

基于不同 PSO-ELM 模型的碾压黏土抗剪强度预测方法研究

金坎辉¹, 杨涛¹, 霍树义¹, 王雷¹, 王诚杰¹, 姜岳¹, 张欢灵²

(1.河北水利电力学院/河北省岩土工程安全与变形控制重点实验室,

河北 沧州 061000; 2.中国铁路北京局集团有限公司天津工务段, 天津 300011)

摘 要:碾压黏土的抗剪强度直接影响碾压土石坝的质量和使用寿命。为得出碾压黏土抗剪强度的最优预测模型,通过粒子群算法优化极限学习机模型(PSO-ELM),分别以 Sine 函数、radbas 函数和 hardlim 函数 3 种激活函数为基础,构建 PSO-ELM_{sin}, PSO-ELM_{rad} 和 PSO-ELM_{hard} 3 种模型,并将模型结果与 ELM 模型、广义回归神经网络模型(GRNN)、随机森林模型(RF)和 BP 神经网络模型进行了对比。结果表明:在黏聚力和内摩擦角的拟合结果中,PSO-ELM_{sin} 模型精度最高,其拟合方程斜率分别为 1.005,1.032;在月值模拟中,PSO-ELM_{sin} 模型与实测值的拟合度最高,相对误差仅在 6.0%~9.3%;PSO-ELM_{sin} 模型在黏聚力模拟中 RMSE,RRMSE,MAE, E_{ns} 和 R^2 分别为 0.776 kPa,1.80%,0.641 kPa,0.993 和 0.997,该模型在内摩擦角模拟中 RMSE,RRMSE,MAE, E_{ns} 和 R^2 分别为 1.635°,6.98%,1.616°,0.983 和 0.998,模型精度均排名第一。因此,PSO-ELM_{sin} 模型在所有模型中精度最高,可作为碾压黏土抗剪强度预测的标准模型使用。

关键词:碾压黏土;抗剪强度;粒子群算法;极限学习机;激活函数

中图分类号:TU411.7

文献标识码:A

文章编号:1005-3409(2022)03-0213-07

Research on Prediction Methods of Shear Strength of Rolled Clay Based on Different PSO-ELM Models

JIN Kanhui¹, YANG Tao¹, HUO Shuyi¹, WANG Lei¹,
WANG Chengjie¹, JIANG Yue¹, ZHANG Huanling²

(1.Hebei University of Water Resource and Electric Engineering & Hebei Key Laboratory of
Geotechnical Engineering Safety and Deformation Control, Cangzhou, HeBei 061000, China;

2.Tianjin Rail way Section of China Rail way Beijing Bureau Group CO., LTD, Tianjin 300011, China)

Abstract: The shear strength of rolled clay directly affects the quality and service life of roller compacted earth-rock dams. In order to obtain the optimal prediction model for the shear strength of rolled clay, we used particle swarm optimization to optimize the extreme learning machine model (PSO-ELM), which is based on the three activation functions of Sine function, radbas function and hardlim function to construct PSO-ELM_{sin}, PSO-ELM_{rad} and PSO-ELM_{hard}. We compared the accuracy with ELM model, generalized regression neural network model (GRNN), random forest model (RF) and BP neural network model. The results show that: in the fitting results of cohesion and internal friction angle, the PSO-ELM_{sin} model has the highest accuracy, and the slopes of the fitting equations are 1.005 and 1.032, respectively, which are closer to the standard value '1'; in the monthly simulation, the PSO-ELM_{sin} model has the relative error of between 6.0% and 9.3%; RMSE, RRMSE and MAE of the PSO-ELM_{sin} model in the cohesion simulation of the PSO-ELM_{sin} model, the RMSE, RRMSE, MAE, E_{ns} and R^2 are 0.776 kPa, 1.80%, 0.641 kPa, 0.993 and 0.997, respectively. In the internal friction angle simulation, the RMSE, RRMSE, MAE, E_{ns} and R^2 are 1.635°, 6.98%, 1.616°, 0.983 and 0.998, respectively. The accuracy of PSO-ELM_{sin} model ranks first.

收稿日期:2021-01-06

修回日期:2021-02-21

资助项目:河北省高等学校科学技术研究项目(Z2019031);道路与铁道工程安全保障省部共建教育部重点实验室(石家庄铁道大学)开放课题(STKF201902);河北省属高等学校基本科研业务费科技重点科研培育项目(SYKY2101)

第一作者:金坎辉(1986—),男,河北沧州人,硕士,讲师,研究方向:土木工程施工及工程结构。E-mail:kingkh0001@163.com

通信作者:杨涛(1986—),男,河北沧洲人,硕士,工程师,研究方向:建筑工程技术。E-mail:cangzhouyt@163.com

respectively. Therefore, the PSO-ELM_{sin} model has the highest accuracy among all models and can be used as a precise model for predicting the shear strength of rolled clay.

