

基于BP神经网络的MICP加固滨海软土强度仿真和预测

谭孝秦¹, 璩继立²

¹上海理工大学环境与建筑学院, 上海

²喀什大学土木工程学院, 新疆 喀什

收稿日期: 2024年4月26日; 录用日期: 2024年5月23日; 发布日期: 2024年5月31日

摘要

MICP是一种环保且有效的滨海软土加固方法, 它是利用微生物分解尿素生成碳酸根, 然后与钙源反应生成碳酸钙沉淀, 填充土颗粒间孔隙的同时胶结分散的土颗粒进而改善其工程力学性能。但加固后土体的强度受营养液浓度、菌液浓度的影响较大, 需要通过大量的试验找寻其规律。为了减少成本, 通过Matlab软件构建BP神经网络模型, 使用624组数据对模型进行训练, 再对加固后土体的156组强度数据进行预测。研究表明: 经过大量的试验数据训练后, 预测的剪应力与实际试验剪应力差异范围在-5.370%到4.238%之间, 决定系数 R^2 均大于0.9。验证了通过BP神经网络预测MICP加固滨海软土强度是可靠的, 可减少试验工作量, 为实际工程节约成本, 为日后类似加固土的研究提供指导。

关键词

BP神经网络, 强度预测, MICP, Matlab

Simulation and Prediction of Strength of MICP Reinforced Coastal Soft Soil Based on BP Neural Network

Xiaoqin Tan¹, Jili Qu²

¹School of Environment and Architecture, University of Shanghai for Science and Technology, Shanghai

²School of Civil Engineering, Kashi University, Kashi Xinjiang

Received: Apr. 26th, 2024; accepted: May 23rd, 2024; published: May 31st, 2024

文章引用: 谭孝秦, 璩继立. 基于BP神经网络的MICP加固滨海软土强度仿真和预测[J]. 建模与仿真, 2024, 13(3): 3942-3951. DOI: 10.12677/mos.2024.133359

Abstract

MICP is an environmentally friendly and effective method for strengthening coastal soft soil. It uses microorganisms to decompose urea to generate carbonate ions, which then react with calcium sources to form calcium carbonate precipitates. It fills the pores between soil particles while cementing dispersed soil particles to improve their engineering mechanical properties. However, the strength of the reinforced soil is greatly affected by the concentration of nutrient solution and bacterial solution, and a large number of experiments are needed to find their patterns. In order to reduce costs, a BP neural network model was constructed using Matlab software, trained with 624 sets of data, and predicted with 156 sets of strength data of the reinforced soil. The research results indicate that after a large amount of experimental data training, the difference between the predicted shear stress and the actual experimental shear stress ranges from -5.370% to 4.238%, and the determination coefficient R^2 is greater than 0.9. Verified the reliability of using BP neural network to predict the strength of MICP reinforced coastal soft soil, which can reduce experimental workload, save costs for practical engineering, and provide guidance for future research on similar reinforced soil.

Keywords

BP Neural Network, Intensity Prediction, MICP, Matlab

Copyright © 2024 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

滨海地区, 如上海、福建、浙江等地软土分布广泛, 软土的天然含水率高、承载力低、压缩性大, 需要进行加固才能运用到工程当中。近年来在“双碳”的背景下, 各种环保加固方式兴起, 微生物诱导碳酸钙沉积技术(Microbially Induced Carbonate Precipitation, MICP)是一种新型的土壤加固技术, 原理是尿素在微生物降解下生成 CO_3^{2-} , 钙源中的 Ca^{2+} 与之结合成有胶凝性质的 CaCO_3 沉淀, 起到填充土颗粒间的孔隙同时胶结分散的土颗粒的作用, 有效提高土体强度。加固的效果也受到营养液浓度、菌液浓度等因素影响。像此类新颖环保的土体加固方式近年来越来越多, 这些研究丰富了工程理论的同时, 也给研究人员们带来了巨大的工作量。对于加固后的土体强度, 检测试验较为困难, 周期较长, 成本很高。Anh [1]构建人工神经网络模型用于造纸污泥灰稳定剂处理余土混合料设计; 顾等[2]引入 LASSO 算法, 对漏湖组黏性土抗剪强度进行有效预测; Hao 等[3]基于中国 15 个城市的 18 个固体废物分类指标, 使用人工神经网络(ANN)模型, 评估城市生活垃圾分离能力。建立基于扫描优化和机器学习方法的人工神经网络来预测缺失指标。从而将城市生活垃圾分离能力的预测精度提高到 95.15%; Huan 等[4]使用 BP 神经网络描绘了污染物羽流, 分析了污染物在不同层中的空间分布, 提出了一个集成 BP 网络和地质统计学的模型, 以描绘共污染地点的土壤污染物羽流; Li 等[5]用 BP 神经网络研究了埋地腐蚀管道的可靠性。结果表明, 用于预测管道破坏压力的拟合公式比传统代码更准确。埋藏深度、冻胀速率、冻胀段长度等对腐蚀管道可靠性的影响相对较小。5000 mm 以内的冻胀段对腐蚀管道的可靠性起到一定的积极作用; 上述研究表明, BP 神经网络预测这个领域国内外已有一定数量的研究, 但是如 MICP 这类新颖环保的土体加固方式,

