

文章编号:1671-1637(2026)08-0159-16

区域互谱-XGBoost融合的刚性道面 支承劣化识别方法

赵鸿铎^{1,2}, 彭科迪^{1,2,3}, 曾孟源^{*1,2}, 成可^{1,2}, 高达辰^{1,2}

(1. 同济大学 民航飞行区设施耐久与运行安全重点实验室, 上海 201804; 2. 同济大学 道路与交通工程教育部
重点实验室, 上海 201804; 3. 米兰理工大学 建筑、环境与建造系, 伦巴第 米兰 20133)

摘要:针对机场刚性道面板底支承劣化识别中传统动力学指标鲁棒性不足及纯数据驱动模型物理可解释性差、易过拟合的问题,提出了一种数据-物理融合的识别方法。通过理论推导明确了互功率谱密度(简称互谱)与道面支承状态的相关性,并面向分布式振动感知提出了区域互谱;区域互谱与XGBoost结合建立了数据物理融合方法,分步识别支承劣化板块及其具体位置;通过对比物理指标法、PCA-SVM数据驱动法及本融合方法在2个试验场景下的表现,验证了其有效性。分析结果表明:区域互谱综合反映了结构振型、频率、阻尼比对道面支承状况的影响,且加载点对支承异常的敏感性显著高于互谱计算点;在识别性能上,物理指标法的平均准确率(83.35%)和召回率(50%)最低;数据驱动方法虽准确率达90.75%,但实际数据可分性较弱且特征冗余(7~14个);数据-物理融合方法表现最优,准确率提升至91.65%,召回率达77.5%,特征维度大幅降至3~5个,特征对应于区域互谱对支承状态的敏感频段,物理可解释性强。研究为刚性道面支承劣化识别提供了一种将物理信息与数据特征结合的方法,在改进既有物理指标的同时,也为人工智能方法在道面结构异常识别的应用提供了可能的途径。

关键词:机场工程;刚性道面;数据物理融合;脱空识别方法;振动监测;互功率谱密度

中图分类号:U416.2 **文献标志码:**A **DOI:**10.19818/j.cnki.1671-1637.2026.236

Identifying method of rigid pavement support deterioration based on local CPSD-XGBoost fusion

ZHAO Hong-duo^{1,2}, PENG Ke-di^{1,2,3}, ZENG Meng-yuan^{*1,2}, CHENG Ke^{1,2}, GAO Da-chen^{1,2}

(1. Key Laboratory of Infrastructure Durability and Operation Safety in Airfield of CAAC, Tongji University, Shanghai 201804, China; 2. Key Laboratory of Road and Traffic Engineering of Ministry of Education, Tongji University, Shanghai 201804, China; 3. Department of Architecture, Built Environment and Construction Engineering, Politecnico di Milano, Milan 20133, Lombardia, Italy)

Abstract: In response to insufficient robustness in traditional dynamic indicators and poor physical interpretability or over-fitting in purely data-driven models for identifying the deterioration of airport rigid pavement slab support, a data-physics fusion identification method was proposed. The

出版历程:2025-12-31 收稿,2026-03-13 修回,2026-03-20 录用

基金项目:国家自然科学基金项目(52278457);国家留学基金委项目(CSC202406260268)

作者简介:赵鸿铎(1976-),男,浙江宁海人,教授,博士生导师,工学博士,E-mail:hdzhao@tongji.edu.cn。

*通信作者:曾孟源(1995-),男,四川成都人,副教授,博士生导师,工学博士,E-mail:myzeng@tongji.edu.cn。

引用格式:赵鸿铎,彭科迪,曾孟源,等. 区域互谱-XGBoost融合的刚性道面支承劣化识别方法[J]. 交通运输工程学报,2026,26(8):159-174.

Citation: ZHAO Hong-duo, PENG Ke-di, ZENG Meng-yuan, et al. Identifying method of rigid pavement support deterioration based on local CPSD-XGBoost fusion[J]. Journal of Traffic and Transportation Engineering, 2026, 26(8): 159-174.

correlation between cross power spectral density (CPSD) and the pavement support state was clarified through theoretical derivation. For distributed vibration sensing, local CPSD was proposed. A data-physics fusion method was developed by combining local CPSD with XGBoost to identify slabs with deteriorated support and subsequently locate the specific regions. Its effectiveness was validated by comparing the performance of the physical indicator method, the principal component analysis-support vector machine (PCA-SVM) data-driven method, and the proposed fusion method across two experimental scenarios. Analysis results show that local CPSD comprehensively reflects the influence of structural mode shapes, frequencies, and damping ratios on the pavement support state. Furthermore, the sensitivity of loading points to support anomalies is significantly higher than that of the CPSD calculation points. Regarding identification performance, the physical indicator method has the lowest average accuracy (83.35%) and recall (50%). Although the data-driven method achieves an accuracy of 90.75%, the actual data exhibit weak separability and feature redundancy (7-14 features). The data-physics fusion method performs the best, with the accuracy rising to 91.65%, the recall reaching 77.5%, and the feature dimension significantly reducing to 3-5. These features correspond to the sensitive frequency bands of the local CPSD for support states, providing strong physical interpretability. A method is provided to combine physical information with data features for identifying support deterioration in rigid pavements. While improving existing physical indicators, it also offers a possible path for applying artificial intelligence methods to identify anomalies in pavement structures.

Keywords: airport engineering; rigid pavement; data-physics fusion; void identification method; vibration monitoring; cross power spectral density

Publication history: Received 2025-12-31; Received in revised form 2026-03-13; Accepted 2026-03-20

Funding: National Natural Science Foundation of China (52278457); Program of China Scholarship Council (CSC202406260268)

* **Corresponding author:** ZENG Meng-yuan, associate professor, PhD, E-mail: myzeng@tongji.edu.cn.

0 引 言

刚性道面结构在温度梯度和动水作用下,道面板可能与基层发生局部脱离,导致板底支承状况劣化,形成板底脱空。板底支承劣化进一步发展可能导致接缝唧泥、错台甚至断板^[1]。因此,及时发现道面支承状态异常对保障道面结构性能和飞机运行安全有重要意义。

传统道面脱空识别主要采用重落锤式弯沉仪 (Heavy Weight Deflectometer, HWD) 测试^[2]、探地雷达^[3-4]、应力波^[5-6]等检测方法,需要在停航间隙开展;较低的检测频次也使其可能错过早期的道面支承异常。而基于埋入式传感器监测运行荷载下的道面振动,可实时识别道面结构支承状况的变化。Wu 等^[7]研发了新型光纤压缩传感器,基于压缩-应变传递机制识别板底与基层的接触状态;赵坪锐等^[8]采用柔度曲率特征值进行脱空的识别和定位。

但支承劣化一般发生于局部区域,点式传感器覆盖范围有限,获取的结构振动信息可能不完备。

如果测点距离脱空区域较远,脱空对振动的影响可能被噪声掩盖。Zeng 等^[9]提出荷载位置与传感器测点应小于 0.3 m 以保证支承条件评估的可靠性。因此,基于低成本、长距离、广覆盖的分布式光纤测量道面结构振动的方法得到发展,有研究发现自功率谱密度(简称自谱)的频谱特征对脱空面积敏感^[10],初步验证了基于自谱识别支承劣化的可行性。但自谱的准确性取决于单个测点的信号质量,实测自谱会受到噪声影响。曾孟源等^[11]进一步考虑了不同测点间的相关性,开展了互功率谱密度(简称互谱)分析,变维度解析了铺面振动全局频域特征。频域分析相关研究还提出了加权频率变化量^[10]、小波包能量^[12]、振动传递率矩阵^[13]等指标识别道面支承异常。

