同济大学
TONGJI UNIVERSITY

硕士学位论文

(专业学位)

基于数物双驱异构双图神经网络的结构损伤定位研究

姓名：颜子茗

学号：2330645

学院：土木工程学院

学科门类：工学

专业学位类别：土木水利

专业领域：土木工程

研究方向：防灾减灾工程及防护工程

指导教师：唐和生

二〇二六年六月

同济大学
TONGJI UNIVERSITY

A thesis submitted to
Tongji University inconformity with the requirements for
The degree of Master of Engineering

Structural Damage Localization Based on a Data–Physics Dual-Driven Heterogeneous Dual-Graph Neural Network

Candidate: Yan ZiMing

Student Number:2330645

School/Department: College of Civil Engineering

Categories: Engineering

Professional Degree Categories:

Civiland Hydraulic Engineering

Major: Civil Engineering

Research Fields: Disaster Mitigation for Structures

Supervisor: Tang HeSheng

May,2026

基于数物双驱异构双图神经网络的结构损伤定位研究

颜子茗　　同济大学

摘要

结构健康监测是保障重大土木基础设施服役安全的核心技术。在实际工程中，实测数据难以覆盖结构从健康到破坏的全生命周期状态，尤其是严重损伤状态的数据极为匮乏局限。真实结构受损数据采集难度大、标注成本高、样本稀缺等。导致基于大数据驱动的机器学习损伤识别在实际应用中仍面临巨大挑战。基于此，本课题研究一种基于高保真传感器数据与仿真数据融合的图神经网络结构损伤定位方法。该方法旨在整合物理传感器采集的真实响应数据与数值仿真生成的理论数据，通过异构双图神经网络多模态学习模型实现传感器观测数据与结构物理之间的特征融合、挖掘跨域数据的共性特征，从而提升损伤定位的准确性、鲁棒性与泛化能力。主要研究工作如下：

（1）提出一种数物双驱异构双图神经网络的结构损伤定位方法。该方法由结构物理图网络与动态传感器图网络构成，前者用于表征结构节点、构件连接、模态特征和刚度等物理信息先验，后者用于刻画传感器响应数据之间动态相关性特征。通过多模态学习交叉注意力机制实现物理和数据的特征融合，动态建模不同模态特征间的依赖关系，实现信息互补，提升了模型的性能和泛化能力。数值模拟实验表明，相较于传传统方法，所提方法表现出更精确的损伤定位能力。

（2）探索数物双驱异构双图神经网络损伤定位方法的鲁棒和泛化性能。以框架结构与桁架结构两种不同结构为研究对象，分析在传感器随机失效情况下的损伤定位能力。结果显示当部分测点信息缺失时，该方法仍能依托结构物理图提供的拓扑先验进行信息补偿，相较于其他方法，表现出更稳定的损伤定位性能。通过传感器随机失效试验表明，该方法在融合多模态学习交叉注意力机制、异构图建模的前提下，具备较强的鲁棒性与泛化潜力，尤其在数据稀缺、传感器失效扰动复杂的工程场景中表现突出。

（3）基于迁移学习增强的异构双图神经网络损伤定位方法及实验验证

为了解决实际结构样本稀缺问题，建立一种迁移学习增强的异构双图神经网络损伤定位方法。该方法结合迁移学习增强策略，实现模型高效训练与跨域知识迁移，并通过域对齐约束减小仿真（源域）与真实（目标域）特征分布差异，从而完成仿真数据与高保真传感器数据融合，提升模型泛化能力与可靠性。为了验证所提方法的有效性，通过一实际钢框架结构损伤识别试验验证，结果表明，该方法能够在真实受损标签不参与网络训练的条件下提升损伤定位性能。

关键词：结构健康监测，损伤定位，迁移学习，图神经网络，异构双图网络。

ABSTRACT

Structural Health Monitoring is a key technology for ensuring the service safety of major civil infrastructure. In practical engineering applications, measured data are usually unable to cover the full range of structural states from the intact condition to failure, and data associated with severe damage states are particularly scarce. The acquisition of real damaged-state data is difficult, costly to label, and limited in sample size, which poses a major challenge to data-driven machine learning methods for structural damage identification. To address this issue, this study investigates a graph-neural-network-based structural damage localization method that integrates high-fidelity sensor measurements with numerical simulation data. The proposed method aims to combine real structural response data collected by physical sensors with simulation-derived theoretical data, and to achieve feature fusion between sensor observations and structural physical information through a multimodal heterogeneous dual-graph neural network. By extracting shared damage-sensitive representations across domains, the method improves the accuracy, robustness, and generalization capability of structural damage localization. The main research work is summarized as follows.

(1) A data–physics dual-driven heterogeneous dual-graph neural network is proposed for structural damage localization. The proposed method consists of a physical structure graph network and a dynamic sensor graph network. The former represents physical priors such as structural nodes, member connectivity, modal characteristics, and stiffness-related information, whereas the latter characterizes the dynamic correlations among sensor response data. A multimodal cross-attention mechanism is introduced to fuse physical information and data-driven response features, dynamically model the dependencies between different modalities, and enable complementary information interaction. Numerical simulation results show that, compared with conventional methods, the proposed method achieves more accurate damage localization performance.

(2) The robustness and generalization capability of the proposed data–physics dual-driven heterogeneous dual-graph neural network are investigated. Frame structures and truss structures are selected as two representative structural systems to

evaluate the damage localization performance under random sensor failure conditions. The results show that when part of the measurement information is missing, the proposed method can still rely on the topological priors provided by the physical structure graph to compensate for incomplete observations, thereby maintaining more stable damage localization performance than other methods. Random sensor failure tests further demonstrate that, by incorporating multimodal cross-attention and heterogeneous graph modeling, the proposed method exhibits strong robustness and generalization potential, especially in engineering scenarios with limited data and complex sensor failure disturbances.

(3) A transfer-learning-enhanced heterogeneous dual-graph neural network is developed and experimentally validated for structural damage localization. To address the scarcity of real damaged-state samples, a transfer-learning-enhanced heterogeneous dual-graph neural network is established. The proposed method incorporates a transfer learning enhancement strategy to facilitate efficient model training and cross-domain knowledge transfer. A domain alignment constraint is further introduced to reduce the feature distribution discrepancy between the simulation domain, regarded as the source domain, and the real structural domain, regarded as the target domain. In this way, numerical simulation data and high-fidelity sensor measurements are effectively integrated, improving the generalization capability and reliability of the model. The effectiveness of the proposed method is validated through a damage identification test on a real steel frame structure. The results indicate that the proposed method can improve damage localization performance without using real damaged-state labels for network training.

Keywords: Structural health monitoring; damage localization; transfer learning; graph neural network; heterogeneous dual-graph network.

目录

第 1 章 绪论 9
1.1 研究背景及意义 9
1.2 国内外研究现状 11
1.2.1 传统结构损伤识别方法 11
1.2.2 传统机器学习在 SHM 中的应用 13
1.2.3 深度学习在 SHM 中的应用 15
1.3 本文研究目的与主要内容 19
1.3.1 研究目的 19
1.3.2 主要研究内容 20
1.3.3 本文主要创新点 21
第 2 章 数物双驱异构双图神经网络结构损伤定位方法 23
2.1 引言 23
2.2 图神经网络基本理论 24
2.2.1 图数据表示 24
2.2.2 谱域图卷积 25
2.2.3 空间域图卷积 26
2.3 时序特征编码与注意力机制基础 28
2.3.1 时序建模方法简述 28
2.3.2 注意力机制与交叉注意力 29
2.4 基于数物双驱异构双图神经网络模型架构 31
2.4.1 基于 TCN-Encoder 的多尺度时序特征提取模块 32
2.4.2 基于时序相关性与空间先验融合的动态传感器图分支 33
2.4.3 基于有限元拓扑与模态先验的结构图分支 35
2.4.4 基于软距离偏置的异构双图交叉注意力融合模块 37
2.4.5 基于边特征学习的楼层级损伤判别模块 38
2.5 本章小结 40
第 3 章 基于数物双驱异构双图神经网络损伤定位方法有效性验证 41
3.1 引言 41
3.2 异构双图网络引入的必要性验证 42
3.2.1 T 型钢架模型与损伤工况 42
3.2.2 局部刚度退化引起的内力重分布与损伤误判分析 42
3.2.3 异构双图结构引入必要性的模型对比验证 44
3.3 IASC-ASCE 基准数据集构建与预处理 48
3.3.1 IASC-ASCE SHM 基准结构概述 48

3.3.2 模拟数据集损伤工况设计与时频数据生成 50
3.3.3 双图样本构建与节点—边特征构造 52
3.4 模型训练策略与基线设置 53
3.4.1 实验环境与网络超参数设置 53
3.4.2 对比基线模型 56
3.4.3 损伤定位性能评价指标 59
3.5 损伤定位结果分析 60
3.5.1 DP-HDGNN 楼层级损伤定位结果 60
3.5.2 Baseline 模型性能对比 63
3.6 DP-HDGNN 核心模块消融实验分析 68
3.6.1 动态传感器拓扑图的有效性验证 69
3.6.2 异构双图交叉注意力融合机制的有效性验证 71
3.6.3 边特征学习模块的有效性验证 73
3.7 本章小结 75
第 4 章 传感器失效时数物双驱异构双图神经网络损伤定位鲁棒性验证. 77
4.1 引言 77
4.2 空间桁架数值仿真模型与复合损伤数据集构建 78
4.2.1 空间桁架结构基本概况与有限元建模 78
4.2.2 随机激励荷载施加与带噪时程序列生成 79
4.3 面向桁架拓扑结构的双图特征构建 81
4.4 模型训练策略与基准模型设置 82
4.4.1 网络超参数搜索与训练环境对齐 82
4.4.2 桁架损伤定位评价指标与基线模型设置 84
4.5 桁架结构损伤定位与传感器失效鲁棒性分析 87
4.5.1 DP-HDGNN 桁架损伤定位精度与混淆矩阵分析 87
4.5.2 基线模型对比与传感器失效鲁棒性分析 90
4.6 本章小结 96
第 5 章 基于迁移学习增强的异构双图神经网络结构损伤定位方法及实验验证 99
5.1 引言 99
5.2 基于迁移学习增强的仿真—实测特征差异修正方法 100
5.2.1 源域监督训练与目标域无标签约束的联合优化 101
5.2.2 基于 MK-MMD 的多尺度特征分布对齐 102
5.2.3 后验阈值校准策略 104
5.3 基于 SSI-COV 与 MAC 的结构模态匹配方法 104
5.3.1 基于 SSI-COV 的实测模态参数识别 104
5.3.2 基于 MAC 与匈牙利算法的仿真—实测模态匹配 106
5.4 真实钢框架试验数据与实验设置 107
5.4.1 真实钢框架试验台架与数据来源 107

5.4.2 真实损伤工况定义与标签映射 108
5.4.3 数据划分及归一化策略 109
5.4.4 对比实验设置与评价指标 110
5.5 钢框架真实数据损伤定位结果分析 112
5.5.1 仿真训练模型直接应用结果分析 112
5.5.2 实测数据融合后的模型性能分析 114
5.6 本章小结 117
第 6 章 结论与展望 119
6.1 主要工作及结论 119
6.2 课题展望 120
参考文献 122
致谢 127
个人简历、在读期间发表的学术成果 128
同济大学学位论文原创性声明 129
同济大学学位论文版权使用授权书 129

第1章 绪论

1.1 研究背景及意义

在土木工程领域，大跨度桥梁、超高层建筑、大跨空间网架结构、大坝及地下隧道工程等大型土木基础设施的建设规模与日俱增。这些国家级重大生命线工程在长达数十甚至上百年的服役周期内，不可避免地会受到恶劣环境侵蚀、材料老化、疲劳累积以及极端自然灾害和异常交通荷载的长期耦合作用。随着服役年限的延长，结构系统内部的微观缺陷会逐渐演化为宏观裂缝，进而导致构件承载能力下降与整体抗灾性能退化。若不能及时发现并修复这些隐患，不仅将严重威胁公共生命财产安全，还会造成不可估量的直接与间接经济损失[1]。历史上多起灾难性结构坍塌事件（如图 1.1 所示），例如美国明尼阿波利斯 I-35W 大桥坍塌、意大利热那亚莫兰迪大桥坍塌这些事故深刻暴露出，传统基于定期人工视觉巡检和局部无损检测的方法在时效性、覆盖面和客观性上存在漏洞。



（a）美国明尼阿波利斯 I-35W 大桥坍塌　　（b）意大利热那亚莫兰迪大桥坍塌

图 1.1 灾害造成的结构破坏

为了推动基础设施运维管理从维修向实时监测的转变，结构健康监测现已成为保障重大工程服役安全、降低全生命周期维护成本的核心技术。结构健康监测系统通过在结构关键受力部位密集部署各类传感器网络，实时采集结构在环境激励荷载下的力学与动力学响应数据。在此海量监测数据的基础上，研究人员利用数据处理与模式识别技术提取对结构状态敏感的特征指标，从而实现对结构潜在损伤的早期预警、精确定位与严重程度量化。

然而，现代超大型土木工程体量庞大、自由度极高，且服役环境复杂。监测系统每天产生海量的高维、非平稳且伴随强环境白噪声的时序数据。传统的基于物理有限元模型驱动的损伤识别方法面临着由于不可知边界条件引起的建模极

度复杂、非线性动力时程计算成本高昂等非凸问题。进入工业物联网与大数据时代，如何从繁杂冗余且信噪比极低的异构数据海洋中，精准剥离出微弱的结构早期损伤特征信号，并建立高泛化性、强鲁棒性的状态评估映射模型，已成为 SHM 领域当前面临的重大挑战与核心科学问题。

近年来，以深度学习为代表的新一代人工智能技术迅猛发展，为打破上述传统技术瓶颈提供了新的技术路径。其中特别是图神经网络能够有效表征传感器在三维空间中的非欧几里得拓扑连接关系，被证明在捕捉结构局部构件刚度退化方面具有独特优势。然而，单一的静态图结构难以应对结构损伤导致内力重分布与响应相关性变化的问题，且纯数据驱动模型在从仿真环境向真实物理世界适配时往往面临泛化性能骤降的瓶颈。

基于此，本课题拟融合结构物理拓扑与数据驱动特征，提出一种数物双驱异构双图神经网络（Data–Physics Dual-Driven Heterogeneous Dual-Graph Neural Network, DP-HDGNN）。该架构通过结构物理图表征结构节点、构件连接与模态先验，通过动态传感器图刻画监测响应之间随结构状态变化产生的相关性，并借助异构双图融合机制实现结构先验与传感器响应信息的协同表征。在此基础上，进一步研究仿真数据训练模型在真实结构实测数据中的适配方法，为真实损伤样本不足条件下的结构损伤定位提供新的技术路径。

1.2 国内外研究现状

结构健康监测的本质是一个典型的物理反问题：利用可观测的结构宏观动力学响应，反推不可直接观测的结构内部微观物理参数演化。Farrar 与 Worden[2]将 SHM 系统性地划分为四个机器学习层级：异常检测、损伤定位、损伤量化与剩余寿命预测。基于这一范式，Rytter[3]奠定了现代结构损伤评估的理论层次。围绕上述目标，结构损伤识别方法经历了由传统物理驱动方法向数据驱动方法、再向深度学习与图学习方法不断演进的过程。

1.2.1 传统结构损伤识别方法

在机器学习与深度学习尚未广泛应用于结构健康监测之前，损伤识别研究主要依托经典结构动力学理论展开。这类方法总体上属于物理驱动范式，其核心思想是通过建立结构动力响应与刚度退化之间的关系，实现损伤的检测、定位与量化。根据所利用特征和建模方式的不同，传统结构损伤识别方法主要经历了由基础模态参数识别、衍生模态参数定位到有限元模型修正定量反演的发展过程。

早期研究多从结构固有动力特性出发，通过固有频率、振型等基础模态参数判断结构状态。根据结构动力学理论，结构固有频率与振型由质量矩阵和刚度矩阵共同决定。当结构发生局部或整体损伤时，刚度退化会引起特征方程变化，进而表现为固有频率偏移和振型形态改变。Cawley 与 Adams[4]率先证明了结构固有频率的变化与损伤位置及程度之间存在解析关系。随后，Salawu[5]全面总结了利用固有频率进行损伤检测的工程实践。该方法测试门槛较低，仅需少量的传感器即可获取固有频率，且受环境随机激振的干扰较小。然而，固有频率本质上属于全局模态特征，对局部微弱损伤和单一构件轻微退化不够敏感，也难以区分对称位置损伤。更重要的是，真实服役桥梁或建筑中由温度变化引起的频率波动，往往可能超过早期损伤导致的频率下降[6]。因此，单纯依赖基础模态参数的方法在复杂结构中的精确定位能力受到明显限制。

为提高对局部损伤的敏感性，研究者进一步发展了基于衍生模态参数的识别方法。与固有频率等全局指标相比，曲率模态、柔度矩阵和模态应变能等参数能够更直接反映局部刚度变化引起的空间响应差异。Pandey 与 Biswas[7]分析了结构柔度矩阵的变化特征，指出柔度矩阵对角线元素的突变可用于反映局部损伤位置；在此基础上，Pandey 等[8]进一步提出了曲率模态概念，证明了其在局部刚度突变处的峰值效应。随后，Shi 等[9]将模态应变能引入损伤定位，通过单元模态应变能变化率，将该理论推广至复杂的三维空间框架结构。Stubbs[10]等提出了损伤指数算法，并在桥梁现场检测中验证了其损伤定位和程度评估能力。Cornwell[11]等则将基于应变能的损伤检测方法从一维的梁类构件进一步拓展至具有二维空间曲率的板类结构，扩大了该理论的工程适用边界。进一步地，Maeck 与 De Roeck[12]利用 Z24 桥监测数据，基于模态曲率与弯矩分析，成功反演了桥梁刚度的退化演化过程，为衍生模态参数在实际复杂工程中的应用提供了工程案例。

总体来看，衍生模态参数提高了传统模态方法对局部损伤的识别能力。Doebling 等[13]系统总结了基于柔度矩阵、模态参与质量等指标的传统损伤识别路线。然而，这类方法在实际应用中仍受到测试条件和数据质量的限制。例如，曲率模态通常需要对离散振型进行空间二阶差分，容易放大环境噪声并产生虚假峰值；为获得稳定、平滑的振型或曲率信息，往往需要布设较密集的传感器网络，这在大型土木结构中会带来较高的工程成本[14]。

为了进一步实现损伤程度的定量反演，有限元模型修正逐渐成为传统物理驱动方法中的重要分支。该方法将损伤识别转化为非线性优化问题：首先建立结构基准有限元模型，随后比较数值预测响应与实测响应之间的差异，并通过优化算法迭代修正局部刚度参数，使模型计算结果逐步逼近真实结构响应。Friswell[15]指出，由于结构损伤通常具有局部性和多发性，而可测信息相对有限，有限元模

型修正不可避免地面临病态反问题，需要引入正则化等数学手段加以约束。Friswell 与 Mottershead[16]进一步阐述了基于灵敏度分析的模型更新框架，通过最小化实测模态参数与数值预测值之间的目标函数残差，反向标定单元刚度折减系数。Peeters 与 De Roeck[17]。在 Z24 桥监测中成功应用了基于子空间方法的模型更新技术，展示了 FEMU 在实际桥梁结构中的应用潜力。

然而，模型更新面临着严峻的病态反问题挑战。Yuen 等[18]与 Yan 等[19]将贝叶斯推断引入模型更新过程，通过马尔可夫链蒙特卡洛方法估计参数后验分布，以量化识别结果的不确定性。该类方法的优势在于具有较强的物理解释能力，一旦模型更新收敛，不仅能够定位损伤，还可进一步估计损伤程度。但与此同时，FEMU 对初始有限元模型精度高度敏感。复杂三维结构的高保真建模成本较高，半刚性节点、边界摩擦、土—结构相互作用等非线性因素也难以通过简单刚度矩阵准确等效。此外，由于实际可布设传感器数量通常远少于结构自由度，目标函数易出现多解性和局部极小值，导致优化过程陷入非唯一解。面对海量高频实时监测数据时，高维迭代优化的计算效率也难以满足在线监测需求。

综上所述，传统结构损伤识别方法以结构动力学理论为基础，具有明确的物理含义和较强的可解释性，在损伤机理分析和定量反演方面发挥了重要作用。但其普遍依赖高质量模态参数、密集传感器布置或高精度有限元模型，在复杂边界条件、强环境噪声和大规模实时监测场景下存在明显局限。随着传感器网络和长期监测数据的快速发展，如何减少对精确物理模型和人工模态特征的依赖，直接从实测数据中挖掘结构状态变化规律，成为推动结构损伤识别方法向机器学习和数据驱动范式发展的重要原因。

1.2.2 传统机器学习在 SHM 中的应用

面对有限元模型修正在复杂真实结构中存在的建模成本高、参数反演病态和计算效率不足等问题，研究者认识到，在实际工程中强制要求算法精确还原结构刚度矩阵往往并不现实。Worden 等[20]明确提出将 SHM 转化为统计机器学习中的异常检测问题，标志着结构损伤识别研究范式由强物理模型驱动向数据驱动方法转变。该思路不再以精确求解偏微分方程或反演完整结构参数为唯一目标，而是将结构视为由多源传感数据表征的信息系统，通过挖掘监测数据中的统计分布变化来判断结构状态。传统机器学习方法由此成为早期数据驱动 SHM 的重要技术路线，其基本流程通常包括时序特征建模、环境干扰解耦与浅层分类器决策三个环节。

在特征建模阶段，时间序列分析是早期 SHM 中最常用的数据驱动方法之一。其核心思想是：在结构健康状态下利用传感器响应建立统计预测模型，当结

构状态发生变化时，实际响应与模型预测结果之间会产生异常残差或残差方差漂移，由此实现损伤识别。Omenzetter[21]等成功将 ARIMA 模型应用于真实桥梁的长期监测中，通过追踪模型自回归系数的突变来实现异常报警。Nair[22]在 ASCE 基准结构上构建了基于 AR 模型与残差统计的损伤检测和定位方法，证明时间序列模型不仅能够识别结构状态变化，也具备一定的损伤定位潜力。进一步地，Gül 与 Catbas[23]针对环境激励下难以直接获得自由衰减响应的问题，引入随机递减与传感器簇划分策略，利用 ARX 模型在环境振动条件下实现了损伤检测、定位与程度估计，增强了该类方法在实际桥梁监测场景中的工程适用性。此类方法的优势在于不依赖复杂有限元模型，且 AR 系数等统计量能够压缩原始时序数据维度，降低工程部署难度。然而，经典时序模型通常建立在线性和平稳假设之上，而真实结构在风荷载、交通荷载或地震激励下的响应往往具有明显非平稳性。同时，单一时序建模主要关注时间维度，难以显式表达多传感器之间由结构几何和构件连接决定的空间力学相关性，因此在复杂空间结构多点复合损伤定位中存在局限。

随着长期监测数据规模不断增大，环境与运行变异对损伤识别结果的影响逐渐受到关注。温度、湿度、交通荷载等因素引起的结构动力特性变化，有时会超过早期微弱损伤本身造成的刚度退化。为了从宏观环境干扰中剥离微弱损伤信息，主成分分析（Principal Component Analysis, PCA）等降维方法被广泛引入 SHM。其基本思想是将环境与运行变异视为占据主要方差的全局成分，而将局部损伤引起的细微变化保留在残差子空间中。Deraemaeker 等[24]利用 PCA 成功过滤了温度对桥梁模态频率的干扰，证明了在完全缺乏温度测量数据的情况下，仅依靠结构响应数据的协方差矩阵特征分解，依然能够实现环境噪声的盲分离。D'Alessandro 等[25]则进一步将非线性 PCA 应用于结构损伤检测,，以增强模型对复杂非线性变化的表达能力。沿着这一思路，Hsu 与 Loh[26]利用非线性 PCA 处理环境因素与损伤特征之间的耦合关系，说明当外部扰动与结构性能退化相互交织时，传统线性降维方法难以充分分离真实损伤信息。总体而言，PCA 类方法提升了机器学习模型对环境干扰的鲁棒性，但其本质仍是基于统计投影的特征压缩。尤其是线性 PCA 难以刻画温度、边界条件与刚度变化之间的复杂非线性关系，容易在降维过程中将损伤相关的高频或非线性特征误判为噪声，从而造成有效信息损失。

在完成特征提取和降维之后，浅层分类器被用于在特征空间中建立健康与损伤状态的决策边界。支持向量机（Support Vector Machine, SVM）和随机森林（Random Forest, RF）是其中最具代表性的两类方法。SVM 通过核函数将低维空间中线性不可分的损伤特征映射至高维空间，并寻找最大间隔分类超平面；RF 则通过多棵决策树集成投票提高分类稳定性。

Bornn 等[27]将 AR 模型与 SVM 结合，实现了复杂航空与土木结构的损伤状态分类；Sony 等[28]与 Figueiredo 等[29]则开展了 SVM、KNN、决策树等多种算法在结构上的横向性能对比。进一步地，Pan 等[30]将小波变换、Hilbert-Huang 变换和 Teager-Huang 变换提取的时频特征输入 SVM，用于斜拉桥的数据驱动状态诊断，表明浅层分类器在配合有效特征构造时仍可取得较好的识别效果。Zhou 等[31]则将小波包分解与随机森林递归特征消除相结合，通过两阶段特征筛选提升损伤敏感特征子集质量，从而增强复杂损伤模式分类的鲁棒性。黄岩等[32]针对井架钢结构损伤识别问题，将时域多参数信息融合与机器学习算法相结合，利用加速度响应信号提取损伤敏感特征，并通过浅层学习器实现结构损伤识别，说明多参数特征融合能够提高传统机器学习方法在复杂钢结构损伤诊断中的适用性。刘鑫鑫等[33]则提出基于小波-ELM 算法的结构损伤识别方法，将小波分析的局部特征提取能力与极限学习机的快速分类能力相结合，为传统特征提取方法与轻量化机器学习模型的结合提供了新的应用案例。

浅层分类器具有数学形式清晰、训练成本较低和小样本泛化能力较强等优点，在损伤样本有限的情况下仍能建立相对稳定的判别边界。但其性能高度依赖前端人工特征的质量，当输入为多传感器原始高维时间序列时，容易受到维度灾难影响，难以实现从原始响应到损伤状态的端到端识别。

总体来看，传统机器学习方法有效降低了结构损伤识别对高精度有限元模型的依赖，推动 SHM 从物理参数反演向数据统计判别转变。然而，这类方法通常仍依赖人工设计的特征、降维指标和分类器组合，其性能上限受专家经验和特征表达能力制约。面对真实结构中高维、非平稳、强噪声和多通道耦合的振动响应，传统统计特征难以全面刻画微弱损伤引发的高频瞬态变化和复杂空间相关性，也难以直接处理海量原始监测数据。因此，如何从原始振动响应中自动学习深层损伤表征，成为后续深度学习方法引入 SHM 领域的重要动因。

1.2.3 深度学习在 SHM 中的应用

传统机器学习方法虽然在一定程度上缓解了有限元模型更新计算成本高、建模难度大的问题，但其性能上限仍然依赖人工特征工程。在复杂空间结构受环境激励作用时，监测信号通常表现出非平稳、强噪声和多通道耦合等特点。依赖专家经验提取的方差、峰度、AR 系数等浅层统计特征，往往难以完整表征微弱损伤引发的高频瞬态变化与跨测点相关性演化[34]。随着大数据技术和 GPU 并行计算能力的发展，深度学习逐渐被引入结构健康监测领域。其核心优势在于能够通过多层非线性映射，从原始振动响应中自动学习与结构状态相关的高阶特征，实现从监测数据到损伤状态标签的端到端映射[35]。这一范式摆脱了传统人工特征设

计的局限，使复杂结构损伤识别由特征构造驱动转向数据表征学习驱动。

早期深度学习在 SHM 中的应用主要集中于对结构响应信号的局部特征提取。卷积类模型由于具有局部感受野和权值共享特性，能够从振动信号中捕捉局部突变、相位偏移和频带能量变化等损伤敏感信息。当结构响应被转化为时频图或图像形式时，二维卷积网络能够借助成熟的图像识别框架提取时频域特征。例如，Yu 等[36]提出了一种基于智能楼宇多传感器数据的深度 2D-CNN 损伤识别方法，通过构建时频特征图实现了高精度的状态评估。而在计算机视觉监测分支，Cha 等[37]利用深度区域卷积网络（Faster R-CNN）实现了混凝土表面裂缝与钢构件疲劳损伤的自动识别。与此同时，考虑到时频转换可能引入额外计算成本并造成相位信息损失，研究者开始直接处理原始加速度时间序列。为此，Abdeljaber 等[38]率先将多通道加速度响应切片输入一维卷积网络，并在 IASC-ASCE 基准钢框架上实现了实时损伤定位；近年来，国内学者也围绕卷积模型在结构损伤识别中的应用开展了拓展研究，秦世强等[39]将结构损伤定位转化为多标签识别问题，提出基于多标签卷积神经网络的结构损伤识别方法；吁强等[40]将经验模态分解与密集连接卷积神经网络结合，以增强模型对振动响应中损伤敏感特征的提取能力；上述研究表明，卷积模型能够有效提取结构响应中的局部损伤特征，但其基本假设仍建立在规则欧几里得网格之上。当传感器在空间中呈稀疏、非规则布置时，单纯依赖卷积操作难以自然表达传感器之间由结构几何和构件连接决定的真实拓扑关系。

在结构动力响应具有明显时间演化特征的背景下，序列建模方法进一步推动了深度学习在 SHM 中的应用。结构在风荷载、地震或环境脉动作用下的响应并非孤立采样点，而是具有历史依赖性的动力过程。因此，能够记忆时间上下文信息的循环类模型被用于结构异常检测、响应预测和性能退化跟踪。Ni 等[41]将深层长短期记忆网络应用于大跨度悬索桥监测数据，实现了异常检测与数据压缩；Sajedi 与 Liang[42]构建了融合卷积特征提取与时序记忆能力的混合网络，用于地震作用下大型结构的损伤识别；Truong 等[43]提出 1D-CGRU 框架，提升了大规模实验数据中的实时检测效率。这类研究说明，将局部特征提取与时间依赖建模相结合，有助于捕捉结构响应中的相位漂移、累积变形和时序演化规律。然而，序列模型主要沿时间维度学习特征，其对空间传力路径的表达能力有限；同时，循环计算机制存在并行效率不足的问题，在处理高采样率、长时程、多传感器监测数据时仍面临计算瓶颈。

除有监督损伤分类外，真实工程中受损样本稀缺的问题也促使无监督深度学习方法得到关注。由于实际结构通常难以获得充足、可控且带标签的损伤数据，许多研究转向利用健康状态数据建立基准模型，再通过异常偏离程度判断结构状

态。Flah 等[44]详细总结了自编码器在无标签 SHM 数据集上的应用潜力。Tang 等[45]、Entezami 等[46]与 Azimi 等[47]分别从卷积自编码器、变分自编码器和深度特征提取角度探索了无监督损伤识别的可行性，Coraça 等[48]进一步将变分自编码器与隐马尔可夫模型结合，通过多传感器振动数据学习结构退化过程。近年来，国内研究也开始将自编码器与数据融合、信号重构相结合，刘玉驰等[49]提出基于数据融合及残差卷积自编码器的结构损伤识别方法，陈鑫婷等[50]则采用多头卷积自编码器开展桥梁结构信号重构与损伤识别研究。无监督模型在一定程度上缓解了真实损伤标签不足的问题，但其判断依据通常依赖重构误差或隐空间分布偏离，更适合用于全局异常预警；若要进一步实现损伤位置识别和程度区分，则仍需将隐空间特征与结构物理位置、构件连接和传力路径建立更明确的对应关系。

随着图神经网络的发展，研究者开始从结构本身的非欧几里得拓扑属性出发，重新组织多传感器监测数据。土木结构天然具有图结构特征：结构节点或传感器测点可视为图节点，梁、柱、斜撑等物理构件可视为图边；当局部构件发生刚度退化时，其引起的动力响应变化并不会局限于损伤位置本身，而是会通过构件连接关系影响相邻节点及相关测点，进而表现为结构内部的内力重分布和多测点响应耦合变化。因此，图神经网络的消息传递机制与结构动力响应在拓扑连接上的传播规律具有较好的形式一致性，能够为复杂结构多传感器损伤识别提供更自然的建模方式[51][52]。Dang 等[53]提出的 g-SDDL 框架直接将原始多通道振动数据输入图卷积网络，证明了 GNN 在端到端损伤定位中的有效性。此后，图学习方法逐渐由单纯的数据驱动建图向物理嵌入与混合驱动方向发展。Kaveh 等[54]将图论概念与模态应变能结合，提出了一种基于图的自适应阈值异常检测算法，用以解决传统 MSE 指标在微弱损伤元素定位上的失效问题。Eslamlou 等[55]进一步将自动化机器学习优化的 GNN 与有限元模型更新相结合，体现了图学习与物理模型融合的趋势。近年国内也出现了相关探索，史子凡等[56]针对 CNN 难以考虑传感器空间相关性的问题，提出基于 GCN 的结构损伤识别模型，并在钢框架有限元模型和钢桁架桥实验数据上验证了其收敛速度、识别精度和抗噪能力。李行等[56]在强噪声、小样本条件下将一维振动数据转换为图数据，并采用图卷积神经网络实现结构损伤识别；杨建辉等[58]则将结构损伤状态、振动数据、节点属性和边连接关系等多维特征输入图卷积神经网络，验证了结构多维特征融合对损伤识别精度和噪声鲁棒性的提升作用。

近年来，为克服静态图在复杂服役环境下表达能力不足的问题，动态建图、注意力机制与 Transformer 结构被引入 SHM 任务。Liu 等[59]提出融合动态图卷积与 Transformer 的无监督异常检测框架，通过传感器时空相关性建模和长程依赖学习，在基准钢结构与真实斜拉桥数据上实现了有效损伤检测。该类研究表明，

GNN 已不再局限于固定邻接矩阵下的局部聚合，而是开始向动态时空关联建模发展。然而，多传感器网络产生的高维、非线性和非平稳响应会使常规图聚合在深层传播中出现过平滑现象，导致局部微弱损伤特征被全局背景响应稀释。针对这一问题，Ren 与 Zhou[60]提出基于交叉注意力机制的双分支图神经网络，以增强多传感器时空相关性的建模能力；Hu 等[61]则将 Transformer 架构引入 SHM，提出了一种图形特征细化与融合机制，以增强模型在强环境噪声下的全局依赖建模与局部特征聚焦能力；进一步地，Wijethunga 等[62]提出双图卷积网络（Dual-Graph Neural Network）。该模型突破了单图模型在空间信息表征上的匮乏，通过双图卷积聚合，在提取局部异常的同时兼顾了全局结构的系统稳定性。Wang 等[63]提出了一种结构自适应统一图神经网络，通过多视图共识表示弱化模型对初始静态邻接矩阵的依赖。倪艳春等[64]提出基于多尺度自适应融合图卷积网络的结构损伤识别方法，通过融合不同尺度图特征提升局部与全局损伤信息的表达能力。上述研究说明，图学习方法正在由单一静态图结构向动态图、多尺度图和多源特征融合方向发展，但如何在统一框架中同时表达结构物理连接关系与传感器响应动态相关性，仍有进一步研究空间。

另一方面，真实结构受损样本不足仍是深度学习方法走向工程应用的重要限制。有限元仿真数据能够提供可控损伤工况和有标签样本，但仿真模型与真实结构在材料参数、边界条件、连接非线性、阻尼机制和测量噪声等方面存在差异，导致仅由仿真数据训练得到的模型直接应用于实测数据时容易出现性能下降。针对这一问题，唐和生等[65]将数字孪生与深度学习结合，利用虚实数据交互为结构损伤识别提供补充样本与状态映射基础；滕辉等[66]基于迁移学习开展框架结构损伤识别研究，说明跨数据来源或跨工况条件下的特征迁移能够改善模型适用性。这类研究表明，仿真数据与实测数据的融合已成为真实损伤样本不足条件下的重要研究方向，但如何进一步结合结构物理信息、传感器动态响应以及特征分布对齐策略，提高模型在真实结构损伤定位中的稳定性，仍是需要深入解决的问题。

综上所述，深度学习推动了 SHM 由人工特征工程向端到端特征学习转变，并在局部特征提取、时序动力建模、无监督异常检测和图拓扑表达等方面取得了显著进展。但面向复杂空间结构和真实服役环境，现有研究仍存在三方面不足：

(1) 传感器响应特征与结构物理先验融合不足。

卷积网络、循环网络及其混合模型主要从振动信号本身提取损伤特征，能够刻画局部频带变化与时序演化规律，但通常缺乏对结构节点连接、构件连接关系和空间拓扑约束的显式表达。在多自由度耦合结构中，局部刚度退化引起的响应变化可能传递至相邻或对称区域，纯时序模型易将这种空间耦合响应误判为异地损伤，导致特征串扰与虚警。现有图神经网络虽然能够引入结构拓扑信息，但多

数仍依赖单一静态邻接关系，难以同时刻画结构固有物理连接与传感器响应之间随结构状态变化产生的动态相关性。

(2) 现有方法在复杂结构与传感器失效条件下的鲁棒性和泛化能力需提高。

实际工程结构通常具有节点连接复杂、构件数量多、响应耦合强等特点，损伤信息可能在多个区域之间传播并叠加。常规图卷积模型在多跳邻域聚合过程中容易将局部异常特征与周围健康节点响应混合，使微弱损伤特征被稀释。同时，工程监测系统中还可能出现传感器随机失效、测点响应缺失或信号中断等情况。当部分观测通道缺失时，纯时序模型容易因输入分布变化而性能下降，常规静态图模型也可能将失效节点的异常信息沿固定邻接关系传播。因此，损伤识别模型不仅需要在完整观测条件下保持较高识别精度，还应在复杂结构和传感器失效条件下具备稳定的损伤定位能力。

(3) 仿真数据与实测传感器数据不匹配制约工程应用。

在实际工程中，实测数据难以覆盖结构从健康到严重损伤的全生命周期状态，真实受损样本获取困难、标注成本高且数量有限，难以支撑深度学习模型的充分训练。有限元仿真数据能够低成本生成丰富的有标签损伤样本，但仿真模型与真实结构在材料参数、边界条件、连接非线性、阻尼机制和测量噪声等方面存在差异，导致仅由仿真数据训练得到的模型直接应用于实际结构时容易出现性能下降。因此，如何利用仿真数据提供损伤判别信息，并融合少量高保真实测传感器数据修正仿真特征与真实响应之间的差异，是推动结构损伤识别方法走向真实工程应用必须解决的问题。

针对上述三大挑战，本文提出了一种数物双驱异构双图神经网络架构，该方法通过构建结构物理图与动态传感器图，通过交叉注意力机制实现结构物理先验与传感器响应特征的融合；通过框架结构与桁架结构算例分析模型在不同结构形式和传感器随机失效条件下的鲁棒性与泛化能力；进一步结合迁移学习思想中的域对齐策略，融合高保真实测传感器数据与仿真数据，提升模型在真实结构损伤定位任务中的适用性。

1.3 本文研究目的与主要内容

1.3.1 研究目的

综合国内外研究现状可知，尽管深度学习与图神经网络为结构健康监测提供了新的技术路径，但在面向复杂空间结构和真实工程应用时，现有研究仍存在以下问题：一是传感器响应数据与结构物理信息之间缺乏有效融合，现有方法往往

偏重单一数据类型，难以同时利用结构拓扑、模态特征和传感器动态响应等多模态信息；二是实际监测环境中传感器失效、测点缺失和结构形式变化会削弱模型的稳定性，现有方法在复杂结构和传感器失效条件下的鲁棒性与泛化能力仍需进一步研究；三是实测数据难以覆盖结构从健康到破坏的全生命周期状态，尤其严重损伤样本极为匮乏，而仿真数据与真实传感器数据之间又存在物理参数、边界条件等差异，导致单纯依赖仿真数据训练的模型难以直接应用于真实结构。

针对上述问题，本文旨在提出并构建一种数物双驱异构双图神经网络。该方法融合结构物理信息与传感器观测数据等多模态数据，引入迁移学习增强与域对齐策略，挖掘仿真数据与真实数据之间的共性损伤特征，减小仿真源域与真实目标域之间的特征分布差异，从而提升模型在复杂结构、传感器失效和真实样本不足条件下的损伤定位能力。本文拟解决的核心问题主要包括以下三个方面：

（1）如何将结构固有的物理拓扑与监测信号的非平稳时序特征进行融合，以实现复杂结构多重损伤的精准定位？

（2）如何验证所提异构双图神经网络模型在复杂结构和传感器随机失效条件下的损伤定位的鲁棒性与泛化性能？

（3）在真实受损样本不足的情况下，如何融合仿真数据与高保真实测传感器数据，通过迁移学习、域对齐和特征差异修正策略，提高模型在真实结构损伤定位任务中的识别性能？

1.3.2 主要研究内容

围绕上述研究目的与科学问题，本文的主要研究内容可归纳为以下三个模块：

(1) 数物双驱异构双图神经网络结构损伤定位方法研究

针对传统深度学习模型难以同时表达结构物理连接关系与传感器动态响应特征的问题，本文提出结构物理图与动态传感器图组成的异构双图神经网络结构损伤定位方法。该方法由结构物理图网络与动态传感器图网络共同构成：结构物理图用于表征结构节点、构件连接、模态特征和刚度相关物理先验，动态传感器图用于刻画传感器响应数据之间随结构状态变化产生的动态相关性。在此基础上，引入时序特征提取模块和多模态交叉注意力融合机制，实现多模态数据融合。通过上述方法，构建兼具数据驱动特征学习能力和物理先验约束能力的损伤定位模型，为后续鲁棒性分析和真实结构实验验证提供模型基础。

(2) 复杂结构传感器失效条件下异构双图神经网络鲁棒性和泛化性能研究

针对复杂结构中节点连接密集以及实际监测系统中传感器失效导致模型识别性能下降的问题，本文开展数物双驱异构双图神经网络的鲁棒性与泛化性能研究。本文选取框架结构与空间桁架结构作为两类代表性结构，考察所提模型在不

同拓扑条件下的损伤定位能力。在框架结构中，重点考察模型对楼层级复合损伤的识别能力；在桁架结构中，针对节点连接更密集、响应耦合更复杂的特点，分析模型在复杂结构中的泛化能力。在此基础上，进一步设置传感器随机失效试验，模拟工程监测中测点响应缺失或观测通道中断的情况，比较 DP-HDGNN 与 MLP、1D-CNN、TCN-GCN 和 TCN-GAT 等模型在观测不完整条件下的性能变化，评估所提方法的传感器缺失鲁棒性。

(3) 基于迁移学习增强策略的异构双图神经网络损伤定位分析与实验验证

面向真实结构受损样本稀缺和仿真数据直接应用于实测数据时性能下降的问题，本文构建基于迁移增强策略的异构双图神经网络损伤定位方法。该方法以有限元仿真数据提供有标签损伤样本和源域损伤判别知识，以真实钢框架试验中的传感器响应数据提供物理一致性约束。在迁移增强策略下，通过实测模态识别与模态匹配建立仿真结构特征和真实结构特征之间的对应关系，并采用多核最大均值差异实现源域数据与目标域数据的特征对齐，减小二者在高维空间中的分布差异，实现仿真—实测数据的融合。最后，基于钢框架结构损伤识别实验来验证所提方法的有效性，分析其在真实受损标签不参与网络训练条件下的损伤定位性能。

1.3.3 本文主要创新点

本文核心创新点可归纳为以下两个方面：

(1) 提出了融合结构物理图与动态传感器图的异构双图损伤定位模型

区别于仅依赖单一时序特征或固定图拓扑的现有方法，本文构建了由结构物理图和动态传感器图组成的异构双图建模框架。结构物理图用于表征结构节点、构件连接和模态先验，动态传感器图用于刻画传感器响应之间的时变相关性；在此基础上，通过交叉注意力融合机制，实现结构物理先验与数据驱动响应特征的融合。该模型提高了复杂结构损伤特征提取与定位能力，在框架结构和空间桁架结构算例中均表现出较好的泛化性。随机传感器失效试验表明，所提双图结构能够在部分测点信息缺失时利用结构拓扑先验和剩余传感器响应进行信息补偿，体现出较好的传感器缺失鲁棒性。

(2) 构建了基于迁移学习增强策略的异构双图损伤定位方法

真实结构受损数据难以覆盖结构全生命周期状态，尤其严重损伤样本稀缺，导致仅依赖实测数据训练深度模型并不现实；而仅依赖仿真数据训练又容易受到仿真模型简化等因素影响，直接应用于实际结构时性能下降。针对这一矛盾，本文构建了基于迁移增强的源域仿真数据与实测数据域对齐策略。该策略以仿真数据作为源域，提供可控损伤工况和有标签训练样本，使模型学习损伤判别边界；

以真实钢框架传感器响应作为目标域，提供真实结构响应约束，用于修正模型对实测数据的特征表征。在实现过程中，通过实测模态识别与仿真—实测模态匹配，建立两类数据在结构图特征层面的物理对应关系；进一步采用多核最大均值差异约束源域仿真特征与实测数据特征在高层表示空间中的分布差异，实现仿真训练模型向真实结构响应的融合。实际钢框架试验结果表明，该策略能够在真实受损标签不参与网络训练的条件下提升真实结构损伤定位性能，为真实样本不足条件下的结构健康监测提供了可行方法。