与 BP 神经网络的结合方面还有欠缺。本研究从资源的充分利用层面出发, 构建出了一种通过 BP 神经网络预测各种变量对于加固土体强度的影响的模型。

BP 神经网络具有很强的非线性映射能力[6], 本文使用 Matlab 软件进行基于 BP 神经网络的 MICP 加固滨海软土的强度预测模型构建, 根据不同的养护天数、营养液浓度、菌液浓度、垂直应力预测土体的应力应变曲线, 预测不同配置下的滨海软土强度, 节约人力物力, 并为滨海软土加固提供指导。

2. BP 神经网络的函数模型和求解

2.1. 神经网络模型构建

根据神经网络的特点, 利用训练集进行训练, 训练开始时, 随机初始化权重和偏置系数, 将归一化的数据正向传播进行拟合, 得到预测的数据[7], 然后根据初步预测的结果和真实试验数据构造损失函数, 计算损失函数的值再反向传播修改权重, 设置误差的阈值, 以上操作经过不断循环, 直到模型达到使用所需的要求[8]。模型的工作步骤如图 1 所示。

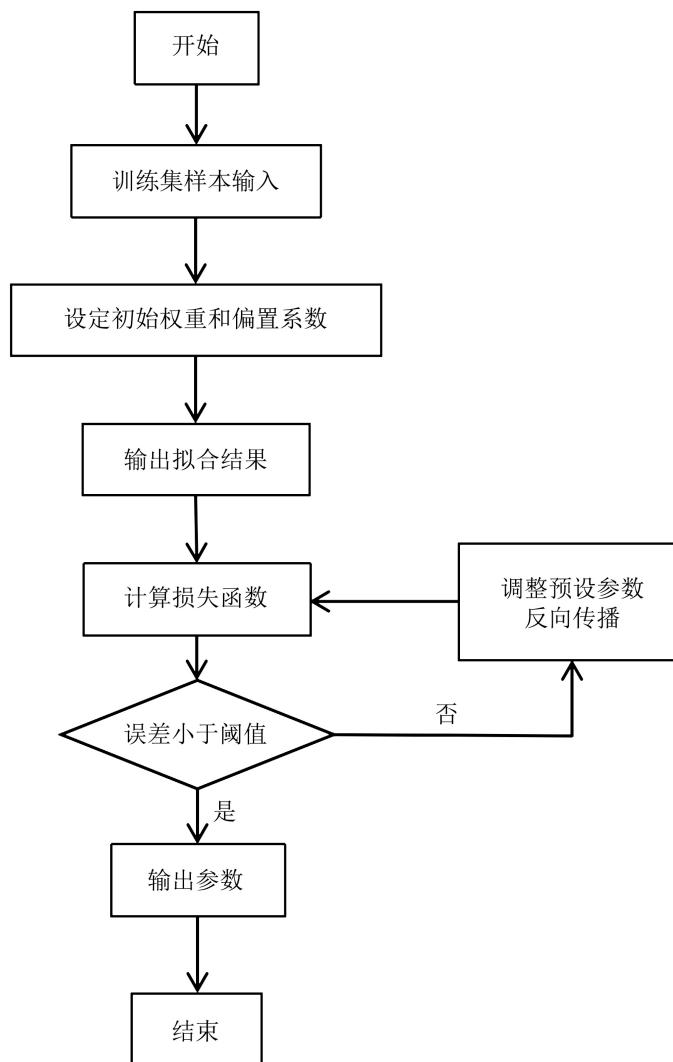


Figure 1. BP Neural network workflow

图 1. BP 神经网络工作流程

2.2. 函数求解

1) 正向传播过程

隐含层输出:

$$y'_{pj} = f_1(\text{net}_{pj}) = f_1\left(\sum_{i=1}^n V_{ji} X_{pi}\right) \quad (1)$$

