

基于边缘增强和通道重建的气体泄漏 红外图像分割算法

胡亚蕾, 秦品乐, 柴锐, 曾建潮

(中北大学 计算机科学与技术学院, 山西 太原 030051)

摘要: 针对泄漏气体的红外图像对比度低、边缘模糊等问题, 本文提出了一种基于边缘增强和通道重建的气体泄漏红外图像分割算法, 该算法在 AP-UNet 架构的基础上进行了优化。首先采用空间和通道重建卷积 (SCConv) 作为轻量化策略, 替代标准卷积操作, 降低计算冗余, 提高了检测实时性; 其次设计并集成边缘引导模块 (EGM), 精准捕捉泄漏气体的边缘细节, 确保在复杂环境及低对比度条件下, 仍能精确识别和分割出泄漏气体的微小边界, 提升了检测的准确度与鲁棒性。此外, 模型使用空间卷积来获取视频帧间特征, 学习气体运动规律, 提高了检测精度。在 GasVid 数据集上的实验结果表明, 本文算法的 Dice 系数、召回率和 F1 分数分别达到 77.8%, 94.1% 和 90.8%, 较基线网络分别提升了 1.4 个百分点, 3.4 个百分点和 0.8 个百分点, 推理速度达到 $25.2 \text{ 帧} \cdot \text{s}^{-1}$, 满足实时检测需求。本文方法能实现高精度的泄漏检测, 优于大多数模型的检测精度, 可以更好地应用于复杂环境下的气体泄漏场景。

关键词: 气体泄漏检测; 轻量化; 边缘增强; 帧间特征; 目标分割

中图分类号: TP391.41 **文献标识码:** A **doi:** 10.62756/jnuc.issn.1673-3193.2024.12.0014

引用格式: 胡亚蕾, 秦品乐, 柴锐, 等. 基于边缘增强和通道重建的气体泄漏红外图像分割算法[J]. 中北大学学报(自然科学版), 2025, 46(5): 574-583.

HU Yalei, QIN Pinle, CHAI Rui, et al. Infrared Image Segmentation Algorithm for Gas Leakage Based on Edge Enhancement and Channel Reconstruction[J]. Journal of North University of China (Natural Science Edition), 2025, 46(5): 574-583.

Infrared Image Segmentation Algorithm for Gas Leakage Based on Edge Enhancement and Channel Reconstruction

HU Yalei, QIN Pinle, CHAI Rui, ZENG Jianchao

(School of Computer Science and Technology, North University of China, Taiyuan 030051, China)

Abstract: Aiming at the problems of low contrast and fuzzy edges of infrared images of leaking gas, this paper proposed a segmentation algorithm for infrared images of gas leakage based on edge enhancement and channel reconstruction. It was optimized on the AP-UNet architecture. Firstly, spatial and channel reconstruction convolution (SCConv) was used as a lightweight strategy to replace the standard convolution operation, which reduced the computational redundancy and improved the detection real-time performance. Secondly, an edge guidance module (EGM) was designed and integrated to accurately capture the

收稿日期: 2024-12-25

基金项目: 山西省科技重大专项计划“揭榜挂帅”项目(202101010101018)

作者简介: 胡亚蕾(2000-), 女, 硕士生, 主要从事红外气体泄漏检测的研究。

通信作者: 秦品乐(1978-), 男, 教授, 博士, 主要从事机器视觉、大数据的研究。E-mail: qpl@nuc.edu.cn.

edge details of the leaking gas, which ensured that the tiny boundaries of the leaking gas could be accurately recognized and segmented under complex environments and low contrast conditions, thus improved the accuracy and robustness of the detection. In addition, the model used spatial convolution to obtain the inter-frame features of the video, and learned the gas motion law to improve the detection accuracy. The experimental results on the GasVid dataset show that the Dice coefficient, recall rate, and $F1$ score of the algorithm in this paper reach 77.8%, 94.1%, and 90.8%, respectively, which are 1.4, 3.4, and 0.8 percentage points higher than those of the baseline network. The inference speed reaches 25.2 frames per second, meeting the requirements of real-time detection. The method in this paper can realize high-precision leakage detection, which is better than the detection accuracy of most models, and can be better applied to gas leakage scenarios in complex environments.

Key words: gas leakage detection; lightweight strategy; edge enhancement; inter-frame features; object segmentation

0 引言

随着工业化进程的加速,确保气体处理和传输系统的安全性变得尤为重要,工业气体泄漏往往会严重威胁到人们的生命与财产安全,因而对使用工业气体的众多场景进行泄漏检测是十分必要的^[1]。传统的传感器检测方法依赖传感器的数量和位置,存在效率低、准确性差等问题。相比于传统的非成像气体泄漏检测技术,红外热成像检测技术具有探测距离远、覆盖范围广、动态直观、实时性强等显著优点,是检测气体泄漏的有效手段^[2]。热像仪可以手持、机载或安装在固定位置,然而目前大多依靠人工视检,耗时耗力。随着计算机视觉和图像处理技术的发展,利用红外摄像机捕捉现场图像,通过图像处理技术取代人工视检进行气体泄漏的自动识别与定位成为了一种高效的新方法^[3]。