这些人为构建的频域指标具有明确的物理内涵,但也存在两方面问题:①频段和阈值选取泛化能力不足,对支承状态敏感的频段可能随着荷载位置、速度等发生变化^[9],显式设定的频段及支承异常的判定阈值在不同工况下的适用性有待提升;②容易

受到噪声干扰,分布式振动监测在获取高维度数据的同时也包含大量噪声干扰,可能降低所建立的指标对板底支承劣化的敏感度。

当前人工智能方法在提取复杂特征、自适应确定阈值方面体现出一定优势^[14]。Sonoda等^[15]基于卷积自编码器定量检测了混凝土空洞大小。张军等^[16]使用探地雷达数据时频特征和极限梯度提升算法(eXtreme Gradient Boosting, XGBoost)构建了脱空识别模型,识别准确率达到98.1%。Zhang等^[17]建立了ResNet18-YOLOv2浅层卷积神经网络模型,识别道面脱空的 F_1 分数超过90%。Li等^[18]基于生成对抗网络提出了风格迁移算法,增强了脱空检测模型的泛化性能。Shi等^[19]对比了多类BP神经网络,发现鲸群优化BP网络预测脱空的能力最佳。但完全依赖数据驱动得到的黑箱模型解释性较差^[20]。物理信息神经网络(Physics-informed Neural Network, PINN)通过采用在惩罚项引入物理边界或强化特征等手段,实现物理建模与深度学习相结合,已经被用于弹性板变形计算^[21]、薄板损伤识别^[22]等研究,但这类方法在实际应用中还面临样本数量与计算成本等挑战。机场道面脱空识别通常难以获取大量已发生脱空的振动数据样本^[23],因而这类方法在有限样本中容易陷入过拟合。

为了有效融合分布式感知的物理与数据信息、实现刚性道面支承劣化的精准识别,本文提出了一种基于区域互功率谱密度(Cross Power Spectral Density, CPSD,下文简称互谱)与XGBoost的数据-物理融合方法,并在小样本脱空数据集上验证。一方面构建区域互谱以增强频域分析的可靠性;另一方面将物理信息前置于特征工程阶段,减少纯数据方法的冗余信息,提高机器学习方法的可解释性。在2个试验场景下对比所提出的方法与传统物理指标构建法、数据驱动机器学习方法的结果,验证了融合方法在支承劣化板块与位置识别中的准确性、鲁棒性及物理可解释性。

1 道面板底支承状态对结构互谱的影响

道面面层结构板可简化为一个多自由度线性系统,用经典结构动力学方程表示其振动如下

$$M\ddot{x}(t) + C\dot{x}(t) + Kx(t) = f(t) \quad (1)$$

式中: M 、 C 、 K 分别为结构的质量、阻尼和刚度矩阵; $x(t)$ 和 $f(t)$ 分别为 t 时刻各个自由度上的位移与荷载向量。

当道面结构发生支承劣化产生脱空,底部边界条件变化将导致 C 和 K 变化,进而影响相同荷载下的结构响应 $x(t)$,该影响也反映在结构响应的频域表达 $X(\omega)$, ω 为频率。

结构上任意2个测点 i, j 的振动响应 $x_i(t)$ 和 $x_j(t)$,通过傅里叶变换转换到频域得到 $X_i(\omega)$ 和 $X_j(\omega)$ 。对于能量有限信号,互谱密度 $S_{ij}(\omega)$ 反映了二者在频域上的相关性,按式(2)计算

$$S_{ij}(\omega) = \lim_{T \rightarrow \infty} \frac{1}{T} E[X_i^*(\omega) X_j(\omega)] \quad (2)$$

式中: T 为信号周期; $E(\cdot)$ 为数学期望。

在道面结构上施加激励荷载 $f(t)$ [频域为 $F(\omega)$]时, $X_i(\omega)$ 和 $X_j(\omega)$ 可以用频响函数 $H_i(\omega)$ 和 $H_j(\omega)$ 表达为

$$X_i(\omega) = H_i(\omega) F(\omega) \quad (3)$$

$$X_j(\omega) = H_j(\omega) F(\omega) \quad (4)$$

将式(3)、(4)代入式(2),得到

$$\begin{aligned} S_{ij}(\omega) &= \lim_{T \rightarrow \infty} \frac{1}{T} E\{[H_i(\omega) F(\omega)]^* [H_j(\omega) F(\omega)]\} \\ &= H_i^*(\omega) H_j(\omega) \lim_{T \rightarrow \infty} \frac{1}{T} E[|F(\omega)|^2] \\ &= H_i^*(\omega) H_j(\omega) S_{FF}(\omega) \end{aligned} \quad (5)$$

式中: $S_{FF}(\omega)$ 为荷载谱。

根据频响函数定义式(6)、(7),互谱 $S_{ij}(\omega)$ 可进一步变换为式(8)

$$H_i(\omega) = \sum_{k=1}^{\infty} \frac{\phi_k(x_i) \phi_k(x_F)}{\omega_k^2 - \omega^2 + i\eta_k \omega_k^2} \quad (6)$$

$$H_j(\omega) = \sum_{k=1}^{\infty} \frac{\phi_k(x_j) \phi_k(x_F)}{\omega_k^2 - \omega^2 + i\eta_k \omega_k^2} \quad (7)$$

$$\begin{aligned} S_{ij}(\omega) &= \sum_{k=1}^{\infty} \frac{\phi_k(x_i) \phi_k(x_F)}{\omega_k^2 - \omega^2 + i\eta_k \omega_k^2} \cdot \\ &\quad \sum_{k=1}^{\infty} \frac{\phi_k(x_j) \phi_k(x_F)}{\omega_k^2 - \omega^2 + i\eta_k \omega_k^2} S_{FF}(\omega) \end{aligned} \quad (8)$$

式中: $\phi_k(x_i)$ 、 $\phi_k(x_j)$ 、 $\phi_k(x_F)$ 分别为两测点位置及加载点位置的 k 阶振型; ω_k 和 η_k 分别为第 k 阶模态频率及阻尼比。

图1所示的实测功率谱密度曲线表明,HWD宽频冲击荷载激发了625 Hz附近甚至更高频率的高阶模态,但在能量分布上,0~250 Hz低频段仍占主导地位。选取能量更集中的一阶模态为代表,将式(8)中的 k 阶结果求和简化为只考虑一阶,并对互谱取绝对值以分析幅值,得到式(9)




图1 板底支承状态对互谱的影响

Fig. 1 Influence of support conditions of slab on cross power spectral density

$$|S_{ij}(\omega)| \approx \frac{|\phi_1(x_i)| |\phi_1(x_j)| \phi_1^2(x_F)}{(\omega_1^2 - \omega^2 + i\eta_1 \omega_1^2)^2} |S_{FF}(\omega)| \quad (9)$$

式中: $\phi_1(x_i)$ 、 $\phi_1(x_j)$ 、 $\phi_1(x_F)$ 分别为点 i 、 j 和加载点的一阶振型; ω_1 、 η_1 分别为一阶频率和阻尼比。

