

# AI驱动的水利工程设施智能巡检与故障诊断系统构建

杜峻 王建军 刘冬雪  
北京市北运河管理处 北京 100101

**摘要：**水利工程设施作为国家基础设施的重要组成部分，其安全稳定运行直接关系到防洪安全、水资源调配及生态环境保护。传统巡检方式依赖人工经验，存在效率低、漏检率高、响应滞后等问题。本文提出一种基于人工智能（AI）的水利工程设施智能巡检与故障诊断系统，通过融合多源传感器数据、深度学习算法与知识图谱技术，实现设施状态的实时感知、异常预警与精准诊断。系统在某大型水库的试点应用表明，巡检效率提升60%，故障识别准确率达92%，为水利工程智能化运维提供了新范式。

**关键词：**水利工程；智能巡检；故障诊断；深度学习；多源数据融合

## 引言

水利工程设施（如大坝、水闸、泵站等）长期暴露于复杂自然环境中，易受水流冲刷、温度变化、材料老化等因素影响，导致结构损伤或功能失效。传统巡检依赖人工定期巡查，存在主观性强、覆盖范围有限、数据利用率低等缺陷，难以满足现代化水利管理的需求。随着物联网（IoT）、大数据、AI等技术的快速发展，智能巡检与故障诊断成为水利工程运维领域的研究热点。

### 1 水利工程设施巡检与故障诊断的技术挑战

#### 1.1 数据复杂性与异构性

水利工程设施涉及结构健康监测（SHM）、设备运行参数、环境变量等多源数据，数据类型包括振动信号、图像、温度、压力等，具有高维度、非线性、动态变化等特点。传统方法难以有效融合多模态数据，导致信息利用率低。

#### 1.2 故障模式多样性

设施故障可能由材料疲劳、设计缺陷、外部冲击等多种因素引发，表现为裂缝、渗漏、变形等不同形态。故障特征与成因之间存在复杂非线性关系，传统基于阈值的诊断方法易产生误报或漏报。

#### 1.3 实时性与可解释性矛盾

深度学习模型虽能实现高精度故障识别，但存在“黑箱”问题，难以向运维人员解释诊断依据。水利工程作为关键基础设施，其决策需兼顾实时性与可解释性，这对模型设计提出更高要求。

#### 1.4 场景适应性不足

水利工程分布广泛，不同地区的气候、地质条件差异显著，导致故障模式具有地域特异性。通用型AI模型难以直接迁移应用，需结合具体场景进行定制化优化。

### 2 AI驱动的智能巡检与故障诊断系统架构

#### 2.1 系统总体框架

本系统采用“端-边-云”协同架构，由数据感知层、边缘计算层、云端分析层与应用服务层构成，实现水利工程设施高效智能巡检与故障诊断。

数据感知层通过光纤光栅传感器、摄像头、超声波探测仪等，全息采集设施应变、温度、图像及内部缺陷等数据。

边缘计算层预处理数据以去噪提效，用简单模型初检异常，异常信息上传云端，正常数据本地存储，减少传输量。

云端分析层为核心，集成深度学习模型与知识图谱，深入分析数据、挖掘特征，结合设计规范、历史案例等实现精准诊断。

应用服务层通过可视化界面，为运维人员展示运行状态、故障信息及处置建议，提升决策效率与科学性。

#### 2.2 多源数据融合与特征提取

水利工程设施数据存在异构性问题，系统采用“时空对齐+特征融合”策略。首先，通过时间同步协议（PTP）与空间坐标映射实现多传感器数据时空对齐。时间同步协议确保不同传感器采集的数据时间一致，避免因时间差异导致分析错误；空间坐标映射统一不同传感器空间位置信息，使数据能在相同空间参考系下分析融合。时空对齐保证了多源数据在时间和空间上的一致性，为后续特征提取和融合奠定基础。其次，利用卷积神经网络（CNN）提取图像特征、长短期记忆网络（LSTM）处理时序信号。CNN具备强大图像特征提取能力，能自动学习图像层次化特征，从低级边缘、纹理特征到高级语义特征。在水利工程设施巡检中，CNN可分析摄像头采集的图像，提取裂缝、渗漏等故障特征。LSTM擅长处理时序信号，能捕捉时序数据长期依赖关

系<sup>[1]</sup>。对于振动信号、温度变化等时序数据，LSTM 可分析其变化趋势和周期性特征，发现潜在故障信息。然后，通过注意力机制融合多模态特征，构建设施状态综合表征向量。注意力机制能自动学习不同模态特征重要性，根据其对故障诊断的贡献分配不同权重。通过融合，将图像特征和时序特征有机结合，形成全面反映设施状态的综合表征向量。该向量包含丰富信息，能更准确描述设施运行状态和故障特征，为后续故障检测和诊断提供有力支持。

