

基于多普勒雷达的突发性灾害体智能识别

乐千桢^{2,3}, 张瑞^{2,3}, 陈辉^{1,2,3,*}, 闫帅星¹, 王东坡¹

1.地质灾害防治与地质环境保护全国重点实验室, 成都 610059

2.数学地质四川省重点实验室, 成都 610059

3.成都理工大学数学科学学院, 成都 610059

摘要:针对突发性地质灾害识别的高精度与实时性需求, 本研究提出了一种适用于多普勒雷达的轻量级多尺度特征融合网络 DRWAF-Net (Doppler Radar Wavelet Attention Fuse Network), 通过小波变换与注意力机制协同优化, 实现了复杂地表环境下泥石流、滚石等灾害体的实时识别。研究充分利用多普勒雷达动态捕获灾害体距离与速度的能力, 整合环境干扰下的泥石流数据集与 RDRD 数据集的核心要素, 针对性构建了突发地质灾害场景的多普勒雷达数据集。实验结果表明, DRWAF-Net 以 2.38M 参数量、9.27MB 模型大小和 6.31ms 推理速度, 使准确率 (96.77%)、精确率 (96.90%)、召回率 (96.77%) 和 F1 分数 (96.77%) 均在测试集上达到最优水平。消融实验验证, 结合多输入注意力门控 (MIAG) 机制的 DRWAF-Net 较基准模型提升识别率 1.87%-3.13%。本研究通过轻量化设计与实时推理优化, 为突发性地质灾害应急响应提供了实时、智能的监测方案。

关键词: 突发性地质灾害; 深度学习; 多普勒雷达; 目标识别; 注意力机制;

中图分类号: P694

收稿日期: 2025-07-03

基金项目: 国家自然科学基金委员会 (42207232), 四川省科学教育联合基金 (项目编号: 2024NSFSC1952), 成都市科学技术局技术创新研发项目 (2024 YF05-01584-SN), 地质灾害防治与地质环境保护全国重点实验室自主研究课题 (SKLGP2022Z011)

第一作者简介: 乐千桢 (1976-), 副教授, 硕士生导师, 主要从事人工智能技术在地质灾害监测的研究。E-mail: leqianqi@cdut.edu.cn, ORCID: 0009-0008 8392-5055

1 引言

全球气候变化加剧及人类活动影响下，泥石流、滚石、崩塌等突发性地质灾害频发（Rickenmann, 1999; Jakob and Lambert, 2009）。这些灾害由岩石风化、地震、降雨或融雪等因素触发，具有突发性强、破坏性大、预警难度等典型特征（何思明等, 2014; 左力艳和杨建锋, 2023）。2014 年“8·3”鲁甸地震致使超 617 人死亡，经济损失 4.6026 亿元，武警云南边防总队救援队谢樵在救援过程中被落石击中，不幸牺牲（石岩和孟宪虎, 2014; 修济刚和陈宇鸣, 2014; 罗璟, 2020）。2019 汶川“8·20”特大山洪泥石流席卷全县 100%乡镇，致 90%以上群众受灾，造成至少 16 人死亡，直接经济损失约 36 亿元，水磨镇政府消防专职队 1 车 7 名消防员救援途中遭遇突发山洪泥石流，造成班长更斯穷牺牲、4 人受伤（昌开馨, 2019; 李明威等, 2021; 罗玉婷, 2021）。这些灾害事件凸显了对地质灾害应急响应时，做到实时监测预警的重要性。

在突发性地质灾害应急响应中，快速准确的灾害类型识别直接影响救援效率与资源配置（La et al., 2022）。传统地质灾害监测手段在实时性与精准性方面存在显著不足。卫星遥感技术（如 Landsat、Sentinel-2 和 Sentinel-1 等）依赖重访周期获取时间序列化光谱和 SAR 图像，时间分辨率从 Radarsat 的数周至 WorldView 卫星群的 1 天不等，难以捕捉短时突发灾害动态；地面 SAR 技术（GBSAR）虽可实现 2 分钟亚毫米级数据采集，但对快速运动目标（速度 >1.8 m/h）的识别能力有限；地面传感器监测系统受限于数据稀疏性、环境干扰及监测盲区，难以满足实时、精准预警的需求（崔鹏等, 2000; 赵延广和雷斌, 2022; Casagli et al., 2023）。相较传统手段，多普勒雷达通过捕捉动态目标的运动特征，可实时获取灾害体的速度（ >1 m/s）、距离等关键参数（Michelini et al., 2020），为地质灾害监测提供了新的技术路径。其高精度与强实时性已得到实际应用验证：HYDRA-G ArcSAR 雷达系统和多普勒雷达系统 RockSpot 等成功监测到 Poggio Baldi 滑坡碎屑流运动过程和多次落石事件（Romeo et al., 2021），并有效跟踪了露天矿中的落石（Michelini et al., 2020）以及阿尔卑斯山区的数次雪崩和岩崩事件（Viviani et al., 2020）。然而，在灾害类型复杂多变场景下，现有

