

DOI: 10.16198/j.cnki.1009-640X.2018.06.012

饶云康, 丁瑜, 倪强, 等. 基于 GA-BP 神经网络的粗粒土渗透系数预测[J]. 水利水电工程学报, 2018(6): 92-97. (RAO Yunkang, DING Yu, NI Qiang, et al. Prediction of permeability coefficients of coarse-grained soil based on GA-BP neural network[J]. Hydro-Science and Engineering, 2018(6): 92-97. (in Chinese))

基于 GA-BP 神经网络的粗粒土渗透系数预测

饶云康¹, 丁瑜^{1, 2, 3}, 倪强⁴, 许文年^{1, 2, 3}, 刘大翔^{1, 2, 3}, 张恒¹

(1. 三峡大学 三峡库区地质灾害教育部重点实验室, 湖北 宜昌 443002; 2. 防灾减灾湖北省重点实验室(三峡大学), 湖北 宜昌 443002; 3. 三峡地区地质灾害与生态环境湖北省协同创新中心, 湖北 宜昌 443002; 4. 嘉兴市规划设计研究院有限公司, 浙江 嘉兴 314050)

摘要: 针对粗粒土渗透性能受颗粒级配、密实程度等因素影响而呈现明显差异, 提出一种粗粒土渗透系数预测方法。收集并整理得到 93 组粗粒土数据, 以全级配($d_{10} \sim d_{100}$)和孔隙比作为 BP 神经网络的输入变量, 利用遗传算法优化 BP 神经网络的初始权值与阈值, 构建基于 BP 神经网络和遗传算法的粗粒土渗透系数预测模型。结果表明: 该 GA-BP 神经网络经过 55 次迭代之后精度满足要求; 87 组训练样本预测结果的平均相对误差为 5.10%, 其中有 75% 的样本相对误差小于平均相对误差; 6 组检测样本预测结果的平均相对误差为 6.39%, 该网络模型泛化性能良好。采用 GA-BP 神经网络, 由全级配和孔隙比能较好地预测粗粒土的渗透系数, 且收敛速度、预测精度及泛化性能均优于标准的 BP 神经网络模型。

关键词: 粗粒土; 渗透系数; BP 神经网络; 遗传算法; 孔隙比; 级配

中图分类号: TU411

文献标志码: A

文章编号: 1009-640X(2018)06-0092-06

根据规范^[1], 粗粒组(粒径在 0.075~60 mm 之间)质量分数大于 50% 的土即为粗粒类土, 简称粗粒土。粗粒土作为建筑材料、基础填料以及渗滤填料在水电、建筑、道路、市政等众多工程领域广泛应用, 其力学特性、渗透特性是岩土工程、水利工程等热切关注和研究的内容^[2-3]。实际工程中, 粗粒土涵盖的范围十分广泛, 粒径尺寸差异巨大, 加之压实状态变化, 其渗透性能呈现明显差异。因此, 如何准确预测粗粒土的渗透系数, 对于相关工程的渗透分析、防渗设计具有重要意义。

渗透系数是表征土体渗透性能的宏观参数, 受诸多因素影响, 其中, 颗粒级配和孔隙比是最主要的两个因素^[4-6]。众多学者们围绕颗粒级配、孔隙比开展了大量试验研究^[7-10]。基于试验成果总结, 学者们提出了一些用于估算粗粒土渗透系数的经验公式^[11-12]。经验公式变量主要为某些表征颗粒级配的指标, 有些也包括孔隙率或孔隙比。采用经验公式估算粗粒土渗透系数, 不同公式的计算结果差异较大, 往往与实测结果不符^[13-14]。由于试验数据有限和未能充分考虑各个粒径颗粒含量和孔隙比的影响, 经验公式适用范围有限。

