

文章编号:1671-1637(2026)08-0190-12

基于CNN-xLSTM-Attention的机场跑道性能衰变预测模型

何印章^{1,2}, 李怡林², 赵晓康¹, 张久鹏¹, 李岩^{*1,2}

(1. 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; 2. 西北工业大学民航学院, 陕西西安 710072)

摘要:为精准预估复杂工况下机场跑道的性能衰变趋势,基于改进深度学习架构建立了CNN-xLSTM-Attention组合预测模型。利用卷积神经网络提取环境、荷载及结构等多源输入数据的局部特征,通过引入包含sLSTM与mLSTM双分支的xLSTM模型以增强对时序依赖的捕捉能力;结合Attention机制动态聚焦关键时间步与特征变量,并采用贝叶斯优化算法自动搜索关键超参数,构建了高精度的PCI衰变预测框架;采用中国两跑道实测时序数据,涵盖通航时间、降雨量、交通荷载等6类关键指标,计算分析了不同模型的预测精度与泛化能力,并引入SHAP与广义加性模型解析了关键特征的非线性影响机制。研究表明:相较于传统LSTM及单一改进模型,CNN-xLSTM-Attention模型具有最优的综合性能,测试集决定系数达到0.922 5,平均绝对百分比误差仅为1.777 8%,有效解决了长序列梯度问题与特征耦合难题;解释性分析发现,通航时间(贡献率为44.8%)与年平均降雨量(贡献率为33.6%)是主导道面状况指数(PCI)衰减的首要因素,交通荷载与温度指标存在显著的阈值效应,而增加面层厚度对延缓衰变具有显著抑制作用。由此可见,建立的道面性能预测模型及其解释性分析方法能够准确捕捉PCI的时序演化规律与关键影响机制,可为机场跑道的分阶段科学养护与运维决策提供可靠的数据支撑。

关键词:机场工程;机场跑道;深度学习;智能运维;性能预测;衰变模型

中图分类号:U41 **文献标志码:**A **DOI:**10.19818/j.cnki.1671-1637.2026.325

Prediction model for performance decay of airport runways based on CNN-xLSTM-Attention

HE Yin-zhang^{1,2}, LI Yi-lin², ZHAO Xiao-kang¹, ZHANG Jiu-peng¹, LI Yan^{*1,2}

(1. Key Laboratory of Smart Construction and Maintenance of Civil Aviation Airports, Chang'an University, Xi'an 710064, Shaanxi, China; 2. School of Civil Aviation, Northwestern Polytechnical University, Xi'an 710072, Shaanxi, China)

Abstract: To accurately predict the performance decay trend of airport runways under complex working conditions, a combined CNN-xLSTM-Attention prediction model was established based on an improved deep learning architecture. A convolutional neural network was utilized to extract local features of multi-source input data such as environment, load, and structure, and an xLSTM model

出版历程:2025-12-18收稿,2026-01-26修回,2026-05-26录用

基金项目:国家自然科学基金项目(52502429)

作者简介:何印章(1997-),男,湖北恩施人,长安大学博士研究生,E-mail:heyinzhang@chd.edu.cn。

*通信作者:李岩(1995-),男,山东德州人,西北工业大学助理研究员,工学博士,博士后,E-mail:mhly@nwpu.edu.cn。

引用格式:何印章,李怡林,赵晓康,等.基于CNN-xLSTM-Attention的机场跑道性能衰变预测模型[J].交通运输工程学报,2026,26(8):190-201.

Citation: HE Yin-zhang, LI Yi-lin, ZHAO Xiao-kang, et al. Prediction model for performance decay of airport runways based on CNN-xLSTM-Attention[J]. Journal of Traffic and Transportation Engineering, 2026, 26(8): 190-201.

containing dual branches of sLSTM and mLSTM was introduced to enhance the capturing ability for temporal dependencies. On this basis, an Attention mechanism was combined to dynamically focus on key time steps and feature variables, and a Bayesian optimization algorithm was adopted to automatically search for key hyperparameters, thereby constructing a high-precision pavement condition index (PCI) decay prediction framework. Using measured time-series data from two runways in China, covering 6 types of key indicators such as service time, rainfall, and traffic load, the prediction accuracy and generalization ability of different models were calculated and analyzed, and SHAP and a generalized additive model were introduced to analyze the nonlinear influence mechanisms of key features. The research results indicate that compared to the traditional LSTM and single improved models, the CNN-xLSTM-Attention model has the optimal comprehensive performance, effectively solving the long-sequence gradient problem and the feature coupling challenge; the coefficient of determination (R^2) of the test set reaches 0.923; the mean absolute percentage error (MAPE) is only 1.778%. The explanatory analysis reveals that service time (contribution rate of 44.8%) and annual average rainfall (contribution rate of 33.6%) are the primary factors dominating the decay of PCI; traffic load and temperature indicators show a significant threshold effect; increasing the surface course thickness has a significant inhibitory effect on delaying the decay. It is thus evident that the established pavement performance prediction model and its explanatory analysis method can accurately capture the temporal evolution patterns and key influence mechanisms of PCI, providing reliable data support for the phased scientific maintenance and operational decisions of airport runways.

