

DOI: 10.16285/j.rsm.2023.0209

基于生物地理优化的人工神经网络模型预测 软土的固结系数

王才进¹, 武 猛¹, 杨 洋², 蔡国军^{1,3}, 刘松玉¹, 何 欢¹, 常建新¹

(1. 东南大学 岩土工程研究所, 江苏 南京 211189; 2. 江苏省交通工程建设局, 江苏 南京 210004;
3. 安徽建筑大学 土木工程学院, 安徽 合肥 230601)

摘 要: 软土固结系数 C_v 是岩土工程结构设计中的重要参数, 测试固结系数需要花费大量的时间和成本。基于生物地理学优化算法 (biogeographical optimization algorithm, BBO) 来改进人工神经网络 (artificial neural network, ANN) 模型, 使用生物地理优化的人工神经网络 (ANN-BBO) 模型对软土固结系数进行计算。基于连淮高速公路改扩建项目的路基软土数据对计算模型进行了训练和测试。通过相关系数矩阵和主成分分析对软土的 11 个物理力学参数进行了统计分析, 确定了 7 个参数作为计算模型的输入参数, 并对计算模型进行了训练和测试; 模型通过相关系数、均方根误差和方差比进行检验, 并对误差进行了统计分析; 采用蒙特卡罗模拟对计算模型的鲁棒性进行了分析。结果表明: ANN-BBO 模型可以用于估计软土的固结系数, 相关系数 $R^2 = 0.947\ 1$, 均方根误差 $RMSE = 0.165\ 7 \times 10^{-3}\ \text{cm}^2/\text{s}$, 方差比 $VAF = 94.54\%$; ANN-BBO 模型预测精度明显优于 ANN 模型; ANN-BBO 模型的鲁棒性比 ANN 模型更好。

关 键 词: 软土; 固结系数; 人工神经网络; 主成分分析; 鲁棒性

中图分类号: TU447

文献标识码: A

文章编号: 1000-7598 (2023) 10-3022-09

Prediction of consolidation coefficient of soft soil using an artificial neural network models with biogeography-based optimization

WANG Cai-jin¹, WU Meng¹, YANG Yang², CAI Guo-jun^{1,3}, LIU Song-yu¹,
HE Huan¹, CHANG Jian-xin¹

(1. Institute of Geotechnical Engineering, Southeast University, Nanjing, Jiangsu 211189, China; 2. Jiangsu Province Transportation Engineering Construction Bureau, Nanjing, Jiangsu 210004, China; 3. School of Civil Engineering, Anhui Jianzhu University, Hefei, Anhui 230601, China)

Abstract: The consolidation coefficient C_v of soft soil is an important parameter in geotechnical engineering. The artificial neural network (ANN) model is improved with the biogeography-based optimization algorithm (BBO). And the artificial neural network with biogeography-based optimization (ANN-BBO) model, trained and tested by using the subgrade soft soil data of the reconstruction and expansion project of Lianyungang-Huai'an expressway, has been adopted to calculate the soft soil consolidation coefficient. Using the correlation coefficient matrix and principal component analysis, eleven physical and mechanical parameters were statistically analyzed, seven of which were identified as input parameters of calculation model which was then trained and tested. The model was tested by correlation coefficient, root mean square error, and variance ratio, whose robustness was analyzed by using Monte Carlo simulation. The results show that the ANN-BBO model can be used to calculate the consolidation coefficient of soft soil, the correlation coefficient $R^2 = 0.947\ 1$, the root mean square error $RMSE = 0.165\ 7 \times 10^{-3}\ \text{cm}^2/\text{s}$, and the variance ratio $VAF = 94.54\%$. The ANN-BBO model has significantly higher prediction accuracy and better robustness, compared with the ANN model.

Keywords: soft soil; consolidation coefficient; artificial neural network; principal component analysis; robustness

收稿日期: 2023-02-21

录用日期: 2023-04-03

基金项目: 国家杰出青年科学基金 (No.42225206); 国家自然科学基金 (No.41877231, No.42072299, No.52008098); 江苏省自然科学基金 (No.BK20200405); 江苏省交通运输科技项目 (No.7921004042B)。

This work was supported by the National Science Fund for Distinguished Young Scholars (42225206), the National Natural Science Foundation of China (41877231, 42072299, 52008098), the Jiangsu Province Natural Science Fund (BK20200405) and the Project of Jiangsu Province Transportation Engineering Construction Bureau (7921004042B).