技术仍难以实现灾害类型的实时准确识别,这一瓶颈问题成为制约地质灾害应急响应效能提升的关键。

当前雷达目标识别技术主要沿着三个方向发展,但各自存在明显局限性。基于数据库的模板匹配方法通过构建高精度模板库实现目标比对,在已知目标库完备时展现出较高识别精度(Huether et al., 2001; 王琨鹏等, 2014; 张林等, 2014; 张鹏宇等, 2022)。但该范式存在三点不足:识别性能与模板数量呈强正相关,计算复杂度随数据库规模指数级增长;特征模板的空间分辨率与角度覆盖度要求形成工程实现的悖论;面对未录入模板库的灾害体类型,系统将丧失识别能力(Zhou et al., 2019)。基于统计学习领域的贝叶斯框架构建分类模型,依托先验知识库实现概率推理,在先验分布已知时表现良好(Chiang et al., 2000; 沈妍琰等, 2020; 李巧等, 2024)。但其性能受制于海量灾害体样本所支撑的准确条件概率密度,以及单一灾害点的局部概率分布,难以泛化(Dubey et al., 2021)。深度学习技术的引入显著提升了雷达目标识别的鲁棒性和泛化能力,突破了传统方法依赖人工设计特征的局限。当前主流深度学习模型分为 Transformer 架构(Vaswani et al., 2017)和卷积神经网络(Convolutional Neural Network, CNN)(Rawat and Wang, 2017; Ajit et al., 2020; Li et al., 2022):前者全局建模能力强但计算复杂度高、参数量大,难以满足雷达的实时性要求;而 CNN 凭借局部感受野和参数共享机制,在局部特征提取和计算效率上更具优势(刘石狮, 2024)。

结合雷达信号特性,学界提出了类时频分析结合 CNN 的创新路径。如马腾等(2024)使用 CNN 结合长短期记忆网络(Long Short-Term Memory, LSTM)构建的 CNN-LSTM 混合模型成功捕获雷达散射截面(Radar Cross section, RCS)信号的空间-时序特征,凸显了深度神经网络处理复杂雷达数据的潜力。Wang et al.(2019)构建的雷达微多普勒特征空间刚性目标分类模型、Roldan et al.(2020)提出的 DopplerNet 模型、Liu et al.(2025)针对复杂情况下识别泥石流的投票模型等,这些深度学习模型都是通过自主学习事件特征,显著提升了目标识别性能。然而,现有方法仍存在双重挑战:一方面,复杂环境下的广域多级特征提取需高容量模型支撑,导致参数规模与计算耗时急剧增加(Boonpook et al., 2021);另一方面,基于多帧序列的分析方法受制于雷达扫描间隔(典型值 400ms/帧)

(Roldan et al., 2020), DopplerNet 模型要得到最佳结果需要两帧作为输入需耗时 800ms, 在灾害应急等时效敏感场景难以满足实时响应需求。因此, 如何在保持高分类精度的同时, 实现模型的轻量化设计与实时推理能力, 成为制约深度学习在雷达目标识别领域深度应用的关键问题。

针对上述关键问题, 本研究提出了一种基于多普勒雷达的突发性地质灾害识别模型 DRWAF-Net (Doppler Radar Wavelet Attention Fuse Network)。该模型通过改进的注意力门控机制来改进小波卷积以构建轻量级多尺度特征融合网络, 对雷达的单帧信号进行高效识别, 旨在提高灾害监测的准确性和实时性(推理时间 ≤ 16 ms/帧)。在此基础上, 设计消融实验验证注意力门控机制模块的有效性, 并使用面向突发地质灾害应急响应数据集, 通过与 Vgg16、ResNet50、MobileNet-v3、ConvNeXt 以及 DopplerNet 等模型的对比试验, 全面评估了模型的性能优势。

2 面向突发地质灾害应急响应数据集

为构建适用于突发地质灾害应急响应现场的多普勒雷达数据集, 本研究整合了环境干扰下的泥石流数据集(Liu et al., 2025)与 RDRD 数据集(Roldan et al., 2020)的核心要素, 覆盖面向应急响应核心需求的 7 分类融合数据集。该数据集聚焦灾害现场高频核心目标: 泥石流数据集提供的灾害本体与次生灾害(泥石流、落石、水流三类, 各 3000 样本)作为灾情判识的直接威胁来源; 环境干扰植被(3000 个样本)用于增强算法在复杂植被背景下的鲁棒性, 抑制灾害目标误检; 整合 RDRD 数据集中的应急响应载体(车辆、无人机各 3000 样本)与现场人员(3000 样本)则支撑空地协同的救援调度与人员安全保障。综上, 数据集共涵盖 7 类 21000 个样本, 系统性覆盖灾害威胁感知、环境干扰抑制、救援力量及人员安全保障等关键环节。




图 1 构建面向突发地质灾害应急响应数据集；(a)预处理环境干扰下的泥石流数据集；(b)预处理 RDRD 数据集

Fig. 1. Construction of an emergency-response-oriented dataset for sudden geological hazard: (a) Pre-processing of the debris-flow dataset under environmental disturbances; (b) Pre-processing of the RDRD dataset

为此，本研究在去除掉环境干扰下的泥石流数据集中明显异常的数据后，鉴于所有距离-多普勒频率谱图的坐标尺度与色标范围统一，使用 Python 的工具包 Pillow 对剩余原始图像进行智能裁剪，提高有效信息占比。此外，将裁剪后的图像统一缩放至标准输入尺寸（长宽均为 224 像素），以适应网络模型的架构要求（图 1(a)）。

为使 RDRD 数据集的表格数据能适用于本研究的多普勒雷达网络模型，使用 Python 的工具包 Pandas 和 Matplotlib 将各表格文件绘制为距离-多普勒频率谱图。采用与环境干扰下的泥石流数据集色标映射一致的“jet”，并对每个距离-多普勒矩阵进行最小-最大归一化（Min-Max Normalization），使得归一化后的能量分布数据分配到相应色标。然后，根据距离-多普勒矩阵的横纵轴比率确定自适应像素比，从而绘制标准尺寸的距离-多普勒谱图（图 1(b)）。

其中，最小-最大归一化和自适应像素比的计算公式为：

$$X'_i = \frac{X_i - X_{min}}{X_{max} - X_{min}}, \quad (1)$$

$$aspect = \frac{N_c}{N_r}, \quad (2)$$

公式(1)中 X_i 是未归一化的原始数据, X_{min} 是当前距离-多普勒矩阵中的最小值, X_{max} 是当前距离-多普勒矩阵中的最大值, X'_i 是归一化后的结果。(2)式中, $aspect$ 为自适应像素比, N_c 为距离-多普勒矩阵的列数, N_r 为距离-多普勒矩阵的行数。根据自适应像素比绘制的数据集可以有效避免传统的深度学习中, 为了统一输入层尺寸而进行缩放(Resize)所使用的诸如双线性插、最近邻插值等插值算法所造成的信息丢失。

