

文章编号: 1007-2780(2026)03-0415-15

基于羽流形态约束与特征解耦的 弱甲烷羽流高光谱遥感分割方法

赵翼^{1,2}, 李海巍^{1*}, 张小荣¹, 宋丽瑶³, 杨伟华¹, 郭琦^{1,2}, 李晗之^{1,2}

(1. 中国科学院西安光学精密机械研究所, 陕西西安 710119;

2. 中国科学院大学, 北京 100049;

3. 西安工业大学人工智能与数据科学研究院, 陕西西安 710021)

摘要: 甲烷(CH₄)是仅次于二氧化碳的第二大人为温室气体,快速精准地识别甲烷排放源对气候变化监测具有重要意义。随着对气候变化问题关注的不断加深,高光谱遥感技术在甲烷羽流监测中的应用逐渐成为研究热点,现有研究多聚焦于大规模甲烷排放事件,而对密集微弱甲烷羽流关注不足。微弱甲烷羽流在高光谱影像中往往难以呈现完整的羽流形态且边界特征模糊,更易受到大气、地表、仪器响应等多重因素干扰。针对微弱甲烷羽流边界模糊易受背景噪声干扰等问题,本文提出了一种深度学习模型——LightMethaneNet(LM-Net)。LM-Net对现有用于甲烷羽流检测的深度学习模型进行改进,引入了用于增强羽流空间特征的动态高斯模块(DGMM)与用于细化特征抑制背景噪声的混合注意力机制,解决了现有的基于深度学习的分割方法在处理此类气体羽流时难以兼顾精度与效率的问题。提出的方法在公开数据集 STARCOP 上进行训练和评估,其中微弱羽流检出的准确率为 53%,召回率为 82.7%。与经典的分割模型相比,LM-Net 在 mIoU、F1 分数、精度方面的最大改进分别达到了 32.34%、38.01%、34.57%。该方法有效提高了微弱甲烷羽流的检测准确率,能够更好地识别微弱羽流及其疑似排放区域,为复杂背景下的高精度甲烷羽流遥感检测提供了可行的技术解决方案。

关键词: 甲烷;深度学习;微弱羽流检测;混合注意力机制;动态高斯模块

中图分类号: TP391 **文献标识码:** A **doi:** 10.37188/CJLCD.2026-0017 **CSTR:** 32172.14.CJLCD.2026-0017

收稿日期: 2026-01-28; **修订日期:** 2026-02-19.

基金项目: 陕西省教育厅一般专项科研计划(No.24JK0481);陕西省自然科学基金基础研究计划(No.2025JC-YBQN-366, No.2025JC-YBMS-256)

Supported by General Special Scientific Research Program of Shaanxi Provincial Department of Education (No.24JK0481); Basic Natural Science Research Program of Shaanxi Province (No.2025JC-YBQN-366, No.2025JC-YBMS-256)

*通信联系人, E-mail: lihaiwei@opt.ac.cn

High-spectral remote sensing segmentation method for weak methane plumes based on plume morphology constraints and feature decoupling

ZHAO Yi^{1,2}, LI Haiwei^{1*}, ZHANG Xiaorong¹, SONG Liyao³,
YANG Weihua¹, GUO Qi^{1,2}, LI Hanzhi^{1,2}

(1. *Xi'an Institute of Optics and Precision Mechanics, Chinese Academy of Sciences, Xi'an 710119, China;*

2. *University of Chinese Academy of Sciences, Beijing 100049, China;*

3. *Institute of Artificial Intelligence and Data Science, Xi'an Technological University, Xi'an 710021, China)*

Abstract: Methane (CH_4) is the second largest anthropogenic greenhouse gas after carbon dioxide. Rapid and accurate identification of methane emission sources is of great significance for climate change monitoring. With the deepening concern over climate change issues, the application of hyperspectral remote sensing technology in methane plume monitoring has gradually become a research hotspot. However, existing studies mostly focus on large-scale methane emission events, while paying insufficient attention to dense and weak methane plumes. Weak methane plumes often fail to present complete plume shapes and have blurred boundary features in hyperspectral images, and are more susceptible to interference from multiple factors such as the atmosphere, surface, and instrument response. To address the problems of blurred boundaries and susceptibility to background noise in weak methane plumes, this paper proposes a deep learning model called LightMethaneNet (LM-Net). LM-Net improves the existing deep learning models for methane plume detection by introducing a dynamic Gaussian module (DGMM) to enhance the spatial features of the plume and a hybrid attention mechanism to refine features and suppressing background noise. This solves the problem that existing deep learning-based segmentation methods have difficulty balancing accuracy and efficiency when dealing with such gas plumes. The proposed method was trained and evaluated on the public dataset STARCOP, achieving 53% accuracy and 82.7% recall rate for the detection of weak plumes. Compared with classic segmentation models, the maximum improvements of LM-Net in mIoU, F1 score, and precision were 32.34%, 38.01%, and 34.57%, respectively. This method effectively improves the detection accuracy of weak methane plumes, enabling better identification of weak plumes and their suspected emission areas, and provides a feasible technical solution for high-precision methane plume remote sensing detection under complex backgrounds.

Key words: methane; deep learning; weak plume detection; hybrid attention mechanism; dynamic Gaussian mixture model

1 引 言

作为一种强大的温室气体,甲烷自工业革命以来导致了约 25% 的全球变暖^[1-2],其大气浓度还在迅速上升^[3]。约 60% 的甲烷排放来自农业、废弃物处理、化石燃料生产、燃烧以及工业排放等人为来源^[4]。

在过去 7 年中,遥感技术已被广泛应用于甲烷排放源的探测与监测^[2,5]。相关研究主要依托多种遥感平台开展,包括 AVIRIS-NG、EMIT、PRISMA 以及部分商业遥感系统。根据所采用遥感平台和技术路线的不同,现有甲烷羽流检测方法大体可分为基于物理机理的反演方法和基于数据驱动的学习方法。其中基于物理的反演

方法通过辐射传输模型分析高光谱数据(使用PRISMA、EnMAP获取)在甲烷特征吸收波段(如2100~2500 nm)^[6]的光谱畸变,反演甲烷的柱浓度或增强信号。这种方法能够对低浓度甲烷实现较为精确的定量监测^[7]。然而,这类高光谱仪器空间覆盖范围有限,数据获取成本较高,制约了其在大范围、常态化监测中的应用^[8-10]。同时还可利用“哨兵-2以及“陆地卫星8号”和“陆地卫星9号”等获取甲烷多光谱图像以反演甲烷的柱浓度或增强信号^[11]。然而,卫星数据的光谱分辨率和空间分辨率都较低,导致其对甲烷的敏感度较低^[10,12],只能成功检测并量化大规模羽流,无法检测在复杂地表环境中的微弱的甲烷羽流^[2,10,12]。基于数据驱动的学习方法利用传感器获取包含甲烷信息的高光谱图像,将这些数据通过匹配滤波器就可以将甲烷羽流和背景与干扰物区分开,找到综合甲烷增强值IME实现甲烷羽流分割^[13-14]。

通过匹配滤波器识别甲烷羽流的方法通常需要人工来完成。随着深度学习在图像检测与分割领域的广泛应用,人们开始尝试使用FCN、CNN、YOLO、CH4Net等网络自动识别和分割甲烷羽流。但这些模型大部分没有专门针对甲烷羽流检测进行优化,难以同时实现鲁棒性、计算效率以及对弱甲烷羽流的可靠监测。在已有研究中,Vaughan等于2024年提出CH4Net^[15]深度分割模型,在Sentinel-2多光谱影像上取得了较高的羽流检出率,但其研究重点主要集中于强排放场景,对弱甲烷羽流的检测性能尚缺乏系统评估。Guanter等^[16]于2025年提出MethaneAIR数据处理链,用于MethaneAIR机载高光谱数据的甲烷点源检测与定量。通过物理反演和匹配滤波算法,可以检测出排放量大于100 kg/h甲烷羽流,但是方法主要依靠人工手动标注,无法自动实现甲烷羽流识别。Ahsan等^[17]于2025年提出的AttMetNet以及Tran等^[18]于2025年提出的用于弱小羽流分割(Small Plume Segmentation)的方法都尝试通过引入注意力机制和光谱增强提高小尺度羽流的检测能力,但总体仍以中等或较明显羽流为主要研究对象,弱羽流条件下的检测性能仍有待进一步研究。