式(9)表明,互谱幅值包含了结构振型、频率、阻尼比以及荷载特性的影响。

该简化仅针对互谱幅值随支承状态变化的控制方程,旨在揭示互谱幅值等特征与模态参数间的因次关系[如式(9)所示的幂次比例],而非为了建立精确的定量数值关系。进一步分析式(9)中的各项。如图1所示,当道面板底支承状态发生劣化,部分区域板底出现脱空,脱空区的振型绝对值将增大。如果互谱计算点 i 或 j 或加载点位于脱空区, $|\phi_1(x_i)|$ 、 $|\phi_1(x_j)|$ 或 $|\phi_1(x_F)|$ 增大,式(9)的分子项将增大;同时,脱空将降低结构整体刚度矩阵,导致道面结构频率和阻尼比下降^[24],即式(9)的分母项减小。在荷载相同的条件下, $S_{FF}(\omega)$ 保持不变,最终脱空将导致 $|S_{ij}(\omega)|$ 增大。因此,道面板底支承状态的劣化将对互谱幅值产生影响。

其中,式(9)分子项含有的 $\phi_1(x_F)$ 为平方项,而 $\phi_1(x_i)$ 和 $\phi_1(x_j)$ 为一次项,所以加载点振型比计算点振型对结果的影响更显著。当二者分别位于支承劣化区域时,由于幂次差异,加载点比计算点对互谱绝对值的影响更大,即加载点比计算点对道面支承状态的变化更加敏感。

在计入能量幅值相对较低的高阶模态后,互谱幅值与振型函数间的严格正比例关系可能退化为非线性关系。但支承劣化导致的能量频域变化是单向的,这种单向性是基于互谱识别板底支承劣化的基础。

2 基于区域互谱的道面支承劣化识别方法

根据道面支承状态对结构互谱的影响规律,结

构不同位置的互谱可能包含板底支承状态等信息。采用分布式光纤实测道面结构振动,利用分布式优势,测点可以覆盖道面板的更多位置和区域,加载点与互谱计算点位于支承劣化区域的概率也更大,这将更有利于识别潜在的支承劣化或脱空。为了综合考量分布式监测获得的多点振动,首先提出了区域互谱,将其作为后续支承劣化识别的基础物理量。

由于实际工程中道面长度大、范围广,直接对全跑道开展脱空的精细识别效率较低。所以采取分步识别策略,先识别出可能脱空的板或范围(例如一块或几块板),再定位该板的具体脱空位置(例如某板边或板角附近)。相应地,道面支承劣化识别可划分为2个子任务:异常板的识别与具体异常位置的识别。区域互谱在这两项子任务中的计算方法如下。

假设道面板内有 N 个监测点,因为加载点的振动响应信噪比通常高于其他测点,所以将式(9)中的其中一个计算点 j 固定为加载点,再与其他测点两两计算互谱,并对 N 个测点的结果取均值,得到以板为单位的区域互谱 $S_L(\omega)$,按式(10)计算

$$S_L(\omega) = \frac{1}{N} \sum_{i=1}^N |S_{iF}(\omega)| = \frac{|\phi_0^3(x_F)| |S_{FF}(\omega)|}{N(-\omega^2 + \omega_0^2 + i\eta_0 \omega_0^2)^2} \sum_{i=1}^N |\phi_0(x_i)| \quad (10)$$

式中: $S_{iF}(\omega)$ 为测点 i 与加载点的功率谱密度。

在初步筛选出潜在的支承劣化板后,可对其补充测试与分析,计算以单元为单位的区域互谱,并据此识别具体的支承劣化位置。根据支承劣化位置识别所期望的空间分辨率,确定分析单元的平面范围,每一个分析单元包含 n 个测点,根据式(11)计算每个分析单元内的区域互谱 $S_L(\omega)$ 为

$$S_L(\omega) = \frac{1}{n^2} \sum_{i=1}^n \sum_{j=1}^n |S_{ij}(\omega)| = \frac{|S_{FF}(\omega)|}{n^2} \cdot \frac{\phi_1^2(x_F) \sum_{i=1}^n \sum_{j=1}^n |\phi_1(x_i)| |\phi_1(x_j)|}{(\omega_1^2 - \omega^2 + i\eta_1 \omega_1^2)^2} \quad (11)$$

区域互谱用于支承劣化识别的原理与互谱类似。在式(10)、(11)中,支承劣化板(或位置)所包含的部分计算点位于脱空区,这些计算点的 $\phi_1(x_i)$ 或 $\phi_1(x_j)$ 增大导致 $\sum_{i=1}^n |\phi_1(x_i)|$ 或 $\sum_{i=1}^n \sum_{j=1}^n |\phi_1(x_i)| |\phi_1(x_j)|$ 增大;同时脱空将使 ω_1 、 η_1 减小;若加载点位于脱空位置还将导致 $\phi_1^2(x_F)$ 增大;三方面综合影响导致支承劣化板(或位置)的 $S_L(\omega)$ 与支承健康板(或位置)

出现显著差异,据此可以识别道面结构的支承劣化。

根据特征工程策略共设计了3种识别方法:方法1为传统物理指标构建法,它依赖领域知识和专家经验,由于指标复杂度较低,在复杂工程环境下容易受到噪声及误差的影响;方法2为数据驱动方法,作为黑箱模型,它所提取的特征或最终结果可能难以理解;为了克服二者的局限性,本研究提出了方法3,为数据-物理融合方法。

图2为本研究开展道面支承劣化识别的示意图,总体上各方法均按照“异常板识别→异常位置识别”的顺序识别,再对每一类方法的识别结果进行对比。




图2 道面支承劣化识别的顺序与方法对比

Fig. 2 Order and method comparison of pavement support deterioration identification

2.1 方法1:基于频带能量占比的物理指标构建法

方法1基于区域互谱的物理意义构造指标。支承劣化导致的区域互谱变化,不仅包含振型导致的整体幅值增大[式(10)、(11)中最右端的求和项],还包括因频率与阻尼比导致的频域分布变化[式(10)、(11)中的分母项],该分布变化既包括峰值频带的偏移,也可能包含区域互谱在特定频段异常增大^[25-26]。

为了反映区域互谱的频域分布特征,对 $S_L(\omega)$ 在频段 $\omega_1 \sim \omega_2$ 上积分,计算其在全频段区域互谱积分中的能量占比 γ ,简称频带能量占比,以此作为识别道面支承异常板块或具体位置的指标

$$\gamma = \frac{\int_{\omega_1}^{\omega_2} S_L(\omega) d\omega}{\int_0^{\infty} S_L(\omega) d\omega} \quad (12)$$

所构建的物理指标在判定支承异常时需要确定阈值。由于结构损伤通常具有稀疏性,因此假设监

测区域中仅有少部分板的支承发生劣化;对于单块板,假设仅有部分位置的支承发生显著劣化,因此只需要识别频带能量占比中的少数异常值。基于统计特性设定阈值 T_0 ,如式(13),将 γ 超过阈值的板(或位置)识别为潜在的支承劣化板(或支承劣化位置)

$$T_0 = \mu + \nu\sigma \quad (13)$$

式中: μ 和 σ 分别为全体样本的频带能量占比均值和方差; ν 为决定阈值宽容程度的系数。

2.2 方法2:基于PCA与SVM的数据驱动方法

识别道面支承是否劣化是一个典型的二分类问题,方法2通过数学变换从数据中提取与支承条件相关的主要特征,并进行分类判断。

区域互谱作为频域分析的结果,其频域坐标点(频率点)的数量远多于样本数量,若直接将区域互谱曲线作为分类模型的输入会导致维度灾难。因此首先对整块板或板内不同位置的区域互谱有效降维,再采用机器学习分类器判断支承劣化情况。本

