

# 基于云边协同与深度学习的长输管道分布式光纤智能预警系统研究

史峰旭, 冯文娟

陕西天然气股份有限公司, 陕西 西安

收稿日期: 2026年7月2日; 录用日期: 2026年8月25日; 发布日期: 2026年9月7日

## 摘 要

针对长输管道沿线外力破坏、车辆扰动、施工活动与复杂环境噪声交织导致的预警不及时、误报率高和定位偏差问题, 本文提出一种基于云边协同与深度学习的分布式光纤智能预警系统。系统采用 $\phi$ -OTDR实现沿线振动连续感知, 在边缘端完成解调、降噪、事件触发与本地初判, 在云端完成模型训练、GIS联动、样本复核与版本管理。算法上, 采用小波包分解增强破土冲击频段, 构建多尺度1D-CNN-BiLSTM-Attention模型识别机械破土、人工敲击、车辆经过、人员走动和环境干扰等事件, 并利用光学里程-管道桩号-GIS坐标映射矩阵修正余缆和盘缆引起的定位畸变。现场样本验证表明, 该方案能够降低无效数据回传量, 缩短告警链路时延, 并为长输管道巡检处置提供可定位、可复核的事件证据。

## 关键词

长输管道, 分布式光纤,  $\phi$ -OTDR, 云边协同, 深度学习, GIS定位

# Research on Distributed Fiber-Optic Intelligent Early Warning System for Long-Distance Pipelines Based on Cloud-Edge Collaboration and Deep Learning

Fengxu Shi, Wenjuan Feng

Shaanxi Natural Gas Co., Ltd., Xi'an Shaanxi

Received: July 2, 2026; accepted: August 25, 2026; published: September 7, 2026

文章引用: 史峰旭, 冯文娟. 基于云边协同与深度学习的长输管道分布式光纤智能预警系统研究[J]. 石油天然气学报, 2026, 48(3): 469-479. DOI: 10.12677/jogt.2026.483051

## Abstract

To improve early warning reliability for long-distance pipelines exposed to excavation, traffic interference, construction activities and non-stationary environmental noise, this paper proposes a distributed fiber-optic intelligent warning system based on cloud-edge collaboration and deep learning. Phase-sensitive optical time-domain reflectometry is used for continuous vibration sensing along the pipeline. Edge nodes perform demodulation, denoising, event triggering and local inference, while the cloud platform supports model training, GIS linkage, sample review and version management. Wavelet packet decomposition is adopted to enhance impact-related frequency bands, and a multi-scale 1D-CNN-BiLSTM-Attention model is designed for event classification. A dynamic mapping matrix between optical distance, pipeline stake number and GIS coordinates is further introduced to compensate localization errors caused by fiber coils and redundant cable sections. Field-oriented evaluation indicates that the framework reduces invalid uplink traffic, shortens warning latency and provides traceable evidence for pipeline inspection and emergency response.

## Keywords

Long-Distance Pipeline, Distributed Fiber-Optic Sensing,  $\phi$ -OTDR, Cloud-Edge Collaboration, Deep Learning, GIS Localization

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

## 1. 引言


长输油气管道通常跨越山区、农田、河谷、交通干线和施工密集区,线路长、环境开放、巡检链条长。一旦发生第三方施工破坏或地质扰动,单纯依赖人工巡线、定点视频或单点传感器难以及时发现风险。分布式光纤振动/声学传感(DVS/DAS)以光纤作为连续传感介质,具有无源、抗电磁干扰、覆盖距离长和空间采样密度高等特点,适合管道、铁路、隧道和输电线路等线状基础设施监测[1]-[5]。

从工程应用看,管道 DAS 系统面临三类关键问题:第一,车辆、风雨、农机和人员活动造成的非平稳噪声易引发误报;第二,原始 DAS 数据为高频“距离 × 时间”矩阵,全量回传会造成带宽和存储压力;第三,光缆余缆、盘缆和接续盒会造成光学里程与实际管道桩号不一致,影响巡检人员到场处置。因此,预警系统需要同时解决信号增强、事件识别、边缘实时处理和 GIS 定位落地问题。