Keywords: airport engineering; airport runway; deep learning; intelligent operation and maintenance; performance prediction; decay model

Publication history: Received 2025-12-18; Received in revised form 2026-01-26; Accepted 2026-05-26

Funding: National Natural Science Foundation of China (52502429)

* **Corresponding author:** LI Yan, research assistant, PhD, E-mail: mhly@nwpu.edu.cn.

0 引言

安全是民航的根本保障,高效是民航的价值体现。作为机场最重要的基础设施区域,飞行区跑道承担飞机的起降和停靠,对飞机的安全运行至关重要^[1-2]。沥青道面因其平整、舒适以及高度机械化施工等特点在国际机场道面建设中备受青睐^[3]。然而,沥青道面性能受道面结构、环境因素及荷载条件等多重因素影响,直接或间接导致道面病害的产生与恶化,进而影响道面整体性能,已成为机场养护工程中需重点考虑的问题^[4]。

道面性能预测模型作为道面养护决策的重要组成部分,可以帮助机场管理者预测未来道面状况,以此确定合适的养护时机并选择合理的养护措施^[5]。目前,道面使用性能预测模型主要有确定型模型、衰变规律模型及人工智能模型^[6]。确定型模型物理机制较为明确,试图通过力学理论分析荷载与环境作用下的道面响应,并将其与材料疲劳、永久变形等经

验破坏准则相关联,从而实现性能预估。其理论扎实,具有较好的外推能力和机理解释性。然而,其精度严重依赖于输入参数的准确性。机场道面结构复杂、材料变异大、全寿命周期内环境作用与荷载数据获取困难且成本高昂,导致参数不确定性极高。此外,模型本身对材料退化、接缝传荷等复杂现象的简化处理,也限制了其在复杂现实条件下的精准预估能力。衰变规律模型基于历史检测数据,建立性能指标与时间或累积荷载的统计关系。模型形式简单、参数易于标定、使用方便,在数据充足的特定场所具有较好的短期拟合效果。但其未能充分反映性能衰变的物理本质与主要驱动因素,模型通用性差,严重依赖建模所用数据集的特定条件,迁移到其他机场或当外部条件发生显著变化时,预估可靠性大幅下降。随着人工智能技术的发展,近年来许多研究者采用以长短期记忆网络(Long Short-term Memory, LSTM)、门控循环单元(Gated Recurrent Unit, GRU)、卷积神经网络(Convolutional Neural

Network, CNN)等为代表的深度学习模型进行道面性能建模,已逐步应用于道面养护工程。Li等^[7]采用反向传播神经网络与LSTM结合的集成预测方法,将道面病害检测数据、交通荷载、气候历史记录及养护档案作为输入数据,建立了道面性能随时间变化的衰变模型;Sun等^[8]建立了具有区域适用性的半刚性沥青道面性能多输出指标的LSTM预测模型,为预防性养护决策提供参考;Chen等^[9]提出一种CNN-LSTM框架用于预测道面弯沉参数,该方法能够在保持评估精度的同时减少检测频次,为道面状况快速评估提供了新的技术选择;Deng等^[10]研究采用CNN和LSTM两种典型的深度学习模型,从有限数据中捕捉车辙发展特征并进行预测;Wu等^[11]采用涵盖路龄、交通荷载、道面性能及气候条件等多变量的道面数据,构建了一种CNN-GRU混合模型用于道面IRI预测;Li等^[12]开发了一种基于粒子群优化算法的GRU模型,用于预测5项道面性能参数,证实了该模型在指导道面最优养护措施方面的应用潜力。

由于道面性能劣化具有明显的时间依赖性,以LSTM与GRU为代表的循环神经网络(Recurrent Neural Network, RNN)在捕捉时间序列数据的局部特征和长期依赖方面展现了优势,因此在道面性能时序预测建模中应用较为广泛。然而,由于LSTM在处理长序列时仍难以完全避免梯度问题,且其隐层状态往往难以充分表征序列的全局关系^[13]。另外,道面性能劣化过程的非线性和强耦合特征也使得传统时序模型难以突出关键特征的作用。注意力(Attention)提供了一种高效、灵活、可解释的机制,在面对复杂输入时,动态地聚焦于最关键的信息子集,从而极大地提升了模型处理信息的能力和效率^[14]。结合Attention可弥补LSTM在全局建模和长距离依赖处理上的不足,同时保留了LSTM对时序数据的建模优势,已成为处理复杂序列任务的有力工具^[15-17]。另外,现有研究仅对道面使用寿命与各影响因素(包括气候条件、道面使用年限、交通参数、结构参数等)的关系进行了有限探讨。随着民航运输业的迅猛发展及飞机荷载的不断增加,亟需深入理解多种特征对道面性能的影响机制。因此,本研究旨在构建涵盖不同区域机场沥青道面的时序数据集,基于改进的LSTM模型xLSTM,提出CNN-xLSTM-Attention复合模型用于道面性能预测。首先采用CNN模型对影响道面状况指数(Pavement Condition Index, PCI)性能的各种特征进行提取,然

后将经CNN处理过后的数据通过xLSTM层提取出时间特征,最后考虑变量在预测中的贡献度大小,通过Attention层提取到时序数据中不同时刻的数据特征对预测值的影响程度,最终完成道面性能时序预测任务。

