



基于改进 BP 神经网络的粉煤灰-矿渣地质聚合物固化软土强度预测模型

姜镇涛¹, 吴大志¹, 刘程旭¹, 陈柯宇²

(1. 浙江理工大学建筑与工程学院, 杭州 310018; 2. 浙江大学建筑与工程学院, 杭州 310058)

摘要: 传统水泥固化软土存在能耗高、碳排放量大且早期性能不足等问题, 且粉煤灰-矿渣地质聚合物固化软土强度受到众多因素影响, 使得最佳配比难以准确预估。针对上述情况, 构建基于改进 BP 神经网络的预测模型, 用于快速准确预测粉煤灰-矿渣地质聚合物固化软土强度并辨识关键影响因素。首先, 依据已有文献资料, 选取前驱体掺量、粉煤灰氧化物成分、碱激发剂参数及土体物理性质等 14 个关键变量, 建立 178 组样本数据集。然后, 分别采用粒子群优化算法(Particle swarm optimization, PSO)和自适应提升算法(Adaptive boosting, AdaBoost), 对反向传播神经网络(Back propagation neural network, BPNN)进行优化, 建立 PSO-BPNN 与 AdaBoost-BPNN 预测模型, 并传统 BPNN、径向基函数神经网络(Radial basis function neural network, RBFNN)及随机森林(Random forest, RF)模型进行对比。最后, 使用 Garson 算法对最优模型进行敏感性分析。结果表明: 构建的两种模型在预测精度与稳定性方面均显著优于传统模型, 其中 PSO-BPNN 模型在拟合精度与泛化能力方面表现最优, 能够更准确地预测多因素下固化软土强度; NaOH 浓度、矿渣掺量及粉煤灰中 CaO 含量是影响粉煤灰-矿渣地质聚合物固化软土强度的主要因素。该研究考虑了地质聚合物作用要素与土体物理性质, 构建的 PSO-BPNN 模型可以有效改善传统模型精度不足的缺陷, 实现了固化软土强度的高效精确预测, 可为工程实践中固化软土配比优化提供参考。

关键词: 粉煤灰-矿渣地质聚合物; 固化软土强度; BP 神经网络; 预测模型; 敏感性分析

中图分类号: TU433

文献标志码: A

文章编号: 1673-3851 (2026) 05-0249-09

引文格式: 姜镇涛, 吴大志, 刘程旭, 等. 基于改进 BP 神经网络的粉煤灰-矿渣地质聚合物固化软土强度预测模型[J]. 浙江理工大学学报(自然科学), 2026, 55(3): 249-257.

Reference Format: LOU Zhentao, WU Dazhi, LIU Chengxu, et al. A strength prediction model of fly ash-slag-based geopolymer-stabilized soft soil using an improved BP neural network[J]. Journal of Zhejiang Sci-Tech University, 2026, 55(3): 249-257.

A strength prediction model of fly ash-slag-based geopolymer-stabilized soft soil using an improved BP neural network

LOU Zhentao¹, WU Dazhi¹, LIU Chengxu¹, CHEN Keyu²

(1. School of Civil Engineering and Architecture, Zhejiang Sci-Tech University, Hangzhou 310018, China;

2. College of Civil Engineering and Architecture, Zhejiang University, Hangzhou 310058, China)

Abstract: Conventional cement-stabilized soft soils are associated with high energy consumption, substantial carbon emissions, and insufficient early-age performance. Meanwhile, the strength of soft soil stabilized using fly ash-slag-based geopolymers is governed by multiple interacting factors, which makes the accurate determination of an optimal mix proportion particularly challenging. To address these issues, an improved BP neural network-based prediction framework was developed to enable rapid and reliable prediction of the strength of geopolymer-stabilized soft soil, as well as the identification of key influencing

收稿日期: 2025-10-20 网络出版日期: 2026-01-27

基金项目: 国家自然科学基金项目(52578443)

作者简介: 姜镇涛(2000—), 男, 杭州人, 硕士研究生, 主要从事地基处理技术方面的研究。

通信作者: 吴大志, E-mail: wudz@zstu.edu.cn

factors. First, based on published experimental data, fourteen critical variables—including precursor content, oxide composition of fly ash, alkali activator parameters, and physical properties of the soil—were selected, and a dataset consisting of 178 samples was established. Subsequently, the back propagation neural network (BPNN) was optimized using particle swarm optimization (PSO) and adaptive boosting (AdaBoost), resulting in the development of PSO-BPNN and AdaBoost-BPNN models. The predictive performance of these models was systematically compared with that of the conventional BPNN, radial basis function neural network (RBFNN), and random forest (RF) models. Finally, sensitivity analysis was conducted on the optimal model using the Garson algorithm. The results indicate that both optimized models exhibit significantly improved prediction accuracy and stability compared with the conventional models. Among them, the PSO-BPNN model demonstrates superior fitting performance and generalization capability, enabling more accurate strength prediction of geopolymer-stabilized soft soil under complex multi-factor conditions. Sensitivity analysis reveals that NaOH concentration, slag content, and CaO content in fly ash are the dominant factors influencing the strength development of fly ash-slag-based geopolymer-stabilized soft soil. By simultaneously considering geopolymer compositional parameters and soil physical properties, the proposed PSO-BPNN model effectively overcomes the accuracy limitations of traditional prediction approaches and achieves efficient and precise strength prediction, providing a practical reference for mix proportion optimization in engineering applications.

