

基于数据驱动的岩石微型桩水平极限承载力预测

张新春¹, 邹有云², 杨萌涛¹, 李安琪³

(1.华北电力大学 机械工程系, 河北 保定 071003;

2.北京宇航高科新材料有限公司, 北京 100076;

3.天津送变电工程有限公司, 天津 300171)

摘要:结合数值模拟和多种数据驱动预测模型能够提高山区岩石微型桩水平极限承载力的预测精度。基于正交试验设计,建立了桩长、桩半径和覆土层厚度等变量的三维有限元模型,生成了微型桩在不同服役工况下的承载力数据集。利用BP神经网络、支持向量机(SVM)、极限梯度提升(XGBoost)和随机森林(RF)模型分别构建了承载力预测模型,并通过可决系数(R^2)、平均绝对误差(MAE)和均方根误差(RMSE)等评价指标对模型性能进行对比分析。研究表明:随机森林(RF)模型在预测精度和泛化能力方面表现最佳,其中可决系数 R^2 达到0.9995,平均绝对误差MAE为1.2 kN,均方根误差RMSE约为0.0026 kN。而BP神经网络、SVM和XGBoost模型虽整体精度略低,但能有效反映承载力变化的整体趋势,可作为辅助工具,用于岩石微型桩水平极限承载力的初步预测。

关键词:微型桩;有限元;机器学习预测;预测模型;数据驱动

中图分类号:TP393 **文献标识码:**A **文章编号:**1671-055X(2026)03-0001-11

随着国家电网建设规模的不断扩大和电力输送需求的日益增长,机械化施工已成为提高施工效率、降低人力成本以及提升工程质量的重要发展方向^[1]。微型桩具有施工便捷、对周围环境扰动小和机械化施工强等特点,成为山区岩石地基工程中的一种重要基础。相较于传统大直径桩,微型桩在施工过程中能有效避免岩体大规模开挖,并具有较高的承载能力和经济效益,广泛适用于山区复杂地形和狭窄施工场地^[2]。

近年来,相关学者针对山区岩土施工进行了大量研究。冯忠居等^[3]通过FLAC3D有限元软件建立了地震作用下桩-岩土体-钢管耦合作用的数值模型,分析了变截面钢管混凝土单桩在地震荷载下的动力特性(位移、应力分布、能量耗散等),为抗震设计提供理论依据;张德华等^[4]通过静载实验研究了岩层中设置承力盘的嵌岩桩抗拔性能,分析了承力盘对桩基

收稿日期:2025-04-03

基金项目:河北省专业学位教学案例(库)项目“输电线路工程案例建设”(KCJSZ2024125)。

作者简介:张新春,男,河北沧州人,工学博士,副教授,主要从事输电线路工程研究;邹有云,女,青海西宁人,助理工程师,主要从事机械工程研究;杨萌涛,男,河南汝阳人,硕士研究生,主要从事输电线路工程研究;李安琪,男,河北平泉人,工程师,主要从事输电线路工程研究。

承载力的提升效果,提出了基于实验数据的抗拔承载力计算方法;叶青等^[5]基于内聚力模型,对嵌岩双斜桩的水平承载特性进行了数值模拟和理论分析,探讨了桩身应力分布、变形规律及破坏机制;唐孟雄等^[6]通过实验和数值模拟,揭示了桩端型式对水平承载力、变形特性及破坏模式的影响规律;Wang等^[7]通过振动实验,研究了基岩和覆盖层边坡在锚杆框架桩作用下的动力响应特性,得到了地震荷载下边坡的变形规律及锚杆框架桩的抗震性能;Zhang等^[8]利用激光扫描点云技术,精确测量了嵌岩桩侧壁粗糙度,并通过数值模拟分析了粗糙度对桩基侧摩阻力和整体承载性能;Yan等^[9]针对沿海地区砂质粉质黏土地质条件,研究了嵌岩钻孔桩的承载特性,并通过试验和理论分析,提出了优化设计方法;王敬德等^[10]研究了山区机械化成孔的大孔径硬岩嵌岩桩的承载能力,分析了不同地质参数及桩径对桩基承载性能的影响,为山区复杂地质条件下的桩基设计与施工提供了技术支撑。尽管微型桩基础在山区地质条件下的承载机理逐渐完善,但依靠传统理论计算或有限元分析方法的工作量巨大,难以高效得到桩基的水平承载力。得益于人工智能方法的快速发展,在桩基础领域,机器学习技术的应用逐渐成为研究热点。张鹏远等^[11]提出了一种结合粒子群优化算法(PSO)与BP神经网络的预测模型,成功应用于软土地基中打入桩承载力的预测;Nguyen等^[12]基于3mSOS算法和神经网络优化方法,预测钻孔桩的荷载—位移关系,通过结合机器学习技术和优化算法,显著提高了预测精度,提高了钻孔桩的设计效率;杜轲等^[13]利用了基于支持向量机的物理信息驱动的机器学习技术,精确预测了地震作用下结构的动态响应;苏国韶等^[14]提出基于高斯过程(GP)算法的CFG桩复合地基承载力预测模型,利用GP方法在处理小样本和非线性问题上的优势,显著提高了承载力预测的精度。