现有方法多以中高排放羽流为优化目标,尚缺乏针对弱羽流特性的专门建模与系统研究。同

时弱甲烷羽流又具有排放强度低、空间连续性弱,且在强吸收波段2100~2500 nm仍易受复杂地表背景干扰等特点。针对上述问题,本文提出了LM-Net,一种面向弱甲烷羽流分割的轻量级深度学习模型。该方法基于高光谱数据,融合形态感知的空间先验与多层注意力机制,实现对弱小甲烷羽流的稳定识别。本工作的主要贡献有两点:

(1)针对弱甲烷羽流空间分布破碎、扩散结构难以由通用卷积稳定建模的问题,引入了动态高斯混合模块(DGMM),通过可学习的羽流形态约束增强羽流的空间连续性和结构一致性。

(2)在高光谱甲烷遥感中,微弱羽流信号通常淹没在复杂的背景响应之中,其主要干扰来源包括大气散射与吸收导致的背景辐射干扰、地表材质反射率差异引起的光谱混叠,以及成像仪器的噪声与响应不一致性。这些因素在光谱维度与空间维度上相互耦合,使得弱甲烷羽流呈现出低对比度、边界模糊且形态不稳定的特征。本研究开发了一种混合注意力模块,联合光谱特性、空间特性和边界特征,以有效抑制背景干扰并突出微弱甲烷响应^[19-20]。

2 基于深度学习的甲烷羽流检测

2.1 数据集构成

本实验在公开的数据集STARCOPI^[21]上进行,该数据集由AVIRIS-NG传感器于2019年在美国二叠纪盆地采集获得,提供了高光谱甲烷排放观测数据^[22]。AVIRIS-NG的光谱覆盖范围为380~2510 nm,光谱分辨率约为5 nm,空间分辨率为3~8 m,使其能够在空间与光谱维度上较精细地刻画甲烷羽流特征。与侧重于大尺度甲烷浓度反演的EMIT数据集以及以点源排放量估计为目标的GHGSat数据集相比,STARCOPI提供了高质量的像素级羽流标注,更适合用于甲烷羽流的精细分割任务。该数据集将甲烷羽流按排放率划分为强羽流与弱羽流,为不同排放强度条件下的检测性能评估提供了基础。

STARCOPI同时提供L1B级校准辐射数据和基于稀疏正则化匹配滤波生成的MAG1C甲烷增强产品^[21]。尽管MAG1C能够提升羽流与背景之间的对比度,但地表反射率不均匀区域仍存在背景伪影和误报,这对微弱羽流的精确分割构

成了额外挑战^[21,23]。为保证标注的可靠性,自动检测到的羽流结果由专家标注员进行了人工修正。在STAR COP数据集中,弱羽流被定义为排放率低于1 000 kg/h^[21]的甲烷羽流,其样本数量(1 439)显著多于强羽流样本(273),呈现出明显的类别不平衡特征。这种不平衡往往导致现有分割模型对弱羽流的召回率下降^[24]。针对上述挑战,本研究设计了结合混合注意力机制与动态高斯混合模块的LM-Net,以提升弱羽流的空间结构表征能力并抑制背景干扰^[25]。

2.2 模型结构

LM-Net采用轻量级编码器-解码器架构作为基础骨干,其中编码器选用EfficientNet-B0,解码器基于UNet++^[22]结构构建。EfficientNet-B0通过复合缩放策略在参数规模与特征表达能力之间取得平衡,提取多层次语义特征并保持较低的计算复杂度和计算复杂度,适用于对效率和稳定性均有要求的遥感分割任务。解码器采用UNet++的密集跳跃连接结构^[26],对来自不同编码层级的特征进行逐级融合与重用。相比于标准U-Net,UNet++通过嵌套式解码路径显式缩小编码特征与解码特征之间的语义差距,从而有助于恢复弱目标的空响,并提升对细长、边界模糊结构的建模能力。

为了增强羽流特有的结构,引入了两个任务

导向型模块:动态高斯混合模块(DGMM)和混合注意力(Hybrid Attention, H-Attention)模块。DGMM被插入到中间编码器阶段(第2~4阶段)的跳跃连接中。在这些阶段,DGMM对输入特征进行形态感知调制,增强甲烷羽流的形状表达。在最终的解码器阶段(紧接在分割头之前),应用了混合注意力模块,通过结合通道级、空间级和边缘感知的注意力来抑制易误检区域噪声。

该网络使用复合损失函数进行端到端训练。如图1所示,整个流程包括分层特征提取、通过DGMM进行形态感知增强、多尺度解码以及使用H-Attention模块进行最终的边界敏感细化,从而实现了对微弱且破碎的甲烷羽流的准确分割。

2.2.1 综合损失函数

为了应对甲烷羽流在复杂背景条件下易受到高反射区域干扰的问题,本研究采用由二元交叉熵损失(Binary Cross-Entropy, BCE)、Dice损失和焦点损失(Focal Loss)组成的综合损失函数。总体损失函数定义为:

$$L_{total} = \lambda_{BCE} \cdot L_{BCE} + \lambda_{dice} \cdot L_{Dice} + \lambda_{focal} \cdot L_{Focal} \quad (1)$$

权重系数根据验证集性能设定为 $\lambda_{BCE} = 0.4$ 、 $\lambda_{Dice} = 0.4$ 和 $\lambda_{Focal} = 0.2$ 。其中,BCE损失用于约束像素级分类概率;Dice损失关注预测区域与真实区域的重叠度,有效缓解前景像素稀疏问题;Focal损失则通过降低易分类样本的权重,引导

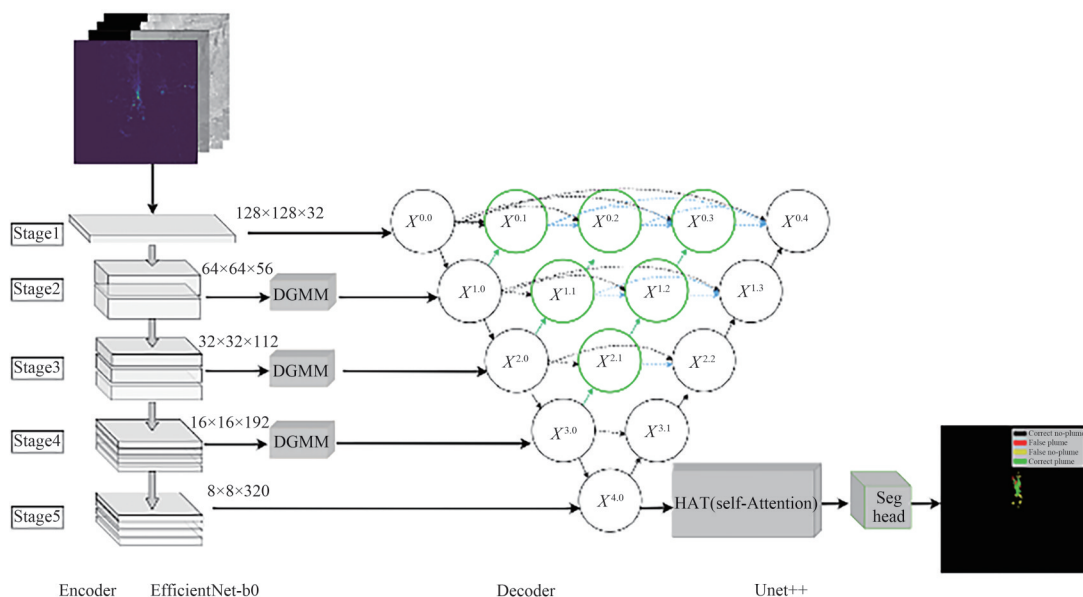


图1 LM-Net总体架构

Fig. 1 Overall architecture of LM-Net

模型关注弱甲烷羽流等难分类区域。三者的联合优化能够在保证整体分割稳定性的同时,提高对弱小羽流区域的检测性能。

2.2.2 混合注意力机制

为提升微弱且边界模糊甲烷羽流的分割精

度,本文在最终解码器阶段引入混合注意力机制。H-Attention模块通过协调光谱特征、空间特征及边缘感知,对高分辨率解码特征进行细化,从而在复杂背景条件下提升边界定位能力,其结构如图2所示。

