

文章编号:1671-1637(2026)08-0129-18

基于纹理特征数据的机场道面沥青加铺层间黏结强度预测方法

邢琛¹, 惠冰^{*1,2}, 杜潇逸¹, 马新岩³, 汪海年^{1,2}

(1. 长安大学公路学院, 陕西西安 710064; 2. 长安大学民航机场智慧建造与运维重点实验室, 陕西西安 710064; 3. 民航科研基地(北京)有限公司, 北京 100029)

摘要:为精准预测“白改黑”机场道面层间黏结强度并揭示界面纹理特征与其的关联机制,本研究制备了16种界面处治工况的旧混凝土面板,通过三维激光检测技术提取界面的几何、波谱和分形指标,建立涵盖几何幅值-尺度分布-结构复杂度的纹理多元表征指标体系;加铺沥青混合料形成“白改黑”复合试件后在3种试验温度下进行剪切试验,构建基于多元纹理数据驱动的剪切强度标准化数据集;基于多层感知机(MLP)和极限梯度提升(XGBoost)建立了集成机器学习模型,并提出改进浣熊优化算法(ICOA)实现超参数寻优;最后利用SHAP分析量化各特征参数对预测结果的贡献。研究表明:铣刨深度为6~10 mm时,在50℃条件下强度仍可维持在0.65 MPa,相比于铣刨深度为4~6 mm时提升了67.9%~69.5%,可显著提升机场高温抗剪能力;ICOA-MLP-XGBoost模型相比其他模型,其决定系数提升了6.1%~10.9%,平均绝对误差降低了35.8%~46.9%,表现出更优越的预测精度和泛化能力,且具有更好的泛化性能和工程稳定性;SHAP分析表明,平均纹理深度、谱熵和分形维数是影响剪切强度的主要因素,鉴于机场道面高胎压重载、低速工况下剪应力集中,建议以6.0~8.0 mm铣刨深度对界面进行处治以达到这3个指标的高SHAP贡献区域。本研究为“白改黑”机场道面层间性能预测提供了高精度、可解释的数据驱动方法,可指导界面处治方案优化与道面耐久性提升。

关键词:机场道面;几何-波谱-分形纹理特征;剪切强度;集成机器学习;超参数优化;可解释性分析
中图分类号:U8 **文献标志码:**A **DOI:**10.19818/j.cnki.1671-1637.2026.239

A prediction model for bonding strength of asphalt overlay on airport pavement based on texture feature data

XING Chen¹, HUI Bing^{*1,2}, DU Xiao-yi¹, MA Xin-yan³, WANG Hai-nian^{1,2}

(1. School of Highway, Chang'an University, Xi'an 710064, Shaanxi, China; 2. Key Laboratory of Intelligent Construction and Maintenance of CAAC, Chang'an University, Xi'an 710064, Shaanxi, China; 3. Civil Aviation Research Base (Beijing) Co., Ltd., Beijing 100029, China)

Abstract: To accurately predict the bonding strength of “white-to-black” airport pavement interfaces and reveal the underlying mechanism linking interface texture to bonding performance, aged concrete slabs under 16 different treatment conditions were prepared. Three-dimensional laser scanning was used to extract geometric, spectral, and fractal indicators, establishing a

出版历程:2025-12-08 收稿,2026-02-20 修回,2026-03-19 录用

基金项目:国家自然科学基金联合基金项目(U2433210);国家自然科学基金项目(52578500)

作者简介:邢琛(1998-),男,河北沧州人,博士研究生,E-mail:2024021089@chd.edu.cn。

*通信作者:惠冰(1982-),男,陕西西安人,教授,博士生导师,工学博士,E-mail:82628532@qq.com。

引用格式:邢琛,惠冰,杜潇逸,等.基于纹理特征数据的机场道面沥青加铺层间黏结强度预测方法[J].交通运输工程学报,2026,26(8):129-146.

Citation: XING Chen, HUI Bing, DU Xiao-yi, et al. A prediction model for bonding strength of asphalt overlay on airport pavement based on texture feature data[J]. Journal of Traffic and Transportation Engineering, 2026, 26(8): 129-146.

multi-index texture characterization system covering geometric amplitude, distribution, and structural complexity. After placing asphalt mixture overlay to form “white-to-black” composite specimens, shear tests were conducted at three temperatures. A standardized shear strength dataset driven by multi-dimensional texture data was constructed. An ensemble machine-learning model combining a multilayer perceptron (MLP) and extreme gradient boosting (XGBoost) was developed, and an improved raccoon optimization algorithm (ICOA) was proposed for hyperparameter tuning. Finally, Shapley Additive Explanations (SHAP) was applied to quantify the contribution of each feature parameter to the predictions. The results show that when the milling depth is 6-10 mm, the shear strength can still maintain 0.65 MPa at 50 °C. Compared with a milling depth of 4-6 mm, the strength increases by 67.9%-69.5%, indicating a significant improvement in high-temperature shear resistance for airport pavements. The ICOA-MLP-XGBoost model outperforms other models, with R^2 improved by 6.1%-10.9% and MAE reduced by 35.8%-46.9%. It achieved higher prediction accuracy and better generalization, with improved robustness for engineering use. SHAP analysis indicates that mean texture depth, spectral entropy, and fractal dimension are the dominant factors affecting shear strength. Given the shear-stress concentration under heavy loads with high tire pressure at low speed on airport pavements, an interface milling depth of 6.0-8.0 mm is recommended for interface treatment to achieve high SHAP contribution ranges for these three indicators. This study provides a highly accurate and interpretable data-driven method for predicting interface performance in “white-to-black” airport pavements, which can guide interface-treatment optimization and improve pavement durability.

Keywords: airport pavement; geometric-spectroscopic-fractal texture feature; shear strength; integrated machine learning; hyperparameter optimization; interpretability analysis

Publication history: Received 2025-12-08; Received in revised form 2026-02-20; Accepted 2026-03-19

Funding: Joint Funds of the National Natural Science Foundation of China (U2433210); National Natural Science Foundation of China (52578500)

* **Corresponding author:** HUI Bing, professor, PhD, E-mail: 82628532@qq.com.

0 引 言

随着使用年限增长,许多现役机场水泥混凝土道面会出现破损、性能下降等问题。“白改黑”技术,即在机场旧水泥混凝土道面上加铺沥青混凝土层,这是一种经济、高效、快速的改造方案,能显著改善道面平整度和抗滑性能^[1-3]。然而,层间黏结强度不足会导致反射裂缝、层间剪切滑移、剥落、拥包等早期病害^[4-6],严重影响道面使用寿命和飞行安全。旧水泥混凝土板表面的层间纹理特征是决定黏结强度的最直接、最重要的因素之一,纹理特征决定了黏结材料的附着面积和机械嵌锁力^[7]。探究界面纹理特征对层间黏结强度的作用机理,对于阐明加铺层耐久性的失效机制至关重要。

界面纹理通过增强层间摩擦效应显著改善黏结性能^[8]。已有研究建立了纹理特征参数与黏结力学性能的定量关联模型,证实界面接触面积的增加可有效提升剪切强度^[9-10]。为克服传统检测方法效率

低、主观性强等缺陷,研究人员将目光转向先进的无损检测技术^[11]。Valikhani 等^[12]使用地面三维激光扫描技术提取了层间界面的算术平均粗糙度 R_a 。在此基础上,Shen 等^[13]使用三维激光检测技术和界面重构技术提取了界面的表面粗糙度指标并与剪切强度进行回归分析。然而,这些研究只着眼于反映界面纹理幅值维度的几何指标,没有考虑能够反映纹理复杂性的分形指标。针对这种情况,Tang 等^[14]提取多个几何纹理指标和分形指标并和黏结强度进行回归分析。但是,该研究仅对分形指标与黏结强度进行了简单的回归分析,未能深入探讨多类型纹理指标对黏结强度的综合影响。并且已有研究表明,波谱指标能够有效反映纹理多尺度(波长)的分布特征及其复杂性^[15-16],因此波谱指标在预测层间黏结强度方面具有重要意义。

