

# 路基压实度预测模型的建立及评价

The Establishment and Evaluation of the Prediction Model of Subgrade Compaction Degree

龙 凯<sup>1</sup>, 邓经祥<sup>2</sup>, 李鸿钊<sup>3</sup>, 惠 冰<sup>3</sup>, 石亚强<sup>2</sup>, 张文俊<sup>3</sup>

(1. 济宁市公路事业发展中心, 济宁 272008; 2. 葛洲坝集团交通投资有限公司, 宜昌 443005;  
3. 山东省交通科学研究院, 济南 250031)

**摘要:** 路基压实度与道路的质量密切相关, 直接影响工程的稳定性和耐久性。为了建立路基压实度预测模型, 开展路基压实度现场试验, 通过控制碾压次数、碾压速度和含水率的试验方法对压实度的影响规律, 采用非线性回归、决策树、支持向量机、神经网络和 XGBoost 等算法建立了 6 个压实度预测模型, 对其预测性能评价。结论表明: 路基压实度与碾压次数呈正比, 而与碾压速度呈反比。当含水率处于最优含水率时, 路基压实度最大。含水率、碾压次数、碾压速度对压实度的影响依次降低; 支持向量机模型对于训练集预测效果较差, 决策树模型对于预测集的预测效果较差, 不适用于路基压实度的预测; 幂函数和对数函数两种非线性回归模型, 神经网络和 XGBoost 两种机器学习模型适用于路基压实度的预测。机器学习的预测性能要高于非线性回归模型。

**关键词:** 路基压实度; 现场试验; 预测模型; 性能评价; 机器学习

中图分类号: U447 文献标志码: A 文章编号: 1005-8249 (2025) 01-0124-06

DOI: 10.19860/j.cnki.issn1005-8249.2025.01.023

LONG Kai<sup>1</sup>, DENG Jingxiang<sup>2</sup>, LI Hongzhao<sup>3</sup>, HUI Bing<sup>3</sup>, SHI Yaqiang<sup>2</sup>, ZHANG Wenjun<sup>3</sup>

(1. Ji'ning Highway Development Center, Ji'ning 272008, China;

2. Gezhouba Group Transportation Investment Co., Ltd., Yichang 443005, China;

3. Shandong Transportation Institute, Ji'nan 250031, China)

**Abstract:** Subgrade compaction is closely related to the quality of the road and directly affects the stability and durability of the project. In order to establish the prediction model of subgrade compaction, carry out the field test of subgrade compaction, through the control of the number of rolling, rolling speed and water content of the test method on the compaction of the law, the use of nonlinear regression, decision tree, support vector machine, neural lattice and XGBoost algorithms to establish a six compaction prediction model, and its prediction performance evaluation. The conclusion shows: The subgrade compaction degree is positively proportional to the number of rolling times and inversely proportional to the rolling speed. When the water content is at the optimal water content, the subgrade compaction is maximum. The effects of water content, number of rolling times and rolling speed on compaction are reduced in order; the support vector machine model has a poor prediction effect on the training set, and the decision tree model has a poor prediction effect on the prediction set, which is not applicable to the

基金项目: 山东省交通运输科技项目 (2023B45)。

作者简介: 龙 凯 (1988—), 男, 硕士, 工程师, 研究方向: 从事公路管理工作。

通信作者: 李鸿钊 (1998—), 男, 硕士, 助理工程师, 研究方向: 路基压实。

收稿日期: 2024-03-26

prediction of subgrade compaction; the two nonlinear regression models of the power function and the logarithmic function, and the two machine learning models of the neural network and the XGBoost are applicable to the prediction of the compaction degree of the subgrade. The prediction performance of machine learning is higher than the nonlinear regression model.