3 适用于多普勒雷达的网络模型

3.1 注意力门控型小波变换特征融合网络

由于多普勒谱图是以色块表征灾害体信息, 不但需要关注色块位置和颜色, 更要注意相连色块所构成的色带所形成的水平、垂直以及形状差异。因此, 为有效提取多普勒谱图的深层、判别性特征, 我们提出了一种新颖的轻量级多尺度特征融合网络——适用于多普勒雷达的注意力门控型小波变换特征融合网络(Doppler Radar Wavelet Attention Fuse Network, DRWAF-Net)。为提高模型准确率, 采用了类似特征金字塔(Feature Pyramid Networks, FPN)、Inception 模块等常用多尺度特征提取方法(Szegedy et al., 2015; Yu and Koltun, 2016; Cai et al., 2016; Lin et al., 2017;)。DRWAF-Net 的核心设计理念在于层级特征精炼与高效信息流控制, 其骨干网络架构由一系列精心设计的定制化的下采样特征提取模块(DownScalingWTAGConv2dBlock)顺序堆叠而成。




图 2 DRWAF-Net 总体框架；(a)轻量级目标识别网络模型结构图；(b)下采样特征提取模块结构图；(c)预测头结构图

Fig. 2. Framework of DRWAF-Net: (a) Architecture of the lightweight object identification network; (b) Structure of the down-sampling feature-extraction module; (c) Structure of the prediction head

如图 2(a)所示，距离-多普勒频率谱图（原始数据输入）输入网络后，先后经历 5 层级联的 DownScalingWTAGConv2dBlock 提取特征并逐渐压缩空间维度，以增加通道数量的方式来增强特征判别性。末级 DownScalingWTAGConv2dBlock 输出经展平后接入预测头（Predict Head），缩减通道至 128 维后，应用 Softmax 函数进行分类（图 2(c)）。这使得预测头在平衡特征丰富度与计算效率的同时避免了过参数化，并且因其独立于主干网络，可设计不同任务的预测头有便于应对相应任务。

3.2 下采样特征提取模块

如图 2(b)所示，DownScalingWTAGConv2dBlock 的核心创新之处在于其巧妙集成的注意力门控型小波卷积模块（WTAGConv2dBlock）。该模块充分利用小

波变换强大的多尺度分析能力，对特征进行精准提取，这能够捕捉到不同尺度下的关键信息，从而为后续的处理提供更为丰富和细致的特征表示。在此基础上，WTAGConv2dBlock 模块内嵌的多输入注意力门控机制（Multi-Input Attention Gate, MIAG）进一步发挥了关键作用，它能够依据特征的重要性和相关性，自适应地对来自多个输入的特征进行融合与强化，使得关键特征得以凸显，同时抑制不相关或次要的特征信息，进而提升了特征表达的判别性和有效性，为网络的性能提升奠定了坚实基础。

在完成特征提取与初步处理后，为了降低特征图的空间分辨率，保留最为显著的特征响应，DownScalingWTAGConv2dBlock 采用了最大池化（MaxPool2d）操作进行下采样。MaxPool2d 通过在指定的窗口区域内选取最大值，不仅有效地减少了特征图的尺寸，降低了计算复杂度，还保留了局部区域内的最显著特征，增强了模型对特征的鲁棒性和泛化能力，使网络能够更加关注于具有重要信息的特征部分，进一步提升了模型的性能和效率。

最后，为充分挖掘和利用特征通道之间的相互依赖关系，DownScalingWTAGConv2dBlock 引入了高效通道注意力模块（Efficient Channel Attention Block, ECABlock）。该模块以轻量级的方式对通道间的关系进行建模，通过学习通道之间的相关性权重，对特征通道进行重新校准，使得网络能够更加关注于信息量丰富、对任务更为关键的特征通道，从而优化了特征表达，进一步提升了网络的性能和效率。

3.3 注意力门控型小波卷积模块

注意力门控型小波卷积模块，即 WTAGConv2dBlock 创新性地融合 MIAG 与小波二维卷积模块（WTConv2d）的优势：WTConv2d 拥有更宽广的感受野（Finder et al., 2024），单个卷积模块即能获取 FPN、Inception 模块类似的感受野，能够有效捕捉目标的形状特征；MIAG 自适应融合 WTConv2d 运算中的多尺度信息，显著增强了模型对关键特征的聚焦能力与特征融合的自适应性。最终，使用 AG 模块（Attention Gate）代替了原本 WTConv2d 所做的求和运算，有效抑制了无关噪声或冗余信息。




图 3 注意力改进的小波卷积模块；(a)WTAGConv2dBlock 的结构；
(b)WTAGConv2dBlock 对输入特征图的处理管线

Fig. 3. Attention-enhanced wavelet transform convolution module: (a) Architecture of WTAGConv2dBlock; (b) Processing pipeline of WTAGConv2dBlock for input feature maps

WTAGConv2dBlock 是提取目标特征的最主要的模块，相较于没有引入 MIAG 的 WTConv2d 模块而言，具有更高的预测准确率（表 3）；相较于传统的多尺度卷积在减少模型参数量和降低计算复杂度方面具有明显优势（如 Inception V3 参数量达 24.36M，而 DRWAF-Net 参数量仅 2.38M），同时能够更高效且高质量地完成特征提取任务（表 2）。