当前黏结强度的评价仍主要依赖经验性定性判断,存在周期长、成本高、具有破坏性及难以全面评

估大范围道面实际状况等局限。传统回归模型因依赖大量试验数据而导致高昂成本与显著误差,然而机器学习凭借其卓越的预测能力,有效克服了这些经验模型的局限^[17-19]。目前,机器学习已广泛应用于路用性能评估^[20-21]、交通流预测^[22-23]与病害检测^[24-25]等领域,并在界面黏结强度这一领域展现出初步的应用潜力。曹玉贵等^[26]采用混合机器学习算法对 FRP 筋与 UHPC 的黏结强度进行预测,为准确预测 FRP 筋与 UHPC 之间黏结强度提供了一种新的方法。刘文博等^[27]使用超参数优化的径向基神经网络对钢管混凝土界面黏结强度进行预测,结果表明,机器学习模型比黏结强度计算公式精度更高。然而,单个学习器容易因模型偏差或数据扰动而陷入局部最优,导致泛化能力弱^[28-29]。同时,鉴于机器学习模型固有的黑箱特性,其可解释性往往受到限制^[30-31]。为此,SHAP (Shapley Additive Explanations)分析成为构建黏结强度预测模型中至关重要的一环,能够通过系统揭示其预测机制,有效增强对机器学习模型的信任度^[32-33]。

综上所述,现有“白改黑”机场道面黏结强度研究存在三大局限:在施工质量控制上,不同界面处理方式(如铣刨和抛丸)可能形成几何粗糙度相近但纹理结构不同的表面,出现粗糙度达标但黏结不足的情况;在纹理指标表征提取上,仅关注界面纹理的几何维度,忽略了纹理在多尺度和复杂度信息上的重要属性特征;在预测模型构建上,层间黏结受多维度纹理

共同驱动,非线性强且对数据扰动敏感,单一学习器往往存在泛化不稳定的问题,且模型超参数空间高维,随机搜索代价高且结果波动较大,不利于工程复现。

因此,为覆盖机场道面“白改黑”工程现场可实施的界面处治工况,本文对抛丸次数和铣刨深度进行了扩展分级并进行处治,利用三维激光检测技术提取界面纹理的几何、波谱与分形特征指标,建立涵盖几何幅值-尺度分布-结构复杂度的界面纹理指标体系。检测“白改黑”复合试件在 0℃、25℃、50℃这 3 种典型机场道面温度的剪切强度,构建包含上述 3 类特征指标的标准化剪切强度数据集。在此基础上,设计一种融合多层感知机与梯度提升模型的集成学习模型,减小多维度输入数据对模型的扰动,从而提升预测精度与泛化能力;针对集成模型超参数难以自动寻优的问题,提出改进浣熊优化算法以提高预测精度与鲁棒性,之后对数据集进行了预测分析;使用 SHAP 分析方法,系统分析纹理指标对黏结性能的影响机理以增强模型的可解释性。

1 “白改黑”道面复合试件的制备

1.1 界面黏结料制备

本文采用西安华泽道路材料有限公司提供的 BE-2 型乳化沥青作为界面黏结料,乳化剂的质量掺量为 1%,油水质量比为 55:45,固体含量为 55%左右。参照《公路工程沥青及沥青混合料试验规程》(JTG E20—2011)进行相关测试,测试结果如表 1 所示。

表 1 BE-2 型乳化沥青技术指标
Table 1 Technical specifications of BE-2 emulsified asphalt

类型	筛上剩余量/%	破乳速度	标准黏度/s	蒸发残留物性质			
				固体质量含量/%	25℃针入度/0.1 mm	软化点/℃	10℃延度/cm
BE-2	<0.1	中裂	26.5	56.87	72.8	46.5	>100

1.2 旧水泥混凝土道面板的制备与处理

1.2.1 旧水泥混凝土道面板的制备

本研究混凝土材料设计参照西宁曹家堡机场“白改黑”加铺工程的旧水泥混凝土道面材料体系与工程要求,旨在保证试验材料在强度等级、骨料组成与耐久性需求等方面与实际机场道面具有一致性。参照规范《普通混凝土配合比设计规程》

(JGJ 55—2011)使用选用强度为 42.5 MPa 的普通硅酸盐水泥制备旧水泥混凝土道面板,细集料为机制砂,粗集料为辉绿岩,压碎值为 17.8%,针片状颗粒质量分数百分比为 2.1%;矿粉为石灰岩矿粉,塑性指数为 3.3。面板密度为 3 115 kg·m⁻³,尺寸为 300 mm×300 mm×50 mm,水泥板配合比质量设计如表 2 所示。

表 2 水泥配合比设计
Table 2 Cement mix proportion design

指标	材料用量/(kg·m ⁻³)					砂率/%	水灰比
	水泥	砂	碎石		水		
			粒径 4.75~9.5 mm	粒径 9.5~19 mm			
数值	310	650	530	800	150	33	0.48

1.2.2 旧水泥混凝土道面板界面处治

根据文献[34],公路“白改黑”旧路面处治中,抛丸机的走行速度设定为 $10\text{ m}\cdot\text{min}^{-1}$,抛丸 2~4 次,或使用铣刨机以相同的走行速度进行操作,铣刨深度为 5~10 mm。鉴于机场道面“白改黑”加铺中,旧面表层污染与弱化程度在跑道接地区和滑行道间差异显著,现场界面处治强度具有较大波动范围。为覆盖从轻度处治到显著去除弱化层的可实施处治水平,本文将抛丸设置为 1~10 次、铣刨深度设置为 5 个级别,包括对照组共 16 组处治工况。该分级旨在识别界面性能提升的阈值区间与边际效益递减点,为工程选参提供依据,详细处治参数见表 3、4。如图 1、2 所示,水泥混凝土板养生完成后采用 250 型小型汽油铣刨机和 PWJ270 型号水平移动式抛丸机板界面进行铣刨和抛丸处治。

表 3 抛丸处治参数

Table 3 Shot blasting treatment parameters

编号	抛丸次数	平均纹理深度/mm	编号	抛丸次数	平均纹理深度/mm
YZ	0	0.11	P-6	6	0.30
P-1	1	0.36	P-7	7	0.29
P-2	2	0.33	P-8	8	0.30
P-3	3	0.29	P-9	9	0.28
P-4	4	0.27	P-10	10	0.29
P-5	5	0.28			

表 4 铣刨处治参数

Table 4 Milling treatment parameters mm

编号	铣刨深度	平均纹理深度
YZ	0	0.11
X-1	(0,2]	0.51
X-2	(2,4]	0.60
X-3	(4,6]	0.82
X-4	(6,8]	1.11
X-5	(8,10]	1.19




图 1 旧水泥混凝土板界面铣刨处治

Fig. 1 Milling treatment of the interface of old cement concrete slabs

1.3 加铺沥青混合料面层的设计与铺装

参照《民用机场沥青道面施工技术规范》(MH/




图 2 抛丸前后水泥板界面对比

Fig. 2 Comparison of the cement board interface before and after shot blasting

T5011—2019),加铺层类型选择 SAM-13 沥青混合料加铺层级配及沥青用量如表 5 所示,通过马歇尔试验获得 SMA-13 沥青混合料体积指标,并计算得到 SMA-13 最佳油石质量百分比为 6.2%。如图 3 所示,水泥板界面处治完成后,在黏结表面进行油撒布,撒布量为 $0.85\text{ kg}\cdot\text{m}^{-2}$,待乳化沥青完全破乳后加铺沥青混凝土面层。按照《公路工程沥青及沥青混合料试验规程》(JTG E20—2011)轮碾法成型 $300\text{ mm}\times 300\text{ mm}\times 100\text{ mm}$ “白加黑”道面板,成型 2 d 进行切割取样,切割后试件尺寸为 $80\text{ mm}\times 80\text{ mm}\times 100\text{ mm}$ 。

表 5 沥青加铺层级配及沥青用量(SAM-13)

Table 5 Asphalt overlay gradation and asphalt dosage (SAM-13)

不同筛孔孔径(mm)下的质量百分率/%									沥青用量/%
16	13.2	9.5	4.75	2.36	1.18	0.6	0.3	0.075	
100	96	56	29	22	18	15	12	10	6.2