研究采用主成分分析(Principal Component Analysis, PCA)及支持向量机(Support Vector Machine, SVM)分别实现频域数据降维与特征分类,作为机器学习领域的经典方法,二者用于稀疏样本的有效性已被验证^[27-28]。

首先对原始区域互谱进行标准化处理,减小原始幅值影响以关注频域分布特征。通过PCA将区域互谱降维到正交子空间,以累计解释方差比超过80%为阈值,自适应地确定主成分数量。随后,将选定的主成分输入SVM进行分类。由于样本和特征数量较少,采用简单线性函数为核函数;针对脱空样本少、健康样本多的不平衡问题,在损失函数中引入了类别权重,提高模型对少数脱空样本的关注度。

2.3 方法3:基于XGBoost的数据-物理融合方法

数据-物理融合方法选择XGBoost模型为主干,XGBoost是一种基于树的模型,本身已具有较好的可解释性^[20],在损伤特征提取^[29]、结构行为预测^[30]中展现出较优秀的性能。首先采用XGBoost算法的非线性特征捕捉能力识别关键频率特征点^[31],再结合物理意义重构特征、用于样本分类和支承状态识别。

在第1阶段,XGBoost作为特征排序器,输入原始的高维度区域互谱,计算每一频率值在分类过程中的累积增益,增益值越高说明该频率点对结果预测的贡献度越大。由于数据样本有限,为了降低随机误差的干扰并保证所筛选频率点的物理稳定性,采用 K 折交叉验证,在每一折中计算各频率点的增益值并累积,根据 K 折累积增益曲线筛选出贡献度最高的几个频率值。

在第2阶段,为了提高模型鲁棒性并增强特征的物理意义,观察筛选出的离散频率点并适当合并,创建多个潜在有效频段。计算各个频段区域互谱的均方根(Root Mean Square, RMS),作为特征排序后重新构造的物理特征。该步骤对一阶段得到的频率点特征进一步降维,可降低噪声和频谱漂移效应对结果的影响。最后将重新构造的特征输入XGBoost分类器,识别支承劣化板或位置。针对样本不平衡问题,在XGBoost模型中引入了梯度权重,通过放大少数类样本的梯度贡献,提高支承劣化样本在损失函数中的权重,进而增强决策树分裂过程中对支承劣化误判的敏感度。

为了评估不同模型的泛化能力并最大化数据利用率,后2种方法在评价模型时都采用了交叉验证策略。具体而言,针对样本量较小的支承劣化板的识别任务,选用留一法策略;针对样本量相对充足的

位置识别任务,采用 K 折交叉验证策略(本研究中 $K=5$);并采用防泄露设计,将主成分提取、XGBoost特征排序等特征工程步骤限制在每一折的训练集中,防止模型提前看过数据而作弊。

3类方法的板底支承状态识别结果以混淆矩阵展示,结果分为4类:板或位置的支承异常且正确识别为异常(True Positive, TP)、实际异常但被漏识别为健康(False Negative, FN)、实际健康且被正确识别为健康(True Negative, TN)、实际健康但被误识别为异常(False Positive, FP)。在实际道面板底支承状态评价中,更关注异常状态的有效检出、避免漏识别,因此期望获得更多TP和更少FN结果。

此外,本研究中脱空板和脱空位置识别都存在数据集明显不平衡的问题,因此单纯的准确率不足以反映模型性能,还需要关注召回率、 F_1 分数等指标,综合评价各方法的道面支承劣化识别能力。

3 试验设计


为了比较和验证3种方法识别支承劣化的有效性和鲁棒性,首先开展9块板试验,修建了板底支承良好及存在脱空的板,以板为单位识别板底支承状态。但每块板受限于尺寸、所包含的分布式光纤振动感知单元数量较少。为进一步比较各方法识别支承劣化位置的效果,开展足尺单板试验,在板下预设了板边和板角脱空,以光纤感知单元为单位判断不同位置的支承状况。

3.1 试验场景1


在半刚性基层上 $4.5\text{ m}\times 4.5\text{ m}\times 0.15\text{ m}$ 范围内修建了9块道面板,单板尺寸为 $1.5\text{ m}\times 1.5\text{ m}\times 0.15\text{ m}$,如图3(a)所示。其中板#7~#9通过凿除指定区域的半刚性基层构造了板角和板边脱空,模拟道面板底支承劣化,凿除深度约为3 cm。为防止混凝土浇筑时流入预设脱空区而导致脱空构造失败,在脱空区填入极易溶盐临时支撑,上覆防水布并封边,结构平面及断面分别如图3(b)、(c);在面层混凝土初步凝固后,注水冲刷盐颗粒进而形成脱空。在结构施工完成后,使用工业内窥镜检查脱空区面层与基层的分离情况,经确认3处脱空均构造成功。

在9块板中布设首尾相连的分布式振动光纤,每块板中的有效监测长度约64 m,包含16个感知单元,每个单元包含4个测点。计算同一单元内各测点响应的平均值以提高信噪比,并代表该单元位置的实测振动。


采用便携式落锤式弯沉仪(Portable Falling




(a) 预设脱空区域



(b) 现场脱空及光纤位置



(c) 预设脱空断面



(d) 4组加载工况的具体位置

图 3 试验场景 1 的布置情况

Fig. 3 Layout of test scene 1

Weight Deflectometer, PFWD)对道面结构施加冲击荷载,根据加载位置(板中、板边、板角等)将加载工况归纳为4组,分别记为A~D,具体加载点位如图3(d)。记录每组加载中9块板的实测振动,共获

得36个以板为单位的样本,其中脱空板样本(板#7~#9)共12个。各样本按“组号-板号”编号,例如样本A-8代表工况A板中加载期间板#8的区域互谱。

3.2 试验场景 2


于同济大学结构试槽修建了一块 $4\text{ m}\times 4\text{ m}\times 0.35\text{ m}$ 的装配式足尺道面板,其位于细砂找平的半刚性基层上,底部的细砂厚度约为3 cm。通过挖除细砂,人为构造了如图4(a)的 $1.2\text{ m}\times 0.7\text{ m}$ 板边脱空和直角边长1.3 m的板角脱空;随后将道面板吊装放置于预设的平面位置,如图4(b)所示。

道面板中布设了与9块板试验相同的振动感知单元,固定于钢筋网架上,板内有效光纤长度共包含144个测点,对应36个感知单元,光纤布置及感知单元序号如图4(c)。2处脱空范围恰好覆盖了感知单元7、18、19与感知单元31。采用HWD在板中及脱空的板边、板角分别进行加载,加载位置见图4(b)圆圈,各点位重复加载6次。按照图4(b)进行E、F、G三组测试后,共得到108个以光纤单元为单位的样本,其中存在脱空的位置占总样本的1/9。


在场景1、2试验期间,均采用NZS-DAS-A01解调仪监测道面结构振动,采样频率为2 500 Hz,激光脉冲宽度为30 ns,测点空间间隔1.021 1 m,标距为测点间隔的3倍。对原始信号进行线性去趋势,消除直流分量。由于实测振动为瞬态冲击信号,为了减少频谱泄露,互谱计算时采用汉宁窗,窗长为1 024。



