

# 改进 OMP 算法下多摄像机慢速动小目标增强检测方法

马海林

(青海警官职业学院 公安系, 西宁 810000)

**摘要:** 针对案件监控视频中慢速运动小目标因长时间曝光或摄像机抖动产生的运动模糊、特征丢失或变形, 导致检测精度降低的问题进行了研究; 采用了融合高斯、中值滤波与 Retinex 算法的降噪增强技术, 为小目标特征提取提供高质量图像; 利用 Faster R-CNN 进行特征提取, 通过卷积和池化操作捕捉局部特征, RPN 网络生成候选区域, 并提出新置信度公式精确定义区域, 再通过 RoI Pooling 获取特征向量; 应用改进 OMP 算法增强小目标特征, 引入局部相关性和能量分布并结合非线性变换, 提升增强效果与稳定性; 在多摄像机小目标关联与信息融合环节, 基于特征向量相似度关联小目标, 采用加权融合处理信息, 形成完整运动轨迹; 基于卡尔曼滤波和支持向量机实现慢速动小目标跟踪与检测结果输出, 通过初始化状态估计与协方差矩阵, 经状态预测、观测更新持续跟踪, 再输入 SVM 判定类别, 同时采用可视化技术标注显示结果, 包括绘制外接矩形框、标注位置和类别信息、显示视频帧等; 经实验测试, 该方法应用后视频帧图像对比度最大值达到 1.9, 小目标特征重构误差最小值达到 0.4%, 实现了较高的检测精度, 满足了准确、清晰地提供慢速动小目标信息的应用需求。

**关键词:** 摄像机监控视频; 目标增强检测; 改进 OMP 算法; Faster R-CNN; 慢速动小目标

## Enhancement Detection Method for Slow-Moving Small Targets with Multiple Cameras Based on Improved OMP Algorithm

MA Hailin

(Department of Public Security, Qinghai Police Vocational College, Xining 810000, China)

**Abstract:** In the surveillance case videos, slow-moving small targets have the characteristics of motion blur, feature loss, or deformation by prolonged exposure or camera shake, research on the reduced monitoring accuracy is conducted. By combining the Gaussian filtering, median filtering, and Retinex algorithm, the denoising enhancement technique is used to provide high-quality images for the feature extraction of small targets. The Faster R-CNN is adopted for their feature extraction, their local features are captured through convolution and pooling operations, the RPN network is used to generate candidate regions, and a new confidence formula is presented to accurately determine the regions, obtaining their feature vectors through RoI Pooling. The improved orthogonal matching pursuit (OMP) algorithm is used to enhance the features of small targets, and the local correlation and energy distribution as well as nonlinear transformation are introduced to improve the enhancement effect and stability. In the association and information fusion for small targets with multiple cameras, based on small targets with feature vector similarity, the weighted fusion is used to process the information, forming a complete motion trajectory. Based on the Kalman filtering and support vector machine, the results for tracking and detecting the slow-moving small targets are output. By initializing state estimation and covariance matrix, the target is continuously tracked through state prediction and observation updates, and then the support vector machine (SVM) is input to determine the category. Meanwhile, the visualization technology is used to annotate and display the results, including the drawing external rectangular boxes, annotating position and category information, displaying video frames, etc. Experimental results that after applying this method, the maximum contrast value of video frame images reaches up to 1.9, with a minimum error of 0.4% for feature reconstruction with small targets, achieving a high detection accuracy and meeting application requirements for the accurate and clear information of slow-moving small targets.

**Keywords:** multi-camera surveillance video; target enhanced detection; improved OMP algorithm; Faster R-CNN; slow-moving small targets

收稿日期:2025-09-05; 修回日期:2025-10-21。

作者简介:马海林(1978-),男,大学本科,讲师。

引用格式:马海林.改进 OMP 算法下多摄像机慢速动小目标增强检测方法[J].计算机测量与控制,2026,34(3):41-49.

## 0 引言

在多摄像机协同工作的监控场景中,面临着诸多特有的挑战。首先,不同摄像机的参数存在差异,包括分辨率、帧率、色彩校正参数等。这些参数的不同会导致同一目标在不同摄像机拍摄的视频帧中呈现出不同的视觉效果,增加了目标特征提取和匹配的难度<sup>[1]</sup>。如一个高分辨率摄像机拍摄的小目标图像细节丰富,而低分辨率摄像机拍摄的另一目标则可能模糊不清,难以准确提取其特征<sup>[2-3]</sup>。其次,视角变化也是一个重要问题。不同摄像机从不同角度拍摄目标,会使目标的外观发生显著变化。同一小目标在不同视角下,其形状、大小、纹理等特征都可能不同,甚至可能出现部分遮挡或完全不同的背景环境。这使得在多摄像机之间准确关联同一目标变得极为困难<sup>[4]</sup>,基于单一视角特征的检测方法难以直接应用于多摄像机场景,容易导致目标关联错误,进而影响后续的信息融合和跟踪检测的准确性。因此,研究多摄像机慢速小目标增强检测方法具有重要的现实意义。

当前已有方法存在着视频帧图像处理性能较差、小目标特征提取精度低、慢速小目标误检率高等问题,无法满足多摄像机监控系统的应用需求。其中,文献[5]采用视觉 Transformer 作为编码器,借助自注意力机制捕捉图像全局关系,处理长程依赖与上下文信息,实现多尺度特征的有效提取。同时,设计了由交互式解码器和辅助解码器构成的双解码器模块,充分利用不同特征的互补信息,促进深层与浅层特征的交互融合,通过叠加两个解码器的结果来更好地重构红外小目标。然而,视觉 Transformer 的计算复杂度较高,对硬件资源需求较大,在实际应用中可能面临部署困难与成本高昂的问题。文献[6]利用多尺度空洞卷积进行特征融合,以补充上下文信息,并引入通道和空间的特征提纯机制,抑制多尺度特征融合后的冲突信息,防止小目标被淹没。同时,采用复制—缩小—粘贴的数据增强方法提高小目标在数据集中的占比,使训练过程更加平衡。但多尺度空洞卷积可能引发网格效应,影响特征提取的准确性。此外,特征提纯机制虽能抑制冲突信息,却也可能过滤掉部分对小目标检测有益的信息,进而影响小目标的检测精度。文献[7]提出了一种将多层卷积融合模块与多感受野融合模块相结合的深度学习模型,通过多层级的特征提取和不同感受野的特征融合,有效表征小目标。尽管多层卷积融合模块和多感受野融合模块提升了特征提取能力,但也增加了模型的复杂度,容易导致模型对噪声的敏感性增强,影响小目标检测的稳定性。文献[8]提出了一种融合注意力和上下文信息的遥感图像小目标检测算法 ACM-YOLO。该算法应用细

