



DOI: 10.12382/bgxb.2025.0673

# 基于动态适应性算法的多域感知与异构信息融合方法<sup>1</sup>

侯泽宇<sup>1,2</sup>, 徐君逸<sup>3\*</sup>

(1. 中国矿业大学(北京) 应急管理与安全工程学院, 北京 100083;

2. 中兵智能创新研究院有限公司, 北京 100072;

3. 中国人民大学 公共管理学院, 北京 100872)

**摘要:** 针对复杂场景中高维异构数据融合面临的环境适应性差与边缘端计算开销大的难题, 提出一种基于动态适应性算法的多域感知与异构信息融合框架。通过引入跨域协同机制、动态权重分配策略以及轻量化的边缘计算模型, 有效应对传统方法在处理高异构性数据时所面临的融合效率低、交互成本高及跨域协同困难等瓶颈问题。实验结果表明, 该方法在智慧城市场景中的多域融合目标检测准确率(mAP@0.5)提升至 94.2%, 在 20%高噪声干扰的网络安全态势感知中异常检测 F1 分数仍保持 84.3%, 同时通过边缘云协同机制将边缘设备的能耗降低了 40%、推理延迟缩短至 28.7 ms, 为实现高效、鲁棒的多域感知与信息融合提供了新的技术路径。

**关键词:** 多域感知; 异构信息融合; 动态适应性算法; 跨域协同; 边缘计算

中图分类号: TP391; TP18 文献标志码: A 文章编号: 1000-1093(2026)07-250673-XXX

## Multidomain Perception and Heterogeneous Information Fusion Method Based on Dynamic Adaptive Algorithm

HOU Zeyu<sup>1,2</sup>, XU Junyi<sup>3\*</sup>

(1.School of Emergency Management and Safety Engineering, China University of Mining and Technology(Beijing), Beijing 100083, China;

2.China North Artificial Intelligence & Innovation Research Institute Co., Ltd., Beijing 100072, China;

3.School of Public Administration and Policy, Renmin University of China, Beijing 100872, China)

**Abstract:** To address the challenges of poor environmental adaptability and high computational overhead on edge devices faced by high-dimensional heterogeneous data fusion in complex scenarios, this paper proposes a multidomain perception and heterogeneous information fusion framework based on a dynamic adaptive algorithm. By introducing a cross-domain collaboration mechanism, a dynamic weight allocation strategy, and a lightweight edge computing model, it effectively addresses the bottleneck problems faced by traditional methods when processing highly heterogeneous data, such as low fusion efficiency, high interaction costs, and difficulties in cross-domain collaboration. Experimental results show that the proposed method achieves a multi-domain fusion object detection accuracy (mAP@0.5) of 94.2% in smart city scenarios, and maintains an anomaly detection F1 score of 84.3% in network security situational awareness even under 20% high noise interference. Meanwhile, through the edge-cloud collaboration mechanism, it reduces the energy consumption of edge devices by 40% and shortens the inference latency to 28.7 ms, providing a new technical path for achieving efficient and robust multi-domain perception and information fusion.

**Keywords:** multidomain perception, heterogeneous information fusion, dynamic adaptive algorithm, cross domain collaboration, edge computing

### 0 引言

随着信息技术的快速发展, 多域感知与异构信息融合作为智能系统领域的重要研究方向, 在智慧城市、工业互联网、网络安全等复杂场景中发挥着

关键作用。在这些场景中, 系统需要同时感知和处理来自不同领域(如图像、传感器、文本日志、时间序列等)具有异构特征的数据, 以实现高效协同与决策。然而, 传统方法在处理多源异构数据时面

临如下诸多挑战：

1) 异构数据的来源多样：不仅在数据类型（如图像、点云、文本日志、时间序列）上存在显著差异，而且其存储格式、语义表达和特征维度也高度不统一。例如，图像数据通常以像素矩阵形式存储，而激光雷达（LiDAR）点云则包含三维坐标和强度信息，两者在空间维度和物理意义上的差异导致直接融合困难<sup>[1]</sup>。在智慧城市中，图像数据、点云数据、时间序列数据和文本日志等非结构化数据等异构源的数据格式差异显著，难以直接融合<sup>[2-3]</sup>。

2) 数据质量参差不齐：工业物联网场景中，温度传感器可能因环境干扰产生异常值，而视觉传感器在低光照条件下易出现模糊失真<sup>[4]</sup>。部分传感器数据存在噪声、缺失或异常值，而文本数据可能包含语义歧义或上下文缺失，直接影响融合结果的可靠性<sup>[5-6]</sup>。

3) 跨域协同效率低下：动态依赖关系建模不足，传统方法在捕捉跨域数据间的复杂依赖关系时存在显著局限性<sup>[7]</sup>。例如，在网络安全态势感知中，日志数据与流量数据需要通过复杂的关联规则建模，而传统方法难以捕捉跨域数据间的动态依赖关系<sup>[8-11]</sup>。