3.3.1 多输入注意力门控

为扩展传统 Attention Gate 的多输入处理能力，本研究受 Transformer 中 Query-Key-Value 架构的启发，首次提出了基于交叉注意力机制的多输入注意力门控机制（MIAG）。该模块允许各输入特征经过分离的特征流，担任本体表示（Queries）和评估依据（Keys）双重角色，通过综合所有输入的特征交互，计

算空间自适应的注意力门限（Attention），赋予各输入特征（Value）以注意力权重，实现智能的多源输入特征融合（图 4(a)）。




图 4 多输入注意力门控模块；(a)MIAG 结构图；(b)MIAG 对特征输入的处理管线

Fig. 4. Multi-Input Attention Gate module: (a) Architecture of MIAG; (b) Processing pipeline of MIAG for feature inputs

此设计突破了传统 Attention Gate 仅支持双输入的限制，Q、K、V 都来自同一输入，实现了基于交叉参考的特征选择，动态生成的空间权重起到“门控”作用，保留了 Attention Gate 的核心思想。其数学表达式等价如下：

$$Output_i = V_i \cdot \sigma \left(Conv \left(Concat \left(\{Q_j\}_1^N, \{K_j\}_1^N \right) \right) \right)_i \quad (3)$$

式 (3) 中， V_i 是 $Input_i$ 未经处理的原始特征值； $\{Q_j\}_1^N$ 与 $\{K_j\}_1^N$ 分别表示所有输入

的 $Queries$ 特征集合与 $Keys$ 特征集合； $Concat$ 用于执行通道维度拼接操作，将所有输入的 $Queries$ 特征集合与 $Keys$ 特征集合从维度上拼接在一起； $Conv$ 是注意力生成器的卷积层序列，亦是图 4(b)中的 $Queries_{(i)}$ 和 $Keys_{(i)}$ 表示的一乘一卷积模块与 ReLU 激活函数的组合处理； σ 是 Sigmoid 激活函数，它允许不同输入的注意力图进行独立激活； $Output_i$ 是 $Input_i$ 与计算注意力图逐元素相乘的结果，亦是经过 MIAG 模块处理的输出结果。

3.3.2 小波二维卷积

基于小波变换构建的小波二维卷积模块（WTConv2d）提高了对形状的敏感性，为 CNN 提供更大的感受野，并增强了网络的鲁棒性（Finder et al., 2024）。通过指定的小波函数 ψ 和分解级数 j 将信号把图像进行逐级分解，各级均涵盖了近似子带（ LL ）、水平细节子带（ LH ）、垂直细节子带（ HL ）和对角细节子带（ HH ）的 4 种不同频率和尺度的成分（图 3(b)）。这种多尺度分析方法使得信号的特征可以从多个层次进行分析，从而更容易识别信号中的瞬态特征以及突变等多尺度关键特征。

$$\begin{aligned}
 LL(j, k) &= \sum_{m,n} f(m, n) \cdot \phi(2^j m - k) \cdot \phi(2^j n - k) \\
 LH(j, k) &= \sum_{m,n} f(m, n) \cdot \phi(2^j m - k) \cdot \psi(2^j n - k) \\
 HL(j, k) &= \sum_{m,n} f(m, n) \cdot \psi(2^j m - k) \cdot \phi(2^j n - k) \\
 HH(j, k) &= \sum_{m,n} f(m, n) \cdot \psi(2^j m - k) \cdot \psi(2^j n - k)
 \end{aligned} \tag{4}$$

公式（4）中， LL 是近似子带， LH 是水平细节子带， HL 是垂直细节子带， HH 是对角细节子带， $f(m, n)$ 是输入的二维离散信号， ϕ 是尺度函数， ψ 是小波函数， j 是分解的尺度（分解级数）， k 是平移参数。

本研究中，为保持网络性能与计算的实时性，分解级数 j 始终为 1；小波函数 ψ 选择的是计算复杂度较低，适合处理多普勒谱图的 Haar 小波。其表达式如

下：

$$f(x) = \begin{cases} 1, & 0 \leq x < \frac{1}{2} \\ -1, & \frac{1}{2} \leq x < 1 \\ 0, & \text{others} \end{cases} \quad (5)$$

式（5）中， $f(x)$ 表示 Haar 小波函数， x 表示输入值。通过该变换，可以降低输入数据的维度，提高深度学习模型的训练效率。当使用 Haar 小波进行二维离散小波变换时，其对应尺度函数 ϕ 和小波函数 ψ 的系数如下：

$$\begin{aligned} \phi &= \left[\frac{1}{\sqrt{2}}, \frac{1}{\sqrt{2}} \right] \\ \psi &= \left[\frac{1}{\sqrt{2}}, -\frac{1}{\sqrt{2}} \right] \end{aligned} \quad (6)$$

根据公式（4）与公式（6），为了利用实现 Haar 小波二维卷积，需要使用以下四组滤波器以步幅为 2 进行深度卷积（Finder et al., 2024）：

$$\begin{aligned} f_{LL} &= \frac{1}{2} \begin{bmatrix} 1 & 1 \\ 1 & 1 \end{bmatrix}, & f_{LH} &= \frac{1}{2} \begin{bmatrix} 1 & -1 \\ 1 & -1 \end{bmatrix} \\ f_{HL} &= \frac{1}{2} \begin{bmatrix} 1 & 1 \\ -1 & -1 \end{bmatrix}, & f_{HH} &= \frac{1}{2} \begin{bmatrix} 1 & -1 \\ -1 & 1 \end{bmatrix} \end{aligned} \quad (7)$$

使用（7）式的 f_{LL} 、 f_{LH} 、 f_{HL} 和 f_{HH} 对输入图像卷积后，会输出四个通道的特征图，每个通道（在每个空间维度上）的输出都有输入图像分辨率的一半，对应记为 LL 、 LH 、 HL 和 HH （图 3(b)）。其中 LL 是输入图像的低频分量，而 LH 、 HL 、 HH 是输入图像的水平、垂直和对角线高频分量。