图 3 复合试件制备流程

Fig. 3 Preparation process of composite specimens

2 室内试验

2.1 三维激光检测

如图 4 所示,为了提取处治前后的旧水泥板的纹理特征,本文采用 LMI 技术公司的双相机线性激光传感器 Gocator 2800 进行点云数据提取,之后使用循




图 4 界面高程点云数据提取与预处理

Fig. 4 Extraction and preprocessing of interface elevation point cloud data

环 8 邻域填充法^[35]和巴特沃斯带通滤波法^[36]进行点云数据异常值和微观纹理滤波,获得点云数据。

2.2 层间界面纹理特征提取

本文提取 3 类粗糙度指标,分别包括平均纹理深度、算数平均高度、偏度、中心频率、谱熵和分形维数。其中几何指标计算公式参照《表面粗糙度标准》(ISO25178)进行计算,光谱指标和分形维数的计算公式见式(1)~(4)。为有效表征界面纹理的空间非均匀性并提供多点重复观测,从而降低单点测量的偶然误差与尺寸效应问题,同时也为了适应剪切试验的尺寸,本研究参考相关文献^[34],将尺寸为 300 mm×300 mm×50 mm 旧水泥板中心区域分为 9 个尺寸为 80 mm×80 mm×50 mm 的矩形区域(图 5),提取每个区域的粗糙度指标,计算公式为

$$S(u, v) = |F(u, v)|^2 \quad (1)$$

$$f_c = \frac{\sum_{u, v} (u, v) S(u, v)}{\sum_{u, v} S(u, v)} \quad (2)$$

$$H = - \sum_{u, v} P(u, v) \lg[P(u, v)] \quad (3)$$

式中: $S(u, v)$ 为频率域坐标在 u 和 v 时的功率谱密度; $F(u, v)$ 为频率域坐标在 u 和 v 时的振幅; f_c 为测试试件计算截面的中心频率; $P(u, v)$ 为频率域坐标在 u 和 v 时的标准化的 PSD 值; H 为试件计算截面的谱熵; u 和 v 分别为与空间坐标 x 和 y 共轭的空间频率变量,表征高度场沿 x 和 y 方向起伏的频率成分。

试件计算截面的分形维数 D_{fs} 为

$$D_{fs} = 2 - \lim_{r \rightarrow 0} \frac{\lg[A(r)]}{\lg(r)} \quad (4)$$

式中: $A(r)$ 为在尺度 r 下对分形对象的测量结果。




图 5 水泥板界面区域划分(单位:cm)

Fig. 5 Cement board interface area division (unit: cm)

2.3 剪切试验

根据规范《道桥用防水涂料》(JC/T975—2005),公路“白改黑”工程仅测试试件 50 °C 条件下的抗剪强度。然而,机场“白改黑”道面在整个服役周期内还将面临低温脆化、中温常态运行及高温抗滑移等多种不利工况。因此,鉴于界面剪切强度对温度具有显著敏感性,本文选取 0 °C、25 °C、50 °C 这 3 种试验温度分别对应机场跑道的低温、中高温和高温运行工况环境,采用万能试验机 UTM-30 对第 2.2 节制备的 80 mm×80 mm×50 mm 的试件开展直剪试验(图 6),剪切速率为 50 mm·min⁻¹。

3 可解释的智能预测模型

3.1 数据集的建立与预处理

受限于道面黏结性能测试领域公开数据集的缺




图 6 剪切试验
Fig. 6 Shear test

失,开展此类研究的一项可行解决方案是自主构建数据集^[18,37]。本研究的核心工作之一是自主构建一个涵盖关键工况的专用数据集。数据集的建立与预处理具体方法如下:

表 6 输入和输出变量的统计分析

Table 6 Statistical analysis of input and output variables

指标	最大值	最小值	平均值	中位数	标准差
平均纹理深度/mm	1.327	0.102	0.463	0.328	0.309
算术平均高度/mm	1.070	0.130	0.430	0.336	0.238
偏度	6.921	1.222	4.531	5.129	1.640
中心频率/(次·mm ⁻¹)	1.349	0.486	0.911	0.877	0.218
谱熵	0.008 94	0.000 17	0.001 97	0.001 27	0.002 07
分形维数	2.133	1.202	1.750	1.759	0.223
试验温度/℃	50	0	25	25	20
剪切强度/MPa	2.671	0.058	1.334	1.408	0.764




图 7 输入变量的相关系数热力图

Fig. 7 Heatmap of correlation coefficients of input variables

(3)数据分割,由于小样本条件下模型性能对数据划分具有敏感性,采用分层抽样结合五折交叉验证法对数据集进行分割,将(1)中 48 个试验组合定义为分层单元,在各层内随机抽样并按比例分配至 5 个互不重叠的子集(fold),使各子集中各组合样本

(1)原始数据获取,本研究数据来源于室内试验,界面处治工况共 16 组,试验温度设置 3 个水平,共 48 个“界面处治+试验温度”组合,每个组合制备 2 个平行试件。每个试件按照第 2.2 节区域划分方法切分为 9 个小尺寸试件进行剪切试验,每次测试均记录输入变量与响应变量,共获取 864 组原始数据。

(2)数据清洗,对原始记录剔除关键变量缺失、单位量纲不一致、以及重复记录的数据。之后使用采用 3 σ 原则对异常值进行剔除,最终选取 450 组数据建立数据集并进行归一化处理。数据集的指标统计如表 6 所示。为了防止模型自变量之间存在相互依赖的多重共线性问题,需要自变量之间的相关性不高于 0.8^[38]。从图 7 可以看出,变量之间的决定系数 R^2 都在 0.8 以下。

占比尽量接近总体分布。每一轮选取其中 4 折(总数据量的 80%)作为训练集训练模型,剩余 1 折(总数据量的 20%)作为测试集评估模型性能。

(4)样本增强,为缓解 450 组有效样本量对模型训练带来的泛化不足问题,本文引入生成对抗网络(Generative Adversarial Network, GAN)进行样本增强^[39]。GAN 仅在每一折的训练数据上训练,测试 fold 保持为原始数据,避免信息泄漏。本研究将训练集数据分别以 0、50%、100%、150%、200% 的比例进行增强,以平均绝对误差(MAE)作为标准,当 MAE 提升小于 1%时停止增强^[40-41]。

为检验波谱与分形指标对层间黏结强度预测的增量贡献,构建 2 套输入特征:特征集 A 仅包含第 2.2 和 2.3 节测得 16 种处治工况下水泥板界面的几何纹理指标,其为平均纹理深度(F_1)、算术平均高度(F_2)和偏度(F_3)和试验温度(F_7);特征集 B 在此基础上加入波谱指标(F_4)和谱熵(F_5)与分形维数(F_6),2 个特征集的输出变量(O)均为对应工况下的复合试件的剪切强度。建立机器学习回归模

型,模型性能通过 MAE、平均绝对百分比误差(MAPE)、均方根误差(RMSE)和决定系数(R^2)进行评估。模型精度越高, R^2 值越接近 1,MAE、MAPE、RMSE 的值就越低。

3.2 机器学习模型

3.2.1 多层感知机

多层感知机(Multilayer Perceptron, MLP)其结构包含输入层、至少一个隐藏层和输出层,各层神经元全连接,使其能够学习并模拟输入与输出之间复杂的非线性关系,突破了单层感知机的局限^[42]。本文的 MLP 结构如图 8 所示,参数设置如表 7 所示。




图 8 MLP 流程

Fig. 8 MLP flow

表 7 MLP 结构参数设置

Table 7 Structure parameter settings of MLP

结构参数	搜索范围
num_hidden_layers	[1,5],基线模型取值 2
hidden_units	[32,128],基线模型取值 64
learning_rate	[0.001,0.5],基线模型取值 0.01
batch_size	[16,256],基线模型取值 32
dropout_rate	[0.1,0.5],基线模型取值 0.1
weight_decay	$[1 \times 10^{-4}, 1 \times 10^{-2}]$,基线模型取值 1×10^{-3}

3.2.2 极限梯度提升模型

极限梯度提升模型(eXtreme Gradient Boosting, XGBoost)通过迭代函数来细化弱学习器的残差以其独特的目标函数和选择损失函数的灵活性而闻名^[43-44]。图 9 给出了 XGBoost 算法的工作流程,参数设置如表 8 所示。

3.2.3 MLP-XGB 集成模型

本文提出集成学习模型,通过对训练数据进行不同的采样或预处理方法将它们组合成一个加权集成模型,以提升整体预测性能和泛化能力。




图 9 XGBoost 流程

Fig. 9 XGBoost flow

表 8 XGBoost 结构参数设置

Table 8 Structure parameter settings of XGBoost

结构参数	搜索范围
n_estimators	[50,500],基线模型取值 2
max_depth	[1,12],基线模型取值 6
learning_rate	[0.01,0.2],基线模型取值 0.05
subsample	[0.5,1],基线模型取值 0.8
colsample_bytree	[0.5,1],基线模型取值 0.8
min_child_weight	[1,20],基线模型取值 2

如图 10 所示,将训练集划分为训练子集(90%)和验证子集(10%),本文将 MLP 与 XGBoost 模型在训练子集上进行训练,分别得到模型 f_{MLP} 和 f_{XGB} 。设验证子集的特征为 X_v ,真实值为 y_v ,经过




