

基于机器学习的软土压缩模量预测及沉降分析

阮永芬¹, 李鹏辉¹, 施虹², 吴龙³, 李飞鹏³, 肖潇³

1. 昆明理工大学 建筑工程学院, 昆明 650500; 2. 云南省设计集团勘察院有限公司, 昆明 650228;
3. 中铁十一局集团城市轨道交通工程有限公司, 武汉 430074

[摘要] 目前, 常规土体试验及预测方法都难以准确获得压缩模量 E_s 。现基于机器学习理论建立一种非参数集成优化法计算 E_s , 并与传统回归模型对比分析。从昆明地铁 5 号线会展中心场地选取 203 组泥炭质土物理力学指标样本, 结合工程经验, 选取其中 8 个重要的物理指标作为输入集, 利用遗传算法优化 BP 神经网络输入层、隐含层及输出层之间的权值及阈值, 采用相关系数 R 、准确率 ACC 及均方根误差 $RMSE$ 多个评估指标优化确定算法的重要参数, 将建立好的模型应用于多种土体, 并与目前应用较多的方法对比分析, 最后比较经验公式与本文方法预测地基沉降的性能。结果显示, GA-BP 神经网络方法对分析样本适应性强、算法收敛快、所得结果精准可靠, 具有较大优越性。该方法对软土场地多参数预测具有一定的指导意义。

[关键词] 压缩模量; 机器学习; 遗传算法; BP 神经网络; 规范法

[分类号] TU443

[文献标志码] A

Prediction and settlement analysis of compression modulus of soft soil based on machine learning

RUAN Yongfen¹, LI Penghui¹, SHI Hong², WU long³, LI Feipeng³, XIAO Xiao³

1. Faculty of Civil Engineering and Mechanics, Kunming University of Science and Technology, Kunming 650500, China;
2. Survey Institute Co., Ltd., Yunnan Design Institute Group, Kunming 650228, China;
3. China Railway 11th Bureau Group Urban Rail Engineering Co., Ltd., Wuhan 430074, China

Abstract: Conventional methods were tested to predict the properties of soil struggle to accurately obtain its compression modulus E_s . In this study we developed a nonparametric integrated method of optimization based on machine learning to calculate E_s and compare it with the traditional model of regression to this end. We chose 203 groups of physical and mechanical indices of samples of peaty soil from the Kunming Metro Line 5 Exhibition Center for this purpose. Eight important physical indices

[收稿日期] 2023-05-15。

[基金项目] 国家自然科学基金重点项目(41931294)。

[第一作者] 阮永芬(1964—), 女, 教授, 研究方向: 岩土工程领域, E-mail: rryy64@163.com。

[通信作者] 李鹏辉(1999—), 男, 硕士研究生, 研究方向: 岩土工程领域, E-mail: 1017434381@qq.com。

[引用格式] 阮永芬, 李鹏辉, 施虹, 等, 2024. 基于机器学习的软土压缩模量预测及沉降分析[J]. 成都理工大学学报(自然科学版), 51(2): 258-268+280.

Ruan Y F, Li P H, Shi H, et al., 2024. Prediction and settlement analysis of compression modulus of soft soil based on machine learning[J]. Journal of Chengdu University of Technology (Science & Technology Edition), 51(2): 258-268+280.

were used as the input set, and the weights and thresholds of the input layer, hidden layer, and output layer of the BP neural network were optimized by using a genetic algorithm. The correlation coefficient, accuracy, and root mean-squared error were used to optimize the parameters of the algorithm, and the resulting model was applied to a variety of soils and compared with prevalent methods in the area. Finally, the predictive performance of the proposed method was compared with the results of the relevant empirical formula. The results showed that the GA-BP neural network-based method was highly adaptable to the analysis of samples, converged quickly, and generated accurate and reliable results. This method could be used to predict multiple parameters of soft soil.

Key words: compression modulus; machine learning; genetic algorithm; BP neural network; normative method

滇池流域广泛分布着由泥炭质土、黏土、粉土及粉砂等互层组成的湖积相软土。这类软土中以泥炭质土最为特殊,分布层数多、物理力学指标较离散、富含有机质胶体、含水量较高、 E_s (压缩模量) 较低、工程性质较差(阮永芬等, 2003), 受外荷载作用下, 容易引发地基沉降、结构变形、土层隆起等严重灾害。许多学者对泥炭质土的物理力学指标及工程特性进行了研究, 通过分析草炭土有机质含量对工程性质的影响, 发现草炭土的压缩性与其有机质含量成正相关性(吕岩等, 2011)。研究指出 E_s 与 v (泊松比) 是影响软土层变形的最重要的两个指标, 通常采用优化算法依据场地沉降反演 E_s 值(阮永芬等, 2021)。昆明泥炭质土 E_s 具有较大的空间变异性, 对地面沉降影响较大(张蕾等, 2022)。因此, 精确地预测泥炭质土 E_s , 可有效保证建筑物工程设计施工的安全。

目前传统方法是基于大量工程勘测资料, 依靠常规物理指标与 E_s 间的线性拟合关系获取 E_s 。基于多种试验分别建立液限 w_l 、孔隙比 e 、含水量 w 与 E_s 间的关系(Azzous et al., 1976)。针对有机淤泥质土与黏土建立多个物理指标与 E_s 间的关系(Giasi et al., 2003)。采用 10 种试验优化已存在的经验公式, 得到适用性较高的新公式(Sridharan and Nagaraj, 2000)。然而, 这些经验公式在不同场地条件下的适用性千差万别, 而泥炭质土物理力学指标变异性较大, 因此单独使用一种或两三种指标线性拟合所得的 E_s 误差较大, 已不足以满足实际工程应用。

近年来, 机器学习在解决多参数耦合问题中显示出快速有效的能力, 因此该算法被广泛应用于沉降预测(刘宏等, 2005; 陈伟航等, 2022)、砂土液化判别(高广运等, 2022; 姜礼涛等, 2022)、基坑

变形(刘鑫菊等, 2022; 张亮亮等, 2023)等多个领域。许多学者已开始采用机器学习理论去解释物理指标与压缩模量 E_s 之间的灰色数学关系。选取多个物理指标分别基于 MLP 与 BRF 神经网络预测 E_s , 但这类算法收敛性较差, 且未设置合理的算法参数, 因此所得预测结果误差较大(蒋建平等, 2011; 张鹤, 2019)。选取相关系数 R 、均方误差 RMSE 2 个评估指标去确定 GA-GBRT 算法中的重要参数, 并对上海黏土 E_s 进行预测, 一定程度上优化所得结果(Zhang et al., 2020)。尽管机器学习在这一领域应用较多, 但由于算法本身存在一定的局限性, 导致机器学习理论在该领域适用性不强。