针对上述不足, 一些学者采用人工神经网络方法预测渗透系数。唐晓松等^[15]采用 BP 神经网络, 由颗粒级配预测了粗粒土渗透系数。王双等^[16]以 $d_{10} \sim d_{\max}$ 表征全级配, 采用 BP 神经网络方法研究了碎石土级配对渗透系数的影响。文献^[16]的研究指出, 级配不是反映渗透系数唯一决定表征, 但该文未考虑孔隙比影响。合理地预测粗粒土渗透系数必须充分考虑各个粒径颗粒含量和孔隙比的影响。

若 BP 神经网络初始权值和阈值设置不合理, 存在收敛速度慢、陷入局部最优等问题^[17]。为克服上述

收稿日期: 2018-04-18

基金项目: 国家重点研发计划资助项目(2017YFC0504902-05); 国家自然科学基金项目资助项目(51678348, 51708333); 湖北省自然科学基金重点实验室资助项目(2016CFA085)

作者简介: 饶云康(1993—), 男, 湖北鄂州人, 硕士研究生, 主要从事环境岩土、多孔介质水分运移等方面研究。

E-mail: 376321668@qq.com 通信作者: 丁瑜(E-mail: thirding@163.com)

不足,可利用遗传算法对网络的初始权值和阈值进行优化,在较大范围进行搜索,代替一般的随机选取,然后应用BP网络算法对其进行精调,搜索出最优解或近似最优解^[18]。为此,本文通过相关文献选取93组粗粒土试验数据,考虑粒径累计曲线中的 $d_{10} \sim d_{100}$ 和孔隙比,利用遗传算法优化BP神经网络的初始权值与阈值,构建基于BP神经网络和遗传算法的粗粒土渗透系数预测模型。

1 样本选取与数据处理

1.1 样本选取

粗粒土渗透系数受诸多因素影响,如颗粒粒径、各级粒径颗粒分配情况、密实程度、颗粒形状等。颗粒级配是颗粒粒径、各级粒径颗粒分配的综合反映;孔隙比不仅直接与土体密实程度密切相关,也与颗粒形状有关。为此,以颗粒级配、孔隙比为主要因子选取样本,对粗粒土渗透系数进行预测。

通过查阅,分别从文献[11],[19],[20],[21],[7],[8]和[22]整理得到11,12,5,31,13,10和11组粗粒土渗透试验样本数据,共93组。样本数据的渗透系数直接来自于文献,是基于达西定律采用常水头试验测定的饱和渗透系数。渗透系数都是标准温度(20℃)下的渗透系数 k_{20} ,避免了温度不同的影响。除渗透系数外,各样本既包括颗粒级配信息,又包括直接或间接的孔隙比参数。

规程^[23]指出,当粗粒土中的细颗粒含量(小于0.075 mm)不超过12%时,土样不会因为细粒土含量过多而产生黏聚力,能自由排水。所选的93组样本均属于规范^[1]的粗粒土定义范围,且样本的细颗粒含量(小于0.075 mm)均不超过12%,属于颗粒之间无黏聚力的能自由排水的粗粒土。选取的样本渗透系数数量级主要为 $10^{-3} \sim 10^{-1}$ cm/s,少量为 10^{-4} cm/s,为典型的粗粒土渗透系数范围。最大粒径为100~5 mm,既有大粒径也有小粒径的粗粒土。样本的孔隙比最大为0.712,最小为0.093。样本的渗透系数、颗粒粒径、孔隙比涵盖范围广,具有代表性。

1.2 数据处理

对于93组数据,采取如下数据处理方式:

(1)孔隙比:若文献中给出了孔隙比,则直接采用;若没直接给出孔隙比,则根据文献提供的其他物理指标,由公式换算得出。

(2)颗粒级配:考虑了以往研究很少关注的粒径 d_{100} ,以 d_{10} , d_{20} , $\dots$, d_{100} 表征颗粒全级配。首先,根据样本数据利用Excel绘制粒径累计曲线;然后,由粒径累计曲线获取全级配 $d_{10} \sim d_{100}$ 粒径。为避免手工操作误差,利用图表数字化工具(GetData Graph Digitizer)从粒径累计曲线中准确获取粒径。

