arXiv:2603.14107v1 [cs.LG] 14 Mar 2026

ST-ResGAT：面向道路状况预测与优先级驱动养护的可解释时空图神经网络

Mohsin Mahmud Topu[1], Azmine Toushik Wasi[1],Mahfuz Ahmed Anik[1],MD Manjurul Ahsan [2]

[1]沙贾拉尔科技大学，锡尔赫特，孟加拉国[2]俄克拉荷马大学，美国俄克拉荷马州诺曼

摘要： 气候脆弱型道路网络亟需从被动的故障后修复转向预测性、可直接用于决策的养护模式。本文提出 ST-ResGAT，这是一种新型时空残差图注意力网络，将残差图注意力编码与 GRU 时间聚合相结合，以预测路面劣化。该框架专为资源受限环境下的部署而设计，可将连续的路面状况指数（PCI）预测结果直接转化为符合美国材料与试验协会（ASTM）标准的养护优先级。基于孟加拉国锡尔赫特 750 个路段的真实检查数据集（2021–2024），ST-ResGAT 显著优于传统的非空间机器学习基线，取得了卓越的预测保真度（$R^2 = 0.93$，$RMSE = 2.72$）。至关重要的是，消融测试证实了对拓扑邻居效应进行建模在数学上的必要性，证明结构衰变会产生空间传染效应。独特之处在于，我们引入 GNNExplainer 对模型进行剖析，证明其学习到的优先级与既有物理工程理论完全一致。此外，我们还量化了分类安全性：ASTM 等级完全一致率达到 85.5%，相邻等级包含率达到 100%，确保预测结果有界且符合工程安全要求。为将模型输出与政策制定相衔接，我们生成了本地化的纵向养护方案，开展气候压力测试，并推导出帕累托可持续性前沿。因此，ST-ResGAT 为高风险、资源匮乏的地质环境下的智能基础设施管理提供了一套实用、可解释且可持续的蓝图。

📅 **日期**：2026年3月15日**通信作者**：Mohsin Mahmud Topu（✉️mohsinmahmudtopu@gmail.com）**关键词**：路面状况指数、预测性养护、可解释人工智能、气候韧性、图注意力网络

Computational Intelligence and Operations Lab

1. 引言

道路基础设施是现代交通运输系统的基础组成部分，为经济流动性、应急响应和区域连通性提供支撑（Lestari 等人，2025年）。然而，对于全球各地的交通机构而言，大规模路面网络的养护仍是一项持续存在的挑战。大多数道路管理部门仍依赖被动养护策略，只有在严重劣化已经显现后才采取干预措施（Famewo 和 Shokouhian，2025年）。这种“故障后修复”模式会加速结构退化，增加车辆运营成本，并给交通网络带来安全风险（Labi 和 Sinha，2003年）。它还会造成严重的环境影响，因为反复的修复周期需要消耗大量集料、沥青结合料和高能耗施工资源，导致基础设施系统的碳足迹不断增加（Mosly，2025年）。因此，从被动管理转向预测性、数据驱动的养护规划，

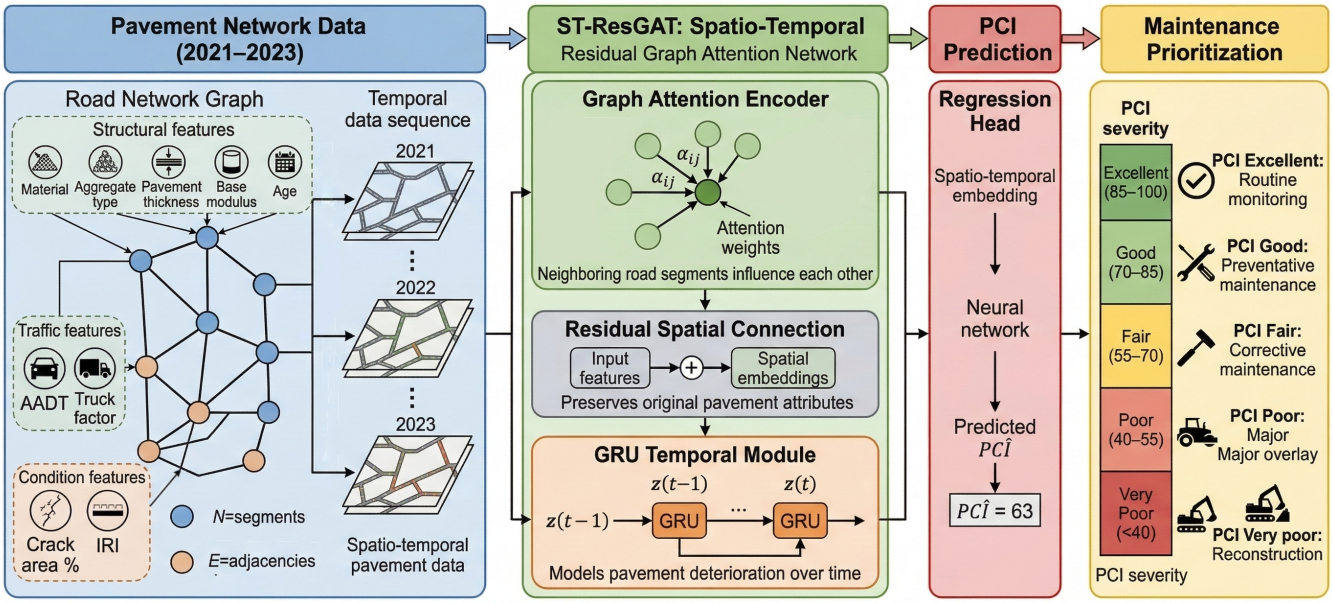

图 1：图形摘要。ST-ResGAT 的开发与评估概述。

已成为可持续基础设施管理以及实现联合国可持续发展目标中多个目标值的一项核心任务。

近年来，机器学习和深度学习的进展加速了自动化路面状况评估与预测框架的发展（Berangi 等人，2025年）。早期研究采用支持向量机（SVM）（Basavaraju 等人，2019年）和人工神经网络（ANN）（Kheirati 和 Golroo，2022年）等经典算法，根据检查数据估算路面状况指数。虽然这些方法证明了数据驱动状况建模的可行性，但往往难以捕捉环境、结构和运行因子之间的复杂交互关系，而这些因子会影响路面劣化（Chen 等人，2023年）。近期研究探索了用于基于图像的病害检测的卷积神经网络（CNN）（Das 等人，2021年；Li 和 Zhao，2019年）、用于表征道路网络拓扑的图神经网络（GNN）（Gao等，2024），以及用于高分辨率基础设施监测的数字孪生（DT）系统（Sierra 等人，2022年；Yan 等人，2023年）。此外，研究人员还提出了结合 GNN 与 DT 框架的混合方法，以应用于预测性养护（Lu 等人，2025年；Topu 等人，2025年）。尽管取得了这些进展，但受数据需求、基础设施成本和计算复杂度的限制，这些方法在实际部署中的应用仍然有限。

现有文献中的一个关键方法学局限在于，许多预测模型将路面路段视为独立实体，忽略了道路网络固有的空间相互依赖性。在实践中，劣化过程会通过共享的荷载模式、排水条件和环境暴露在相互连接的路段之间传播（Sadeghian 等，2025年）。忽略这些网络依赖关系会削弱模型捕捉真实劣化动态的能力。同时，先进的数字化监测框架通常依赖高质量的自动化检测系统，而其准确率通常在 85–90% 之间，仍低于人工调查（Luo 等，2022年，Pierce 等，2013）。对于在数据可用性有限且资源受限条件下运营的交通机构而言，这些限制尤其棘手。此外，即使开发出了预测模型，它们也很少与运营层面的养护规划相结合。现有调度方法通常依赖回顾性数据以及遗传算法等优化技术（Chiou 等，2025年）或多-

准则决策方法（Sayadinia 和 Beheshtinia，2021年），这些方法仍然与前瞻性的劣化预测相脱节。因此，预测分析与可执行的养护优先级排序之间仍存在鸿沟。

为应对这些挑战，本研究提出 ST-ResGAT，这是一种可解释的时空残差图注意力网络，旨在对相互连接的道路网络中的路面劣化进行建模，同时支持养护优先级排序。该架构融合了图注意力机制以捕捉空间依赖关系，利用残差连接稳定深度图学习，并通过门控时间聚合表征纵向劣化动态。与逐点回归模型或传统时间预测器不同，ST-ResGAT 在预测未来路面状况指数（PCI）变化轨迹时，明确纳入网络拓扑和邻居影响。该框架还通过将连续的 PCI 预测结果转换为 ASTM D6433 状况类别（ASTM国际，2023年），并生成以优先级为导向的养护方案，进一步弥合预测与运营决策之间的差距。模型采用一个纵向路面检测数据集进行评估，该数据集包含 2021年 至 2024年 收集的 750 个道路路段上的 3,000 个观测值。实验结果表明，ST-ResGAT 的表现始终优于五种基准方法，在留出数据上达到 R^2 0.93。为提升透明度和从业者信任度，本研究将基于 GNNExplainer（Ying 等人，2019年）的可解释人工智能技术应用于时空图学习场景，从而实现对劣化驱动因素的局部和全局解释。此外，该框架还通过考察预测的 PCI 类别与 ASTM 阈值之间的一致性来评估分类安全性，进而量化实际部署中养护误分类的风险。

本文的主要贡献如下：

1. 我们开发了 **ST-ResGAT**，这是一种可解释的时空残差图注意力网络，融合了图注意力机制、残差学习和门控时间聚合，用于建模道路网络中的空间依赖关系和时间劣化动态。2. 我们提出了一个**预测到决策框架**，将连续的路面状况指数（PCI）预测值转换为符合 ASTM D6433 标准的状况类别（ASTM国际，2023年），并生成路段级养护优先级排名，以支持实际资产管理。3. 我们拓展了**面向时空图神经网络的可解释人工智能技术**，调整特征归因和基于扰动的分析方法，以识别主要劣化驱动因素，并提升基础设施工程师对模型的可解释性。4. 我们使用一个纵向检测数据集开展了详细的**实证评估**，该数据集涵盖2021–2024年的750个路面路段，结果表明模型提升了预测准确度，实现了稳健的ASTM类别对齐，并能够提供可用于实际操作的养护优先级排序。

本文其余部分安排如下。第2 节回顾了路面健康预测、基础设施图神经网络以及道路健康监测中基于优先级的养护等相关研究。第4 节介绍问题表述和方法，并详细说明ST-ResGAT模型以及从预测到决策的转换。第4节介绍数据集和实验设置。第6 节和6.5 节报告实验结果、模型诊断和消融研究。第7 节讨论部署考量、可持续发展目标的契合情况以及本研究的实际意义。第7.2节详述本研究的局限性和未来研究方向，第8 节总结研究发现。表1列出了本文中使用的所有缩写和首字母缩略词。

表1：缩写和首字母缩略词

缩写	全称
AADT	年平均日交通量
AdaBoost	自适应提升
AI	人工智能
ANN	人工神经网络
ASTM	美国材料与试验协会
CatBoost	类别提升
CDV	修正扣减值
CNN	卷积神经网络
DL	深度学习
DT	数字孪生
EPT	有效路面厚度
FE	有限元
GA	遗传算法
GAT	图注意力网络
GNN	图神经网络
GPR	探地雷达
GRU	门控循环单元
IRI	国际粗糙度指数
激光雷达	激光雷达
LSTM	长短期记忆
LTPP	长期路面性能
MAE	平均绝对误差
ML	机器学习
MLP	多层感知机
MSE	均方误差
PCI	路面状况指数
REC	回归误差曲线
RF	随机森林
RHD	道路与公路局
RL	强化学习
RMMS	道路养护管理系统
RMSE	均方根误差
RUL	剩余使用寿命
SDGs	可持续发展目标
SNO	同时网络优化
时空图神经网络	时空图神经网络
ST-ResGAT	时空残差图注意力网络
时空图注意力网络	时空图注意力网络
SVM	支持向量机
UAV	无人驾驶飞行器
XAI	可解释人工智能
XGBoost	极端梯度提升

2. 相关研究

本节回顾路面健康状况预测、基于图的路面劣化建模，以及基于优先级的养护优化框架的最新进展。我们讨论道路损坏检测和预测性养护的成熟方法。最后，我们指出方法上的不足，以此说明开发所提出的预测性养护框架的必要性。

2.1. 基于机器学习的道路状况预测

将路面状况指数（PCI）的评估自动化，已从传统经验方程逐步转向稳健的机器学习（ML）架构（Yuan 等人，2024年；Ani 等人，2025年；Daghigh 等人，2024年）。研究人员利用长期路面性能（LTPP）数据集等大型观测数据资源，证明了集成学习器的有效性。例如，Piryonesi 和 El-Diraby（2021年）使用 LTPP 数据集训练随机森林和梯度提升分类器，报告的类别预测准确率超过 85%。类似地，XGBoost 已应用于公路混凝土病害预测（Lee 和 Sun，2020年）；比较研究则评估了朴素贝叶斯、提升森林、 k近邻和多变量线性回归在裂缝评级任务中的表现（Inkoom 等人，2019年）。越来越多的研究证实，融入机器学习能够显著提高路面损坏预测的准确性（Wu 等人，2020年；Nabipour 等人，2019年；Basavaraju 等人，2019年；Ani 等人，2025年）。

与此同时，深度学习（DL）方法因能够学习复杂的非线性关系和层次化特征表示而日益受到关注（Peng 等人，2024年）。前馈人工神经网络能够灵活地逼近函数，但仍容易受到超参数设置的影响（Radwan 等人，2025年，Karballaeezadeh 等人，2020年）；卷积架构擅长捕捉与 PCI 预测相关的空间模式（Majidifard 等人，2020年）；循环模型，尤其是长短期记忆网络，常用于刻画时间动态（Gowda 等人，2025年，Choi 和 Do，2019年）。尽管取得了这些进展，实践中仍存在两个问题：大多数模型要么忽视了损伤传播所受的空间邻近效应，要么对此刻画不足；此外，它们很少将连续预测结果转化为符合工程需求的状况等级区间，并量化安全裕度。这些局限性使机器学习输出难以满足从业者开展实际决策的需求。

2.2. 基于图的道路健康预测模型

图神经网络将公路网络概念化为由相互连接的节点和边构成的非欧几里得系统。这一转变承认，路面劣化是一个依赖拓扑结构的过程，即某一路段的结构性病害必然会影响相邻路段的劣化速率（Tong 等人，2025年）。Gao 等人 (2024年)证明，通过利用GraphSAGE，模型能够成功捕捉这些空间相关性，提高道路状况预测的准确性；与传统机器学习回归器相比，得分提升了 R^2 0% 至 20%。随着注意力机制的引入，该领域持续发展，这使得人们能够更细致地理解网络影响（Wasi 等人，2024年）。

时空图神经网络（ST-GNNs）已成为网络化基础设施预测的主流范式，因为它们能够联合建模拓扑结构与时间（Corradini 等人，2025年）。当代架构结合了学习得到的空间编码器（图卷积或注意力机制）与时间模块（循环神经网络、时间卷积或注意力机制），以捕捉节点状态在邻居影响下的演变（Rahmani 等人，2023年，Guo 等人，2023年）。表中对具有代表性的时空架构、它们在路面状况预测方面的局限性以及本研究针对性实验的总结

已在表2中给出。

2.3. 养护优化与调度

长期以来，养护计划的优化一直被视为一个受约束的数学问题，主要利用元启发式算法，在预算限制与网络性能之间进行平衡（Wettewa 等人，2024年，Li 等人，2025年）。早期模型通常使用元启发式求解器，在有限预算与网络性能目标之间进行权衡。例如，Yamany 等人 （2024年）利用遗传算法（GA）优化公路管理机构的多年期预算分配，结果表明，与人工优先级排序相比，自动化调度能够改善整体网络状况。同样，Zhu 等人（2025年）构建了一种新型路面养护决策模型，将裂缝成因纳入其中，以提高决策准确性和养护成效。Yao 等人 （2022年）针对多车道公路网络构建了强化学习仿真，与传统的基于阈值的方案相比，实现了约26.6%的全生命周期成本节省。在此基础上，Yao 等人 （2024年）提出了一种多智能体强化学习模型，明确刻画了相邻路段之间的相互依赖关系。在一个现实公路网络案例中，他们的“同时网络优化”（SNO）方法使总成本降低约3.0%，并使平均路面性能提高最高达17.5%。这些研究表明，数据驱动的优化能够显著优于人工预算分配。