Key words: fly ash-slag based geopolymer; strength of stabilized soft soil; BP neural network; prediction model; sensitivity analysis

0 引言

软黏土因具有含水量高、压缩性大、承载力低等特性,常给岩土工程建设带来严峻挑战,因此对软黏土进行固化有重要的工程意义^[1]。目前,传统硅酸盐水泥(OPC)是工程现场用于软黏土固化的主要材料之一,但在生产过程中会产生大量碳排放,每生产1 t水泥约释放810 kgCO₂^[2],造成严重的环境污染。地质聚合物的前驱体主要来源于粉煤灰与矿渣等工业固废,因其富含SiO₂和Al₂O₃等活性氧化物,被广泛用于合成地质聚合物^[3]。相比传统硅酸盐水泥,地质聚合物以工业固废为原料,生产能耗低,是一种低碳环保型胶凝材料,可有效缓解水泥高碳造成的环境污染;同时,地质聚合物是一种三维网络结构的无机聚合物材料,具有优异的力学性能和耐腐蚀性等特点,在软土加固等工程领域中展现出更大的应用潜力^[4]。

近年来,粉煤灰-矿渣基地质聚合物在软黏土固化中的应用已成为研究热点,研究重点包括固化机理、微观结构演化以及固化土强度发展规律等方面。胡建林等^[5]研究了不同矿渣与粉煤灰配比下,激发剂模数、激发剂掺量、固化材料掺量及养护龄期对土体固化强度的影响,发现当矿渣掺量为80%时,90 d固化土强度可达16.19 MPa,高于水泥固化效果。Min等^[6]研究以粉煤灰与矿渣为前驱体、NaOH与硅酸钠为激发剂的地质聚合物对软黏土固化性能的

影响,结果表明:当矿渣掺量为70%、硅酸钠模数为1.0且NaOH浓度为5 mol/L时,固化土的强度最优;模数增至1.3、1.5和1.7时,固化土的抗压强度分别下降约41.29%、66.56%和68.72%。Yu等^[7]分析了激发剂种类、模数、掺量以及矿渣掺量对土体强度的影响,发现激发剂参数是影响固化土强度的主要因素。骆展鹏等^[8]研究了矿渣-粉煤灰-玻璃粉复合固化盾构土的力学性能,结果表明:随着矿渣与玻璃粉掺量的变化,固化土的早期强度和黏聚力显著不同;适当增加玻璃粉可提高固化土的早期强度,同时生成的N-A-S-H、C-S-H、C-A-S-H凝胶可改善土体密实度,提升整体力学性能。

近年来,机器学习方法被广泛用于预测水泥砂浆力学性能。人工神经网络(Artificial neural network, ANN)、随机森林(Random forest, RF)和支持向量机(Support vector machine, SVM)等算法在水泥砂浆的性能预测中已得到广泛应用^[9-10]。胡艳香等^[11]采用粒子群优化算法(Particle swarm optimization, PSO)和遗传优化算法(Genetic algorithm, GA)来优化反向传播神经网络(Back propagation neural network, BPNN),将锂渣和橡胶砂浆作为输入变量,并结合养护时间,建立了水泥砂浆抗压强度的预测模型。马士宾等^[12]采用PSO算法来优化BPNN,将镁钾比、硼砂含量、水胶比及粉煤灰含量作为输入,砂浆凝结时间、早期抗压及抗折强度作为输出,建立了磷酸镁水泥砂浆力学性能

预测模型,结果表明该模型的应用效果显著优于传统响应面法。

ANN 模型在预测无侧限抗压强度方面虽然可以获得较高的预测精度,但仍面临收敛速度慢、容易过拟合等问题。现有研究尝试使用 PSO 或集成学习算法来调整模型参数,以改善其预测精度,但这些方法在固化土强度预测方面的研究仍较少^[13-14]。同时,固化土和水泥砂浆在反应机理上存在较大差异,固化土强度受前驱体氧化物含量、土体物理性质等多种因素影响,使得以往的模型很难准确预测固化土强度。鉴于此,构建一套面向固化软土强度的专用预测模型具有重要研究价值,不仅可实现固化软土强度的精准预测,更能为固化体系的配比优化提供关键技术支撑。