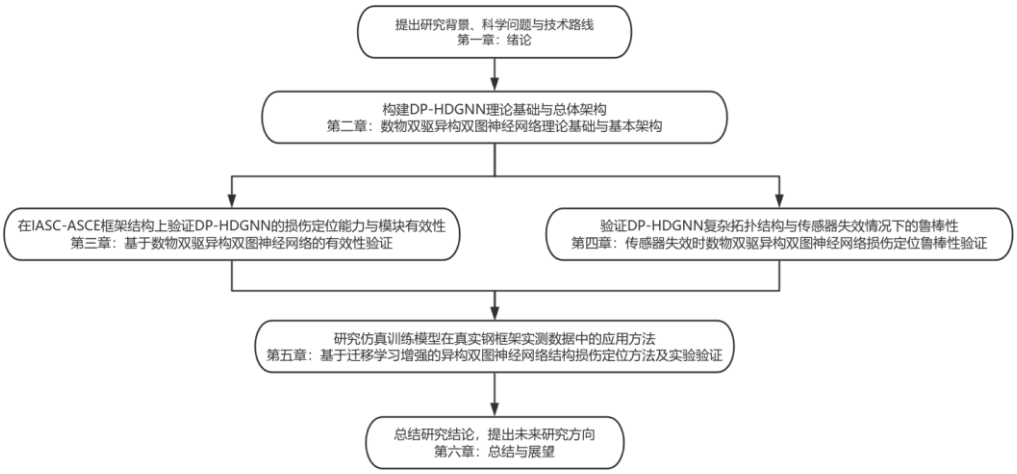


图 1.2 全文章节逻辑图

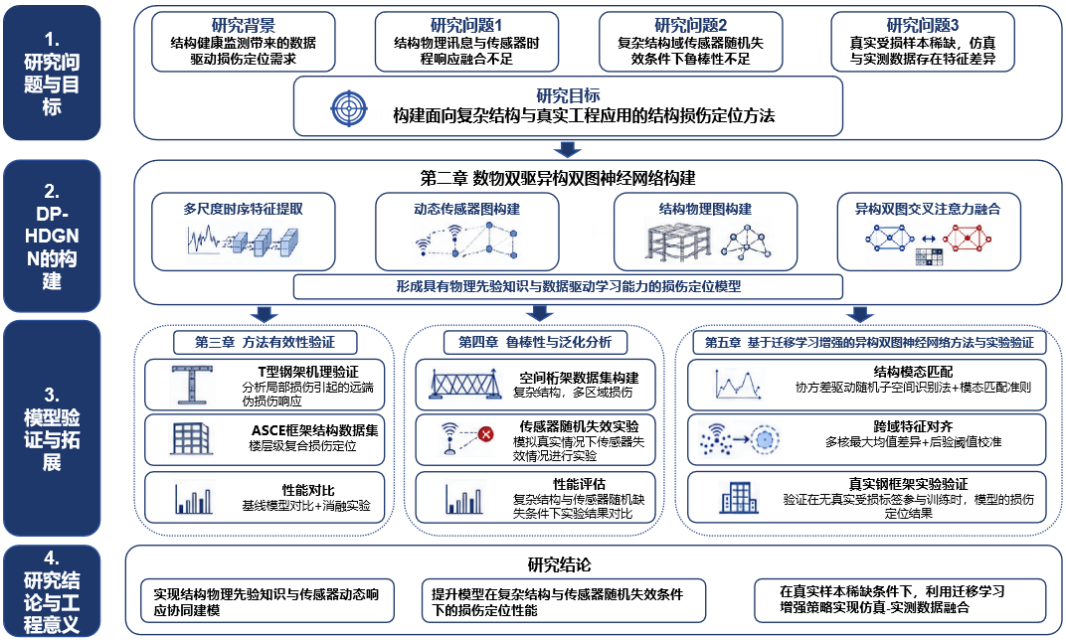


图 1.3 全文技术路线图

第2章 数物双驱异构双图神经网络结构损伤定位方法

2.1 引言

第一章围绕结构健康监测中的损伤定位问题，梳理了传统物理驱动方法、机器学习方法与深度学习方法的发展现状，并指出现有方法在复杂结构损伤识别中仍存在两类关键不足：一方面，纯时序模型主要从传感器振动响应中提取损伤敏感特征，虽然能够刻画信号的局部波动与时序演化规律，但缺乏对结构节点连接、构件关系和空间拓扑约束的显式表达；另一方面，常规图神经网络虽能够引入结构连接信息，但多依赖单一固定邻接关系，难以同时描述结构固有物理拓扑与传感器响应之间随结构状态变化产生的动态相关性。因此，如何在模型结构中同时表达结构物理信息与传感器响应数据，并实现二者之间的有效融合，是本文开展损伤定位研究的基础问题。

针对上述问题，本文提出数物双驱异构双图神经网络（Data–Physics Dual-Driven Heterogeneous Dual-Graph Neural Network, DP-HDGNN）结构损伤定位方法。该模型并非简单地将结构参数与传感器数据进行特征拼接，而是分别从结构物理空间和传感器观测空间建立图表示：结构物理图用于描述结构节点、构件连接、模态特征及边属性等物理先验，动态传感器图用于刻画不同测点响应之间随结构状态变化产生的相关关系。在此基础上，模型通过交叉注意力机制实现两类图特征的交互，使传感器观测信息能够在结构物理约束下参与损伤表征学习，从而形成兼具数据驱动特征提取能力和物理一致性约束能力的损伤定位模型。

本章主要围绕 DP-HDGNN 的理论基础与模型构建展开。首先，从图学习本身出发，介绍图数据表示、谱域图卷积、空间域消息传递和图注意力机制，为结构物理图和动态传感器图的建模提供理论基础；其次，简要阐述时序特征编码与注意力机制，说明模型提取多尺度振动响应特征以及实现异构特征交互的基本原理；最后，系统给出 DP-HDGNN 的总体架构与关键模块设计，包括基于 TCN-Encoder 的多尺度时序特征提取、动态传感器图构建、结构物理图分支、异构双图交叉注意力融合以及边特征学习损伤判别模块。

通过上述内容，本章旨在完成数物双驱异构双图神经网络从理论基础到模型架构的构建，为后续章节的数值验证、鲁棒性分析和真实结构实验应用提供统一的模型基础。

2.2 图神经网络基本理论

图神经网络（Graph Neural Network, GNN）是一类面向图结构数据的深度学习模型。与卷积神经网络主要处理规则网格数据不同，GNN 直接以节点和边为基本单元，通过邻域信息聚合和节点状态更新实现对非欧几里得结构数据的表征学习。本节仅从图学习本身出发，介绍本文后续模型构建所需的图数据表示、谱域图卷积、空间域消息传递和图注意力机制。

2.2.1 图数据表示

一个图通常表示为：$\mathcal{G}=(\mathcal{V},\mathcal{E})$，其中，$V$ 表示节点集合，E 表示边集合。如图 2.1 所示，设图中共有 N 个节点，则节点特征矩阵可表示为：$X\in R^{N\times F}$，其中，F 为每个节点的特征维度。图的连接关系通常由邻接矩阵表示：$A\in R^{N\times N}$，若节点 i 与节点 j 之间存在连接，则 $A_{ij}\neq 0$；若二者不存在连接，则 $A_{ij}=0$。当图中边具有属性时，可进一步为每条边定义边特征：$e_{ij}\in R^{F_e}$，其中，F_e 表示边特征维度。边特征可用于描述节点之间的关系强度、连接类型或其他附加信息。

为描述图结构的整体连接关系，通常定义度矩阵：$D_{ii}=\sum_{j=1}^{N}A_{ij}$，在此基础上，图拉普拉斯矩阵定义为：$L=D-A$，为了缓解节点度数差异带来的尺度影响，常采用对称归一化拉普拉斯矩阵：$L_{sym}=I-D^{-\frac{1}{2}}AD^{-\frac{1}{2}}$，在图神经网络中，节点特征 X、邻接矩阵 A 以及边特征 e_{ij} 共同构成模型输入。GNN 的核心任务是基于图结构关系对节点特征进行更新，从而获得包含邻域信息的节点嵌入表示。

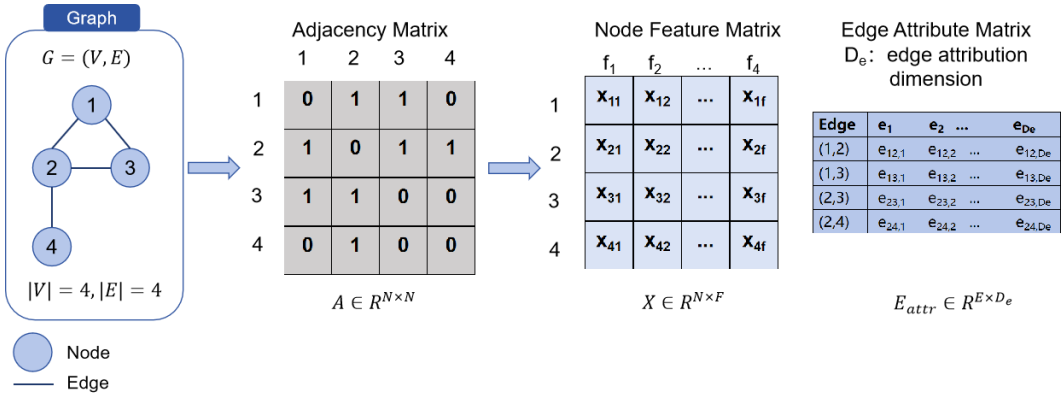


图 2.1 图数据基本概念示意图

2.2.2 谱域图卷积

根据卷积定理，两个信号在时域的卷积等于其在频域的逐点乘积。定义图上的卷积算子$*_{\mathcal{G}}$为信号x与滤波器g_θ的运算：

$$x *_{\mathcal{G}} g_\theta = U\left(\left(U^T g_\theta\right)\odot\left(U^T x\right)\right) = U\hat{g}_\theta(\Lambda)U^T x \tag{2.1}$$

其中$\hat{g}_\theta(\Lambda) = diag(\theta_1,\ldots,\theta_N)$是由可学习参数$\theta$构成的对角矩阵，用于调制不同频率的幅度。

为降低计算复杂度，ChebNet 使用切比雪夫多项式对谱域滤波器进行近似：

$$g_\theta\left(L\right) \approx \sum_{k=0}^{K-1}\theta_k T_k(\tilde{L}) \tag{2.2}$$

其中$\tilde{L} = \frac{2}{\lambda_{\max}}L - I_N$是将特征值缩放至$[-1,1]$区间的重缩放拉普拉斯矩阵，满足切比雪夫多项式的定义域要求。$T_k\left(x\right)$为k阶切比雪夫多项式，由递归公式定义：

$$T_0\left(x\right)=1, T_1\left(x\right)=x, T_k\left(x\right)=2xT_{k-1}\left(x\right)-T_{k-2}\left(x\right) \tag{2.3}$$

此时，图卷积操作转化为：

$$x *_{\mathcal{G}} g_\theta = \sum_{k=0}^{K-1}\theta_k T_k(\tilde{L}) \tag{2.4}$$

这一公式巧妙地绕过了特征分解。因为$T_k(\tilde{L})$仅涉及矩阵L的幂运算，而L^k在图论中表示 k－hop 邻居的连接路径。因此，K阶多项式滤波器是严格K阶领域局部的，节点v_i的特征更新仅依赖于其K阶邻域内的节点信息。

考虑到 ChebNet 模型的复杂性，研究者将其简化并提出了 GCN，核心思想是将卷积操作从欧氏空间推广至图结构域。取$K=1$,并假设$\lambda_{max}\approx 2$，滤波器简化为：

$$g_\theta * x \approx \theta_0 x + \theta_1\left(L - I_N\right)x = \theta_0 x - \theta_1 D^{-1/2}AD^{-1/2}x \tag{2.5}$$

为了进一步减少参数量，强制令$\theta = \theta_0 = -\theta_1$，则卷积操作变为：

$$g_\theta * x \approx \theta\left(I_N + D^{-1/2}AD^{-1/2}\right)x \tag{2.6}$$

算子$I_N + D^{-1/2}AD^{-1/2}$的特征值范围在$[0,2]$，在深层网络中反复相乘会导致数值不稳定。为此，GCN 引入了重归一化技巧

$$I_N + D^{-1/2}AD^{-1/2} \rightarrow \tilde{D}^{-1/2}\tilde{A}\tilde{D}^{-1/2} \tag{2.7}$$

最终的传播方式为：

$$H^{(k+1)}=\sigma\left(\tilde{D}^{-1/2}\tilde{A}\tilde{D}^{-1/2}H^{(k)}W^{(k)}\right) \tag{2.8}$$

其中 $\tilde{A}=A+I$ 表示加入自环的邻接矩阵；$\tilde{D}$ 为对应的度矩阵；$W^{(k)}$ 为可学习参数矩阵；$\sigma(\bullet)$ 为非线性激活函数。

GCN 通过邻接矩阵归一化实现邻域特征聚合，具有结构简单、训练稳定等优点。然而，GCN 对邻居节点的贡献通常采用固定归一化权重，难以区分不同邻居节点的重要性；同时，当网络层数增加时，节点表示可能逐渐趋同，出现过平滑现象。此外，标准 GCN 对边特征的利用能力有限，难以表达复杂图结构中不同连接关系的差异。因此，在本文模型中，GCN 主要作为图卷积理论的基础，而后续具体模块更侧重于空间域消息传递与注意力机制。

2.2.3 空间域图卷积

与谱域方法不同，空间域图神经网络直接在节点邻域内进行信息传递和特征更新，不依赖图拉普拉斯矩阵的特征分解，因而具有更强的灵活性。空间域方法通常可统一表示为消息传递神经网络（Message Passing Neural Network, MPNN）框架。对于图中的任意节点 v_i，在第 k 层神经网络中，其特征向量 $h_i^{(l)}$ 的更新过程遵循以下数学公式：

$$h_i^{(k)}=\phi^{(k)}\left(h_i^{(k-1)},\bigoplus_{j\in N(i)}\psi^{(k)}\left(h_i^{(k-1)},h_j^{(k-1)},e_{ij}\right)\right) \tag{2.9}$$

其中 $h_i^{(k)}$ 表示节点 i 在第 k 层的隐藏表示；$N(i)$ 表示节点 i 的邻居节点集合；$\psi^{(k)}$ 为消息函数，用于构造从邻居节点 j 传递到节点 i 的信息；$\bigoplus$ 表示对邻居消息的置换不变聚合算子；$\phi^{(k)}$ 为更新函数。如图 2.2 所示，该更新形式保证了 GNN 对节点排列顺序的不变性，是图结构理论的核心。MPNN 通过邻域消息聚合和节点状态更新实现图结构上的特征传播，其优势在于能够在非规则拓扑中表达局部关联关系。本文后续主要利用这一机制实现结构节点、边属性与传感器响应特征间的信息聚合。

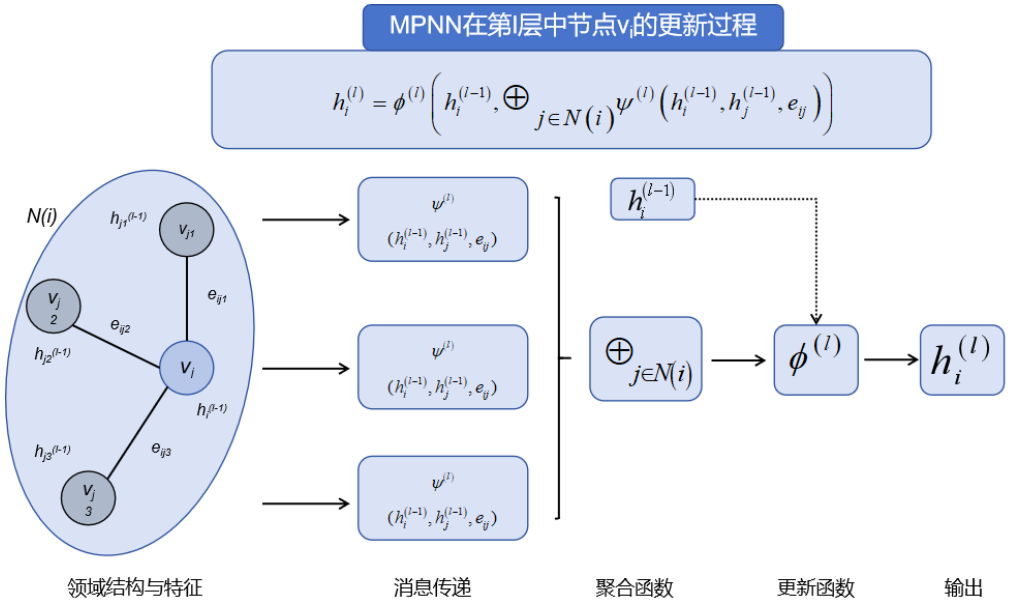


图 2.2 MPNN 示意图

空间域消息传递机制具有两个重要特点。第一，其更新过程直接依赖节点邻域结构，便于结合边特征和局部连接关系进行建模；第二，聚合函数通常具有置换不变性，即邻居节点的排列顺序不会影响最终聚合结果。这使得空间域 GNN 能够适应不同节点顺序下的图结构数据，也便于扩展到包含边属性和动态图关系的任务。

对于本文所研究的异构双图模型而言，空间域消息传递机制为结构物理图和动态传感器图的特征更新提供了基础。结构图中的节点和边可通过消息传递实现局部拓扑信息聚合；传感器图中的节点则可基于动态构建的邻接关系更新其响应特征表示。

在标准 GCN 或一般 MPNN 中，邻居节点的聚合权重通常由固定邻接关系或预设函数决定，难以根据输入特征自适应调整不同邻居的重要性。图注意力网络（Graph Attention Network, GAT）通过在邻域聚合中引入注意力机制，使模型能够根据节点特征自动学习邻居权重。在第 k 层，节点 i 与邻居节点 j 之间的注意力权重与节点的更新形式为：

$$e_{ij}^{(k)} = LeakyReLU\left(a^T\left[W^{(k)}h_i^{(k)} \,\|\, W^{(k)}h_j^{(k)}\right]\right) \tag{2.10}$$

$$\alpha_{ij}^{(k)} = \frac{e^{e_{ij}^{(k)}}}{\sum_{l\in N(i)} e^{e_{ij}^{(k)}}} \tag{2.11}$$

$$h_i^{(k+1)} = \sigma(\sum_{l\in N(i)} \alpha_{ij}^{(k)} W^{(k)} \mathrm{h}_j^{(k)}) \tag{2.12}$$

其中α为可学习的注意力权重向量；$\|$表示向量拼接；$N(i)$表示节点i的邻居节点集合；$h_j^{(k)}$表示节点 j 的 k 层特征，相比于 GCN 模型，GAT 能够区分出不同构件对于节点特征的影响，利用边的特征定义注意力权重，从而根据注意力权重的大小对于节点特征更新做出对应调整。进一步地，GATv2 对注意力计算顺序进行了改进，使注意力权重具有更强的动态表达能力。其一般形式可写为：

$$s_{ij} = a^T LeakyReLU\left(W\left[h_i \| h_j \| e_{ij}\right]\right) \tag{2.13}$$

相较于固定权重的图卷积，图注意力机制能够根据输入特征自适应调整邻域聚合关系，更适合处理节点重要性随样本状态变化而变化的图学习任务。本文后续的结构物理图更新、动态传感器图聚合以及基于边特征学习的损伤判别模块均与这一思想密切相关。

2.3 时序特征编码与注意力机制基础

序列数据广泛存在于自然语言处理、时间序列预测、信号分析和模式识别等任务中，其共同特点是样本内部不同时间步之间并非相互独立，而是存在一定的顺序依赖关系。因此，如何从长序列中提取有效特征，并建立不同时间位置之间的关联，是深度学习序列建模中的重要问题。

传统序列建模方法主要以循环神经网络及其门控变体为代表，通过隐藏状态递推刻画历史信息；随后，时序卷积网络利用一维卷积和膨胀卷积提高了序列特征提取的并行效率；进一步地，注意力机制通过查询、键和值之间的匹配关系，实现了对序列内部或不同特征集合之间关联关系的自适应建模。本节主要介绍上述方法的基本原理，为后续网络结构设计提供理论基础。

2.3.1 时序建模方法简述

循环神经网络（Recurrent Neural Network, RNN）是早期处理序列数据的典型模型。其核心思想是在时间维度上引入隐藏状态，使当前时刻的输出不仅依赖当前输入，还依赖前一时刻传递而来的历史信息。给定输入序列$\{x_t\}_{t=1}^{T}$，标准 RNN 在在时间步 t 的隐藏状态更新形式为：

$$h_t = \sigma\left(W_{xh}x_t + W_{hh}h_{t-1} + b_h\right) \tag{2.14}$$

其中$h_t \in R^d$为隐藏状态，W_{xh}，W_{hh}为权重矩阵，$\sigma(\bullet)$为非线性激活函数，常用 Tanh 或 ReLU，输出可进一步表示为：

$$y_t = \psi\left(W_{hy}h_t + b_y\right) \tag{2.15}$$

在实际训练过程中，RNN 通常采用反向传播通过时间进行参数更新。对于长序列，其梯度形式可表示为多项雅可比矩阵的连乘：

$$\frac{\partial \mathrm{L}}{\partial h_t} = \prod_{k=t}^{T} \frac{\partial h_k}{\partial h_{k-1}} \cdot \frac{\partial \mathrm{L}}{\partial h_T} \tag{2.16}$$

RNN 的优势在于能够利用历史状态描述序列依赖关系，但其递推计算方式决定了各时间步之间难以并行处理；同时，当序列较长时，反向传播过程中容易出现梯度消失或梯度爆炸问题。

为缓解上述问题，长短期记忆网络（Long Short-Term Memory, LSTM）在 RNN 基础上引入门控机制，通过输入门、遗忘门和输出门控制历史信息的保留与更新，从而增强模型对长时依赖关系的表达能力。LSTM 在振动响应建模中能够作为典型的纯时序模型，用于表征仅依赖时间序列特征进行损伤识别的情况。然而，LSTM 仍然保留了循环网络的串行计算特征，在处理高采样率、长时程、多传感器响应时计算效率受限；同时，其主要沿时间维度建模，难以显式表达传感器之间的空间拓扑关系。

与循环网络不同，时序卷积网络（Temporal Convolutional Network, TCN）采用一维卷积对序列进行并行特征提取。TCN 通常结合因果卷积和膨胀卷积，在保持时间顺序的同时扩大感受野。给定输入序列 x，一维膨胀卷积可表示为：

$$y(t) = \sum_{k=0}^{K-1} w(k)x(t - d \cdot k) \tag{2.17}$$

其中，K 为卷积核大小，d 为膨胀率。当 $d = 1$ 时，该式退化为普通一维卷积；当 $d > 1$ 时，卷积核能够以间隔采样的方式覆盖更长的时间范围，从而在不显著增加参数量的情况下扩大模型感受野。多层膨胀卷积堆叠后，模型能够同时提取短时局部波动与长时趋势特征。

总体而言，RNN 与 LSTM 依靠隐藏状态递推建模序列依赖，适合刻画时间顺序关系，但计算并行性受限；TCN 则通过卷积操作和膨胀机制提取多尺度时序特征，能够在保持较高计算效率的同时扩大时间感受野。二者分别代表了递归式序列建模和卷积式序列建模两类思路。

2.3.2 注意力机制与交叉注意力

注意力机制（Attention Mechanism）的核心思想是根据特征之间的相关程度，自适应分配不同信息单元的权重，从而突出对当前任务更重要的特征。对于结构

健康监测中的多传感器响应数据，不同测点在不同结构状态下对损伤识别的贡献并不相同；同时，结构物理图与传感器图具有不同的节点含义和特征来源，不能简单依靠特征拼接完成有效融合。因此，注意力机制为动态相关性建模和异构特征交互提供了合适的计算工具。

对于输入序列 $X \in R^{L\times d_{\text{model}}}$（其中 L 为序列长度，d_{model} 为特征维度），自注意力机制首先通过三个可学习的线性变换矩阵 $W^Q, W^K, W^V \in R^{d_{\text{model}}\times d_k}$ 将输入投影到不同的特征子空间：

$$Q = XW^Q,\ K = XW^K,\ V = XW^V \tag{2.18}$$

这里，Q（Query）代表当前关注的焦点，K（Key）代表被检索信息的索引特征，V（Value）代表实际包含的内容信息。这种分离的设计源于信息检索领域的思想：查询与键的匹配度决定了检索内容的权重。

注意力权重的计算公式为：

$$Attention\left(Q,K,V\right) = softmax\left(\frac{QK^T}{\sqrt{d_k}}\right)V \tag{2.19}$$

其中 d_k 为键向量维度，引入缩放因子用于防止点积过大、稳定梯度。与 RNN 与 LSTM 相比，Transformer 具有显著优势：其所有时间步的特征计算可并行进行，极大提升了训练效率。

为了捕捉时间序列中不同模式的特征，Transformer 采用了多头注意力机制。模型将特征维度分割为 h 个头，每个头独立进行注意力计算：

$$MultiHead\left(Q,K,V\right) = Concat\left(head_1,\ldots,head_n\right)W^O \tag{2.20}$$

$$head_i = Attention\left(QW_i^Q, KW_i^K, VW_i^V\right) \tag{2.21}$$

不同的头可以学习关注不同频率的特征。多头机制能够使模型在不同特征子空间中学习不同的关联模式，从而提升注意力机制的表达能力。

自注意力机制中，查询、键和值均由同一组输入特征生成，其主要作用是建模同一特征集合内部的相关性。当查询特征与键值特征来自不同输入时，注意力机制可扩展为交叉注意力（Cross-Attention）。设两组输入特征分别为：$X_a \in R^{N_a\times d}, X_b \in R^{N_b\times d}$，其中，$X_a$ 为查询端输入，X_b 为被检索端输入。交叉注意力首先分别生成：

$$Q_a = X_aW_Q, K_b = X_bW_K, V_b = X_bW_V \tag{2.22}$$

$$CrossAttention\left(X_a, X_b\right) = Softmax\left(\frac{Q_aK_b^T}{\sqrt{d_k}}\right)V_b \tag{2.23}$$

交叉注意力的本质是利用一组特征作为查询，从另一组特征中检索并聚合相关信息。与简单拼接或直接相加不同，交叉注意力能够根据特征匹配程度建立两组输入之间的软关联关系，因此常用于多源信息融合、编码器—解码器交互以及异构特征对齐等任务。

2.4 基于数物双驱异构双图神经网络模型架构

本节进一步给出数物双驱异构双图神经网络（DP-HDGNN）的整体架构与模块设计。本文方法的基本思想是：从实际建筑结构出发，建立其对应的有限元模型，随后，基于结构节点、构件连接与模态信息构建结构图，并根据监测响应数据构建传感器图，在此基础上，通过结构支路与传感器支路分别完成特征提取，再借助交叉注意力机制实现双图特征融合，最终输出楼层级损伤分类结果。与仅依赖单一时序特征或固定图拓扑的模型相比，该架构能够同时利用结构物理先验与监测数据中的动态信息，从而提升复杂结构损伤识别的准确性与稳定性。

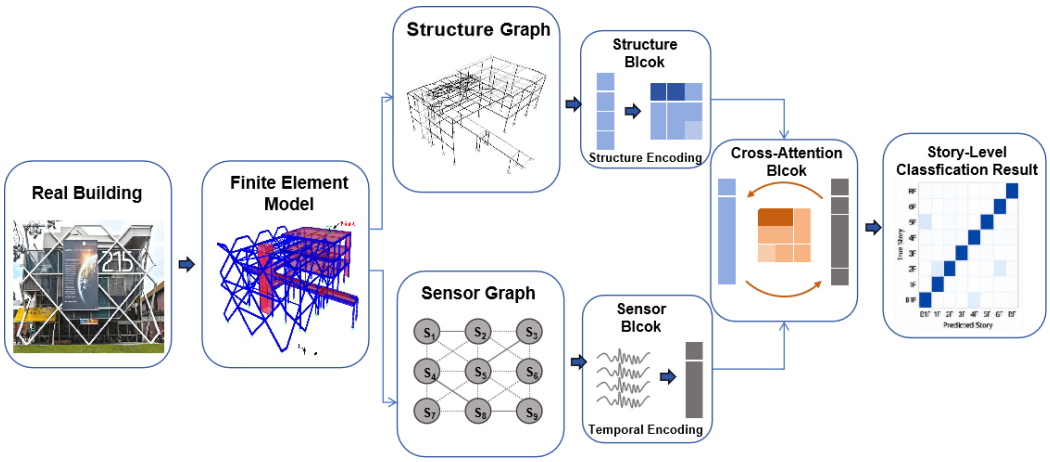


图 2.3 数物双驱异构双图神经网络总体流程图

如图 2.3 所示，DP-HDGNN 由结构支路、传感器支路、跨图融合模块和分类输出模块组成。结构支路用于编码结构节点、构件连接和模态先验信息，传感器支路用于提取监测响应中的时序特征并构建动态传感器关系；两类特征经交叉注意力模块进行融合后，输入分类头完成楼层级损伤判别。模型整体可以概括为以下四个模块：

(1) 时序特征编码：利用多尺度 TCN 编码器从原始加速度时程中提取高维动力学特征，解决长序列依赖问题。

(2) 动态传感器图构建：基于信号相似度与空间距离的门控融合机制，构建稀疏的传感器动态拓扑，并进行图卷积特征聚合。

(3) 异构图交叉融合：利用带有软距离偏置的交叉注意力，将稀疏的传感器信息

映射到密集的结构模态图中，实现物理与数据的对齐。

(4) 显式边更新模块：在结构图中引入显式边更新层，对节点间关系进行进一步表征，最终通过楼层级注意力池化输出各层的损伤概率。

为进一步说明上述模块之间的计算关系，图 2.4 给出了 DP-HDGNN 的详细计算架构。与总体流程图不同，该图重点展示传感器支路、结构支路、跨图融合以及楼层级判别模块的详细情况。

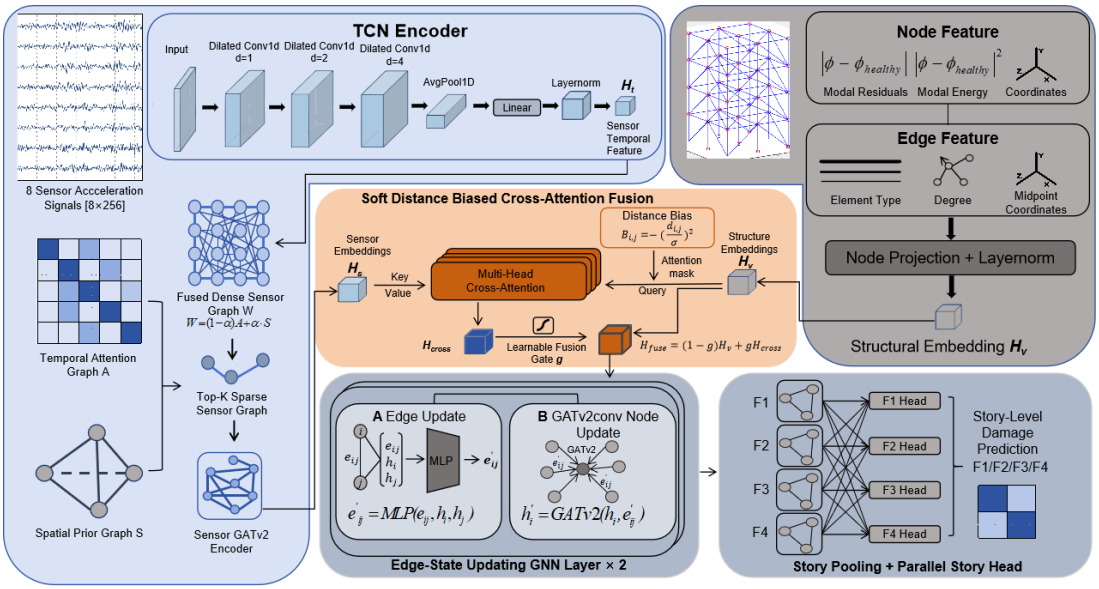


图 2.4 数物双驱异构双图神经网络详细架构

2.4.1 基于 TCN-Encoder 的多尺度时序特征提取模块

结构振动响应通常表现为高采样率、长持时和非平稳等特征。对于损伤定位任务而言，原始加速度时程中既包含由整体刚度变化引起的低频响应差异，也包含由局部构件退化、连接状态变化或测量噪声引起的短时波动。因此，模型需要从长序列响应中同时提取局部瞬态特征与较长时间范围内的动态演化特征。若直接采用循环神经网络处理此类长序列数据，其递推计算方式会限制并行效率，并可能在长时程训练中出现梯度衰减问题。为提高时序特征提取效率，本文采用基于膨胀卷积的时序卷积编码器（Temporal Convolutional Network Encoder, TCN-Encoder）对各传感器加速度响应进行编码，其结构如图 2.5 所示。

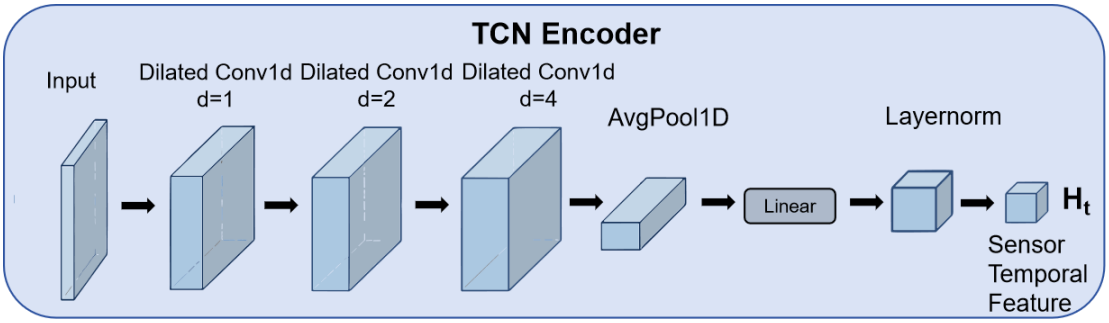


图 2.5 TCN-Encoder 架构示意图

TCN-Encoder 的核心在于通过膨胀卷积（Dilated Convolution）扩大时间感受野。对于一维输入序列 $x \in R^T$ 和卷积核 $f:0,\ldots,k-1 \to R$，在时刻 t 的膨胀卷积操作定义为：

$$(F *_d x)(t) = \sum_{i=0}^{k-1} f(i) \cdot x(t - d \cdot i) \tag{2.24}$$

其中 f 为卷积核，K 为卷积核尺寸，当 $d=1$ 时，卷积核在相邻时间点上连续滑动，主要提取短时间范围内的局部波动特征；当 d 增大时，卷积核以间隔采样的方式覆盖更长的时间范围，使模型能够感知较长时程内的响应变化。本文采用多层膨胀卷积堆叠结构，膨胀率设置为 $d=[1,2,4]$，卷积核大小设置为 $k=5$，从而在不显著增加参数量的情况下获得多尺度时间感受野。

在具体实现中，每个传感器的加速度时程首先输入多层一维膨胀卷积网络。不同膨胀率的卷积层依次作用于时序特征，使浅层卷积更侧重提取局部瞬态扰动，深层卷积则进一步整合较长时间范围内的响应变化。为增强模型对非线性时序特征的表达能力，每个卷积层后引入 GELU 激活函数。随后，卷积输出通过全局平均池化压缩为固定长度特征，并经线性映射与归一化操作得到传感器节点嵌入向量 $h_i \in R^{d_{model}}$：

$$h_i = LayerNorm\left(Linear\left(Pool\left(F\right)\right)\right) \tag{2.25}$$

通过该过程，原始高维加速度时程被转换为固定维度的节点特征，为后续动态传感器图构建和图神经网络特征聚合提供输入。

综上，TCN-Encoder 的作用并不是直接完成损伤判别，而是将每个传感器的长时程加速度响应压缩为包含多尺度时序信息的节点嵌入。该模块为后续传感器动态图构建、异构双图交叉融合以及楼层级损伤分类奠定了时序特征基础。

2.4.2 基于时序相关性与空间先验融合的动态传感器图分支

在实际工程中，传感器之间的依赖关系是复杂的。一方面，它们受到几何

位置的约束，即在物理上相邻的传感器往往具有强相关性；另一方面，它们受到结构状态的动态影响，主要体现在损伤可能改变传力路径，导致原本相关的传感器相似程度减弱。传统的静态图方法无法反映这种时变特性。为此，本文提出了一种物理先验与数据驱动相结合的动态图构建机制如图 2.6 所示，该机制创新性地融合了两种图邻接矩阵：

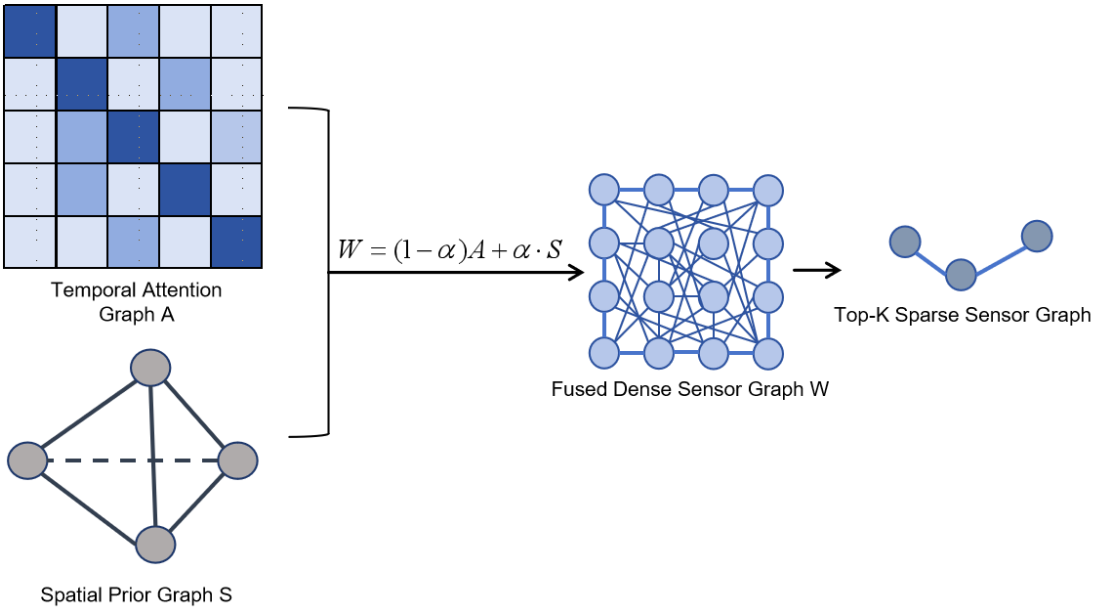


图 2.6 动态传感器图架构示意图

数据驱动的时序相似性图(A_{data})为了捕捉传感器数据的动态相关性，我们利用自注意力机制计算传感器特征之间的相似度。给定 TCN 编码后的传感器特征 $H \in R^{N\times d}$，首先通过线性变换生成 Q 与 K,V，然后计算缩放点积注意力得分：

$$Q = XW^{Q}, K = XW^{K} \tag{2.26}$$

$$Attention\left(Q_A, K_B, V_B\right) = soft\max\left(\frac{Q_A K_B^T}{\sqrt{d_k}}\right)V_B \tag{2.27}$$

纯数据驱动的方法容易受到环境噪声的干扰，产生虚假的连接。为了增强鲁棒性，我们引入基于欧氏距离的高斯核函数作为物理正则化项。对于传感器坐标 p_i, p_j：

$$A_{prior,ij} = e^{\left(-\frac{\|p_i - p_j\|^2}{2\sigma^2}\right)} \tag{2.28}$$

其中 σ 为控制衰减速率的超参数。该矩阵 A_{prior} 表明物理上靠近的节点应当具有更强的相互作用，这为图结构提供了一个稳定的骨架。

为了在这两种图之间取得最佳平衡，本文设计了一个可学习的门控系数 γ。该门控不是一个固定的标量，而是基于当前全局传感器状态动态生成的：

$$h_{global} = MeanPooling\left(H\right) \tag{2.29}$$

$$\alpha = sigmoid\left(MLP\left(h_{global}\right)\right) \tag{2.30}$$

最终的融合邻接矩阵 W_{fuse} 计算如下：

$$W_{fused} = \left(1-\gamma\right)\cdot A_{data} + \gamma \cdot A_{prior} \tag{2.31}$$

通过门控融合机制可以动态性的调整基于物理的先验图与基于数据的时序相关图的比重，从而使结构处于线性弹性阶段且噪声较低时，模型可能自动增大 α，更多依赖稳定的空间先验；当结构发生非线性损伤或受到复杂激励时，信号相关性模式发生改变，模型会自动减小 α 更多依赖数据驱动的注意力图来捕捉异常的耦合关系。

在通过门控机制获得融合邻接矩阵 W_{fuse} 后，直接利用该矩阵进行图卷积运算在理论与计算上均存在显著缺陷：考虑到接收的传感器信号往往受到环境白噪声干扰。若直接使用融合邻接矩阵 W_{fuse}，很容易让模型将微弱的噪声相关性误判为物理连接，导致学习到错误的依赖关系。

为此，本文引入 Top-K 选择算法对图拓扑进行稀疏化处理。Top-K 算子是一种非可微的硬阈值筛选机制，其数学形式可定义为：对于节点 i，仅保留其邻域内权重最大的 K 个连接，即：

$$\mathcal{N}_k\left(i\right) = \left\{ j \middle|\ W_{ij} \in \mathrm{top}_k\left(\left\{W_{il} \middle|\ l \in V\right\}\right)\right\} \tag{2.32}$$

$$\hat{W}_{i,j} = \begin{cases} W_{ij}, & \text{if } j \in \mathcal{N}_k\left(i\right) \\ 0, & \text{otherwise} \end{cases} \tag{2.33}$$

这种稀疏化处理不仅提高了计算效率，还具有物理意义：它模拟了结构中传力路径的稀疏性。最终生成的动态图被送入图注意力层进行特征聚合，得到包含时序响应关系的传感器节点嵌入。至此，传感器支路完成了由原始监测序列到动态传感器图特征的转换。

2.4.3 基于有限元拓扑与模态先验的结构图分支

与动态传感器图侧重表征监测响应之间的时变相关性不同，结构图分支的主要作用是向网络提供相对稳定的结构空间先验。对于实际建筑结构而言，其节点位置、构件连接关系以及构件类型等信息可由有限元模型直接获得，这些信息反

映了结构的基本几何拓扑和构件组成方式。若仅依赖传感器时序数据进行损伤判别，模型容易受到噪声、测点布置和局部响应异常的影响；而结构图分支能够为后续双图融合提供明确的空间参考，使传感器特征在进入分类阶段前具有可依托的结构载体。如图 2.7 所示，本文将有限元模型抽象为结构图：$G_{str}=\left(V_{str},E_{str},X_{str},E_{attr}\right)$，其中，$V_{str}$ 表示结构节点集合，E_{str} 表示由梁、柱、斜撑等构件连接形成的边集合，X_{str} 和 E_{attr} 分别表示节点特征矩阵与边特征矩阵。结构图的拓扑连接关系由有限元模型中的单元连接关系确定，因此其邻接矩阵不随单个输入样本变化，而是作为模型中的稳定结构先验参与后续特征交互。

对于结构图中的任意节点 v_i，其节点特征主要由三类信息构成：节点空间坐标、模态残差信息和模态能量信息。节点空间坐标用于描述该节点在整体结构中的几何位置；模态残差用于表征当前状态相对于健康基准状态的模态变化；模态能量信息用于补充节点在结构振动形态中的参与程度。节点特征可统一表示为：$x_i^{str}=\left[q_i \| \Delta\phi_i \| p_i\right]$，其中，$p_i$ 为节点坐标，$\Delta\phi_i$ 为节点模态残差向量，q_i 表示与模态能量或节点状态相关的补充特征，$\|$ 表示特征拼接。

对于结构图中的任意边，其边特征 e_{ij}^{attr} 用于描述连接节点 i 与节点 j 的构件属性。本文引入构件类型、空间位置和拓扑属性等信息，以增强结构图对不同构件关系的表达能力。边特征可表示为：$e_{ij}^{attr}=\left[t_{ij} \| c_{ij} \| r_{ij}\right]$，其中，$t_{ij}$ 表示构件类型编码，如梁、柱或斜撑；c_{ij} 表示构件中点坐标或方向相关信息；r_{ij} 表示与节点散度的和差特征。

在进入后续双图融合之前，结构图分支首先对节点特征和边特征进行维度统一。对于节点特征，采用线性映射和归一化操作获得结构节点嵌入：$h_i^{str}=LayerNorm\left(W_x x_i^{str}+b_x\right)$，对于边特征，同样采用映射函数得到边状态初始表示：$z_{ij}^{str}=LayerNorm\left(W_e e_{ij}^{str}+b_e\right)$，其中，$LayerNorm$ 表示归一化操作，W_x、W_e、b_x、b_e 为可学习参数。

结构图分支侧重描述结构本身的空间拓扑与基准物理属性。其输出的结构节点嵌入 h_i^{str} 和边状态初始表示 z_{ij}^{str} 分别作为后续交叉注意力融合和边特征学习模块的输入。通过这一设计，模型能够在利用传感器动态响应信息的同时，保留结构有限元模型提供的几何连接关系与模态先验，从而避免完全依赖数据相关性导致的空间表征不稳定问题。

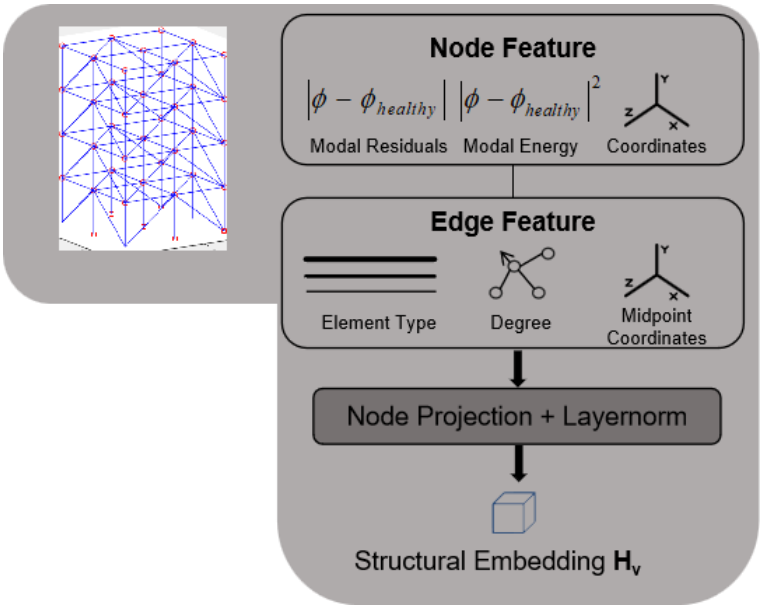


图 2.7 结构物理图架构示意图

2.4.4 基于软距离偏置的异构双图交叉注意力融合模块

在分别获得结构图节点特征与传感器图节点特征后，需要进一步建立两类特征之间的交互关系。由于结构图节点与传感器节点在数量、空间位置和特征语义上并不一致，若直接进行拼接或加权相加，难以充分表达二者之间的对应关系。因此，本文引入交叉注意力机制，使结构图节点能够根据自身特征从传感器图中选择性聚合相关的动态响应信息。其架构如图 2.8 所示。

