

基于目标检测的 VOCs 泄漏区域识别技术研究

杨承霖, 陈海永*, 岳学智, 邓立齐, 郭东歌, 王海超, 杨菁

(汉威科技集团股份有限公司, 郑州 450001)

摘要: 为解决红外气体成像仪在挥发性有机化合物(VOCs)泄漏识别中错漏检率高、算法执行效率低和模型泛化能力差等问题, 提出了一种基于运动特征增强的 VOCs 泄漏区识别方法。先提取稳定状态下运动前景进行特征增强和图像融合, 以获取实验样本; 然后通过模型预训练和迁移学习的方法进行模型训练, 获取检测模型; 最后将模型部署至红外气体成像仪进行实验验证。结果表明, 该算法单帧平均识别时间 49ms, 满足视频级检测要求, 在典型应用场景下可有效检测到泄漏的气体, 并渲染上色。

关键词: 图像处理; 目标检测; VOCs; 红外气体成像仪

The research on VOCs leak area identification technology based on target detection

YANG Chenglin, CHEN Haiyong*, YUE Xuezhi, DENG Liqi, GUO Dongge, WANG Haichao, YANG Jing

(Hanwei Electronics Group Corporation, Zhengzhou 450001, China)

Abstract: To address the high false-positive and false-negative rates, low algorithm execution efficiency, and poor model generalization in the identification of volatile organic compounds (VOCs) leaks using infrared gas imaging, a method for identifying VOCs leak areas based on motion feature enhancement is proposed. First, stable-state motion foregrounds are extracted for feature enhancement and image fusion to obtain experimental samples. Then, model training is conducted through pre-training and transfer learning to acquire the detection model. Finally, the model is deployed to an infrared gas imager for experimental validation. Results show that the algorithm has an average recognition time of 49ms per frame, meeting video-level detection requirements, and can effectively detect and colorize leaking gases in typical applications.

Keywords: image processing; target detection; volatile organic compounds leakage; infrared gas imaging camera

1 引言

挥发性有机化合物 (volatile organic compounds, VOCs) 是一类在常温条件下易挥发的化合物, 这些化合物在工业生产、交通运输、建筑材料以及室内气体环境中均广泛分布, 其光化学反应形成的臭氧和其他有毒污染物会对环境造成严重污染。

随着气体探测技术的不断发展, VOCs 泄漏监测已由非成像模式逐步转向成像模式。比如, Bertin 公司的 Second-Sight^[1] 产品设计有多个滤光片, 可依据气体在不同波段的吸收特性, 实现对特定气体的精确识别。FLIR 公司的光学气体图像摄像机 (optical gas imaging OGI^[2]) 采用了窄带滤光片和斯特林制冷系统, 使其能够可视化气体在红外吸收波段的分布情况, 通过差分图像技术, 该设备能够有效识别可疑的 VOCs 泄漏区域, 进一步提高了监测的准确性和可靠性。

随着红外图像分析技术的不断发展, 越来越多的学者开始将其与红外成像技术相结合, 以提高 VOCs 泄漏的自动化识别效果。较为典型方法有帧差法^[3, 4]、光流法^[5, 6]和背景建模法^[7], 这些方法的核心思想是利用目标的运动特征来识别目标。然而, 由于 VOCs 的泄漏通常以不稳定的模式移动, 使得上述方法难以区分气体运动区域和非气体运动区域。为减少非气体运动区域干扰、提升识别效果, 研究者们从背景建模算法, 运动区域的轮廓、面积、纹理和历史特征等方面进行了深入研究。例如, WANG 等^[8]将多幅帧间差分 and 背景差分后图像进行了融合处理, 经形态学滤波后得到了疑似 VOCs 泄漏区域。LIU 等^[9]基于支持向量机分类算法, 设计了一种基于形状特征分类的泄漏 VOCs 识别方法。为提高识别精度, 多特征融合识别的方法也备受关注。例如, HONG 等^[10]通过优化高斯背景建模, 并引入气体不规则性、气体连通区域面积和移动方向等特征, 显著提高了高浓度 VOCs 泄漏区域的识别效果。BADAWI 等^[11]则利用 VOCs 动态纹理区域的空间和时间结构特征, 结合视频图像深度神经网络和时间序列神经网络的方法, 实现了从视频中快速识别 VOCs 泄漏区域。