粒度的查询感知稀疏注意力减少小目标特征信息的丢失,设计局部上下文增强函数以关注不同类别遥感目标所需的上下文信息,并使用加权双向特征金字塔网络强化多尺度特征融合能力。然而,局部上下文增强函数的设计可能过于依赖特定数据集的特征,在新的数据集上可能无法有效发挥作用,从而无法保障设计方法的应用效果。文献[9]先对图像进行预处理以降低外界因素的影响,再采用 Harris 角点检测方法提取候选目标区域,并将 HOG 算法与支持向量分类器相结合进行小目标检测。但 Harris 角点检测方法可能提取到一些非目标区域的角点,从而增加后续检测的负担。

为了解决上述问题或缺陷,提出改进 OMP 算法下多摄像机慢速小目标增强检测方法。

## 1 多摄像机视频帧图像去噪处理

本研究聚焦于多摄像机监控视频帧图像去噪处理,旨在解决因噪声干扰、对比度低及亮度不均等问题导致慢速小目标检测精度下降的难题。本节深入剖析了多摄像机视频帧图像中噪声特性,发现主要为高斯噪声与椒盐噪声,同时针对图像存在的其他质量缺陷展开研究。

针对上述问题,融合高斯滤波算法、中值滤波算法与 Retinex 算法。高斯滤波算法通过高斯分布函数对图像进行平滑处理,去除高斯噪声,其标准差和滤波器窗口大小影响平滑效果与图像模糊程度;中值滤波算法利用取中值操作函数,有效去除椒盐噪声。二者结合,充分发挥各自优势,去除图像中不同类型的噪声。在此基础上,采用 Retinex 算法对去噪后的图像进行增强处理。该算法基于人类视觉系统的颜色恒常性理论,将图像分解为反射分量和光照分量,通过去除光照分量影响得到反射分量,增强图像对比度和视觉效果。

本文提出融合 3 种算法的新方法,突破了单一算法去噪增强的局限性。科学地利用各算法原理,先通过高斯和中值滤波去除噪声,再用 Retinex 算法增强图像,解决了多摄像机视频帧图像噪声大、对比度低等影响小目标检测的技术难点。最终,为小目标特征提取提供了质量更高的视频帧图像依据,显著提升了慢速小目标检测精度,在图像处理领域具有较高的学术价值和应用前景。

在高斯滤波、中值滤波与 Retinex 算法融合去噪增强环节,参数设置的合理性至关重要。对于高斯滤波,标准差是关键参数。较小标准差(如 0.5~1.0)的高斯滤波,能较好保留慢速小目标边缘等细节特征,但对高频噪声去除效果有限;较大标准差(如 2.0~3.0)虽可有效平滑图像、去除多种噪声,但易使小目标特征模糊。中值滤波的窗口大小也影响去噪效果,小窗口(如 3×3)对细小噪声敏感,大窗口(如 7×7)去噪强

却可能丢失小目标关键信息。Retinex 算法中, 高斯环绕尺度参数影响光照估计, 合适尺度能提升图像对比度且保留特征。经大量实验, 针对本场景选定特定参数组合, 使算法对高斯噪声、椒盐噪声等不同类型噪声均有较好鲁棒性, 有效为小目标特征提取提供高质量图像。

多摄像机视频帧图像中噪声主要为高斯噪声与椒盐噪声, 设计方法融合高斯滤波算法与中值滤波算法对其进行去除处理, 表达式为:

$$\begin{cases} f'_i(x, y) = \frac{1}{2\pi\sigma^2} \sum_{s=-a}^a \sum_{t=-b}^b f_i(x+s, y+t) \cdot e^{-\frac{s^2+t^2}{2\sigma^2}} \\ g_i(x, y) = \text{median}\{f'_i(x+s, y+t)\} \end{cases} \quad (1)$$

式中,  $f'_i(x, y)$  代表高斯滤波算法应用后输出的第  $i$  个摄像机视频帧图像;  $\sigma$  代表高斯分布的标准差, 其决定了滤波器的平滑程度<sup>[10]</sup>。 $\sigma$  越大, 平滑效果越强, 但视频帧图像也会变得越模糊;  $a$  与  $b$  代表滤波器窗口的大小;  $f_i(x+s, y+t)$  代表原始视频帧图像在坐标  $(x+s, y+t)$  处的像素值;  $g_i(x, y)$  代表中值滤波算法应用后输出的第  $i$  个摄像机视频帧图像;  $\text{median}\{\cdot\}$  代表取中值操作函数;  $f'_i(x+s, y+t)$  代表视频帧图像  $f'_i(x, y)$  在坐标  $(x+s, y+t)$  处的像素值。

以去噪处理后的视频帧图像  $g_i(x, y)$  为基础, 采用 Retinex 算法对其进行增强处理。Retinex 算法是基于人类视觉系统的颜色恒常性理论提出的图像增强算法, 其认为图像可以分解为反射分量和光照分量, 通过去除光照分量的影响, 可以得到反射分量, 从而实现图像质量的增强<sup>[11]</sup>。基于 Retinex 算法的视频帧图像  $g_i(x, y)$  增强公式为:

$$\begin{cases} \hat{g}_i(x, y) = \log_2[g_i(x, y)] - \log_2[F(x, y) \cdot g_i(x, y)] \\ F(x, y) = f'_i(x, y) \lambda e^{-\frac{x^2+y^2}{2\sigma^2}} \end{cases} \quad (2)$$

式中,  $\hat{g}_i(x, y)$  代表视频帧图像  $g_i(x, y)$  增强结果, 即反射分量;  $F(x, y)$  代表高斯环绕函数;  $\lambda$  代表归一化常数, 取值范围为  $0 \sim 1$ ;  $\sigma$  代表高斯环绕函数的标准差, 其决定了 Retinex 算法对光照分量的估计精度。

上述过程通过高斯滤波算法、中值滤波算法与 Retinex 算法的融合应用, 有效地去除了多摄像机视频帧图像的高斯噪声和椒盐噪声, 并增强了多摄像机视频帧图像的对比度和视觉效果, 为小目标特征提取提供质量更高的视频帧图像依据。