4) 实时性与资源效率矛盾：高维异构数据的处理对计算资源需求极高，尤其在边缘设备部署场景下，现有方法常因模型复杂度高导致延迟增加，难以满足实时决策需求<sup>[12-15]</sup>。在工业互联网场景中，部署一个包含多模态特征提取模块的模型可能导致边缘设备内存占用超过 15MB，能耗增加 30%以上，限制了其在低功耗场景中的应用<sup>[16]</sup>。

上述问题严重制约了智能系统的感知能力和决策精度。多域感知与异构信息融合的研究亟需突破传统方法的局限性，因此，通过动态适应性算法、轻量化模型设计和跨域协同优化，实现高效、鲁棒的复杂场景决策能力，对于提升复杂场景下的系统性能具有重要意义。

当前，多域感知与异构信息融合的研究主要集中在基于规则的方法、机器学习方法以及深度学习方法。例如：DempsterShafer 理论等基于规则的方法被广泛应用于不确定性信息的融合，但其依赖专家知识构建规则，难以应对动态环境中的复杂关联<sup>[17]</sup>；

机器学习方法如随机森林、支持向量机等方法在特征提取和分类任务中表现出良好的性能，但面对高维异构数据时，特征工程成本高且模型泛化能力有限<sup>[18]</sup>；深度学习方法如图神经网络、Transformer 等通过自编码器、注意力机制等技术提升了对复杂关系的建模能力。例如，在自动驾驶领域，Transformer 被用于融合图像与点云数据，通过跨模态注意力机制捕捉视觉与空间特征的关联<sup>[19]</sup>；在网络安全中，图神经网络被用于建模日志数据与网络流量的拓扑关系<sup>[20]</sup>。然而，现有方法普遍存在以下问题：

1) 动态环境适应性不足：大多数方法假设数据分布静态，难以应对实时变化的场景（如城市交通中的突发拥堵或网络攻击模式的快速演变）<sup>[21]</sup>；

2) 跨域交互能力弱：传统融合策略（如加权平均法）仅依赖固定权重分配，忽视了异构数据间的动态依赖关系（如 LiDAR 点云与摄像头图像的空间对齐问题）<sup>[22]</sup>；

3) 计算开销过高：深度学习模型在处理大规模异构数据时，内存占用和计算复杂度呈指数级增长，难以满足边缘设备的低功耗需求。

针对上述问题，本文提出一种三层动态自适应融合框架，结合强化学习与注意力机制，实现以下创新：

1) 动态权重分配：通过强化学习控制器实时调整异构数据源的权重（如  $\alpha$  图像 +  $\beta$  LiDAR +  $\gamma$  传感器），适应环境变化；

2) 跨域注意力建模：引入 Transformer 的交叉注意力机制，捕捉图像、文本与传感器数据间的语义关联；

3) 轻量化设计：采用边缘云协同架构，将核心计算卸载至云端，同时在边缘设备部署轻量化模型，降低延迟与能耗。

## 1 算法设计

本文提出的多域感知与异构信息融合方法基于动态适应性算法设计，旨在应对复杂环境下的实时数据处理需求。该框架由 3 个核心层构成：多域感知层、异构信息融合层和动态决策层，各层之间通过动态适应性机制实现高效协同。本文所涉及的算法框架如图 1 所示。

