

文章编号 1004-924X(2016)11-2855-08

## 基于张量低秩分解和稀疏表示的 红外微小气体泄漏检测

隋中山<sup>1\*</sup>, 李俊山<sup>1</sup>, 张 姣<sup>1</sup>, 隋晓斐<sup>2</sup>

(1. 火箭军工程大学, 信息工程系, 陕西 西安 710025;

2. 96618 部队, 北京 100085)

**摘要:** 为了检测石化工业生产过程中微小气体的泄漏, 提出了一种应用红外成像技术的单帧红外小目标检测方法。研究了低秩稀疏分解理论和稀疏表示理论, 并提出了一种新的基于张量低秩分解和稀疏表示的小目标检测方法。该方法基于张量分解的形式充分发掘背景矩阵所包含的信息; 利用先验知识构造微小气体泄漏的目标字典; 同时利用背景的低秩约束和小目标的稀疏表示约束分解出微小气体的泄漏目标。最后基于非精确增广拉格朗日乘子法 (IALM), 对本文算法进行最优化求解, 并通过实验分析比较了本文方法和已有方法的优缺点。结果表明: 本文方法的检测效果优于其他已有方法, 并且具有较好的 ROC (受试者工作特征) 曲线, 可以满足工业生产中微小气体泄漏检测的要求。

**关键词:** 计算机视觉; 红外检测; 泄漏检测; 张量低秩分解; 稀疏表示; 红外成像

**中图分类号:** TP391.4; TN215 **文献标识码:** A **doi:** 10.3788/OPE.20162411.2855

## Micro gas leakage detection based on tensor low rank decomposition and sparse representation from infrared images

SUI Zhong-shan<sup>1\*</sup>, LI Jun-shan<sup>1</sup>, ZHANG jiao<sup>1</sup>, SUI Xiao-fei<sup>2</sup>

(1. Department of Information Engineering,

Rocket Force University of Engineering, Xi'an 710025, China;

2. Unit 96618, the Chinese People's Liberation Army, Beijing 100085, China)

\* Corresponding author, E-mail: zclszs@163.com

**Abstract:** To detect the micro gas leakage in petrochemical production, a single-frame small target detection method was proposed by using infrared images. The low-rank sparse decomposition theory and sparse representation theory were researched and an innovative method to detect a micro-target was proposed based on tensor low-rank decomposition and sparse representation. The tensor decomposition form was employed in exploiting the information contained in background matrices, The priori knowledge was used to construct a micro gas leakage target dictionary, meanwhile, the micro-gas leakage targets were decomposed by low-rank constraint in the background and sparse representation in the micro-target. Finally, the algorithm was solved optimally by using Inexact Augmented Lagrange Multiplier (IALM) method and its merits were compared with that of common

收稿日期: 2016-07-11; 修订日期: 2016-08-12.

基金项目: 国家自然科学基金资助项目 (No. 61175120)

methods. The results indicate that the proposed algorithm has better detection efficiency than that of common methods and it shows better ROC (Receiver Operating Characteristics) curves. It concludes that these results meet the requirements of micro gas leakage detection during industrial productions.

**Key words:** computer vision; infrared detection; leakage detection; tensor low-rank decomposition; sparse representation; infrared imaging

## 1 引言

石化工业中很多中间或最终产品都是气体,这些气体大部分是无色透明的且易发生泄漏,易造成重大安全事故。目前,传统的石化工业泄漏气体的检测方式大都基于化学方法。近年来,红外成像技术不断进步,红外成像设备成本逐渐降低,使得利用红外图像处理 and 计算机视觉原理进行气体泄漏的自动检测已经成为可能。自然界中一切温度高于绝对零度的物体都在不停地发射红外辐射,而且基于此可进行热红外成像,在热红外图像中不同的亮度区域代表不同的温度区域。在石化工业的生产过程中,工业气体的温度一般与周边自然环境有较大区别,则当管道或者容器存在微小泄漏时,泄漏点的温度将与周边温度明显不同。在红外图像中,微小气体本身的形状和内部结构很难体现出来,但是它与周围环境之间的温度差而产生的亮度差则很明显。因此可以将微小气体检测问题归为红外小目标检测问题,小目标是指在图像中所占像素较少,内部结构和外部轮廓均不明显的目标<sup>[1-2]</sup>。

