DOI：10.13245/j.hust.260014

# 改进RIME优化集成模型的海上单桩冲刷深度预测

韩 坤[1] 陈 剑[2] 赵旭光[3] 陈 鑫[1]

(1．中国农业大学水利与土木工程学院，北京 100083；2．温州市水利电力勘测设计院，浙江温州 325000；3．龙源(北京)新能源工程设计研究院有限公司，北京 100034)

**摘要** 基于单桩冲刷试验数据，提出一种融合极限梯度提升(XGBoost)、轻量级梯度提升机(LightGBM)和随机森林(RF)的集成模型，并通过改进霜冰优化算法(GRIME)来优化模型超参数和集成权重，用于预测单桩基础冲刷深度，同时采用Shapley加法解释(SHAP)方法进行可解释性分析．结果表明：在量纲参数和无量纲参数组合下，所提模型均表现出最佳的预测性能，对比其他机器学习模型，测试集均方根误差平均降低了12.71%和21.33%，决定系数平均提高了2.27%和3.23%；SHAP分析显示：近底流速$U_c$和速度比是影响冲刷深度及相对冲刷深度预测结果的关键参数，且无量纲参数模型的可解释性更强，更符合物理变化规律．

**关键词** 单桩基础；冲刷深度预测；集成模型；改进霜冰优化算法；可解释性；Shapley加法解释

**中图分类号** P753 **文献标志码** A **文章编号** 1671-4512(2026)10-0073-08

# Improvement of RIME optimized integrated model for offshore monopile scour depth prediction

*HAN Kun*[1] *CHEN Jian*[2] *ZHAO Xuguang*[3] *CHEN Xin*[1]

(1．College of Water Resources and Civil Engineering，China Agricultural University，Beijing 100083，China；
2．Wenzhou Water Conservancy Survey and Design Institute Co. Ltd.，Wenzhou 325000，Zhejiang China；
3．Longyuan (Beijing) New Energy Engineering Design Research Institute Co. Ltd.，Beijing 100034，China)

**Abstract** Based on monopile scour test data，an ensemble model integrating extreme gradient boosting (XGBoost)，light gradient boosting machine (LightGBM)，and random forest (RF) was proposed，and the hyperparameters and ensemble weights were optimized using an improved globalized rime optimization algorithm (GRIME) for predicting scour depth around monopile foundations．Meanwhile，Shapley additive explanations (SHAP) were employed for interpretability analysis．Results show that the proposed model exhibits the best predictive performance under both dimensional and dimensionless parameter combinations．Compared with other machine learning models，the average root mean square error (RMSE) of the test set is reduced by 12.71% and 21.33%，while the average coefficient of determination ($R^2$) is improved by 2.27% and 3.23%，respectively．SHAP analysis show that near-bed current velocity ($U_c$) and velocity ratio are the key parameters affecting the prediction results of scour depth and relative scour depth，and the dimensionless-parameter-based model exhibits stronger interpretability and is more consistent with physical variation laws．

**Key words** monopile foundation；scour depth prediction；ensemble model；improved rime ice optimization algorithm；explainability；Shapley additive explanations

海上风电作为我国可再生能源开发的重要方向，近年来发展迅速．但复杂的海洋环境常导致桩基周围土体发生局部冲刷，引发结构失稳或破坏，因此准确预测单桩周围的平衡冲刷深度对于保障风

**收稿日期** 2026-01-07．

**作者简介** 韩 坤(2000—)，男，博士研究生；陈 鑫(通信作者)，教授，E-mail：chenx@cau.edu.cn．

**基金项目** 国家自然科学基金资助项目(12472415)．

机的安全运行至关重要[1]．目前，冲刷深度预测主要依赖经验公式[2-5]，但经验模型难以全面刻画多因素间的非线性关系，预测精度受限．

近年来，机器学习凭借其非线性建模能力和对高维数据的适应性，逐渐应用于解决复杂的海洋工程问题[6]．其中，树模型通过集成多棵决策树，在计算效率和预测性能方面表现突出．文献[7]基于极限梯度提升(XGBoost)建立了圆形桥墩冲刷深度的预测模型，其精度优于支持向量机(SVM)和BP神经网络．然而，机器学习模型的性能受超参数选择影响较大，且泛化性较差，难以满足高精度预测需求[8]．为此，学者们引入贝叶斯优化(BO)、粒子群(PSO)等智能优化算法以提升模型的预测性能[9]，并通过集成融合不同模型进一步增强预测精度[10]．但在非线性冲刷预测问题中，这类算法易陷入局部最优、早熟收敛和对初始样本敏感，传统集成方法又多依赖经验加权，难以实现模型超参数与集成权重的协同寻优，精度与稳定性仍难以兼顾．

基于上述问题，本研究提出一种高效、准确且具可解释性的单桩基础冲刷深度预测模型，首先，基于已有文献收集466组单桩冲刷试验数据，构建冲刷深度数据库，然后提出一种融合XGBoost，轻量级梯度提升机(LightGBM)和随机森林(RF)的集成模型，并通过改进霜冰优化算法(GRIME)协同优化模型超参数与集成权重．最后引入Shapley加法解释(SHAP)方法，提升模型的可解释性并揭示输入参数与冲刷深度间的非线性关系．