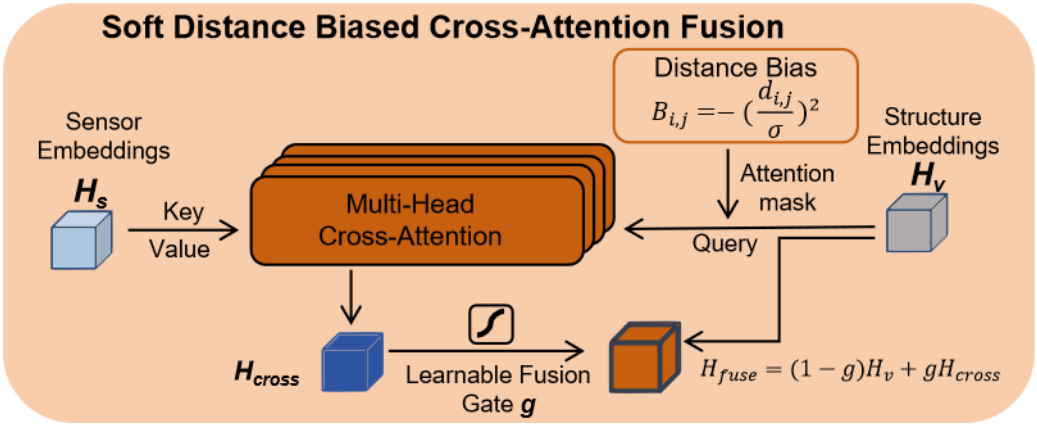


图 2.8 Cross-Attention 架构示意图

设结构图节点特征为 H_{str}，传感器图节点特征为 H_{sen}，则交叉注意力中的查询、键和值分别定义为：

$$Q = H_{str}W_Q,\quad K = H_{sen}W_K,\quad V = H_{sen}W_V \tag{2.34}$$

其中，W_Q、W_K 和 W_V 为可学习映射矩阵。为避免注意力权重完全由特征相似性决定，本文进一步引入基于空间距离的软偏置项。设第 i 个结构节点与第 j 个传感器节点之间的欧氏距离为 d_{ij}，则距离偏置定义为：

$$Bias_{ij} = -\left(\frac{d_{ij}}{\sigma_{dist}}\right)^2 \tag{2.35}$$

其中，σ 为距离尺度参数。该偏置项以连续衰减的方式调节跨图注意力权重，使空间距离较近的节点对在注意力计算中具有更高的初始权重，同时仍保留远距离节点通过特征相似性参与信息交互的可能性。加入软距离偏置后的交叉注意力计算为：

$$H_{cross} = Softmax\left(\frac{QK^T + Bias_{ij}}{\sqrt{d}}\right)V \tag{2.36}$$

其中，d 为特征维度。与硬距离截断相比，软距离偏置不会直接切断远距离节点之间的信息通路，而是以权重衰减的方式引入空间先验，从而提高跨图特征匹配的稳定性。

获得交叉注意力输出后，本文进一步采用门控融合机制平衡结构原始表征与跨图响应特征。门控权重与最终融合特征定义为：

$$G = \sigma\left(MLP\left(H_{str}\right)\right) \tag{2.37}$$

$$H_{fuse} = LayerNorm\left[\left(1-G\right)\odot H_{str} + G\odot H_{cross}\right] \tag{2.38}$$

通过该机制，模型能够在保留结构图原始信息的同时，引入传感器图中的动态响应特征，为后续边状态更新与楼层级损伤判别提供融合表示。

2.4.5 基于边特征学习的楼层级损伤判别模块

经过交叉注意力融合后，结构节点特征已经包含来自传感器支路的动态响应信息。为进一步增强模型对节点间关系变化的表达能力，本文在结构图上引入边特征学习机制。与仅更新节点特征的常规图神经网络不同，该模块将边特征视为可更新状态，使边属性能够随节点表示共同参与后续消息传递。其架构如图 2.9 所示。

设第 l 层中节点 i 和节点 j 的特征分别为 $h_i^{(l)}$ 和 $h_j^{(l)}$，边的状态为 $e_{ij}^{(l)}$。边状态更新可表示为：

$$\Delta e_{ij}^{(l)} = MLP_e\left(e_{ij}^{(l)} \| \, h_i^{(l)} \| \, h_j^{(l)}\right) \tag{2.39}$$

$$e_{ij}^{(l+1)} = LayerNorm\left(e_{ij}^{(l)} + \Delta e_{ij}^{(l)}\right) \tag{2.40}$$

该设计使边特征不再只是静态输入，而是能够根据相邻节点状态进行自适应调整。在获得更新后的边状态后，节点特征通过带边属性的 GATv2 进行更新：

$$\Delta h_i^{(l)} = GATv2\left(h_i^{(l)}, \left\{h_j^{(l)}, e_{ij}^{(l+1)} \mid j \in \mathcal{N}(i)\right\}\right) \tag{2.41}$$

$$h_i^{(l+1)} = GELU\left[LayerNorm\left(h_i^{(l)} + \Delta h_i^{(l)}\right)\right] \tag{2.42}$$

其中，$\mathcal{N}(i)$表示节点 i的邻域集合。通过这种方式，更新后的边状态能够参与节点间消息传递，从而增强模型对结构图中连接关系变化的表征能力。本文堆叠两层边特征学习图网络，以逐步细化结构节点与边的联合表示。

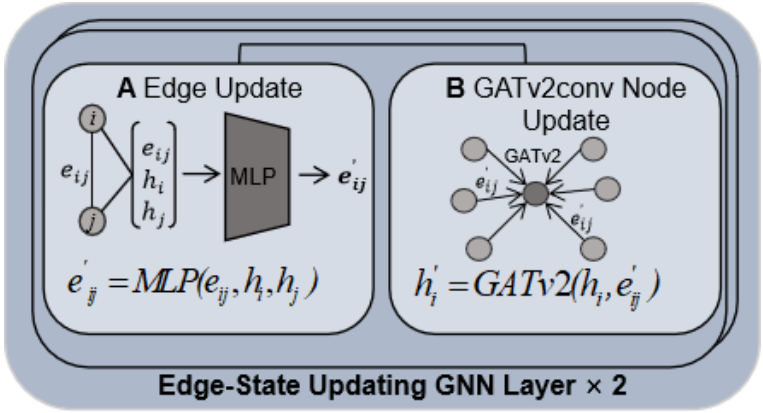


图 2.9 Edge-State Updating GNN 架构示意图

楼层级注意力池化：在 ASCE Benchmark 基准问题中，我们实施了分层池化策略：首先，对于层高为 H_{story} 的规则建筑，映射关系可定义为 $k = z_i / H_{\text{story}}$ 。这一步骤将全图节点集划分为 K 个互不重叠的楼层子集 $V_k = \{v_i \mid \mathcal{M}(v_i) = S_k\}$ 。

其次，考虑到在同一楼层内，不同节点对损伤的敏感度差异巨大。因此，我们对每个楼层子集 V_k 采用自适应注意力池化：

$$s_i = \sigma_{\text{gate}}\left(MLP_{pool}(h_i)\right) \tag{2.43}$$

$$h_{S_k} = \sum_{v_i \in V_k} softmax(s_i) \cdot h_i \tag{2.44}$$

其中，s_i 为节点 i 的损伤显著性得分。Softmax 操作在楼层子集 V_k 内部进行归一化。该机制能够自动关注该楼层中特征突变最剧烈的关键节点，滤除背景噪声，生成一个能够概括该楼层健康状态的特征向量 $h_{S_k} \in R^{d_{\text{model}}}$ 。本文在多任务分类头中设计了基于一维卷积的上下文混合机制。该操作使得第 i 层的最终判别特征不仅源于本层信息，还融合了第 $i-1$ 层与 $i+1$ 层的上下文特征。

$$H_{story} = \sigma\left(Conv1d_{k=3}\left(h_{S_k}\right)\right) \tag{2.45}$$

综上所述，通过显式边更新层的显式边更新与楼层级注意力池化，模型实现了从微观构件状态推断宏观楼层损伤的跨尺度建模。

2.5 本章小结

本章围绕数物双驱异构双图神经网络（DP-HDGNN）的理论基础与模型构建展开，重点解决结构物理信息与传感器响应数据如何在统一网络框架中协同表征的问题。主要工作可概括如下。

1. 梳理了图神经网络的基本理论，为结构图与传感器图建模提供基础

本章首先介绍了图数据表示、邻接矩阵、节点特征、边特征以及图拉普拉斯等基本概念，并进一步说明了谱域图卷积、空间域消息传递和图注意力机制的基本原理。其中，谱域图卷积为理解图结构上的特征传播提供理论背景，空间域消息传递机制为节点与邻域之间的信息聚合提供统一计算形式，图注意力机制则为后续动态邻域权重分配和异构特征交互提供了方法基础。由此，结构节点、构件边属性与传感器响应特征能够在图学习框架下进行统一表达。

2. 明确了时序特征编码与注意力机制在本文模型中的作用

针对结构振动响应具有长时程、高采样率和非平稳等特点，本章比较了循环神经网络、长短期记忆网络和时序卷积网络的基本特征，并采用 TCN-Encoder 作为传感器响应的多尺度时序编码工具。TCN 通过膨胀卷积扩大时间感受野，能够在较高并行效率下提取局部瞬态波动与长时程响应变化。同时，本章介绍了自注意力与交叉注意力机制，说明其能够通过查询、键和值之间的匹配关系建立不同特征集合之间的软关联，为传感器观测空间与结构物理空间之间的特征融合提供理论依据。

3. 构建了结构物理图与动态传感器图协同建模的 DP-HDGNN 架构

本章提出的 DP-HDGNN 将结构物理信息与传感器响应数据分别组织为两类图结构。结构物理图用于表征结构节点、构件连接、模态特征和边属性等物理先验，动态传感器图则根据传感器振动响应自适应刻画测点之间的动态相关性。与简单特征拼接不同，该模型将物理信息和观测数据分别保留在对应的特征空间中，为后续交叉融合提供更加明确的结构载体和数据表征。

综上，本章完成了 DP-HDGNN 从理论基础到模型架构的系统构建。该模型将结构物理图作为稳定物理先验，将动态传感器图作为响应数据表征，并通过交叉注意力实现多模态信息的融合，为后续损伤定位实验提供了模型基础。下一章将首先通过 T 型钢架算例说明图拓扑建模的必要性，并进一步基于 IASC-ASCE 框架结构验证所提模型在楼层级复合损伤定位任务中的有效性。

第3章 基于数物双驱异构双图神经网络损伤定位方法有效性验证

3.1 引言

第二章构建了数物双驱异构双图神经网络的理论基础与模型架构，详细阐述了结构物理图、动态传感器图、交叉注意力融合和边特征学习等模块的计算流程。然而，模型架构不能仅停留在理论层面，还需要通过结构算例进行验证。对于结构损伤定位任务而言，模型不仅需要从多测点振动响应中提取损伤敏感特征，还需要区分真实损伤区域与由结构耦合引起的远端响应扰动。因此，本章围绕数值仿真条件下的框架结构损伤定位问题，验证 DP-HDGNN 在复合损伤、噪声干扰和多模型对比条件下的识别能力。

在进入标准框架结构验证之前，本章首先引入 T 型钢架算例，用于说明结构物理先验约束在复杂结构损伤定位中的必要性。该算例具有典型的分叉连接与左右对称悬臂特征，当局部构件发生刚度折减时，损伤扰动不仅会影响受损区域附近的动力响应，也可能通过中心连接节点传递至远端健康分支，使非损伤区域的加速度响应呈现类似损伤的变化。对于仅依赖时序特征的模型而言，这类空间耦合响应容易被误判为异地损伤。因此，T 型钢架算例的作用不是作为本章主体实验，而是作为机理性验证，用于说明复杂结构损伤定位需要同时考虑结构拓扑约束和测点响应动态相关性。

在此基础上，本章选取 IASC-ASCE 基准框架作为主要验证平台。本文基于对应的有限元模型构建包含单层、双层和多层复合损伤的仿真数据集，并结合不同激励形式、噪声水平和刚度折减程度生成多测点加速度响应。随后，将有限元拓扑、构件边属性、模态特征和传感器时程响应统一保存为双图样本，用于 DP-HDGNN 的训练、验证与测试。

本章主要开展以下工作：首先，通过 T 型钢架算例分析局部损伤引发的空间耦合响应及其对纯时序模型的干扰作用，说明引入图拓扑约束和动态测点关联建模的必要性；其次，基于 IASC-ASCE 框架结构构建楼层级复合损伤数据集，并转化为结构图与动态传感器图的数据形式；再次，在统一训练策略和评价指标下，将 DP-HDGNN 与 MLP、1D-CNN、TCN-GCN 和 TCN-GAT 等模型进行对比，分析所提模型在楼层级损伤定位任务中的性能优势；最后，通过核心模块消融实验考察动态传感器图、交叉注意力融合和边特征学习等模块对模型性能的贡献。

3.2 异构双图网络引入的必要性验证

3.2.1 T 型钢架模型与损伤工况

为揭示复杂结构中局部损伤与远端响应之间的耦合关系，本文构建 T 型分叉平面钢架数值算例。该结构由底部固接主立柱和左右对称悬臂横梁组成，在中心节点处形成分叉连接区域。与规则剪切型框架相比，该结构的响应传播路径更具非均匀性和对称耦合特征，适合用于分析纯时序模型在损伤定位中产生异地虚警的原因。表 3.1 给出了该算例的主要设置。

表 3.1 T 型钢架参数设置表

参数	具体设置
单元类型	欧拉伯努利单元
节点与单元	13 个节点，12 个单元
构件参数	国标 24a 工字钢
边界条件	底部主立柱固接
拓扑特征	主立柱与左右对称悬臂横梁在节点 5 处交汇
激励方式	节点 3 与节点 5 施加双点独立宽频非平稳随机激励
传感器布置	节点 3、5、7、9、11、13 布设 6 个虚拟加速度传感器
损伤形式	随机选取 1-3 个单元进行刚度折减
损伤程度	刚度折减 10%—40%
噪声设置	SNR = 5%—15%
对比模型	LSTM、TCN-GAT、DP-HDGNN

其中，LSTM 用于表征仅依赖多测点时序响应进行损伤判别的纯数据驱动方法；TCN-GAT 在时序编码基础上引入固定图拓扑，用于表征常规图时空建模方法；DP-HDGNN 则进一步融合动态传感器图与结构图信息，用于考察异构双图建模对异地虚警的抑制能力。通过三类模型的对比，可以从算例层面说明图拓扑信息和动态响应关联对复杂结构损伤定位的重要作用。

3.2.2 局部刚度退化引起的内力重分布与损伤误判分析

为进一步揭示分叉拓扑结构中局部损伤对远端测点响应的影响，本节以 T 型钢架算例中的典型单损伤工况为例开展分析。如图 3.1 所示，选取左侧分支第 7 号单元发生刚度折减的工况作为研究对象，刚度折减程度设定为 30%。在激励

设置上，为突出局部损伤扰动在结构拓扑中的传播特征，仅保留节点 5 处的竖向宽频随机激励，并提取左侧损伤邻近区域与右侧健康分支测点的竖向加速度响应进行对比分析。由于该 T 型钢架在几何形式上具有左右分支近似对称的特点，右侧健康分支虽然未发生局部刚度退化，但其动力响应仍可能受到中心分叉节点处响应重分布的影响。

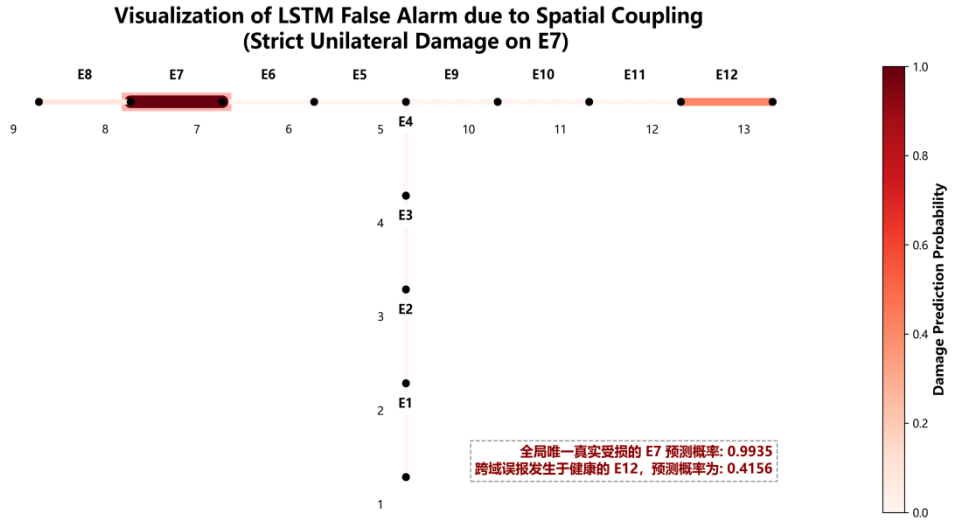


图 3.1 左侧悬臂受损工况真实物理拓扑图

从结构响应机理上看，局部构件刚度折减会改变损伤区域附近的局部动力特性，但这种变化并不会完全限制在受损单元附近。对于 T 型分叉钢架而言，左右悬臂分支通过中心节点与主立柱连接，局部刚度退化会改变分叉节点处的内力传递关系和响应分配模式，使扰动沿结构连接路径传递至远端健康分支。因此，当左侧分支发生刚度折减后，右侧未受损分支的加速度响应仍可能在幅值、相位或频带能量上出现间接变化。该现象表明，健康测点中可能存在由内力重分配引起的伪损伤特征。

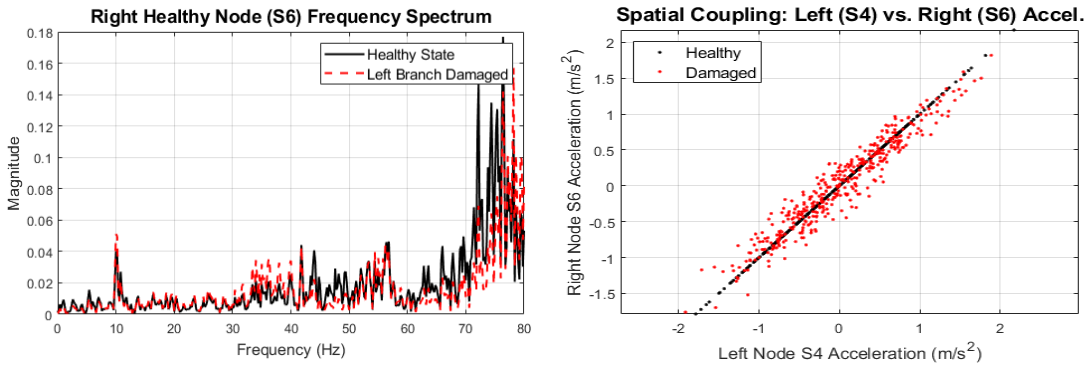


图 3.2 健康状态与左侧分支损伤后右侧节点特征示意图

由图 3.2 可以看出，在第 7 号单元发生刚度折减后，右侧健康分支测点的响

应并非保持完全稳定，而是出现了与左侧损伤分支相似的局部波动或相关性变化。对于时序模型而言，这种远端健康测点中的异常响应容易被错误解释为该区域存在损伤，从而导致异地虚警。

这一现象揭示了复杂框架结构损伤定位中的一个关键问题：损伤定位并不是单纯的时间序列分类任务，而是同时受到局部刚度退化、结构连接路径和多测点动态相关性的共同影响。纯时序模型虽然能够从加速度信号中提取时间依赖特征，但其缺乏对结构空间拓扑的显式约束，因此在具有分叉路径、对称分支和远端耦合响应的结构中，容易产生损伤位置误判。

3.2.3 异构双图结构引入必要性的模型对比验证

为进一步验证图拓扑信息对复杂结构损伤定位的作用，本节在 T 型钢架数据集上选取 LSTM、TCN-GAT 与 DP-HDGNN 三类模型进行对比分析。前两种基线模型架构如图 3.2 与图 3.3 所示，三类模型分别代表不同层次的建模方式：LSTM 表征纯时序建模方法，主要依靠隐藏状态递推提取多测点响应中的时间依赖特征；TCN-GAT 在时序编码基础上引入图注意力聚合，用于表征静态或固定图拓扑约束下的时空建模方法；DP-HDGNN 则进一步构建结构图与动态传感器图，并通过交叉注意力机制实现双图特征融合，用于考察异构双图建模对异地虚警的抑制能力。

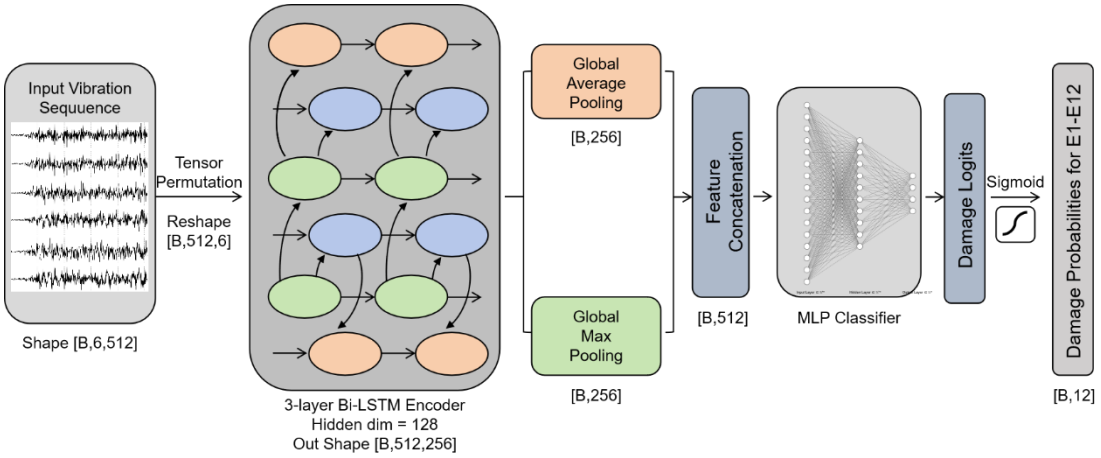


图 3.3 时序基线 LSTM 架构示意图

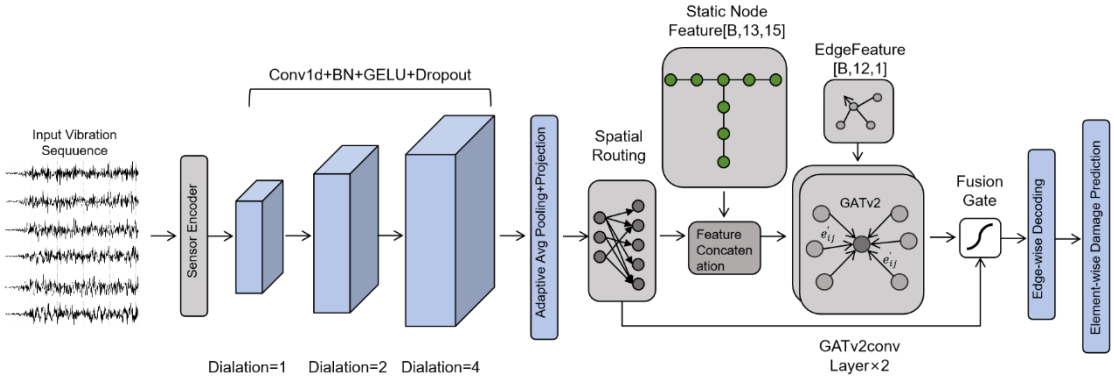


图 3.4 静态图基线 TCN-GAT 架构示意图

在实验设置上，三类模型均采用相同的训练集、验证集与测试集划分方式，并使用相同的输入时程窗口和损伤标签定义。如表 3.2 所示

表 3.2 LSTM 与 TCN-GAT 模型参数示意表

参数类别	超参数名称	LSTM	TCN-GAT
输入与输出	Number of sensors	6	6
	Sequence length	512	512
	Number of elements	12	12
网络容量与维度	Hidden dim	128	128
	Num layers	3	2
	TCN hidden	/	32/64/128
	TCN dilation	/	1/2/4
图拓扑构建	Static node feature dim	/	15
	GAT input feature dim		143
	Edge feature dim	/	1
	GAT heads	/	4
优化器与训练策略	Optimizer	AdamW	AdamW
	Learning rate	0.0005	0.0005
	Weight decay	0.0001	0.0001
	Loss function	BCE With Logits Loss	BCE With Logits Loss
	Batch size	32	32
	Dropout	0.3	0.3
	Epochs	150	150

续表

参数类别	超参数名称	LSTM	TCN-GAT
	Patience	10	10
	Scheduler	Cosine Annealing LR	Cosine Annealing LR

在上述统一实验设定下，本文进一步将不同模型的预测结果投影至 T 型钢架的杆单元空间中，以分析各模型在复杂分叉拓扑下的损伤定位能力。为此，本文选取左侧悬臂分支受损工况作为典型样本进行可视化分析，其中真实损伤位置为第 E8 单元，右侧对称健康区域中的 E12 单元用于观察远端耦合响应是否诱发虚警。

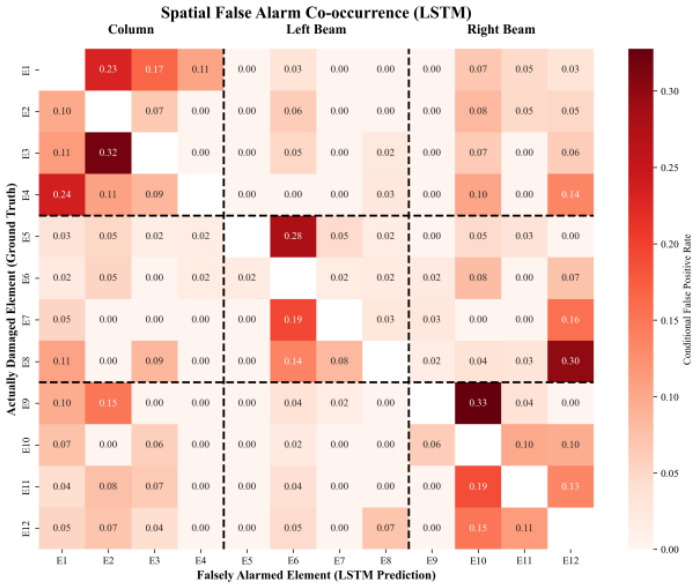


图 3.5 LSTM 虚警率单元热力图

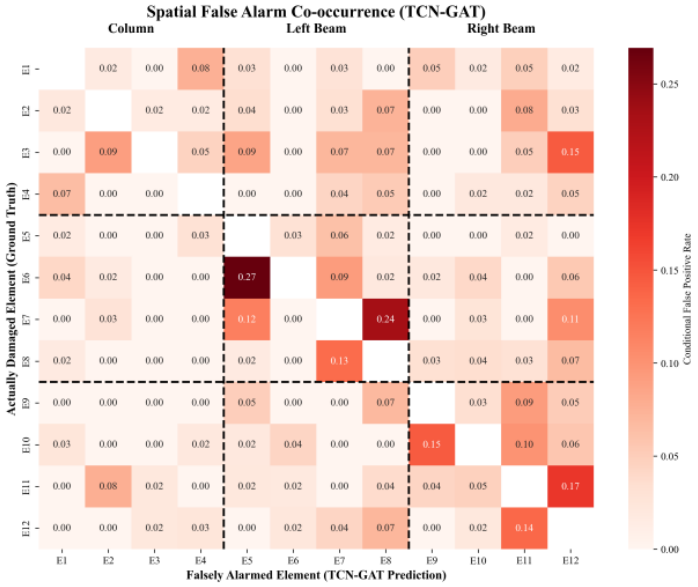


图 3.6 TCN-GAT 虚警率单元热力图

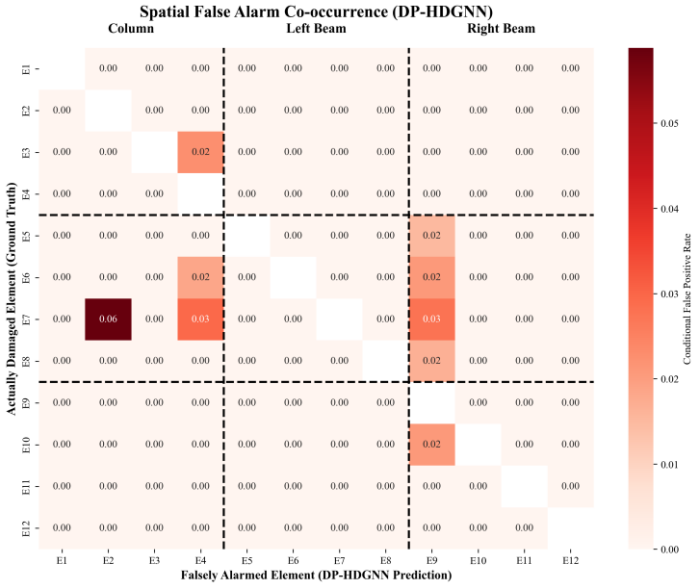


图 3.7 DP-HDGNN 模型虚警率单元热力图

在上述统一实验设定下，本文将三类模型的预测结果映射至 T 型钢架的杆单元空间中，并统计不同真实损伤单元下模型在其他单元上的虚警共现情况，结果如图 3.5 至图 3.7 所示。对于 LSTM 模型，由于其仅依赖多测点加速度序列中的时间依赖关系进行损伤判别，缺乏对结构连接关系和构件空间位置的显式约束，因此在多个工况下出现了明显的远端虚警。以 E8 单元受损为例，右侧健康分支中的 E12 单元误判概率达到 30%，说明纯时序模型容易将由分叉节点耦合引起的被动响应变化解释为真实损伤特征。

引入静态图拓扑后的 TCN-GAT 模型在空间虚警抑制方面表现出明显改善。相较于 LSTM，TCN-GAT 的高虚警区域显著收缩，E8 损伤工况下 E12 单元的误判概率由 30% 降低至 7%。这一结果说明，结构图物理先验约束能够有效削弱由时序特征相似性导致的异地虚警，使预测结果集中于真实损伤单元及其邻近区域。然而，TCN-GAT 依赖固定图拓扑，难以刻画损伤发生后传感器相关性随结构状态变化产生的动态调整，因此在部分相邻单元或对称区域仍存在局部误判。

相比之下，DP-HDGNN 的虚警共现热力图进一步表现出更稳定的空间收敛特征。模型预测结果主要集中于真实损伤单元及其邻近区域，远端健康分支上的虚警响应明显降低。这说明 DP-HDGNN 并非简单地在固定拓扑上进行特征平滑，而是同时利用结构物理图提供的稳定空间先验和动态传感器图提供的样本相关性信息，通过交叉注意力机制实现双图特征融合，从而更有效地区分真实损伤区域与远端耦合扰动区域。

综上，T 型钢架预验证表明，复杂结构中的损伤定位不能被简单视为多通道时间序列分类任务。纯时序模型容易受到空间耦合响应干扰而产生异地虚警；静态图模型能够引入拓扑约束并降低误判，但对损伤诱导的动态相关性变化表达不足；DP-HDGNN 通过结构图与动态传感器图的协同建模，能够进一步提升空间定位稳定性。基于这一认识，下一节将以 IASC-ASCE 标准框架结构为主要验证对象，从复合损伤、噪声干扰、长尾分布、基线对比和消融实验等方面系统评估所提模型的损伤识别性能。

3.3 IASC-ASCE 基准数据集构建与预处理

为了全面模拟真实土木工程结构在服役期内可能遭受的各类结构变异，准确提取蕴含在振动响应中的微弱损伤特征，建立一套高保真度、物理机制明确且具有代表性的数据集是开展深度学习网络训练的首要前提。本节将详细介绍作为数据源的 IASC-ASCE SHM 基准结构[67]，深入探讨其物理构造、有限元模型以及损伤模拟的内在机理。

3.3.1 IASC-ASCE SHM 基准结构概述

IASC-ASCE 结构是一个四层、两跨乘以两跨的三维缩尺钢框架结构模型之上。该结构的有限元模型主要包括两个阶段（Phase I 与 Phase II），其中 Phase I 主要侧重于结构模型对于预设定的六种损伤模式的响应，而 Phase II 则是侧重于自定义损伤模式获得结构的响应，其复杂度和对真实工程环境的模拟逼真度逐级

递增。本文的仿真数据集主要立足于 Phase I 与 Phase II 的仿真模型框架，旨在最大程度贴近结构损伤的客观规律。

1. 结构的物理几何构造与材料特性

该基准结构被设计为一个具有典型剪切型层间变形特征的三维钢结构框架。其整体平面尺寸为2.5m × 2.5m，总高度为 3.6m，结构共分为四层，每一层的层高均为 0.9m。

楼面系统由分布在各层钢梁上的钢板或附加质量块构成，第一层的四个楼板重 800kg；第二、三层楼板重达 600kg；第四层楼板为了满足不对称加载的要求，重量分为两种情况：一是四个楼板均为 400kg，二是三个 400kg 的楼板与一个 550kg 的楼板。在材料属性方面，所有钢材的弹性模量 E 均设定为典型的 200GPa，泊松比μ为 0.3，屈服强度均为 300Mpa。

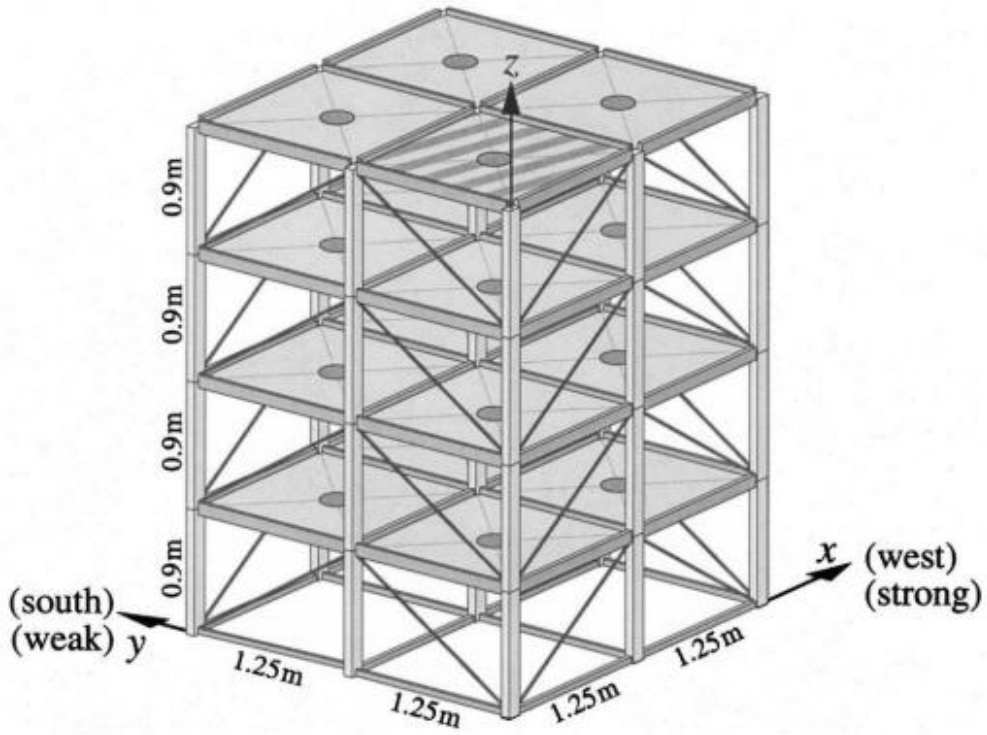


图 3.8 ASCE 模型示意图

2. 结构动力学仿真模型的构建

为了模拟结构在复杂荷载下的响应，ASCE 开发了 120-DOF 的高保真有限元模型。在该模型中所有梁柱均采用经典的三维欧拉-伯努利梁单元或铁木辛柯梁单元进行离散，考虑了弯曲、剪切以及轴向变形的耦合。斜向支撑被模拟为只承受轴向拉压力的桁架单元。

在 phase I 阶段仿真数据集之中，模型主要集中关注以下六种损伤工况

表 3.3 不同损伤工况的具体描述

损伤模式	损伤情况
损伤模式 1	第一层所有斜撑移除
损伤模式 2	第一、三层所有斜撑移除
损伤模式 3	第一层西南角房间斜撑移除
损伤模式 4	第一、三层西南角房间斜撑移除
损伤模式 5	第一、三层西南角房间斜撑移除、第一层西南方向梁柱节点螺栓松弛
损伤模式 6	第一层所有斜撑刚度折减 2/3

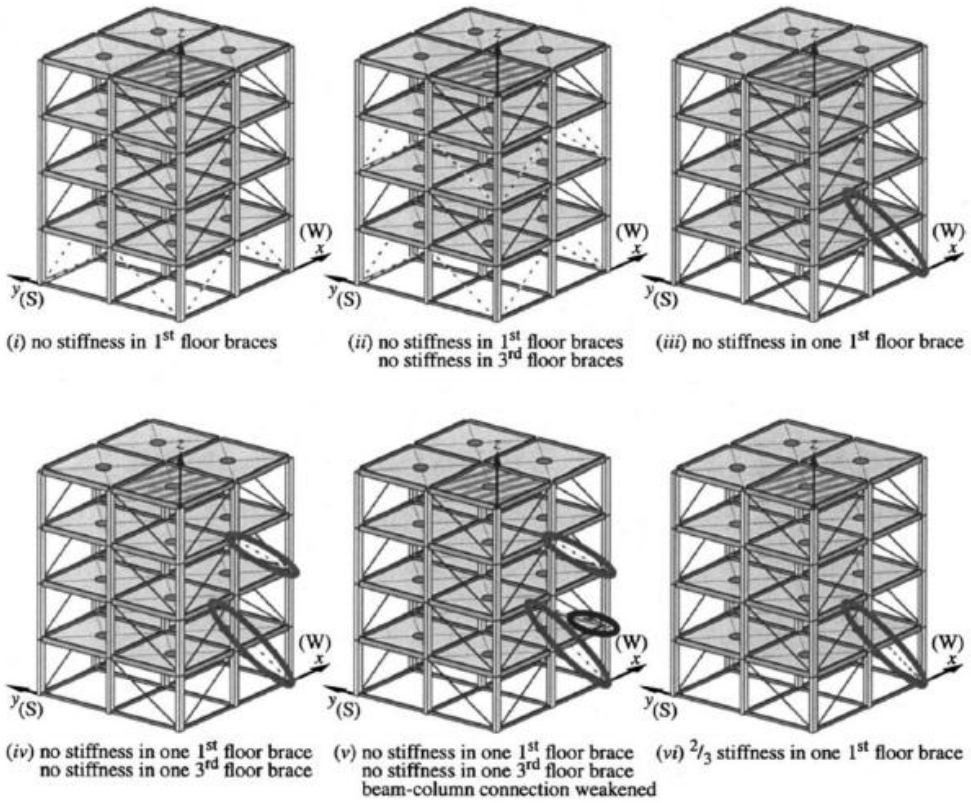


图 3.9 ASCE 六种损伤模式示意图

3.3.2 模拟数据集损伤工况设计与时频数据生成

为构建用于框架结构损伤定位的仿真数据集，本文基于 IASC-ASCE 120 自由度有限元模型开展动力时程分析。数据生成过程主要包括损伤工况设定、随机激励输入、动力响应求解和观测噪声叠加四个环节。给出了本节仿真数据生成的主要设置。

表 3.4 ASCE 仿真数据集参数设置

参数	设置
损伤类型	单层损伤 2000 组，双层损伤 1500 组，多层复合损伤 1500 组
损伤实现方式	通过构件刚度折减模拟局部刚度退化
主要退化构件	以斜撑刚度退化为主，梁柱轻微退化为辅
激励类型	平稳高斯白噪声、非平稳包络随机激励
采样设置	20 s，200 Hz
噪声设置	SNR = 5%~20%

本研究在 MATLAB 数值平台中，引入单元刚度折减系数。对于结构中的任意第 e 个单元，其损伤后的单元刚度矩阵 K_e^d 可表示为：

$$K_e^d = (1-\alpha_e) K_e \tag{3.1}$$

其中，K_e 为无损状态下的初始单元刚度矩阵；$\alpha_e \in [0,1]$ 为该单元的刚度折减系数，$\alpha_e = 0$ 表示绝对健康，α_e 大代表损伤越严重。对应的多种损伤类型如图 3.10 所示。

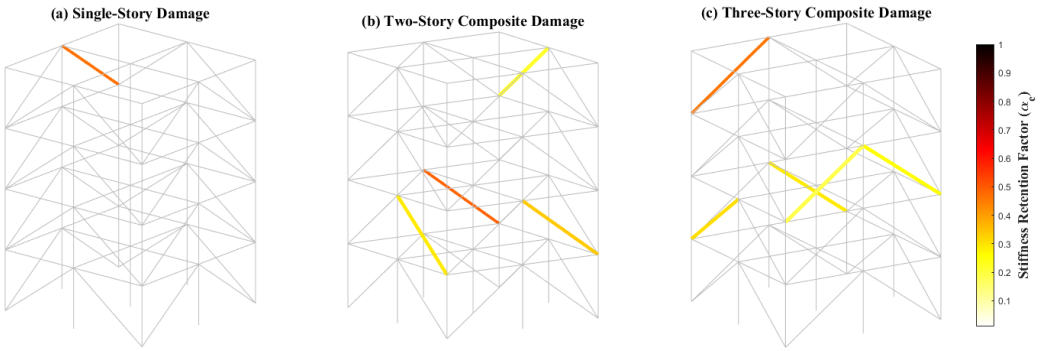


图 3.10 ASCE 模型复合损伤工况示意图

所有生成的损伤样本均被赋予一个全局 One-Hot 编码标签向量 $Y \in R^4$，每一维精确对应一层的健康或损伤状态，确保网络在训练时具有明确的楼层级监督信号。

在激励输入方面，为提高数据集对复杂工况的覆盖能力，本文采用平稳高斯白噪声与非平稳随机激励两类输入形式。前者用于模拟常规环境激励下的宽频带随机扰动，后者通过时变包络调制随机噪声，用于模拟能量随时间变化的非平稳动力输入。两类激励在数据生成过程中随机组合，使模型能够接触到不同频率组成和能量演化特征的结构响应。

在动力响应求解方面，将损伤后的质量矩阵、阻尼矩阵和刚度矩阵代入结构

运动方程，通过数值积分获得各测点连续加速度时程。每组仿真样本生成 20 s 的动力响应，采样频率为 200 Hz。为进一步模拟实际监测中的测量误差，在纯净加速度响应上叠加不同信噪比水平的高斯噪声，形成最终输入网络的观测信号。上述处理使数据集同时包含损伤位置、损伤程度、激励形式和噪声水平的变化，为后续模型训练与抗噪性能验证提供基础。

此外，在物理激励的非平稳性之上，还必须考虑传感器系统的固有测量误差，在数值积分生成的纯净加速度信号序列上，人为注入了不同信噪比的测量噪声。如图 3.11 所示，对于传感器获取的信号 $x_{clean}(t)$，加噪后的真实观测信号 $x_{obs}(t)$ 构造如下：

$$x_{obs}(t)=x_{clean}(t)+n_{noise}(t) \tag{3.2}$$

其中，$n_{noise}(t)$ 为服从 $\mathcal{N}(0,\sigma^2)$ 分布的高斯白噪声，其方差 σ^2 由指定的信噪比等级严格控制。这一处理使得仿真数据在统计分布上极大地向实际工程的低质量信号靠拢。

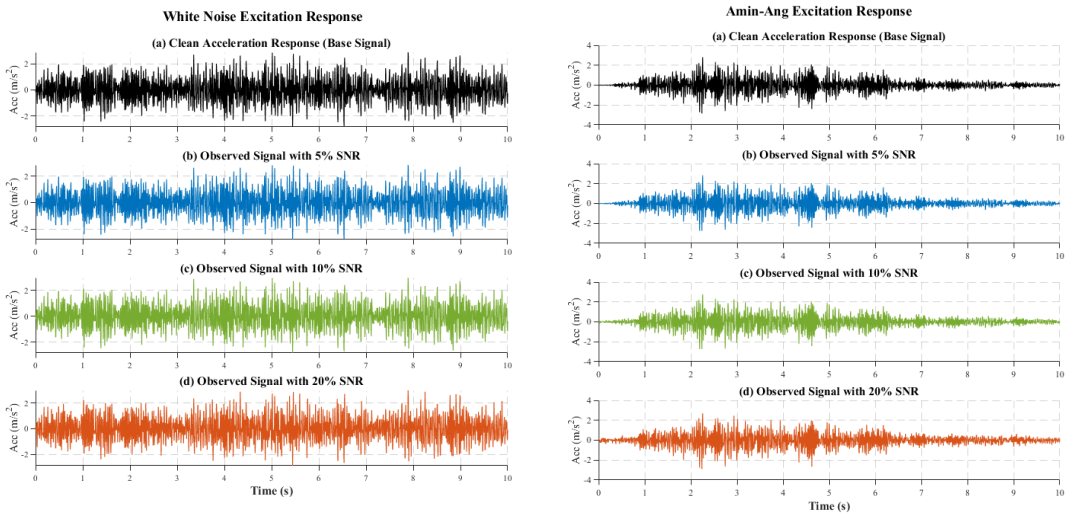


图 3.11 加速度信号不同噪声对比图

3.3.3 双图样本构建与节点—边特征构造

在完成损伤工况设定与动力响应生成后，需要进一步将连续加速度时程、有限元拓扑信息和模态特征统一封装为适用于 DP-HDGNN 输入的双图形式。与传统深度学习模型直接以多通道时程作为输入不同，本文所提出的模型同时利用结构图与传感器响应信息，因此数据预处理阶段需分别构造结构图特征、传感器时序输入以及楼层级损伤标签，具体的构造与计算方式在 2.4 节中已经给出。ASCE 双图样本的组成如表 3.5 所示