第一作者简介: 王才进, 男, 1995 年生, 博士研究生, 主要从事原位测试和热传导方面的研究。E-mail: wangcaijin@seu.edu.cn

通讯作者: 蔡国军, 男, 1977 年生, 博士, 教授, 主要从事原位测试和环境岩土方面的研究。E-mail: focuscai@163.com

1 引言

在岩土工程中,固结系数 C_v 是地基沉降分析的重要参数,也是在工程稳定性分析中差异沉降估算的重要参数。沉降量和沉降速率与体积变化系数有关,而体积变化系数由固结系数决定。一般来说,固结系数是通过室内试验和现场测试得出,室内测试主要通过室内固结试验法测定,现场测试主要通过孔压静力触探 (CPTU)^[1-2]、原位渗透系数测试系统 (BAT)、扁铲侧胀仪 (DTM) 及螺旋板载荷试验 (SPLT) 测定,以 CPTU 测试和 BAT 测试为主。快速和准确获得软土的固结系数,对岩土工程越来越重要。

近年来,很多研究人员对软土的固结系数进行了大量研究,对软土次固结及其基本性质已有很多的研究^[3-6]。庄迎春等^[7]对萧山软黏土进行一维固结试验,发现软土在固结过程中固结系数是呈非线性变化的;李国维等^[8]通过软土重塑试样进行一维压缩试验,认为次固结系数和超载比之间可以通过双曲线简化模型进行模拟,对次压缩变形公式进行了改进,改进后的公式具有更高的可靠性;孙立强等^[9]为研究新近吹填土的固结系数,建立了渗透系数随固结应力的变化关系;Yang 等^[10]基于分层沉降的现场监测结果,建立了固结系数的反分析方法;桂跃等^[11]基于大量室内试验结果对高原湖相泥炭土一维固结特性进行了系统分析,得出原状样结构性不显著是泥炭土固结特性的主要原因;邓岳保等^[12]建立了荷载和加热联合作用下饱和土地基固结沉降、超静孔压和固结度的计算方法,所建立的热固结理论可以分析地基在加热后的回弹与沉降。综上所述,软土的固结系数主要通过室内试验和理论分析得到,但这些计算方法难以建立固结系数与其他物理力学参数之间的良好关系,这些方法只能应用于特定的情况,难以对固结系数进行全面地分析和预测。

本文以连淮高速公路改扩建路基软土为研究对象,对软土的物理力学参数进行系统分析,建立基于生物地理学优化的神经网络模型 (ANN-BBO) 模型来预测软土的固结系数 C_v 。对计算模型进行性能检验、误差分析和鲁棒性分析,以明确本文所提计算模型的有效性和鲁棒性。

2 基于生物地理学优化的人工神经网络模型

人工神经网络 (ANN) 模型是基于模仿神经元

的结构和功能的信息处理系统^[13]。ANN 由许多神经元构成,可以处理和学习大量的输入数据。目前已经开发出很多优化算法,如列文伯格-马夸尔特算法、共轭梯度算法、贝叶斯正则化算法等^[14]。ANN 模型隐藏层的多少取决于问题的复杂程度,对于一般岩土工程,一个隐藏层是非常有效的结构^[15]。输入层的功能是获取输入数据和过滤输入数据,并将数据传入隐藏层;隐藏层节点功能的主要作用是接收来自输入层的数据,通过这些输入数据来进行学习来构建训练模型;输出层是将处理数据导出,得出计算值^[16]。图 1 是一个典型的 ANN 结构,其中 X_1 、 X_2 和 X_n 是输入参数, C_v 是输出参数。ANN 模型的优点是不需对输入数据进行限制,模型只需要对给定的输入数据进行学习,然后就可以进行计算。




图 1 ANN 模型示意图

Fig.1 Schematic diagram of ANN model

生物地理学优化算法 (BBO) 是受生物地理学原理启发而提出的优化算法,主要思想类似于生物学方法,它是在遗传算法和粒子群算法的基础上发展出来的新算法^[17]。因此, BBO 常用来解决很多实际的优化问题,每一组候选解由多个参数表征^[18]。本文基于 BBO 来优化神经网络计算模型的权重和偏差,建立计算软土固结系数 C_v 的 ANN-BBO 模型。

3 数据预处理及模型鲁棒性分析

3.1 数据预处理

在复杂的岩土工程问题中,常使用相关矩阵对大量输入参数进行自变量识别。Ebrahim-Zadeh 等^[19]使用相关矩阵对 148 个土样的 28 种性质进行了评估,研究了土体抗拉强度与含水率之间的相关关系;Guan 等^[20]为研究土体的吸附性质,对 55 个土样物理参数和化学参数的相关矩阵进行分析。皮尔森相关系数为

$$r_{x,y} = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2} \sqrt{\sum_{i=1}^n (Y_i - \bar{Y})^2}} \quad (1)$$

式中: $r_{x,y}$ 为皮尔森相关系数; X_i 为一个土体参数; Y_i 为一个土体参数; $\bar{X}$ 和 $\bar{Y}$ 分别为 X 和 Y 的平均值; n 为 X 数据集和 Y 数据集中的数据总量。