1 数据来源与数据集构建

1.1 道面分区方法

首先,本文根据已有研究成果并参考《民用机场道面评价管理技术规范》(MH/T 5024—2019)中关于跑道功能分区与道面管理单元划分的要求,对2条跑道R1和R2进行分区并编码^[18]。考虑跑道不同位置在运行工况与荷载作用特征上的差异,将每条跑道沿纵向划分为5个区块,分别记为R1-01~R1-05与R2-01~R2-05;区块边界与跑道端部、起飞/着陆主要作用段及中部过渡段相对应。在此基础上,以450 m²为面积单元,将各区块进一步细分为若干道面单元,形成跑道-区块-单元的三级编码体系,如图1所示。按该方案,R1跑道共划分为240个单元,R2跑道共划分为400个单元,各区块单元数量见表1。




图1 跑道道面划分方案

Fig. 1 Runway pavement division scheme

表1 跑道道面区块和单元划分结果

Table 1 Division results of runway pavement blocks and units			
跑道	单元总数/个	区块	单元数量/个
R1	240	R1-01	40
		R1-02	53
		R1-03	54
		R1-04	53
		R1-05	40
R2	400	R2-01	66
		R2-02	89
		R2-03	90
		R2-04	89
		R2-05	66

需要说明的是,上述分区划分主要服务于道面评价数据的组织、统计汇总与薄弱区域识别,为PCI年

度调查结果提供空间管理框架。本文研究重点为跑道PCI随时间的整体衰变预测与趋势分析,空间划分用于刻画PCI分布与局部薄弱单元的演化特征,而非依赖年度外部指标解释同年不同单元之间的差异。

1.2 道面性能影响因素

为从机理层面揭示道面性能演化规律,并为后续建立性能衰变模型提供输入变量支撑,有必要同步采集与道面服役状态密切相关的外部/内部影响因素。机场道面分类评级的测算精度取决于多源基础数据的完备性与可靠性,一般涵盖3个维度:①道面属性数据包括历史建造参数(面层层厚、材料模量)、结构类型(面层/基层/底基层材料类型)等;②航空运营数据涵盖机型组合谱系、年运行架次、荷载空间分布特征等;③环境数据包含道面服役年限、温度参数、降雨参数等。基于相关研究^[18-19],本文选取通航时间、年平均降雨量、年起降架次、高温天数、低温天数和面层厚度等特征构建道面影响因素集合,分别记为 $x_1 \sim x_6$,用于量化各类因素对跑道PCI衰变过程的影响。具体来源如下:①道面性能数据,PCI数据源于合作机场的现场检测结果;②环境因素数据,原始气象数据来源于机场所在地气象站的历年观测资料(年平均降雨量、年气温超过30℃的天数及年气温低于-5℃的天数均由逐日观测值计算得到);③其他影响因素数据,路龄、结构参数及荷载数据均来源于机场管理方。上述关键影响因素的类型与描述性统计如表2所示。

表2 道面性能影响因素类型

Table 2 Types of factors influencing pavement performance

变量类型	描述	均值	范围
环境参数	x_2/mm 年平均降雨量	765.2	[200, 1 798]
	x_4/d 年气温超过30℃的天数	35.3	[11, 49]
	x_5/d 年气温低于-5℃的天数	22.5	[0, 45]
荷载参数	$x_3/\text{万架}$ 经折算后的年飞机运行架次	14.9	[1.2, 26.8]
路龄	$x_1/\text{年}$ 距离建成或上一次大中修的时间	4	[1, 7]
结构参数	x_6/mm 面层厚度	160	[100, 220]

具体而言, x_1 衡量道面服役年限,与结构材料性能衰减高度相关。 x_2 、 x_4 、 x_5 反映了道面所处的水-温耦合作用水平,对道面老化及水损害有直接影响。 x_3 则代表跑道所承受的交通荷载强度,是反映结构疲劳累积程度的关键指标。由于机场可同时起降不同机型,不同重量、宽度以及轮载组合的飞机表现出不同的力学特性与荷载空间分布特征。为此,对机

场交通参数作进一步规定:①跑道标准交通参数由不同机型飞机与权重系数加权求得;②为体现荷载空间分布特征,不同区块、单元的交通量参数由标准交通参数与折减系数加权求得。 x_6 则从设计层面体现了道面抵抗荷载与环境作用的能力^[20]。通过在时间维度上对这些指标与PCI变化进行对比分析,可更准确地识别道面性能衰减的主导因素,为养护策略的制定和资源优化配置提供更加科学的数据基础。

1.3 道面性能数据分布特征分析

在数据建模中,异常值可能影响统计特征并降低模型精度。输入特征 $x_1 \sim x_6$ 均来自官方统计与实际结构参数,来源规范且物理含义明确,本文未对其额外剔除异常值,而重点检验目标变量PCI的异常波动。为此,采用箱线图对2018~2024年2条跑道PCI年度分布进行可视化分析,如图2所示。结果显示,两跑道PCI均持续衰减:R1均值由接近100.00降至67.40,箱体及下须逐年下移,表明部分单元在疲劳与病害累积下劣化更为显著;R2趋势相似但更缓和,均值由93.70降至68.13,上四分位与最大值保持较高,但下四分位及低值点逐年增多,反映局部薄弱区扩展。总体上,PCI随时间衰减且离散性增强,体现整体平缓劣化与局部加速退化并存;箱线图未见明显孤立异常点,故不进行异常值剔除。

