

基于云边协同的多模态洪涝灾害预测架构

陈淑萍, 方禾, 石宇歆, 林舟, 张弛张

(福建师范大学计算机与网络空间安全学院, 福建 福州 350117)

摘要: 洪涝灾害频发严重威胁社会经济稳定与居民财产安全, 提升洪涝灾害预测的准确性与实时性成为亟须解决的问题。为此, 提出了基于云边协同的多模态洪涝灾害预测架构, 突破传统云计算在传输时延、计算负载与实时性方面的瓶颈。该架构利用物联网设备采集原始数据, 在边缘层构建基于长短期记忆网络 (LSTM) 的局部实时预测模型生成局部预测结果; 在云端构建基于 Transformer 的全局融合预测模型提取长距离依赖关系, 形成全局预测结果, 并设计权重自适应调整算法以优化局部与全局结果的协同。实验结果显示, 该架构在洪涝灾害预测的准确性、数据传输时延、实际带宽速率及边缘计算资源利用率均优于传统集中式云计算架构。研究表明, 云边协同与多模态融合能够有效提升洪涝灾害预测的准确性与实时性, 为防灾减灾和科学决策提供了新思路。

关键词: 洪涝灾害预测; 云边协同; LSTM; Transformer

中图分类号: TP393.09

文献标志码: A

doi: 10.11959/j.issn.2096-3750.2026.00516

A multimodal flood prediction architecture based on cloud-edge collaboration

Chen Shuping, Fang He, Shi Yuxin, Lin Zhou, Zhang Chizhang

College of Computer and Cyber Security, Fujian Normal University, Fuzhou 350117, China

Abstract: The frequent occurrence of flood disasters is found to pose a serious threat to socio-economic stability and residents' property security, and the improvement of prediction accuracy and timeliness is identified as an urgent issue. To address this problem, a multimodal flood disaster prediction architecture based on cloud-edge collaboration was proposed, which overcame the bottlenecks of traditional cloud computing in terms of transmission latency, computational load, and real-time performance. In this architecture, raw data was collected by IoT devices, a local real-time prediction model based on LSTM networks was constructed at the edge layer to generate local prediction results, and a global fusion model based on Transformer networks was built in the cloud to capture long-range dependencies and produce global results. Moreover, an adaptive weight adjustment algorithm was designed to optimize the coordination between local and global outputs. Experimental results show that the proposed architecture outperforms traditional centralized cloud computing in prediction accuracy, data transmission latency, actual bandwidth rate, and edge computing resource utilization. It is concluded that cloud-edge collaboration and multimodal fusion effectively enhance the accuracy and timeliness of flood disaster prediction, providing new insights for disaster prevention, mitigation, and scientific decision-making.

Key words: flood disaster prediction, cloud-edge collaboration, LSTM, Transformer

收稿日期: 2025-03-29; 修回日期: 2025-07-28

通信作者: 方禾, fanghe@fjnu.edu.cn

基金项目: 国家自然科学基金资助项目 (No. 62401145); 国家级大学生创新创业训练计划项目 (No. 202510394023); 福建省科技重大专项专题项目 (No. 2024YZ040025); 江苏省自然科学基金资助项目 (No. BK20230479)

Foundation Items: The National Natural Science Foundation of China (No. 62401145), The National Innovation and Entrepreneurship Training Program for College Students (No. 202510394023), The Major Science and Technology Project of Fujian Province (No. 2024YZ040025), The Natural Science Foundation of Jiangsu Province (No. BK20230479)

0 引言

在全球气候变化的背景下，极端天气事件呈现非线性增长态势，洪涝灾害因其高频次、广域性和链式破坏效应，已成为全球自然灾害损失的主要原因^[1]。气候变化引发的极端降水^[2]、台风等事件强度的增加，进一步扩大了洪涝灾害的潜在风险边界。中国受季风气候与复杂地形影响，21世纪年均因气象灾害导致的经济损失逾2 000亿元，受灾人口超4亿人^[3]，其中洪涝灾害对基础设施损毁和公共卫生的危害尤为突出，凸显出防灾减灾工作的战略紧迫性。在此背景下，突破传统洪涝灾害预测架构在预测精度与响应时效上的双重瓶颈，已成为降低经济损失和人员伤亡的关键技术路径，具有重要的社会经济价值和科学研究意义。

洪涝灾害预测^[4]依赖于对复杂环境变量的精准建模和快速响应，而传统预测模型在计算效能及实时性等方面存在诸多挑战，难以满足极端天气条件下的精准预警需求：（1）传统集中式计算架构依赖云端高性能计算资源处理海量水文、气象和遥感数据，但数据传输时延和算力瓶颈严重影响预测响应速度，难以满足分钟级实时预警需求；（2）现有方法主要依赖单一数据源，缺乏对雷达回波、卫星云图等异构数据的高效融合，对灾害复杂演化机制的理解受限，影响预测精度；（3）传统预测模型采用周期性数据更新机制，无法动态整合边缘端实时观测数据，难以及时捕捉突发极端天气事件，影响预警时效性。