目前红外小目标检测主要分为两类:基于单帧图像的方法和基于图像序列的方法。就本文研究背景而言,气体泄漏位置在视频序列中不会发生变化,所以基于图像序列的方法并不适用。因此本文将重点研究基于单帧图像的红外小目标检测算法。该算法主要分为 3 种:滤波方法<sup>[3-4]</sup>、基于人眼视觉注意机制的显著性检测方法<sup>[5-6]</sup>、基于成分表达和字典学习的方法<sup>[7-9]</sup>。滤波方法在局部信噪较低、频率特性不显著的情况下误警率比较高;显著性检测方法的理论基础尚待进一步完善且结果相对不稳定;基于成分表达和字典学习的方法结果较为稳定、效果较好,近年来越来越受到重视。

## 2 相关方法和理论

### 2.1 低秩稀疏分解

低秩稀疏分解方法在前景检测领域已经取得了重要进展<sup>[10-12]</sup>。图像构成的矩阵可以分解成低秩矩阵代表的背景和稀疏矩阵代表的前景对象。它可以表示如下:

$$\mathbf{D} = \mathbf{L} + \mathbf{S}, \quad (1)$$

其中:  $\mathbf{D} \in \mathbf{R}^{m \times n}$  是所观察到的图像,当然  $\mathbf{D}$  必须满足非局部自相似性的条件, $\mathbf{L}$  和  $\mathbf{S}$  分别表示背景和前景。基于主成分追踪 (Principal Component Pursuit, PCP) 的鲁棒主成分分析 (Robust Principal Component Analysis, RPCA) 首次提出用  $l_1$ -范数来约束前景矩阵,因为它们是包含一小部分非零元素的稀疏矩阵,并且假设背景图像线性相关,从而形成低秩矩阵  $\mathbf{L}$ 。这个矩阵分解可以通过以下凸优化解决:

$$\min_{\mathbf{L}, \mathbf{S}} \|\mathbf{L}\|_* + \lambda \|\mathbf{S}\|_1 \quad \text{s. t.} \quad \mathbf{D} = \mathbf{L} + \mathbf{S}, \quad (2)$$

其中:  $\|\mathbf{L}\|_*$  是矩阵  $\mathbf{L}$  的核范数,是其奇异值的总和,  $\|\mathbf{S}\|_1$  表示  $\mathbf{S}$  的  $l_1$ -范数。 $\lambda$  为一个正的系数。

以上为低秩稀疏分解的基本形式,随后又发展出多种不同形式:IRPCA (Inductive Robust Principal Component Analysis)、低秩表示 (Low-Rank Representation, LRR)、LatLRR (Latent Low-Rank Representation) 等方法。其中 LRR 方法应用较为广泛,因为它可以处理背景数据来自多个不同子空间的情况,其核心思想是找到一个低秩表达矩阵  $\mathbf{V} = [\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_n] \in \mathbf{R}^{n \times n}$ , 它可以将数据向量用数据字典  $\mathbf{A}$  的基的线性组合表达出来,如果将原始数据  $\mathbf{D}$  直接作为数据字典 (即  $\mathbf{A} = \mathbf{D}$ ), 则 LRR 方法可以用下列最优化问题表示:

$$\min_{\mathbf{V}, \mathbf{S}} \|\mathbf{V}\|_* + \lambda \|\mathbf{S}\|_{2,1} \quad \text{s. t.} \quad \mathbf{D} = \mathbf{A}\mathbf{V} + \mathbf{S}, \mathbf{A} = \mathbf{D}. \quad (3)$$