本文分别采用 PSO 和 AdaBoost (Adaptive boosting)对 BPNN 进行优化,以构建粉煤灰-矿渣地质聚合物固化软土无侧限抗压强度预测模型。基于现有的国内外文献,收集了 178 个数据样本,从地质聚合物影响因素和土体物理性质两个维度选取 14 个关键变量作为输入;通过对比 PSO-BPNN、AdaBoost-BPNN 和传统 BPNN 模型预测结果,确定 PSO-BPNN 模型精度最高;使用径向基函数神经网络 (Radial basis function neural network, RBFNN)与随机森林验证模型的可靠性,为地质聚合物固化软土配合比设计提供参考依据。针对 PSO-BPNN 模型,采用 Garson 算法进行敏感性分析,分析影响固化土强度的主要因素以及各变量对固化土强度的影响。该研究有效改善了传统 BPNN 模型预测精度有限的缺陷,能够为固化软土配比优化提供参考,以减少前期试验成本,实现高效配比设计。

1 模型建立

1.1 数据集建立

粉煤灰与矿渣是地质聚合物常用的前驱体材料。作为一种典型的火山灰材料,粉煤灰主要由 SiO_2 、 Al_2O_3 和 CaO 等氧化物组成,为地质聚合物反应提供必需的硅铝酸盐。粉煤灰可分为 F 类和 C 类,其中:F 类 CaO 含量较低,缺乏水泥性质;而 C 类 CaO 含量较高,兼具部分水泥与火山灰特性。已有的研究表明,固化土的无侧限抗压强度随粉煤灰中 CaO 与 SiO_2 质量比的升高而增大^[15]。因此,为全面表征 F 类和 C 类粉煤灰在固化土体中的性能差异,并提高预测模型的实用性与精度,本文选取粉煤灰中 3 种主要氧化物成分 (SiO_2 、 Al_2O_3 、 CaO) 的

含量作为输入变量。矿渣是炼铁的副产品,也常用于制备地质聚合物。由于矿渣的化学成分通常较为稳定,批次间差异较小,本文未考虑其具体氧化物含量^[16]。地质聚合物的力学性能与其碱性激发剂的种类和用量密切相关。常用激发剂包括 NaOH 、 Na_2SiO_3 以及二者的混合物。激发剂中 NaOH 与 Na_2SiO_3 的质量比、 NaOH 物质的量浓度以及 Na_2SiO_3 中 $\text{SiO}_2/\text{Na}_2\text{O}$ 的摩尔比例,均对材料性能有着重要影响。

基于上述分析,结合现有文献建议^[17],本文最终确定以下参数作为地质聚合物固化土强度预测模型的输入:粉煤灰与矿渣的掺量、粉煤灰中 SiO_2 、 Al_2O_3 、 CaO 的质量分数、 NaOH 掺量及物质的量浓度、 Na_2SiO_3 掺量及 Na_2SiO_3 的模数 ($\text{SiO}_2/\text{Na}_2\text{O}$ 摩尔比)、碱固比、土体含水率、液限、塑限以及养护温度。以上参数均被证实对地质聚合物固化软土强度具有重要影响。本文使用的数据集从文献^[18-24]中整理获得,共包含 178 组实验数据。将数据集随机划分为训练集 (80%) 和测试集 (20%)。在建模前,为消除不同变量量纲差异对模型训练的影响,对所有输入数据进行了归一化处理,归一化范围为 $[-1, 1]$,具体计算公式为:

$$x_{\text{norm}} = 2 \times \frac{x - x_{\text{min}}}{x_{\text{max}} - x_{\text{min}}} - 1 \quad (1)$$

其中: x 为输入值, x_{norm} 为归一化后的数据, x_{min} 为输入数据集中的最小值, x_{max} 为输入数据集中的最大值。

1.2 BP 神经网络改进

1.2.1 BPNN

BPNN 通过模拟人脑工作机制建立数学模型,能够学习输入与输出之间的非线性关系,实现对输出的快速预测。BPNN 结构如图 1 所示,由输入层、隐藏层和输出层构成,输入层和输出层神经元数量分别对应输入与输出参数个数。隐藏层可为单层或多层,每层神经元数量及层数需通过超参数优化确定。BPNN 凭借强大的非线性映射能力,已应用于岩土工程领域的承载力、强度及沉降预测等研究中^[25-26]。

1.2.2 PSO

PSO 是一种基于群体智能的优化方法,其核心思想源于鸟群觅食行为,通过个体在搜索空间中不断调整位置来逼近最优解。PSO 具有计算效率高、搜索精度高的特点。近年来,PSO 及其改进算法已被应用于拱坝变形预测、隧道地基稳定性预测等领域,均取得了良好效果^[27-28]。本文采用 PSO 优化