相较于传统的二维卷积，由小波二维卷积模块进行小波分解得到的 LL 、 LH 、 HL 和 HH 能够提供更全面的、不同尺度下的高频细节特征和低频信息，使得模型能够获得更高的准确率（表 3）。

应用 MIAG 处理 LL 、 LH 、 HL 和 HH 特征图，得到的 W_{LL} 、 W_{LH} 、 W_{HL} 和 W_{HH} （图 3(b)）进行特征互补性优化，可以提高模型跨尺度上下文感知能力。针对不同目标的不同尺度信息能够自适应特征选择，而且无论目标尺度如何变化，总有一个

尺度特征被增强。通过 WTConv2d 提供的多尺度特征，再通过 MIAG 实现智能特征选择，这种架构模仿了人类视觉系统的多尺度处理和注意力机制，是解决复杂视觉任务的有效范式。

4 结果与讨论

4.1 与常用网络模型对比测试

为验证方法有效性，本研究中采用的经典基准模型 Vgg16 (Simonyan and Zisserman, 2014) 和 ResNet50 (He et al., 2016; Litjens et al., 2017; Gu et al., 2018; Khan et al., 2020)、轻量级标杆 MobileNet-V3-large (Howard et al., 2019)、代表性的 SOTA (State Of The Arts) 模型 ConvNeXt-Tiny (Liu et al., 2022)、为多普勒雷达设计的 DopplerNet (Roldan et al., 2020) 以及本轻量级多尺度特征融合模型 DRWAF-Net 进行对比实验。

具体测试方法是设定随机数种子为 42 后，将面向突发地质灾害应急响应数据集全部数据按照 2:1 的比例 (Liu et al., 2025) 随机划分为训练集和测试集。然后使用上述提及的所有的模型对训练集进行特征学习，并设计早停机制：当训练集损失值在 10 轮内不再下降，则停止训练。训练 100 轮的过程中，持续测试各模型在测试集上的准确率，在达到指定训练轮次或者满足早停机制时结束模型训练，整个过程中会保留各模型在测试集上准确率最高的模型以供对比。

本研究使用的硬件平台为 13th Gen Intel(R) Core(TM) i9-13900K 处理器，并使用 NVIDIA GeForce RTX 3090 显卡加速训练。软件环境使用的 Python 版本号为 3.12，CUDA 版本号为 12.6，Pytorch 版本号为 2.6.0。

4.1.1 评价指标

评价一个深度学习模型性能的优劣，常使用四个评价标准：准确率 (Accuracy, A)、精确率 (Precision, P)、召回率 (Recall, R) 和 F1 分数 (F1-score, F₁)，其公式如下：

$$\begin{aligned}
Accuracy &= \frac{TP + TN}{TP + TN + FP + FN} \\
Precision &= \frac{TP}{TP + FP} \\
Recall &= \frac{TP}{TP + FN} \\
F1_score &= \frac{2 \times Precision \times Recall}{Precision + Recall}
\end{aligned} \tag{8}$$

其中， TP （True Positive）、 FP （False Positive）、 TN （True Negative）和 FN （False Negative）分别表示真阳性、假阳性、真阴性以及假阴性。 $Accuracy$ 是准确率（A），表示正确分类的样本数与样本总数的比例。 $Precision$ 是精确率（P），用于衡量预测为阳性的样本中真阳性样本的比例。 $Recall$ 是召回率（R），用于测量模型正确预测为真的真阳性样本的比例。 $F1_score$ 代表 F1 分数（F₁），综合考虑了精确率（P）和召回率（R），表示它们的调和平均值，越高表示它们的平衡越好。这四个评价指标（A，P，R，F₁）的取值范围均为[0, 1]。

此外，混淆矩阵（Confusion Matrix）可以提供模型分类性能的详细信息（Heydarian et al., 2022）。混淆矩阵图中，每行表示属于该类的实际样本数，每列对应于预测属于该类的样本总数，对角线元素则表示正确预测的样本数。在模型预测过程中，预测值沿对角线密集分布表明模型的性能越好，通过混淆矩阵图也很容易知道模型倾向于错误分类哪些目标（Liu et al., 2025）。

4.1.2 模型性能

表 1 是以长 224 维度、宽 224 维度、3 通道的标准尺寸张量，并根据面向突发地质灾害应急响应数据集种类数固定输出维度为 7 时，各模型的参数量（Params）、浮点运算次数（FLOPs）、模型大小（Size）以及模型资源效率指标（Model Resource Efficiency Index, MREI），并评估对边缘设备的兼容性。其中，MREI 的公式如下：

$$MREI = \sqrt[3]{Params \times FLOPs \times Size} \tag{9}$$

其中， $Params$ 是以百万（M）为单位的模型参数量； $FLOPs$ 是以十亿（G）为单

位的模型每秒所需计算量，用来衡量一个模型或算法的总体复杂度；*Size*是以兆字节（MB）为单位的模型大小。*MREI* 强调了模型在资源利用方面的效率，其值越小越能直观体现模型“轻量-高效”。

表 1 对比模型列表暨边缘设备兼容性分析

Model (year)	Params (M)	FLOPs (G)	Size (MB)	MREI	兼容性
Vgg16 (2014)	134.29	15.47	512.29	102.10	★☆☆☆☆
ResNet50 (2016)	23.52	4.13	90.06	20.61	★★☆☆☆
MobileNet-V3-large (2019)	4.21	0.23	16.30	2.51	★★★★☆
DopplerNet (2020)	100.94	0.14	385.07	17.59	★★★★☆
ConvNeXt-Tiny (2022)	27.82	4.46	106.23	23.62	★★☆☆☆
DRWAF-Net	2.38	0.29	9.27	1.86	★★★★★