**Key words:** subgrade compaction degree; field test; predictive modeling; performance evaluation; machine learning

## 0 引言

基础是建筑物最下部的承重构件, 承受建筑物的全部荷载, 其施工质量对于上覆结构的耐久性和长期功能有着重要的影响。压实作业是作为路基施工的重要工序, 是保证上覆结构使用寿命和性能的重要前提<sup>[1-2]</sup>。路基压实度是路基压实质量的关键指标之一, 准确监测和预测路基压实度, 对于控制工程质量和降低工程成本具有重要意义<sup>[3-4]</sup>。

传统的压实检测方法主要有灌砂法、环刀法、核子密度仪法和钻芯法等, 但这些方法存在以下缺点: 操作要求高, 采用过程难以精确控制; 样本数量多, 工作量大, 检测速度慢; 采样过程对土壤造成较大的扰动, 影响测量值的准确性和探测层的稳定性。因此, 有必要建立一种有效预测压实度的方法, 以支持工程时间中更有效的决策<sup>[5-7]</sup>。

传统的预测方法主要采用多元回归分析建立目标参数的预测方程, 然而, 该方法需要提前预设拟合方程, 针对复杂和高度非线性数据时并不是十分有效。随着计算机算法的发展, 机器学习在工程案例中得到了较大的应用和发展, 在处理复杂的高度非线性数据时具有较少的假设和约束<sup>[8-10]</sup>。一些学者已经采用机器学习方法来预测压实参数。Kurnaz 等<sup>[11]</sup>分别使用群体数据处理方法 (GMDH)、极限学习机 (ELM)、双向递归神经网络 (BRNN) 和支持向量机 (SVM) 对土壤压实参数进行预测, 结果表明, ELM 测试结果最佳, 支持向量机预测精度最低; 同样, Jayan 等<sup>[12]</sup>利用 177 组试验室测量数据, 通过神经网络模型预测了最大干密度和最佳含水率, 发现人工神经网络预测压实参数的能力较好, 精度较高; Wang 等<sup>[13]</sup>利用多表达式编程 (MEP) 开发了一种新的土壤压实参数预测模型, 并证明了该模型可以很好地预测数据库中各种土壤的压实参数; Moinfar 等<sup>[14]</sup>利用自适应神经模糊推理系统 (ANFIS) 预测了拖拉机四轮驱动、后轮驱动、前

轮驱动、行驶速度等因素对土壤压实度的影响, 相关系数达到 0.99; Wang 等<sup>[15]</sup>利用随机森林算法根据路基土的力学特性和压实力预测路基土的压实程度, 预测精度较好; Liu 等<sup>[16]</sup>通过选取自然密度、含水率、最优含水率等参数, 建立了基于人工神经网络的压实度预测模型, 表明该模型可以有效预测土壤压实度。

路基压实度与土体性质和压实条件等影响因素有关。含水率是土体的重要参数, 也是预测路基压实度的最重要的因素。现场施工过程中, 压实设备的碾压次数以及碾压速度同样影响着路基压实度。因此, 选择含水率、碾压次数和碾压速度作为影响因素, 进行现场试验获得不同影响因素下的路基压实度, 然后采用多元非线性回归、决策树、支持向量机、神经网络、XGBoost 等 5 种方法建立路基压实度的预测模型, 并对这些模型进行了分析和比较, 以选择最为合适的压力度预测模型。

## 1 材料和方法

### 1.1 工程概况

以某高速公路工程 (K12 + 095 ~ K12 + 131 段) 为例, 该路段长 36 m, 宽 24.5 m, 路基填土最大干密度为 1.76 g/cm<sup>3</sup>, 最佳含水率为 16%。

### 1.2 测试方案

选择碾压次数、碾压速度和含水率 3 个影响因素对路基压实度开展试验研究, 其中, 碾压次数设置为 6、8、10, 碾压速度设置为 2.0、2.5、3.0 km/h, 路基填料的含水率设置为 14%、16%、18%, 采用全面试验方案, 见表 1。

现场试验纵向每 10 m 作为一个试验区, 共设置 27 个试验区, 根据测试方案进行碾压作业, 并采用灌砂法对路基压实度进行监测。为保证试验数据的准确度, 每个试验区均进行 3 次灌砂试验获取试验数据。