(a) 脱空构造



(b) 脱空及加载位置



(c) 感知单元布置

图 4 试验场景 2 的布置情况

Fig. 4 Layout of test scene 2

4 支承劣化识别结果

为了排除分类器自身性能差异对结果的影响,本节在第2节所述3种方法的基础上,增设PCA+XGBoost作为控制变量对照组。该对照组输入与方法2相同的PCA降维特征,并采用与方法3相同的XGBoost分类器。在分类器相同的条件下对比区域互谱特征与PCA特征,验证融合方法在物理特征降维与识别准确性等方面的优势。

4.1 支承劣化板的识别结果

试验场景1的9块板在板中(加载工况A)、板边(加载工况B、C)和板角(加载工况D)的单板区域互谱分别见图5(a)~(c)。

图5(a)为板中加载结果。板#9在300~800 Hz的幅值明显高于其他板,区域互谱主要分布于该频段;板#7、#8略高于其他板,但与其他板的差异相对较小。图5(b)的板边加载结果中,300~800 Hz内的区域互谱的幅值从大到小为板#9、#8、#7、其他板;在800 Hz以上,板#1~#6的区域互谱包含3个峰值,其中板#1最为显著,而板#7~#9的3个峰值相对较小,其中板#9最弱。图5(c)的板角加载工况下,板#7~#9的区域互谱也主要分布在300~800 Hz,在该频段的幅值由大到小依次为板#7、板#9、板#8,且显著大于6块支承健康板。

综合上述结果,支承劣化板#7~#9的区域互谱均在300~800 Hz内分布更集中。为进一步分析支承劣化导致区域互谱变化的原因,提取这3块板的结果,见图6。区域互谱在频域的变化差异可归因为计算点和加载点两方面,具体分析如下。

(1) 计算点的影响

当加载点不在脱空区内,脱空区包含的计算点越多,脱空板与健康板的区域互谱差异越显著。以板中加载工况图6(a)为例,板#7~#9各有1、1、4个感知单元位于脱空区域内,分别对应4、4、16个计算点,根据式(10),脱空区域内的计算点越多,即有更多 $\phi_1(x_i)$ 增大,进而导致 $S_L(\omega)$ 越大,因此3块支承劣化板的区域互谱在优势频段的幅值大于其他板。图6(a)中,板#9与其他板的差异最显著,而板#7和#8在750 Hz以内几乎完全重合。

图6(c)的板角加载工况下,板#8、#9的加载点均位于支承健康区域,但由于板#9脱空区包含的计算点数量大于板#8(16个大于4个),所以板#9在优势频段的分布比板#8更集中。

(2) 加载点的影响

当加载点位于脱空区,区域互谱在300~800 Hz内随脱空区加载点增加而增大。如图6(b)所示,随脱空区的加载点数量递增(板#7~#9分别为0、1、3个),优势频段的区域互谱幅值呈现出板#9、#8、#7由大到小的趋势。图6(c)也反映了相同规律,脱空区有1个加载点的板#7,其区域互谱幅值高于脱空区无加载点的板#8。

(3) 二者影响对比

加载点脱空引起的区域互谱变化显著大于计算点脱空的情况。该现象可由式(10)解释,由于在单板区域互谱的计算中采用了加载点作为参考点, $S_L(\omega)$ 对加载点模态振型 $\phi_1(x_F)$ 具有三次方的依赖关系,而对计算点振型 $\phi_1(x_i)$ 仅为一次方依赖,该幂次差异放大了区域互谱对加载点处脱空的敏感性。如图6(c),以板#8为基准,虽然板#9在脱空区增加了12个计算点,但其区域互谱在300~800 Hz内总体上仍低于增加了1个加载点的板#7。

将300~800 Hz设定为关注频段,各板在该频段的频带能量占比见图7。在36个样本中,除样本C-7以外(板边加载工况C的板#7,图7的第25个样本),其他11个脱空板样本的频带能量占比均大于均值 μ (水平点线),说明脱空板的频带能量占比在所有样本中偏大,所观察到的物理规律有效。设阈值为 $T_0 = \mu + \sigma$,4个样本超过阈值(水平虚线),但有8个样本漏识别,召回率仅为33.3%;若以 μ 为阈值,召回率可达91.7%,但7个健康样本被误认为脱空。相关结果表明,物理指标构建法对脱空板的识别结果会受到阈值选取的显著影响,鲁棒性不足。

采用数据驱动方法识别道面板底支承异常时,以区域互谱为输入。但每个样本的区域互谱为一个长度为2 501的向量,对于36个样本的识别严重冗余。为了消除特征冗余并提取关键信息,首先采用PCA对原始高维数据进行降维。提取出的各主成分的方差解释比见图8,其中前7个主成分的累积方差贡献率为82.4%(大于设定的阈值80%),包含了原始数据的大部分信息,因此被选定为输入SVM用于分类的特征向量。

为了直观展示特征分布并从视觉上检验样本的可分性,图9进一步选取了信息量最集中的前2个主成分(累积方差贡献率54.1%),将高维特征空间映射至二维平面。尽管二维投影只保留了部分方差信息,但图9中2类样本已大致呈现出分离趋势,脱空板样本(三角形与叉号)主要分布于图中




图 5 九块板试验的区域互谱密度

Fig. 5 Local cross power spectral density of nine slab tests




图6 脱空区的计算点与加载点对区域互谱的影响分析

Fig. 6 Influence analysis of calculation points and loading points in void area on local CPSD




图7 九块板试验各样本的频带能量占比

Fig. 7 Band energy ratios of samples in nine slab tests

的右上区域, 支承良好的样本(圆圈与方块)主要分布于左下方区域, 这表明 PCA 识别到了部分有效特征。

基于数据的可分性基础, 将前述的 7 个主成分输入 SVM 进行最终分类, 预设脱空样本正确识别到 9 个, 漏识别 3 个(A-7、B-7、D-9 号样本), 召回率提升至 75.0%。在对照组中, 采用 XGBoost 分类器识别到的脱空板样本与 SVM 完全一致。

数据-物理融合方法中, 首先建立基于 XGBoost 的特征排序器, 计算各频率点在每次分类中的累积增益值, 结果见图 10(a), 用圆点标出了累积增益值

前 5 的频率点。同时, 在每一轮留一法验证中对增益排名前 15 的频率点计数, 图 10(b)为各频率点的累积频次, 并标出了频次超过 2/3(27 次)的频率点。图 10(a)可以反映特征的增益强度, 图 10(b)反映特征的稳定性。二者结果具有较高的一致性, 突出的频率值都位于 720 Hz 附近。

以图 10(a)的结果进一步提炼物理特征, 累积增益前 5 的频率点为 704.50、717.75、718.50、721.25、728.75 Hz, 综合考虑频带之间的重叠及频带对频率点的覆盖, 将带宽设为 12 Hz, 选取 698~710、713~725、723~735 Hz 三个有效频段。最后以 3 个频段




图8 主成分方差解释比

Fig. 8 Variance interpretability ratio of principal components






图9 前2个主成分的二维可视化与板的识别结果

Fig. 9 2D visualization of the first two principal components and slab identification



(a) 按照累积增益值



(b) 按照增益排名计算频次

图10 XGBoost特征排序中不同频率点的贡献度

Fig. 10 Contribution of different frequency points in XGBoost feature ordering

的区域互谱RMS作为特征,输入XGBoost分类器进行支承劣化板的识别。该方法正确识别了10个预设脱空的板样本,漏识别2个脱空样本(A-7、A-8号样本),召回率提升至83.3%。