2 GA-BP神经网络预测模型

通过常用的3层网络结构,采用试凑法确定隐含层神经元个数。首先,由经验公式^[24] $J = \sqrt{m + n} + a$ (J 为隐含层神经元个数, m 为输入层神经元个数, n 为输出层神经元个数, a 为0~10的常数)来确定隐含层神经元个数范围。根据经验公式求得该神经网络隐含层神经元个数范围为4~14。然后分别在4~14个隐含层神经元条件下用相同的参数设置和训练样本重复建模20次,每次都使用相同的检测样本进行测试,通过对比20次检测样本的平均相对误差,最终确定隐含层最优神经元个数为12个。

BP神经网络传统的梯度下降法具有收敛速度慢、易陷入局部最小值等缺陷,而Levenberg-Marquardt(L-M)遗传算法可改善传统算法的缺陷,提高网络的收敛速度,以及增加网络训练精度^[25]。为此,网络训练函数采用trainlm函数,trainlm函数使用L-M算法,学习速率基值为0.001,学习速率减少率为0.1,学习速率增加率为10,最大学习速率为 10^{10} 。

GA-BP神经网络模型通过Matlab软件编程实现,遗传算法采用gaot工具箱,基本步骤如下:

(1)数据归一化,划分样本。导入93组样本数据,将样本数据归一化到 $[-1, 1]$,随机选择6组样本作为检测样本,剩余87组作为训练样本。

(2)建立BP神经网络。网络采用3层结构,输入层有11个神经元,分别代表 d_{10} , d_{20} , $\dots$, d_{100} 和孔隙比;

输出层神经元为渗透系数;隐含层有 12 个神经元;隐含层传递函数为 tansig 函数,输出层传递函数为 purelin 函数,网络性能函数采用均方误差 mse 函数;最大迭代次数为 1 000 次,目标误差值为 5×10^{-6} ,最低性能梯度为 10^{-10} 。

(3)产生初始种群。编码方式采用浮点数编码,个体由输入层与隐含层、隐含层与输出层神经元之间的连接权值,隐含层和输出层的阈值 4 部分组成,BP 神经网络为 11-12-1 结构,因此,个体编码长度为 $11 \times 12 + 12 \times 1 + 12 + 1 = 157$ 。个体中的变量范围为 $[-3, 3]$,种群规模为 50。

(4)解码,计算适应度。解码个体得到 BP 神经网络的初始权值和阈值,采用训练样本的网络计算值与试验值的均方差作为目标函数值,将目标函数值的倒数作为适应度,适应度越高,均方差越小,则该个体越优良。

(5)选择、交叉、变异,产生新种群。选择操作采用轮盘赌法选择算子;交叉操作采用算术交叉算子,即 2 个个体经过线性组合产生 2 个新的个体;变异操作采用非均匀变异算子。

(6)重复步骤(4)和(5),直至达到最大遗传代数 100。种群适应度进化曲线如图 1 所示,进化 75 代后种群的最大适应度保持不变,平均适应度与最大适应度基本重合,此时得到最优个体。

(7)解码最优个体得到优化的初始权值和阈值。

(8)采用优化后的初始权值和阈值,利用训练样本训练神经网络。

(9)通过检测样本检验网络模型的泛化性能。





图 1 适应度进化曲线

Fig. 1 Fitness evolution curves

3 结果分析与讨论

3.1 模型收敛速度

分别采用 BP 神经网络和 GA-BP 神经网络两种方法建立粗粒土渗透系数预测模型进行对比研究。图 2 为两种方法的训练窗口。BP 神经网络经过 120 次迭代之后达到目标误差值 5×10^{-6} 的要求,而采用相同的参数设置,GA-BP 神经网络只需 55 次迭代就能达到目标误差值。表明遗传算法能优化得到合理的 BP 神经网络初始权值和阈值,能明显提高 BP 神经网络的收敛速度。