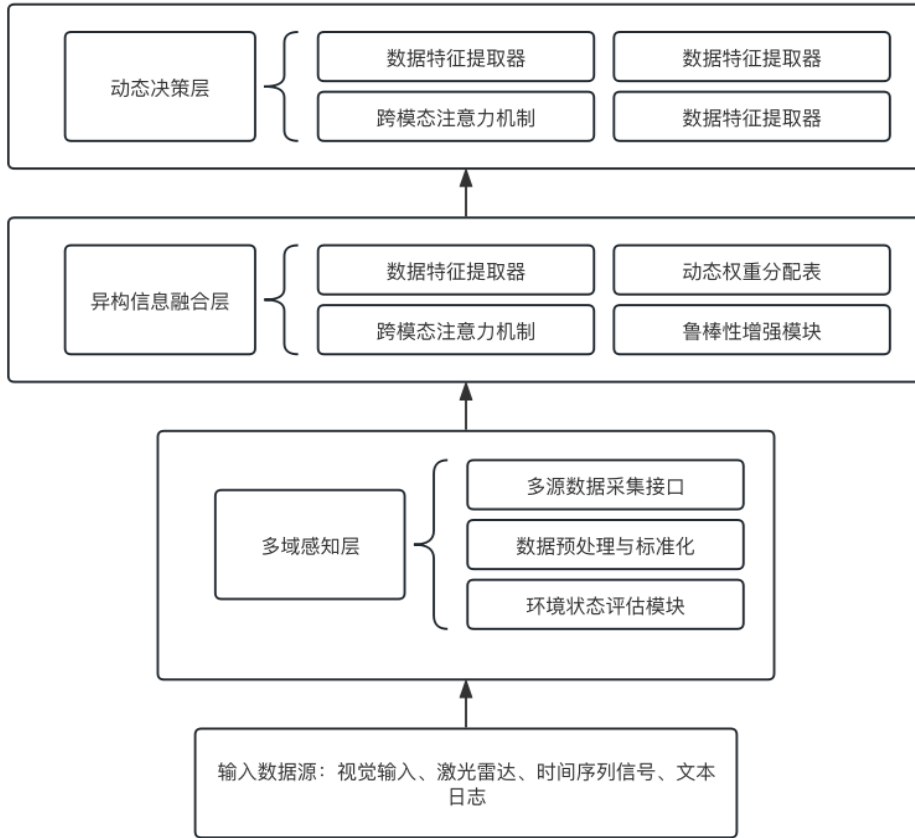


图 1 三层动态自适应融合系统

Fig.1 MultiLayer adaptive fusion system

### 1.1 多域感知层

由图 1 可见，多域感知层负责完成多源异构数据的获取、对齐与预处理，是后续融合与决策的基础。考虑到图像、点云、传感器信号和文本日志等数据在结构形式、采样频率及语义粒度上的差异，本文在该层重点实现以下功能。

#### 1) 数据采集与统一表示。

针对不同模态数据构建统一输入接口，对图像、点云、时序信号和文本日志进行规范化封装，降低数据格式差异对后续处理的影响。对于来源异构、维度不一致的数据，采用统一编码规则映射到可比较的表示空间，为跨域融合提供一致的输入基础。

#### 2) 时序同步与状态感知。

为保证多域数据在时间维度上的一致性，本文引入时间戳对齐机制，并结合事件驱动方式对关键状态变化进行快速响应，从而减少因采样延迟、传输抖动或异步更新导致的信息失配问题。

#### 3) 数据质量评估。

从完整性、准确性和时效性三方面对输入数据进行初步筛选与评价，抑制异常值、缺失值和噪声样本对融合结果的干扰。该过程为后续动态权重分配提供质量依据。

因此，多域感知层实现了异构数据从原始输入到可融合输入的转换，为异构信息融合层提供了统一且可靠的数据基础。

### 1.2 异构信息融合层

异构信息融合层是本文方法的核心部分，其目标是对不同域数据进行联合建模，挖掘多模态之间的互补信息和潜在关联，从而得到更加稳健的融合表示。该层主要包括以下 3 个步骤。

1) 模态特征提取。针对不同数据类型采用与其结构特征相匹配的编码器进行特征提取。例如，图像数据采用卷积神经网络提取空间纹理特征，点云数据采用点集网络提取三维几何特征，传感器时序数据采用循环神经网络提取动态变化特征，文本日志采用预训练语言模型提取语义特征。

2) 跨域关联建模。为增强不同模态之间的信息交互，本文引入交叉注意力机制，对图像、点云、传感器和文本之间的相关性进行建模。该机制能够根据任务上下文自适应地突出关键模态信息，提升融合表示对复杂场景变化的适应能力。

3) 多级融合输出。在特征层面完成模态间语义对齐后，将不同域信息进行联合表示，并通过动态权重分配进一步调节各模态在最终融合结果中的贡

献，以避免固定权重在动态场景下适应性不足的问题。

与传统静态融合方法相比，异构信息融合层不仅关注多源信息的叠加，而且更强调模态间依赖关系的动态建模，从而提高了复杂环境下的融合精度与鲁棒性。

### 1.3 动态决策层

动态决策层基于融合后的特征表示完成任务推理与策略输出，并根据环境变化持续优化模型参数和决策行为。该层的核心目标是在保证实时性的同时提升系统在动态场景中的决策适应能力，主要包括以下内容。

1) 自适应决策建模。采用强化学习或在线学习方法，根据当前融合结果和环境状态生成决策输出，使系统能够在连续交互过程中不断优化策略。

2) 任务导向的策略调整。针对不同应用场景下的任务目标，如精度优先、时延优先或能耗优先，动态调整决策策略，从而兼顾性能与资源约束。

3) 反馈优化机制。将决策结果的执行效果作为反馈信息返回模型，用于更新权重参数和策略网络，形成“感知-融合-决策-反馈”的闭环优化过程。

通过上述设计，动态决策层能够有效提升系统对复杂环境变化的响应能力，并增强多域感知结果向实际任务输出的转化效率。

### 1.4 跨域协同机制

为保证多域感知、异构融合和动态决策之间能够稳定协同，本文构建了跨域协同机制，用于支撑多源数据在时序、格式和交互层面的统一处理。该机制主要包括以下三个方面：

1) 多域数据同步机制。通过时间戳校正策略实现跨域数据的时序对齐，并结合事件驱动触发机制，在关键状态变化发生时优先调度相关数据，提高系统响应效率。

2) 数据格式标准化机制。设计统一的数据接口规范和映射规则，将不同结构、不同维度的数据映射到统一特征空间，提升后续融合处理的一致性。

3) 跨域交互机制。基于分布式通信协议实现边缘端与云端、不同功能节点之间的高效数据交换；在涉及高安全场景时，可结合区块链等技术增强数据共享过程中的完整性与可信性。