综上所述,对于山区岩石微型桩的相关研究还较少,需要引入更为先进的数据驱动方法,为岩石微型桩承载力的精准预测提供新的思路。为此,运用数值模拟计算和机器学习模型预测相结合的方法来实现山区微型桩水平极限承载力预测,采用正交试验设计原理设计微型桩水平承载力数值模拟计算方案,再建立三维有限元数值模型得出在不同参数取值下的承载力,基于数值模拟计算结果所得到的数据集,使用不同机器学习方法建立微型桩的水平承载力预测模型,对不同机器学习模型进行预测分析研究,为机器学习在基础工程领域的应用提供新思路。

1 山区岩石微型桩数值模拟计算

在考虑岩石微型桩水平承载力的主要影响因素及其取值范围的基础上,结合实际工程需求,根据正交试验设计原理制定了数值模拟计算方案。本研究以桩长、桩半径和覆土层厚度为主要变量,设定桩长为8.0~12.0 m之间,桩半径为0.1~0.2 m,覆土层厚度为3.0~7.0 m,通过参数正交得到114组模拟计算结果。这些变量的选择考虑了实际工程中岩石微型桩设计参数的合理性,确保数值模拟能够覆盖多种实际工况,采用正交试验设计方法设计的模拟计算方案具有均衡分散性和综合可比性,而且正交实验能保证各个因素之间相互独立,以较少的模拟计算次数获得较全面而真实地反映自变量与因变量之间的计算结果^[15],桩长、桩半径和覆土层厚度3个变量的取值如表1所示。

表1 水平承载力影响因素取值

编号	桩长/m	半径/m	覆土层/m
1	8.0	0.100	3.0
2	9.0	0.125	4.0
3	10.0	0.150	5.0
4	11.0	0.175	6.0
5	12.0	0.200	7.0

在数值模拟中,采用了三维有限元分析方法,通过ABAQUS有限元分析软件建立岩石微型桩与周围岩土体相互作用的计算模型,对不同变量组合下的岩石微型桩水平承载力进行了系统模拟。为减少模型边界效应对水平承载力的影响,模型岩土体的长、宽和高分别为8.0、8.0和20.0 m,岩土体采用Mohr-Coulomb弹塑性模型,桩体采用弹性本构模型^[16],具体微型桩土模型参数如表2所示。

表2 微型桩模型参数

参数	土体	岩石	微型桩
重度 ρ /(kg/m ³)	1 900.0	2 500.0	2 400.0
弹性模量E/MPa	10.0	5.0×10^3	3.0×10^4
泊松比 μ	0.3	0.25	0.25
黏聚力c/kPa	25.0	120.0	
内摩擦角 φ (°)	13.0	35.0	

微型桩有限元模型示意图如图1所示。




图1 微型桩有限元模型图

利用显式动力有限元方法并借助 ABAQUS 对不同服役工况的承载力进行了数值模拟。土体模型的侧面采用径向约束,以有效控制侧面土体的位移和变形,顶面取自由约束,在该面上的节点可以自由地沿水平面移动和旋转,在模型底部取固定约束,以保证边界节点不发生平移和旋转。考虑桩—土接触面,将其分为法向和切向 2 部分,法向接触面采用硬接触模块,切向接触面采用罚函数,并设置摩擦系数为 0.3,模型采用八节点六面体单元(C3D8R)进行离散,考虑到计算精度和计算效率,模型采用中等的网格密度,并对桩及周围岩土体进行局部化加密^[17]。

嵌岩桩模型荷载—位移曲线有限元结果与试验结果对比如图 2 所示。




图2 实验结果与有限元结果对比

由图 2 可知,在材料本构参数、边界条件、加载条件等完全相同的条件下,有限元模拟结果与白晓宇等^[18]的实验结果吻合较好,从而证明了所提出的有限元模拟结果的可靠性。

依据正交设计的 114 组模拟计算方案,将各方案设定的因素对应的数值模型进行模拟计算,可得 114 组岩石微型桩水平承载力模拟计算方案的计算结果,如表 3 所示。

表 3 微型水平承载力模拟计算结果

编号	桩长/m	半径/m	覆土层/m	水平承载力/kN
1	8.0	0.1	3.0	31.5
2	8.0	0.125	3.0	43.5
3	8.0	0.15	3.0	56.6
4	8.0	0.2	3.0	85.0
⋮	⋮	⋮	⋮	⋮
112	12.0	0.125	7.0	42.9
113	12.0	0.15	7.0	55.4
114	12.0	0.2	7.0	81.2

