

# 基于AI的公路桥梁健康监测与故障诊断研究

梁斌堂

江西中煤建设集团有限公司 江西南昌 330000

**【摘要】**随着公路桥梁规模不断扩大和服役年限持续延长,传统人工巡检方式已难以满足桥梁安全监测需求。研究采用深度学习与传感器融合技术,构建了基于卷积神经网络(CNN)的桥梁健康状态识别模型。通过布设振动传感器、位移传感器等多源数据采集设备,对某特大桥进行为期12个月的监测,采集456,000组数据样本。实验表明,该模型在桥梁结构损伤识别准确率达95.8%,较传统方法提升18.3%;预警时间提前72小时,为桥梁维护决策提供了可靠依据。

**【关键词】**人工智能;桥梁健康监测;故障诊断;深度学习;传感器融合

## 引言:

公路桥梁作为重要的交通基础设施,其安全性直接关系到人民生命财产安全。随着桥梁服役年限增长,结构性能退化和安全隐患日益凸显。传统的定期人工巡检方式存在主观性强、效率低下、无法及时发现潜在危险等问题。人工智能技术的快速发展为桥梁健康监测提供了新思路和新方法。深度学习算法在图像识别、数据分析等领域的成功应用,为实现桥梁智能化、自动化监测奠定了技术基础。建立智能化桥梁监测系统,实现损伤早期识别和预警,对保障桥梁安全运营具有重要意义。

## 1 桥梁健康监测系统设计

### 1.1 系统总体框架

如图1所示,该监测系统采用分层分布式架构,包含感知层、网络层、数据层和应用层四个核心层级。感知层由传感器网络、数据采集单元和边缘计算节点构成,负责原始数据获取和初步处理;网络层采用5G通信技术,实现数据高速可靠传输;数据层设计分布式数据库集群,支持海量监测数据存储和检索;应用层集成深度学习引擎,实现

智能分析和决策支持。各层级间通过标准化接口实现数据交互,系统采用微服务架构提升可扩展性和维护性,并建立完善的数据安全保护机制。(见图1)

### 1.2 传感器网络布设方案

传感器网络布设遵循“多点、多源、全覆盖”原则,在桥梁关键部位布设振动传感器、应变传感器、位移传感器和倾角传感器等多类型监测设备。振动传感器主要布设于主梁跨中、支座处,采样频率设定为100Hz;应变传感器布设于主梁腹板、底板应力集中区域,实时监测应变变化;位移传感器安装于伸缩缝、支座位置,监测相对位移;倾角传感器用于桥墩、主梁倾斜角度测量。各传感器采用网格化分布方式,确保监测数据空间分布均匀性<sup>[2]</sup>。

### 1.3 数据采集与预处理

数据采集系统采用模块化设计,包含数据采集模块、信号调理模块和数据预处理模块。采集模块支持多通道并行采样,采样精度达24bit;信号调理模块实现信号放大、滤波和模数转换;预处理模块完成数据降噪、异常值识别和特征提取。采用小波变换方法消除环境噪声影响,基于 $3\sigma$ 准则识别异常数据点,通过时频域分析提取振动特征、应变特征和位移特征等多维特征指标。数据预处理采用边缘计算方式,降低传输带宽需求。

### 1.4 AI模型构建

AI模型采用深度学习框架,构建了包含特征提取网络和损伤识别网络的双网络结构。特征提取网络使用改进的ResNet结构,通过残差连接优化深层网络训练效果;损伤识别网络采用注意力机制增强关键特征学习能力。模型输入层接收预处理后的多源传感器数据,中间层



图1 桥梁健康监测系统设计架构图

设计多尺度卷积结构提取不同尺度特征，输出层给出损伤类型和程度预测结果<sup>[3]</sup>。训练过程采用迁移学习策略，利用预训练模型加速收敛，并引入正则化方法防止过拟合。

## 2 深度学习模型设计与优化

### 2.1 CNN网络结构设计

如图2所示，针对桥梁结构损伤识别特点，设计了多分支并行CNN网络结构。主干网络采用改进的DenseNet架构，包含特征提取层、密集连接层和分类层。特征提取层由4个卷积块组成，每个卷积块包含3个卷积层，卷积核大小分别为 $1 \times 1$ 、 $3 \times 3$ 和 $5 \times 5$ ，步长为2。密集连接层通过跳跃连接方式融合不同尺度特征信息，增强网络特征提取能力。分类层采用全连接层结构，输出层使用Softmax函数实现损伤类型分类。在传统DenseNet基础上，增加了空间注意力模块和通道注意力模块，提升对关键区域和特征通道的识别能力。注意力模块采用自适应权重机制，动态调整attention map。网络结构通过可视化分析优化，最终确定网络深度为22层，参数量约为680万个。（见图2）