当然 LRR 方法也存在一些缺点如:LRR 方法在恢复或分割数据时会丢失原始数据矩阵列方向上包含的信息;LRR 方法要求原始数据  $\mathbf{D}$  必须包含足够多的纯净信息,但这在现实生活中是较难满足的。

## 2.2 稀疏表示

生物学家的研究成果显示,哺乳类动物通过视觉神经能快速、准确、低耗地对自然景物成像,其核心在于它们感知视觉信息时,只使用视觉皮层中少量神经元即可完成,即视觉信息可以用少量的神经元进行稀疏表示。从信号处理角度看,即信号可以表示为字典中少量原子的线性组合。在图像处理应用的过程中,其表达形式如下:

$$\mathbf{T} = \mathbf{O}\mathbf{H}, \quad (4)$$

其中: $\mathbf{O} = \{o_1, o_2, \dots, o_p\} \in \mathbf{R}^{q \times p}$  为字典矩阵,每一列  $o_i$  为字典原子,若满足  $p \gg q$ , 则  $\mathbf{O}$  为超完备字典; $\mathbf{H}$  为稀疏表示系数矩阵,且必须满足  $\|\mathbf{H}\|_0 < \gamma$ ,  $\gamma$  为一较小常数。其结果可以通过将  $\|\mathbf{H}\|_0$  松弛为  $\|\mathbf{H}\|_1$  来求解。

## 2.3 低秩稀疏分解和稀疏表示的融合

目前,有研究者尝试在一定条件下对两种方法进行融合。他们利用背景的低秩特性,同时构造字典对前景的稀疏表达。针对红外小目标检测,将 LRR 和稀疏表示的方法相融合,如下所示:

$$\mathbf{D} = \mathbf{D}\mathbf{V} + \mathbf{O}\mathbf{H}, \quad (5)$$

其中: $\mathbf{D}$  为原始数据, $\mathbf{O}$  为红外小目标超完备字典,需要先行构造,且对算法性能影响较大。这个矩阵分解可以通过以下凸优化解决:

$$\min_{\mathbf{V}, \mathbf{H}} \|\mathbf{V}\|_* + \lambda \|\mathbf{H}\|_1 \quad \text{s. t.} \quad \mathbf{D} = \mathbf{D}\mathbf{V} + \mathbf{O}\mathbf{H}. \quad (6)$$

虽然融合方法在性能和效果上有一定提升,但是原始 LRR 方法的一些缺陷仍然没有解决,因此本文将对其进行改进。

## 3 张量低秩分解和稀疏表示

### 3.1 张量低秩分解和稀疏表示

LRR 方法是沿着原始数据矩阵的行方向恢复数据的,所以列方向上的信息将丢失。为了能同时利用行信息和列信息,本文引入张量的表示形式。寻求一个三阶张量的表达形式  $\mathbf{UDV}$  来代

替 LRR 方法中的低秩部分  $\mathbf{DV}$ , 那么张量低秩分解和稀疏表示融合的表达形式为:

$$\mathbf{D} = \mathbf{UDV} + \mathbf{O}\mathbf{H}, \quad (7)$$

其中: $\mathbf{D}$  为原始数据, $\mathbf{U}$  为一个低秩投影矩阵, $\mathbf{V}$  为一个低秩表示矩阵, $\mathbf{O}$  为红外小目标超完备字典, $\mathbf{H}$  为一个稀疏的系数矩阵,即须满足  $\|\mathbf{H}\|_0 < \gamma$ ,  $\gamma$  为一较小常数。为了完成式(7)所示的分解,结合所须条件,需要实现下列目标:

$$\min_{\mathbf{U}, \mathbf{V}, \mathbf{H}} \text{rank}(\mathbf{U}) + \text{rank}(\mathbf{V}) + \lambda \|\mathbf{H}\|_0, \quad \text{s. t.} \quad \mathbf{D} = \mathbf{UDV} + \mathbf{O}\mathbf{H}. \quad (8)$$