## 2 基于 Faster R-CNN 的视频帧图像小目标特征提取

将经过去噪与增强处理后的多摄像机视频帧图像  $\hat{g}_i(x, y)$  作为输入, 利用 Faster R-CNN 中的卷积神经网络中卷积操作和池化操作, 对输入的视频帧图像进行

处理, 旨在解决小目标因像素占比低, 在传统方法中特征难以有效捕捉与提取的难题。利用 Faster R-CNN 强大的特征提取能力。通过卷积操作借助卷积核滑动, 有效捕捉小目标边缘、纹理等局部特征; 池化操作降低分辨率同时增加维度<sup>[12]</sup>, 强化小目标关键信息表达。RPN 网络生成多尺度、多长宽比的锚点, 经分类与回归处理生成候选区域, 分类判断锚点是否含小目标, 回归调整锚点位置大小。在锚点筛选调整中, 提出新的置信度计算公式, 综合考虑交并比、运动速度差、余弦相似度等因素, 更精确定最终候选区域, 利用 RoI Pooling 获取小目标特征向量。特征提取流程如下所示。

步骤一: 视频帧图像输入

将多摄像机视频帧图像  $\hat{g}_i(x, y)$  作为 Faster R-CNN 的输入, 其尺寸大小为  $H \times W \times C$ 。其中,  $H$  代表视频帧图像的高度,  $W$  代表视频帧图像的宽度,  $C$  代表视频帧图像的通道数。

步骤二: 特征图提取

应用 Faster R-CNN 中的卷积神经网络提取多摄像机视频帧图像  $\hat{g}_i(x, y)$  的特征图, 通过卷积操作和池化操作, 逐步降低视频帧图像的空间分辨率, 并增加特征图的维度, 从而提取出具有小目标关键信息的特征图, 表达式为:

$$\begin{cases} G_i(x, y, k) = \sum_{m=0}^{k_h-1} \sum_{n=0}^{k_w-1} \sum_{l=0}^{C-1} \psi_{m, n, l, k} \times \hat{g}_i(x+m, y+n, l) + \beta_k \\ \hat{G}_i(x, y, k) = \max_{0 \leq m < p_h, 0 \leq n < p_w} G_i(x \times \alpha + m, y \times \alpha + n, k) \end{cases} \quad (3)$$

式中,  $G_i(x, y, k)$  代表经过卷积操作获得的多摄像机视频帧图像  $\hat{g}_i(x, y)$  特征图, 即位置  $(x, y)$  处第  $k$  个通道的值;  $k_h$  与  $k_w$  代表卷积核的高度与宽度;  $\psi_{m, n, l, k}$  代表卷积核权重;  $\beta_k$  代表第  $k$  个通道的偏置项;  $\hat{G}_i(x, y, k)$  代表经过池化操作获得的多摄像机视频帧图像  $\hat{g}_i(x, y)$  特征图;  $p_h$  与  $p_w$  代表池化窗口的高度和宽度;  $\alpha$  代表池化操作的步长。

步骤三: 小目标候选区域生成

采用 Faster R-CNN 中的区域建议网络 (RPN) 在多摄像机视频帧图像特征图  $\hat{G}_i(x, y, k)$  上滑动一个小的卷积核, 生成多个锚点, 并对其进行分类与回归处理, 即可生成小目标候选区域 (需要注意的是, 每个锚点对应不同尺度和长宽比的小目标候选区域)<sup>[13]</sup>。设定锚点尺度集合为  $V = \{v_1, v_2, \dots, v_N\}$ , 长宽比集合为  $R = \{r_1, r_2, \dots, r_M\}$ 。对于特征图  $\hat{G}_i(x, y, k)$  上的每个位置  $(x, y)$ , 生成的锚点数量为  $N \times M$ 。锚点的宽度和高度计算公式为:

$$\begin{cases} h_c = \frac{v}{\sqrt{r}} \\ w_c = v \sqrt{r} \end{cases} \quad (4)$$

式中,  $h_c$  与  $w_c$  代表锚点的高度和宽度;  $v$  代表锚点的尺度;  $r$  代表锚点的长宽比。

区域建议网络 (RPN) 的分类任务主要是判断锚点是否包含小目标, 回归任务主要是调整锚点的位置和大小, 使其更准确地包围小目标<sup>[14]</sup>。其中, 分类分支输出一个二分类的分数  $P$ , 代表锚点包含小目标的概率。回归分支输出四个偏移量  $(\Delta_x, \Delta_y, \Delta_h, \Delta_w)$ , 用于调整锚点的位置和大小, 表达式为:

$$\begin{cases} \Delta_x = \frac{x - x_c}{w_c} \\ \Delta_y = \frac{y - y_c}{h_c} \\ \Delta_h = \hat{G}_i(x, y, k) \log_2\left(\frac{w}{w_c}\right) \\ \Delta_w = \hat{G}_i(x, y, k) \log_2\left(\frac{h}{h_c}\right) \end{cases} \quad (5)$$

式中,  $(x, y, h, w)$  代表调整后的小目标候选区域的坐标与大小;  $(x_c, y_c, h_c, w_c)$  代表锚点的坐标和大小。

依据上述分类分数  $P$  与回归偏移量  $(\Delta_x, \Delta_y, \Delta_h, \Delta_w)$ , 对锚点进行筛选和调整, 生成最终的小目标候选区域。其中, 当分类分数  $P$  大于或者等于阈值  $P^*$  时, 认定锚点包含小目标, 对其进行保留操作; 当分类分数  $P$  小于阈值  $P^*$  时, 认定锚点不包含小目标, 对其进行删除操作。然后, 依据回归偏移量  $(\Delta_x, \Delta_y, \Delta_h, \Delta_w)$  对保留锚点进行适当的调整, 并对其置信度进行计算, 表达式为:

$$\chi = \delta_1 \cdot IoU[(x_c, y_c, h_c, w_c)] + \delta_2 \cdot e^{-\|\Delta\|/\tau} + \delta_3 \cdot \text{sim}[\hat{G}_i(x, y, k), \hat{G}_c(x, y, k)] \quad (6)$$

式中,  $\chi$  代表锚点  $(x_c, y_c, h_c, w_c)$  的置信度;  $\delta_1$ 、 $\delta_2$  与  $\delta_3$  代表权重系数, 默认取值为 0.5、0.3 与 0.2;  $IoU[(x_c, y_c, h_c, w_c)]$  代表当前锚点  $(x_c, y_c, h_c, w_c)$  与真实锚点的交并比;  $\Delta$  代表相邻帧小目标运动速度差;  $\tau$  代表温度系数, 主要用于控制运动敏感度, 通常设定为 5;  $\text{sim}[\hat{G}_i(x, y, k), \hat{G}_c(x, y, k)]$  代表当前帧特征图  $\hat{G}_i(x, y, k)$  与参考帧  $\hat{G}_c(x, y, k)$  的余弦相似度。