相关系数 R^2 在 0 和 1 之间, 相关系数 R^2 接近 0 表示两个随机变量没有相关性, 相关系数 R^2 接近 1 表示两个随机变量相关性很高。

当一个复杂问题有很多输入参数时, 输入参数之间具有一定的相关性, 此时, 两个参数反映问题的信息有一定的重叠。为了减少输入参数而不影响问题的本质, 使用主成分分析对原先的输入参数进行分析, 将关系密切的输入参数删除, 建立尽可能少的新参数, 这些新参数在反映问题信息方面可以尽可能保存原有信息^[21]。

3.2 模型鲁棒性分析

由于岩土参数具有可变性, 在使用 ANN-BBO 计算岩土参数时, 需要对模型的鲁棒性进行检验, 也就是计算模型在输入可变性参数时计算模型维持原有性能的特征^[22]。通常使用蒙特卡罗模拟对模型的鲁棒性进行检验, 蒙特卡罗模拟评估预测模型鲁棒性的示意图如图 2 所示。蒙特卡罗模拟主要通过改变输入参数重复模拟预测结果^[23]。




图 2 模型鲁棒性分析原理^[13]

Fig.2 Principles of model robustness analysis^[13]

蒙特卡罗方法广泛用于评估计算模型的鲁棒性。因为该方法可以处理不规则函数或复杂模型, 特别是人工神经网络。本文使用蒙特卡罗方法研究预测模型输出参数与输入参数之间的可变性。为研究人工计算模型在计算软土固结系数 C_v 中的鲁棒性, 对结果进行统计分析, 基于以下方程确定蒙特卡罗方法运行的最佳次数^[24]:

$$f = \frac{1}{m} \sum_{j=1}^m S_j \quad (2)$$

式中: f 为最佳模拟次数; m 为蒙特卡罗实现次数; S_j 为考虑的实际随机变量。 m 的最佳值表示达到稳定解所需要的时间。

4 模型数据库

本文使用的数据来源于连淮高速公路改扩建路基软土, 共计 205 个软土样品数据。其中, 将土样深度 (m)、含水率 (%)、天然密度 (g/cm^3)、干密度 (g/cm^3)、孔隙比、饱和度 (%)、土粒相对密度、液限 (%)、塑限 (%)、塑性指数和液性指数作为计算模型的输入参数。而软土的固结系数 C_v (cm^2/s) 作为计算模型的输出参数。样品深度、液限和固结系数 C_v 的累积分布函数如图 3 所示。各参数的定量统计分析如表 1 所示, 表中 D 表示分位数, D_{10} 、 D_{25} 、 D_{50} 、 D_{75} 和 D_{90} 分别表示 10%、25%、50%、75% 和 90% 分位数。

从图 3 和表 1 可以看出, 样品深度范围为 0.7~29.2 m, 数据主要集中在深度 0.7~12 m 范围内, 样品深度的中值 D_{50} 为 2.8 m, 标准偏差为 3.38 m; 液限变化范围为 16.3%~91.7%, 主要集中在 20%~80% 范围内, 液限的中值 D_{50} 为 46.5%, 标准偏差为 12.9%; 固结系数的变化范围为 $0.15 \times 10^{-3} \sim 3.49 \times 10^{-3} \text{ cm}^2/\text{s}$, 主要集中在 $0 \sim 1 \times 10^{-3} \text{ cm}^2/\text{s}$ 范围内, 标准偏差为 $0.66 \times 10^{-3} \text{ cm}^2/\text{s}$ 。

在多参数分析复杂问题时, 参数与参数之间会出现共线性问题, 需要对数据进行预处理, 以降低模型输入空间的维数, 从而使测量过程中的误差最小化。计算了 11 个输入参数的相关矩阵, 如表 2 所示。从表中可以看出, 样品深度与其他输入参数的相关系数 $R^2 < 0.05$, 表明样品深度是独立变量。含水率与天然密度的相关系数 $R^2 = 0.77$, 天然密度跟干密度的相关系数 $R^2 = 0.69$; 孔隙比与天然密度和含水率的相关系数 $R^2 > 0.8$, 可以使用孔隙比参数代表这 3 个参数; 液限与塑限的相关系数 $R^2 = 0.7$, 液限与塑性指数的相关系数 $R^2 = 0.8$, 在液限、塑限和塑性指数 3 个参数中, 可以选用液限参数代表; 其他输入参数的相关系数 $R^2 < 0.6$ 。因此, 模型的输入参数由原来的 11 个减少为 7 个, 这 7 个输入参数分别为样品深度、干密度、孔隙比、饱和度、土粒相对密度、液限和液性指数。

下面使用主成分分析对输入参数进行分析。主成分分析的结果如表 3 所示。从表中可以得出, 主成分分析 PC_1 、 PC_2 、 PC_3 、 PC_4 、 PC_5 、 PC_6 和 PC_7 的方差百分比分别为 45.79%、20.70%、11.07%、8.02%、6.92%、3.62% 和 2.62%, 其他主成分分析