4种方法在支承劣化板识别中的混淆矩阵及分类评价指标汇总于表1。物理指标构建法的效果最差,这可能是由于频带划分不够精细、环境噪声干扰以及基于均值和标准差的阈值缺乏自适应性。数据驱动方法、对照组和数据-物理融合方法都借助机器学习捕获了数据特征,显著改善了脱空板的识别结果,准确率分别提升了8.3%和11.1%。与PCA+SVM相比,对照组改变分类器未对结果产生影响,而融合方法通过引入物理特征使召回率提高了8.3%。但该变化仅对应于一个样本的检出结果不同,考虑到样本规模较小,可认为后3种方法识别支承劣化板的性能相近。

表1 不同方法对支承劣化板的识别效果对比

Table 1 Comparison of identification performances of methods on slabs with deteriorated support

方法	预测结果							
	物理指标构建		PCA+SVM		PCA+XGBoost		XGBoost排序分类	
	健康	异常	健康	异常	健康	异常	健康	异常
实际健康	24	0	22	2	22	2	22	2
实际异常	8	4	3	9	3	9	2	10
准确率/%	77.8		86.1		86.1		88.9	
召回率/%	33.3		75.0		75.0		83.3	
F ₁ 分数/%	50.0		78.3		78.3		83.3	

4.2 支承劣化位置识别结果

在单块足尺道面板的板边脱空区域(测试E)、板中支承良好区域(测试F)与板角脱空区域(测试G)分别开展测试,各感知单元所在位置的区域互谱频带能量占比 γ 见图11。虚线方框标示了真实脱空区域内的感知单元,实心圆点标示了超过阈值 $T_0 = \mu + \sigma$ 的单元位置。

在测试E和G中,加载点恰为脱空位置,脱空区附近的 γ 均出现异常值,识别到了板边、板角脱空。而测试F加载板中位置,异常值仅识别到板边脱空区的1个单元。综合3次测试的108个单元样本,成功识别到8个脱空样本,有4个脱空样本漏识别,对应的召回率为66.7%。

在应用数据驱动方法时,先用PCA对单元级别的区域互谱以降维。图12展示了所有样本在前2项主成分空间中的投影分布。尽管前2项主成分的累积方差贡献率已达到61.23%,但脱空样本(三角形




图 11 单板足尺试验中各样本的频带能量占比及脱空位置识别结果

Fig. 11 Band energy ratio of samples and identification results of void position in one-slab full-scale tests




图 12 前 2 个主成分的二维可视化与单元的识别结果

Fig. 12 2D visualization of the first two principal components and void unit identification

与叉号)与健康单元样本(圆圈与方块)在分布上呈现显著混叠,说明前 2 项主成分对支承劣化位置的表征能力有限。因此将累计解释方差比的阈值提高至 90%,筛选出 14 个主成分,再输入 SVM 识别支承劣化位置。最终脱空样本正确识别 8 个、漏识别 4 个,召回率为 66.7%。对照组使用 XGBoost 分类器的结果与之相比,有 2 个健康单元样本被误识别为脱空,准确率比原数据驱动方法下降了 1.0%。

数据物理融合方法结果如下。XGBoost 特征排序器得到的各频率点累积增益见图 13,其中 800 Hz 附近的累积增益最大。为进一步提取频带特征,选取了累积增益最大的前 9 个频率点(图 13 圆点标示),并将位置相近的频率点融合为一个频段。其中,虽然 688 Hz 存在局部增益峰值,但其邻近频率点的增益值极低,呈现孤立特征;且该频率点在增益排序中为第 9 位(末位),因此在频段构建时予以剔除。

以 20 Hz 为带宽,选取 215~235、350~370、785~805、910~930、1 175~1 195 Hz 五个频段(如图 13 阴影条带所示),涵盖了上述频率特征点,分别计算各频段的 RMS 值作为新特征。图 14 展示了各特征的皮尔逊相关系数矩阵,其中特征 3 与特征 2、特征 4 的相关系数分别为 0.59 和 0.68,展现出较强




图 13 XGBoost 特征排序中各频率点的累积增益

Fig. 13 Cumulative gains of frequency points in XGBoost feature ordering




图 14 五个频段特征的相关性分析

Fig. 14 Correlation analysis of five band features

的相关性。这可能是由于脱空导致上述频段的区域互谱呈现出同步增强的趋势。

将 5 个频段的 RMS 作为新特征输入 XGBoost 分类器识别支承劣化位置,108 个样本的结果如图 15(a)所示,根据光纤单元的实际平面位置,将感知单元 1~36 映射到平面上得到图 15(b)。该方法在 3 组测试中的表现相似,板边脱空样本(单元 7、18、19)在每组测试中各识别到了 2 个,板角脱空样本在测试 F 中漏识别,在测试 E 和 G 中成功识别。两处假阳性结果(对应的感知单元位置未发生脱空却被识别为脱空)位于单元 20 和 32,其实际平面位置分别紧邻着板边脱空和板角脱空位置,如图 15(b)所示。

4 种方法的支承劣化位置识别结果见表 2。数据-物理融合方法及对照组与数据驱动方法仅在健康位置的识别中有 1 个样本的差异,而对脱空位置的识别能力相当。尽管后 3 种方法的准确率和 F_1 分数均显著优于物理指标构建方法,其中准确率增加了 6.5% 和 5.5%,但表 2 中各方法的召回率均为 66.7%。这表明不同方法间的性能差异主要体现在增强了对健康样本的抗干扰能力、降低误报率,而未显著提升对脱空样本的检出能力。




图 15 数据物理融合方法的脱空位置识别结果

Fig. 15 Void position identification results of data-physics fusion method

表 2 不同方法对支承劣化位置的识别效果对比

Table 2 Comparison of identification performance of methods on support deterioration position

方法		预测结果							
		物理指标构建		PCA+SVM		PCA+XGBoost		XGBoost排序分类	
				健康	异常	健康	异常	健康	异常
实际结果	健康	88	8	95	1	94	2	94	2
	异常	4	8	4	8	4	8	4	8
准确率/%		88.9		95.4		94.4		94.4	
召回率/%		66.7		66.7		66.7		66.7	
F ₁ 分数/%		57.1		76.2		72.7		72.7	

5 讨论

将表 1 与表 2 的指标值求平均,得到 4 种方法在道面支承劣化识别中的平均表现,物理指标法、数据驱动法、对照组和融合方法的平均准确率分别为 83.35%、90.75%、90.25%、91.65%,平均召回率分别为 50.00%、70.85%、70.85%、77.50%。平均结果反映出物理指标法的效果较差,但后 3 种方法在指标数值上的差异并不显著,需要进一步分析。

5.1 物理可解释性

在识别支承劣化板时,方法 2 与对照组的结果完全相同,故将二者合并分析,支承劣化板的区域互谱在前 2 个主成分平面上的投影主要位于右上区域;而物理数据融合方法通过特征排序识别到敏感频率点,并用频带替代离散频率点增强物理容错性,其分类展现出更明确的物理依据:脱空板的区域互

谱,特别是 698~735 Hz 附近的分布情况与非脱空板有显著差异。

进一步分析方法 2、3 的 FN 样本(实际支承劣化但被漏识别为健康),对比 2 种方法的可解释性。PCA+SVM 方法漏识别 D-9 样本,该样本对应于板 #9(脱空范围最大)在板角荷载激励下的工况。从物理机制分析,该工况的损伤特征应较为显著,理论识别难度低于 D-8 样本(对应脱空范围较小的板 #8,且在非脱空板角加载)。对该样本的漏检,可能揭示了纯数据驱动方法在特征提取方面存在鲁棒性不足的缺陷。