当公式 (6) 输出结果——置信度  $\chi$  达到最大值时<sup>[15]</sup>, 其锚点对应候选区域即为最终的小目标候选区域, 记为  $(\hat{x}_c, \hat{y}_c, \hat{h}_c, \hat{w}_c)$ 。

#### 步骤四: 小目标特征向量获取

应用 Faster R-CNN 中的感兴趣区域池化 (RoI Pooling) 将小目标候选区域  $(\hat{x}_c, \hat{y}_c, \hat{h}_c, \hat{w}_c)$  映射到特征图  $\hat{G}_i(x, y, k)$  上, 即可获得视频帧图像小目标特征向量提取结果, 表达式为:

$$\bar{G}_i = \chi \Gamma\{(\hat{x}_c, \hat{y}_c, \hat{h}_c, \hat{w}_c), \hat{G}_i(x, y, k)\} \quad (7)$$

式中,  $\bar{G}_i$  代表第  $i$  个摄像机视频帧图像的小目标特征向量;  $\Gamma\{\cdot\}$  代表小目标候选区域映射函数。

上述过程完成了视频帧图像小目标特征的提取, 为

后续小目标特征增强提供一定的便利。

### 3 基于改进 OMP 的小目标特征增强

为解决传统 OMP 算法在小目标特征增强任务中增强效果差、性能不稳定的技术难题, 以上述提取的视频帧图像小目标特征向量  $\bar{G}_i$  为依据, 应用改进 OMP 算法对其进行增强处理。OMP 算法是一种常用的稀疏信号重构算法, 在特征增强领域有着广泛的应用<sup>[16]</sup>。但是, 针对小目标特征增强任务, 传统 OMP 算法存在着增强效果差、性能发挥不稳定等问题, 故设计方法对其进行改进。在改进 OMP 算法中, 引入局部相关性旨在更精准地选择字典原子。通过计算目标区域与字典原子间的局部相似度, 依据局部相关性大小排序, 优先选取与目标局部特征高度匹配的原子, 避免因全局相似度误导而选错原子, 从而提升特征提取的准确性。能量分布则用于提升特征稳定性, 将目标区域能量按空间分布划分, 根据能量集中程度调整原子选择权重, 使能量集中区域的原子更易被选中, 保证特征在不同帧间的稳定性。非线性变换在特征增强中, 通过对提取的特征进行非线性映射, 扩大特征间的差异, 增强特征的区分度, 使原本微弱的特征差异变得明显, 同时抑制噪声干扰, 进一步提升特征的可靠性和可检测性。

以此为基础, 对视频帧图像小目标特征向量  $\bar{G}_i$  进行增强, 本研究创新性地局部相关性和能量分布引入 OMP 算法, 结合非线性变换新技术, 解决了传统算法在小目标特征增强上的不足。新方法能更准确选择字典原子, 减少噪声干扰, 使增强后的小目标特征向量在不同环境和条件下更稳定, 有效提高了小目标特征增强效果, 为后续小目标准确识别和定位提供有力支持, 在理论和实践上都具有创新性和科学性。其具体流程如下所示。

#### 1) 初始化:

对改进 OMP 算法参数进行初始化处理, 主要包括稀疏度、残差、索引集与稀疏系数向量。其中, 根据小目标特征向量  $\bar{G}_i$  的先验知识确定稀疏度  $\kappa$  (即稀疏系数向量  $A$  中非零元素的个数); 初始残差设置为  $\epsilon_0 = \bar{G}_i$ , 表示初始时还没有用任何字典原子来重构小目标特征, 残差就是原始特征向量本身; 索引集主要用于记录每次迭代中选择的字典原子的索引, 初始化结果为  $\Omega_0 = \phi$ ; 稀疏系数向量初始化结果为  $A_0 = 0$ , 即初始时所有系数都为零。

#### 2) 迭代过程:

改进 OMP 算法为了更好地适应小目标特征向量, 在原子选择过程中引入局部相关性和能量分布的考量, 其先对字典原子进行聚类分析, 将字典原子分成若干个局部区域。在每次迭代过程中, 不仅考虑全局内积绝对值, 还考虑原子所在局部区域的平均能量<sup>[17]</sup>。以上述

内容为基础,确定改进OMP算法的原子选择准则,表达式为:

$$j_{\max} = \bar{G}_i \arg \max_{j=1,2,\dots,N_D} \frac{|\langle \varepsilon_{q-1}, d_j \rangle|}{E_{\text{local}}(j)} \quad (8)$$

式中,  $j_{\max}$  代表原子索引;  $N_D$  代表字典  $D$  的原子列数;  $\varepsilon_{q-1}$  代表第  $q-1$  次迭代的残差;  $d_j$  代表字典  $D$  的第  $j$  列原子;  $E_{\text{local}}(j)$  代表原子  $d_j$  所在局部区域的平均能量。

将依据公式(8)选择的原子索引  $j_{\max}$  加入到索引集  $\Omega_q = \Omega_{q-1} \cup \{j_{\max}\}$  中,利用最小二乘法求解稀疏系数向量中对应索引集  $\Omega_q$  的元素。设定  $D_{\Omega_q}$  是由字典  $D$  中索引集  $\Omega_q$  对应的原子组成的子矩阵,则稀疏系数向量中对应索引集  $\Omega_q$  的元素  $A_{\Omega_q}$  可以通过最小化残差  $\| \bar{G}_i - D_{\Omega_q} A_{\Omega_q} \|_2^2$  得到,表达式为:

$$A_{\Omega_q} = (D_{\Omega_q}^T D_{\Omega_q})^{-1} D_{\Omega_q}^T \bar{G}_i \quad (9)$$

需要注意的是,将稀疏系数向量  $A_{\Omega_q}$  中非索引集对应的元素置为零。以公式(9)输出结果为基础,计算新的残差  $\varepsilon_q = \bar{G}_i - D A_{\Omega_q}$  ( $A_{\Omega_q}$  代表第  $q$  次迭代的稀疏系数向量,由  $A_{\Omega_q}$  构成),即用更新后的稀疏系数向量和字典来重构小目标特征向量,然后计算重构误差作为新的残差。