## 道桥技术

表 1 路基压实度测试方案

Table 1 Subgrade compaction test programme

试验编号	碾压次数/次	碾压速度/(km/h)	含水率/%	试验编号	碾压次数/次	碾压速度/(km/h)	含水率/%
1	6	2.0	14	15	8	2.5	18
2	6	2.0	16	16	8	3.0	14
3	6	2.0	18	17	8	3.0	16
4	6	2.5	14	18	8	3.0	18
5	6	2.5	16	19	10	2.0	14
6	6	2.5	18	20	10	2.0	16
7	6	3.0	14	21	10	2.0	18
8	6	3.0	16	22	10	2.5	14
9	6	3.0	18	23	10	2.5	16
10	8	2.0	14	24	10	2.5	18
11	8	2.0	16	25	10	3.0	14
12	8	2.0	18	26	10	3.0	16
13	8	2.5	14	27	10	3.0	18
14	8	2.5	16				

## 1.3 预测方法

共采用非线性回归方法（幂函数、对数函数）、决策树、支持向量机、神经网络、XGBoost 5 种算法建立 6 种路基压实度的预测模型。

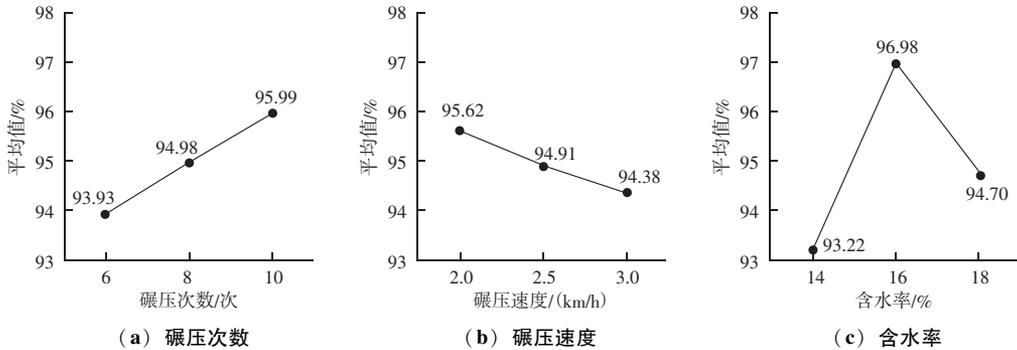


图 1 路基压实度平均值

Fig. 1 Average value of subgrade compaction

## 2.2 模型性能评价

## 2.2.1 评价指标

为了有效评价这些预测模型的效果和性能，选择相关系数（ $R^2$ ）、均方根误差（ $RMSE$ ）、均方误差（ $MSE$ ）和平均绝对误差（ $MAE$ ）作为评价指标，具体如下：

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

## 2 结果与讨论

## 2.1 影响因素分析

根据路基压实度测试结果，计算各因素各水平的平均值，如图 1 所示，路基压实度与碾压次数呈正比，而与碾压速度呈反比，二者均近似线性关系。当填土含水率处于最优含水率（16%）时，路基压实度最大。因此，碾压次数为 10 次，碾压速度为 2.0 km/h，含水率为 16% 时，即工况 20，路基压实度最大。

进一步地，采用决策树模型和 XGBoost 模型可以计算出各影响因素的权重，决策树模型，碾压次数、碾压速度和含水率的权重值分别为 0.17、0.06 和 0.76；XGBoost 模型，碾压次数、碾压速度和含水率的权重值分别为 0.33、0.15 和 0.52。由此可知，含水率对于路基压实度的影响最大，碾压次数次之，碾压速度的影响最小。在实际工程中，碾压次数的增加、碾压速度降低会大大增加施工成本，降低经济效益，因此，路基填料的含水率对于路基压实工作至关重要。

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

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

$$MAE = \frac{1}{n} \sum_{i=1}^n \left| \hat{y}_i - y_i \right| \quad (4)$$

式中： $y_i$  为路基压实度的试验值； $\hat{y}_i$  为路基压实度的模型预测值； $\bar{y}_i$  为路基压实度的平均试验值； $n$  为样本数量。

