

考虑施工参数影响的心墙砾石土渗透系数预测方法

李 晴,佟大威,余 佳,王佳俊,王 星

(天津大学水利工程仿真与安全国家重点实验室,天津 300350)

摘要:针对当前心墙砾石土渗透系数预测研究仅考虑料源参数,而少数考虑了施工质量的单一预测模型存在预测误差大、数据特征获取不全面的问题,构建了综合考虑施工质量和料源参数的 BPNN-WOA-SVM 渗透系数组合预测模型。该模型通过引入鲸鱼优化算法(WOA)解决支持向量机(SVM)参数选择困难的问题,通过最大信息熵原理综合了 BP 神经网络(BPNN)较强的自适应能力以及鲸鱼优化支持向量机算法(WOA-SVM)良好的回归性能、适用小样本的优点。工程实例应用表明,构建的组合预测模型与单一预测模型相比,降低了均方误差、平均绝对误差和相对分析误差,提高了预测精度和收敛速度,在心墙砾石土渗透系数预测方面具有较强的优越性。

关键词:心墙砾石土;渗透系数;施工质量;鲸鱼优化支持向量机算法;BP 神经网络;组合预测模型

中图分类号:TV523;TV541 **文献标志码:**A **文章编号:**1006-7647(2022)06-0092-06

Prediction method of permeability coefficient for gravel soil of a core wall considering construction quality//LI Qing,TONG Dawei,YU Jia,WANG Jiajun,WANG Xing(*State Key Laboratory of Hydraulic Engineering Simulation and Safety, Tianjin University, Tianjin 300350, China*)

Abstract: In view of the permeability coefficient prediction for gravel soil of a core wall only considering material sources parameters, while a few prediction methods only considering construction quality having the problems of large error and incomplete data characteristics, a combined permeability coefficient predicting model BPNN-WOA-SVM considering both construction quality and material sources parameters was proposed. Whales optimization algorithm (WOA) was introduced to solve the difficult problem of SVM parameter selection, and the maximum information entropy principle was adopted to synthesize the strong adaptive ability of BPNN, good regression performance of whale optimized support vector machine (WOA-SVM) algorithm, and the advantages of small sample size. Engineering application results show that compared with the single prediction method, the combined prediction method reduces the mean square error, mean absolute error and relative analysis error, improves the prediction accuracy and convergence rate, and has a strong advantage in predicting the permeability coefficient for gravel soil of a core wall.

Key words: gravel soil of a core wall; permeability coefficient; construction quality; WOA-SVM; BP neural network; combined prediction model

砾石土心墙堆石坝的设计和安全管理中,渗流特性十分关键。心墙砾石土渗透系数不仅是坝体渗流特性的重要表征因素^[1],也是反映土石坝坝体填筑碾压质量的指标之一^[2]。因此,心墙砾石土渗透系数的分析和确定对坝体的渗流安全至关重要。

国内外学者围绕渗透系数开展了大量研究,如通过模型试验分析颗粒级配、孔隙比、曲率系数、不均匀系数等因素对渗透特性的影响^[3-5],但这些研究均是基于特定情况对渗透系数进行预测分析,不具有普适性,难以反映各影响因素和渗透系数之间复杂的非线性特征。人工神经网络(artificial neural

network,ANN)、支持向量机(support vector machine,SVM)等方法已越来越多地用于渗透系数预测研究。例如:Elbisy^[6]利用 SVM 和非线性统计回归方法预测砂土的渗透系数;Kashani 等^[7]提出一种基于 ANN 的多模型集成方法用于预测农田渗透系数;唐晓松等^[8-9]建立了神经网络预测模型研究各因素对渗透系数的影响并验证了其可靠性。上述研究均基于室内试验或现场原位试验,仅考虑料源特征参数建立了与渗透系数的非线性关系,缺少对施工质量因素(如压实质量等)的分析。而少数考虑压实质量的渗透系数预测模型^[10]虽然在收敛能力方面有

