



## 基于MRAU视频分割模型的矿井涌（突）水风险识别方法

武强 张帅 杜沅泽 徐华 赵颖旺

### 引用本文：

武强，张帅，杜沅泽，等. 基于MRAU视频分割模型的矿井涌（突）水风险识别方法[J]. 煤炭科学技术, 2024, 52(11): 17–28.

WU Qiang, ZHANG Shuai, DU Yuanze. Mine water inrush risk identification method based on MRAU video segmentation model[J]. Coal Science and Technology, 2024, 52(11): 17–28.

在线阅读 View online: <https://doi.org/10.12438/cst.2024-1370>

### 您可能感兴趣的其他文章

#### Articles you may be interested in

#### 基于PCA-AWOA-ELM模型的矿井突水水源识别

Identification of mine water inrush source based on PCA-AWOA-ELM model

煤炭科学技术. 2023, 51(3): 182–189 <https://doi.org/10.13199/j.cnki.cst.2021-0541>

#### 基于PSO-XGBoost的矿井突水水源快速判别模型

A rapid identification model of mine water inrush based on PSO-XGBoost

煤炭科学技术. 2023, 51(7): 72–82 <https://doi.org/10.13199/j.cnki.cst.2023-0446>

#### 基于客观组合权-改进集对分析模型的矿井突水水源识别

Identification of mine water inrush source based on objective combined weights-improved set pair analysis model

煤炭科学技术. 2022, 50(4): 156–164 <http://www.mtkxjs.com.cn/article/id/b8e26494-24ec-4e4f-a52f-8693f033d9b1>

#### 基于组合权-改进灰色关联度理论的矿井突水水源识别

Identification of mine water inrush source based on combination weight-theory of improved grey relational degree

煤炭科学技术. 2022, 50(4): 165–172 <http://www.mtkxjs.com.cn/article/id/5a05304b-bf77-476e-ad0e-b04a3128fd56>

#### 基于Piper-层次聚类灰色关联度的突水水源识别

Study on mine water inrush source discrimination method based on Piper-hierarchical clustering-gray rational analysis

煤炭科学技术. 2024, 52(S1): 221–227 <https://doi.org/10.12438/cst.2023-0918>

#### 采动诱发充填断层活化滞后突水机制研究

Study on mechanism of delayed water inrush caused by mining-induced filling fault activation

煤炭科学技术. 2022, 50(3): 136–143 <http://www.mtkxjs.com.cn/article/id/cb30c14f-58a8-4f1b-9ee3-3a2cfa06df9>



关注微信公众号，获得更多资讯信息



移动扫码阅读

武 强, 张 帅, 杜沅泽, 等. 基于 MRAU 视频分割模型的矿井涌(突)水风险识别方法[J]. 煤炭科学技术, 2024, 52(11): 17-28.

WU Qiang, ZHANG Shuai, DU Yuanze, *et al.* Mine water inrush risk identification method based on MRAU video segmentation model[J]. Coal Science and Technology, 2024, 52(11): 17-28.

## 基于 MRAU 视频分割模型的矿井涌(突)水风险识别方法

武 强<sup>1,2,3</sup>, 张 帅<sup>1,2,3</sup>, 杜沅泽<sup>1,2,3</sup>, 徐 华<sup>4</sup>, 赵颖旺<sup>1,2,3</sup>

(1. 矿业大学(北京) 内蒙古研究院, 内蒙古 鄂尔多斯 017000; 2. 中国矿业大学(北京) 国家煤矿水害防治工程技术研究中心, 北京 100083;

3. 矿山水防治与资源化利用国家矿山安全监察局重点实验室, 北京 100083; 4. 北京石油化工学院 信息工程学院, 北京 102617)

**摘 要:** 矿井涌(突)水视频识别是智能化矿井建设的关键之一, 通过识别涌(突)水从无到有、从小到大的动态演变过程, 有助于防止水量超出矿井排水能力并演变为水害。为此提出了一种基于多通道残差注意力机制的 U<sup>2</sup>Net 视频分割模型(MRAU), 旨在识别涌(突)水的演变过程。首先, 基于卷积注意力模块(CBAM)改进 U<sup>2</sup>Net 网络模型, 以提高特征提取效果。通过多通道残差预处理, 区分水流动态特征与静态背景, 并将处理结果作为注意力机制输入模型, 从而强化水流特征的学习。此外, 使用中间帧掩码作为标签进行多帧融合学习, 进一步提升网络对水流动态特征的识别能力。最终, 通过学习不同场景下的水流特征, 实现对未知场景中涌(突)水动态演变的有效识别。通过与 Deeplab、LRASPP、FCN、U<sup>2</sup>Net 网络模型的对比试验, 选用 *Dice* 和 *IoU* 作为评价指标。试验结果表明, MRAU 模型的 *Dice* 和 *IoU* 分别达到 92.88% 和 87.51%, 相比 U<sup>2</sup>Net 基础网络, 识别结果分别提高了 4.71% 和 7.41%。在未知的涌(突)水场景中测试时, MRAU 的 *Dice* 和 *IoU* 得分分别达到了 86.75% 和 80.23%。与其他模型相比, MRAU 的识别精度最高, 表明该模型在不同场景下对水流特征具有更强的泛化能力。此外, MRAU 能够精准监测涌(突)水流量从小到大的演变过程。最后, 通过在井下环境中模拟突水场景, 进一步验证 MRAU 模型在实际生产中的实用性, 为矿井水害监测提供了有效的技术手段。

**关键词:** 矿井涌(突)水; 视频分割; MRAU; 多通道残差预处理; 注意力机制; U<sup>2</sup>Net

中图分类号: TD742

文献标志码: A

文章编号: 0253-2336(2024)11-0017-12

### Mine water inrush risk identification method based on MRAU video segmentation model

WU Qiang<sup>1,2,3</sup>, ZHANG Shuai<sup>1,2,3</sup>, DU Yuanze<sup>1,2,3</sup>, XU Hua<sup>4</sup>, ZHAO Yingwang<sup>1,2,3</sup>

(1. Inner Mongolia Research Institute, University of Mining and Technology-Beijing, Ordos 017000, China; 2. National Engineering Research Center of Coal Mine Water Hazard Controlling, China University of Mining and Technology-Beijing, Beijing 100083, China; 3. Key Laboratory of Mine Water Control and Resources Utilization, National Mine Safety Administration, Beijing 100083, China; 4. College of Information Engineering, Beijing Institute of Petrochemical Technology, Beijing 102617, China)

**Abstract:** Mine water inrush video recognition is a key component in intelligent mine construction. By recognizing the dynamic evolution of water inrush from none to some and from small to large, it helps prevent the water volume from exceeding the mine's drainage capacity and turning into a water hazard. Therefore, a video segmentation model based on the Multi-channel Residual Attention mechanism and U<sup>2</sup>Net (MRAU) was proposed to identify the evolution process of water inrush. First, the U<sup>2</sup>Net network model was improved based on the Convolutional Block Attention Module (CBAM) to enhance feature extraction. Then, through multi-channel residual preprocessing, the dynamic features of water flow were distinguished from the static background, and the processed results were input into the model as an attention mechanism to reinforce the learning of water flow features. In addition, intermediate frame masks were used as labels for multi-