图 10 MLP-XGB 集成模型

Fig. 10 MLP-XGB ensemble learning

验证子集后可以得到模型预测值分别为 $y_{v,MLP}$ 和 $y_{v,XGB}$, 从而得到预测值与真实值之间的误差分别为 $E_{MAE,v,MLP}$ 和 $E_{MAE,v,XGB}$, 如式(5)、(6)所示

$$E_{MAE,v,MLP} = |y_{v,MLP} - y_v| \quad (5)$$

$$E_{MAE,v,XGB} = |y_{v,XGB} - y_v| \quad (6)$$

通过验证子集的误差来决定结合权重, 如公式(7)、(8)所示

$$Q_{MLP} = \frac{E_{MAE,v,MLP}}{E_{MAE,v,MLP} + E_{MAE,v,XGB}} \quad (7)$$

$$Q_{XGB} = \frac{E_{MAE,v,XGB}}{E_{MAE,v,MLP} + E_{MAE,v,XGB}} \quad (8)$$

式中: Q_{MLP} 和 Q_{XGB} 分别为 MLP 和 XGB 模型在集成模型中所占权重。

定义一个阈值 θ , 如果满足式(9), 即当 2 个算法的相对差值比大于阈值则不进行结合

$$\frac{|E_{MAE,v,MLP} - E_{MAE,v,XGB}|}{\max\{E_{MAE,v,MLP}, E_{MAE,v,XGB}\}} > \theta \quad (9)$$

如果 $E_{MAE,v,MLP} > E_{MAE,v,XGB}$, 则 $Q_{MLP} = 0, Q_{XGB} = 1$; 如果 $E_{MAE,v,MLP} < E_{MAE,v,XGB}$, 则 $Q_{MLP} = 1, Q_{XGB} = 0$ 。

最终预测模型为

$$\hat{f} = Q_{MLP}f_{MLP} + Q_{XGB}f_{XGB} \quad (10)$$

为了验证本文提出的集成学习模型算法的优越性, 选择其他 6 种工程应用中主流的机器学习算法进行比较, 具体模型见表 9, 模型结构参数设置参考相关文献。

表 9 机器学习算法

Table 9 Machine learning algorithm

序号	名称	优势	参考文献
1	支持向量回归 (Support Vector Regression, SVR)	泛化强, 非线性拟合好	[21]
2	随机森林回归 (Random Forest, RF)	抗噪稳健强, 不易过拟合	[45]
3	最小二乘提升 (Least Squares Boosting, LSBoost)	精度提升明显, 适应非线性	[46]
4	广义加性模型 (Generalized Additive Model, GAM)	可刻画, 非线性	[47]
5	极限学习机回归 (Extreme Learning Machine Regression, ELM)	训练速度极快, 实现简单高效	[26]
6	梯度提升树 (Light Gradient Boosting Machine, LGBM)	训练高效快速, 精度高可扩展	[48]

3.3 超参数优化算法

本研究的集成预测模型包含多组件与融合机制, 常规搜索难以稳定实现自动寻优^[49]。为提升机场“白改黑”道面黏结性能预测在不同工况下的精度

与稳定性, 本文基于浣熊优化算法 (Coati Optimization Algorithm, COA)^[49] 开发改进浣熊优化算法 (Improved COA, ICOA) 的超参数寻优算法, 以增强工程预测任务上的精度提升与稳定性表现, 具体算法的改进步骤如下。

将每个候选解 x 视为集成模型的一组超参数向量, 以训练集预测误差作为寻优目标函数, ICOA 的寻优目标为

$$\mathbf{x}^* = \arg \min_{x \in \Omega} F(x) \quad (11)$$

$$F(x) = E_{RMSE, tra}[\hat{y}(x), y] \quad (12)$$

式中: $\mathbf{x}^*$ 为候选超参数向量; $F(x)$ 为在超参数为 x 时的目标函数值; $\hat{y}(x)$ 为在超参数 x 下训练得到的模型对训练集样本的预测值; y 为训练集样本的真实观测值; $E_{RMSE, tra}(\cdot)$ 为训练集上的均方根误差。

为避免传统 COA 在复杂非凸目标下出现早熟收敛, ICOA 引入衰减参数以调节搜索步长与接受策略

$$T_k = T_0 \alpha^k \quad 0 < \alpha < 1 \quad (13)$$

式中: k 为迭代次数。

随着 T_k 衰减, 算法由大范围搜索逐步过渡到最优解邻域的精细搜索, 从而在有限评估次数下提升最终预测精度与稳定性。

在开发阶段, 为增强跳出局部最优的能力, 对候选解采用概率接受准则

$$p = \begin{cases} 1 & F(x_{new}) \leq F(x_{old}) \\ \exp\left[\frac{F(x_{old}) - F(x_{new})}{T_k}\right] & F(x_{new}) > F(x_{old}) \end{cases} \quad (14)$$

式中: p 为接受新解的概率; x_{old} 为当前超参数组合; x_{new} 为候选超参数组合; $F(\cdot)$ 为目标函数; T_k 为第 k 次迭代的衰减参数

该机制使得当误差略有上升时仍可能接受新解, 从而降低在耦合强、混合型超参数空间中陷入局部最优的概率, 提升重复运行的稳定性。

为了验证本文提出的 ICOA 超参数优化算法的优越性, 选择其他 6 种工程应用中主流的超参数优化算法进行比较, 具体算法见表 10。

3.4 可解释性分析算法

对数据集的测试集进行 SHAP 分析以降低计算需求, 同时保持分析的严谨性并避免解释上的过度拟合。SHAP 值的正负反映了特征对模型预测结果的影响, 正值表示特征对预测结果有正向推动作用, 负值则表示负向影响^[33], 其计算公式如下

$$\phi_i = \sum_{S \in N} \frac{|S|!(|N| - |S| - 1)!}{|N|!} \cdot [v(S \cup \{i\}) - v(S)] \quad (15)$$

表 10 超参数优化算法

Table 10 Hyperparameter optimization algorithms

序号	名称	优势	参考文献
1	粒子群优化算法(Particle Swarm Optimization, PSO)	易于实现,快速收敛,良好的探索开发,可并行性	[50]
2	蚁群优化算法(Ant Colony Optimization, ACO)	强组合问题求解器,通过信息素反馈自适应,抗局部最优鲁棒,固有可并行化	[50]
3	白鲸优化算法(Whale Optimization Algorithm, WOA)	高效的搜索机制,快速的收敛速度,最小参数设置,优秀的探索-开发平衡	[50]
4	贝叶斯优化算法(Bayesian Optimization, BO)	高效的全局优化,数据高效的函数优化,平衡探索和开发	[51]
5	饥饿游戏优化算法(Hunger Games Search, HGS)	自适应搜索,全局局部平衡,计算简单,鲁棒性能优秀	[52]
6	海鹰搜索算法(Cald Eagle Search, BES)	有效的探索能力,稳健的全局优化性能,有效的探索-开发平衡	[52]

式中: N 为所有特征的集合; S 为任何不包含特征 i 的特征子集; $|S|$ 为集合 S 中的特征数量; $v(S)$ 为特征集 S 对模型预测输出的贡献; $v(S \cup \{i\})$ 为特征集 $S \cup \{i\}$ (其中包含特征 i) 对预测输出的贡献。

4 结果与分析

4.1 室内试验结果分析

4.1.1 纹理特征指标

经过不同处治工况处理后的水泥板界面纹理特征参数结果如图 11、12 所示。在相同处治参数下,不同检测区域的纹理特征指标存在离散性。这种现象是由抛丸材料大小不同以及铣刨刀片的切削角度不同所导致的^[53-54]。

由图 11 可知:在几何指标中,MTD 和算术平均值 S_a 随着抛丸次数的增加呈现先增加后减小再趋于平稳的趋势,而偏度 S_{ku} 在抛丸 3 次后趋于平稳,相比于对照组,最大均值增长率分别为 199.3%、71.3%、203.8%;在波谱指标中, H 随着抛丸次数的增加呈现先增加后减小再趋于平稳的趋势,而中心频率 f_c 呈现先降低再升高后趋于稳定的趋势;而分形指标 D_{fs} 呈现先增加后减小再趋于平稳

的趋势,相比于对照组,最大均值增长率为 20.5%。这是由于在最初的几次抛丸中,界面的表面纹理会变得粗糙且结构复杂,而随着抛丸次数的增加,表面纹理的棱角特征会被打磨光滑,从而降低了表面粗糙度和复杂程度^[55-56]。