泄漏气体红外图像信噪比低,具有对比度低、边缘模糊、背景复杂等问题。针对这些问题,研究人员开发了一系列高级图像处理算法,例如混合高斯背景建模、基于深度学习的实例分割方法、各向异性扩散的气体泄漏红外图像增强算法等。这些算法能够有效降噪、增强泄漏特征,并实现泄漏源的自动识别与定位。Nie等^[4]提出了一种结合高斯滤波与自适应直方图的气体泄漏检测红外图像增强算法,该算法利用高斯滤波降噪并保留重要信息,使用自适应直方图分割技术进行局部特性动态调整,强化泄漏细节同时削弱背景干扰,有效提升了泄漏特征的可见性。但这种情况下,与气体外形相似的云团特征也会增强,进而影响对实际气体泄漏的识别。

Zhao等^[5]提出了一种基于引导滤波的图像增强方法,该方法先利用引导滤波提取基础图层,并计算得出细节图层,然后采用可见性恢复算法优化基础图层,同时利用CLAHE算法增强细节图层,最后将这两层加权融合以重建增强后的灰度图像,然而该方法不适用于有复杂背景干扰的场景。Tian等^[6]提出CondInst方法对Mask R-CNN进行改进,该方法根据检测到的实例个数生成动态个数的掩膜,每个掩膜都会把其对应实例的特征包含到滤波器参数中,从而更加关注于该实例,改善分割精度。该方法在背景与目标重叠的地方,可能会出现掩膜形状扭曲或位置偏移的问题,从而导致不能精确地表示目标区域。李泉成等^[7]提出了一种基于光流增强的红外气体泄漏检测算法,使用光流网络预测运动信息并转换为双通道图像,与输入帧灰度图进行通道融合后,送入YOLOv5网络进行检测,最终确定视频中是否存在气体泄漏并获取其位置信息。然而在图像对比度较低时,容易出现漏检情况,且网络参数较多,实时性欠佳。Xie等^[8]提出了一种弱监督蒸馏网络,该方法主要利用复杂的类激活映射生成准确的热图作为伪标签,利用伪标签对提出的专用模型进行训练,生成更准确的热图结果,最后将热图结果与基于背景差分法得到的前景融合,减少了可燃气体检测结果的误报。但是,复杂背景的干扰可能导致类激活映射生成的伪标签不够准确。综上所述,由于气体云团对比度低、边缘模糊、复杂背景的干扰,使得气体区域难以从图像中区分出来,这给气体检测带来了难度。

本文针对基于红外成像的气体泄漏检测任务中图像对比度低、复杂背景干扰、实时性差等问题,对AP-UNet^[9]模型进行了优化:首先,引入空

间和通道重建卷积(Spatial and Channel Reconstruction Convolution, SCConv)^[10]替代传统卷积,实现模型轻量化,通过动态选择卷积核适应输入内容,降低了计算成本,提升了实时处理能力;其次,集成边缘引导模块(Edge Guidance Module, EGM)^[11],强化模型对边缘信息的捕捉,尤其适用于辨识红外图像中泄漏气体的细微边缘,从而在复杂背景下显著提高分割的准确度与鲁棒性,这对提升检测效率与精确性至关重要。此外,加入了空间卷积来获取视频帧间特征,学习气体运动的规律,以提高分割准确率。这三点改进提高了模型在气体泄漏检测应用中的性能。

1 相关工作

AP-UNet是一种专门为多波束水柱图像中的气体羽流自动分割任务设计的改进型U-Net架构。其结构如图1所示,在编码器和解码器之间增加了注意力增强跳跃连接,以增强有意义信息的传输。解码器对特征图进行卷积和上采样后,通过金字塔池化模块(Pyramid Pooling Module, PPM)对多尺度上下文信息进行聚合。该模型相比于U-Net能够更有效抑制复杂的噪声干扰,一定程度上提高了分割精度。下面分别介绍AP-UNet中的编码器、解码器和跳跃连接。