本文融合云边协同框架、多模态数据融合，提出一种基于云边协同的多模态洪涝灾害预测架构。通过在边缘层使用长短期记忆网络模型进行局部实时预测，与在云端层利用云计算^[5]使用Transformer模型进行全局融合预测，并利用权重自适应调整机制优化融合预测结果，从而得到最终预测结果，实现灾害预测的高效计算、快速响应与智能优化，提升洪涝灾害预测的准确性与实时性。

1 相关工作

为提升洪涝灾害预测的精度和时效性，国内外研究者近年来提出了多种方法。在统计建模与物理驱动方法方面，水文工程中心河流分析^[6]（HEC-RAS, hydrologic engineering center river analysis）模型基于流体力学方程模拟河道洪水演进，但需高精

度的地形数据支撑，计算复杂度较高。暴雨洪水管理模型^[7]（SWMM, storm water management model）适用于城市内涝模拟，通过管网拓扑建模预测积水深度，但对突发降水响应存在滞后。在机器学习与深度学习方法中，长短期记忆网络^[8]/门控循环单元^[9]（LSTM/GRU, long short-term memory/gated recurrent unit）时序预测通过门控机制捕捉长期依赖关系，在小时级别的预测中表现优异，但空间建模能力不足。Transformer^[10]时空建模利用自注意力机制^[11]捕获全局特征，在72 h预见期的预测中取得较好的效果，但参数量较大，计算成本较高。云边协同^[12]架构中，边缘轻量化推理采用模型剪枝与量化技术^[13]，将模型压缩至较小尺寸，推理速度提升，但可能影响预测精度。云端联邦^[14]优化通过分布式训练聚合多边缘节点数据，模型泛化误差降低，但多模态融合效率仍需提升。

针对传统洪涝灾害预测方法的局限性，近年来，洪涝灾害预测领域的多模态数据融合与云边协同架构的相关研究逐渐成为热点。多模态数据融合^[15]技术主要包括早期融合、晚期融合和混合融合3种策略。（1）早期融合将不同模态的数据特征关联起来并输入模型，以获取跨模态特征间的关系。但模态差异较大时，需要大量的数据预处理。（2）晚期融合分别对不同模态数据进行建模，在最后阶段通过统计或机器学习方法对预测结果进行融合。但难以有效获取跨模态特征信息。（3）混合融合通过多层神经网络将不同模态的原始输入转化为多层表征，在不同层次对信息进行聚合，进而增强模型的灵活性，但网络结构设计比较复杂。

多模态数据融合技术通过对物联网传感器^[16]、卫星遥感^[17]与雷达回波图^[18]等多源数据的融合，提升了灾害预测的精度和稳定性。正如Shen^[19]等构建了多模态数据的洪涝灾害知识图谱，实现了对灾害的全面感知和预测。在云边协同架构方面，边缘计算^[20]通过在边缘端进行数据预处理和初步预测，云端进行全局优化，实现了预测时效性的提升。在云边协同架构中，晚期融合更适合边缘计算^[21]，每个边缘节点可以独立处理本地单模态数据，并将结果在云端聚合^[22]，从而减少传输负载，提高效率。