BPNN 模型的初始权重与阈值,构建了 PSO-BPNN 模型。粒子群规模设为 20,在兼顾计算效率的同时保证搜索多样性;学习因子 C_1 和 C_2 均取 2,惯性权重的最大值与最小值分别设为 0.9 和 0.4,以增强算法前期的全局搜索能力并提高后期的局部收敛性能。算法最大迭代次数设定为 50 次。上述 PSO 超参数的具体设置汇总见表 1,PSO 优化 BPNN 模型的流程如图 2 所示。

1.2.3 AdaBoost 集成学习算法

AdaBoost 是一种自适应增强算法,通过迭代训练基础学习器并调整样本权重以提升模型性能。已有研究表明,AdaBoost 改进模型在工程预测中效果良好,如用于混凝土抗压强度预测和大坝变形监控^[29-30]。本文选用 BPNN 作为基础学习器,通过 AdaBoost 对其进行优化,构建了 AdaBoost-BPNN 模型。各基础 BPNN 的结构与超参数设置与常规 BPNN 保持一致,优化流程见图 3。




图 1 BPNN 结构图

表 1 PSO 超参数

超参数	参数值
粒子群数量/个	20
C_1, C_2	2
惯性权重的最大值	0.9
惯性权重的最小值	0.4
最大迭代次数/次	50

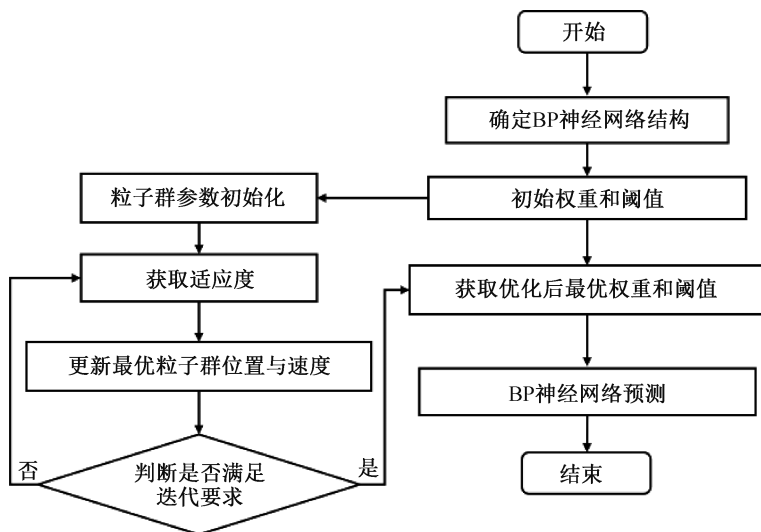


图 2 PSO 优化 BPNN 流程图




图 3 AdaBoost 优化 BPNN 流程图

1.3 超参数优化

本文中, BPNN 隐藏层和输出层分别采用 Tansig 和 Purelin 作为激活函数,训练算法选用 Levenberg-Marquardt 方法。该方法结合了高斯-牛

顿法和梯度下降法的优点,能利用一阶和二阶导数信息,从而加快训练速度。同时,以均方误差作为损失函数,避免计算复杂的 Hessian 矩阵。模型超参数中,隐藏层的层数和神经元数量对预测效果影响较大。尽管增加网络层数可以提升模型表达能力,但过多的层数容易导致过拟合、训练困难。考虑到 3 层网络已经可以比较好地拟合非线性关系,本文最终采用了 3 层结构。确定隐藏层神经元数量时需要平衡计算效率和模型泛化能力。为此首先根据经验公式确定了神经元数量的合理取值范围,具体表达式如式(2)所示:

$$l < \sqrt{m+n} + a \quad (2)$$

其中: l 为神经元数, n 为输入个数, m 为输出个数, a 取 1~10 之间。本模型中输入个数为 14, 输出个数为 1, 因此神经元个数范围为 4~15。

在此基础上, 采用网格搜索方法对该范围内的神经元数量进行逐一测试, 并结合验证集结果筛选最优配置。通过比较不同神经元数量条件下训练集与测试集的平均绝对误差, 确定模型的最优隐藏层数量。本文采用平均绝对误差 e_{MA} 作为模型预测性能评价指标, 用以衡量预测值与实测值之间的偏差, 其计算方法如式(3)所示:

$$e_{MA} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (3)$$

其中: n 为样本数, y_i 为真实值, \hat{y}_i 为预测值。

不同隐层神经元数量的平均绝对误差如图 4 所示, 从图中可以看出, 当隐藏层神经元数量为 7 时, 模型在训练集和测试集上的误差均处于较低水平, 综合预测性能最佳。因此, 本文最终确定隐藏层神经元数量为 7 个, 其余超参数设置见表 2。