Keywords: rolled clay; shear strength; particle swarm optimization; extreme learning machine; activation function

由于具有取材方便、施工简单等优点,土石坝已成为目前国内应用最广泛的坝型之一^[1-3]。其中,土体黏聚力和内摩擦角等抗剪强度将直接影响坝体质量及使用寿命。由《碾压式土石坝施工规范》可知,碾压土石坝的质量与碾压黏土的碾压次数、碾压质量等参数有关^[4]。当碾压土石坝施工完成后,需对坝体碾压黏土的强度指标进行长时间观测,以保证坝体正常运行^[5]。现如今,黏土黏聚力和内摩擦角的测定方法多采用直剪或三轴试验进行,这种方法虽精度较高,但操作复杂、成本较高,在一定程度上无法广泛应用^[6-7]。因此,找寻合理的方法估算黏土抗剪强度,对碾压土石坝质量提升十分关键。

传统的估算方法,是通过黏土含水率、干密度等基本物理指标的测定,从而构建土体黏聚力和内摩擦角估算模型,但此类模型多为单一因素模型,无法全面反映各影响因素与黏土抗剪强度之间的关系^[8]。机器学习模型无需找出各影响因素之间的具体函数关系,同时可充分考虑每个因素的影响,已逐渐广泛应用于抗剪强度预测研究中。王志会等^[9]基于 PSO-BPNN 模型构建了充填体围岩界面抗剪强度预测模型,指出该模型可较好预测围岩抗剪强度;谢文强等^[10]基于 BP 神经网络模型构建了黏土不排水抗剪强度预测模型,指出神经网络模型预测结果明显优于传统经验模型,其中 Broyden-Fletcher-Goldfarb-Shanno 算法下的 BP 神经网络模型精度最高;许健等^[11]基于 BP 神经网络模型分析了黄土抗剪强度的变化趋势,指出该方法具有较好的预测精度,能够综

合描述诸因素与黏聚力的量化关系。
截止到目前,碾压黏土作为碾压土石坝的主要组成部分,关于抗剪强度预测模型的研究较少,而传统的 BP 神经网络模型需要较多的学习样本,模型初始权值和阈值的选择随机性强,使模型精度较低,限制了模型应用^[12-13]。本文以实测碾压黏土黏聚力和内摩擦角 2 项抗剪强度指标为基础,基于粒子群优化的极限学习机模型 (PSO-ELM) 构建碾压黏土抗剪强度预测模型,以期对碾压土石坝设计、施工和管理提供科学依据。

1 研究方法

1.1 碾压黏土抗剪强度测定

本次研究以实际碾压土石坝工程为例,选择九龙水库为研究对象,该水库位于四川南充市,选择土石坝坝体心墙部位进行取土测量,在施工过程中严格控制碾压参数,黏土心墙碾压参数可见表 1。工程施工完毕后,按《碾压式土石坝施工规范》要求测定土体含水率、干密度、内摩擦角和黏聚力等指标,测定频率每月测定 3 组,测定时间为 5 a,共 180 组实测数据。

为更好的表征碾压黏土的抗剪强度,本文引入土体冻融循环次数,设置不同土体的冻融循环次数,对土体抗剪强度进行测定,将土体在 -20℃ 下冻结 12 h 后,在 20℃ 下融化 12 h 记为 1 次冻融循环,其中天然土体冻融循环次数为 0 次,设置 5 次和 10 次共 2 个梯度,其中第 37—108 组数据为进行冻融循环的土体,其余土体均为天然土体。

表 1 施工基本参数确定

取土部位	组成材料	碾压机具	碾压次数	土料厚度/cm	行车速度/(km·h ⁻¹)
心墙	黏土	LT320B 压路机,凸块碾	不少于 8 次	40±5	2.0

1.2 粒子群算法优化极限学习机模型

Huang 等^[14]于 2006 年提出了极限学习机模型 (ELM),该模型由输入层、输出层和隐含层 3 部分组成,设隐含层神经元的激活函数为 $g(\omega, X, b)$,则 ELM 模型输出层表达式为:

$$F(X_i)=\sum_{j=1}^m\beta_jg(\omega_{ij}X_i+b_j)\tag{1}$$

式中: β_j 为隐含层到输出层的连接值; ω_{ij} 为输入层到隐含层的连接值; X_i 为输入层变量值; b_j 为第 j 个隐含层的阈值。

ELM 模型激活函数可分为 3 种: Sine 函数 (ELM_{sin})、Radbas 函数 (ELM_{rad}) 和 Hardlim 函数 (ELM_{hard}),3 种函数具体公式如下:

Sine 函数:

$$g(\omega_{ij},X_i,b_j)=g(\omega_{ij}X_i+b_j)=\sin(\omega_{ij}X_i+b_j)$$

Radbas 函数:

$$g(\omega_{ij},X_i,b_j)=\exp(-\frac{\|X-\omega_{ij}\|^2}{b_j^2})$$

Hardlim 函数:

$$g(\omega_{ij}, X_i, b_j) = \begin{cases} 1 & \omega_{ij}X + b_j \geq 0 \\ 2 & \omega_{ij}X + b_j < 0 \end{cases}$$

初始 ELM 模型的缺点是它的权值和隐藏偏差是随机确定的,从而易产生非最优解^[15]。粒子群优化算法是一种广泛应用于机器学习模型参数调整的优化方法,在建模中已被证明有良好的应用前景,因此,采用粒子群算法可进一步提高 ELM 模型精度。

假设在一个有 D 维的空间里,给定一个有 n 个粒子的总体 $X = (X_1, X_2, \dots, X_n)$,粒子 i 的位置和速度分别为 $X_i = (X_{i1}, X_{i2}, \dots, X_{iD})$ 和 $V = (V_{i1}, V_{i2}, \dots, V_{iD})$,最优粒子 i 和对应的整个种群的位置分别为 $P_i = (P_{i1}, P_{i2}, \dots, P_{iD})^T$ 和 $P_g = (P_{g1}, P_{g2}, \dots, P_{gD})^T$,在粒子群优化的迭代过程中,粒子 i 的位置和速度的更新为:

$$X_{id} = X_{id} + X_{id} \quad (d=1, 2, \dots, D, i=1, 2, \dots, n) \quad (2)$$

$$V_{id}^{k+1} = \omega V_{id}^k + c_1 r_{1,i}^k (P_{id}^k - X_{id}^k) + c_2 r_{2,i}^k (P_{gd}^k - X_{id}^k) \quad (3)$$