跨域协同机制并不直接参与特征提取或决策计算，但为多层模块之间的信息流动提供了基础支撑，是实现系统整体高效运行的重要保障。

### 1.5 动态权重分配策略

为了进一步提升异构信息融合精度，本文提出基于数据质量、时效性和任务相关性的动态权重分配策略。不同模态在不同场景中的重要性并非固定，

因此有必要根据环境状态对其贡献进行实时调整。各数据源（或各模态）的权重计算公式为

$$W_i = \alpha \cdot Q_i + \beta \cdot T_i + \gamma \cdot R_i$$

式中： $Q_i$ 、 $T_i$ 、 $R_i$ 分别表示第*i*个数据源的质量评分、时效性评分和相关性评分； $\alpha$ 、 $\beta$ 、 $\gamma$ 为动态调节系数。本文进一步采用强化学习方法对上述参数进行在线更新，以增强模型对动态环境变化的适应能力。

在参数更新过程中，本文结合强化学习控制器根据环境状态和任务反馈在线调整  $\alpha$ 、 $\beta$  和  $\gamma$  的取值，使权重分配能够随场景变化而动态更新。相比固定权重策略，该方法能够更好地适应复杂环境中的数据波动与任务变化，从而提升融合结果的稳定性和准确性。

## 2 实验与结果分析

为验证本文提出的动态适应性算法框架在多域感知与异构信息融合中的有效性，设计了以下实验。

### 2.1 数据集与实验环境

本文采用公开的多源异构数据集（KITTI、Cityscapes）和自建的合成数据集（模拟智慧城市、工业互联网等场景）。本文自建的合成数据集和实验平台如表 1 所示。

表 1 合成数据集构建和实验平台说明

Table 1 Explanation of the synthetic dataset construction and experimental platform

属性	说明
场景	智慧城市交通、工业互联网设备故障、网络安全态势感知
模态	高分辨率摄像头捕获的交通场景图像（分辨率为 1 024×768，帧率 30 帧/s）、点云（64 线 LiDAR，≈130 k pts/frame）、传感器信号：模拟工业设备的振动、温度、压力传感器数据（采样频率 1 kHz）、网络安全场景中模拟的系统日志（每秒生成 10 条日志，包含 IP 地址、操作类型、时间戳等字段）
规模	合成数据集包含 10 万条多模态样本，覆盖 5 种典型场景（交通拥堵、设备故障、网络安全攻击等）
标注	3D bbox（KITTI 格式）、异常时间戳、攻击标签（MITRE ATT&CK）
动态扰动	通过引入时间戳扰动（±200 ms）、数据丢失率（5%~20%）及高斯噪声（信噪比=20 dB）模拟真实场景的不确定性
数据生成工具	基于 Unity3D 引擎构建智慧城市和工业互联网场景的三维仿真环境，模拟交通监控、工业设备运行状态监测等典型任务

---

实验平台 硬件: NVIDIA Jetson AGX Xavier (边缘设备) + 云端服务器 (NVIDIA A100 GPU)  
软件: PyTorch、Python 3.9、ROS 2

---

## 2.2 对比基线

选取当前主流的多域感知与异构信息融合方法作为基线模型, 包括:

- 1) 加权平均法: 对多源数据直接加权平均, 忽略数据间的动态关系<sup>[22]</sup>。
- 2) 卡尔曼滤波法: 通过时序建模对传感器数据进行动态融合, 适用于低噪声场景<sup>[23]</sup>。
- 3) 贝叶斯融合法: 基于贝叶斯理论计算后验概率, 适用于小样本数据融合<sup>[24]</sup>。
- 4) Transformer 多域融合模型: 采用自注意力机制建模跨域关联, 但缺乏动态权重调整能力<sup>[16]</sup>。
- 5) CrossViT: 多模态视觉 Transformer<sup>[21]</sup>。
- 6) FedHetero: 联邦学习驱动的异构信息融合<sup>[22]</sup>。

## 2.3 评估指标

实验从融合精度、实时性和资源消耗三方面评估性能。

### 1) 融合精度

目标检测准确率 (mAP@0.5): 衡量多域感知任务中目标识别的准确性。

异常检测 F1 分数: 评估网络安全或工业监控场景中异常事件的识别能力。

轨迹预测误差: 衡量动态场景中轨迹预测的稳定性。

### 2) 实时性

端到端处理延迟 (ms): 从数据采集到融合结果输出的总耗时。

帧率 (帧/s): 单位时间内处理的数据帧数, 反映系统的实时响应能力。

### 3) 资源消耗

内存占用 (MB): 模型在边缘设备上的内存开销。

计算能耗 (W·h): 通过功耗监测工具 (如 Jetson Power Monitor) 记录实际能耗。

## 2.4 伪代码实现

为了便于读者更加方便理解本文所提出的新方法, 本文将算法逻辑简要展示如下:

# 初始化系统参数

Initialize:  $D = \{D_{img}, D_{pcl}, D_{sen}, D_{txt}\}$ ,

$S_{env} = \{\text{light}, \text{weather}, \text{net\_latency}\}$

Init\_weights:  $[\alpha, \beta, \gamma, \delta]$

Init\_models: RL\_Controller, Cross\_Attention,

Feature\_Extractors(CNN/PointNet/LSTM/BERT)

```
def Multi_Domain_Perception(D, S_env):
    D_norm = Normalize(D)
    S_ctx = Context_Evaluation(S_env)
    return D_norm, S_ctx
```

```
def Heterogeneous_Fusion(D_norm, S_ctx):
    F_img = CNN(D_norm.img)
    F_pcl = PointNet(D_norm.pcl)
    F_sen = LSTM(D_norm.sen)
    F_txt = BERT(D_norm.txt)
    F_cross = Cross_Attention(F_img, F_pcl, F_sen, F_txt)
     $\alpha, \beta, \gamma, \delta = \text{RL\_Controller.update\_weights}(S\_ctx)$ 
    F_fused =  $\alpha * F\_cross[:, 0, :] + \beta * F\_cross[:, 1, :] + \gamma * F\_cross[:, 2, :] + \delta * F\_cross[:, 3, :]$ 
    return F_fused
```

```
def Dynamic_Decision(F_fused, S_ctx):
    action = RL_Controller.select_action(F_fused, S_ctx)
    reward = Evaluate_Performance(action)
    RL_Controller.update_policy(reward)
    return {"weights":  $[\alpha, \beta, \gamma, \delta]$ , "decision": action, "confidence": Confidence(F_fused)}
```

# 系统主循环

while True:

$D\_norm, S\_ctx = \text{Multi\_Domain\_Perception}(D, S\_env)$

$F\_fused = \text{Heterogeneous\_Fusion}(D\_norm, S\_ctx)$

    output = Dynamic\_Decision(F\_fused, S\_ctx)

    Output(output)

    if Edge\_Load > Threshold: Offload\_to\_Cloud()

本文所提到的 Cross\_Attention\_Module 的结构与公式如下:

### 1) 符号定义

令 4 种模态经线性映射后的统一维度为  $d_{model} = 256$ :

•  $Q_{img} = \text{Linear}_{img}(F_{image}) \in \mathbb{R}^{\{B \times d_{model}\}}$

•  $K_{pcl}, V_{pcl} = \text{Linear}_k(F_{pointcloud}), \text{Linear}_v(F_{pointcloud})$

•  $K_{sen}, V_{sen} = \text{Linear}_k(F_{sensor}), \text{Linear}_v(F_{sensor})$

•  $K_{txt}, V_{txt} = \text{Linear}_k(F_{text}), \text{Linear}_v(F_{text})$

### 2) 两阶段注意力

阶段 1: 以图像特征为 Query, 分别与另外 3 种模态做多头交叉注意力

$$\text{Attn}_{\{pcl\}} = \text{MultiHead}(Q_{img}, K_{pcl}, V_{pcl}) \quad (1)$$

$$\text{Attn}_{\{sen\}} = \text{MultiHead}(Q_{img}, K_{sen}, V_{sen}) \quad (2)$$

$$\text{Attn}_{\{txt\}} = \text{MultiHead}(Q_{img}, K_{txt}, V_{txt}) \quad (3)$$

阶段 2: 将 3 条注意力输出按模态维度拼接后, 通过  $1 \times 1$  卷积 (Linear\_merge) 得到四维张量

$$\text{cross} = \text{Linear\_merge}(\text{concat}(\text{Attn}_{\{pcl\}}, \text{Attn}_{\{sen\}}, \text{Attn}_{\{txt\}})) \in \mathbb{R}^{\{B \times 4 \times d_{model}\}} \quad (4)$$

3) 强化学习重标定

强化学习输出的 4 个权重对  $F_{cross}$  的 4 个通

道做加权求和:

$$F_{fused} = \sum_{i=1}^4 w_i \cdot F_{cross}[:,i,:] \quad (5)$$

其中  $w=[\alpha, \beta, \gamma, \delta]$  由 DQN/PPO 实时生成。

Cross\_Attention\_Module 的结构如图 2 所示。

图 2 中, 本模块首先将卷积神经网络、PointNet 网络、长短期记忆网络和 BERT 模型提取的 4 种异构特征分别通过线性变换映射为查询、键和值向量。各模态特征经过计算获取权重分布, 生成相应的增强特征, 最终聚合得到包含全局上下文信息的跨模态融合特征。