一定提高,但其全局收敛性是在无穷代的基础上寻找全局最优解,会影响算法的执行效率^[11-13];且其属于单一预测模型,存在数据特征获取不全面的缺点,预测精度有待进一步提高^[14]。

BP 神经网络(back propagation neural network, BPNN)因其具有较强的自适应能力已在渗透系数预测研究中得到应用,但 BPNN 存在收敛速度慢、易出现欠学习或过学习的问题^[15],通过与 SVM 组合,利用 SVM 良好的回归性能解决这一问题。传统的 SVM 方法易因参数设置不当造成预测准确率偏低^[16-17],因此本文采用鲸鱼优化算法(whales optimization algorithm, WOA)^[18]进行优化,建立 BPNN-WOA-SVM 渗透系数组合预测模型,该模型综合了 BPNN 较强的自适应能力以及 WOA-SVM 模型良好的逼近能力、泛化能力和适合小样本的优点,基于最大信息熵原理^[19-20]选择了最优权重来组合 2 种模型,并通过工程实例应用验证了模型的可行性和适用性。

1 模型构建

1.1 BPNN

BPNN 是基于误差反向传播算法的多层前馈神经网络,按有监督学习方式训练,包含输入层、隐含层、输出层(图 1)。输入层包含 9 个变量,即基于现场试坑试验得到的料源参数:不均匀系数 C_u 、曲率系数 C_c 、粒径大于 5 mm 颗粒质量分数 D_5 、粒径小于 0.075 mm 颗粒质量分数 $D_{0.075}$ 和含水率 w ;基于碾压质量实时监控系统得到的碾压参数:静碾遍数 N_0 、低振碾遍数 N_1 、高振碾遍数 N_2 、压实厚度 H 。隐含层和输出层中, ω 和 b 分别为权重和偏置参数。神经网络采用训练和检验样本数据进行学习和检验,不断修正网络权重和偏置参数使误差函数负向下降,逼近期望输出。选择正切 Sigmoid 函数作为传递函数,选取 Trainlm 作为训练函数,将最大训练次数设置为 1 000 次,最小误差设置为 0.001,学习速度设置为 0.1。




图 1 BPNN 结构

1.2 WOA-SVM 算法

选择合适的 SVM 参数(惩罚因子 C 和核参数

g)是建立高维空间里最优回归模型的重要过程。近年来,一些元启发式算法被引入以解决 SVM 模型的参数优化问题。WOA 具有调节参数少、全局收敛性强、收敛速度快等特点^[21],因此本文用 WOA 对 SVM 模型参数进行优化。WOA-SVM 算法优化模型参数的流程:①在搜索空间中设置鲸鱼初始种群数量 $n=50$,最大迭代数 $M=100$,将 SVM 的参数设定为每个鲸鱼个体,初始化种群;②设定参数 C 和 g 的搜索范围,计算出种群个体的适应度值,并更新种群最优值;③对种群个体进行位置更新,产生新的参数组合,再次计算适应度值,直到满足条件或者达到最大迭代次数,否则转到步骤②;④得到全局最优参数(C, g),建立 SVM 回归预测模型。

1.3 渗透系数预测模型构建

考虑施工质量的心墙区砾石土渗透系数预测模型的目标函数是建立渗透系数与各影响因子非线性关系:

$$k=f(C_u,C_c,D_5,D_{0.075},w,N_0,N_1,N_2,H) \quad (1)$$

考虑相关参数与渗透系数可能存在的非线性关系,可采用最大信息系数(maximal information coefficient, MIC)分析方法^[22]捕捉变量间的函数和非函数关系,利用互信息和网格划分计算最大信息系数,计算公式为

$$\begin{cases} I(x,y)=\sum_{x,y}p(x,y)\log_2\frac{p(x,y)}{p(x)p(y)} \\ MIC(x,y)=\max_{xy<B}\frac{I(x,y)}{\log_2(\min(|x|,|y|))} \end{cases} \quad (2)$$