1.4 道面性能数据集相关性分析

经统计,本文共获得R1跑道道面时序数据226组、R2跑道道面时序数据357组(每组由影响因素 $x_1 \sim x_6$ 与PCI构成)。为避免后续性能衰变建模中自变量间相关性过高而导致参数估计不稳定或解释偏移,对 $x_1 \sim x_6$ 的相关性进行诊断性分析。考虑到各影响因素多为年度尺度指标,变量关系可能呈现非线性单调特征,且不必满足正态分布与线性假设,故采用Spearman秩相关系数衡量变量间的单调相关程度。同时,为降低将2条跑道混合分析带来的统计伪相关风险,分别对R1与R2计算相关矩阵,结果如图3所示。由图3(a)可见,R1跑道中各因素之间的Spearman相关系数整体处于低到中等水平,取值为0.21~0.60。其中相关性相对较高的变量对包括 x_1 与 x_2 以及 x_4 与 x_5 ,其余变量对在0.21~0.57范围内。图3(b)显示,R2跑道中相关性总体分布相近,相关系数为0.21~0.64。综合两跑道结果,自变量间未呈现显著的高相关结构,表明共线性风险总体可控。因此,本文不基于相关性结果进行变量筛选或剔除,后续衰变建模中保留全部影响因素 $x_1 \sim x_6$,相关性分析仅作为数据集诊断与稳健性说明。




图2 道面PCI数据分布

Fig. 2 Distribution of pavement PCI data




图3 道面PCI数据相关性分析

Fig. 3 Correlation analysis of pavement PCI data

2 道面性能衰变模型构建

2.1 模型架构

道面PCI的衰变过程受环境、荷载与结构等多因素耦合作用,具有显著的非线性、多尺度与时变特征。传统线性回归或单一时序模型往往难以同时兼顾局部模式表征、长短期依赖以及关键时刻对衰变贡献的差异性。为更精细刻画PCI的时序衰变规律,本文引入CNN-xLSTM-Attention组合预测模型,以期在复杂工况下获得更稳定且更具可解释性的道面性能预测结果。具体而言,CNN用于从多源输入中自动提取局部模式与高阶特征^[21];xLSTM通过分支间交叉连接增强对不同时间尺度相关性的刻画能力;Attention机制则在时间与特征

2个维度为隐状态分配可学习权重,使模型能够自适应聚焦于对PCI衰变影响更显著的关键时刻与关键因素^[22]。三者的协同融合既弥补单一模型表达能力受限的问题,也提升了对复杂衰变机理的表征精度。

图4为本文提出的CNN-xLSTM-Attention框架。首先,将时序道面数据输入卷积层,卷积输出经ReLU激活函数后形成 C (卷积核个数)维的局部特征图;随后通过Permute操作调整张量维度以适配序列建模,并送入xLSTM模块,其中sLSTM与mLSTM两个分支并行提取短期与长期时序特征,并在模块内部实现交叉融合。xLSTM的输出进一步输入Attention层,通过包含线性变换与Softmax的子网络生成注意力权重,并结合残差连接进行加权叠




图 4 CNN-xLSTM-Attention 模型框架

Fig. 4 Framework of the CNN-xLSTM-Attention model

加,得到加权后的序列表示。最后,经全局平均池化将序列表示聚合为定长向量,并通过全连接层映射为对应时刻的PCI预测值,从而形成端到端的道面性能衰变建模框架。

在输入与输出方面,考虑到道面性能演化的短期记忆特性,模型采用步长为2的时间窗口,即使用相邻2年的观测数据作为一个输入序列,输入特征维度为6,对应前文定义的 $x_1 \sim x_6$ 六类影响因素,目标特征为PCI。所有特征在输入前均进行标准化处理,以消除量纲差异并加快收敛,表示为

$$Z_{\text{norm}} = \frac{Z_i - Z_{\min}}{Z_{\max} - Z_{\min}} \quad (1)$$

式中: Z_{norm} 为标准化后的特征值; Z_i 为样本中第 i 个值; $Z_{\max}$ 与 $Z_{\min}$ 分别为样本数据最大值与最小值。

为避免时序预测中的信息泄漏,本文采用按年份时间顺序的严格划分:以2018~2022年份样本作为训练集,2023和2024年份样本作为测试集,以确保训练集不包含任何测试年份及其未来信息,从而获得更客观的泛化评估结果。参数设置方面,卷积模块采用单层一维卷积进行初始特征提取,卷积核数量设置为128,宽度为3,步长为1,使用ReLU激活函数,并沿特征维度进行零填充以保持序列长度。xLSTM模块由一层sLSTM和一层mLSTM并行组成,隐含单元数均配置为128以便于特征融合;注意力子网络采用全连接层产生注意力得分并经Softmax归一化,该全连接层将输入映射为单维注意力评分。加权求和后,输出即为经过注意力加权的时序特征向量。模型训练采用均方误差(Mean

Squared Error, MSE)作为损失函数,以Adam优化器进行参数更新,初始学习率为0.001,Batch size设置为32,epochs为100,并结合提前停止等策略防止过拟合。