对式(8)进行松弛,结果如下:

$$\min_{\mathbf{U}, \mathbf{V}, \mathbf{H}} \|\mathbf{U}\|_* + \|\mathbf{V}\|_* + \lambda \|\mathbf{H}\|_1 \quad \text{s. t.} \quad \mathbf{D} = \mathbf{UDV} + \mathbf{O}\mathbf{H}. \quad (9)$$

### 3.2 最优化求解

本文采用非精确增广拉格朗日乘子 (IALM) 方法进行最优化求解,首先引入两个辅助变量  $\mathbf{J}$ ,  $\mathbf{K}$ , 将式(9)转变为下式:

$$\min_{\mathbf{U}, \mathbf{V}, \mathbf{H}, \mathbf{J}, \mathbf{K}} \|\mathbf{J}\|_* + \|\mathbf{K}\|_* + \lambda \|\mathbf{H}\|_1 \quad \text{s. t.} \quad \mathbf{D} = \mathbf{X}\mathbf{V} + \mathbf{O}\mathbf{H}, \mathbf{X} = \mathbf{U}\mathbf{D}, \mathbf{U} = \mathbf{J}, \mathbf{V} = \mathbf{K}. \quad (10)$$

其增广拉格朗日方程为:

$$\begin{aligned} L(\mathbf{U}, \mathbf{V}, \mathbf{H}, \mathbf{J}, \mathbf{K}, Y_1, Y_2, Y_3) = & \|\mathbf{J}\|_* + \|\mathbf{K}\|_* + \lambda \|\mathbf{H}\|_1 + \\ & \langle Y_1, \mathbf{D} - \mathbf{U}\mathbf{D}\mathbf{V} - \mathbf{O}\mathbf{H} \rangle + \langle Y_2, \mathbf{U} - \mathbf{J} \rangle + \langle Y_3, \mathbf{V} - \mathbf{K} \rangle + \\ & \frac{\mu}{2} (\|\mathbf{D} - \mathbf{U}\mathbf{D}\mathbf{V} - \mathbf{O}\mathbf{H}\|_F^2 + \|\mathbf{U} - \mathbf{J}\|_F^2 + \|\mathbf{V} - \mathbf{K}\|_F^2), \end{aligned} \quad (11)$$

其中: $Y_1, Y_2, Y_3$  是拉格朗日乘子,  $\mu$  为惩罚因子 ( $\mu > 0$ )。

其具体求解步骤为:

(1) 初始化:输入原始数据,对各变量赋初值,设定误差。

(2) 固定其他变量更新  $\mathbf{J}$ :

$$\begin{aligned} \mathbf{J} = \arg\min \|\mathbf{J}\|_* + \langle Y_2, \mathbf{U} - \mathbf{J} \rangle + \frac{\mu}{2} \|\mathbf{U} - \mathbf{J}\|_F^2 = \\ \arg\min \frac{1}{\mu} \|\mathbf{J}\|_* + \frac{1}{2} \left\| \mathbf{J} - \left[ \mathbf{U} + \frac{Y_2}{\mu} \right] \right\|_F^2. \end{aligned} \quad (12)$$

式(12)的解可由奇异值收缩算子  $\text{SVT}_\mu \left[ \mathbf{U} + \frac{Y_2}{\mu} \right]$  获得,奇异值收缩算子的具体公式为:

$$SVT_{\mu}(Y) = P \text{diag}[(\delta - \mu)_+] Q$$

$$(\delta - \mu)_+ = \begin{cases} \delta - \mu, & \delta > \mu \\ 0, & \delta \leq \mu \end{cases}, \quad (13)$$

其中:  $P, Q, \delta$  由  $Y$  的奇异值分解获得, 即  $Y = P\Sigma Q, \Sigma = \text{diag}(\delta)$ 。