表 3.5 ASCE 双图样本组成与特征定义

输入类型	数据内容	特征组成	作用
结构图节点特征	有限元节点	节点坐标、前五阶模态残差、模态应变能	表征结构空间位置与模态变化
结构图边特征	有限元构件连接	构件类型、中点坐标、节点度数相关特征	表征构件属性与局部拓扑关系
传感器时序输入	加速度响应切片	各测点定长加速度时程	提供动态响应信息
传感器空间信息	测点坐标	传感器三维空间坐标	提供空间距离先验

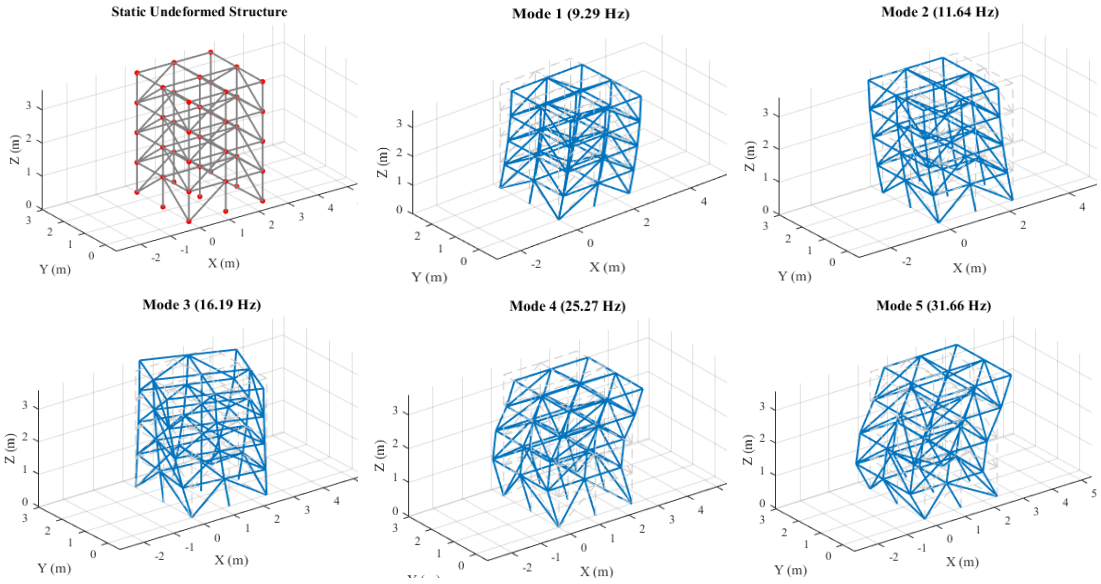


图 3.12 ASCE 有限元模型健康状态前五阶振型示意图

至此，ASCE 仿真数据被统一封装为包含结构图、传感器时序输入、传感器坐标和楼层级损伤标签的双图样本。该数据形式既保留了有限元模型提供的结构拓扑与模态先验，又保留了监测响应中的时序动力信息，为后续 DP-HDGNN 的训练、验证与测试提供了统一的数据基础。

3.4 模型训练策略与基线设置

在完成框架结构有限元动力响应生成、楼层级标签定义以及双图样本构造后，模型性能不仅取决于输入样本中结构物理信息与传感器响应信息的表达质量，还受到网络容量、优化器设置、损失函数设计和推断阶段决策阈值的影响。基于此，

本节进一步说明 DP-HDGNN 的训练环境、超参数设置、损失函数设计、后验阈值校准以及对比基线模型设置。

3.4.1 实验环境与网络超参数设置

1. 软硬件运行环境与数据划分预处理

本研究的所有模型搭建、训练与测试均在基于 Python 编程语言的深度学习框架 PyTorch 及其图神经网络扩展库 PyTorch Geometric(PyG)下完成。为保证张量矩阵运算与图卷积聚合的高效性，模型训练依托于支持 CUDA 加速的 GPU 硬件平台。实验采用的 CUDA 版本是 11.2，PyG 版本是 2.5.3，采用的显卡是 3060Ti，在确保实验可复现性的前提下，全局随机种子被严格固定为 42。

为了客观评估模型的泛化能力与损伤定位精度，本研究构建了互斥的训练集、验证集与测试集（Train/Val/Test）。具体而言，全部样本按照 8:1:1 的比例划分为训练集、验证集与测试集，对应样本数分别为 train、Val 与 Test。为避免信息泄露，同一组原始损伤工况经不同后处理得到的关联样本仅被划入同一数据子集，不跨训练、验证与测试集合重复出现。所有标准化统计量均仅由训练集计算，并用于验证集与测试集的归一化处理。

考虑到深度学习模型对输入特征尺度的敏感性，在将数据喂入网络之前，本研究执行了严格的全局标准化。为避免数据泄露，均值与标准差等统计特征仅在训练集上进行计算提取，随后应用至验证集与测试集中，以真实模拟模型在面对未知监测数据时的前向推理过程。

2. 核心网络架构超参数配置

DP-HDGNN 模型的网络容量需要兼顾局部高频特征的精细提取与全局图拓扑的高效传递。为此，本研究使用了 Optuna 超参数寻优的结果进行带入，实验结果如图 3.13 所示。

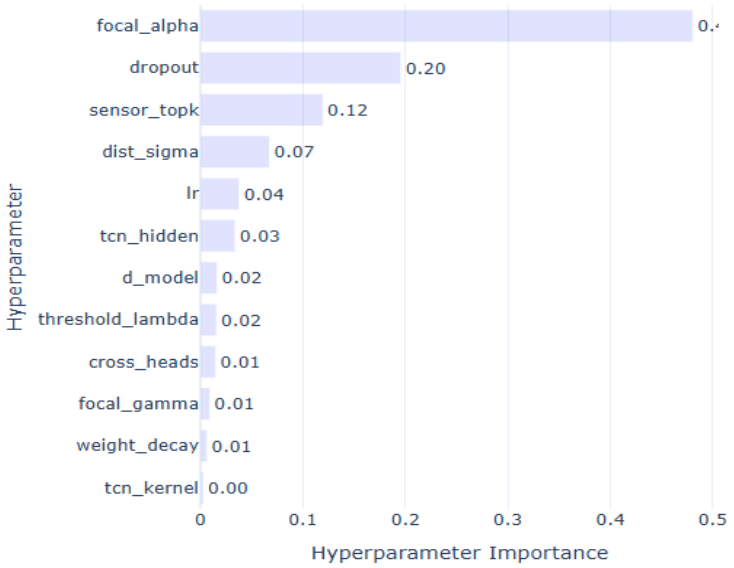


图 3.13 超参数敏感性分析

本研究最终确定的核心网络架构与优化器超参数如表 3.6 所示

表 3.6 DP-HDGNN 模型超参数

参数类别	超参数名称	设定值
网络容量与维度	D_model	224
	TCN_kernel	7
	TCN_hidden	64
	Cross_heads	4
图拓扑构建	Sensor_topk	3
	Dist_sigma	2
优化器与训练策略	Optimizer	AdamW
	Learning_rate	6.8×10^{-4}
	Weight_decay	3.5×10^{-4}
	Focal_alpha	0.65
	Focal_gamma	2.5
	Batchsize	64
	Dropout	0.2
	Epochs	100
	Patience	10

3. 损失函数重加权与优化策略

在真实的结构健康监测场景中，结构处于健康状态的样本数量往往远大于发生损伤的样本，这构成了典型的类别不平衡问题。若采用常规的交叉熵损失，网

络梯度易被海量“健康样本”所主导，导致模型对少数“损伤样本”的后验概率受到压制。

为此，本研究在监督学习阶段引入了二元焦点损失函数（Binary Focal Loss）以替代常规交叉损失熵。该损失函数在设计上包含了两个维度的惩罚机制：首先，针对模型末端多任务头输出的每一层二分类 Logits，引入类别平衡系数，在物理意义上相当于将健康类的基准权重设为 1.0 的同时，将损伤类的惩罚权重设定为 2.5，以此提升少数类的基础错判代价；更关键的是，该函数引入了动态聚焦调节因子。随着网络对大量健康样本的预测置信度逐渐升高，该调节因子会自动衰减这些易分样本在总损失中的梯度贡献比例。这种动静结合的重加权机制，有效避免了模型陷入虚假的高准确率陷阱，提升了网络对微弱异常信号及难分类边界的敏感度。

4. 基于验证集的后验决策阈值校准（Post-hoc Threshold Calibration）

在多标签损伤识别任务中，深度分类模型通常为每一个标签输出独立的后验概率，并通过设定判别阈值将连续概率转化为离散损伤标签。常用做法是采用固定阈值 0.5 进行判定，但在类别分布不均衡、不同楼层损伤样本数量差异较大或模型输出概率存在偏移时，统一阈值可能难以同时兼顾 Precision 与 Recall，进而导致少数损伤类漏报或健康类误报。多标签分类中的阈值选择研究表明，对不同标签设置独立阈值能够改善模型的预测性能；同时，F1 指标与决策阈值之间存在直接关系，可通过验证集搜索使 F1 得分最优的判别阈值[68]。

为了解决这一问题，本研究在模型完成初级训练后，引入了逐层解耦的后验决策阈值寻优机制。具体而言，模型在验证集上冻结网络参数并输出所有样本对于四个楼层的独立预测概率分布。随后，算法针对第一层至第四层，分别在的概率区间内以 0.01 为步长进行全域网格扫描。对于每一个候选阈值，实时计算该层在验证集上的二分类 Macro-F1Score。

最终，每一层都分别获得一个最优后验判别阈值。在随后的测试阶段，模型不再使用 0.5 盲判，而是利用这组最佳校准阈值来输出最终的离散化损伤标签。这一后置校准机制，在不增加任何网络参数量的前提下，极大程度地挖掘了 DP-HDGNN 模型在复合损伤工况下的定位潜力。

3.4.2 对比基线模型

为了量化本研究所提出的 DP-HDGNN 模型在复合损伤定位中的性能优势，实验部分严格遵循控制变量原则，选取了结构健康监测与深度学习领域中极具代表性的四种经典网络作为对比基线模型。这些模型涵盖了从纯时序数据驱动到基础空间拓扑聚合的不同阶段。

1. 多层感知机（MLP）

多层感知机是最基础的深度前馈人工神经网络。该模型不包含任何时域序列建模或空域图谱计算机制，直接将多通道的离散加速度时间序列展平为一维向量，通过多层全连接层的线性映射与非线性激活函数拟合损伤概率。其架构如图 3.14 所示。

选取此模型作为本实验的基线模型，旨在暴露当网络完全缺乏时序依赖感知与空间物理拓扑先验时，面对高维、强耦合且包含环境噪声的非平稳振动信号，纯粹依赖数据映射极易陷入维度灾难的后果。

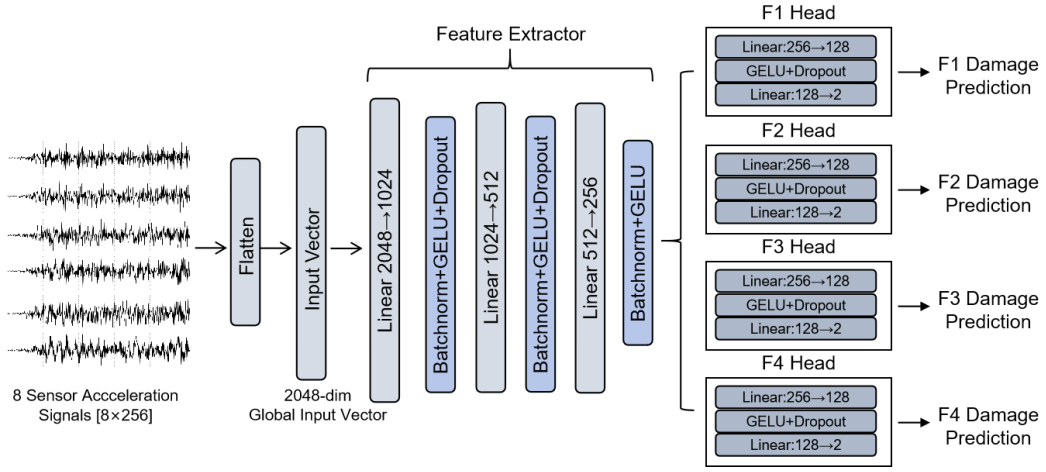


图 3.14 MLP 网络架构示意图

2. 一维卷积神经网络（1D-CNN）

一维卷积神经网络不包含任何图论或空间拓扑结构，直接将多通道的离散加速度时间序列作为输入，通过堆叠的一维卷积层与池化层提取高频动力学特征，最终通过全连接层输出楼层级损伤概率。其架构如图 3.15 所示

选取此模型为基线模型是为了验证在缺乏结构物理空间拓扑的情况下，仅依赖纯信号处理技术在应对复杂多层损伤时存在的性能瓶颈。

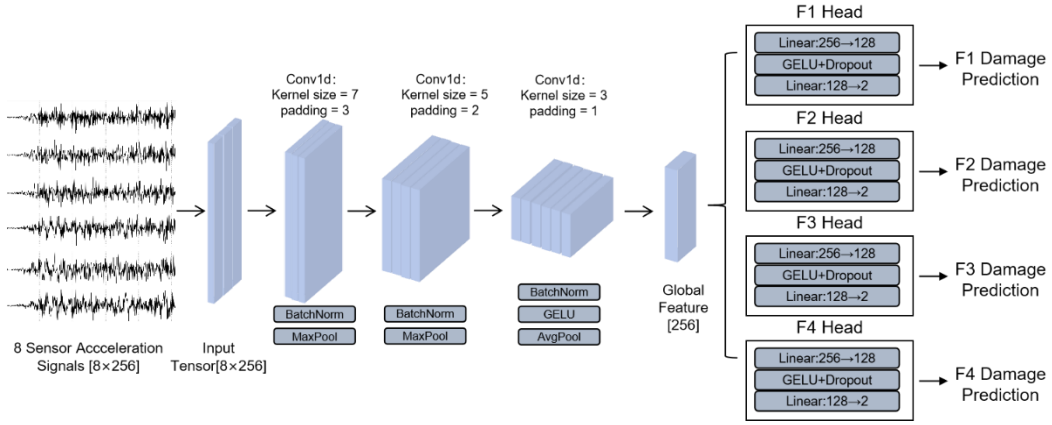


图 3.15 1D-CNN 网络架构示意图

3. 时序图卷积网络（TCN-GCN）

时序图卷积网络结合了时间卷积网络（TCN）与经典的谱域图卷积网络（GCN）。其架构如图 3.16 所示，为了保证特征提取能力的公平性，该基线模型采用了与本文模型完全相同的 TCN 编码器将时间序列映射为节点隐式特征，但在图拓扑聚合阶段，采用了传统的拉普拉斯平滑聚合。

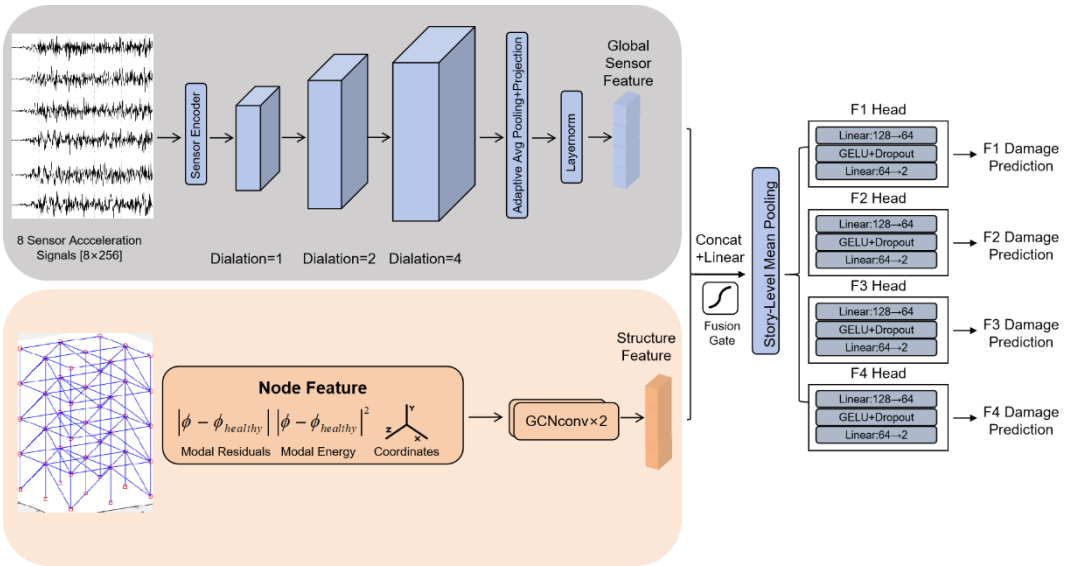


图 3.16 TCN-GCN 网络架构示意图

考虑到传统的 GCN 依赖固定的单一物理连通性图，且同等对待所有邻居节点。通过与该模型对比，旨在证明本研究所提出的“数据驱动动态传感器图”在提取损伤响应方面的必要性。

4. 时序图注意力网络（TCN-GAT）

该模型在 TCN-GCN 的基础上，将图卷积网络 GCN 更改为图注意力网络 GAT。其架构如图 3.17 所示，其能够基于节点特征的相似度动态分配邻居聚合

权重。

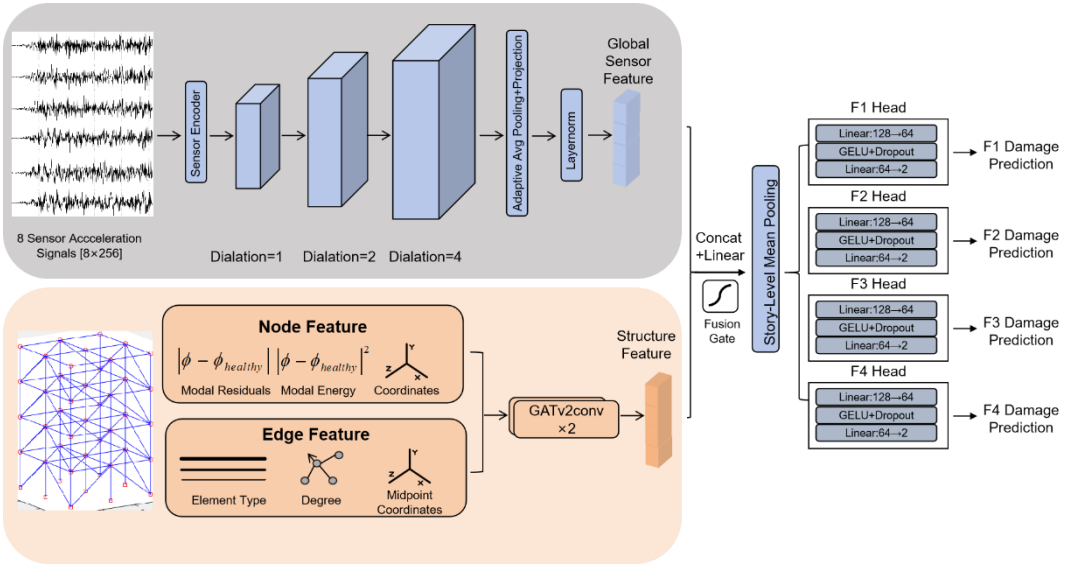


图 3.17 TCN-GAT 网络架构示意图

考虑到普通的 GAT 仅利用节点特征计算注意力，缺乏对物理距离的感知与边特征的显式更新。通过与该模型对比，旨在量化本文模型中软距离偏置与显式边更新层带来的性能增益。

在对比实验中，为防止由于模型参数或训练策略差异导致的差异，本研究对所有基线模型实施了严格的超参数对齐策略：

特征规模对齐：所有图网络基线（TCN-GCN,TCN-GAT）的节点特征提取共享相同的 TCN 架构与隐式特征维度d_{model}。对于无法处理异构高维边特征的常规 GCN/GAT，其输入的图拓扑统一退化为基于传感器物理坐标的静态距离高斯图S，以保证其基础的空间感知能力。

训练环境对齐：所有基线模型均采用完全相同的优化策略，包括 AdamW 优化器、相同的初始学习率、批处理大小以及 Focal-loss 的损失函数设定。

输出尺度对齐：所有模型的末端均接入相同的层级注意力池化与独立楼层分类头，并在推断阶段统一应用基于验证集的后验阈值寻优机制。

通过上述严格的同构化约束，本研究确保了后续实验中记录的任何性能提升，均归因于 DP-HDGNN 核心理论模块的有效性。

3.4.3 损伤定位性能评价指标

在框架结构的健康监测与微弱损伤定位任务中，科学、客观的评价指标是衡量深度学习模型特征提取与泛化能力的标尺。由于本研究将四层框架的损伤定位解耦为四个独立的二分类任务，因此，模型的性能评估本质上是对这四个二分类

任务表现的量化。

如前文所述，真实的结构损伤数据集具有极端的长尾分布与类别不平衡特性，即健康样本数量远大于损伤样本。在这种条件下，如果仅采用传统的整体准确率作为唯一评价标准，模型极易将所有样本预测为健康来获得虚高的准确率指标，而忽视其对损伤样本进行漏报的问题。为此，本研究构建了以混淆矩阵为基础，以 F1-Score 与 PR-AUC 为核心的多维度综合评价体系。

针对结构任意第 i 层的二分类判别结果，可以严格定义混淆矩阵的四个基础基本元：

真正类（True Positive, TP）：模型正确预测出该楼层存在刚度退化。

真负类（True Negative, TN）：模型正确预测出该楼层处于健康状态。

假正类（False Positive, FP）：该楼层实际健康，但模型预测为损伤。

假负类（False Negative, FN）：该楼层实际存在刚度退化，但模型预测健康。

基于上述定义，首先引入三个基础评价指标：准确率、精确率与召回率。

准确率衡量了模型在所有预测样本中，分类正确的全局比例。对于结构整体的损伤定位评估，其全局准确率计算公式为：

$$Accuracy = \frac{\sum_{i=1}^{4}\left(TP_i + TN_i\right)}{\sum_{i=1}^{4}\left(TP_i + FP_i + TN_i + FN_i\right)} \tag{3.3}$$

尽管准确率能够直观反映模型的整体判别能力，但在长尾数据集下其说服力有限，因此在本研究中仅作为辅助参考指标，重点考察各楼层的独立准确率，以评估模型沿结构标高的空间分辨率差异。

精确率代表了在模型判定的所有损伤中，真正发生损伤的比例；而召回率代表了在所有实际发生的损伤工况中，被模型成功捕捉到的比例。其数学表达为：

$$Precision = \frac{TP}{TP + FP} \tag{3.4}$$

$$Recall = \frac{TP}{TP + FN} \tag{3.5}$$

本研究选取 F1-Score 作为评价模型综合定位性能的核心指标，并将其作为后验决策阈值寻优的唯一目标函数。F1-Score 是精确率与召回率的调和平均值，其计算公式为：

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} = \frac{2TP}{2TP + FP + FN} \tag{3.6}$$

与算术平均不同，调和平均机制对极小值更为敏感。这意味着，只有当模型的 Precision 和 Recall 同时维持在高水平时，F1-Score 才会取得高分。因此，全局

F1-Score 能够最真实地反映 DP-HDGNN 模型在面对楼层复合损伤时的精确定位能力。

为了客观评估模型在不同置信度阈值下的极限性能，本研究引入了精确率-召回率曲线下面积（Precision-Recall Area Under Curve, PR-AUC）。

PR 曲线以 Recall 为横坐标，Precision 为纵坐标，描绘了决策阈值从 0 连续变化到 1 的过程中，模型对少数类判别能力的动态轨迹。PR-AUC 为该曲线下方的积分面积，其数学定义为：

$$PR\text{-}AUC = \int_0^1 Precision\left(Recall\right) d\left(Recall\right) \tag{3.7}$$

由于 PR 曲线的计算逻辑天然排除了真负类的统计干扰，这使得该指标能够将评估重心实质性地聚焦于模型对少数损伤样本的识别敏感度上。PR-AUC 数值越趋近于 1.0，表明模型在判断损伤模式高准确率的前提下，依然能够保持良好的精确度。因此，在后续的对比实验分析中，PR-AUC 将被用作衡量各类基线模型在长尾分布的数据集下对损伤进行判断的核心量化准则。

综上所述，本研究构建的多维度评价体系通过结合 F1-Score 与 PR-AUC，为后续客观检验 DP-HDGNN 模型在复杂时空环境噪声干扰下的损伤判别能力，确立了度量标尺。

3.5 损伤定位结果分析

本节将详细展示 DP-HDGNN 模型在 IASC-ASCE 仿真数据集上的训练动态与最终识别性能，并通过与多种前沿深度学习基线的横向对比，全面量化本文所提创新模型对解决损伤定位与长尾不平衡问题的实际贡献。

3.5.1 DP-HDGNN 楼层级损伤定位结果

根据 3.3.1 节设定的训练策略，DP-HDGNN 模型在训练集与验证集上的损失与 F1-Score 演化轨迹如图所示。在 AdamW 优化器的驱动下，Train Loss 在前 20 个 Epoch 内呈现出明显的下降，表明网络正快速捕获高频时序特征与空间拓扑信息的映射关系。随着阶梯式学习率在第 20 轮的触发衰减，Loss 曲线逐渐平滑并收敛。值得注意的是，验证集上的 F1-Score 曲线与训练集 Loss 保持同步，并未出现典型的过拟合分化现象。这主要归功于双图融合阶段的 Top-K 自适应稀疏化机制有效屏蔽了冗余噪声连边的干扰。最终，模型在第 25Epoch 触发了早停机制，定格了具备最优结果的网络权重。

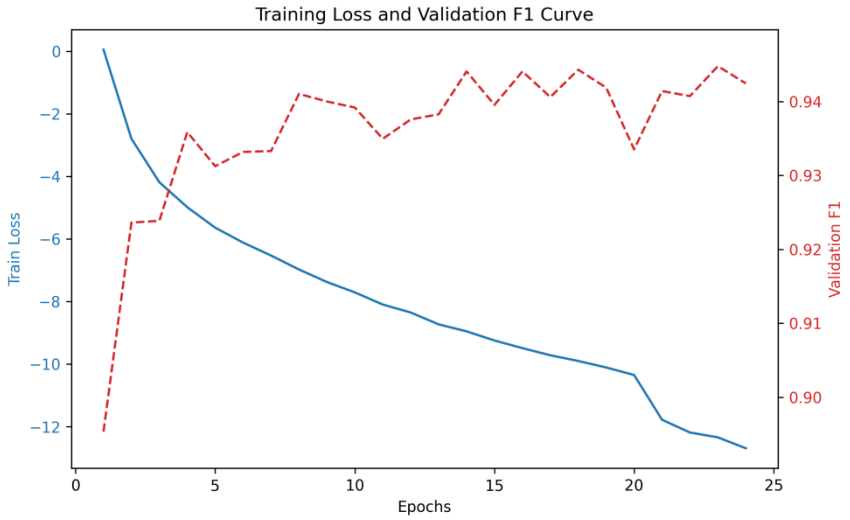


图 3.18 DP-HDGNN 损失函数与 Val-F1 示意图

在测试集上，DP-HDGNN 结合最佳校准阈值，展现出了卓越的微弱损伤定位精度。下图展示了四个楼层独立的损伤分类混淆矩阵。从矩阵对角线的高密度分布可以直观得出，模型在四个楼层上均取得了极高的真负例与真正例。

DP-HDGNN 凭借独特的网络架构，将各楼层的漏报样本数严格压制在了 8.2%，有效避免了出现损伤却被忽略的问题。同时，虚警样本数也被抑制到 3% 左右。

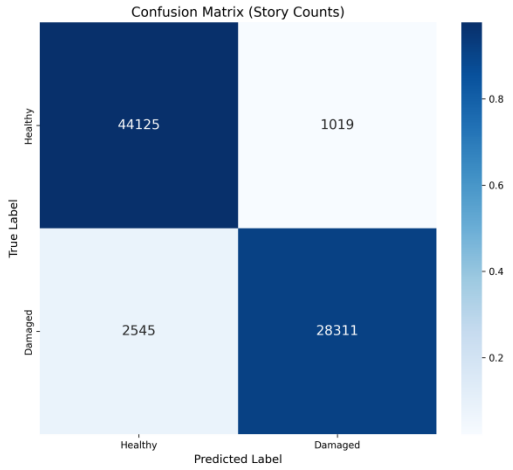


图 3.19 测试集全样本混淆矩阵

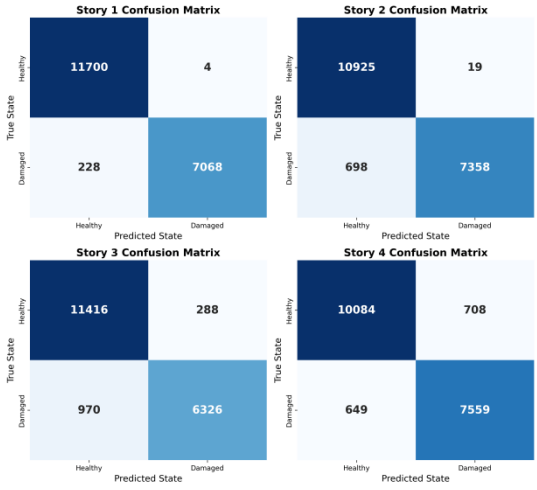


图 3.20 测试集全样本楼层级混淆矩阵

在不平衡数据集的测试下，模型的精确率-召回率曲线如图 3.21 所示。该曲线紧密贴合坐标轴右上角，其曲线下面积（PR-AUC）高达 0.9856。这一指标证明：本研究提出的 DP-HDGNN 模型实现了复杂空间框架在强环境噪声下的复杂损伤定位。

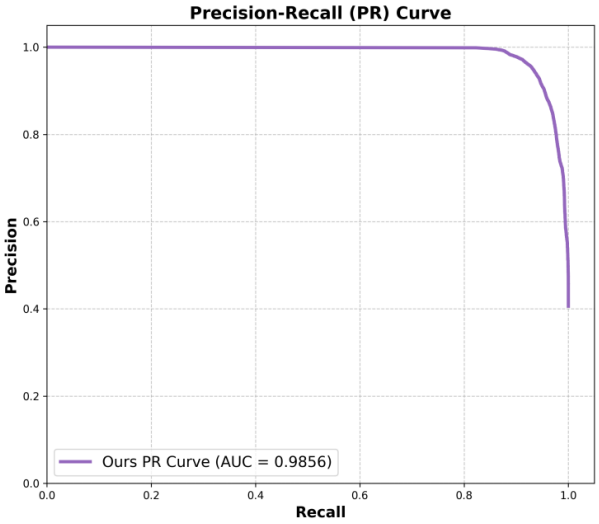


图 3.21 PR-AUC 曲线值

为了直观揭示 DP-HDGNN 模型内部的物理映射机理，本研究提取了模型在推理阶段自适应构建的动态传感器图W，并针对健康状态与多种复合损伤工况进行了网络拓扑的可视化分析，分析结果如图 3.22 至图 3.27 所示。

在结构处于无损健康状态时，传感器节点间的连边拓扑主要由空间物理高斯图S主导，当特定楼层发生刚度退化时，动态响应相位差发生局部畸变。此时自适应门控机制通过时序相似度图A，对于 Sensor 图进行动态重构。Top-K 自适应稀疏化机制切断了部分受噪声干扰的远端弱相关边，使得注意力权重向受损区域的传感器集群收敛。这一动态演化过程，证明了模型具备了数据驱动与空间先验双向融合的损伤定位能力。

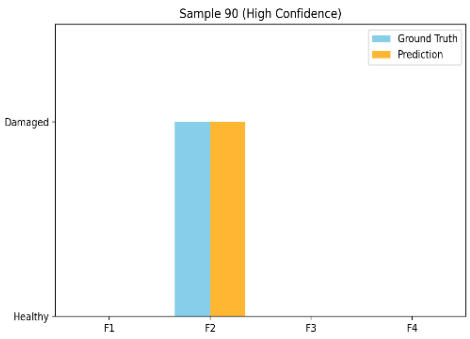


图 3.22 单层损伤真实值与预测值对比图

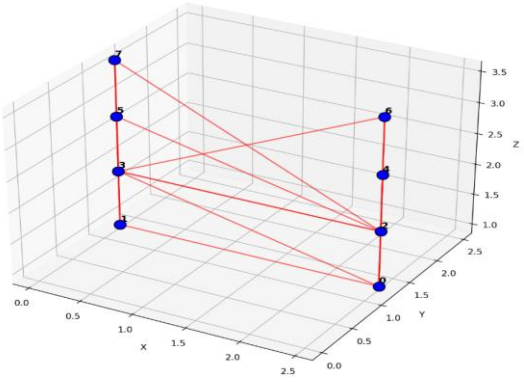


图 3.23 单层损伤动态 Sensor 图

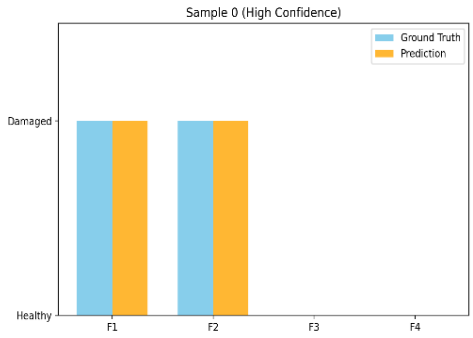


图 3.24 双层损伤真实值与预测值对比图

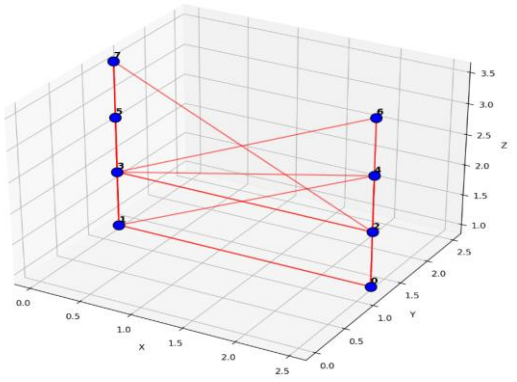


图 3.25 双层损伤动态 Sensor 图

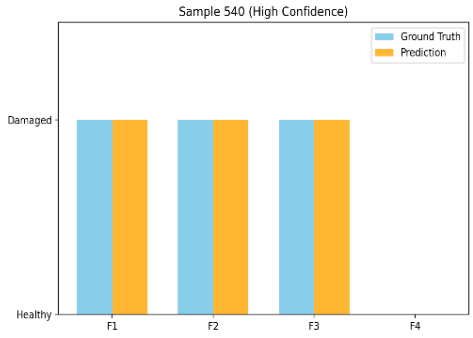


图 3.26 多层损伤真实值与预测值对比图

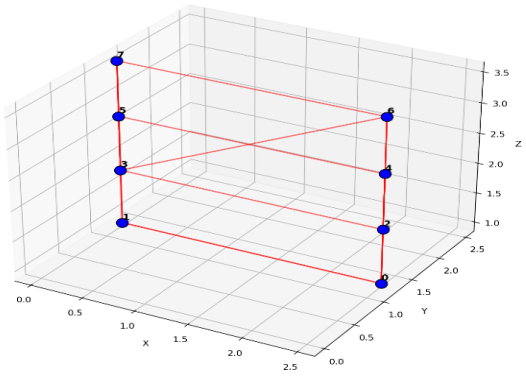


图 3.27 多层损伤动态 Sensor 图

3.5.2 Baseline 模型性能对比

为客观量化 DP-HDGNN 模型的性能优势，本研究将其与 3.3.2 节中设定的四种基线模型（MLP,1D-CNN,TCN-GCN,TCN-GAT）在相同的测试集与超参数约束下进行了平行交叉验证。各模型的综合损伤定位性能如表 3.7 所示。

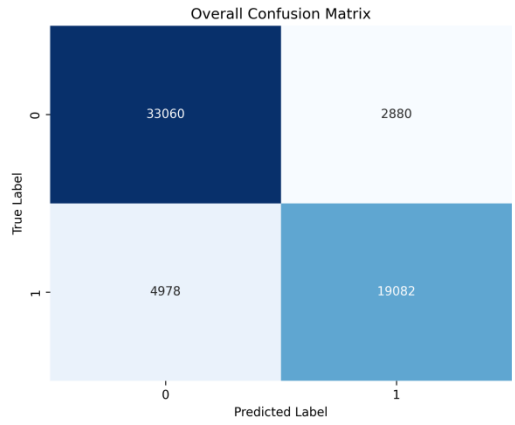
表 3.7 DP-HDGNN 与其它模型性能对比

模型名称	测试集 loss	F1-Score	PR-AUC	整体 ACC
MLP	0.4489	0.8293	0.9169	0.8690
1D-CNN	0.1421	0.9347	0.9754	0.9480
TCN-GCN	0.4415	0.8527	0.9361	0.8817
TCN-GAT	0.2516	0.9156	0.9760	0.9310
DP-HDGNN	**0.0084**	**0.9470**	**0.9875**	**0.9583**

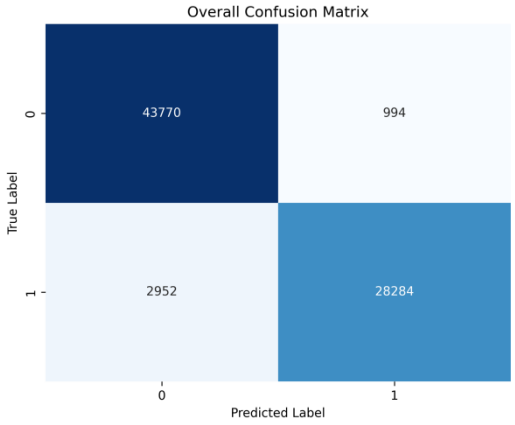
观察表 3.7 可知，MLP 模型虽然在整体的准确度和损伤定位表现上取得了

较为稳定的结果，但其性能未能达到最佳。特别是在 F1 分数和 PR-AUC 方面，MLP 的表现略逊色于后续引入时空结构特征的模型。

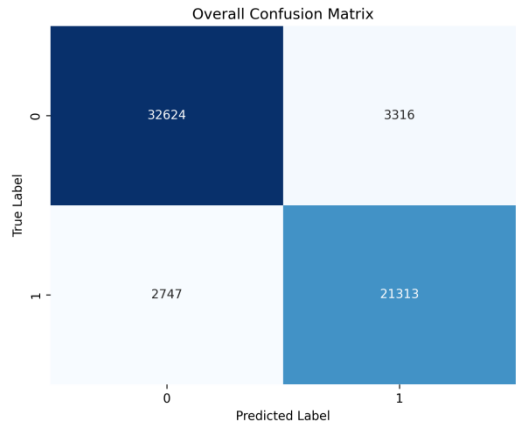
引入了基础图神经网络架构的 TCN-GCN 模型，其各项指标不仅未能取得领先，反而处于所有对比基线中的靠后位置。这一结果深刻揭示了传统图卷积在结构微弱损伤识别中的内在缺陷。TCN-GCN 强依赖于固定的物理空间高斯连通图，且采用拉普拉斯平滑进行节点特征的同构化聚合。当结构发生局部微小刚度退化时，其产生的高频异常响应特征极易在静态图的邻居聚合过程中，被周围大量健康节点的宏观低频背景信号所稀释。这种过平滑效应直接导致了局部损伤特征的丢失，证明了在复杂的损伤情况中，静态拓扑图难以胜任特征解耦的任务。



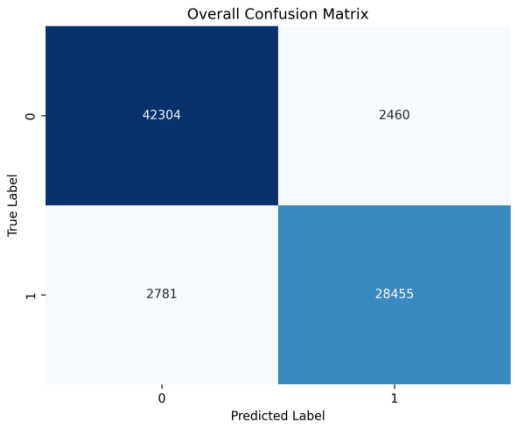
（a）MLP 全局混淆矩阵示意图



（b）1D-CNN 全局混淆矩阵示意图



（c）TCN-GCN 全局混淆矩阵示意图



（d）TCN-GAT 全局混淆矩阵示意图

图 3.28 不同 Baseline 的全局混淆矩阵

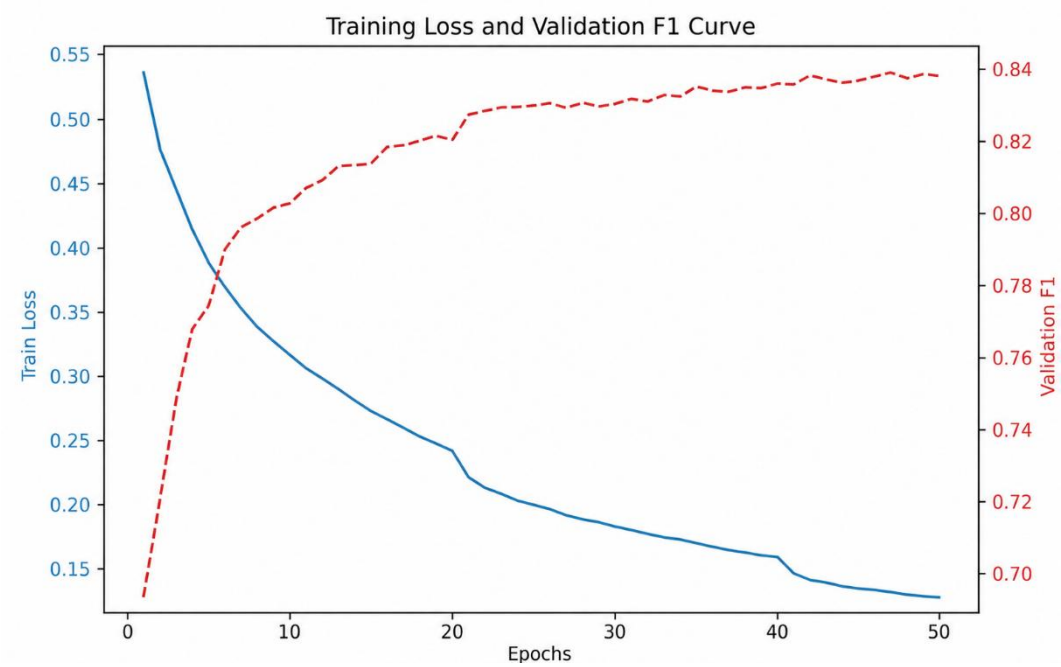


图 3.29 MLP Baseline 损失函数与 Val-F1 示意图

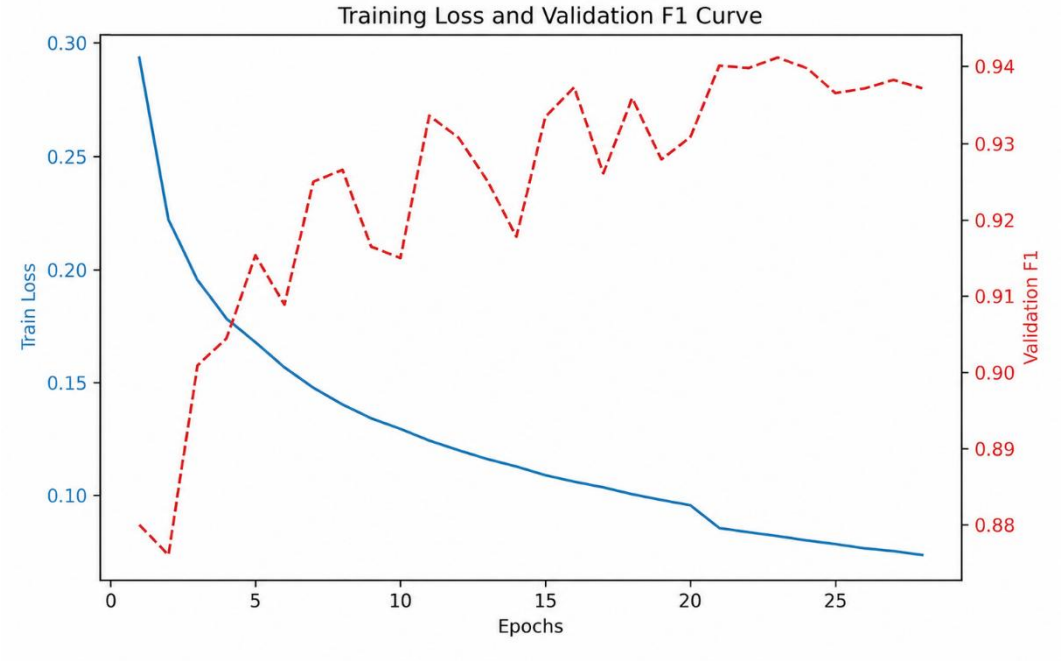


图 3.30 1D-CNN Baseline 损失函数与 Val-F1 示意图



图 3.31 TCN-GCN Baseline 损失函数与 Val-F1 示意图

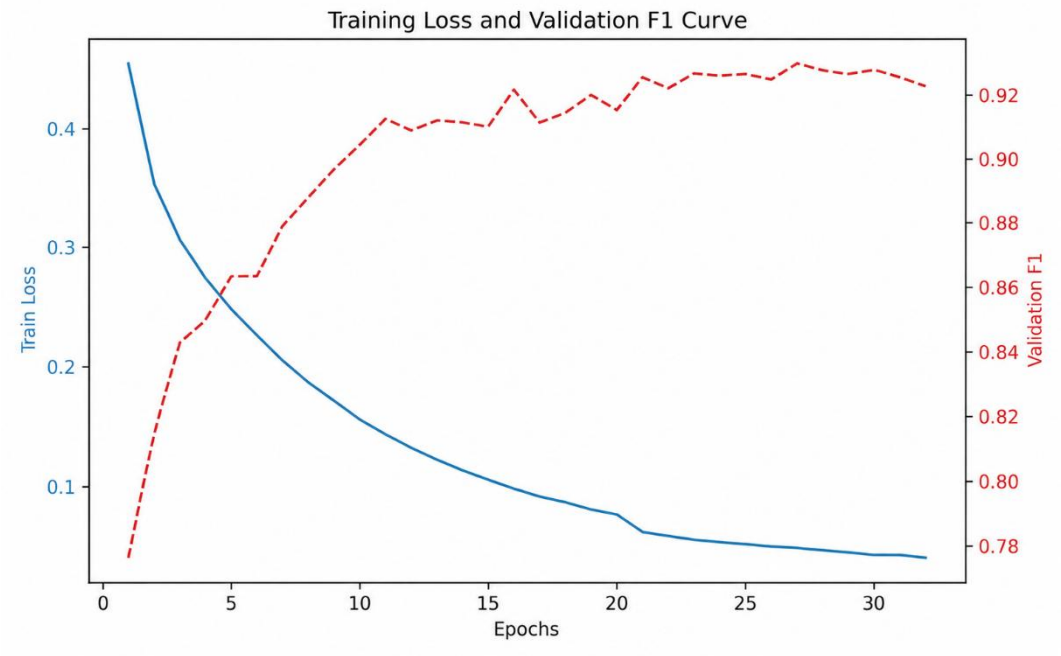


图 3.32 TCN-GAT Baseline 损失函数与 Val-F1 示意图

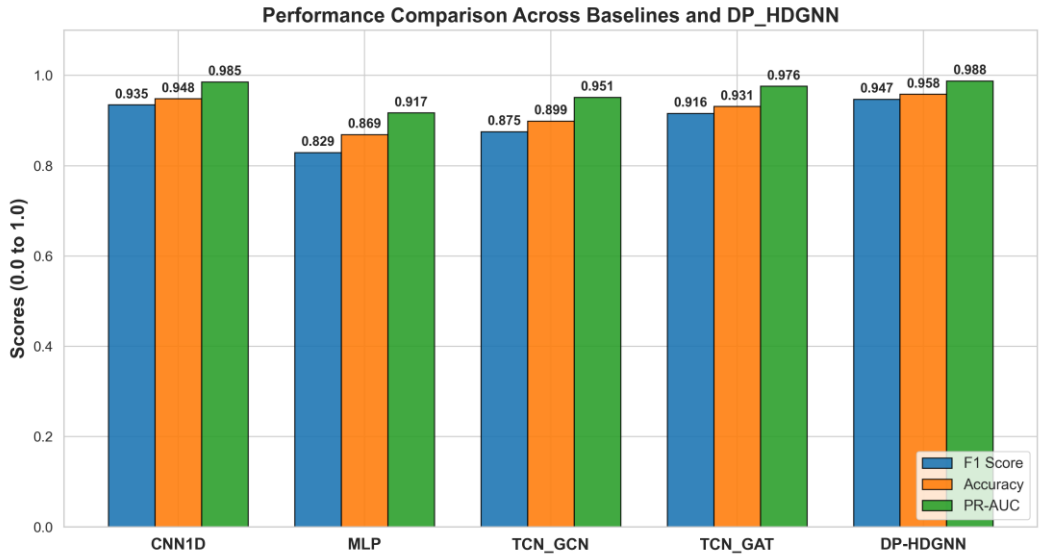


图 3.33 DP-HDGNN 与 Baseline 性能对比图

从图 3.28 至图 3.33 来看，1D-CNN 取得了较强的竞争表现，说明纯时序建模已能够捕获相当一部分损伤相关动力学特征；但其在 PR-AUC 上仍略低于 DP-HDGNN，表明在引入空间先验后，模型对虚警的抑制能力进一步提升。进一步地，将图聚合器升级为注意力机制的 TCN-GAT 模型，其性能相较于 TCN-GCN 有了显著跃升。GAT 的动态权重分配在一定程度上缓解了过平滑问题。然而，由于常规 GAT 仅依赖节点特征计算注意力，缺乏对物理空间距离的显式感知，且无法对边特征进行显式更新，导致其整体精度依然无法突破瓶颈。