式中: ω 为惯性权重; k 为当前迭代次数; c_1 和 c_2 为算法加速系数; $r_{1,i}^k$ 和 $r_{2,i}^k$ 为模型经验参数,取值在 $0 \sim 1$ 。

由于 ELM 模型共有 3 种激活函数,PSO-ELM 模型同样具有 3 种激活函数,最终分别构建了 PSO-ELM_{sin}, SO-ELM_{rad} 和 PSO-ELM_{hard} 共 3 种模型。

1.3 模型训练与验证

本文以前 3 a 的实测数据作为训练数据集,以最后 2 a 的数据作为验证数据集,以含水率、干密度和冻融循环次数 3 种参数为模型输入组合,对 3 种激活函数下的 PSO-ELM 模型精度进行验证。为进一步比较 PSO-ELM 模型的精度,本文引入广义回归神经网络模型 (GRNN)^[16]、随机森林模型 (RF)^[17] 和 BP 神经网络模型 (BP)^[18],最终比较 9 种模型精度,得出碾压黏土抗剪强度指标最优预测模型。

1.4 模型精度评价指标

以均方根误差 (RMSE), 相对均方根误差 (RRMSE), 确定系数 (R^2), 平均绝对误差 (MAE) 和模型效率系数 (E_{ns}) 5 种指标形成评价指标体系,用于评判不同模型的精度,具体公式如下:

$$RMSE = \sqrt{\frac{1}{m} \sum_{i=1}^m (Y_i - X_i)^2} \times 100\% \quad (4)$$

$$RRMSE = \frac{\sqrt{\frac{1}{m} \sum_{i=1}^m (Y_i - X_i)^2}}{\sqrt{\frac{1}{m} \sum_{i=1}^m (Y_i - \bar{Y})^2}} \times 100\% \quad (5)$$

$$R^2 = \frac{[\sum_{i=1}^m (X_i - \bar{X})(Y_i - \bar{Y})]^2}{\sum_{i=1}^m (X_i - \bar{X})^2 \sum_{i=1}^m (Y_i - \bar{Y})^2} \quad (6)$$

$$MAE = \frac{1}{m} \sum_{i=1}^m |X_i - Y_i| \quad (7)$$

$$E_{ns} = 1 - \frac{\sum_{i=1}^m (Y_i - X_i)^2}{\sum_{i=1}^m (X_i - \bar{X})^2} \quad (8)$$

式中: X_i 和 Y_i 分别为模型模拟值及实测值; \bar{X} 为 X_i 的平均值。

由于评估指标过多,单个评估指标很难比较不同的模型。因此,引入 GPI 指数来全面评估模型仿真结果,公式如下:

$$GPI_i = \sum_{j=1}^5 \alpha_j (g_j - y_{ij}) \quad (9)$$

式中: α_j 为常数,MAE 和 RRMSE 取 1,NS 取 -1 ; g_j 为不同指标的缩放值的中位数; y_{ij} 为不同指标的尺度值。

2 结果与分析

2.1 不同模型模拟值与实测值拟合结果与分析

图 1 为不同模型碾压黏土黏聚力拟合结果。由图中可以看出,不同模型模拟值与实测值的拟合效果存在差异。其中,3 种 PSO-ELM 模型的精度普遍高于其余模型,PSO-ELM_{sin} 模型的精度最高,其拟合方程斜率仅为 1.005,决定系数 R^2 达到了 0.998,且与实测值的相关性达到了极显著水平 ($p < 0.01$),PSO-ELM_{rad} 和 PSO-ELM_{hard} 模型的精度次之,拟合方程斜率分别为 1.016, 1.018, 决定系数 R^2 分别达到了 0.977, 0.971; ELM 模型的精度次之,3 种模型中同样表现为 ELM_{sin} 模型精度最高,其拟合方程斜率仅为 1.056,决定系数 R^2 达到了 0.965; GRNN 模型、RF 模型和 BP 神经网络模型的精度较差,其中 BP 神经网络模型的精度最低,其与实测值的拟合方程斜率为 0.770, R^2 仅为 0.656,与实测值的相关性仅达到了显著水平 ($p < 0.05$)。

图 2 为不同模型碾压黏土内摩擦角拟合结果。由图中可以看出,3 种 PSO-ELM 模型的精度较高,其中 PSO-ELM_{sin} 模型的精度最高,而在 3 种 ELM 模型中,ELM_{sin} 模型精度高于 PSO-ELM_{hard} 模型,3 种激活函数表现出的精度关系为 Sine 函数 > Radbas 函数 > Hardlim 函数,GRNN 模型、RF 模型和 BP 神经网络模型的精度较差,拟合方程斜率分别为 1.273, 0.759, 1.291, R^2 分别为 0.725, 0.594, 0.508, 其中 GRNN 模型模拟值与实测值的相关性达到了极显著水平 ($p < 0.01$),而 RF 模型和 BP 神经网络模型的相关性未达显著水平 ($p > 0.05$)。