(a) BP神经网络

(b) GA-BP神经网络

图 2 网络训练窗口

Fig. 2 Neural network training window

3.2 训练样本验证

用建立的 GA-BP 神经网络模型预测训练样本,结果如图 3 所示,平均相对误差为 5.10%,其中有 75% 的样本相对误差小于平均相对误差,渗透系数预测值与试验值较接近,相对误差在可接受范围,精度较高。BP 神经网络模型对训练样本的预测误差与 GA-BP 神经网络相差不大。

3.3 预测精度及泛化性能

神经网络预测精度的评价指标主要为相对误差和平均相对误差,为了检验和比较两种模型的预测精度和泛化性能,分别用两种模型预测 6 组检测样本。6 组检测样本来源于 5 篇文献,孔隙比最大为 0.548,最小为




图 3 训练样本的预测结果

Fig. 3 Predicted results of training samples

0. 121。检测样本最大粒径为 60~5 mm,且渗透系数试验值数量级涵盖 $10^{-3} \sim 10^{-1}$ cm/s,具有代表性。

检测样本的两种模型预测结果与试验结果如表 1 所示,采用 GA-BP 神经网络的最大相对误差为 10. 44%,平均相对误差为 6. 39%,渗透系数预测值与试验值较接近,相对误差在可接受范围,表明该神经网络的泛化性能良好。而采用 BP 神经网络,最大相对误差为 31. 97%,平均相对误差为 12. 64%,预测误差明显高于 GA-BP 神经网络,表明 GA-BP 神经网络模型的泛化性能优于 BP 神经网络。

表 1 检测样本的预测结果

Tab. 1 Predicted results of testing samples

编号	来源	试验值/(cm·s ⁻¹)	BP 神经网络		GA-BP 神经网络	
			预测值/(cm·s ⁻¹)	相对误差/%	预测值/(cm·s ⁻¹)	相对误差/%
S1	文献[19]	8.32×10^{-2}	7.99×10^{-2}	3. 97	8.75×10^{-2}	5. 17
S2	文献[20]	3.50×10^{-1}	2.38×10^{-1}	31. 97	3.33×10^{-1}	5. 01
S3	文献[21]	2.20×10^{-2}	2.10×10^{-2}	4. 55	2.31×10^{-2}	4. 85
S4	文献[21]	5.70×10^{-2}	5.29×10^{-2}	7. 19	5.43×10^{-2}	4. 75
S5	文献[8]	1.42×10^{-2}	1.27×10^{-2}	10. 56	1.31×10^{-2}	8. 13
S6	文献[22]	3.13×10^{-3}	2.58×10^{-3}	17. 57	3.46×10^{-3}	10. 44

全级配和孔隙比表征粗粒土自身性质,而试验过程中的击实操作导致的颗粒破碎会使粗粒土级配略有改变,渗透试验存在边壁效应和尺寸效应^[3]等均会影响渗透系数试验结果,因此神经网络的渗透系数预测值与试验值存在误差是正常的。

综上所述,考虑全级配和孔隙比建立 GA-BP 神经网络模型,其预测值与试验值较吻合,且具有较好的泛化性能。颗粒级配和孔隙比是粗粒土渗透系数的主要影响因素,该神经网络能充分反映颗粒级配和孔隙比对粗粒土渗透系数的影响。研究表明,采用 GA-BP 神经网络,由全级配和孔隙比能较好地预测粗粒土渗透系数,可为实际工程中粗粒土选配与改善提供参考依据。