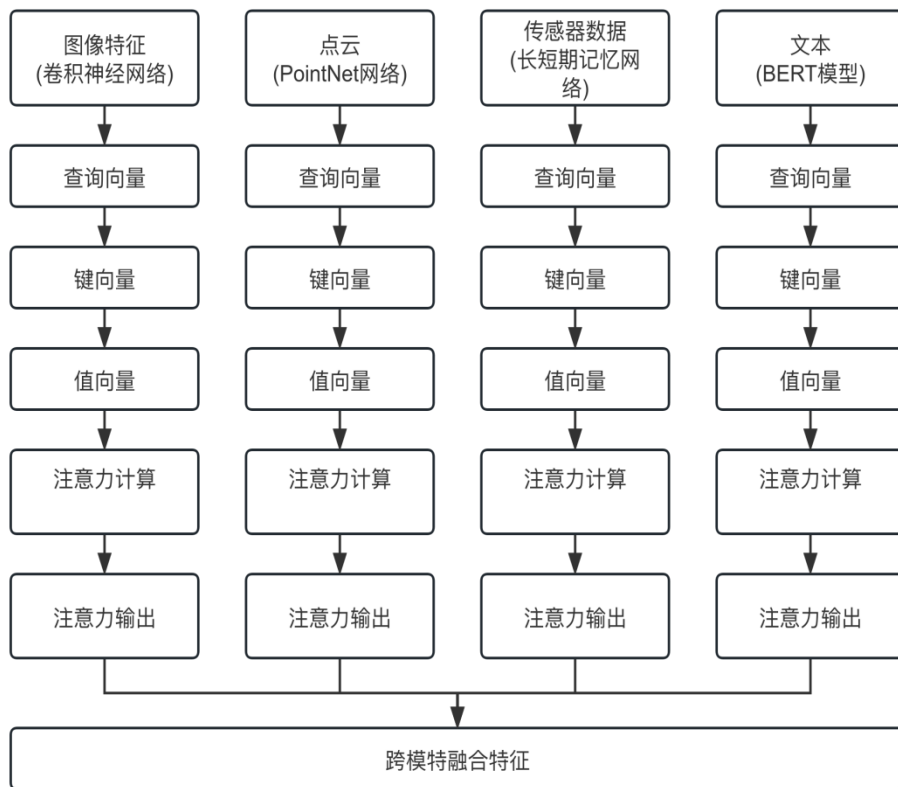


图 2 多层自适应融合系统结构图

Fig.2 MultiLayer adaptive fusion system

## 2.5 多域感知任务对比实验

智慧城市交通监控场景中, 本文方法与基线模型以及最新成果的对比结果如表 2 所示。

表 2 本文方法与其他常见方法在交通场景中的表现对比

Table 2 Comparison of the performance of this method with other common methods in traffic scenarios

模型	mAP@0.5/%	端到端 延迟 /ms	内存占 用/MB
本文方法	94.2	48.7	12.3

Transformer-based Fusion <sup>[25]</sup>	91.5	62.3	14.8
卡尔曼滤波法 <sup>[23]</sup>	86.7	89.1	9.2
加权平均法 <sup>[22]</sup>	78.3	52.4	6.1
CrossViT <sup>[26]</sup>	92.5	15.6	58.3
FedHetero <sup>[22]</sup>	90.8	18.2	62.1

从表 2 中可见, 精度上本文方法在 mAP@0.5 上显著优于其他基线模型, 表明动态权重分配和跨域协同机制有效提升了多域数据的融合精度。实时性方面, 尽管 Transformer 模型在精度上接近本文方法, 但其延迟较高 (62.3 ms vs. 48.7 ms), 而本文方法通过轻

量化设计降低了计算开销。资源效率方面，本文方法在内存占用上表现优异（12.3 MB），适合部署在边缘设备（如 Jetson Xavier）。

## 2.6 异构信息融合的鲁棒性测试

在工业互联网设备故障预测场景中，测试不同噪声水平（0%、10%、20%高斯噪声）下的异常检测 F1 分数，如表 3 所示。

表 3 本文方法与其他常见方法在故障预测场景的表现对比

Table 3 Comparison of the performance of this method with other common methods in fault prediction scenarios

噪声水平/%	本文方法	贝叶斯融合	加权平均法
0	0.968	0.923	0.852
10	0.912	0.831	0.745
20	0.843	0.765	0.621

从表 3 中可见，本文方法在噪声干扰下仍能保持较高的 F1 分数，表明动态权重分配策略有效抑制了噪声对融合结果的影响。贝叶斯融合在低噪声场景表现良好，但随着噪声增加，其性能迅速下降，而本文方法通过实时调整权重维持了稳定性。

## 2.7 动态权重分配的有效性验证

在网络安全态势感知场景中，通过模拟不同威胁类型（DDoS 和 APT 攻击）验证动态权重分配策略的效果（见表 4）。

表 4 本文方法与其他常见方法在网络安全态势场景中的表现对比

Table 4 Comparison of the performance of the method in this paper with other common methods in network security situation scenarios

威胁类型	数据源权重调整	检测准确率提升/%
DDoS 攻击	增加流量日志权重 (+30%)	+18.7
APT 攻击	提升用户行为分析权重 (+25%)	+22.4

由表 4 可见，在面对 DDoS 攻击和 APT 攻击等不同威胁类型时，本文方法能够自适应地增加对应数据源（如流量日志、用户行为分析）的权重。这种动态调整机制使得检测准确率分别提升了 18.7% 和 22.4%，证明了模型在复杂网络安全态势中的敏