相比之下，在本实验设置下，DP-HDGNN 在 F1、PR-AUC 与整体 ACC 等指标上均取得了最优结果。DP-HDGNN 并非盲目聚合邻居，而是将物理先验知识注入交叉注意力架构，同时利用显式边更新层更新边状态，在深层网络中隔离了受损区域与健康区域的特征干扰。PR-AUC 接近 1.0，表明模型在当前数据集上具有较强的少数类区分能力。这证明本模型在追求极低漏报率的工程需求下，依然能够维持较高的预警精确率。

综上分析，DP-HDGNN 模型在多尺度特征解耦以及抗长尾效应干扰方面，优于现有的经典深度学习框架，其在复杂工况下具有较好的应用潜力。

3.6 DP-HDGNN 核心模块消融实验分析

如第 3.4 节的基线对比结果所述，本文所提出的 DP-HDGNN 模型在多类复合损伤与刚度退化工况下，其宏观定位精度（Macro-F1）与抗虚警鲁棒性均优于传统纯数据驱动模型。然而，仅依赖宏观评价指标的提升，尚不足以揭示

该深度网络内部特征提取机制的物理合理性。为进一步探究 DP-HDGNN 中各项核心创新模块的损伤感知增益，本节遵循严格的控制变量原则，设计了一系列网络架构级别的消融实验。通过定向剥离或退化特定的计算模块，深度分析动态传感器拓扑、异构双图交叉注意力以及边特征学习模块在损伤定位中的贡献。实验设置与实验结果分别如表 3.8、表 3.9 所示

表 3.8 ASCE 核心模块消融实验设置

变体名称	保留模块	替换内容	验证目的
DP-HDGNN	结构物理图、动态传感器图、交叉注意力、边特征学习	无	作为完整模型对照
固定传感器拓扑变体	结构物理图、交叉注意力、边特征学习	将动态传感器图替换为固定拓扑	验证动态建图作用
线性门控融合变体	结构物理图、动态传感器图、边特征学习	将交叉注意力替换为特征拼接	验证跨图注意力融合作用
无边特征学习变体	结构物理图、动态传感器图、交叉注意力	取消边特征学习层	验证边特征学习作用

表 3.9 DP-HDGNN 与其它消融实验模型性能对比

模型名称	测试集 loss	F1-Score	PR-AUC	整体 ACC
固定传感器拓扑变体	0.0331	0.9330	0.9784	0.9465
线性门控融合变体	0.0239	0.9184	0.9761	0.9364
无边特征学习变体	0.0299	0.8904	0.9645	0.9127
DP-HDGNN	**0.0084**	**0.9470**	**0.9875**	**0.9583**

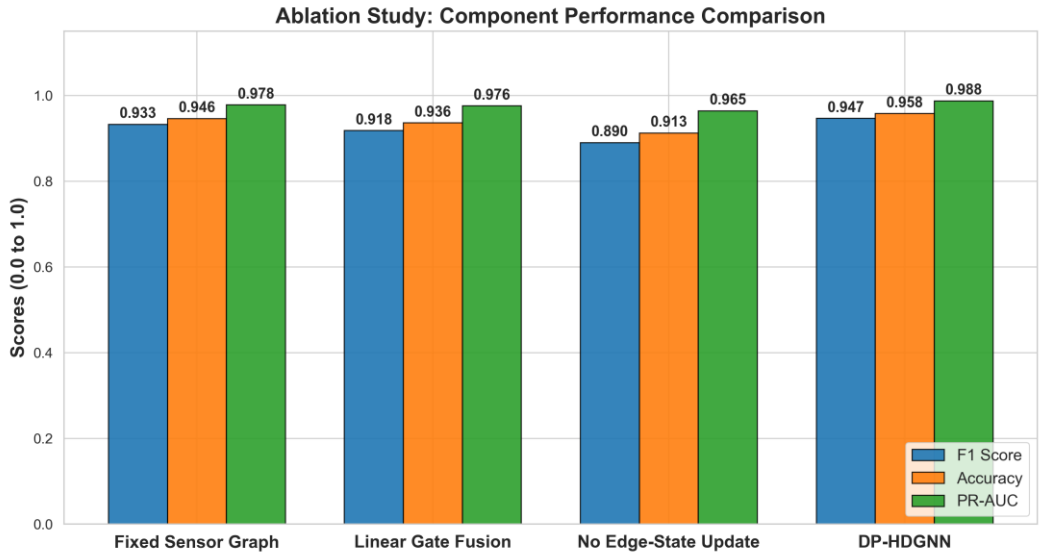


图 3.34 DP-HDGNN 与其它消融实验模型性能对比示意图

3.6.1 动态传感器拓扑图的有效性验证

在 DP-HDGNN 的原始架构中，传感器节点的图拓扑连通性是由动态传感器图模块生成的，该模块综合考虑了传感器间的物理坐标距离与时序振动信号的协方差相似性。为量化该动态图机制的有效性，本节构建了固定传感器拓扑变体。如图 3.35 所示，在此变体中，动态构图机制被剥离，退化为基于纯空间欧氏距离的静态传感器图。即网络在消息传递过程中，仅允许物理距离小于特定阈值 λ 的传感器节点之间产生固定的边连接，而完全忽略了由于结构局部刚度退化引发的时域信号相位差与高频响应变化。

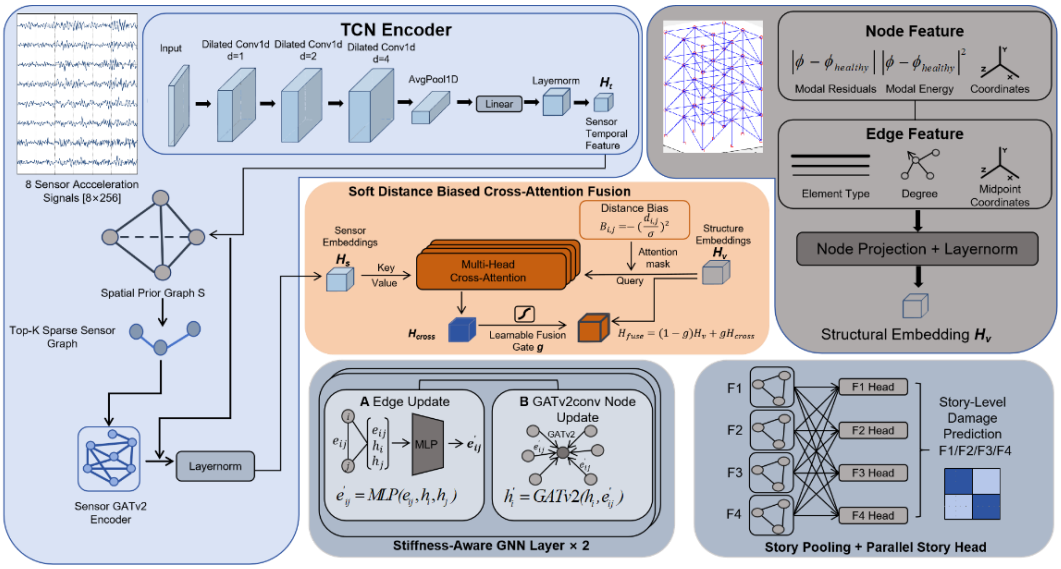


图 3.35 固定传感器拓扑变体网络架构示意图

从结构动力学的物理本质剖析，当空间框架结构的局部构件发生刚度退化时，其会导致原本在健康状态下振动同步的相邻节点，其加速度时程响应呈现出显著的非平稳时滞与瞬态特征畸变。依赖静态空间欧氏距离的构图法则，本质上仅是对结构初始几何拓扑的刚性映射。由于其边权重在整个训练周期内保持冻结，该架构能较好捕捉结构损伤的信息。相反，本文设计的动态传感器图模块，通过自适应相似度网络，赋予模型跨越固定空间拓扑限制进行损伤定位的能力。

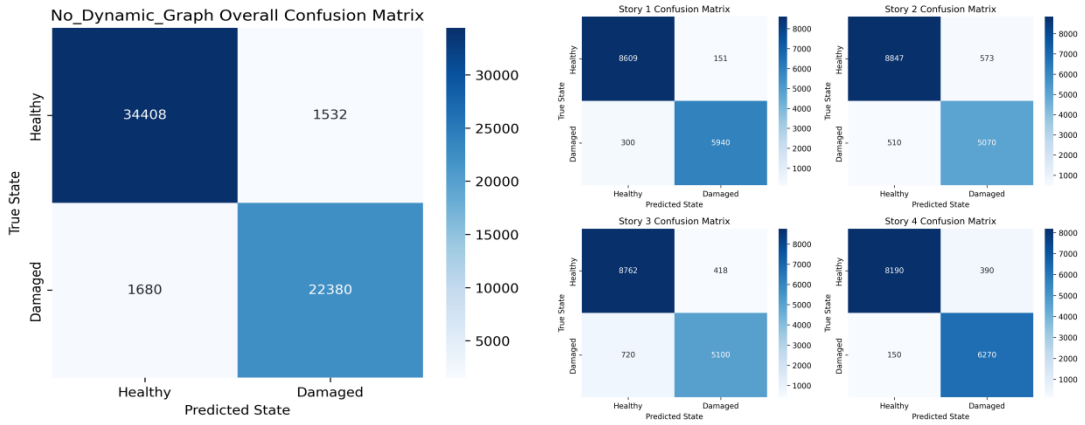


图 3.36 固定传感器拓扑变体全局混淆矩阵与每层混淆矩阵

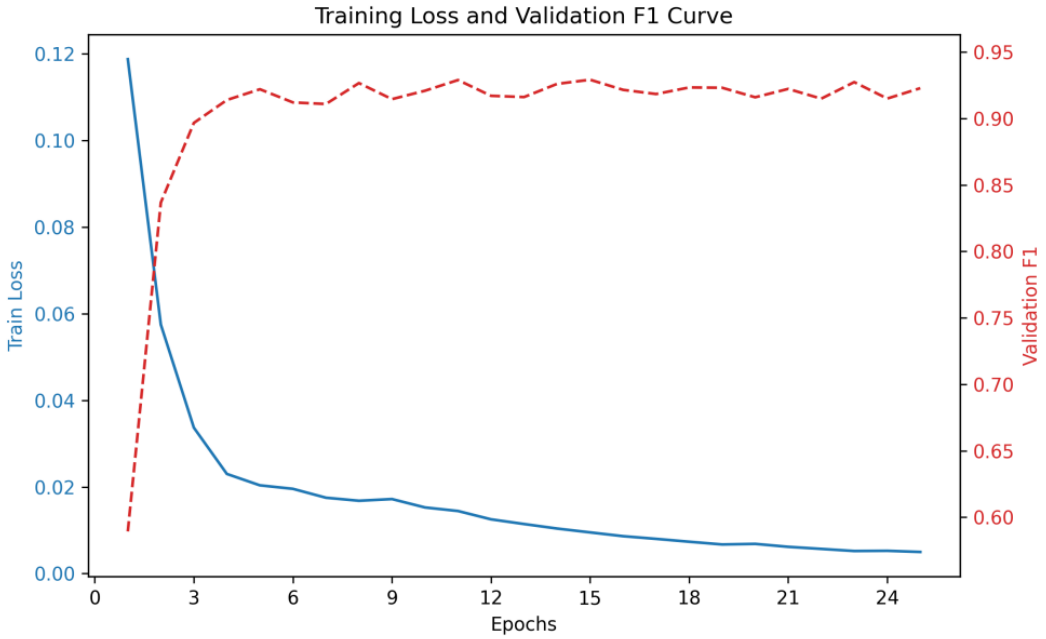


图 3.37 固定传感器拓扑变体训练损失函数与 Val-F1 示意图

通过分析图 3.36、图 3.37 可知，纯物理距离约束的静态拓扑在刻画结构刚度损伤时，存在感知瓶颈。本文在 DP-HDGNN 中引入的数据驱动动态建图机制，能够有效融合时序语义与空间关联，实现了从静态几何拓扑向动态响应

拓扑的转变。该机制对于捕获微观尺度下的高频损伤特征、提升模型对局部刚度退化的感知敏感度，具有增益作用。

3.6.2 异构双图交叉注意力融合机制的有效性验证

在 DP-HDGNN 原始架构中，为解决有限测点与海量结构自由度之间的空间不对等问题，引入了交叉注意力机制以实现“传感器观测空间”与“结构物理空间”的对齐。为了严密论证该算法的必要性，本小节基于消融实验代码构建了线性门控融合变体。如图 3.38 所示，在此变体中，网络剥离了基于 Query-Key-Value 架构的自适应注意力寻优路径，转而采用线性门控机制。具体实施上，由时序编码器提取的传感器节点特征张量与由图卷积提取的结构物理节点特征张量，通过线性门控机制进行特征融合，以替代原有的异构空间交互查询机制。

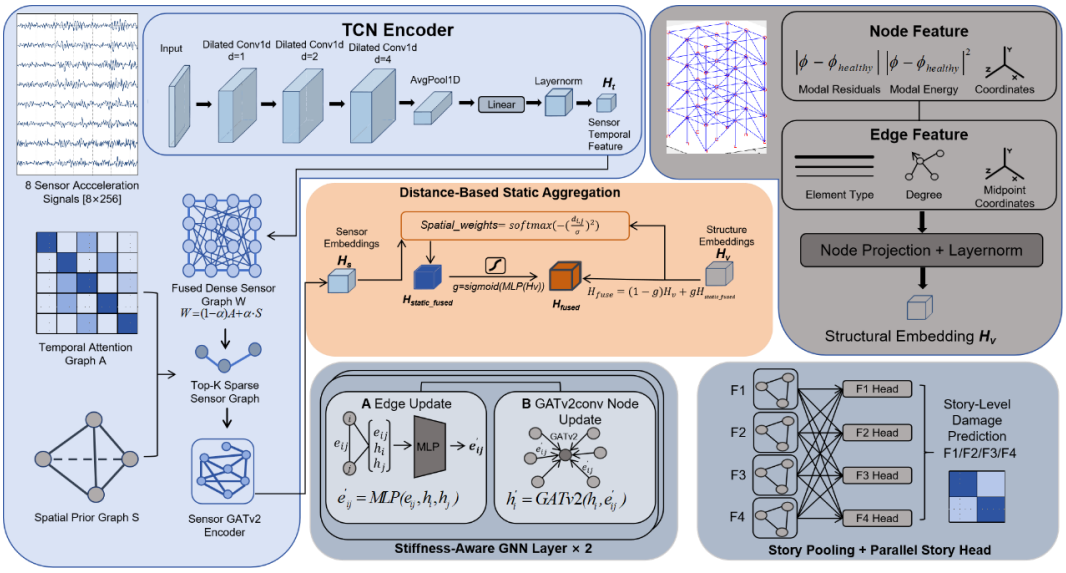


图 3.38 线性门控融合变体网络架构示意图

在异构空间特征融合任务中，线性门控机制本质上是执行标量级别的权重标定。当结构发生刚度退化引发模态混叠与内力重分布时，局部损伤的特征往往会传导至远端传感器通道。线性门控机制的理论缺陷在于其只能被动接收前端的静态特征进行比例混合，无法跨越几何边界去主动搜寻异常信号。相反，本文引入的交叉注意力机制赋予了网络在全局感受野下的动态空间寻优能力。通过将物理实体映射为查询向量（Query），将传感器观测映射为键值对（Key-Value），该机制迫使网络在每次推断时，锁定与当前节点最相似的观测特征。

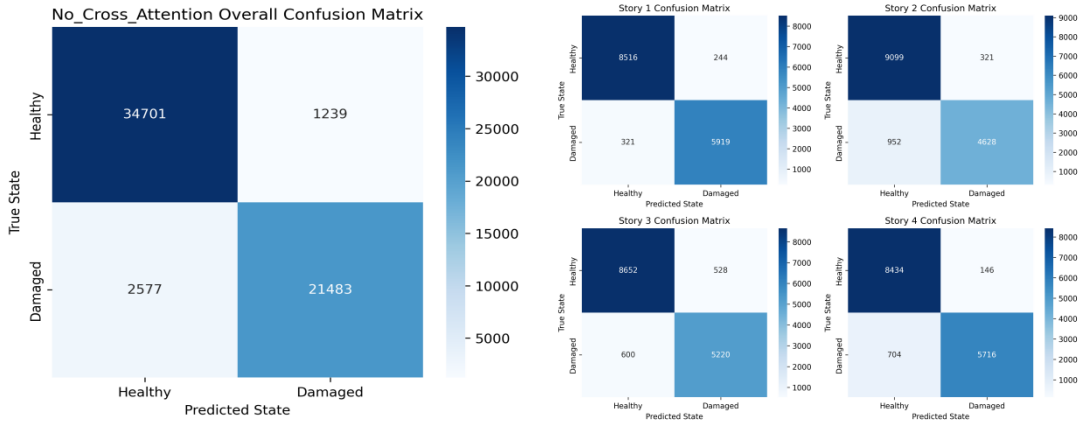


图 3.39 线性门控融合变体全局混淆矩阵与每层混淆矩阵

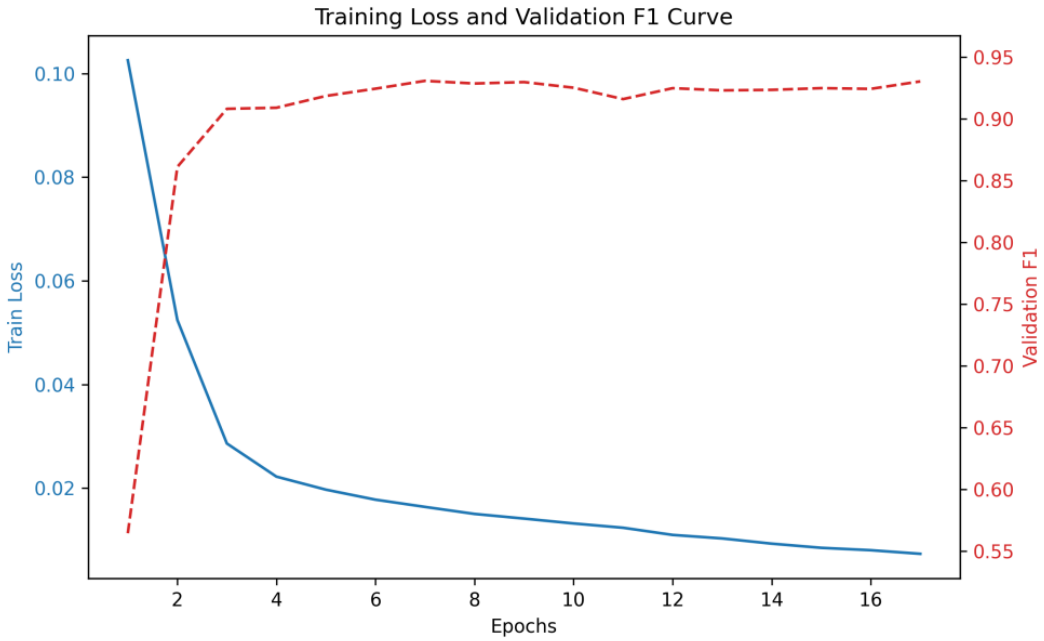


图 3.40 线性门控融合变体训练损失函数与 Val-F1 示意图

通过分析图 3.39、图 3.40 可知，面对高自由度结构的动力学演化，单纯依赖线性门控机制进行异构特征的融合，存在特征对齐瓶颈。该消融实验反向印证了 DP-HDGNN 所搭载的交叉注意力机制打破了线性门控的感知局限，实现了异构空间中基于动力学相关性的高维特征融合，是赋予模型强大空间解析力与鲁棒性的核心。

3.6.3 边特征学习模块的有效性验证

在处理结构物理拓扑时，本文提出的 DP-HDGNN 完整架构设计了专用的显式边更新层。该网络层在执行空间消息传递时，不仅利用节点特征，还显式

地将有限元模型中杆件的截面几何属性与散度和差作为边特征注入聚合函数中。为量化该物理信息前馈机制的具体增益，本小节构建了无边特征学习变体。如图 3.41 所示，在此消融变体中，剥离融合显式力学属性的消息传递网络，将其整体替换为标准的图注意力卷积层。标准 GATv2Conv 在计算中心节点与邻居节点的注意力权重系数时，仅依赖隐式节点特征向量的内积相似度。

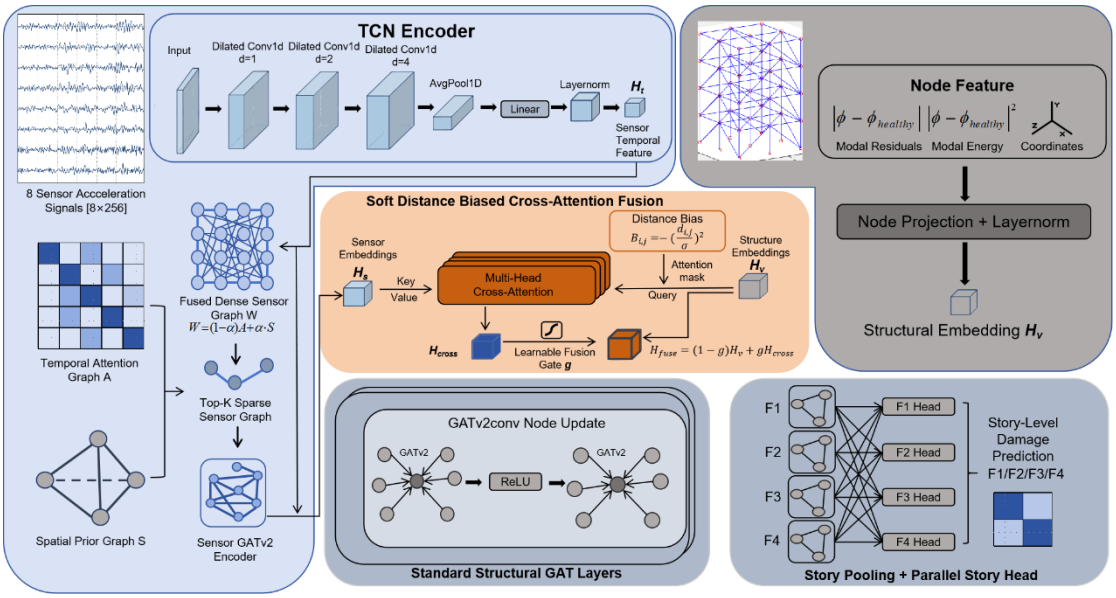


图 3.41 无边特征学习变体网络架构示意图

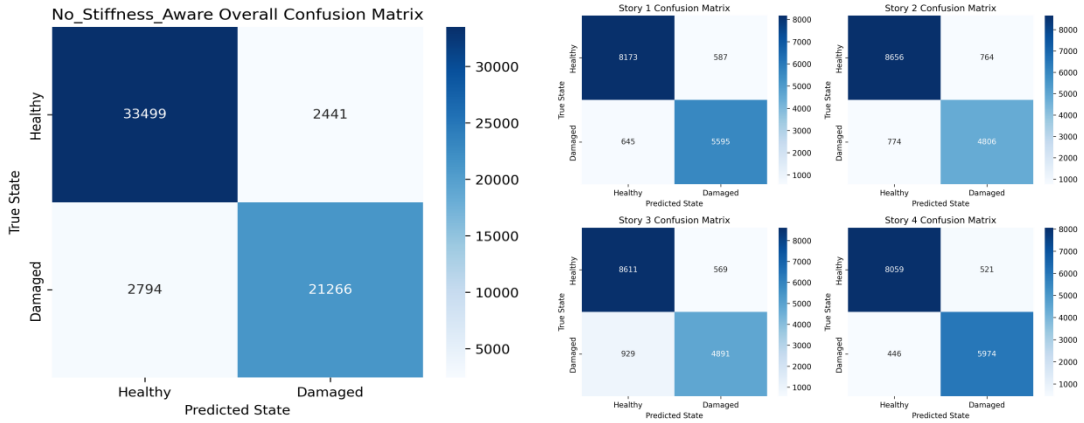


图 3.42 无边特征学习变体全局混淆矩阵与每层混淆矩阵

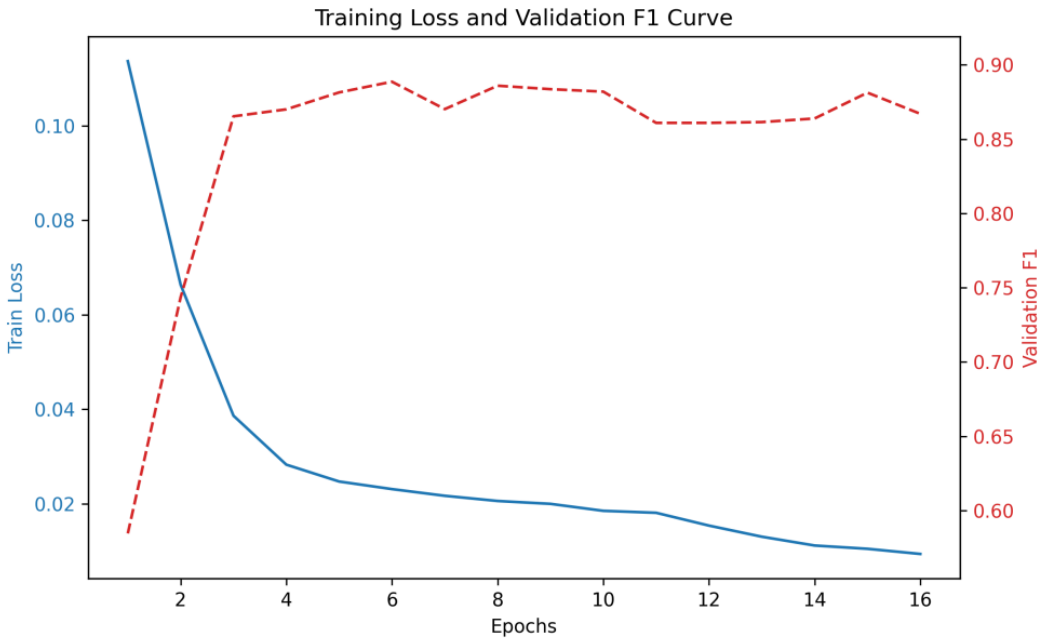


图 3.43 无边特征学习变体训练损失函数与 Val-F1 示意图

通过分析图 3.42、图 3.43 可知，在面向实体工程的结构健康监测中，将结构的本构力学属性以边特征的形式显式注入图神经网络，能够遏制了高频损伤特征在深层网络中的过度平滑弥散。该结果说明，将边特征学习模块引入图消息传递，有助于缓解深层传播中的特征平滑问题，并增强模型结果的物理可解释性。

3.7 本章小结

本章围绕数物双驱异构双图神经网络（DP-HDGNN）在框架结构损伤定位任务中的有效性开展数值仿真研究。第二章完成了模型理论与架构设计，但模型是否能够有效抑制空间耦合响应造成的误判、是否能够在复合损伤与噪声干扰条件下保持稳定识别性能，仍需通过具有明确结构动力学背景的算例进行验证。本章主要结论如下。

(1) 通过 T 型钢架算例体现了物理信息图结合动态传感器图的必要性

本章首先构建 T 型分叉钢架算例，分析局部刚度折减损伤对结构全局响应的影响。结果表明，局部损伤由于内部传力路径复杂，对全局结构不同位置的动力响应具有复杂的影响关系，由结构的空间物理信息决定的。对于仅依赖多通道时序响应的模型而言，这类远端响应扰动容易被误判为真实损伤，从而产生异地虚警。该算例说明，结构损伤定位不能仅依赖传感器时序特征，还需要将结构连接关系、空间传力路径等物理信息及测点响应之间的动态相关性共同纳入模型。

在此基础上，本章选取 IASC-ASCE 120 自由度框架结构作为主要验证对象，生成包含单层损伤、双层损伤和多层复合损伤的有限元仿真样本，并综合考虑激励形式、噪声水平和刚度折减程度对结构动力响应的影响。随后，将有限元节点连接关系、构件边属性、模态残差信息以及多测点加速度时程统一组织为 DP-HDGNN 可使用的双图样本，使结构物理先验与传感器动态响应能够在同一输入框架下协同表达。由此，T 型钢架算例完成了损伤误判机理说明，IASC-ASCE 框架数据集则为后续模型训练、对比验证和消融分析提供了标准化实验基础。

(2) 模型对比验证 DP-HDGNN 在楼层级复合损伤定位中的有效性

本章在统一数据划分、训练策略和评价指标下，将 DP-HDGNN 与 MLP、1D-CNN、TCN-GCN 和 TCN-GAT 等基线模型进行对比。结果表明，纯时序模型虽然能够提取部分损伤敏感响应特征，但缺乏结构空间约束，容易受到远端耦合响应和噪声扰动影响；常规单图模型能够引入一定拓扑信息，但难以同时刻画稳定的结构物理连接和随结构状态变化的传感器动态相关性。相比之下，DP-HDGNN 通过结构物理图与动态传感器图的协同建模，在 Macro-F1、PR-AUC 和整体准确率等指标上均取得更优结果。结合动态传感器图可视化结果可知，模型能够随结构状态变化调整测点间关联关系，在健康状态下更多依托空间先验，在损伤状态下增强对异常响应区域的关注，从而提高楼层级损伤定位的稳定性与可解释性。

(3) 消融实验进一步验证了核心模块对模型性能提升的贡献

为分析 DP-HDGNN 性能提升的来源，本章构建了固定传感器拓扑变体、线性门控融合变体和无边特征学习变体。实验结果表明，三类变体均出现不同程度的性能退化，说明动态传感器图、异构双图交叉注意力融合和边特征学习等模块共同支撑模型完成复合损伤定位任务。

综上，本章通过 T 型钢架预验证与 IASC-ASCE 框架结构仿真实验，验证了 DP-HDGNN 在框架结构复合损伤定位中的有效性。T 型钢架算例说明了引入图拓扑约束和动态测点关联建模的必要性；IASC-ASCE 框架结构实验进一步表明，结构物理图与动态传感器图协同建模能够提升模型在复合损伤和噪声干扰条件下的识别稳定性；消融实验则明确了各核心模块对模型性能的实际贡献。需要进一步指出的是，本章主要面向框架结构数值仿真场景，尚未充分考察更复杂拓扑结构以及传感器随机失效条件下的模型表现。因此，下一章将以空间桁架结构为代表性算例，进一步分析 DP-HDGNN 在复杂结构和观测信息缺失条件下的鲁棒性与泛化能力。

第4章 传感器失效时数物双驱异构双图神经网络损伤定位鲁棒性验证

4.1 引言

第三章基于 T 型钢架预验证和框架结构算例，验证了 DP-HDGNN 在框架结构复合损伤定位中的有效性，说明结构物理图与动态传感器图的协同建模能够提升模型对局部损伤与空间耦合响应的区分能力。然而，实际工程中的结构形式并不局限于框架结构，监测系统也难以长期保持传感器通道完整。对于节点连接更密集、构件数量更多、响应耦合更强的结构，局部损伤信息可能在多个区域之间传播并叠加，使损伤特征更容易被整体振动背景所掩盖；同时，传感器还可能因数据传输中断、硬件故障或局部环境干扰而出现响应缺失或失真。上述因素都会增加模型在真实监测场景中的识别难度。

传感器失效是结构健康监测中必须重点考虑的问题。当部分测点响应缺失时，纯时序模型的输入通道分布会发生改变，容易导致特征提取过程不稳定；常规静态图模型虽然能够利用固定邻接关系进行空间聚合，但失效节点的异常输入可能沿固定图结构传播，进而影响周围节点的特征表示。因此，损伤识别模型不仅需要在测点完整条件下具备较高识别精度，还应在局部观测信息缺失时，能够依托结构拓扑先验和剩余有效测点响应维持稳定判别能力。

基于上述问题，本章以一 14 跨空间简支桁架作为代表性复杂结构算例，进一步考察 DP-HDGNN 在复杂拓扑结构和传感器随机失效条件下的鲁棒性与泛化能力。因此，本章在保持 DP-HDGNN 核心架构不变的基础上，对结构图边特征、区域级标签定义和模型输出形式进行调整，将楼层级损伤识别扩展为 14 跨区域级多标签损伤定位任务。

本章主要围绕三个层面展开：首先，建立一 14 跨空间简支桁架有限元模型，构建包含健康状态、单区域损伤和多区域复合损伤的带噪动力响应数据集，并根据桁架拓扑特点完成双图样本构造；其次，在测点完整条件下，将 DP-HDGNN 与 MLP、1D-CNN、TCN-GCN 和 TCN-GAT 等基线模型进行对比，分析不同模型在复杂桁架结构区域级损伤定位任务中的性能差异；最后，通过随机传感器失效试验模拟测点响应缺失或观测通道中断，考察不同模型在观测不完整条件下的性能变化，重点验证 DP-HDGNN 是否能够利用结构物理图提供的拓扑先验和剩余传感器响应实现信息补偿。

通过上述研究，本章旨在回答两个问题：其一，面对节点连接更密集、响应耦合更复杂的桁架结构，DP-HDGNN 是否仍能保持稳定的区域级损伤定位能力；其二，当部分传感器响应缺失时，所提异构双图结构是否能够依托结构拓扑先验和剩余有效测点信息进行特征补偿，从而降低观测不完整对损伤识别结果的影响。

4.2 空间桁架数值仿真模型与复合损伤数据集构建

4.2.1 空间桁架结构基本概况与有限元建模

本节主要从有限元模型、损伤工况和带噪动力响应生成三个方面对数据集构建过程进行说明。相比原始结构动力学理论推导，本节重点关注数据生成逻辑、关键参数和样本定义方式，为后续模型训练与性能评估提供统一的数据基础。具体有限元模型参数如图 4.1 与表 4.1 所示。

表 4.1 复杂结构验证算例有限元模型参数

参数	具体设置
边界条件	两端简支
跨数	14
单跨长度	0.5m
横截面尺寸	$0.5\text{m}\times0.5\text{m}$
弹性模量	$E_0=68.9\text{GPa}$
材料密度	$\rho=2700\text{kg/m}^3$
纵向弦杆	$A_{long}=1.5\times10^{-4}\text{m}^2$
横向腹杆	$A_{batt}=1.0\times10^{-4}\text{m}^2$
刚度折减范围	$10\%\sim40\%$
损伤类型	单区域损伤、多区域复合损伤（最多三个区域）
健康样本	1500 组
单区域损伤样本	1500 组
多区域损伤样本	2000 组
标签形式	14 维区域级多标签二分类

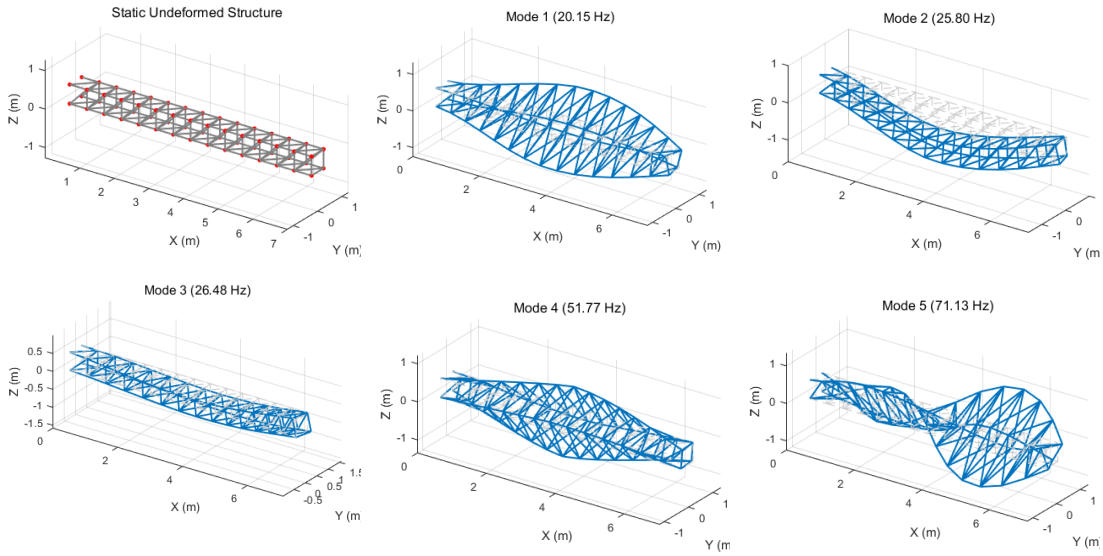


图 4.1 桁架结构基本概况

4.2.2 随机激励荷载施加与带噪时程序列生成

在完成有限元模型建立与损伤工况设定后，需进一步生成不同结构状态下的动力响应数据。与第三章框架结构中常见的基底激励不同，本章所采用的空间桁架算例主要通过节点外力激励产生动力响应。为增强响应数据对整体低频弯曲和局部高频振动特征的覆盖能力，本文采用非对称双点复合激励方式，在结构不同空间位置和不同方向自由度上施加外部节点力。具体设置如表 4.2 与图 4.2、图 4.3 所示。

表 4.2 非对称复合激励与带噪动力响应生成设置

参数	设置
激励形式	双点非对称节点力激励
激励位置	节点 18 的 Y 向自由度；节点 43 的 Z 向自由度
激励组成	线性扫频正弦分量 + 低频有色噪声分量
扫频范围	0.5~80Hz
有色噪声	高斯白噪声经 15 Hz 低通滤波生成
激励幅值	每个样本随机生成
阻尼比	0.015~0.025
仿真时长	20s
信噪比范围	SNR=25~65dB
时间步长	0.005s

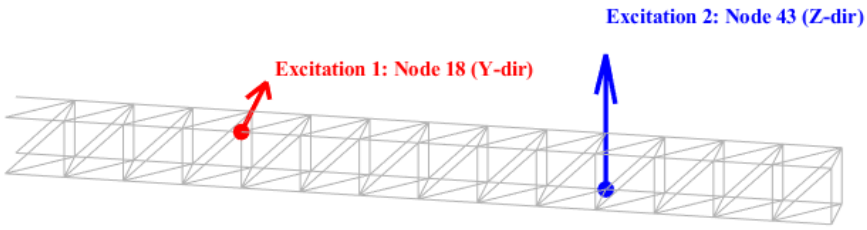


图 4.2 桁架结构施加激励位置

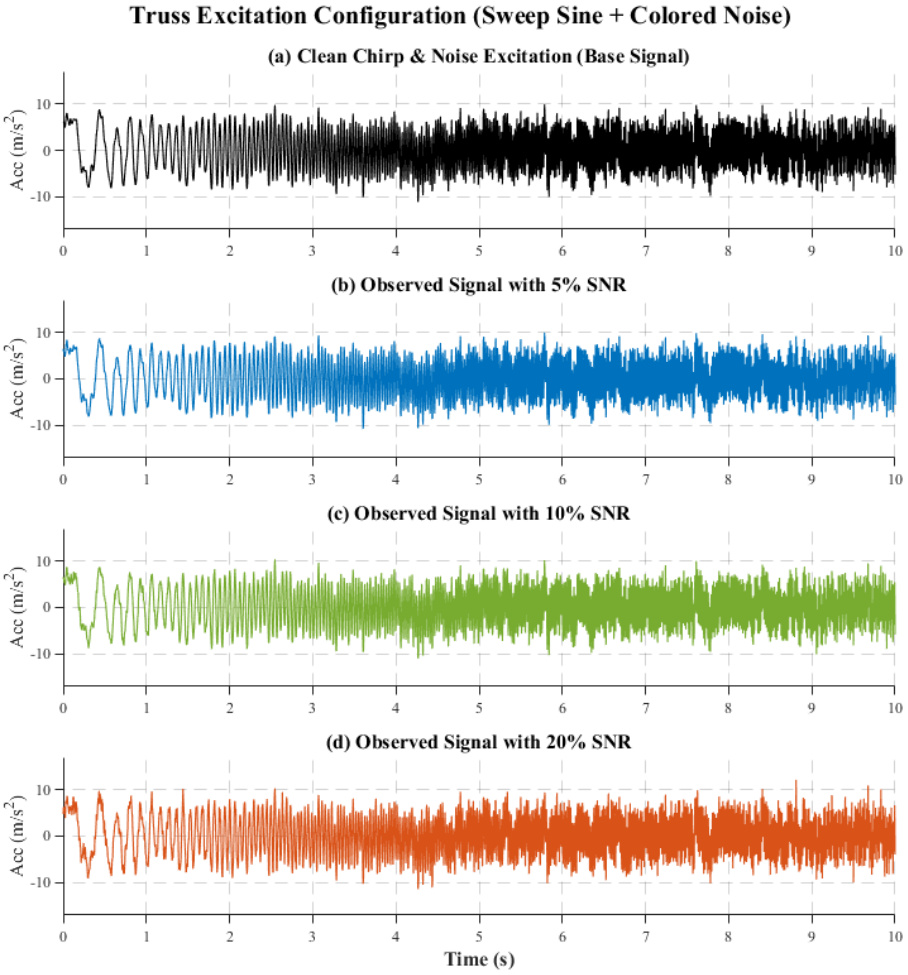


图 4.3 扫频正弦与噪声激励在不同 SNR 下示意图

通过上述处理，每个损伤工况均对应一组包含结构状态、复合激励和测量噪声影响的加速度响应数据。与单一平稳随机激励相比，扫频正弦与有色噪声叠加的复合输入能够同时激发结构的宽频动态特征和低频环境扰动成分；双点非对称激励则有助于打破结构响应的空间对称性，提高数据集中不同跨区损伤样本的可区分度。由此生成的带噪动力响应数据为后续 DP-HDGNN 在复杂结构中的损