由图 12 可知:在几何指标中,MTD 和 S_a 随着铣刨深度的增加呈现先上升后平缓的趋势,相比于对照组,最大均值增长率分别为 795.6%和 358.3%, S_{ku} 呈现先上升后平缓的趋势,最大均值增长率为 120.6%; H 和 D_{fs} 随着铣刨深度的增加而上升,相比于对照组,最大均值增长率分别为 141.4%和 56.4%, f_c 呈现下降的趋势。这是由于随着铣刨深度增加,界面的表面纹理会变得粗糙且结构复杂^[35],从而使得几何指标和分形指标增加, f_c 下降。

综上所述,几何指标、波谱指标与分形指标对抛丸次数和铣刨深度的响应规律并不一致,这说明界面纹理演化不仅体现在几何幅值变化,还体现在尺度结构特征与多尺度复杂性的变化。因而在施工质量控制中,仅采用几何粗糙度指标不足以表征界面真实纹理结构。机场“白改黑”道面在高轮载、冲击与剪切等更不利工况下对层间黏结更敏感,因此施工质量控制不应仅以几何粗糙度达标为判据,而应结合波谱与分形等多维纹理指标进行综合评价以降低界面黏结不足的风险。

4.1.2 剪切强度

图 13 展示了层间界面在抛丸和铣刨处治下“白改黑”道面的剪切强度在 0℃、25℃、50℃试验条件下的变化趋势。由图 13(a)可知,在 0℃与 25℃条件下,抛丸处治的界面剪切强度整体维持在 2.0~2.3 和 1.0~1.4 MPa,较未处治组(YZ)提高约 25%~55%,这说明在该温度下,黏结层的模量高、流动性低,使界面剪切刚度较大,多尺度纹理得以通过增加真实有效接触与局部咬合。然而,当温度升高至 50℃时,黏结层软化蠕变使界面刚度降低并削弱纹理嵌锁与有效接触,各组剪切强度骤降至约 0.35~0.45 MPa,仅为常温强度的 18%~23%,强度衰减幅度高达 75%以上。

由图 13(b)可知:在 0℃、25℃和 50℃条件下,铣刨参数为 X-1~X-3 的界面剪切强度均提升至 2.2~2.3、1.30~1.50、0.35~0.45 MPa,相比于对照组增幅为 35%~45%、0~45%和 250%~330%,处治效果进入相对稳定的平台区,这是由于界面纹理的机械嵌锁效应已基本定型,进一步微小的纹理差异不足以显著改变应力传递路径与有效承载面




图 11 抛丸处治后水泥板界面纹理特征指标数值

Fig. 11 Value of the texture characteristic index of the cement board interface after shot blasting treatment

积;当处治参数由 X-3 进一步提升至 X-4~X-5 时,各温度下的剪切强度相比于 X-3 增幅为 15%~20%、10%~25%和 45%~56%,这说明纹理嵌锁效应得到了增强,抗微滑移能力更强,有效承载接触与单位接触点抗剪阻力得到了提升。值得注意的是,50℃条件下处治界面剪切强度的涨幅显著高于 0℃和 25℃,这是由于高温下界面强度因黏结层软

化接近残余低值,处治引入的机械嵌锁效应显著上升,因此相对常温表现为更大的提升幅度。

综上所述,抛丸处治方式下的界面剪切强度在常温下有 25%~55%的提升幅度,高温下降至 0.35~0.45 MPa。普通公路“白改黑”工程已基本满足使用需求,然而,机场道面承受飞机高胎压重载与低速作用,层间剪应力集中更强,50℃下残余抗




图 12 铣刨处治后水泥板界面纹理特征指标数值

Fig. 12 Value of the interface texture characteristic index of the cement board after milling treatment

剪能力直接对应结构层间滑移风险。因此,可能无法满足机场道面“白改黑”工程要求。相比之下,抛丸处治下界面跨越纹理嵌锁阈值并在高温下仍保持较高残余抗剪强度,其中铣刨参数为 X-4 和 X-5 时,高温抗剪强度仍可维持在 0.65 MPa 左右,表现出更高的抗高温滑移性能,因而更适用于满足机场道面高安全等级运行需求。

4.2 预测模型性能评估与对比

4.2.1 基线模型对比

在机器学习研究中,对基线模型进行性能对比,是为新方法效能评估提供客观基准、验证其有效性与先进性的不可或缺环节^[50]。通过对比表 11、12 可知,与特征集 A 相比,特征集 B 在各机器学习模型下均获得更优的预测性能:相同基线模型中,使用




图 13 不同层间界面处治工况下“白改黑”道面的剪切强度

Fig. 13 Shear strength of the white-to-black runway under different interlayer interface treatment conditions

表 11 9 种基线模型在特征集 A 测试集的预测性能对比

Table 11 Comparison of the prediction performance of test sets of feature set A of nine baseline models

模型	MAE	MAPE	RMSE	R^2
SVR	0.211	0.291	0.290	0.677
RF	0.215	0.296	0.299	0.662
LSBoost	0.206	0.283	0.282	0.683
GAM	0.222	0.309	0.307	0.652
ELM	0.230	0.315	0.319	0.633
LGBM	0.195	0.268	0.271	0.698
MLP	0.201	0.278	0.278	0.688
XGBoost	0.197	0.274	0.273	0.695
MLP-XGBoost	0.191	0.263	0.263	0.709

表 12 9 种基线模型在特征集 B 测试集的预测性能对比

Table 12 Comparison of the prediction performance of test sets of feature set B of nine baseline models

模型	MAE	MAPE	RMSE	R^2
SVR	0.182	0.203	0.235	0.732
RF	0.188	0.231	0.247	0.715
LSBoost	0.179	0.195	0.222	0.754
GAM	0.195	0.266	0.268	0.704
ELM	0.207	0.276	0.281	0.678
LGBM	0.165	0.173	0.195	0.811
MLP	0.173	0.186	0.218	0.779
XGBoost	0.167	0.178	0.203	0.805
MLP-XGBoost	0.152	0.168	0.189	0.847

特征集 B 的基线模型相比于特征集 A, R^2 提升了 8%~19%, 同时 MAE、MAPE、RMSE 分别降低了 10%~20%、12%~31%、12%~28%。同时表 13 表明, 相比与特征集 A, 特征集 B 在 ICOA-MLP-

表 13 ICOA-MLP-XGBoost 模型在 2 个特征集下的预测性能对比

Table 13 Comparison of the prediction performance of two feature sets of ICOA-MLP-XGBoost model

特征集	MAE	MAPE	RMSE	R^2
A	0.158	0.173	0.193	0.822
B	0.071	0.089	0.092	0.964

XGBoost 模型上 R^2 提升了 17.3%, MAE、MAPE、RMSE 分别下降了 55.8%、48.5%、53.3%, 这表明相较于特征集 A, 特征集 B 中的波谱指标 f_c 、 H 与分形指标 D_{fs} 在纹理几何幅值信息之外对黏结强度提供了额外的纹理尺度的分布特征和复杂度有效信息, 有助于提升模型的泛化预测能力。

表 11、12 还分别对比了 9 种基线模型的预测精度。在特征集 B 中, 本研究的 MLP-XGBoost 集成模型相比于其他模型 MAE、MAPE 和 RMSE 分别降低了 8%~19%、5%~36%、6%~29%; 同时 R^2 提升了 8%~24%。这表明 MLP-XGBoost 集成模型相较于其他模型具有更优的预测精度与拟合能力, 因此选择 MLP-XGBoost 集成模型作为后续研究的基线模型。

4.2.2 超参数优化算法对比

图 14 展示了测试集上 MLP-XGBoost 集成模型经过不同超参数优化算法优化后的性能对比。通过不同超参数优化算法, 模型的预测性能均得到了提升; 其中, 经过 ICOA 算法优化的模型的预测性能最佳。相比于其他优化算法, 经过 ICOA 算法优化后的预测模型在 MAE、MAPE、RMSE 降低了 13.7%~53.3%、12.9%~43.7%、13.4%~49.7%, R^2 提升了 6.1%~10.9%。图 15 展示了 ICOA-MLP-XGBoost 模型在测试集上的预测结果与实测




图 14 MLP-XGBoost 模型经过超参数优化后的性能对比

Fig. 14 Performance comparison of the MLP-XGBoost model after hyperparameter optimization




图 15 ICOA-MLP-XGBoost 模型在测试集上的预测结果与实测结果对比


Fig. 15 Comparison of the prediction results of the ICOA-MLP-XGBoost model on the test set with the measured results

结果对比,该模型的 R^2 为 0.964, 优于其他优化算法改进的模型。


4.3 过拟合与稳定性检验

为了防止模型出现过拟合现象,本文采用 5 折交叉验证对模型的泛化能力进行评估。相关研究表明^[50,57],若模型在连续 5 个训练-验证周期后,其各项评估指标的相对标准差均在 5% 以内,则可判定该模型具备出色的泛化能力。