式中: y'_{pj} 为隐含层的输出; net_{pj} 为神经因子; V_{ji} 为输入层到隐含层之间的权值; X_{pi} 为隐含层的输入。

输出层输出:

$$y_{pk} = f_2(\text{net}_{pk}) = f_2\left(\sum_{k=1}^q w_{jk} y'_{pj}\right) \quad (2)$$

式中: y_{pk} 为输出层输出; w_{jk} 为附加向量因子。

正向传播中的误差函数:

$$E_p = \frac{1}{2} \sum_{k=1}^m (d_{pk} - y_{pk})^2 \quad (3)$$

式中: E_p 为正向传播中的误差函数; d_{pk} 为输出的期望值。

2) 反向传播过程

通过调整输出层的权值, 使得误差减小, 依据链式法则及所述关系, 函数沿梯度运行方向的变化最快, BP 神经网络中通过梯度下降法来更新权重[9]。权值的变化量 ΔW_{jk} :

$$\begin{aligned} \Delta W_{jk} &= -\eta \frac{\partial E_p}{\partial W_{jk}} = \sum_{p=1}^P \left(-\eta \frac{\partial E_p}{\partial W_{jk}} \right) \\ &= \eta \sum_{p=1}^P \left(-\frac{\partial E_p}{\partial \text{net}_{pk}} \cdot \frac{\partial \text{net}_{pk}}{\partial W_{jk}} \right) \end{aligned} \quad (4)$$

式中: η 为反向传播过程中的权值因子。

设反向传播经激活函数后的误差为:

$$\delta_{pk} = -\frac{\partial E_p}{\partial \text{net}_{pk}} = -\frac{\partial E_p}{\partial y_{pk}} \cdot \frac{\partial y_{pk}}{\partial \text{net}_{pk}} \quad (5)$$

根据(4)和(5), 可以得到 δ_{pk} :

$$\delta_{pk} = (d_{pk} - y_{pk}) y_{pk} (1 - y_{pk}) \quad (6)$$

根据上述公式可以得到神经元的权值变化 ΔW_{jk} 为:

$$\begin{aligned} \Delta W_{jk} &= \eta \sum_{p=1}^P \left(-\frac{\partial E_p}{\partial \text{net}_{pk}} \cdot \frac{\partial \text{net}_{pk}}{\partial W_{jk}} \right) \\ &= \eta \sum_{p=1}^P (d_{pk} - y_{pk}) y_{pk} (1 - y_{pk}) y'_{pj} \end{aligned} \quad (7)$$

输入层和隐含层之间的权值变化 ΔV_{ij} 为:

$$\Delta V_{ij} = -\eta \frac{\partial E}{\partial V_{ij}} = \sum_{p=1}^P \left(-\eta \frac{\partial E_p}{\partial V_{ij}} \right) = \eta \sum_{p=1}^P \left(-\frac{\partial E_p}{\partial \text{net}_{pj}} \cdot \frac{\partial \text{net}_{pj}}{\partial V_{ij}} \right) \quad (8)$$

假设反向传播经过激活函数 j 次后的误差为:

$$\delta'_{pj} = -\frac{\partial E_p}{\partial net_{pj}} = \frac{\partial E_p}{\partial y'_{pj}} \cdot \frac{\partial y'_{pj}}{\partial net_{pj}} \quad (9)$$

根据(8)和(9)可得:

$$\delta'_{pj} = y'_{pj}(1 - y'_{pj}) \sum_{k=1}^K \delta_{pk} W_{jk} \quad (10)$$