与此同时，研究界正逐渐转向整合损伤检测与养护调度的一体化“数字孪生”框架。一项关键趋势是将基于图的预测模型嵌入实时监测平台。例如，Topu 等人（2025年）提出了一种路面数字孪生，通过无人机、激光雷达和嵌入式传感器数据流，持续更新道路网络的图模型。图神经网络（GNN）从这些时空输入中学习（包括物理属性、交通荷载和环境数据），以预测路段劣化。类似地，Lu 等人（2025年）在公路数字孪生中开发了一种时空图注意力网络（STGAT）。通过融合异构历史与实时数据（例如，平整度、开裂和交通量），STGAT能够准确预测未来的路面状况。此外，研究人员还探讨了将模糊逻辑与基于图神经网络的预测结果相结合的混合框架，以应对环境应力因素和材料老化带来的固有不确定性（Santos 等人，2022年），从而为资产管理者提供更具韧性的决策支持层。

2.4. 研究空白分析

尽管机器学习和基于图的方法在道路损伤预测方面已展现出良好的性能（Gao 等人，2024年，Kong 等人，2024年，Yuan 等人，2024年，Ani 等人，2025年），但现有研究大多仍局限于损伤预测或分类。这些研究主要预测未来某个时点发生损伤的风险，却未将后续决策过程形式化，因而无法确定应优先处理哪条具体道路或路段。即使是最初为交通流预测设计的先进时空图神经网络框架（Bui 等人，2022年，Zhong 等人，2025年），其模型构建通常也以平稳或周期性的时间模式为指导，而非基于能够明确捕捉突发事件驱动的劣化机制，例如严重洪水后观测到的路面状况指数（PCI）快速损失（Masuda 等人，2016）。当前的一体化解决方案通常依赖数字孪生架构（Lu 等人，2025年），这需要高昂的资本投资和专业技术能力，对于资源受限的低收入国家而言并不可行。此外，GNNExplainer 等常用于图的可解释性方法在这一领域仍鲜有探索。因此，预测、解释和干预设计往往被视为依次进行的阶段，而非结构上集成的框架。由此可见，针对高脆弱性季风环境的框架在方法学上仍十分匮乏，例如

表2：基于图的基础设施预测模型：概述、研究空白以及 ST-ResGAT 如何解决这些问题。

作者 / 年份（模型）	应用	Gaps	ST-ResGAT 的贡献
Gao 等人（2024年）（GraphSAGE）	应用于道路网络的图神经网络拓扑，以 PMIS 数据为基础对路面劣化进行建模使用 PMIS数据进行劣化分析。	对邻域效应进行隐式建模；在.....方面可解释性有限基础设施决策。	带残差投影的图注意力量化邻居的影响，并提供可解释的空间学习。
Zhou 和 Al-Qadi（2024年）（有限元-GNN 代理模型）	训练完成的图神经代理模型基于三维有限元路面响应模拟。	侧重于结构响应预测，而非网络级 PCI 预测。	将图学习扩展至路段级路面状况指数预测，并结合时间建模。
Tong 等人 (2025年)（时空图自回归网络）	时空图自回-归模型结合图注意力-力机制和时间自回归预测。	消息传递过程中的特征混合；可解释性有限对从业者而言。	残差空间表示使其稳定特征传播具有可解释的节点影响。
Dang 等（2022年）（g-SDDL）	GNN + 卷积堆叠操作-直接处理原始振动信号；用于多种损伤检测的堆叠模型，无需手工设计特征。	专注于分类/损伤基于振动数据进行检测；未专为网络级连续路面状况指数预测或长期劣化预测而设计。	启发 ST-ResGAT 中原始传感器→节点特征处理流程（使用原始时间序列作为节点输入）以及集成/堆叠策略以实现稳健的多损伤路段建模，同时保留 ST-ResGAT 的时间预测和可解释性。
Djenouri et al. (2022年) (智能-图卷积网络裂缝检测)	图像到图转换与用于道路裂缝检测的图卷积网络。	图块级检测；忽略网络拓扑和时间恶化。	路段级图表示，可捕捉空间传播路面状况。
Feng等(2023年) (SCL-GCN)	对比学习增强的 GCN for 基于激光雷达的裂缝检测。	侧重检测；缺乏时序预测与养护决策映射。	将空间图注意力网络与时序 GRU 结合，以实现劣化预测。
Liu 和 Al-Qadi (2025年) (GPS-GNN 路面模拟-tor)	编码器–处理器–解码器基于三维有限元训练的图神经网络代理模型路面模拟。	高保真有限元代理模型，但并非专为可直接用于决策的 PCI 预测而设计。	利用结构响应模式，并将输出映射至主护状况等级区间。
Su 等（2026）(GNN–Transformer 多任务)	物理引导的GNN模型微-结构拓扑，而Transformer-前者分析随机载荷谱以进行疲劳预测。	微观结构尺度建模；有限的适用性至道路网络层面的劣化。	ST-ResGAT侧重于路段层面的空间拓扑和时间劣化，以进行网络尺度预测。
He等（2024年）（HeteroGNN + 本体-论）	用于桥梁缺陷本体以预测养护-维护活动。	专注于桥梁养护分类，而非状况预测。	采用可解释的图推理将预测PCI与养护优先级排序相联系。
Kong 等人 (2024年) (STP-GNN)	扩展的消息传递图神经网络用于时空退化传播建模，以预测剩余使用寿命。	专为设备剩余使用寿命设计；基础设施专属可解释性有限。可解释性。	残差空间注意力机制及专为路面网络劣化建模量身定制的可解释性。

孟加拉国锡尔赫特。在此类气候风险高发的环境中，基础设施管理仍主要依赖反应式维护做法，这不仅造成大量资源低效，还加剧了公共运行中断、环境退化和事故风险。这些状况凸显了迫切需要一种可行且适应具体情境的框架，以支持主动式基础设施管理。然而，在道路健康监测研究中，将时空预测与稳健的维护画像及优先级排序层相结合的方法仍然有限，尤其是在资源匮乏的地质环境中。

为应对这些局限性，我们提出了一种时空残差图注意力框架，在统一架构中整合预测、解释和基于优先级的排序，以实现高效养护。我们并未将可解释性和预测准确性视为最终分析结果，而是将通过GNNExplainer得出的模型解释纳入决策框架，确保养护建议在物理层面可解释、在实际操作中可靠。此外，AI驱动建议的可靠性很少从风险管理的角度进行评估，因为现有框架大多忽略分类安全性和边际误差分析，导致对边界情况的行为缺乏充分考察，尽管这可能对灾难性的基础设施故障产生重要影响。

除了方法稳健性之外，这些挑战在孟加拉国等国家还具有更广泛的可持续发展影响。在这些国家，气候脆弱性、基础设施韧性和可持续城市交通需求带来的结构性压力，持续阻碍联合国可持续发展目标的推进。通过将可解释的时空预测与养护优先级排序及风险意识评估相结合，所提出的框架间接支持更广泛的可持续发展目标，包括经济生产力、韧性城市、负责任的资源利用和气候行动。由此，本研究超越了对基础设施的描述性建模，转向以可持续发展为导向的决策范式，将预测洞见转化为可操作的策略，既支持在全球发展目标值方面取得可衡量的进展，也能在气候压力日益加剧的情况下实现公路资产的韧性管理。

3. 研究动机

气候脆弱地区的道路网络因极端水文和环境条件而加速劣化。孟加拉国是一个尤为典型的研究背景，因为其相当大比例的人口和交通基础设施暴露于季节性洪涝、降水变异性较大以及快速城市扩张等影响之下。全国约有56%的人口居住在高度暴露于气候相关灾害的地区（Haque and Yousuf，2024）。这些环境压力会显著影响路面性能，增加水分渗入、削弱路基层，并加剧荷载诱导疲劳过程。

东北部的锡尔赫特专区充分展现了这些挑战的严重性。在2022年洪水事件期间，该地区约55.76%的区域遭洪水淹没，近1,060万居民受到影响，约43.38%的主要道路被淹没（Shafiq，2023年）。洪水诱发损坏加剧了路面病害，例如剥落、坑槽形成和结构基层失效，导致路面状况指数（PCI）迅速下降。由此造成的中断不仅涉及工程问题，还会增加运输成本、影响货运，并限制人们获取基本服务。

这些环境冲击很少孤立地影响道路路段。洪水传播、排水连通性和交通重新分配，往往会导致交通网络相邻路段出现空间相关的劣化模式。因此，某一地点的路面劣化可能通过改变荷载模式、共同的环境暴露以及

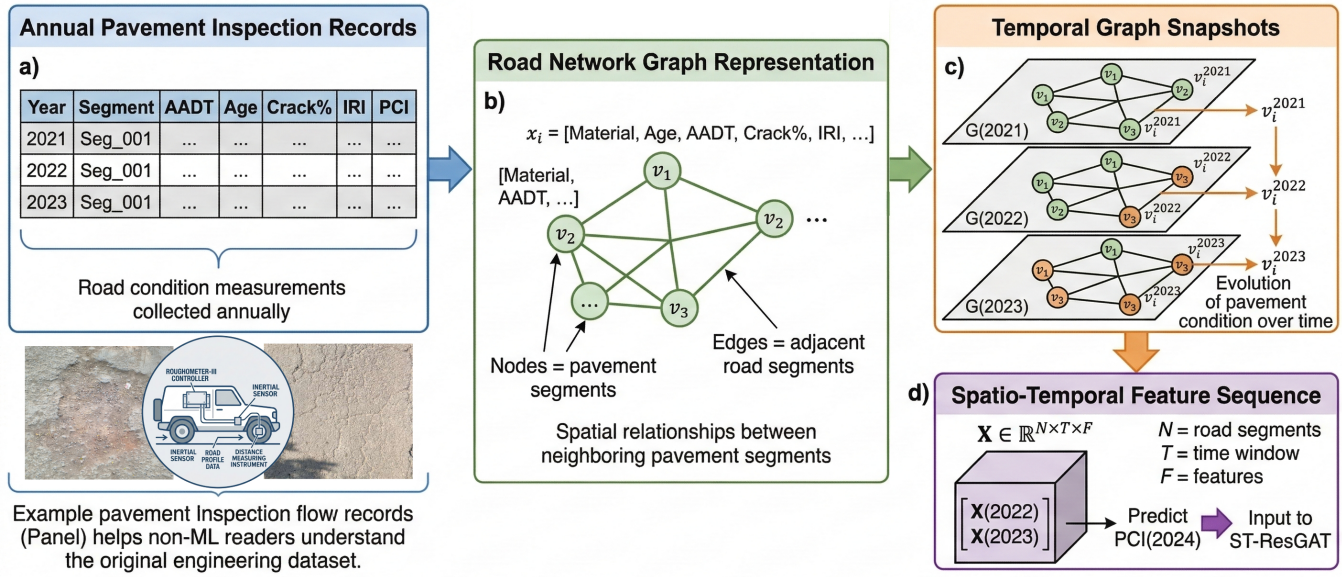

图2：ST-ResGAT中所使用的时空图表示的构建。首先，将跨多年收集的路面检查记录整理为每个道路路段的节点特征。道路网络拓扑定义了各路段之间的邻接关系，从而形成图结构。每一年对应一个图快照，其拓扑保持不变，但节点属性会更新。随后，将一段时间窗口内的历史快照结合起来，创建时空特征序列，并将其作为所提出的ST-ResGAT模型的输入，用于未来的路面状况预测。

延迟养护的影响，左右相邻连接的性能。这类网络层级依赖凸显了对分析框架的需求，即能够在刻画时间劣化动态的同时，对空间交互进行建模。

与此同时，许多发展中地区的交通机构面临诸多限制，包括检查数据有限、养护预算受限，以及难以获取高成本的监测技术（如数字孪生系统）。这些限制降低了依赖密集传感器网络或持续高分辨率调查的基础设施监测方法的可行性。因此，开发兼具数据效率和运营可解释性的预测模型具有重要价值，从而能够在资源受限的交通管理环境中支持主动养护规划。

4. 方法

本节详细介绍时空残差图注意力网络（ST-ResGAT）的构建方法、架构和验证策略。为准确捕捉路面劣化复杂且相互依存的动态变化，首先将实体道路基础设施数学建模为非欧几里得图，并整合多维结构、交通量和状况属性。所提出的深度学习架构将多头图注意力机制与门控循环单元（GRU）协同结合，其中多头图注意力机制通过残差连接增强，以捕捉结构损伤的空间传染，门控循环单元则用于建模时间序列中的时间衰减。此外，为确保该框架能够作为实际运行的决策支持工具，本节还介绍了可解释人工智能（GNNExplainer）的集成，以提高机理透明度，并说明如何将连续的路面状况指数（PCI）预测值转换为标准化且符合工程安全要求的 ASTM 养护类别。

4.1. 问题表述

假设一个道路网络包含 N 个路面路段，观测时间跨度为 T 年。每个路段表示为图中的一个节点，道路路段之间的邻接关系构成图边。目标是利用结构、交通量和历史属性，预测未来某一年的每个路段的路面状况指数（*PCI*）。表3 列出了所有使用的符号说明。

形式上，道路网络表示为图 $G=(V,E)$，其中 $V=\{v_1,v_2,...,v_N\}$ 表示路面路段集合，E 表示路段之间的邻接关系。对于时刻t的每个节点 v_i，我们定义一个特征向量 $\boldsymbol{x}_i^{(t)}\in\mathbb{R}^F$，其中 F 表示属性数量。为捕捉路面劣化和荷载行为的不同方面，这些特征分为三类。第一类为结构特征 (i)，包括路面材料类型、集料类型、有效路面厚度 (EPT)、基层模量和路面年龄，用于描述路面结构的物理和力学属性。第二类为交通特征 (ii)，例如年平均日交通量 (AADT) 和卡车因子，用于表示车辆荷载强度以及重型车辆对路面性能的影响（Kumar 和 Suman，2025年）。第三类为状况特征 (iii)，包括裂缝面积百分比和国际粗糙度指数 (IRI)，用于表征路面当前的路表病害和行驶质量（Paterson，1986年）。

预测目标为 PCI 值 $y_i^{(t)}\in\mathbb{R}$。给定 T_0 个往年的历史观测值，目标是估算

$$\hat{y}_i^{(t+1)}=f_\theta\left(\boldsymbol{x}_i^{(t-T_0+1)},\ldots,\boldsymbol{x}_i^{(t)},G\right), \tag{1}$$

其中 $f_\theta(\cdot)$ 表示所提出的**时空残差图注意力网络 (ST-ResGAT)**，其参数化为 θ。预测的 PCI 值随后依据ASTM国际 (2023年) 进行严重程度分类，以用于养护优先级排序；不过，优先级排序流程本身独立于图模型。

4.2. 数据预处理与图构建

数据集描述。 该数据集包含 $N=750$条道路路段在2021年至2024年间的路面检查记录。每条记录都包含上述特征以及实测 PCI 值。设 $\mathcal{D}=\{(X^{(t)},Y_{(t)})\}_{t=2021}^{2024}$ 其中 $X^{(t)}\in\mathbb{R}^{N\times F}$，$Y_{(t)}\in\mathbb{R}^N$。每一行对应一个路面路段。实验采用时间预测设置，使用涵盖2021年至2023年的历史观测值对模型进行训练和验证。最终评估在2024年数据集上进行，并以前两年的2022—2023年观测值作为输入，以评估模型对未来路面状况预测的泛化能力，并模拟现实世界的决策场景。

