

煤矿井红外热成像中的多尺度融合目标特征检测

陈湘源[†], 牛青

(国能榆林能源有限责任公司, 陕西 榆林 719000)

摘要:煤矿井内环境复杂,存在较多的危险因素,单一尺度的特征提取很难实现精准检测目标,无法充分保障工作人员的安全。为此,提出了煤矿井红外热成像中的多尺度融合目标特征检测。通过基于自适应邻域的噪声抑制方法对图像展开去噪处理,并利用线性 and 非线性灰度变换方法增强红外热成像。采用特征金字塔展开多尺度融合目标特征提取,利用多尺度融合技术,结合 YOLOv5 网络预测损失函数,实现煤矿井红外热成像目标检测。实验结果表明,所提算法的煤矿井红外热成像效果较好,能够全部检测到红外热成像目标特征,同时 $P-R$ 曲线图的 AP 面积较大,说明所提算法提高了目标特征检测的精度、效率和可靠性。

关键词:多尺度融合;红外热成像;目标特征检测;特征金字塔;煤矿井

中图分类号:TP391

文献标识码:A

Multi-scale Fusion Target Feature Detection in Infrared Thermal Imaging of Coal Mines

CHEN Xiangyuan[†], NIU Qing

(Guoneng Yulin Energy Co., Ltd., Yulin, Shaanxi 719000, China)

Abstract: The environment in coal mine is complex and there are many risk factors. It is difficult to achieve the accurate detection target by single scale feature extraction, and the safety of staff cannot be fully guaranteed. Therefore, multi-scale fusion target feature detection in infrared thermal imaging of coal mines is proposed. By using adaptive neighborhood based noise suppression methods to denoise the image, and utilizing linear and nonlinear grayscale transformation methods to enhance infrared thermal imaging. The multi-scale fusion target feature extraction is carried out by feature pyramid, and the multi-scale fusion technology is used to predict the loss function combined with YOLOv5 network to realize the target detection of infrared thermal imaging in coal mines. The experimental results show that the proposed algorithm performs well in infrared thermal imaging of coal mines, and can detect all infrared thermal imaging target features. At the same time, the AP area of the $P-R$ curve is larger, indicating that the proposed algorithm improves the accuracy, efficiency, and reliability of target feature detection.

Key words: multi-scale fusion; infrared thermal imaging; target feature detection; characteristic pyramid; coal mine wells

煤矿井是煤炭资源的主要采集地,也是煤矿生产和工作的主要场所。然而,煤矿井内环境复杂,

存在着各种危险因素,如瓦斯、粉尘等。一旦发生事故,不仅会造成煤炭资源的大量流失,还会出现

严重的环境污染,甚至可能造成人员伤亡^[1-2]。为此,研究煤矿井内情况对保障煤矿井生产和工作安全具有重要意义和价值。

李北明等^[3]通过 GhostNet 算法对模型采取剪枝处理,使用 Mosaic 和 Copy-paste 两种方法展开数据增强,提高 YOLOv5 的检测准确率,建立红外安防领域数据集,实现红外目标检测。但该方法去噪处理后的图像仍存在颗粒噪声。赵洪山等^[4]利用双边滤波增强图像纹理特征,根据特殊纹理特征和图像扫描法,建立反映伞裙周期性的描述子,并展开红外热成像的粗识别。在基于密度的聚类算法(Density-Based Spatial Clustering of Applications with Noise, DBSCAN)的基础上,建立目标图像的超参数求解,通过特征点聚类,实现高压绝缘套管精细分割。但该方法的图像增强效果差,无法提取到有效的细节纹理信息。宋子壮等^[5]利用图像翻译网络得出目标域图像,使用梯度反转层优化网络提取特征的域间适应性。通过最大均值差异损失缩小,提取不同红外探测器图像的特征分布。使用 AdamW 异步更新优化算法,但该方法检测到的目标数量与实际数量相差较大,降低了目标识别的精度。为此,提出了煤矿井红外热成像中的多尺度融合目标特征检测。