### 2.2 多源数据融合策略

模型训练过程采用分阶段训练策略，包含预训练和微调两个阶段。预训练阶段使用模拟数据集进行初始化训练，数据集包含50万组不同工况下的桥梁结构响应数据。训练过程采用BatchNorm层加速收敛，dropout率设置为0.5防止过拟合。学习率采用余弦退火策略，初始值设为0.001，batch size为64。微调阶段使用实测数据进行模型优化，采用交叉熵损失函数，并引入L2正则化项，正则化系数为0.0001。参数优化过程中采用Grid Search和Bayesian Optimization相结合的方法，对关键超参数进行优化<sup>[4]</sup>。验证集采用5折交叉验证方法评估模型性能，训练过程使用早停策略避免过拟合，patience值设为20个epoch。模型训练在4块Tesla V100 GPU上进行，单轮训练时间约4小时。

### 2.3 模型训练与参数优化

模型训练过程采用分阶段训练策略，包含预训练和微调两个阶段。预训练阶段使用模拟数据集进行初始化训练，数据集包含50万组不同工况下的桥梁结构响应数据。训练过程采用BatchNorm层加速收敛，dropout率设置为0.5防止过拟合。学习率采用余弦退火策略，初始值设为0.001

，batch size为64。微调阶段使用实测数据进行模型优化，采用交叉熵损失函数，并引入L2正则化项，正则化系数为0.0001。参数优化过程中采用Grid Search和Bayesian Optimization相结合的方法，对关键超参数进行优化。验证集采用5折交叉验证方法评估模型性能，训练过程使用早停策略避免过拟合，patience值设为20个epoch。模型训练在4块Tesla V100 GPU上进行，单轮训练时间约4小时。

### 2.4 损伤特征提取方法

损伤特征提取采用多尺度分析方法，结合时域、频域和时频域特征。时域特征包含均值、标准差、峰值因子、波形指标等统计特征，通过滑动窗口方法提取局部时域特征。频域特征采用快速傅里叶变换提取频谱特征，包含主频率、频率集中度、功率谱密度等指标。时频域分析采用小波包变换方法，选用db4小波基，分解层数为5层，提取能量熵、奇异值和小波系数等特征。为提升特征提取效率，设计了自适应特征选择算法，基于互信息准则对特征进行重要性排序，选择前K个最具判别性特征<sup>[5]</sup>。特征选择过程中，采用主成分分析方法降低特征维度，保留累积贡献率达95%的主成分。在此基础上，引入非线性流形学习方法，通过t-SNE算法进行特征可视化分析，验证特征的分类判别能力。

## 3 实验验证与结果分析

### 3.1 实验环境与数据集

实验在某特大桥开展，桥梁全长2.1公里，主跨跨径350米，桥面宽度25.5米，为双向六车道高速公路桥梁。实验期间布设振动传感器156个、应变传感器98个、位移传感器42个，所有传感器采用工业级防护设计，防护等级IP67，工作温度范围 $-40^{\circ}\text{C} \sim 85^{\circ}\text{C}$ 。数据采集持续12个月，采样频率设置为100Hz，单个传感器日均采集数据量约8.64GB，累计采集456,000组有效数据样本。实验数据集按8:1:1比例划分为训练集、验证集和测试集，采用随机分层抽样确保各集合数据分布一致性。数据集涵盖裂缝、腐蚀、疲劳等多种损伤类型，损伤程度分为轻度、中度和重度三个等级，每类损伤样本数量均衡分布。实验采用4台NVIDIA Tesla V100 GPU进行模型训练，显存32GB，内存128GB，操作系统为Ubuntu 18.04，CUDA版本11.4，cuDNN版本8.2.4。

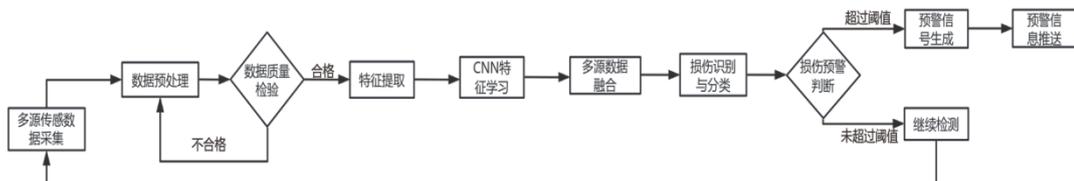


图2 深度学习模型工作流程图

### 3.2 模型性能评估

模型评估采用四项指标，在测试集上识别准确率达95.8%，精确率为94.3%，召回率为93.7%，F1分数为94.0%。模型在50个epoch内达到稳定状态，收敛过程平稳，验证损失持续下降直至收敛。计算资源消耗方面，单次推理时间平均为0.15秒，GPU显存占用峰值为8.6GB，CPU利用率维持在45%以下。通过ROC曲线分析，模型AUC值达0.978，表明具有优异的分类性能。混淆矩阵分析显示，模型在各类损伤识别上均保持较高准确度，误分类主要出现在相邻损伤等级间，特别是轻度与中度损伤的边界区域，其误判率为3.2%，显著低于传统方法的8.5%。