本文在现有分布式光纤传感与工业边缘计算研究基础上,构建“端-边-云”协同架构,将实时性要求高的解调、降噪和触发逻辑部署在边缘端,将样本管理、模型训练、GIS 联动和运维闭环部署在云端。研究重点不是单一算法指标提升,而是形成能够进入管道运维流程的完整预警链路。系统总体技术路线见图 1。

与现有工作相比,本文的差异与贡献主要体现在以下三个方面。已有管道 DAS 研究[6] [7]多聚焦事件检测方法、知识规则与机器学习模型的性能,架构层面的端-边-云协同、弱网缓存和运维闭环描述相对有限。本文构建感知端-边缘端-云平台-移动/调度端的分层架构:边缘端完成解调、降噪、触发和初判,仅回传事件证据,云端负责训练、复核、GIS 联动和版本管理;在模型层,将小波包频带增

强与多尺度 1D-CNN-BiLSTM-Attention 结合, 以兼顾局部冲击、时间演化与可解释特征; 在定位层, 建立光学里程 - 管道桩号 - GIS 坐标映射矩阵, 并利用 FWHM 异常展宽识别余缆/盘缆, 补偿仅依赖光学里程定位造成的偏差。因此, 本文贡献不局限于单一识别器优化, 而是形成覆盖“感知 - 边缘判定 - 云端复核 - 定位修正 - 巡检反馈”的可落地预警链路。



**Figure 1.** Technical route of distributed fiber-optic warning for long-distance pipelines

**图 1.** 长输管道分布式光纤智能预警技术路线

## 2. 相关技术基础与研究现状

从研究现状看, 相关工作可分为三类: 一是基于  $\phi$ -OTDR/DAS 的信号增强与事件分类, 强调噪声抑制、模式识别或学习算法比较; 二是面向地震、火山等线状或大范围基础设施的分布式光纤感知应用, 证明了长距离连续观测能力; 三是深度学习、边缘计算及云端协同等通用技术。上述研究为本文提供了感知机理、算法和计算架构基础, 但管道场景下的余缆/盘缆定位畸变、弱网运行和告警证据闭环仍需工程化整合。本文以管道运维为对象, 对感知、识别、定位和系统部署进行联合设计。相关信号分类和增强研究见文献[8]-[10], 分布式光纤在线性基础设施及地球物理监测中的应用见文献[11]-[13]。


### 2.1. $\phi$ -OTDR 振动感知机理

$\phi$ -OTDR 系统向传感光纤注入窄线宽相干脉冲光, 光纤内部微观折射率不均匀性产生瑞利后向散射。外界振动引起光纤应变和折射率变化, 使散射光相位发生扰动。接收端按光脉冲飞行时间展开散射信号, 得到沿光纤的空间响应; 对相邻时刻相位或强度差分后, 可获得振动事件的时间位置矩阵[2]。


该机制的定位精度与脉冲宽度、采样率、光纤折射率设定和现场光缆耦合状态有关。实际管道工程中, 传感光缆可能与管道同沟、旁沟或经由通信管道敷设, 振动从地表或管体传递到光缆会经历土壤、套管和护套衰减。因此, 系统需要通过现场定标建立区段化阈值和位置映射。相关感知与定位关系见图 2。

### 2.2. 云边协同架构

云边协同的核心是把高实时、强本地性的任务放在边缘端, 把全局训练、跨站点数据融合和业务协同放在云端。边缘端负责 I/Q 解调、相位解卷绕、坏道剔除、动态基线、事件触发和轻量化推理; 云端负责样本库、模型训练、GIS 地图、告警工单和模型版本管理。该分工可避免原始波形长期全量上传, 也能在弱网状态下维持本地告警能力。端 - 边 - 云任务分工与数据流见图 3, 功能分工见表 1。