3) 小目标特征向量增强与输出:

经过  $Q$  次迭代后,得到最终的稀疏系数向量  $A_Q$ ,联合字典  $D$  重构小目标特征向量  $G'_i = D A_Q$ 。为了进一步增强小目标特征向量  $G'_i$ ,对其进行非线性变换,其表达式为:

$$\tilde{G}'_i = \frac{A_{\Omega_q}}{1 + e^{-\varphi G'_i}} \quad (10)$$

式中,  $\tilde{G}'_i$  代表增强后的小目标特征向量;  $\varphi$  代表一个控制 Sigmoid 函数斜率的参数。

上述通过改进OMP算法完成了小目标特征向量的增强处理,其在局部相关性和能量分布的考量下,能够更准确地选择与小目标特征相关的字典原子,再加之非线性变换函数的应用,可以增强小目标特征向量的鲁棒性,减少噪声和干扰的影响,使特征向量在不同的环境和条件下更加稳定,从而有效地提高小目标特征向量的增强效果。

#### 4 多摄像机小目标关联与信息融合

针对多摄像机监控场景下,小目标跟踪中单个摄像机因视野范围限制无法完整跟踪小目标运动轨迹,易导致目标丢失的技术难题,提出基于特征向量相似度的小目标关联方法。不同摄像机从不同角度拍摄视频,通过对不同摄像机视频帧图像中的小目标进行关联,将各个摄像机捕捉到的小目标片段连接起来,形成小目标在更大范围内的完整运动轨迹,实现全面跟踪,避免因视野局限导致的目标丢失。对于不同摄像机在同一时间或相近时间拍摄的视频帧图像中的小目标特征向量  $\tilde{G}_i$  与  $\tilde{G}_j$ ,

计算两者之间的相似度,表达式为:

$$\rho_{i,j} = \frac{\tilde{G}'_i \cdot \tilde{G}_j}{\|\tilde{G}'_i\| \|\tilde{G}_j\|} \quad (11)$$

式中,  $\rho_{i,j}$  代表第  $i$  个摄像机视频帧图像的小目标特征向量  $\tilde{G}_i$  与第  $j$  个摄像机视频帧图像的小目标特征向量  $\tilde{G}_j$  的相似度。

以公式(11)计算结果为基础,设定小目标关联规则,具体如下所示:

- 1) 若  $\rho_{i,j}$  大于或者等于阈值  $\rho^*$ , 认定第  $i$  个与第  $j$  个摄像机视频帧图像中的小目标是关联的;
- 2) 若  $\rho_{i,j}$  小于阈值  $\rho^*$ , 认定第  $i$  个与第  $j$  个摄像机视频帧图像中的小目标是非关联的。

对于关联的小目标对,采用加权融合方式对其信息进行融合处理,表达式为:

$$\zeta = \gamma_1 \tilde{G}'_i + \gamma_2 \rho_{i,j} \quad (12)$$

式中,  $\zeta$  代表多摄像机小目标信息融合结果;  $\gamma_1$  与  $\gamma_2$  代表信息融合权重系数。

上述过程将特征向量相似度计算与加权融合技术相结合,解决了多摄像机监控中小目标关联不准确、信息融合不充分的技术难点。能够精准关联不同摄像机中的小目标,并有效融合其信息,形成小目标在更大范围内的完整运动轨迹,为后续慢速动小目标的准确跟踪与检测提供了充足且可靠的数据支撑。

#### 5 慢速动小目标跟踪与检测结果输出

根据多摄像机小目标信息融合结果,得到小目标在初始时刻的状态估计和协方差矩阵。状态估计包含了小目标在初始时刻的位置、速度等信息,协方差矩阵则反映了状态估计的不确定性。在研究深度上,深入剖析卡尔曼滤波、支持向量机等理论在目标跟踪检测中的应用机制,构建了一套完整且精细的跟踪检测与可视化体系。以上述融合的多摄像机小目标信息  $\zeta$  为依据,本节基于多摄像机信息融合结果初始化小目标状态估计与协方差矩阵,为后续跟踪提供精准起点。利用卡尔曼滤波进行小目标跟踪,在状态预测阶段,通过状态转移矩阵和过程噪声协方差矩阵,合理预测小目标状态及不确定性;观测更新时,依据卡尔曼增益计算公式,结合观测矩阵与噪声协方差矩阵,精准计算卡尔曼增益,进而实时更新小目标状态与协方差矩阵,有效解决了慢速动小目标状态估计不准确、跟踪易丢失的难题。具体过程如下所示。

1) 初始化:

根据多摄像机小目标信息融合结果  $\zeta$  得到小目标在初始时刻  $u = 0$  的状态估计  $\hat{X}_{0|0}$  和协方差矩阵  $P_{0|0}$ 。

2) 小目标状态预测:

利用状态转移矩阵  $\eta_u$  对小目标在  $u$  时刻状态进行预测,并计算预测状态的协方差矩阵,表达式为:

$$\begin{cases} \hat{\mathbf{X}}_{u|u-1} = \zeta \boldsymbol{\eta}_u \mathbf{X}_{u-1|u-1} \\ \mathbf{P}_{u|u-1} = \boldsymbol{\eta}_u \mathbf{P}_{u-1|u-1} \boldsymbol{\eta}_u^T + \boldsymbol{\theta}_u \end{cases} \quad (13)$$

式中,  $\hat{\mathbf{X}}_{u|u-1}$  与  $\mathbf{P}_{u|u-1}$  代表  $u$  时刻慢速动小目标状态预测结果及其协方差矩阵;  $\hat{\mathbf{X}}_{u-1|u-1}$  与  $\mathbf{P}_{u-1|u-1}$  代表  $u-1$  时刻慢速动小目标状态预测结果及其协方差矩阵;  $\boldsymbol{\theta}_u$  代表过程噪声的协方差矩阵。

### 3) 观测更新:

依据公式 (13) 输出结果计算卡尔曼增益, 表达式为:

$$\vartheta_u = \mathbf{X}_{u|u-1} \mathbf{P}_{u|u-1} \mathbf{H}_u^T (\mathbf{H}_u \mathbf{P}_{u|u-1} \mathbf{H}_u^T + \boldsymbol{\Psi}_u)^{-1} \quad (14)$$

式中,  $\vartheta_u$  代表  $u$  时刻卡尔曼增益;  $\mathbf{H}_u$  代表观测矩阵;  $\boldsymbol{\Psi}_u$  代表观测噪声的协方差矩阵。