考虑到现有模型的局限性, 本文以昆明泥炭质土多个重要的物理力学指标样本为研究对象, 采用留出法对样本划分, 得到互斥且具有相似统计特征的训练、预测集, 利用 GA 算法优化调整 BP 神经网络参数, 选取多个评估指标衡量模型预测效果, 并将建立好的模型与经验公式应用于实际工程的地基沉降计算中, 对预测结果进行检验。结果表明, 本文模型准确率、算法稳定性以及对多种土体的适用性都较好。研究成果及结论对滇池流域湖相沉积软土地场地设计及施工有较高的应用价值与指导意义。

1 数据获取及分析

1.1 研究区泥炭质土特性

昆明会展中心场地属典型的滇池盆地湖积平原地貌, 场地范围分布有多层泥炭质土, 层厚为 0.65~5.25 m, 具有明显的地区特点。收集不同泥炭质土层物理力学指标样本共 203 组, 其物理力学指标统计结果如表 1 所示。可看

出,该场地泥炭质土有机质含量 w_u 较高、抗剪强度指标 (c, φ) 较低、 E_s 也较低、孔隙比 e 大及含水量 w 高等。该场地泥炭质土工程性质较

差,地基承载力较低,压缩性较大,对建构筑地基具有不利影响,需采取合适的措施进行处理,以满足施工要求。

表 1 各层泥炭质土的物理力学指标统计结果

Table 1 Physical and mechanical indices of each layer of peaty soil

地层	$\rho/(\text{g}\cdot\text{cm}^{-3})$	$w/\%$	$w_l/\%$	$w_p/\%$	e	$w_u/\%$	c/kPa	$\varphi/^\circ$	E_s/MPa
③ ₁ ¹	1.31	110.10	135.40	100.00	2.49	24.33	12.70	2.30	1.38
③ ₂	1.42	101.20	119.20	87.20	2.40	18.36	10.10	5.20	1.85
④ ₁	1.25	145.70	182.10	146.40	2.93	40.10	13.00	3.20	2.25
⑤ ₁ ²	1.27	130.60	174.30	140.60	2.52	38.77	15.20	5.10	2.59

1.2 指标选取及数据分析

为确保后续模型预测效果,以及全面反映泥炭质土的变形特性,从多角度选择合适的物理指标作为研究对象。通过整理指标间换算公式(表 2)及众多学者所选研究对象,综合选取 9 个指标作为研究对象(蒋建平等, 2011; 张鹤, 2019; Zhang et al., 2020)。采用深度 d 来描述土样的所处空间位置,代表其土体的初始条件;密度 ρ 、含水量 w 、比重 G_s 、液塑限 w_l, w_p 、有机质含量 w_u 为实验实测值,代表土体的原始状态;孔隙比 e 虽为计算可得,但其为泥炭质土的工程特性之一,也应作为模型输入量之一;选用 E_s 作为模型输出结果。

表 2 部分物理指标换算公式

Table 2 Part of the formula for the conversion of the physical indices

序号	换算公式
1	$\rho_d = \rho / (1 + w)$
2	$\gamma = \rho g$
3	$I_l = (w - w_l) / I_p$
4	$I_p = w_l - w_p$
5	$e = G_s \rho_w (1 + w) / \rho - 1$
6	$a_{1-2} = (e_i - e_{i+1}) / (\rho_{i+1} - \rho_i)$
7	$E_s = (1 + e_i) / a_{1-2}$
8	$s_r = w G_s \rho / G_s \rho_s (1 + w) - \rho$

为验证所选数据可用于后续模型输入,描述 E_s 与 8 个指标间相关性及分布情况(图 1)。从图 1 中可看出,所选参数分布较为集中,规律性较强,离散性较弱,所选参数较合理,可有效保证后续模型稳定运行。同时发现该场地 8 个输入指标之间相关性较高,最高可达 0.91,因此可构建双

指标间经验公式,为该场地参数取值提供参考。需要注意的是,在这 8 个指标中, d 与 E_s 间相关性最高,达到 0.78,而其余指标与 E_s 间相关性最高仅有 0.24,相关性较差,即 d 是影响 E_s 变化的重要因素。出现这个现象的主要原因为下层泥炭质土沉积时间长,孔隙中的大量自由水被排出,导致土体压缩性增大。

2 算法模型建立

2.1 BP 神经网络原理

BP 神经网络算法是一种常见的前馈神经网络,是目前应用最为广泛的神经网络模型。BP 神经网络的学习过程主要分为 2 个阶段:第一阶段是误差的正向传播,从输入层经过隐含层最终达到输出层;第二阶段是误差的反向传播,从输出层到达隐含层最终达到输入层。通过依次调节 2 层之间的权重与偏置,正反向传播循环反复,直至网格收敛,使得输出结果逼近实际值(图 2)。

2.2 GA-BP 神经网络模型

虽然 BP 神经网络具有较强的非线性映射能力、自适应能力及泛化能力,但同样存在局部极小化、收敛速度慢等缺点(刘洋, 2018; 熊玄辰等, 2021),因此本文引入遗传(GA)算法与 BP 神经网络组合。GA 是模拟自然界生物遗传学及进化论而发明的一种并行随机搜索优化方法,依据达尔文的“适者生存,优胜劣汰”思想,通过数学的形式将大自然的淘汰进化过程转换成优化目标个体编码基因的选择、交叉和变异的过程,从而产生优良的基因,使新产生的个体在集成了上一代个体优良基因的基础上性能更优于上一代(欧阳磊等, 2022)。