# 1　数据来源与预处理

## 1.1　参数选择

为了预测两种常见海洋动力学(纯波浪、组合波浪与水流)条件下单桩的平衡冲刷深度，首先须要确定影响冲刷深度的物理参数集．已有研究表明圆柱形单桩基础的平衡冲刷深度主要受三个方面的影响：单桩几何形状、水动力条件和沉积物特性．这种关系可以表示为

$$S = f_1(d_{50},\ U_{\mathrm{m}},\ U_{\mathrm{c}},\ T,\ D),$$

式中：$S$为冲刷深度；$d_{50}$为中值粒径；$U_{\mathrm{m}}$为最大波浪轨道速度；$U_{\mathrm{c}}$为未受干扰的近底流速；$T$为波浪周期；$D$为单桩直径．

为了使公式中的物理含义更加准确和通用，须要使用无量纲数表示冲刷相关参数．根据π定理定义的相对冲刷深度($S/D$)表示为

$$S/D = f_2(\delta,\ \Phi_{\mathrm{KC}},\ Fr_{\mathrm{a}},\ \mathrm{Re},\ D/d_{50}),$$

式中：$\delta=U_{\mathrm{c}}/(U_{\mathrm{c}}+U_{\mathrm{m}})$为速度比，表征波流共同作用效应；$\Phi_{\mathrm{KC}}=U_{\mathrm{m}}T/D$为Keulegan-Carpenter数；$Fr_{\mathrm{a}}=(U_{\mathrm{c}}+2U_{\mathrm{m}}/\pi)/\sqrt{gD}$为基于平均速度的弗劳德数[4]，其中$g$为重力加速度；$Re=\rho U_{\mathrm{m}}D/\mu$为桩雷诺数，其中$\rho$为流体密度，$\mu$为动力黏度．

## 1.2　数据库建立及数据分析

本研究汇总了多组单桩基础冲刷试验数据[2-5,11-21]用于机器学习建模，试验模型尺度范围为1∶50到1∶100．数据集涵盖了不同工况，包括桩径、水流条件和试验装置的变化．通过数据清洗及交叉验证等措施，减少数据误差对模型的影响，验证了模型的泛化能力和适用性．首先对数据集进行清洗：剔除冲刷深度为零的数据样本；剔除物理参数值缺失或明显错误的数据样本；根据$\delta$的定义，纯波浪作用视为特殊组合波流(流为零)，将纯波浪样本的$U_{\mathrm{c}}$和$\delta$取为零．

经过数据预处理后，共获得466个有效数据样本．表1总结了各参数的统计范围，包括最大值、最小值、平均值和标准差(SD)．并按照有量纲参数和无量纲参数进行分类；同时，本研究采用Pearson相关性分析来探讨输入参数之间的线性相关性，以便更好地理解各参数的敏感性．从整体情况来看，输入参数间的Pearson相关系数介于−0.44～0.52，表明独立输入参数间不存在多重共线性，因此所有参数均可用于构建机器学习模型．

**表1　各参数统计值**

| 参数 | 有量纲参数 | | | | | 无量纲参数 | | | | |
|---|---|---|---|---|---|---|---|---|---|---|
| | $d_{50}$/m | $U_{\mathrm{m}}$/(mm·s$^{-1}$) | $U_{\mathrm{c}}$/(cm·s$^{-1}$) | $T$/s | $D$/cm | $\delta$ | $\Phi_{\mathrm{KC}}$ | $Fr_{\mathrm{a}}$ | $Re$ | $D/d_{50}$ |
| 最小值 | $6.0\times10^{-5}$ | 50 | 0 | 0.8 | 1 | $0.0\times10^{0}$ | $2.0\times10^{-1}$ | $3.0\times10^{-2}$ | $2.3\times10^{3}$ | $3.4\times10^{1}$ |
| 最大值 | $1.8\times10^{-3}$ | 530 | 60 | 5.4 | 100 | $7.8\times10^{-1}$ | $5.3\times10^{1}$ | $1.1\times10^{0}$ | $6.1\times10^{5}$ | $1.8\times10^{4}$ |
| 均值 | $3.8\times10^{-4}$ | 220 | 7 | 2.6 | 11 | $1.7\times10^{-1}$ | $1.2\times10^{1}$ | $2.8\times10^{-1}$ | $4.1\times10^{4}$ | $6.5\times10^{2}$ |
| 标准差 | $4.0\times10^{-4}$ | 9 | 10 | 1.1 | 17 | $2.6\times10^{-1}$ | $9.6\times10^{0}$ | $1.5\times10^{-1}$ | $7.5\times10^{4}$ | $1.5\times10^{3}$ |

# 2　算法改进及模型构建

## 2.1　改进RIME(GRIME)算法

GRIME算法是对霜冰优化(RIME)算法[22]的改

进，通过引入Tent混沌映射和莱维飞行(Levy)反向学习策略，有效增强了种群多样性和全局搜索能力．相较于RIME，PSO和灰狼优化(GWO)等算法，其在高维非线性参数优化中表现出更优的收敛稳定性，更适用于集成模型超参数与权重的联合优化．具体而言，GRIME的改进如下．