一般来说，这些评价指标的评价标准如下：相关系数  $R^2$  ( $0 < R^2 < 1$ ) 越大，建模的精度越高；

$MSE$  值越小, 拟合效果越好;  $RMSE$  值越小, 模型的预测能力越好;  $MAE$  值越小, 试验值与预测值的偏差越小。

### 2.2.2 评价结果

将现场试验获得的数据可以分为两部分: 训练集和预测集。训练集用于模型的训练, 预测集用于对训练集模型的结果进行数据测试, 验证其泛化能力。根据数据总量确定分配给每个训练集和预测集的数据比例。当数据总量较大时, 用于训练和预测的数据比例分别为 80% 和 20%; 当数据总量有限时, 对应的比例分别为 70% 和 30%。在此研究中, 数据样本总数为 27, 总量有限, 因此选择 18 组作为训练数据, 9 组作为预测数据。随机选择训练集和预测集, 在文中, 试验编号 1、2、3、6、7、8、9、10、12、13、14、16、17、20、23、25、26 和 27 为训练集, 试验编号 4、5、11、15、18、19、21、22 和 24

为预测集。

采用 MATLAB 对幂函数、对数函数、决策树、支持向量机、神经网络以及 XGBoost 等 6 种模型进行了建模和计算, 运算参数见表 2。路基压实度预测结果如图 2 和表 3 所示, 对于训练集, 当采用碾压次数、碾压速度和含水率 3 个变量数据预测路基压实度时, 幂函数、对数函数、决策树、神经网络以及 XGBoost 模型表现出很好地预测性能, 相关系数 ( $R^2$ ) 均大于 0.95, 均方根误差 ( $RMSE$ )、均方误差 ( $MSE$ ) 和平均绝对误差 ( $MAE$ ) 均很小, 接近于 0。然而支持向量机模型的准确率较低, 其相关系数 ( $R^2$ ) 仅为 0.597, 而其他评价指标均显著大于其他的模型。可以看出, 在模型的训练阶段, 支持向量机模型已经不能准确的预测路基压实度, 所以在预测集中不会表现出较好的预测性能 ( $R^2$  仅为 0.578), 因此, 支持向量机模型不适合路基压实度的预测。

表 2 预测模型参数  
Table 2 Predictive model parameters

模型	参数			
幂函数	$K = -106.907 + 0.539x - 0.1376y + 25.020z - 0.7703z^2$			
对数函数	$K = 603.888 - 24.399z + 4.129\ln y + 394.414\ln z$			
决策树模型	数据预处理	归一化	节点分裂最小样本数	2
	节点分裂标准	Squared_error	叶节点最小样本数	1
	节点分裂方式	best	树最大深度	不限制
支持向量机	数据预处理	归一化	核函数系数值	0.01
	误差项惩罚函数	1.0	模型收敛参数	0.001
	Kernel	rbf	最大迭代次数	2000
神经网络	数据预处理	归一化	L2 正则化系数	$1.0E-4$
	隐层神经元设置	(100)	初始化学学习率	$1.0E-4$
	激活函数	Logistic	最大迭代次数	200
	权重优化方法	Ibfgs	优化容忍度	0.001
XGBoost	提升器类型	gbtree	特征采集率	1.0
	学习器数量	100	最小子节点权重	1.0
	学习率	0.1	分裂收益阈值	0.0
	树最大深度	6	L1 正则化	0.0
	样本采集率	1.0	L2 正则化	1.0