由表 3 可以看出,各设计参数对水平承载力的影响规律,增加桩半径对水平承载力的提升最显著。当桩长与覆土层厚度固定时,桩半径从 0.1 m 增至 0.2 m,承载力提升幅度均超过 100%。

2 预测模型构建

2.1 预测模型简介

根据正交试验设计所获得的114组数据集,选用BP神经网络、支持向量机(support vector machine, SVM)、极限梯度提升(eXtreme gradient boosting, XGBoost)和随机森林(random forest, RF)4种典型机器学习模型来构建预测模型。这一选择主要基于研究数据特征与模型原理的匹配性:数据集样本量有限,且输入变量(桩长、桩半径、覆土层厚度)与输出(水平极限承载力)之间呈现复杂的非线性关系。所选模型在处理此类“小样本、强非线性”回归问题时各具优势且原理互补。其中BP神经网络是一种经典的前馈型神经网络,通过反向传播算法调整权重和偏置,利用非线性激活函数(如Sigmoid、ReLU等)处理输入数据,能够适应复杂的非线性关系^[19],适用于分类、回归和时间序列预测等任务。然而,其训练效率较低,对超参数(如学习率、层数、节点数等)敏感,且容易陷入局部最优或过拟合。SVM基于统计学习理论,在小样本条件下具有良好的泛化能力,并能借助核函数有效刻画变量间的非线性关系,是一种基于统计学习理论的监督学习算法,通过最大化分类间隔寻找最优超平面^[20],并利用核函数(如RBF核、多项式核等)处理线性不可分问题。研究表明,XGBoost模型^[21]和RF^[22]模型能高效捕捉多个设计参数之间的交互效应并抑制过拟合,二者分别通过梯度提升(Boosting)和袋装法(Bagging)的核心机制提升预测性能。通过对不同机理的模型进行系统对比,可以更为全面地评估数据驱动方法在研究特定问题中的性能差异与适用性,从而保证研究结论的可靠性。

2.2 预测模型对比分析

采用可决系数(R^2)、平均绝对误差(MAE)和均方根误差(RMSE)3个指标,初步评估模型的预测性能。其中, R^2 用于衡量模型对因变量变异的解释能力,其计算方法见式(1):

$$R^2 = 1 - \frac{SS_{\text{res}}}{SS_{\text{tot}}} \quad (1)$$

式中: $R^2 = 1 - \frac{SS_{\text{res}}}{SS_{\text{tot}}}$ 为残差平方和, $SS_{\text{tot}} = \sum_{i=1}^n (y_i - \hat{y})^2$ 为总平方和。 R^2 越接近1,表明模型的拟合效果越好。

MAE反映了预测值与实际值之间绝对误差的平均水平,其计算方法见式(2):

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (2)$$

MAE值越小,说明模型的预测精度越高。

均方根误差(RMSE)通过计算误差平方的平均值的平方根,衡量了预测误差的离散程度,其计算方法见式(3):

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (3)$$

RMSE值越小,表明模型的预测稳定性越强。

BP神经网络、SVM、XGBoost和RF4种模型的评价指标如图3所示。




图3 BP神经网络、SVM、XGBoost和RF4种模型的评价指标

图3展示了BP神经网络、SVM、XGBoost和RF这4种模型的 R^2 、MAE和RMSE,从拟合和预测效果来看,RF效果最好,之后依次是SVM、BP神经网络和XGBoost。综合而言,RF模型是预测任务的最佳选择,适合处理复杂非线性关系且具有良好的泛化能力,而BP神经网络、SVM模型和XGBoost模型则可用于整体趋势预测或作为辅助分析工具。