2 系统模型

传统洪涝灾害预测系统模型架构如图1所示。

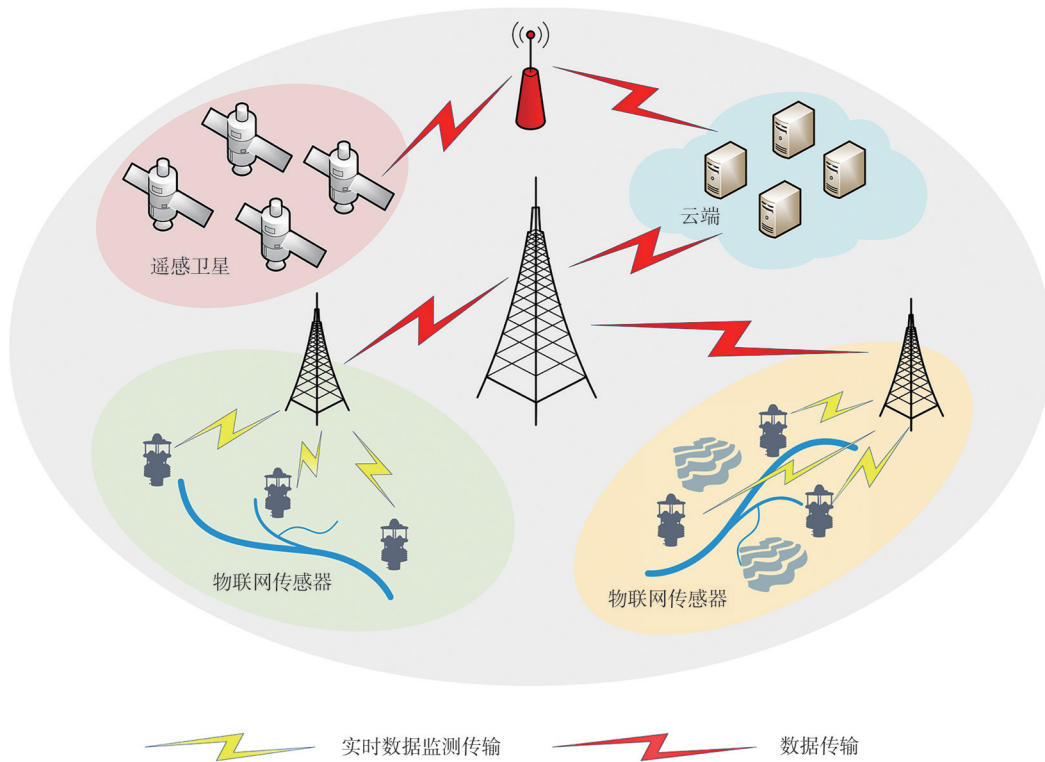


图1 传统洪涝灾害预测系统模型架构

传统洪涝灾害预测系统主要是基于集中式云计算架构^[23]。通过在流域范围内部署各种物联网传感器^[24]，如水位计、雨量计等，实时监测水文和气象数据；通过遥感卫星拍摄高分辨率流域云图，提供更丰富的流域实时观测信息，并将采集到的物联网传感器数据、卫星云图利用物联网技术上传至云端服务器。

云端服务器接收传感器数据和卫星云图，对多源数据进行预处理。利用多模态数据融合技术对多源数据进行融合，并将融合后的数据输入预测模型，生成洪涝灾害预测预警信息。

然而，目前基于集中式云计算的洪涝灾害预测系统仍存在不足之处。（1）系统采用端到云全链路数据处理模式，卫星云图等庞大数据量在多模态数据融合过程中完全依赖云端算力进行特征提取与模型预测，会产生显著的计算时延，难以满足洪涝灾害预警中对分钟级响应的实时性要求。（2）系统日均处理达PB量级的异构数据，导致网络的实际带宽速率显著降低。（3）现有系统架构计算负载集中在云端，导致边缘端的计算资源长期空闲，边缘端实时处理能力也未能得到有效释放。

基于上述问题，本文引入云边协同架构，结合多模态数据融合技术，提出基于云边协同的多模态

洪涝灾害预测架构，在本文架构中，充分利用了云端和边缘端的优势，将数据处理任务在二者之间进行分配，并将局部实时预测与全局融合预测结果利用权重自适应调整算法进行优化，以增强实时处理效能、提升预测预警的精确度。

本文提出的基于云边协同的多模态洪涝灾害预测架构，在边缘层采用基于LSTM的局部实时预测模型，在云端层采用基于Transformer的全局融合预测模型，最后结合权重自适应调整算法提高最终预测结果的精确度。基于云边协同的多模态洪涝灾害预测架构如图2所示。

本文架构引入云边协同架构的设计理念，将系统分为终端层、边缘层和云端层。在边缘层部署具备计算和存储能力的节点，实现局部实时预测。云端层利用强大的计算资源进行全局融合预测。通过在云端和边缘层之间合理分配数据处理任务，有效结合局部实时预测与全局融合预测结果，提高洪涝灾害预测的实时处理能力和预测的精确度。该方法中3层具体功能介绍如下。

（1）终端层：负责存储物联网传感器和卫星采集的数据，并对多模态原始数据进行传输。

（2）边缘层：负责实时处理并初步分析本地数据。每个边缘节点接收来自终端层的本地单模态数

据，使用卷积神经网络（CNN, convolutional neural network）对卫星云图进行数据的预处理^[25]，同时采用基于LSTM的局部实时预测模型独立处理本地传感器数据^[26]，实现低时延、高效的局部预测，最后将结果传输至云端层进行融合，从而减少数据传输负载，提高预测的实时性。

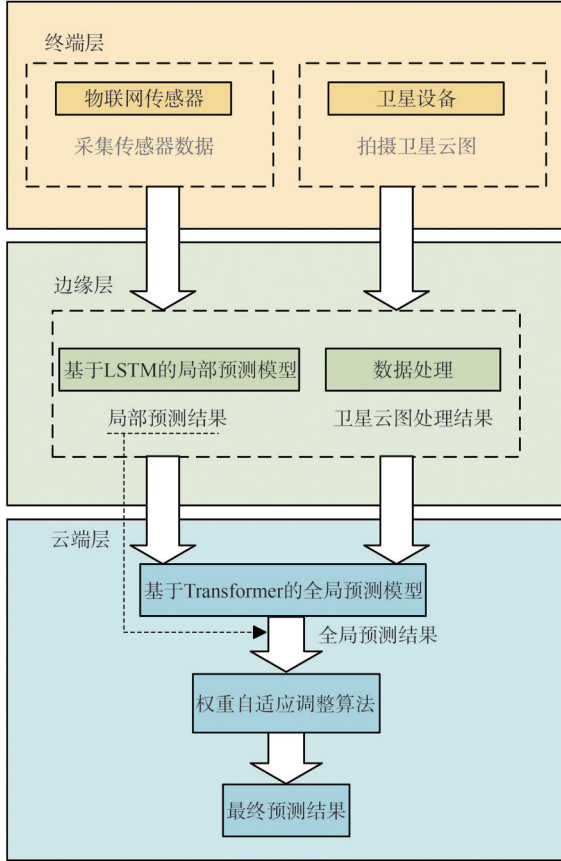


图2 基于云边协同的多模态洪涝灾害预测架构

(3) 云端层：负责深度分析和模型训练。云端接收多个边缘节点上传的结果，采用基于Transformer的全局融合预测模型^[27]进行深度融合，得到全局融合预测结果，提升整体预测精度。同时引入权重自适应调整算法，融合局部预测与全局预测结果，得到最终预测结果^[28]，提高预测结果的精确度和预警决策的可靠性。