伤定位与传感器失效鲁棒性验证提供了基础。

4.3 面向桁架拓扑结构的双图特征构建

在将数物双驱异构双图神经网络（DP-HDGNN）从多层框架推广至空间桁架时，面临的最大挑战在于结构节点拓扑的增加以及力学边界的模糊化。本节针对桁架的力学特性，对物理结构图与传感器动态图的特征映射机制进行了自适应调整。

在第三章的框架结构算例中，结构图边特征包含构件类型 one-hot 编码、构件中点坐标以及端点节点度数相关特征等信息。其中，构件类型编码用于区分梁、柱、斜撑等不同受力构件，适用于以弯剪受力为主、构件功能差异较明显的框架结构。

然而，在本章的空间桁架算例中，有限元模型中的杆件均按三维桁架单元处理，主要承受轴向拉压作用。若继续保留面向框架结构设计的构件类型 one-hot 编码，不仅会增加输入特征维度，也可能引入与本算例力学建模假设不完全匹配的冗余信息。因此，本章在结构图边特征构造中去除了框架专用的构件类型编码，仅保留能够描述局部连接关系与空间位置的低维特征。

对于图中任意边 e_{ij}，其边特征定义为：$e_{ij}=\left[d_i+d_j,|d_i-d_j|,x_{ij}^m,y_{ij}^m,z_{ij}^m\right]$。其中，$d_i$和$d_j$分别表示边两端节点在结构图中的度数，$d_i+d_j$用于反映该杆件所处局部区域的连接密集程度，$|d_i-d_j|$用于描述边两端节点连接状态的差异；$x_{ij}^m,y_{ij}^m,z_{ij}^m$为杆件中点在三维空间中的归一化坐标，用于表征该杆件在整体结构中的空间位置。

通过上述方法，结构物理图边特征由框架结构中的高维构件类型描述，转化为适用于桁架拓扑的 5 维拓扑—几何特征。该处理既避免了不必要的特征冗余，也保留了桁架损伤区域识别所需的局部连接与空间位置信息。

第三章中的 IASC-ASCE 框架结构具有明确的楼层边界，因此模型输出被定义为楼层级损伤判别结果。与之不同，本章采用的 14 跨空间桁架不具有天然楼层划分，若继续采用楼层级池化方式，将无法与桁架结构的实际几何分区对应。因此，本章将模型读出方式调整为跨区域级输出，即以每一个结构跨作为一个独立的损伤识别区域。

设桁架纵向坐标为 x，单跨长度为 L_{bay}，总跨数为 $N_{bay}=14$。对于任意节点或传感器位置 x_i，其所属区域索引定义为：

$$Index_{bay} = \mathrm{Clamp}\left(\frac{x_{coords} - \epsilon}{L_{bay}}, 0, N_{bays} - 1 \right) \tag{4.1}$$

其中，$N_{bays} = 14$，Clamp(·) 为边界截断函数，用于保证所有节点均被归入合法的区域范围内。

4.4 模型训练策略与基准模型设置

在确立了面向密集空间桁架的物理图特征构建与区域级离散池化策略后，本节旨在构建一套科学、严密且具备控制变量逻辑的实验评估框架。相较于第三章的多层剪切框架，14 跨空间桁架在自由度规模、节点连通密度以及损伤特征的时空稀疏性上均呈现出显著的复杂化趋势。因此，本节的实验环境设置不仅需要客观量化模型在全新拓扑下的特征拟合精度，更需从超参数鲁棒性与基线模型局限性等维度，深入剖析异构双图结构在实现泛化时所面临的瓶颈。

4.4.1 网络超参数搜索与训练环境对齐

在基于深度学习的结构健康监测研究中，计算环境的统一性与超参数的自适应寻优是确保模型评估具有公允性与最优拟合状态的核心前提。针对多层剪切框架与密集空间桁架在物理构型上的本质差异，本章在模型训练上所使用的计算平台与超参数寻优策略与第三章框架结构的保持一致。

1. 计算平台与软件基础环境的严格对齐

为确保本章实验数据与第三章具有绝对的可比性，并消除由底层硬件算子差异引发的训练波动，本节所有对比模型的训练与推断测试均严格依托于与第三章完全一致的计算平台。

2. 面向桁架拓扑的网络超参数重搜索机制

空间桁架的结构拓扑与多层框架存在几何差异：其节点数量与连边密度呈完全不同，且局部力学传导路径更为弥散。若盲目照搬第三章的超参数设定，不仅无法有效捕获密集网架中的高频微弱损伤信号，更极易导致深层图特征在传递过程中的过度平滑效应。基于此理论，本研究针对 14 跨桁架数据集，对 DP-HDGNN 模型的全域超参数空间进行 Optuna 全局自动化超参数寻优。结果如图 4.4 所示。

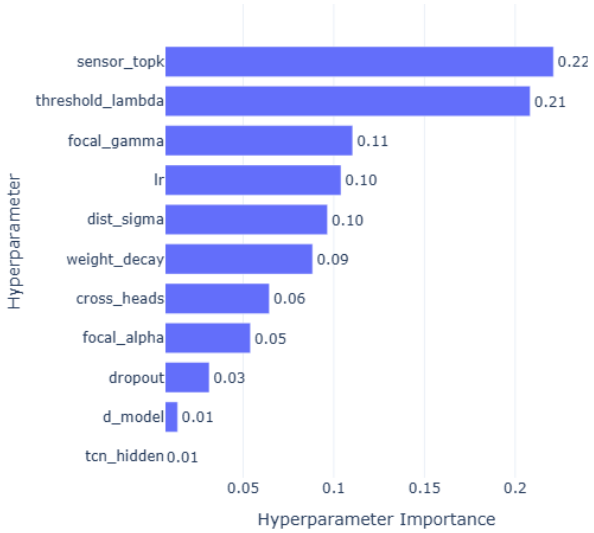


图 4.4 Optuna 超参数敏感性分析

具体而言，针对处理非平稳随机振动信号的时序编码器模块，算法对其一维膨胀卷积的隐藏层特征维度 d_{model}、卷积核尺寸以及多尺度膨胀率重新进行了敏感性分析，以确保时域感受野能够覆盖桁架的低频整体弯曲与高频局部颤振响应。在双图交叉注意力模块中，针对图节点规模的膨胀，模型重新校准了多头注意力机制的并行头数与动态传感器图的 Top-K 稀疏化截断阈值，从而在保障拓扑连通性的同时，最大限度地剔除了由环境白噪声引发的冗余注意力连接。

具体而言，模型选取的超参数如表 4.3 所示：

表 4.3 DP-HDGNN 模型超参数

参数类别	超参数名称	设定值
网络容量与维度	D_model	128
	TCN_kernel	7
	TCN_hidden	128
	Cross_heads	8
图拓扑构建	Sensor_topk	3
	Dist_sigma	4
优化器与训练策	Optimizer	AdamW
	Learning_rate	4.94×10^{-4}
	Weight_decay	9.79×10^{-3}
	Batchsize	128
	Dropout	0.3
	Epochs	100

续表

参数类别	超参数名称	设定值
	Patience	30

3. 优化器配置与余弦退火学习率策略

在网络反向传播的优化策略层面，本实验继续采用引入 AdamW 算法，以抑制庞大参数量在拟合复杂图特征时产生的过拟合问题。其次，本章摒弃了传统的阶梯式学习率衰减策略，转而引入了余弦退火学习率调度策略（Cosine Annealing LR）。在训练初期，初始学习率被设定为 4.94e-4，允许网络快速降低损失；随后，学习率严格遵循余弦函数曲线进行平滑衰减

$$\eta_t = \eta_{min} + \frac{1}{2}(\eta_{max} - \eta_{min})\left(1 + \cos\left(\frac{T_{cur}}{T_{max}}\pi\right)\right) \tag{4.2}$$

相较于阶梯式衰减在节点处引发的梯度震荡，余弦退火机制能够引导模型在训练中后期以微小步幅逼近全局最优解，增强了网络的优化稳定性。

4. 应对稀疏损伤分布的损失函数重构

在 14 跨桁架的区域级（Zone-level）定位任务中，损伤标签的统计分布呈现出比第三章更为极端的长尾数据不平衡（Long-tail Imbalance）特征。在被离散化为 14 个独立物理状态区域的桁架中，针对单跨微弱损伤工况，其全局健康区域与受损区域的样本标签分布比例攀升至 13:1 。这种极度失衡的分布极易诱发梯度主导效应，使分类器陷入虚假局部最优解。为解决这一问题，本研究在寻优目标中放弃了标准的交叉熵，转而定制了带有动态正样本权重α的二元焦点损失函数

$$FL(p_t) = -\alpha_t(1-p_t)^{\gamma}\log(p_t) \tag{4.3}$$

通过引入聚焦参数$\gamma = 1.0$，强制优化器在反向传播时降低易分健康样本的梯度权重，将算力聚焦于早期损伤边界。

5. 后验决策阈值寻优

除了分布比例的客观失衡外，空间简支桁架在物理机制上同样具有显著的空间动力学敏感度异质性。由于模型对不同空间跨度的特征敏感度存在先天物理差异，采用统一固定的 0.5 概率阈值显然违背了动力学直觉。因此，本章将第三章提出的“逐层后验决策阈值校准机制”由 4 维扩展至 14 维空间。在模型推断阶段，算法基于验证集输出的连续概率分布，针对 14 个空间跨度分别在$[0.05, 0.95]$的概率阈值区间内执行网格搜索，独立寻找使各跨度局部 Macro-F1 指数达到最大化的阈值向量 $\tau_{opt} = [\tau_1, \tau_2, ..., \tau_{14}]$。

4.4.2 桁架损伤定位评价指标与基线模型设置

为了在 14 跨桁架结构中客观量化 DP-HDGNN 提取拓扑关联特征的优越性，本节在评价体系与对比基线的选取上进行了分析。本章引入了多尺度评价指标，并精心挑选了四类在特征提取机制上存在显著差异的基础深度学习架构作为平行对比阵营。

1. 复杂结构下的评价指标重构

在 14 跨桁架的区域级复合损伤定位任务中，网络的预测头被重构为 14 个二分类器。在这种极端不平衡的多标签分类设定下，传统的全局准确率因受到庞大健康基数的掩盖而失效。模型只需简单预测为健康状态，即可获得高达 92.8% 的准确率。 基于此，本章的量化评价体系严格聚焦于少数受损类的召回率与精确率，并重点考察两者的调和平均数以及精确率-召回率曲线下面积。在实际工程背景中：

假负类：意味着关键承载区域的隐蔽腹杆已发生疲劳断裂，但系统未报警。这种漏报是诱发结构局部失稳乃至连续性倒塌的直接元凶。

假正类：在包含数百根构件的庞大桁架中，频繁的虚警意味着引导维护人员前往安全的跨度进行无效排查，极大地损耗了检修成本。

因此，Macro-F1 分数作为兼顾漏报惩罚与虚警惩罚的综合性标尺，能够最客观地反映算法在复杂工业应用中的综合可靠度；而 PR-AUC 面积越接近 1，则代表模型在不同决策阈值下区分损伤特征的抗噪鲁棒性越强。

2. 密集节点下的基线模型理论剖析

在确保输入多点随机节点力激励张量与离散化标签完全对齐的严苛约束下，本章选取的四种经典基线模型在应对空间桁架时，暴露出了与其算法设计的不足：

多层感知机（MLP）：在处理多通道振动数据时，MLP 必须将输入张量在空间与时间维度上进行展平，随后映射至 14 个区域标签。这种机制忽略了时间序列的动态演化规律与传感器在三维空间中的拓扑约束。面对耦合的桁架响应，MLP 易遭遇过拟合现象。其架构如图 4.5 所示

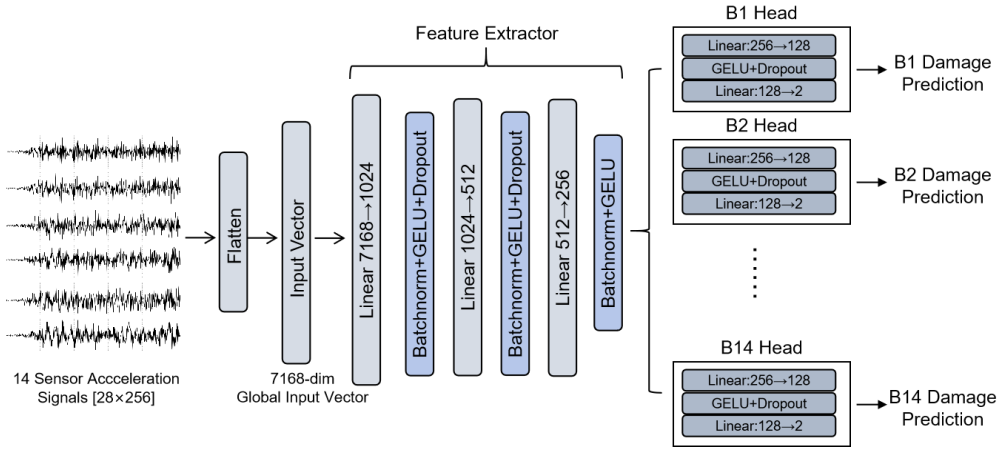


图 4.5 MLP Baseline 网络架构示意图

一维时序卷积网络（1D-CNN）：1D-CNN 引入了局部感受野能够捕捉时间序列的高频瞬态激变。然而，1D-CNN 依然受限于欧几里得网格假设，其本质上仅在时间轴上进行特征抽取，在空间轴上只能将不同传感器视为独立的平行通道。在多跨复合轻微损伤工况下，由于缺乏显式物理传导路径引导，1D-CNN 无法有效解耦频域信号中严重的模态混叠现象，导致空间解析度受限。其架构如图 4.6 所示

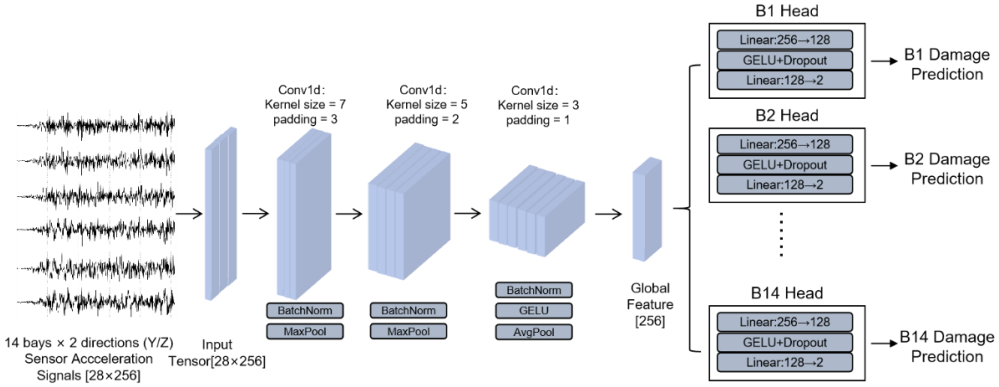


图 4.6 1D-CNN Baseline 网络架构示意图

时序图卷积网络（TCN-GCN）：GCN 通过谱图理论引入了处理非欧图拓扑的数学工具。但在 14 跨空间桁架网络中，节点规模与连通边缘密度较多。GCN 固有的拉普拉斯平滑算子在执行多阶邻居聚合时，等效于在密集的空间图上进行马尔可夫随机游走。在一个紧凑的局部网架中，单根受损杆件的高频异常特征在经过两层均值聚合后，会被周围多根健康杆件的低频宏观特征同化。这种因拓扑密度增加而导致的过平滑现象，是制约常规图卷积在空间桁架中取得高定位精度的核心问题。其架构如图 4.7 所示

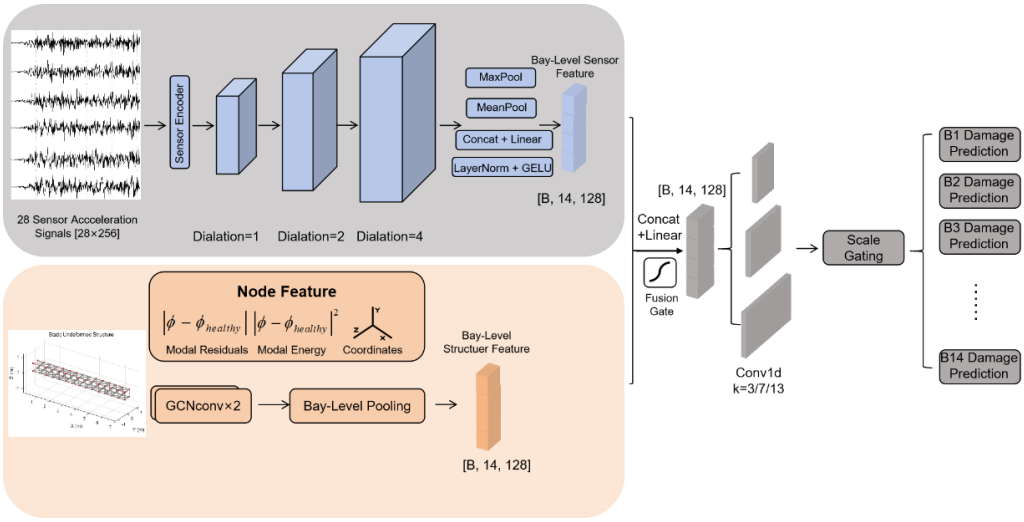


图 4.7 TCN-GCN Baseline 网络架构示意图

时序图注意力网络（TCN-GAT）：GAT 引入节点间的自注意力机制试图缓解过平滑。然而，常规 GAT 缺乏包含底层拓扑度数与几何坐标的高维物理边特征约束。在桁架节点密集且面临两点独立随机激振干扰下，GAT 的注意力系数计算缺乏空间距离衰减惩罚与圣维南原理的物理引导。这导致模型极易产生违背结构动力学规律的虚假远端关联矩阵，进而引发区域定位的严重干扰。其架构如图 4.8 所示

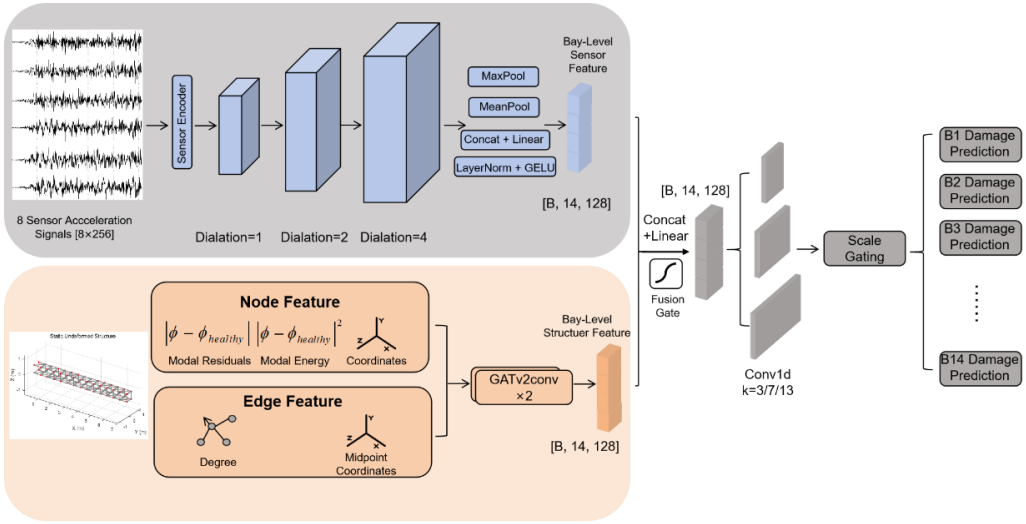


图 4.8 TCN-GAT Baseline 网络架构示意图

对比之下，本文提出的 DP-HDGNN 利用“软距离偏置”将严密的物理几何惩罚引入注意力计算，并结合数据驱动的 Top-K 掩码技术强制斩断冗余图连边。同时辅以基于物理坐标的池化机制，DP-HDGNN 在网络架构上规避了基线模型在应对复杂密集桁架拓扑时的盲区。

4.5 桁架结构损伤定位与传感器失效鲁棒性分析

本节旨在通过特征的量化指标与可视化矩阵，全面剖析数物双驱异构双图神经网络（DP-HDGNN）在 14 跨空间桁架结构中的损伤定位性能。为进一步贴近恶劣的真实工程服役环境，本节不仅评估了模型在完备监测网络下的理想性能，更引入了传感器失效的测试工况，以客观反映模型在传感器缺失时的鲁棒性。

4.5.1 DP-HDGNN 桁架损伤定位精度与混淆矩阵分析

在所有 14 个空间跨度节点均能稳定输出 Y 向与 Z 向加速度时序序列的理想工况下，DP-HDGNN 展现出了良好的区域级损伤解耦能力。面对高达 13:1 的极端健康/受损标签不平衡比例，所提模型在验证集上取得了超过 85.5% 的 Macro-F1 分数。

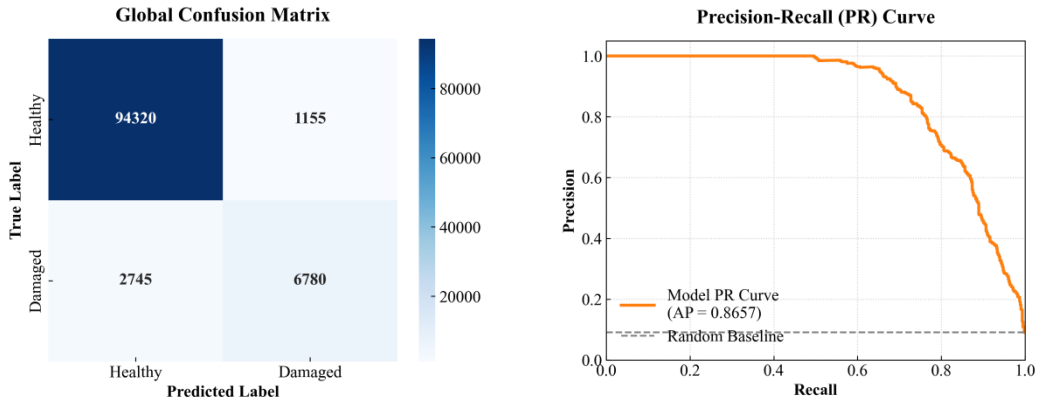


图 4.9 DP-HDGNN 在测试集上的混淆矩阵与 PR-AUC 曲线

图 4.9 给出了 DP-HDGNN 在测试集上的整体混淆矩阵与 PR-AUC 曲线。从整体混淆矩阵可以看出，模型对健康状态样本的识别具有较高稳定性，真负例数量远高于假正类数量；与此同时，受损样本也能够被较大比例地正确检出，说明模型已经具备从强健康背景中分离微弱损伤信号的能力。进一步结合数值可知，模型在全测试集上将大部分健康跨度准确判定为健康，而由局部随机波动引发的虚警数量相对较低；相比之下，漏报仍然是当前模型误差的主要来源。这一现象说明，在不平衡的区域级损伤识别任务中，模型整体呈现出谨慎的倾向，即优先抑制虚警，再在此基础上尽可能提高对真实损伤的召回能力。这样的误差结构与实际工程监测场景是吻合的：对于构件数量众多、局部响应耦合显著的空间桁架而言，若模型缺乏足够的拓扑约束，通常更容易出现大面积虚警；而 DP-HDGNN 能够将假正类控制在较低水平，说明其并未被局部噪声放大或远距离伪相关性所

主导。

从 PR 曲线的形态可以进一步验证上述判断。图中 PR-AUC 达到 0.8657，曲线在中高召回率区间内仍能保持较高精确率，仅在召回率逼近极限时才出现较为明显的下降。这表明模型并非依靠单一保守阈值换取表面上的低虚警，而是在不同决策阈值下都具备相对稳定的少数类判别能力。结合前文的动态图构建机制可以认为，模型在动态传感器图中引入的 Top-K 稀疏化约束，有效削弱了由远端弱相关节点形成的冗余信息传播；而结构图中的物理先验则为判别过程提供了稳定的拓扑参照，从而共同支撑了对少数类样本的有效识别。

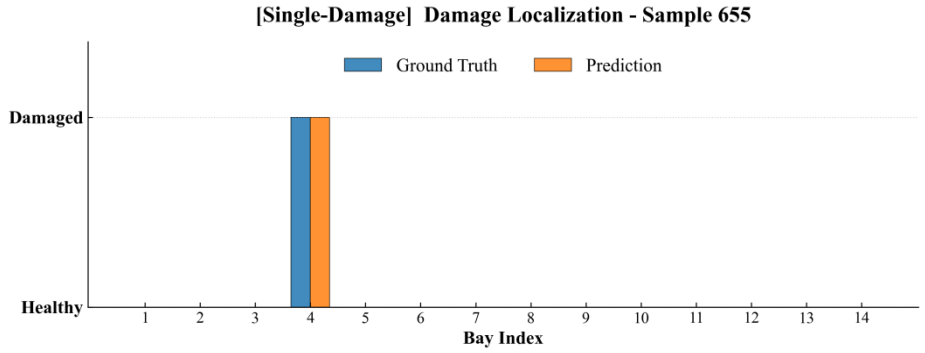


图 4.10 单损伤真实值与模型预测值对比图

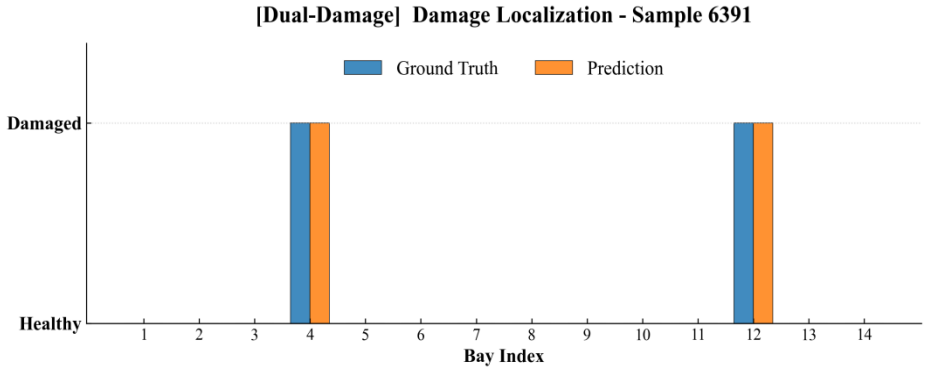


图 4.11 双损伤真实值与模型预测值对比图

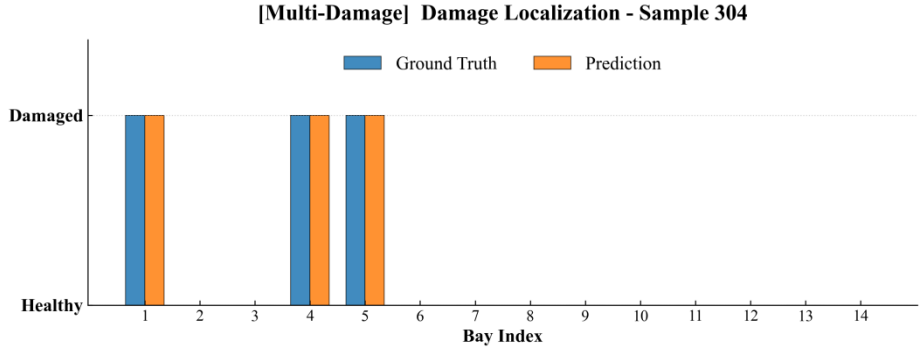


图 4.12 多损伤真实值与模型预测值对比图

为避免仅凭总体指标得出结论，图 4.10 至图 4.12 进一步展示了单损伤、双损伤与多损伤工况下典型样本的真实值与预测值对比结果。从图中可以看到，在代表性的单损伤样本中，模型能够准确锁定受损跨位，未出现相邻跨位的误报，说明其对局部孤立损伤具有较好的空间分辨率；在双损伤样本中，两个受损区域均被正确识别，表明模型能够在复合损伤条件下保持对多个异常区域的同时感知能力，未因局部特征竞争而遗漏其中一处损伤；在多损伤样本中，多个受损跨位与预测结果仍能保持一致，说明所提模型并不依赖单个传感器的异常响应完成定位，而是具备从多处扰动叠加的复杂响应中提取有效判别信息的能力。换言之，这三类典型样本共同说明，DP-HDGNN 的优势不仅体现在总体统计指标上，也体现在不同损伤复杂度下的一致性预测表现上。

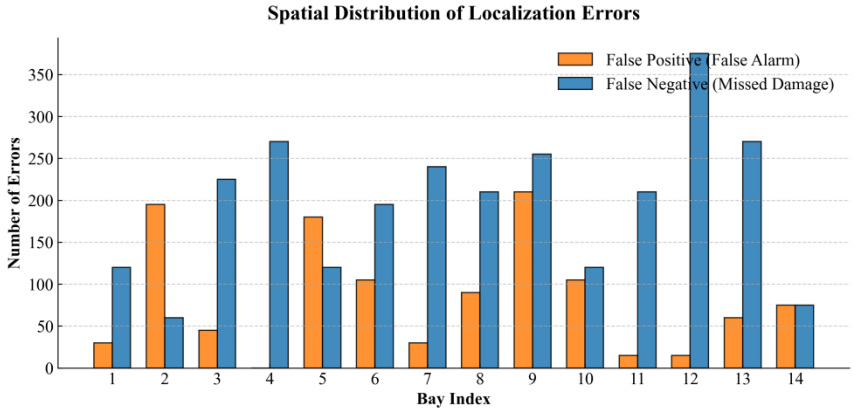


图 4.13 DP-HDGNN 各跨定位误差空间分布

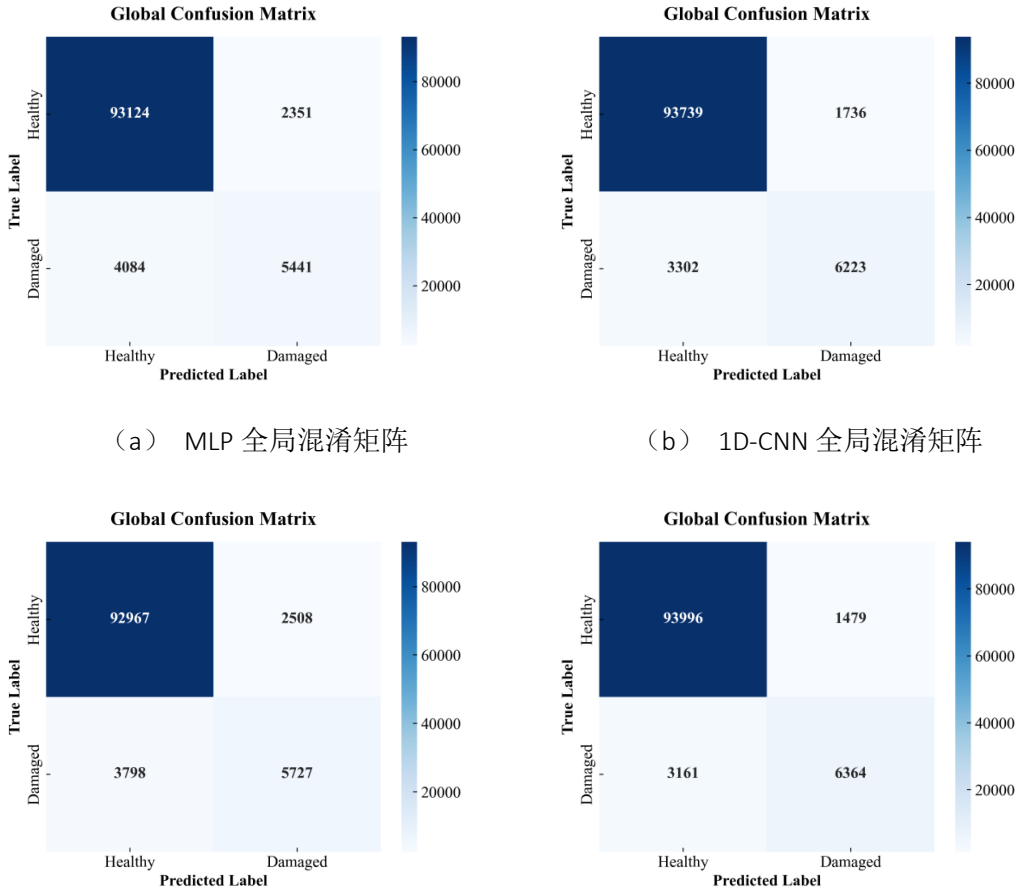
图 4.13 展示了测试集中各跨位定位误差的空间分布特征。可以看出，模型误差在不同跨位间呈现出明显的非均匀性，其中多数跨位的假负类数量高于假正类数量，表明模型整体仍表现出一定的保守判损倾向。相比之下，假正类仅集中于少数跨位，且其数量明显低于主要漏报区间，说明所提模型能够较好抑制误报警的空间扩散。值得注意的是，第四跨与第十二跨附近的漏报现象相对更为突出。结合工况设置可知，这两个跨位对应外部激励的施加位置，因此其响应信号更易受到激励主导成分的影响，导致损伤所引起的局部刚度退化信息在总响应中的相对表征被削弱。与此同时，激励能量沿桁架拓扑向周边构件传播，也会使局部异常特征在空间上发生扩散，从而增加模型对该区域损伤进行准确辨识的难度。该现象表明，在空间桁架结构中，激励输入位置附近的损伤识别更易受到强迫响应掩蔽效应的干扰，这也是导致区域间识别性能存在差异的重要原因之一。

4.5.2 基线模型对比与传感器失效鲁棒性分析

为凸显 DP-HDGNN 在理论架构上的优势，本节将四种经典深度学习基线模型（MLP、1D-CNN、TCN-GCN、TCN-GAT）置于相同的极端非平衡测试集与传感器失效工况下进行对比。

1. 完备监测网络下的理论瓶颈暴露

在无传感器失效的基准测试中，基线模型在面对 14 跨桁架的动力学响应时，暴露了其底层特征提取机制的局限性：



（a） MLP 全局混淆矩阵　　（b） 1D-CNN 全局混淆矩阵

（c） TCN-GCN 全局混淆矩阵　　（d） TCN-GAT 全局混淆矩阵

图 4.14 基准模型的全局混淆矩阵示意图

图 4.14 给出了四种基线模型在 14 跨桁架损伤定位任务中的全局混淆矩阵对比结果。可以看出，不同模型在健康类与受损类样本上的判别能力存在显著差异。总体而言，MLP 与 1D-CNN 的矩阵中均表现出较为突出的假负类累积现象，即模型更倾向于将真实受损跨度误判为健康状态，说明纯数据驱动模型在面对密集桁架中耦合多通道响应时，难以有效从宏观背景振动中剥离局部损伤特征。相比之下，TCN-GCN 与 TCN-GAT 虽然引入了图结构信息，但其对受损类样本的识别仍未达到理想水平：前者受限于密集图上的过平滑效应，后者则由于缺乏充

分的物理先验约束，注意力分配仍存在一定的离散与扩散现象。由此可见，在密集空间桁架场景下，仅依赖浅层图聚合或纯时序卷积，均难以实现对局部损伤区域的稳定解耦。

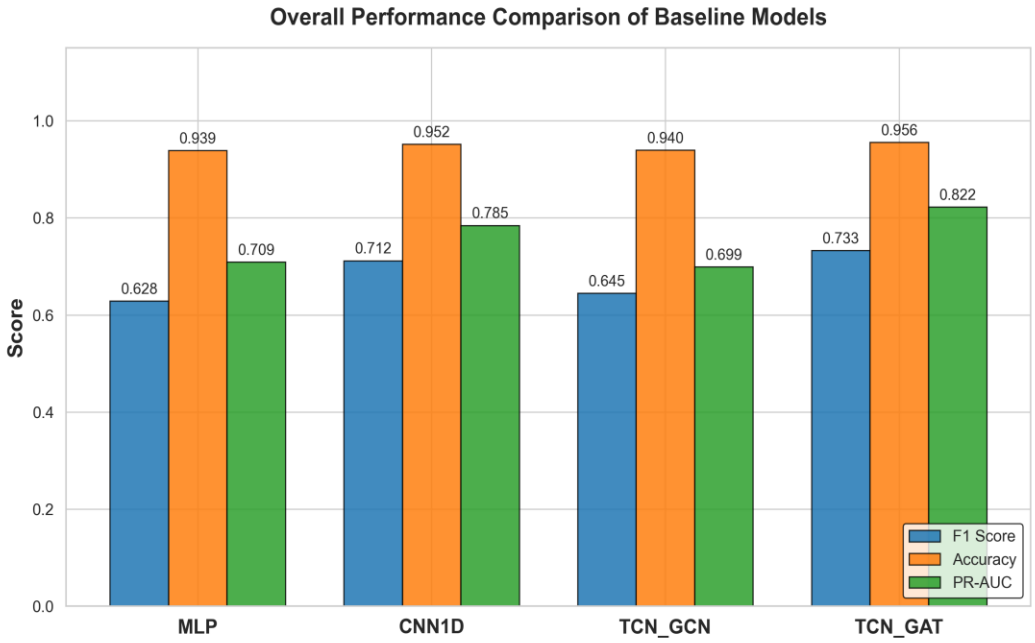


图 4.15 基准模型的综合表现

图 4.15 展示了四种基线模型在 F1 分数、整体准确率与 PR-AUC 三项指标上的综合表现。可以看出，虽然各模型在整体准确率维度上的差异并不如 F1 与 PR-AUC 那样显著，但这并不意味着其损伤定位能力接近。其原因在于，14 跨桁架任务具有明显的健康类占优特征，单纯依赖整体准确率容易受到大量健康样本的掩盖，从而高估模型的真实性能。相较之下，F1 分数与 PR-AUC 更能反映模型在少数受损类上的综合识别能力。从图中可以观察到，MLP 与 1D-CNN 在 F1 和 PR-AUC 上整体处于较低水平，表明其对损伤类样本的召回率与精确率均存在明显不足；TCN-GCN 虽引入图卷积机制，但受密集拓扑中过平滑现象影响，其综合指标仍未取得实质性突破；TCN-GAT 则在整体表现上略优于前述模型，说明注意力机制在一定程度上缓解了固定均值聚合带来的特征同质化问题。然而，即便如此，传统基线模型仍未能同时兼顾高精确率与高召回率，这也进一步说明仅靠常规图学习框架，仍难以解决空间桁架结构中的局部损伤解耦难题。

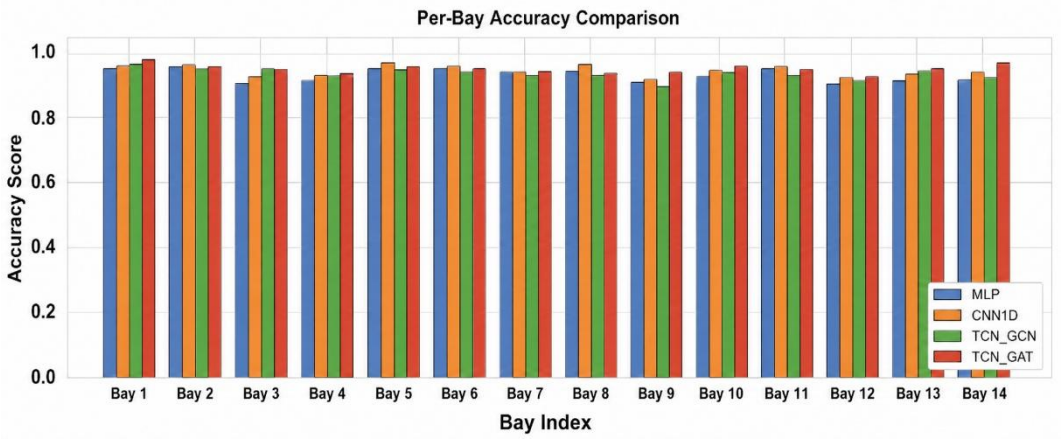


图 4.16 基准模型准确率对比空间分布图

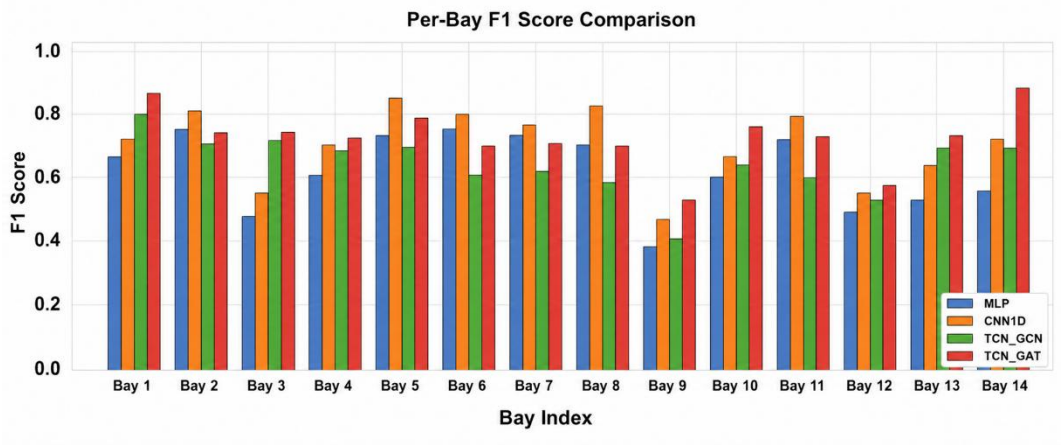


图 4.17 基准模型 F1 对比空间分布图

图 4.16 与图 4.17 进一步展示了不同基线模型在各跨区域上的准确率与 F1 分数空间分布，相较于准确率，图 4.17 更能真实反映模型对局部损伤的空间解耦能力。可以看出，各模型的 F1 值在不同跨位之间呈现出更明显的波动特征，说明空间桁架中不同区域的损伤识别难度存在显著差异。总体而言，MLP 在多数跨位上的 F1 值均处于较低水平，表明其在缺乏时空结构归纳偏置的情况下，难以从高维耦合响应中提取稳定的局部损伤特征；1D-CNN 虽在若干跨位上较 MLP 有一定改善，但仍表现出明显的跨间不均衡，说明单纯依赖时间轴卷积难以解决空间模态混叠问题；TCN-GCN 的 F1 分布则进一步揭示了密集拓扑下图卷积的过平滑缺陷，即局部损伤特征在多跳邻域传播中被周围健康杆件的背景响应迅速稀释，导致部分跨位的识别性能显著受损；相较之下，TCN-GAT 在大多数跨位上取得了更高的 F1 值，说明注意力机制在一定程度上提升了模型对关键区域的聚焦能力，但其空间分布仍存在明显起伏，表明缺乏显式物理约束的注意力权重仍不足以抑制密集拓扑中的信息扩散。由此可见，图 4.17 比图 4.16 更直

接地揭示了传统基线模型在复杂空间桁架场景下的局部定位瓶颈。

2. 传感器鲁棒性试验与双图协同效应剖析

在实际工程服役环境下，传感器由于信号传输中断或硬件损坏导致的测点失效是不可避免的随机事件。因此，一个真正具备工程应用潜力的损伤识别模型，不仅应当在监测网络完备的理想条件下保持较高精度，更应当在局部观测缺失时仍维持稳定的判别能力。基于此，本节进一步引入“随机传感器失效”工况，以系统考察不同模型在传感器失效条件下的鲁棒性，并借此揭示 DP-HDGNN 双图协同机制的优势。

首先，在第三章所构建的 IASC-ASCE 多层剪切框架场景中，本文对传感器失效条件下的识别性能进行了初步验证。相关结果如图 4.19 所示：当框架结构中部分观测通道被随机掩盖后，传统纯时序模型与单图模型的性能均出现了不同程度的退化，而 DP-HDGNN 仍能够保持较为稳定的识别结果。其原因在于，ASCE 框架虽然存在层间耦合与扭转效应，但整体上仍具有清晰的楼层分界，因此当局部测点缺失时，模型尚可依赖其余楼层相邻节点的动态响应以及结构物理图中的拓扑约束，完成对损伤楼层的重构。其实验结果初步表明：DP-HDGNN 的性能并不完全依赖某一个固定传感器通道，而是能够通过动态图与物理图之间的异构对齐，在观测缺失时重新分配注意力权重，将判别重心转移至其余仍然有效的响应节点。这一现象为本章进一步讨论更高复杂度空间桁架中的鲁棒性问题提供了直接的先验证据。

桁架场景下的随机传感器失效试验，本质上是在比第三章更严苛的条件下，对 DP-HDGNN 的双图协同机制进行压力测试。图 4.18 与表 4.4 给出了不同模型在随机测点失效工况下的性能对比结果。可以看到，传统深度学习模型在传感器缺失条件下的表现揭示了明显的架构脆弱性：对于 MLP 与 1D-CNN 等纯时序模型，由于输入张量与测点通道严格绑定，一旦某个测点被零值掩盖，其后续卷积或全连接计算会立即发生统计分布偏移，导致深层特征整体失真；而对于 TCN-GCN 等静态图模型，失效节点产生的异常零值特征在拉普拉斯平滑过程中会沿邻接矩阵向周边节点扩散，进而诱发全子图范围内的特征污染。这种由单点缺失触发的级联退化，正是传统图模型在复杂空间拓扑中鲁棒性不足的根本原因。