**a**．初始化种群：利用Tent混沌映射生成初始种群，相比其他映射方法，在分布和收敛速度上更具优势，增强了初期种群的多样性，从而确保优化搜索能够覆盖更广泛的超参数空间．表达式为

$$x_n^{m+1}=\begin{cases}2x_n^m & (0\leqslant x_n^m\leqslant 0.5),\\ 2(1-x_n^m) & (0.5<x_n^m\leqslant 1);\end{cases}$$

$$p_n^m=L_{\mathrm{b}}+\left(U_{\mathrm{b}}-L_{\mathrm{b}}\right)x_n^m,$$

式中：$x_n^m$为第$n$个个体在第$m$维的混沌变量值；$p_n^m$为第$n$个个体在第$m$维的初始化位置；$U_{\mathrm{b}}$和$L_{\mathrm{b}}$分别为上下边界值．

**b**．全局搜索：与传统优化策略相比，Levy飞行和反向学习策略提供更高效的跳跃式搜索，能在复杂的非线性优化问题中找到更准确的全局解，提升算法的全局优化能力和收敛速度．其表达式为

$$\tilde{p}_n^m=L_{\mathrm{b}}+U_{\mathrm{b}}-p_n^m+a\times\mathrm{Levy}(b);$$

$$\mathrm{Levy}(b)=u/|v|^{1/b}\quad(u,\ v\sim N(0,\ 1)),$$

式中：$a$为缩放因子；$b$为稳定指数；$\mathrm{Levy}(b)$为服从Levy分布的随机步长；$\tilde{p}_n^m$为反向位置．图1显示了GRIME算法的具体优化流程．

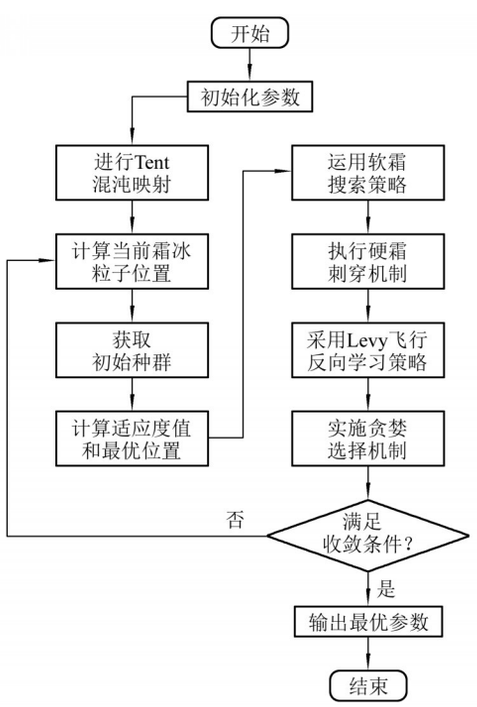



图1　GRIME算法优化流程图

### 2.2　GRIME优化的集成模型

树模型在冲刷深度预测中具有较高的预测精度和可行性，优于其他机器学习模型[6-7,9]，因此选取XGBoost，LightGBM和随机森林(RF)作为基模型进行融合．其中XGBoost具有较强的非线性拟合能力；LightGBM在保证精度的同时具备较高的训练效率；RF则通过多决策树集成增强了模型的稳定性和抗过拟合能力．

传统的简单平均或经验加权集成方式难以充分发挥不同模型在特征表达和泛化能力方面的互补优势．为此，本研究引入GRIME算法，在集成学习框架下实现集成权重及模型超参数的协同优化，从而提升模型整体预测性能和稳定性．GRIME优化的集成公式为

$$P_{\mathrm{j}}=\alpha P_{\mathrm{XG}}+\beta P_{\mathrm{Li}}+\gamma P_{\mathrm{RF}},$$

式中：$P_{\mathrm{XG}}$，$P_{\mathrm{Li}}$和$P_{\mathrm{RF}}$分别为XGBoost，LightGBM和RF模型经过GRIME优化后的预测值；$\alpha$，$\beta$和$\gamma$为各自的集成权重，且满足$\alpha+\beta+\gamma=1$；$P_{\mathrm{j}}$为融合预测值．单桩冲刷深度预测的具体步骤如下．

**a**．数据收集与处理．将466组数据归一化后，随机划分为训练集(80%)和测试集(20%)，使用量纲参数组合预测($S$)、无量纲参数组合预测$S/D$．

**b**．模型构建及对比．构建基于GRIME优化的集成模型进行冲刷深度预测，训练过程中结合五折交叉验证来降低过拟合的风险，并与SVR，RF，XGBoost模型及传统经验公式进行对比．

**c**．模型评估及可解释性．使用评价指标评估模型预测性能．采用SHAP方法分析输入参数对冲刷深度的贡献及影响．

## 3　结果和讨论

### 3.1　GRIME算法的性能评估

为了验证GRIME算法优化集成模型的优越性，将GRIME算法与GWO，GA，SSA，RIME和PSO算法进行对比，具体方法是将每种算法应用于集成模型优化，并选用均方根误差(RMSE)作为适应度值．所有算法的初始学习率为0.01，种群数量设置为30，最大迭代次数设置为20．图2展示了在相同迭代条件下六种算法的收敛行为及误差变化情况．