表 2 BPNN 超参数

超参数	超参数结果
输入层和隐藏层之间的激活函数	Tansig
隐藏层和输出层之间的激活函数	Purelin
训练算法	Levenberg-Marquardt
隐藏层个数/个	1
隐藏层中神经元数量/个	7

1.4 模型评估

在建立神经网络模型后, 为了全面评价其预测性能并进行模型间的对比分析, 本文选取决定系数 R^2 、平均绝对误差 e_{MA} 、均方根误差 R_{MSE} 作为主要统计指标。决定系数用于衡量模型的拟合优度, 反映因变量的变异性中有多大比例可由自变量解释, 其取值范围为 $[0, 1]$, 越接近 1 说明模型拟合效果越好。平均绝对误差用于评估预测值与实验值之间的偏离程度, 值越小表示预测结果与实际结果越接

近。均方根误差则用于刻画预测值与实验值之间的整体偏差。其中, 平均绝对误差的计算方法见式(3)。决定系数和均方根误差的计算方法分别按式(4)和式(5)计算:

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)}{\sum_{i=1}^n (y_i - \bar{y}_i)} \quad (4)$$

$$R_{MSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (5)$$




图 4 隐藏层中不同神经元数量的平均绝对误差

2 结果与讨论

2.1 不同模型预测结果与分析

测试数据没有参与模型训练过程, 因此它的预测结果和实际值之间的误差能够反映模型预测能力, 误差越小说明模型预测越准确。图 5 显示了 BPNN、PSO-BPNN 和 AdaBoost-BPNN 这 3 种模型在测试集上的预测效果。从图 5(a)中可以看出, 基础 BPNN 模型的预测值和实际值偏差比较明显, 预测精度有限; 从图 5(b)中可以看出, AdaBoost-BPNN 模型的预测值更接近实际值, 说明加入 AdaBoost 后模型鲁棒性和泛化能力都得到明显改善; 从图 5(c)可以看出, PSO-BPNN 模型的预测曲




图 5 BPNN、AdaBoost-BPNN、PSO-BPNN 模型在测试集上的抗压强度预测值与实际值对比图

线和实际值拟合得最好,整体偏差最小,可知 PSO 优化对模型预测性能的提升效果最为显著。整体来说,相比单一 BPNN 模型,不管是采用 AdaBoost 还是 PSO 优化,都能有效提高预测精度,其中 PSO-BPNN 模型在本文数据上表现最佳,工程适用性也更优越。

图 6 展示了测试集上 3 种模型回归预测效果对比情况。从图 6(a)中可以看出,基础 BPNN 模型的结果虽然大体沿着 $y=x$ 线趋势分布,但实际数据点




图 6 BPNN、AdaBoost-BPNN、PSO-BPNN 模型在测试集上的抗压强度预测值与实际值回归拟合对比图

表 3 列出了 3 种模型在预测粉煤灰-矿渣地质聚合物固化软黏土无侧限抗压强度时的表现。从表 3 可以看出:PSO-BPNN 模型表现最突出, R^2 达到 0.96,而 e_{MA} 和 R_{MSE} 分别只有 0.35 和 0.52,预测值和实际值很接近,这主要得益于 PSO 对初始权重与阈值的调整,让基础 BPNN 模型收敛得更快、泛化能力也更强。相比之下,基础 BPNN 模型的各项指标都最低,这可能是由于过拟合问题,AdaBoost-BPNN 模型表现处于中间水平,虽然比基础 BPNN 模型好,但整体精度不如 PSO-BPNN 模型。从 R^2 看,PSO-BPNN 模型比基础 BPNN 模型提升了 77.8%,AdaBoost-BPNN 模型则提升了 54.9%,所以在固化软土强度预测中,PSO 对模型性能的提升效果明显比 AdaBoost 更显著,PSO-BPNN 模型具备比较好的应用前景。

表 3 测试集中各模型的评估指标

模型	R^2	e_{MA}	R_{MSE}
BPNN	0.54	0.73	1.62
PSO-BPNN	0.96	0.35	0.52
AdaBoost-BPNN	0.83	0.69	0.94

2.2 传统模型比较

为了进一步验证 PSO-BPNN 模型对数据的泛化能力与可信度,将其与使用 RBFNN 与 RF 的两种模型进行对比。RBFNN 是一种基于径向基函数的前馈神经网络,具有较强的泛化能力,常在处理复

仍较为散乱,若干个样本点明显偏离 $y=x$,说明该模型预测精度有所欠缺。相比之下,从图 6(b)中可以看出,AdaBoost-BPNN 模型的预测结果与参考线贴合得更紧密,表明其预测准确性与泛化性能均获得了提升,这主要是因为集成学习机制有效减小了模型偏差。从图 6(c)中可以看出,PSO-BPNN 模型的拟合效果最好,预测值和实际值的吻合度最高,误差最小,这主要是因为该模型通过 PSO 优化了网络超参数,在加快收敛速度的同时也显著提高了预测精度。