**Figure 2.** Schematic of  $\phi$ -OTDR vibration sensing and optical-distance localization  
**图 2.**  $\phi$ -OTDR 振动感知与光程定位机理示意



**Figure 3.** Cloud-edge-end architecture and data flow  
**图 3.** 端 - 边 - 云协同架构与数据流

**Table 1.** Functional division of cloud-edge collaborative tasks  
**表 1.** 云边协同功能分工

| 层级     | 主要任务                  | 输出结果           |
|--------|-----------------------|----------------|
| 现场感知端  | 光脉冲发射、散射光接收、原始矩阵采集    | 距离 - 时间振动数据    |
| 边缘计算端  | 解调、降噪、阈值触发、轻量推理、缓存    | 事件片段、特征、初判结果   |
| 云平台端   | 模型训练、GIS 映射、样本复核、工单管理 | 分级告警、定位信息、模型版本 |
| 移动/调度端 | 告警接收、现场核查、处置反馈        | 复核标签、巡检记录      |

### 3. 方法与系统设计

#### 3.1. 数据处理流程

系统以连续 DAS 矩阵为输入, 先完成坏点剔除、增益归一化和背景基线更新, 再通过小波包分解 (WPD) 将信号划分为多个频带。结合管道场景经验, 低频段主要包含地表缓慢扰动和温漂, 中频段包含车辆与机械背景, 高频瞬态段包含敲击、破土和金属碰撞等高危特征。重构时对目标频带赋予较高权重, 对低频漂移和高频电子噪声进行抑制。相关小波去噪与可学习变换研究为该处理流程提供了方法基础 [14]-[16]。

事件触发采用短时能量、频带能量比、空间连续性和持续时间联合判定, 避免单点毛刺直接进入告警流程。触发后, 边缘端仅上传事件前后窗口、特征摘要、区段编号和模型初判结果, 原始长时波形保存在本地缓存或按策略抽样回传。降噪处理结果见图 4, 典型频带及其工程含义见表 2。




Figure 4. Schematic waveform comparison before and after wavelet-packet denoising

图 4. 小波包降噪前后波形对比示意

Table 2. Typical frequency bands and engineering meanings

表 2. 典型频带与工程含义

| 频带范围      | 主要来源         | 处理策略         |
|-----------|--------------|--------------|
| 0~20 Hz   | 地表慢变、风致低频、温漂 | 抑制基线漂移       |
| 20~50 Hz  | 车辆、农机、远端施工背景 | 保留统计特征, 降低权重 |
| 50~150 Hz | 敲击、破土、斗齿碰撞   | 增强目标频段       |
| 150 Hz 以上 | 电气噪声、系统抖动    | 根据采样条件剔除或降权  |


#### 3.2. 事件识别模型

事件识别模型采用多尺度 1D-CNN-BiLSTM-Attention 结构。并行卷积分支使用不同长度卷积核提取局部冲击和长包络特征; BiLSTM 提取事件演化顺序; 自注意力层对关键时间片赋权, 增强破土瞬间、连续敲击峰值和车辆通过周期等有效片段。输出层给出类别和置信度, 并保留关键频带、空间展宽和注意力峰值作为解释性证据。其中, 深度学习、LSTM 和注意力机制分别用于表征复杂特征、时间演化和关



键片段权重[17]-[20]。

为适应边缘端部署, 模型训练在云端完成, 边缘端仅加载通过验证的轻量化推理版本。模型发布采用版本号、阈值表和类别表绑定方式, 必要时可进行灰度发布和回滚。该部署思路与边缘计算及工业物联网深度学习研究相衔接, 并可结合联邦学习与 MQTT 实现跨站点更新和事件消息传输[21]-[26]。模型结构见图 5。