3 基于云边协同的多模态洪涝灾害预测架构

3.1 基于LSTM的局部实时预测模型

LSTM是一种特殊的递归神经网络（RNN, recurrent neural network），通过引入门控机制有效缓解了传统RNN在长序列数据处理中的梯度消失和梯度爆炸问题。LSTM的核心结构由遗忘门、输入

门和输出门组成，通过对信息有选择性的记忆与更新有效捕获长时间依赖关系。本文构建的基于LSTM的局部实时预测模型通过多层LSTM捕获时序依赖关系，实现传感器时序数据的初步实时预测，有效降低了云计算的负载，并将边缘层局部预测结果上传，为云端层的全局预测提高局部特征增强的效果。本文模型采用四级联LSTM层进行特征提取，通过逐层抽象，提取从局部天气波动到区域降雨趋势的多尺度特征。模型以物联网传感器采集的时序数据为输入，通过滑动窗口机制构建训练样本

$$\begin{cases} \mathbf{X}^{(i)} = [\mathbf{x}_i, \mathbf{x}_{i+1}, \dots, \mathbf{x}_{i+S-1}] \in \mathbb{R}^S \\ \mathbf{Y}^{(i)} = [\mathbf{x}_{i+S}, \mathbf{x}_{i+S+1}, \dots, \mathbf{x}_{i+S+P-1}] \in \mathbb{R}^P \end{cases} \quad (1)$$

其中， $\mathbf{X}^{(i)}$ 为输入序列， $\mathbf{Y}^{(i)}$ 为目标序列， S 为历史观测窗口长度， P 为预测时间步长。

遗忘门决定从历史记忆单元中保留信息的比例

$$f_i = \sigma(\mathbf{W}_f[\mathbf{h}_{i-1}, \mathbf{x}_i] + \mathbf{b}_f) \quad (2)$$

其中， f_i 为遗忘门输出， \mathbf{W}_f 为权重矩阵， \mathbf{h}_{i-1} 为上一时刻的隐状态， \mathbf{x}_i 为当前输入， \mathbf{b}_f 为偏置项， σ 输出值域为[0,1]，数值越大表示对应维度的记忆保留比例越高。

输入门控制新信息的更新量

$$\begin{cases} i_i = \sigma(\mathbf{W}_i[\mathbf{h}_{i-1}, \mathbf{x}_i] + \mathbf{b}_i) \\ \tilde{\mathbf{C}}_i = \tanh(\mathbf{W}_c[\mathbf{h}_{i-1}, \mathbf{x}_i] + \mathbf{b}_c) \end{cases} \quad (3)$$

其中， i_i 为输入门值， \mathbf{W}_i 和 \mathbf{W}_c 为权重矩阵， \mathbf{b}_i 和 \mathbf{b}_c 为偏置项， $\tilde{\mathbf{C}}_i$ 为候选记忆。

记忆单元更新结合遗忘门与输入门更新长期记忆

$$\mathbf{C}_i = f_i \odot \mathbf{C}_{i-1} + i_i \odot \tilde{\mathbf{C}}_i \quad (4)$$

其中， \mathbf{C}_i 为当前细胞状态， \mathbf{C}_{i-1} 为上一时刻的细胞状态， \odot 表示逐元素相乘，实现记忆的动态衰减与增强。

输出门基于当前记忆生成隐状态输出

$$\begin{cases} o_i = \sigma(\mathbf{W}_o[\mathbf{h}_{i-1}, \mathbf{x}_i] + \mathbf{b}_o) \\ \mathbf{h}_i = o_i \odot \tanh(\mathbf{C}_i) \end{cases} \quad (5)$$

其中， o_i 为输出门输出， \mathbf{W}_o 为权重矩阵， \mathbf{b}_o 为偏置项。

取末层LSTM的最终隐状态 $\mathbf{h}_S^{(L)} \in \mathbb{R}^n$ ，通过全连接层映射至预测空间

$$\hat{\mathbf{Y}} = \mathbf{W}_{fc} \mathbf{h}_S^{(L)} + \mathbf{b}_{fc} \quad (6)$$

其中, \hat{Y} 为预测结果, $\hat{Y} \in \mathbb{R}^P$, $W_{fc} \in \mathbb{R}^{P \times H}$, H 为 LSTM 隐层维度。