收稿日期: 2024-09-25

策划编辑: 常 琛

责任编辑: 戴春雷

DOI: 10.12438/cst.2024-1370

基金项目: 国家自然科学基金资助项目(42027801, 42202283); 中央高校基本科研业务费资助项目(2022YJSSH01)

作者简介: 武 强(1959—), 男, 内蒙古呼和浩特人, 中国工程院院士。E-mail: wuq@cumtb.edu.cn

通讯作者: 张 帅(1993—), 男, 山东济南人, 博士研究生。E-mail: zhangshuaicumtb@163.com

frame fusion learning, further enhancing the network's ability to recognize the dynamic features of water flow. Finally, by learning the water flow features in different scenarios, the model effectively recognizes the dynamic changes of water inrush in unknown scenarios. Comparative experiments with Deeplab, LRASPP, FCN, and U<sup>2</sup>Net network models, using *Dice* and *IoU* as evaluation metrics, show that the *Dice* and *IoU* of the MRAU model reach 92.88% and 87.51%, respectively, which represents improvements of 4.71% and 7.41% over the baseline U<sup>2</sup>Net network. When tested in unknown water inrush scenarios, the MRAU model achieves *Dice* and *IoU* scores of 86.75% and 80.23%. Compared to other models, MRAU achieves the highest recognition accuracy, demonstrating stronger generalization capabilities in recognizing water flow features across different scenarios. Moreover, MRAU can accurately monitor the dynamic evolution of water inrush from small to large. Finally, simulations of water inrush scenarios in underground environments further verify the practical utility of the MRAU model in real-world production, providing an effective technical solution for mine water hazard monitoring.

**Key words:** mine water inrush; video segmentation; MRAU; multichannel residual preprocessing; attention mechanism; U<sup>2</sup>Net

## 0 引言

矿井水害是矿山安全生产的一类重大灾害,常导致严重的人员伤亡和财产损失<sup>[1-2]</sup>。第一时间识别水害事故并实施有效的预防措施,对确保人员安全撤离、将水害影响降到最低至关重要<sup>[3-4]</sup>。涌(突)水演变成水害的过程通常从初始的渗水开始,随着水流的扩散、范围扩大以及水压和涌水量的增加,一旦超过矿井的排水能力,将导致大范围的淹井和结构破坏,进而形成全面的水害。传统的涌(突)水监测方法主要依赖井下工人的定期巡检和传感器监测,但存在局限性。事故发生时,工人可能优先逃生而非通知控制中心,从而导致响应延迟。例如,2019年曾家沟煤矿发生水害事故,水害发生后近0.5 h,井口值班人员才发现主平硐井口有水流出,并随后向调度中心汇报,造成了一定延迟,未能在第一时间通知其他工作人员。此外,传感器监测作为接触式方法,在事故中容易受损,影响其稳定性和可靠性。

相比之下,视频识别技术在矿井水害监测中具有显著优势,特别是在对涌(突)水监测时。视频识别技术通过非接触式、全天候的实时监测,能够自动分析视频流,迅速识别矿井内涌(突)水的动态演变过程,并在涌(突)水从无到有的初期阶段及流量逐渐增加时,及时发出预警。这一技术不仅有效避免了因人工监测延迟或盲点带来的风险,还减少了工人在危险环境中的暴露时间,降低了安全风险和人员配置成本。基于现有的监控摄像头,视频识别技术无需额外的硬件投资,能够以较低成本实现高效的矿井水害监测。

目前,矿井智能化发展迅速<sup>[5-6]</sup>,视觉识别技术已广泛应用于煤岩纹理检测<sup>[7-9]</sup>、煤矸石分选<sup>[10-12]</sup>、地下作业异常识别<sup>[13-14]</sup>以及井下图像去噪<sup>[15-18]</sup>。在矿井涌(突)水监测方面,视觉识别技术的应用相对较少,主要原因是有限的样本无法覆盖所有涌(突)水

场景,当未知场景出现涌(突)水的动态变化时,常规的深度学习方法很难精确捕捉。此外,水流的动态变化对深度学习算法提出了更高的挑战。因此,需要一种能够学习和提取水流视觉特征的方法,以便在不同场景下有效识别水流特征。这种方法应具备忽略背景干扰的能力,专注于水流的视觉特征,从而提高矿井涌(突)水的识别精度。

矿井涌(突)水的视觉特征可分为空间特征和时间特征。空间特征主要表现为形状和颜色,而时间特征涉及动态纹理。卷积神经网络能够分层提取水流在时间和空间上的低级和高级特征<sup>[19]</sup>,相比于传统方法更具效率和灵活性。在图像识别领域,图像分类主要关注整体信息,为整个图像输出标签或类别。然而,它难以有效提取不同背景下的水流特征,也无法清晰可视化水流与背景的区别<sup>[20]</sup>。相比之下,图像分割通过将图像划分为多个区域或像素组,其中每个区域代表不同的类别<sup>[21]</sup>。相比于单张图像的分割,视频分割方法不仅能够识别单张视频帧中的水流和背景,确定其精确边界、位置和形状,还能考虑水流在时间维度上的变化,从而利用多帧水流面积的变化来反映涌(突)水水量的变化。因此,采用视频分割方法可以更直观地呈现矿井涌(突)水的演变过程。

为此,提出了一种基于多通道残差注意力机制的U<sup>2</sup>Net视频分割模型(MRAU)。当识别地点发生涌(突)水时,该模型能够基于已学习的涌(突)水特征,精准识别涌(突)水从无到有的渗水过程。此外,通过对连续视频帧的分析,模型还可以进一步识别从小到大的涌(突)水演变过程。为消除背景影响,模型采用多通道残差预处理方法,以实现跨场景的涌(突)水识别。同时,将预处理结果作为注意力机制输入到模型中,从而增强了对水流动态特征与静态背景的区分能力。此外,模型引入CBAM模块以改进U<sup>2</sup>Net网络(即CBAM-U<sup>2</sup>Net),从而提高了边缘



特征提取的精度。最后,提出了一种多帧融合预处理方法,利用中间视频帧的掩码作为反向传播的标签,进一步强化了水流动态特征的识别能力。

## 1 MRAU 模型设计

### 1.1 整体网络结构

MRAU 网络整体结构如图 1 所示,将 3 个模块




图 1 MRAU 网络整体结构

Fig.1 Overall structure of the MRAU network

第 2 个模块是改进的 U<sup>2</sup>Net 网络模型,其特点是在每个 U 型结构中嵌入了 CBAM 模块。引入 CBAM 显著增强了网络的特征提取能力,使其更有效地关注重要特征,同时抑制无关或冗余部分。U 型结构的每一层经过优化,确保特征图在多次下采样和上采样后保留最有价值的信息。这对分割任务尤为关键,特别是在矿井涌(突)水识别中,因为需要精确区分水流边缘与复杂纹理场景。