上述研究中, VOCs 泄漏区域识别算法多集中在优化背景建模、改善 VOCs 疑似区域分类模型和多特征融合等方面, 所设计算法在 VOCs 泄漏识别中存在误识别率高、漏检率高、算法执行效率低以及模型泛化能力差等问题, 并且在 VOCs 泄漏区域的特征提取方面缺少自主学习能力。因此, 本文作者提出了一种基于增强运动区域特征并利用目标识别算法识别 VOCs 泄漏区域的算法, 该算法的优势在于结合了视频稳定性判定和混合高斯背景建模, 提高了算法的执行效率和背景建模质量; 运动图像增强处理在保留原始帧数据特征的同时, 融合了运动区域的细节特征, 提高了 VOCs 泄漏区域的识别精度和可靠性。

2 算法原理与模型构建

2.1 算法原理

本文采用的一种基于增强运动区域特征并利用目标识别算法识别 VOCs 泄漏区域的算法，包括视频稳定性判定、运动背景提取、运动前景特征增强与 VOCs 泄漏区域识别等步骤。通过分析相邻视频帧灰度投影矩阵变化率来判断视频是否稳定，减少干扰因素的影响；利用高斯混合模型背景建模提取出静止区域作为运动背景；通过背景差分，提取出视频中的运动区域，并进行图像增强，突出细节特征，并利用运动目标检测算法识别 VOCs 泄漏区域，实现对泄漏区域的识别。算法具体实现流程如下图 1 所示。

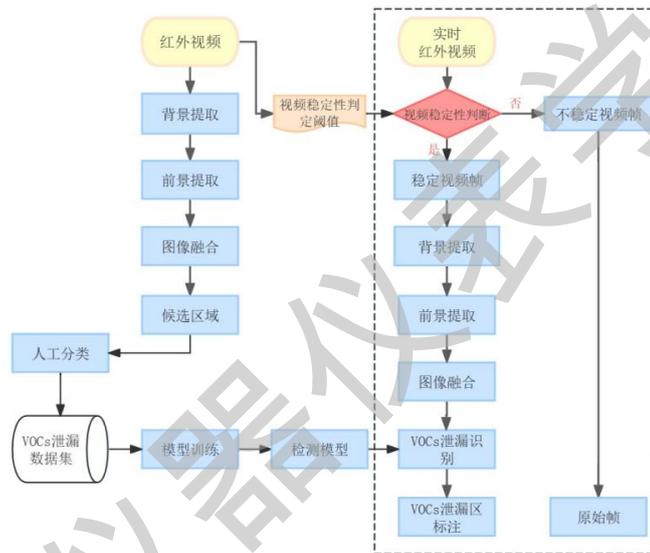


图 1 技术路线

2.1.1 视频稳定性判定

本文中，将灰度投影矩阵变化率作为判定视频稳定性的指标。较小的投影变化率表示视频处于稳定状态，较高的投影变化率表示视频处于非稳定状态，或者视频中有快速移动物体的干扰。该算法计算效率高，能够有效过滤非稳定状态的视频数据，减少镜头晃动、人员快速移动等因素对结果的干扰。

灰度投影矩阵计算

分别计算视频第 k 帧行方向 1 维灰度投影矩阵 X_k 、列方向 1 维灰度投影矩阵 Y_k 和上一帧行方向 1 维灰度投影矩阵 X_{k-1} 、列方向 1 维灰度投影矩阵 Y_{k-1} ，计算公式见下：