2.2 超参数优化方法

在模型训练中,超参数对模型的表达能力与泛化性能具有关键影响,但其搜索空间往往高维且相互耦合,依赖经验设定或网格搜索不仅计算开销大,也难以保证获得近似最优解。为此,本文采用贝叶斯优化(Bayesian Optimization, BO)对模型的超参数进行自动搜索。BO基于已有评估点构建目标函数的代理模型,并通过采集函数在探索与利用之间进行权衡,从而迭代推荐下一组候选超参数,实现以较少试验次数逼近最优解^[23]。本文将优化目标设定为验证集上的均方根误差(RMSE)最小化,并设置BO的最大迭代评估次数为300次,每次迭代均以对应候选超参数训练模型并返回其RMSE作为BO的反馈信号。为抑制过拟合并提高评估稳定性,当验证指标在连续50个训练周期内不再提升时触发提前停止机制;相关实现细节可参考前期研究成果^[24]。

2.3 模型性能评价指标

为全面评估模型的预测能力与泛化表现,本文采用平均绝对百分比误差(MAPE)、平均绝对误差(MAE)、RMSE及决定系数(R^2)指标。 R^2 用于衡量模型对整体数据的拟合优度;MAE反映预测值与实测值之间的平均偏离程度,其值用 E_{MAE} 表示;RMSE刻画误差的绝对大小,对较大偏差更为敏感,其值用 E_{RMSE} 表示;MAPE则表征预测结果的相对误差水

平,便于不同量级样本之间的比较,其值用 E_{MAPE} 表示。一般而言,当MAPE、MAE和RMSE越小、 R^2 越接近1,表明模型具有更高的预测精度和更好的稳定性与泛化能力。相关指标的计算方法分别为

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

$$E_{\text{MAE}} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (3)$$

$$E_{\text{RMSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (4)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (5)$$

式中: n 为样本数; y_i 为第*i*个实测值; $\hat{y}_i$ 为第*i*个预测值; $\bar{y}$ 为样本均值。

2.4 SHAP模型

Shapley Additive exPlanations (SHAP)是一种基于Shapley值的模型解释方法,可将单一样本的预测结果分解为“基准项+各特征贡献”的加性形式,从而在不改变原模型结构的前提下,定量表征各输入变量对跑道PCI预测的正负影响及贡献大小^[25]。将SHAP引入PCI衰变模型分析,有助于解释复杂模型的决策依据、识别对PCI变化最敏感的关键因素,并为养护指标筛选与干预优先级排序提供可解释支撑^[26-27]。SHAP值的计算方法为

$$f(x) = \phi_0 + \sum_{i=1}^M \phi_i \quad (6)$$

表3 相关超参数优化结果

Table 3 Optimization results of related hyperparameters

模块	超参数	范围	最优值
卷积层	C	{16, 32, 64, 128}	128
xLSTM	每个分支(sLSTM、mLSTM)的隐藏单元数 h	{32, 64, 128}	128
	Dropout比例 p	(0, 0.4)	0.249
Attention	注意力全连接层维度 d_{att}	{8, 16, 32, 64}	64
训练相关超参数	学习率 η	$(1.0 \times 10^{-4}, 1.0 \times 10^{-2})$	2.2×10^{-3}
	Batch size	{8, 16, 32, 64}	8

3.2 模型性能对比验证

为验证所提出模型的有效性,本文将其与LSTM、xLSTM以及CNN-xLSTM进行对比,结果如图5所示。结果显示,4种模型性能呈现逐步提升趋势。LSTM与xLSTM的拟合优度相近,训练集 R^2 分别为0.880与0.879,测试集 R^2 均为0.875,但xLSTM在误差指标上未体现优势,其测试集RMSE、MAE与MAPE分别为2.165、1.703、2.534%,均高于LSTM的2.102、1.512、2.317%,说明仅增强循环结构

式中: $f(x)$ 为模型对样本 x 的预测值; ϕ_0 为基准项; ϕ_i 为第*i*个特征的SHAP贡献值; M 为特征数。

2.5 GAM分析

在利用SHAP获得关键特征后,为进一步分析这些因素与PCI之间的具体函数关系及其非线性变化趋势,本文采用广义加性模型(Generalized Additive Model, GAM)进行拟合^[28]。GAM通过对每个特征构建平滑函数并以加性方式叠加,能够在不预设具体函数形式的前提下刻画非线性关系,适用于识别阈值效应、饱和效应与阶段性变化规律;同时,其特征-效应曲线表达方式直观,可将特征重要性进一步转化为可解释的影响模式,为分阶段预防性养护策略提供依据。需要指出的是,GAM以加性结构为核心,通常难以充分表征高阶特征的交互作用,且平滑项的复杂度设置可能影响拟合的平滑程度与外推能力,因此本文将GAM主要用于机制解释与阈值识别,而非替代预测模型。GAM的拟合形式为

$$g(\mathbb{E}) = \beta_0 + \sum_{j=1}^K f_j(x_j) \quad (7)$$

式中: $g(\cdot)$ 为链接函数; $\mathbb{E}$ 为期望; β_0 为截距项; $f_j(\cdot)$ 为第*j*个特征的平滑函数; K 为纳入模型的关键特征数; x_j 为第*j*个特征的值。

3 结果与讨论

3.1 超参数优化结果

采用BO优化相关超参数,对于超参数类型、范围和最优值如表3所示,后续所有对比与评估均基于表3所示的最优超参数配置完成。

对降低误差的贡献有限。引入卷积特征提取后,CNN-xLSTM在训练集与测试集上均实现一致性提升,测试集 R^2 提升至0.898,RMSE、MAE、MAPE降至1.931、1.329、1.897%,表明卷积模块能够有效提取PCI时序的局部模式。进一步加入Attention机制后,模型的测试集 R^2 提升至0.923,RMSE与MAPE进一步降至1.758与1.778%,较LSTM分别降低约16%与23%,MAE为1.331,与CNN-xLSTM基本持平。