杂问题时表现出良好的性能,现已应用于预测桩沉降、岩土工程可靠性分析之中^[31-32]。RF 是经典集成决策算法之一,采用 Bagging 策略训练并集成多棵决策树,并集成所有决策树的预测结果后输出最终结果。已有学者将其应用于土质边坡系统可靠性分析、土壤液化预测等领域^[33-34]。将 PSO-BPNN、RF、RBFNN 模型的评价指标 R^2 、 e_{MA} 和 R_{MSE} 进行对比,结果如表 4 所示。从表 4 可以发现,PSO-BPNN 模型在各个评价指标上均优于其他模型,表明该模型适用于本文数据集。

表 4 PSO-BPNN、RBFNN、RF 模型评估指标参数

模型	R^2	e_{MA}	R_{MSE}
PSO-BPNN	0.96	0.35	0.52
RBFNN	0.86	0.65	1.04
RF	0.64	0.64	1.70

2.3 敏感性分析

现有研究中,Garson 算法常与神经网络相结合用于敏感性分析,以评估输入参数对模型输出的影响^[35-36]。该算法通过分解隐藏层至输出层的连接权重,将其重新分配至每一个输入变量,从而定量计算各输入对输出的相对贡献度,为识别关键参数提供依据。本文采用 Garson 算法对 PSO-BPNN 模型进行了敏感性分析,以量化各输入参数对无侧限抗压强度预测结果的影响,结果如图 7 所示。从图 7 可知,在所考虑的 14 个输入参数中,NaOH 物质的

量浓度、矿渣掺量、粉煤灰中 CaO 含量、液限、碱固比以及粉煤灰中 SiO₂ 含量对无侧限抗压强度的影

响最为显著,因此上述因素可认为是控制地质聚合物固化软土强度的关键因素。




图 7 粉煤灰-矿渣基地质聚合物固化软土强度的关键变量的重要性

从工程应用角度来看,为有效提高固化土的早期强度,应优先调控 NaOH 的物质的量浓度与矿渣的掺量。这主要是因为 NaOH 物质的量浓度决定了反应环境的碱度,而碱度的变化会影响矿渣中 Ca²⁺ 的析出以及硅铝酸盐的反应速率,从而调控 C-S-H、C-A-S-H、N-A-S-H 凝胶的生成。这些凝胶不仅填充了土体孔隙,还通过胶结作用连接分散的土颗粒,形成更致密的微观结构,从而增强固化土强度。从敏感性分析结果可知,NaOH 物质的量浓度是影响固化土强度最关键的参数,适当提高浓度可以促进硅铝酸盐前驱体充分溶解,加快凝胶生成,使得强度提升较为明显。矿渣的掺量和粉煤灰中 CaO 含量的重要性次之,两者所提供的 Ca²⁺ 能促进 C-S-H 凝胶和 C-A-S-H 凝胶生成,从而提高固化土强度。一般来说,矿渣中 Ca²⁺ 含量比粉煤灰高,因此增加矿渣掺量有助于固化土在微观结构上更密实,整体强度也随之提升。土体的液限也是重要的影响因素,它反映了土体的矿物组成和胶体颗粒的含量,会对土体结构产生影响。此外,碱固比和粉煤灰中 SiO₂ 含量同样不可忽视。SiO₂ 是生成 N-A-S-H 凝胶的主要原料,适量的碱激发剂能有效促进反应,形成更多凝胶。但是,碱激发剂过量时,会导致地质聚合物解聚形成过多的团簇结构,从而抑制反应进程,降低固化土的早期强度。

3 结 语

本文构建了粉煤灰-矿渣基地质聚合物固化软土无侧限抗压强度的 PSO-BPNN 与 AdaBoost-BPNN 预测模型,明确了关键配比与相关物理化学参数,并对不同机器学习模型的预测性能进行了对比分析,定量评估了各输入变量对固化软土强度的影响,主要结论如下:

a) PSO-BPNN 模型和 AdaBoost-BPNN 模型均能够准确预测地质聚合物固化软土的无侧限抗压强度,为固化软土配比优化提供技术支持,其中 PSO-BPNN 模型预测精度最高。

b) 模型性能对比结果表明,PSO-BPNN 模型的 R² 达到 0.96,显著高于 BPNN 模型和 AdaBoost 模型。与 BPNN 模型相比,PSO-BPNN 模型的预测精度提升约 77.8%,与 AdaBoost-BPNN 模型相比提升约 54.9%,表明该模型具有较高准确性。

c) 基于 PSO-BPNN 模型的敏感性分析显示,NaOH 物质的量浓度和矿渣掺量是影响固化软土无侧限抗压强度的关键因素,可为地质聚合物固化软土配比优化及工程应用提供参考。