图 3 参数分布曲线

Fig.3 Parameter distribution curve

表 1 连淮高速扩建路基软土各参数定量统计分析

参数	样品深度/m	含水率/%	天然密度/(g · cm ⁻³)	干密度/(g · cm ⁻³)	孔隙比	饱和度/%	土粒相对密度	液限/%	塑限/%	塑性指数	液性指数	固结系数 $C_v/(10^{-3} \text{ m}^2 \cdot \text{s}^{-1})$
符号	N_1	N_2	N_3	N_4	N_5	N_6	N_7	N_8	N_9	N_{10}	N_{11}	Y
最小值	0.70	14.80	1.35	0.77	0.40	75.50	2.33	16.30	11.40	4.90	0.01	0.15
D_{10}	1.30	25.70	1.62	1.04	0.73	92.00	2.54	31.50	19.80	11.40	0.12	0.26
D_{25}	2.00	31.48	1.72	1.17	0.84	96.28	2.63	41.26	21.60	17.20	0.32	0.40
D_{50}	2.80	36.70	1.83	1.34	1.00	98.60	2.70	46.50	24.70	21.80	0.64	0.55
D_{75}	5.03	46.13	1.91	1.44	1.24	98.71	2.73	54.45	29.50	26.40	0.97	0.87
D_{90}	8.20	59.20	1.98	1.57	1.51	99.32	2.75	65.10	33.20	33.50	1.49	1.52
最大值	29.20	98.10	2.18	1.90	2.79	100.00	2.83	91.70	38.20	53.50	2.52	3.49
标准偏差	3.38	15.24	0.14	0.20	0.38	4.35	0.09	12.79	5.25	8.87	0.52	0.66

表 2 输入参数的相关系数矩阵 R^2 Table 2 Correlation coefficient matrix of input parameters R^2

参数	N_1	N_2	N_3	N_4	N_5	N_6	N_7	N_8	N_9	N_{10}	N_{11}
N_1	1.00	0.02	0.01	0.00	0.02	0.01	0.01	0.02	0.00	0.04	0.00
N_2	0.02	1.00	0.77	0.54	0.94	0.02	0.18	0.25	0.18	0.22	0.46
N_3	0.01	0.77	1.00	0.69	0.82	0.02	0.17	0.24	0.24	0.17	0.39
N_4	0.00	0.54	0.69	1.00	0.56	0.00	0.06	0.17	0.19	0.12	0.34
N_5	0.02	0.94	0.82	0.56	1.00	0.00	0.07	0.27	0.22	0.22	0.4
N_6	0.01	0.02	0.02	0.00	0.00	1.00	0.02	0.00	0.01	0.00	0.01
N_7	0.01	0.18	0.17	0.06	0.07	0.02	1.00	0.00	0.00	0.01	0.14
N_8	0.02	0.25	0.24	0.17	0.27	0.00	0.00	1.00	0.70	0.90	0.04
N_9	0.00	0.18	0.24	0.19	0.22	0.01	0.00	0.70	1.00	0.38	0.03
N_{10}	0.04	0.22	0.17	0.12	0.22	0.00	0.01	0.90	0.38	1.00	0.04
N_{11}	0.00	0.46	0.39	0.34	0.40	0.01	0.14	0.04	0.03	0.04	1.00

的方差百分比最大值为 0.7%；可以得出，这 7 个独立参数可以代表数据总变化的 98.75%。样品深度对 PC_4 的贡献为 78%，含水率对 PC_1 、 PC_7 和 PC_9 的贡献分别为 42%、30%和 41%，干密度对 PC_6 和 PC_7 的贡献分别为 42%和 71%，孔隙比对 PC_1 、 PC_7 和 PC_{10} 的贡献分别为 42%、34%和 69%，饱和度对 PC_3 和 PC_4 的贡献分别为 70%和 60%，土粒相对密度对 PC_5 的贡献为 88%。液限对 PC_1 和 PC_2 的贡献分别为 31%和 46%，塑限对 PC_2 、 PC_7 和 PC_{11} 的贡献分

别为 40%、41%和 32%，塑性指数对 PC_2 、 PC_6 和 PC_{11} 的贡献分别为 43%、53%和 54%，液性指数对 PC_8 的贡献为 76%。主成分分析结果与相关系数矩阵结果一致，因此，模型的输入参数选择样品深度、干密度、孔隙比、饱和度、土粒相对密度、液限和液性指数能代表原始数据所反映的信息，因为移除的参数与其他参数具有很高的相关性^[25]。本文将使用这 7 个输入参数来训练和验证计算模型、量化每个模型的鲁棒性。