1 煤矿井红外热成像预处理

煤矿井环境较为复杂,存在较多干扰因素,获取的红外热图像往往存在噪声,且对比度较低,会影响煤矿井红外热成像目标特征的检测和识别。为了提高煤矿井红外热成像目标特征检测的精度,进行煤矿井红外热成像预处理。

1.1 煤矿井红外热成像的噪声抑制

在煤矿井红外热成像的去噪过程中,主要采用基于自适应邻域的噪声抑制,其具体思路为:通过最大类间方差法确定像素模板的最佳分割阈值。根据最佳分割阈值将像素划分为前景、背景和噪声,其中前景指与种子像素存在相同特征的像元,背景指固定邻域内与前景邻接的部分,从而抑制煤矿井红外热成像中的噪声,达到较好的红外热成像效果。

在煤矿井红外热成像的种子像素中建立一个 7×7 的领域范围, $O(o, k)$ 表示煤矿井红外热成像中种子像素,其中的 o 是像素中的灰度, k 是该灰度值出现的像素次数,此范围内存在的全部像素 O 的定义如式(1)所示:

$$O = \begin{cases} 1, & |O - O(o, k)| < Y \\ 0, & \text{其他} \end{cases} \quad (1)$$

其中, Y 是分割阈值,用来判断种子像素间的相似性。利用最大类间方差法将红外热成像的像素分为前景、背景和噪声,以方便后续的红外热成像噪声抑制。

最大类间方差法属于阈值分割方法中的一种经典方法,是一种非参数、无监督的自适应方法。将 $D = \{0, 1, 2, \dots, M\}$ 设定为种子像素模板中所有灰度的集合, A_o 表示灰度 o 出现在集合 D 中的概率, $\{1, 2, \dots, l\}$ 表示集合 D 对应背景的灰度子集, $\{l+1, l+2, \dots, M\}$ 表示集合 D 对应目标的灰度子集,以此推出类别 θ 和 ν 的平均灰度值和标准差,如式(2)所示:

$$\begin{cases} \theta_0 = \sum_{o=0}^l A_o, \theta_1 = \sum_{o=l+1}^M A_o \\ \nu_0 = \sum_{o=0}^l A_o \cdot O/\theta_0, \nu_1 = \sum_{o=l+1}^M A_o \cdot O/\theta_1 \end{cases} \quad (2)$$

由此计算类别 θ 和 ν 的类间方差表达式如式(3)所示:

$$\sigma^2 = \theta_0 \cdot \theta_1 \cdot (\nu_1 - \nu_0)^2 \quad (3)$$

根据最大类间方差的规律,在灰度为 0 至 M 之间修改分割阈值 Y ,同时计算修改后的类间方差,类间方差最大时的 Y 值即为煤矿井红外热成像中种子像素模板的最佳分割阈值。

在煤矿井红外热成像中种子像素的 7×7 邻域范围内,每一个像素 1 组合成的连通区域为种子像素的自适应邻域^[6],每一个含有 0 且至少与一个像素 1 相邻的像素组合成的连通区域为背景区域。煤矿井红外热成像中种子像素的自适应领域示意图如图 1 所示。

图 1 中的煤矿井红外热成像种子像素的自适应邻域即为种子像素对应的对象,对于单个噪声的种子像素,种子的自适应邻域是种子本身;对于红外热成像中的细节或边缘位置的种子像素,它的自适应邻域即为细节或边缘位置的一个连通子区域^[7]。找出煤矿井红外热成像种子像素的自适应邻域后,对煤矿井红外热成像展开去噪处理,如式(4)所示:

$$W = \begin{cases} \sum_{q=-1}^1 \sum_{m=-1}^1 o_q o_m, M_v = 1 \\ \sigma^2 \sum_{F_v} o_{F_v}, M_v > 1 \end{cases} \quad (4)$$

其中, F_v 是确定的煤矿井红外热成像种子像素的自适应邻域范围; o_q, o_m, o_{F_v} 分别为自适应邻

域范围内种子像素的最大灰度值、最小灰度值以及原始灰度值; M_v 是在确定的自适应邻域范围内种子像素的数量(个)。当 $M_v = 1$ 时,表示检测的种子像素属于强噪声,需要对其进行抑制处理。由此完成煤矿井红外热成像的噪声抑制。