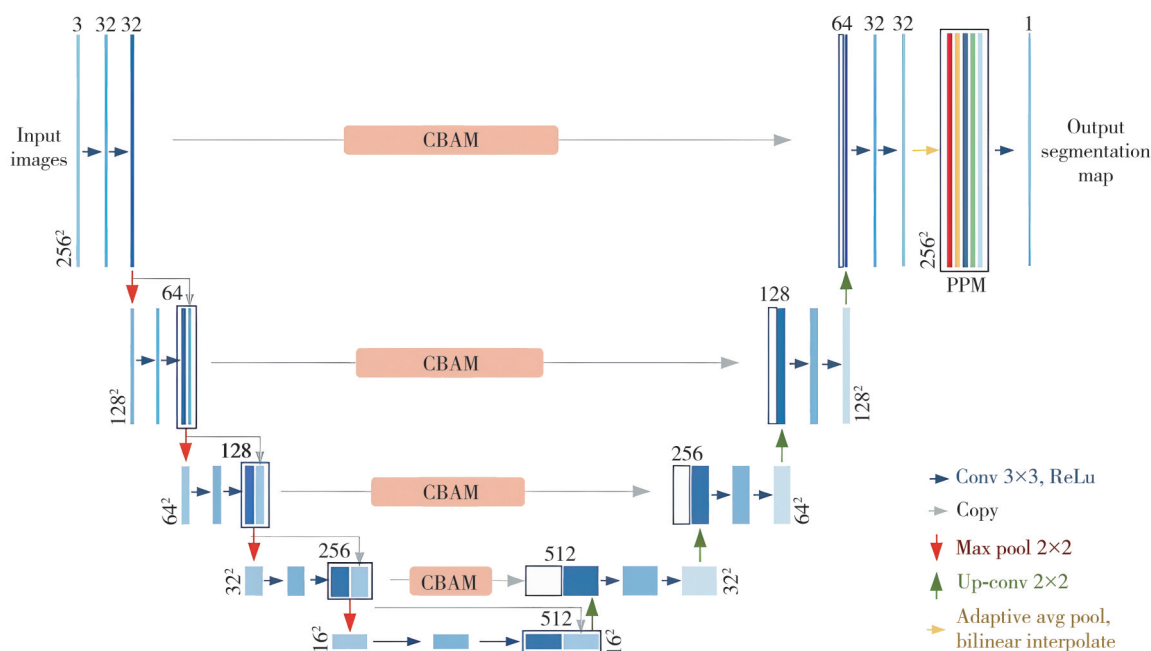


图1 AP-UNet网络模型示意图

Fig. 1 Schematic diagram of AP-UNet network model

1.1 编码器

编码器通过卷积运算提取并描述输入图像的特征。AP-UNet参考U-Net设计了一个具有跳跃结构的特征提取模块。该模块使用 3×3 卷积核。在第一次卷积之后进行批归一化操作,加快了收敛速度,提高了模型的稳定性。然后,使用ReLU函数来激活特征。第二次卷积后,将特征与输入特征和ReLU运算后的输出进行拼接。整个编码器由5层组成,每层通过 2×2 的最大池化操作连接,降低特征图的空间分辨率,扩大感受野,提取图像的高级特征。

1.2 解码器

解码器通过卷积和上采样操作逐步实现特征

层的维数压缩和空间信息恢复。首先,对每一层的高级语义特征进行上采样,降低信道维数;之后,将跳跃连接和上采样的特征连接起来,然后进行 3×3 卷积操作。在解码器的最后一次卷积之后,将特征输入到PPM中进行自适应平均池化和双线性插值,以构建多尺度特征金字塔。得到了4层不同尺度的特征描述,实现了对全局上下文信息的有效利用。每个像素所属类别的概率值可以通过sigmoid函数得到,如式(1)。结果以0.5作为阈值进行二值化。将像素大于0.5的概率标记为1(目标);反之被标记为0(背景)。

$$\hat{y} = \frac{1}{1 + e^{-x}} \quad (1)$$

1.3 跳跃连接

在U-Net架构中,跳跃连接旨在补偿由池化和上采样操作导致的空间信息损失,对目标的精细化分割起着积极作用。AP-U-Net在此基础上得到了进一步增强,通过在跳跃前加入带有残差结构的CBAM(Channel, Spatial Attention Module)模块,加强了跳跃连接在补充语义信息方面的优势。CBAM模块在通道维度上强调显著特征,并在空间维度上聚焦于气体羽流目标的位置,从而抑制噪声干扰。

2 基于边缘增强和通道重建的气体泄漏红外图像分割算法

针对提升红外成像气体泄漏检测模型的效率与性能,本文在原有的AP-U-Net架构上进行了三处关键改进。首先使用SCConv替换了传统卷积

方法,实现了模型的轻量化。SCConv是一种有效减少计算量的策略,允许网络根据不同输入内容动态选择适用的卷积核。这意味着在处理图像时,不是所有卷积核都会被均匀使用,而是根据特征图的内容有选择性地应用,从而减少了不必要的计算负担,提升了计算效率。这对于需要实时处理大量数据的气体泄漏检测尤为重要。其次集成了EGM,目的是为了增强模型对边缘信息的敏感度。该模块能够引导网络更加专注于图像中的边缘特征,即使在复杂的背景和低对比度条件下也能准确检测气体泄漏的细微边界。通过在特征提取过程中加强对边缘信息的利用,提高了分割的精确度和鲁棒性,对于提高检测效率和准确性非常关键。最后,使用空间卷积获取视频帧间特征,学习气体运动规律,进而更有效地分辨真正的气体泄漏与静态背景噪声或其他移动物体。这有助于跟踪并定位泄漏的发展过程,提高检测的准确性。整体网络结构如图2所示。