结果表明：与其他算法相比，GRIME在迭代初期即可获得更低的适应度值，表现出更快的收敛速度．这主要归因于Tent混沌映射与Levy飞行反向学习策略的引入，有效提升了全局搜索效率并降低了预测误差．无量纲参数条件下，各算法整体收

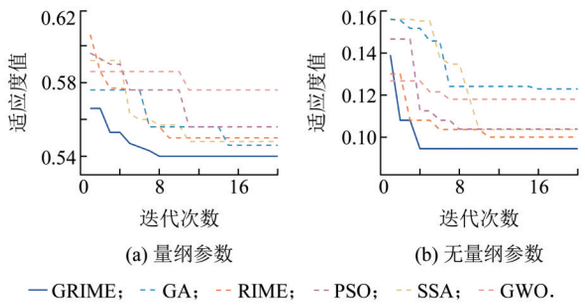



图2　不同优化算法优化效果比较

敛更快且稳定性更好，GRIME 更早达到稳定的 RMSE，表明无量纲输入有助于降低搜索空间复杂度、提高优化效率；相比之下，有量纲参数受物理尺度差异影响，优化过程波动略大．

### 3.2　预测结果分析

本研究选取平均绝对误差(MAE)、RMSE、相关系数(CC)和决定系数($R^2$)作为评价指标．为验证所提模型的可行性和准确性，将其与 SVR，RF 和 XGBoost 三种机器学习模型进行对比分析，这些模型在工程问题中表现优异，其中 SVR 作为经典的回归模型，已广泛应用于单桩冲刷预测．为保证对比的公平性，所有对比模型均采用网格搜索结合五折交叉验证对其关键超参数进行优化．对于所提集成模型，GRIME 算法的参数经多次实验确定：初始学习率为0.01、种群规模为30、最大迭代次数为100，缩放因子为0.2，优化得到的模型超参数和集成权重结果见表2．

**表2　模型超参数与集成权重设置**

| 模型 | 参数 | 参数取值 | |
|---|---|---|---|
| | | 有量纲 | 无量纲 |
| RF | 树的数量 | 100 | 150 |
| | 树最大深度 | 8 | 6 |
| | $\gamma$ | 0.216 | 0.232 |
| LightGBM | 树的数量 | 250 | 150 |
| | 树最大深度 | 7 | 6 |
| | 叶子数量 | 15 | 15 |
| | $\beta$ | 0.366 | 0.355 |
| XGBoost | 树的数量 | 250 | 200 |
| | 树最大深度 | 6 | 5 |
| | $\alpha$ | 0.418 | 0.413 |

图3展示了四种模型在量纲参数下的预测结果散点图，可以观察到：SVR 模型在训练集和测试集中的预测结果较为分散，大部分预测值在超出±25%的误差范围，RF 和 XGBoost 的预测值大多集中在±25%的误差范围内．所提模型的预测值最接近1∶1线，表明其能够有效捕捉输入参数之间的非线性关系．

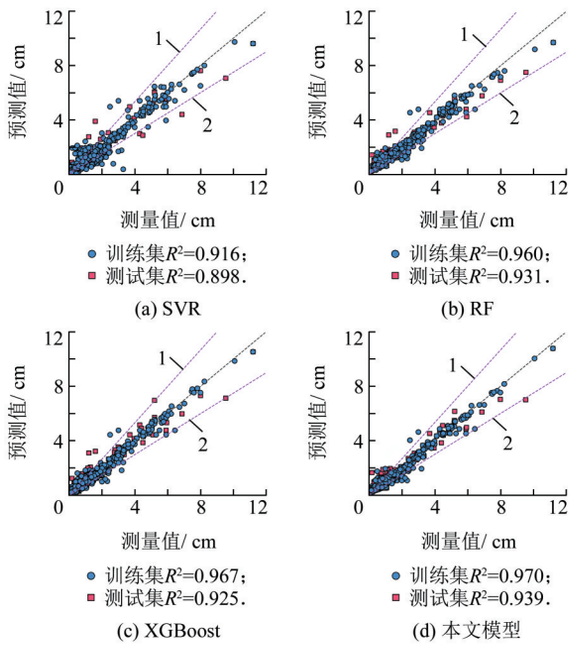



图3　不同模型在量纲参数下的预测结果

图4展示了四种模型在无量纲参数下的预测结果散点图，与其他三种模型相比，所提模型在±25% 误差范围内的预测比例明显更高，进一步证明了 GRMIE 优化的集成模型具有最佳的预测能力．在两类参数组合下，所提模型均表现出优异的预测性能．