4 结 语

- 考虑全级配 $d_{10} \sim d_{100}$ 和孔隙比,分别采用 BP 神经网络和 GA-BP 神经网络构建粗粒土渗透系数预测模型,得出主要结论如下:
- (1)BP 神经网络和 GA-BP 神经网络分别经过 120 次和 55 次迭代之后达到相同的目标误差值。分析 6 组检测样本的预测结果,BP 神经网络的最大相对误差为 31. 97%,平均相对误差为 12. 64%,而 GA-BP 神经网络的最大相对误差为 10. 44%,平均相对误差为 6. 39%。表明遗传算法能优化得到合理的 BP 神经网络初始权值和阈值,能明显提高 BP 神经网络的收敛速度,所建模型预测精度较高且泛化性能较好。
- (2)87 组训练样本预测结果的平均相对误差为 5. 10%,6 组检测样本预测结果的平均相对误差为 6. 39%,表明 GA-BP 神经网络模型能充分反映颗粒级配和孔隙比对粗粒土渗透系数的影响,采用 GA-BP 神经网络,由全级配和孔隙比能较好地预测粗粒土的渗透系数。
- (3)收集各工程渗透试验数据,建立神经网络大数据平台,可为后续粗粒土工程渗透系数的预估提供参考。

参 考 文 献:

[1] GB/T50145—2007 土的工程分类标准[S]. (GB/T50145—2007 Standard for engineering classification of soil[S]. (in Chinese))

[2] 刘建坤,于钱米,刘景宇,等. 细粒土不均匀分布对粗粒土力学特性的影响[J]. 岩土工程学报, 2017, 39(3): 562-572.