模型采用均方误差损失函数 $L(\theta)$ 进行参数优化

$$L(\theta) = \frac{1}{N} \sum_{i=1}^N \|Y^{(i)} - \hat{Y}^{(i)}\| \quad (7)$$

模型参数更新遵循 Adam 优化规则^[29]

$$\theta_{t+1} = \theta_t - \eta \frac{\hat{m}_t}{\sqrt{\hat{v}_t + \delta}} \quad (8)$$

其中, η 为优化器学习率, \hat{m}_t 和 \hat{v}_t 分别为偏差校正后的一阶、二阶矩估计。最后将预测结果 \hat{Y} 以及最终隐状态 h_s 压缩上传至云端进行下一步处理。

3.2 基于 Transformer 的全局融合预测模型

Transformer 是一种基于自注意力机制的深度学习模型。通过自注意力机制, Transformer 能够并行处理输入序列并且可以同时关注序列中的所有位置, 从而捕捉全局依赖关系。Transformer 主要由多头注意力、位置编码、残差连接和层归一化、编码器、解码器组成。本文构建的基于 Transformer 的全局融合预测模型通过多头注意力机制捕捉长距离依赖关系, 实现对多源数据输入进行全局建模, 增强了模型的预测能力和泛化性能, 为洪涝灾害预测预警提供了强有力的支持^[30]。本文模型采用 3 层 Transformer 编码器和解码器结构, 通过多头注意力机制捕捉全局的卫星云图和传感器数据的时空特征, 将多源输入映射到统一的特征空间, 实现数据的时空融合并进行最终预测。模型以边缘层上传的局部预测结果、卫星云图的时空特征作为输入。

使用位置编码注入序列的位置信息, 使得 Transformer 具备处理序列顺序的能力。位置编码通常采用正弦和余弦函数计算

$$PE_{(\text{pos}, 2i)} = \sin\left(\frac{\text{pos}}{10000^{\frac{2i}{d_{\text{model}}}}}\right) \quad (9)$$

$$PE_{(\text{pos}, 2i+1)} = \cos\left(\frac{\text{pos}}{10000^{\frac{2i}{d_{\text{model}}}}}\right) \quad (10)$$

其中, pos 表示位置, i 表示维度索引, d_{model} 是模型维度。

多头自注意力^[31] (MSA, multi-head self-attention) 机制是 Transformer 的核心组件, 用于捕捉序列中不同位置之间的相关性

$$A(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (11)$$

其中, Q 、 K 、 V 分别是查询、键和值向量, d_k 是 key 的维度。

前馈神经网络 (FNN, feedforward neural network) 位于每个注意力层之后, 包含两个线性变换和一个激活函数。FNN 用于捕捉输入序列中的长程依赖关系, 并更好地理解序列中的语义信息。

$$\text{FFN}(x) = \text{ReLU}(xW_1 + b_1)W_2 + b_2 \quad (12)$$

其中, ReLU 为激活函数, W_1 和 W_2 是权重矩阵, b_1 和 b_2 是偏置向量。最后通过全连接层映射到目标维度, 生成全局的预测结果。

3.3 权重自适应调整算法

为了对局部预测与全局预测结果的准确性进行动态评估, 在本文架构中引入权重自适应调整算法。基于误差反比原则自适应调整权重, 以提高最终预测结果的可靠性。权重自适应调整算法确保了误差较小的预测模型在融合过程中占据更高的权重, 从而增强预测的准确性和稳定性。

为了优化局部和全局预测结果的权重, 本文算法基于历史数据计算误差, 依据误差反比原则分配权重, 使用均方误差表示局部预测和全局预测的误差

$$\text{MSE}_{\text{local}} = \frac{1}{N} \sum_{i=1}^N (y_{\text{local}}^{(i)} - y_{\text{true}}^{(i)})^2 \quad (13)$$

$$\text{MSE}_{\text{global}} = \frac{1}{N} \sum_{i=1}^N (y_{\text{global}}^{(i)} - y_{\text{true}}^{(i)})^2 \quad (14)$$

其中, $\text{MSE}_{\text{local}}$ 为局部预测误差, $\text{MSE}_{\text{global}}$ 为全局预测误差, N 为样本数量, y_{true} 为真实值。

为了提高预测结果的可靠性, 本文机制采用误差的倒数进行权重归一化分配

$$\omega_{\text{local}} = \frac{1/\text{MSE}_{\text{local}}}{1/\text{MSE}_{\text{local}} + 1/\text{MSE}_{\text{global}}} \quad (15)$$

其中, ω_{local} 为局部预测权重, ω_{global} 为全局预测权重, $\omega_{\text{local}} + \omega_{\text{global}} = 1$ 。

为了充分利用局部和全局预测的信息, 本文机制选择采用加权融合策略计算最终预测结果

$$y_{\text{final}} = \omega_{\text{local}} \cdot y_{\text{local}} + \omega_{\text{global}} \cdot y_{\text{global}} \quad (16)$$