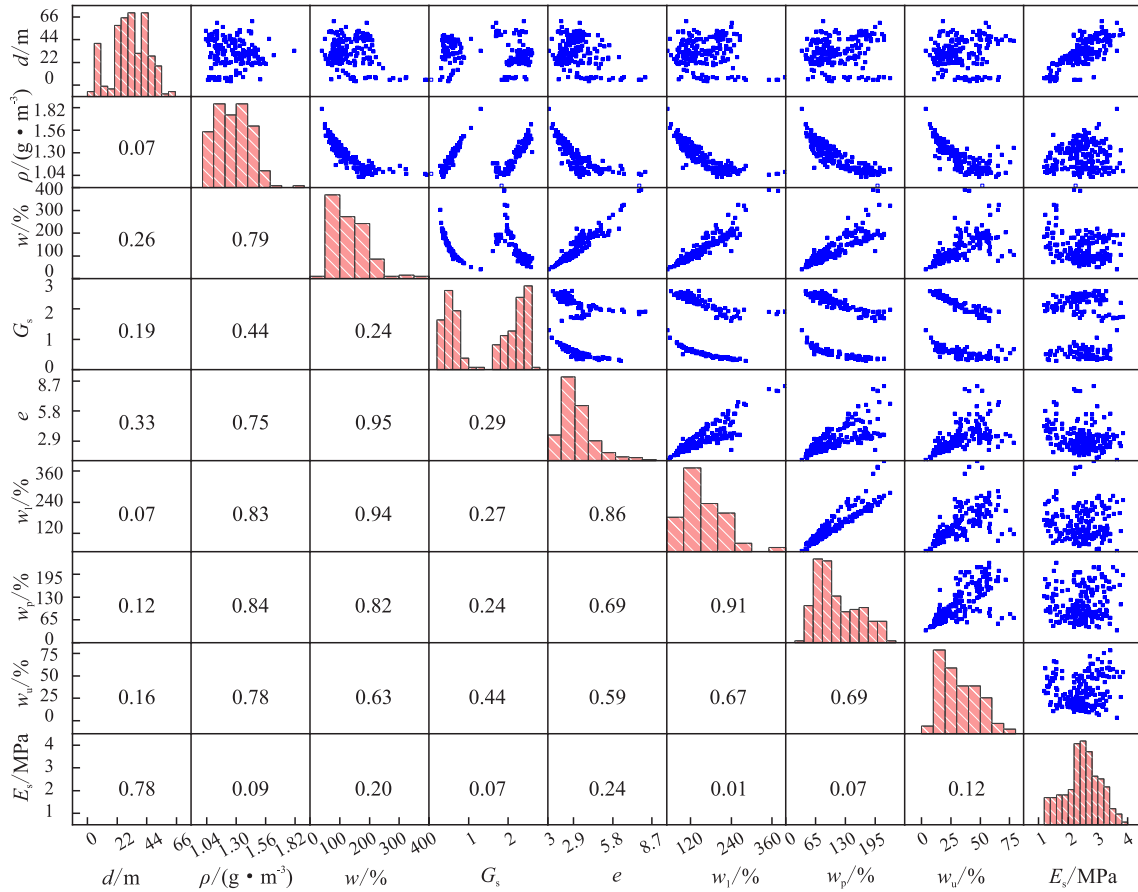


图 1 指标分布及相关性

Fig. 1 Distribution of the indices and the correlations between them




图 2 BP 神经网络学习过程

Fig. 2 Process of learning of the BP neural network

将遗传算法与 BP 神经网络结合,进行网络模型的参数优化,避免网络模型训练过程中陷入局部极值的问题,提高模型预测精度和稳定性(图 3)。其步骤如下:

(1)首先,将 BP 神经网络初始权值和阈值以实数编码的方式转译成一个实数串,将一组权值和阈值编码的字符串定义为一个个体,若干个个体

组成一个种群。

(2)为衡量所有个体基因的优良程度,即衡量每组编码的初始权值和阈值对网络模型训练后的

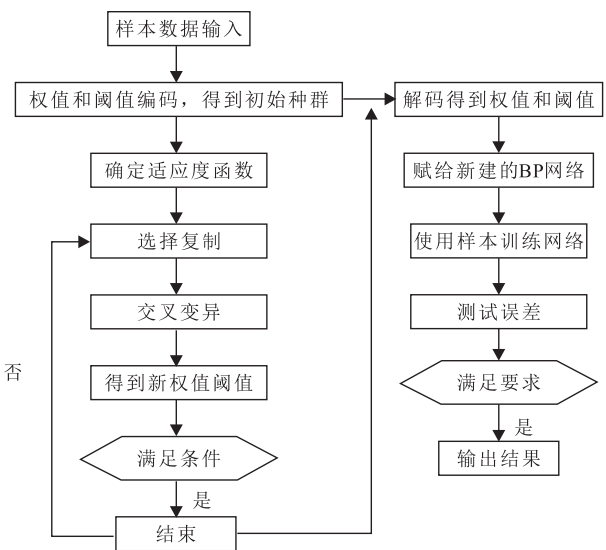


图 3 GA-BP 神经网络算法流程图

Fig. 3 Flowchart of the GA-BP neural network algorithm

预测泛化能力。将网络模型输出值和实际值的相对误差作为个体的适应度函数值 F , 计算如下。

$$F = \frac{1}{n} \sum_{i=1}^n \frac{|p_i - y_i|}{y_i} \quad (1)$$

式中: n 为训练样本数量; y_i 和 p_i 分别为每个训练样本的实际值与预测值。

(3) 经过个体编码、适应度函数确定和初始种群的生成后, 进行遗传算法的循环过程, 在这一过程中会不断产生新个体组成新的种群, 直到满足设定的迭代数, 退出循环。

(4) 经过遗传算法的选择运算、交叉运算、变异运算等步骤, 满足最大进化迭代次数后, 遗传算法优化流程终止。将适应度值最优的权值和阈值赋值到 BP 神经网络, 进行再次训练, 训练结束后进行测试数据的预测分析。

3 案例分析

3.1 数据划分

首先将样本数据划分训练集和测试集, 一般情况下训练集占比 60%~90%, 且测试集应该尽可能与训练集相互排斥。训练集和测试集应该具有类似的统计特征, 可避免因数据划分引入额外的偏差, 对最终结果产生影响。因此, 本文采用留出法对样本数据进行划分, 分别测试训练集样本占比在 60%~90% 范围内的预测效果。最终确

定训练集和测试集的最佳占比分别为 70% 和 30%, 训练集样本数和测试集样本数分别为 153 个和 50 个。现对划分后的输入、输出变量的重要统计结果进行分析(表 3), 可发现训练集样本与测试集样本的大部分统计结果相差不大, 数据区间范围一致, 划分后的数据集可代表相同的总体, 因此可认为数据划分较合理。

确定好样本集后, 为避免各输入指标的数据级差异过大, 影响算法求解效果, 应先将各指标进行归一化, 如公式(2)所示。当模型计算结束后, 可采用反归一化得到实际输出结果(陆文玲等, 2022), 如公式(3)所示。

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

$$y = \frac{(y_{\text{norm}} + 1)(y_{\text{max}} - y_{\text{min}})}{2} + y_{\text{min}} \quad (3)$$

3.2 模型建立

由 1.2 节可知, 本文选择 8 个输入指标与 1 个输出指标, 故可确定模型输入层与输出层节点数, 由此构建“物理参数—压缩模量”预测模型。而隐含层一般采用一层可满足其精度要求, 且节点数可采用经验公式确定, 如公式(4)所示。