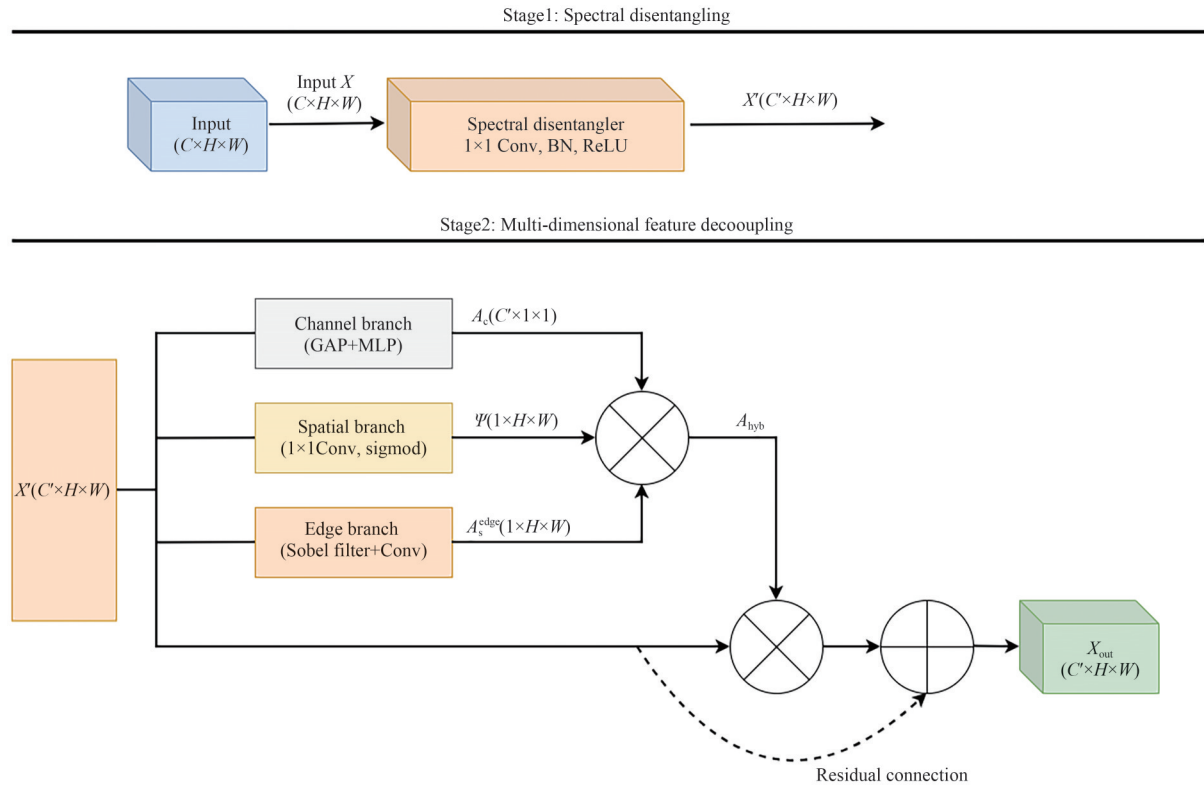


图2 混合注意力模块的详细结构

Fig. 2 Detailed structure of the Hybrid Attention module

假设解码器的输出为 $X \in \mathbb{R}^{B \times C \times H \times W}$ 。其中 B 为批次大小, C 为通道数, H 和 W 分别为高和宽。通过一个 1×1 卷积对通道进行线性重组, 得到解耦特征 X' :

$$X' = \text{ReLU}(\text{BN}(\text{Conv}_{1 \times 1}(X))). \quad (2)$$

通过 X' 分别获得通道注意力 A_c 、空间门控 Ψ 以及边缘感知空间注意力 A_s^{edge} 。输入特征图 X' 经过全局平均池化(Global Average Pooling, GAP), 得到包含每个通道的空间全局特征 z_c :

$$z_c = \text{GAP}(X') \in \mathbb{R}^{B \times C}. \quad (3)$$

通过两层全连接层(分别为 W_1 和 W_2) 和 Sigmoid 激活函数 σ 对通道描述符 z_c 进行线性变换获得通道注意力缩放因子 s_c :

$$s_c = \sigma(W_2 \text{ReLU}(W_1 z_c)). \quad (4)$$

将每个通道的注意力缩放因子 s_c 通过空间

广播(Broadcasting)应用到整个空间, 从而生成通道注意力图 A_c , 用于增强与甲烷吸收相关的光谱通道:

$$A_c = s_c \text{ broadcast spatially}. \quad (5)$$

Ψ 由 1×1 卷积和 Sigmoid 激活生成, 用于定位潜在羽流区域:

$$\Psi = \sigma(\text{BN}(\text{Conv}_{1 \times 1}(X'))). \quad (6)$$

将 X' 通过平均池化获得灰度图 I , 再使用 Sobel 滤波器提取边缘特征 E 。接着, 将边缘特征与每个像素的最大值和平均值投影拼接, 最后通过卷积层生成空间注意力 A_s^{edge} , 用于增强薄弱或破碎的边界响应:

$$A_s^{\text{edge}} = \text{Conv}([\text{Avg}(X'), \text{Max}(X'), E]). \quad (7)$$

3种注意力线索通过逐元素乘法融合形成混合注意力:

$$A_{\text{hyb}} = \Psi \odot \text{broadcast}(A_c) \odot A_s^{\text{edge}}. \quad (8)$$

最终输出通过残差方式进行特征细化:

$$X_{\text{out}} = X' + X' \odot A_{\text{hyb}}. \quad (9)$$

残差融合避免了对微弱但真实羽流响应的过度抑制,使注意力机制仅作为特征调制器。与仅基于通道或粗略空间注意力的模块(如 SE、CBAM)相比,H-Attention 整合了边缘感知、空间特征和光谱特征,通过显式引入边缘感知线索,在保持较低计算开销的同时,有效提升了弱羽流的边界保真度。

表 1 注意力模块的比较

Tab. 1 Comparison of the attention module

Module	Channel attention	Spatial attention	Edge awareness	Residual fusion
SE	✓	×	×	×
CBAM	✓	✓ (coarse)	×	×
H-Attention	✓	✓ (coarse)	✓ (edge)	✓

2.2.3 DGMM 用于羽流形态约束

为增强甲烷羽流中固有的平滑且各向异性扩散结构,本文提出动态高斯混合模块(Dynamic Gaussian Mixture Module, DGMM),并将其作为形态约束引入网络。DGMM 通过内容自适应的方式生成通道相关的高斯核,用于强调羽流状的扩散特征,同时抑制由地形边缘和传感器噪声引起的无关响应。该模块被嵌入至第 2~第 4 个编码器阶段的跳跃连接中,在解码特征融合之前对中层特征进行形态约束,其结构如图 3 所示。