综上所述,在碾压黏土抗剪强度预测模型中,PSO-ELM 模型均表现出较高的精度,同时 PSO-ELM_{sin} 模型为精度最高模型。

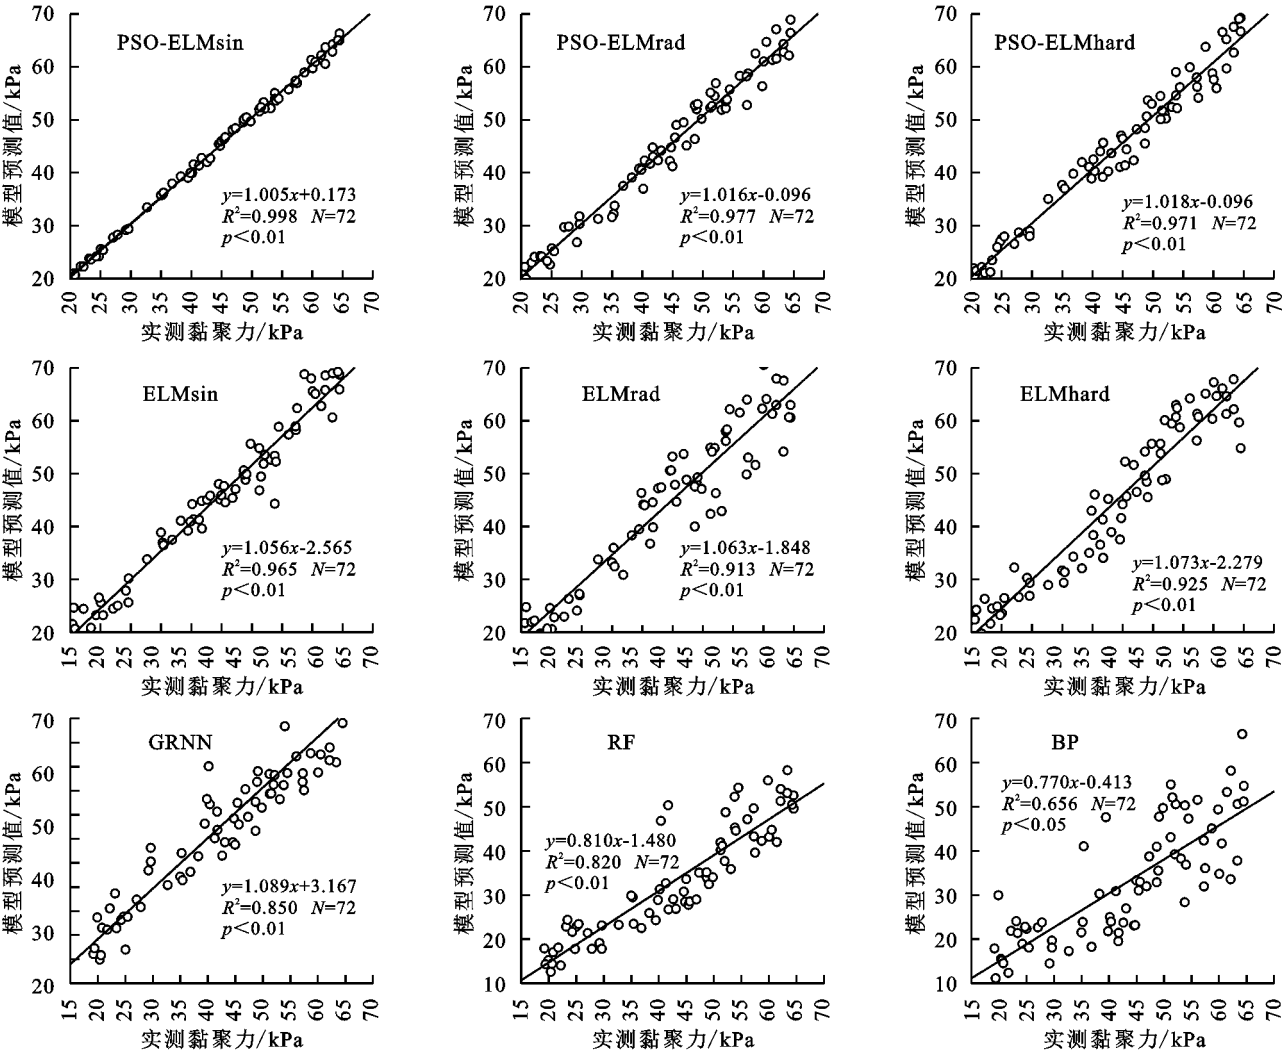


图 1 不同模型黏聚力拟合结果

2.2 不同模型模拟值年内变化趋势分析

图 3 为不同模型模拟的黏聚力和内摩擦角年内变化趋势图。由图中可以看出,不同模型模拟值与实测值的变化趋势基本一致,碾压黏土抗剪强度在年内呈现先升高后降低的趋势,这可能与碾压黏土在年内的含水率和干密度变化有关。在不同模型中,PSO-ELM 模型对黏聚力和内摩擦角月值的拟合结果较高,其中 PSO-ELM_{sin}模型的精度最高,与实测值的相对误差在 6.0%~9.3%,3 种 ELM 模型精度次之,相对误差在 10.9%~20.9%。BP 神经网络模型精度最低,其模拟值与实测值的相对误差均在 20%以上。综上所述,PSO-ELM_{sin}模型为抗剪强度月值预测精度最高模型。

2.3 不同模型模拟值精度对比

表 2 列出了不同模型黏聚力模拟值精度对比。由表中可以看出,PSO-ELM_{sin}模型精度最高,其 R^2 和 E_{ns} 分别达到了 0.997,0.998,GPI 排名第一,达到了 1.409。3 种 PSO-ELM 模型精度较高,GPI 排名前 3 位。3 种 ELM 模型精度次之,精度表现为