设计要点: 小卷积核捕获瞬时冲击, 大卷积核提取机械作业包络, Bi-LSTM保持事件演化顺序, 自注意力增强少数关键帧贡献。


**Figure 5.** Multi-scale 1D-CNN-BiLSTM-Attention event recognition model

**图 5.** 多尺度 1D-CNN-BiLSTM-Attention 事件识别模型

### 3.3. GIS 定位与余缆修正

光学里程并不等同于管道实际里程。工程现场常存在余缆、盘缆、绕行、接续盒和历史改线, 若直接把光程作为地理位置, 会造成巡检误导。本文采用光学里程 - 管道桩号 - GIS 坐标映射矩阵, 通过已知桩号敲击、车辆通过、接头位置和 OTDR 曲线建立分段插值关系。

盘缆区识别采用空间半高全宽(FWHM)异常展宽判据。理论上, 点状敲击在光纤轴向的空间响应宽度相对稳定; 当某区段出现异常展宽或多峰重复响应时, 说明光纤在局部空间内存在回绕或盘存。系统将该区段标记为余缆段, 并在 GIS 映射中进行长度补偿。映射关系与修正流程见图 6。



**Figure 6.** Optical distance, pipeline stake and GIS mapping with redundant cable correction

**图 6.** 光学里程 - 管道桩号 - GIS 坐标映射与余缆修正

4. 试验设计与评价指标

4.1. 试验场景

试验覆盖典型长输管道环境，包括平原耕作区、山区道路邻近区、跨河桥梁区、阀室周边区和施工活动敏感区。采集事件包括机械破土、人工敲击、车辆经过、人员走动、风雨背景、动物扰动和环境静默。每类样本均记录时间、光学里程、GPS 位置、现场照片或巡检备注，形成可追溯样本。

数据集按线路区段和时间批次划分训练集、验证集和测试集，避免同一连续事件片段同时出现在训练和测试中。对于高危事件样本不足的问题，采用现场脚本化采样和类别均衡策略，保证模型既能识别高频常见干扰，也能保持高危事件召回率。数据集与场景配置见表 3。

Table 3. Dataset and scenario configuration  
表 3. 数据集与场景配置

| 类别   | 采集方式             | 主要判别特征         | 风险等级 |
|------|------------------|----------------|------|
| 机械破土 | 挖掘机/破碎锤模拟或现场施工记录 | 周期性冲击、能量高、空间连续 | 高    |
| 人工敲击 | 已知桩号敲击定标         | 短时峰值明显、持续时间短   | 中/高  |
| 车辆经过 | 道路邻近区车辆通行        | 低中频包络、移动轨迹明显   | 低/中  |
| 人员走动 | 沿线行走或踩踏          | 能量较低、间歇性强      | 低    |
| 环境干扰 | 风雨、农机远端、动物扰动     | 频带分散、置信度不稳定    | 低    |

4.2. 评价指标

评价指标分为信号、识别、定位和系统四类。信号指标包括 SNR、目标频段能量占比和事件片段可分辨性；识别指标包括 Precision、Recall、F1-Score 和高危事件漏报率；定位指标包括光学里程误差、桩号误差、GIS 坐标误差和盘缆修正前后偏差；系统指标包括端到端时延、上行数据压缩率、边缘端 CPU/内存占用和断网缓存恢复能力。评价指标体系见表 4。

Table 4. Evaluation index system  
表 4. 评价指标体系

| 维度   | 指标                             | 用途          |
|------|--------------------------------|-------------|
| 信号质量 | SNR、频带能量比、事件峰值清晰度              | 验证降噪和特征增强效果 |
| 识别性能 | Precision、Recall、F1-Score、混淆矩阵 | 评估多类别事件分类能力 |
| 定位性能 | 桩号误差、GIS 误差、FWHM 异常识别率         | 验证巡检可达性     |
| 系统性能 | 时延、上行数据量、缓存恢复、模型推理耗时           | 验证工程部署能力    |