图 3 DGMM 原理及形态调节过程

Fig. 3 Principle of DGMM and the process of form regulation

设输入特征为 $X \in \mathbb{R}^{B \times C \times H \times W}$, DGMM 为每个通道预测一组高斯混合参数 $\Theta = \{(\mu_x^{(i)}, \mu_y^{(i)}, \sigma^{(i)})\}_{i=1}^{N_g}$, 其中 $N_g = 3$ 。这些参数由轻量级参数生成网络预测,该网络由全局平均池化、通道压缩的 1×1 卷积和非线性激活构成,以保证计算效率。

对于第 i 个高斯分量,其在空间位置 $(u|v)$ 处的响应定义为:

$$G_i(u, v) = \exp\left(-\frac{(u - \mu_x^{(i)})^2 + (v - \mu_y^{(i)})^2}{2(\sigma^{(i)})^2}\right). \quad (10)$$

所有分量相加并归一化后形成动态卷积核 K ,并以深度可分离方式作用于输入特征,得到形态调制特征 X' 。为避免过度平滑并保留局部高频细节,DGMM 并行计算一条基线特征流 X_{base} ,并通过通道自适应的门控机制进行融合,得到 DGMM 的最终输出特征图 Y :

$$Y = \alpha \odot X_{\text{base}} + (1 - \alpha) \odot X', \quad (11)$$

其中,融合权重 α 由 1×1 卷积和 Sigmoid 函数预测。

通过在编码阶段显式引入扩散形态约束,DGMM 有效增强了羽流的空间连续性,并减少了由背景结构导致的碎片化预测。与多尺度或可变形卷积模块(例如 ASPP、可变形卷积)相比,DGMM 在卷积过程中显式引入了符合甲烷羽流扩散特性的形态约束,从而缩小了参数搜索空间并加快了收敛速度。

表 2 DGMM 与其他卷积模块的比较

Tab. 2 Comparison of DGMM with other convolutional modules

Module	Morphology-aware prior	Channel-adaptive	Spatially adaptive
Generic Dynamic Conv	×	✓	✓
Multi-Scale/Deformable Conv (ASPP, Deformable Conv)	×	✓	✓
DGMM	✓	✓	✓

2.3 网络训练

所有模型均使用 PyTorch 实现,并使用 Adam 优化器进行训练,初始学习率为 $1e-4$,每 30 个周期就降低 0.5 倍。复合损失函数(BCE+Dice+Focal)被用于所有实验,超参数在验证集上进行了经验性调整。训练在一台 NVIDIA 4090 GPU 上进行,批处理大小为 8,同时根据验证集的 F1 分数应用了提前停止机制,以防止过拟合。主要的评估指标包括 mIoU、精确率、召回率和 F1 分数^[27-29],该训练策略对于评估在弱且破碎羽流场景下的模型性能具有重要作用。

为了确保公平的基准测试,只要源代码可用,

所有竞争模型都在相同的实验条件下进行训练。对于缺乏完整训练脚本的预训练模型,本研究使用官方权重,并在不进行额外微调的情况下报告测试集结果。这种方法确保任何LM-Net的性能提升都可以归因于所提出的DGM和H-Attention模块,而不是数据处理、超参数设置或训练协议的差异。

2.4 评估指标

为了定量评估模型的分割性能,采用平均交并比(mIoU)、精确率(Precision)、召回率(Recall)和F1分数作为评价指标。mIoU衡量预测结果与真实掩码在像素层面的整体重叠程度,是语义分割任务中最常用的综合指标。精确率和召回率分别反映模型对羽流像素的误报控制能力和漏检情况,而F1分数综合考虑二者的平衡性。上述指标共同用于评估模型在强、弱甲烷羽流及复杂背景条件下的分割性能。

3 实验结果与分析

3.1 与不同网络结构的对比

为了评估LM-Net的有效性,本研究与多个分割模型进行了全面比较,包括在遥感中广泛应用的经典建筑架构(U-Net、UNet++)、以全局注

意力著称的具有代表性的轻量级Transformer模型SegFormer^[30]以及最近专门用于甲烷检测的模型CH4Net。所有模型均在相同的条件下在STARCOPT测试集上进行训练和评估,以确保公平的基准测试。

如表3所示,LM-Net表现卓越,达到了最高的mIoU(56.70%),在弱羽流检测方面表现出色(F1分数:64.73%,精确度:53.16%),相比专门设计用于甲烷分割的2024年模型CH4Net有稳步提升(mIoU增加了21.46%,弱羽流F1分数增加了22.23%)。这表明本研究的基于物理形态约束的指导方法,即使应用于针对特定领域的驱动模型上也能带来明显改进。此外,LM-Net也优于通用的Transformer架构SegFormer,突显了嵌入物理形态约束和边缘感知细化,相较于纯粹的数据驱动、全局注意力机制,在这一低对比度、形态受限任务中的优势。这些成果归功于本研究的核心创新:DGMM模块能够学习符合物理规律且连贯的羽流结构,而H-attention模块则能细化边界并抑制背景中的错误预测。相比之下,通用架构(U-Net、UNet++、DeepLabV3+、SegFormer)会对微弱的羽流产生碎片化或过度平滑的预测。

表3 基线模型之间的定量比较

Tab. 3 Quantitative comparison among baseline models

Model	Backbone	mIoU/%	F1-Score/%	Precision/%
U-Net	ResNet-50	27.68	30.59	18.59
U-Net	EfficientNet-B0	34.20	39.47	25.67
UNet++	ResNet-101	28.01	31.54	19.05
UNet++	EfficientNet-B0	34.24	37.29	23.64
SegFormer	B0	24.36	26.72	26.72
Ch4net	/	35.24	42.50	36.50
LM-Net	EfficientNet-B0	56.70	64.73	53.16

注:粗体数字表示最优值

图4~图7展示了不同模型在4个评估维度下的定性对比结果。其中,图4侧重于微小羽流的完整性与抗噪能力,图5考察小羽流情况下的抗背景噪声能力,图6针对无羽流区域的预测准确性,图7则展示了标准条件下羽流的整体完整性。各部分前3行依次为UNet(搭配EfficientNet-B0)、

UNet++(搭配EfficientNet-B0)及CH4Net,最后一行展示了本文提出的LM-Net。在误差分析列中,绿色代表正确检出,黄色代表因背景伪影导致的误报,红色代表漏检区域。