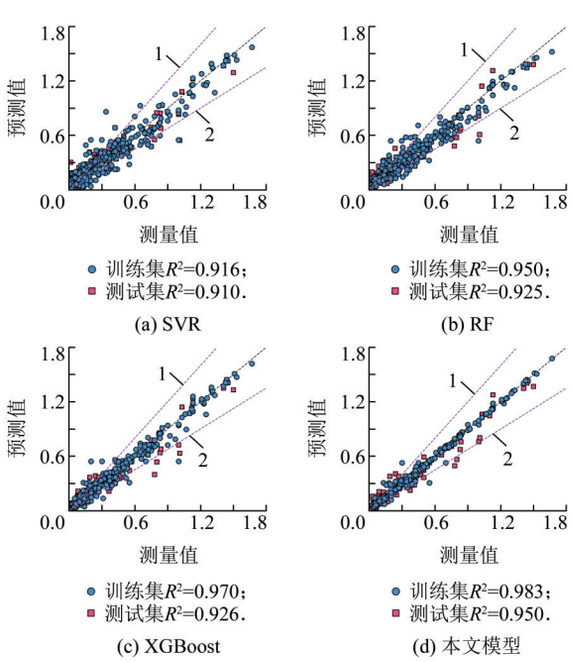



图4　不同模型在无量纲参数下的预测结果

表3汇总了四种模型在训练集和测试集上的评价指标．对于量纲参数组合，所提模型在测试集中

表现最优，相关系数和$R^2$最高，RMSE和MAE最低．相比之下，SVR模型的$R^2$较低且RMSE较大，预测精度尚不满足工程需求．在无量纲参数组合下，本文模型性能同样优于SVR，RF和XGBoost．测试集中的相关系数及$R^2$，MAE，RMSE均表现出显著提升，进一步验证了所提模型的预测优势．

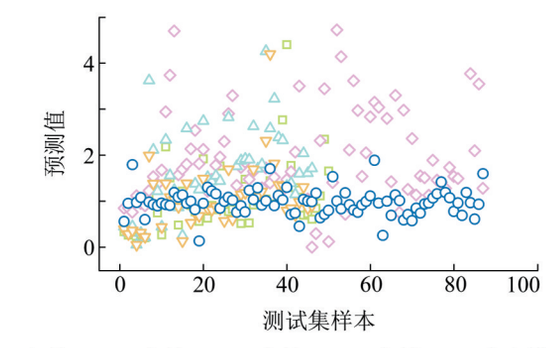
**表3　不同模型性能评价指标对比**

| 数据集 | 模型 | 有量纲 | | | | 无量纲 | | | |
|---|---|---|---|---|---|---|---|---|---|
| | | MAE/cm | RMSE/cm | 相关系数 | $R^2$ | MAE | RMSE | 相关系数 | $R^2$ |
| 训练集 | SVR | 0.343 | 0.542 | 0.957 | 0.917 | 0.078 | 0.102 | 0.957 | 0.916 |
| | RF | 0.140 | 0.374 | 0.981 | 0.960 | 0.055 | 0.078 | 0.976 | 0.950 |
| | XGBoost | 0.217 | 0.337 | 0.984 | 0.968 | 0.040 | 0.061 | 0.985 | 0.970 |
| | 本文模型 | 0.193 | 0.323 | 0.985 | 0.970 | 0.021 | 0.046 | 0.991 | 0.983 |
| 测试集 | SVR | 0.447 | 0.697 | 0.949 | 0.899 | 0.084 | 0.114 | 0.956 | 0.910 |
| | RF | 0.330 | 0.574 | 0.972 | 0.931 | 0.076 | 0.104 | 0.963 | 0.925 |
| | XGBoost | 0.409 | 0.598 | 0.965 | 0.925 | 0.072 | 0.103 | 0.964 | 0.926 |
| | 本文模型 | 0.231 | 0.540 | 0.978 | 0.939 | 0.059 | 0.084 | 0.976 | 0.950 |

图3、图4和表3的结果表明：在两种参数组合下，RF和XGBoost的预测结果优于SVR，因为树模型通过逐步修正误差可达到更高的精度，且在处理复杂数据和非线性关系更具鲁棒性．XGBoost的预测效果优于RF，主要由于其正则化控制模型复杂度和缺失值处理策略，有效防止过拟合．本文模型取得了最优结果，因为其结合了三种树模型的优势，提升了非线性关系处理、特征选择和模型泛化能力，验证了集成方法的可行性和合理性．

### 3.3　与经验公式对比

为验证本文模型相较于传统经验公式的优越性，本研究基于测试集数据，将其与四个经验公式[2,17,19,23]进行对比分析．图5的结果显示：本文模型的预测值最接近测量值，离散性最小．表4总结了各模型的性能评价指标，本文模型的预测性能显著优于传统经验公式，平均值、标准差和变异系数分别为0.970，0.285和29.3%．相比Qi等[17]的模型，本文模型的相关系数提高了45.24%，RMSE和MAE分别降低了72.37%和73.89%．Zanke等[23]提出的模型表现最差．总体而言，本文模型在预测性能上明显优于传统经验公式．