第 3 个模块是反向传播。在这一阶段,使用中间帧的标注图像作为真实标签,以更好地捕捉和描述水流的动态特性,使网络专注于水流的流动性和连续性。在学习过程中,这些动态特征作为训练目标,中间帧标签帮助网络准确描绘水流前后的运动变化,从而提升模型对水流流动性的理解和分割准确性。3 个模块的协同工作改善了视频特征提取,并增强了模型对动态环境变化的适应能力,使该结构非常适合在不同场景中识别水流,特别是在复杂的井下环境中提取涌(突)水特征。

### 1.2 CBAM 模块

CBAM<sup>[22]</sup> 利用空间和通道注意力机制增强模型的特征处理能力,显著提高了模型的视觉性能。CBAM 模块结构如图 2 所示,空间注意力机制强调图像中特定位置的重要特征,而通道注意力机制则增强识别任务中最有效的特征通道。CBAM 通过最大池化和平均池化有效地压缩特征图,保留关键特征,并利用多层感知机进一步细化和增强这些特征。

整合到一个统一框架中,以优化分割结果。图 1 中,  $t_1 \sim t_3$  为第 1~3 帧。第 1 个模块是多通道残差注意力机制,其核心在于利用多通道残差方法对视频进行预处理,并融合连续帧特征,以捕捉多个视频帧之间的动态特征。预处理后的视频帧作为多帧注意力机制的输入,使模型更加关注水流的动态特征。最后,将这些特征拼接后作为后续分割模型的输入。

最终, CBAM 通过 Sigmoid 函数确定每个特征的权重,抑制不必要的特征,突出重要特征,使模型专注于关键的信息。

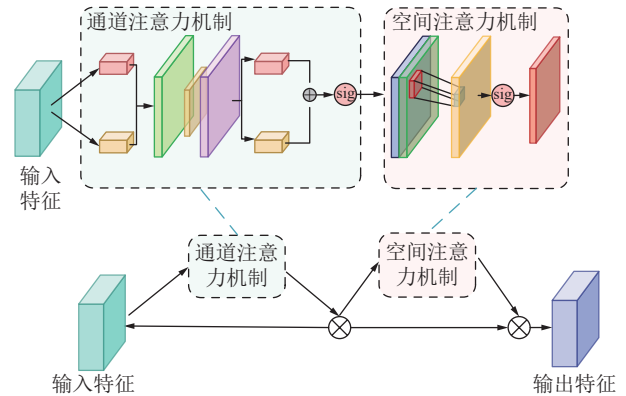


图 2 CBAM 模块结构

Fig.2 CBAM module structure diagram

### 1.3 基于 CBAM 的 U<sup>2</sup>Net 网络结构

U<sup>2</sup>Net<sup>[23]</sup> 网络模型在图像语义分割领域表现出良好的性能,采用了残差 U 结构(RSU)模块来捕捉不同尺度中更多的上下文信息。RSU 模块替代了 Unet<sup>[24]</sup> 中的传统卷积块,这一改进使 U<sup>2</sup>Net 在更深的层次中保持高分辨率细节,同时准确地整合多尺度信息,从而显著提高了分割任务的准确性和鲁棒性。

集成 CBAM 模块以提升 U<sup>2</sup>Net 模型显著目标的识别能力,U<sup>2</sup>Net 网络的 U 型结构引入 CBAM 模块,同时嵌入到每个 RSU 模块中。CBAM-RSU4F 模块结构如图 3 所示,以 RSU4F 模块为例,将左侧每一

个特征提取模块的输出  $H \times W \times C_{mid}$  传入 CBAM 模块, 并与右侧每个特征提取模块输出的  $H \times W \times C_{mid}$  进行相加, 从而在每个小的 U 型结构中嵌入 CBAM 模块。图 3 中  $k_3$  表示卷积核大小为  $3 \times 3$ ,  $s_1$  表示卷积的步长为 1,  $d_2$ 、 $d_4$ 、 $d_8$  表示卷积的扩张率, 分别为 2、4 和 8, 用于扩张卷积操作。这些扩张率会影响感受野, 使得在不同尺度上提取特征, 更适合处理多尺度信息。

图 4 展示了  $U^2Net$  的整体结构, 其中输入特征为 MRAU 第 1 个模块的输出, 随后经过网络层处理。网络层包含 6 个编码器 (En\_1—En\_6), 每个编码器包含一个 CBAM-RSU 模块, 各模块配置和深度不同。这些编码器通过逐步减小空间维度 (卷积和池化) 并增加通道维度, 捕捉视频帧的高级语义特征。网络还包含 5 个解码器 (De\_1—De\_5), 每个解码器同样包含一个 CBAM-RSU 模块, 逐步对编码器特征图进行上采样。  $S_{side}^{(1)}—S_{side}^{(6)}$  表示网络中各层解码器生成的多尺度侧输出用于捕获不同分辨率的特征并辅助最终结果的融合。计算过程与 CBAM-RSU 结构类似, 将每个编码器的输出传入 CBAM 模块, 并与解码器的输出相加。每个编码器的输出 (Sup\_1—Sup\_6) 经过进一步的卷积和上采样处理, 生成不同尺度的