图5 不同模型评价指标对比

Fig. 5 Comparison of evaluation metrics for different models

在此基础上,本文采用泰勒图将相关系数、标准差与归一化RMSE映射到同一极坐标空间,更直观地比较模型输出与观测序列的一致性。图6显示: CNN-xLSTM-Attention与参考点(REF)的距离最小、相关系数最高,且标准差更接近观测值,表明其具有更强的相关性与更小的综合误差;CNN-xLSTM次之,相比LSTM与xLSTM在相关性与误差指标上均有改善。综上,在统一的评估设置下, CNN-xLSTM-Attention在预测精度与分布一致性方面均表现更优。




图6 基于泰勒图的模型测试集性能对比

Fig. 6 Performance comparison of models on the test set based on Taylor diagram

图7为4种模型在训练集和测试集上的预测值与真实值对比散点图及残差分布情况,用于检验模型对PCI的表征能力。整体而言,各模型散点总体沿1:1

对角线分布,说明均能捕捉PCI随特征变化的总体趋势;但不同模型的贴线程度、低值区偏差与残差离散度存在差异。LSTM与xLSTM在低PCI区段的散点离散更明显,表现为局部偏差增大、残差分布更分散,显示其对“劣化加速阶段”的非线性与局部突变刻画不足,容易在工程上造成对重病害区域状态判断的不确定性。引入卷积结构后,CNN-xLSTM模型的散点明显向对角线收敛,残差箱线图的离散范围收窄,表明卷积模块能够更有效提取与PCI劣化相关的局部模式,从而提升拟合稳定性与泛化一致性。进一步叠加注意力机制后,模型在训练集与测试集上均表现出最强的一致性:散点集中于对角线附近、边际分布重合度更高,且训练/测试残差差异不显著,说明模型在避免过拟合的同时实现了更优的全区间预测精度。该结论与图5、6的对比结果保持一致,表明注意力机制有助于强化关键劣化因子的权重分配,从而提高PCI预测的工程可用性与决策可靠性。

3.3 特征重要性分析

采用PCI衰减值作为目标变量进行SHAP分析,并以平均SHAP值刻画各因素对衰减幅度的总体影响强度与相对重要性,结果如图8所示。由图8可见:通航时间贡献占比最高(44.8%),为PCI衰减的首要驱动因素,表明服役年限累积效应在该数据集中对衰减幅度具有主导影响;年平均降雨量次之(33.6%),说明水作用过程对衰减幅度同样具有显著贡献;年起降架次占6.8%,反映运行荷载对衰减的持续作用。温度因素中,低温天数(9.5%)高于高温天数(3.5%),提示该跑道的衰减更可能与低温相关病害过程关联更强。面层厚度占比最小(1.8%),其总体贡献较弱,可能与该变量在样本中的取值波动范围较小有关。




图7 不同模型预测值与真实值对比

Fig. 7 Comparison of predicted values and true values by different models

进一步地,图8(a)的堆叠图展示了不同衰减水平样本下PCI衰减的变化规律。随着PCI衰减值由低到高,各因素的影响强度并非恒定,表明不同衰减阶段对外部驱动的敏感性存在差异。其中 x_1 与 x_2 在各衰减区间内始终保持主要贡献,且在PCI高衰减样本中, x_1 的影响强度更为突出。相应地,图8(b)从相对占比角度进一步表明:在低衰减样本中,贡献主要集中在 x_1 与 x_2 ;而随着衰减加深,温度相关因素(尤其 x_5)的贡献占比逐步提高,说明驱动因素在不同样本间存在明显的阶段性差异。需要强调的是,图8刻画的是影响强度大小与相对重要性,变量对PCI衰减的正负贡献方向仍需结合特征效应曲线进行判定。

为进一步刻画图8中不同因子的作用方向,本文在以PCI衰减值为目标变量的前提下,结合SHAP与

GAM拟合得到各因子的偏依赖曲线,用于识别变量取值变化对预测衰减幅度的影响及其阈值特征,结果如图9所示。图9纵轴SHAP值表示基准水平对模型输出PCI衰减值的边际贡献。SHAP值大于0表明该变量取值使预测的PCI衰减值增大(即衰减加快),SHAP值小于0则表明其使预测的PCI衰减值减小(即衰减趋缓),SHAP值为0表明变量对预测结果无影响。

如图9所示,通航时间在早期对PCI衰减值的贡献较弱,而当通航时间超过5.82年后,SHAP贡献快速转为显著正向并持续增大,说明在该数据集下,运行年限累积到一定阶段后,道面年衰减幅度明显加剧,呈现后期加速劣化特征。年平均降雨量表现为分段非线性:低降雨条件下SHAP贡献偏弱或为负(对应较小的预测衰减),随后整体转为正向,并





图8 基于SHAP模型的R1道面PCI衰减特征重要性分析

Fig. 8 Feature importance analysis of R1 pavement PCI deterioration value based on SHAP model