图拓扑构建。 网络的连通性和排列方式称为其拓扑（Ahmadzai 等，2019年）。因此，道路交通网络具有各种特定的拓扑，用边、顶点、路径和环来表示其结构（Rodrigue，2020年）。道路网络拓扑通过路面路段之间的邻接关系构建。如果路段 i 与路段 j直接相邻，则添加一条无向边：$e_{ij}\in E$。图结构由边索引矩阵表示 $\boldsymbol{A}\in\{0,1\}^{N\times N}$，其中

$$A_{ij}=\begin{cases}1 & \text{if segments } i \text{ and } j \text{ are adjacent}\\ 0 & \text{otherwise}\end{cases}. \tag{2}$$

由于邻接关系具有对称性，因此将图视为无向图。图构建过程如图2所示。

表 3: 符号说明。

符号	描述
G	道路网络的图表示 （V、 E）
V	路面路段（图节点）的集合
E	路段之间的邻接关系（边）的集合
N	网络中的路面路段总数
T	时间观测总数（年）
F	描述路面属性的节点特征数量
v_i	图中的第i个路面路段（节点）
$\boldsymbol{x}_i^{(t)}$	节点 i 在时间 t的特征向量
$X^{(t)}$	时间 t的节点特征矩阵 , $X^{(t)} \in \mathbb{R}^{N \times F}$
$Y(t)$	时间 t的真实 PCI 值向量
$y_i^{(t)}$	路段 i 在时间 t的观测路面状况指数
$\hat{y}_i^{(t)}$	路段 i的预测路面状况指数值
$\boldsymbol{A}$	表示图连通性的邻接矩阵
A_{ij}	显示节点 i 和 j 是否相邻的二元指示变量
$\mathcal{N}(i)$	与节点 i 相连的相邻节点集合
T_0	历史观测值所使用的时间窗口长度
$\boldsymbol{X}$	时间特征张量 $\in \mathbb{R}^{N \times T_0 \times F}$
W	图注意力层中的可学习权重矩阵
$\boldsymbol{a}$	GAT 层中的注意力权重向量
α_{ij}	节点 i 与 j之间的归一化注意力系数
$\boldsymbol{h}_i$	经过图注意力聚合后节点 i 的空间嵌入
$\boldsymbol{z}_i$	节点 i的残差空间表示
$\boldsymbol{S}_i$	节点 i的空间嵌入时间序列
h_t	GRU 在时间步 t的隐藏状态
f_θ	参数化为 θ的 ST-ResGAT 模型
$\mathcal{L}$	训练损失函数（均方误差）
I_f	特征 f 的基于置换的重要性分数
$\boldsymbol{M}_f$	GNNExplainer 学得的特征重要性掩码
$\boldsymbol{M}_e$	GNNExplainer 学得的边重要性掩码

时间图快照。每年对应一个图快照： $G^{(t)} = (V, E, X^{(t)})$。节点集和图拓扑在不同时期保持不变，而节点特征每年都会演变。

时间窗口构建。 为纳入历史上下文，构建长度为 T_0的滑动时间窗口。对于每个训练实例，$\boldsymbol{X}_i = \left[\boldsymbol{x}_i^{(t-T_0+1)}, \ \boldsymbol{x}^{(t-T_0+2)}{}_i, \ \ldots, \ \boldsymbol{x}_i^{(t)}\right]$，预测目标则变为 $y_i^{(t+1)}$ 。因此，每个样本由 $\boldsymbol{X} \in \mathbb{R}^{N \times T_0 \times F}$ 组成。

特征归一化。 特征幅值差异显著（例如，年平均日交通量与裂缝百分比）。因此，所有特征均使用 $\tilde{x} = \frac{x-\mu}{\sigma}$ 进行标准化，其中 μ 和 σ 仅使用训练数据计算。训练期间，目标值也会进行类似的归一化，并在评估时进行逆变换。

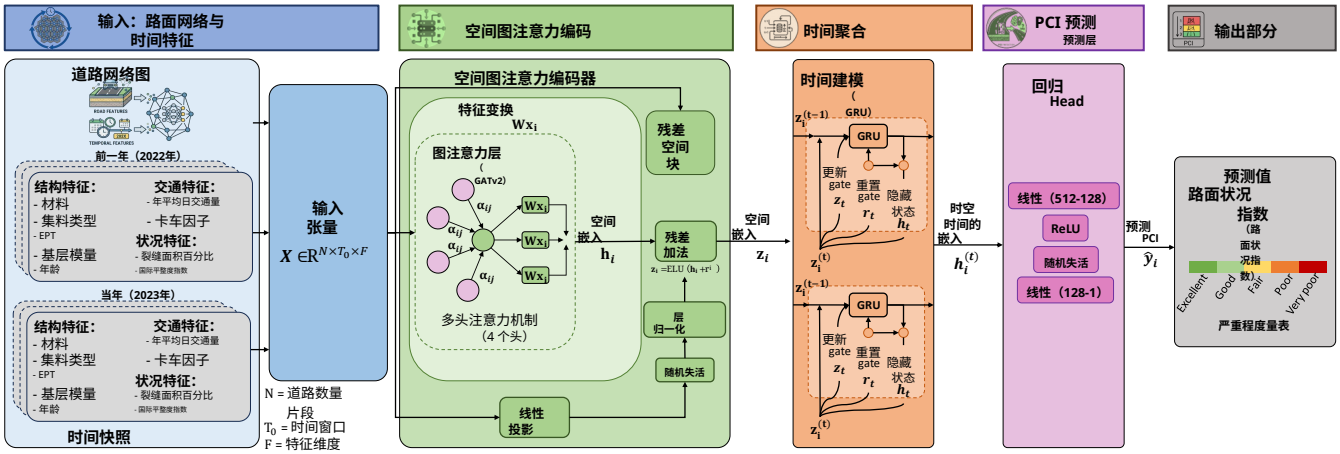

图 3：用于路面状况预测的时空残差图注意力网络（ST-ResGAT）架构。模型以时间节点特征和道路网络图作为输入。通过带有残差连接的多头图注意力网络（GAT）层，学习相邻路面路段之间的空间依赖关系，同时保留原始结构属性。利用门控循环单元（GRU）聚合多个时间步的空间嵌入，以捕捉时间退化模式。随后，将最终的时空表示输入回归头，以估算各路段的路面状况指数（PCI），并可据此确定养护优先级。

4.3. ST-ResGAT

所提模型结合了空间图注意力和时间序列建模，以捕捉相邻道路路段之间的空间依赖关系以及时间退化模式。该架构由三个主要部分组成：（i）基于图注意力网络的空间编码器，用于学习相邻路面路段之间的交互关系；（ii）残差空间表示模块，用于保留原始特征信息并稳定训练；（iii）采用门控循环单元（GRU）实现的时间聚合模块，用于对跨越多年的历史路面劣化进行建模。图 3 展示了所提模型的架构。

4.3.1. 空间图注意力编码器

道路路面区段并非彼此独立。道路路段的状况往往受相邻路段状况的影响，因为相邻的路面路段通常具有相似的环境暴露、交通荷载和施工特征（Gao 等人，2024年）。为对道路网络中的这种空间依赖进行建模，本文使用图注意力网络（GAT）（Vaswani 等人，2017年）层作为空间编码器。

对于每个时间步 t，节点特征会沿图结构传播，使每个路面路段都能整合其相邻路段的信息。模型不会为所有邻居赋予相同的影响力，而是学习一个注意力权重，以确定每个相邻路段对给定路段表示的贡献程度。对于节点 i，其与邻居 j 的注意力系数计算如下：

$$e_{ij} = \text{LeakyReLU}\left(\boldsymbol{a}^T [W\boldsymbol{x}_i \,\|\, W\boldsymbol{x}_j]\right) \tag{3}$$

其中， W 是用于变换输入特征的可学习权重矩阵， $\boldsymbol{a}$ 是用于衡量两个节点之间兼容性的注意力向量， $\|$ 表示特征拼接。此操作使模型能够比较相邻路面路段的特征特性。

随后，使用 Softmax 函数对节点 i 的所有邻居对应的原始注意力分数进行归一化：

$$\alpha_{ij} = \frac{\exp(e_{ij})}{\sum_{k \in \mathcal{N}(i)} \exp(e_{ik})}. \tag{4}$$

这些归一化系数决定了各邻居在更新节点 i 的表示时所具有的影响力。通过聚合邻居经变换后的特征，并以学习到的注意力系数作为权重，即可得到更新后的节点表示：

$$\boldsymbol{h}_i = \sigma\left(\sum_{j \in \mathcal{N}(i)} \alpha_{ij} W \boldsymbol{x}_j \right). \tag{5}$$

为提升空间编码器的表达能力，采用多头注意力机制。多个注意力机制并行运行，各自学习相邻路段之间不同的交互模式。随后将各注意力头的输出进行拼接：

$$\boldsymbol{h}_i = \|_{k=1}^{K} \sigma\left(\sum_{j \in \mathcal{N}(i)} \alpha_{ij}^{(k)} W^{(k)} \boldsymbol{x}_j \right). \tag{6}$$

这种多头机制使模型能够捕捉不同的空间关系，例如相邻路面路段之间共享的交通荷载模式或相似的结构特征。

4.3.2. 残差空间表示

尽管图注意力层能够有效捕捉空间交互，但较深的图变换有时可能会扭曲原始节点特征（Wu 等人，2023年）。在路面状况建模中，原始结构属性和交通属性仍是重要的预测因素，不应在特征传播过程中丢失。为保留这些信息并提高训练稳定性，空间编码器中引入了残差连接。

首先通过线性变换，将原始节点特征投影到相同的嵌入维度： $\boldsymbol{r}_i = W_r \boldsymbol{x}_i$ 随后，将此残差表示与基于注意力的嵌入相加：

$$\boldsymbol{z}_i = \mathrm{ELU}(\boldsymbol{h}_i + \boldsymbol{r}_i). \tag{7}$$

残差连接确保模型在纳入从相邻路段聚合的信息的同时，仍能访问原始结构属性和交通属性。此步骤之后，应用层归一化和随机失活，以稳定训练并减少过拟合。

4.3.3. 时间特征聚合

路面劣化本质上是一个时间过程。道路路段的结构状况会随着时间推移，在交通量荷载、环境暴露和材料老化的作用下逐渐变化。因此，

模型必须捕捉路面特征在多年间的演变，而不是依赖单一时间点的快照。

对于每个节点，收集前序步骤在整个时间窗口内获得的空间嵌入： $\boldsymbol{S}_i = [\boldsymbol{z}_i^{(t-T_0+1)}$ ，……， $\boldsymbol{z}_i^{(t)}]$。该序列描述了路面路段的结构和空间特征如何随时间演变。随后，使用门控循环单元（GRU）处理该序列。GRU 是一种循环神经网络架构，旨在捕捉时间依赖关系，同时避免梯度消失问题。

GRU 维护一个用于概括历史信息的隐藏状态。其更新过程由两个门控制，用于调节信息随时间的流动。

更新门的计算公式为

$$\boldsymbol{z}_t = \sigma(W_z x_t + U_z h_{t-1}) \tag{8}$$

它决定应保留多少前一时刻的隐藏状态。

重置门的计算公式为

$$\boldsymbol{r}_t = \sigma(W_r x_t + U_r h_{t-1}) \tag{9}$$

它决定过去的信息对候选隐藏状态的影响程度。

候选隐藏表示计算如下

$$\tilde{h}_t = \tanh(W_h x_t + U_h(r_t \odot h_{t-1})) \tag{10}$$

最终隐藏状态更新如下

$$h_t = (1 - z_t) \odot h_{t-1} + z_t \odot \tilde{h}_t. \tag{11}$$

通过这些门控机制，GRU 学习路面特征如何随年份演变，以及过去的状况如何影响未来的劣化。最终隐藏状态 $h_i^{(t)}$ 作为一种紧凑表示，总结了每个道路路段的空间交互和历史路面演变。

4.3.4. 预测层

模型的最后一步是估计下一个时间段的路面状况指数。通过 GRU 获得的时间表示被输入前馈回归网络，该网络将学习得到的嵌入映射为标量 PCI 预测值。

节点 i 的预测路面状况指数值计算如下

$$\hat{y}_i = W_2 \phi(W_1 h_i^{(t)}) \tag{12}$$

其中 $\phi(\cdot)$ 表示 ReLU 激活函数。

该回归层学习组合时空表示与预期路面状况值之间的映射。由此得到的预测既反映路段当前的结构特征，也反映网络中观察到的历史劣化模式。

4.3.5. 学习目标

The 模型使用在训练节点上计算的均方误差损失进行训练：

$$\mathcal{L} = \frac{1}{|V_{train}|} \sum_{i \in V_{train}} (\hat{y}_i - y_i)^2. \tag{13}$$

4.3.6. 训练流程

训练首先根据历史观测值构建时间图窗口。对于每个窗口，模型接收节点特征序列以及对应的图拓扑。利用图注意力层计算路面路段的空间表示，以捕捉相邻道路路段之间的交互关系。随后，GRU模块对时间窗口内的这些空间嵌入进行处理，以建模随时间变化的劣化动态。接着，将得到的时间表示输入回归头，预测下一年的路面状况指数（PCI）值。通过基于梯度的优化，根据预测的 PCI 值与观测到的 PCI 值之间的均方误差损失更新模型参数。

4.3.7. 基于预测的养护优先级排序

为确保实际应用性，按照全球认可的 ASTMD6433（ASTM国际，2023年）标准，将连续的 PCI 预测值转换为离散的可执行类别，如表 2所示。

表4： 路面状况指数（PCI）严重程度及建议措施，依据ASTM国际（2023年）

PCI	严重程度等级	建议措施	实际影响
86–100	1（非常低）	例行监测	结构状况良好，无需立即采取措施
71–85	2（低）	预防性维护	明显磨损，需进行裂缝密封
56–70	3（中等）	修复性养护	严重病害，需要修补
41–55	4（高）	大面积加铺	严重病害，潜在基层失效
0–40	5（危急）	全面重建	结构失效，高安全隐患

令 $\hat{y}_i$ 表示预测PCI。使用预设阈值划分严重程度类别：

$$S_i = \begin{cases} \text{Excellent} & 85 \le \hat{y}_i \le 100 \\ \text{Good} & 70 \le \hat{y}_i < 85 \\ \text{Fair} & 55 \le \hat{y}_i < 70 \\ \text{Poor} & 40 \le \hat{y}_i < 55 \\ \text{Very Poor} & \hat{y}_i < 40 \end{cases}. \tag{14}$$

将预测的严重程度排序与根据实际路面状况指数值得出的排序进行比较。尽管具体的 PCI 值可能略有差异，但预测类别总体上与实际优先级相符。

这表明，ST-ResGAT 模型能够充分捕捉劣化模式，从而支持实际的养护规划。

4.4. 可解释人工智能

尽管所提出的 ST-ResGAT 模型具有较高的预测性能，但要了解哪些路面特征会影响预测的状况评分，可解释性必不可少。为此，我们采用一种可解释人工智能框架，结合**GNNExplainer** (Ying 等人，2019年）进行局部解释，并采用**基于置换的特征重要性**方法实现全局可解释性。

4.4.1. 使用 *GNNExplainer* 进行局部解释

图神经网络运行于复杂的图结构之上，因此难以解释各个特征和边的贡献（Lu 等人，2025年）。为分析模型针对特定路面路段的决策过程，我们使用 GNNExplainer。

给定一个训练好的模型 f_θ和一个节点 v_i，GNNExplainer旨在寻找最小子图 G_S和特征子集 F_S，使模型预测与解释之间的互信息最大化：$\max_{G_S,\ F_S} I(Y_i;\ G_S, F_S)$其中 $Y_i = f_\theta(G, X)_i$ 表示节点 i的预测PCI。解释过程会学习两个掩码：*(i)* 特征掩码 $\boldsymbol{M}_f$，用于识别重要的节点属性；*(ii)* 边掩码 $\boldsymbol{M}_e$，用于识别有影响力的图连接。这些掩码通过基于梯度的学习进行优化：

$$\min_{\boldsymbol{M}_f, \boldsymbol{M}_e} \mathcal{L}_{pred} + \lambda_1 ||\boldsymbol{M}_f||_1 + \lambda_2 H(\boldsymbol{M}_f) + \lambda_3 ||\boldsymbol{M}_e||_1 \tag{15}$$