3 模型预测分析

BP神经网络、SVM、XGBoost和RF四种模型对岩石微型桩水平极限承载力的预测值与真实值对比如图4所示。

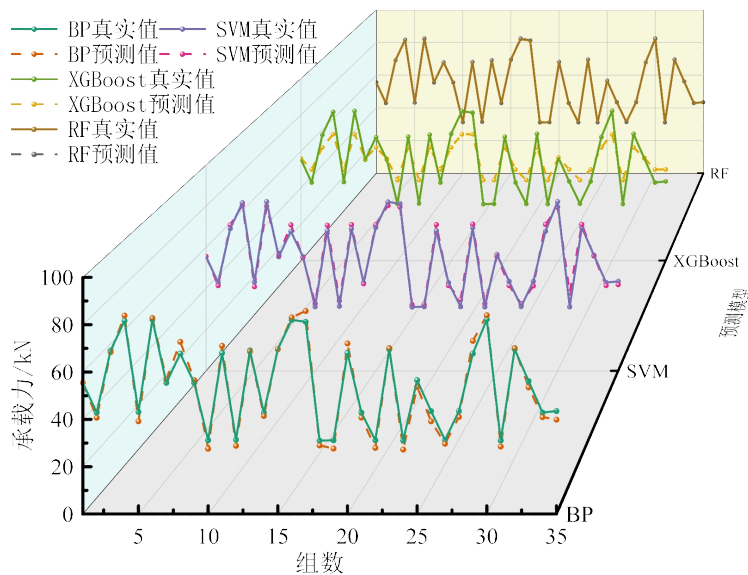


图4 BP神经网络、SVM、XGBoost和RF四种模型预测值与真实值对比

从图4得知,SVM与RF模型均能较好地反映出真实值的波动特征,且二者曲线形态相近,表明它们均有效学习了参数与承载力间的主要物理关系。然而,在局部精度上,尤其是在极值点附近,模型间存在显著差异。BP神经网络能够捕捉整体变化趋势,但在快速变化区域和极值点的预测精度较低,表现为响应滞后,反映其对复杂非线性关系的拟合能力不足。SVM模型在中间承载力区间内预测效果较佳,预测曲线与真实值曲线接近,但在极值点附近未能准确捕捉极值的幅值变化。XGBoost模型对测试集的预测值与真实值整体趋势一致,但数据点存在偏差,表明模型对全局趋势拟合较好,但局部预测精度仍需提升。相比之下,RF模型不仅保持了与SVM相似的优秀趋势捕捉能力,更在全局和局部均展现出最高的预测精度,其预测曲线能够精准地跟随真实值变化,对极值点的捕捉效果尤为突出,但在部分数据点上表现出轻微过拟合现象,可能对局部噪声较敏感。