8	14	13	2	7	4	10
13	12	8	3	6	7	7
7	10	9	10	9	8	6
3	17	10	9	9	8	5
4	15	6	8	8	9	8
8	11	6	9	10	11	7
13	12	11	7	8	6	5

(a) 7×7邻域

0	0	0	0	1	0	1
0	0	1	0	0	1	1
1	1	1	1	1	1	0
0	0	1	1	1	1	0
0	0	0	1	1	1	1
1	0	0	1	1	1	1
0	0	1	1	1	0	0

(b) 邻域模板

0	0	0	0	△	0	△
0	0	△	0	0	△	△
△	△	△	△	△	△	0
0	0	△	0	△	△	0
0	0	0	△	△	△	△
1	0	0	△	△	△	△
0	0	1	△	△	0	0

(c) 邻域与背景区的确定(三角形为邻域,圆形为背景)

图 1 煤矿井红外热成像中种子像素的自适应邻域

1.2 增强煤矿井红外热成像

煤矿井红外热成像增强是指以舍弃图像中目标物体以外区域的信息为代价,增强目标物体区域的细节信息。通过线性灰度变换和非线性灰度变换,提高煤矿井红外热成像的对比度,从而增强煤矿井红外热成像。

1.2.1 线性灰度变换

线性灰度变换通常用于调整图像的亮度和对比度。在煤矿井红外热成像中,通过将煤矿井红外热成像灰度值映射到一个新的范围,使得图像更加清晰、明亮。在线性点的计算过程中,将经过去噪处理后的灰度值范围为 $[q_1, Q]$ 的原始煤矿井红外热成像 $g(x, y)$ 变换成灰度值范围为 $[m_1, M_1]$ 的图像 $h(x, y)$, 具体过程如式(5)所示:

$$h(x, y) = \frac{(M_1 - q_1)}{(Q - q_1)} \cdot W(g(x, y) - q_1) + m_1 \quad (5)$$

式(5)即为线性点的计算公式,对应的线性灰度变换图像如图 2 所示。




图 2 线性灰度变换图像

通过对煤矿井红外热成像的线性灰度变换实行分段处理,并在分段后的不同灰度段展开压缩或拉伸,从而在细节上改善红外热成像的对比度。对图像 $h(x, y)$ 进行分段设计后的图像表达式如式(6)所示:

$$h(x, y)' = \begin{cases} l_1 g(x, y) + m_1, & 0 \leq Wg(x, y) \leq g_1 \\ l_2 g(x + g_1, y) + h_1, & g_1 < Wg(x, y) \leq g_2 \\ l_3 g(x + g_2, y) + h_2, & g_2 < Wg(x, y) \leq g_3 \end{cases} \quad (6)$$

其中, l_1 、 l_2 、 l_3 指线性变换图像被分段后不同直线的斜率, h_1 、 h_2 分别为分段线性灰度变换的纵坐标值。

1.2.2 非线性灰度变换

非线性灰度变换通常用于处理图像中的低对比度等问题。在煤矿井红外热成像中,由于煤矿井环境较暗,煤矿井红外热成像可能存在低对比度区域,因此通过非线性灰度变换提高图像的质量和对比度。对数变换算法和 Gamma 校正算法是非线性变换中的两种主要算法。对数变换处理煤矿井红外热成像主要是拓展图像中灰度值较低的部分,压缩图像中灰度值较高的部分。经过非线性灰度变换,将原始煤矿井红外热成像 $g(x, y)$ 变换成图像 $h_2(x, y)$ 的过程如式(7)所示:

$$h_2(x, y) = g(x, y) + \lg v \quad (7)$$

式中, v 是常数。

Gamma 校正的实质是:设定 ϵ 是煤矿井红外热成像的灰度值, η 表示煤矿井传感器的入射光强度,此时入射光强度对图像灰度值的影响如式(8)所示:

$$\epsilon = \eta h_2(x, y) \quad (8)$$

其中, η 表示常数。

为实现煤矿井红外热成像增强,需要使入射光的强度和煤矿井红外热成像灰度成正比^[8],将图像灰度值进行 Gamma 校正,此时 Gamma 校正变换

式如式(9)所示:

$$\varepsilon_1 = l_f \varepsilon \quad (9)$$

其中, l_f 表示常数。

当 η 取不同值时, Gamma 校正^[9]函数曲线如图 3 所示。




图 3 Gamma 校正函数曲线

由图 3 可知,当 $\eta < 1$ 和 $\eta > 1$ 时,入射光亮度和图像的灰度值呈非线性变换;当 $\eta = 1$ 时,Gamma 校正函数曲线为线性变换。