$$Q = \sqrt{(W + E)} + C \quad (4)$$

式中: Q 为隐含层节点数; W 为输入层节点数; E 为输出层节点数; C 为 0 到 10 的常数。

表 3 输入、输出样本统计结果

Table 3 Results of the input and output samples

变量	类型	均值	标准差	偏度	峰度	最小值	中位数	最大值
d/m	训练	30.73	13.13	-0.14	-0.45	3.70	30.70	61.70
	预测	34.09	13.84	-0.76	-0.19	5.30	37.65	56.40
$\rho/(g \cdot cm^{-3})$	训练	1.27	0.14	0.13	-1.02	1.03	1.29	1.63
	预测	1.24	0.16	1.03	1.52	1.03	1.23	1.81
$w/\%$	训练	134.11	64.06	1.65	4.01	49.70	110.00	418.00
	预测	140.80	69.23	1.92	5.13	39.50	120.00	392.00
G_s	训练	1.51	0.85	-0.22	-1.77	0.29	1.91	2.60
	预测	1.36	0.84	0.08	-1.82	0.34	1.46	2.53
e	训练	3.09	1.22	1.59	3.15	1.29	2.78	8.21
	预测	3.25	1.30	1.78	4.56	1.07	3.00	7.90
$w_1/\%$	训练	154.00	59.51	1.08	1.57	59.50	136.00	398.00
	预测	163.78	65.50	1.07	1.79	52.70	155.00	377.00
$w_p/\%$	训练	109.85	45.44	0.70	-0.57	43.00	95.00	227.40
	预测	117.76	49.04	0.33	-1.12	34.90	106.00	210.00
$w_u/\%$	训练	31.47	15.92	0.54	-0.85	7.00	28.50	71.63
	预测	35.65	18.18	0.42	-0.51	3.54	32.56	78.57
E_s/MPa	训练	2.44	0.61	-0.11	-0.46	1.20	2.49	3.85
	预测	2.58	0.54	-0.32	-0.17	1.30	2.59	3.64

为使本文模型预测效果达到最优,本文采用相关系数 R 、均方根误差 $RMSE$ 以及正确率 ACC 评估模型预测性能。 $RMSE$ 用来衡量真实值与预测值之间偏差, $RMSE$ 值越小代表两值误差越小,意味着预测效果越好。由于模型本身以及试验中所得数据会存在一定的误差,采用 APD 来表示实测值与预测值的绝对差值, APD 越小,指标误差越小。最终本文确定当 APD 小于 5 时,认为这组样本数据达到预测目标。其中 R , $RMSE$, APD , ACC 计算如公式(5)~(8)所示。

$$R = \frac{\sum_{i=1}^n (y_i - \bar{y})(x_i - \bar{x})}{\sqrt{\sum_{i=1}^n (y_i - \bar{y})^2 \cdot \sum_{i=1}^n (x_i - \bar{x})^2}} \quad (5)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - x_i)^2} \quad (6)$$

$$APD = |E_{s(实)} - E_{s(预)}| / E_{s(实)} \times 100\% \quad (7)$$

$$ACC = N_{APD < 5\%} / N_{总} \times 100\% \quad (8)$$

式中: \bar{x} , \bar{y} 代表不同指标的平均值; x_i , y_i 代表不同指标的实测值。

现采用遗传(GA)算法优化 BP 神经网络,在 GA 算法中需提前设定 4 个参数:群体大小、交叉概率、变异系数及遗传代数,其中部分参数可采用反复试算法和考虑目前常用的设计参数进行确定。其中,随着遗传代数的增加,模型的适应度会发生变化(图 4)。当遗传代数达到 7 以后,最佳适应度曲线与平均适应度曲线相吻合,则可认为该模型达到最佳预测效果,GA 算法的参数设置如表 4 所示。同理,采用相同方法确定 BP 神经




图 4 不同遗传代数适应度变化
Fig. 4 Changes in the fitness of different genetic generations

网络参数,结果如表 5 所示。由公式(4)可知,隐含层节点数一般设置为[3,13],但结合目前研究可发现一般情况下设置的隐含层节点数比输入层节点数大,因此初步设置隐含层节点为[9,14]。

表 4 遗传算法参数设置

群体大小	交叉概率	变异系数	遗传代数
50	0.50	0.10	7~15

表 5 BP 神经网络算法参数设置
Table 5 Parameter settings of the BP neural network algorithm

训练目标	学习效率	迭代次数	训练方法	传递函数	隐含层节点
0.001	0.100	1000	LM 方法	隐含层:tansig 输出层:purelin	9~14

由表 4,5 可知,遗传代数有 9 种选择,隐含层节点数有 6 种选择,则在模型运行时共有 54 种组合选择,利用编程软件通过多次计算可得预测效果最优情况时的遗传代数为 12,隐含层节点数 13。分别做出遗传代数为 12 时不同隐含层节点数的模型评价效果及隐含层节点数为 13 时不同遗传代数的模型预测效果图(图 5)。由图 5-A 可知,随着隐含层节点数增加, R 值基本不发生大的变化;当节点数达到 13 时,此时 R 值最大, $RMSE$ 最小, ACC 最大,因此选取隐含层节点数为 13。由图 5-B 可知,随着遗传代数的增加, R , ACC , $RMSE$ 变化虽然没有规律,但可明显看出当遗传代数为 12 时, $RMSE$ 最小,其余两值较大,因此选取遗传代数为 12。

3.3 优化方法预测分析

将训练样本通过归一化后输入到本文模型中,且将上述确定算法参数设置于该模型中,利用公式(2)得到归一化后的预测 E_s 值,再利用公式(3)进行反归一化得到实际预测 E_s 值。可知预测值与真实值基本一致,两值间误差较小(图 6)。将预测值与真实值回归分析可发现,大部分点落在理想拟合曲线附近,实际拟合曲线与理想拟合曲线偏差不大,真实值与预测值的 R 达到 0.93, ACC 达到 82.1%, $RMSE$ 为 0.33。说明训练样本预测结果可被接受。因此,成功建立 GA-BP 神经网络预测模型。

同理,比较了测试样本的 E_s 真实值与预测值(图 7)。除了一些非常大或非常小的样本外,测

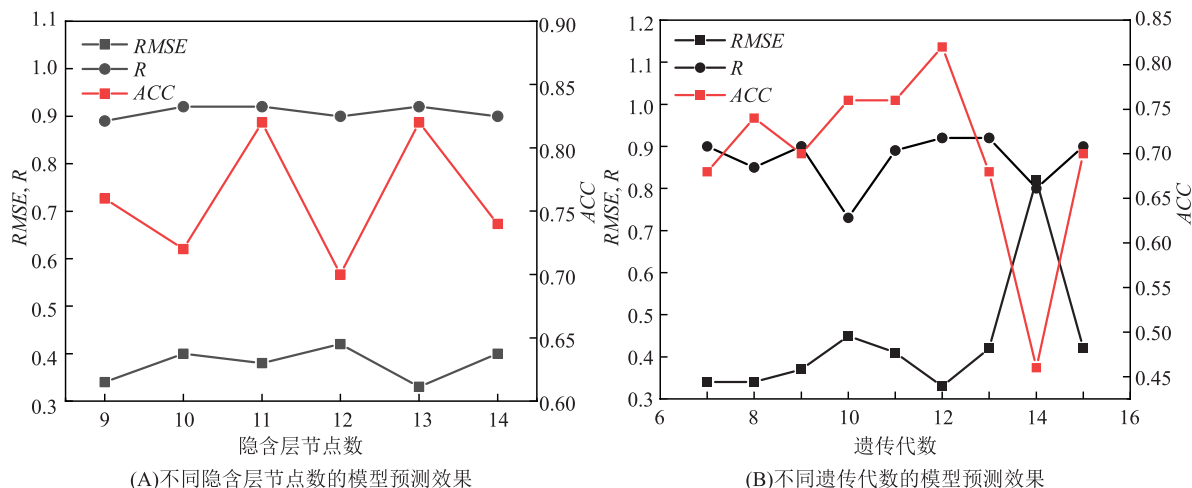


图 5 隐含层节点数与遗传代数的确定

Fig. 5 Determination of the number of nodes of the hidden layer and the genetic algebra