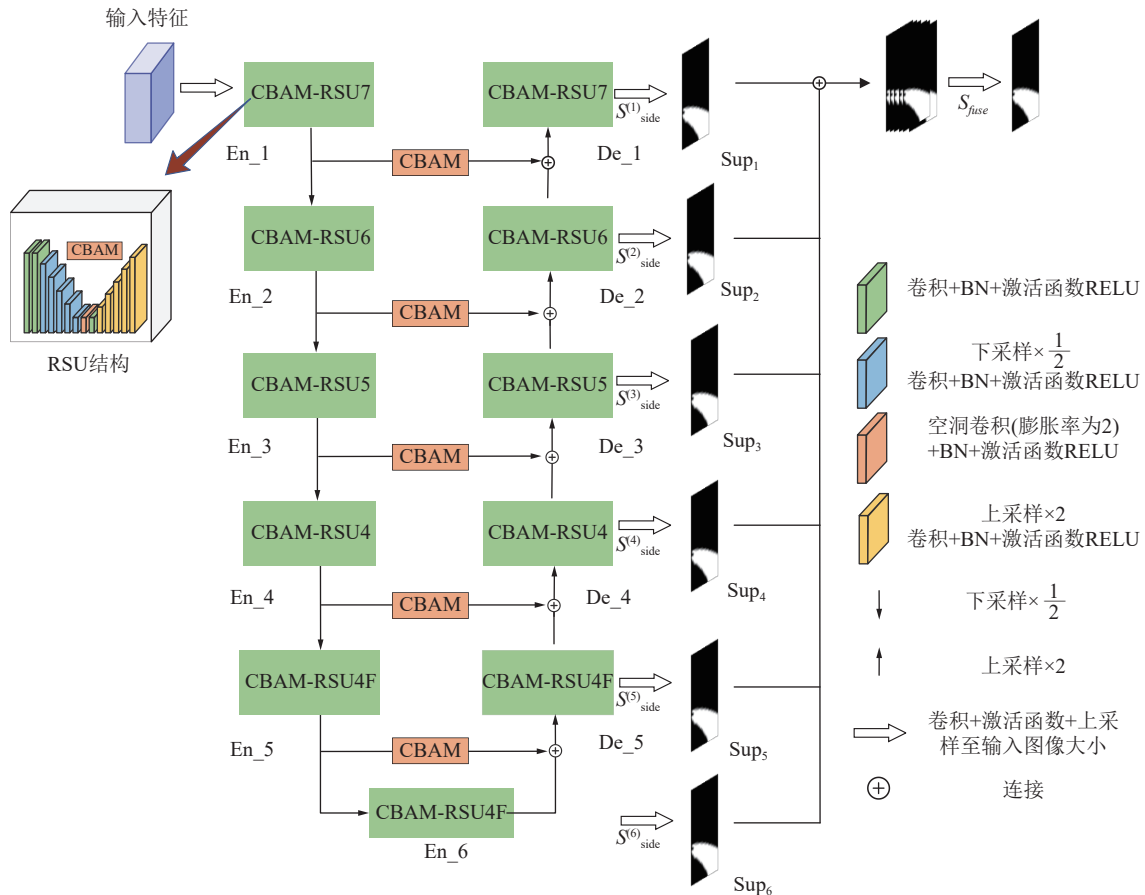


图 3 CBAM-RSU4F 模块结构

Fig.3 CBAM-RSU4F module structure

涌(突)水预测图, 每个多尺度预测图对应不同分辨率的视频帧。最终的涌(突)水预测 ( $S_{fuse}$ ) 通过收集和合并所有尺度的预测结果获得, 并通过 Sigmoid 函数激活生成涌(突)水的二值预测图。

图 4 基于 CBAM 的  $U^2Net$  网络模型Fig.4  $U^2Net$  network model based on CBAM

#### 1.4 多通道残差预处理

在矿井涌(突)水识别过程中,由于井下环境复杂,获取不同场景下的涌(突)水样本非常困难。因此,背景的高度变化性使得单一场景训练变得不可行。针对上述问题,识别真实矿井涌(突)水视频的关键步骤之一是消除背景影响。水流的动态变化主要由颜色、纹理、波纹和光照条件引起,而静态部分(如岩壁和煤壁)会干扰水流识别。本研究重点在于生成仅保留纹理和颜色的水流特征帧,并应用多通道方法消除静态背景。多通道模式通过处理 RGB 三个通道的残差,保留水流的动态特征,从而提高了每个像素的阈值。该方法通过计算连续视频帧中每个通道像素的平均值,获得平均像素帧。实现这一功能的前提是相机位置固定,且静态背景与动态对象之间有明确区别。因此,视频中每个通道的平均像素帧具有如下像素级定义:

$$\overline{F_R}(x,y) = \sum_{i=1}^t I_i(x,y) \quad (1)$$

$$\overline{F_G}(x,y) = \sum_{i=1}^t I_i(x,y) \quad (2)$$

$$\overline{F_B}(x,y) = \sum_{i=1}^t I_i(x,y) \quad (3)$$

式中:  $\overline{F_R}(x,y), \overline{F_G}(x,y), \overline{F_B}(x,y)$  分别为 RGB 三个通道的平均像素值;  $t$  为视频中的帧数;  $i$  为当前视频帧;

$I_i(x,y)$  为该位置的像素值。

然后,通过计算视频帧与平均像素帧的差值获得残差图像。图 5 中的结果表明,多通道方法保留了 RGB 颜色范围,从而增加了像素阈值。该方法通过放大水流的独特视觉属性(如颜色和纹理变化),增强了水的动态特征与静态背景的区别能力。

#### 1.5 多通道残差注意力机制

深度神经网络使用的注意力机制通常捕捉不同特征之间的长距离依赖关系,并对全局上下文信息建模。在不同环境下的涌(突)水识别中,重点是捕捉水流的流动性并消除背景的复杂性。从不同背景的涌(突)水视频中提取特征时,背景特征会影响全局信息。因此,在输入特征之前,将多个视频帧融合,并将多通道残差图像作为注意力机制,融入多帧特征向量中。这样,较高的权重赋予水流的动态部分,从而增强模型对涌(突)水关键部分的关注,而较小的权重则分配给与水流无关的背景区域。多通道残差注意力机制如图 6 所示,首先将 3 张输入大小为  $H \times W \times C$  的连续视频帧通过 Conv2d+BN+ReLU 层进行特征提取,然后在第三个维度进行拼接,得到  $H \times W \times 3C$  的特征向量。紧接着,使用 CBAM-RSU4 模块融合 3 张图像的特征,并优化特征流。这样,使其在图像的低级特征(如边缘和纹理)与高级特征(如物体部分和整体结构)之间保持平衡。




图 5 多通道残差预处理方法

Fig.5 Multi-channel residual preprocessing method




图 6 多通道残差注意力机制

Fig.6 Multi-channel residual attention mechanism

同时,多通道残差图像首先通过 Conv2d+BN+ReLU 层进行特征提取。然后,多通道残差图像与 CBAM-RSU4 模块的输出相乘,作为 3 个连续帧的注意力机制。最后,将其与 CBAM-RSU4 模块融合后的特征相加,生成最终的特征图像。总体上,经过 CBAM-RSU4 模块处理的特征图作为查询向量,因为它们是模型当前关注的特征。多通道残差图像作为关键向量,参与注意力权重的计算,通过 Conv2d+BN+ReLU 层实现。

## 2 试 验

### 2.1 数据集

本研究旨在通过学习水流特征,在未知场景中



提取水流信息,实现不同场景下的矿井涌(突)水识别。为此,建立了多样化的水流数据集作为综合训练样本。数据集分为 3 部分:视频水数据集、矿井涌(突)水数据集,以及掘进与回采工作面数据集。图 7 展示了各数据集的示例。




图 7 数据集结构  
Fig.7 Datasets structure

**视频水数据集(VWD):**由于涌(突)水的本质是水流,其时空演变过程与水流高度相似,例如水流扩展速度较快,并伴随水体亮度波动等现象。因此,收集了视频水数据集(VWD),包含数小时的水流视频素材,是目前最大规模的水流视频数据库之一。如图 7a 所示,数据集收录了 160 个视频,涵盖多种水流形态,如溪流、喷泉、瀑布和海洋等场景。数据集包含丰富的水流颜色、纹理及时间特征,使模型能够在不同条件下学习水流的动态变化。