ELM_{sin}模型>ELM_{rad}模型>ELM_{hard}模型,3 种模型 GPI 分别为 0.568,-0.050 和 -0.002,排名 4—6 位。GRNN 模型和 RF 模型精度较低,RMSE,RRMSE 和 MAE 分别为 8.158,11.315 kPa,18.93%和 26.26%,5.749,10.090 kPa, R^2 和 E_{ns} 分别达到了 0.756,0.739 和 0.850,0.820,GPI 排名 7—8 位。BP 模型精度最低,RMSE,RRMSE 和 MAE 分别为 13.313 kPa,30.90%和 11.203 kPa, R^2 和 E_{ns} 分别为 0.656,0.685,模型误差较高且一致性较低,GPI 排名最低。

表 3 列出了不同模型内摩擦角模拟值精度对比。由表中可以看出,PSO-ELM_{sin}模型精度最高,其 RMSE,RRMSE 和 MAE 分别为 1.635°,6.98%和 1.616°, R^2 和 E_{ns} 分别达到了 0.993,0.983,GPI 排名第一。3 种 ELM 模型中同样表现为 ELM_{sin}模型精度最高,GPI 为 0.255,排名第 4,GRNN 模型和 RF 模型精度较低,RMSE,RRMSE 和 MAE 分别为 3.223,3.476°,13.77%和 15.85%,3.176,3.356°, R^2 和 E_{ns} 分别达到了 0.961,0.840,0.768,0.729,GPI 排名 7—8 位,BP 模型精度最低。

2.4 碾压黏土抗剪强度影响因素分析

为得出影响碾压黏土抗剪强度的关键因素,本文以 PSO-ELM_{sin} 模型为基础分析了不同参数输入组合下的模型精度,结果见表 4—5。

由表中可以看出,不同输入组合下的模型精度不同,其中输入参数个数为 2 的组合精度高于参数个数为 1 的组合,其中干密度和含水率组合下的模型

精度最高,干密度与冻融循环次数的组合次之,当输入参数组合个数为 1 时,3 种组合方式表现出的精度为干密度最高、含水率次之、冻融循环次数最低,这表明碾压黏土抗剪强度影响因素影响程度由高到低依次为干密度、含水率和冻融循环次数,综上所述,为保证模型预测精度,干密度为模型输入必不可少的输入因素。