式中: x 为各影响因素; y 为渗透系数; $p(x,y)$ 为 x 和 y 的联合概率; $I(x,y)$ 为互信息; B 为网格划分的上限值,设置 MIC 阈值为 0.6 时,模型的精度最优。

算法集包括 BP 神经网络算法 Y_1 、鲸鱼优化支持向量机算法 Y_2 和最大信息熵 E ,寻优公式为

$$\begin{cases} Y_1=[\omega,b] \\ Y_2=[C,g] \\ E=a_1Y_1+a_2Y_2 \end{cases} \quad (3)$$

式中: α_1 为 Y_1 权重系数; α_2 为 Y_2 权重系数。

建立基于 BPNN 和 WOA-SVM 渗透系数组合预测模型,并对模型的精度进行测试:

$$\hat{f}_i=\Omega(\alpha,\sigma,c,d,N|y_k(x_i)) \quad (4)$$

式中: α,σ,c,d 为核参数; N 为规则个数核参数。 α,σ,c,d 及 N 决定了目标函数 $\hat{f}_i$ 的结构,这些参数可由训练样本 $y_k(x_i)$ 确定。模型训练完成后,需要对模型的精度进行测试,精度测试指标为 MSE、MAE 及 RPD;MSE 代表均方误差;MAE 代表平均绝对误差;RPD 代表相对分析误差。

2 模型的拟合精度检验

2.1 参数相关性分析

分析料源参数(C_u 、 C_c 、 D_5 、 $D_{0.075}$ 、 w)、施工质量参数(N_0 、 N_1 、 N_2 、 H)与渗透系数之间的最大信息系数 MIC, MIC 越大,该参数的相关性越高,越适合作为输入参数进行渗透系数预测^[21]。经相关性分析可知各影响因子 MIC 在 0.6 ~ 0.9 之间,整体上, MIC 均高于 0.6, C_u 、 C_c 、 D_5 、 $D_{0.075}$ 、 N_0 、 N_1 、 N_2 、 H 、 w 与渗透系数之间呈一定的相关性。因此,在渗透系数预测模型构建中,以上参数均需作为模型的输入参数。提取 89 组数据,9 组作为验证数据,表 1 为其中 10 组数据的输入参数。

2.2 对比分析

WOA 最优参数惩罚因子 C 为 752.062,核参数 g 为 0.0010141,最优准确率 99.9061%。由图 2 可知适应度在迭代过程中有波动,说明此时避免陷入局部最优,进化效果较为明显。通过计算得到 WOA-SVM 算法预测结果,并与实际结果对比分析,如图 3 所示。




图 2 WOA-SVM 算法适应度曲线

采用 BPNN 算法得到模型训练预测期望对比如图 4 所示。BPNN 模型和 WOA-SVM 模型均能得到较好的预测结果,但精度有待于进一步提高。利用最大信息熵原理综合 2 种算法的优势,确定 BPNN 算法和 WOA-SVM 模型的权重。图 5 为最大信息熵组合算法预测结果,组合模型的预测值与实际值的




图 3 WOA-SVM 算法训练预测期望对比
误差更小,表明本文提出的方法精度更高。




图 4 BPNN 模型训练预测期望对比




图 5 最大信息熵组合模型训练预测期望对比

从表 2 可以看出,3 种预测算法 RPD 均大于 2.0,说明 3 种预测模型均具有良好预测能力,BPNN-WOA-SVM 组合模型预测能力最佳;BPNN-WOA-SVM 组合模型的平均值相较于其他 2 种算法更加接近实测值的平均值。综上所述,BPNN-WOA-SVM 组合模型预测结果误差最小,预测能力最为优良。