将线性灰度变换和非线性灰度变换分别应用于原始煤矿井红外热成像,将得到的两个增强后的图像进行加权平均,获取到增强效果更好的煤矿井红外热成像,表达式如式(10)所示:

$$E = w_1 h(x, y)' + w_2 \varepsilon_1 \quad (10)$$

其中, w_1 、 w_2 分别表示线性灰度变换和非线性灰度变换的权重。以此达到较好的煤矿井红外热成像增强效果。

2 煤矿井红外热成像目标特征检测

利用多尺度融合技术,对经过预处理的煤矿井红外热成像进行煤矿井红外热成像目标特征提取,结合 YOLOv5 网络预测损失函数,实现煤矿井红外热成像目标特征检测。

2.1 提取煤矿井红外热成像目标多尺度融合特征

由于煤矿井内环境复杂,光线较弱,因此单一尺度的特征提取很难检测到红外热成像目标,多尺度融合技术可以通过融合不同尺度的红外热成像目标信息,使得检测结果更为可靠。另一方面,煤矿井中红外热成像目标的大小和方向各不相同,单一的检测算法难以适应各种目标,多尺度融合技术能够更好地适应不同的目标需要,在不同尺度下对目标特征进行多角度、多方向的检测,使红外热成像目标检测更加全面。为此,采用多尺度融合技术,将煤矿井红外热成像按照不同的比例缩放,得到不同尺度的图像。多尺度是指不同比例下对图像进行缩放处理以获得不同尺度的图像。包括:大尺度的图像经过较小的缩放比例;中尺度的图像经

过中等程度的缩放比例;小尺度的图像经过较小的缩放比例。在每个尺度下,提取一系列目标相关的特征,如纹理特征、形状特征和颜色特征等,描述目标的属性和特点。使用卷积神经网络(如 VGG、ResNet 等)对每个尺度的图像进行特征提取。利用特征金字塔^[10]放入特征聚合层中展开多尺度融合特征提取。不同尺度图像特征融合利用各尺度特征的权重进行加权融合,根据不同尺度特征的贡献值进行加权求和从而实现融合。

将红外热成像输入 Focus 模块中采取切片处理,然后对处理后的图像展开卷积操作以得到特征映射。利用 Focus 模块展开卷积层替换。在对每个尺度的煤矿井红外线成像目标分别进行特征提取时,利用在卷积层中嵌入的 Focus 模块得到相应的特征图。对于不同尺度的特征图,可以采用特征金字塔进行特征融合,以得到多尺度融合的特征表示。采用特征金字塔中的特征图进行级联,堆叠较高分辨率的特征图和较低分辨率的特征图,从而形成一个多通道的特征聚合层。

采用 CSP 方法将特征聚合层的特征映射分为两部分,并利用跨阶段结构层次方法进行合并处理。通过金字塔模块,最大程度地融合特征聚合层。利用多尺度融合^[11]将特征聚合层中存在的大感受野特征以及深层网络中存在的高语义特征融合处理,由此完成煤矿井红外热成像多尺度融合特征提取。

2.2 检测煤矿井红外热成像目标特征

提取到煤矿井红外热成像目标特征后,展开煤矿井红外热成像中的多尺度融合目标特征检测。煤矿井内的物体在红外热成像中通常呈现出固定的形状,红外热成像仪与目标物体的相对位置会对目标在红外热成像中的几何特征产生直接影响。YOLOv5 网络预测层中红外热成像仪与目标物体的相对位置可以通过目标成像的几何特征与角点信息呈现,且引入了 CSPDarknet53 作为骨干网络,通过自适应的多尺度训练和测试来适应不同大小的目标,使得主干网络与特征金字塔融合得更紧密。与其他 YOLO 版本相比,YOLOv5 具有更高的速度和检测精度,因此结合 YOLOv5 网络预测损失函数,将不同尺度的红外热成像目标特征融合^[12-13],实现检测煤矿井红外热成像目标特征。