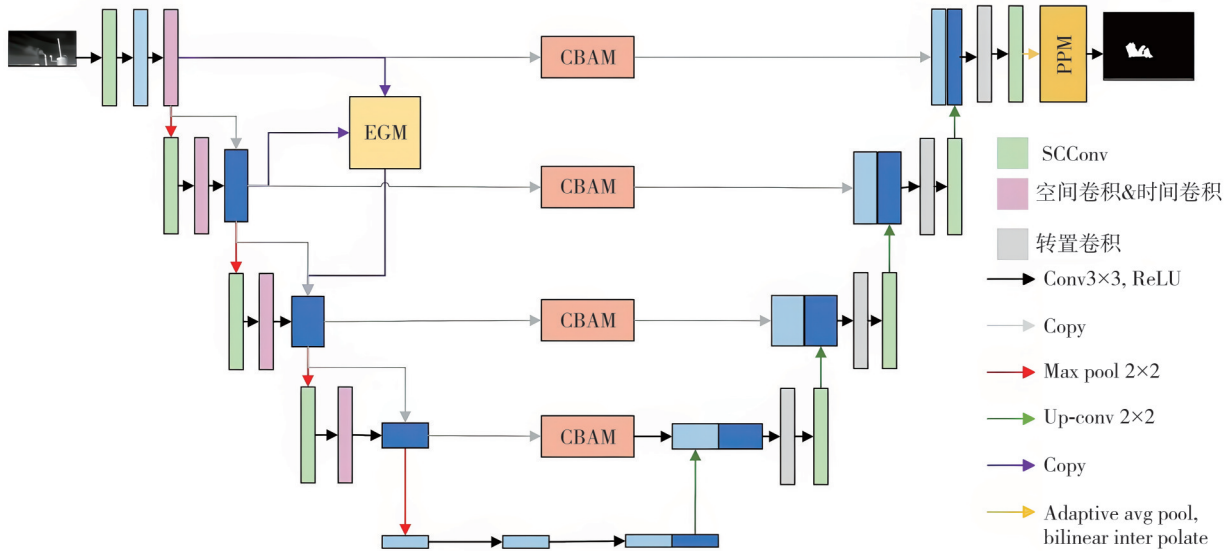


图2 本文网络模型示意图

Fig. 2 Schematic diagram of the proposed network model

2.1 空间和通道重建卷积SCConv

CNN需要庞大的计算资源,部分原因是卷积层提取冗余特征。SCConv是一种创新的卷积神经网络模块,旨在通过减少特征图中的空间和通道冗余来提高模型效率和性能。SCConv的核心设计包括两个关键组件:空间重建单元(SRU)和通道重建单元(CRU),分别针对特征图的空间维度和通道维度进行优化。通过其独特的SRU和CRU,SCConv能够自适应地识别并减少特征图

中的空间和通道冗余信息。这不仅减轻了模型的计算负担,还有助于提升特征表示的效率和质量。在去除冗余的同时,SCConv能够生成更具判别性的特征,并且通过自矫正操作,能够构建长程的空间与通道间相关性,这有助于模型更好地理解 and 区分不同的视觉模式。

2.1.1 空间重建单元(SRU)

SRU通过分离-重建的操作达到优化特征图中空间信息表示的目的,其结构如图3所示。在分离阶段SRU尝试将输入特征图中的信息分为两

部分：一部分是信息丰富、与空间内容紧密相关的特征；另一部分则是信息相对较少、对空间内容贡献不大的特征。这种分离旨在识别哪些特征对于理解图像的空间结构至关重要，哪些可能是冗余或噪声。为了实现分离，SRU利用了组归一化(Group Normalization, GN)层。在深度学习

中，GN将通道分组并对每组进行独立的标准化处理。关键在于，GN层中的缩放因子(scale factors)可以被视为衡量特征图中信息含量的一种方式。较大的缩放因子可能表示该特征图包含较多的有效信息，而较小的缩放因子则可能意味着信息含量较低或冗余。

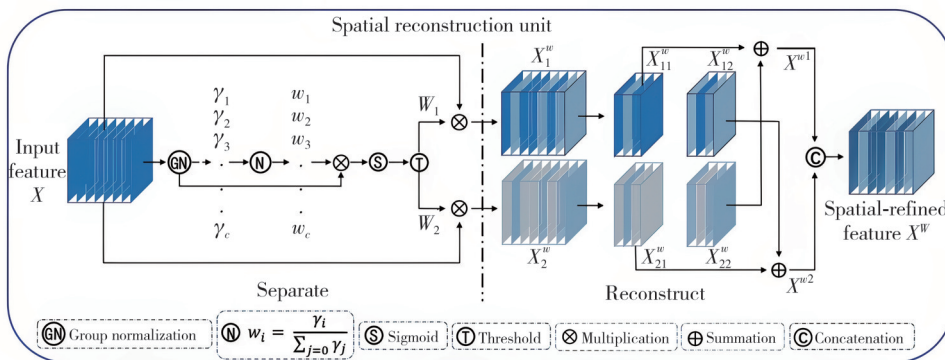


图3 空间结构单元的结构图

Fig. 3 The architecture of spatial reconstruction unit

在重建阶段基于GN层提供的信息评估，SRU会增强那些被判定为信息丰富(即与空间内容紧密相关)的特征图，通过调整或重新组合这些特征，以更好地保留和突出图像的关键空间结构信息。与此同时，对于那些信息含量较低的特征图，SRU会采取措施，如降低其权重或直接剔除，从而减少不必

要的计算和存储开销，提高特征表达的效率。

2.1.2 通道重建单元 (CRU)