从表 1 的对比数据可知，DRWAF-Net 在模型轻量化表现上优势显著：其参数量仅为 2.38M，模型尺寸压缩至 9.27MB，两项核心指标均优于常用于轻量级设备部署的 MobileNet-V3-large（4.21M 参数/16.30MB 尺寸），成为对比模型中最紧凑的架构。尽管其算力需求（0.29GFLOPs）略高于 MobileNet-V3-large（0.23GFLOPs），但结合 2.38M 的超小参数量来看，单位计算效率表现依然突出。这种极致轻量化设计使其在边缘计算节点、嵌入式多普勒雷达系统等对模型体积与算力敏感的场景中具备独特优势——既能降低硬件存储成本，又能在低功耗设备上实现高效推理，为实时处理等任务提供了更优的工程化解决方案。与 ResNet50（23.52M 参数/90.06MB 尺寸）、Vgg16（134.29M 参数/512.29MB 尺寸）等传统模型相比，DRWAF-Net 的参数规模仅为前者的 1/10 至 1/50，展现出针对资源受限环境的深度优化设计。

使用表 1 中的模型于环境干扰下的泥石流数据集进行训练和测试，具体测试结果如下图：




图 5 各模型每轮测试集的性能对比；(a)准确率对比；(b)精确率对比；(c)召回率对比；(d)F1 分数对比

Fig. 5. Performance comparison of all models on the test dataset across epochs: (a) Accuracy; (b) Precision; (c) Recall; (d) F1-score

图 5 中，DRAWF-Net 在面向突发地质灾害应急响应数据集上的性能表现都十分良好——取得了最高的测试集准确率、精确率、召回率和 F1 分数。此外，DRAWF-Net 的测试准确率、精确率、召回率和 F1 分数在训练第 20 个迭代轮次后率先稳定在 96.3%附近，波动范围小于 0.5%，而其他模型仍在经历明显的性能振荡。这样的表现通常意味着更高的训练效率和资源利用率：模型更快地收敛，意味着节省大量的训练时和计算资源（GPU/CPU 损耗、电力），也从侧面反映出模型架构（模块、层数、类型、宽度等）与当前任务的匹配度较高。




图 6 最佳模型评价指标对比

Fig. 6. Comparison of evaluation metrics for the best-performing models

如图 6 所示，Vgg16、DopplerNet 与 ConvNeXt-Tiny 未达 95%；ResNet50 和 MobileNet-V3-large 突破 95%；DRWAF-Net 以 96.77% 的准确率居首，较次优模型（ResNet50）提升 1.05%，反映其整体预测能力领先。同时，DRWAF-Net 高达 96.90% 的精度意味着预测正类样本可靠性最强，误报率最低（如能减少灾害事件错误报警）；召回率为 96.77% 相较于 ResNet50 的 95.73% 取得 1.04% 的优势，这意味着最优的样本覆盖能力，能最大限度抑制漏检（如灾害事件漏报风险）；F1 分数为 96.77%，显著超越对比模型（如 ResNet50 的 95.71% 和 MobileNet-V3 的 95.58%），体现 DRWAF-Net 查准率与查全率的最佳平衡。总的来说，DRWAF-Net 凭借全面领先的指标表现，不仅验证了其模型架构兼具高精度与高鲁棒性，更为突发灾害应急响应场景的实时监测预警提供了可靠性更高的解决方案。

表 2 模型最佳性能与推理耗时对比

Model (year)	FLOPs (G)	A (%)	P (%)	R (%)	F ₁ (%)	Time (ms)
Vgg16 (2014)	15.47	93.26	93.73	93.26	93.09	2.35
ResNet50 (2016)	4.13	95.72	95.83	95.73	95.71	6.37
MobileNet-V3-large (2019)	0.23	95.59	95.63	95.59	95.58	6.42
DopplerNet (2020)	0.14	91.18	91.38	91.19	91.04	1.26

ConvNeXt-Tiny (2022)	4.46	77.73	79.79	77.73	77.02	5.69
DRWAF-Net	0.29	96.77	96.90	96.77	96.77	6.31

如表 2 所示，虽然 DRWAF-Net 在算力需求（0.29GFLOPs）和推理耗时（6.31ms）上并非最优，但其综合性能显著领先：在四大核心指标上超越 ConvNeXt-Tiny、Vgg16 和 DopplerNet（如 F1 分数领先 DopplerNet 5.73%）；相较排名第二的 ResNet50，推理速度提升 0.94%，且准确率（A）、精度（P）、召回率（R）和 F1 分数（F₁）均高出 $\geq 1\%$ 。值得注意的是：DRWAF-Net 仅需 0.29GFLOPs 算力，不及 ResNet50 的 7%（4.13GFLOPs），在边缘设备部署时能有效避免算力瓶颈；并且，结合多普勒雷达数据帧从数秒一帧到一秒数十帧不等（Roldan et al., 2020; Ristic et al., 2022），DRWAF-Net 推理耗时 6.31ms 是完全满足实时处理需求的（阈值：数十毫秒）。综上，DRWAF-Net 凭借最佳的精度-效率平衡（96.77%准确率与 0.29GFLOPs），成为突发灾害应急响应场景的最优解。




图 7 对测试样本进行多分类的混淆矩阵

Fig. 7. Confusion matrix for multi-class classification on the test samples

如图 7 所示，DRWAF-Net 在灾害本体与次生灾害识别方面表现最佳，这对应急响应人员的安全至关重要。在泥石流类（DF）识别上，Vgg16、ResNet50、MobileNet-V3-large 及 DRWAF-Net 均达到 100%的准确率。而在滚石类（ROCK）