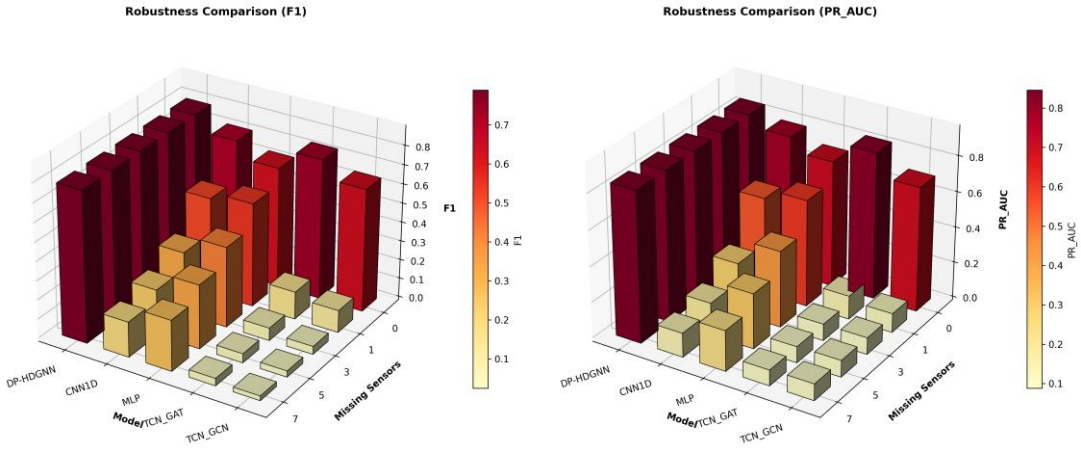


图 4.18 DP-HDGNN 与 Baseline 在桁架结构上鲁棒性综合对比图

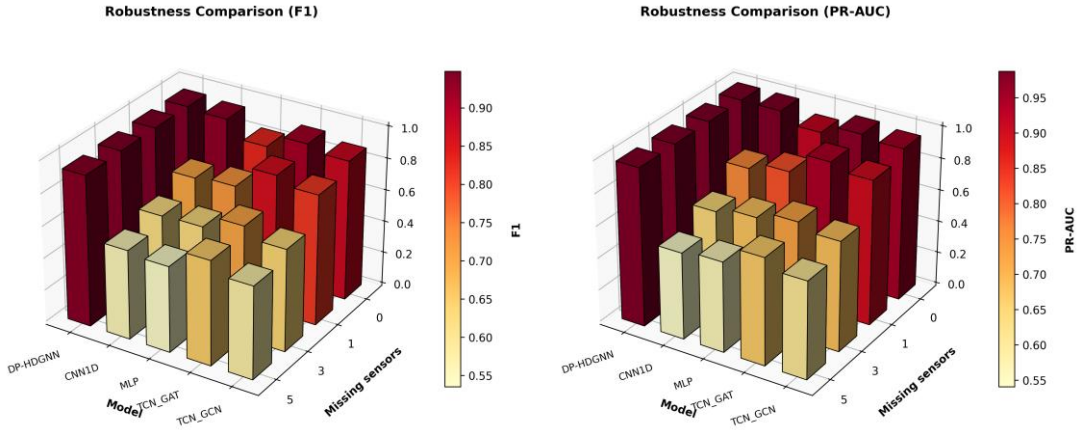


图 4.19 DP-HDGNN 与 Baseline 在 ASCE 结构上鲁棒性综合对比图

表 4.4 ASCE 与桁架数据集中传感器鲁棒性试验 F1 结果对比表

模型名称 缺失传感器个数	ASCE 数据集			桁架数据集			
	1	3	5	1	3	5	7
DP-HDGNN	**0.948**	**0.945**	**0.939**	**0.789**	**0.788**	**0.788**	**0.787**
CNN1D	0.704	0.615	0.556	0.507	0.326	0.239	0.184
MLP	0.723	0.622	0.535	0.543	0.421	0.335	0.266
TCN-GAT	0.862	0.702	0.650	0.144	0.066	0.048	0.039
TCN-GCN	0.813	0.637	0.576	0.116	0.042	0.032	0.024

相比之下，DP-HDGNN 在桁架场景下仍表现出明显优于基线模型的稳定性。在随机 1 个测点失效的条件下，模型的 F1 与 PR-AUC 虽较完备测点工况有所下降，但整体仍保持在较高水平，说明其并未因局部观测中断而立即失去对受损区域的判别能力。这一点与第三章 ASCE 框架中的现象相互呼应，二者都是在传感器损失的条件下利用结构物理图提供的拓扑先验，在交叉注意力权重计算阶段自动降低失效测点对结构节点表征的贡献，将决策重心转移至其余健康通道及

其对应的物理区域。正因为存在这一机制，DP-HDGNN 才表现出更平滑的性能衰减曲线。

为进一步解耦“双图协同”机制中各模块的独立贡献，并验证时域特征在极端工况下的必要性，本节增设了桁架结构全测点（14 个传感器）失效的极端边界工况实验。如图 4.20 所示，当所有观测节点的时域信号均被掩盖时，模型的输入特征实质上退化为单一的静态物理图骨架，此时 DP-HDGNN 的 F1 分数与 PR-AUC 指标均出现了明显下降。说明模型的高精度识别能力并不能仅由静态物理图单独支撑。换言之，结构物理图的主要作用在于提供稳定的拓扑边界、抑制异常扩散并在局部观测缺失时提供先验约束；用于感知实时损伤响应、识别局部刚度退化的信息，仍然来自动态传感器图所提取的动力学特征。只有当二者通过交叉注意力实现有效对齐后，模型才能同时获得这两类互补信息，进而形成对复杂损伤模式与观测残缺的联合鲁棒性。由此可见，DP-HDGNN 的性能优势并非来自某一个单独模块，而是来自其整体的协同机制。

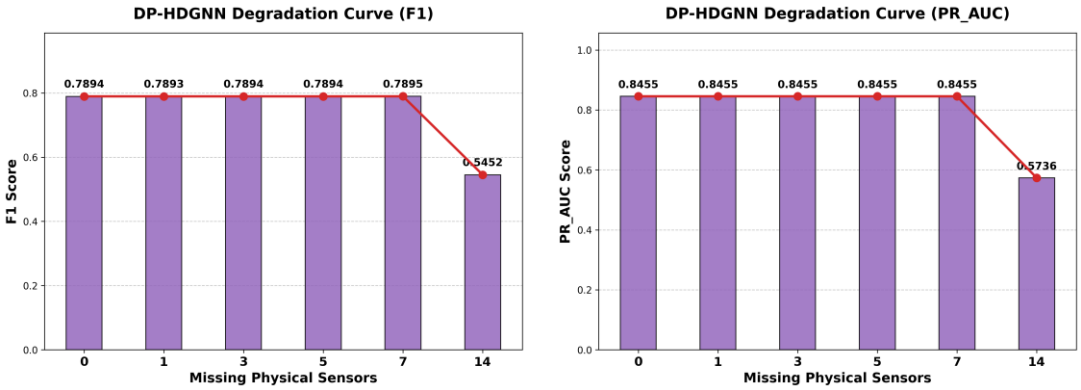


图 4.20 极端传感器失效工况下 F1 与 PR-AUC 表现

综上量化对比与机理剖析可知，无论是基于欧几里得空间的传统序列网络，还是缺乏真实力学约束的浅层图聚合模型，均难以克服大型空间桁架结构中的信号跨区域串扰与失效级联误差。本文构建的 DP-HDGNN 凭借“动态稀疏截断”与“物理先验交叉门控”的双重保障机制，抑制了过平滑效应与异常噪声的空间扩散，在应对极端的传感器缺失与类别长尾分布等工程实际挑战中，确立了显著的架构优势与鲁棒性。

4.6 本章小结

本章围绕 DP-HDGNN 在复杂结构中的损伤定位能力与传感器失效条件下的鲁棒性开展数值验证。本章重点考察模型在节点连接更密集、区域损伤边界更

复杂以及观测信息缺失条件下的识别稳定性。主要工作与结论如下。

(1) 构建了面向空间桁架结构的区域级损伤定位任务数据集

本章建立了 14 跨空间简支桁架有限元模型，并通过杆件刚度折减生成健康状态、单区域损伤和多区域复合损伤样本。同时，本章将 14 个结构跨定义为 14 个损伤识别区域，构建区域级多标签损伤定位任务，用于考察 DP-HDGNN 在不同结构形式下的泛化性能。

为使模型适应该桁架算例的结构特点，本章在保持 DP-HDGNN 核心架构不变的基础上，对输入特征和输出形式进行了相应调整。在结构图边特征构造方面，考虑到桁架杆件主要承担轴向拉压作用，本文去除了框架结构中用于区分梁、柱、斜撑的构件类型编码，保留节点度数关系和杆件空间位置信息等更符合桁架连接特征的拓扑—几何属性；在模型输出方面，将原有楼层级损伤判别调整为 14 跨区域级输出，使模型预测结果能够与桁架结构的空间分区和损伤设置相对应。由此，本章形成了适用于空间桁架结构的区域级双图样本，为后续损伤定位性能对比和传感器失效鲁棒性分析提供了数据基础。

(2) 验证了 DP-HDGNN 在复杂结构损伤定位中的有效性

在测点完整条件下，本章将 DP-HDGNN 与 MLP、1D-CNN、TCN-GCN 和 TCN-GAT 等模型进行对比。结果表明，纯时序模型缺乏结构连接关系约束，难以从高维耦合响应中稳定分离局部损伤特征；常规图模型虽然引入了拓扑聚合机制，但在密集连接结构中仍可能受到过平滑或注意力扩散影响，导致局部损伤特征被周围健康区域响应削弱。相比之下，DP-HDGNN 通过结构图提供稳定拓扑参照，并利用动态传感器图刻画测点间时变相关性，在区域级损伤识别任务中表现出更稳定的定位能力。

(3) 评估了传感器随机失效条件下的模型鲁棒性

本章通过随机屏蔽部分传感器响应，模拟实际监测中的测点缺失和观测通道中断。结果表明，MLP 和 1D-CNN 等纯时序模型对输入通道缺失较为敏感，性能随缺失测点数量增加而明显下降；TCN-GCN 和 TCN-GAT 等常规图模型在传感器失效后也出现显著退化，说明固定图聚合或单一图注意力难以充分抵抗观测不完整带来的特征污染。相比之下，DP-HDGNN 在部分传感器缺失条件下仍能维持较稳定的识别性能。其原因在于，结构物理图为模型提供了拓扑先验；动态传感器图则能够基于剩余有效测点重新刻画响应相关性，并通过交叉注意力机制将观测信息映射至结构物理空间，从而在一定程度上补偿缺失测点造成的信息不足。该结果说明，DP-HDGNN 的传感器失效鲁棒性并非来源于单一模块，而是来自结构物理图、动态传感器图和异构融合机制之间的信息互补作用。

综上，本章通过一 14 跨空间简支桁架算例与随机传感器失效试验，进一步

验证了 DP-HDGNN 在复杂结构和传感器不完整条件下的适用性。研究结果表明，所提模型不仅能够从框架结构推广到更复杂的结构，还能够在部分测点缺失时依托结构拓扑先验和剩余传感器响应维持较稳定的损伤定位性能。需要指出的是，第三章和第四章均基于有限元仿真数据开展验证，而真实结构实测数据还会受到材料参数误差、边界条件差异、连接状态不确定和环境噪声等因素影响。因此，下一章将开展高保真传感器数据与仿真数据融合条件下的真实结构损伤定位问题研究与实验验证。

第5章 基于迁移学习增强的异构双图神经网络结构损伤定位方法及实验验证

5.1 引言

第三章和第四章分别从框架结构复合损伤定位、复杂结构损伤识别以及传感器随机失效鲁棒性等方面验证了 DP-HDGNN 的有效性。上述研究均基于有限元仿真数据开展，仿真数据具有损伤工况可控、标签明确、样本数量充足等优势，能够为深度学习模型训练提供稳定的数据基础。然而，在实际工程中，真实结构受损样本往往难以大量获取，尤其是严重损伤或多位置复合损伤状态具有偶发性、不可重复性和高风险性，难以依靠实测数据覆盖结构从健康到破坏的完整生命周期。因此，仅依赖真实受损样本训练深度模型并不现实。

利用有限元模型生成损伤样本，并将仿真数据中学习到的损伤识别能力应用于真实结构，是缓解真实损伤样本不足的重要途径。但仿真数据与高保真实测传感器数据并不完全一致。有限元模型与真实结构中存在因为模型简化而产生的差异。这些差异会体现在结构模态参数、加速度响应统计特征以及模型高维表示空间中，导致仅由仿真数据训练得到的模型直接应用于实测数据时容易出现性能下降。

针对上述问题，本章研究基于迁移学习增强的 DP-HDGNN 损伤定位方法。该方法以有限元仿真数据作为源域，提供可控的有标签损伤样本；以一真实钢框架试验数据作为目标域，提供高保真传感器响应与真实结构约束。通过迁移增强策略，模型先从源域数据中学习损伤判别规律，再利用目标域数据修正结构特征表示和高维特征分布，实现源域—目标域数据融合，从而提高仿真训练模型在真实结构响应中的适应能力。

具体而言，本章首先通过实测模态识别与仿真—实测模态匹配，使源域与目标域数据在结构图特征层面保持物理对应关系；随后引入迁移学习域对齐思想，采用多核最大均值差异减小源域仿真特征与目标域实测特征在高层表示空间中的分布偏差；并结合真实健康样本约束、高置信伪标签和后验阈值校准，进一步提升模型在真实钢框架损伤定位任务中的识别稳定性。

最后，本章以一真实钢框架试验数据对所提方法进行实验验证。首先，将仅由仿真数据训练得到的模型直接应用于实测数据，用于分析仿真数据与实测数据差异对损伤识别结果的影响；随后，在仿真训练模型的基础上引入高保真实测传

感器数据，并与 MLP、1D-CNN、TCN-GCN、TCN-GAT 等基线模型进行对比。实验结果表明，所提方法能够有效减小仿真特征与实测特征之间的分布差异，并在真实受损标签不参与网络训练的条件下提升真实钢框架损伤识别性能，验证了高保真传感器数据与仿真数据融合用于真实结构损伤定位的有效性。其整体架构如图 5.1 所示

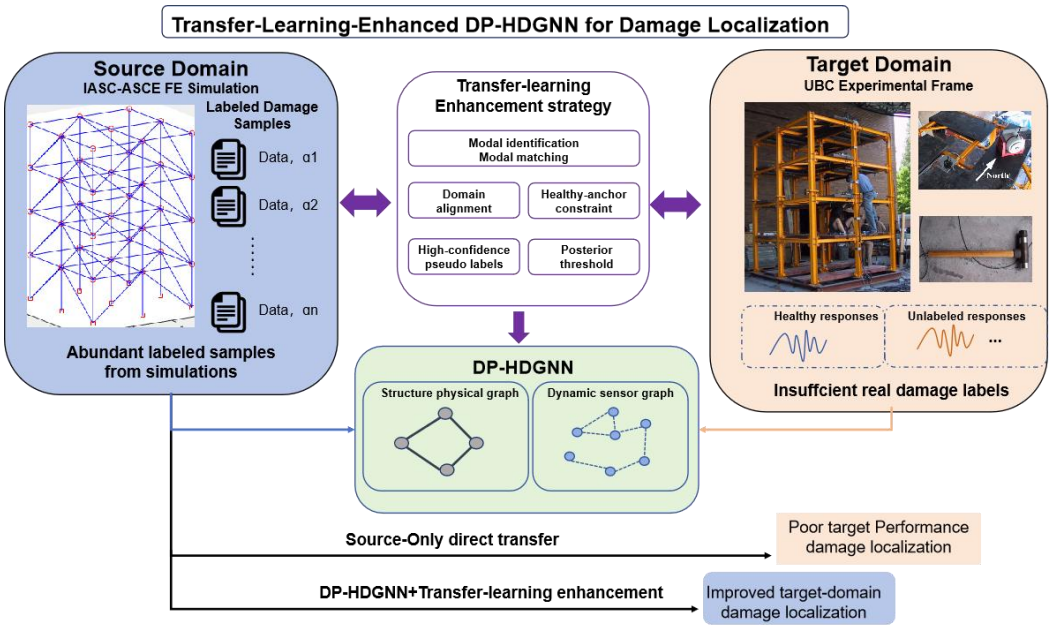


图 5.1 基于迁移学习增强的 DP-HDGNN 损伤定位流程图

5.2 基于迁移学习增强的仿真—实测特征差异修正方法

由图 5.1 可知，本章所述仿真—实测数据融合并不是将两类样本简单合并后直接训练，而是在 DP-HDGNN 主干网络基础上引入迁移增强策略，使源域仿真数据与目标域实测数据在特征学习过程中协同参与模型优化。因此，本节重点为如何在训练优化层面对仿真特征与实测特征之间的差异进行修正。

具体而言，迁移增强策略主要包括源域监督学习、目标域无标签约束和源域—目标域特征对齐三个部分。首先，利用带标签仿真样本对模型进行监督训练，使 DP-HDGNN 能够从源域数据中学习基本的损伤判别能力；其次，引入真实健康样本和无标签实测响应，对模型在目标域数据上的输出分布进行约束，减小模型对仿真数据特有响应模式的依赖；最后，采用多核最大均值差异（Multi-Kernel Maximum Mean Discrepancy, MK-MMD）度量源域仿真特征与目标域实测特征在高维表示空间中的分布差异，并将其作为联合优化目标中的特征对齐约束。通过上述处理，模型能够在保持仿真样本监督学习能力的同时，逐步提高对真实钢框

架响应的适应能力。

5.2.1 源域监督训练与目标域无标签约束的联合优化

为实现仿真数据与实测数据在训练过程中的协同利用，本文在 DP-HDGNN 主干网络基础上构建联合优化目标。该目标由三部分组成：一是源域仿真样本的监督损失，用于保证模型能够从有标签仿真样本中学习楼层级损伤判别能力；二是目标域实测样本的无标签约束，用于利用健康样本和无标签实测响应修正模型在真实结构数据上的输出分布；三是源域—目标域特征差异约束，用于通过 MK-MMD 减小两类数据在高层表示空间中的分布差异。整体损失函数定义为：

$$L = L_{sim} + \lambda_{real} L_{real} + \lambda_{mmd}(p) L_{mmd} \tag{5.1}$$

其中，L_{sim} 用于保证模型在仿真样本上的损伤判别能力，L_{real} 用于利用实测样本自身的分布信息约束模型输出，L_{mmd} 用于缩小仿真特征与实测特征在高层表示空间中的差异；λ_{real} 和 $\lambda_{mmd}(p)$ 分别为对应损失项的权重，p 表示训练进程。

1. 仿真样本监督损失

对于带有完整标签的仿真样本，模型需要学习楼层级损伤分类边界，并保持对健康/受损状态的基本区分能力。本文将仿真监督损失定义为：

$$\mathcal{L}_{sim} = \mathcal{L}_{cls} + \lambda_{bin}\mathcal{L}_{bin} + \lambda_{ord}\mathcal{L}_{ord} \tag{5.2}$$

其中，$\mathcal{L}_{cls}^{s}$ 作为主分类任务，采用结合类别先验分布的加权交叉熵，以惩罚长尾数据分布下少数类的预测偏差。$\mathcal{L}_{bin}^{s}$ 为健康/受损二元辅助损失，用于强化模型对异常状态的基础判别能力；$\mathcal{L}_{ord}$ 为损伤程度顺序约束，用于表达刚度折减程度之间的相对顺序关系。该项并不改变模型的最终分类目标，而是用于减少不同损伤等级在特征空间中的无序分布。

2. 实测样本无标签约束

由于真实受损标签不参与训练，实测数据主要通过健康锚点、信息熵约束和高置信伪标签三种方式参与模型优化。实测样本约束项写为：

$$\mathcal{L}_{real} = \lambda_{h}\mathcal{L}_{h} + \lambda_{ent}\mathcal{L}_{ent} + \lambda_{pseudo}\mathcal{L}_{pseudo} \tag{5.3}$$

其中，$\mathcal{L}_{h}$ 为实测健康锚点损失。真实结构的健康状态通常较容易获取，因此本文选取少量 UBC 健康基准样本作为实测健康锚点，约束其在模型输出端收敛至健康类别。该处理能够为实测数据提供稳定参考，减少特征空间无序漂移。

信息熵约束 $\mathcal{L}_{ent}^{t}$ 用于降低模型对无标签实测样本的预测不确定性，其形式为：$\mathcal{L}_{ent}^{t} = -\frac{1}{N_t}\sum y_t \log y_t$，通过最小化信息熵，模型倾向于将实测样本划分至更明确

的类别区域，从而降低模糊判别带来的不稳定性。

对于预测置信度较高的实测样本，本文进一步引入伪标签自训练损失 $\mathcal{L}_{pseudo}^{t}$，当模型对某一实测样本的预测概率高于 $P_{high}=0.85$ 或低于 $P_{low}=0.15$ 时，将其作为高置信样本参与伪标签训练。该策略仅利用模型较为确定的实测样本，避免低置信样本对分类边界造成干扰。

3. 动态权重调度

在训练初期，模型的高维特征尚未稳定，若过早施加较强的仿真—实测特征差异约束，可能影响仿真分类边界的形成。因此，本文采用随训练进程逐步增强的动态权重：

$$\lambda_{mmd}(p)=\begin{cases}0, & p<0.1\\ \lambda_{max}\left(\dfrac{2}{1+\exp\left[-\gamma\dfrac{p-0.1}{0.9}\right]}-1\right), & p\geq 0.1\end{cases} \tag{5.4}$$

其中，$p\in[0,1]$ 为归一化训练进度，λ_{max} 为最大权重，γ 控制权重增长速度。该调度策略使模型在训练前期优先学习仿真样本中的损伤判别规律，随后逐步增强实测数据融合约束，从而提高训练过程的稳定性。

此外，为避免不同损失项对分类边界产生过强扰动，本文采用分组学习率策略：DP-HDGNN 主干特征提取器采用相对较高的学习率，以保持特征空间调整能力；分类头采用较低学习率，以减少伪标签和差异约束对最终判别边界的剧烈影响。

5.2.2 基于 MK-MMD 的多尺度特征分布对齐

仿真数据与实测数据之间的特征分布差异不仅体现在原始加速度时程上，也会传递至模型的高维特征空间。为了约束两类数据在高层表示中的统计差异，本文采用最大均值差异（Maximum Mean Discrepancy, MMD）作为非参数距离度量。MMD 通过比较两组样本在再生核希尔伯特空间中的均值嵌入来衡量分布差异。

设仿真样本的高维特征集合为：$\mathcal{H}_{sim}=\left\{h_i^{sim}\right\}_{i=1}^{m}$，实测样本的高维特征集合为：$\mathcal{H}_{real}=\left\{h_j^{real}\right\}_{j=1}^{n}$，则二者的 MMD 距离定义为：

$$MMD^2\left(\mathcal{H}_{sim},\mathcal{H}_{real}\right)=\left\|\frac{1}{m}\sum_{i=1}^{m}\phi\left(h_i^{sim}\right)-\frac{1}{n}\sum_{j=1}^{n}\phi\left(h_j^{real}\right)\right\|_{\mathcal{H}}^2 \tag{5.5}$$

其中，$\phi(\cdot)$ 为核映射函数，$\mathcal{H}$ 表示再生核希尔伯特空间。根据核技巧，上式可写为经验估计形式：

$$\mathrm{MMD}^2(H_s,H_t)=\frac{1}{m^2}\sum_{i=1}^{m}\sum_{j=1}^{m}k(\mathrm{h}_s^{(i)},h_s^{(j)})+\frac{1}{n^2}\sum_{i=1}^{n}\sum_{j=1}^{n}k(h_t^{(i)},h_t^{(j)})-\frac{2}{mn}\sum_{i=1}^{m}\sum_{j=1}^{n}k(h_s^{(i)},h_t^{(j)}) \tag{5.6}$$

其中，$k(\cdot,\cdot)$为核函数。最小化 MMD 的作用，是在高维特征空间中减小仿真样本与实测样本的均值嵌入差异，使模型不再仅依赖仿真数据中特有的响应模式进行判别。

考虑到结构响应包含不同尺度的动力特征，单一带宽的核函数难以同时刻画整体低频响应和局部高频扰动。为此，本文采用多核最大均值差异（Multi-kernel MMD, MK-MMD），将多个不同带宽的高斯核进行线性组合，其原理如图 5.2 所示：

$$k_{mk}(h,h')=\sum_{u=1}^{U}\beta_u k_u(h,h';\sigma_u) \tag{5.7}$$

$$\sum\beta_u=1,\beta_u\geq 0 \tag{5.8}$$

其中，σ_u为第 u 个高斯核的带宽参数，β_u为对应权重。窄带宽核更关注局部特征差异，宽带宽核更关注整体分布差异。通过多尺度核组合，MK-MMD 能够更充分地约束仿真数据与实测数据在不同特征尺度上的差异。

在具体实现中，本文分别对实测健康锚点和高置信伪标签样本施加特征差异约束。整体损失可表示为：

$$\mathcal{L}_{mmd}=MMD_{mk}^2\left(\mathcal{H}_{sim}^h,\mathcal{H}_{real}^h\right)+\alpha MMD_{mk}^2\left(\mathcal{H}_{sim}^p,\mathcal{H}_{real}^p\right) \tag{5.9}$$

其中，$\mathcal{H}_{sim}^h$和$\mathcal{H}_{real}^h$分别表示仿真健康样本与实测健康锚点的高维特征；$\mathcal{H}_{sim}^p$和$\mathcal{H}_{real}^p$分别表示仿真样本与高置信实测伪标签样本中类别相对应的特征集合；α为伪标签样本约束项权重。该设计能够在不使用真实受损标签参与训练的前提下，利用实测数据自身的分布结构修正模型高维表示。

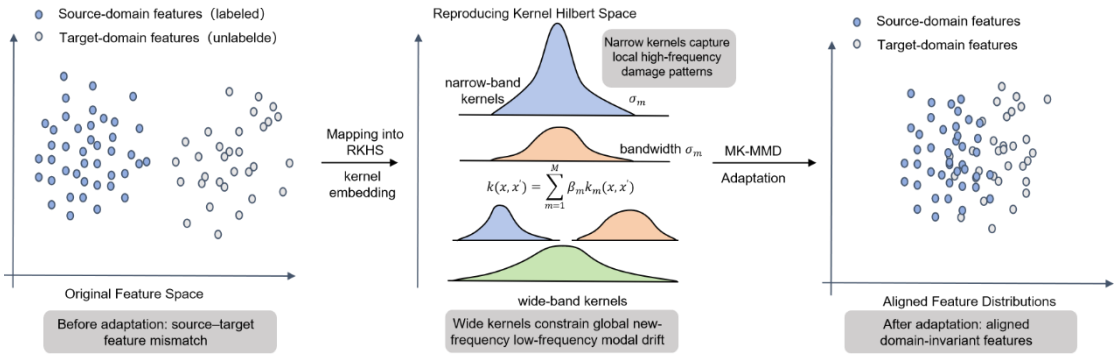


图 5.2 MK-MMD 原理示意图

综上，本文采用 MK-MMD 对仿真特征与实测特征进行多尺度特征分布对齐，并结合健康锚点、信息熵约束和高置信伪标签训练，使模型在保留仿真样本损伤判别能力的同时，提高对 UBC 真实钢框架响应的适应能力。该方法为真实损伤样本不足条件下的结构损伤定位提供了可实现的训练策略。

5.2.3 后验阈值校准策略

上述 MK-MMD、健康锚点和伪标签约束主要作用于模型的特征表示层面，用于缓解仿真样本与实测样本之间的分布差异。然而，在最终损伤定位任务中，模型仍需将连续概率输出转化为离散的楼层级损伤标签。若继续采用 0.5 作为阈值进行损伤判定，容易导致部分楼层漏报或误报。为缓解这一问题，本文引入楼层级后验阈值校准策略。

具体而言，本文在验证集上冻结网络参数，仅对模型输出概率进行后处理。设模型对验证集中第 j个样本在第 i个楼层上的连续预测概率为 $Y_t^{(i)} \in [0,1]^{N_{val}}$，对应真实二值标签为 $Y_t^{(i)} \in \{0,1\}^{N_{val}}$。对于每一个楼层 i，在区间 $[0.05, 0.95]$ 内构建候选阈值集合，并逐一计算该楼层在验证集上的 F1 分数。最优阈值定义为：

$$\tau_{opt}^{(i)} = \arg\max_{\tau_k} F1\text{-}Score(Y_t^{(i)}, \mathbb{I}(Y_t^{(i)} > \tau_k)) \tag{5.10}$$

上述遍历操作在结构各层级分类器上独立展开，最终求解得到适配于真实数据的最优阈值向量 $\tau_{opt} = [\tau_{opt}^{(1)}, \tau_{opt}^{(2)}, \tau_{opt}^{(3)}, \tau_{opt}^{(4)}]$。在测试阶段，模型输出的概率张量将与该校准向量进行比较，从而生成最终的损伤定位结果。这一基于验证分布后验寻优的阈值校准策略，从统计决策层面补偿了模型在复杂物理环境下的敏感度退化问题。

5.3 基于 SSI-COV 与 MAC 的结构模态匹配方法

5.3.1 基于 SSI-COV 的实测模态参数识别

DP-HDGNN 的结构图分支需要节点模态特征作为输入。对于有限元仿真数据，结构频率与振型可由模型直接计算获得，而对于真实试验结构，模型参数、边界条件和连接状态无法完全确定，输入激励也难以准确测量，因此无法直接使用有限元模型中的模态特征代替实测结构特征。为使实测数据能够构造与仿真数据一致的结构图节点特征，本文首先采用协方差驱动随机子空间识别法（Covariance-driven Stochastic Subspace Identification, SSI-COV）从实测加速度响应中提取结构模态参数；随后，利用模态保证准则（Modal Assurance Criterion,

MAC）与匈牙利匹配算法建立仿真模态与实测模态之间的阶次对应关系。

真实框架结构在未知环境白噪声激励下的动力学行为，可等效为一个离散时间随机状态空间模型：

$$\mathrm{x}_{k+1} = Ax_k + w_k \tag{5.11}$$

$$y_k = Cx_k + v_k \tag{5.12}$$

其中，$x_k \in R^n$ 为隐式状态向量，其中包含位移与速度信息，$y_k \in R^l$ 为传感器在时刻 k 的可观测输出向量；A 为离散状态转移矩阵，其中蕴含了结构所有的模态参数，C 为观测矩阵；w_k 与 v_k 分别代表不可测的过程噪声（环境激振）与测量噪声，两者均被假设为零均值白噪声序列。

SSI-COV 算法的核心思想是通过输出序列的协方差矩阵，直接利用奇异值分解（SVD）剥离出系统可观测量与噪声子空间。首先，定义输出向量的理论协方差矩阵为 $R_i = E[y_{k+i}y_k^T]$。在实际算法部署中，利用有限长观测序列 $Y \in R^{l\times N}$ 计算其无偏估计经验协方差矩阵：

$$R_i = \frac{1}{N-i}\sum_{k=0}^{N-i-1} y_{k+i}y_k^T \tag{5.13}$$

随后，利用一系列时间延迟的协方差矩阵构造分块托普利茨矩阵（Block Toeplitz Matrix）$T_{1|i} \in R^{li\times li}$：

$$T_{1|i} = \begin{bmatrix} R_i & R_{i-1} & \cdots & R_1 \\ R_{i+1} & R_i & \cdots & R_2 \\ \vdots & \vdots & \ddots & \vdots \\ R_{2i-1} & R_{2i-2} & \cdots & R_i \end{bmatrix} = O_i\Gamma_i \tag{5.14}$$

根据随机系统理论，该托普利茨矩阵可被精确分解为扩展可观测矩阵 O_i 与反向随机状态序列协方差矩阵 Γ_i 的乘积。

为分离系统真实的主导模态，本研究对托普利茨矩阵 $T_{1|i}$ 执行奇异值分解：

$$T_{1|i} = U\Sigma V^H = \begin{bmatrix} U_1 & U_2 \end{bmatrix}\begin{bmatrix} \Sigma_1 & 0 \\ 0 & \Sigma_2 \end{bmatrix}\begin{bmatrix} V_1^H \\ V_2^H \end{bmatrix} \approx U_1\Sigma_1V_1^H \tag{5.15}$$

通过设定截断阶数（Model Order），保留包含结构真实动力学能量的非零奇异值对角阵 Σ_1 及其对应的左奇异向量 U_1。由此可直接提取出系统的扩展可观测矩阵 $O_i = U_1\Sigma_1^{1/2}$。进一步利用子空间平移不变性，通过伪逆运算求解出系统状态转移矩阵 A 与观测矩阵 C。最后，对状态矩阵 A 进行特征值分解 $A = \Psi\Lambda\Psi^{-1}$，即

可通过解析换算，提取出真实物理台架的各阶固有圆频率 ω_r 、阻尼比 ξ_r 以及振型向量 $\Phi = C\Psi$ 。由此，SSI-COV 将原始实测加速度时程转化为可用于结构图分支的模态特征，为后续真实结构双图样本重建提供基础。

5.3.2 基于 MAC 与匈牙利算法的仿真—实测模态匹配

由于实测模态由加速度响应识别得到，其模态阶次可能与有限元仿真模态不完全一致，实际计算中可能出现模态遗漏、阶次交换或相近频率下的误匹配现象。若直接将未经匹配的实测振型作为结构图节点特征，可能导致同一阶次的仿真特征与实测特征在物理含义上不一致。因此，在构建真实结构图特征之前，需要先完成仿真模态与实测模态之间的阶次匹配。

本文采用模态保证准则 MAC 衡量两阶振型之间的空间一致性[69]。设由有限元健康基准模型得到的第 r 阶参考振型为 ϕ_r^{sim} ，由实测响应识别得到的第 c 阶振型为 ϕ_c^{real} ，则二者的 MAC 值定义为：

$$\mathrm{MAC}(r,c)=\frac{\left|(\phi_{ref}^{(r)})^T\phi_{cur}^{(c)}\right|^2}{\left((\phi_{ref}^{(r)})^T\phi_{ref}^{(r)}\right)\left((\phi_{cur}^{(c)})^T\phi_{cur}^{(c)}\right)} \tag{5.16}$$

MAC 值越接近 1，表示两阶振型在空间分布上越一致。为避免仅依据振型相似度造成相近频率模态的误匹配，本文进一步结合频率偏差构造综合匹配代价。对于参考阶次 r与实测阶次 c，其频率相对偏差定义为：

$$\delta_f(r,c)=\frac{\left|f_r^{sim}-f_c^{real}\right|}{f_r^{sim}} \tag{5.17}$$

若 $\delta_f(r,c)$超过给定容差，则认为该组模态不满足匹配条件；否则，其匹配代价定义为：

$$D(r,c)=1-\mathrm{MAC}(r,c)+\lambda_f\delta_f(r,c) \tag{5.18}$$

其中，λ_f 为频率偏差权重系数。上述代价矩阵D同时考虑了振型空间一致性和频率接近程度，$D(r,c)$ 越小表示第r阶仿真模态与第c阶实测模态越可能对应。本文采用匈牙利算法对代价矩阵 D进行全局最小代价匹配。匈牙利算法是一种用于求解指派问题的经典组合优化算法，能够在给定代价矩阵的条件下获得总匹配代价最小的一组一一对应关系[70]。由此可得到仿真模态与实测模态之间的最优阶次匹配结果。

通过上述模态匹配过程，实测振型可按照有限元参考模态的阶次重新排列，使仿真数据与实测数据在结构图节点特征层面保持一致。最终，本文将匹配后的

实测振型与节点坐标等信息共同构成真实结构图节点特征，并与实测加速度时序样本一起封装为 DP-HDGNN 的输入数据。该处理保证了模型在使用真实试验数据时，结构图分支与传感器分支能够分别获得可对应的模态信息和动态响应信息，为后续仿真训练模型在实测结构上的损伤定位分析提供数据基础。

5.4 真实钢框架试验数据与实验设置

5.4.1 真实钢框架试验台架与数据来源

为评价迁移增强策略在真实结构上的适用性，本章真实钢框架试验数据作为实测验证对象。

UBC 真实物理试验台架是一个四层两跨三维空间钢框架模型[67]。该模型平面尺寸为 2.5m×2.5m，总高度为3.6m（层高 0.9m）。在材料与截面属性方面，框架的主体构件均采用 B300W 级热轧型钢：柱截面为 B100×9，主梁截面为 S75×11，各层间支撑斜腹杆采用具有较小长细比的圆钢管。在节点连接方式上，梁柱节点采用典型的半刚性高强螺栓连接，这种连接方式在真实环境激振下极易产生非线性的微观滑移与摩擦耗能，是诱发真实数据与有限元仿真数据产生严重差异的核心所在。为模拟楼板质量分布，试验结构在各跨楼面设置附加质量块，其中第 1—3 层每层布置四块 1000 kg 质量块，第 4 层布置四块 750 kg 质量块；部分质量偏心布置以增强结构平动—扭转耦合效应。

在数据采集系统配置上，研究团队在框架的每一层及基础部位均布置了高精度的单轴或双轴力平衡式加速度传感器。为了全面捕捉结构在三维空间中的扭转与平动响应，每层固定布置 3 个主要的水平加速度计，分别测量 X 向的主平动与 Y 向的平动/扭转。共布置 15 个加速度传感器，FBA 传感器布置在东西框架用于测量南北向响应，EPI 传感器靠近中柱布置用于测量东西向响应。

在物理激励手段上，实验阶段设计了三种不同频带特性的激振方式：（1）环境脉动：利用风载及周围地表微震动作为宽频带白噪声输入，用于模拟结构日常服役状态下的微弱响应。（2）冲击锤激振：在结构的特定楼层节点施加瞬态脉冲荷载，激发结构的高阶模态与局部高频响应特征；（3）电动激振器：激振器被固定于框架结构的第四层楼板之上，能够输入扫频正弦波或特定的随机带限噪声。结构各层的振动响应通过分布于梁柱节点的加速度传感器网络进行同步采集。

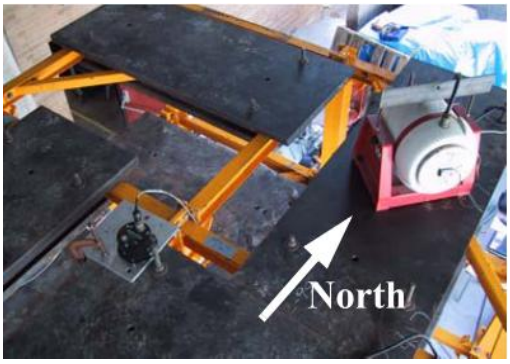


图 5.3 电动激振器



图 5.4 冲击锤



图 5.5 钢框架缩尺模型

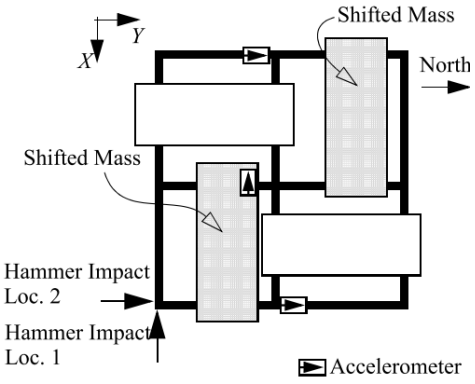


图 5.6 冲击锤激励位置与加速度计位置

5.4.2 真实损伤工况定义与标签映射

为构建用于实测结构损伤定位验证的数据集，UBC 试验团队在实体框架上设置了 9 种不同支撑移除和连接松动工况，如表 5.1 所示。在本研究的验证框架中，这些物理损伤模式被严密映射为区域级的层间刚度退化标签：

表 5.1 UBC 9 种工况示意

工况编号	主要损伤形式	标签映射
Config 01	支撑与节点连接均保持完整	[0,0,0,0]
Config 02	移除东侧立面的全部斜向支撑	[1,1,1,1]
Config 03	移除东南角一跨内 1—4 层全部斜向支撑	[1,1,1,1]
Config 04	移除东南角一跨内第 1 层与第 4 层斜向支撑	[1,0,0,1]
Config 05	移除东南角一跨内第 1 层斜向支撑	[1,0,0,0]
Config 06	移除东侧立面 1—4 层全部斜向支撑，同时移除北侧立面第 2 层斜向支撑	[1,1,1,1]

续表

工况编号	主要损伤形式	标签映射
Config 07	移除所有楼层的斜向支撑	[1,1,1,1]
Config 08	在 Config 07 基础上，松开东侧立面北侧梁两端、1—4 层梁柱连接螺栓	[1,1,1,1]
Config 09	在 Config 07 基础上，松开东侧立面北侧梁两端、第 1 层与第 2 层梁柱连接螺栓	[1,1,1,1]

由于本文任务为楼层级损伤定位，真实试验工况中的构件拆除、支撑移除和连接松动被统一映射为四维楼层损伤标签。该映射并不追求构件级精确定位，而是用于评价模型对真实结构楼层损伤状态的识别能力。

上述工况映射完成后，真实钢框架数据即可形成与仿真训练任务一致的楼层级损伤标签体系。结合第 5.2 节所述的实测模态识别与模态匹配方法，本文进一步将实测加速度响应、匹配后的模态特征和楼层级标签共同封装为 DP-HDGNN 可处理的实测样本。由此，真实钢框架数据不仅能够用于检验仿真训练模型的直接应用性能，也能够用于后续实测数据辅助修正与最终损伤定位验证。

5.4.3 数据划分及归一化策略

在仿真数据与实测数据联合使用时，数据归一化方式会直接影响模型评估的客观性。若直接使用实测数据的整体均值与标准差进行归一化，则等价于在数据预处理阶段提前引入真实试验数据的全局统计信息，可能导致评估结果偏乐观。为避免该问题，本文采用仿真统计量固定归一化策略：仅在仿真训练集上计算输入特征的均值与标准差，并将该统计量固定后统一作用于仿真验证集、仿真测试集以及全部实测数据。其表达式为：

$$X_t^{(j)} = \frac{X_t^{(j)} - \mu_s}{\sigma_s + \epsilon} \tag{5.19}$$

其中，$\epsilon = 10^{-8}$ 为防止分母极小的常数项。该处理方式能够保留仿真数据与实测数据之间真实存在的统计差异，从而更准确地检验模型对实测数据的适应能力。

在数据划分方面，仿真数据用于网络参数训练与基础验证，实测数据用于实测适配、阈值校准与最终测试。对于真实钢框架数据，Config 01 为健康基准工况，其样本按时间顺序划分为训练、验证和测试三部分。其中，训练部分仅作为真实健康锚点参与模型优化，验证部分用于观察模型在健康状态下的收敛稳定性，测试部分用于检验模型对未参与训练的健康样本的识别能力。

对于受损工况，本文不使用真实受损标签参与网络参数训练，而是将部分实

测响应作为无标签样本参与特征适配和高置信伪标签筛选。随后，选取部分受损工况构成验证集，用于后验阈值校准与模型选择；剩余受损工况作为最终测试集，用于评价模型对未见真实损伤工况的识别能力。具体划分方式如表 5.1 所示，该划分方式能够在尽量减少真实受损标签使用的前提下，检验仿真训练模型在真实结构上的损伤定位性能。

表 5.2 UBC 实测数据训练、验证与测试划分方式

数据集划分	工况编号	样本划分	是否参与网络权重更新	是否使用真实损伤标签
训练集	Config01	60%样本数量	是	使用健康标签[0,0,0,0]
训练集	Config04	全部样本	是	否
训练集	Config05	全部样本	是	否
训练集	Config07	全部样本	是	否
验证集	Config01	20%样本数量	否	使用健康标签[0,0,0,0]
验证集	Config02	全部样本	否	否
验证集	Config06	全部样本	否	否
测试集	Config01	20%样本数量	否	否
测试集	Config03	全部样本	否	否
测试集	Config08	全部样本	否	否
测试集	Config09	全部样本	否	否

需要说明的是，Config 04、Config 05 和 Config 07 虽参与模型适配训练，但其真实损伤标签不参与网络参数更新，仅通过模型预测的高置信伪标签和特征差异约束提供辅助信息。Config 02 和 Config 06 的标签仅用于验证阶段的阈值校准与模型选择，不参与反向传播。Config 03、Config 08 和 Config 09 在训练阶段完全屏蔽，仅用于最终测试。该划分方式避免了模型简单记忆真实受损工况，同时保留了少量真实健康样本和无标签实测样本在工程应用中的可获得性。

5.4.4 对比实验设置与评价指标

为客观评价迁移增强策略在真实钢框架实测数据上的应用效果，并进一步量化实测数据的贡献，本文设置统一的对比实验方案。对比实验主要围绕两个层面展开：一是比较不同网络结构在仅依赖仿真数据训练时对真实结构响应的直接识别能力；二是比较引入实测健康样本和无标签实测响应后，各模型在真实结构损

伤定位任务中的性能提升。

首先，本文建立仿真训练直接应用实验。该实验中，所有模型仅使用有限元仿真数据进行训练，训练完成后冻结全部网络参数，并直接输入真实钢框架实测数据进行推理。该设置用于检验不同模型在未利用实测数据进行辅助修正时，对真实结构响应的直接泛化能力。为保证对比完整性，本文选取 MLP、1D-CNN、TCN-GCN、TCN-GAT 和 DP-HDGNN 五类模型作为对比对象，其结构特点如下。

（1）多层感知机（MLP）。该模型不包含时序卷积、循环结构或图聚合机制，而是将多通道加速度时程展平后输入多层全连接网络进行分类。设置该模型的目的在于考察：在缺乏时序建模和结构拓扑约束的条件下，仅依赖输入数据整体统计特征能否完成真实钢框架损伤识别。

（2）一维时序卷积网络（1D-CNN）。该模型直接在时间轴上对多通道加速度序列执行局部卷积，用于提取局部时间片段中的频带变化与瞬态扰动特征。设置该基线的目的在于分析：仅依靠时间域局部特征提取，而不显式引入结构空间关系时，模型在真实结构数据中的识别能力。

（3）时序图卷积网络（TCN-GCN）。该模型在时序编码后引入固定图卷积聚合机制，用于表征传感器或结构节点之间的固定邻接关系。设置该基线的目的在于考察：常规静态图聚合是否能够提升模型对真实结构响应的表达能力，以及固定邻接关系在仿真数据与实测数据存在差异时是否仍然稳定有效。

（4）时序图注意力网络（TCN-GAT）。该模型在图卷积基础上引入注意力权重分配机制，使节点能够根据特征相似性自适应聚合邻域信息。设置该模型的目的在于分析：单一图注意力机制在缺乏结构物理图与动态传感器图协同约束时，对真实结构中复杂响应变化的适应能力。

（5）数物双驱异构双图神经网络（DP-HDGNN）。该模型保留结构物理图、动态传感器图、交叉注意力融合和边特征学习等核心模块。通过将仅由仿真数据训练得到的 DP-HDGNN 与后续实测数据辅助修正后的 DP-HDGNN 进行对比，可以进一步区分网络结构本身带来的识别能力与实测数据修正策略带来的性能增益。