相比之下,XGBoost 方法漏检的 A-7、A-8 样本以及 PCA+SVM 方法漏识别的 A-7、B-7 样本,均属于板 #7 和 #8 的板角脱空工况,且加载位置与脱空区域不重合。由于脱空范围较小且远离激励位置,脱空导致的振动信号特征较弱,该类漏检具有一定的物理归因,这表明数据-物理融合方法构建的分类边界可能更符合实际的物理损伤机制。

与当前热点的 PINN 相比,本文方法也嵌入了物理信息,但嵌入方式不同。PINN 将偏微分方程作为损失函数惩罚项,其通过方程实现的物理约束具有理论价值,但在边界条件复杂的道面结构中,建模简化将引入系统性误差。而融合方法采用物理知识引导的特征工程,将复杂动力学特性凝练为区域互谱对支承劣化敏感的频带,其工程指导意义比 PINN 方法更直观。

5.2 特征效率与工程实用性

在支承劣化位置的识别中,数据驱动方法、对照

组与数据-物理融合方法均在4个脱空样本处各漏检一次,且错误识别的位置均分布在板角脱空区域附近。尽管三者准确率相近,但从特征工程与计算效率角度分析,数据-物理融合方法具有更高的特征利用效率与工程实用性。

基于PCA的方法依赖14个输入特征,但其PCA投影(图9)显示,脱空与非脱空样本在低维空间的线性可分性显著低于板样本(图12),这表明该类模型由于缺乏物理机制约束,倾向于在高维特征空间中构建复杂边界来拟合样本分布,这不仅造成特征冗余,还可能导致模型泛化性能退化。

而XGBoost融合方法通过物理机制指导频段优选,有效剔除了冗余信息,仅需5维区域互谱特征即可实现同等水平的识别精度。此外,在支承劣化板识别任务中,融合方法仅使用3维特征实现了比数据驱动方法7维特征更优异的效果。进一步与PINN的思路对比,PINN在迭代过程中计算复杂,而本研究提出的融合方法属于轻量化模型,计算开销极低,更有利于在大规模分布式监测及边缘计算场景中应用。所提出的融合方法以更精简的特征参数达到相当的预测能力,这体现了该方法的参数经济性,有利于模型在复杂工程环境下保持稳健识别。

5.3 方法局限性

在支承劣化识别任务中,虽然方法2、3采用机器学习将非脱空样本的识别准确率提升了5.5%~6.5%,但表2中各方法的召回率均位于66.7%,这表明当前方法的性能瓶颈并非算法,而是受限于振动测量质量及区域互谱特征的完备性。结合试验条件分析,该局限性主要源于三方面。

首先,脱空区传感器布设密度不足。受限于板内钢筋排布,最外侧的感知单元中心与板边距离为55 cm,大于单元直径30 cm。该空间偏移削弱了感知单元对板边区域互谱特征的捕捉能力,影响脱空识别结果。其次,单元的区域互谱信噪比受加载位置制约。结构振动能量随传递距离剧烈衰减,板中受荷时,板边和板角单元的振动强度较低,损伤特征更容易被环境噪声掩盖。此外,频域分辨率不足也会导致互谱特征的频率偏移被淹没。若支承劣化导致某一频段的互谱偏移小于该分辨率,或发生变化的频带较窄,对应的特征变化将难以体现在离散的频率网格中。

针对上述问题,未来工程应用可采取以下优化方案。增大板边板角区域的布设密度并使其靠近板边;采用重复激励和时域平均来提高单元信噪比,此

外对接近荷载的单元赋予更高置信度,结合遍历加载提升整体识别精度;延长单样本采集时间并提高采样频率,捕获更精细的频域特征变化。

6 结 语

(1)研究表明刚性道面支承劣化通过改变结构振型、频率、阻尼比,进而影响互谱;在互谱的基础上,区域互谱发挥了分布式测量的优势,可以用于识别道面支承劣化。支承劣化板或位置的区域互谱在频域分布上与健康的板或位置有明显差异,当加载点位于脱空区,该差异将显著增大。

(2)基于区域互谱与XGBoost的数据-物理融合方法在板识别和位置识别中,准确率($91.65\% > 83.35\%$)和召回率($77.50\% > 50.00\%$)均明显优于物理指标方法提出的频带能量占比。区域互谱中反映道面支承状况的优势频段可能存在差异,人工选定的频带能量占比的积分频段与阈值对复杂条件的适应性较差,而融合方法能够基于数据特征遴选特征频段和阈值。

(3)数据驱动方法的平均准确率达90.75%,但融合方法在特征数量及物理解释性上显著更优。融合方法采用的特征数量不到数据驱动方法的1/2(板识别3个,小于7个,位置识别5个,小于14个),且选取的特征对应于道面支承劣化对区域互谱影响最显著的频段。在本研究中,698~735 Hz附近的区域互谱分布可以用于识别支承劣化的板块;350~370、785~805 Hz等5个频带的区域互谱分布可以用于识别支承劣化的具体位置。

(4)研究所提出的方法为刚性道面结构异常诊断提供了一种融合数据方法与物理特征的技术路径。针对当前试验样本较少、模型泛化性不足的问题,后续研究将引入数据增强技术丰富样本,或基于仿真数据预训练模型进行迁移学习和微调。在工程应用上,将结合道面长期监测数据与弯沉检测结果,将数据-物理融合思路与方法进一步拓展应用于飞机荷载激励下的道面结构振动分析,以实现复杂条件下的道面结构异常识别。

参 考 文 献:

References:

- [1] 李 盛,张海涛,孙 煜,等. 在役水泥路面劣化行为与延寿技术综述[J]. 交通运输工程学报,2024,24(3):25-47.
LI Sheng, ZHANG Hai-tao, SUN Yu, et al. Review on deterioration behavior and life extension technologies of cement pavement in service[J]. Journal of Traffic and Transportation