$$X_k(x) = \frac{1}{w} \sum_{y=1}^w f_k(x, y) \quad (1)$$

$$Y_k(y) = \frac{1}{h} \sum_{x=1}^h f_k(x, y) \quad (2)$$

$$X_{k-1}(x) = \frac{1}{w} \sum_{y=1}^w f_{k-1}(x, y) \quad (3)$$

$$Y_{k-1}(y) = \frac{1}{h} \sum_{x=1}^h f_{k-1}(x, y) \quad (4)$$

式中： h 表示视频帧的行数； w 表示视频帧的列数； $f_k(x,y)$ 、 $f_{k-1}(x,y)$ 分别表示视频第 k 、 $k-1$ 帧图像的2维灰度信息； $X_k(x)$ 、 $Y_k(y)$ 表示第 k 帧图像第 x 行和第 y 列的灰度投影值； $X_{k-1}(x)$ 、 $Y_{k-1}(y)$ 表示第 $k-1$ 帧图像第 x 行和第 y 列的灰度投影值。

灰度投影矩阵标准差计算

分别计算第 k 帧行方向的灰度投影标准差矩阵 $S_{x,k}$ 、列方向灰度投影标准差矩阵 $S_{y,k}$ 和上一帧行方向灰度投影标准差矩阵 $S_{x,k-1}$ 、列方向灰度投影标准差矩阵 $S_{y,k-1}$,计算公式算为：

$$S_{x,k}(x) = \sqrt{\frac{1}{w} \sum_{y=1}^w (f_k(x, y) - X_k(x))^2} \quad (5)$$

$$S_{y,k}(y) = \sqrt{\frac{1}{h} \sum_{x=1}^h (f_k(x, y) - Y_k(y))^2} \quad (6)$$

$$S_{x,k-1}(x) = \sqrt{\frac{1}{w} \sum_{y=1}^w (f_{k-1}(x, y) - X_{k-1}(x))^2} \quad (7)$$

$$S_{y,k-1}(y) = \sqrt{\frac{1}{h} \sum_{x=1}^h (f_{k-1}(x, y) - Y_{k-1}(y))^2} \quad (8)$$

式中： $S_{x,k}(x)$ 、 $S_{y,k}(y)$ 分别表示第 k 帧图像第 x 行和第 y 列的灰度投影标准差； $S_{x,k-1}(x)$ 、 $S_{y,k-1}(y)$ 分别表示第 $k-1$ 帧图像第 x 行和第 y 列的灰度投影标准差。

灰度投影矩阵变化率计算

利用式（9）和式（10）分别计算行、列方向灰度投影矩阵变化率 X_c 和 Y_c ：

$$X_c = \frac{\sum_{x=1}^h |X_{k-1}(x) - X_k(x)|}{\frac{1}{w} \sum S_{x,k-1}} \quad (9)$$

$$Y_c = \frac{\sum_{y=1}^w |Y_{k-1}(y) - Y_k(y)|}{\frac{1}{h} \sum S_{y,k-1}} \quad (10)$$

式中： $\frac{1}{w} \sum S_{x,k-1}$ 和 $\frac{1}{h} \sum S_{y,k-1}$ 分别表示视频第 $k-1$ 帧行方向和列方向灰度投影标准差的均值。如果 X_c 和 Y_c 都较低，则说明第 k 帧图像处于稳定视频序列中。

2.1.2 运动背景提取

本文采用均值背景建模算法作为背景建模和前景提取方法，如下式（11）所示，取连续 N 帧图像的均值作为背景。

$$b(x, y, k) = \frac{1}{N} \sum_{i=1}^N f(x, y, k) \quad (11)$$

2.1.3 运动前景提取

计算帧差

采用连续两帧图像与背景图像进行灰度值差值分析，取两者的均值作为帧差结果；然后将平均值与预设阈值进行比较，如果平均值超过阈值，则相应区域被判定为运动区域。这种方法能够有效地检测出运动目标，并且在实际操作中具有较高的准确性和可靠性

$$d(x, y, k - 1) = |f(x, y, k - 1) - b(x, y, k - 1)| \quad (12)$$

$$d(x, y, k) = |f(x, y, k) - b(x, y, k)| \quad (13)$$

$$g(x, y, k) = (d(x, y, k - 1) + d(x, y, k)) \times 0.5 \quad (14)$$

式中： $f(x,y,k-1)$ 和 $f(x,y,k)$ 表示影像第 $k-1$ 和第 k 帧图像 (x,y) 处的灰度值； $b(x,y,k)$ 表示第 k 帧的运动背景； $d(x,y,k-1)$ 和 $d(x,y,k)$ 表示第 $k-1$ 和第 k 帧的帧差结果； $g(x,y,k)$ 表示第 k 帧求均值后的帧差结果，即运动前景。