其中, y_{local} 为局部预测结果, y_{global} 为全局预测结果, y_{final} 为最终预测结果。

权重自适应调整算法伪代码如算法 1 所示。

算法 1: 权重自适应调整算法

输入: 局部预测结果 y_{local} ; 全局预测结果 y_{global} ;
真实值 y_{true} ; 样本数量 N

输出: 最终预测结果 y_{final}

for $i = 1$ to N **do**

$MSE_{local} \leftarrow$ 计算样本 i 的局部误差(式(13))

$MSE_{global} \leftarrow$ 计算样本 i 的全局误差(式(14))

end for

$\omega_{local} \leftarrow$ 计算局部预测权重(式(15))

$\omega_{global} \leftarrow 1 - \omega_{local}$

$y_{final} \leftarrow$ 计算最终预测结果(式(16))

return y_{final}

4 实验结果与分析

本文使用的传感器数据来自 ERA5 数据集中 2020 年 1 月 1 日至 2024 年 12 月 31 日的“再分析”每小时数据。该数据集来自欧洲中期天气预报中心, 包含从 1979 年至今的全球历史气象和气候数据, 如温度、降水量、地表气压等多种关键气象变量。卫星云图数据集来自风云卫星遥感数据服务网络 VISSR 的红外通道 1 数据, 该数据提供了 5 km 的空间分辨率和等距矩形投影。本文选取均方误差 MSE 作为模型评价指标

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (17)$$

其中, y_i 是第 i 个实际值, \hat{y}_i 是第 i 个预测值, n 是样本总数。

常见洪涝灾害预测架构大多为基于集中式云计算, 该架构将原始数据全部传输至云端, 在云端进行数据预处理和洪涝灾害预测。而 LSTM 或 Transformer 常用于作为洪涝灾害预测的训练模型。为了全面评估本文架构与常见洪涝灾害预测架构的性能, 基于时间变化的不同模型 MSE 对比分析如图 3 所示。

基于图 3 结果, 计算各模型 MSE 的平均水平见表 1。在基于时间变化的 MSE 对比中, LSTM 整体表现优于 Transformer。本文所提架构进行 LSTM 与 Transformer 二者的协同, 从整体来看本文架构整体表现较优于对照组模型, 表明本文架构在预测精度上有一定的提高。

在云边协同架构下, 原始数据在边缘端进行处理之后, 大大减少了需要传输的数据量, 网络资源利用更为高效, 从而显著降低了数据传输时延, 明

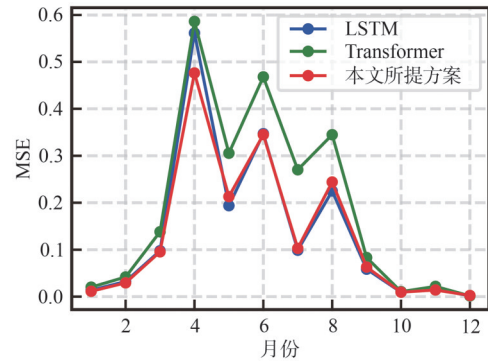


图3 基于时间变化的不同模型MSE对比分析

表1 各模型MSE的平均水平

模型	MSE
本文所提方案	0.134
LSTM	0.138
Transformer	0.191

显提高了数据传输时的实际带宽速率, 同时也充分利用了边缘端的计算资源。本文实验通过构建集中式云计算架构与云边协同架构的对比实验平台, 系统测量了两种架构在边缘至云端数据传输过程中的关键性能指标。实验设置多组不同规模的原始数据样本, 分别采集传输时延、实际带宽速率及边缘计算资源利用率这 3 个指标, 基于数据量变化的传输时延、实际带宽速率和边缘计算资源利用率的对比分析如图 4 所示。基于等量原始数据条件下进行的 30 次重复测量, 得到的两种架构性能对比结果见表 2。云边协同架构呈现显著性能优势: 在传输时延方面较集中式云计算架构平均降低约 53.1%; 实际带宽速率较传统架构平均提升 24.1%; 边缘节点计算资源利用率稳定维持在 92% 左右, 充分验证了云边协同架构在实时性保障、带宽资源优化和计算负载均衡方面的技术先进性。通过将数据处理任务交至边缘节点, 在实际灾害发生时, 本文架构能够在本地快速处理原始数据, 减少云端数据传输的需求, 从而减轻网络带宽的负担, 显著优化灾害发生时的响应时间和预警时效。

本文提出的架构集成了边缘 LSTM 局部实时预测模块、云端 Transformer 全局融合预测模块以及权重自适应调整算法。由于权重自适应调整算法的作用主要依赖于前两个模块所提供的特征表示, 本阶段实验聚焦于前两个核心模块, 进行单独的性能评估。移除云端 Transformer 与权重自适应调整算法, 仅保留 LSTM 模型在边缘层对原始数据的预处




图4 基于数据量变化的传输时延、实际带宽速率和边缘计算资源利用率的对比分析

表2 两种架构性能对比结果

指标	云边协同架构	集中式云计算架构
数据传输时延/ms	18.36	39.21
实际带宽速率/(Mbit·s ⁻¹)	80.16	64.62
边缘计算资源利用率	92%	0