表 1 输入参数

序号	H/cm	N_0	N_1	N_2	$D_5/\%$	$D_{0.075}/\%$	$w/\%$	C_u	C_c	$k/(10^{-5}\text{cm}\cdot\text{s}^{-1})$
1	31.3	2	11	13	60.1	56.4	8.1	15	1.8	0.50
2	27.0	2	8	11	59.2	47.7	8.5	15	1.25	0.41
3	27.2	2	11	10	49.4	45.5	22.6	59	1.12	0.32
4	32.0	1	10	11	48.6	39.7	23.5	74	1.07	0.11
5	25.7	0	10	9	59.8	49.8	6.1	7.5	2.5	0.59
6	37.1	1	9	12	52.6	47.4	21.3	40	1.21	0.39
7	30.6	2	8	9	56.8	49.3	22.6	54	1.67	0.42
8	26.8	2	10	10	61.2	47.5	6.1	10	2.16	0.58
9	27.4	2	10	9	57.8	44.0	7.0	17	1.82	0.56
10	23.5	1	10	13	57.9	46.8	15.6	27	1.54	0.66

表2 3种预测模型误差分析结果

模型	平均值/ (10 ⁻⁵ cm·s ⁻¹)	标准差/ (10 ⁻⁵ cm·s ⁻¹)	MSE	MAE	RPD
实测值	0.532	1.3735			
BPNN	0.541	1.3312	0.2027	0.1666	6.7743
WOA-SVM	0.525	1.4072	0.2000	0.1777	6.8677
BPNN-WOA-SVM	0.537	1.4374	0.0632	0.1333	8.4113

3 工程实例验证

我国西南某在建水电站的挡水建筑物为心墙堆石坝,最大坝高295.00m。防渗体为砾石土直心墙,心墙顶宽6.00m,顶高程2873.00m,心墙上下游坡均为1:0.2,在心墙与堆石之间设有反滤层和过渡层。按照心墙区的施工参数标准;用于修筑心墙的防渗料 $D_{0.075}$ 应该大于等于15%,同时颗粒级配应符合规范要求,且要避免出现颗粒分离、砾石集中等现象。经过碾压施工之后,心墙料的渗透系数应小于等于 1×10^{-5} cm/s。碾压设备的碾压遍数设置为10遍振碾+2遍静碾,碾压区域占总区域的比值应大于等于95%。

3.1 考虑与不考虑施工质量影响的预测结果对比

在考虑碾压参数与不考虑碾压参数的条件下分别对施工仓面任意位置的渗透系数进行预测,得到的预测结果如图6所示,平均值与标准差对比见表3。




图6 碾压参数对预测结果影响对比

渗透系数预测模型仅考虑料源参数的情况下,渗透系数平均值为 0.765×10^{-5} cm/s,各仓面的标准差平均为 0.364×10^{-5} cm/s,分布较为分散;考虑碾压参数后,渗透系数平均值为 0.532×10^{-5} cm/s,各仓面的标准差平均为 0.206×10^{-5} cm/s,渗透系数预测精度更高,标准差降低了43.4%。

表3 碾压参数影响结果

仓面编号	仓面渗透系数平均值/(10 ⁻⁵ m·s ⁻¹)			仓面渗透系数 平均值增加/%	仓面渗透系数标准差/(10 ⁻⁵ m·s ⁻¹)			仓面渗透系数 标准差增加/%
	实测值	考虑碾压参数	不考虑碾压参数		实测值	考虑碾压参数	不考虑碾压参数	
1	0.530	0.528	0.788	49.24	0.167	0.162	0.328	102.47
2	0.517	0.523	0.722	38.04	0.192	0.186	0.305	63.98
3	0.545	0.543	0.786	44.75	0.174	0.173	0.328	89.60
4	0.542	0.533	0.735	37.89	0.211	0.203	0.399	96.55
5	0.528	0.535	0.792	48.03	0.188	0.185	0.323	74.59

以心墙A区2600.73m高程处的某施工区域为例具体进行研究分析。基于建立的渗透系数组合预测模型得到该仓面的渗透系数分布如图7所示,均满足小于 1×10^{-5} cm/s,可知该仓面碾压后的渗透系数分布满足施工要求。