- (LIU Jiankun, YU Qianmi, LIU Jingyu, et al. Influence of non-uniform distribution of fine soil on mechanical properties of coarse-grained soil[J]. Chinese Journal of Geotechnical Engineering, 2017, 39(3): 562-572. (in Chinese))
- [3] 朱国胜, 张家发, 陈劲松, 等. 宽级配粗粒土渗透试验尺寸效应及边壁效应研究[J]. 岩土力学, 2012, 33(9): 2569-2574. (ZHU Guosheng, ZHANG Jiafa, CHEN Jinsong, et al. Study of size and wall effects in seepage test of broadly graded coarse materials[J]. Rock and Soil Mechanics, 2012, 33(9): 2569-2574. (in Chinese))
- [4] 黄达, 曾彬, 王庆乐. 粗粒土孔隙比及级配参数与渗透系数概率的相关性研究[J]. 水利学报, 2015, 46(8): 900-907. (HUANG Da, ZENG Bin, WANG Qingle. Study on probabilistic relation between permeability coefficient and void ratio and grain composition of coarse grained soils using Copula theory[J]. Journal of Hydraulic Engineering, 2015, 46(8): 900-907. (in Chinese))
- [5] 邵生俊, 李建军, 杨扶银. 粗粒土孔隙特征及其对泥浆渗透性的影响[J]. 岩土工程学报, 2009, 31(1): 59-65. (SHAO Shengjun, LI Jianjun, YANG Fuyin. Pore characteristics of coarse grained soil and their effect on slurry permeability[J]. Chinese Journal of Geotechnical Engineering, 2009, 31(1): 59-65. (in Chinese))
- [6] 黄文熙. 土的工程性质[M]. 北京: 水利电力出版社, 1983. (HUANG Wenxi. Engineering properties of soils[M]. Beijing: China Water & Power Press, 1983. (in Chinese))
- [7] 李文波. 粗粒土物理力学特性研究[D]. 昆明: 昆明理工大学, 2015. (LI Wenbo. Study on physical and mechanical properties of coarse grained soil[D]. Kunming: Kunming University of Science and Technology, 2015. (in Chinese))
- [8] 张宜健. 不同粒径级砂性土渗透特性试验研究[D]. 西安: 西安建筑科技大学, 2013. (ZHANG Yijian. Investigation on permeability of sands with different particle size [D]. Xi'an: Xi'an University of Architecture and Technology, 2013. (in Chinese))
- [9] 张国栋, 廖爱明, 李泯蒂, 等. 碎石土渗透特性试验研究[J]. 水利水运工程学报, 2016(5): 91-95. (ZHANG Guodong, LIAO Aiming, LI Mindi, et al. Model test studies on permeability of gravel soil[J]. Hydro-Science and Engineering, 2016(5): 91-95. (in Chinese))
- [10] 王俊杰, 卢孝志, 邱珍锋, 等. 粗粒土渗透系数影响因素试验研究[J]. 水利水运工程学报, 2013(6): 16-20. (WANG Junjie, LU Xiaozhi, QIU Zhenfeng, et al. Experimental studies on influence factors of permeability coefficients of coarse-grained soil [J]. Hydro-Science and Engineering, 2013(6): 16-20. (in Chinese))
- [11] 朱崇辉, 刘俊民, 王增红. 粗粒土的颗粒级配对渗透系数的影响规律研究[J]. 人民黄河, 2005, 27(12): 79-81. (ZHU Chonghui, LIU Junmin, WANG Zenghong. Experimental study on osmosis of cohesion less soils[J]. Yellow River, 2005, 27(12): 79-81. (in Chinese))
- [12] 刘杰. 土的渗流稳定与渗流控制[M]. 北京: 水利电力出版社, 1992. (LIU Jie. Seepage stability and seepage control of soil [M]. Beijing: Water Resources and Electric Power Press, 1992. (in Chinese))
- [13] AGUS S S, LEONG E C, RAHARDJO H. Estimating permeability functions of Singapore residual soils[J]. Engineering Geology, 2005, 78(1): 119-133.
- [14] SONG J X, CHEN X H, CHENG C, et al. Feasibility of grain-size analysis methods for determination of vertical hydraulic conductivity of streambeds[J]. Journal of Hydrology, 2009, 375(3): 428-437.
- [15] 唐晓松, 郑颖人, 董诚. 应用神经网络预估粗颗粒土的渗透系数[J]. 岩土力学, 2007, 28(增刊1): 133-136, 143. (TANG Xiaosong, ZHENG Yingren, DONG Cheng. The prediction of seepage coefficient of coarse-grained soil by neurotic network[J]. Rock and Soil Mechanics, 2007, 28(Suppl1): 133-136. (in Chinese))
- [16] 王双, 李小春, 王少泉, 等. 碎石土级配特征对渗透系数的影响研究[J]. 岩石力学与工程学报, 2015, 34(增刊2): 4394-4402. (WANG Shuang, LI Xiaochun, WANG Shaoquan, et al. Study of gravel-soil gradation characteristics influence on the permeability coefficient[J]. Chinese Journal of Rock Mechanics and Engineering, 2015, 34(Suppl2): 4394-4402. (in Chinese))
- [17] 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, 46(5): 837-841, 904. (WANG Deming, WANG Li, ZHANG Guangming. Short-term wind speed forecast model for wind farms based on genetic BP neural network[J]. Journal of Zhejiang University (Engineering Science), 2012, 46(5): 837-841, 904. (in Chinese))
- [18] 彭基伟, 吕文华, 行鸿彦, 等. 基于改进 GA-BP 神经网络的湿度传感器的温度补偿[J]. 仪器仪表学报, 2013, 34(1): 153-160. (PENG Jiwei, LYU Wenhua, XING Hongyan, et al. Temperature compensation for humidity sensor based on improved GA-BP neural network[J]. Chinese Journal of Scientific Instrument, 2013, 34(1): 153-160. (in Chinese))
- [19] 李文波. 粗粒土渗透特性影响因素及渗透规律试验研究[J]. 价值工程, 2013(36): 105-107. (LI Wenbo. The influence