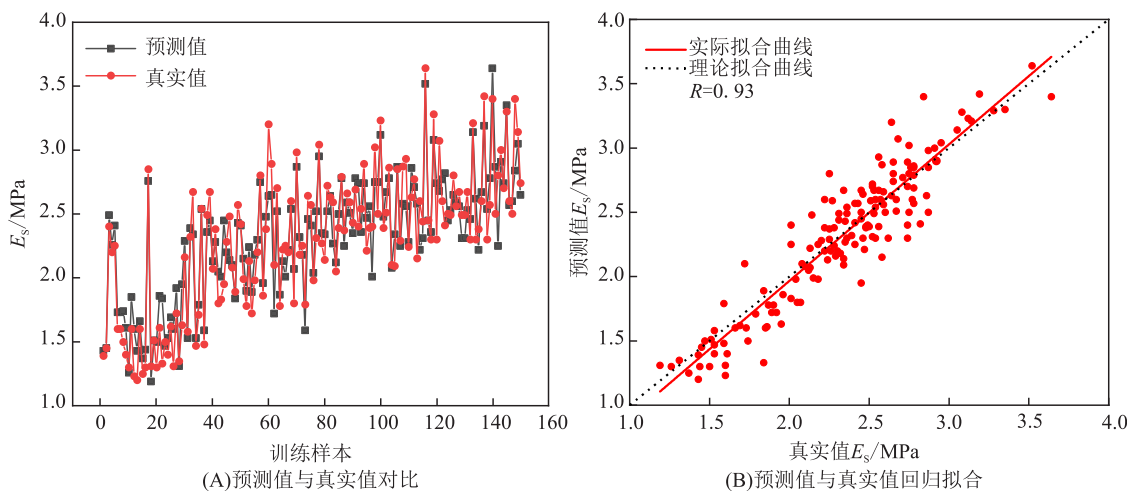


图 6 训练样本 Es 预测结果

Fig. 6 Results of predictions of E_s based on the training samples

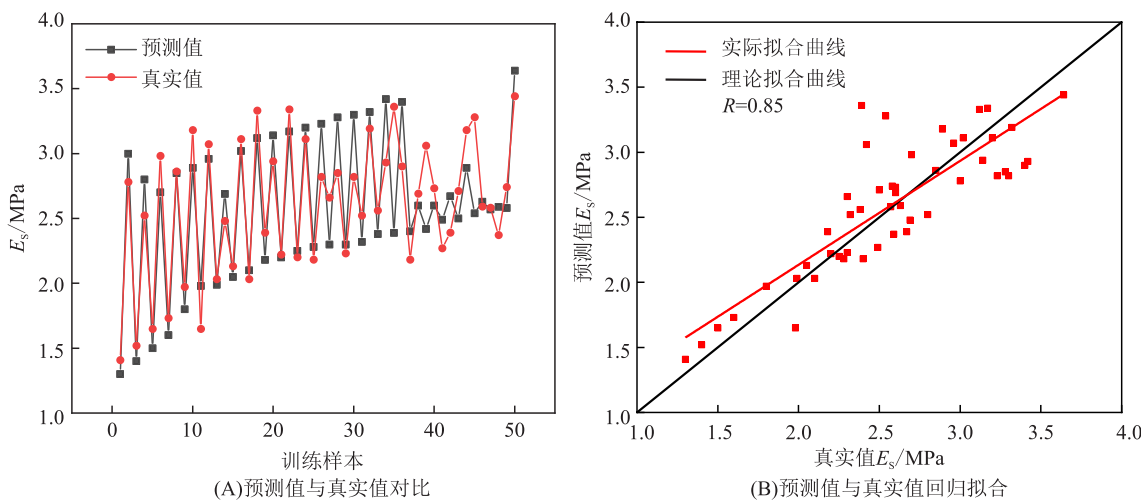


图 7 预测样本 Es 预测结果

Fig. 7 Results of predictions of E_s based on the prediction samples

试集的预测性能大多都很好。其中测试集中 E_s 真实值与预测值的 R 达到 0.85,说明本文所建立模型具有较高的预测性能,所得预测结果较合理。

3.4 指标重要性分析及适用性分析

为了解各输入指标对模型预测性能的影响,对输入指标进行敏感性分析。从 GA-BP 神经网络模型得到的各指标重要性结果(图 8),可知, d 是最敏感的指标,相对重要性得分为 0.142,其主要是由 d 与 E_s 的相关性较高所导致。其次敏感性相对较高的为 w_1 与 w_p 。 w_1 反映了在软土可塑状态与流动状态之间变化, w_p 反映了软土在可塑状态与半固体状态之间变化。其中由 w_1, w_p 及 w 计算可得液性指数 I_L (公式 9),其反映了软土的软硬状态, I_L 越大,土体越软,其 E_s 越低。泥炭质土的有机质主要为植物残渣,在土体内部形成架空结构,因此其含量大小可影响到 E_s, e, w, ρ 及 G_s 等多个指标发生变化,而 w 与 ρ 重要性与其余指标相比,其占比相对较小。通过对各指标重要性分析,可为后续多参数预测时物理力学




图 8 各指标重要性分析
Fig. 8 Analysis of the importance of each index

指标选取研究提供参考。

$$I_L = \frac{w - w_p}{I_p} = \frac{w - w_p}{w_1 - w_p} \quad (9)$$

为进一步验证本文模型的优越性,本文选取 BP 神经网络、偏小二乘法(PLS)、多层感知人工神经网络(MLP)、径向基函数神经网络(RBF)方法与 GA-BP 神经网络进行对比分析(图 9)。可看出优化后的 GA-BP 神经网络算法在 ACC 上超出 BP 神经网络 10%, R 超出 0.13, $RMSE$ 降低 0.09,且与其余方法对比,各指标提升幅度更大。这说明 GA-BP 神经网络算法总体上对预测样本适应性更优、预测效果更好、泛化性能更高,具有较高的稳定性。