- Engineering, 2024, 24(3): 25-47.
- [2] 凌建明, 刘海伦, 马正好, 等. 总弯沉比及其在机场刚性道面板底脱空判定中的适用性[J]. 同济大学学报(自然科学版), 2023, 51(7): 1085-1093.
- LING Jian-ming, LIU Hai-lun, MA Zheng-hao, et al. Total deflection ratio and its applicability in void identification of airport rigid pavement [J]. Journal of Tongji University (Natural Science), 2023, 51(7): 1085-1093.
- [3] ZHANG Y M, TONG Z, SHE X H, et al. SWC-net and multi-phase heterogeneous FDTD model for void detection underneath airport pavement slab [J]. IEEE Transactions on Intelligent Transportation Systems, 2024, 25(12): 20698-20714.
- [4] 张一鸣, 鲍帆, 童峥, 等. 非均质机场水泥道面板底脱空雷达波响应[J]. 东南大学学报(自然科学版), 2023, 53(1): 137-148.
- ZHANG Yi-ming, BAO Fan, TONG Zheng, et al. Radar wave response of slab bottom voids in heterogeneous airport concrete pavement [J]. Journal of Southeast University (Natural Science Edition), 2023, 53(1): 137-148.
- [5] 张宇辉, 张献民. 机场道面及其下部地基脱空的测试方法[J]. 交通运输工程学报, 2016, 16(6): 1-11.
- ZHANG Yu-hui, ZHANG Xian-min. Test methods of airport pavement and subjacent foundation void [J]. Journal of Traffic and Transportation Engineering, 2016, 16(6): 1-11.
- [6] LI M X, ANDERSON N, SNEED L, et al. Condition assessment of concrete pavements using both ground penetrating radar and stress-wave based techniques [J]. Journal of Applied Geophysics, 2016, 135: 297-308.
- [7] WU D F, ZENG M Y, ZHAO H D, et al. A novel distributed sensing method for support condition monitoring under concrete pavement [J]. International Journal of Pavement Engineering, 2022, 23(7): 2227-2241.
- [8] 赵坪锐, 徐天赐, 刘卫星, 等. 单元板式轨道脱空伤损识别的柔度曲率特征值法[J]. 西南交通大学学报, 2021, 56(5): 1100-1108, 1127, 1109-1111.
- ZHAO Ping-rui, XU Tian-ci, LIU Wei-xing, et al. Flexibility curvature eigenvalue method for debonding damage identification of unit slab track [J]. Journal of Southwest Jiaotong University, 2021, 56(5): 1100-1108, 1127, 1109-1111.
- [9] ZENG M Y, WU D F, ZHAO H D, et al. Novel assessment method for support conditions of concrete pavement under traffic loads using distributed optical sensing technology [J]. Transportation Research Record, 2020, 2674(4): 42-56.
- [10] 曾孟源, 赵鸿铎, 吴获非, 等. 基于振动感知的混凝土铺面板底脱空识别方法[J]. 中国公路学报, 2020, 33(3): 42-52.
- ZENG Meng-yuan, ZHAO Hong-duo, WU Di-fei, et al. Identification of cavities underneath concrete pavement based on pavement vibration [J]. China Journal of Highway and Transport, 2020, 33(3): 42-52.
- [11] 曾孟源, 赵鸿铎, 边泽英, 等. 基于分布式光纤的混凝土路面振动场感知与解析[J]. 中国公路学报, 2022, 35(7): 78-90.
- ZENG Meng-yuan, ZHAO Hong-duo, BIAN Ze-ying, et al. Sensing and analysis of concrete pavement vibration field based on distributed optical fiber [J]. China Journal of Highway and Transport, 2022, 35(7): 78-90.
- [12] ZHAO H D, WU D F, ZENG M Y, et al. Assessment of concrete pavement support conditions using distributed optical vibration sensing fiber and a neural network [J]. Construction and Building Materials, 2019, 216: 214-226.
- [13] 吴获非, 向晖, 刘成龙, 等. 基于振动传递率函数的水泥混凝土铺面板底脱空识别方法[J]. 北京工业大学学报, 2024, 50(4): 453-465.
- WU Di-fei, XIANG Hui, LIU Cheng-long, et al. Void-underneath identification method of cement concrete pavement using vibration transmissibility function [J]. Journal of Beijing University of Technology, 2024, 50(4): 453-465.
- [14] 罗丹, 黄晓琴, 冷费贤, 等. 数字孪生在交通基础设施智能建造中的应用与挑战[J]. 交通运输工程学报, 2025, 25(3): 33-64.
- LUO Dan, HUANG Xiao-qin, LENG Fei-xian, et al. Applications and challenges of digital twin in intelligent construction of transportation infrastructure [J]. Journal of Traffic and Transportation Engineering, 2025, 25(3): 33-64.
- [15] SONODA Y, LU C, YIN Y F. Basic research on usefulness of convolutional autoencoders in detecting defects in concrete using hammering sound [J]. Structural Health Monitoring, 2023, 22(4): 2231-2250.
- [16] 张军, 姜文涛, 张云, 等. 基于极限梯度提升和探地雷达时频特征的水泥路面脱空识别[J]. 同济大学学报(自然科学版), 2024, 52(1): 104-114, 121.
- ZHANG Jun, JIANG Wen-tao, ZHANG Yun, et al. Cement pavement void identification based on XGBoost and gpr time-frequency features [J]. Journal of Tongji University (Natural Science), 2024, 52(1): 104-114, 121.
- [17] ZHANG J, LU Y M, YANG Z, et al. Recognition of void defects in airport runways using ground-penetrating radar and shallow CNN [J]. Automation in Construction, 2022, 138: 104260.
- [18] LI H F, WANG B Y, LIU S S, et al. GPR-STA: A style transfer algorithm for enhancing GPR data in airport runway structural defect detection [C]//Springer. CCF National Conference of Computer Applications. Singapore: Springer, 2024: 344-358.
- [19] SHI B, WANG X, DONG Q, et al. Voids prediction beneath cement concrete slabs using a FEM-ANN method [J]. International Journal of Pavement Engineering, 2023, 24(1): 2191198.
- [20] ZHU Y J, CHEN L Y. Framework for developing prediction models for boundary conditions of slabs in girders considering interpretability: An application for deck slabs in composite box girders [J]. Journal of Bridge Engineering, 2025, 30(4): 04025010.

- [21] IJAZ H, QABUR A, AATI K, et al. Physics-aware mesh-free deep learning for rectangular elastic plate deformation with support-dependent boundary enforcement [J]. *International Journal of Applied Mechanics*, 2025, 17(12): 2550109.
- [22] ZHOU W, XU Y F. Damage identification for plate structures using physics-informed neural networks [J]. *Mechanical Systems and Signal Processing*, 2024, 209: 111111.
- [23] 余忠儒,单德山,孙榕徽. 基于种群的桥梁结构健康监测研究综述与挑战[J]. *交通运输工程学报*, 2025, 25(5): 1-22.
YU Zhong-ru, SHAN De-shan, SUN Rong-hui. Population-based structural health monitoring of bridges: Review and challenges [J]. *Journal of Traffic and Transportation Engineering*, 2025, 25(5): 1-22.
- [24] SAJID S, CHOUINARD L, CARINO N. Condition assessment of concrete plates using impulse-response test with affinity propagation and homoscedasticity [J]. *Mechanical Systems and Signal Processing*, 2022, 178: 109289.
- [25] WANG X, MA Z L, HU X, et al. Void detection of airport concrete pavement slabs based on vibration response under moving load[J]. *Sensors*, 2025, 25(15): 4703.
- [26] LIU X Z, ZHU L Y, LI Z W. Dynamic assessment of interlayer debonding in high-speed slab tracks using frequency-domain simulation[J]. *Results in Engineering*, 2026, 29: 108515.
- [27] TANG L Q, LI Y H, BAO Q, et al. Quantitative identification of damage in composite structures using sparse sensor arrays and multi-domain-feature fusion of guided waves [J]. *Measurement*, 2023, 208: 112482.
- [28] LIU J, LIU F Y, WANG L B. Automated, economical, and environmentally-friendly asphalt mix design based on machine learning and multi-objective grey wolf optimization[J]. *Journal of Traffic and Transportation Engineering (English Edition)*, 2024, 11(3): 381-405.
- [29] LAXMAN K C, TABASSUM N, AI L, et al. Automated crack detection and crack depth prediction for reinforced concrete structures using deep learning [J]. *Construction and Building Materials*, 2023, 370: 130709.
- [30] BABOLI NEZHADI E, LABIBZADEH M, HOSSEINLOU F, et al. Machine learning-based design of double corrugated steel plate shear walls [J]. *International Journal of Structural Integrity*, 2024, 15(6): 1216-1248.
- [31] YUAN H Z, ZHAO K, YAN Y, et al. Long tunnel group driving fatigue detection model based on XGBoost algorithm [J]. *Journal of Traffic and Transportation Engineering (English Edition)*, 2025, 12(1): 167-179.