□文献[19]；◇文献[17]；△文献[23]；▽文献[2]；○本文模型．

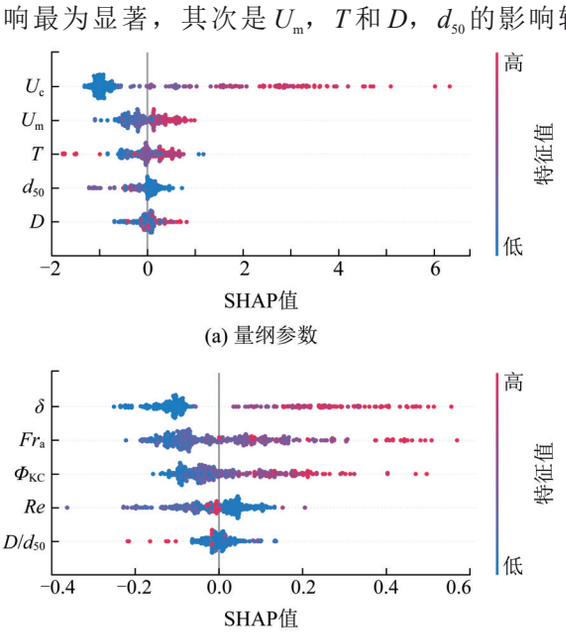
图5　本文模型与经验公式预测结果对比

**表4　本文模型与经验公式性能评价指标对比**

| 模型 | 平均值 | 标准差 | 变异系数/% | RMSE | MAE | 相关系数 |
|---|---|---|---|---|---|---|
| Sumer等[2] | 1.041 | 0.682 | 65.5 | 0.358 | 0.117 | 0.603 |
| Zanke等[23] | 1.591 | 0.917 | 57.6 | 0.425 | 0.575 | 0.519 |
| Qi等[17] | 1.886 | 0.967 | 51.3 | 0.304 | 0.226 | 0.672 |
| Dogan[19] | 1.052 | 0.739 | 70.2 | 0.354 | 0.136 | 0.609 |
| 本文模型 | 0.970 | 0.285 | 29.3 | 0.084 | 0.059 | 0.976 |

### 3.4　全局可解释性

通过SHAP方法可以识别对冲刷深度预测贡献最显著的输入参数[24]．图6为SHAP值汇总图，由图可见：对于量纲参数组合，$U_c$对冲刷深度预测的影响最为显著，其次是$U_m$，$T$和$D$，$d_{50}$的影响较




(a) 量纲参数

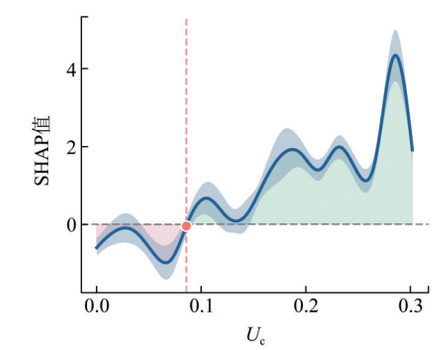
(b) 无量纲参数

图6　SHAP值汇总图

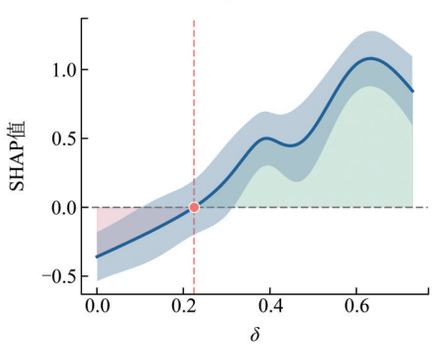
小．该结果与Zhang等[25]的研究结论一致，其研究证实$U_c$和$U_m$在冲刷深度的发展中起主导作用．随着$U_c$值的增大，床面切应力增大，进而导致冲刷深度的增加．$U_m$与$D$也呈现类似的正相关关系．$d_{50}$的增大则增强了床面的抗冲刷强度，进而减小了冲刷深度．$T$展现出复杂的非线性关系，可能是由于数据集中长周期样本较少，因此导致了拟合偏差．

在预测相对冲刷深度的无量纲参数中，$\delta$是最显著的影响参数，$Fr_a$，$Re$，$\Phi_{KC}$和$D/d_{50}$的重要性依次递减．该排序与Guan等[9]的研究结论一致，研究表明$\delta$和$D/d_{50}$分别是对相对冲刷深度影响最大的和最小的参数．具体而言，$\delta$增大表征水流主导作用增强，$Fr_a$升高反映惯性力超越重力，$\Phi_{KC}$增大证明往复流强度提升，均会导致相对冲刷深度的增大．然而，$Re$与$D/d_{50}$并未表现出明显的正负相关关系，且由于流态和其他水动力因素的影响，其贡献较低，对预测结果的影响相对较弱．

图7进一步给出了关键参数$U_c$和$\delta$的SHAP特征依赖关系，图中$p$为统计显著性检验值．可以看出：两者在低取值区间内对应的SHAP值接近于零或为负，表明对冲刷深度的影响有限；而当参数超过临界范围后，SHAP值迅速增大并呈现明显非线性增长趋势，反映了水动力增强导致马蹄涡发展和床沙输运能力显著提高，从而加剧冲刷的发展过程．




(a) $U_c$($R^2$=99.0%)