图 9 多方法预测效果对比
Fig. 9 Comparison of predictions by multiple methods

将本文方法应用于该地区湖相粉土、黏土等多种土体,具体的计算过程不再赘述,将多种土体的 E_s 预测结果统计于表 6。可发现本文方法不仅适用于泥炭质土,还可以较好适用于其他土体。由本文方法所得结果的 ACC 较高, R 较高, $RMSE$ 较低。说明本文方法具有较高的工程应用价值,适应性较强,后续可将本文方法推广应用于其余地区软土地带。

表 6 多种土体适用性对比

Table 6 Comparison of applicability of various soils

土体	样本集	E_s /MPa	n	隐含层节点数	遗传代数	ACC	RMSE	R
粉土	训练集	5.76	78	12	13	81.10	0.36	0.89
	预测集	5.58	30					0.86
黏土	训练集	2.74	102	12	12	83.40	0.38	0.90
	预测集	2.79	42					0.88
粉砂	训练集	7.12	90	13	14	86.30	0.31	0.92
	预测集	7.02	35					0.91

4 模型应用分析

4.1 经验公式与优化方法对比

目前,众多学者将压缩指数 C_c 与物理指标拟合得到计算 E_s 的经验公式(Azzous et al.,1976; Giasi et al.,2003),如公式(10)所示。其中,针对现有的经验公式,主要通过通过对 10 多种多个地区的软土试验分析,分别将 C_c 与多个物理指标拟合,得到优化后的应用效果较好的公式(Sridharan and Nagaraj,2000),如公式(11),(12)所示。

$$E_s = \frac{1+e_1}{10C_c + \lg 2} \quad (10)$$

式中: e_1 为 0.1 MPa 压力下的孔隙比; C_c 为压缩

指数。

$$C_c = 0.008(\omega_1 - 12) \quad (11)$$

$$C_c = 0.014(I_p + 3.6) \quad (12)$$

将公式(10)与公式(11),(12)分别联立得到 E_s 与多个物理指标之间的关系式,如公式(13),(14)所示。

$$E_s = \frac{1+e_1}{0.08(\omega_1 - 12) + \lg 2} \quad (13)$$

$$E_s = \frac{1+e_1}{0.14(I_p + 3.6) + \lg 2} \quad (14)$$

为验证本文模型所得结果,将训练及预测集数据代入公式(13),(14)中,得到不同方法下的 E_s 的计算结果(图 10)。

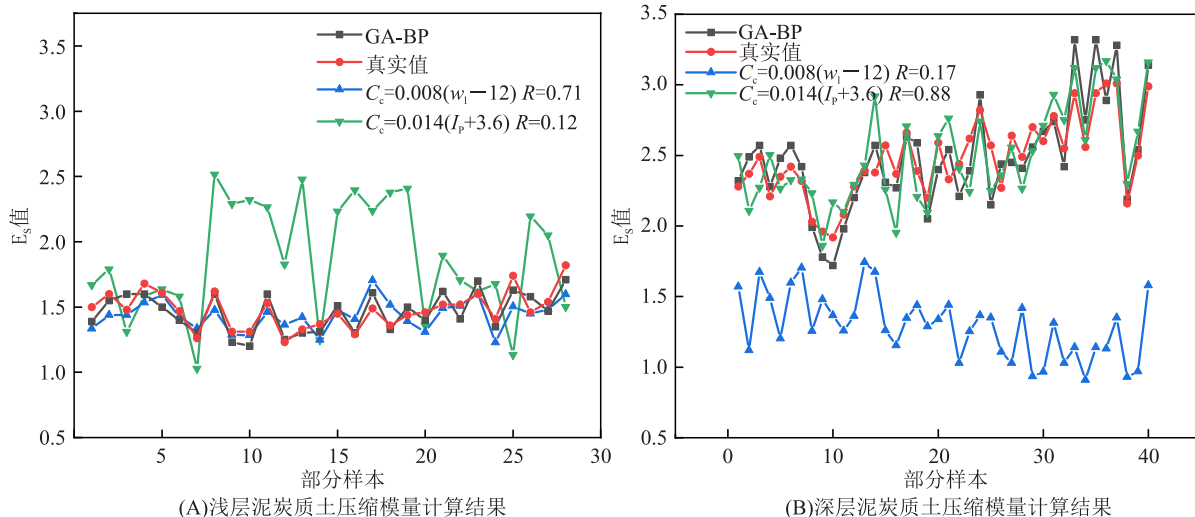


图 10 经验公式与 GA-BP 所得 E_s 比较

Fig. 10 Comparison of values of E_s obtained by the empirical formula and the GA-BP model

从图 10 可看出,由公式(13)计算的浅层泥炭质土样本的 E_s 更接近真实值。相反,由公式(14)计算的深层泥炭质土样本的 E_s 更接近真实值。

主要原因如下:由于泥炭质土 ω_1 比一般黏土较高,故公式(13)所得 E_s 比一般黏土偏低,而上部土层 E_s 较低,故公式(13)更适用于上部泥炭土层;而泥炭质土 I_p 与一般黏土相差不大,由公式(14)计算的 E_s 比公式(13)偏大,故公式(14)不适用于上部土层;伴随着泥炭质土样本埋深 d 增加,物理指标逐渐变好,与一般黏土较接近,因此公式(14)更适用于深层泥炭质土层。与经验公式相比,本文模型的 R 值较高,表明由 GA-BP 神经网络算法得到的 E_s 明显优于经验公式所得 E_s 。

4.2 地基沉降计算

为验证 GA-BP 神经网络模型的性能是否优

于现有的经验公式,将本文所得 E_s 应用于地基沉降计算中。地基最终沉降量 S 计算方法目前主要为分层总和法,包括单项压缩法、规范法、浙大经验公式、黄文熙三维压缩法及考虑先期固结压力沉降计算法等多种方法。常用的以规范法为主(杨光华等,2017)。

$$S = \psi_s \sum_{i=1}^n \frac{p_c}{E_{si}} (z_i \bar{a}_i - z_{i-1} \bar{a}_{i-1}) \quad (15)$$

式中: ψ_s 为沉降计算经验系数; n 为沉降计算深度范围内划分的土层数; p_c 为对应于荷载效应准永久组合时基础底面处的附加压力(kPa); E_{si} 为基础底面下第 i 层土的压缩模量(MPa)。

目前《建筑地基基础设计规范》中未给出 $E_s < 2.5$ MPa 时的经验系数(中华人民共和国住

房和城乡建设部,2011),由于泥炭质土 E_s 较小,这导致规范法计算所得 S 偏大。针对此问题,提出了 E_s 为 2.05~4.15 MPa 时沉降计算经验系数的拟合曲线方程,给出 E_s 为 1.5~2.0 MPa 时经验系数建议值(王晓楠等,2012),如表 7 所示。