### 2.3 基于深度学习的故障检测模型

水利工程设施故障模式多样，系统设计了双分支检测网络，包括异常检测分支和分类诊断分支。异常检测分支采用自编码器（AE）无监督学习框架。自编码器由编码器和解码器组成，编码器将输入数据压缩成低维潜在表示，解码器将潜在表示重构为原始数据。训练时，自编码器学习输入数据正常模式和特征。输入数据异常时，重构误差显著增大，通过监测重构误差可识别未知故障。该分支能初步检测水利工程设施中新出现的、未在训练数据中出现的故障，提高系统故障检测能力。分类诊断分支基于残差网络（ResNet）构建监督学习模型。残差网络引入残差块解决深度神经网络梯度消失问题，使网络可构建得更深，学习更复杂特征。在该分支中，用带有标签的正常和故障样本训练 ResNet 模型，使其学习不同故障类型特征表示。训练完成后，模型可准确分类已知故障类型，确定故障具体类型。为提升诊断鲁棒性，两分支结果通过加权融合处理<sup>[2]</sup>。根据不同分支性能和可靠性分配不同权重，综合两个分支输出结果得到最终故障诊断结果。同时，引入对抗训练增强模型对噪声数据的抗干扰能力。对抗训练在训练过程中生成对抗样本，使模型面对含噪声或干扰的数据时保持较好性能，提高模型泛化能力和稳定性。

### 2.4 知识图谱驱动的可解释诊断

为解决深度学习可解释性不足问题，系统构建了水利工程知识图谱。知识图谱以“实体 - 关系 - 属性”三元组形式组织知识，涵盖设施实体（如大坝、闸门）、故障实体（如裂缝、渗漏）以及它们之间的关系（如“裂缝导致渗漏”）。构建知识图谱时，先收集整理水利工程设施的设计规范、历史故障案例、专家经验等结构化知识。然后抽取转换这些知识，表示为“实体 - 关系 - 属性”三元组形式。例如，“大坝出现裂缝可能导致渗漏”可表示为（大坝，出现，裂缝）、（裂缝，导致，渗漏）等三元组。将这些三元组存储在图数据库中，构建起水利工程知识图谱。诊断过程中，模型输出故障概

率后，通过图谱推理引擎（如 Neo4j）追溯故障传播路径。Neo4j 是高性能图数据库，能高效存储和查询图数据。利用其 Cypher 语言可在知识图谱中进行路径推理和查询。例如，模型判断闸门出现渗漏故障时，系统通过图谱推理引擎查找与渗漏相关的实体和关系，生成“故障现象 - 潜在原因 - 处置建议”逻辑链。如“闸门左侧渗漏”可能对应“渗漏可能由密封条老化或结构变形引起，建议检查密封条压紧力与闸门垂直度”。该逻辑链为运维人员提供清晰故障分析和处置建议，提高故障诊断可解释性和实用性。

### 2.5 轻量化模型部署与边缘协同

水利工程现场计算资源有限，系统采用模型压缩技术（如知识蒸馏、量化剪枝）将云端大模型转化为轻量化边缘模型，并部署于智能网关或无人机巡检终端。知识蒸馏是将大型教师模型知识迁移到小型学生模型的技术。让小型学生模型学习大型教师模型输出分布，使其在保持较高性能的同时，大大减少模型参数和计算量。量化剪枝是对模型参数进行量化和剪枝操作，将浮点参数转换为低精度定点数参数，去除模型中不重要的参数和连接，进一步减小模型大小和计算复杂度。经模型压缩后，轻量化边缘模型参数量可减少 80% 以上，精度损失控制在 3% 以内。这些模型可部署在智能网关或无人机巡检终端等边缘设备上。边缘节点负责实时数据采集与初步分析，利用轻量化模型快速处理采集的数据，检测异常情况。发现异常时，边缘节点上传相关信息至云端进一步分析诊断。云端进行全局优化与模型更新。收集来自各边缘节点的数据和诊断结果，综合分析挖掘更深层次的故障模式和规律。根据新数据和反馈信息，更新优化云端大模型，然后将更新后的模型参数或知识下发至边缘节点，实现边缘 - 云端协同学习和模型更新。这种“分布式感知 - 集中式学习”闭环体系充分利用边缘设备实时数据处理能力和云端强大计算学习能力，提高系统整体性能和适应性。

## 3 系统实现与关键技术

### 3.1 数据采集与预处理

以某水库大坝为例，为全面监测其运行状态，部署了多种传感器。光纤光栅传感器用于监测应变与温度变化，凭借高精度和长距离监测优势，可实时获取关键部位信息，及时发现结构异常。摄像头安装在合适位置，通过高清图像监测大坝表面裂缝的形态、长度和宽度等特征。声发射传感器用于监测大坝内部损伤，捕捉裂缝扩展或材料破坏时产生的声发射信号，为判断内部健康状况提供依据。传感器采样频率设为 100Hz - 1kHz，以满