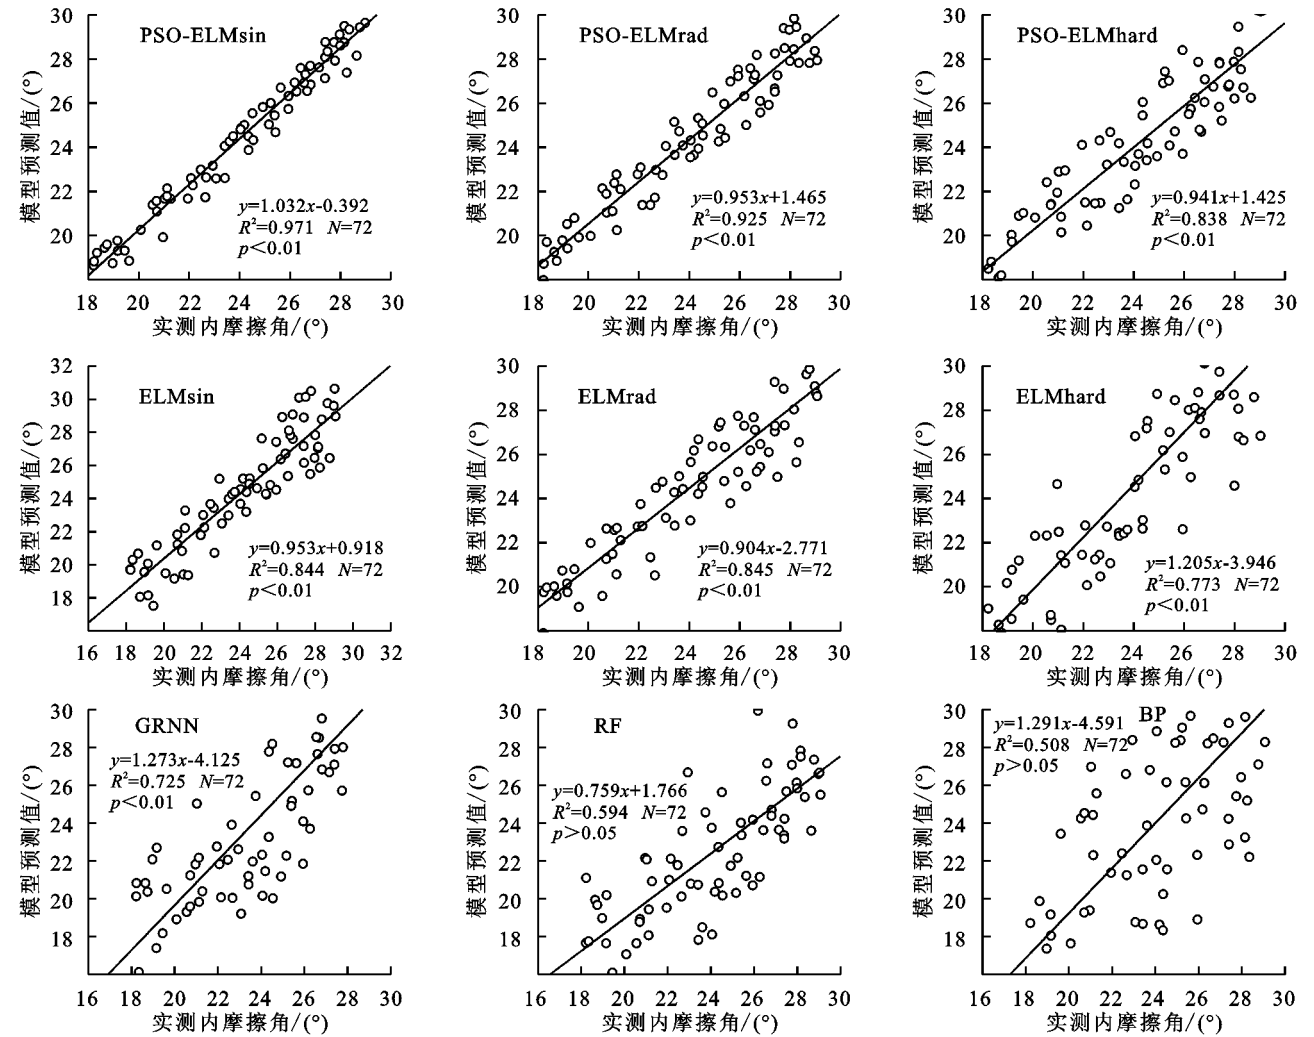


图 2 不同模型内摩擦角拟合结果




图 3 不同模型黏聚力和内摩擦角年内变化趋势

2.5 模型可移植性分析

为进一步验证 PSO-ELM_{sin} 模型精度,本文验证了

模型的可移植性,在同一水库的副坝进行取样研究,同样测定副坝的干密度、含水率及冻融循环次数指标,将

副坝不同指标作为模型输入组合,验证主坝抗剪强度指标,结果见表 6—7。由表中可以看出,输入副坝参数不同组合下的模型精度略低于主坝本身参数输入,当输入副坝干密度、含水率及冻融循环次数时,模型精度仍较

高, E_{ns} 和 R^2 仍在 0.95 以上,这表明,PSO-ELM_{sin} 模型具有较好的可移植性,在应用模型时,若坝体本身缺少相关资料,可采用其他环境、材料相近的坝体资料作为模型输入参数,仍可保证模型较高的精度。

表 2 不同模型黏聚力模拟精度对比

模型	黏聚力						排名
	RMSE/kPa	RRMSE/%	E_{ns}	R^2	MAE/kPa	GPI	
PSO-ELM _{sin}	0.776	1.80	0.997	0.998	0.641	1.409	1
PSO-ELM _{rad}	2.261	5.25	0.974	0.977	1.862	0.921	2
PSO-ELM _{hard}	2.544	5.90	0.967	0.971	2.111	0.811	3
ELM _{sin}	3.278	7.61	0.945	0.965	2.505	0.568	4
ELM _{rad}	4.512	10.48	0.895	0.913	3.681	−0.050	5
ELM _{hard}	4.463	10.36	0.897	0.925	3.707	−0.002	6
GRNN	8.158	18.93	0.756	0.850	5.749	−1.457	7
RF	11.315	26.26	0.739	0.820	10.090	−2.515	8
BP	13.313	30.90	0.685	0.656	11.203	−3.591	9

表 3 不同模型内摩擦角模拟精度对比

模型	内摩擦角						排名
	RMSE/(°)	RRMSE/%	E_{ns}	R^2	MAE/(°)	GPI	
PSO-ELM _{sin}	1.635	6.98	0.983	0.993	1.616	2.475	1
PSO-ELM _{rad}	1.666	7.12	0.972	0.991	1.646	2.382	2
PSO-ELM _{hard}	2.374	10.14	0.964	0.981	2.342	1.246	3
ELM _{sin}	3.015	12.88	0.963	0.978	2.986	0.255	4
ELM _{rad}	3.145	13.44	0.955	0.970	3.108	0.000	5
ELM _{hard}	3.190	13.63	0.894	0.962	3.142	−0.307	6
GRNN	3.223	13.77	0.768	0.961	3.176	−0.800	7
RF	3.476	14.85	0.729	0.840	3.356	−1.811	8
BP	3.636	15.53	0.694	0.766	3.564	−2.525	9

表 4 PSO-ELM_{sin} 模型不同组合输入下黏聚力模拟精度对比

参数组合	黏聚力				
	RMSE/kPa	RRMSE/%	E_{ns}	R^2	MAE/kPa
干密度、含水率	2.476	7.38	0.965	0.958	3.569
干密度、冻融循环次数	3.794	10.67	0.934	0.942	4.667
含水率、冻融循环次数	5.573	12.86	0.864	0.848	6.024
干密度	10.742	20.74	0.802	0.814	10.963
含水率	11.734	24.71	0.751	0.742	10.091
冻融循环次数	13.741	30.17	0.706	0.694	11.286

表 5 PSO-ELM_{sin} 模型不同组合输入下内摩擦角模拟精度对比

参数组合	内摩擦角				
	RMSE/(°)	RRMSE/%	E_{ns}	R^2	MAE/(°)
干密度、含水率	3.334	12.56	0.952	0.952	4.543
干密度、冻融循环次数	4.199	14.54	0.932	0.936	5.451
含水率、冻融循环次数	5.402	17.10	0.861	0.858	6.255
干密度	10.478	26.01	0.820	0.827	11.443
含水率	13.366	27.67	0.811	0.798	13.517
冻融循环次数	14.468	33.44	0.702	0.731	15.721

表 6 黏聚力可移植性分析

参数组合	黏聚力			
	RMSE/kPa	RRMSE/%	E_{ns}	MAE/kPa
干密度、含水率、冻融循环次数	1.264	4.83	0.987	1.374
干密度、含水率	3.747	8.79	0.955	4.876
干密度、冻融循环次数	4.078	11.73	0.911	5.682
含水率、冻融循环次数	6.743	14.66	0.832	7.142
干密度	11.641	22.54	0.812	11.734
含水率	12.446	25.74	0.762	13.424
冻融循环次数	14.176	29.47	0.712	15.662