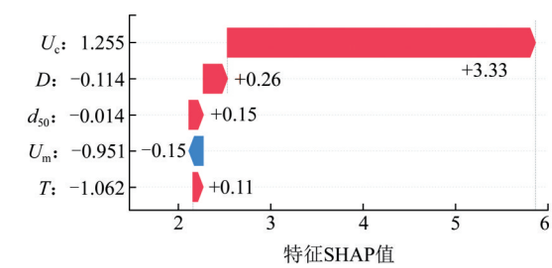

(b) $\delta$($R^2$=96.8%)

正向贡献；　反向贡献．

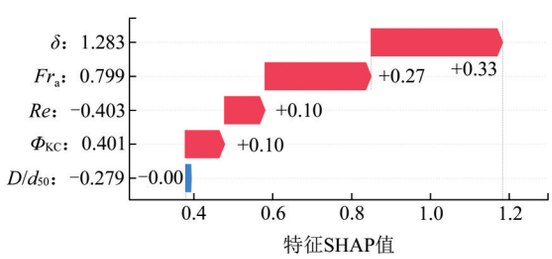
图7　SHAP特征依赖图($p$<0.01)

### 3.5　局部可解释性

图8展示了两种参数组合中随机抽取的两个样本的解释结果，$f(x)$为单个样本的预测值，$E[F(x)]$为基准值．图8(a)中：$f(x)$=5.863，$E[F(x)]$=2.159；图8(b)中：$f(x)$=1.183，$E[F(x)]$=0.379．对于量纲参数组合的样本，$U_c$对预测结果产生正向影响，这与SHAP值汇总图一致．$U_m$和$D$出现了负向贡献，原因在于尽管数据经过归一化处理，参数间的物理尺度仍存在差异，导致贡献分摊效应，同时数据本身的联合分布偏置也可能导致此现象．这表明：无量纲参数组合建模更具优势，不仅能避免上述问题，还能更准确地揭示各输入参数在模型预测中的作用．




(a) 量纲参数样本




(b) 无量纲参数样本

图8　SHAP局部解释图

对于无量纲参数组合的样本，基准值为0.379，$\delta$为主要输入参数，使相对冲刷深度预测值较基准值增加0.33，对预测结果产生正向影响；$Fr_a$，$Re$和$\Phi_{KC}$同样对结果产生正向影响，其SHAP值分别为0.27，0.1和0.1；而$D/d_{50}$则表现为负向影响，SHAP值为0．最终该样本的相对冲刷深度预测值为1.183．其余样本的解释结果整体上也呈现出类似的规律．

## 4　结论

**a**．与SVR，RF和XGBoost模型相比，本文模型在量纲参数组合下，CC和$R^2$平均提高了1.67%和2.27%；在无量纲参数组合下，MAE和RMSE平

均降低了23.39%和21.33%．这表明集成三种树模型有效捕捉了冲刷深度与相关参数之间的复杂非线性关系，且GRIME算法有效提升了模型预测性能．

**b**．与传统经验公式相比，本文模型在相对冲刷深度预测中，RMSE和MAE平均降低了76.35%和67.45%，CC平均提高了63.88%．这验证了模型在预测精度、鲁棒性和稳定性上的优势．

**c**．SHAP全局可解释分析表明：近底流速$U_c$对单桩冲刷深度预测的贡献最大；速度比$\delta$对相对冲刷深度预测的贡献最大．局部可解释分析表明：使用无量纲参数构建的模型具有更强的可解释性，更符合物理变化规律．

本文模型不仅适用于纯波浪与波流共同作用条件下的单桩冲刷预测，还能通过无量纲参数体系与现场监测数据相结合，作为现有冲刷评估或监测系统中的预测模块，具有较强的工程应用潜力．未来将进一步拓展模型在斜向波流、非稳态载荷等复杂工况下的适用性，以满足实际工程的应用需求．

## 参　考　文　献


[1] WANG C，WU Q Y，ZHANG H，et al．Effect of scour remediation by solidified soil on lateral response of monopile supporting offshore wind turbines using numerical model[J]．Applied Ocean Research，2024，150：104143．

[2] SUMER B M，FREDSØE J，CHRISTIANSEN N．Scour around vertical pile in waves[J]．Journal of Waterway，Port，Coastal，and Ocean Engineering，1992，118(1)：15-31．

[3] SUMER B M，FREDSØE J．Scour around pile in combined waves and current[J]．Journal of Hydraulic Engineering，2001，127(5)：403-411．

[4] QI W G，GAO F P．Physical modeling of local scour development around a large-diameter monopile in combined waves and current[J]．Coastal Engineering，2014，83：72-81．

[5] CHEN B，LI S W．Experimental study of local scour around a vertical cylinder under wave-only and combined wave-current conditions in a large-scale flume[J]．Journal of Hydraulic Engineering，2018，144(9)：04018058．

[6] GUAN D W，XIE Y X，CHIEW Y M，et al．Estimation of local scour around monopile foundations for offshore structures using machine learning models[J]．Ocean Engineering，2024，296：116951．