图7 渗透系数分布云图

3.2 模型预测结果对比

分别用BPNN模型、WOA-SVM模型和BPNN-WOA-SVM组合模型预测训练样本,渗透系数预测结果对比如图8所示,可见BPNN-WOA-SVM组合模型预测结果相比BPNN和WOA-SVM模型预测结




图8 实测值与预测结果对比

果更接近实测值,验证了 BPNN-WOA-SVM 组合模型的可行性和适用性。

4 结 语

本文考虑施工质量的影响,将控制指标料源参数和表征施工质量的碾压参数作为输入参数进行心墙砾石土渗透系数预测;针对 BPNN 收敛速度慢、易出现欠学习或过学习的不足,以及 SVM 因参数设置不当易出现预测准确率偏低的问题,引入 WOA 对 SVM 对参数进行优化,综合 BPNN 和 WOA-SVM 方法的优点,构建了 BPNN-WOA-SVM 渗透系数组合预测模型。在组合预测模型中利用最大信息熵原理,选择熵最大的模型为最优模型。在对渗透系数进行预测时,BPNN-WOA-SVM 组合模型相比单一的 BPNN 和 WOA-SVM 预测方法降低了均方误差、平均绝对误差和相对分析误差,提高了收敛速度,具有良好的应用效果。

参考文献:

[1] 邵生俊,李建军,杨扶银.粗粒土孔隙特征及其对泥浆渗透性的影响[J].岩土工程学报,2009,31(1):59-65. (SHAO Shengjun, LI Jianjun, YANG Fuyin. Pore characteristics of coarse grained soil and their effect on slurry permeability [J]. Chinese Journal of Geotechnical Engineering, 2009, 31 (1) : 59-65. (in Chinese))

[2] 黄文熙.土的工程性质[M].北京:水利电力出版社,1983.

[3] 刘一飞,郑东生,杨兵,等.粒径及级配特性对土体渗透系数影响的细观模拟[J].岩土力学,2019,40(1):403-412. (LIU Yifei, ZHENG Dongsheng, YANG Bing, et al. Microscopic simulation of influence of particle size and gradation on permeability coefficient of soil [J]. Chinese Rock and Soil Mechanics, 2019, 40 (1) : 403-412. (in Chinese))

[4] 黄达,曾彬,王庆乐.粗粒土孔隙比及级配参数与渗透系数概率的相关性研究[J].水利学报,2015,46(8):900-907. (HUANG Da, ZENG Bin, WANG Qingle. Study on the correlation between porosity ratio, grading parameters and permeability coefficient probability of coarse-grained soil [J]. Journal of Hydraulic Engineering, 2015, 46 (8) : 900-907. (in Chinese))

[5] 唐凯,郭丹,沈才华,等.细颗粒含量对极细砂渗透性的影响规律和细观机理[J].水利水电科技进展,2021,41(6):46-51. (TANG Kai, GUO Dan, SHEN Caihua, et al. Influence rule of fine particle content on sand permeability and its mesoscopic mechanism [J]. Advances in Science and Technology of Water Resources, 2021, 41 (6) : 46-51. (in Chinese))

[6] ELBISY M S. Support vector machine and regression

analysis to predict the field hydraulic conductivity of sandy soil [J]. KSCE Journal of Civil Engineering, 2015, 19 (7) : 2307-2316.

[7] KASHANI M H, GHORBANI M A, SHAHABI M, et al. Multiple AI model integration strategy: application to saturated hydraulic conductivity prediction from easily available soil properties [J]. Soil & Tillage Research, 2020, 196: 104449.

[8] 唐晓松,郑颖人,董诚.应用神经网络预估粗颗粒土的渗透系数[J].岩土力学,2007,28(增刊1):133-136. (TANG Xiaosong, ZHENG Yingren, DONG Cheng. Neural network is applied to predict the permeability coefficient of coarse granular soil [J]. Rock and Soil Mechanics, 2007, 28 (Sup1) : 133-136. (in Chinese))

[9] 王双,李小春,王少泉,等.碎石土级配特征对渗透系数的影响研究[J].岩石力学与工程学报,2015,34(增刊2):4394-4402. (WANG Shuang, LI Xiaochun, WANG Shaoquan, et al. Study on the effect of gradation characteristics of gravel soil on permeability coefficient [J]. Journal of Rock Mechanics and Engineering, 2015, 34 (Sup2) : 4394-4402. (in Chinese))

[10] 吕鹏.基于不确定性分析的土石坝渗流性态研究[D].天津:天津大学,2019.