**矿井涌(突)水数据集:**该数据集通过井下摄像头对各个出水点进行采样。如图 7b 所示,数据集包含 120 个视频,涵盖重力水、渗水、喷射状承压水和地表积水等不同形态的涌(突)水视觉特征,并包括光线较暗及噪声干扰下的涌(突)水场景。

**掘进和回采工作面数据集:**煤矿作业中,掘进和回采工作面最易发生涌(突)水现象。主要原因包括

复杂的地质结构、开采导致的地层破裂、监测预警不足,以及未处理的老空区等。在掘进和回采作业中,掘进机、带式输送机、刮板输送机和采煤机等设备均在运转。因此,掘进和回采工作面成为矿井涌(突)水的主要监测对象。为验证模型在实际场景中的效果并增强其背景泛化能力,采集了井下回采和掘进作业的视频,并将其标注为无水。如图 7c 所示,数据集收录了 50 个视频。

这些数据集不仅关注水的基本特征,还涵盖了涌(突)水的多种视觉形态,提升其在不同场景中的泛化能力。此外,由于数据集中每个视频的背景完全不同,因此在划分测试集和训练集时,背景环境之间不存在交集。这种多维数据集不仅使模型能够充分学习水流特征,还能检验其跨场景识别能力,从而准确识别和应对不同环境下的涌(突)水现象。

## 2.2 评价指标

MRAU 分割性能的评估指标为 *Dice* 系数和交并比 *IoU*。*Dice* 系数用于量化分割模型在给定数据集上的性能,特别注重小物体的表现,能够反映水流细节。*Dice* 系数公式如下

$$Dice = \frac{2T_p}{(T_p + F_N) + (T_p + F_p)} \quad (4)$$

其中,  $T_p$  为真阳性的数量,代表正确识别到的水流;  $F_N$  为假阴性的数量,即被标记为非水像素的水流像素;  $F_p$  为假阳性的数量,即错误识别为非水像素的水流像素。*Dice* 系数是一种集合相似性度量,常用于计算两个样本之间的相似性。*Dice* 值的范围为 0 ~ 1。

*IoU* 广泛用于评估 2 个集合的相似性,其计算方法如下

$$I(A, B) = \frac{A \cap B}{A \cup B} \quad (5)$$

式中,  $I(A, B)$  为  $A$ 、 $B$  两个集合的交并比;  $A$ 、 $B$  分别为 2 个掩码。

首先,需要确定  $A$  和  $B$  的重叠像素数,代表了 2 个掩码共同覆盖的区域。然后,需要计算 2 个掩码中所有像素的总数,即每个掩码的像素数之和。*IoU* 通过将重叠像素数除以总像素数计算,反映 2 个掩码的覆盖程度。

## 2.3 试验细节

所有 MRAU 试验均在 PyTorch 深度学习框架下,并使用 NVIDIA 24GB RTX A5000 GPU 进行。训练过程中混合使用了 3 个数据集,并将每个数据集按 8 : 2 的比例划分为训练集和测试集。模型采用交叉熵损失来衡量真实值与预测输出之间的差异,

从而在训练过程中调整权重并优化性能。训练进行了约 500 个 epoch, 并使用数据增强来优化网络参数。分割模型训练使用 Adam 优化器, 学习率为 0.001, 动量为 0.9。模型以每批次 8 个样本的批量大小进行训练, 经过 500 个 epoch, 每个 epoch 迭代 9 次, 共 4 500 次迭代, 并且每 20 个 epoch 将学习率降低 0.1。

### 3 试验与应用分析

#### 3.1 与主流分割模型的比较

将 MRAU 方法的性能与几种主流分割模型(包括 DeepLab、LRASPP、FCN 和 U<sup>2</sup>Net)进行了比较。表 1 展示了在相同训练条件下的多轮测试结果。MRAU 模型的 *Dice* 平均值和 *IoU* 平均值分别为 92.88% 和 87.51%, 均优于其他模型。与 FCN 相比, U<sup>2</sup>Net 模型的 *Dice* 值提高了 8%, 表明双 U 形结构增

强了网络的特征提取能力。进一步观察显示, 与修改前的 U<sup>2</sup>Net 模型相比, MRAU 的 *Dice* 平均值和 *IoU* 平均值显著提高了 4.71% 和 7.41%。LRASPP 的 *Dice* 和 *IoU* 值相对较低(分别为 72.38% 和 60.23%), 反映出像素误分类较多。

表 1 不同模型的测试性能

Table 1 Test performance of different models

项目	DeepLab	LRASPP	FCN	U <sup>2</sup> Net	MRAU
训练参数/10 <sup>6</sup>	42.0	3.2	35.3	44.0	44.2
训练时间/h	27.4	5.3	25.3	28.6	30.2
<i>Dice</i> /%	78.87	72.38	80.16	88.17	92.88
<i>IoU</i> /%	67.76	60.23	69.54	80.1	87.51

图 8 展示了各模型的分割结果。结果表明, MRAU 模型在水流边识别方面具有较高精度, 且误识别像素点较少, 说明模型在水流与背景的区别上




图 8 不同模型的分割结果

Fig.8 Segmentation results of different models



表现优异。图8还展示了矿井中灯光昏暗、噪声较大的场景测试情况。测试结果显示,MRAU模型依然能够捕捉涌(突)水特征,与其他模型相比,对噪声和光线的敏感度较低,具备较强的抗干扰能力。

比较了4种现有模型与MRAU在训练过程中的损失函数变化情况。如图9所示,DeepLab模型的损失函数初始值较高,但随后迅速下降,表明其初始学习效果较好。FCN模型的损失函数也呈现出类似的快速下降,但在整个训练过程中波动较小,说明其在训练数据上收敛较为稳定。LRASPP模型最终达到了较低的损失值,但在训练过程中波动较大。

U<sup>2</sup>Net模型的损失函数迅速下降,并在某一时刻后趋于稳定,波动极小,反映了U<sup>2</sup>Net模型在训练早期阶段实现了有效的数据拟合。MRAU模型的初始损失值远高于其他模型,表明其初始误差较大。初期损失函数波动剧烈,随后迅速趋于稳定并持续下降,表明模型对初始数据高度敏感,且能够很好地适应训练样本。在早期阶段,模型的损失函数与其他模型表现出类似的下降速度,但在整个训练过程中波动较大。这些波动是由于MRAU模型复杂性较高且参数较多。然而,损失函数最终趋于稳定,表明MRAU能够有效适应训练数据。