表 3 输入参数的主成分分析

Table 3 Principal component analysis of input parameters

参数	PC ₁	PC ₂	PC ₃	PC ₄	PC ₅	PC ₆	PC ₇	PC ₈	PC ₉	PC ₁₀	PC ₁₁
方差百分比/%	45.79	20.70	11.07	8.02	6.92	3.62	2.62	0.70	0.49	0.06	0.00
N_1	-0.08	-0.07	-0.55	0.78	-0.23	0.14	0.00	-0.05	0.01	0.00	0.00
N_2	0.42	-0.16	0.07	0.05	0.06	0.20	0.30	-0.13	0.41	-0.69	0.00
N_3	-0.41	0.14	0.17	0.11	0.06	0.06	0.02	0.39	0.77	0.16	0.00
N_4	-0.37	0.13	0.14	-0.05	-0.19	0.42	0.71	0.08	-0.32	-0.03	0.00
N_5	0.42	-0.11	-0.07	-0.03	0.19	0.21	0.34	-0.30	0.23	0.69	0.00
N_6	0.02	-0.08	0.70	0.60	0.26	-0.17	0.04	-0.11	-0.17	0.05	0.00
N_7	-0.17	0.25	-0.32	0.03	0.88	0.07	0.06	0.00	-0.12	-0.14	0.00
N_8	0.31	0.46	0.05	0.09	-0.07	0.11	-0.06	0.22	-0.05	0.02	-0.78
N_9	0.28	0.40	-0.12	0.08	-0.09	-0.61	0.41	0.29	0.00	0.02	0.32
N_{10}	0.28	0.43	0.14	0.08	-0.04	0.53	-0.33	0.15	-0.08	0.02	0.54
N_{11}	0.23	-0.54	-0.05	0.02	0.15	0.12	0.03	0.76	-0.19	0.07	0.00

5 计算模型的建立与性能检验

5.1 计算模型的建立

根据第 4 章的分析, 计算模型输入参数为样品深度、干密度、孔隙比、饱和度、土粒相对密度、液限和液性指数, 输出参数为软土的固结系数 C_v 。本文基于生物地理学优化的神经网络计算模型进行训练。将数据分为两个部分, 70% 为训练部分, 30% 为测试部分, 训练部分数据用来更新神经元权重。ANN-BBO 模型使用 50 个栖息地、1 000 次迭代次数, 隐藏层神经元的数量从 1 开始增加, 通过训练得出最佳隐藏层和隐藏层神经元数, 激活函数为 Sigmoid 函数, 动量因子 μ 为 0.001, 学习率为 0.1, 模型的训练和预测在 Matlab 中进行。ANN 模型和 ANN-BBO 模型的训练泛化点如图 4 所示, 从图中可以看出, ANN-BBO 模型最先达到泛化点。ANN-BBO 模型和 ANN 模型 (训练集) 对软土固结系数 C_v 的计算结果与实测结果如图 5 所示。






图 4 ANN 模型和 ANN-BBO 模型训练性能对比

Fig.4 Comparison of training performance between ANN model and ANN-BBO model



(a) ANN-BBO 模型



(b) ANN 模型

图 5 ANN-BBO 模型和 ANN 模型性能对比

Fig.5 Performance comparison between ANN-BBO model and ANN model

从图 5 可以看出, ANN-BBO 模型和 ANN 模型在训练数据集中比较准确地计算出软土的固结系数 C_v 。为了得到预测结果与实测结果的相关性, 对预测值与实测值进行线性拟合, 拟合方程如图 5 所示。计算模型训练效果最好的是 ANN-BBO 模型, $R^2 = 0.960 2$; ANN 模型训练效果接近 ANN-BBO 模型, $R^2 = 0.940 9$ 。从线性拟合曲线看, ANN-BBO 模型

线性拟合的斜率接近 1, ANN-BBO 模型的预测精度最高。ANN 模型经过 BBO 算法优化后, 其预测精度明显提高。

5.2 计算模型的性能检验

为了检验预测模型的性能, 需要对所建立的预测模型进行检验, 在检验模型的性能时常使用相关系数 R^2 、均方根误差 (RMSE) 和方差比 (VAF) 等指标^[26-27]。RMSE 和 VAF 的计算公式为

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_a - y_b)^2} \quad (3)$$

$$\text{VAF} = \left[1 - \frac{\text{var}(y_a - y_b)}{\text{var}(y_a)} \right] \times 100 \quad (4)$$

式中: y_a 为固结系数 C_v 的实测值; y_b 为固结系数 C_v 的预测值; var 表示方差; N 为样本的编号。表 4 给出了 ANN-BBO 模型和 ANN 模型的检验结果。ANN-BBO 模型和 ANN 模型中软土固结系数 C_v 的预测结果如图 6 所示。

表 4 ANN-BBO 模型和 ANN 模型的检验结果

模型	数据集	R^2	RMSE/($10^{-3} \text{ cm}^2 \cdot \text{s}^{-1}$)	VAF/%
ANN-BBO	训练集	0.960 2	0.173 7	92.64
	测试集	0.947 1	0.165 7	94.54
ANN	训练集	0.940 9	0.190 2	91.19
	测试集	0.935 2	0.204 3	91.31