矿井内目标区域在红外热成像中通常呈固定形状,目标区域的四个角点一般受到空间顺序的限制,为此,设定四个角点的顺序按照顺时针方向,空间序列对目标特征检测的约束为:

$$\begin{cases} x_1 \leq x_2 \\ x_4 \leq x_3 \\ y_1 \geq y_2 \\ y_3 \geq y_4 \end{cases} \quad (11)$$

其中, (x_1, y_1) 、 (x_2, y_2) 、 (x_3, y_3) 、 (x_4, y_4) 分别表示红外热成像中目标物体预测框的四个角点对应的坐标。根据四个角点坐标, 计算目标预测框中心点在红外热图像中的坐标, 如式(12)所示:

$$\begin{cases} p_x = \frac{x_2 + x_3 - (x_1 + x_4)}{2} \\ p_y = \frac{y_2 + y_3 - (y_1 + y_4)}{2} \end{cases} \quad (12)$$

在进行多尺度融合目标特征检测时, 需要考虑到交互比(IoU)的影响^[14], 以保证包含目标特征的红外热成像与不包含目标特征的红外热成像的比例平衡。煤矿井的目标特征检测具有特殊性, 已有的交并比测评方法无法及时检测到目标物体的真实框与预测框的重合角度以及方向, 为解决上述问题, 需要寻找目标物体与预测框的最小封闭框, 此时交并比的损失 G 如式(13)所示:

$$G = 1 - ED_1 \cap D_2 / (D_1 + D_2 - D_1 \cap D_2) + (D_H - D_1 \cup D_2) / D_H \quad (13)$$

其中, D_1 表示经过特征提取后的红外热成像目标物体在煤矿井红外热成像中所占的面积; D_2 表示煤矿井红外热成像中目标预测框的面积; D_H 表示目标物体与预测框形成的最小封闭框的面积。由式(13)可推出, 煤矿井红外热成像目标框中心点置信度 Z_{conf} 的预测如式(14)所示:

$$Z_{\text{conf}} = \sum z^{(obj)} G \quad (14)$$

其中, $z^{(obj)}$ 为目标物体是否在预测框中的二值量。对红外热成像中目标框的长宽进行预测, 如式(15)所示:

$$Z_{\text{box}} = \mu \sum Z_{\text{conf}} [(\hat{p}_x - G)^2 + (\hat{p}_y - G)^2 + (\sqrt{e_o} - \varphi)^2 + (\sqrt{j_o} - \hat{j}_o)^2] \quad (15)$$

其中, e_o 、 j_o 为红外热成像目标物体预测框的规格; $\hat{e}_o$ 、 $\hat{j}_o$ 为红外热成像中目标物体的规格; μ 表示预测量的权重系数。

对红外热成像中目标类别 Z_{class} 的预测定义如式(16)所示:

$$Z_{\text{class}} = \sum A \cdot Z_{\text{box}} \quad (16)$$

其中, A 表示检测对象出现在红外热成像预测框中时, 每个预测类别存在的概率(%)。

依据目标物体四个角点的坐标和序列约束, 对目标物体的角点 Z_{corner} 展开预测, 如式(17)所示:

$$Z_{\text{corner}} = \mu \sum Z_{\text{class}} \quad (17)$$

为了实现煤矿井红外热成像目标特征检测, 分别计算目标框中心点置信度预测 Z_{conf} 损失值、目标框的长宽预测 Z_{box} 损失值、目标类别预测 Z_{class} 损失值、目标物体的角点预测 Z_{corner} 损失值^[15], 其计算过程如式(18)所示:

$$\begin{cases} L_{\text{conf}} = Z_{\text{conf}} - S_{\text{conf}} \\ L_{\text{box}} = Z_{\text{box}} - S_{\text{box}} \\ L_{\text{class}} = Z_{\text{class}} - S_{\text{class}} \\ L_{\text{corner}} = Z_{\text{corner}} - S_{\text{corner}} \end{cases} \quad (18)$$