表 7 补充沉降计算经验系数

Table 7 Calculation of the empirical coefficient of settlement

E_s/MPa	1.50	2.00	2.50
$P_0 \geq f_{ak}$	1.71	1.56	1.46

根据会展中心场地软土分布和土层厚度情况进行沉降监测,选择 6 个观测点进行验证分析,分别将本文方法与经验公式所得 E_s 应用于公式(15)计算沉降(图 11)。由 GA-BP 神经网络计算的沉降量偏高,但与实际沉降量最为接近,而其余两种经验公式所得沉降与实际沉降偏差较大,因此用本文方法所得结果比经验公式所得结果更可靠。

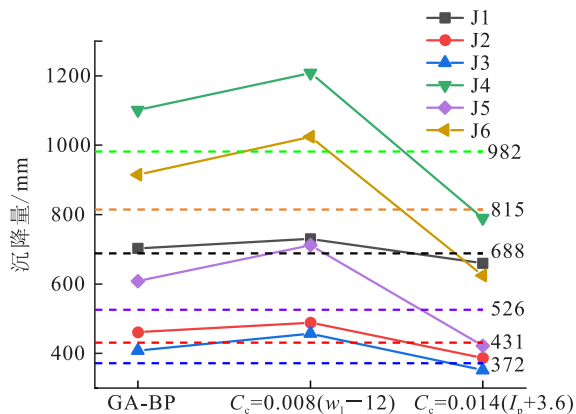


图 11 多方法沉降计算结果

Fig. 11 Calculation of settlement by using multiple methods

5 结论

a. 本文建立的 GA-BP 神经网络模型在训练集和测试集上预测效果较好,相关系数 R 分别为 0.93 与 0.85,且正确率 ACC 达到 82.1%, $RMSE$ 为 0.33。与其余方法相比,各评价指标有很大程度提升。且本文方法可较好适用于多种土体,具有较高的工程应用价值。

b. 通过研究各指标相对重要性,发现埋深 d 是敏感性最高的指标,占比为 0.142,而其次指标为 w_1 与 w_p ,占比分别为 0.139 与 0.126,研究结果可为湖相软土地多参数预测时物理力学指标

选取提供参考。

c. 将本文方法与经验公式所得 E_s 对比可得,GA-BP 神经网络算法得到的 E_s 明显优于经验公式所得 E_s ,且由 w_1 计算所得的经验公式适用于上层泥炭质土,由于深层泥炭质土物理指标较好,因此用 I_p 计算所得的经验公式适用于深层泥炭质土。

d. 将 GA-BP 神经网络模型及经验公式所得 E_s 代入补充后的规范法中,由 GA-BP 神经网络计算的沉降量与实际沉降量最为接近,说明本文模型所得结果合理可靠。

[参 考 文 献]

- 陈伟航,罗强,王腾飞,等,2022. 基于 Bi-LSTM 的非等时距路基工后沉降滚动预测[J]. 浙江大学学报(工学版),56(4):683-691.
- Chen W H, Luo Q, Wang T F, et al., 2022. Bi-LSTM based rolling forecast of subgrade post-construction settlement with unevenly spaced time series[J]. Journal of Zhejiang University (Engineering Science), 56(4):683-691. (in Chinese)
- 高广运,洪洋,耿建龙,等,2022. 饱和砂土液化判别与放大效应数值模拟研究[J]. 工程地质学报,30(6):1874-1881.
- Gao G Y, Hong Y, Geng J L, et al., 2022. Numerical simulation of saturated sand liquefaction discrimination and amplification effect [J]. Journal of Engineering Geology, 30(6):1874-1881. (in Chinese)
- 蒋建平,阎长虹,高广运,2011. 地基土压缩系数的 RBF 神经网络预测[J]. 江苏大学学报(自然科学版),32(2):232-235.
- Jiang J P, Yan C H, Gao G Y, 2011. Prediction on compressibility coefficient of soil based on RBF neural network[J]. Journal of Jiangsu University (Natural Science Edition), 32(2):232-235. (in Chinese)
- 姜礼涛,周爱红,袁颖,等,2022. 基于 NRS-ISSA-SVM 的砂土液化判别模型[J]. 地震工程学报,44(3):570-578.
- Jiang L T, Zhou A H, Yuan Y, et al., 2022. A discriminant model for sand liquefaction based on NRS-ISSA-SVM[J]. China Earthquake Engineering Journal, 44(3):570-578. (in Chinese)
- 刘宏,李攀峰,张倬元,2005. 用人工神经网络模型预测高填方地基工后沉降[J]. 成都理工大学学报(自然科学版),32(3):284-287.
- Liu H, Li P F, Zhang Z Y, 2005. Prediction of the post-