从检验结果和预测结果可知, ANN-BBO 模型和 ANN 模型都准确地计算了软土固结系数 C_v 。计算模型预测精度最高的是 ANN-BBO 模型, ANN 模型的预测精度略低于 ANN-BBO 模型。从图 6(c)中可以看出, 当固结系数 $C_v < 1.2 \times 10^{-3} \text{ cm}^2/\text{s}$ 时, 预测结果较离散, 当固结系数 $C_v > 1.2 \times 10^{-3} \text{ cm}^2/\text{s}$ 时, 预测精度较高。

ANN-BBO 模型和 ANN 模型预测值与实测值对比如图 7 所示。从图中可以看出, ANN-BBO 模型和 ANN 模型的计算值与实测值的偏差较小。ANN-BBO 模型和 ANN 模型误差分布如图 8 所示。从图 8(a)可以看出, 对于训练数据集, 计算模型的误差分布主要集中在 $-0.375 \times 10^{-3} \sim 0.375 \times 10^{-3} \text{ cm}^2/\text{s}$ 之间, 每个计算模型的计算误差都很小; ANN-BBO 模型误差分布达到最高峰值, 并靠近 0, 其次是 ANN 模型。从图 8(b)可以看出, 对于测试数据集, 计算模型的误差分布主要集中在 $-0.5 \times 10^{-3} \sim 0.375 \times 10^{-3} \text{ cm}^2/\text{s}$ 之间。从表 4 可以看出, ANN-BBO 模型的性能明显优于 ANN 模型。




图 6 ANN-BBO 模型和 ANN 模型预测结果
Fig.6 Prediction results of ANN-BBO model and ANN model






图 7 计算模型计算值与实测值的样本指数函数对比
Fig.7 Comparison of sample exponential function between calculated value and measured value of calculation model



(a) 训练数据集



(b) 测试数据集


图 8 计算模型性能对比

Fig.8 Comparison of computational model performance


上述分析表明, ANN-BBO 模型在预测软土的固结系数 C_v 方面的性能最好, ANN-BBO 模型的权重和偏差基于 BBO 优化技术使模型的性能更好, ANN 模型也很好预测了软土的固结系数 C_v 。

6 基于蒙特卡罗模拟的计算模型鲁棒性分析

为了检验 ANN-BBO 模型和 ANN 模型的鲁棒性, 将数据库的输入参数作为新的随机输入参数, 生成了 300 个蒙特卡罗模拟。通过计算 ANN-BBO 模型和 ANN 模型的预测误差, 得到 ANN-BBO 模型和 ANN 模型的 300 个误差计算值, 得出了误差计算值的概率分布。蒙特卡罗模拟结果如图 9 所示, 误差统计如表 5 所示。从图 9(a)和表 5 可以看出, ANN-BBO 模型的相关系数 R^2 分布最靠近 1, 其次是 ANN 模型, ANN-BBO 模型的相关系数 R^2 主要分布在 0.875~0.975 范围内。从图 9(b)和表 5 可以看出, ANN-BBO 模型的概率分布最靠近 0, 其次是 ANN 模型; 分布结果跟相关系数 R^2 的概率分布



(a) 相关系数



(b) 均方根误差

图 9 蒙特卡罗模拟结果

Fig.9 Monte Carlo simulation results

表 5 预测模型鲁棒性分析

Table 5 Robustness analysis of prediction models

指标	R^2		RMSE	
	ANN-BBO	ANN	ANN-BBO	ANN
D25	0.923 8	0.852 7	0.151 3	0.197 2
D50	0.937 8	0.914 0	0.175 1	0.246 9
D75	0.950 2	0.925 0	0.199 3	0.364 6
平均值	0.935 7	0.882 0	0.178 3	0.302 8

结果相同。ANN-BBO 模型和 ANN 模型相关系数 R^2 和均方根误差 RMSE 的分位数和平均值如表 5 所示。在 300 次蒙特卡罗模拟中, 相关系数 R^2 和均方根误差 RMSE 的统计表明, ANN-BBO 模型的鲁棒性最好, ANN 模型的鲁棒性较差。

7 结 论

本文基于生物地理优化的人工神经网络模型对软土的固结系数 C_v 进行计算, 得出以下主要结论:

(1) 通过相关系数矩阵和主成分分析对软土 11 个参数进行分析, 删除了含水率、天然密度、塑限

和塑限指数 4 个参数, 选择择样品深度、干密度、孔隙比、饱和度、土粒相对密度、液限和液性指数 7 个参数作为计算模型的输入参数。

(2) 建立的软土固结系数 C_v 计算的 ANN-BBO 模型, 并与 ANN 模型进行对比分析。使用相关系数 R^2 和均方根误差 RMSE 来检验计算模型时, ANN-BBO 模型的计算结果良好, 计算值与实测值的误差较小。ANN-BBO 模型的相关系数 $R^2 = 0.9471$, 均方根误差 RMSE = 0.1657, 方差比 VAF = 94.54%; ANN-BBO 模型的预测精度明显优于 ANN 模型。