图 16(a)展示了 MLP-XGBoost 模型经过不同超参数算法优化后在 5 折交叉验证前后的性能对比。只有 COA 和 ICOA 算法优化后的模型,训练集上的各项评估指标相对标准差均控制在 5% 以内,表明经过 ICOA 优化的模型在不同数据子集中能够学习到高度稳定的内在规律。同时,相比于传统 COA 算法,经过 ICOA 优化的模型在训练集上



(a) MLP-XGBoost 模型经过不同超参数算法优化后的稳定性对比



(b) ICOA-MLP-XGBoost 在不同划分策略划分后的数据集上的稳定性对比

图 16 MLP-XGBoost 模型经过不同超参数算法优化后 5 折交叉验证结果

Fig. 16 5-fold cross-validation results of the MLP-XGBoost model after being optimized with different hyperparameter algorithms

的 MAE、MAPE、RMSE、 R^2 指标相对标准差分别降低了 36.8%、63.4%、28.1%、55.5%。这表明 ICOA 相比于传统 COA 和其他经典超参数优化算法具有更加出色的泛化能力和鲁棒性能。图 16(b)表明 ICOA-MLP-XGBoost 在本研究提出的分层结合 5 折交叉验证策略划分后的数据集上的稳定性最佳。

4.4 可解释性分析

如图 17 所示,在纹理指标中,MTD(F_1)、 $H(F_5)$ 、 $D_{fs}(F_6)$ 是影响“白改黑”机场道面层间剪切强度的主要因素,其对应特征重要性值分别为 0.580、0.546、0.19。相较于 $Sku(F_3)$ 的重要性,上述 3 项因素的贡献度分别提升了 80.9%~452.3%。因此,除层间界面的几何指标外,还需进一步关注波谱指标与分形指标对其剪切性能的影响。




图 17 ICOA-MLP-XGBoost 模型的 SHAP 分析

Fig. 17 SHAP analysis of the ICOA-MLP-XGBoost model

由图 18(a)可知,MTD 对层间抗剪切强度的贡献呈现明显的分段式增强趋势。当 MTD 介于 $0.1 \sim 0.8$ mm 时,SHAP 值主要集中在 $0.0 \sim 0.2$,该区间

内随 MTD 增加,SHAP 仅呈弱上升,整体增幅约小于 0.2。当 MTD 超过 $0.8 \sim 0.9$ mm 后,SHAP 值分布出现明显增长,多数样本迅速上升至 $0.4 \sim 0.8$,




图 18 关键预测变量对输出值的影响

Fig. 18 Influence of key predictors on the output

峰值接近 0.9,相比于 MTD 介于 0.1~0.8 mm 时提升了 200%~800%。这表明 MTD 在该阈值以上的边际贡献显著放大。这是由于当纹理深度较小(<0.8 mm)时,界面尚未形成充分有效的界面结合与应力传递路径,因而对剪切强度的提升作用有限;但 MTD 提升至 0.9 mm 以上时,实际受力的有效接触面积虽然可能局部集中,但单位接触点的抗剪阻力显著提高,显著增强了界面的抗剪切性能^[8,14]。因此对机场道面而言,MTD 应被视为控制界面安全冗余的关键阈值型参数,评价重点需放在高温-重载条件下能否稳定进入“高贡献区间”,而非仅满足公路工程的经验性粗糙度水平。

由图 18(b)可知:当 $H<0.002$ 时,SHAP 值主要分布在 $-0.6\sim 0$,表明低谱熵条件下多尺度纹理离散性不足,此时有效接触面积虽较大,但应力传递路径单一,剪应力易在界面连续薄层中集中,对抗剪强度产生抑制作用;当 H 增至 $0.002\sim 0.004$ 时,有效接触面积增加,单位接触点承载能力显著提高,SHAP 值迅速跃升至 $0.2\sim 0.5$,贡献由负转正,增幅 $0.5\sim 0.8$;当 $H>0.005$ 后,界面多尺度结构趋于完善,机械嵌锁体系稳定形成,应力在不同尺度粗糙单元之间分散传递^[7,34],SHAP 值进一步稳定在 $0.6\sim 0.9$,进入高贡献平台区。从工程应用角度看,普通公路“白改黑”工程中,只要界面具备基本嵌锁结构并满足交通荷载下的层间协同工作即可, H 进入正贡献区间即可满足使用需求;而机场道面承受高胎压及重轮载低速作用,当 $H\geq 0.005$ 稳定进入高贡献区,界面才能在高温-重载耦合作用下保持足够的安全冗余。

由图 18(c)可知:当 $D_{fs}<1.60$ 时,纹理复杂度低,界面纹理层级不足,机械嵌锁结构不连续,抗剪行为更多受黏结料控制,因此 SHAP 值主要集中在 $-0.15\sim -0.05$,表现为负贡献;而当 D_{fs} 介于 $1.60\sim 1.80$ 时,纹理复杂度增加,多尺度峰谷结构逐步完善,粗尺度嵌锁与细尺度咬合作用协同形成稳定受力界面,SHAP 显著上升提升至 $0.10\sim 0.25$,增幅约 $0.3\sim 0.4$,并形成高 SHAP 值集中区域;而当 $D_{fs}>1.85$ 后,界面纹理过于复杂,界面形貌趋于过度破碎与尖锐化,实际有效接触面积可能下降,导致整体抗剪贡献反向衰减,SHAP 值快速转为显著负贡献,主要分布在 $-0.6\sim -0.2$ 。从工程意义看,普通公路“白改黑”工程通常只需界面具备基本嵌锁即可满足交通荷载下的协同受力需求, D_{fs} 进入正贡献区间即可实现性能保障;而机场道面

承受高胎压重载、低速作用条件下的高剪应力集中效应,因而机场道面更推荐将 D_{fs} 控制在力学最优的区间($1.60\sim 1.80$)。

本研究的几何幅值、尺度分布、复杂度纹理特征具有通用力学意义,通过影响机械嵌锁、有效接触面积与应力传递路径改变剪切承载力,因此不同处治方式下其主导作用方向总体一致。本文处治方式与参数已覆盖机场“白改黑”从轻度处治到显著去除弱化层的主要可实施区间,故关键纹理特征与剪切强度关系及阈值结论在该工程窗口内具有代表性与可用性。但其有效性受黏结材料种类与性能约束,超出覆盖范围或工况显著变化时需谨慎外推并补充验证。

综上所述,MTD、 H 、 D_{fs} 是影响机场道面“白改黑”层间抗剪黏结的主控纹理指标。由于机场道面需承受飞机起落过程中的高接触应力与低速重复荷载作用,层间界面剪应力集中效应更为突出。因此上述指标应尽可能稳定落入其对应的高 SHAP 贡献区间。结合图中结果对比 2 类处治方式可知,仅 X-4 处治能够同时使 MTD、 H 、 D_{fs} 均进入高 SHAP 值区域,表明其对提升层间抗剪黏结能力的综合增益最为显著。因此,建议机场道面“白改黑”界面处治工程优先采用铣刨处治,并将铣刨深度控制在 $6.0\sim 8.0$ mm 内,以获得更优的层间抗剪性能与工程可靠性。

5 结 语

(1)构建了涵盖几何幅值-尺度分布-结构复杂度的界面纹理多元表征指标体系,旧水泥板跑道经过抛丸处治后,各纹理指标随次数增加呈先增后减至平稳,MTD、 H 、 D_{fs} 相比于对照组最大均值增长率分别达 199.3%、286.8%、20.5%;而随铣刨深度增加,上述指标持续上升,MTD 增长率最高达 795.6%, H 、 D_{fs} 亦分别提升 141.4%、56.4%。

(2)抛丸处治在 $0\text{ }^{\circ}\text{C}$ 与 $25\text{ }^{\circ}\text{C}$ 下界面剪切强度相比于未经处治界面可提升 25%~55%,但 $50\text{ }^{\circ}\text{C}$ 时仅 $0.35\sim 0.45$ MPa,较常温衰减 75%以上;铣刨参数为 X-1~X-3 时,各温度下的界面剪切强度增幅趋于平缓,当参数提高至 X-4~X-5 时, $50\text{ }^{\circ}\text{C}$ 条件下强度仍可维持在 0.65 MPa,较 X-3 提高 45%~56%。因此,针对机场“白改黑”工程高温重载工况,应优先选取 X-4~X-5 参数,以显著提升高温残余抗剪能力。