理以及对传感器数据的预测，形成仅边缘 LSTM 模块实验；直接使用云端 Transformer 对传感器数据、卫星云图多模态数据进行预处理和预测，形成仅云端 Transformer 模块实验；边缘层 LSTM 输出作为输入传入云端 Transformer，未进行权重自适应调整，形成边缘-云端模块实验。不同模块基于轮次变化的 MSE 对比分析如图 5 所示。边缘 LSTM 模块具备较好的时间序列建模能力，云端 Transformer 模块在缺乏边缘预测基础时，收敛速度和精度均有限；边缘-云端模块较优于单一模块，协同局部时空依赖和全局跨模态特征，提高预测效果。为提升模型预测性能，本文对关键模型超参数进行敏感性分析，由于边缘层模型的轻量化需求和性能敏感性较高，本阶段超参数分析聚焦于边缘 LSTM 模块，评估窗口长度 S 对时序建模能力的影响。




图5 不同模块基于轮次变化的 MSE 对比分析

为提升模型预测性能，本文对关键模型超参数进行敏感性分析，由于边缘层模型的轻量化需求和性能敏感性较高，本阶段超参数分析聚焦于边缘 LSTM 模块，评估窗口长度 S 对时序建模能力的影响。边缘 LSTM 模块随窗口长度 S 变化的 MSE 对比分析如图 6 所示。较长的窗口有利于提升模型的时序建模能力并降低预测误差，但 S 超过 36 带来额外计算开销的同时精度提升却有限。因此，综合性能与成本， S 选取 24 为较优配置。




图6 边缘 LSTM 模块随窗口长度 S 变化的 MSE 对比分析

5 结束语

本文基于云边协同和多模态数据融合技术，设计了基于云边协同的多模态洪涝灾害预测架构。针对传统基于集中式云计算的洪涝灾害预测架构在数据传输时延、计算负载和实时性等方面的问题，结合云边协同计算的理念，在边缘层提出了基于 LSTM 的局部实时预测模型；在云端层，提出了基于 Transformer 的全局融合预测模型；引入权重自适应融合算法优化融合边缘和云端的预测结果。与传统基于集中式云计算的洪涝灾害预测架构相比，本文研究的基于云边协同的多模态洪涝灾害预测架

构在准确度和实时性方面都有一定的提高，但仍存在进一步优化的空间：（1）本文提出的架构将 LSTM 与 Transformer 二者协同，未来还可以在模型结构设计以及训练策略上进行更精细的优化，以提高模型的综合能力；（2）当前使用的多模态数据类型主要基于传感器数据与卫星云图，未来可以适度引入雷达回波图、无人机航拍影像等更多数据源类型，模型在复杂灾害场景下的泛化能力能够进一步提高。未来的工作将围绕协同策略优化与多源异构数据深度融合两个方向展开，进一步提升灾害预测模型在复杂场景下的泛化能力、实时响应速度和预测精确度，保障人民公共安全。