BP神经网络、SVM、XGBoost和RF4种模型在训练集和测试集上的回归曲线如图5所示。

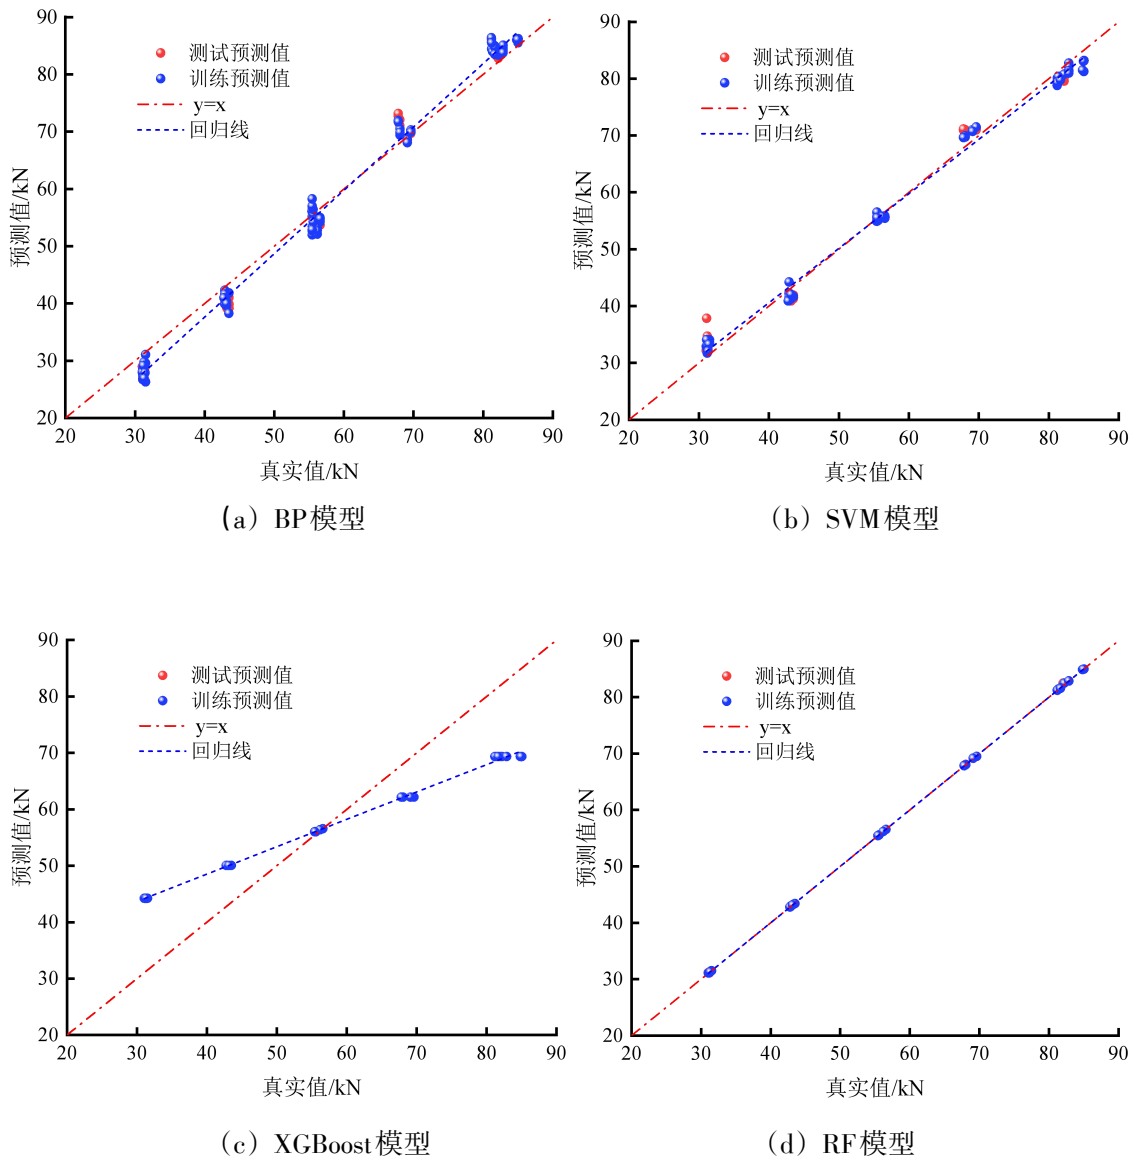


图5 模型回归曲线

从图5中可以看出, BP神经网络的预测值分布较为集中, 回归线与 $y=x$ 直线(此线代表预测值等于真实值)接近, 说明模型对训练集和测试集的整体拟合较好。然而, 从测试集的分布来看, 部分数据点的偏差较大, 尤其在高承载力范围(>70.0 kN)出现了回归线轻微偏离的现象, 表明BP神经网络在处理复杂非线性数据时存在一定局限性。SVM模型的回归表现优于BP网络, 测试集数据点分布较为均匀, 回归线与 $y=x$ 直线更加贴近。模型在训练集和测试集上的一致性较高, 显示出SVM在捕捉整体趋势和局部非线性关系方面的能力较强, 但在低承载力范围(<40.0 kN)测试点仍略有偏差。XGBoost模型的回归线存在一定偏离, 测试集数据点分布出现轻微系统性误差, 表明模型可能在处理特定范围内的数据时未能完全拟合, 但其预测趋势可作为辅助分析使用。RF的回归表现最佳, 训练集和测试集的数据点几乎完全分布在 $y=x$ 直线附近, 预测值与真实值重合度高, 反映出RF模型对岩石微型桩水平极限承载力数据的强大拟合能力, 能够很好地捕捉复杂的非线性关系, 同时具有较好的泛化能力。