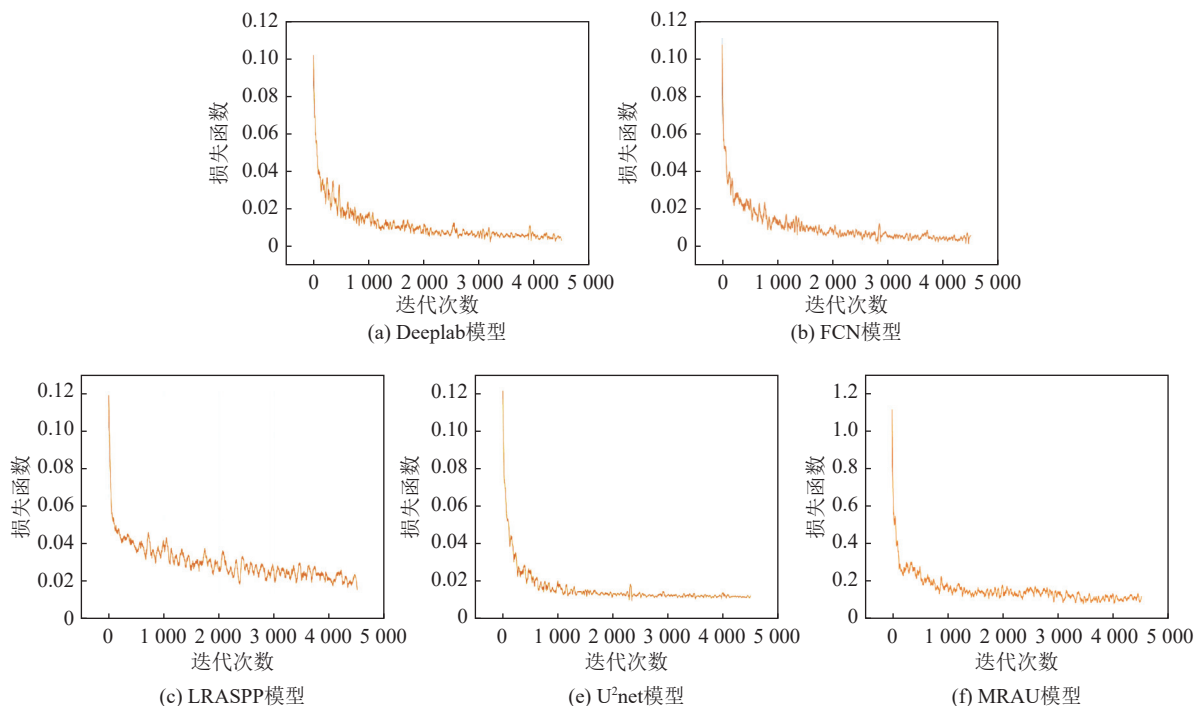


图9 不同模型的损失函数变化曲线  
Fig.9 Change curve of loss function of different models

### 3.2 CBAM 模块性能验证

为验证CBAM对MRAU模型的影响,随机从测试集中选取视频样本进行试验,识别结果如图10所示。

由图10第1行可以看出,当水流与背景区分明显时,未引入CBAM模块的特征提取效果与引入CBAM的MRAU差距不大。然而如图10第2行所示,当背景较为复杂时,未引入CBAM模块的特征提取效果与MRAU相比差距明显,不仅未能提取视频帧上部边缘的水流,且水流轮廓发生了较大变化,因此可见CBAM在降低背景影响方面效果显著。CBAM模块对MRAU模型性能的影响见表2。可知,引入CBAM模块后,模型的Dice和IoU分别提高了2.02%和2.9%。由此可见,CBAM增强了目标特征与边界的区分度,减少了背景特征的干扰,从而

提高了识别精度。

### 3.3 多通道残差注意力机制性能验证

多通道残差注意力机制提升了模型在不同环境中对涌(突)水识别的泛化能力,同时强化了水流




图10 引入CBAM注意力机制的对比效果  
Fig.10 Comparison effect of introducing CBAM attention mechanism

特征。为进一步验证该机制的性能,从测试集中选取了公共水流数据集和矿井涌(突)水数据集进行试验。表 3 的结果表明,完整的 MRAU 模型在 *Dice* 和 *IoU* 分数上显著高于未引入多通道残差注意力机制的模型,分别提高了 2.95% 和 4.13%。此外,引入多通道残差注意力机制后,2 个数据集上的结果均得到改善。

表 2 引入 CBAM 模块的对比结果  
Table 2 Compares results of introducing CBAM module

项目	未引入CBAM	MRAU
<i>Dice</i> /%	88.10	90.12
<i>IoU</i> /%	84.33	87.23

表 3 引入多通道残差注意力机制的模型性能  
Table 3 Performance of model introducing multi-channel residual attention mechanism

项目	无多通道残差注意力机制		MRAU	
	<i>Dice</i> /%	<i>IoU</i> /%	<i>Dice</i> /%	<i>IoU</i> /%
水流公共集	89.10	81.40	93.24	87.58
矿井数据集	85.68	77.81	87.44	79.9
平均值	87.39	79.61	90.34	83.74

图 11 展示了 2 个铁矿数据集的测试结果。在复杂背景下,多通道残差注意力机制使模型能够专注于水流特征,且预测结果与标签高度匹配。然而,未引入注意力机制的模型与标签匹配较差,识别区域分散,且水花边缘匹配不完整。




图 11 引入多通道残差注意力机制的对比效果  
Fig.11 Comparison of the introduction of a multi-channel residual attention mechanism

### 3.4 帧数的定量评价

将多通道残差帧用作水流的动态帧,可有效捕捉水流的动态特征,每一帧都整合了前后帧的动态信息。因此,在反向传播过程中使用中间帧作为标签掩码(图 12),以避免信息丢失。对于连续输入的视频帧,此方法避免了多帧之间的信息丢失,同时增

强了模型对动态特征的捕捉能力。




图 12 中间帧标记示意  
Fig.12 Schematic diagram of intermediate frame marking

为探究不同输入帧数量对模型识别效果的影响,进行了测试集试验,结果见表 4。当输入 3 帧时识别效果最佳,*Dice* 和 *IoU* 分数分别达到 92.88% 和 87.51%。这说明 3 帧输入能够在捕捉水流的动态变化和保持较高的时序性之间达到最佳平衡。当输入帧数超过 3 帧时,识别率下降。模型需整合更多帧的信息,使部分中间帧的标签难以反映所有帧的特征,从而削弱了对动态信息的捕捉效果。这种现象可以归因于在连续的时间序列中,某些中间帧的水流特征变化不明显,增加了模型对无效信息的处理负担,进而影响整体识别效果。此外,使用单帧输入时,*Dice* 和 *IoU* 分数分别比 3 帧输入低 3.39% 和 5.71%,进一步证明多帧输入使模型能够更好地捕捉水流的时序性,增强对水流流动细节特征的敏感度。

表 4 不同输入帧数的识别结果  
Table 4 Identification results of different input frame numbers

项目	1帧	3帧	5帧	7帧
<i>Dice</i> /%	89.50	92.88	90.67	87.38
<i>IoU</i> /%	81.80	87.51	83.51	79.08