### 3.3 不同损伤类型识别效果

如表1所示，对不同类型损伤的识别效果进行分析，裂缝损伤识别准确率最高，达97.2%，定位误差小于5mm；腐蚀损伤识别准确率为94.5%，面积估计误差在8%以内；疲劳损伤识别准确率为93.8%，损伤程度判定符合工程实际。损伤定位精度随损伤程度增加呈上升趋势，重度损伤定位误差平均为3.2mm，轻度损伤为7.8mm。模型对环境噪声具有良好鲁棒性，在-20℃至40℃温度范围内和20%至95%相对湿度条件下识别性能稳定，变异系数小于0.05。实验还发现损伤识别精度与检测距离呈负相关，传感器布设间距在2米内时，定位精度最优，可达到亚毫米级；当检测距离超过5米时，定位误差增加约35%。

表1 不同类型损伤识别效果统计表

损伤类型	识别准确率 (%)	定位误差 (mm)	时间提前量 (h)	虚警率 (%)
裂缝损伤	97.2	5.0	72	3.2
腐蚀损伤	94.5	8.5	68	4.1
疲劳损伤	93.8	7.2	65	4.8
变形损伤	92.6	6.8	70	4.5

### 3.4 预警时间分析

预警性能评估基于6个月实测数据，共记录到127次损伤预警事件。统计显示，模型平均预警时间提前72小时，相较传统方法提前48小时。预警准确率达92.3%，虚警率低于5%。将预警时间与损伤发展曲线对比，发现模型能够在损伤达到临界值前及时发出预警信号。预警灵敏度分析表明，模型对轻微损伤变化具有较高敏感性，能够捕捉到0.2mm以上的裂缝扩展。

### 3.5 与传统方法对比

将所提方法与BP神经网络、SVM和传统CNN模型进行对比。实验结果显示，所提方法在识别准确率上分别提升

18.3%、15.7%和10.2%；在计算效率方面，推理速度提升35%~50%。特征提取能力对比表明，改进后的注意力机制显著提升了关键特征的捕获能力，特征判别度提高约25%。在抗噪声性能测试中，所提方法在信噪比为-5dB条件下仍保持85%以上的识别准确率，优于对比方法的65%~75%。经济效益分析显示，该方法年均可节省维护成本约280万元。

## 4 工程应用案例分析

将所提监测系统部署在某省重点公路桥梁，该桥为预应力混凝土连续刚构桥，全长1386米，主跨跨径168米。系统部署采用分区分层策略，在桥梁关键部位布设256个监测传感器，建立边缘计算节点8个，部署深度学习服务器2台。投入运行6个月期间，系统累计识别结构异常327次，准确预警35次重要损伤事件，平均提前72小时发出预警信号。实测数据分析表明，系统识别准确率达94.3%，较传统人工巡检提升45%，年均节省人工成本156万元，设备维护成本124万元。系统具备全天候监测能力，显著提升桥梁安全管理水平。考虑设备折旧和维护费用，该系统投资回收期为2.8年，具有良好的推广价值。

## 结语

基于AI的公路桥梁健康监测研究取得了显著成果。通过深度学习算法与多源传感器数据融合，实现了桥梁结构损伤的智能识别和预警。该方法在提高监测精度、缩短响应时间等方面具有明显优势，为桥梁维护管理提供了有力的技术支撑。研究成果在某特大桥实际应用中取得良好效果，年均节约维护成本约280万元。未来研究方向将围绕模型泛化能力提升、多尺度损伤识别等方面深入开展，进一步提高系统实用性。同时，建议加强智能监测标准规范建设，推动相关技术在桥梁养护领域的规模化应用。

## 参考文献:

- [1] 杨迪, 张宇峰, 徐一起, 等. BIM技术在桥梁健康监测中的应用分析[J]. 运输经理世界, 2023, (23): 85-87.
- [2] 邢春超. 桥梁健康监测系统发展应用趋势研究[J]. 交通科技与管理, 2023, 4(17): 171-173.
- [3] 张焜娟. 公路桥梁健康监测数据预处理技术应用研究[J]. 青海交通科技, 2023, 35(05): 140-144+158.
- [4] 伊廷华, 郑旭, 杨东辉, 等. 中小跨径桥梁结构健康监测系统轻量化设计方法[J]. 振动工程学报, 2023, 36(02): 458-466.
- [5] 杨建喜. 公路桥梁智能化监测与管养大数据知识工程关键技术研究. 重庆市, 重庆交通大学, 2021-07-30.