[11] 王红瑞,魏豪杉,胡立堂,等.基于遗传算法的 SVM-AR 改进模型与应用[J].河海大学学报(自然科学版),2020,48(6):488-497. (WANG Hongrui, WEI Haoshan, HU Litang, et al. Improved model and application of SVM-AR based on genetic algorithm [J]. Journal of Hohai University (Natural Sciences), 2020, 48 (6) : 488-497. (in Chinese))

[12] 谢军,王倩,倪雅静,等.基于遗传算法进行结构优化的研究现状[J].河北建筑工程学院学报,2018,36(3):14-21. (XIE Jun, WANG Qian, NI Yajing, et al. Research status of structural optimization based on genetic algorithm [J]. Journal of Hebei Institute of Civil Engineering and Architecture, 2018, 36 (3) : 14-21. (in Chinese))

[13] 张伟,段毅,曲智国,等.基于自适应遗传算法的相控阵雷达事件调度策略研究[J].信息系统工程,2019(1):156-158. (ZHANG Wei, DUAN Yi, QU Zhiguo, et al. Research on event scheduling strategy of phased array radar based on adaptive genetic algorithm [J]. Information Systems Engineering, 2019 (1) : 156-158. (in Chinese))

[14] 单英浩,付青,耿炫,等.基于改进 BP-SVM-ELM 与粒子化 SOM-LSF 的微电网光伏发电组合预测方法[J].中国电机工程学报,2016,36(12):3334-3343. (SHAN Yinghao, FU Qing, GENG Xuan, et al. A combination prediction method for microgrid photovoltaic power generation based on improved BP-SVM-ELM and particle SOM-LSF [J]. Proceedings of the CSEE, 2016, 36 (12) : 3334-3343. (in Chinese))

[15] 张弛,郭媛,黎明.人工神经网络模型发展及应用综述

- [J]. 计算机工程与应用, 2021, 57 (11): 57-69. (ZHANG Chi, GUO Yuan, LI Ming. Review of the development and application of artificial neural network models [J]. Computer Engineering and Applications, 2021, 57(11): 57-69. (in Chinese))
- [16] 徐卫亚, 徐伟, 闫龙, 等. 基于LMBP和SVR的倾倒变形体变形预测[J]. 河海大学学报(自然科学版), 2021, 49(1): 64-69. (XU Weiya, XU Wei, YAN Long, et al. Deformation prediction of toppling deformed slope based on LMBP and SVR [J]. Journal of Hohai University (Natural Sciences), 2021, 49(1): 64-69. (in Chinese))
- [17] 潘志刚, 林祥峰, 张继生. 基于支持向量机的桥墩局部冲刷深度预测模型[J]. 水利水电科技进展, 2021, 41(6): 78-81. (PAN Zhigang, LIN Xiangfeng, ZHANG Jisheng. Prediction model for bridge pier local scour depth based on support vector machine [J]. Advances in Science and Technology of Water Resources, 2021, 41(6): 78-81. (in Chinese))
- [18] MIRJALILI S, LEWIS A. The whale optimization Algorithm[J]. Advances in Engineering Software, 2016, 95: 51-67.
- [19] 谢林江, 尹东. 基于最大相关熵准则的鲁棒度量学习算法[J]. 计算机系统应用, 2018, 27(10): 146-153. (XIE Linjiang, YIN Dong. Robust metric learning algorithm based on maximum correlation entropy criterion [J]. Computer System Applications, 2018, 27(10): 146-153. (in Chinese))
- [20] POKHAREL P, SANTAMARIA I, XU Jianwu, et al. Correntropy for random processes: properties and applications in signal processing[J]. Information Science and Statistics, 2010, 11: 415-455.
- [21] 岳晓宇, 彭显刚, 林俐. 鲸鱼优化支持向量机的短期风电功率预测[J]. 电力系统及其自动化学报, 2020, 32(2): 146-150. (YUE Xiaoyu, PENG Xiangang, LIN Li. Short-term wind power prediction based on whale optimized support vector machine [J]. Journal of Power Systems and Automation, 2020, 32(2): 146-150. (in Chinese))
- [22] RESHEF D N, RESHEF Y A, SABTEI P C. Detecting novel associations in large data sets[J]. Science, 2011, 334(6062): 1518-1524.