5. 结果与分析

5.1. 降噪与触发效果

在强交通背景下，WPD 处理后目标冲击片段的上升沿和衰减周期更清晰，低频基线漂移得到抑制。与直接阈值法相比，联合频带能量和空间连续性的触发策略能够过滤部分孤立毛刺，减少无效告警进入云端。降噪效果示例见表 5。

Table 5. Example of denoising performance  
表 5. 降噪效果示例

| 指标       | 原始信号   | 处理后信号   | 变化        |
|----------|--------|---------|-----------|
| SNR      | 1.5 dB | 12.5 dB | 提升约 11 dB |
| 局部峰值可分辨性 | 弱      | 明显      | 冲击段更清晰    |
| 目标频段能量占比 | 12%    | 78%     | 目标频段增强    |
| 误触发片段    | 较多     | 减少      | 降低上行无效数据  |

5.2. 事件识别性能

模型在车辆经过和环境干扰类别上表现较稳定，对机械破土具有较高召回率。人工敲击与人员走动在低能量样本中存在一定混淆，主要原因是二者均可能表现为短时局部峰值。工程使用时，高危类别应优先保证召回率，并通过二级复核降低误报影响。事件识别混淆情况见图 7，分类性能示例见表 6。




Figure 7. Confusion matrix of event recognition  
图 7. 事件识别混淆矩阵示意

Table 6. Example of classification performance  
表 6. 分类性能示例

| 事件类型 | Precision | Recall | F1-Score |
|------|-----------|--------|----------|
| 机械破土 | 93.5%     | 95.8%  | 0.946    |
| 人工敲击 | 91.2%     | 88.5%  | 0.898    |
| 车辆经过 | 97.4%     | 98.2%  | 0.978    |
| 环境干扰 | 98.1%     | 98.5%  | 0.983    |
| 加权平均 | 92.8%     | 92.1%  | 0.924    |



### 5.3. 定位与时延表现

通过已知桩号定标和 GIS 映射修正后, 系统能够把光学里程转换为巡检人员可识别的管道桩号和地图坐标。盘缆区未经修正时可能造成百米级偏差, 修正后定位误差可控制在巡检可接受范围内。

云边协同减少了原始波形长时间回传, 边缘端先判定、云端再复核的流程使告警时延更稳定。弱网条件下, 边缘缓存可保留事件片段, 网络恢复后再补传证据, 避免高危事件丢失。端到端时延与上行数据压缩结果见图 8, 定位与系统性能示例见表 7。




Figure 8. End-to-end latency and uplink traffic compression

图 8. 端到端时延与上行数据压缩示意

Table 7. Example of localization and system performance

表 7. 定位与系统性能示例

| 项目       | 结果       | 说明             |
|----------|----------|----------------|
| 普通区段定位误差 | 约 5~10 m | 依赖桩号定标和光缆耦合    |
| 盘缆修正前偏差  | 可达百米级    | 由余缆长度引起        |
| 盘缆修正后偏差  | 降至可巡检范围  | 通过 FWHM 异常识别补偿 |
| 端到端告警时延  | <500 ms  | 边缘触发后推送云端/移动端  |
| 上行数据压缩   | >99%     | 由全量波形转为事件片段/特征 |

## 6. 讨论

该系统的工程价值在于把 DAS 连续感知能力转化为可执行的巡检结果。仅有高灵敏度传感并不足以支撑生产运维, 系统还必须具备误报控制、风险分级、定位修正、样本回写和模型版本管理能力。云边协同使“实时告警”和“持续学习”分离: 边缘端保证响应, 云端保证模型迭代和跨线路知识积累。

系统仍存在三方面改进空间。第一, 跨区段泛化能力需要长期验证, 不同土壤、埋深和光缆结构会改变振动耦合特性; 第二, 低能量人工活动与环境干扰之间仍可能混淆, 需要引入更多现场复核样本; 第三, 单一 DAS 信号缺少可视证据, 未来可融合无人机、视频、施工票、气象和 InSAR 等数据, 形成多源互证的风险判断。