本文构建的 PSO-BPNN 模型综合考虑了 14 种影响因素,能够更为全面地反映各因素对粉煤灰-矿渣基地质聚合物固化软土无侧限抗压强度的影响,在

一定程度上弥补了传统 BPNN 模型的缺陷。模型预测结果较传统模型具有更高的准确性和适用性,可为地质聚合物固化软土强度预测及工程应用提供技术支持。同时,基于 PSO-BPNN 模型的敏感性分析结果可为固化软土配比优化与性能提升提供参考。

参考文献:

- [1] Lin P Y, Chen X Y, Jiang M J, et al. Mapping shear strength and compressibility of soft soils with artificial neural networks [J]. *Engineering Geology*, 2022, 300: 106585.
- [2] Wu Y G, Lu B W, Bai T, et al. Geopolymer, green alkali activated cementitious material: Synthesis, applications and challenges [J]. *Construction and Building Materials*, 2019, 224: 930-949.
- [3] 王辉,高尚,郭美丽,等. 粉煤灰-矿渣基泡沫地聚合物微观孔隙结构与宏观性能[J]. *建筑材料学报*, 2024, 27(5): 461-470.
- [4] 张津津,李博,余闯,等. 矿渣-粉煤灰地聚合物固化砂土力学特性研究[J]. *岩土力学*, 2022, 43(9): 2421-2430.
- [5] 胡建林,赵天怡,冷发光,等. 碱激发矿渣-粉煤灰地质聚合物固化土力学特性及强度预测[J/OL]. *复合材料学报*, 2025: 1-12. (2025-05-26)[2025-11-18]. <https://doi.org/10.13801/j.cnki.fhclxb.20250526.003>.
- [6] Min Y F, Gao M J, Yao C Q, et al. On the use of one-part geopolymer activated by solid sodium silicate in soft clay stabilization [J]. *Construction and Building Materials*, 2023, 402: 132957.
- [7] Yu J R, Chen Y H, Chen G, et al. Experimental study of the feasibility of using anhydrous sodium metasilicate as a geopolymer activator for soil stabilization [J]. *Engineering Geology*, 2020, 264: 105316.
- [8] 骆展鹏,熊春林,韩泽军,等. 矿渣-粉煤灰-玻璃粉复合固化盾构土力学性能及固化机制[J]. *硅酸盐通报*, 2025, 44(5): 1803-1812.
- [9] 赵东三,徐正中,高旭,等. 基于动态机器学习的水泥胶砂性能预测研究[J]. *混凝土*, 2024(3): 147-152.
- [10] 蔡锦程,许子彦,董振勇,等. 基于机器学习的砂浆流变特性预测[J]. *公路交通科技*, 2024, 41(6): 138-147.
- [11] 胡艳香,陈昊,薛凯喜,等. 基于 PSO-BP 和 GA-BP 算法神经网络的锂渣-橡胶砂浆抗压强度预测研究[J]. *混凝土*, 2023(10): 59-63.
- [12] 马士宾,李盈霞,闫伟阳. 基于两种方法优化磷酸镁水泥砂浆配合比研究[J]. *混凝土*, 2023(1): 140-145.
- [13] Cai B, Lin X Q, Fu F, et al. Postfire residual capacity of steel fiber reinforced volcanic scoria concrete using PSO-BPNN machine learning[J]. *Structures*, 2022, 44: 236-247.
- [14] Abdolrasol M G M, Suhail Hussain S M, Ustun T S, et al. Artificial neural networks based optimization techniques: A review[J]. *Electronics*, 2021, 10(21): 2689.
- [15] Turan C N, Javadi A A, Vinai R. Effects of class C and class F fly ash on mechanical and microstructural behavior of clay soil: A comparative study[J]. *Materials*, 2022, 15(5): 1845.
- [16] Li Y, Shen J, Lin H, et al. Optimization design for alkali-activated slag-fly ash geopolymer concrete based on artificial intelligence considering compressive strength, cost, and carbon emission [J]. *Journal of Building Engineering*, 2023, 75: 106929.
- [17] Zhang J, Choi C E, Liang Z, et al. A generic framework for mix design of geopolymer for soil stabilization: Composition-informed machine learning model [J]. *Computers and Geotechnics*, 2024, 170: 106322.
- [18] Odeh N A, Al-Rkaby A H J. Strength, Durability, and Microstructures characterization of sustainable geopolymer improved clayey soil [J]. *Case Studies in Construction Materials*, 2022, 16: e00988.
- [19] Chen Z, Gao Y, Wei W, et al. Stabilization of soft clay by a low-calcium fly ash geopolymer[J]. *Journal of Materials in Civil Engineering*, 2023, 35(11): 04023398.
- [20] Bhavita Chowdary V, Ramanamurty V, Pillai R J. Experimental evaluation of strength and durability characteristics of geopolymer stabilised soft soil for deep mixing applications[J]. *Innovative Infrastructure Solutions*, 2021, 6(1): 40.
- [21] Phetchuay C, Horpibulsuk S, Arulrajah A, et al. Strength development in soft marine clay stabilized by fly ash and calcium carbide residue based geopolymer[J]. *Applied Clay Science*, 2016, 127/128: 134-142.
- [22] Yaghoubi M, Arulrajah A, Disfani M M, et al. Impact of field conditions on the strength development of a geopolymer stabilized marine clay[J]. *Applied Clay Science*, 2019, 167: 33-42.
- [23] Yaghoubi M, Arulrajah A, Disfani M M, et al. Effects of industrial by-product based geopolymers on the strength development of a soft soil[J]. *Soils and Foundations*, 2018, 58(3): 716-728.
- [24] Abdullah H H, Shahin M A, Sarker P. Use of fly-ash geopolymer incorporating ground granulated slag for stabilisation of Kaolin clay cured at ambient temperature[J]. *Geotechnical and Geological Engineering*, 2019, 37(2): 721-740.
- [25] 杨明辉,宋牧原,姚高占,等. 机器学习预测盾构掘进地表沉降的研究进展及展望[J]. *隧道建设(中英文)*, 2024, 44(11): 2119-2132.
- [26] 渠建伟. 基于 BP 神经网络的振冲碎石桩复合地基承载力预测[J]. *铁道建筑*, 2017, (4): 87-90.
- [27] 魏博文,柳波,徐富刚,等. 融合 PSO-SVM 的混凝土拱坝多测点变形监控混合模型[J]. *武汉大学学报(信息科学版)*, 2023, 48(3): 396-407.
- [28] 胡军,董建华,王凯凯. 隧道洞室地基稳定性双阶段多策略粒子群 BP 网络模型研究[J]. *现代隧道技术*, 2017, 54(3): 50-57.
- [29] 赵佳亮,达列雄,郭鸿,等. 基于 MLP-AdaBoost 模型的混凝土抗压强度预测研究[J]. *混凝土*, 2025(6): 17-22.
- [30] 代硕,苏怀智,谷宇,等. 基于 HO-BP-AdaBoost 的大坝变形