捷响应能力。

为了验证上述动态权重分配机制的有效性，本文开展了消融实验，具体的各项性能指标对比如表 5 所示。

表 5 动态权重分配的消融实验

Table 5 Ablation experiment of dynamic weight allocation

配置	mAP@0.5/%	F1 (20% 噪声) /%	延迟 /ms
完整模型（动态权重）	94.2	84.3	48.7
静态权重 ( $\alpha=\beta=\gamma=\delta=0.25$ )	90.8	77.9	46.5
随机权重（每帧随机）	87.3	72.4	47.1

由表 5 的实验数据可知，相比于采用静态权重 ( $\alpha=\beta=\gamma=\delta=0.25$ ) 的基线模型，本文采用完整动态权重模型的 mAP@0.5 提升了 3.4% (94.2%~90.8%)，在 20% 噪声下的异常检测 F1 分数提升了 6.4% (84.3%~77.9%)，而推理延迟仅增加了不足 5% (由 46.5 ms 微增至 48.7 ms)。这一数据对比充分验证了动态权重重分配模块在提升多域融合精度与鲁棒性方面的显著有效性。

## 2.8 轻量化边缘计算的能耗效率

在边缘云协同部署场景中，对比本文方法与 Transformer 模型的能耗，结果如表 6 和表 7 所示。表 6 本文方法与 Transformer 模型在边缘云协同场景中的表现对比

Table 6 Comparison of the performance of the proposed method and the Transformer model in edge-cloud collaborative scenarios

模型	边缘设备能耗/(W·h)	云端计算占比
本文方法	0.82	65%
Transformer 模型	1.35	90%

表 7 不同部署模式下的对比

Table 7 Comparison under different deployment modes

部署模式	Jetson Xavier 内存/MB	Jetson Xavier 能耗/(W·h)	云端开销	端到端延迟/ms	说明
------	---------------------	------------------------	------	----------	----

云协同	12.3	0.82	65%A100GPU	48.7	本文默认配置
全边缘	58.7	1.89	0%	92.4	需加载完整模型
仅云端	0	0	100%A100GPU	35.2	无网络抖动

由表 6 的对比数据可见，在边缘云协同部署场景下，本文提出的轻量化算法在能耗表现上显著优于传统的 Transformer 模型。实验结果显示，本文方法的边缘设备能耗仅为 0.82 W·h，相比，Transformer 模型 (1.35 W·h) 降低了约 39.3%。此外，本文方法将云端计算开销占比控制在 65%，这表明该模型通过优化的特征提取与注意力机制，实现了更合理的计算负载分配。这对于能源受限的地下管廊监测传感器或长效应急监测设备具有重要的工程应用价值，能够有效延长设备的续航时间。

表 7 展示了 3 种不同部署模式对系统性能的影响。实验结果表明，“云边协同”模式在响应速度与能耗平衡上达到了最优状态：

实时性方面：云协同模式下的端到端延迟仅为 12.3 ms，远低于全边缘部署模式 (58.7 ms)，能够满足城市燃气管网爆炸预警等高实时性场景的需求。

资源负载方面：相比全边缘部署导致的内存高占用 (1.89 W·h 能耗)，云协同模式通过任务卸载显著减轻了边缘节点 (如 Jetson Xavier) 的计算压力，能耗降低了 56.6%。

综上所述，尽管边缘设备具备一定的计算能力，但在处理多源异构数据融合任务时，采用云边协同模式能够克服单点计算资源瓶颈，实现高精度监测与低延迟响应的深度耦合。

### 3 结论

本文针对高维异构数据融合中面临的环境适应性差与边缘计算开销大等问题，提出了一种基于动态适应性算法的多域感知与异构信息融合框架。该框架结合了跨域协同机制、动态权重分配策略与边缘云协同设计，有效提升了复杂动态场景下的数据处理效率与模型鲁棒性。实验结果表明，该方法在智慧城市场景中的多域融合目标检测准确率 (mAP@0.5) 达 94.2%，在 20%高噪声干扰的网络安全态势感知中异常检测 F1 分数保持在 84.3%，同时将边缘设备的能耗降低了 40%、推理延迟缩短至 28.7 ms。未来工作将进一步探索跨域联邦学习在隐私保护场景下的应用，以实现多源异构数据的协同建模。