和 水流类（CREEK）识别上，DRWAF-Net 分别以 96.9%和 89.5%的准确率领先，相较次优模型 Vgg16 对两类的准确率分别提升 0.4%和 0.3%。然而，包括 DRWAF-Net 在内的模型普遍存在“水流-无人机混淆”现象：对水流类（CREEK）的误判率均超过 10%。这表明，在无人机与水流目标处于多普勒雷达相同方位角与仰角的场景下，模型存在超过 10%的概率将水流威胁误判为无人机或其他目标，构成模型在实际应用中的潜在失效风险。进一步分析发现，水流与无人机两类目标在经模型多层卷积处理后所生成的特征表示具有较高的相似性，导致模型在区分这两类目标时难以实现令人满意的分类精度。此外，在植被类（VEGE）识别中，DRWAF-Net 也取得了 96.8%的最佳准确率，显著解决了 Vgg16（207 次误分）、DopplerNet（95 次误分）和 ConvNeXt-Tiny（598 次误分）模型中因动态场景运动特征提取不足导致的关键 ROCK-VEGE 混淆问题，将该类错误限制在仅 9 个案例内。综合各项识别性能，DRWAF-Net 不仅确保了灾害本体、次生灾害、环境干扰及应急响应载体识别的准确性，还进一步降低了系统的误报率。

4.2 多输入门控消融实验

在模块中添加新的模块可以毫无疑问地说会增加模型参数量，这无疑会增加模型的浮点运算次数，单纯的参数量、浮点运算次数的对比无法全面反映新模块的作用。因此，为验证 MIAG 的有效性，参与消融实验的模型依据相同的骨干网络的基础模块不同，划分为使用未经过修改的 WTConv2 构建的 DRNet-v1（Doppler Radar Network version 1）、使用仅在 WTConv2d 结合 AG 模块构建的 DRNet-v2（Doppler Radar Network version 2）、使用仅在 WTConv2d 加入 MIAG 模块构建的 DRNet-v3（Doppler Radar Network version 3）以及使用 WTAGConv2dBlock 构建的 DRWAF-Net，分别测试这三个模型在面向突发地质灾害应急响应数据集上的性能表现。

表 3 消融实验性能对比

Model (block)	Size (MB)	A (%)	P (%)	R (%)	F ₁ (%)	Time (ms)
DRNet-v1 (None)	6.50	93.68	93.85	93.69	93.64	4.12
DRNet-v2 (with AG)	6.88	94.20	94.44	94.20	94.15	4.93
DRNet-v3 (with MIAG)	8.88	95.56	95.73	95.56	95.54	5.90

DRWAF-Net	9.27	96.77	96.90	96.77	96.77	6.31
-----------	------	-------	-------	-------	-------	------

如表 3 所示,未集成 MIAG 与 AG 模块的 DRNet-v1 模型尺寸最小(6.50MB),推理耗时最低(4.12ms),但其各项性能指标均最低(F1 分数仅 93.64%)。

仅集成 AG 模块的 DRNet-v2 在模型尺寸(6.88MB)与推理耗时(4.93ms)上居中,其性能指标较 DRNet-v1 平均提升约 0.53%,验证了 AG 模块的有效性,但仍未达到 95%的可用阈值。

仅集成 MIAG 模块的 DRNet-v3 模型尺寸(8.88MB)与推理耗时(5.90ms)增加较大(较 DRNet-v1 分别增加 2.38MB 和 1.78ms),但其性能指标平均提升达 1.88%,且四项指标均超过 95%,达到可用状态。这充分证明了 MIAG 模块对性能提升的显著贡献。与 DRNet-v2 相比,MIAG 模块带来的性能提升幅度高于 AG 模块。

最终,DRWAF-Net 在仅比 DRNet-v1 增大 2.77MB(9.27MB)和增加 2.19ms 推理耗时(6.31ms)的情况下,四项核心性能指标全面领先,平均较 DRNet-v1 提升 3.08%(F1 分数提升 3.13%),在对比模型中展现出最佳平衡性。相较于 DRNet-v2 与 DRNet-v3,DRWAF-Net 模型尺寸分别增大 2.39MB 和 0.39MB,性能指标则提升 2.46%至 2.61%和 1.17%至 1.22%。

综合模型尺寸、推理耗时及性能表现,DRWAF-Net 中集成的 MIAG 模块被证明是切实有效的核心组件。

4.3 讨论

综合前文实验结果,本章节的核心讨论围绕模型在实际应用中的稳健性与效率展开:首先,对比分析前文 9 个模型的过拟合现象,通过考察训练集与独立测试集上的损失一致性曲线(Loss Consistency Curve, LCC)评判分类模型性能一致性,评估泛化能力的坚实程度和过拟合程度。其次,着眼于模型的实际部署需求(尤其是对实时性的要求),我们将探讨 DRWAF-Net 等高性能模型进行轻量化设计的潜力和路径。

其中,LCC 是将模型在每个迭代轮次计算测试损失与训练损失之前,使用 softmax 激活函数计算之后的比值:

$$LCC_i = \frac{\frac{1}{N_{test}} \sum_{n=1}^{N_{test}} CE(\sigma(P_{test_n}), T_{test_n})_i}{\frac{1}{N_{train}} \sum_{n=1}^{N_{train}} CE(\sigma(P_{train_n}), T_{train_n})_i}, \quad i \in [1, Epoch] \cap \mathbb{Z} \quad (10)$$

式 (10) 中, LCC_i 是构成 LCC 的各点数值; N_{test} 和 N_{train} 分别是测试集和训练集数量; CE 指代分类模型计算损失值的交叉熵损失函数 (Cross-Entropy Loss Function); σ 则表示 softmax 激活函数; P_{test_n} 和 T_{test_n} 、 P_{train_n} 和 T_{train_n} 分别为测试集、训练集中第 n 个样本的模型预测值和样本真实值; $Epoch$ 是总训练轮次。该比值趋近于 1 通常表示模型泛化良好, 未过拟合; 若该比值持续显著大于 1, 则强烈提示模型在训练集上过拟合, 昭示其在测试集上泛化能力下降。