其中 H（·）表示熵正则化，用于鼓励生成稀疏解释。

4.4.2. 将 *GNNExplainer* 适配到时空图输入

ST-ResGAT 模型接受时间特征序列 $X \in \mathbb{R}^{N \times T_0 \times F}$，其中 T_0 表示历史时间窗口。然而，GNNExplainer 框架假设节点具有维度为 $X \in \mathbb{R}^{N \times F}$的静态特征。

为弥合这一差异，我们引入了一个包装模型，将静态节点特征转换为时间序列。设 $\boldsymbol{x}_i \in \mathbb{R}^F$ 表示 GNNExplainer 提供的扰动节点特征。包装模型沿时间维度重复特征向量，以重建时间序列： $\tilde{X}_i = [\boldsymbol{x}_i, \boldsymbol{x}_i, \ldots, \boldsymbol{x}_i]$，共 T_0 个时间步。随后，将生成的张量 $\tilde{X} \in \mathbb{R}^{N \times T_0 \times F}$输入 ST- ResGAT 模型。此策略使 GNNExplainer 能够评估模型空间组件的特征重要性，同时保持与时间架构的兼容性。

4.4.3. 节点级特征重要性

对于选定的路面路段 v_i，GNNExplainer 会生成一个特征重要性向量 $\boldsymbol{m}_i \in \mathbb{R}^F$，用于表示各属性对预测PCI的相对贡献。为便于可视化和比较，对重要性值进行归一化：

$$\tilde{m}_{i,f} = \frac{m_{i,f}}{\sum_{k=1}^{F} m_{i,k}} \tag{16}$$

其中 $\tilde{m}_{i,\ f}$ 表示特征 f 的归一化重要性。

这些归一化得分通过条形图进行可视化，以说明哪些结构、交通量或状况变量对给定道路路段的预测结果影响最大。

4.4.4. 全局特征重要性

虽然 GNNExplainer 提供局部解释，但全局特征重要性采用基于置换的方法进行评估（Hassija 等人，2024年）。设 $\hat{Y}$ 表示模型预测，Y 表示真实 PCI 值。基线预测误差使用均方误差（MSE）计算：

$$\text{MSE}_{base} = \frac{1}{N}\sum_{i=1}^{N}(y_i - \hat{y}_i)^2 \tag{17}$$

为衡量特征 f 的重要性，将该特征值在各节点间随机置换：$X^{perm}:,:,f$这会破坏该特征与目标变量之间的关系。
使用扰动后的特征重新计算模型预测，从而得到新的误差值：MSE_f^{perm}。特征重要性得分定义为 $I_f = \text{MSE}_f^{perm} - \text{MSE}_{base}$。误差增幅越大，表示模型对该特征的依赖程度越高。

为获得相对贡献，将各项得分进行归一化：

$$\tilde{I}_f = \frac{I_f}{\sum_{k=1}^{F} I_k}. \tag{18}$$

该方法量化了各项结构特征和交通量特征对路面健康预测的整体影响。

5. 数据与实验设置

5.1. 数据收集

为评估所提出的 ST-ResGAT 框架的有效性，我们采用了一个真实世界的高分辨率数据集，该数据集涵盖孟加拉国锡尔赫特地区的 750 个实体道路路段。数据从道路与公路局（RHD，2001年）的官方记录中经过细致整理而成。数据收集过程中，孟加拉国道路与公路局（RHD，2001年）使用安装在车辆上的 III 型路面平整度测量仪。道路与公路局（RHD）依据 ASTM D6433（ASTM国际，2023年）所述的方法计算路面状况指数（PCI），该指数为道路状况提供 0–100 的标准化数值评级。该过程首先对划定的抽样单元开展目视调查，以识别路面病害的类型、严重程度和数量。随后，利用基于密度的权重因子将这些观测值转换为扣减值，以反映每种缺陷的影响。为在考虑多种病害的同时避免对评分过度惩罚，迭代计算修正扣减值（CDV），并通过从 100 中减去最大 CDV 确定最终的路面状况指数（PCI）（Zafar 等，2019年）。该数据是 RHD 道路养护管理系统（RMMS）的核心数据。其余输入特征均从 RHD （2001年）数据库中收集。锡尔赫特因其独特的社会环境特征而被战略性地选为研究区域。该地区是全国最易受洪水影响的区域之一，经常遭受会加速路面劣化的山洪，同时也是重要的国家级旅游枢纽。因此，维护该地区的基础设施健康状况对于灾害韧性（可持续发展目标 11/13）和当地旅游业驱动型经济（可持续发展目标 8）都至关重要。

5.2. 数据统计

所汇编的数据集构成了一份跨越 2021年至 2024年的纵向路面监测记录。该网络由 750 个表示为图节点的道路路段组成，共包含 3000 个时间观测。每个节点对应一个具有空间差异的路面路段，而边表示相邻路段之间的邻接关系。构建的道路图总计包含 1498 条双向邻接连接，使模型能够捕捉交通网络中的空间依赖关系。

每个节点观测值由十二个解释变量刻画，这些变量描述了影响路面劣化的结构、交通、环境和材料状况。结构属性包括现有路面厚度（EPT）、基层模量和以年为单位的路面年龄。交通相关荷载状况通过年平均日交通量（AADT）和卡车因子表示，两者都会影响疲劳累积和结构磨损。材料特性通过路面材料类型和集料类型的分类指标进行描述。环境暴露由洪水风险等级和距采石场来源的距离表示，而路面病害指标包括国际粗糙度指数（IRI）和裂缝面积百分比。路面状况指数（PCI）是主要预测目标，代表每个路面路段的整体结构健康状况。表5 汇总了建模过程中使用的所有变量的描述性统计。

表 5： 数据集的描述性统计。

特征	唯一值	Min	Max	Mean	Std
材料	2	0	1	0.74	0.44
集料_类型	2	0	1	0.87	0.34
洪水 _Risk	3	0	2	0.93	0.86
距采石场_距离	2	0	1	0.26	0.44
年龄_年	10	2	11	6.56	2.28
交通量_AADT	2505	5004	19977	9481.24	4039.14
卡车 _因子	817	1.00	11.99	5.77	3.09
EPT_mm	538	120.60	320.00	253.80	58.69
Base_模量	657	150.80	499.60	349.56	103.09
裂缝 _Area_Pct	1069	0.00	21.92	4.32	3.95
IRI	349	1.00	5.66	2.65	0.69
PCI	1950	36.65	97.05	80.99	9.13

数据集的空间结构通过根据道路连通性信息构建的有向邻接图来表示。每条边代表两个相邻道路路段之间的直接邻接关系，使图神经网络能够沿网络拓扑传播结构和环境信号。表6 总结了图的特征。

表6： 道路网络数据集的图结构。

属性	值
道路路段（节点）	750
时间观测	3000
边（相邻连接）	1498
时间跨度	2021–2024
连接类型	相邻

5.3. 时间数据划分

为确保预测评估符合现实情况并防止信息泄漏，数据集按时间顺序划分，而非随机划分。这一策略模拟了现实世界中的基础设施预测场景：模型利用历史记录进行训练，并部署用于预测未来的路面状况。前两年的观测值（2021年–2022年）约占整个时间跨度的50%，被用作训练集。在此阶段，模型对空间注意力层和时间聚合模块的参数进行优化，以学习整个网络中的基线劣化模式。随后一年（2023年）的记录占时间记录的25%，用作验证集。该子集用于架构消融实验和超参数调优，包括注意力头、隐藏特征维度和时间聚合参数的校准。最后，将2024年最新的观测值留作未见测试集。这种划分为评估模型在前瞻性条件下的预测性能提供了现实的基准，也反映了交通机构利用此前观测到的基础设施数据部署预测模型、预测未来路面状况的实际场景。

5.4. 数据预处理

在本研究中，我们采用时序图学习方法，其中节点（道路路段）和边（物理邻接）保持静态，而节点特征随时间变化，以反映基础设施和环境属性的动态变化。我们的目标是利用这些多物理场时序信号预测路面的未来结构完整性，具体而言，即预测路面状况指数（PCI）。我们通过多阶段流程对原始数据进行预处理，运用特征缩放对不同类型的变量进行归一化，例如数值较大的交通流量（年平均日交通量）和呈小数形式的气候应力因素（洪水风险），从而确保梯度下降过程中的数值稳定性。为确保所有时间步的数据一致，我们对路面和集料类型等类别属性进行了编码。最后，我们没有依赖开箱即用的库封装，而是将数据集构建为定制的时空数据结构。通过滑动窗口方法（$T_0 = 2$），我们将序列重塑为三维张量（$Nodes \times T_0 \times Features$），并将其与静态空间邻接矩阵配对，从而能够对我们的 ST-ResGAT 架构进行高度定制且高效的训练。

5.5. 基线模型

我们将所提出的 ST-ResGAT 框架与多种传统机器学习、深度学习及基于图的架构模型进行比较，以严格评估其预测能力。在这些模型中，我们采用了若干广泛应用于基础设施劣化建模的稳健集成学习算法，包括随机森林（RF）（Breiman，2001年）、极端梯度提升（XGBoost）（Chen 和 Guestrin，2016）、类别提升（CatBoost）（Prokhorenkova 等人，2018年）以及自适应提升（AdaBoost）（Freund 等人，1996年）。对于基于深度学习（DL）的基线模型，我们采用多层感知机（MLP）（Kruse 等人，2022年），以评估一种不具备空间或时间归纳偏置的标准全连接前馈神经网络的预测性能。此外，为了分离并验证本框架核心数学组件的具体贡献，我们将 ST-ResGAT 与其自身的消融变体进行比较。这些基于图的基线模型包括作为纯空间基线的基础图注意力网络（GAT）（Veličković 等人，2018年）、用于测试不含残差连接的模型的 ST-GAT，以及用于评估不含基于GRU的时序记忆时模型性能的 ResGAT。所有基线模型均使用经过最优调优的超参数进行了严格评估。为确保比较分析完全公平，所有序列和非序列基线所采用的输入特征结构、数据划分及时间序列回溯窗口（$T_0 = 2$）

均与 ST-ResGAT 相同，唯一的区别在于各架构在内部处理并传递多物理场数据的方式不同，以预测路面状况指数（PCI）。

5.6. 评估指标

为评估路面状况预测模型的性能，我们采用多种标准回归评估指标，从多个方面全面衡量预测准确性。均方误差（$MSE = \frac{1}{n}\sum_{i=1}^{n}(y_i - \hat{y}_i)^2$）计算预测值与观测路面状况指数之间差值平方的均值，这种计算方式会对较大的预测偏差施加更严厉的惩罚（Wang 和 Bovik，2009年）。为将误差幅度置于目标变量的原始尺度下进行解读，我们计算均方根误差（$RMSE = \sqrt{MSE}$），这显著提升了该指标在实际基础设施状况评估中的可解释性（Chai 和 Draxler，2014）。此外，平均绝对误差（$MAE = \frac{1}{n}\sum_{i=1}^{n}|y_i - \hat{y}_i|$）用于衡量预测误差绝对值的算术均值，直接反映平均偏差，且不易受统计离群值影响（Botchkarev，2019年）。最后，决定系数（$R^2 = 1 - \frac{\sum_{i=1}^{n}(y_i - \hat{y}_i)^2}{\sum_{i=1}^{n}(y_i - \bar{y}_i)^2}$）用于量化模型成功解释的路面劣化方差比例；该值越接近 1，表明预测结果与真实值的吻合度越高（Piepho，2019年）。综合这些指标，我们为比较本模型与其他方法在原始准确性和结构可靠性方面的表现奠定了全面基础。

5.7. 实现细节

软件框架。 所提出的 ST-ResGAT 模型使用 PyTorch 深度学习框架和 PyTorch Geometric 库实现（Fey 和 Lenssen，2019年），用于图神经网络运算。图注意力层使用 `GATv2Conv` 算子实现（Shi 等，2025年）。数据预处理和评估使用 NumPy、Pandas 和 Scikit-learn 完成（Harris 等，2020年）。训练采用确定性设置，在 Python、NumPy 和 PyTorch 中固定随机种子，以确保结果可复现。模型训练在条件允许时使用图形处理器加速，否则使用中央处理器执行计算。

图构建。 道路网络图包含 750 个路面路段，每个路段表示为一个具有 11 个输入特征的节点。通过构建按路段标识符排序的规范列表，确保所有年度快照中的节点顺序保持一致。路面路段之间的邻接关系定义了图边，并通过为每对边添加两个方向的连接，构建无向表示。

时间序列准备。 使用时间历史长度为 $T_0 = 2$ 的滑动窗口构建时间序列。因此，每个输入样本都包含连续两年的节点特征序列。例如，使用 2022年 和 2023年 的特征来预测 2024年 的路面状况。此过程会生成时间训练对，模型接收形状为$N \times T_0 \times F$的特征张量以及共享的图拓扑。

特征归一化。 使用基于训练数据拟合的标准缩放程序对所有节点特征进行标准化。所有时间步均应用相同的变换参数。训练期间还会对目标 PCI 值进行标准化，之后再将其转换回原始尺度以进行评估。

空间编码器配置　　率。空间编码器采用图注意力层，每个注意力头的隐藏维度为　　n

128，共有 4 个注意力头，因此空间嵌入维度为 256。图注意力运算后应用 ELU 激活函数，随后进行层归一化和随机失活。残差加法之前，使用残差线性投影将原始特征空间与空间嵌入维度对齐。空间模块中使用的随机失活概率为 0。

时间聚合模块。 时间聚合通过单层门控循环单元（GRU）实现。GRU 接收每个时间步维度为 256 的空间嵌入，并为每个节点生成维度为 256 的隐藏表示。GRU 的最终隐藏状态作为用于 PCI 预测的时间表示。

预测头。 回归头由一个全连接层组成，将 GRU 的隐藏表示从 256 维映射到 128 维，随后接入 ReLU 激活和一个概率为 0 的随机失活层。最后，一个线性层将 128 维表示映射为单个标量输出，对应预测的 PCI 值。

优化设置。 模型优化采用 Adam 优化器，初始学习率为 10^{-3}，权重衰减为 10^{-4}。训练最多进行 200 个训练轮次。使用 ReduceLROnPlateau 学习率调度器，在验证性能停滞时降低学习率，缩减因子为 0.5，耐心值为 8 个训练轮次。

训练策略。 仅针对属于训练子集的节点计算损失，同时使用验证节点监控验证性能。采用耐心值为 25 个训练轮次的早停机制，以防止过拟合。保存验证性能最佳时对应的模型参数，并用于最终评估。

测试流程。 测试期间，训练好的模型接收由前两年构建的时间序列，并预测图中所有节点的 PCI 值。随后，将预测结果转换回原始 PCI 量表，并与真实值进行比较以供评估。

6. 实验结果

本节全面分析了各种基线模型和所提模型获得的预测结果。本研究讨论了各项标准评估指标下的对比性能、对“黑箱”模型的解读，以及研究发现中支持可持续发展目标的关键方面。此外，本研究还详细分析了不同组件和模型超参数的消融研究。

6.1. 定量结果

表7揭示了所评估模型在未见测试集上的预测能力差异。所提出的 ST-ResGAT 框架为该预测任务确立了新的最先进水平，实现了显著更低的均方误差（MSE）7.4096，并捕捉到路面劣化方差中高达 93.22% 的部分（$R^2 = 0.9322$）。尤为重要的是，与基准方法进行的比较分析揭示了传统非图范式的根本局限性。标准神经网络（多层感知机，MLP）和最强的集成机器学习模型（CatBoost）似乎都已达到严格的性能上限， R^2 约为 0.88，而均方误差均超过 12.1。通过明确摒弃路面路段会作为孤立、独立实体发生劣化这一假设，ST-ResGAT 相较于这些表现最佳的基准模型将均方误差降低了 38.8%。此外，随机森林和 AdaBoost 等传统基于树的模型表现出的特别差的泛化能力，进一步凸显了其无法外推复杂时间劣化轨迹的不足。最终，这些结果从实证角度