- factors of coarse-grained soil permeability characteristics and testing study on seepage law of the coarse-grained soil[J]. Value Engineering, 2013(36): 105-107. (in Chinese))
- [20] 鲁华征. 级配碎石设计方法研究[D]. 西安: 长安大学, 2006. (LU Huazheng. Design method of graded grave[D]. Xi'an: Chang'an University, 2006. (in Chinese))
- [21] 朱崇辉. 粗粒土的渗透特性研究[D]. 西安: 西北农林科技大学, 2006. (ZHU Chonghui. Study on the coarse-grained soil permeability characteristic[D]. Xi'an: Northwest A & F University, 2006. (in Chinese))
- [22] 谢定松, 蔡红, 魏迎奇, 等. 粗粒土渗透试验缩尺原则与方法探讨[J]. 岩土工程学报, 2015, 37(2): 369-373. (XIE Dingsong, CAI Hong, WEI Yingqi, et al. Scaling principle and method in seepage tests on coarse materials[J]. Chinese Journal of Geotechnical Engineering, 2015, 37(2): 369-373. (in Chinese))
- [23] SL237—1999 土工试验规程[S]. (SL237—1999 Specification of soil test[S]. (in Chinese))
- [24] 陈明. MATLAB 神经网络原理与实例精解[M]. 北京: 清华大学出版社, 2013. (CHEN Ming. MATLAB neural network principles and examples[M]. Beijing: Tsinghua University Press, 2013. (in Chinese))
- [25] 王元章, 吴春华, 周笛青, 等. 基于BP神经网络的光伏阵列故障诊断研究[J]. 电力系统保护与控制, 2013, 41(16): 108-114. (WANG Yuanzhang, WU Chunhua, ZHOU Diqing, et al. A survey of fault diagnosis for PV array based on BP neural network[J]. Power System Protection and Control, 2013, 41(16): 108-114. (in Chinese))

Prediction of permeability coefficients of coarse-grained soil based on GA-BP neural network

RAO Yunkang¹, DING Yu^{1, 2, 3}, NI Qiang⁴, XU Wennian^{1, 2, 3}, LIU Daxiang^{1, 2, 3}, ZHANG Heng¹

(1. Key Laboratory of Geological Hazards in Three Gorges Reservoir Area, Ministry of Education, China Three Gorges University, Yichang 443002, China; 2. Key Laboratory of Disaster Prevention and Mitigation, Hubei Province, China Three Gorges University, Yichang 443002, China; 3. Collaborative Innovation Center for Geo-Hazards and Eco-environment in Three Gorges Area, Hubei Province, Yichang 443002, China; 4. Jiaxing Planning & Research Institute Co., Ltd., Jiaxing 314050, China)

Abstract: In view of the obvious difference in the permeability of the coarse grained soil, effected by factors such as gradation of grain and compaction degree, a prediction method for the permeability of the coarse-grained soil is proposed in this study. 93 groups of data of the coarse-grained soil are collected and obtained. Taking the full gradation($d_{10} \sim d_{100}$) and the porosity ratio as the input variables of the BP neural network, a prediction model for the permeability coefficients of the coarse-grained soil is developed on the basis of the BP neural network and genetic algorithm, by using the genetic algorithm to optimize the BP neural network's initial weights and thresholds. The research results show that the accuracy of the GA-BP neural network meets the requirements after 55 iterations. And the mean relative error of the predicted results of 87 groups of the training samples is 5.10%. Moreover, a relative error of 75% of the training samples is less than the mean relative error. In addition, the mean relative error of 6 groups of the testing samples is 6.39%, which indicates that the generalization performance of the network model is high. It is concluded that the permeability coefficients of the coarse-grained soil can be well predicted by applying the GA-BP neural network considering the full gradation and void ratio. Moreover, The convergence rate, the prediction accuracy and the generalization performance of the GA-BP neural network are better than those of the standard BP neural network model. And the model based on the GA-BP neural network can provide technical references and support for the selection and improvement of the coarse-grained soil in practical engineering.

Key words: coarse-grained soil; permeability coefficient; BP neural network; genetic algorithm; void ratio; gradation