CRU采用了拆分-变换-融合策略，这是一种高效处理特征图通道维度的方法，旨在优化通道间的相互作用，减少通道冗余，同时增强特征表达能力，其结构如图4所示。

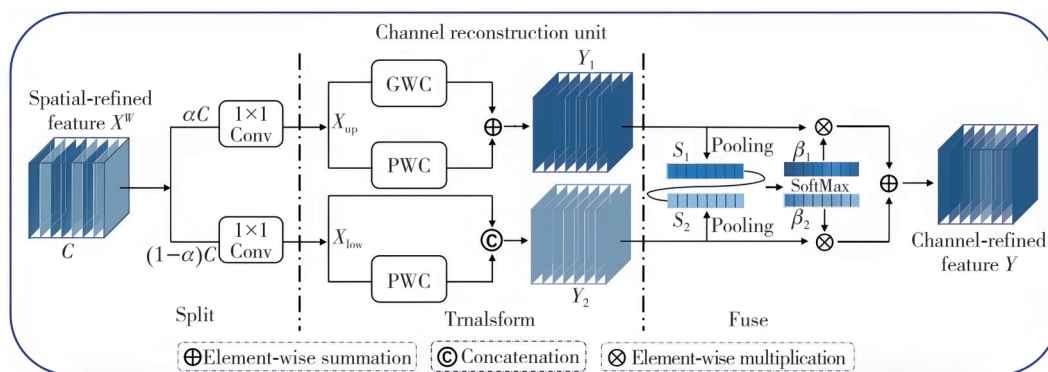


图4 通道重构单元的结构图

Fig. 4 The architecture of channel reconstruction unit

首先，CRU将输入特征图的通道按一定规则(如均匀划分或基于特征重要性)分成多个小组。这样做是为了分别处理这些小组，从而更细致地分析和优化通道间的关系和冗余。对每个通道小组进行独立的变换操作，这些变换可以包括但不限于卷积操作、非线性激活函数(如ReLU)、归一化处理等。变换的目标是重新编码每个通道小组，以增强其独特性，减少冗余，并更好地捕捉不同类型的特征。在某些实践中，还会加入额外的机制促进通道小组间的交互，如交叉注意力机

制，让每个小组能够基于其他小组的信息调整自身的特征表示，进一步优化通道间的信息流动和互补。经过独立变换后的各通道小组被重新组合，通过加权求和或更复杂的融合策略(如注意力融合)整合为新的特征图。融合过程中，每个小组的贡献根据其特征的重要性或与任务的相关性进行动态调整，确保最终输出的特征图既能保持多样性，又能高效地代表输入图像的关键信息。

通过这样的拆分-变换-融合流程，不必要的通道信息被有效抑制，CRU不仅减少了通道间的

冗余信息,还促进了不同特征间的有效协同,不仅有助于提升模型的性能,还在一定程度上减少了计算和内存消耗。

2.2 图像边缘增强模块 (EGM)

针对气体图像边缘轮廓不清晰的特点,加入

增强图像边缘的模块,从而提升分割效果。EGM 是一种专门设计的模块,用于在解码路径中引入边缘信息,以改善分割结果的准确性。其通过两种策略实现:一是提供边缘注意力表示,二是使用边缘检测损失进行早期监督。该模块的结构图如图 5 所示。

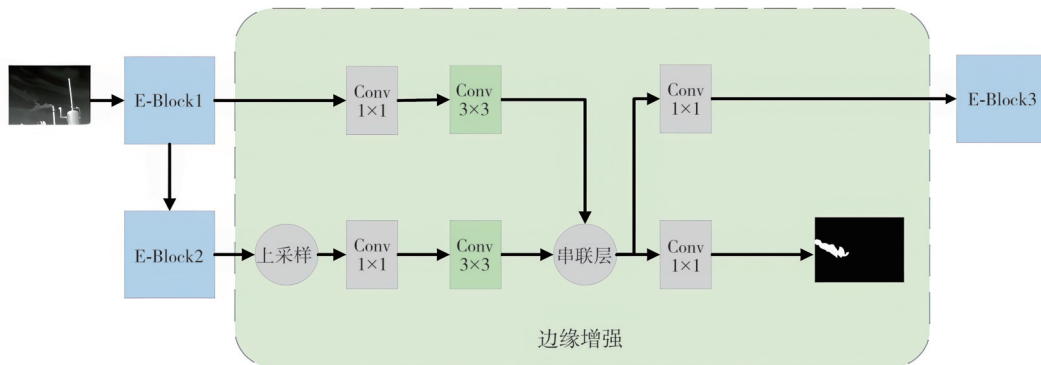


图 5 边缘引导模块结构图

Fig. 5 Structure diagram of edge guidance module

边缘注意力表示部分可以指导分割过程。它通过一系列卷积操作(例如 1×1 卷积、深度可分离卷积等)来提取和融合边缘特征,并将其与其他特征结合,形成边缘引导特征。这些特征随后被传递到解码路径中的后续层,帮助模型更好地识别和分割边缘区域。

除了提供边缘注意力表示外,EGM 还通过另一个 1×1 卷积层预测边缘检测结果,用于早期监督,也就是边缘检测损失监督部分。这意味着模型不仅在最终的分割结果上受到监督,还在边缘检测任务上受到监督,进一步强化了边缘信息的学习。

这种双重作用使得模型能够在高层面的特征提取中更好地利用边缘信息,从而提高分割质量。EGM 中还用了 Lovász-Softmax 损失,其在类不平衡问题上的性能优于交叉熵损失,计算方法如式(2)、式(3)所示。

$$L = \frac{1}{C} \bar{\Delta}_c(m(c)), \quad (2)$$

$$m_i(c) = \begin{cases} 1 - p_i(c), & c = y_i(c), \\ p_i(c), & \text{其他。} \end{cases} \quad (3)$$

2.3 帧间信息

在编码器和解码器的设计上,采纳了 ST-UNET^[12]中结合时间与空间卷积的架构,旨在提升对动态场景的理解能力。输入层采用空间卷积策略,初始生成 8 个激活图,这些图谱共享权重,