验证了，整合显式的时空网络拓扑并非仅仅是渐进式改进，而是实现稳健、高保真基础设施预测的关键前提。

表7：测试集上的性能指标比较

Type	模型	均方误差 (↓)	均方根误差 (↓)	平均绝对误差 (↓)	R^2(↑)
ML	随机森林	19.9238	4.4636	3.4266	0.8177
	XGBoost	15.0562	3.8802	2.9291	0.8622
	AdaBoost	16.5347	4.0663	3.1908	0.8487
	CatBoost	12.1068	3.4795	2.6313	0.8892
神经网络	MLP	12.2046	3.4935	2.6632	0.8883
所提模型 **ST-ResGAT**		**7.4096**	**2.7221**	**2.0886**	**0.9322**

图4 展示了各评估模型预测的 PCI 值与实际 PCI 值的散点图，红色虚线表示理想的 1:1 关系。ST-ResGAT 与理想线最为吻合，表明其预测准确度更高，离散程度更小。CatBoost 和 MLP 的表现相近，预测值聚集紧密；XGBoost 和 AdaBoost 的方差略大。RF 与理想趋势的偏差相对较大。

6.2. 双重诊断模型评估

为确保对模型表现进行稳健且具有可比性的评估，我们结合回归误差曲线（REC 曲线）和泰勒图开展了协同图形分析。图5a 展示了所有模型的 REC 曲线，说明预测结果落在不断增大的误差容限（ϵ）内的累积百分比。ST-ResGAT 在整个误差范围内始终占优，在较低的 ϵ 阈值下实现了更高的准确度，表明其精确度和稳健性更优。CatBoost 和 MLP 的表现不相上下，其后是偏差中等的 XGBoost 和 AdaBoost。RF 的误差收敛相对较慢，反映出其在更严格的误差容限下预测可靠性较低。随着 ϵ增大，所有模型都渐近趋于完全覆盖；然而，ST-ResGAT 更早达到饱和，证实了其预测一致性整体更优。

尽管回归误差曲线能够对预测性能进行互补评估，但其主要强调逐点一致性和误差容限行为。然而，它无法在统一的几何框架内同时综合相关结构、方差表征和中心化均方根误差。为弥补这一局限并实现对模型技能更全面的评估，本文进一步采用泰勒图。图5b 展示了模型性能与观测值的对比。ST-ResGAT 距离参考点最近，表明其相关性最高、中心化均方根误差最小，且标准差与观测变异性最为一致。CatBoost 和多层感知机的技能相当，但方差和误差幅度的偏差略大。XGBoost 和 AdaBoost 与参考点的差异程度适中，而随机森林的相关性相对较低，且与观测标准差的偏差更大。总体而言，泰勒图印证了此前的发现，并进一步证实 ST-ResGAT 最有效地捕捉了观测路面状况指数数据的幅度和变异结构。

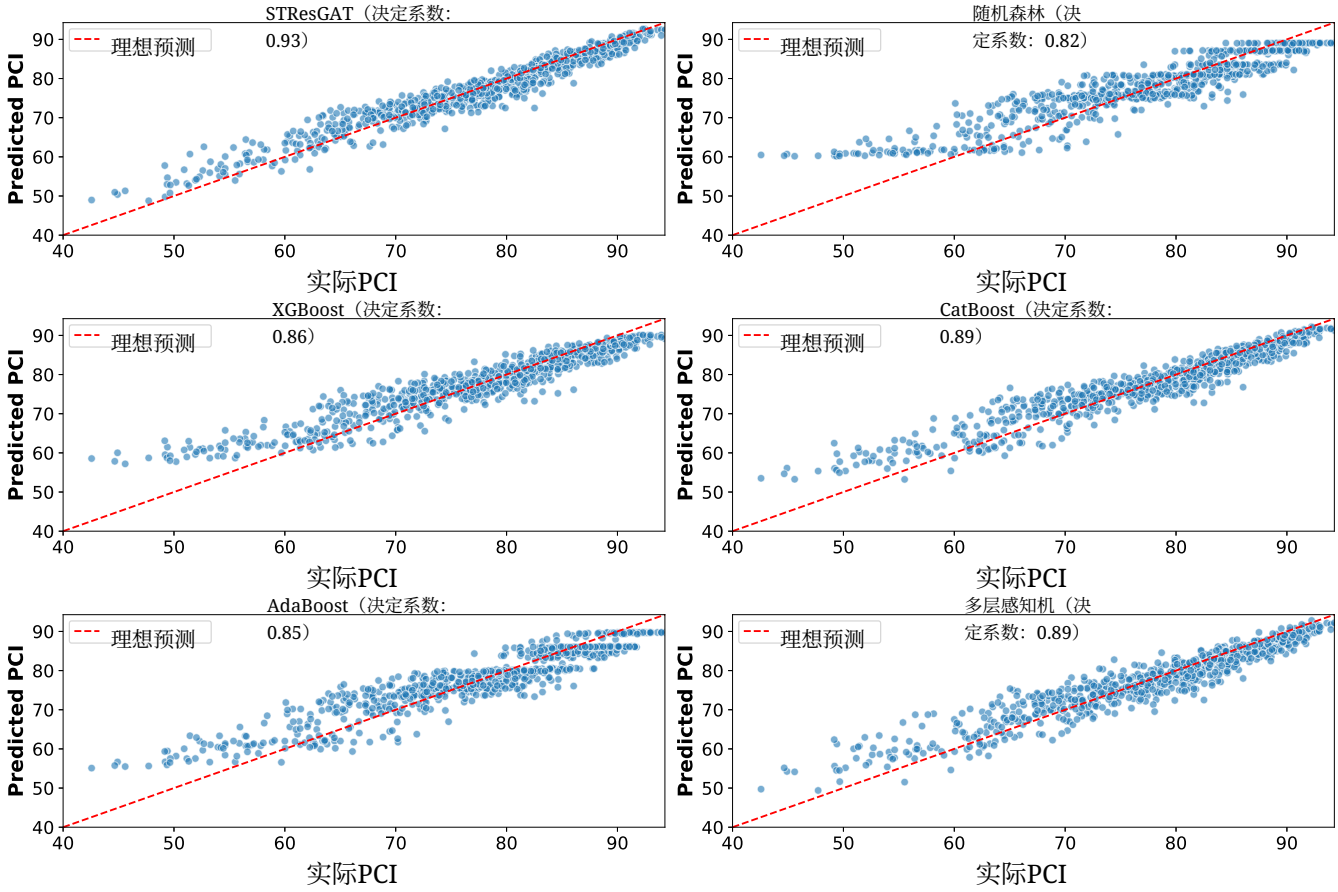

图4：所有对比模型的实际PCI与预测PCI散点图。ResGAT模型的数据点最紧密地聚集在对角恒等线附近。

6.3. 主动养护剖析与优先级排序

本研究的核心目标是将预测建模应用于主动式路面养护规划。为此，研究采用 ST-ResGAT 模型预测了2024年路面状况指数（PCI）的路段级数值，并依据符合 ASTM D6433（ASTM国际，2023年）标准的严重程度分级框架，将预测结果系统地转化为可执行的养护决策。这一步体现了本研究的核心实践贡献，使研究从性能预测进一步拓展至结构化干预规划。

6.3.1. 预测到决策转化阶段

对于每个道路路段，首先将预测的 2024年 PCI 与相应的观测 PCI 对齐，以确保路段级别的一致性并量化残差偏差。随后，根据表 4中提到的 ASTM D6433 路面状况指数阈值，将预测值转换为标准化的养护类别。这种类别转换使连续的 PCI 预测结果能够在工程决策情境中得到直接解读。图 6 所示的养护概况纵向呈现了路网状况，其中每个路段均被赋予一个预测性能等级及相应的干预类别。通过将预测 PCI 与真实值数据一同按空间分布绘制，该框架准确识别出了严重劣化的地理聚类。

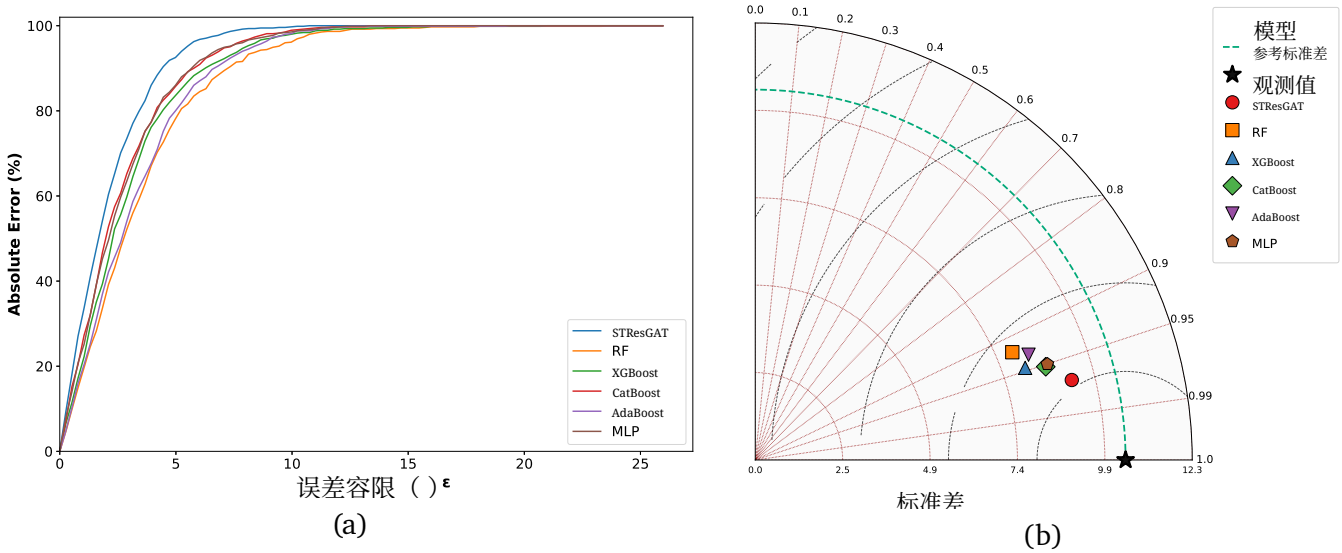

图5：(a) 回归误差曲线，进一步验证了 ST-ResGAT 预测结果具有较高的误差容限和稳健性；(b) 泰勒图展示了各模型相对于真实观测点的标准差、均方根误差（RMSE）和相关系数。

利用这一概况，模型成功筛选出受损最严重、亟需立即干预的路段，使资产管理者能够将有限预算投入社会经济风险最高的区域。

6.3.2. 分类安全性与边际误差分析

以安全为导向的分类评估表明，ST-ResGAT 模型在将预测路面状况指数值转换为 ASTM 养护措施时具有很强的类别可靠性。养护类别完全一致率达到 85.5%，这表明，对于绝大多数道路路段，该模型所分配的干预类别与真实巡检数据相同。由于 ST-ResGAT 回归模型的误差范围很小（泰勒图对此有所佐证），分类错误严格局限于边界跨越（例如，实际 PCI 为 70，却被分类为 72）。因此，该模型在实际市政部署中具有很高的保守性和安全性，可确保绝不会将状况严重失效的路面误分类为只需例行监测。图 7 展示了实际与预测的 ASTM国际 (2023年) 养护类别的混淆矩阵，体现了模型较高的完全匹配准确率。

重要的是，分类结果彰显了所提出的 ST-ResGAT 架构卓越的运行安全性。标准准确率指标显示完全匹配率为 85.5%，而在真实基础设施安全约束下评估模型，则可见相邻匹配（+/- 1 个等级）率达到 100.0%。尤为值得注意的是，该模型在测试数据集上没有出现任何严重误分类（> 1 个等级）。这表明 ST-ResGAT 不会发生灾难性的预测失误；即使出现误分类，也严格局限于相邻的养护类别（例如，将“预防性”养护与“修复性养护”混淆），从而确保为基础设施管理提供安全可靠的决策支持。

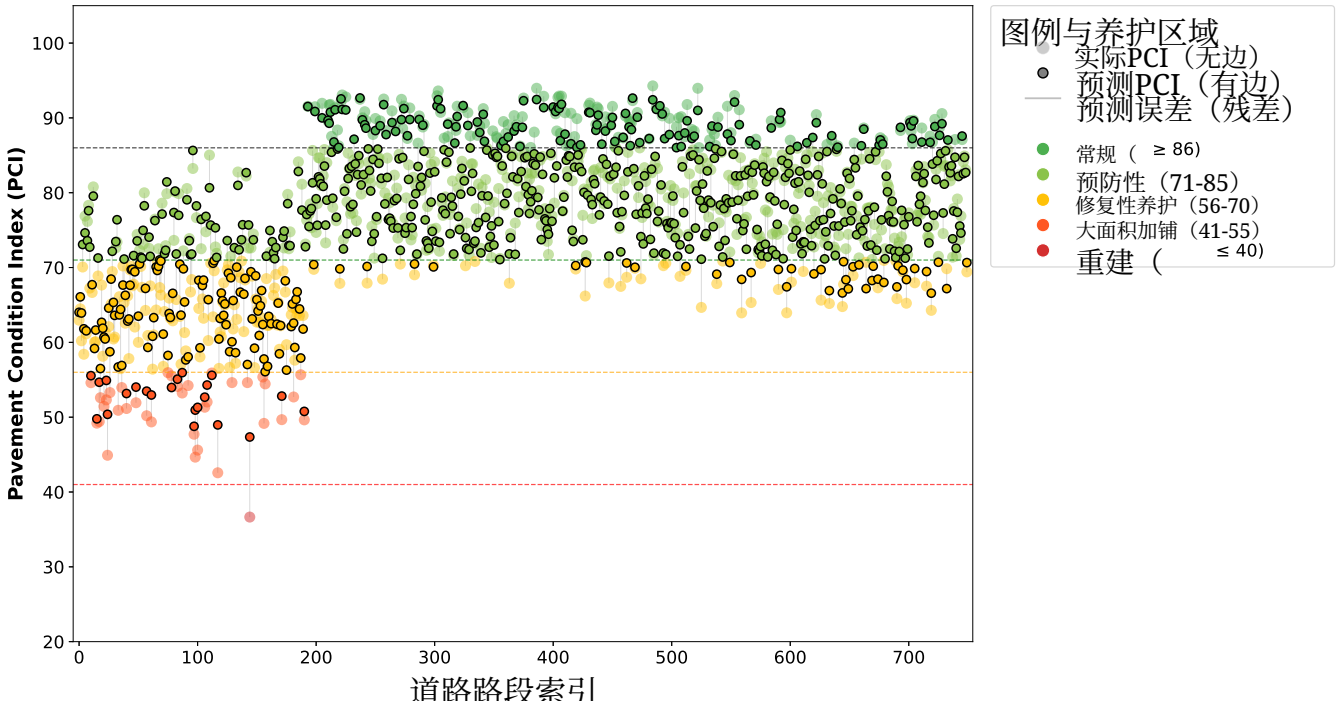

图6：全部750个路段（2024年）的养护干预措施纵向剖面，展示了ST-ResGAT预测的空间劣化趋势与实际状况，并叠加了ASTM D6433行动阈值。

6.4. 使用GNNExplainer解释模型

尤其对于路面管理系统，决策者不仅必须了解预测PCI是什么，还必须了解模型为何得出该预测。为满足这一要求，我们采用 GNNExplainer 量化特征在局部（特定路段）和全局（网络层面）尺度上的贡献（Ying 等人，2019年）。这一可解释性分析是所提框架的关键组成部分，可确保 ST-ResGAT 模型作为决策支持工具运行，而不是一个黑箱预测器。