边缘模型部署应坚持“可解释、可维护、可回滚”原则。对于管道安全预警, 高危事件召回率和现

场信任度通常比单次离线测试准确率更重要。模型输出应同步展示关键频段能量、空间展宽、持续时间、置信度和定位误差范围, 使值班人员能够理解告警依据。

## 7. 结论

本文提出了一种基于云边协同与深度学习的长输管道分布式光纤智能预警系统。系统在感知层采用 $\phi$ -OTDR实现沿线连续振动采集, 在边缘层完成降噪、触发和本地初判, 在云端完成模型训练、GIS联动和运维闭环。

研究表明, 小波包分解有助于增强破土冲击等目标频段, 多尺度1D-CNN-BiLSTM-Attention模型能够综合局部冲击、机械包络和时间演化特征, 光学里程-桩号-GIS映射矩阵能够修正盘缆和余缆导致的定位偏差。云边协同机制可降低原始数据回传压力, 并提升弱网条件下的告警稳定性。

后续工作应围绕跨线路数据集建设、极端天气样本补充、边缘模型轻量化、多模态融合和数据安全治理展开, 以支撑长输管网规模化、长期化智能运维。

## 参考文献

- [1] 吴德胜. 管道完整性管理[M]. 北京: 石油工业出版社, 2018.
- [2] Hartog, A.H. (2017) An Introduction to Distributed Optical Fibre Sensors. CRC Press.
- [3] Rao, Y.J., Wang, Z.N., Wu, H.J., Ran, Z.L. and Han, B. (2021) Recent Advances in Phase-Sensitive Optical Time Domain Reflectometry ( $\phi$ -OTDR). *Photonic Sensors*, **11**, 1-30. <https://doi.org/10.1007/s13320-021-0619-4>
- [4] Zhu, H.H., Liu, W., Wang, T., Su, J.W. and Shi, B. (2022) Distributed Acoustic Sensing for Monitoring Linear Infrastructures: Current Status and Trends. *Sensors*, **22**, 7550. <https://doi.org/10.3390/s22197550>
- [5] Lu, Y., Zhu, T., Chen, L. and Bao, X. (2010) Distributed Vibration Sensor Using Coherent Detection of Phase-OTDR. *Journal of Lightwave Technology*, **28**, 3243-3249.
- [6] Tejedor, J., Macias-Guarasa, J., Martins, H., Pastor-Graells, J., Corredra, P. and Martin-Lopez, S. (2017) Machine Learning Methods for Pipeline Surveillance Systems Based on Distributed Acoustic Sensing: A Review. *Applied Sciences*, **7**, Article 841. <https://doi.org/10.3390/app7080841>
- [7] Bublin, M. (2021) Event Detection for Distributed Acoustic Sensing: Combining Knowledge-Based, Classical Machine Learning, and Deep Learning Approaches. *Sensors*, **21**, Article 7527. <https://doi.org/10.3390/s21227527>
- [8] Barantsov, I.A., Pnev, A.B., Koshelev, K.I., Tynchenko, V.S., Nelyub, V.A. and Borodulin, A.S. (2023) Classification of Acoustic Influences Registered with Phase-Sensitive OTDR Using Pattern Recognition Methods. *Sensors*, **23**, Article 582. <https://doi.org/10.3390/s23020582>
- [9] Jiang, F., Zhang, Z.H., Lu, Z.X., Li, H.L., Tian, Y.H., Zhang, Y.X., et al. (2021) High-Fidelity Acoustic Signal Enhancement for Phase-OTDR Using Supervised Learning. *Optics Express*, **29**, 33467-33480. <https://doi.org/10.1364/oe.439646>
- [10] Muñoz, F. and Soto, M.A. (2022) Enhancing Fibre-Optic Distributed Acoustic Sensing Capabilities with Blind Near-Field Array Signal Processing. *Nature Communications*, **13**, Article No. 4019. <https://doi.org/10.1038/s41467-022-31681-x>
- [11] Lindsey, N.J., Martin, E.R., Dreger, D.S., Freifeld, B., Cole, S., James, S.R., et al. (2017) Fiber-Optic Network Observations of Earthquake Wavefields. *Geophysical Research Letters*, **44**, 11792-11799. <https://doi.org/10.1002/2017gl075722>
- [12] Williams, E.F., Fernández-Ruiz, M.R., Magalhaes, R., Vanthillo, R., Zhan, Z., González-Herráez, M., et al. (2019) Distributed Sensing of Microseisms and Teleseisms with Submarine Dark Fibers. *Nature Communications*, **10**, Article No. 5778. <https://doi.org/10.1038/s41467-019-13262-7>
- [13] Jousset, P., Currenti, G., Schwarz, B., Chalari, A., Tilmann, F., Reinsch, T., et al. (2022) Fibre Optic Distributed Acoustic Sensing of Volcanic Events. *Nature Communications*, **13**, Article No. 1753. <https://doi.org/10.1038/s41467-022-29184-w>
- [14] Donoho, D.L. and Johnstone, I.M. (1994) Ideal Spatial Adaptation by Wavelet Shrinkage. *Biometrika*, **81**, 425-455. <https://doi.org/10.1093/biomet/81.3.425>
- [15] Donoho, D.L. (1995) De-Noising by Soft-Thresholding. *IEEE Transactions on Information Theory*, **41**, 613-627. <https://doi.org/10.1109/18.382009>