可知输入层和隐含层之间的权值变化量为:

$$\Delta V_{ij} = \eta \sum_{p=1}^P \left(-\frac{\partial E_p}{\partial net_{pj}} \cdot \frac{\partial net_{pj}}{\partial W_{ij}} \right) = \eta \sum_{p=1}^P \left(\sum_{k=1}^K \delta_{pk} V_{jk} \right) y'_{pj}(1 - y'_{pj}) x_{pi} \quad (11)$$

BP 神经网络拥有良好的学习能力, 经过大量数据训练, 可以得到目标的特征, 拥有对新数据进行准确分析预测的能力。

3. 模型预测

3.1. 神经网络的训练

本研究使用 MATLAB 进行 BP 神经网络的编写。使用 StandardScaler 归一化对数据进行预处理; 激活函数选用双曲正切函数 $\tanh(x)$ 作为激活函数; 采用 glort 初始化, 损失函数使用平方差损失函数 MSE Loss; 优化器采用 Adam 优化器; 正则化系数为 0.0034, 偏置初始化方式全为 0; 对于隐层神经元的选取, 在测试集上的性能指标, 选取每个点的误差作为性能评估指标; 决定系数 R^2 是指自变量对因变量的解释程度, R^2 越大表示拟合程度越高[10]; 学习率选择 0.01, 训练次数 epoch 选择 1000 次。把经过 MICP 加固后的海滨软土强度数据中的 80% 作为训练集, 20% 的数据作为测试集, 训练集包括 624 组数据, 测试集中包括 156 组数据[11] [12]。输入为养护天数、菌液浓度、营养液浓度、垂直应力、剪切位移五个输入量, 由于输入数量较多, 隐藏层数确定为 3。BP 神经网络的隐含层节点数对 BP 神经网络预测精度有很大的影响, 使用公式(12)确定隐含层的点数范围, 经过多次循环和试验确定最佳的隐含层节点数, 在网络训练达到目标误差时, 停止训练。经过调试优化, 层的尺寸为 65, 4, 247 时, 逼近效果最好, 误差较小, 神经网络结构如图 2。




Figure 2. Structure diagram of BP neural network
图 2. BP 神经网络结构图

隐含层节点数如公式(12)表示:

$$l = \sqrt{m+n+a} \quad (12)$$

式中: l 为隐含层的节点数; m 为输入层的节点数; n 为输出层的节点数; a 为 0~10 之间的常数。

神经网络的表达式可以简单的如公式(13)表示:

$$H = \sum \sigma(X \times \omega + b) \quad (13)$$

式中: Y 为输出结果; X 为输入的数据; ω 为权重矩阵; b 为偏置矩阵; σ 为激活函数。

为了更有效率的训练神经网络, 选取的 526 组数据里面, 分别包含了不同的养护天数、营养液浓度、菌液浓度、垂直应力、剪切位移等变量。其中需要预测的 C、F、G 组养护天数均为 14 天, 这是因为养护 21 天和 28 天的试块强度反而下降, 对于强度最佳的养护天数为 14 天, 其他养护天数的预测不具有工程价值。而营养液浓度和菌液浓度是在土壤中生成碳酸钙沉淀的重要影响因素, C、F、G 中含有不同营养液浓度和菌液浓度的组合, 以此更好验证的 BP 神经网络的可靠性。试块的养护天数、营养液浓度、菌液浓度如表 1。

Table 1. Data grouping scheme

表 1. 数据分组方案

试验组	养护天数/d	营养液浓度/(mol/L)	菌液浓度 OD600	数据类型
A	3	1	0.70	测试组
B	7	1	0.70	测试组
C	14	1	0.70	预测组
D	21	1	0.70	测试组
E	14	0.5	0.65	测试组
F	14	1	0.65	测试组
G	14	1.5	0.65	预测组
H	14	2	0.65	预测组
I	14	1	0.30	测试组
J	14	1	0.60	测试组
K	14	1	0.90	测试组
L	28	0	0	测试组

3.2. 预测结果

在本研究中, 使用 A、B、D、E、H、I、J、K、L 组的试验数据作为测试集, 这些数据反映了不同的变量对于土体强度的影响程度。训练到位后去预测 C、F、G 组的试验数据, 通过预测出的数据和实际数据, 绘制了对比图, 下图中黑色曲线为真实的试验数据, 蓝色曲线为预测的数据(图 3~7)。并且通过这些数据算出了定系数 R^2 , 以及百分误差。根据误差值绘制了散点图(图 8), 以便寻找加固后的土体强度变化规律。