### 3.5 跨场景涌(突)水水量动态识别

为评估 MRAU 算法在矿井涌(突)水视频识别领域的有效性并间接验证其跨场景泛化能力,采用某矿的突水样本进行测试,该样本类型未在训练集中出现。测试样本为井下工作面底板突水的视频,如图 13 所示。图 13a 中的原始视频帧显示水从底板含水层连续喷出的情景,水流如喷泉般涌出,且水量随时间增加。最终识别结果如图 13d 所示,MRAU 有效地分割了突水区域,*Dice* 值为 86.75%,*IoU* 值为 80.23%。




图 13 MRAU 突水分割结果

Fig.13 Results of MRAU water intrusion segmentation

此外,还比较了其他模型的跨场景识别能力,见表 5。结果表明,MRAU 在跨场景识别中显著优于其他模型。

表 5 不同模型的跨场景突水识别性能指标

Table 5 Performance indicators of cross-scene water intrusion recognition for different models

项目	DeepLab	LRASPP	FCN	U <sup>2</sup> Net	MRAU
Dice/%	76.86	81.39	78.28	82.50	86.75
IoU/%	68.97	73.07	70.49	75.67	80.23

图像分割技术能够捕捉涌(突)水特征,从而实现从无到有的识别。此外,通过分析矿井涌(突)水过程中多张视频帧中水流面积的变化,可以捕捉到涌(突)水的初始迹象及其扩展过程。因此,本次试验对图 13 所示的突水视频进行了像素值统计,结果如图 14 所示。每一帧的含水像素数量随时间增加,呈现出明显的扩展趋势。

### 3.6 应用分析

在矿井中部署大量防爆摄像头,使模型能够在复杂环境下获取稳定且清晰的图像。鉴于回采和掘进工作面水害发生概率较高,利用该位置的摄像头进行视频数据采集,并通过安防平台管理视频流,实现实时监测。利用 MRAU 模型的预处理方法,对视频流进行实时解析。将训练好的 MRAU 模型通过 ONNX 神经网络框架集成到安防平台中,实现涌(突)水的自动识别。经测算,模型调用一个摄像头进行识别的时间为 5 s,表明该方法能够满足矿井突发水情的实时监控需求。

在矿井涌(突)水实时监测过程中,因其动态演




图 14 突水像素变化曲线

Fig.14 change curve of water intrusion pixels

变为突发事件,难以观测到真实情形,因此难以用于模型的测试和验证。为进一步验证模型在实际场景中的应用可行性,本研究基于某工作面视频流模拟真实突水场景,以便在安全、可控环境下进行测试,不仅确保了人员和设备的安全,还生成大量测试数据,用于检验模型的可靠性。此外,模拟突水场景可多次重复测试,降低成本和时间消耗,确保模型在各种条件下均能稳定运行。本次模拟地点选在陕西某矿 4107 工作面 115 号支架底板,突水类型为底板突水。监测过程中,在安防平台的视频流中定时插入视频帧。监测结果如图 15 所示。

图 15a 展示了模拟的底板突水图像,其中水量逐渐增加。图 15b 和图 15c 分别展示了预测的二值图像和目标提取结果。可知,随着时间推移,分割区




图 15 模拟监测结果

Fig.15 Simulated monitor results



域的面积逐渐增加。此外,识别结果中的噪声点较少,这是由于回采和掘进数据集作为无水标签参与训练,使模型充分学习了井下环境。另一方面,由于在模型训练中未使用回采工作面的突水样本,进一步证明了 MRAU 在井下作业环境中的优异表现。表 6 详细列出了每一帧的水像素数量,各帧之间的差值始终大于 0,清晰地表明突水面积在不断扩大,显示出明显的突水趋势。

表 6 不同视频帧中水像素个数

Table 6 Number of water pixels in different image frames

$t_1$	$t_2$	$t_3$	$t_4$
32 846	40 753	76 567	94 156

## 4 结 论

1) MRAU 对地下场景变化具有高度的鲁棒性。模型的 *Dice* 和 *IoU* 分别达到 92.88% 和 87.51%, 比  $U^2Net$  提高了 4.71% 和 7.41%, 能够准确识别涌(突)水特征。

2) 融合多通道残差注意力机制, 提高了模型在不同场景下的泛化能力。融合后的 MRAU 模型的 *Dice* 和 *IoU* 相较于未融合时分别提高了 2.95% 和 4.13%。引入 CBAM 注意力模块以改进  $U^2Net$  网络, 提升了模型的 *Dice* 和 *IoU*, 分别增加了 2.02% 和 2.9%。此外, 中间帧标签能够有效捕捉水流的动态特征, 并且连续帧的最佳数量为 3 帧。

3) 在真实突水场景中进行测试, 结果表明 MRAU 的识别效果最佳, 验证了其出色的跨场景识别能力。同时, 还研究了涌(突)水从小到大的动态演变过程。分析多帧视频图像, 尤其是对含水像素随时间扩展趋势的统计, 显示 MRAU 模型能够有效捕捉涌(突)水的初始迹象及其水量和水流面积增大的趋势。在井下作业场景中, 模拟突水场景以检验 MRAU 模型的泛化能力。结果表明, MRAU 能够很好地识别回采工作面的突水, 验证了模型在实际应用中的可行性。