足不同信号采集需求。采集的原始数据含噪声和干扰，需预处理。去噪采用小波变换，其时频局部化特性好，能将信号分解到不同频率子带，处理小波系数可去除噪声、保留有用特征。归一化用 Min - Max 标准化方法，将数据线性变换到[0, 1]或[- 1, 1]范围，消除量纲差异，使数据可比。对于缺失值，用 KNN 插值方法，根据邻近样本加权平均值填充，保持数据局部特征和分布规律。预处理确保了输入数据质量，为后续模型训练和故障诊断提供可靠基础。

### 3.2 深度学习模型训练与优化

为提高模型训练效率和性能，采用迁移学习策略。基于 ImageNet 预训练的 ResNet - 50 模型初始化图像分支参数，ImageNet 是大规模图像数据集，ResNet - 50 在其上预训练后已具备通用图像特征提取能力，迁移到水利工程设施故障诊断图像分支可加速收敛、提高泛化能力。时序分支采用双向 LSTM 结构，能同时考虑过去和未来时序信息，更好捕捉长期依赖关系，分析水利工程设施振动信号、温度变化等时序数据的趋势和周期性特征，发现潜在故障信息。训练数据集含 5000 组正常样本和 3000 组故障样本，为提高泛化能力、避免过拟合，通过数据增强（旋转、缩放、加噪）扩充至 2 万组，使模型学习更丰富特征和模式。模型在 NVIDIA Tesla V100 GPU 上训练，其并行计算能力强，可加速训练。优化器选 Adam，结合动量梯度下降和自适应学习率优点，根据参数历史梯度信息自动调整学习率，加快收敛。学习率动态调整，初始值 0.001，每 10 轮训练衰减 10%，训练初期快速收敛，后期避免震荡，提高训练效果<sup>[3]</sup>。

### 3.3 知识图谱构建与应用

知识图谱以“实体 - 关系 - 属性”三元组组织知识。水利工程知识图谱包含设施实体（如大坝、闸门、泵站）、故障实体（如裂缝、渗漏、变形）及它们的关系（如“裂缝导致渗漏”“变形影响闸门启闭”），每个实体和关系有相应属性，如大坝有高度、长度、建造时间，裂缝有长度、宽度、深度等。用 Neo4j 图数据库存储与查询知识图谱，它采用原生图存储结构，能高效存储和查询图数据。构建时将三元组导入数据库形成图结

构。诊断时调用 Cypher 语言实现路径推理，Cypher 是 Neo4j 专用查询语言，语法简洁易懂。如输入“闸门左侧渗漏”，系统通过 Cypher 语言在知识图谱中查询相关实体和关系，输出“渗漏可能由密封条老化或结构变形引起，建议检查密封条压紧力与闸门垂直度”等结果，为运维人员提供决策支持。

### 3.4 边缘 - 云端协同机制

边缘节点用 NVIDIA Jetson AGX Xavier 开发板，计算能力强、功耗低，适合运行轻量化模型。运行压缩后的模型，经模型压缩技术处理，参数量减少 80% 以上，精度损失控制在 3% 以内，能在边缘节点高效处理实时数据。云端定期接收边缘节点上传的难样本，难样本是模型在边缘节点处理时置信度低于阈值的样本，含复杂或罕见故障特征，边缘轻量化模型难准确处理。云端收集后利用强大计算资源和丰富数据进一步分析。通过联邦学习更新全局模型，它是分布式机器学习方法，允许多边缘节点不共享原始数据共同训练全局模型。各边缘节点用本地数据训练轻量化模型，上传参数至云端，云端聚合更新得到全局模型参数，再下发至各边缘节点，实现协同学习，避免数据隐私泄露，提高模型整体性能和适应性。

### 结束语

本文围绕水利工程智能巡检与故障诊断展开，融合深度学习技术与多源数据融合方法，构建了更精准的诊断模型。研究验证了多源数据互补性对提升巡检效率的作用，为水利设施安全运维提供新思路。未来可进一步优化数据融合策略，提升复杂环境下模型的研究性，助力智慧水利发展。

### 参考文献

- [1] 彭在兴. 基于智能巡检的智能化变电站状态监测系统设计方案[J]. 华东电力, 2019, 40(06): 999-1001.
- [2] 安全喜. 电气高压开关设备在线监测技术与优越性分析[J]. 河南科技, 2018, (3): 77, 82.
- [3] 陈志勇, 李伟. 智能巡检的智能化变电站状态监测系统设计方案[J]. 黑龙江科技信息, 2018, (21): 77.