表 7 内摩擦角可移植性分析

参数组合	内摩擦角				
	RMSE/(°)	RRMSE/%	E_{ns}	R^2	MAE/(°)
干密度、含水率、冻融循环次数	2.143	7.02	0.968	0.962	2.132
干密度、含水率	4.136	13.55	0.942	0.931	5.521
干密度、冻融循环次数	4.224	14.74	0.921	0.922	5.627
含水率、冻融循环次数	6.752	17.52	0.872	0.859	6.723
干密度	12.423	27.14	0.817	0.809	14.762
含水率	13.687	29.62	0.796	0.775	14.524
冻融循环次数	14.756	35.39	0.715	0.722	15.962

3 讨论

ELM 模型中参数的随机取值在一定程度上影响了模型精度。PSO-ELM 模型可克服传统 ELM 模型随机选取参数、要求样本量庞大的缺陷,基于粒子群算法自动找出 ELM 模型的最优参数,最终得出最优模型,解决了传统 ELM 模型泛化能力较差的问题,在较少隐含层个数前提下得出精度较高的结果^[19]。张念等^[20]在模拟梨枣树液流时、张颖等^[21]对水质进行评价时、王新民等^[22]预测建筑物爆破震动速度时均指出 PSO-ELM 模型均有更高的精度。同时本文研究表明,ELM 模型精度高于 GRNN 模型、RF 模型和 BP 神经网络模型,这进一步证明了 PSO-ELM 模型的科学性。

本文研究表明,干密度和含水率是影响碾压黏土抗剪强度较关键的因素,陈佳雨等^[7]研究干密度和含水率对红黏土抗剪强度影响时指出,干密度和含水率是使红黏土抗剪强度变化的关键因素,与本文结论基本一致。陆业奇^[23]研究含水率对黏土抗剪强度影响时发现,随着含水率的升高,土体黏聚力与内摩擦角均呈现先增加后减小的趋势。由于水库在年内存在丰枯水交替变化的趋势,黏土含水率在全年先增加后降低,这可能也是本文黏聚力和内摩擦角呈现先增加后降低趋势的重要原因。

4 结论

- (1) 在抗剪强度日值的模拟中,PSO-ELM 模型精度普遍最高,3 种 ELM 模型精度次之,BP 神经网络模型精度最差。3 种 PSO-ELM 模型中,PSO-ELM_{sin}模型精度最高,黏聚力和内摩擦角模拟中的拟合方程斜率分别为 1.005,1.032,3 种激活函数精度依次为 Sine 函数>radbas 函数>hardlim 函数;
- (2) 在抗剪强度月值的模拟中,PSO-ELM_{sin}模型精度最高,其与实测中的相对误差在 6.0%~9.3%;
- (3) PSO-ELM_{sin}模型表现出了最低的误差和最高的一致性,在黏聚力拟合中,其 RMSE,RRMSE 和 MAE 分别为 0.776 kPa,1.80%和 0.641 kPa, R^2 和

E_{ns} 分别达到了 0.997,0.998,内摩擦角拟合中,其 RMSE,RRMSE 和 MAE 分别为 1.635°,6.98%和 1.616°, R^2 和 E_{ns} 分别达到了 0.993,0.983,GPI 排名在所有模型中均为第一位;

(4) 通过对不同输入参数组合下的模型精度对比可知,影响碾压黏土抗剪强度最关键的因素为干密度,含水率次之,冻融循环次数的影响程度最低,PSO-ELM_{sin}模型具有最高的精度,且具有较高的可移植性。

本文仅选择了干密度、含水率和冻融循环次数作为模型输入参数,验证了 PSO-ELM 模型的科学性,指出 PSO-ELM_{sin}模型为碾压黏土抗剪强度预测的标准模型。在今后的研究中,可进一步加入黏土含量、孔隙率、渗透系数等参数,进一步验证模型精度,为碾压黏土抗剪强度精确估算提供科学依据。

参考文献:

[1] 胡赛潇,张云发,刘超,等.基于坝坡稳定复核的土石坝整体填筑质量评价[J].人民黄河,2018,40(5):133-138.

[2] 刘东海,王光辉.实时监控下土石坝碾压质量全仓面评估[J].水利学报,2010,41(6):720-726.

[3] Lai J, Wu S, Chiang C H. Evaluating the compaction quality of backfills by stress wave velocities[J]. Journal of Testing and Evaluation, 2011,39(5):785-791.

[4] 国家能源局.碾压式土石坝施工规范:DL/T 5129-2013[S].北京:中国电力出版社,2014:20-25.

[5] 赵惠新,吴志琴,李兆宇,等.基于 BP 神经网络冻融作用下细粒土抗剪强度的研究[J].水电能源科学,2012,30(4):32-33,78.

[6] 蒋佳莉,张卫兵,王红雨.干湿循环作用下银川地区重塑粉质黏土强度劣化试验研究[J].公路交通科技,2020,37(5):33-42.

[7] 陈佳雨,刘之葵.含水率及干密度对桂林红黏土抗剪强度的影响[J].中国岩溶,2019,38(6):930-936.

[8] 尚松浩,毛晓敏.基于 BP 神经网络的土壤冻结温度及未冻水含量预测模型[J].冰川冻土,2001,23(4):414-418.

[9] 王志会,吴爱祥,王洪江.基于 PSO-BPNN 的充填体围岩界面抗剪强度预测[J].矿业研究与开发,2020,40(3):130-134.

(3):359-366.

[10] 熊光洁,张博凯,李崇银,等.基于 SPEI 的中国西南地区 1961—2012 年干旱变化特征分析[J].气候变化研究进展,2013,9(3):192-198.