式中, S_{conf} 、 S_{box} 、 S_{class} 、 S_{corner} 分别表示目标框中心点置信度实际值、目标框的长宽实际值、目标类别实际值、目标物体的角点实际值。

由此可推出 YOLOv5 网络预测损失函数, 如式(19)所示:

$$L = L_{\text{box}} + L_{\text{conf}} + L_{\text{class}} + L_{\text{corner}} \quad (19)$$

将提取到的红外热成像几何特征输入式(19)中, 完成煤矿井红外热成像目标特征检测。

3 实验与分析

为了验证煤矿井红外热成像中的多尺度融合目标特征检测的整体有效性, 需要对其展开测试。选择一台配备有 NVIDIA GPU 的计算机, GPU 的型号为 NVIDIA GTX 1060, 并在该计算机中安装 Python 3. X 环境。红外热成像工具选择 RS6780 红外热成像仪, 进行煤矿井红外热成像目标特征检测实验。煤矿井工作环境如图 4 所示。



图 4 煤矿井工作环境

将红外热成像仪放置在煤矿井道侧面, 采集到的数据形式为视频, 利用抽帧得到 500 组 640×480 的红外热成像数据。

3.1 煤矿井红外热成像效果

由于受到亮度等因素的影响, 采集到的煤矿井

红外热成像清晰度较低,直接影响煤矿井红外热成像效果。为此,现采用所提算法、文献[3]算法和文献[4]算法对煤矿井红外热成像展开处理,不同算法的煤矿井红外热成像清晰度如图 5 所示。




图 5 不同算法的煤矿井红外热成像清晰度

由图 5 可知,原始红外热成像的清晰度较低,经文献[3]和文献[4]算法处理过的图像仍存在噪声,清晰度仍然较低。使用所提算法能够有效清除原始红外热成像中存在的颗粒噪声和条纹噪声,提高了图像的清晰度,表明所提算法的煤矿井红外热成像效果较好。主要是因为所提算法采用了基于自适应邻域的噪声抑制,通过最大类间方差法确定了最佳分割阈值,抑制了煤矿井红外热成像中的噪声,具有较好的红外热成像效果。

3.2 煤矿井红外热成像目标特征检测精度

选取某一时刻的煤矿井红外热成像,采用 3 种算法展开煤矿井红外热成像目标检测。煤矿井红外热成像目标特征检测结果如图 6 所示。

由图 6 可知,文献[3]算法和文献[4]算法的煤矿井红外热成像目标特征检测结果中的目标框与实际人脸位置相差较大,且存在漏检的问题,而所提算法能够全部检测到红外热成像目标特征,说明所提算法的煤矿井红外热成像目标特征检测精度更高。这是因为所提算法通过煤矿井红外热成像预处理,去除了红外热成像中的干扰因素,增强了红外热成像,从而提高了煤矿井红外热成像目标特征检测的精度。




图 6 煤矿井红外热成像目标特征检测结果

3.3 煤矿井红外热成像目标特征检测可靠性

在煤矿井红外热成像的目标特征检测中,准确率 P 表示红外热成像的目标检测值与目标真实值的比值;召回率 R 表示检测的煤矿井红外热成像目标数量在所有目标中所占的比例。 mAP 计算可以验证算法的可靠性,其中, AP 是指 $P-R$ 曲线下方的面积。 $P-R$ 曲线下方的面积越大,说明该算法的煤矿井红外热成像目标特征检测结果越可靠。

统计 3 种算法的准确率和召回率,得到的 $P-R$ 曲线图如图 7 所示。




图 7 $P-R$ 曲线图

由图 7 中的 $P-R$ 曲线可知,所提算法对红外热成像目标特征检测的准确率和召回率都高于文献[3]算法和文献[4]算法,且 AP 面积更大,表示所提算法的煤矿井红外热成像目标特征检测的可靠性较高。这是因为所提算法利用多尺度融合技术,通过融合不同尺度的红外热成像目标特征,使得目标特征检测结果更加可靠。