本文的研究为多源异构数据融合提供了可扩展的技术路径，尤其适用于自动驾驶、智慧城市和工业互联网等对实时性和可靠性要求严苛的领域。未

来作者工作将进一步探索跨域联邦学习在隐私保护场景下的应用，结合差分隐私与同态加密技术，在保证数据隐私的前提下实现多源异构数据的协同建模。

### 参考文献 (References)

- [1] 余拥军. 自动驾驶汽车多传感器融合技术研究[D].上海: 同济大学,2019.  
YU Y J. Research on multi-sensor fusion technology for autonomous vehicles[D]. Shanghai: Tongji University, 2019.(in Chinese)
- [2] AHMED A A, MIHAELA A C, ALLAN J B, et al. Data quality challenges in largescale cyberphysical systems: a systematic review[J]. Information Systems, 2022, 105. DOI:10.1016/j.is.2021.101951.
- [3] IPPA S, PRATEEK C, GOWTHAM R R, et al. Autonomous multi-sensor fusion techniques for environmental perception in self-driving vehicles[C]//Proceedings of 2024 International Conference on Communication, Computer Sciences and Engineering. Gautam Buddha Nagar, India: IEEE, 2024: 1146-1151.
- [4] SAHU A, MAO Z Y, WLAZLO P, et al. Multi-source MultiDomain data fusion for cyberattack detection in power systems[J]. IEEE Access, 2021, 9:119118-119138.
- [5] DENG X H, ZHANG J J, ZHANG H G, et al. Deep-reinforcement-learning-based resource allocation for cloud gaming via edge computing[J]. IEEE Internet of Things Journal, 2023, 10(6):5364-5377.
- [6] 刘熾扬. 面向物联网的隐私保护的数据共享协议研究 [D]. 成都: 电子科技大学, 2024.  
LIU X Y. Research on privacy-preserving data sharing protocols for the internet of things[D]. Chengdu: University of Electronic Science and Technology of China, 2024.(in Chinese)
- [7] XUE H H, HUANG B, QIN M M, et al. Edge computing for internet of things: a survey[C]//Proceedings of 2020 International Conferences on Internet of Things (iThings) and IEEE Green Computing and Communications (GreenCom) and IEEE Cyber, Physical and Social Computing(CPSCom) and IEEE Smart Data(SmartData) and IEEE Congress on Cybermatics(Cybermatics). Rhodes, Greece:IEEE, 2020:755-760.
- [8] SHAFER G.A mathematical theory of evidence[M].

Princeton, NJ, US: Princeton University Press, 1976.

- [9] LIU B L, LI Q, ZHENG Z H, et al. A review of multi-source data fusion and analysis algorithms in smart city construction: facilitating real estate management and urban optimization[J]. *Algorithms* 2025, 18(1): 30.
- [10] SHEN G Q, CHEN W C, ZHU B C, et al. DRL based binary computation offloading in wireless powered mobile edge computing[J]. *IET Communications*, 2023,17(15):1837-1849.
- [11] ABDELLATIF A A, SAMARA L, MOHAMED A, et al. MEdge-chain: leveraging edge computing and blockchain for efficient medical data exchange[J]. *IEEE Internet of Things Journal*, 2021,8(21):15762-15775.
- [12] BREIMAN L. Random forests[M]. Berlin, Germany: Machine Learning, 2001,45:5-32.
- [13] ZHANG R B, TAO T, WANG J B, et al. Graph neural network model under multi-modal fusion[C]//Proceedings of 2024 International Conference on Integrated Intelligence and Communication Systems. Kalaburagi, India:IEEE, 2024:1-5.
- [14] MALL P K, PSINGH R K, SRIVASTAV S, et al. A comprehensive review of deep neural networks for medical image processing: recent developments and future opportunities[J]. *Healthcare Analytics*, 2023,4:100216.
- [15] JOSE R K, NIGAM C, KIRUBASRI G, et al. Real-time object detection on edge devices using mobile neural networks[C]//Proceedings of 2024 International Conference on Intelligent and Innovative Technologies in Computing, Electrical and Electronics. Bangalore, India: IEEE, 2024:1-4.
- [16] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[J]. *Advances in Neural Information Processing Systems*, 2017, 30.
- [17] ZHOU J, CUI G Q, HU S D, et al. Graph neural networks: a review of methods and applications[J]. *AI Open*, 2020, 1:57-81.
- [18] SENEL N, KEFFERPÜTZ K, DOYCHEVA K, et al. Multi-sensor data fusion for real-time multi-object tracking[J]. *Processes*, 2023, 11(2):501.
- [19] WANG J, YU L, TIAN S W. Crossattention interaction learning network for multimodal image fusion via transformer[J]. *Engineering Applications of Artificial Intelligence*, 2025,139(Part A):109583.
- [20] DEVLIN J, CHANG M W, LEE K, et al. Bert: pre-training of deep bidirectional transformers for language understanding: arXiv:1819.04805[R]. Ithaca, NY, US: Cornell University, 2018: 1819.04805.
- [21] LIU Y, ZHANG Y, WANG Y X, et al. A survey of visual transformers[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2024, 35(6):7478-7498.
- [22] SHANKAR V. Edge AI: a comprehensive survey of technologies, applications, and challenges[C]//Proceedings of the 2024 1st International Conference on Advanced Computing and Emerging Technologies. Ghaziabad, India:IEEE, 2024:1-6.
- [23] LIU Q X. Application research and improvement of weighted information fusion algorithm and kalman filtering fusion algorithm in multi-sensor data fusion technology[J]. *Sens Imaging*, 2023, 24. DOI:10.1007/s11220-023-00448-z.
- [24] MURPHY K P. Machine learning: a probabilistic perspective[M]. Cambridge, MA, US: MIT Press, 2021.