以公式 (14) 计算结果——卡尔曼增益  $\vartheta_u$  为基础, 联合观测向量, 实时对小目标状态及其协方差矩阵进行更新, 表达式为:

$$\begin{cases} \hat{\mathbf{X}}_{u|u} = \hat{\mathbf{X}}_{u|u-1} + \vartheta_u (\mathbf{Z}_u - \mathbf{H}_u \hat{\mathbf{X}}_{u|u-1}) \\ \mathbf{P}_{u|u} = (\mathbf{I} - \boldsymbol{\vartheta}_u \mathbf{H}_u) \mathbf{P}_{u|u-1} \end{cases} \quad (15)$$

式中,  $\hat{\mathbf{X}}_{u|u}$  与  $\mathbf{P}_{u|u}$  代表小目标状态及其协方差矩阵更新结果;  $\mathbf{Z}_u$  代表观测向量;  $\mathbf{I}$  代表单位矩阵。

### 4) 小目标持续跟踪程序制定:

重复迭代进行步骤二~步骤三, 对每一帧视频图像进行小目标状态预测和观测更新, 即可实现对慢速动小目标的持续跟踪<sup>[18]</sup>。

### 5) 慢速动小目标检测结果输出与可视化:

将多摄像机小目标信息融合结果  $\zeta$  输入至支持向量机 (SVM) 中, 通过决策函数即可完成小目标类别的判定, 表达式为:

$$\xi = \hat{\mathbf{X}}_{u|u} \text{sign} \left( \sum_{i=1}^{N_m} \boldsymbol{\mu}_i \xi_i \boldsymbol{\kappa}(\zeta_i, \zeta) + b \right) \quad (16)$$

式中,  $\xi$  代表慢速动小目标类别编号;  $\text{sign}(\cdot)$  代表符号函数;  $\boldsymbol{\mu}_i$  代表拉格朗日乘子向量;  $\zeta_i$  与  $\xi_i$  代表第  $i$  个样本的小目标信息融合结果与类别编号;  $N_m$  代表样本的总数量;  $\boldsymbol{\kappa}(\zeta_i, \zeta)$  代表核矩阵;  $b$  代表偏置项, 可以通过支持向量计算得到。

与此同时, 联合多摄像机小目标信息融合结果  $\zeta$  确定小目标中心坐标及其高度与宽度  $(\hat{x}_c, \hat{y}_c, \hat{h}_c, \hat{w}_c)$ , 并采用可视化技术将检测结果在原始视频帧图像上进行标注和显示, 方便用户直观地了解慢速动小目标的检测情况。慢速动小目标可视化步骤如下所示。

#### 1) 绘制慢速动小目标外接矩形框:

根据小目标位置与大小信息  $(\hat{x}_c, \hat{y}_c, \hat{h}_c, \hat{w}_c)$  在原始视频帧图像上绘制一个矩形框, 将小目标包围起来。矩形框颜色可以根据小目标类别进行区分, 例如车辆使用蓝色矩形框标注、行人使用红色矩形框标注等。

#### 2) 标注慢速动小目标位置和类别信息:

在矩形框的上方或附近位置, 采用文字标注小目标的位置坐标  $(\hat{x}_c, \hat{y}_c)$  和类别信息。需要注意的是, 文字

的颜色应与矩形框颜色形成鲜明对比, 以便用户清晰读取。

#### 3) 显示视频帧:

将标注后的视频帧图像显示在屏幕上, 用户可以通过视频播放的方式直观地观察慢速动小目标的检测和跟踪结果。

综上所述, 通过 Faster R-CNN 与改进 OMP 算法的引入与应用, 设计方法实现了多摄像机监控视频慢速动小目标的有效跟踪和检测, 并对其进行了直观展示, 为用户提供准确、清晰的慢速动小目标信息。

## 6 实验

选取基于视觉 Transformer 和双解码器的慢速动小目标检测方法 (文献 [5] 方法) 与基于上下文增强和特征提纯的慢速动小目标检测方法 (文献 [6] 方法) 作为对照方法 1 与对照方法 2, 联合设计方法共同进行对比实验, 通过实验数据深度分析验证设计方法的应用性能。算法实现的主要步骤如下。

1) 视频帧图像去噪处理: 融合高斯滤波和中值滤波去除多摄像机视频帧图像的高斯与椒盐噪声, 再用 Retinex 算法增强图像对比度;

2) 视频帧图像小目标特征提取: 将去噪增强后的图像输入 Faster R-CNN, 利用卷积、池化、RPN 等操作提取小目标特征向量;

3) 小目标特征增强: 以提取的特征向量为依据, 用改进 OMP 算法通过初始化参数、迭代确定原子选择准则等增强小目标特征向量鲁棒性;

4) 多摄像机小目标关联: 计算不同摄像机视频帧中小目标特征向量相似度, 依设定规则判定小目标是否关联;

5) 多摄像机小目标信息融合: 对关联小目标信息采用加权融合, 形成其在更大范围的完整运动轨迹;

6) 慢速动小目标跟踪初始化: 根据信息融合结果得到小目标初始状态估计和协方差矩阵, 为跟踪提供起点;

7) 小目标状态预测: 利用状态转移矩阵预测小目标状态并计算协方差矩阵;

8) 观测更新: 依据状态预测结果计算卡尔曼增益, 联合观测向量更新小目标状态及协方差矩阵;

9) 小目标持续跟踪: 重复状态预测和观测更新步骤, 实现对慢速动小目标的持续跟踪;

10) 慢速动小目标检测结果输出与可视化: 将融合结果输入 SVM 判定类别, 确定目标信息并可视化显示标注后的视频帧图像。

### 6.1 实验数据集构建

从 PETS2009、EPFL Campus Dataset、DukeMT-MC、BrnoCompSpeed 等公开数据集中随机抽取多个慢

速动小目标样本,以此为基础,构建实验数据集,具体如表 1 所示。

表 1 实验数据集示意图

数据集	训练集	验证集	测试集
行人样本数量/个	785	452	235
车辆样本数量/个	695	362	125
交通标志样本数量/个	712	312	169
无人机样本数量/个	700	302	263
昆虫样本数量/个	612	415	251
小型舰艇样本数量/个	685	402	241
首饰样本数量/个	677	410	247
纽扣样本数量/个	701	477	215
药片样本数量/个	735	370	233
建筑物样本数量/个	754	366	201
总样本数量/个	7 056	3 868	2 180
平均噪声水平/dB	45.12	36.25	38.45