3.4 煤矿井红外热成像目标特征检测时间

选取不同时刻的煤矿井红外热成像,分别命名为 1、2、3、4、5、6、7、8、9、10。采用 3 种算法展开煤矿井红外热成像目标检测,对比不同算法的检测时间,如表 1 所示。

表 1 不同算法的检测时间(单位:ms)			
红外热成像	所提算法	文献[3]算法	文献[4]算法
1	11	15	18
2	4	10	15
3	8	17	22
4	6	12	19
5	9	14	20
6	12	20	18
7	15	21	19
8	7	15	18
9	11	18	22
10	8	13	20
平均值	9.1	15.5	19.1

根据表 1 可知,文献[3]算法和文献[4]算法的平均检测时间分别为 15.5 ms 和 19.1 ms,而所提算法的平均检测时间仅为 9.1 ms,说明所提算法具有较高的检测效率。

4 结 论

本文提出了煤矿井红外热成像中的多尺度融合目标特征检测。该算法对矿井内的红外热成像展开降噪以及增强处理。利用多尺度融合技术,结合特征金字塔进行特征提取,结合 YOLOv5 网络预测损失函数,实现煤矿井红外热成像目标特征检测。经过实验验证,该算法有效提高了红外热成像的清晰度,说明所提算法的煤矿井红外热成像效果

较好,目标特征检测精度、效率和可靠性较高。

参考文献

[1] 李团结,白光星,张琦,等. 基于微光谱和正压输气技术的煤矿自燃火灾监测系统[J]. 煤矿安全,2022,53(11):113—117.

[2] 孙继平,范伟强. 矿井红外热成像远距离测温误差分析与精确测温方法[J]. 煤炭学报,2022,47(4):1709—1722.

[3] 李北明,金荣璐,徐召飞,等. 基于特征蒸馏的改进 Ghost-YOLOv5 红外目标检测算法[J]. 郑州大学学报(工学版),2022,43(1):20—26.

[4] 赵洪山,张则言,孟航,等. 基于高压绝缘套管纹理特征的红外目标检测[J]. 红外技术,2021,43(3):258—265.

[5] 宋子壮,杨嘉伟,张东方,等. 基于无监督域适应的低空海面红外目标检测[J]. 光学学报,2022,42(4):127—134.

[6] 刘玮. 基于红外成像的金属表面缺陷视觉检测方法研究[J]. 世界有色金属,2019,531(15):255—256.

[7] 曲海成,申磊. 面向目标检测的 SAR 图像去噪和语义增强[J]. 光子学报,2022,51(4):329—343.

[8] 王一竹,李渊,杨宇. 基于人眼亮度感知的 S 型函数图像对比度增强算法[J]. 电子科技大学学报,2022,51(4):600—607.

[9] 李辉,王欢,王冬秀. 基于改进深度森林的抗恶意代码攻击算法仿真[J]. 计算机仿真,2022,39(1):353—357.

[10] 彭志耀,刘子杨,冯传旭,等. 面向交通标志检测的尺度感知双向特征金字塔网络[J]. 计算机辅助设计与图形学学报,2022,34(1):133—141.

[11] 陈欣,万敏杰,马超,等. 采用多尺度特征融合 SSD 的遥感图像小目标检测[J]. 光学精密工程,2021,29(11):2672—2682.

[12] 许婷婷,傅俊琼,罗昆. 基于 CNN 和多尺度融合的驾驶员打电话行为检测[J]. 计算机技术与发展,2022,32(2):88—93.

[13] 胡振宇,陈琦,朱大奇. 基于颜色平衡和多尺度融合的水下图像增强[J]. 光学精密工程,2022,30(17):2133—2146.

[14] 周华平,郭伟. 改进 YOLOv5 网络在遥感图像目标检测中的应用[J]. 遥感信息,2022,37(5):23—30.

[15] 马跃坤,李再韩,赵彦旭,等. 无砟轨道板表面裂缝的红外热成像检测方法[J]. 铁道科学与工程学报,2022,19(3):579—587.