强的特点使得选取具有代表性的训练样本数据非常重要,如果预测误差过大可能是数据的问题,关于如何减小训练样本数据中的误差或噪声对预测精度的影响需做进一步研究。

参考文献：

[1] 狄圣杰,徐卫亚.黏性土求主动土压力的库尔曼法及应用[J].岩土工程学报,2010,33(6):970-974.

(上接第 46 页)

有效地对低碳水利的实现情况进行考核检查。通过考核及其相应的奖惩,推动低碳水利的进程和发展。

5 结 语

低碳经济时代必然呼唤低碳水利。水利行业需要全面引进低碳经济理念,并积极实现,以促进水利的可持续发展,推进现代水利建设。

参考文献：

[1] 袁优男.低碳经济的概念内涵[J].城市环境与城市生态,2010,23(1):43-46.
[2] 齐洪钢.发展低碳经济建设节约型社会[J].经营管理者,2010(2):195-205.
[3] 蔡永海,张召.低碳时代中国生态文明建设新路径的探索[J].山西大学学报,2010,33(2):109-111.
[4] 江苏省水利厅.江苏省“十一·五”水利发展专项规划[R].南京:江苏省水利厅,2006.
[5] 江苏省环境保护厅.2009 年度江苏省环境状况公报[R].南京:江苏省环境保护厅,2010.
[6] 黄海田,樊志远,朱炳喜,等.水利建设工程推广应用预拌混凝土及其质量控制要点[J].商品混凝土,2009(10):59-61,63.

[2] 张玉,张方方.变水位多工况下大型渠道土质边坡的稳定分析[J].水利水电科技进展,2010,30(1):56-60.
[3] TOMANDL D, SCHOBER A. A modified general regression neural network with new efficient training algorithms as a robust ‘ black box ’ tool for data analysis[J]. Neural Networks, 2001, 14(4):1023-1034.
[4] 周昊,郑立刚,樊建人,等.广义回归神经网络在煤灰熔点预测中的应用[J].浙江大学学报:工学版,2004,38(11):1470-1482.
[5] 兰海涛,李谦,韩春雨.基于广义回归神经网络的边坡稳定性评价[J].岩土力学,2009,30(11):3460-3463.
[6] 周建萍,闫澍旺.广义回归神经网络预测加筋土支挡结构高度[J].岩土力学,2002,23(4):486-490.
[7] 冯志鹏,宋希庚,薛冬新,等.基于广义回归神经网络的时间序列预测研究[J].振动、测试与诊断,2003,23(2):105-144.
[8] DI Sheng-jie, XU Wei-ya, WEI Qing. The selection of spread and the application in engineering of GRNN[C]//Proceedings of 2nd International Conference on Information Science and Engineering, Hangzhou: IEEE, 2010: 5508-5511.
[9] BROOMHEAD D S, LOWE D. Multivariable functional interpolation and adaptive networks[J]. Complex System, 1988, 2: 321-355.
[10] SPECHT D F. A general regression neural network[J]. IEEE Transactions on Neural Network, 1991, 2: 568-576.
[11] DING D X, ZHANG Z J. Artificial neural network based inverse design method for circular sliding slopes[J]. J Cent South Univ Technol, 2004, 11(1):89-92.

(收稿日期:2010-07-06 编辑:骆超)

[7] 黄海田,张寒,黄亚明,等.从江水北调的实践看南水北调江苏境内工程实行优待电价的必要性和可行性[J].南水北调与水利科技,2007,3(4):3-11.
[8] 陈轶琦,刘谢莹,杨新明.水利改造亟待武装“低碳泵”[N].南通日报,2010-04-06(B06).
[9] 黄海田,冯晓莉,谢伟东,等.南水北调东线江苏境内泵站工程规划设计的优化[J].排灌机械,2005,23(5):19-21.
[10] 周颖,李清宇.苏南小城镇低碳水网系统的规划方法与政策探析[J].水利经济,2010,28(6):33-35,39.
[11] 赵黛青,张晔,蔡国田.低碳建筑的发展路径研究[J].建筑经济,2010(2):47-49.
[12] 吕振霖.加快提升江苏水利建设的现代化管理水平[J].江苏水利,2010(5):11-13,19.
[13] 黄海田.苏通大桥建设管理对江苏水利建设质量管理的启示[J].工程质量,2010,28(1):1-4.
[14] 江苏省农村水利科技发展中心.江苏省农村水利建设评价指标体系与方法研究[R].南京:江苏省农村水利科技发展中心,2010.
[15] 陈坚.对新时期我国泵站工程某些问题的再认识[J].中国农村水利水电,2004(4):71-72.
[16] 曹小琳,柳云状.我国发展低碳建筑的障碍因素及对策研究[J].建筑经济,2010(3):115-117.

(收稿日期:2010-08-05 编辑:高建群)