[11] 贾艳青,张勃.基于日 SPEI 的近 55 a 西南地区极端干旱事件时空演变特征[J].地理科学,2018,38(3):474-483.

[12] 王东,张勃,安美玲,等.基于 SPEI 的西南地区近 53 a 干旱时空特征分析[J].自然资源学报,2014,29(6):1003-1016.

[13] Vicente-Serrano S M, Beguería S, López-Moreno J I. A multiscale drought index sensitive to global warming: The standardized precipitation evapotranspiration index[J]. Journal of Climate, 2010,23(7):1696-1718.

[14] 闻新宇,王绍武,朱锦红,等.英国 CRU 高分辨率格点资料揭示的 20 世纪中国气候变化[J].大气科学,2006,30(5):894-904.

[15] 陈发虎,黄伟,靳立亚,等.全球变暖背景下中亚干旱区降水变化特征及其空间差异[J].中国科学:地球科学,2011,41(11):1647-1657.

[16] 史晓亮,吴梦月,丁皓. SPEI 和植被遥感信息监测西南地区干旱差异分析[J].农业机械学报,2020,51(12):184-192.

[17] 万红莲,王静.多尺度下宝鸡地区干旱动态格局演变及其与植被覆盖的关系[J].生态学报,2018,38(19):6941-6952.

[18] 师玉锋,梁思琦,彭守璋.1901—2017 年黄土高原地区气候干旱的时空变化[J].水土保持通报,2020,40(1):283-289,325.

[19] 刘世梁,田韞钰,尹洁洁,等.云南省植被 NDVI 时间变化特征及其对干旱的响应[J].生态学报,2016,36(15):4699-4707.

[20] 温庆志,孙鹏,张强,等.基于多源遥感数据的农业干旱监测模型构建及应用[J].生态学报,2019,39(20):7757-7770.

[21] 裴琳,严中伟,杨辉.400 多年来中国东部旱涝型变化与太平洋年代际振荡关系[J].科学通报,2015,60(1):97-108.

[22] 段海霞,王素萍,冯建英.2012 年全国干旱状况及其影响与成因[J].干旱气象,2013,31(1):220-229.

[23] 王素萍,段海霞,冯建英.2013 年春季全国干旱状况及其影响与成因[J].干旱气象,2013,31(2):441-449.

[24] 贾艳青,张勃,马彬,等.1960—2015 年中国西南地区持续性干旱事件时空演变特征[J].干旱区资源与环境,2018,32(5):171-176.

[25] 徐海亮.六十年来西南地区气象干旱灾害及气候环境变化[J].玉溪师范学院学报,2020,36(3):92-103.

[26] 崔立鲁,宋哲,邹正波,等.基于 GRACE 的 2009—2010 年西南地区特大干旱分析[J].人民长江,2020,51(7):13-19.

[27] 王秋云,蔡艺友,方文维,等.西南地区 1971—2012 年干旱变化特征分析[J].陕西气象,2020(6):30-35.

[28] 贺晋云,张明军,王鹏,等.近 50 年西南地区极端干旱气候变化特征[J].地理学报,2011,66(9):1179-1190.



(上接第 219 页)

[10] 谢文强,蔡国军,王睿,等.基于 CPTu 数据的黏性土不排水抗剪强度神经网络预测[J].土木工程学报,2019,52(S2):35-41.

[11] 许健,冯灿,王掌权.基于 BP 神经网络的重塑黄土冻融过程抗剪强度劣化特性研究[J].水利与建筑工程学报,2016,14(6):13-17.

[12] Wang Y M, Traore S, Kerh T. Neural network approach for estimating reference evapotranspiration from limited climatic data in Burkina Faso[J]. Wseas Transactions on Computers, 2008,7(6):704-713.

[13] Traorea S, Wang Y M, Kerh T. Artificial neural network for modeling reference evapotranspiration complex process in Sudano-Sahelian zone[J]. Agricultural Water Management, 2010,97(5):707-714.

[14] Huang G B, Zhu Q Y, Siew C K. Extreme learning machine: theory and applications[J]. Neurocomputing, 2006,70:489-501.

[15] Zhu B, Feng Y, Gong D Z, et al. Hybrid particle swarm optimization with extreme learning machine for daily reference evapotranspiration prediction from limited climatic data[J]. Computers and Electronics in Agriculture, 2020,173:1-13.

[16] 冉桂义,肖璐,崔宁博,等.基于广义回归神经网络模型模拟夏玉米蒸发蒸腾量[J].中国农村水利水电,2020(2):93-99.

[17] 张智韬,劳聪聪,王海峰,等.基于 FOD 和 SVM-DA-RF 的土壤有机质含量高光谱预测[J].农业机械学报,2020,51(1):156-167.

[18] 展超.基于 BP 神经网络的富水砂层渣土改良试验效果预测[J].隧道建设(中英文),2020,40(7):988-996.

[19] 王杰,毕浩洋.一种基于粒子群优化的极限学习机[J].郑州大学学报:理学版,2013,45(1):100-104.

[20] 张念,崔宁博,赵璐,等.基于 PSO-ELM 的温室梨枣树液流量模拟[J].灌溉排水学报,2019,38(8):1-8.

[21] 张颖,李梅.基于粒子群优化极限学习机的水质评价新模型[J].环境科学与技术,2016,39(5):135-139.

[22] 王新民,万孝衡,朱阳亚,等.基于 PSO-ELM 的建筑物爆破震动速度预测[J].科技导报,2014,32(19):15-20.

[23] 陆业奇.含水率对黏土与混凝土接触面抗剪强度影响研究[J].水力发电,2018,44(12):126-129.