(3) 固定其他变量更新  $K$ :

$$K = \text{argmin} \|K\|_* + \langle Y_3, V - K \rangle + \frac{\mu}{2} \|V - K\|_F^2 =$$

$$\text{argmin} \frac{1}{\mu} \|K\|_* + \frac{1}{2} \left\| K - \left[ V + \frac{Y_3}{\mu} \right] \right\|_F^2. \quad (14)$$

式(14)的求解方法与式(12)相同。

(4) 固定其他变量, 更新  $H$ :

$$H = \text{argmin} \beta \|H\|_1 + \langle Y_1, D - UDV - OH \rangle +$$

$$\frac{\mu}{2} \|D - UDV - OH\|_F^2 = \text{argmin} \frac{\beta}{\mu} \|H\|_1 +$$

$$\frac{1}{2} \left\| OH - D - UDV + \frac{Y_1}{\mu} \right\|_F^2. \quad (15)$$

式(15)的解可以通过二次最小代价流的方法获得。

(5) 固定其他变量更新  $U$ :

$$\text{令 } \partial L(U, V, H, J, K, Y_1, Y_2, Y_3) / \partial U = 0,$$

求得:

$$U = \left[ \frac{1}{\mu} (Y_1 V^T D^T - Y_2) + (D - OH) V^T D^T + J \right] \cdot$$

$$(D V V^T D^T + I)^{-1}. \quad (16)$$

(6) 固定其他变量更新  $V$ :

$$\text{令 } \partial L(U, V, S, E, J, K, Y_1, Y_2, Y_3) / \partial V = 0,$$

求得:

$$V = (D^T U^T U D + I)^{-1} \cdot$$

$$\left[ \frac{1}{\mu} (D^T U^T Y_1 - Y_3) + D^T U^T (D - OH) + K \right]. \quad (17)$$

(7) 更新拉格朗日乘子  $Y_1, Y_2, Y_3$ :

$$Y_1 = Y_1 + \mu(D - UDV - OH), \quad (18)$$

$$Y_2 = Y_2 + \mu(U - J), \quad (19)$$

$$Y_3 = Y_3 + \mu(V - K). \quad (20)$$

(8) 更新参数  $\mu$ :

$$\mu = \min(\kappa\mu, \mu_{\max}), \quad (21)$$

其中:  $\kappa$  为更新步长且  $\kappa > 1$ ,  $\mu_{\max}$  为指定的  $\mu$  的上限。

(9) 判断是否达到收敛条件:

$$\|D - UDV - OH\|_{\infty} < \epsilon,$$

$$\|U - J\|_{\infty} < \epsilon, \|V - K\|_{\infty} < \epsilon, \quad (22)$$

其中  $\epsilon$  为误差。

当达到收敛条件时算法结束, 否则重复步骤(2)~(9)。

### 3.3 算法分析

本文方法相对于第 2 节介绍的已有方法的最大优点在于算法在恢复背景数据矩阵(UDV)是从行(V)和列(U)两个方向同时进行计算的, 因此本文算法可以同时利用行方向和列方向上的信息进行恢复; 其次, 本文算法将背景的低秩约束和小目标的稀疏表示约束相结合, 传统的低秩分解重点对背景进行约束, 本文算法则可以更好地突出前景小目标的重要性, 也更适合于本文应用背景。本文算法的复杂度为  $O(m^2 n + n^3)$ , 较为复杂, 在实时性要求较高的场景中应用还存在一定困难。

## 4 张量低秩分解和稀疏表示的红外微小气体泄漏检测算法

利用第 3 节提出的方法进行泄漏检测, 其基本步骤如图 1 所示。




图 1 张量低秩分解和稀疏表示的红外微小气体泄漏检测算法

Fig. 1 Micro gas leakage detection algorithm based on tensor low rank decomposition and sparse representation