BP神经网络、SVM、XGBoost和RF 4种模型在测试集上的预测值与真实值之间的误差分析如图6所示。

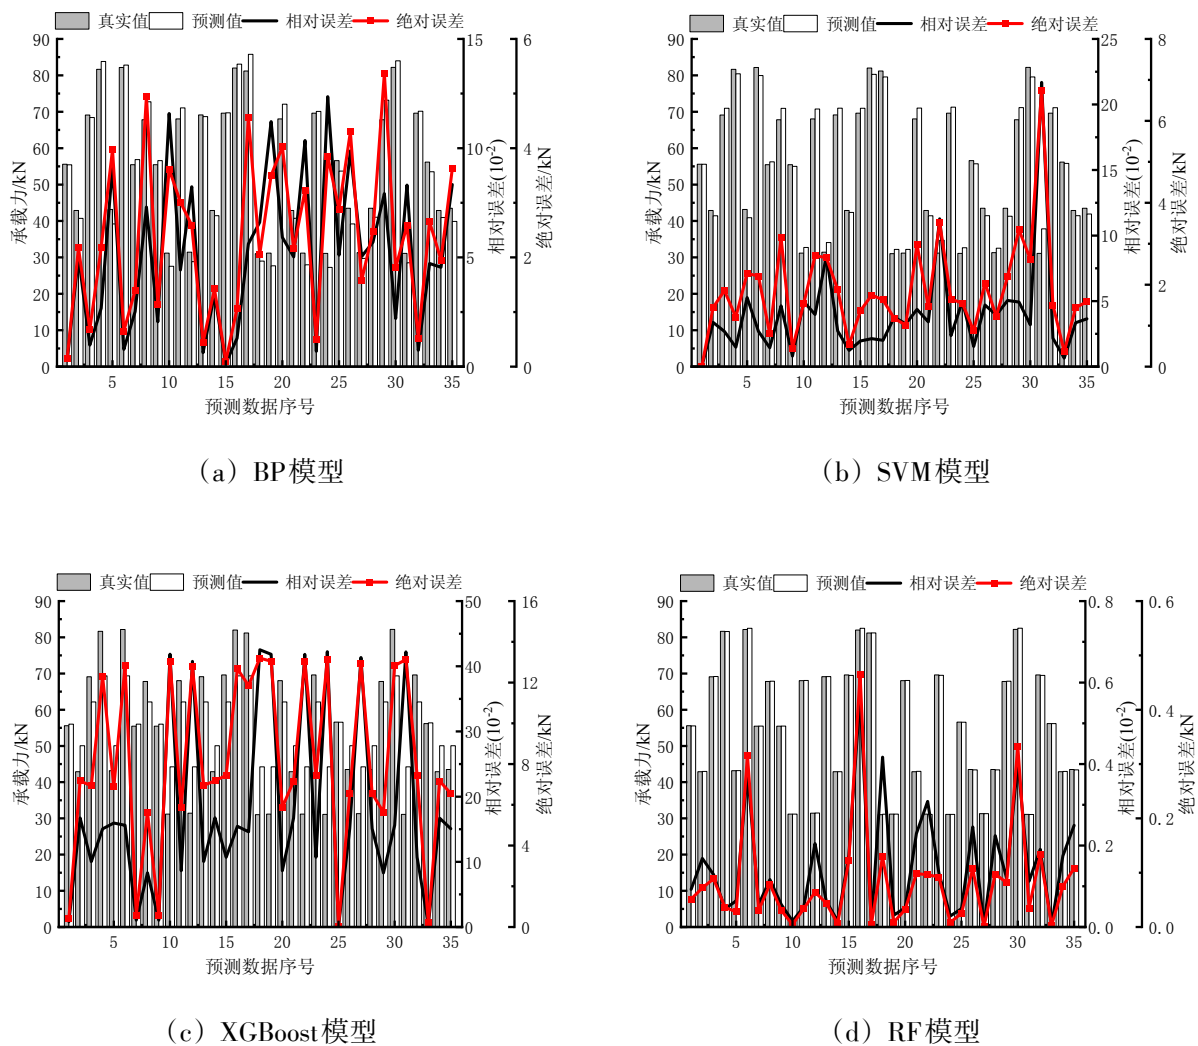


图6 误差分析曲线

从图6(a)可以看出, BP神经网络在大部分数据点的预测值与真实值相对接近,但其相对误差和绝对误差在局部峰值附近显著增大,显示出模型对极值点的预测能力不足,误差主要集中在快速上升或下降的区域。这可能是BP网络对数据的非线性特征捕捉有限,导致模型在复杂关系下表现不足;从图6(b)看出, SVM模型的误差分布更加均匀,相对误差和绝对误差的峰值有所减小,表明 SVM对整体趋势的预测能力较强。特别是在中间值范围(40.0~70.0 kN)表现较为优异,但在极值附近误差较高,表明 SVM对快速变化的承载力特征拟合能力有限,但总体误差幅度小于BP网络;从图6(c)看出, XGBoost模型的误差表现最差,其绝对误差与相对误差的整体分布及峰值均为四者中最高,表明在该数据集与参数设置下, XGBoost模型的预测稳定性不足,泛化能力较弱;从图6(d)看出, RF的误差表现最佳,绝对误差和相对误差的整体幅度最低,且误差分布更加均匀,特别是在极值区域,误差幅度明显低于其他模型。RF在拟合复杂非线性关系和处理噪声数据方面展现了出色的能力,其误差曲线与真实值趋势高度吻合,几乎没有明显偏离。