注:  $K$  为路基压实度;  $x$  为碾压次数;  $y$  为碾压速度;  $z$  为含水率。

表 3 预测模型性能评价  
Table 3 Evaluation of prediction model performance

模型	训练集				预测集			
	MAE	MSE	RMSE	$R^2$	MAE	MSE	RMSE	$R^2$
幂函数	0.259 6	0.118 0	0.343 6	0.972 6	0.364 6	0.193 0	0.439 3	0.896 7
对数函数	0.281 9	0.138 1	0.371 6	0.967 9	0.318 7	0.152 0	0.389 9	0.918 6
决策树	0.000 0	0.000 0	0.000 0	1.000 0	0.681 1	0.588 5	0.767 1	0.685 0
支持向量机	0.946 1	1.736 7	1.317 8	0.596 5	0.669 5	0.787 5	0.887 4	0.578 4
神经网络	0.069 9	0.009 1	0.095 2	0.997 9	0.285 4	0.114 7	0.338 7	0.938 6
XGBoost	0.033 1	0.003 1	0.055 7	0.999 3	0.266 4	0.125 7	0.354 6	0.932 7

## 道桥技术

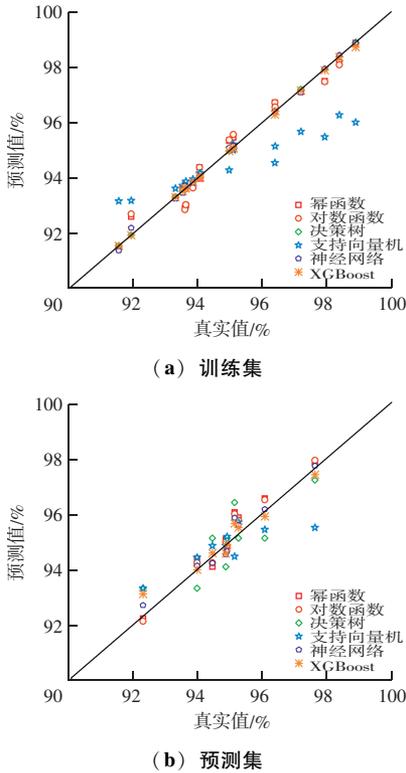


图2 各模型预测结果

Fig.2 Predictions of the models

采用预测集的数据对各模型进行进一步评价,幂函数、对数函数、决策树、神经网络以及 XGBoost 模型的相关系数 ( $R^2$ ) 分别为 0.896 7、0.918 6、0.685 0、0.938 6 和 0.932 7, 均比训练集的相关系数 ( $R^2$ ) 小, 说明各模型在预测集的预测效果均有所下降。对于决策树模型, 其预测集的相关系数 ( $R^2$ ) 仅为 0.685 0, 然而在训练集的相关系数 ( $R^2$ ) 达到了 1.000, 均方根误差 (RMSE)、均方误差 (MSE) 和平均绝对误差 (MAE) 均为 0, 这说明决策树模型在训练过程中出现了过拟合问题, 在训练集中表现出较好的预测性能, 但在测试集中的预测效果较差, 因此, 该模型也不适用于路基压实度的预测。

综上所述, 幂函数和对数函数两种非线性回归模型, 神经网络和 XGBoost 两种机器学习模型适用于路基压实度的预测。同时, 两种非线性回归模型预测性能接近, 两种机器学习模型的预测性能也较为接近, 机器学习的预测性能要高于非线性回归模型。非线性回归模型虽然预测性能一般, 但是它有明确的表达式, 在工程实践过程中便于使用。而机器学习模型虽然预测性能较好, 但是需要计算机运算,

操作较为不便。因此, 在实践过程中, 应根据模型预测性能和模型便捷程度综合进行选择。

### 3 结论

通过现场试验获取了不同碾压次数、碾压速度以及含水率的路基压实度, 采用多元非线性回归、决策树、支持向量机、神经网络、XGBoost 等 5 种方法建立了 6 个路基压实度预测模型, 探讨了这些模型应用于路基压实度预测的可行性, 并对各模型进行了评价。具体结论如下:

(1) 路基压实度与碾压次数呈正比, 而与碾压速度呈反比。当含水率处于最优含水率时, 路基压实度最大。各因素对于压实度的影响程度从大到小依次为: 含水率、碾压次数、碾压速度。