### 4.1 构造微小气体泄漏超完备字典

超完备字典的选择与构造是一个基础且关键的问题, 影响着算法的最终效果。利用大量真实样本进行字典学习和更新能取得最佳效果, 但是在本文实验条件下很难获得足够数量的泄漏样本。现实中发生泄漏时, 泄漏中心点往往是温度的极值点(低温气体泄漏对应温度最低点, 高温气

体泄漏对应温度最高点)。以高温气体为例,当泄漏发生时,泄漏中心点的温度最高,往四周扩散时逐渐降低。体现在红外图像上即是泄漏中心点亮度最高,往四周逐渐降低。因此本文选择二维高斯模型(如式(23)所示)对微小气体泄漏进行建模,通过调节模型中的参数,生成一系列样本图像,继而构成微小气体泄漏超完备目标字典:

$$P(i, j) = I_{\max} \exp \left\{ -\frac{1}{2} \left[ \frac{(x-x_0)^2}{\sigma_x^2} + \frac{(y-y_0)^2}{\sigma_y^2} \right] \right\}$$

$$\text{s. t. } \alpha < \frac{I_{\max}}{\sigma_x}, \frac{I_{\max}}{\sigma_y} < \beta, \quad (23)$$

其中:  $(i, j)$  为图像点的坐标;  $I_{\max}$  是泄漏中心点的亮度值;  $(x_0, y_0)$  是泄漏中心点坐标;  $\sigma_x$  和  $\sigma_y$  分别为水平散布参数和垂直散布参数。通过调节  $I_{\max}, (x_0, y_0), \sigma_x$  和  $\sigma_y$  4 个参数,即可获得不同形状,不同中心点位置,不同亮度的气体泄漏样本图像。 $\alpha, \beta$  表示  $I_{\max}$  和  $\sigma_x, \sigma_y$  的约束关系。最后将得到的  $k \times k$  气体泄漏样本图像按列展开成  $k^2$  维向量并组合成字典矩阵  $\mathbf{O} = \{o_1, o_2, \dots, o_p\} \in \mathbf{R}^{k^2 \times p}$ , 其中的每一个列向量  $o_i$  是超完备字典的基, 总共有  $p$  个原子。图 2 为高温气体泄漏检测所使用的超完备字典。




图 2 微小气体泄漏超完备字典

Fig. 2 Over-complete dictionary of micro gas leakage

#### 4.2 构造数据矩阵

由于在算法中需要使用超完备字典  $\mathbf{O}$ , 所以需要将原始图像重新构造成与超完备字典  $\mathbf{O}$  相匹配的数据矩阵。其方法为使用滑动窗口进行扫描, 窗口大小一般与气体泄漏目标大小匹配, 为  $k \times k$ , 移动步长为  $k/2$ , 共获得  $N$  个图像子块, 相邻子块之间有重叠部分可以强化其低秩属性, 将每个子块按列展开成  $k^2$  维向量, 组成数据矩阵  $\mathbf{D} \in \mathbf{R}^{k^2 \times N}$ 。图 3 为原始图像与数据矩阵对比图。



图 3 原始图像与数据矩阵

Fig. 3 Original image and data matrix

#### 4.3 运行算法获得结果

将重构后的数据矩阵  $\mathbf{D}$  与超完备字典  $\mathbf{O}$  作为输入, 通过第 3.2 节中提出的最优化方法进行求解, 最终得到最优估计  $\mathbf{U}^*, \mathbf{V}^*$  和  $\mathbf{H}^*$ , 计算  $\mathbf{O}\mathbf{H}^*$  得到微小气体泄漏检测的初步结果, 然后对  $\mathbf{O}\mathbf{H}^*$  构造数据矩阵过程的逆处理(如 4.2 节所述), 由于滑动窗口的步长小于滑动窗口本身大小, 所以在原始图像中某一个位置点有可能会对应多个子窗口中不同的亮度值, 当出现这种情况时就取各个不同亮度值的平均值, 最终即可获得检测结果。