(3) 基于蒙特卡罗模拟对计算模型的鲁棒性进行分析。根据模拟结果的统计分析, ANN-BBO 模型的鲁棒性比 ANN 模型更好。

参 考 文 献

- [1] 武猛, 蔡国军, 王才进, 等. 基于电阻率孔压静力触探的浅层气可靠度识别[J]. 岩土力学, 2022, 43(12): 3463-3473.
WU Meng, CAI Guo-jun, WANG Cai-jin, et al. Reliability identification of subsurface shallow gas based on resistivity piezocone penetration tests[J]. **Rock and Soil Mechanics**, 2022, 43(12): 3463-3473.
- [2] 汪晔欢, 王勇, 孔令伟, 等. 基于原位多功能孔压静力触探的含浅层气地层识别与应用[J]. 岩土力学, 2022, 43(12): 3474-3483.
WANG Ye-huan, WANG Yong, KONG Ling-wei, et al. Identification of shallow gas-bearing strata based on in situ multi-function piezocone penetration test and its application[J]. **Rock and Soil Mechanics**, 2022, 43(12): 3474-3483.
- [3] BJERRUM L. Engineering geology of normally consolidation marine clays as related to settlements of buildings[J]. **Geotechnique**, 1967, 17(2): 81-118.
- [4] 余松霖, 柯瀚, 詹良通, 等. 工程渣土的工程特性及矿坑填埋场的工后沉降和容量分析[J]. 浙江大学学报(工学版), 2020, 54(12): 2364-2376, 2385.
YU Song-lin, KE Han, ZHAN Liang-tong, et al. Engineering properties of excavated soil and analysis of post-construction settlement and capacity for pit landfill[J]. **Journal of Zhejiang University (Engineering Science)**, 2020, 54(12): 2364-2376, 2385.
- [5] 江留慧, 李传勋, 杨怡青, 等. 变荷载下双层地基一维非线性固结近似解析解[J]. 岩土力学, 2020, 41(5): 1583-1590, 1598.
JIANG Liu-hui, LI Chuan-xun, YANG Yi-qing, et al. Approximate analytical solutions for one-dimensional nonlinear consolidation of double-layered soil under time-dependent loading[J]. **Rock and Soil Mechanics**, 2020, 41(5): 1583-1590, 1598.
- [6] 胡亚元. 准塑性的黏弹性模型在黏土中的应用[J]. 岩土工程学报, 2009, 31(3): 353-360.
HU Ya-yuan. Application of plastic-like visco-elastic model to clay[J]. **Chinese Journal of Geotechnical Engineering**, 2009, 31(3): 353-360.
- [7] 庄迎春, 刘世明, 谢康和. 萧山软黏土一维固结系数非线性研究[J]. 岩石力学与工程学报, 2005, 24(12): 4565-4569.
ZHUANG Ying-chun, LIU Shi-ming, XIE Kang-he. Study on nonlinearity of one-dimensional consolidation coefficient of Xiaoshan clay[J]. **Chinese Journal of Rock Mechanics and Engineering**, 2005, 24(12): 4565-4569.
- [8] 李国维, 盛维高, 蒋华忠, 等. 超载卸荷后再压缩软土的次压缩特征及变形计算[J]. 岩土工程学报, 2009, 31(1): 118-123.
LI Guo-wei, SHENG Wei-gao, JIANG Hua-zhong, et al. Secondary compression characteristics and settlement calculation of soft clay under overloading-unloading and reloading[J]. **Chinese Journal of Geotechnical Engineering**, 2009, 31(1): 118-123.
- [9] 孙立强, 闫澍旺, 邱长林. 考虑新近吹填土固结系数为变量的固结理论研究[J]. 岩土工程学报, 2013, 35(增刊 1): 312-316.
SUN Li-qiang, YAN Shu-wang, QIU Chang-lin. Consolidation theory considering coefficient of consolidation of hydraulic fill as variable[J]. **Chinese Journal of Geotechnical Engineering**, 2013, 35(Suppl.1): 312-316.
- [10] YANG P, ZHANG J, HU H, et al. Coefficient analysis of soft soil consolidation based on measurement of stratified settlement[J]. **Geotechnical and Geological Engineering**, 2015, 34(1): 383-390.
- [11] 桂跃, 余志华, 刘海明, 等. 高原湖相泥炭土固结系数变化规律试验研究[J]. 岩石力学与工程学报, 2016, 35(增刊 1): 3259-3267.
GUI Yue, YU Zhi-hua, LIU Hai-ming, et al. Experimental study of the change law of consolidation coefficient of the plateau lacustrine peaty soil[J]. **Chinese Journal of Rock Mechanics and Engineering**, 2016, 35(Suppl.1): 3259-3267.