为保证不同模型之间的对比公平性，本文在两类实验中采用相同的数据划分方式、输入时间窗、楼层级标签定义和评价指标。各模型在仿真数据上的训练设置保持一致，仿真训练直接应用方案与实测数据辅助修正方案之间的主要差异仅在于是否引入实测样本参与模型修正。因此，二者的对比能够用于分析：仅依赖仿真数据训练时模型在真实结构上的性能衰减程度，以及引入实测数据辅助修正后模型性能的提升幅度。

由于真实钢框架试验数据中健康样本占比较高，若仅采用整体准确率作为评价指标，容易掩盖模型对受损状态的漏报问题。因此，本文选取 Macro-F1 和 PR-AUC 作为核心评价指标，并将 Accuracy 作为辅助指标。其中，Macro-F1 对各类别或各楼层的 F1 分数进行平均，能够减弱多数健康样本对总体结果的主导作用，更适合评价类别不均衡条件下的损伤识别能力；PR-AUC 通过统计不同判定阈值下 Precision 与 Recall 的关系，反映模型对受损样本的综合检出能力。相比 ROC-AUC，PR-AUC 更关注正类样本，即本文中的受损状态，因此更适用于真实损伤样本较少的评价场景。Accuracy 则用于补充反映模型整体分类正确率，但不作为唯一评价依据。

5.5 钢框架真实数据损伤定位结果分析

5.5.1 仿真训练模型直接应用结果分析

为明确仅依赖仿真数据训练时模型在真实结构上的识别能力，本文首先对仿真训练直接应用方案进行测试。该方案中，所有模型均仅在有限元仿真数据上完成参数优化，随后冻结网络权重，并直接输入真实钢框架试验数据进行推理。该实验用于观察不同网络结构在面对真实连接状态、边界条件、激励差异和测量噪声时的性能变化。图 5.7 给出了各模型在真实数据测试集上的性能对比。

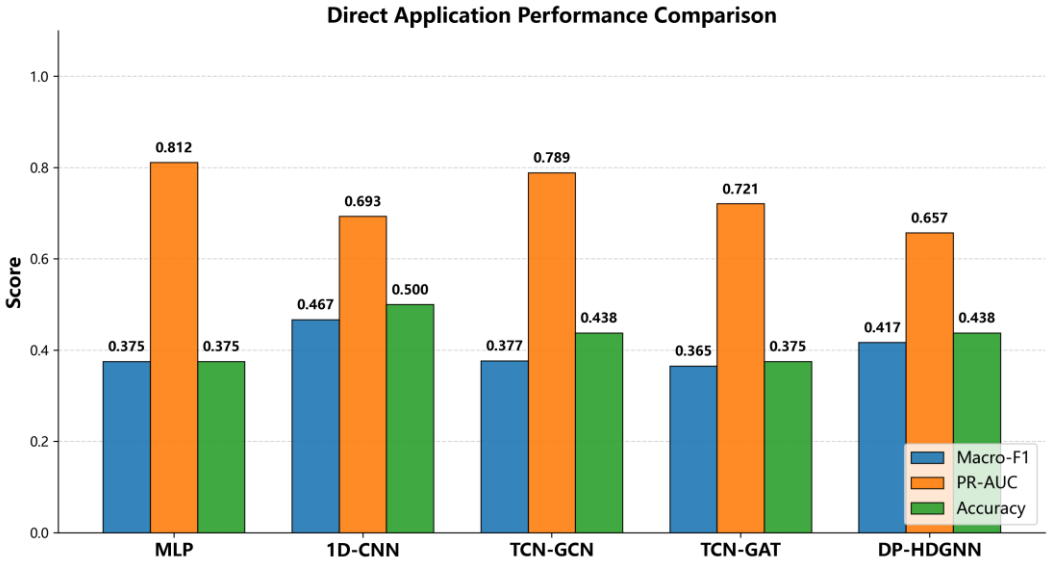


图 5.7 未采用迁移增强策略时模型性能对比

由图 5.7 可知，各模型在真实钢框架数据上的性能均较仿真测试阶段明显下降。这说明，有限元仿真数据虽然能够提供数量充足、标签明确的损伤样本，

但其响应特征仍难以完全覆盖真实结构中的连接滑移、边界扰动、局部非线性、激励差异和测量噪声等因素。模型若仅依赖仿真数据完成训练，直接应用于实测数据时容易出现判别边界偏移，从而导致受损样本识别能力下降。

从各模型结果来看，MLP 的 Macro-F1、PR-AUC 和 Accuracy 分别为 0.375、0.812 和 0.375。虽然其 PR-AUC 相对较高，但 Macro-F1 和 Accuracy 较低，说明模型在不同阈值下仍能对部分受损样本保持一定排序能力，但最终离散化判别结果并不稳定。其原因在于，MLP 直接对展平后的时序特征进行全连接映射，缺乏时序局部模式提取和结构空间关系建模能力，因此难以稳定区分真实台架中的楼层损伤状态。

1D-CNN 的 Macro-F1 提升至 0.467，Accuracy 为 0.500，说明一维卷积能够从加速度响应中提取一定的局部时间片段特征，相较于 MLP 具备更强的时序表征能力。然而，其 PR-AUC 为 0.693，低于 MLP 和 TCN-GCN，表明该模型虽然在离散判别结果上有所改善，但对受损样本的置信度排序并不稳定。由于 1D-CNN 未显式引入传感器空间位置和结构连接关系，真实台架中由楼层耦合、连接状态变化和局部测量噪声引起的响应差异，仍容易被混入普通时序特征中，限制了其真实损伤识别能力。

TCN-GCN 的 Macro-F1、PR-AUC 和 Accuracy 分别为 0.377、0.789 和 0.438。该模型在时序编码后引入固定图卷积，理论上能够利用一定的测点关系信息，但其性能并未明显优于纯时序模型。这表明，固定图聚合在真实结构数据中存在一定局限。由于真实钢框架的连接状态、支撑拆除和螺栓松动会改变结构响应关系，固定邻接关系难以充分反映实测响应中的动态变化，图卷积聚合过程中还可能削弱局部异常特征。

TCN-GAT 的 Macro-F1 为 0.365，PR-AUC 为 0.721，Accuracy 为 0.375。与 TCN-GCN 相比，图注意力机制能够根据节点特征自适应分配邻居权重，但在仿真训练直接应用条件下，其优势并未充分体现。这说明，常规 GAT 的注意力权重仍主要由仿真数据中学习到的节点特征关系驱动，当输入转为真实试验响应后，注意力分配容易受到噪声、边界扰动和连接状态差异的影响，导致判别结果不稳定。

DP-HDGNN 在仿真训练直接应用条件下的 Macro-F1、PR-AUC 和 Accuracy 分别为 0.417、0.657 和 0.438。该结果表明，尽管 DP-HDGNN 在前文仿真实验中表现出较强的双图特征建模能力，但仅依靠仿真数据训练时，其结构图与传感器图融合机制仍不能完全克服仿真响应与实测响应之间的差异。尤其是 PR-AUC 低于部分基线模型，说明模型对真实受损样本的概率排序稳定性不足。这并不意味着 DP-HDGNN 的结构设计失效，而是说明仿真数据中学习到的

高层特征表示直接应用于真实结构时，仍会受到真实连接状态、测量噪声和模态参数差异的影响。

综合来看，图 5.7 反映出一个共同现象：各类模型仅依赖仿真数据训练后直接应用于真实钢框架数据时，均难以获得稳定的损伤定位性能。该结果说明，仿真数据能够提供充足的损伤标签和可控工况，但仍无法完全覆盖真实结构中的连接状态变化、边界扰动和测量噪声。因此，仿真训练直接应用实验构成了本章的对照基线，也进一步说明了第 5.3 节所提出的实测数据辅助修正策略的必要性。下一节将进一步分析引入实测健康锚点、无标签实测响应和特征差异约束后，不同模型在真实钢框架损伤定位任务中的性能变化。

5.5.2 实测数据融合后的模型性能分析

在仿真训练直接应用结果的基础上，本文进一步引入实测数据融合策略，对各模型在真实钢框架测试集上的识别性能进行评估。该策略利用 Config 01 中的健康样本作为实测健康锚点，并结合 Config 04、Config 05 和 Config 07 的无标签实测响应，通过特征差异约束、高置信伪标签和楼层级阈值校准等方式修正模型在实测数据上的输出偏差。图 5.8 给出了各模型完成实测数据融合后的性能对比。

由图 5.8 可知，所有模型在引入实测数据辅助适配后均获得不同程度提升，尤其是 PR-AUC 指标普遍提高至 0.9 以上，说明适配策略改善了模型对受损样本的排序能力，使模型在不同判定阈值下能够更稳定地区分健康状态与损伤状态。其中，DP-HDGNN 的三项指标均明显优于其他模型，表明所提模型在真实钢框架损伤定位任务中具有更高的识别精度和稳定性。

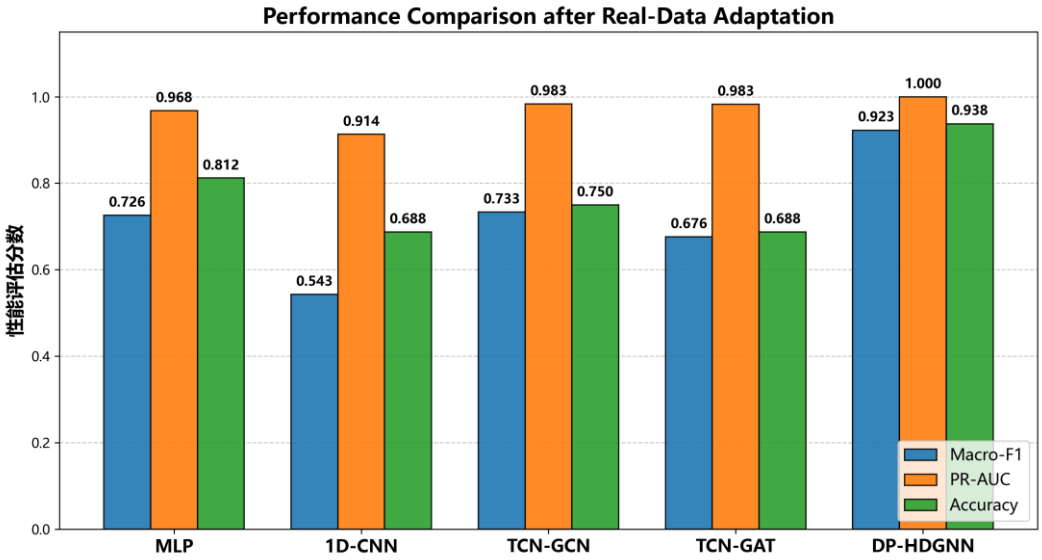
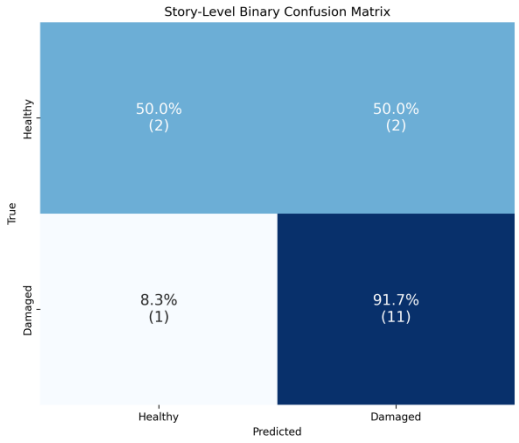
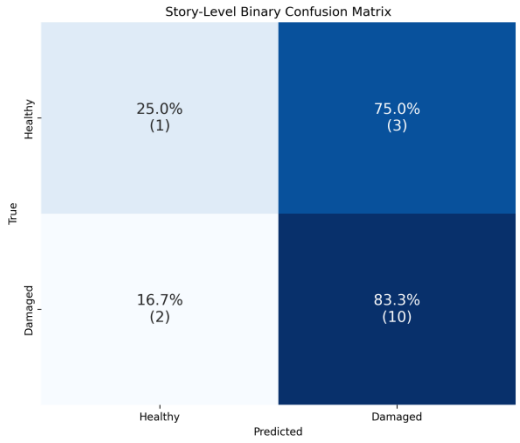


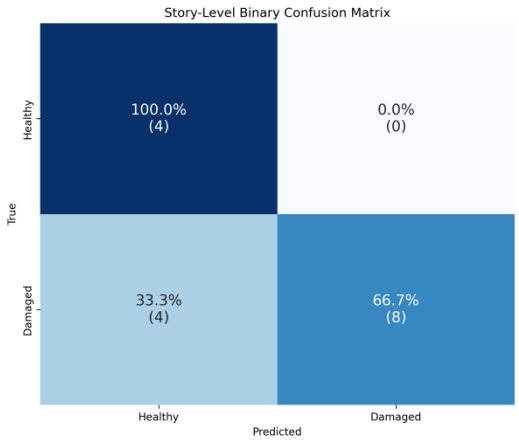
图 5.8 采用迁移增强策略后模型性能对比



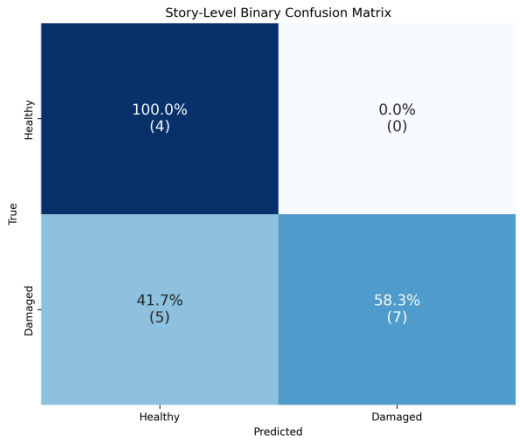
（a）MLP 测试集混淆矩阵



（b）1D-CNN 测试集混淆矩阵



（c）TCN-GCN 测试集混淆矩阵



（d）TCN-GAT 测试集混淆矩阵

图 5.9 采用迁移增强策略后的 Baseline 混淆矩阵

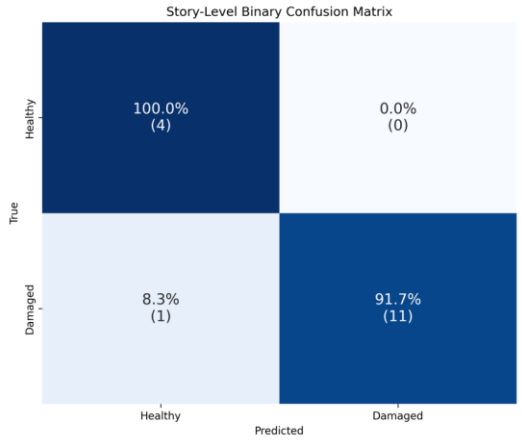


图 5.10 DP-HDGNN 实测数据融合后的混淆矩阵

从各基线模型来看，MLP 在完成实测数据融合后取得了 0.726 的 Macro-F1、0.968 的 PR-AUC 和 0.812 的 Accuracy，成为 baseline 中表现最好的模型。该现象需要结合任务特点进行理解。在仿真测试中，MLP 表现较弱，主要原因在于其缺乏时序卷积和结构拓扑建模能力，难以从多测点振动响应中提取稳定的时空损伤特征。然而，在仿真数据应用于实测数据时，模型面临的主要困难不仅是特征表达能力不足，更包括仿真响应与实测响应之间的统计差异。对于复杂模型而言，其在仿真数据中学习到的局部时序模式、固定图聚合规律或注意力权重，可能会更强地依赖仿真模型中的理想边界条件和响应特征，直接修正时反而容易受到实测噪声和连接非理想性的影响。

相比之下，MLP 结构简单、参数容量较低，虽然缺乏精细的时空特征表达能力，但其判别边界更偏向全局统计特征。在引入实测健康锚点、特征差异约束和阈值校准后，MLP 更容易形成相对平滑的全局分类边界，因此能够从实测数据融合策略中获得较大收益。这并不说明 MLP 的结构表达能力优于图时序模型，而是说明在真实样本有限、实测差异修正约束较强的条件下，低容量模型具有一定的正则化优势。其 Macro-F1 和 Accuracy 仍明显低于 DP-HDGNN，说明单纯依赖全连接映射仍难以充分刻画多测点响应之间的空间关系。

1D-CNN 在适配后取得了 0.543 的 Macro-F1、0.914 的 PR-AUC 和 0.688 的 Accuracy，整体表现弱于 MLP 和图网络模型。该结果说明，一维卷积虽然能够提取局部时间片段中的频带变化和瞬态扰动特征，但缺乏对传感器空间布置和结构连接关系的显式表达。当真实钢框架中存在楼层耦合、支撑拆除和连接松动等因素时，仅依靠局部时序特征仍难以准确完成楼层级损伤定位。

TCN-GCN 和 TCN-GAT 在适配后均表现出较高的 PR-AUC，分别达到 0.983 和 0.983，说明图结构建模能够提升模型对真实受损样本的区分能力。但二者的 Macro-F1 和 Accuracy 仍低于 DP-HDGNN，表明常规图模型在最终离散判别上仍存在不足。其原因在于，TCN-GCN 主要依赖固定邻接关系进行特征聚合，难以充分反映实测结构中由支撑拆除、连接松动和边界扰动引起的响应关系变化；TCN-GAT 虽然能够通过注意力机制自适应分配邻居权重，但其图结构仍较为单一，缺乏结构图与传感器动态图之间的协同约束，因此在复杂真实响应下仍容易出现局部误判。

相比之下，完成实测数据融合后的 DP-HDGNN 取得了最优结果，说明其优势并非单纯来自适配策略，而是来自模型结构与实测数据修正机制的共同作用。一方面，DP-HDGNN 通过结构图保留结构节点、构件连接和模态信息，使模型在真实数据中仍具有相对稳定的物理参照；另一方面，动态传感器图能够根据实测响应变化调整测点间关联关系，缓解固定图结构对真实响应变化适应不足的问

题。在此基础上，实测健康锚点、特征差异约束和阈值校准进一步修正了模型输出偏差，使其高层特征表示更适合 UBC 真实钢框架数据。因此，DP-HDGNN 在 Macro-F1、PR-AUC 和 Accuracy 上均取得最优表现，体现出更强的真实结构损伤识别能力。

综上，实测数据融合策略能够有效改善仿真训练模型在真实钢框架数据上的性能，但最终识别效果仍取决于模型自身的特征建模能力。MLP 在适配后成为 baseline 中最优模型，反映出低容量模型在统计差异修正中的正则化优势；而 DP-HDGNN 进一步凭借结构图与动态传感器图的协同建模能力取得整体最优结果，说明在真实损伤样本不足条件下，仿真数据训练与实测数据融合相结合的策略能够有效提升结构损伤定位性能。

5.6 本章小结

本章围绕真实受损样本不足条件下的结构损伤定位问题，研究了基于迁移增强的仿真—实测数据融合方法并采用真实实验来验证其有效性。主要工作与结论如下。

（1）完成了真实钢框架实测数据的模态特征提取

DP-HDGNN 的结构图分支需要模态节点特征作为输入。对于有限元仿真数据，模态参数可由数值模型直接计算获得；而对于真实钢框架试验数据，结构参数、边界条件和连接状态均存在不确定性，无法直接使用仿真模态替代实测结构特征。为此，本章采用协方差驱动随机子空间识别方法从实测加速度响应中识别结构模态参数，并结合模态保证准则与匈牙利算法完成仿真模态与实测模态之间的阶次匹配，使两类数据在结构图特征层面保持物理对应关系。该处理为仿真训练模型应用于真实钢框架数据提供了结构图输入基础。

（2）在迁移学习增强框架下实现了源域与目标域数据融合

为减小仿真样本与实测样本之间的特征分布差异，本章在 DP-HDGNN 主干网络基础上建立联合优化目标。仿真数据作为源域，提供有标签损伤样本，用于训练模型的基本损伤判别边界；真实钢框架实测数据作为目标域，其中真实健康样本用于提供健康状态约束，无标签实测响应用于参与特征分布修正。在特征表示层面，本文引入多核最大均值差异作为源域—目标域特征对齐约束，对仿真特征与实测特征进行多尺度分布度量，减小二者在高维空间中的分布偏差；在训练与决策层面，结合健康锚点、信息熵约束、高置信伪标签、动态权重调度和后验阈值校准，进一步改善模型在真实钢框架响应上的输出稳定性。该方法的重点在于，不使用真实受损标签参与网络权重更新，而是利用少量高保真实测传感器

数据对仿真训练模型进行特征域对齐，使模型在保留仿真样本损伤判别能力的同时，提高对真实结构响应的适应能力。

（3）迁移增强策略对损伤定位性能的实际钢框架试验验证

本章以真实钢框架试验数据作为验证对象，介绍了试验台架、传感器布置、激励方式和损伤工况，并将支撑移除、连接松动等真实损伤模式映射为楼层级损伤标签。为贴近真实工程中受损标签难以获取的应用场景，本文在训练过程中不使用真实受损标签更新网络参数，仅引入少量真实健康样本作为目标域健康锚点，并利用无标签实测响应参与迁移学习增强修正；验证集标签仅用于模型选择和后验阈值校准，最终测试集用于评价模型对未参与训练工况的损伤识别能力。

实验结果表明，当仅使用有限元仿真数据训练模型并直接应用于真实钢框架数据时，各类模型均出现不同程度的性能下降，说明仿真数据与实测数据之间的差异会削弱模型在真实结构中的直接应用效果。引入高保真实测传感器数据进行迁移学习增强修正后，各模型识别性能均有所提升，其中 DP-HDGNN 取得最优结果。该结果说明，结构物理图与动态传感器图的协同建模能够为真实结构损伤定位提供较稳定的特征表达；同时，源域—目标域特征对齐与后验阈值校准等方法能够进一步减小仿真训练模型与真实结构响应之间的差异，提高模型对真实钢框架损伤状态的识别能力。

综上，本章验证了基于仿真数据训练并结合实测数据辅助适配的结构损伤定位方法在真实钢框架试验数据中的可行性。研究结果表明，在真实受损样本不足的条件下，可以引入迁移学习增强策略，利用有限元仿真数据提供大量的有标签损伤样本，并借助少量真实健康响应和无标签实测响应对深度学习模型进行修正，从而提升真实结构损伤定位任务中的应用效果。

第6章 结论与展望

6.1 主要工作及结论

结构健康监测是保障重大土木基础设施长期服役安全的重要技术。近年来，深度学习方法在结构损伤特征提取与状态识别中展现出较强潜力，但在面对复杂空间结构时，仍存在结构物理信息与传感器响应数据融合不足、复杂拓扑与观测缺失条件下模型稳定性不足、真实受损样本稀缺等问题。针对上述问题，本文以多层框架结构、空间桁架结构和真实钢框架试验数据为研究对象，提出数物双驱异构双图神经网络（DP-HDGNN）结构损伤定位方法，并围绕模型构建、复杂结构鲁棒性验证以及仿真—实测数据融合开展系统研究。全文主要工作及结论如下。

1. 提出了数物双驱异构双图神经网络损伤定位方法

本文提出了数物双驱异构双图神经网络（DP-HDGNN）。该模型将结构物理信息与传感器观测数据分别组织为结构物理图和动态传感器图：前者用于表征结构节点、构件连接、模态特征及边属性等物理先验，后者用于描述不同测点响应之间随结构状态变化而演化的动态相关关系。在此基础上，模型利用异构双图交叉注意力机制实现观测空间与物理空间的信息交互，并引入边特征学习机制增强构件连接关系在损伤判别中的表达能力。该方法使损伤定位同时具备数据驱动特征提取能力与物理先验约束能力，为复杂结构损伤识别提供了统一的模型基础。

2. 验证了 DP-HDGNN 在复杂结构与传感器失效条件下的损伤定位鲁棒性

本文分别基于 T 型钢架、IASC-ASCE 框架结构和 14 跨空间桁架结构开展数值实验。首先，T 型钢架算例表明，局部损伤可通过结构连接关系诱发远端健康区域的伪损伤特征，说明仅依赖多通道时序响应易产生异地虚警，从机理上证明了引入结构拓扑约束的必要性。随后，基于 IASC-ASCE 框架结构构建损伤数据集，验证了 DP-HDGNN 在复合损伤和类别不均衡条件下的损伤定位能力。进一步将研究对象扩展至 14 跨空间桁架结构后，结果表明，该模型在节点连接更密集、响应耦合更复杂的场景中仍能保持稳定识别性能。随机传感器失效试验进一步说明，当部分测点响应缺失时，DP-HDGNN 能够依托结构物理图提供稳定的拓扑约束，并利用剩余有效响应重建测点间动态关联，从而对缺失观测信息进行补偿，其性能退化明显小于纯时序模型和常规图模型，表现出较好的传感器缺失鲁棒性。

3. 构建了基于迁移学习增强的 DP-HDGNN 损伤定位方法及实验验证

本文构建了迁移学习增强的 DP-HDGNN 损伤定位方法用于解决真实受损样本稀缺问题。该方法以有限元仿真数据作为源域，利用其工况可控、标签明确和损伤状态覆盖充分的特点，学习模型的基础损伤判别能力；以真实钢框架试验数据作为目标域，利用其实测响应约束模型对真实结构动力特征的表征。在此基础上，通过迁移学习增强策略促进源域判别能力向目标域迁移，并利用域对齐约束减小仿真特征与实测特征在高维表示空间中的分布差异，实现仿真与实测数据的协同利用。

在具体实现上，本文通过实测模态识别与仿真—实测模态匹配构造满足 DP-HDGNN 输入要求的目标域结构图特征；通过多核最大均值差异实现源域—目标域多尺度特征分布对齐；同时结合真实健康样本锚点、高置信伪标签和楼层级后验阈值校准，提高模型对真实钢框架响应的适应能力。真实钢框架损伤识别结果表明，在真实受损标签不参与网络训练的条件下，引入迁移学习增强策略后各模型性能均得到提升，其中 DP-HDGNN 表现最优，Macro-F1 达到 92% 以上。该结果说明，仿真数据能够为模型提供有效的损伤判别基础，而实测数据可通过迁移增强与域对齐策略修正模型对真实结构响应的特征表征，进而提升真实结构损伤定位的准确性与泛化能力。

综上，本文针对复杂结构损伤定位中物理信息与传感器响应融合不足、观测缺失以及真实受损样本稀缺等问题，提出了数物双驱异构双图神经网络损伤定位方法，并进一步构建了面向真实结构的仿真—实测数据融合识别策略。研究结果表明，所提方法能够在仿真数据充足而真实损伤样本有限的条件下，实现结构物理先验、传感器动态响应与实测数据约束的协同利用，为复杂工程结构的智能损伤定位与安全评估提供了有效技术路径。

6.2 课题展望

尽管本文在复杂空间结构的损伤定位技术上取得了阶段性进展，但受限于深度学习模型自身的弱可解释性及现有计算资源限制，本研究在迈向工程化在线应用的过程中仍存在亟待深化的研究空间。未来的研究工作可重点围绕以下三个维度展开：

1. 由离散状态分类向构件级损伤回归的拓展

目前本研究的诊断层级主要局限于楼层或宏观区域的损伤分类界定。然而，工程实际安全评估与寿命预测亟需获取具体承载构件的连续刚度退化参数。未来研究可考虑将离散的模式识别任务重构为多变量连续回归预测任务，以实现对各

构件刚度折减比例的精细化百分比量化，从而为结构全生命周期的疲劳演化边界提供精确输入。

2. 基于动态子图挖掘与物理信息内嵌的局部高精细定位

复杂大型结构在发生微小局部损伤时，其非线性动力响应通常仅局限于特定的拓扑子区域。未来研究可引入动态子图划分算法，促使图网络在推断阶段自适应地将感受野收敛于疑似受损的局部区域，剥离全局无关模态的计算冗余与噪声干扰。同时，应进一步探索将结构动力学微分方程或能量守恒准则作为正则化项嵌于网络损失函数中，构建物理信息图神经网络（Physics-Informed GNN），以期在无标签的真实数据中提供更为严密的力学收敛保证。

3. 面向结构长效服役演化的开放集识别与持续在线更新机制

本文在真实钢框架试验数据中验证了基于仿真数据训练并结合实测数据辅助适配的损伤定位方法，但仍建立在已知损伤工况与有限试验样本的基础上。实际土木结构在长期服役过程中，可能出现训练阶段未覆盖的新型损伤模式、连接状态退化、边界条件变化以及环境荷载扰动，仅依赖既有工况训练得到的固定模型，难以长期保持稳定识别能力。未来研究可进一步引入开放集识别与不确定性评估机制，使模型在面对未知损伤或异常响应时，不仅能够给出损伤定位结果，还能够判断该样本是否超出既有知识范围，从而降低未知工况被误判为已知类别的风险。

此外，实际工程监测数据具有连续积累的特点。未来可结合在线学习或增量更新策略，使模型在不完全重新训练的条件下，利用新增监测数据逐步修正模型参数和判定阈值。通过持续更新健康基准、动态调整传感器关联关系，并结合少量人工复核样本对模型进行校正，可提高模型在结构全寿命周期内的适应能力和诊断稳定性，为复杂工程结构的长期智能监测提供支撑。

参考文献

[1] Chan T H T, Li J, Caprani C. Structural identification and evaluation for SHM applications[J]. Journal of Civil Structural Health Monitoring, 2018, 8: 719-720.

[2] Farrar C R, Worden K. An introduction to structural health monitoring[J]. Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences, 2007, 365(1851): 303-315.

[3] Rytter A. Vibrational based inspection of civil engineering structures[D]. Aalborg: Aalborg University, 1993.

[4] Cawley P, Adams R. The location of defects in structures from measurements of natural frequencies[J]. Journal of Strain Analysis for Engineering Design, 1979, 14: 49-57.

[5] Salawu O S. Detection of structural damage through changes in frequency: a review[J]. Engineering Structures, 1997, 19(9): 718-723.

[6] Sohn H, Dzwonczyk M, Straser E G, et al. An experimental study of temperature effect on modal parameters of the Alamosa Canyon Bridge[J]. Earthquake Engineering & Structural Dynamics, 1999, 28(8): 879-897.

[7] Pandey A K, Biswas M. Damage detection in structures using changes in flexibility[J]. Journal of Sound and Vibration, 1994, 169(1): 3-17.

[8] Pandey A K, Biswas M, Samman M M. Damage detection from changes in curvature mode shapes[J]. Journal of Sound and Vibration, 1991, 145(2): 321-332.

[9] Shi Z Y, Law S S, Zhang L M. Structural damage localization from modal strain energy change[J]. Journal of Sound and Vibration, 1998, 218(5): 825-844.

[10] Stubbs N, Kim J T, Farrar C R. Field verification of a nondestructive damage localization and severity estimation algorithm[C]//Proceedings of the 13th International Modal Analysis Conference. Nashville: SEM, 1995: 210-218.

[11] Cornwell P, Doebling S W, Farrar C R. Application of the strain energy damage detection method to plate-like structures[J]. Journal of Sound and Vibration, 1999, 224(2): 359-374.

[12] Maeck J, De Roeck G. Damage assessment using vibration analysis on the Z24-bridge[J]. Mechanical Systems and Signal Processing, 2003, 17(1): 133-142.

[13] Doebling S W, Farrar C R, Prime M B, et al. Damage identification and health monitoring of structural and mechanical systems from changes in their vibration characteristics: a literature review[R]. Los Alamos: Los Alamos National Laboratory, 1996.

[14] Maeck J, De Roeck G. Dynamic bending and torsion stiffness derivation from modal curvatures and torsion rates[J]. Journal of Sound and Vibration, 1999, 225(1): 153-170.

[15] Friswell M I. Damage identification using inverse methods[J]. Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences, 2007, 365(1851): 393-410.

[16] Friswell M I, Mottershead J E. Finite element model updating in structural dynamics[M]. Dordrecht: Springer, 1995.

[17] Peeters B, De Roeck G. One-year monitoring of the Z24-Bridge: environmental effects versus damage events[J]. Earthquake Engineering & Structural Dynamics, 2001, 30(2): 149-171.

[18] Yuen K V, Beck J L, Katafygiotis L S. Structural health monitoring of bridges using seismic responses[J]. Journal of Structural Engineering, 2006, 132(12): 1994-2004.

[19] Yan A M, Kerschen E, De Boe P, et al. Structural damage diagnosis under varying environmental conditions—Part I: a linear analysis[J]. Mechanical Systems and Signal Processing, 2005, 19(4): 847-864.

[20] Worden K, Manson G, Fieller N R J. Fault detection using outlier analysis[J]. Journal of Sound and Vibration, 2000, 229(3): 647-667.

[21] Omenzetter P, Brownjohn J. Application of time series analysis for bridge monitoring[J]. Smart Materials and Structures, 2006, 15: 129-138.

[22] Nair K K, Kiremidjian A S, Law K H. Time series-based damage detection and localization algorithm with application to the ASCE benchmark structure[J]. Journal of Sound and Vibration, 2006, 291(1-2): 349-368.

[23] Gül M, Catbas F N. Damage assessment with ambient vibration data using a novel time series analysis methodology[J]. Journal of Structural Engineering, 2011, 137(12): 1518-1526.

[24] Deraemaeker A, Reynders E, De Roeck G, et al. Vibration-based structural health monitoring using output-only measurements under changing environment[J]. Mechanical Systems and Signal Processing, 2008, 22(1): 34-56.

[25] D'Alessandro A, Worden K. Principal component analysis for damage detection[M]//Farrar C R, Worden K, eds. Structural health monitoring. Berlin: Springer, 2008: 279-301.

[26] Hsu T Y, Loh C H. Damage detection accommodating nonlinear environmental effects by nonlinear principal component analysis[J]. Structural Control and Health Monitoring, 2010, 17(3): 338-354.

[27] Bornn L, Farrar C R, Park G, et al. Structural health monitoring with autoregressive support vector machines[J]. Journal of Vibration and Acoustics, 2009, 131(2): 021004.

[28] Sony S, Laventure S, Sadhu A. A literature review of next-generation smart sensing technology in structural health monitoring[J]. Structural Control and Health Monitoring, 2019, 26(3): e2321.

[29] Figueiredo E, Figueiras J, Park G, et al. Machine learning algorithms for damage detection under operational and environmental variability[J]. Structural Health Monitoring, 2011, 10(6): 559-572.

[30] Pan H, Azimi M, Yan F, Lin Z. Time-frequency-based data-driven structural diagnosis and damage detection for cable-stayed bridges[J]. Journal of Bridge Engineering, 2018, 23(6): 04018033.

[31] Zhou Q, Zhou H, Zhou Q, Yang F, Luo L. Structure damage detection based on random forest recursive feature elimination[J]. Mechanical Systems and Signal Processing, 2014, 46(1): 82-90.

[32] 黄岩, 韩东颖, 朱国庆, 等. 基于时域多参数信息融合与机器学习算法的井架钢结构损伤识别[J]. 计量学报, 2024, 45(5): 698-705.

[33] 刘鑫鑫, 管德清, 王沁畅, 等. 基于小波-ELM 算法的结构损伤识别[J]. 交通科学与工程, 2025, 41(3): 145-150.

[34] Avci O, Abdeljaber O, Kiranyaz S, et al. A review of vibration-based damage detection in civil structures: from traditional methods to machine learning and deep learning applications[J]. Mechanical Systems and Signal Processing, 2021, 147: 107077.

[35] Sony S, Dunphy K, MacZura A, et al. A systematic review of convolutional neural network-based structural condition assessment techniques[J]. Engineering Structures, 2021, 226: 111347.

[36] Yu Y, Wang C, Gu X, et al. A novel deep learning-based method for damage identification of smart building structures[J]. Structural Health Monitoring, 2019, 18(1): 143-163.

[37] Cha Y J, Choi W, Büyüköztürk O. Deep learning-based crack damage detection using convolutional neural networks[J]. Computer-Aided Civil and Infrastructure Engineering, 2017, 32(5): 361-378.

[38] Abdeljaber O, Avci O, Kiranyaz S, et al. Real-time structural health monitoring using 1D convolutional neural networks[J]. Journal of Sound and Vibration, 2017, 387: 440-451.

[39] 秦世强, 苏晟, 杨睿. 基于多标签卷积神经网络的结构损伤识别[J]. 建筑科学与工程学报, 2024, 41(3): 108-119.

[40] 吁强, 蔡晓丽, 李翠, 等. 基于密集连接卷积神经网络的结构损伤识别[J]. 地震工程与工程振动, 2024, 44(3): 61-72.

[41] Ni F, Zhang J, Noori M N. Deep learning for data anomaly detection and data compression of a long-span suspension bridge[J]. Computer-Aided Civil and Infrastructure Engineering, 2020, 35(7): 685-700.

[42] Sajedi S O, Liang X. Vibration-based semantic damage segmentation for large-scale structural health monitoring[J]. Computer-Aided Civil and Infrastructure Engineering, 2020, 35(6): 579-596.

[43] Truong T T, Lee J, Nguyen-Thoi T. An effective framework for real-time structural damage detection using one-dimensional convolutional gated recurrent unit neural network and high performance computing[J]. Ocean Engineering, 2022, 253: 111202.

[44] Flah M, Nunez I, Ben Chaabene W, et al. Machine learning algorithms in civil structural health monitoring: a systematic review[J]. Archives of Computational Methods in Engineering, 2021, 28(4): 2621-2643.

[45] Tang Z, Chen Z, Bao Y, et al. Convolutional neural network-based data anomaly detection method using multiple information for structural health monitoring[J]. International Journal of Distributed Sensor Networks, 2019, 15(3): 1550147719836281.

[46] Entezami A, Sarmadi H, Behkamal B, et al. Big data analytics and structural health monitoring: a statistical pattern recognition-based approach[J]. Sensors, 2020, 20(8): 2328.

[47] Azimi M, Eslamlou A D, Pekcan G. Data-driven structural health monitoring and damage detection through deep learning: state-of-the-art review[J]. Sensors, 2020, 20(10): 2778.

[48] Coraça E M, Ferreira J V, Nóbrega E G O. An unsupervised structural health monitoring framework based on Variational Autoencoders and Hidden Markov Models[J]. Reliability Engineering & System Safety, 2023, 231: 109025.

[49] 刘玉驰, 蒋玉峰, 王树青, 等. 基于数据融合及残差卷积自编码器的结构损伤识别方法[J]. 振动与冲击, 2023, 42(4): 194-203.

[50] 陈鑫婷, 张军, 鲁东明, 等. 基于多头卷积自编码器的桥梁结构信号重构与损伤识别方法研究[J]. 振动与冲击, 2025, 44(6): 298-305.

[51] Kipf T N, Welling M. Semi-supervised classification with graph convolutional networks[C]//Proceedings of the 5th International Conference on Learning Representations. Toulon, France, 2017.

[52] Veličković P, Cucurull G, Casanova A, et al. Graph attention networks[C]//International Conference on Learning Representations (ICLR). 2018.

[53] Dang V H, Vu T C, Nguyen B D, et al. Structural damage detection framework based on graph convolutional network directly using vibration data[J]. Structures, 2022, 38: 40-51.

[54] Kaveh A, Rahmani P, Eslamlou A D. Damage detection using a graph-based adaptive threshold for modal strain energy and improved water strider algorithm[J]. Periodica Polytechnica Civil Engineering, 2021, 65(4): 989-1007.

[55] Eslamlou A D, Ghasemlou A, Barros B, et al. A hybrid data-physics framework with conformal GNN for enhanced damage identification[J]. Advanced Engineering Informatics, 2025, 68: 103718.

[56] 史子凡, 郭文华, 郭柳君, 等. 基于图卷积神经网络的结构损伤识别研究[J]. 铁道科学与工程学报, 2025: 1-12[2025-06-14].

[57] 李行, 骆勇鹏, 郭旭,等. 强噪声小样本条件下基于图卷积神经网络的结构损伤识别[J]. 地震工程与工程振动, 2024, 44(3): 52-60.

[58] 杨建辉, 赵清瑄, 蒲脯林. 基于结构多维特征构建图卷积神经网络的结构损伤识别方法[J]. 湖南大学学报(自然科学版), 2025, 52(8): 158-171.

[59] Liu J, Li Q, Li L, et al. Structural damage detection and localization via an unsupervised anomaly detection method[J]. Reliability Engineering & System Safety, 2024, 252: 110465.

[60] Ren Z, Zhou Y. On cross-attention-based graph neural networks for fault diagnosis using multi-sensor measurement[J]. Structural Health Monitoring, 2025: 14759217251327760.

[61] Hu T, Ma K, Xiao J. Graph feature refinement and fusion in Transformer for structural damage detection[J]. Sensors, 2024, 24(13): 4415.

[62] Wijethunga R, Samarabandu J, Sadhu A. Robust and efficient dual-graph neural networks for structural damage detection and localization[J]. Engineering Structures, 2025, 343: 121265.

[63] Wang J, Feng S, Lyu G, et al. SURER: Structure-Adaptive Unified Graph Neural Network for Multi-View Clustering[C]//Proceedings of the AAAI Conference on Artificial Intelligence. Palo Alto: AAAI Press, 2024.

[64] 倪艳春, 靳启源, 胡睿. 基于多尺度自适应融合图卷积网络的结构损伤识别[J]. 工业建筑, 2025, 55(12): 188-197.

[65] 唐和生, 王泽宇, 陈嘉缘. 基于数字孪生和深度学习的结构损伤识别[J]. 土木与环境工程学报(中英文), 2024, 46(1): 110-121.

[66] 滕辉, 康帅, 王自法, 等. 基于迁移学习的框架结构损伤识别研究[J]. 世界地震工程, 2023, 39(3).

[67] Johnson E A, Lam H F, Katafygiotis L S, Beck J L. Phase I IASC-ASCE structural health monitoring benchmark problem using simulated data[J]. Journal of Engineering Mechanics, 2004, 130(1): 3-15.

[68] Collell G, Prelec D, Patil K R. A simple plug-in bagging ensemble based on threshold-moving for classifying binary and multiclass imbalanced data[J]. Neurocomputing, 2018, 275: 330-340.

[69] Allemang R J. The modal assurance criterion—twenty years of use and abuse[J]. Sound and Vibration, 2003, 37(8): 14-21.

[70] Kuhn H W. The Hungarian method for the assignment problem[J]. Naval Research Logistics Quarterly, 1955, 2(1/2): 83-97.

致谢

回顾三年的研究生生涯，心中充满感激。论文的完成不仅凝结了个人的努力，也离不开师长、家人、同门与朋友们的支持和帮助。在此，谨向所有关心、帮助和陪伴我的人致以诚挚的感谢。

首先，衷心感谢我的导师唐和生教授。三年来，唐老师在论文选题、研究思路、模型构建、试验分析以及论文写作等方面给予了我悉心指导。从研究方向的确定到具体问题的推进，唐老师始终以严谨的学术态度和深厚的专业积累引导我不断思考、不断修正，也让我逐渐理解科研工作中逻辑严密、求真务实的重要性。除学术指导外，唐老师也十分关心我的职业发展与个人规划，在尊重我个人意愿的基础上，给予我充分的时间和空间去探索未来发展的不同可能。唐老师的指导与包容，使我在研究生阶段不仅完成了学术训练，也更加清楚地认识了自己的能力、兴趣与方向。在此，向唐老师致以最诚挚的感谢和敬意。

其次，感谢我的家人。求学过程中难免会遇到压力、迷茫与低谷，而父母始终站在我的身后，默默给予我最坚定的支持。他们包容我的焦虑，消化我的负面情绪，理解我的选择，并在每一个重要决定面前给予我无条件的信任与鼓励。正是这份稳定而温暖的支持，让我能够在面对困难时继续坚持，也让我有勇气不断追求自己真正想要的人生道路。对此，我将永远心怀感激。

同时，感谢课题组的各位同门、师兄师姐和师弟师妹们。研究生阶段的学习和科研并非孤立完成，许多问题的解决都离不开大家在实验、代码、论文写作和日常交流中的帮助。感谢你们在我遇到困难时给予的建议与支持，也感谢这三年共同学习、讨论和成长的经历。正是这些平凡而真实的陪伴，使研究生生活更加充实而难忘。

最后，感谢同济大学土木工程学院为我提供良好的学习平台和科研环境，也感谢所有在论文完成过程中给予帮助的老师和同学。三年的研究生生活即将结束，但这段经历带给我的思考、磨炼与成长将继续影响我未来的道路。愿自己在今后的人生中，始终保持真诚、坚韧与热爱，继续向前。

个人简历、在读期间发表的学术成果

个人简历：

2023 年 6 月毕业于湖南大学土木工程专业，获工学学士学位。
2023 年 9 月入同济大学土木工程学院结构防灾减灾工程系攻读硕士学位。

同济大学学位论文原创性声明

本人郑重声明：所呈交的学位论文《基于数物双驱异构双图神经网络的结构损伤定位研究》，是本人在导师指导下，独立进行研究工作所取得的成果。除文中已经注明引用的内容外，本学位论文的研究成果不包含任何他人创作的、已公开发表或者没有公开发表的作品的内容。对本论文所涉及的研究工作做出贡献的其他个人和集体，均已在文中以明确方式标明。本学位论文原创性声明的法律责任由本人承担。

学位论文作者签名：

日期：年月日

同济大学学位论文版权使用授权书

本人完全了解同济大学关于收集、保存、使用学位论文的规定，同意如下各项内容：按照学校要求提交学位论文的印刷本和电子版本；学校有权保存学位论文的印刷本和电子版，并采用影印、缩印、扫描、数字化或其它手段保存论文；学校有权提供目录检索以及提供本学位论文全文或者部分的阅览服务；学校有权按有关规定向国家有关部门或者机构送交论文的复印件和电子版；允许论文被查阅和借阅。学校有权将本学位论文的全部或部分内容授权编入有关数据库出版传播，可以采用影印、缩印或扫描等复制手段保存和汇编本学位论文。

本学位论文属于（在以下方框内打“√”）：

□保密，在_____年解密后适用本授权书。

□不保密。

学位论文作者签名：指导教师签名：

日期：年月日日期：年月日