### 5 实验与结果

设计了两组实验以验证本文算法的有效性, 一组为有效性实验, 另一组为对比性实验。所有程序运行在 Windows 7 + Intel Core i5-3470 3.2 GHz + 8G RAM 配置下, 采用 Matlab 2010b 编程。

#### 5.1 有效性实验

在本文应用背景下, 对算法的有效性进行验证。




图 4 中间结果

Fig. 4 Intermediate results

图 4 展示了算法在运行过程中的中间结果, (1)为原始图像, (2)为原始图像转置后的数据矩阵, (3)为  $U^* DV^*$ , (4)为  $OH^*$ , 最终结果如图 5 所示。

图 5 中, A, B, D 为高温气体发生泄漏的场景, C 为低温气体发生泄漏的场景。第(1)列为原始图像, 第(2)列为算法得到的背景成分, 第(3)列为检出的气体泄漏信息。需要指出的是对高温气体泄漏和低温气体泄漏检测两种情况, 需要构造不同的字典。通过实验发现, 本文方法可以有效检出高温和低温微小气体泄漏。




图 5 最终检测结果

Fig. 5 Final detection results

## 5.2 对比性实验

图 6 中, 第(1)列为原始图像。第(2)列为本文算法得到的背景成分。第(3)列为高低帽算法<sup>[3]</sup>的检测结果, 它是一种滤波算法, 其中 A、B、D 行为采用 TH(高帽)算法检测暗背景下的高亮度目标, 利用开操作将暗背景下的小亮目标侵蚀掉, 再与原图像相减, 突出小目标, 其适用于平滑背景。对于噪声大, 局部对比不明显的图像, 如 D

(3)的检测效果不佳; C 行为采用 LH(低帽)算法检测暗目标, 其利用闭操作将小的暗目标填充掉, 再与原图像相减。可以明显看出检测目标的亮度发生了反转, 由暗目标转变为亮目标。第(4)列为基于视觉显著性<sup>[6]</sup>的检测算法, 其利用亮度信息和方向信息进行检测, 它可以同时检测出亮度异常的点, 在原始图像中较亮和较暗的目标在检测结果中都呈现为亮点, 如 D(4)所示, 因此容易造成误检; 当目标过小时则容易造成漏检, 如 A(4)所示。由图 6 可以看出: 不同的算法, 检测结果差异比较明显。在本文的研究背景下, 基于视觉显著性的检测算法的通用性较好的, 但是容易造成误检和漏检; 高低帽方法在简单背景下效果较好, 在复杂背景下效果不佳; 本文方法充分利用了原始图像的低秩背景和目标的先验知识, 有效降低了漏检率, 对红外小目标的检测效果优于其他算法, 在通用性上则有一定不足, 因为针对低温和高温泄漏需要设计不同的字典。




图 6 检测结果

Fig. 6 Detection results



为了定量说明本文算法的优点,利用受试者工作特征(Receiver Operating Characteristics, ROC)曲线对各个算法性能进行评价。ROC 曲线以误警率为横轴,以正确检出率为纵轴,曲线与 X 轴之间的面积越大,说明算法性能越好,正确检出率和误警率定义如下:

$$P_d = N_r / N_T, \quad (24)$$

$$P_{fa} = N_f / N_T, \quad (25)$$

其中:  $P_d$  为正确检出率,  $P_{fa}$  为误警率,  $N_r$  为正确检测个数,  $N_f$  为错误检测个数,  $N_T$  为实际目标总数。

在图 5 所示的 4 组背景下,随机添加模拟气体泄漏点,其检测结果如图 7 所示。




图 7 ROC 曲线

Fig. 7 ROC curves

## 6 结 论

本文根据现代石化工业对微小气体泄漏检测的要求,在理论上提出基于张量低秩分解和稀疏表示的方法,并给出了基于 IALM 的最优化求解

### 参考文献:

- [1] 何玉杰,李敏,张金利,等. 基于低秩三分解的红外图像杂波抑制[J]. 光学精密工程, 2015, 23(7): 2069-2078.  
HE Y J, LI M, ZHANG J L, et al.. Clutter sup-

pression of infrared image based on three-component low-rank matrix decomposition [J]. *Opt. Precision Eng.*, 2015, 23(7): 2069-2078. (in Chinese)  
[2] 赵爱翌,王宏力,杨小冈,等. 基于结构低秩编码的复杂环境红外弱小目标检测算法[J]. 中国惯性技术学报, 2015, 23(5): 662-669.