- [12] 邓岳保, 王天园, 孔纲强. 考虑温度效应的饱和土地基固结理论[J]. 岩土工程学报, 2019, 41(10): 1827-1835.
DENG Yue-bao, WANG Tian-yuan, KONG Gang-qiang. Consolidation theory for saturated ground considering temperature effects[J]. **Chinese Journal of Geotechnical Engineering**, 2019, 41(10): 1827-1835.
- [13] 王才进, 蔡国军, 武猛, 等. 基于人工智能算法预测土体导热系数[J]. 岩土工程学报, 2022, 44(10): 1899-1907.
WANG Cai-jin, CAI Guo-jun, WU Meng, et al. Prediction of thermal conductivity of soils based on artificial intelligence algorithm[J]. **Chinese Journal of Geotechnical Engineering**, 2022, 44(10): 1899-1907.
- [14] BURDEN F, WINKLER D. Bayesian regularization of neural networks[J]. **Methods in Molecular Biology**, 2008, 458: 25-44.
- [15] ORBANIC P, FAJDIGA M. A neural network approach to describing the fretting fatigue in aluminum-steel couplings[J]. **International Journal of Fatigue**, 2003, 25: 201-207.
- [16] NGUYEN T A, LY H B, JAAFARI A, et al. Estimation of friction capacity of driven piles in clay using artificial neural network[J]. **Vietnam Journal of Earth Sciences**, 2020, 42(2): 265-275.
- [17] SIMON D. Biogeography-based optimization[J]. **IEEE Transactions on Evolutionary Computation**, 2009, 12(6): 702-713.
- [18] 杨波, 程维政, 朱超. 小世界效应加速生物地理学优化的社团识别算法[J]. 哈尔滨工业大学学报, 2020, 52(3): 179-185, 194.
YANG Bo, CHENG Wei-zheng, ZHU Chao. Detecting communities via biogeography-based optimization accelerated by small-world effects[J]. **Journal of Harbin Institute of Technology**, 2020, 52(3): 179-185, 194.
- [19] EBRAHIM-ZADEH G, BAYAT H, SINEGANI A A S, et al. Investigating the correlation between soil tensile strength curve and soil water retention curve via modeling[J]. **Soil and Tillage Research**, 2017, 167: 9-29.
- [20] GUAN Yiqing, WEI Jianhui, ZHANG Danrong, et al. To identify the important soil properties affecting dinoseb adsorption with statistical analysis[J]. **The Scientific World Journal**, 2013, 2013: 362854.
- [21] 武仁杰, 李海波, 于崇, 等. 基于统计分级判别的爆破块度预测模型[J]. 岩石力学与工程学报, 2018, 37(1): 141-147.
WU Ren-jie, LI Hai-bo, YU Chong, et al. Model for blasting fragmentation prediction based on statistical classification[J]. **Chinese Journal of Rock Mechanics and Engineering**, 2018, 37(1): 141-147.
- [22] 李亚军, 刘斯宏, 傅中志, 等. 多层地基土坡的随机有限元模型不同参数比较分析[J]. 岩土工程学报, 2014, 36(1): 162-169.
LI Ya-jun, LIU Si-hong, FU Zhong-zhi, et al. Comparative study on different parameters of random finite element models for an embankment supported by multilayered foundations[J]. **Chinese Journal of Geotechnical Engineering**, 2014, 36(1): 162-169.
- [23] CHEN J, MEI S, IRIZARRY J T, et al. A Monte Carlo approach to approximating the effects of pore geometry on the phase behavior of soil freezing[J]. **Journal of Advances in Modeling Earth Systems**, 2020, 12(10): e2020MS002117.
- [24] GUILLEMINOT J, SOIZE C. Stochastic model and generator for random fields with symmetry properties: application to the mesoscopic modeling of elastic random media[J]. **Multiscale Modeling & Simulation**, 2013, 11(3): 840-870.
- [25] 许昌, 岳东杰, 董育烦, 等. 基于主成分和半参数的大坝变形监测回归模型[J]. 岩土力学, 2011, 32(12): 3738-3742.
XU Chang, YUE Dong-jie, DONG Yu-fan, et al. Regression model for dam deformation based on principal component and semi-parametric analysis[J]. **Rock and Soil Mechanics**, 2011, 32(12): 3738-3742.
- [26] ZHANG T, WANG C, LIU S, et al. Assessment of soil thermal conduction using artificial neural network models[J]. **Cold Regions Science and Technology**, 2020, 169: 102907.
- [27] ERZIN Y, RAO B H, SINGH D N. Artificial neural network models for predicting soil thermal resistivity[J]. **International Journal of Thermal Sciences**, 2008, 47(10): 1347-1358.