Figure 3. Vertical stress $P = 50$ kPa shear stress-shear displacement curve
图 3. 垂直应力 $P = 50$ kPa 剪应力 - 剪切位移曲线




Figure 4. Vertical stress $P = 100$ kPa shear stress-shear displacement curve
图 4. 垂直应力 $P = 100$ kPa 剪应力 - 剪切位移曲线




Figure 5. Vertical stress $P = 200$ kPa shear stress-shear displacement curve
图 5. 垂直应力 $P = 200$ kPa 剪应力 - 剪切位移曲线




Figure 6. Vertical stress $P = 300$ kPa shear stress-shear displacement curve
图 6. 垂直应力 $P = 300$ kPa 剪应力 - 剪切位移曲线




Figure 7. Comparison of the true value with the predicted value
图 7. 真实值与预测值对比

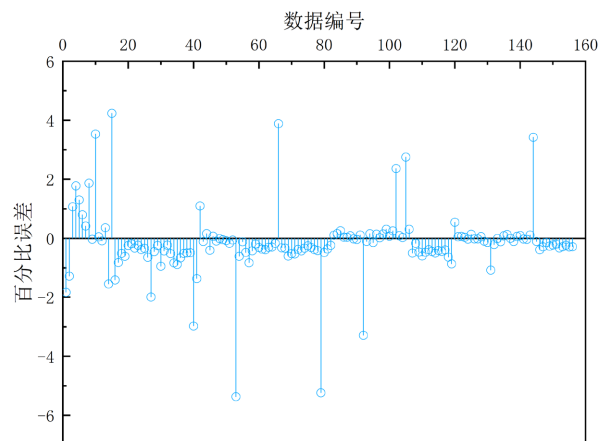


Figure 8. Percentage error
图 8. 百分误差

在预测整条剪应力 - 剪切位移曲线产生的单个点的最大误差, 以及整条曲线的决定性数 R^2 如表 2 所示。

Table 2. Maximum prediction curve error and determination coefficient

表 2. 预测曲线误差最大值和决定系数

试验组	垂直应力(Kpa)	此曲线误差最大值(%)	预测曲线决定系数 R^2
C	50	3.533	0.933
C	100	4.238	0.926
C	200	-1.991	0.947
C	300	-2.974	0.931
F	50	2.754	0.943
F	100	-1.079	0.967
F	200	3.425	0.947
F	300	-0.386	0.939
G	50	-5.370	0.929
G	100	3.884	0.917
G	200	-5.236	0.925
G	300	-3.287	0.937

$$E = \frac{T - P}{T} \times 100\% \quad (13)$$

式中: E 为误差值, T 为试验值, P 为预测值。

图 3、图 4、图 5、图 6 中的黑色曲线为实际值曲线, 蓝色曲线为预测曲线。3 个预测组中的养护天数均为 14 天。其中包含了 156 组数据, 经过训练后, 预测出的曲线的增长趋势与实际趋势相符合, 决定系数 R^2 最高达到 0.967, 最低为 0.917, 平均决定系数为 0.937。表明所建立的 BP 神经网络符合要求, 可以预测不用垂直应力、不同营养液浓度菌液浓度下的加固土体强度。

图 7、图 8 分别为 156 组预测数据的对比图和误差图。使用 BP 神经网络预测得到的结果和实际数据对比, 误差在 -5.370% 到 4.238% 之间。通过多个曲线对比分析发现, 预测出来强度最大的是营养液浓度 1.5 mol/L, 菌液浓度为 0.65 时最大, 与原文的结果一致。经过误差图可以发现, 绝大部分的误差都控制在 1% 以内, 少部分误差控制在 2% 以内, 但是有极个别点的误差会突然超过 4%, 这可能是由于权值和阈值还未达到最佳, 但从曲线总体上来说, 拟合程度较高, 具有可靠性。