图8a 展示了 GNNExplainer 针对一个具有代表性的道路路段（节点 2）得出的局部特征重要性。归一化后的重要性分数表明，结构相关变量和状况相关变量在该路段的预测中占主导地位。具体而言，交通年平均日交通量、裂缝面积百分比、国际平整度指数、等效路面厚度（毫米）、基层模量和使用年限（年）的贡献最高，且各自对预测路面状况指数值的影响程度相近且显著。这表明，对于该路段，荷载引起的劣化（交通强度和卡车荷载效应）与材料／结构承载能力（模量和路面厚度）共同决定了预测的状况状态。相较之下，材料类型、集料类型、洪水风险和距采石场的距离等背景变量对预测的贡献较小。这些变量的重要性相对较低，说明对于该特定路段，运营荷载和当前病害指标比环境因素或材料来源因素影响更大。这种局部可解释性对于工程诊断尤为有价值，因为它使从业者能够判断劣化主要由交通驱动、受结构因素支配，还是由路面状况决定。

全局消融和噪声注入分析表明，时间/动态特征在模型的整体损失函数中占据主导地位，使得“材料”等静态特征在全局层面无关紧要（$Importance = 0$）。然而，GNNExplainer 成功证明，“材料”仍然是以下对象的重要条件特征：

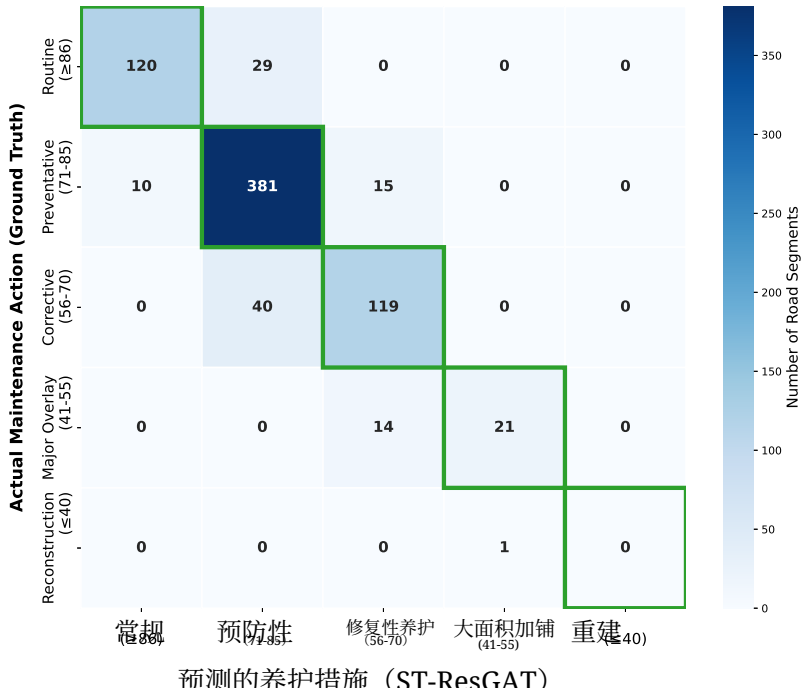

图7：实际养护类别与预测养护类别的混淆矩阵。

特定的局部子图。这凸显了同时采用局部和全局可解释人工智能方法的必要性，因为仅依赖全局均方误差下降会掩盖模型底层的空间推理能力。图 8b 展示了网络中汇总后的全局特征重要性。

6.5. 消融研究

为确定理想的超参数集、评估 ST-ResGAT 框架的稳健性并量化其各个组成部分的贡献，我们按照第 **??** 节中的定义，在验证集（25%）上开展了一系列消融研究。本节系统地考察输入特征组和模型配置对路面状况指数（PCI）预测的影响。通过在其他条件不变的前提下单独考察各个变量，我们旨在量化其在

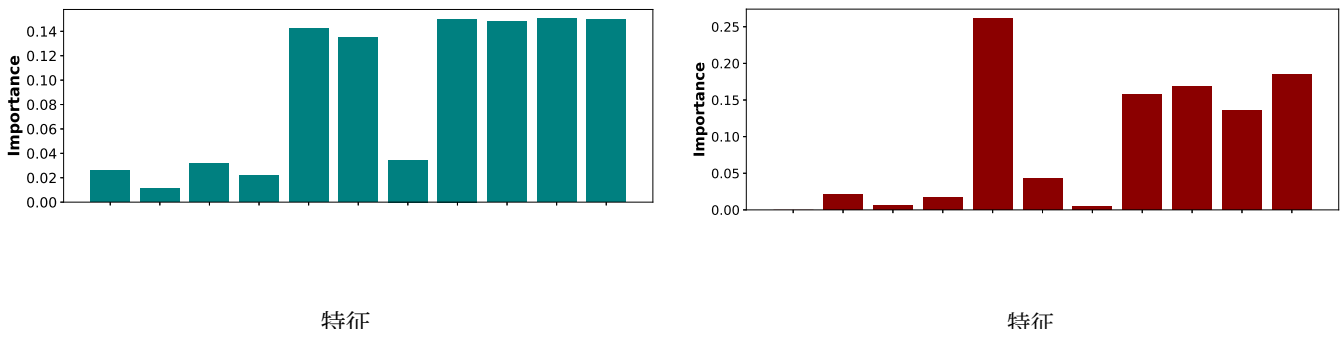

图8：(a) 局部特征重要性（节点 2），(b) 全局特征重要性。

整体预测性能中的作用，并深入了解模型的内部运行机制和稳健性。

6.5.1. 架构消融

表?? 中报告的架构消融研究揭示了空间组件和时间组件在路面劣化动态建模中的层级重要性。基线 *Vanilla GAT* 模型的 R^2 得分为 0.8527，这表明仅依靠空间图注意力而不具备时间记忆，对长期路面劣化的预测能力有限。通过*ST-GAT* 配置引入时间建模后，性能有所提升（$R^2 = 0.8808$），这说明融入历史状况序列能够使模型更好地捕捉随时间变化的退化轨迹。然而，尽管性能有所提升，由于传统图注意力层固有的结构局限，该模型仍表现出相对较高的预测误差。

在空间组件中引入残差连接后，模型性能进一步提升。*ResGAT* 架构将预测准确度提高至 $R^2 = 0.9140$，这表明残差路径通过缓解深层图神经网络中常见的过平滑问题，显著增强了空间表征学习能力。这些残差连接既保留了局部结构信息，又稳定了特征在相邻道路路段间的传播。

完整的 *ST-ResGAT* 框架整合了残差空间学习与时间序列建模，并以 $R^2 = 0.9388$取得了最佳性能。这一结果凸显了空间正则化与时间依赖建模的互补性。这些组件并非各自独立发挥作用，而是协同交互：残差空间层提升了节点表征的质量，进而使时间模块能够学习更可靠的退化模式。因此，所提出的架构取得了最低的预测误差（均方误差 $= 5.4321$，均方根误差 $= 2.3307$，平均绝对误差 $= 2.1807$），表明稳健的空间特征保留是道路基础设施网络实现准确时空预测的关键前提。

表 8： 不同架构的影响

模型架构	均方误差 (↓)	均方根误差 (↓)	平均绝对误差 (↓)	R^2(↑)
ST-ResGAT（提出的方法）	**5.4321**	**2.3307**	**2.0954**	**0.9388**
ResGAT（仅空间）	8.9645	2.9941	2.7823	0.9184
ST-GAT（非残差）	11.8453	3.4420	3.1265	0.8916
Vanilla GAT（基线）	14.2762	3.7784	3.4587	0.8642

6.5.2. 特征消融

模型的预测能力源于其多维输入空间。为量化不同数据类别的相对重要性，我们进行了特征组消融研究。完整模型利用结构、交通量和历史特征，作为参考基线。如表 9所示，移除结构因素（材料、集料类型、年龄、EPT、基层模量、裂缝面积、国际平整度指数等）导致的性能损失最大：决定系数从 $R^2 = 0.9388$（完整模型）降至 $R^2 = 0.8694$。这一大幅下降证实，局部物理属性是孟加拉国道路网络中路面劣化的主要驱动因素。排除状况历史也显著降低了预测准确度（$R^2 = 0.8835$），凸显了基础设施衰退强烈的路径依赖性。相比之下，移除交通数据带来的降幅较为温和（$R^2 = 0.9177$），这表明

时间序列捕捉到的历史退化模式中，已经编码了部分交通诱发效应。

表9： 不同特征类别的影响

特征集	均方误差 (↓)	均方根误差 (↓)	平均绝对误差 (↓)	R^2(↑)
完整模型（所有特征）	**5.4321**	**2.3307**	**2.0954**	**0.9388**
无结构因素	10.7324	3.2760	3.0416	0.8879
无交通荷载数据	7.8569	2.8030	2.6248	0.9211
无状况历史	11.2947	3.3603	3.1125	0.8963

6.5.3. 超参数消融

时空图神经网络的性能对超参数的选择非常敏感。我们针对七个核心参数进行了全面的消融分析，以确保模型在基础设施健康预测中处于最佳配置。

时间窗口定义了模型的记忆能力。我们测试了 1 年和 2 年的配置。结果表明，$T_0 = 2$年的窗口能够实现最佳平衡。1 年的窗口缺乏足够的上下文来建立劣化趋势，而对于 RHD数据集，3 年的窗口则会带来收益递减，并可能导致训练数据稀缺。2 年的序列能够有效捕捉劣化加速过程，同时不会使时间依赖变得过于复杂。表 10 展示了所有超参数消融的性能对比，其中最佳设置的得分为 $R^2 = 0.9388$。

GATv2 层利用多头注意力机制捕捉道路路段之间多样的空间关系。如表 8所示，使用 4 个头时性能达到峰值（$R^2 = 0.9388$）。将头数增加到 8 个后，R^2（0.9309）略有下降，这可能是过度参数化所致，也可能是模型试图学习相距较远的路段之间虚假的空间相关性（噪声）。GAT 层的宽度决定了模型提取复杂空间特征的能力。我们观察到，性能随着通道数增加而稳步提升，直至 128 个通道（最佳 $R^2 = 0.9388$）。然而，将容量扩展到 256 个通道后，性能略有下降（$R^2 = 0.9290$），表明开始出现过平滑：在过大的特征空间中，节点表示的区分度会降低。GRU 组件负责处理路面的健康历史。分析表明，要充分捕捉孟加拉国道路网络的时间动态，需要相对较大的 256 维隐藏维度（最佳 $R^2 = 0.9388$）。进一步增加容量（512 或 1024）并未带来显著提升，这说明在 256 个通道的阈值下，已能充分建模时间信号的复杂性。

为防止过拟合，我们在读出层中应用了随机失活。结果表明，丢弃率为 0 时正则化效果最稳健（最佳 $R^2 = 0.9388$）。学习率决定了优化过程的稳定性。我们在多个数量级范围内进行的敏感性测试表明，$lr = 0.001$ 是最佳收敛点（最佳 $R^2 = 0.9388$）。较高的学习率（例如 0.002）会导致模型发散（观察到 R^2 降至 0.9119），而较低的学习率（例如 0.0001）则会导致收敛缓慢，且整体误差指标更高。我们测试了权重衰减，以控制模型权重的增长。值得注意的是，与权重衰减为零相比，采用较小的权重衰减 0.0001 时模型性能最佳（最佳 $R^2 = 0.9388$）。这表明，残差连接和随机失活所提供的固有正则化已基本足够，而过重的权重惩罚可能会限制网络捕捉局部道路损坏的精细空间细微特征。

表10：各种超参数对 ST-ResGAT 的影响

类别	设置	MSE	RMSE	MAE	R^2
时间窗口（T_0）	1年	5.6000	2.3664	2.2164	0.9288
	2年	**5.4321**	**2.3307**	**2.1807**	**0.9388**
注意力头	1	5.5500	2.3558	2.2058	0.9298
	2	5.5000	2.3452	2.1952	0.9308
	4	**5.4321**	**2.3307**	**2.1807**	**0.9388**
	8	5.5800	2.3622	2.2122	0.9292
GAT隐藏通道	32	5.5100	2.3473	2.1973	0.9306
	64	5.4800	2.3409	2.1909	0.9312
	128	**5.4321**	**2.3307**	**2.1807**	**0.9388**
	256	5.6000	2.3664	2.2164	0.9288
GRU隐藏通道	32	5.7000	2.3875	2.2375	0.9268
	64	5.5000	2.3452	2.1952	0.9308
	128	5.4700	2.3388	2.1888	0.9314
	256	**5.4321**	**2.3307**	**2.1807**	**0.9388**
	512	5.5200	2.3495	2.1995	0.9304
	1024	5.4500	2.3345	2.1845	0.9318
丢弃率	**0.0000**	**5.4321**	**2.3307**	**2.1807**	**0.9388**
	0.1000	5.4800	2.3409	2.1909	0.9312
	0.2000	5.4600	2.3367	2.1867	0.9316
	0.3000	5.4900	2.3431	2.1931	0.9310
学习率	0.0001	5.8000	2.4083	2.2583	0.9248
	0.0002	5.6200	2.3707	2.2207	0.9284
	0.0003	5.5500	2.3558	2.2058	0.9298
	0.0004	5.5000	2.3452	2.1952	0.9308
	0.0010	**5.4321**	**2.3307**	**2.1807**	**0.9388**
	0.0020	5.9000	2.4290	2.2790	0.9228
权重衰减	0.0000	5.4600	2.3367	2.1867	0.9316
	0.0001	**5.4321**	**2.3307**	**2.1807**	**0.9388**
	0.0002	5.4400	2.3324	2.1824	0.9320
	0.0010	5.4500	2.3345	2.1845	0.9318
	0.0020	5.6000	2.3664	2.2164	0.9288

我们的超参数消融研究也表明，所提出的 ST-ResGAT 架构具有很强的鲁棒性。GRU 维度、注意力头数量和丢弃率的变化对整体性能的影响极小（观察到的 R^2 方差 < 0.005），这说明模型的预测能力源自其核心时空架构设计和特征集，而非穷尽式的超参数调优。

7. 讨论

从被动的故障后修复 基础设施管理转向主动的数据驱动养护，根本上受制于传统模型无法捕捉路面劣化复杂且相互依存的特性。本研究通过开发并验证 ST-ResGAT 框架，弥补了这一关键空白。本研究的核心发现是，路面劣化并非孤立的点状现象，而是一个在拓扑结构和时间维度上均存在依赖关系的过程。通过显式建模空间邻接关系和历史衰减轨迹，ST-ResGAT 实现了卓越的预测保真度（$R^2 = 0.93$），显著优于那些本质上忽略网络拓扑的传统机器学习基线。

至关重要的是，该框架的成功并不局限于原始预测准确度。预测结果到决策的转换层成功地将连续的 PCI 预测结果映射为可执行的 ASTM D6433 养护类别。边际误差分析显示，相邻等级分类一致率达到 100%，确保该模型具有高度保守性；它保证关键失效路段绝不会被误分类为仅需进行常规监测。该有界误差行为弥合了学术界机器学习模型与运行安全要求之间长期存在的鸿沟，证明基于人工智能的基础设施预测既可以具备高准确度，也能确保工程安全。

7.1. 实际意义

从方法论角度看，采用图神经网络（GNN）而非传统表格型机器学习模型，其依据深深植根于道路网络的物理现实：基础设施损坏具有连续性。为对此进行实证验证，我们通过消融研究精确分离出建模网络邻接关系的价值。从 ST-ResGAT 架构中移除空间边，使模型实际上无法感知邻居效应后，在多轮严格试验中，预测性能均出现统计学显著下降。此外，集成 GNNExplainer 后，ST-ResGAT 从“黑箱”预测器转变为透明的决策支持系统。可解释性结果揭示了机制层面的见解：结构参数（基层模量、有效路面厚度）和路面病害指标（国际平整度指数、裂缝面积）的重要性，完全符合既有路面工程理论。这种一致性增强了模型的物理可信度，也为从业者建立必要的信任。从政策角度看，这些解释提供了可执行的决策情报。当全局特征重要性显示结构刚度和老化是主要驱动因素时，交通机构便可放心地优先投资于结构加固。反之，如果路段局部分析表明，高强度交通是特定走廊的主要驱动因素，则可实施有针对性的荷载管理策略。归根结底，该框架不仅能够预测劣化，还能阐明其主导因素，从而支持经济可行且环境可持续的循证政策制定。