在实验数据集构建中,所选样本具备充分多样性与覆盖性。数据集中涵盖行人、车辆、交通标志等众多慢速小目标种类,能模拟实际监控中的多元目标场景。运动速度范围设定贴合慢速小目标特性,可反映不同运动状态。同时,样本取自多个公开数据集,包含不同场景复杂度,如校园、公路等,有效模拟了实际监控中复杂多变的环境,充分证明了该数据集对实际应用场景具有良好代表性。

## 6.2 视频帧图像检测质量分析

在实验数据集中随机抽取 14 幅视频帧图像作为实验对象,应用设计方法、对照方法 1 与对照方法 2 对其进行去噪与增强,通过对比度来评估视频帧图像质量,如图 1 所示。




图 1 视频帧图像对比度示意图

相较于对照方法 1 与对照方法 2 来看,设计方法应用后视频帧图像对比度显著更大,其最大值达到了 1.9。这主要是因为设计方法融合了高斯滤波算法、中值滤波算法与 Retinex 算法对视频帧图像进行预处理。其中,高斯滤波算法通过对视频帧图像中每个像素点及其邻域像素进行加权平均运算,有效地抑制了高斯噪声,从而提高了视频帧图像质量;中值滤波算法通过取邻域内像素值的中值来替换中心像素点的值,有效地抑

制了椒盐噪声,使得视频帧图像的亮度分布更加均匀,减少了噪声对对比度的扭曲,让视频帧图像更加清晰,进一步提升了视频帧图像质量;Retinex 算法是将视频帧图像分解为反射分量和照明分量,通过对这两个分量的处理来改善视频帧图像的视觉效果,从而有效增强视频帧图像的饱和度和对比度。由此可见,设计方法通过高斯滤波算法、中值滤波算法与 Retinex 算法的融合应用,对其噪声进行了有效的抑制,进而显著提高了视频帧图像的对比度,充分证实设计方法视频帧图像处理效果更佳。

## 6.3 视频帧图像小目标特征提取性能分析

在实验数据集中随机抽取一幅视频帧图像作为实验对象,应用设计方法、对照方法 1 与对照方法 2 对其小目标特征进行提取,通过小目标候选区域(锚点框)来显示应用方法的特征提取性能,如图 2 所示。



图 2 小目标候选区域(锚点框)示意图

设计方法应用后小目标候选区域(锚点框)能够包围全部小目标,并且内部干扰信息较少;而对照方法 1 与对照方法 2 应用后小目标候选区域(锚点框)并不能完全包围全部小目标,并且内部干扰信息较多。这主要是因为设计方法选用了 Faster R-CNN 来提取视频帧图像小目标特征,其骨干网络为卷积神经网络,具备强大的特征提取能力,能够精准地提取视频帧图像特征图,再利用 RPN 能够高效地生成大量可能包含小目标的候选区域(锚点框),利用检测网络对候选区域进行进一步的分类和回归,确定候选区域是否包含小目标,从而确定最终的小目标候选区域(锚点框),确保锚点框能够紧密包围小目标,减少内部干扰信息。

## 6.4 小目标特征增强效果评估与分析

应用设计方法、对照方法 1 与对照方法 2 对小目标特征进行增强处理,通过小目标特征重构误差来显示小目标特征增强效果,如图 3 所示。

设计方法应用后小目标特征重构误差显著低于对照方法 1 与对照方法 2,其最小值达到了 0.4%。设计方法应用改进 OMP 算法对小目标特征进行增强处理,其在每次迭代中,不再单纯依据与残差的内积大小选择原子,而是综合考量原子与小目标特征的相似度以及原子




图 3 小目标特征重构误差示意图

之间的冗余度。通过引入相似度权重和冗余度惩罚项，使得改进 OMP 算法更倾向于选择那些对小目标特征贡献大且彼此之间相关性小的原子。与此同时，改进 OMP 算法对迭代终止条件进行了调整。根据小目标特征的特点，设定了一个动态的残差阈值。当残差小于该阈值时，算法停止迭代。此阈值并非固定不变，而是根据小目标在图像中的尺寸、亮度等因素自适应调整，既能保证小目标特征的重构精度，又能避免过度迭代导致的计算资源浪费，从而显著地降低了设计方法的小目标特征重构误差，最小值达到 0.4%，远优于对照方法。

6.5 慢速动小目标检测性能分析

应用设计方法、对照方法 1 与对照方法 2 进行慢速动小目标检测实验，其检测结果如图 4 所示。




图 4 慢速动小目标检测结果示意图

设计方法获得的慢速动小目标检测结果与实际检测结果一致，而对照方法 1 与对照方法 2 获得的慢速动小目标检测结果与实际检测结果存在着一定的偏差，例如对照方法 1 中的右侧行人 (35, 9) 和左下方行人 (3, 3)，和对照方法 2 中右侧车辆 (38, 19) 和左下方第 2 个行人 (10, 5)。这主要是因为设计方法基于卡尔曼滤波对慢速动小目标进行跟踪与检测，通过建立小目标的状态方程和观测方程，对小目标的状态进行实时估计和预测。在慢速动小目标检测中，设计方法首先利用初始帧信息对小目标的位置、高度、宽度等状态进行初始化。随着视频帧的推进，卡尔曼滤波根据前一帧的小目

标状态预测当前帧的小目标位置，并结合当前帧的观测值进行更新。此种预测—更新机制使得设计方法能够动态跟踪慢速动小目标的运动轨迹，并结合支持向量机 (SVM) 对小目标类别进行了精准的判定，从而有效提升了设计方法的慢速动小目标检测精度。

为了全面评估设计方法、对照方法 1 与对照方法 2 的性能，进一步设计实验对算法运行时间、硬件需求进行评估，并分析在实际监控系统中的可行性，结果如表 2 所示。

表 2 不同方法的运行时间测试

评估指标	设计方法	对照方法 1	对照方法 2
算法运行时间/(ms/帧)	85	120	105
CPU 占用率/%	45	60	55
GPU 占用率/%	30	40	35
改进 OMP 算法平均迭代次数	12	—	—
改进 OMP 算法平均收敛时间/ms	15	—	—

由表 2 可知，设计方法的算法运行时间相对较短，CPU 和 GPU 占用率也相对较低。这表明设计方法在硬件资源有限的实际监控系统中具有更好的适用性，能够在保证检测精度的同时，减少对系统资源的占用。