上述研究结果表明, 在预测加固土强度的应用领域中, BP 神经网络具有很强的非线性映射能力和潜力, 经过一定程度的训练过后, 预测的数据拥有可靠性。

4. 结论

综上所述, 本文通过训练 BP 神经网络后, 对 MICP 加固法对滨海软土的强度影响的试验数据进行预测, 得到了以下结论。

第一, 使用 BP 神经网络预测得到的结果和实际数据对比, 误差在-5.370%到 4.238%之间, 决定系数 R^2 最高达到 0.967, 最低为 0.917, 所建立的检测模型可靠。这会为加固土使用的掺料的掺量、配合比提供重要的理论依据, 减少试验研究的工作量和成本, 缩短试验周期。

第二, 利用 BP 神经网络预测 MICP 软土加固的强度, 能够通过已有的指标数据推测其加固土强度, 虽然可以极大减少前期的试验工作量, 但需要足够的训练数据, 验证模型的准确性及泛化能力之后再考虑应用。

第三, 预测数据绝大部分点的误差控制在 2% 以内, 但个别点误差会超过 4%, 虽然 BP 神经网络可以高精度的逼近非线性函数, 具有非常强大的线性拟合能力, 但初始的权值和阈值是具有随机性的, 这容易导致模型在局部上失灵, 产生较大的误差, 针对这一问题, 应该引入更多智能算法进行优化。

参考文献

- [1] Anh, T.T.P. (2024) Application of Artificial Neural Network Models for Mixture Design of Surplus Soils Treated with Paper Sludge Ash-Based Stabilizer. *Transportation Geotechnics*, **46**, Article ID: 101247. <https://doi.org/10.1016/j.trgeo.2024.101247>
- [2] 顾春生, 许书刚, 杨鹏, 等. 基于 LASSO-BP 神经网络模型的涪湖组黏性土抗剪强度预测[J]. 世界地质, 2023, 42(3): 577-587.
- [3] Xi, H., Li, Z., Han, J., et al. (2022) Evaluating the Capability of Municipal Solid Waste Separation in China Based on AHP-EWM and BP Neural Network. *Waste Management*, **139**, 208-216. <https://doi.org/10.1016/j.wasman.2021.12.015>
- [4] Tao, H., Liao, X., Zhao, D., et al. (2019) Delineation of Soil Contaminant Plumes at a Co-Contaminated Site Using BP Neural Networks and Geostatistics. *Geoderma*, **354**, Article ID: 113878. <https://doi.org/10.1016/j.geoderma.2019.07.036>
- [5] Li, X., He, M. and Liu, X. (2023) Assessment of Reliability for Subterranean Corroded Pipelines in Cold Regions Using Monte Carlo Method and BP Neural Network. *Cold Regions Science and Technology*, **216**, Article ID: 104002. <https://doi.org/10.1016/j.coldregions.2023.104002>
- [6] Du, X. and Han, X. (2024) Natural Frequency Identification Model Based on BP Neural Network for Camellia Oleifera Fruit Harvesting. *Biosystems Engineering*, **237**, 38-49. <https://doi.org/10.1016/j.biosystemseng.2023.11.012>
- [7] 孙少杰, 吴门新, 庄立伟, 等. 基于 CNN 卷积神经网络和 BP 神经网络的冬小麦县级产量预测[J]. 农业工程学报, 2022(11): 151-160.
- [8] 伍丹华, 周礼梅. 基于 BP 神经网络的粮食产量预测[J]. 农业工程技术, 2020(27): 51-53.
- [9] Wang, Z., Chen, Q., Wang, Z., et al. (2022) The Investigation into the Failure Criteria of Concrete Based on the BP Neural Network. *Engineering Fracture Mechanics*, **275**, Article ID: 108835. <https://doi.org/10.1016/j.engfracmech.2022.108835>
- [10] Feng, Q., Xie, X., Wang, P., et al. (2024) Prediction of Durability of Reinforced Concrete Based on Hybrid-Bp Neural Network. *Construction and Building Materials*, **425**, Article ID: 136091. <https://doi.org/10.1016/j.conbuildmat.2024.136091>
- [11] 蚁曼冰, 王延宁, 刘东, 等. 基于微生物诱导碳酸钙沉淀技术加固滨海软土的试验研究[J]. 汕头大学学报(自然科学版), 2020, 35(3): 47-54.
- [12] 蚁曼冰, 林鹏. 菌液与营养液比例对微生物加固软土的影响[J]. 四川建材, 2020, 46(8): 63-64.