图9 $x_1 \sim x_6$ 对PCI衰减的影响Fig. 9 Effects of $x_1 \sim x_6$ on PCI deterioration

在 661.40 mm 与 1 434.82 mm 附近出现波动;尤其当降雨量高于 661.40 mm 后,正向贡献明显放大,表明高降雨环境更可能通过水损害与湿热耦合过程提高 PCI 衰减幅度。年起降架次在 3.03 万架附近由负向转为正向,超过该阈值后正向贡献增强,说明高

强度荷载运行会增加 PCI 衰减,加快损伤累积与劣化进程。温度指标同样呈现阈值特征。高温天数在 23.35 d 附近由负向转为正向,低温天数在 19.03 d 附近出现类似变化,表明高低温气候累积到一定水平后,会使 PCI 衰减值的预测值增大,衰减加剧。相

比之下,面层厚度总体呈现负向贡献占优,即厚度增加倾向于降低 PCI 衰减,其关键转折点约为 13.93 cm。当厚度低于该值附近时,SHAP 更可能为正或接近 0,对应较大的衰减幅度;随着厚度增加并超过该转折点,SHAP 逐步转为负且幅值增大,说明较厚面层可降低 PCI 年衰减幅度并延缓劣化。

需要说明的是,本节结论基于本文所采用的单一跑道面数据得到,所识别的阈值为 SHAP-GAM 拟合曲线的统计拐点,用于描述在当前数据覆盖范围内变量影响由弱到强或由负到正的转变区间,并不等同于工程规范限值;其可迁移性仍需在更多跑道样本与不同工况数据上进一步外部验证与校准。

4 结 语

(1)相较 LSTM、xLSTM 与 CNN-xLSTM,本文提出的 CNN-xLSTM-Attention 模型综合性能最优。在训练集与测试集上 R^2 分别达到 0.946 与 0.923;测试集 RMSE、MAE 与 MAPE 分别为 1.758、1.331 与 1.778%,表现出更高的预测精度与更稳定的泛化能力。

(2)泰勒图与一致性/残差分布联合评估表明,CNN-xLSTM-Attention 在相关性保持、波动幅度再现与综合误差控制方面更具优势,预测散点更集中于 1:1 线附近、残差整体更小且训练/测试一致性更好,说明其能够更有效捕捉 PCI 的时序演化规律。

(3)SHAP 与 GAM 可解释性分析揭示了 PCI 衰减的主控因素及其非线性作用机制:通航时间与降雨量为主要驱动因子,其次为起降架次;面层厚度对 PCI 衰减具有抑制作用,厚度越大衰减越缓;温度指标呈现阈值效应且低温影响更敏感。上述规律为养护决策提供支撑,可用于识别对劣化最敏感的关键因子,并为养护重点区段加密检测提供依据。

(4)受限于数据时序长度、检测频率与机场区域化差异,模型在跨机场直接迁移时可能出现性能衰减;当外部环境、结构层参数或交通谱发生显著变化,亦需进行再训练或适配。因此,本文模型更适用于同机场或相近工况机场的年度滚动预测与区段级预警;对于跨区域推广,应满足基础特征体系一致、PCI 评价标准一致的要求。

(5)未来研究将扩充多机场长周期数据,融合病害类型与结构检测信息,进一步引入迁移学习与不确定性量化框架,以增强跨区域预测可靠性与结论的工程可验证性。

参考文献:

References:

- [1] 凌建明,方意心,张家科,等. 机场智能跑道体系架构与关键技术[J]. 土木工程学报,2022,55(2):120-128.
LING Jian-ming, FANG Yi-xin, ZHANG Jia-ke, et al. Framework and key technologies of airport smart runway[J]. China Civil Engineering Journal, 2022, 55(2): 120-128.
- [2] HOU T X, LIU S F, MAO W Y, et al. Stochastic vibration analysis of aircraft-rigid pavement system under random aircraft parameters[J]. International Journal of Pavement Engineering, 2026, 27(1): 2666268.
- [3] RAGUSA E, COSTA A, DI GRAZIANO A. Exploring new computational strategies for managing maintenance activities of airport pavement systems[J]. International Journal of Pavement Research and Technology, 2024, 17(1): 80-101.
- [4] 史保华,许巍,齐勇,等. 机场沥青道面管理与预防性维护对策[J]. 交通运输工程学报,2008,8(2):74-79.
SHI Bao-hua, XU Wei, QI Yong, et al. Management and preventive maintenance countermeasures of airport asphalt pavement[J]. Journal of Traffic and Transportation Engineering, 2008, 8(2): 74-79.
- [5] SONG Y, WANG Y D, HU X, et al. An efficient and explainable ensemble learning model for asphalt pavement condition prediction based on LTPP dataset[J]. IEEE Transactions on Intelligent Transportation Systems, 2022, 23(11): 22084-22093.
- [6] SHOLEVAR N, GOLROO A, ESFAHANI S R. Machine learning techniques for pavement condition evaluation[J]. Automation in Construction, 2022, 136: 104190.
- [7] LI J L, YING H, WANG X F, et al. Automated decision making in highway pavement preventive maintenance based on deep learning[J]. Automation in Construction, 2022, 135: 104111.
- [8] SUN X, WANG H L, MEI S L. Explainable highway performance degradation prediction model based on LSTM[J]. Advanced Engineering Informatics, 2024, 61: 102539.
- [9] CHEN S T, CAO J D, WAN Y, et al. A novel CPO-CNN-LSTM based deep learning approach for multi-time scale deflection basin area prediction in asphalt pavement[J]. Construction and Building Materials, 2025, 458: 139540.
- [10] DENG Y, SHI X M. Short-term predictions of asphalt pavement rutting using deep-learning models[J]. Journal of Transportation Engineering, Part B: Pavements, 2024, 150(2): 04024004.
- [11] WU Y N, ZHANG Q F, WANG Y, et al. Advanced hybrid CNN-GRU model for IRI prediction in flexible asphalt pavements[J]. Journal of Transportation Engineering, Part B: Pavements, 2025, 151(2): 04025003.
- [12] LI J L, ZHANG Z S, WANG X F, et al. Intelligent decision-making model in preventive maintenance of asphalt pavement based on PSO-GRU neural network[J]. Advanced Engineering Informatics, 2022, 51: 101525.
- [13] BECK M, PÖPPEL K, SPANRING M, et al. xLSTM: Extended long short-term memory[J]. Advances in Neural