均匀应用于连续的 8 个视频帧。通过应用任何梯度下降优化器,网络能够习得视频序列中每一帧的特征表达。随后,将所提取的帧内特征传递至后续的卷积层,这一过程不仅补充了帧间的关联信息,还增强了特征的细节层次,使得模型能够捕捉更为丰富的图像纹理和动态变化。

鉴于气体流动呈现出复杂且高度非线性的时变特性,在网络中增设了一个隐藏层,并采用了诸如 sigmoid 或 ReLU 等非线性激活函数,以此来模拟和处理气体运动的非线性模式。空间与时间卷积的协同作用,进一步强化了帧间信息的融合,从而显著提升了模型对气体流动性预测的能力。这一设计使模型得以精准学习气体扩散的内在规律,进而显著提高了气体掩模预测的准确性,最终达到增强分割精度的效果。

2.4 损失函数

损失函数用于衡量预测结果与真实结果之间的差异,以便指导神经网络中的误差反向传播。二元交叉熵损失(BCEloss)常用于二分类问题中,其数学表达式如式(4)所示。

$$BCE_{\text{loss}} = \frac{1}{N} \sum_{i=1}^N [y \log(\hat{y}) + (1 - y) \log(1 - \hat{y})], \quad (4)$$

式中: \hat{y} 为 sigmoid 函数输出的概率值; N 为像素的数量。

为了解决样本类别不平衡和分类难度不平衡

的问题,采用改进的交叉熵损失作为损失函数,如式(5)所示

$$F = -\alpha(1 - e^{-BCE})^\gamma BCE_{\text{loss}}, \quad (5)$$

式中: α 为类别间的权重参数,设定为1; γ 为聚焦参数,设定为2。

3 实验结果与分析

本文网络模型的实验使用了系统为Ubuntu 18.04, 64位的NVIDIA Station服务器,内存为128 G, 4个Tesla V100显卡,每张显卡的显存为32 G。本文使用Python3.8下的PyTorch框架实现,训练时使用Adam优化器,Cuda11, batch size为64, epoch为300,初始学习率为 10^{-3} 。图6为网络训练损失曲线图,横坐标有epoch表示在模型训练过程中整个数据集被完整遍历的次数,一个epoch是指模型在训练过程中遍历整个训练数据集一次的过程,纵坐标loss为损失值,是衡量模型预测结果与实际结果差异的指标。可以看出,随着训练次数的增加,损失值逐渐减小并趋于稳定,没有过拟合。




图6 本文网络训练损失曲线图

Fig. 6 Training loss curve of the proposed network model

3.1 数据集及评估指标

由于目前未有公开带注释文件的红外甲烷图像数据集,本文所采用的数据集源自GasVid^[13],是一个由31个视频组成用于深度学习训练的大型甲烷视频集。数据集视频由FLIR GF-320红外热像仪拍摄。考虑到实验平台硬件性能瓶颈,对视频进行时域下采样稀疏处理得到2 188张图片作为本次的实验数据集用于训练和测试。本文使用图像标注,工具Labelme根据甲烷气体泄漏区域与背景区域的像素差异性对训练集和测试集图像

中甲烷气体泄漏区域进行像素级精细标注,得到对应图像的真实值(Ground Truth, GT),保存为符合COCO数据集标准格式的JSON文件用于模型训练和测试。数据集图像及真实值标签如图7所示。实验按照4:1的比例将数据集随机分成训练集和测试集,分别用于训练模型和验证最终模型的泛化能力。

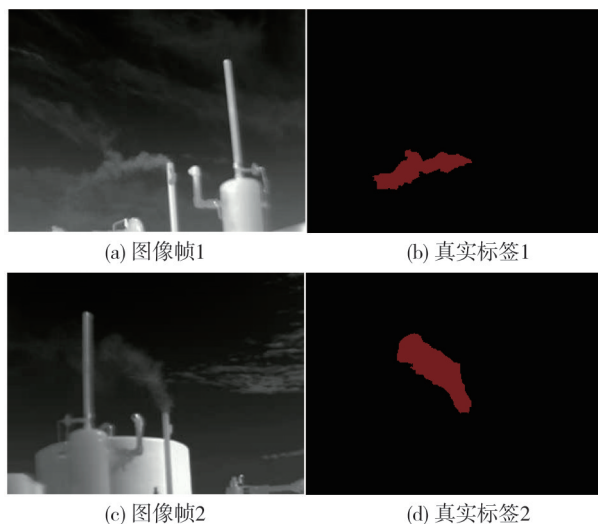


图7 数据集图像及真实值标签

Fig. 7 Dataset image and ground truth

为了测试泄漏气体分割网络的性能,采用Dice系数、准确率Precision、召回率Recall、F1评分和每秒检测红外图像的张数(FPS)等评价指标来评价该方法的性能。