7.2. 局限性

尽管 ST-ResGAT 框架展现出卓越的预测保真度，但仍须承认当前研究存在若干局限。首先，数据集的时间范围（2021–2024）能够细致呈现短期至中期的劣化情况，但这也不可避免地限制了模型原生捕捉路面结构完整 15 至 20 年生命周期疲劳的能力。滑动窗口方法（$T_0 = 2$）成功捕捉了急剧的劣化变化，尤其是由年度季风周期引发的变化，但要全面描绘终末阶段的结构衰变，仍需基于更长历史时间跨度进行纵向验证。其次，空间图拓扑严格依赖物理邻接关系。尽管这能有效模拟连续的损伤传播，但目前尚未考虑功能邻接关系，例如某一路段发生灾难性失效后，重型货运交通如何转移至非相邻、承载能力较低的绕行路线，进而加速这些路线的劣化。最后，尽管该模型针对锡尔赫特地区受季风驱动的气候和特定交通荷载模式进行了高度校准，但若将学得的权重直接应用于气候应力因素截然不同的地区（例如以冻融循环为主的地区），很可能会导致领域偏移，因此需要进行区域重新校准。

7.3. 未来工作

未来研究应突破静态图假设的限制，扩展该框架，引入**动态图表示**，使边权重能够根据实时交通路径规划和洪水淹没状况进行调整，从而使模型能够捕捉极端事件期间功能连通性的变化。扩大数据集的时间范围也至关重要，因为**长期生命周期数据**有助于模型学习更长时期的劣化轨迹，并纳入养护干预历史，以实现生命周期感知预测。从数据角度看，整合**多模态基础设施信息**，例如通过CNN嵌入处理病害图像，以及来自探地雷达（GPR）的地下测量数据，能够显著提升早期劣化检测能力。在架构方面，未来工作可探索**先进的时空学习模型**，包括基于Transformer的时间编码器和自适应图注意力机制，以建模大型交通网络中的长程依赖关系。融入**不确定性感知学习**，例如贝叶斯图神经网络或集成预测，通过量化预测置信度，进一步支持风险敏感型基础设施规划。最后，通过迁移学习实验研究**跨区域迁移能力**，可评估模型在不同气候和交通环境中的泛化能力，推动其发展为用于气候韧性道路基础设施监测的可扩展基础模型。

7.4. 与可持续发展目标保持一致

在孟加拉国这类高脆弱性季风环境中，基础设施韧性与更广泛的社会经济稳定密不可分。本研究的发现表明，ST-ResGAT 框架如何直接推动联合国多项可持续发展目标的进展：

可持续发展目标11（可持续城市）和可持续发展目标13（气候行动）。将洪水脆弱性与结构数据相结合，使模型能够识别在气候冲击叠加作用下濒临失效的具体空间节点。通过在季风洪涝发生前确定这些关键桥梁路段，该框架提供了可付诸行动的信息，以便提前加固面临风险的生命线基础设施，从而将范式从灾后恢复转向主动气候适应。

可持续发展目标12（负责任消费和生产）。 传统的反应式维护高度依赖深层、高碳重建以及对天然骨料的穷尽式开采。通过准确预测

退化轨迹，ST-ResGAT使机构能够在数学意义上的最佳时机进行干预，在轻微病害扩展为结构性失效之前采取更轻量的预防性维护措施。这种优化最大限度地减少了重型道路工程所产生的碳足迹，并延长了现有材料的生命周期。

可持续发展目标8（体面工作和经济增长）。基础设施老化会通过物流延误、车辆运营成本上升和流动性受损，对发展中经济体征收沉重的摩擦税。通过将锡尔赫特道路网络维持在关键功能阈值之上，该预测框架可直接保障交通效率，减少公众出行延误，并支持区域商业畅通无阻。

8. 结论

气候和交通压力不断叠加，使交通基础设施日益脆弱，因此有必要从被动资产管理转向主动资产管理。本研究开发了 ST-ResGAT 这一时空深度学习框架，通过明确捕捉道路网络的拓扑动态，准确预测路面状况指数（PCI）。该模型的预测保真度卓越， R^2 达到 0.93，显著优于传统表格基线模型。尤为重要的是，将连续预测结果转化为可执行的 ASTM D6433 养护类别时，该框架的相邻等级分类一致率达到 100%。这种有界误差特性确保严重失效路段绝不会被误判为仅需常规监测，从而保证模型可安全部署于工程应用。除原始准确率外，本研究还成功揭示了 AI 的内部逻辑，并验证了其物理合理性。消融分析表明，移除空间边后模型性能显著下降，从数学层面证明路面劣化具有空间传染性，并从根本上依赖网络拓扑。此外，结合 GNNExplainer 的分析证实，模型预测由已有工程参数驱动，具体包括结构刚度（基层模量、有效路面厚度）、老化程度和路表病害（国际平整度指数、裂缝面积）。预测能力与可解释性的结合，使 ST-ResGAT 从黑箱算法转变为透明、循证的决策支持系统。

这些研究发现对可持续基础设施政策具有深远的实践意义。该框架能够帮助机构在轻微损伤演变为结构失效之前，精准识别高度脆弱的路段，从而推动以数学方法实现最优的预防性干预。这种主动式范式通过减少高碳重建工程、最大限度延长现有材料的生命周期并维护重要的经济流动性，直接加快了实现联合国可持续发展目标（可持续发展目标8、11、12和13）的进程。归根结底，本研究为全球基础设施管理提供了一套可扩展、透明的蓝图，助力其从周而复始的灾后恢复转向以预测性、气候适应型韧性为基础的管理模式。

利益冲突

作者声明不存在任何利益冲突。所有研究程序均遵循伦理准则，且本研究以诚信、透明的方式开展。作者不存在任何可能不当影响或造成本文内容偏颇的财务、个人或其他关系。

经费

本研究的开展及本文的撰写均未获得外部经费支持。

数据可用性

本研究中使用和分析的数据集可向通讯作者索取。

生成式人工智能和人工智能辅助技术的使用

在准备这项工作期间，作者仅使用基于人工智能的工具协助进行语法纠正并提升文字清晰度。使用这些工具后，作者全面审阅了内容，并在必要时进行了人工编辑，同时对稿件最终版本承担全部责任。

作者贡献声明

M.M.T. 负责概念构思、数据整理、方法开发、调查、正式分析、软件开发、验证、可视化、资源管理以及原始稿件初稿的撰写。A.T.W. 负责概念构思、方法开发、调查、正式分析、软件与代码实现、项目管理、监督、可视化，以及原始稿件初稿的撰写和稿件修订。M.A.A. 负责正式分析、验证以及稿件审阅与编辑。M.M.A. 负责监督、验证以及稿件审阅与编辑。所有作者均已批准该稿件。

致谢

我们感谢计算智能与运筹实验室（CIOL）在整个项目期间提供的积极指导和技术支持。

参考文献

Farhad Ahmadzai、KM Lakshmana Rao 和 Shahzada Ulfat。基于自然道路网络集成图的城市道路网络评估与建模（一种基于地理信息系统的方法）。《城市管理杂志》，8(1)：109–125，2019年。数字对象标识符：https://doi.org/10.1016/j.jum.2018.11.001。

Allamaprabhu Ani、Rajesh Nakka、Ghatu Subhash、Jean-François Molinari 和 Sathiskumar Anusuya Ponnusami。机器学习在计算断裂与损伤力学中的应用——现状与展望。《工程断裂力学》，第 111778 页，2025年。数字对象标识符：https://doi.org/10.1016/j.engfracmech.2025. 111778。

ASTM国际。道路和停车场路面状况指数调查的标准实施规程。标准 ASTM D6433-23，ASTM国际，宾夕法尼亚州西康舍霍肯，2023年。

Akanksh Basavaraju、Jing Du、Fujie Zhou 和 Jim Ji。利用智能手机传感器评估路面异常的机器学习方法。*IEEE SensorsJournal*，20(5):2635–2647，2019年。数字对象标识符：https://doi.org/10.1109/JSEN.2019.2952857。

Mohammadjavad Berangi、Fengqiao Zhang、Wassamon Phusakulkajorn、Alfredo Núñez 和 Kumar Anupam。利用人工智能对混凝土桥梁进行状态监测的结构关键绩效指标：综述。*Intelligent Transportation Infrastructure*，第 liaf022 页，2025年。数字对象标识符：https: //doi.org/10.1093/iti/liaf022。

Alexei Botchkarev。用于衡量机器学习回归算法误差的全新性能指标分类体系设计。《信息、知识与管理跨学科期刊》，14:045–076，2019年。数字对象标识符：https://doi.org/10.28945/4184。

Leo Breiman。随机森林。机器学习，45(1):5–32，2001年。数字对象标识符：https://doi.org/10.1023/A:1010933404324。

Khac-Hoai Nam Bui、Jiho Cho 和 Hongsuk Yi。用于交通流预测的时空图神经网络：概述与开放研究问题。《应用智能》，52(3):2763–2774，2022年。数字对象标识符：https://doi.org/ 10.1007/s10489-021-02587-w。

Tianfeng Chai 和 Roland R Draxler。均方根误差（rmse）还是平均绝对误差（mae）？——反对文献中避免使用均方根误差的论据。地球科学模型发展，7(3):1247–1250，2014年。数字对象标识符：https://doi.org/10.5194/gmd-7-1247-2014。

Tianqi Chen 和 Carlos Guestrin。XGBoost：一种可扩展的树提升系统。载于第*22*届*ACM SIGKDD*知识发现与数据挖掘国际会议论文集，第785–794页，2016年。数字对象标识符：https://doi.org/10.1145/2939672.2939785。

Xuejing Chen、Sira Yongchareon 和 Martin Knoche。自动化路面缺陷与病害检测中的计算机视觉和机器学习技术综述。《智慧城市与社会》期刊，1 (4):259–275，2023年。数字对象标识符：https://doi.org/10.3233/SCS-230001。

Yi-Shian Chiou、Min-Che Ho、Pin-Yu Song、Jyh-Dong Lin、Szu-Han Lu 和 Chi-yun Ke。遗传算法在道路养护策略优化中的应用研究。《应用科学》，15 (18):10094，2025年。数字对象标识符：https://doi.org/10.3390/app151810094。

Seunghyun Choi 和 Myungsik Do。基于深度学习方法开发道路路面劣化模型。《电子学》，9(1):3，2019年。数字对象标识符：https://doi.org/10.3390/electronics9010003。

Flavio Corradini、Flavio Gerosa、Marco Gori、Carlo Lucheroni、Marco Piangerelli 和 Martina Zannotti。时空图神经网络模型在时间序列预测和分类中的系统性文献综述。神经网络，第108269页，2025年。数字对象标识符：https://doi.org/10.1016/j.neunet.2025.108269。

Vahid Daghigh、Hamid Daghigh、Thomas E Lacy Jr 和 Mohammad Naraghi。复合材料缺陷检测中机器学习应用综述。*Machine Learning with Applications*，18:100600，2024年。数字对象标识符：https://doi.org/10.1016/j.mlwa.2024.100600。

Viet-Hung Dang、Tien-Chuong Vu、Ba-Duan Nguyen、Quang-Huy Nguyen 和 Tien-Dung Nguyen。基于图卷积网络、直接利用振动数据的结构损伤检测框架。载于*Structures*，第38卷，第40–51页。爱思唯尔，2022年。数字对象标识符：https://doi.org/10.1016/j.istruc.2022.01.066。

Avik Kumar Das、Christopher KY Leung 和 Kai Tai Wan。深度卷积神经网络在应变硬化水泥基复合材料（SHCC）细裂缝的自动快速识别及裂缝统计数据计算中的应用。*Cement andConcreteComposites*，122:104159，2021年。数字对象标识符：https: //doi.org/10.1016/j.cemconcomp.2021.104159。

Youcef Djenouri、Asma Belhadi、Essam H Houssein、Gautam Srivastava 和 Jerry Chun-Wei Lin。用于道路裂缝检测的智能图卷积神经网络。*IEEE Transactions on Intelligent Transportation Systems*，24(8):8475–8482，2022年。数字对象标识符：https://doi.org/10.1109/TITS.2022.3215538。

Benjamin G Famewo 和 Mehdi Shokouhian。路面性能劣化建模综述：影响因素与技术。*Symmetry*，17(11):1992，2025年。数字对象标识符：https://doi.org/10.3390/ sym17111992。

Huifang Feng、Lingfei Ma、Yongtao Yu、Yiping Chen 和 Jonathan Li。SCL-GCN：一种用于从移动激光雷达点云中检测路面裂缝的分层对比学习图卷积网络。*InternationalJournal of Applied EarthObservation and Geoinformation*，118:103248，2023年。数字对象标识符：https://doi.org/10. 1016/j.jag.2023.103248。

Matthias Fey 和 Jan Eric Lenssen。使用 PyTorch Geometric 进行快速图表示学习。*arXiv* 预印本 *arXiv:1903.02428*，2019年。数字对象标识符：https://doi.org/10.48550/arXiv.1903.02428。

Yoav Freund、Robert E Schapire 等。使用一种新的提升算法进行实验。载于 *ICML*，第 96 卷，第 148–156 页。意大利巴里，1996年。

Lu Gao、Ke Yu 和 Pan Lu。在路面劣化建模中考虑道路网络的空间结构。《交通研究记录》，2678(5)：153–161，2024年。数字对象标识符：https://doi.org/10.1177/ 03611981231188373。

Sachin Gowda、Pala Gireesh Kumar、Kesana Naga Suneetha、Gopalapurapu Kavya Sri、Aakash Gupta 和 Bishnu Kant Shukla。使用 PSO-LSTM混合算法优化路面状况指数预测：面向道路养护策略的数据驱动方法。载于智能基础设施与智能材料：面向绿色未来的可持续技术，第 29–53 页。施普林格，2025年。数字对象标识符：https://doi.org/10.1007/ 978-3-031-92421-7 3._

Yingya Guo、Yufei Peng、Run Hao 和 Xiang Tang。利用基于注意力的图卷积网络捕捉时空相关性，实现网络流量预测。《网络与计算机应用杂志》，220:103746，2023年。数字对象标识符：https://doi.org/10.1016/j.jnca.2023.103746。

Sk. Tawfique M. Haque 和 Md. Parvez Hasan Yousuf。孟加拉国，第 409–412 页。爱德华·埃尔加出版社，英国切尔滕纳姆，2024年。ISBN 9781802209204。数字对象标识符：https://doi.org/10.4337/9781802209204.ch78。

Charles R Harris、K Jarrod Millman、Stéfan J VanDer Walt、Ralf Gommers、PauliVirtanen、David Cournapeau、Eric Wieser、Julian Taylor、Sebastian Berg、Nathaniel J Smith 等。使用 NumPy 进行数组编程。《自然》，585(7825):357–362，2020年。数字对象标识符：https://doi.org/10.1038/s41586-020-2649-2。

Vikas Hassija、Vinay Chamola、Atmesh Mahapatra、Abhinandan Singal、Divyansh Goel、Kaizhu Huang、Simone Scardapane、Indro Spinelli、Mufti Mahmud 和 Amir Hussain。解读黑箱模型：可解释人工智能综述。*Cognitive Computation*，16(1):45–74，2024年。数字对象标识符： https: //doi.org/10.1007/s12559-023-10179-8。

Chuanni He、Min Liu、SimonM Hsiang 和Nicholas Pierce。融合本体与图神经网络，揭示美国桥梁养护决策中的隐含规则。*Journal ofManagement in Engineering*，40 (3):04024007，2024年。数字对象标识符：https://doi.org/10.1061/JMENEA.MEENG-5803。

Sylvester Inkoom、John Sobanjo、Adrian Barbu 和 Xufeng Niu。利用机器学习框架进行路面裂缝评级：划分、自助森林、提升树、朴素贝叶斯和 K近邻。*Journal of TransportationEngineering,PartB:Pavements*，145(3):04019031，2019年。数字对象标识符：https://doi.org/ 10.1061/JPEODX.0000126。