- Information Processing Systems, 2024, 37: 107547-107603.
- [14] HAN C J, MA T, GU L H, et al. Asphalt pavement health prediction based on improved transformer network[J]. IEEE Transactions on Intelligent Transportation Systems, 2023, 24(4): 4482-4493.
- [15] 张 兵,周丹丹,孙 健,等. 基于双向长短期记忆网络的公交到站时间预测模型[J]. 交通运输系统工程与信息,2023,23(2): 148-160.
- ZHANG Bing, ZHOU Dan-dan, SUN Jian, et al. Bus arrival time prediction model based on bidirectional long short-term memory network[J]. Journal of Transportation Systems Engineering and Information Technology, 2023, 23(2): 148-160.
- [16] OYEWOLA D O, AKINWUNMI S A, OMOTEHINWA T O. Deep LSTM and LSTM-Attention Q-learning based reinforcement learning in oil and gas sector prediction[J]. Knowledge-based Systems, 2024, 284: 111290.
- [17] MH/T 5024—2019,民用机场道面评价管理技术规范[S].
- MH/T 5024—2019, Technical Specification for Airport Pavement Evaluation and Management[S].
- [18] LI Y, ZOU Z B, ZHANG J P, et al. Study on the evolution of airport asphalt pavement integrated distress based on association rule mining[J]. Construction and Building Materials, 2023, 369: 130565.
- [19] 李龙海,伍思铭. 机场刚性道面等级评价与参数敏感性分析[J]. 重庆交通大学学报(自然科学版),2026,45(2):14-23.
- LI Long-hai, WU Si-ming. Evaluation of airport rigid pavement grades and parameter sensitivity[J]. Journal of Chongqing Jiaotong University (Natural Sciences), 2026, 45(2): 14-23.
- [20] BHANDARI S, LUO X H, WANG F. Understanding the effects of structural factors and traffic loading on flexible pavement performance[J]. International Journal of Transportation Science and Technology, 2023, 12(1): 258-272.
- [21] KIRANYAZ S, AVCI O, ABDELJABER O, et al. 1D Convolutional neural networks and applications: A survey[J]. Mechanical Systems and Signal Processing, 2021, 151: 107398.
- [22] 张颖超,安 然,陈 昕,等. 基于多时距风速波动过程划分的高铁沿线风速预测[J]. 交通运输工程学报,2025,25(3): 362-379.
- ZHANG Ying-chao, AN Ran, CHEN Xin, et al. Wind speed prediction along high-speed railway based on multi-time-interval wind speed fluctuation process division[J]. Journal of Traffic and Transportation Engineering, 2025, 25(3): 362-379.
- [23] 王晓明,汪 帆,翟 岸,等. 退化RC桥梁检测-维护规划的贝叶斯决策方法[J]. 交通运输工程学报,2025,25(3):130-143.
- WANG Xiao-ming, WANG Fan, ZHAI An, et al. Bayesian decision method of inspection and maintenance planning for deteriorating RC bridges[J]. Journal of Traffic and Transportation Engineering, 2025, 25(3): 130-143.
- [24] HE Y Z, GAO S J, LI Y, et al. Adaptive machine learning framework: Predicting UHPC performance from data to modelling[J]. Results in Engineering, 2025, 27: 106724.
- [25] LI Z Q. Extracting spatial effects from machine learning model using local interpretation method: An example of SHAP and XGBoost[J]. Computers, Environment and Urban Systems, 2022, 96: 101845.
- [26] 何印章,苏浩然,郝宇远,等. 基于机器学习和SHAP模型的超高性能混凝土性能预测与分析框架[J]. 中国公路学报, 2026,39(4):261-282.
- HE Yin-zhang, SU Hao-ran, HAO Ning-yuan, et al. A predictive and analytical framework for ultra-high performance concrete properties using machine learning and SHAP modeling[J]. China Journal of Highway and Transport, 2026, 39(4): 261-282.
- [27] YANG X, ZHANG J Q, LIU W B, et al. Automation in road distress detection, diagnosis and treatment[J]. Journal of Road Engineering, 2024, 4(1): 1-26.
- [28] PINHEIRO M G, MADEIRA S C, FRANCISCO A P. Short-term electricity load forecasting: A systematic approach from system level to secondary substations[J]. Applied Energy, 2023, 332: 120493.