(3)ICOA-MLP-XGBoost 集成模型相较于多种

主流预测模型,在剪切强度数据集上表现出更优越的预测性能,MAE 显著降低 35.8%~46.9%, R^2 提升幅度达 6.1%~10.9%。该模型在训练集上的各项性能指标差异均稳定在 5%以内,且相比于传统 COA-MLP-XGBoost 模型,在训练集上的 MAE 和 R^2 指标相对偏差均值分别降低了 36.8% 和 55.5%。这表明该模型可以有效减小多维度纹理特征数据对剪切强度的扰动,体现了良好的泛化性能与较强的鲁棒性。

(4)相比于输入参数仅包含几何指标的特征集 A,包括几何指标、波谱指标和分形指标的特征集 B 在 ICOA-MLP-XGBoost 模型上 R^2 提升了 17.3%, MAE、MAPE、RMSE 分别下降了 55.8%、48.5%、53.3%。这表明除了几何指标之外,波谱指标与分形指标对界面黏结强度的预测提供了额外的纹理尺度的分布特征和复杂度有效信息。

(5)SHAP 分析表明:在纹理特征中,MTD、 H 、 D_{fs} 是影响剪切强度的 3 个关键因子,这 3 个指标的高 SHAP 贡献区分别为 0.85~0.135、0.002~0.009、1.170~1.186 mm。鉴于机场道面高胎压重载、低速工况下剪应力集中,应使 3 个指标处于高 SHAP 贡献区以保障安全运行。对比 2 类处治方式,仅 X-4 可同时满足该要求,因此建议优选铣刨处治,铣刨深度以 6.0~8.0 mm 为宜。

参 考 文 献 :

References :

- [1] 姜 利,苏 禹,程 维,等.基于应力吸收层的“白改黑”路面温度应力有限元分析[J].科学技术与工程,2019,19(3): 232-238.
JIANG Li, SU Yu, CHENG Wei, et al. Finite element analysis of temperature stress of “white to black” pavement based on stress absorption layer[J]. Science Technology and Engineering, 2019, 19(3): 232-238.
- [2] 向泽君,罗再谦,汪 明.连续实景影像在“白改黑”工程测量上的应用研究[J].测绘通报,2011(9):42-44,69.
XIANG Ze-jun, LUO Zai-qian, WANG Ming. Application of digital panorama map to road project during the night work[J]. Bulletin of Surveying and Mapping, 2011(9): 42-44, 69.
- [3] WU C Y, HONG S X, CHEN T, et al. Application of hot-mixed ultrathin friction course in the white-to-black maintenance project of concrete bridge deck[J]. Journal of Performance of Constructed Facilities, 2022, 36: 04021116.
- [4] DAS R, MOHAMMAD L N, ELSEIFI M, et al. Effects of tack coat application on interface bond strength and short-term pavement performance [J]. Transportation Research Record: Journal of the Transportation Research Board, 2017, 2633(1): 1-8.
- [5] SALINAS A, AL-QADI I L, HASIBA K I, et al. Interface layer tack coat optimization [J]. Transportation Research Record: Journal of the Transportation Research Board, 2013(2372): 53-60.
- [6] RAPOSEIRAS A C, CASTRO-FRESNO D, VEGA-ZAMANILLO A, et al. Test methods and influential factors for analysis of bonding between bituminous pavement layers[J]. Construction and Building Materials, 2013, 43: 372-381.
- [7] KOZUBAL J V, HASSANAT A, TARAWNEH A S, et al. Automatic strength assessment of the virtually modelled concrete interfaces based on shadow-light images [J]. Construction and Building Materials, 2022, 359: 129296.
- [8] MOHAMAD M E, IBRAHIM I S, ABDULLAH R, et al. Friction and cohesion coefficients of composite concrete-to-concrete bond[J]. Cement and Concrete Composites, 2015, 56: 1-14.
- [9] COURARD L, PIOTROWSKI T, GARBACZ A. Near-to-surface properties affecting bond strength in concrete repair[J]. Cement and Concrete Composites, 2014, 46: 73-80.
- [10] SONG W M, SHU X, HUANG B S, et al. Influence of interface characteristics on the shear performance between open-graded friction course and underlying layer[J]. Journal of Materials in Civil Engineering, 2017, 29(8): 04017077.
- [11] ZHANG B S, YU J J, CHEN W Z, et al. Experimental study on bond performance of NC-UHPC interfaces with different roughness and substrate strength[J]. Materials, 2023, 16(7): 2708.
- [12] VALIKHANI A, JAHROMI A J, MANTAWY IM, et al. Experimental evaluation of concrete-to-UHPC bond strength with correlation to surface roughness for repair application[J]. Construction and Building Materials, 2020, 238: 117753.
- [13] SHEN Y J, YANG H W, XI J M, et al. A novel shearing fracture morphology method to assess the influence of freeze-thaw actions on concrete - granite interface [J]. Cold Regions Science and Technology, 2020, 169: 102900.
- [14] TANG Z P, HUANG F L, PENG H. Effect of 3D roughness characteristics on bonding behaviors between concrete substrate and asphalt overlay[J]. Construction and Building Materials, 2021, 270: 121386.
- [15] ORESHKIN O, PLATONOV A, PANOV D, et al. Comparison of metrics for shape quality evaluation of textures produced by laser structuring by remelting (waveshape) [J]. Micromachines, 2022, 13(4): 618.
- [16] CHEN D. Evaluating asphalt pavement surface texture using 3D digital imaging [J]. International Journal of Pavement Engineering, 2020, 21(4): 416-427.
- [17] 张 玲,陈昀灏,王文涛,等.数据驱动的渗蚀-动载作用下粗粒土强度预测[J].中国公路学报,2025,38(10):228-239.
ZHANG Ling, CHEN Yun-hao, WANG Wen-tao, et al. Strength prediction for coarse-grained soil strength subjected to penetrating erosion and cyclic loading via a data-driven approach[J]. China Journal of Highway and Transport,