图像增强

为解决 VOCs 泄漏运动前景灰度值低、存在异常噪声、对比度不明显的问题，本文提出了一种优化的线性拉伸算法来提升图像质量。首先计算图像的相对累积直方图，查找最小百分比和最大百分比相对应的数据值，将其分别标记为 a 值和 b 值；接着利用最小调整百分比 0.1 和最大调整百分比 0.5 更新 a 值（见式（15））和 b 值（见式（16）），得到新的 a' 和 b' ，将小于 a' 和大于的 b' 值标记为最小噪声和最大噪声；然后使用公式（见式（17））对图像进行拉伸和噪声去除。

$$a' = a - (b - a) \times 0.1 \quad (15)$$

$$b' = b + (b - a) \times 0.5 \quad (16)$$

$$E(x, y, k) = \begin{cases} 0, & (g(x, y, k) < a') \\ 255, & (g(x, y, k) > b') \\ \frac{g(x, y, k) - a'}{(b' - a')} \times 255, & (a' \leq g(x, y, k) \leq b') \end{cases} \quad (17)$$

式中： $g(x, y, k-1)$ 表示原始运动前景； $E(x, y, k)$ 表示第 k 帧图像经过拉伸和图像增强后的运动前景。

为了更为准确进行气体区域识别，将经过特征增强的运动前景与原始图像进行加权融合后，用于目标检测识别。

2.2 模型构建

2.2.1 数据获取

数据获取实验选择原油油气为 VOCs 泄漏源，场景内包含林木干扰，天气条件为微风，树枝有明显晃动，符合移动干扰的特征。实验现场如图 2 所示。

数据采集设备为汉威科技集团自主研发的 C330-H 制冷型红外气体成像仪（图 3），该成像仪采用了浙江超晶晟锐光电有限公司的 II 类超晶格中波制冷型机芯，主要参数如表 1 所示。



图 2 实验地点



图 3 C330-H 红外气体成像仪

表 1 红外气体成像仪核心参数

项目	技术参数
分辨率	640*512
像元大小	15um
光谱范围	3.2 μ m~3.5 μ m
热灵敏度	22mk
制冷方法	斯特林制冷
数据位数	8bit/14bit

为便于数据分析，我们对红外气体成像仪采集的原始数据进行处理，将 YUV 格式的二进制数据转换为通用的数据格式、调整分辨率和帧率设置等，最终形成分辨率为 640*512、帧率为 25 的高质量视频。

2.2.2 视频稳定性阈值获取

我们按照文献 12^[12]对原始视频序列进行投影矩阵变化率的统计分析，根据该序列的分布和统计特性，首先计算投影矩阵变化率序列的标准差，并将两倍标准差的数值定义为异常视频帧的判定阈值，剔除了大于该阈值的视频数据。这样可以过滤掉异常值或异常波动，保留相对平稳的数据。接着，我们对剩余数据取均值，以得到一个稳定的投影矩阵变化率阈值。当投影矩阵的变化率小于或等于阈值时，我们认为视频处于稳定状态，可以进行后续处理和识别操作。而一旦超过阈值，则判定图像处于运动状态或有快速移动物体的干扰。通过以上处理和阈值设定，可以筛选出稳定的视频帧，以确保后续处理的准确性和可靠性。

2.2.3 VOCs 泄漏数据集获取

基于 2.2.2 节获取的稳定性判定阈值，按 2.1 节所述方法对稳定状态的视频帧进行背景建模、运动前景提取、运动前景图像增强等处理后，人工筛选出具有明显泄漏气体特征的图像进行样本标注，实验共获取 VOCs 泄漏样本 323 个。部分数据样本进行气体特征标注情况如图 4 所示。