Dice系数(C_D)、准确率(P_{re})、召回率(R_{ec})和F1评分是根据基于像素统计的二进制分类的混淆矩阵计算的。

$$C_D = \frac{2 \times N_{TP}}{2 \times N_{TP} + N_{FP} + N_{FN}}, \quad (6)$$

$$P_{re} = \frac{N_{TP}}{N_{TP} + N_{FP}}, \quad (7)$$

$$R_{ec} = \frac{N_{TP}}{N_{TP} + N_{FN}}, \quad (8)$$

$$F1 = \frac{2 \times P_{re} \times R_{ec}}{P_{re} + R_{ec}}, \quad (9)$$

式中: N_{TP} (真阳性)表示样本中的目标被正确预测的像素数; N_{FP} (假阳性)表示样本中的背景被预测为目标的像素数; N_{FN} (假阴性)表示样本中的目标被预测为背景的像素数。

3.2 对比试验

为了测试模型的性能,将本文网络与多种经典语义分割网络以及用于烟雾分割的网络进行比

较，包括 Att-UNet^[14]、DeepLabv3+^[15]、SegNeXt-T^[16]和 AP-UNet^[9]，在红外图形数据集上共进行了3组对比实验。

图 8 为不同网络在红外数据集上的对比实验，其中第一列为输入的测试图像，第二列为人工标注的标签，后几列为各个模型的实验结果。其中，Att-UNet的分割结果与真实值相差较大，部分背景被误分割为气体边缘颜色较淡的区域，由于 Att-UNet 在下采样的过程中丢失了部分特征，上采样时只融合到了特征图的1/8的信息，导致细节丢失严重，因此未能正确分割出气体的边

缘，存在误分割的情况；DeepLabv3+ 和 SegNeXt-T 模型并未对浅层的信息进行处理，直接融合了浅层信息，引入了背景噪声，会将靠近气体边缘且灰度相近的背景分割为气体，导致误分割；AP-UNet对多层的特征加以融合，并且通过注意力机制增强特征选择，使得分割效果明显优于 SegNeXt-T 和 Att-UNet，但是边缘连贯性不足，在气体的微小细节处仍然有轮廓错分的情况。实验结果表明与其他的方法相比，本文所提方法分割出的气体位置更加准确，边缘微小细节更加清晰，误分割和漏分割的情况也更少。




图 8 红外图像数据集对比实验结果

Fig. 8 Results of experiments comparing infrared image datasets

表 1 给出了红外数据集上不同模型的性能对比，通过一系列关键评价指标的分析，凸显了本文提出模型的卓越性能。具体而言，本文模型在 Dice 系数、召回率和 F1 分数三个重要指标上取得了最佳成绩，分别高达 77.8%，94.1% 和 90.8%，直观地反映了模型在目标分割任务上的高度准确性和一致性。本文模型的 Dice 系数较 AP-UNet 提升了 1.4 个百分点，表明分割区域与真实标注的重叠度更高，但提升幅度较小，可能受限于红外图像固有的低对比度特性。本文模型召回率达到 94.1%，显著高于其他模型(AP-UNet 为 90.7%)，说明对气体边缘的漏检率大幅降低，得益于 EGM 模块的边界增强设计。然而，在准确

率这一指标上，本文模型(92.5%)略低于 AP-UNet(93.5%)，表明在减少误检(背景误判为气体)方面仍有改进空间，可能因 EGM 对微弱边缘的敏感性导致部分噪声被误激活。

表 1 不同模型的检测指标对比

Tab. 1 Comparison on detection index of different models

模型	$c_D/\%$	$P_{re}/\%$	$R_{ec}/\%$	$F1/\%$	推理速度/ (帧·s ⁻¹)
Att-UNet	71.3	89.4	86.2	88.3	22.6
DeepLabv3+	73.8	90.3	90.8	89.9	16.7
SegNeXt-T	74.5	92.8	89.0	86.4	28.5
AP-UNet	76.4	93.5	90.7	90.0	24.8
本文模型	77.8	92.5	94.1	90.8	25.2

尽管本文模型与 AP-UNet 相比有微小差距，但考虑到红外数据集的复杂性和挑战性，结合 F1

分数,这细微的差异并不影响整体性能的领先优势。本文模型的帧率虽然小于SegNeXt-T,略微高于AP-UNet,但仍拥有 $25.2 \text{ 帧} \cdot \text{s}^{-1}$ 的检测速度,满足实际工程应用的实时性要求。就整体分割效果而言,本文提出的模型明显优于其他模型。

3.3 消融实验

为了分析各个模块对网络的影响,在AP-UNet上依次使用SCConv卷积替换常规二维卷积,增加EGM提升边缘分割性能,并且使用相同的超参数对这些网络进行训练与测试。

消融实验的性能测试结果如表2所示,实验结果表明,虽然SCConv结构对模型的整体性能影响相对较小,没有显著改变关键性能指标如Dice指数和准确率,但是加快了模型的训练速度,这对于大规模数据集的处理和实时应用具有重要意义。通过引入EGM模块这一改进带来了明显的性能提升,Dice指数从初始状态跃升至76.9%,相较于原模型提升了3.6个百分点,同时准确率也得到了显著的提升。这表明EGM模块在提升边缘分割性能方面发挥了关键作用,使得模型在处理复杂图像边缘时更为准确,整体分割效果更佳。

表2 消融实验指标对比

Tab. 2 Comparison of ablation parameters

模型	$c_D/\%$	$P_{re}/\%$	$R_{ec}/\%$	$F1/\%$	推理速度/ (帧·s ⁻¹)
SCConv+UNet	74.3	90.1	89.8	83.2	26.3
EGM+UNet	76.9	91.4	94.2	90.3	21.4
本文模型	77.8	92.5	94.1	90.8	25.2