实验结果表明,LM-Net在4个维度上均展现出显著优于传统卷积网络与通用架构的稳健性

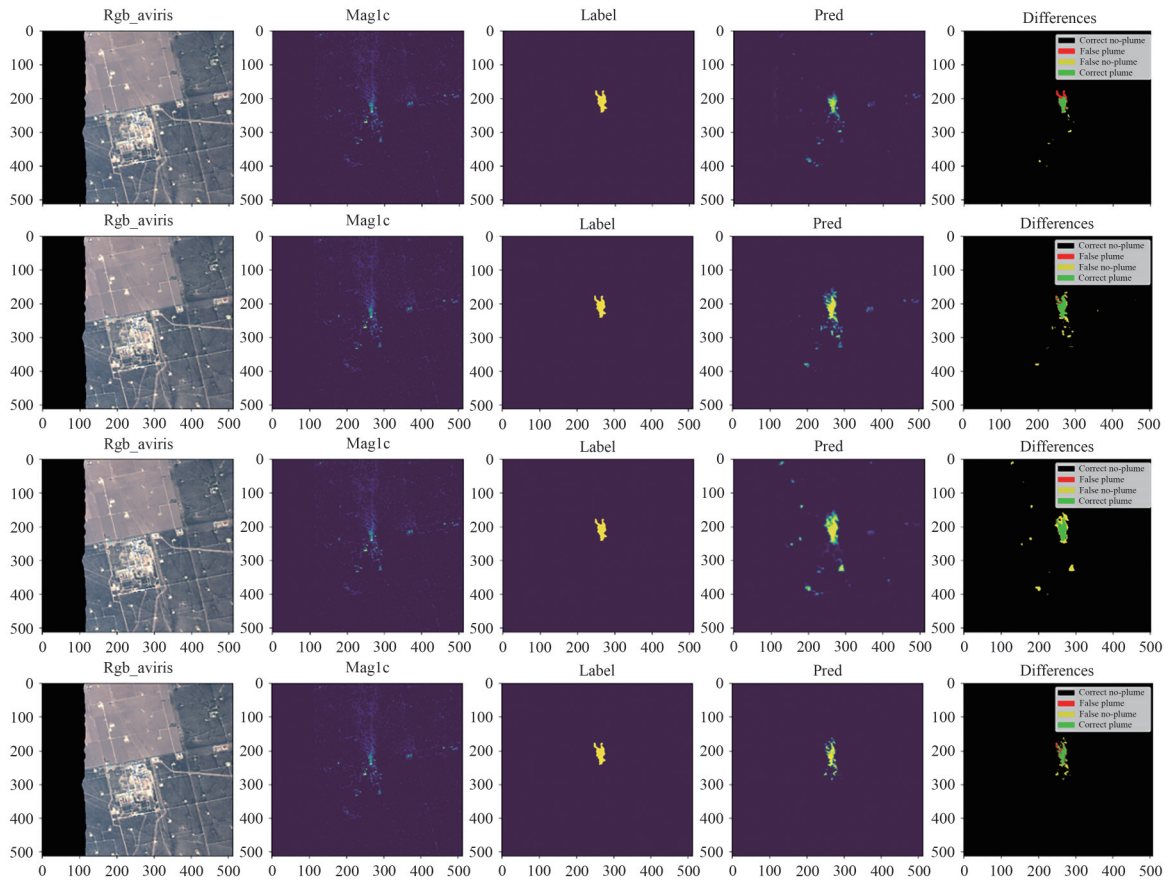


图4 微小羽流形态完整性对比。在differences误差分析列中,绿色代表模型正确检出的像素(真阳性),红色代表漏判区域(假阴性),黄色代表因背景干扰导致的误判区域(假阳性)。

Fig. 4 Comparison of the integrity of microscopic plume morphology. In the “differences” error analysis column, green represents the pixels correctly detected by the model (True Positive), red represents the missed detection areas (False Negative), and yellow represents the misjudgment areas caused by background interference (False Positive).

能。在针对微小羽流的图4、图5场景中,对比模型常因信噪比过低出现大面积黄色(误报)碎片,而LM-Net凭借形态约束机制能够维持羽流的连续结构,显著降低了探测下限,为早期微小泄漏的捕捉提供了技术支撑。在复杂背景干扰的图6场景中,LM-Net有效消除了其他模型中密集红色(漏检)噪点,这在实际工程应用中可大幅降低虚假报警率,节省大量不必要的人工现场核查成本。在标准排放条件(图7)下,LM-Net生成的预测掩膜边缘清晰且与真实标签高度吻合,极大程度减少了边界处的误判与漏判。这种形态保真度不仅提升了分割精度,更由于精准还原了羽流物理轮廓,为后续泄漏通量的科学反演与碳核算提供了可靠的基础数据,具有实践应用价值。

3.2 模块贡献分析

为了量化LM-Net中各个组件的贡献,本研

究在STARCOP基准测试集^[21]上进行了系列消融实验。评估重点在于整体性能,同时也针对容易和困难的羽流子集进行评估,以检验每个模块在不同分割难度下的有效性。

消融结果证实了LM-Net的每个模块都对分割性能有显著贡献,特别是对于较弱和破碎的羽流。DGMM、H-Attention机制和复合损失函数的结合产生了准确率较高且兼顾计算效率的结果。

3.2.1 DGMM的影响

DGMM引入了一种针对甲烷羽流的形态约束,引导特征提取向类似羽流的扩散模式发展^[31]。如表4所示,LM-Net中DGMM模块的引入提高了边界准确性和F1分数,还提高了对困难羽流的识别能力,F1分数从42.32%提高到50.55%。这表明DGMM有效地保留了弱且破




图5 微小羽流形态抗背景噪声能力对比。在differences误差分析列中,绿色代表模型正确检出的像素(真阳性),红色代表漏判区域(假阴性),黄色代表因背景干扰导致的误判区域(假阳性)。

Fig. 5 Comparison of the ability of microscopic plume morphology to resist background noise applications. In the “differences” error analysis column, green represents the pixels correctly detected by the model (True Positive), red represents the missed detection areas (False Negative), and yellow represents the misjudgment areas caused by background interference (False Positive).

碎的羽流结构,提供了标准卷积无法提供的羽流形态约束。

如表4所示,引入DGMM后模型在弱和破碎羽流的边界刻画与识别能力上均得到明显提升。为进一步验证其作用机制,本研究对DGMM进行了可视化分析。图8可视化了DGMM在推理过程中动态生成的高斯卷积核在甲烷增强图(MAG1C)上的叠加结果,用于分析其形态建模机制。可以看出,这些高斯核会根据局部羽流结构自适应地调整其尺度、偏心率和方向:细长的核沿着拉伸的羽流段分布,而紧凑的核则集中于小尺度或孤立的羽流碎片区域。这一现象表明,DGMM并非对特征进行简单平滑,而是作为一种诱导性的形态约束,引导特征响应向符合羽流扩散特性的几何结构演化。与此同时,高斯核的响应保持

高度局部化,并有效避免扩散至无关的高对比度背景区域。图8和图9从激活响应和核形态两个层面提供了定性证据,表明DGMM能够学习到具有形态一致性的空间表示,从而增强羽流结构的连贯性与稳定性。

图9展示了DGMM内部激活响应与真实羽流掩码的叠加结果,可以观察到该模块在推理过程中能够自适应地聚焦于符合羽流扩散特征的空间区域。具体而言,DGMM在甲烷羽流主体区域表现出强烈且空间上一致的响应,而在非羽流区域(如建筑物、土壤或道路)中则基本保持不活跃状态。对于尺度较大的羽流,其激活模式与主要扩散轴及下游羽流尾部高度一致,能够有效追踪拉长的传输几何形状。即使在弱或破碎羽流情况下,DGMM仍能突出微弱的甲烷信号并