监控模型[J]. 水电能源科学, 2025, 43(7): 153-156.

[31] Zhang M, Du Q, Yang J, et al. Modeling the pile settlement using the Integrated Radial Basis Function (RBF) neural network by Novel Optimization algorithms; HRBF-AOA and HRBF-BBO[J]. Journal of Intelligent & Fuzzy Systems, 2022, 43(6): 7009-7022.

[32] Liu Y D, Yang Z Y, Li X Y. Adaptive ensemble learning of radial basis functions for efficient geotechnical reliability analysis[J]. Computers and Geotechnics, 2022, 146: 104753.

[33] Chen W H, Ding J W, Wang T F, et al. An adaptive sequential sampling method based on ANN_MCD and RF;

Application in geotechnical problems [J]. Applied Soft Computing, 2023, 144: 110462.

[34] Zhou J, Huang S, Zhou T, et al. Employing a genetic algorithm and grey wolf optimizer for optimizing RF models to evaluate soil liquefaction potential[J]. Artificial Intelligence Review, 2022, 55(7): 5673-5705.

[35] 王泉. 基于 BP-Garson 组合模型的堤岸稳定影响因素敏感性分析[J]. 水电能源科学, 2018, 36(6): 122-124.

[36] 朱璘琦, 牛晓凡, 肖显斌. 基于改良 BP 神经网络的生物质锅炉飞灰含碳量预测模型研究[J]. 可再生能源, 2020, 38(2): 150-157.

团队介绍

吴大志教授团队聚焦于基坑工程、地基处理等方面的研究,致力于解决基坑开挖对运营地铁隧道的影响、固废资源化利用等领域的关键问题,现主持国家自然科学基金重点项目子课题和面上项目各 1 项、企业委托课题多项。经过 10 多年的攻关,揭示了基坑开挖对紧邻地铁隧道的影响机理,构建了相应的技术防控体系;提出了基于粉煤灰、矿渣、钢渣等工业固废的胶凝材料配比设计方法,成功应用于软土固化等工程场景,取得了较为显著的社会、环境和经济效益。获浙江省自然科学奖三等奖 1 项、中华环保联合会自然科学奖二等奖 1 项、中国商业联合会科技进步奖二等奖 3 项,获浙江省研究生教育学会教育成果奖二等奖 1 项,获中国纺织工业联合会教学成果奖二等奖 2 项。发表学术论文 100 余篇,其中高被引论文 1 篇,SCI 或 EI 收录 50 余篇;获授权发明专利 8 项,主编教材 1 部。

(责任编辑:康 锋)