### 参考文献(References):

- [1] 武强. 我国矿井水防控与资源化利用的研究进展、问题和展望[J]. 煤炭学报, 2014, 39(5): 795–805.  
WU Qiang. Progress, problems and prospects of prevention and control technology of mine water and reutilization in China[J]. Journal of China Coal Society, 2014, 39(5): 795–805.
- [2] 武强, 崔芳鹏, 赵苏启, 等. 矿井水害类型划分及主要特征分析[J]. 煤炭学报, 2013, 38(4): 561–565.  
WU Qiang, CUI Fangpeng, ZHAO Suqi, et al. Type classification and main characteristics of mine water disasters[J]. Journal of China Coal Society, 2013, 38(4): 561–565.
- [3] 曾一凡, 武强, 赵苏启, 等. 我国煤矿水害事故特征、成因与防治对策[J]. 煤炭科学技术, 2023, 51(7): 1–14.  
ZENG Yifan, WU Qiang, ZHAO Suqi, et al. Characteristics, causes, and prevention measures of coal mine water hazard accidents in China[J]. Coal Science and Technology, 2023, 51(7): 1–14.
- [4] 武强, 徐华, 赵颖旺, 等. 基于云平台的矿井水害智慧应急救援系统与应用[J]. 煤炭学报, 2018, 43(10): 2661–2667.  
WU Qiang, XU Hua, ZHAO Yingwang, et al. Cloud-based smart emergency rescue system and its application in mine water disaster[J]. Journal of China Coal Society, 2018, 43(10): 2661–2667.
- [5] 王学文, 王孝亭, 谢嘉成, 等. 综采工作面 XR 技术发展综述: 从虚拟 3D 可视化到数字孪生的演化[J]. 绿色矿山, 2024, 2(1): 76–85.  
WANG Xuewen, WANG Xiaoting, XIE Jiacheng, et al. Review of XR technology development in fully mechanized mining faces: From 3D visualization to digital twin[J]. Journal of Green Mine, 2024, 2(1): 76–85.
- [6] 鲍久圣, 张可琨, 王茂森, 等. 矿山数字孪生 MiDT: 模型架构、关键技术及研究展望[J]. 绿色矿山, 2023, 1(1): 166–177.  
BAO Jiusheng, ZHANG Kekun, WANG Maosen, et al. Mine digital twin: Model architecture, key technologies and research prospects[J]. Journal of Green Mine, 2023, 1(1): 166–177.
- [7] 闫志蕊, 王宏伟, 耿毅德. 基于改进 DeeplabV3+ 和迁移学习的煤岩界面图像识别方法[J]. 煤炭科学技术, 2023, 51(S1): 429–439.  
YAN Zhirui, WANG Hongwei, GENG Yide. Coal-rock interface image recognition method based on improved DeeplabV3+ and transfer learning[J]. Coal Science and Technology, 2023, 51(S1): 429–439.
- [8] 闫旭, 郭建雄. 图像处理技术在无人综采系统中的应用研究[J]. 煤炭科学技术, 2022, 50(S1): 269–276.  
YAN Xu, WU Jianxiong. Application of image processing technology in unmanned fully mechanized mining system[J]. Coal Science and Technology, 2022, 50(S1): 269–276.
- [9] 许献磊, 王一丹, 朱鹏桥, 等. 基于高频雷达波的煤岩层位识别与追踪方法研究[J]. 煤炭科学技术, 2022, 50(7): 50–58.  
XU Xianlei, WANG Yidan, ZHU Pengqiao, et al. Research on coal and rock horizon identification and tracking method based on high frequency radar waves[J]. Coal Science and Technology, 2022, 50(7): 50–58.
- [10] 曹现刚, 李莹, 王鹏, 等. 煤矸石识别方法研究现状与展望[J]. 工矿自动化, 2020, 46(1): 38–43.  
CAO Xiangang, LI Ying, WANG Peng, et al. Research status of coal-gangue identification method and its prospect[J]. Industry and Mine Automation, 2020, 46(1): 38–43.
- [11] 饶中钰, 吴景涛, 李明. 煤矸石图像分类方法[J]. 工矿自动化, 2020, 46(3): 69–73.  
RAO Zhongyu, WU Jingtao, LI Ming. Coal-gangue image classi-

- fication method[J]. Industry and Mine Automation, 2020, 46(3): 69–73.
- [12] 沈宁, 窦东阳, 杨程, 等. 基于机器视觉的煤矸石多工况识别研究[J]. 煤炭工程, 2019, 51(1): 120–125.  
SHEN Ning, DOU Dongyang, YANG Cheng, et al. Research on multi-condition identification of gangue based on machine vision[J]. Coal Engineering, 2019, 51(1): 120–125.
- [13] 杨春雨, 袁晓光. 煤矿井下巷道变形巡检视频异常检测方法[J]. 工矿自动化, 2021, 47(2): 13–17.  
YANG Chunyu, YUAN Xiaoguang. Anomaly detection method of inspection video for coal mine underground roadway deformation[J]. Journal of Mine Automation, 2021, 47(2): 13–17.
- [14] 王昱栋, 代伟, 马小平. 基于机器视觉的锚杆异常快速检测方法[J]. 工矿自动化, 2021, 47(4): 13–18.  
WANG Yudong, DAI Wei, MA Xiaoping. Rapid detection method of bolt abnormality based on machine vision[J]. Journal of Mine Automation, 2021, 47(4): 13–18.
- [15] 付燕, 李瑶, 严斌斌. 一种煤矿井下视频图像增强算法[J]. 工矿自动化, 2018, 44(7): 80–83.  
FU Yan, LI Yao, YAN Binbin. An underground video image enhancement algorithm[J]. Industry and Mine Automation, 2018, 44(7): 80–83.
- [16] 王震威, 冯瑾, 卢兆林. 基于耦合偏微分方程的煤矿图像去噪算法[J]. 工矿自动化, 2013, 39(10): 81–85.  
WANG Zhenwei, FENG Jin, LU Zhaolin. Denoising algorithm for coal mine image based on coupled partial differential equations[J]. Journal of Mine Automation, 2013, 39(10): 81–85.
- [17] 孙继平, 江静. 基于 PURE-LET 的激光光斑图像快速去噪算法[J]. 煤炭学报, 2013, 38(9): 1710–1714.  
SUN Jiping, JIANG Jing. PURE-LET-based fast denoising algorithm for laser spot imagery[J]. Journal of China Coal Society, 2013, 38(9): 1710–1714.
- [18] 田丰, 陈婷婷, 刘晓佩. 基于自适应光照估计的 Retinex-Net 矿井图像增强算法研究[J/OL]. 煤炭科学技术, 2024: 1–16 [2024–06–30]. DOI: [10.12438/cst.2024-0561](https://doi.org/10.12438/cst.2024-0561).
- Tian Feng, Chen Tingting, Liu Xiaopei. Research on Retinex-Net mine image enhancement algorithm based on adaptive illumination estimation [J/OL]. Coal Science and Technology, 2024: 1–16. [2024–06–30]. DOI: [10.12438/cst.2024-0561](https://doi.org/10.12438/cst.2024-0561).
- [19] YU C D, LUO H Z, FAN Y W, et al. A cascaded convolutional neural network for two-phase flow PIV of an object entering water[J]. IEEE Transactions on Instrumentation and Measurement, 2021, 71: 5002410.
- [20] MANGALRAJ M, MOHANTY A, SINGH S. Salient object detection using water flow approach and image boundary contrast map[C]//2021 International Conference on Computing, Communication, and Intelligent Systems (ICCCIS). Greater Noida: IEEE, 2021: 161–166.
- [21] KHAN M N, ANWAR S. Robust weed recognition through color based image segmentation and convolution neural network based classification[C]//ASME International Mechanical Engineering Congress and Exposition, Salt Lake City: American Society of Mechanical Engineers, 2019: V004T05A045.
- [22] SANGHYUN W, JONGCHAN P, JOON-YOUNG L, et al. CBAM: Convolutional block attention module[C]//Proceedings of the European Conference on Computer Vision (ECCV), 2018: 3–19.
- [23] QIN X B, ZHANG Z C, HUANG C Y, et al. U<sup>2</sup>-Net: Going deeper with nested U-structure for salient object detection[J]. Pattern Recognition, 2020, 106: 107404.
- [24] RONNEBERGER O, FISCHER P, BROX T. U-net: Convolutional networks for biomedical image segmentation[C]//Medical image computing and computer-assisted intervention–MICCAI 2015: 18th international conference. Munich: Springer International Publishing, 2015: 234–241.