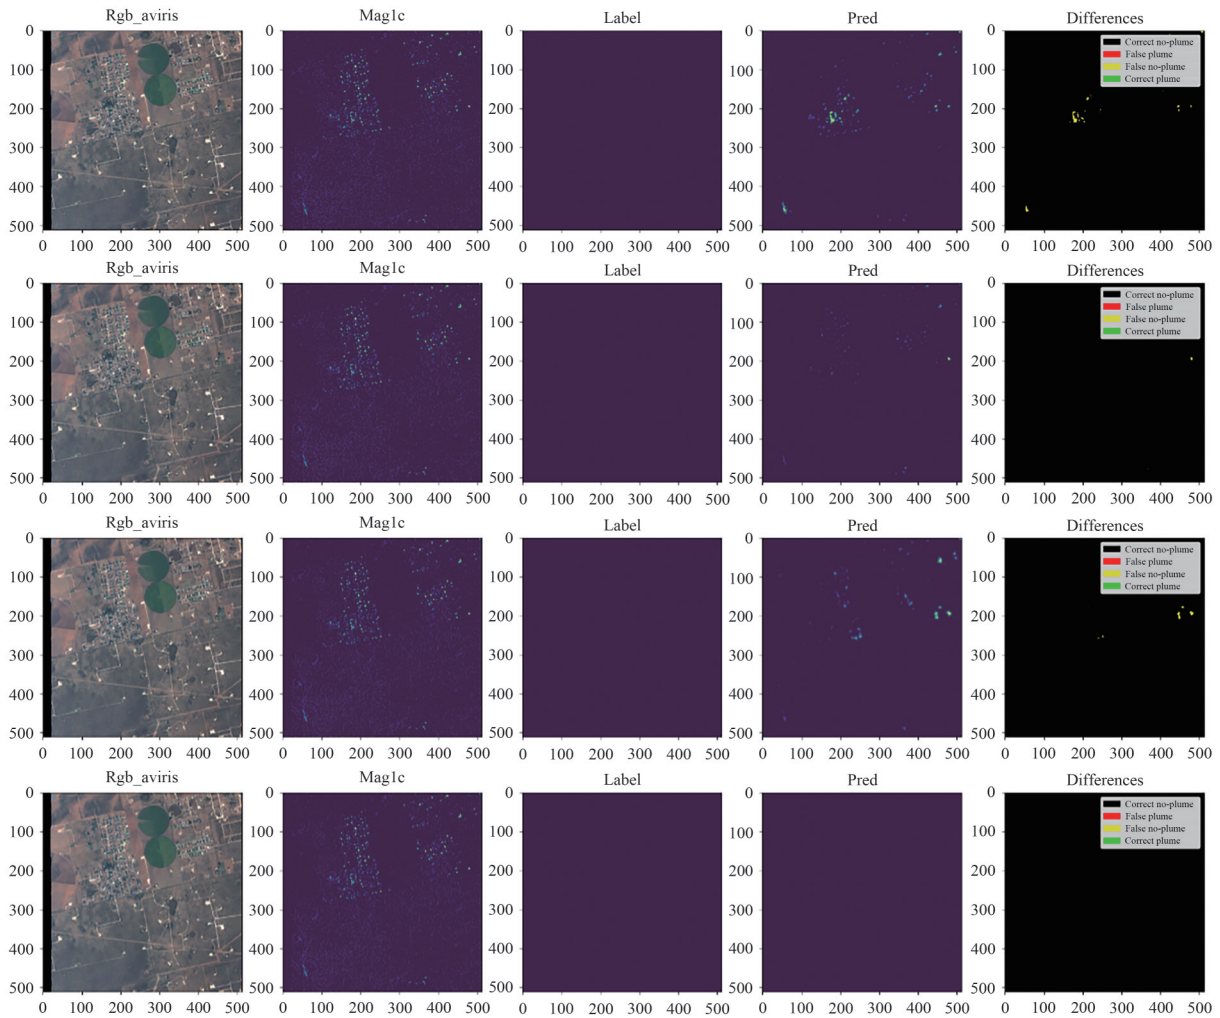


图 6 无羽流区域的预测准确性对比。在 differences 误差分析列中,绿色代表模型正确检出的像素(真阳性),红色代表漏判区域(假阴性),黄色代表因背景干扰导致的误判区域(假阳性)。

Fig. 6 Comparison of prediction accuracy in the non-plume regions. In the “differences” error analysis column, green represents the pixels correctly detected by the model (True Positive), red represents the missed detection areas (False Negative), and yellow represents the misjudgment areas caused by background interference (False Positive).

抑制背景杂波,体现出其在低信噪比区域保持空间连续性的能力。

3.2.2 H-Attention 模块特征解耦机制的影响

H-Attention 模块通过多维特征解耦机制,有效增强了网络在复杂背景区域抑制假阳性信号的能力。如图 10 的可视化结果所示,该模块通过将特征投影至不同的子空间实现了物理意义上的解耦。光谱解耦图(图 10(a))利用通道重组初步抑制了非甲烷相关的背景光谱噪声,物理边缘解耦图(图 10(b))则通过 Sobel 算子提取了羽流的扩散边界,最终融合注意力图(图 10(c))展示了光谱特征、空间形态与边界约束三者融合后的最终注意力分布。可以观察到,空间维度的

介入使得模型能够精准抑制非羽流区域的激活,实现了对目标的提取。这种解耦策略使得模型能够从杂乱的地表纹理中精准剥离出微弱信号。消融实验显示,当引入该模块至主体框架时,对羽流的平均交并比提高了 5.5%,且总体召回率保持在较高水平。这证明了基于特征解耦的细化机制能够有选择地突出关键羽流特征,从而在不降低整体分割质量的情况下,提升模型对背景伪影的辨别与抑制能力。

3.3 计算效率分析

本研究不仅关注了分割的准确性,还测量了 LM-Net 的分割效率,包括:计算浮点运算次数,统计参数数量,记录每次推理运行的时间,并检

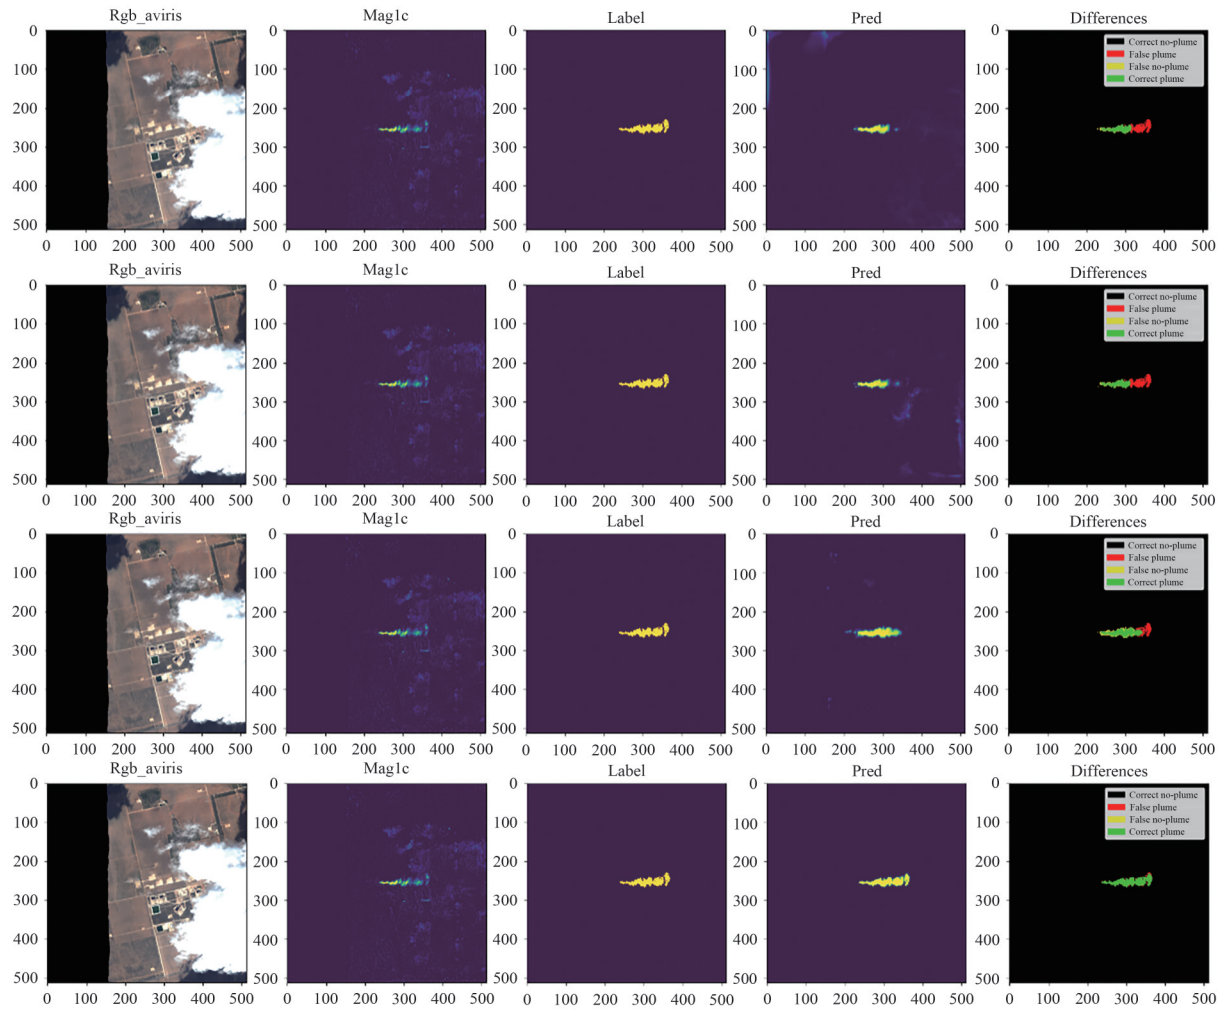


图 7 标准条件下羽流的整体完整性对比。在 differences 误差分析列中,绿色代表模型正确检出的像素(真阳性),红色代表漏判区域(假阴性),黄色代表因背景干扰导致的误判区域(假阳性)。

Fig. 7 Comparison of the overall integrity of the plume under standard conditions. In the “differences” error analysis column, green represents the pixels correctly detected by the model (True Positive), red represents the missed detection areas (False Negative), and yellow represents the misjudgment areas caused by background interference (False Positive).