7 结束语

慢速动小目标检测是现今计算机视觉领域主要研究课题之一，其难点源于慢速动小目标自身特性、环境复杂性等多维度因素的耦合作用。在多摄像机监控系统实际运行过程中，慢速动小目标像素占比通常低于 0.1%，运动速度低于 5 像素/帧，并且还会受到遮挡干扰、光照变化、多视角几何畸变等因素的影响，致使其检测难度与挑战巨大。从物理层面出发，慢速运动使得小目标在相邻帧间位移量小于噪声阈值，传统方法无法有效区分慢速动小目标与传感器噪声。此外，小目标像素覆盖度极小，使其携带的特征极度稀疏，对特征提取性能提出了更高的要求，而传统方法使用的下采样操作会导致特征图中小目标响应消失，进而影响慢速动小目标的检测效果。因此，提出改进 OMP 算法下多摄像机慢速动小目标增强检测方法。实验结果显示：设计方法显著提升了视频帧图像对比度，视频帧图像小目标特征提取性能与慢速动小目标检测精度，并降低了小目标特征重构误差，为相关研究提供一定的借鉴与参考。

参考文献：

[1] 张志豪, 厉小润, 陈淑涵. 基于改进 YOLO11 的无人机航拍图像小目标检测算法 [J]. 液晶与显示, 2025, 40 (6): 915-930.

[2] 陈海永, 刘博洋, 晏行伟. 基于 YOLO-SCAT 的可见光

- 图像无人机小目标检测算法 [J]. 应用光学, 2025, 46 (3): 505-514.
- [3] 张世豪, 董 雷, 赵昀杰. 基于 YOLOX 的小麦穗旋转目标检测 [J]. 江苏农业科学, 2024, 52 (20): 157-164.
- [4] 宋志勇, 许云涛. 基于多普勒与微多普勒联合利用的弱小目标检测与估计方法 [J]. 电子与信息学报, 2023, 45 (11): 4083-4091.
- [5] 代少升, 刘科生, 黄 炼, 等. 基于视觉 Transformer 和双解码器的红外小目标检测方法 [J]. 红外技术, 2024, 46 (9): 1070-1080.
- [6] 肖进胜, 赵 陶, 周 剑, 等. 基于上下文增强和特征提纯的小目标检测网络 [J]. 计算机研究与发展, 2023, 60 (2): 465-474.
- [7] 张 鹏, 石丽芬, 陈子阳, 等. 基于多层卷积融合的红外小目标检测算法 [J]. 激光与光电子学进展, 2024, 61 (16): 204-213.
- [8] 刘 赏, 周煜炜, 代 尧, 等. 融合注意力和上下文信息的遥感图像小目标检测算法 [J]. 计算机应用, 2025, 45 (1): 292-300.
- [9] 马丽娟, 黄 勇, 李艳翠. 基于机器学习的低信噪比图像序列小目标检测 [J]. 计算机仿真, 2023, 40 (10): 219-223.
- [10] 赵 迪, 行鸿彦, 王海峰, 等. 基于 SAE-GA-XGBoost 算法的海面小目标检测 [J]. 雷达科学与技术, 2023, 23 (9): 81-90.
- (上接第 40 页)
- [2] 邵宇鹰, 王 泉, 彭 鹏, 等. 基于波束形成算法的干式变压器异响定位装置研制及应用 [J]. 高压电器, 2022, 58 (5): 187-194.
- [3] 包海龙, 邵宇鹰, 王 泉, 等. 基于反卷积波束形成算法的干式变压器异响故障识别技术 [J]. 中国电力, 2022, 55 (2): 90-97.
- [4] 李红岩, 张豪杰, 荣 相, 等. 矿用干式变压器故障诊断和寿命预测技术现状及展望 [J]. 煤炭工程, 2024, 56 (2): 146-151.
- [5] 高煦轲, 秦 超, 高 讽, 等. 基于 LSTM-GMM 的配电干式变压器绕组故障双参数预警模型 [J]. 科学技术与工程, 2024, 24 (31): 13407-13414.
- [6] 秦剑华, 刘 洋, 杨景刚, 等. 电力电缆局放及温度的多维度检测方法研究 [J]. 电测与仪表, 2023, 60 (3): 92-96.
- [7] 钱庆林, 孙炜昊, 王 真, 等. 基于非线性尺度空间与极坐标分布熵的 GIS 局放特征提取方法 [J]. 电网技术, 2024, 48 (8): 3525-3533.
- [8] 张轩瑞, 王昊天, 胡一丹, 等. 电力变压器振荡型雷电冲击耐压试验及局部放电检测技术 [J]. 高电压技术, 2023, 49 (12): 5032-5041.
- [9] 罗传仙, 张 民, 程 林, 等. 基于声电联合传感阵列的变压器局部放电诊断技术研究 [J]. 电网与清洁能源, 2023, 39 (9): 81-90.
- [10] 姜红花, 杨祥海, 丁睿柔, 等. 基于改进 ResNet18 的苹果叶部病害多分类算法研究 [J]. 农业机械学报, 2023, 54 (4): 295-303.
- [11] 刘芳军, 李 玥, 武 凌, 等. 基于改进 ResNet18 的胡麻干旱胁迫识别与分类研究 [J]. 江西农业大学学报, 2023, 45 (6): 1517-1527.
- [12] 袁思邈, 方 春, 孙福振. 基于改进残差网络的热轧带钢表面缺陷研究 [J]. 计算机仿真, 2022, 39 (7): 243-247.
- [13] 张 寒, 熊 云, 唐 信, 等. 声纹信号一图形差分场增强和多头自注意力机制的变压器工作状态辨识方法 [J]. 应用声学, 2024, 43 (1): 119-130.
- [14] 万可力, 马宏忠, 崔佳嘉, 等. 基于 Mel-GADF 与 ConvNeXt-T 的变压器铁心松动故障诊断方法 [J]. 电力自动化设备, 2024, 44 (3): 217-224.
- [15] 闫泽玉, 杨 洋, 刘云鹏, 等. 基于神经监督决策树算法的多感知 GIS 局部放电识别 [J]. 中国电机工程学报, 2024, 44 (14): 5821-5832.
- [16] 王琼苑, 褚继峰, 李秋霖, 等. 基于微型气体传感阵列的空气绝缘设备放电故障识别 [J]. 电工技术学报, 2023, 38 (23): 6494-6502.
- [17] 张晓新, 刘莹莹, 林 峰, 等. 基于特高频法的开关柜局放监测系统研究 [J]. 电力电子技术, 2023, 57 (6): 42-45.