pression of infrared image based on three-component low-rank matrix decomposition [J]. *Opt. Precision Eng.*, 2015, 23(7): 2069-2078. (in Chinese)

- [2] 赵爱翌,王宏力,杨小冈,等. 基于结构低秩编码的复杂环境红外弱小目标检测算法[J]. 中国惯性技术学报, 2015, 23(5): 662-669.

- ZHAO A G, WANG H L, YANG X G, *et al.*. Infrared dim small target detection algorithm based on structural low-rank coding under complex environment [J]. *Journal of Chinese Inertial Technology*, 2015, 23(5): 662-669. (in Chinese)
- [3] TOM V T, PELI T, LEUNG M, *et al.*. Morphology-based algorithm for point target detection in infrared backgrounds [C]. *Optical Engineering and Photonics in Aerospace Sensing. International Society for Optics and Photonics*, 1993: 2-11.
- [4] DESHPANDE S D, MENG H E, VENKATESWARLU R, *et al.*. Max-mean and max-median filters for detection of small targets [C]. *SPIE's International Symposium on Optical Science, Engineering, and Instrumentation*, 1999: 74-83.
- [5] HAN J H, MA Y, ZHOU B, *et al.*. A robust infrared small target detection algorithm based on human visual system [J]. *Geoscience and Remote Sensing Letters*, 2014, 11(12): 2168-2172.
- [6] QI S X, MA J, TAO C, *et al.*. A robust directional saliency-based method for infrared small target detection under various complex backgrounds [J]. *IEEE Geoscience and Remote Sensing Letters*, 2013, 10(3): 495-499.
- [7] YANG C W, LIU H P, LIAO S Y, *et al.*. Small target detection in infrared video sequence using robust dictionary learning [J]. *Infrared Physics & Technology*, 2015, 68: 1-9.
- [8] ZHENG C Y, LI H. Small infrared target detection based on low-rank and sparse matrix decomposition [J]. *Applied Mechanics and Materials*, 2013, 239: 214-218.
- [9] HE Y J, LI M, ZHANG J L, *et al.*. Small infrared target detection based on low-rank and sparse representation [J]. *Infrared Physics & Technology*, 2015, 68: 98-109.
- [10] LIU X, ZHAO G Y. Background subtraction based on low-rank and structured sparse decomposition [J]. *IEEE Transactions on Image Processing DRAFT*, 2015.
- [11] YAO J, LIU X, QI C. Foreground detection using low rank and structured sparsity [C]. *Proc. IEEE Int. Conf. Multimed. Expo.*, 2014: 1-6.
- [12] BOUWMANS T, ZAHZAH E H. Robust PCA via principal component pursuit: A review for a comparative evaluation in video surveillance [J]. *Comput. Vis. Image Underst.*, 2014, 122: 22-34.

#### 作者简介:



隋中山(1985—),男,山东平度人,博士研究生,2007年、2009年于第二炮兵工程学院分别获得学士、硕士学位,主要从事图像目标识别方面的研究。  
E-mail: zclszs@163.com



李俊山(1956—),男,陕西白水人,教授,博士生导师,1981于国防科技大学获得学士学位,1988年于第二炮兵工程学院获得硕士学位,2001年于西安微电子技术研究所获得博士学位,主要从事智能图像处理与目标感知识别,电子对抗模拟与仿真等方面的研究。  
E-mail: lijunshan403@163.com

(版权所有 未经许可 不得转载)