[7] KUMAR L，AFZAL M S．Estimating pier scour depth under combined waves and current using boosting machine-learning models[J]．Acta Geophysica，2024，72(3)：1895-1911．

[8] 余红玲，王晓玲，任炳昱，等．土石坝渗流性态分析的IAO-XGBoost集成学习模型与预测结果解释[J]．水利学报，2023，54(10)：1195-1209．

[9] QI H N，ZHOU J，LI C Q，et al．Comprehensive pier scour depth Prediction：metaheuristic-optimized XGBoost models with interpretability insights[J]．Ocean Engineering，2026，343：123195．

[10] 高永涛，朱强，吴顺川，等．基于AVOA-XGBoost模型的岩爆预测研究[J]．华中科技大学学报(自然科学版)，2023，51(12)：151-157．

[11] SUMER B M，FREDSØE J．Wave scour around a large vertical circular cylinder[J]．Journal of Waterway，Port，Coastal，and Ocean Engineering，2001，127(3)：125-134．

[12] DEY S，SUMER B M，FREDSØE J．Control of scour at vertical circular piles under waves and current[J]．Journal of Hydraulic Engineering，2006，132(3)：270-279．

[13] DEY S，HELKJÆR A，SUMER B M，et al．Scour at vertical piles in sand-clay mixtures under waves[J]．Journal of Waterway，Port，Coastal，and Ocean Engineering，2011，137(6)：324-331．

[14] SUMER B M，HATIPOGLU F，FREDSØE J．Wave scour around a pile in sand，medium dense，and dense silt[J]．Journal of Waterway，Port，Coastal，and Ocean Engineering，2007，133(1)：14-27．

[15] PARK J H，KIM K H．The local scour around a slender pile in combined waves and current[J]．Journal of Korean Society of Coastal and Ocean Engineers，2010，22(6)：405-414．

[16] SUMER B M，PETERSEN T U，LOCATELLI L，et al．Backfilling of a scour hole around a pile in waves and current[J]．Journal of Waterway，Port，Coastal，and Ocean Engineering，2013，139(1)：9-23．

[17] QI W G，GAO F P．Equilibrium scour depth at offshore monopile foundation in combined waves and current[J]．Science China Technological Sciences，2014，57(5)：1030-1039．

[18] LYU X，CHENG Y Z，WANG W S，et al．Experimental study on local scour around submerged monopile under combined waves and current[J]．Ocean Engineering，2021，240：109929．

[19] DOGAN M．The equilibrium depth of wave scour around both slender and large piles[J]．Ocean Engineering，2021，236：109474．

[20] GAUTAM S，DUTTA D，BIHS H，et al．Three-dimensional Computational Fluid Dynamics modelling of

scour around a single pile due to combined action of the waves and current using Level-Set method[J]. Coastal Engineering，2021，170：104002.

[21] GONG E Y，CHEN S G，CHEN X，et al. Large-scale experimental study on scour around offshore monopile under combined wave and current condition[J]. Ocean Engineering，2023，283：115186.

[22] SU H，ZHAO D，HEIDARI A A，et al. RIME：a physics-based optimization[J]. Neurocomputing，2023，532：183-214.

[23] ZANKE U C E，HSU T W，ROLAND A，et al. Equilibrium scour depths around piles in noncohesive sediments under currents and waves[J]. Coastal Engineering，2011，58(10)：986-991.

[24] 吴鹏，陈健，黄珏皓. 基于可解释机器学习方法的月壤力学参数预测[J]. 华中科技大学学报(自然科学版)，2026，54(2)：24-34.

[25] ZHANG Z Y，YU T S，ZHAO Z S. Wave run-up on composite bucket foundation due to random waves：model tests and prediction formulae[J]. Coastal Engineering，2022，177：104177.

(上接第 72 页)

[10] 张欢. 考虑浅水效应的船舶操纵运动数值模拟[D]. 重庆：重庆交通大学，2015.

[11] 刘晗. 船舶近岸壁航行操纵性水动力与运动稳定性研究[D]. 上海：上海交通大学，2017.

[12] 张显库，任俊生，张秀凤. 船舶建模与控制[M]. 大连：大连海事大学出版社，2014.

[13] Anh Khoa Vo，Thi Loan Mai，MyungJun Jeon ，et al. Experimental investigation of the hydrodynamic characteristics of a ship due to bank effect[J]. Journal of Korean Navigation and Port Reserch，2022，46(2)：82-91.

[14] Ch′ng P W，Doctors L J，Renilson M R. A method of calculating the ship-bank interaction forces and moments in restricted water[J]， International Shipbuilding Progress，1993，421(40)：7-23.

[15] NINGSIH W， SUHARTI P H， GHANI M. Performance analysis of IMC-PID controller on PCT-14 air pressure control system[J]. MethodsX，2024，13：102966.

[16] LIU X，HE Y X，ZHANG K，et al. Research on the decision-making method for autonomous navigation for the ocean-going ship in the ships′ routeing waters[J]. Ocean Engineering，2025，323：120641.

[17] 中华人民共和国交通运输部. JTS 165—2025 海港总体设计规范[S]. 北京：人民交通出版社，2025.