- 
- [16] Michau, G., Frusque, G. and Fink, O. (2022) Fully Learnable Deep Wavelet Transform for Unsupervised Monitoring of High-Frequency Time Series. *Proceedings of the National Academy of Sciences of the United States of America*, **119**, e2106598119. <https://doi.org/10.1073/pnas.2106598119>
  - [17] LeCun, Y., Bengio, Y. and Hinton, G. (2015) Deep Learning. *Nature*, **521**, 436-444. <https://doi.org/10.1038/nature14539>
  - [18] Hochreiter, S. and Schmidhuber, J. (1997) Long Short-Term Memory. *Neural Computation*, **9**, 1735-1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
  - [19] Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A.N., Kaiser, L. and Polosukhin, I. (2017) Attention Is All You Need. *Advances in Neural Information Processing Systems* 2017, Long Beach, 4-9 December 2017, 5998-6008.
  - [20] Lim, B. and Zohren, S. (2021) Time-Series Forecasting with Deep Learning: A Survey. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, **379**, Article ID: 20200209. <https://doi.org/10.1098/rsta.2020.0209>
  - [21] Zeng, A., Chen, M., Zhang, L. and Xu, Q. (2023) Are Transformers Effective for Time Series Forecasting? *Proceedings of the AAAI Conference on Artificial Intelligence*, **37**, 11121-11128. <https://doi.org/10.1609/aaai.v37i9.26317>
  - [22] Shi, W., Cao, J., Zhang, Q., Li, Y. and Xu, L. (2016) Edge Computing: Vision and Challenges. *IEEE Internet of Things Journal*, **3**, 637-646. <https://doi.org/10.1109/jiot.2016.2579198>
  - [23] Satyanarayanan, M. (2017) The Emergence of Edge Computing. *Computer*, **50**, 30-39. <https://doi.org/10.1109/mc.2017.9>
  - [24] Liang, F., Yu, W., Liu, X., Griffith, D. and Golmie, N. (2020) Toward Edge-Based Deep Learning in Industrial Internet of Things. *IEEE Internet of Things Journal*, **7**, 4329-4341. <https://doi.org/10.1109/jiot.2019.2963635>
  - [25] Bao, G. and Guo, P. (2022) Federated Learning in Cloud-Edge Collaborative Architecture: Key Technologies, Applications and Challenges. *Journal of Cloud Computing*, **11**, Article No. 94. <https://doi.org/10.1186/s13677-022-00377-4>
  - [26] OASIS (2019) MQTT Version 5.0: OASIS Standard.