- 2025, 38(10): 228-239.
- [18] 姚俊峰,何 瑞,史童童,等. 基于机器学习的交通流预测方法综述[J]. 交通运输工程学报, 2023, 23(3): 44-67.
YAO JUN-feng, HE RUI, SHI TONG-tong, et al. Review on machine learning based traffic flow prediction methods[J]. Journal of Traffic and Transportation Engineering, 2023, 23(3): 44-67.
- [19] SADOWSKI L, HOŁA J, CZARNECKI S, et al. Pull-off adhesion prediction of variable thick overlay to the substrate[J]. Automation in Construction, 2018, 85: 10-23.
- [20] 谭忆秋,肖神清,熊学堂. 路面抗滑性能检测与预估方法综述[J]. 交通运输工程学报, 2021, 21(4): 32-47.
TAN Yi-qiu, XIAO SHEN-qing, XIONG XUE-tang, et al. Review on detection and prediction methods for pavement skid resistance [J]. Journal of Traffic and Transportation Engineering, 2021, 21(4): 32-47.
- [21] 曲世琦,梁尊东,张 鑫. 基于增强极限梯度提升算法的沥青混合料动态模量和相位角预测方法[J]. 科学技术与工程, 2025, 25(3): 1225-1234.
QU Shi-qi, LIANG Zun-dong, ZHANG Xin. Enhanced XGBoost-based prediction method for dynamic modulus and phase angle of asphalt mixture[J]. Science Technology and Engineering, 2025, 25(3): 1225-1234.
- [22] 崔建勋,要 甲,赵泊媛. 基于深度学习的短期交通流预测方法综述[J]. 交通运输工程学报, 2024, 24(2): 50-64.
CUI Jian-xun, YAO Jia, ZHAO Po Yuan. Review on short-term traffic flow prediction methods based on deep learning[J]. Journal of Traffic and Transportation Engineering, 2024, 24(2): 50-64.
- [23] 王亦兵,余宏鑫,靳风悦,等. 连续流动态模型引导的深度学习高速公路交通状态估计[J]. 交通运输工程学报, 2025, 12: 1-31.
WANG Yi-bing, YU HONG-xin, JIN FENG-yue, et al. Freeway traffic state estimation using continuum-flow-model guided deep learning [J]. Journal of Traffic and Transportation Engineering, 2025, 12: 1-31.
- [24] 马泽超,刘小明,夏汗青,等. 基于图神经网络的路面病害态势预测方法[J]. 浙江大学学报(工学版), 2024, 58(12): 2596-2608.
MA Ze-chao, LIU Xiao-ming, XIA Han-qing, et al. Pavement distress situation prediction method based on graph neural network[J]. Journal of Zhejiang University (Engineering Science), 2024, 58(12): 2596-2608.
- [25] 邹 政,陈 江,郎 洪,等. 基于机器学习方法的路面病害检测研究综述[J]. 交通信息与安全, 2025, 43(2): 154-168.
ZOU Zheng, CHEN Jiang, LANG Hong, et al. A review of pavement distress detection based on machine learning methods[J]. Journal of Transport Information and Safety, 2025, 43(2): 154-168.
- [26] 曹玉贵,韦嘉豪,梅支耀,等. 基于混合机器学习算法的FRP筋与UHPC粘结强度预测[J]. 沈阳建筑大学学报(自然科学版), 2025, 41(3): 289-298.
CAO Yu-gui, WEI Jia-hao, MEI Zhi-yao, et al. Prediction of bond strength between FRP bars and UHPC using a hybrid machine learning algorithm[J]. Journal of Shenyang Jianzhu University (Natural Science), 2025, 41(3): 289-298.
- [27] 刘文博,杨喜娟,王 力,等. 基于SSA-RBFNN的钢管混凝土界面粘结强度研究[J]. 中国安全生产科学技术, 2025, 21(3): 148-155.
LIU Wen-bo, YANG Xi-juan, WANG Li, et al. Study on interfacial bond strength of concrete-filled steel tube based on SSA-RBFNN[J]. Journal of Safety Science and Technology, 2025, 21(3): 148-155.
- [28] ZHANG C, SHEN S H, HUANG H, et al. In-situ dynamic modulus prediction for asphalt pavement combining machine learning algorithm and sensing technology[J]. IEEE Transactions on Intelligent Transportation Systems, 2024, 25(8): 8695-8704.
- [29] VAN DAO D, NGUYEN N L, LY H B, et al. Cost-effective approaches based on machine learning to predict dynamic modulus of warm mix asphalt with high reclaimed asphalt pavement[J]. Materials, 2020, 13(15): 3272.
- [30] FENG D C, WANG W J, MANGALATHU S, et al. Interpretable XGBoost-SHAP machine-learning model for shear strength prediction of squat RC walls [J]. Journal of Structural Engineering, 2021, 147(11): 04021173.
- [31] MEDDAGE D P P, EKANAYAKE I U, WEERASURIYA A U, et al. Explainable Machine Learning (XML) to predict external wind pressure of a low-rise building in urban-like settings [J]. Journal of Wind Engineering and Industrial Aerodynamics, 2022, 226: 105027.
- [32] RANJIBARAN G, RECUPERO D R, ROY C K, et al. C-SHAP: A hybrid method for fast and efficient interpretability[J]. Applied Sciences, 2025, 15(2): 672.
- [33] WANG H J, LIANG Q X, HANCOCK J T, et al. Feature selection strategies: A comparative analysis of SHAP-value and importance-based methods [J]. Journal of Big Data, 2024, 11(1): 44.
- [34] XING C, HUI B, WANG H N, et al. Research on the roughness characteristics of cement concrete base after treatment based on 3D laser detection technology[J]. Construction and Building Materials, 2025, 460: 139818.
- [35] LIANG J, GU X Y, CHEN Y Z, et al. A novel pavement mean texture depth evaluation strategy based on three-dimensional pavement data filtered by a new filtering approach [J]. Measurement, 2020, 166: 108265.
- [36] MAHATA S, KAR R, MANDAL D. Optimal modelling of $(1+\alpha)$ order butterworth filter under the CFE framework[J]. Fractal and Fractional, 2020, 4(4): 55.
- [37] 徐星星,黄 昶. 基于高完备性自建数据集的集装箱锁销识别[J]. 华东师范大学学报(自然科学版), 2025(4): 28-37.
XU Xing-xing, HUANG Chang. Container lock pins recognition based on a self-built dataset with high completeness[J]. Journal of East China Normal University (Natural Science), 2025(4): 28-37.

- [38] DUNLOP P, SMITH S. Estimating key characteristics of the concrete delivery and placement process using linear regression analysis[J]. *Civil Engineering and Environmental Systems*, 2003, 20(4): 273-290.
- [39] YU H, WANG Q F, SHI J Y. Data augmentation generated by generative adversarial network for small sample datasets clustering[J]. *Neural Processing Letters*, 2023, 55(6): 8365-8384.
- [40] LIN L Y, ZHAO S X, ZHANG Y R, et al. Purposive data augmentation strategy and lightweight classification model for small sample industrial defect dataset[J]. *IEEE Transactions on Industrial Informatics*, 2024, 20(9): 11475-11484.
- [41] FENG K, MA S X, XI H Y, et al. Small-sample-data augmentation and transfer strategies for forest cover change monitoring[J]. *Ecological Indicators*, 2025, 178: 113870.
- [42] GAO S, YANG W H, XU M L, et al. U-MLP: MLP-based ultralight refinement network for medical image segmentation[J]. *Computers in Biology and Medicine*, 2023, 165: 107460.
- [43] NIAZKAR M, MENAPACE A, BRENTAN B, et al. Applications of XGBoost in water resources engineering: A systematic literature review[J]. *Environmental Modelling & Software*, 2024, 174: 105971.
- [44] QIU Y G, ZHOU J, KHANDELWAL M, et al. Performance evaluation of hybrid WOA-XGBoost, GWO-XGBoost and BO-XGBoost models to predict blast-induced ground vibration[J]. *Engineering with Computers*, 2022, 38(5): 4145-4162.
- [45] HUANG J D, KUMAR G S, REN J L, et al. Accurately predicting dynamic modulus of asphalt mixtures in low-temperature regions using hybrid artificial intelligence model[J]. *Construction and Building Materials*, 2021, 297: 123655.
- [46] ZHANG Y, XU X J. Modulus of elasticity predictions through LSBoost for concrete of normal and high strength[J]. *Materials Chemistry and Physics*, 2022, 283: 126007.
- [47] 李芊昀,王自溪,李 杰,等. 基于广义相加模型的北京市 2018—2022 年地面臭氧气象影响要素研究[J]. *环境科学学报*, 2024, 44(4): 206-214.
LI Qian-yun, WANG Zi-xi, LI Jie, et al. Research on the influence of meteorological factors on ground-level ozone in Beijing from 2018 to 2022 based on generalized additive model[J]. *Acta Scientiae Circumstantiae*, 2024, 44(4): 206-214.
- [48] 吴国超,李爱莲,解韶峰. 基于改进的黑翅鸢优化算法-轻梯度提升机建立的转炉炼钢终点温度预测模型[J]. *材料与冶金学报*, 2026, 25(1): 37-45.
WU Guo-chao, LI Ai-lian, XIE Shao-feng. Improved black-winged kite optimization algorithm-light gradient boosting machine model to predict converter steelmaking endpoint temperature[J]. *Journal of Materials and Metallurgy*, 2026, 25(1): 37-45.
- [49] ADLER J, RIBAK E N. Simulated annealing in application to telescope phasing[J]. *Physica A: Statistical Mechanics and Its Applications*, 2021, 572: 125900.
- [50] ZHANG K, MIN Z H, HAO X T, et al. Enhancing understanding of asphalt mixture dynamic modulus prediction through interpretable machine learning method[J]. *Advanced Engineering Informatics*, 2025, 65: 103111.
- [51] ZHANG F, CANNONE FALCHETTO A, WANG D, et al. Prediction of asphalt rheological properties for paving and maintenance assistance using explainable machine learning[J]. *Fuel*, 2025, 396: 135319.
- [52] PHUNG B N, LE T H, MAI H T, et al. Advancing basalt fiber asphalt concrete design: A novel approach using gradient boosting and metaheuristic algorithms[J]. *Case Studies in Construction Materials*, 2023, 19: 02528.
- [53] KENNEDY D M, VAHEY J, HANNEY D. Micro shot blasting of machine tools for improving surface finish and reducing cutting forces in manufacturing[J]. *Materials and Design*, 2005, 26(3): 203-208.
- [54] LU X H, JIA Z Y, ZHANG H X, et al. Tool point frequency response prediction for micromilling by receptance coupling substructure analysis[J]. *Journal of Manufacturing Science and Engineering*, 2017, 139(7): 071004.
- [55] LI L, WANG K C P, LI Q, et al. Impacts of sample size on calculation of pavement texture indicators with 1mm 3D surface data[J]. *Periodica Polytechnica Transportation Engineering*, 2017, 46(1): 42.
- [56] QIAN J S, CEN Y B, et al. Spectrum parameters for runway roughness based on statistical and vibration analysis[J]. *International Journal of Pavement Engineering*, 2022, 23(11): 3757-3769.
- [57] WONG T T, YEY P Y. Reliable accuracy estimates from k -fold cross validation[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2020, 32(8): 1586-1594.