参考文献：

- [1] Perera D, Seidou O, Agnihotri J, et al. Flood early warning systems: a review of benefits, challenges and prospects[J]. UNU-INWEH, 2019.
- [2] Gimeno L, Sorí R, Vázquez M, et al. Extreme precipitation events[J]. WIREs Water, 2022, 9(6): e1611.
- [3] 李莹, 赵珊珊. 2001—2020年中国洪涝灾害损失与致灾危险性研究[J]. 气候变化研究进展, 2022, 18(2): 154-165.
Li Y, Zhao S S. Floods losses and hazards in China from 2001 to 2020[J]. Climate Change Research, 2022, 18(2): 154-165.
- [4] Moishin M, Deo R C, Prasad R, et al. Designing deep-based learning flood forecast model with ConvLSTM hybrid algorithm[J]. IEEE Access, 2021, 9: 50982-50993.
- [5] Kurze T, Klems M, Bermbach D, et al. Cloud federation[J]. Cloud Computing, 2011: 32-38.
- [6] Dysarz T. Application of Python scripting techniques for control and automation of HEC-RAS simulations[J]. Water, 2018, 10(10): 1382.
- [7] 许迪. SWMM模型综述[J]. 环境科学导刊, 2014, 33(6): 23-26.
Xu D. An overview of storm water management model (SWMM)[J]. Environmental Science Survey, 2014, 33(6): 23-26.
- [8] Hochreiter S, Schmidhuber J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735-1780.
- [9] Dey R, Salem F M. Gate-variants of gated recurrent unit (GRU) neural networks[C]//Proceedings of the 2017 IEEE 60th International Midwest Symposium on Circuits and Systems (MWSCAS). Piscataway: IEEE Press, 2017: 1597-1600.
- [10] Han K, Xiao A, Wu E, et al. Transformer in transformer[J]. Advances in Neural Information Processing Systems, 2021, 34: 15908-15919.
- [11] Ding Y F, Jia M P, Miao Q H, et al. A novel time-frequency Transformer based on self-attention mechanism and its application in fault diagnosis of rolling bearings[J]. Mechanical Systems and Signal Processing, 2022, 168: 108616.
- [12] Chen Y, Liu B, Lin W, et al. Cloud edge collaboration overview[J]. Computer Science, 2021, 48(3): 259-268.
- [13] Tang W T, Wei X X, Li B. Automated model compression by jointly applied pruning and quantization[PP]. 2020.
- [14] Anbarasan M, Muthu B, Sivaparthipan C B, et al. Detection of flood disaster system based on IoT, big data and convolutional deep neural network[J]. Computer Communications, 2020, 150: 150-157.
- [15] Zeyu R, Zhenchao W, Zunwang K, et al. An overview of multi-modal data fusion[J]. Journal of Computer Engineering & Applications, 2021, 57(18).
- [16] Krishnamurthi R, Kumar A, Gopinathan D, et al. An overview of IoT sensor data processing, fusion, and analysis techniques[J]. Sensors, 2020, 20(21): 6076.
- [17] Chuvieco Salinero E. Fundamentals of satellite remote sensing[M]. Boca Raton: CRC Press, 2020.
- [18] Yin X Y, Hu Z Q, Zheng J F, et al. Study on radar echo-filling in an occlusion area by a deep learning algorithm[J]. Remote Sensing, 2021, 13(9): 1779.
- [19] 沈伟豪, 钟燕飞, 王俊珏, 等. 多模态数据的洪涝灾害知识图谱构建与应用[J]. 武汉大学学报(信息科学版), 2023, 48(12): 2009-2018.
Shen W H, Zhong Y F, Wang J J, et al. Construction and application of flood disaster knowledge graph based on multi-modal data[J]. Geomatics and Information Science of Wuhan University, 2023, 48(12): 2009-2018.
- [20] 丁春涛, 曹建农, 杨磊, 等. 边缘计算综述: 应用、现状及挑战[J]. 中兴通讯技术, 2019, 25(3): 1-7.
Ding C T, Cao J N, Yang L, et al. Edge computing: applications, state-of-the-art and challenges[J]. ZTE Technology Journal, 2019, 25(3): 1-7.
- [21] 边缘计算产业联盟, 工业互联网产业联盟. 边缘计算与云计算协同白皮书2.0[R]. 2020.
ECC, AII. Edge computing and cloud computing collaboration white paper 2.0[R]. 2020.
- [22] 何俊, 张彩庆, 李小珍, 等. 面向深度学习的多模态融合技术研究综述[J]. 计算机工程, 2020, 46(5): 1-11.
He J, Zhang C Q, Li X Z, et al. Survey of research on multimodal fusion technology for deep learning[J]. Computer Engineering, 2020, 46(5): 1-11.
- [23] 罗军舟, 金嘉晖, 宋爱波, 等. 云计算: 体系架构与关键技术[J]. 通信学报, 2011, 32(7): 3-21.
Luo J Z, Jin J H, Song A B, et al. Cloud computing: architecture and key technologies[J]. Journal on Communications, 2011, 32(7): 3-21.
- [24] Tang Q, Liang J, Zhu F Q. A comparative review on multi-modal sensors fusion based on deep learning[J]. Signal Processing, 2023, 213: 109165.
- [25] Bai C, Zhao D, Zhang M J, et al. Multimodal information fusion for weather systems and clouds identification from satellite images[J].

IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2022, 15: 7333-7345.

- [26] Segal-Rozenhaimer M, Li A L, Das K, et al. Cloud detection algorithm for multi-modal satellite imagery using convolutional neural networks (CNN)[J]. Remote Sensing of Environment, 2020, 237: 111446.
- [27] Li C Y, Liu X X, Li S T. Transformer meets GAN: cloud-free multispectral image reconstruction via multisensor data fusion in satellite images[J]. IEEE Transactions on Geoscience and Remote Sensing, 2023, 61: 5408513.
- [28] Zhang X B, Jin Q Z, Yu T Z, et al. Multi-modal spatio-temporal meteorological forecasting with deep neural network[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2022, 188: 380-393.
- [29] Kingma D P, Ba J. Adam: a method for stochastic optimization[PP]. arXiv (2017-01-30)[2026-02-01]. arXiv: 1412.6980.
- [30] 高广尚. 深度学习推荐模型中的注意力机制研究综述[J]. 计算机工程与应用, 2022, 58(9): 9-18.
Gao G S. Survey on attention mechanisms in deep learning recommendation models[J]. Computer Engineering and Applications, 2022, 58(9): 9-18.

[作者简介]



陈淑萍(2004-), 女, 福建师范大学计算机与网络空间安全学院在读, 主要研究方向为云边协同、神经网络。



方禾(1991-), 女, 博士, 福建师范大学计算机与网络空间安全学院教授、博士生导师, 主要研究方向为无线网络安全、智能认证、信任管理、异常检测与智能监测、分布式机器学习与多任务优化方法。



石宇歆(2004-), 男, 福建师范大学计算机与网络空间安全学院在读, 主要研究方向为神经网络。



林舟(2004-), 男, 福建师范大学计算机与网络空间安全学院在读, 主要研究方向为边缘计算。



张弛张(2004-), 男, 福建师范大学计算机与网络空间安全学院在读, 主要研究方向为神经网络、多模态融合。