(2) 在训练集中, 幂函数、对数函数、决策树、神经网络以及 XGBoost 模型的相关系数 ( $R^2$ ) 均大于 0.95, 表现出较好的预测性能。支持向量机模型的相关系数 ( $R^2$ ) 仅为 0.596 5, 其准确率较差。

(3) 在预测集中, 幂函数、对数函数、决策树、神经网络以及 XGBoost 模型的相关系数 ( $R^2$ ) 分别为 0.896 7、0.918 6、0.685 0、0.938 6 和 0.932 7, 预测效果弱于训练集。决策树模型表现出了过拟合现象, 不适用于路基压实度的预测。

(4) 幂函数和对数函数两种非线性回归模型, 神经网络和 XGBoost 两种机器学习模型适用于路基压实度的预测。机器学习模型的预测性能要高于非线性回归模型。

### 参 考 文 献

- [1] 王海林, 张富奎, 刘佳. 基于不同填料类型的路基压实质量快速评价方法 [J]. 公路, 2024, 69 (1): 71-74.
- [2] 《中国公路学报》编辑部. 中国路基工程学术综述. 2021 [J]. 中国公路学报, 2021, 34 (3): 1-49.
- [3] 李育元. 寒区公路填石路基施工关键技术与稳定性分析 [J]. 粉煤灰综合利用, 2021, 35 (6): 109-114.
- [4] 高熙贺. 粉煤灰路基填筑施工技术的研究 [J]. 粉煤灰综合利用, 2019 (3): 66-69.
- [5] 郭华杰, 江辉煌, 刘向明. 基于 MFCC 的路基土密实度识别技术研究 [J]. 铁道工程学报, 2023, 40 (11): 8-16.
- [6] 周志军, 张志鹏, 郭涛, 等. 黄土路基补强分层压实度检测方法 [J]. 铁道科学与工程学报, 2020, 17 (12): 3052-3062.

(下转第 144 页)

## 研究与应用

- 2022, 12 (10): 252–255.
- [42] 刘亚辉, 冯建林, 许传华. 空心玻璃微珠在反射隔热涂料中的应用 [J]. 现代涂料与涂装, 2014, 17 (2): 22–23, 33.
- [43] 王福强, 戴国军, 潘建中, 等. 一种无机反射隔热轻质陶彩石涂料及其制备方法 [P]. 浙江省: CN114525046A, 2022–05–24.
- [44] 缪松兰, 马光华, 李清涛, 等. 建筑陶瓷抛光废渣制备轻质陶瓷材料的研究 [J]. 陶瓷学报, 2005 (2): 71–79.
- [45] 税安泽, 夏海斌, 曾令可, 等. 利用抛光砖废料制备多孔保温建筑材料 [J]. 硅酸盐通报, 2008, 166 (1): 191–195.
- [46] 张三明, 陈湛, 余其康, 等. 利用废弃煤矸石生产保温砖及其在自保温墙体中的应用 [J]. 新型建筑材料, 2009, 36 (9): 22–26.
- [47] 汪学彬, 杨重卿, 张祥伟, 等. 工业固体废弃物制备陶粒及其应用研究进展 [J]. 中国粉体技术, 2021, 27 (2): 1–8.
- [48] RILEY C M. Relation of chemical properties to the bloating of clays [J]. Journal of the American ceramic society, 2006, 34 (4): 121–128.
- [49] 姜中宏, 胡丽丽. 玻璃的相图结构模型 [J]. 中国科学 E 辑: 技术科学, 1996 (5): 395–404.
- [50] 范佳乐. 利用钨尾矿制备泡沫微晶玻璃的研究 [D]. 赣州: 江西理工大学, 2020.
- [51] 岳东亭. 利用污泥/赤泥/钢渣等固体废物制备新型多孔陶粒的膨胀机理研究 [D]. 济南: 山东大学, 2014.
- [52] 叶晓春. 煤矿固体废弃物泡沫隔热陶瓷组成与性能一体化设计和制备 [D]. 南昌: 南昌大学, 2018.
- [53] 李颖, 吴保华, 倪文, 等. 矿渣-钢渣-石膏体系早期水化反应中的协同作用 [J]. 东北大学学报 (自然科学版), 2020, 41 (4): 581–586.
- [54] 王亚光. 赤泥-粉煤灰-脱硫石膏新型胶凝材料微结构演变与复合协同效应 [D]. 北京: 北京科技大学, 2022.
- [55] 刘晓圣, 王美娜, 王振方, 等. 全固废泡沫混凝土性能研究 [J]. 混凝土与水泥制品, 2018 (10): 4.
- [56] 杨世钊. 固废基硫铝系绿色节能保温材料的制备及优化研究 [D]. 济南: 山东大学, 2021.