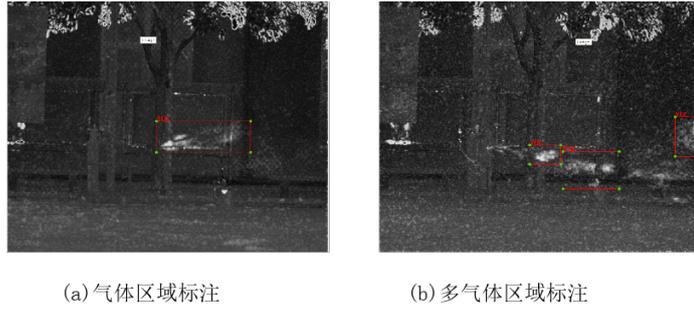


图 4 部分已标注数据集

2.2.4 模型选择与训练

选择 PyTorch 2.1.1 框架来训练基于 YOLOv7 算法的目标检测网络模型。由于真实样本有限，为了提高模型的泛化能力并降低小样本数据带来的过拟合问题，我们采用迁移学习中模型预训练的策略。在预训练阶段使用与 VOCs 泄漏数据集具有相似特征的烟雾数据集进行训练，以获得一个具有较好烟雾特征提取能力的模型。这一策略旨在使模型具备一定的先验知识，有助于模型更好地处理和提取 VOCs 泄漏数据集中的目标信息。

预训练数据集为网络公开数据集^[15]，共 15000 个，训练、验证和测试集比例为 8:1:1，即 80%的数据用于训练模型，10%的数据用于验证模型的性能和调优，另外 10%的数据用于测试模型的泛化能力和评估最终性能。真实 VOCs 数据集 323 个，数据集划分方法与预训练数据集划分方法一致。

模型评估遵循训练与验证两个阶段：在训练阶段，使用检测边界框损失（bounding box loss）、物体置信度损失（object confidence loss）、准确率（precision）和召回率(recall)来衡量模型对目标边界框的识别能力；在验证阶段，使用检测边界框损失、物体置信度损失、平均精度均值（mean average precision,mAP）mAP@0.5 和 mAP@0.5:0.95 指标综合评价模型性能。其中，mAP@0.5 是指固定交并比（intersection over union, IOU）阈值 0.5 下进行，mAP@0.5:0.95 是指 IOU 阈值从 0.5 到 0.95 时的平均精度均值，更全面地评估目标检测模型的性能。图 5 为 VOCs 识别模型训练过程的可视化结果，从训练结果可以看出，模型迁移对 VOCs 泄漏识别模型的训练效率提升明显。

为评价模型精度，以测试集为输入数据，以 mAP@0.5 和 mAP@0.5:0.95 为评价指标对模型精度进行评价，结果表明在 IOU 为 0.5 时，mAP 为 0.88；当 IOU 阈值从 0.5~0.95 时，mAP 为 0.51。

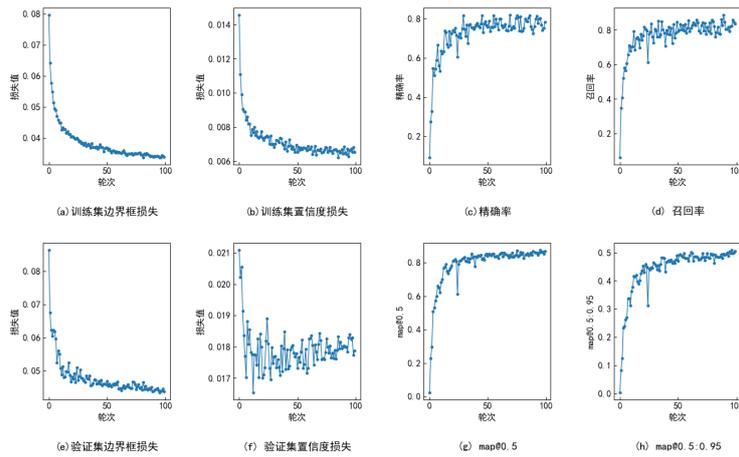


图 5 VOCs 识别模型训练结果

3 算法测试验证

将算法部署至红外气体成像仪 C330-H 进行检测效果和算法耗时测试。该产品集成有高性能边缘计算平台，可有效利用硬件处理能力加速网络模型推理过程，保证算法性能最佳。