- load settlement of high embankment by artificial neural network[J]. *Journal of Chengdu University of Technology (Science & Technology Edition)*, 32(3): 284–287. (in Chinese)
- 刘鑫菊, 郑刚, 周海祚, 等, 2022. 临近基坑开挖引起的隧道变形预测分析[J]. *重庆大学学报*, 45(7): 37–44.
- Liu X J, Zheng G, Zhou H Z, *et al.*, 2022. Prediction of the tunnel displacement included by adjacent excavations [J]. *Journal of Chongqing University*, 45(7): 37–44. (in Chinese)
- 刘洋, 2018. 基于相控神经网络的地震多属性储层厚度预测[J]. *成都理工大学学报(自然科学版)*, 45(2): 221–228.
- Liu Y, 2018. Study on the reservoir thickness prediction by seismic multi-attributes based on facies-guided neural network[J]. *Journal of Chengdu University of Technology (Science & Technology Edition)*, 45(2): 221–228. (in Chinese)
- 陆文玲, 夏家辉, 孔繁锦, 2022. 自适应反归一化改进多层神经网络轴流转浆水轮机协联功率预测[J]. *广西大学学报(自然科学版)*, 47(6): 1532–1542.
- Lu W L, Xia J H, Kong F N, 2022. Kaplan turbine coordination power prediction based on improved multilayer neural network with adaptive anti-normalization[J]. *Journal of Guangxi University (Natural Science Edition)*, 47(6): 1532–1542. (in Chinese)
- 吕岩, 佴磊, 徐燕, 等, 2011. 有机质对草炭土物理力学性质影响的机理分析[J]. *岩土工程学报*, 33(4): 655–660.
- Lü Y, Nai L, Xu Y, *et al.*, 2011. The mechanism of organic matter effect on physical and mechanical properties of turfy soil[J]. *Chinese Journal of Geotechnical Engineering*, 33(4): 655–660. (in Chinese)
- 欧阳磊, 邓希萍, 何利军, 等, 2022. 基于遗传算法优化 BP 神经网络的压缩系数预测研究[J]. *土工基础*, 36(6): 907–910.
- Ouyang L, Deng X P, He L J, *et al.*, 2022. Prediction of soil compression coefficient by genetic algorithm optimized BP neural network[J]. *Soil Engineering and Foundation*, 36(6): 907–910. (in Chinese)
- 阮永芬, 刘岳东, 王东, 等, 2003. 昆明泥炭与泥炭质土对建筑地基的影响[J]. *昆明理工大学学报(理工版)*, 28(3): 121–124.
- Ruan Y F, Liu Y D, Wang D, *et al.*, 2003. Effect of Kunming's peat & peaty soil on the building foundation [J]. *Journal of Kunming University of Science and Technology (Natural Science)*, 28(3): 121–124. (in Chinese)
- 阮永芬, 余东晓, 吴龙, 等, 2021. DE-GWO 算法优化 SVM 反演软土力学参数[J]. *岩土工程学报*, 43(增刊 1): 166–170.
- Ruan Y F, Yu D X, Wu L, *et al.*, 2021. DE-GWO algorithm to optimize SVM inversion mechanical parameters of soft soil[J]. *Chinese Journal of Geotechnical Engineering*, 43(S1): 166–170. (in Chinese)
- 王晓楠, 郭一鹏, 刘江涛, 等, 2012. 高原湖相沉积软土地基沉降计算经验系数的推算[J]. *工程地质学报*, 20(6): 1036–1041.
- Wang X N, Guo Y P, Liu J T, *et al.*, 2012. Prediction of empirical settlement coefficient for soft clay ground of plateau lacustrine-deposits [J]. *Journal of Engineering Geology*, 20(6): 1036–1041. (in Chinese)
- 熊宸辰, 曹俊兴, 周鹏, 等, 2021. 基于双向长短期记忆神经网络的岩相预测方法[J]. *成都理工大学学报(自然科学版)*, 48(2): 226–234.
- Xiong X C, Cao J X, Zhou P, *et al.*, 2021. Lithofacies prediction method based on bidirectional long short memory neural network[J]. *Journal of Chengdu University of Technology (Science & Technology Edition)*, 48(2): 226–234. (in Chinese)
- 杨光华, 李俊, 贾恺, 等, 2017. 改进的地基沉降计算的工程方法[J]. *岩石力学与工程学报*, 36(增刊 2): 4229–4234.
- Yang G H, Li J, Jia K, *et al.*, 2017. Improved settlement calculation method for engineering practice[J]. *Chinese Journal of Rock Mechanics and Engineering*, 36(S2): 4229–4234. (in Chinese)
- 张鹤, 2019. 基于软土常规物理参数的压缩模量预测研究[J]. *铁道建筑技术*, (1): 1–5.
- Zhang H, 2019. Prediction study on compression modulus of soft soil based on conventional physical parameters [J]. *Railway Construction Technology*, (1): 1–5. (in Chinese)
- 张蕾, 闫吉祥, 曹净, 等, 2022. 基于变异性分析的滇池泥炭土的小范围空间分布规律及物理力学性质[J]. *自然灾害学报*, 31(2): 176–185.
- Zhang L, Yan J X, Cao J, *et al.*, 2022. Spatial distribution and physico-mechanical properties of peat soil in Dianchi Lake based on variability analysis[J]. *Journal of Natural Disasters*, 31(2): 176–185. (in Chinese)
- 张亮亮, 程桦, 姚直书, 等, 2023. 基于改进 Knothe 时间模型的地表最大沉降速度预测[J]. *岩土力学*, 44(4): 1111–1119.

- 117—135.
- Sheng J J, Sun Y Q, Huang H, *et al.*, 2022. HBRNet: Boundary enhancement segmentation network for cropland extraction in high-resolution remote sensing images[J]. *Agriculture Basel*, 12(8):1284.
- Su T F, Zhang S W, Tian Y N, 2020. Extracting croplands in western Inner Mongolia by using random forest and temporal feature selection[J]. *Journal of Spatial Science*, 65(3):519—537.
- Swinnen J, Burkitbayeva S, Schierhorn F, *et al.*, 2017. Production potential in the “bread baskets” of Eastern Europe and Central Asia[J]. *Global Food Security*, 14:38—53.
- Tang J, Zhang X Y, Chen Z C, *et al.*, 2022. Crop identification and analysis in typical cultivated areas of Inner Mongolia with single-phase Sentinel-2 images [J]. *Sustainability*, 14(19):12789.
- Tulczyjew L, Kawulok M, Longepe N, *et al.*, 2022. Graph neural networks extract high-resolution cultivated land maps from Sentinel-2 image series[J]. *IEEE Geoscience and Remote Sensing Letters*, 19.
- Wang Z Y, Zhou J H, Liao Z H, *et al.*, 2020. Semantic segmentation of track image based on deep neural network[J]. *The Journal of China Universities of Posts and Telecommunications*, 27(5):23—33.
- Wietzke A, Leuschner C, 2020. Surveying the arable plant diversity of conventionally managed farmland: A comparison of methods [J]. *Environmental Monitoring and Assessment*, 192(2):1—15.
- Woo S, Park J, Lee J Y, *et al.*, 2018. Cbam: Convolutional block attention module[C]//Proceedings of the European conference on computer vision (ECCV). Munich: Springer Nature Switzerland, 3—19.
- Zhou J C, Hao M L, Zhang D H, *et al.*, 2019. Fusion PSP-net image segmentation based method for multi-focus image fusion [J]. *IEEE Photonics Journal*, 11(6):1—12.
- Zhou Z W, Siddiquee M, Tajbakhsh N, *et al.*, 2020. UNet plus plus: Redesigning skip connections to exploit multiscale features in image segmentation[J]. *IEEE Transactions on Medical Imaging*, 39(6):1856—1867.

(责任编辑:甘娟娟)



(上接第 268 页)

- Zhang L L, Cheng H, Yao Z S, *et al.*, 2023. Prediction of maximum surface subsidence velocity based on improved Knothe time model[J]. *Rock and Soil Mechanics*, 44(4):1111—1119. (in Chinese)
- 中华人民共和国住房和城乡建设部, 2011. 建筑地基基础设计规范: GB 50007—2011[S]. 北京: 中国建筑工业出版社.
- Ministry of Housing and Urban-Rural Development of the People's Republic of China, 2011. Code for design of building foundation: GB 50007—2011 [S]. Beijing: China Construction Industry Press.
- Azzouz A S, Krizek R J, Corotis R B, 1976. Regression analysis of soil compressibility[J]. *Soils and Foundations*, 16(2):19—29.
- Giasi I C, Cherubini C, Paccapelo F, 2003. Evaluation of compression index of remoulded clays by means of Atterberg limits[J]. *Bulletin of Engineering Geology and the Environment*, 62(4):333—340.
- Sridharan A, Nagaraj H B, 2000. Compressibility behaviour of remoulded, fine-grained soils and correlation with index properties [J]. *Canadian Geotechnical Journal*, 37(3):712—722.
- Zhang D M, Zhang J Z, Huang H W, *et al.*, 2020. Machine learning-based prediction of soil compression modulus with application of 1D settlement[J]. *Journal of Zhejiang University-Science A (Applied Physics & Engineering)*, 21(6):430—444.

(责任编辑:甘娟娟)