(上接第 123 页)

- [14] GUO P G, CARPINTERI A, SPAGNOLI A, et al. Effects of mechanical properties of concrete constituents including active mineral admixtures on fatigue behaviours of high performance concrete [J]. Fatigue & Fracture of Engineering Materials & Structures, 2010, 33 (1): 66–75.
- [15] 刘峰. 粉煤灰掺量对高性能混凝土性能的影响 [J]. 科技与企业, 2012 (12): 316–317.
- [16] YOICHI M, VANISSORN V, ITARU H, et al. Tensile mechanical properties of fly ash concrete at early age for thermal stress analysis [J]. Journal of Infrastructure Preservation and Resilience, 2020, 1 (1): 1–14.
- [17] 宋旭明, 戴公连, 龚雪芬. 粉煤灰高性能混凝土疲劳性能试验研究 [C]. 中国公路学会 2007 年学术年会论文集 (下). 2007: 226–230.
- [18] 曹兴龙. 绿色高性能混凝土配合比设计与性能预测 [D]. 兰州: 兰州交通大学, 2015.
- [19] 中国建筑科学研究院. 混凝土结构试验方法标准: GB/T 50152 [S]. 北京: 中国标准化出版社, 2012.

(上接第 128 页)

- [7] 王延仓, 李笑芳, 张文胜, 等. 基于高光谱技术公路路基土壤压实度定量反演的研究 [J]. 光谱学与光谱分析, 2023, 43 (7): 2294–2300.
- [8] 王如会. 基于改进灰色 Markov 模型的建筑工程造价预测研究 [J]. 粉煤灰综合利用, 2023, 37 (6): 122–127.
- [9] 赵得杰, 毕经东, 李浩. 基于 ARIMA 模型的基坑变形预测研究 [J]. 粉煤灰综合利用, 2021, 35 (5): 40–45.
- [10] 李风增. 基于人工神经网络模型预测混凝土抗压强度 [J]. 粉煤灰综合利用, 2023, 37 (3): 126–133.
- [11] KURNAZ T F, KAYA Y. The performance comparison of the soft computing methods on the prediction of soil compaction parameters [J]. Arabian Journal of Geosciences, 2022, 13 (4): 1–13.
- [12] JAYAN J, SANKAR N. Prediction of compaction parameters of soils using artificial neural network [J]. Asian Journal of Engineering and Technology, 2015, 3 (4): 1–8.
- [13] WANG H, YIN Z. High performance prediction of soil compaction parameters using multi expression programming [J]. Engineering Geology, 2020, 276: 105758.
- [14] MOINFAR A, SHAHGHOLI G, GILANDEH Y A, et al. Investigating the effect of the tractor driving system type on soil compaction using different methods of ANN [J]. Anfis and Step Wise Regression, 2022, 222: 105444.
- [15] WANG X, DONG X, ZHANG Z, et al. Compaction quality evaluation of subgrade based on soil characteristics assessment using machine learning [J]. Transportation Geotechnics, 2022, 32: 100703.
- [16] LIU G, PIE L, LI S. Compactness prediction of airport soil field based on artificial neural network [J]. Journal of Shenzhen University (Science and Engineering), 2021, 38 (1): 54–60.