BP神经网络、SVM、XGBoost和RF 4种模型在训练集和测试集上的绝对误差分布如图7所示。

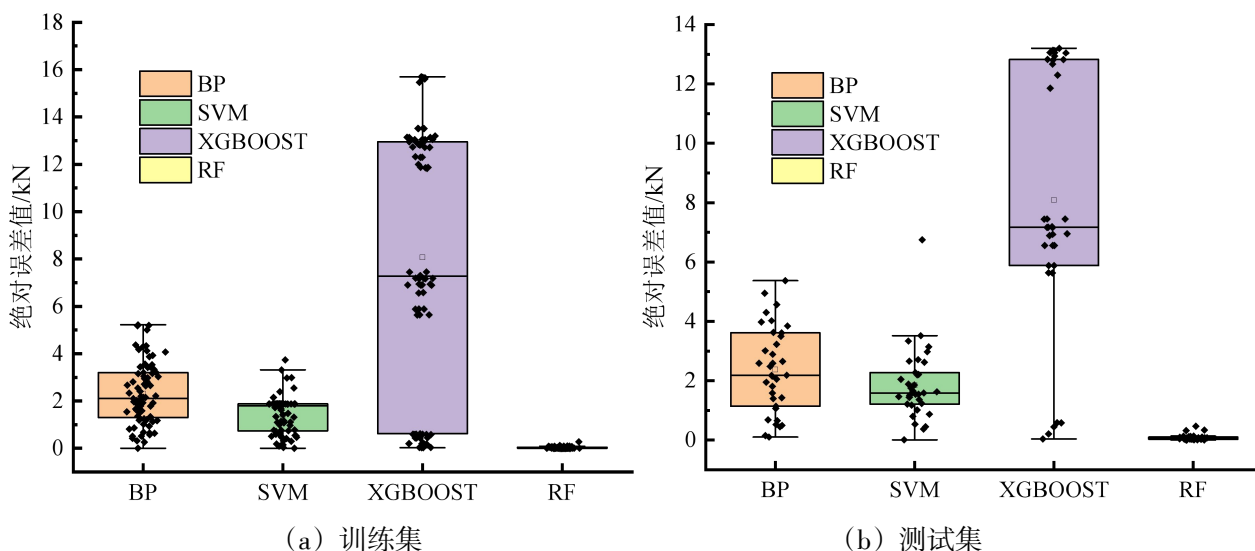


图7 BP神经网络、SVM、XGBoost和RF四种模型训练误差箱线图

从图7可以看出, BP模型的误差范围较宽,箱体分布显示误差的中位数约为3.0 kN偏高,同时存在少量离群点,表明模型在部分数据点上的预测存在较大偏差。SVM模型的误差箱体明显比BP小,显示误差分布更加集中,且中位数低于BP,约为2.0 kN,同时边缘离群点较少,表明SVM在测试集上的预测更加稳定。XGBoost模型的误差范围最广,箱体和须状部分的跨度较大,尤其是存在一些高离群点,极端误差显著,表明模型在部分复杂数据点上表现不够稳定。RF的误差最小,显示误差分布极为集中,中位数接近于0,误差控制为0~1.5 kN,离群点数量少,反映RF模型在测试集上的预测表现最为稳定和精确。

4 研究结论

通过数值模拟和机器学习预测相结合的方法,构建了岩石桩水平承载力的预测模型,提出一种基于机器学习的微型桩水平承载力快速预测方法。基于某输电线路微型桩工程地质

参数,系统探讨了BP神经网络、SVM、XGBoost和RF的预测模型构建方法,完成了对岩石桩水平承载力的可靠性分析与评估,得到如下结论:

第一,桩半径的增加可显著提高水平承载力,而桩长和覆土层厚度对水平承载力呈现明显非线性的影响,采用机器学习预测可以捕捉复杂的非线性关系,实现对水平承载力较为精准的预测。

第二,通过BP神经网络、SVM、XGBoost和RF4种模型的对比分析,在本次研究中,RF模型的可决系数 R^2 达到0.996,平均绝对误差MAE为1.2 kN,均方根误差RMSE在1.5 kN以内,在预测精度和泛化能力方面表现最佳,特别是在捕捉复杂非线性关系和极值点时效果显著。

第三,SVM模型在中间承载力区间的预测精度较高,但在极值点附近略有不足;BP神经网络和XGBoost模型对数据整体趋势的拟合能力较好,不需要平滑处理,即可得到稳定性良好的曲线,但在复杂非线性关系的处理上稍显不足。

5 参考文献

- [1] 薛正元,余亮,杨明,等.山区特高压输电线路岩石锚杆基础的应用及造价分析[J].武汉大学学报(工学版),2022,55(S1):142-147.
- [2] 沈茂丁,孟建,崔少东.微型桩在山区油气管道防护中的变形机制模型试验研究[J].自然灾害学报,2023,32(6):208-219.
- [3] 冯忠居,张亮,张聪,等.地震作用下变截面钢管混凝土单桩动力响应[J].河北大学学报(自然科学版),2024,44(2):122-130.
- [4] 张德华,郭腾,崔隽.岩层设承载力盘的嵌岩桩抗拔静载试验及计算方法研究[J].土木工程学报,2021,54(8):120-128.
- [5] 叶青,郭伟,任宇晓,等.基于内聚力模型的嵌岩双斜桩水平承载特性分析[J].岩土工程学报,2024,46(S1):233-238.
- [6] 唐孟雄,凌造,刘春林,等.桩端型式对嵌岩随钻跟管桩承载性能的影响[J].岩石力学与工程学报,2022,41(S1):3053-3062.
- [7] Wang Lei, Pu Qianhui, Chen Guangpeng, et al. Dynamic responses characteristics of bedrock and overburden layer slope with anchored frame piles based on shaking table test[J]. Scientific Reports, 2025, 15:4574.
- [8] Zhang Junbao, Hu Yulie, Wang Yiteng, et al. Sidewall roughness measurement and bearing performance simulation of rock-socketed piles based on laser scanning point cloud[J]. Applied Sciences, 2025, 15:889.
- [9] Yan Nan, Hao Zengming, Bai Xiaoyu, et al. Load-bearing characteristics and optimization design for rock-socketed bored piles in sandy silty clay in coastal areas[J]. Soil Dynamics and Earthquake Engineering, 2025, 190:109207.
- [10] 王敬德,张新春,刘增炜,等.山区机械化成孔的大孔径硬岩嵌岩桩承载能力[J].河北大学学报(自然科学版),2024,44(6):561-570.
- [11] 张鹏远,吴宝峰.基于PSO算法优化BP神经网络的打入桩承载力预测模型研究[J].水利科学与寒区工程,2024,7(11):62-65.
- [12] Nguyen T, Ly K D, Shiau J, et al. Optimizing load-displacement prediction for bored piles with the 3mSOS algorithm and neural networks[J]. Ocean Engineering, 2024, 304:117758.
- [13] 杜轲,吴文贤,林志鹏,等.基于物理驱动支持向量机方法的地震作用下结构动力响应求解[J].振动与冲击,2025,44(3):284-290.