验证实验在具有代表性的园区进行，以甲烷和原油油气挥发为待检测泄漏气体。场景内包含灌木晃动干扰。记录试验天气条件，调制不同测试距离。甲烷气体释放过程中利用玻璃转子流量计控制气体流量为 0.5L~1L/min；以开盖状态下自然挥发的原油油气为原油挥发气体。算法执行效率分析实验与检测试验同步展开，实现过程中记录各帧投影矩阵变化率、耗时，检测结果等关键数据，当视频稳定算法判定视频处于稳定状态，满足背景建模要求后，识别算法开始运行，记录算法耗时。实验开展过程中，利用红外气体成像仪录屏功能录制检测结果。

红外气体成像仪在实验环境下可以检测到不同流量等条件下的甲烷泄漏和原油挥发的微量气体，并可对气体进行渲染上色。部分检测结果如下图 6 所示。

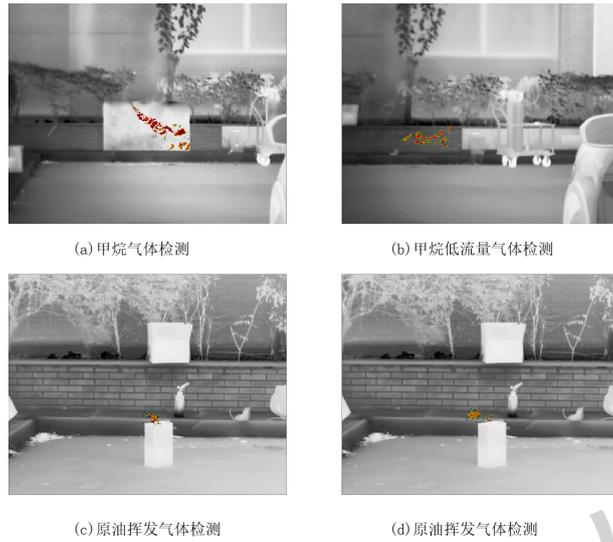


图 6 甲烷泄漏检测效果

将算法耗时结果按最大、最小和平均耗时进行统计，分别为 83ms、38ms 和 49ms。为更详细表达检测过程中投影矩阵变化率、算法耗时等关键参数，将部分检测过程参数绘制为图予以展示，具体结果如图 9 所示。

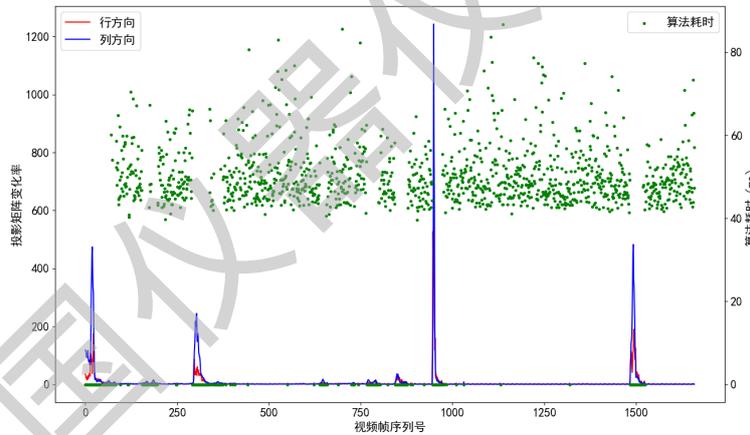


图 7 算法运行参数统计图

实验结果表明，本文算法可有效过滤林木、人员移动等干扰，算法平均耗时为 49ms，帧率约为 21 FPS（frames per second, FPS），可满足视频级检测要求。在应用试验中，红外气体成像仪针对不同场景的泄漏气体和原油挥发气体，可有效检测识别到气体，并对气体渲染上色。