(收稿日期: 2021-07-31 编辑: 刘晓艳)

(上接第 32 页)

- [9] CHEN L C, ZHU Yukun, PAPANDREOU G, et al. Encoder-decoder with Atrous separable convolution for semantic image segmentation [C]//15th European Conference on Computer Vision. Munich: Springer, 2018: 833-851.
- [10] XUE Yadong, LI Yicheng. A fast detection method via region-based fully convolutional neural networks for shield tunnel lining defects [J]. Computer-Aided Civil and Infrastructure Engineering, 2018, 33(8): 638-654.
- [11] 李思琦. 基于迁移学习的多源遥感影像建筑垃圾识别[D]. 北京: 北京建筑大学, 2020.
- [12] 王超, 贾贺, 张社荣, 等. 基于图像的混凝土表面裂缝量化高效识别方法[J]. 水力发电学报, 2021, 40(3): 134-144. (WANG Chao, JIA He, ZHANG Sherong, et al. Image-based quantitative and efficient identification method for concrete surface cracks [J]. Journal of Hydroelectric Engineering, 2021, 40(3): 134-144. (in Chinese))
- [13] 张小伟, 包腾飞, 高兴和. 基于计算机视觉的混凝土坝裂缝检测方法[J]. 水利水电科技进展, 2021, 41(5): 83-88. (ZHANG Xiaowei, BAO Tengfei, GAO Xinghe. Crack detection method of concrete dams based on computer vision[J]. Advances in Science and Technology of Water Resources, 2021, 41(5): 83-88. (in Chinese))
- [14] 王一兵, 包腾飞, 高治鑫. 基于 LabVIEW+VDM 的混凝土坝裂缝检测方法[J]. 水利水电科技进展, 2021, 41(5): 76-82. (WANG Yibing, BAO Tengfei, GAO Zhixin. Crack detection method of concrete dams based on LabVIEW+VDM[J]. Advances in Science and Technology of Water Resources, 2021, 41(5): 76-82. (in Chinese))
- [15] 陈丹丹. 基于 Deeplabv3+ 的高分遥感影像道路损毁信息提取方法研究[D]. 北京: 中国地震局地震预测研究所, 2020.
- [16] SANDLER M, HOWARD A, ZHU Menglong, et al. MobileNetV2: inverted residuals and linear bottlenecks [C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City: IEEE, 2018.
- [17] 赵洋, 许军. 基于 MobileNetV2 与树莓派的人脸识别系统[J]. 计算机系统应用, 2021, 30(8): 67-72. (ZHAO Yang, XU Jun. Face recognition system based on MobileNetV2 and Raspberry Pi [J]. Computer Systems & Applications, 2021, 30(8): 67-72. (in Chinese))
- [18] 邢恩铭, 王文赛, 周榴, 等. 基于改进 U-Net 的皮肤超声图像自动分割算法[J]. 生物医学工程与临床, 2021, 25(2): 123-130. (XING Enming, WANG Wensai, ZHOU Liu, et al. Automatic segmentation algorithm of skin ultrasound image based on improved U-Net [J]. Biomedical Engineering and Clinical Medicine, 2021, 25(2): 123-130. (in Chinese))

(收稿日期: 2021-12-06 编辑: 俞云利)