表 4 UNet++和 EfficientNet-B0 变体在 STARCOP 数据集上的消融结果

Tab. 4 Ablation results of UNet++ and EfficientNet-B0 variants on the STARCOP dataset

Model variant	DGMM	H-Attention	mIoU/%	F1-Score/%
Baseline(UNet++)	×	×	41.25	42.32
+H-Attn	×	✓	46.79	56.25
+DGMM	✓	×	47.10	50.55
+Var. Conv. (without prior)	(Var. Conv.)	✓	42.18	37.63
FullModel(Ours)	✓	✓	56.70	64.73

查 GPU 内存使用情况。表 5 列出了本研究尝试的所有网络形状和骨干网络组合的相应数据。

本研究选择 EfficientNet-B0 作为骨干网络。在此基础上,LM-Net 在保持准确性和速度的同

时达到了最佳平衡。DGMM 和混合注意力机制确实增加了工作量,该模型需要 5.24 GFLOPs 和 2.61M 个参数。然而,它在 NVIDIA 4090 GPU 上仍能以超过 60 FPS 的速度运行,内存消耗很低,




图8 DGMM 动态卷积核可视化

Fig. 8 Visualization of DGMM dynamic convolution kernel




图9 DGMM 内部激活响应可视化

Fig. 9 Visualization of internal activation responses within DGMM

仅为 172.40 MB。像 ResNet101 或 DenseNet121 这样更重的骨干网络则消耗了更多的功率,但准


(a) 光谱解耦图 (b) 物理边缘解耦图 (c) 融合注意力图
(a) Spectral decoupling map (b) Physical edge decoupling map (c) Fused attention map

图10 H-Attention 特征解耦可视化

Fig. 10 H-Attention feature decoupling visualization

确性的提升实际上并不显著^[32]。LM-Net 的设计表明,形状感知模块和注意力机制能够有效地融合在一起,且不会显著增加计算负担,这使其适用于空中或航天型甲烷监测系统的实际部署^[22-23]。值得注意的是,仅使用可变卷积或复合损失函数的模型变体,在效率和准确性方面存在不同的权衡,这进一步证实了在实际应用中根据具体需求选择合适模块的重要性。

表 5 不同网络架构的计算效率

Tab. 5 Computational efficiency of different network architectures

Model	Backbone	Params/M	FLOPs/G	Inference time/ms
U-Net	ResNet-50	32.52	2.69	7.94
U-Net	MobileNet-V2	6.63	0.85	4.90
U-Net	EfficientNet-B0	2.28	2.53	10.14
DeepLabV3+	ResNet-101	45.67	3.54	14.81
UNet++	ResNet-101	67.98	15.62	15.19
UNet++	EfficientNet-B0	2.60	1.28	12.90
LM-Net	EfficientNet-B0	2.61	5.24	16.22

注:粗体数字表示最优值

4 结 论

微弱甲烷羽流具有对比度低、边界特征模糊

等特点,这些因素共同限制了深度学习网络准确识别它们的能力。为了解决这个问题,本研究提出了一个轻量级的分割框架 LM-Net。该模型

通过融合 UNet++ 和 EfficientNet 的优势,引入动态高斯模块(DGMM)和混合注意力机制(H-Attention),有效地解决了微弱甲烷羽流在高光谱图像中存在的边界模糊和背景噪声干扰问题。在 STARCOP 基准数据集上的实验结果表明,LightMethaneNet 在微弱羽流的检测中优于传统模型,如 UNet++、DeepLabV3+ 和 Ch4net,其 F1 分数提高至 64.73%,准确率提高至 53.16%。该方法不仅提高了甲烷羽流的分割精度,还具有较高的计算效率。总体而言,LM-Net 在检测精度和计算效率之间实现了良好的平衡。它将形态约束知识与轻量级架构设计相结合,表明基于物理的形态约束能够切实有效地提高甲烷羽流分割的效果,为复杂背景条件下弱甲烷羽流的稳

定识别提供了一种可行的技术路线。

后续将从物理先验引入与多源信息融合两个维度实现进一步优化:一是计划将真实风速与风向作为物理先验引入模型,通过气象数据动态指导高斯核的偏心率与旋转角度,使卷积核的各向异性扩散特征与大气传输物理模型深度对齐,从而在低信噪比下更精准区分弱羽流边缘与条带状地表伪影;二是探索多时相(Multi-temporal)数据的差异化分析,利用时序建模将“静态”地表背景噪声与“动态”排放信号进行时空维度的特征解耦,通过多源信息的协同约束有效消除因地表反射率非均匀性导致的假阳性误报,最终实现在复杂背景工况下对弱甲烷羽流持续、准确的量化遥感监测。

参 考 文 献:

- [1] Intergovernmental Panel on Climate Change (IPCC). *Climate Change 2013: the Physical Science Basis: Working Group I Contribution to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change* [M]. Cambridge: Cambridge University Press, 2014.
- [2] VARON D J, JERVIS D, MCKEEVER J, *et al.* High-frequency monitoring of anomalous methane point sources with multispectral Sentinel-2 satellite observations [J]. *Atmospheric Measurement Techniques*, 2021, 14(4): 2771-2785.
- [3] TOLLEFSON J. Scientists raise alarm over ‘dangerously fast’ growth in atmospheric methane [J/OL]. *Nature*, (2022-02-28). <https://www.nature.com/articles/d41586-022-00312-2>.
- [4] National Academies of Sciences, Engineering, and Medicine, Division on Earth and Life Studies, Board on Environmental Studies and Toxicology, *et al.* Improving characterization of anthropogenic methane emissions in the United States [R]. Washington: the National Academies Press, 2018.
- [5] IRAKULIS-LOITXATE I, GUANTER L, MAASAKKERS J D, *et al.* Satellites detect abatable super-emissions in one of the world’s largest methane hotspot regions [J]. *Environmental Science & Technology*, 2022, 56(4): 2143-2152.
- [6] 方卫芳,李小英,王雅鹏,等. 基于HIRAS的大气甲烷探测敏感性分析与反演波长选择[J]. *遥感技术与应用*, 2024, 39(4): 809-820.
FANG W F, LI X Y, WANG Y P, *et al.* Sensitivity analysis and inversion wavelength selection for atmospheric methane detection based on HIRAS [J]. *Remote Sensing Technology and Application*, 2024, 39(4): 809-820. (in Chinese)
- [7] 周晨,马柳昊,王宇. 基于外差相敏色散光谱技术的宽动态范围甲烷气体检测[J]. *中国光学(中英文)*, 2024, 17(4): 789-800.
ZHOU C, MA L H, WANG Y. Measurement of methane concentration with wide dynamic range using heterodyne phase-sensitive dispersion spectroscopy [J]. *Chinese Optics*, 2024, 17(4): 789-800. (in Chinese)
- [8] LAUVAUX T, GIRON C, MAZZOLINI M, *et al.* Global assessment of oil and gas methane ultra-emitters [J]. *Science*, 2022, 375(6580): 557-561.
- [9] JACOB D J, VARON D J, CUSWORTH D H, *et al.* Quantifying methane emissions from the global scale down to point sources using satellite observations of atmospheric methane [J]. *Atmospheric Chemistry and Physics*, 2022, 22(14): 9617-9646.
- [10] 蔡小莉,鲍云飞,黄巧林. 基于卫星遥感的大气甲烷探测反演技术综述[J]. *航天返回与遥感*, 2025, 46(1):