- [14] 苏国韶,张研,燕柳斌. CFG 桩复合地基承载力预测的高斯过程模型[J]. 计算机工程与应用,2011,47(4):236–238.
- [15] 杜双奎. 试验优化设计与统计分析[M]. 北京:科学出版社,2020:143–145.
- [16] 季雨坤,王钦科,赵国良,等. 斜坡上嵌岩抗拔桩竖向承载变形特性模型试验及数值模拟[J]. 岩土力学,2023,44(6):1604–1614.
- [17] 李克先,雷刚,李健,等. 土岩组合地层深基坑桩撑体系变形及受力分析[J]. 科学技术与工程,2021,21(1):310–317.
- [18] 白晓宇,刁浩杰,银吉超,等. 大直径嵌岩灌注桩承载特性试验与有限元模拟[J]. 重庆交通大学学报(自然科学版),2024,43(9):25–33.
- [19] Zhang Xinchun, Gu Lirong, Yin Xiaodi, et al. Mechanical behavior and failure prediction of cylindrical lithium-ion batteries under mechanical abuse using data-driven machine learning [J]. Journal of Applied Mechanics-Transactions of the ASME, 2025, 92:021003.
- [20] Ai Yuhao, Song Bin, Wu Shaocheng, et al. Diagnosis of reverse-connection defects in high-voltage cable cross-bonded grounding system based on ARO-SVM[J]. Sensors, 2025, 25:590.
- [21] Dashtgoli S D, Dehnad H M, Mobinipour A S, et al. Performance comparison of machine learning algorithms for maximum displacement prediction in soldier pile wall excavation [J]. Underground Space, 2024, 16:301–313.
- [22] Yaychi B M, Esmaeili F M. Estimating axial bearing capacity of driven piles using tuned random forest frameworks[J]. Geotechnical and Geological Engineering, 2024, 42:7813–7834.

Prediction of Horizontal Ultimate Bearing Capacity of Rock Micro-Piles Based on Data-Driven Technology

Zhang Xinchun¹, Zou Youyun², Yang Mengtao¹, Li Anqi³

(1.Department of Mechanical Engineering, North China Electric Power University, Baoding 071003,China;

2.Beijing Aerospace High-Tech New Materials Co., Ltd., Beijing 100076, China;

3.Tianjin Electric Power Transmission and Transformation Engineering Co., Ltd., Tianjin 300171, China)

Abstract: To improve the prediction accuracy of the horizontal ultimate bearing capacity of rock micro-piles in mountainous areas, a comprehensive research method combining numerical simulation and multiple data-driven prediction models is proposed. Based on the orthogonal experimental design, the three-dimensional finite element model with variables such as pile length, pile radius, and overburden soil thickness are established, and a dataset of bearing capacity of micro-piles under different service conditions is generated. Using the BP neural network, support vector machine (SVM), extreme gradient boosting (XGBoost), and random forest (RF), the prediction models for bearing capacity were constructed, and the model performance is compared and analyzed by the evaluation metrics including the coefficient of determination (R^2), mean absolute error (MAE), and root mean square error (RMSE). The results show that the random forest model achieves the best prediction accuracy and generalization ability, with R^2 reaching 0.999 5, MAE of 1.2 kN, and RMSE of approximately 0.002 6 kN. Although the BP neural network, SVM, and XGBoost models have slightly lower overall accuracy, they can effectively capture the overall trend of bearing capacity variation and can serve as auxiliary tools for preliminary prediction of the horizontal ultimate bearing capacity of rock micro-piles.

Keywords: Micro-piles; Finite element; Machine learning prediction; Prediction model; Data-driven

[责任编辑:杨 洪 江 伟]