4 结论

为提高 VOCs 泄漏区域检测效率和识别精度，本文采用了一种基于增强运动区域特征并利用目标识别算法识别 VOCs 泄漏区域的算法。在背景建模方面，将视频稳定性判定技术与高斯背景建模相结合，减

少了镜头移动、抖动和检测区内物体快速移动等因素对背景建模和移动区域提取的干扰，提高了背景建模质量和算法执行效率。在泄漏区域特征增强方面，对运动前景进行异常噪声过滤和细节增强，并与原始图像进行加权融合，提高了泄漏区域的可识别性。在泄漏区识别方面，利用目标检测算法，实现了 VOCs 泄漏区域的精准识别，泄漏区域识别精度 $\text{map}@0.5$ 为 0.88， $\text{map}@0.5:0.95$ 为 0.51。在算法应用方面，利用红外气体成像仪进行有典型树木晃动干扰、人员移动等干扰场景下的试验验证，结果表明算法单帧平均识别时间为 49ms，帧率约为 21 FPS，可满足实时监测需求，可有效检测识别甲烷气体和原油挥发气体泄漏，并渲染上色。

参考文献:

- [1] Naranjo E, Baliga S, Bernascolle P F, et al. IR gas imaging in an industrial setting[J]. Proceedings of the SPIE, 2010,7661:7661K.
- [2] Rangel J, Schmoll R, Kroll A. Catadioptric stereo optical gas imaging system for scene flow computation of gas structures [J]. IEEE Sensors Journal, 2021, 21(5):6811-6820.
- [3] Husein A M, Calvin, Halim D, et al. Motion detect application with frame difference method on a surveillance camera[J]. Journal of Physics: Conference Series, 2019. 1230(1): p. 012017.
- [4] Wang L M, Tong Z, Ji B, et al. Temporal difference networks for efficient action recognition[J]. in Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2021:1895-1904.
- [5] Xin Y, Hou J, Dong L, et al. A self-adaptive optical flow method for the moving object detection in the video sequences[J]. Optik-International Journal for Light and Electron Optics, 2014, 125(19):5690-5694.
- [6] Wang X, Feng L I, Xin L, et al. Moving Targets Detection for Satellite-Based Surveillance Video[C]//IGARSS 2019 - 2019 IEEE International Geoscience and Remote Sensing Symposium. Yokohama, Japan, 2019:5492-5495
- [7] He W, Li J, Qi Q, et al. SIM-MFR: Spatial interactions mechanisms based multi-feature representation for background modeling[J]. Journal of Visual Communication and Image Representation , 2022, 88:103622.
- [8] Wang J P, Li J S, Yang Y W, et al. Ethylene Gas Leakage Detection based on Infrared Imaging[J]. Journal of Liquid Crystals and Displays, 2014, 29(4): 623-628.
- [9] Liu L M, Zhang Y Z, Luan L, et al. A shape-based infrared image gas leakage detection method[J]. Journal of Applied Optics, 2019, 40(03): 468-472.

- [10] Hong S Z, YING H, Yu H W, et al. A VOCs gas detection algorithm based on infrared thermal imaging[C]//2019 Chinese Control and Decision Conference (CCDC). Nanchang, China: IEEE, 2019:329-334.
- [11] Badawi D, Pan H , Cetin S C, et al. Computationally Efficient Spatio-Temporal Dynamic Texture Recognition for Volatile Organic Compound (VOC) Leakage Detection in Industrial Plants[J]. IEEE Journal of Selected Topics in Signal Processing, 2020, 14(4): p. 676-687.
- [12] 杨承霖, 陈海永, 岳学智等. 基于目标检测的 VOCs 泄漏区域识别技术研究[J/OL].激光技术,1-17[2024-09-18].<http://kns.cnki.net/kcms/detail/51.1125.TN.20240327.1941.004.html>.
- [13] Cheng H Y, Yin J L, Chen B H, et al. Smoke 100k: A Database for Smoke Detection[C]. in 2019 IEEE 8th Global Conference on Consumer Electronics (GCCE). Osaka, Japan, 2019:596-597.