- 160-173.
- CAI X L, BAO Y F, HUANG Q L. Review of atmospheric methane detection and inversion techniques based on space remote sensing satellites [J]. *Spacecraft Recovery & Remote Sensing*, 2025, 46(1): 160-173. (in Chinese)
- [11] 刘洋, 李博, 林冠宇, 等. 紫外小 F 数高变倍高光谱成像仪设计[J]. 中国光学(中英文), 2024, 17(1): 79-88.
- LIU Y, LI B, LIN G Y, *et al.* Design of UV-band hyperspectral resolution imaging spectrometer with small F-number and high variable ratio [J]. *Chinese Optics*, 2024, 17(1): 79-88. (in Chinese)
- [12] SHERWIN E D, RUTHERFORD J S, CHEN Y L, *et al.* Single-blind validation of space-based point-source detection and quantification of onshore methane emissions [J]. *Scientific Reports*, 2023, 13(1): 3836.
- [13] 何卓, 李正强, 马奕, 等. 碧空一号卫星大气甲烷羽流探测及点源排放量遥感分析[J]. 光学学报(网络版), 2025, 2(22): 2215001.
- HE Z, LI Z Q, MA Y, *et al.* Detection of atmospheric methane plumes and remote sensing analysis of point source emissions based on BK-1 satellite [J]. *Acta Optica Sinica (Online)*, 2025, 2(22): 2215001. (in Chinese)
- [14] EHRET T, DE TRUCHIS A, MAZZOLINI M, *et al.* Global tracking and quantification of oil and gas methane emissions from recurrent Sentinel-2 imagery [J]. *Environmental Science & Technology*, 2022, 56(14): 10517-10529.
- [15] VAUGHAN A, MATEO-GARCÍA G, GÓMEZ-CHOVA L, *et al.* CH4Net: a deep learning model for monitoring methane super-emitters with Sentinel-2 imagery [J]. *Atmospheric Measurement Techniques*, 2024, 17(9): 2583-2593.
- [16] GUANTER L, WARREN J, OMARA M, *et al.* Detection and quantification of methane plumes with the MethaneAIR airborne spectrometer [J]. *Atmospheric Measurement Techniques*, 2025, 18(7): 3857-3872.
- [17] AHSAN R, SHANTO S H, ARIFIN S, *et al.* AttMetNet: Attention-enhanced deep neural network for methane plume detection in Sentinel-2 satellite imagery [C]. The Fourteenth International Conference on Learning Representations. Rio de Janeiro: OpenReview. net, 2026.
- [18] TRAN K D M, VAN NGUYEN H, MUHAMMAD RAWI A B, *et al.* Robust small methane plume segmentation in satellite imagery [C]. 2025 14th International Conference on Control, Automation and Information Sciences (ICCAIS). Jeju: IEEE, 2025: 134-139.
- [19] MA Y F, LIU Y H, HE Y, *et al.* Design of multipass cell with dense spot patterns and its performance in a light-induced thermoelastic spectroscopy-based methane sensor [J]. *Light: Advanced Manufacturing*, 2025, 6(1): 5-13.
- [20] 何自芬, 曹辉柱, 张印辉, 等. 空间信息自适应调控和特征对齐的红外甲烷实例分割[J]. 光学精密工程, 2023, 31(20): 3034-3049.
- HE Z F, CAO H Z, ZHANG Y H, *et al.* Spatial information adaptive regulation and feature alignment for infrared methane instance segmentation [J]. *Optics and Precision Engineering*, 2023, 31(20): 3034-3049. (in Chinese)
- [21] RŮŽIČKA V, MATEO-GARCIA G, GÓMEZ-CHOVA L, *et al.* Semantic segmentation of methane plumes with hyperspectral machine learning models [J]. *Scientific Reports*, 2023, 13(1): 19999.
- [22] THOMPSON D R, LEIFER I, BOVENSMANN H, *et al.* Real-time remote detection and measurement for airborne imaging spectroscopy: a case study with methane [J]. *Atmospheric Measurement Techniques*, 2015, 8(10): 4383-4397.
- [23] 荣亚琪, 张丽娟, 崔金利, 等. 基于 NODE-UNet++ 和标记分水岭算法的红细胞图像分割[J]. 液晶与显示, 2022, 37(9): 1190-1198.
- RONG Y Q, ZHANG L J, CUI J L, *et al.* Red blood cell image segmentation based on NODE-UNet++ and marker watershed [J]. *Chinese Journal of Liquid Crystals and Displays*, 2022, 37(9): 1190-1198. (in Chinese)
- [24] ROY S K, DERIA A, SHAH C, *et al.* Spectral-spatial morphological attention transformer for hyperspectral image classification [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2023, 61: 5503615.
- [25] LIU X, GODBOLE A, LU C, *et al.* Optimisation of dispersion parameters of Gaussian plume model for CO₂ dispersion [J]. *Environmental Science and Pollution Research*, 2015, 22(22): 18288-18299.
- [26] ZHOU Z W, SIDDIQUEE R, TAJBAKSH N, *et al.* UNet++: a nested U-net architecture for medical image

- segmentation [C]//*Proceedings of the 4th International Workshop, DLMIA 2018, and 8th International Workshop on Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support*. Granada: Springer, 2018: 3-11.
- [27] OUERGHI E. Detection of methane plume emissions with satellite imagery [D]. Paris: Université Paris-Saclay, 2023.
- [28] CHENG B W, GIRSHICK R, DOLLÁR P, *et al.* Boundary IoU: improving object-centric image segmentation evaluation [C]//*Proceedings of the 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. Nashville: IEEE, 2021: 15334-15342.
- [29] ZI Y, ZHOU C Y, CHEN J F, *et al.* Hyperspectral methane plume segmentation through foundation computer vision models [J]. *IEEE Access*, 2025, 13: 143031-143041.
- [30] 刘玉,郭迎春,朱叶,等. 基于双交叉注意力Transformer网络的小样本图像语义分割[J]. *液晶与显示*, 2024, 39(11):1494-1505.
LIU Y, GUO Y C, ZHU Y, *et al.* Dual cross-attention Transformer network for few-shot image semantic segmentation [J]. *Chinese Journal of Liquid Crystals and Displays*, 2024, 39(11): 1494-1505. (in Chinese)
- [31] 徐凯歌,孙晓明,陈泳吉,等. 基于扩散模型的细胞图像与掩膜联合生成数据扩充方法[J]. *光学精密工程*, 2026, 34(4):652-670.
XU K G, SUN X M, CHEN Y J, *et al.* A diffusion model based data augmentation method for joint generation of cell images and masks [J]. *Optics and Precision Engineering*, 2026, 34(4): 652-670. (in Chinese)
- [32] CHEN C, FAN M, WANG Z B, *et al.* MPSUNet: a deep learning-based segmentation framework for methane plume detection with space-based hyperspectral and multispectral imagery [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2025, 63: 5403115.

作者简介:



赵翼,男,硕士研究生,2020年于河北农业大学获得学士学位,主要从事高光谱遥感图像处理方面的研究。E-mail: 19931603485@163.com



李海巍,男,博士,研究员,2016年于中南大学获得博士学位,主要从事高光谱遥感图像处理方面的研究。E-mail: lihaiwei@opt.ac.cn