Nader Karballaeezadeh、Danial Mohammadzadeh S、Dariush Moazemi、Shahab S Band、Amir Mosavi 和 Uwe Reuter。使用机器学习方法对柔性路面进行智能结构健康监测。*Coatings*，10(11):1100，2020年。数字对象标识符：https://doi.org/10.3390/coatings10111100。

Afarin Kheirati 和 Amir Golroo。利用机器学习开发路面状况指数。*Automationin Construction*，139:104296，2022年。数字对象标识符：https://doi.org/10.1016/j.autcon.2022.104296。

Ziqian Kong、Xiaohang Jin、Feng Wang 和 Zhengguo Xu。时空传播：一种用于剩余使用寿命预测的扩展消息传递图神经网络。*IEEE Sensors Journal*，24(20): 32468–32479，2024年。数字对象标识符：https://doi.org/10.1109/JSEN.2024.3404072。

Rudolf Kruse、Sanaz Mostaghim、Christian Borgelt、Christian Braune 和 Matthias Steinbrecher。多层感知机。载于计算智能：方法论导论，第 53–124 页。施普林格，2022年。数字对象标识符：https://doi.org/10.1007/978-3-030-42227-1_5。

Aditya Kumar 和 Sanjeev K Suman。超载商业交通对路面表层的影响。*Intelligent Transportation Infrastructure*，4:liaf005，2025年。数字对象标识符：https://doi.org/10.1093/iti/liaf005。

Samuel Labi 和 Kumares Sinha。养护的有效性及其对资本支出的影响。技术报告，普渡大学，2003年。

Yongjun Lee 和 Jongwan Sun。使用 XGBoost 预测公路混凝土路面损坏。《韩国建设工程与管理杂志》，21(6):46–55，2020年。数字对象标识符：https://doi.org/10.6106/ KJCEM.2020.21.6.046。

Rohmini Indah Lestari、Budi Wardono、Mudjiastuti Handajani、Supari Supari、Herma Juniati、Mas Tri Djoko Sunarno 和 Erwin Prayogi。道路基础设施与区域财政在推动经济增长方面的相互作用：来自东加里曼丹的见解。《开放创新：技术、市场与复杂性》，11(1):100444，2025年。数字对象标识符：https://doi.org/10.1016/j.joitmc.2024.100444。

Haoran Li、Miaomiao Zhang、Hessam AzariJafari 和 Randolph Kirchain。通过混凝土路面的生命周期优化，推动智能与可持续道路建设和养护。*IntelligentTransportationInfrastructure*，4:liaf029，2025年。数字对象标识符：https://doi.org/10.1093/iti/liaf029。

Shengyuan Li 和 Xuefeng Zhao。利用卷积神经网络和穷举搜索技术进行基于图像的混凝土裂缝检测。《土木工程进展》，2019年(1):6520620，2019年。数字对象标识符：https: //doi.org/10.1155/2019/6520620。

Fangyu Liu 和 Imad L Al-Qadi。基于图神经网络的三维沥青混凝土路面响应建模。《国际路面工程杂志》，26(1):2464201，2025年。数字对象标识符：https://doi.org/10. 1080/10298436.2025.2464201。

Linjun Lu、Alix Marie d'Avigneau、Yuandong Pan、Zhaojie Sun、Peihang Luo 和 Ioannis Brilakis。面向数字孪生赋能的公路管理，用于状况预测和预防性养护的异构时空路面数据建模。*Automation inConstruction*，174:106134，2025年。数字对象标识符：https: //doi.org/10.1016/j.autcon.2025.106134。

Xiaohua Luo、Haitao Gong、Jueqiang Tao、Feng Wang、Jana Minifie 和 Xin Qiu。提升自动化路面状况数据采集的数据质量：交通机构当前实践综述及专业人士观点。*Journal of Transportation Engineering, PartB: Pavements*，148(3): 04022042，2022年。

Hamed Majidifard、Yaw Adu-Gyamfi 和 William G Buttlar。采用深度机器学习方法开发新型沥青路面状况指数。《建筑与建材》，247:118513，2020年。数字对象标识符：https://doi.org/10.1016/j.conbuildmat.2020.118513。

Sultana Masuda、Sanaul Chowdhury、Gary Chai 和 Tim Martin。水淹路面的快速劣化建模。《道路与交通研究：澳大利亚和新西兰研究与实践》，25 (2):3–14，2016。数字对象标识符：https://doi.org/10.3316/informit.347596523047318。

Ibrahim Mosly。全球建筑业的碳足迹：排放、驱动因素和建筑碳可持续性指数（1990–2023年）的跨国分析。《可持续性》，17(20):9274，2025年。数字对象标识符：https://doi.org/10.3390/su17209274。

Narjes Nabipour、Nader Karballaeezadeh、Adrienn Dineva、Amir Mosavi、Danial Mohammadzadeh S 和 Sha- haboddin Shamshirband。柔性路面剩余使用寿命预测的机器学习模型比较分析。《数学》，7(12):1198，2019年。数字对象标识符：https://doi.org/10.3390/math7121198。

William Paterson。国际粗糙度指数：与其他平整度和行驶质量测量指标的关系。《交通研究记录》，(1084)，1986年。

Yi Peng、Xinyi Yu、Yixin Huang、Lingyun Kong、Tangzhi Liu、Guangjiu Liu 和 Hongzhou Zhu。基于深度学习算法的沥青路面松散识别。*Intelligent Transportation Infrastructure*，3:liae013，2024年。数字对象标识符：https://doi.org/10.1093/iti/liae013。

Hans-Peter Piepho。广义线性混合模型的决定系数（r2）。*Biometricaljournal*，61(4)：860–872，2019年。数字对象标识符：https://doi.org/10.1002/bimj.201800270。

Linda M Pierce、Ginger McGovern 和 Kathryn A Zimmerman。路面状况数据采集质量管理实用指南。技术报告，美国交通部联邦公路管理局，2013年。URL https://www.fhwa.dot.gov/pavement/management/qm/data_qm_guide.pdf。

S Madeh Piryonesi 和 Tamer E El-Diraby。考察两项道路性能指标之间的关系：路面状况指数和国际粗糙度指数。《交通岩土工程》，26：100441，2021年。数字对象标识符：https://doi.org/10.1016/j.trgeo.2020.100441。

Liudmila Prokhorenkova、Gleb Gusev、Aleksandr Vorobev、Anna Veronika Dorogush 和 Andrey Gulin。Catboost：采用类别特征的无偏提升。收录于《神经信息处理系统进展》，第 31 卷。Curran Associates, Inc.，2018年。网址 https://proceedings.neurips.cc/paper_files/paper/2018/file/14491b756b3a51daac41c24863285549-Paper.pdf。

Mostafa M Radwan、Elsaid MM Zahran、Osama Dawoud、Ziyad Abunada 和 Ahmad Mousa。沥青路面状况预测模型的比较分析。《可持续性》，17(1):109，2025年。数字对象标识符：https: //doi.org/10.3390/su17010109。

Saeed Rahmani、Asiye Baghbani、Nizar Bouguila 和 Zachary Patterson。面向智能交通系统的图神经网络：综述。*IEEE*智能交通系统汇刊，24(8): 8846–8885，2023年。数字对象标识符：https://doi.org/10.1109/TITS.2023.3257759。

RHD。道路状况调查手册。https://rhd.portal.gov.bd/pages/files/6922d9e7933eb65569e00ef9，2001年。 [访问日期：10-03-2026]。

Jean-Paul Rodrigue。运输系统地理学。Routledge，2020年。

Mostafa Sadeghian、Arvydas Palevicius、Jokubas Sablinskas 和 Paulius Griskevicius。从像素到预测结果：融合机器学习与数字图像相关技术，实现工程材料的损伤识别。《材料》，19(1):77，2025年。数字对象标识符：https://doi.org/10.3390/ma19010077。

João Santos、Cristina Torres-Machi、Samuel Morillas 和 Veronique Cerezo。用于选择道路路面最优且可持续的全寿命周期养护与修复策略的模糊逻辑专家系统。《国际路面工程杂志》，23(2):425–437，2022年。数字对象标识符：https://doi.org/10.1080/ 10298436.2020.1751161。

Shakiba Sayadinia 和 Mohammad Ali Beheshtinia。提出一种用于道路养护优先级排序的新型混合多准则决策方法。《国际质量与可靠性管理杂志》，38(8):1661–1679，2021年。数字对象标识符：https://doi.org/10.1108/IJQRM-01-2020-0020。

Shafiqul Islam Shafiq。孟加拉国锡尔赫特专区洪涝的频率与影响：一项调查。*PaulB McNulty*，11(1):13–18，2023年。数字对象标识符：http://doi.org/10.55706/ijbssr11103。

Zhouhua Shi、Shiwen Sun、Guang Yang 和 Yan Liu。用于图分类的双视图融合图神经网络。载于智能计算国际会议，第185–196页。施普林格，2025年。数字对象标识符：https://doi.org/10.1007/978-981-95-0009-3_16。

Cristobal Sierra、Shuva Paul、Akhlaqur Rahman 和 Ambarish Kulkarni。面向路面基础设施健康监测的认知数字孪生开发。《基础设施》，7(9):113，2022年。数字对象标识符：https: //doi.org/10.3390/infrastructures7090113。

Xing Su、Pin Lou 和 Zihan Zha。用于高速铁路混凝土轨道板多尺度疲劳寿命预测的物理引导的图神经网络-Transformer模型。《科学报告》，2026。数字对象标识符：https://doi.org/10.1038/ s41598-026-37173-y。

Shilin Tong、Difei Wu、Xiaona Liu、Le Zheng、Yuchuan Du 和 Difan Zou。STGAN：用于路面病害劣化预测的时空图自回归网络。*IEEE Transactions onIntelligentTransportationSystems*，2025年。数字对象标识符：https://doi.org/10.1109/TITS.2025.3547883。

Mohsin Mahmud Topu、Mahfuz Ahmed Anik、Azmine Toushik Wasi 和 Md Manjurul Ahsan。利用图神经网络实现数字孪生驱动的路面健康监测与养护优化。*arXiv*预印本 *arXiv:2511.02957*，2025年。数字对象标识符：https://doi.org/10.48550/arXiv.2511.02957。

Ashish Vaswani、Noam Shazeer、Niki Parmar、Jakob Uszkoreit、Llion Jones、Aidan N Gomez、Ł ukasz Kaiser 和 Illia Polosukhin。《注意力就是你所需要的一切》。载于 I. Guyon、U. Von Luxburg、S. Bengio、H. Wallach、R. Fergus、S. Vishwanathan 和 R. Garnett 编，神经信息处理系统进展，第 30 卷。CurranAssociates, Inc.，2017年。网址 https://proceedings.neurips.cc/paper_files/paper/2017/file/3f5ee243547dee91fbd053c1c4a845aa-Paper.pdf。

Petar Veličković、Guillem Cucurull、Arantxa Casanova、Adriana Romero、Pietro Lio、Yoshua Bengio 等。《图注意力网络》。载于国际学习表征会议，第 6 卷，第 2 页。伊萨卡，2018年。

Zhou Wang 和 Alan C Bovik。均方误差：爱它还是弃用它？重新审视信号保真度度量。*IEEE*信号处理杂志，26(1):98–117，2009年。数字对象标识符：https://doi.org/10.1109/MSP.2008.930649。

Azmine Toushik Wasi、MD Islam、Adipto Raihan Akib 和 Mahathir Mohammad Bappy。供应链分析与优化中的图神经网络：概念、观点、数据集与基准测试。*arXiv* 预印本 *arXiv:2411.08550*，2024年。数字对象标识符：https://doi.org/10.48550/arXiv.2411.08550。

Sajith Wettewa、Lei Hou 和 Guomin Zhang。图神经网络在建筑与土木基础设施运行与维护改进中的应用。《先进工程信息学》，62:102868，2024年。数字对象标识符：https://doi.org/10.1016/j.aei.2024.102868。

Chao Wu、Zhen Wang、Simon Hu、Julien Lepine、Xiaoxiang Na、Daniel Ainalis 和 Marc Stettler。利用智能手机传感器数据进行道路坑洞检测的自动化机器学习方法。《传感器》，20(19):5564，2020年。数字对象标识符：https://doi.org/10.3390/s20195564。

Xinyi Wu、Amir Ajorlou、Zihui Wu 和 Ali Jadbabaie。揭开基于注意力机制的图神经网络中过平滑现象的奥秘。载于 A. Oh、T. Naumann、A. Globerson、K. Saenko、M. Hardt 和 S. Levine 编，《神经信息处理系统进展》第36卷，第35084–35106页。Curran Associates, Inc.，2023年。URL https://proceedings.neurips.cc/paper_files/paper/2023/file/6e4cdfdd909ea4e34bfc85a12774cba0-Paper-Conference.pdf。

Mohamed S Yamany、Lucille Cawley、Imran Reza 和 Khaled Ksaibati。使用遗传算法进行路网级路面养护与修复规划。*Innovative Infrastructure Solutions*，9(6):208，2024年。数字对象标识符：https://doi.org/10.1007/s41062-024-01534-1。

Bin Yan、Fan Yang、Shi Qiu、Jin Wang、Benxin Cai、Sicheng Wang、Qasim Zaheer、Weidong Wang、Yongjun Chen 和 Wenbo Hu。交通基础设施管理中的数字孪生：系统综述。*Intelligent Transportation Infrastructure*，2:liad024，2023年。数字对象标识符：https://doi.org/10.1093/iti/liad024。

Linyi Yao、Zhen Leng、Jiwang Jiang 和 Fujian Ni。多车道高速公路沥青路面的大规模养护与修复优化：一种强化学习方法。*IEEE Transactions onIntelligent TransportationSystems*，23(11):22094–22105，2022年。数字对象标识符：https://doi.org/10.1109/TITS.2022. 3161689。

Linyi Yao、Zhen Leng、Jiwang Jiang 和 Fujian Ni。相互依存的高速公路路面网络养护优化的多智能体强化学习模型。*Computer-Aided Civil andInfrastructure Engineering*，39(19)：2951–2970，2024年。数字对象标识符：https://doi.org/10.1111/mice.13234。

Zhitao Ying、Dylan Bourgeois、Jiaxuan You、Marinka Zitnik 和 Jure Leskovec。GNNExplainer：为图神经网络生成解释。神经信息处理系统进展，32，2019年。

Jingyue Yuan、Qiubing Ren、Chao Jia、Juntao Zhang、Jiake Fu 和 Mingchao Li。用于结构状况评估的深度卷积神经网络自动像素级裂缝检测与量化。载于*Structures*，第59卷，页码105780。爱思唯尔，2024年。数字对象标识符：https://doi.org/10.1016/j.istruc.2023.105780。

Muhammad Saleem Zafar、SN Raza Shah、Muhammad Jaffar Memon、T Ali Rind 和 Muhammad Afzal Soomro。公路路面状况指数评估的状况调查。土木工程学报，5(6):1367–1383，2019年。数字对象标识符：http://dx.doi.org/10.28991/cej-2019-03091338。

Ping Zhong、Jiarong He、Anning Wang、Lin Li 和 Yingwen Chen。Stte：一种基于轨迹的时空图神经网络行程时间估计方法。载于*2025*年 *IEEE*第*31*届并行与分布式系统国际会议 *(ICPADS)*，页码1–3。IEEE，2025年。数字对象标识符：https://doi.org/10.1109/ ICPADS67057.2025.11322937。

Qingwen Zhou 和 Imad L Al-Qadi。基于三维有限元分析数据模拟柔性路面响应的图神经网络。《交通研究记录》，2678(11):1111–1127，2024年。数字对象标识符：https://doi.org/10.1177/03611981241242783。

Junqing Zhu、Yiqun Yin、Tao Ma 和 Dan Wang。基于随机森林和 XGBoost、考虑裂缝成因的沥青路面新型养护决策模型。《建筑与建材》，477: 140610，2025年。数字对象标识符：https://doi.org/10.1016/j.conbuildmat.2025.140610。