4 结 论

本文针对基于红外成像的气体泄漏检测容易出现误分割和漏分割的现状,对现有的AP-UNet架构实施了三项创新性改进,显著提升了模型的检测性能。首先引入SCConv,以此替代传统的卷积操作,成功实现了模型轻量化的目标。其次,集成了一种创新的EGM,专门设计用于增强模型对红外图像中泄漏气体边缘信息的敏感度。本文方法还引入了空间卷积来捕获视频帧间的特征,深入理解气体的运动方式,使得模型能在复杂背景或低对比度环境下,更加精确地识别并定位泄漏点。从实验数据可以看出,本文提出的优化模型在气体泄漏检测任务中展现出了卓越的能力,不仅提高了检测速度,还在复杂场景下保持了较

高的检测精度,一定程度上解决了实时性与准确性之间的平衡难题。由于没有开放数据集,本文自行标注的数据集量较少,未来工作可增加数据量,以进一步验证网络的分割性能。本文算法模型仍存在进一步优化的空间,由于算法复杂度有一定提升,所以实时性并未显著提高,且分割精度也仍有待提升。后续研究可以探索更先进的注意力机制,以持续推动气体泄漏检测技术的进步,保障工业生产的安全与高效。

参考文献:

- [1] SHIRLEY C P, RAJA J I J, EVANGELIN SONIA S V, et al. Recognition and monitoring of gas leakage using infrared imaging technique with machine learning [J]. Multimedia Tools and Applications, 2024, 83 (12): 35413-35426.
- [2] ZHAO Q, NIE X, LUO D, et al. An effective method for gas-leak area detection and gas identification with mid-infrared image [J]. Photonics, 2022, 9 (12): 992.
- [3] 左金辉,徐文斌,周世杰,等.基于低对比度红外图像时空信息的气体泄漏检测[J].光学精密工程,2024,32(8):1186-1198.
ZUO Jinhui, XU Wenbin, ZHOU Shijie, et al. Gas leakage detection based on spatiotemporal information of low contrast infrared images [J]. Optics and Precision Engineering, 2024, 32 (8): 1186-1198. (in Chinese)
- [4] NIE X, ZHANG H, LIU H, et al. An infrared image enhancement algorithm for gas leak detecting based on gaussian filtering and adaptive histogram segmentation [C]//2021 IEEE International Conference on Real-time Computing and Robotics (RCAR), 2021: 359-363.
- [5] ZHAO Q, LUO D, WANG J, et al. An image enhancement method for gas leak detection based on infrared imaging [C]//2023 IEEE International Conference on Real-time Computing and Robotics (RCAR), 2023: 245-250.
- [6] TIAN Z, SHEN C, CHEN H. Conditional convolutions for instance segmentation [DB/OL]. (2020-07-26) [2024-12-25]. <https://arxiv.org/abs/2003.05664>.
- [7] 李泉成,曹江涛,姬晓飞.光流增强的红外成像气体泄漏检测方法[J].电子测量与仪器学报,2023,37(3):50-56.
LI Quancheng, CAO Jiangtao, JI Xiaofei. Infrared imaging gas leak detection method with optical flow

- enhancement[J]. *Journal of Electronic Measurement and Instrumentation*, 2023, 37(3): 50-56. (in Chinese)
- [8] XIE L, ZHANG C, YANG C, et al. An infrared gas detection algorithm based on weak supervision [C]// *International Conference on Image, Signal Processing, and Pattern Recognition (ISPP 2024)*, 2024: 1011-1019.
- [9] YANG F, WANG F, LUAN Z, et al. Automatic segmentation of gas plumes from multibeam water column images using a U-shape network[J]. *Journal of Oceanology and Limnology*, 2023, 41(5): 1753-1764.
- [10] LI J, WEN Y, HE L. SCConv: Spatial and channel reconstruction convolution for feature redundancy [C]// *2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2023: 6153-6162.
- [11] ZHANG Z, FU H, DAI H, et al. Et-net: A generic edge-attention guidance network for medical image segmentation [C]// *Medical Image Computing and Computer Assisted Intervention-MICCAI*, 2019: 442-450.
- [12] BHATT R, UZUNBAS M G, HOANG T, et al. Segmentation of low-level temporal plume patterns from IR video [C]// *2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (DVPRW)*, 2019: 847-854.
- [13] WANG J, TCHAPMI L P, RAVIKUMAR A P, et al. Machine vision for natural gas methane emissions detection using an infrared camera [J]. *Applied Energy*, 2020, 257: 113998.
- [14] OKTAY O, SCHLEMPER J, LE FOLGOC L, et al. Attention U-Net: Learning where to look for the pancreas [DB/OL]. (2018-05-20) [2024-12-25]. <https://arxiv.org/abs/1804.03999v3>.
- [15] CHEN L C, ZHU Y, PAPANDREOU G, et al. Encoder-decoder with atrous separable convolution for semantic image segmentation [C]// *Computer Vision-ECCV 2018*. Cham: Springer International Publishing, 2018: 833-851.
- [16] GUO M H, LU C Z, HOU Q, et al. Segnext: Rethinking convolutional attention design for semantic segmentation [DB/OL]. (2022-09-18) [2024-12-25]. <https://arxiv.org/abs/2209.08575>.