图 8 各模型的损失一致性曲线

Fig. 8. Loss consistency curves of all models

如图 8 所示, 在参与评估的 9 个模型中, 各系列模型的损失一致性曲线在训练后期均稳定在 1 附近, 其值大小一定程度上能反映训练损失和测试损失的差距, 各最佳模型的 LCC 差距最大为 0.0429 (MobileNet-V3-large 达到 1.0454 而

ConvNeXt-Tiny 仅为 1.0025）。具体分析各模型最优配置（对应表 2 和表 3）：ConvNeXt-Tiny 的 LCC 值最接近理论最优值 1，训练-测试差异极小，但其数值都相对较高，并非模型已进入全局最优，而是该模型使用的“标签平滑”、“权重衰减”等正则化策略，联合过度约束所致，但该策略是其他模型缩小 LCC 值的有利工具。DRWAF-Net 过拟合程度较低，以 1.0179 仅次于 ConvNeXt-Tiny，和他模型一同有望辅以正则化策略降低过拟合程度。最后，综合考虑各模型训练损失、测试损失和 LCC 表现，可以认为 LCC 值在 1 ± 0.02 的区间内，模型泛化良好。

最后，未来工作将针对“拓展面向突发灾害应急响应数据集”和“完善 DRWAF-Net”进一步展开：首先，数据集将集成更多类型的灾害场景（如地震、雪崩、洪水等），提高跨域泛化能力；其次，引入自适应分解级数机制，在轻量级的前提下探索更高分解阶数或其他小波基带来的精度收益。此外，通过知识蒸馏或动态剪枝，继续压缩推理延时与功耗，以满足边缘节点的极端资源限制。同时，集成先进的数据增强技术至模型训练流程中，如采用频谱掩码增强（Spectral Masking Augmentation）动态添加噪声，提升模型在复杂背景下的鲁棒性，有望提升模型性能。最终，未来模型将在更多类型的灾害场景中验证模型的泛化能力，并通过迁移学习或零样本学习技术，减少对大规模标注数据的依赖。

5 结论

针对突发性地质灾害识别的高精度与实时性需求，本研究提出了一种适用于多普勒雷达的深度学习网络模型 DRWAF-Net，并通过系统的消融实验与对比验证，证明了所提模型在精度、效率及泛化能力上的显著优势，为地质灾害应急响应提供了新的技术解决方案。

（1）DRWAF-Net 在自建 7 分类数据集上取得了 96.90% 的精确率和 96.77% 的召回率，较 DopplerNet 模型提升 5.52%-5.73%。其参数量仅 2.38M、模型尺寸 9.27MB，单帧推理耗时 6.31ms，较 ResNet50 等基准模型计算量减少 93%，满足灾害应急场景的实时性需求。

（2）该模型通过设计多输入注意力门控（MIAG）模块，突破传统门控机制的双输入限制，实现多源特征的自适应融合；结合小波二维卷积（WTConv2d）

模块，使用 Haar 小波变换提升多尺度特征提取能力；通过极致轻量化设计，满足边缘计算设备部署需求。

（3）研究构建的 7 分类融合数据集涵盖泥石流、滚石、落石等灾害本体及环境干扰样本，为灾害识别任务提供了标准化测试基准。DRWAF-Net 在植被遮挡、动态背景等干扰场景下仍保持高鲁棒性，对灾害体识别准确率高（如泥石流与滚石准确率达 100%和 96.9%），且能有效区分易混淆目标（如滚石与植被误检率降低至 3.1%和 3.2%），为地质灾害应急响应现场提供了高效、智能的监测工具。

参考文献

- Ajit, A., Acharya, K., Samanta, A. (2020). A Review of Convolutional Neural Networks. 2020 International Conference on Emerging Trends in Information Technology and Engineering (ic-ETITE). <https://doi.org/10.1109/ic-ETITE47903.2020.049>
- Boonpook, W., Tan, Y., Xu, B. (2021). Deep learning-based multi-feature semantic segmentation in building extraction from images of UAV photogrammetry. *International Journal of Remote Sensing*, 42(1), 1-19. https://doi.org/10.1007/978-3-319-46493-0_22
- Cai, Z., Fan, Q., Feris, R. S., et al. (2016). A Unified Multi-scale Deep Convolutional Neural Network for Fast Object Detection. Computer Vision – ECCV 2016. https://doi.org/10.1007/978-3-319-46493-0_22
- Casagli, N., Intrieri, E., Tofani, V., et al. (2023). Landslide detection, monitoring and prediction with remote-sensing techniques. *Nature Reviews Earth & Environment*, 4(1), 51-64. <https://doi.org/10.1038/s43017-022-00373-x>
- Dubey, A., Santra, A., Fuchs, J., et al. (2021). Bayesradar : Bayesian Metric-Kalman Filter Learning for Improved and Reliable Radar Target Classification. 2021 IEEE 31st International Workshop on Machine Learning for Signal Processing (MLSP). <https://doi.org/10.1109/MLSP52302.2021.9596290>
- Finder, S. E., Amoyal, R., Treister, E., et al. (2024). Wavelet Convolutions for Large Receptive Fields. Computer Vision – ECCV 2024. https://doi.org/10.1007/978-3-031-72949-2_21
- Gu, J., Wang, Z., Kuen, J., et al. (2018). Recent advances in convolutional neural networks. *Pattern recognition*, 77, 354-377. <https://doi.org/10.1016/j.patcog.2017.10.013>
- He, K., Zhang, X., Ren, S., et al. (2016). Deep Residual Learning for Image Recognition. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). <https://doi.org/10.1109/CVPR.2016.90>
- Heydarian, M., Doyle, T. E., Samavi, R. (2022). MLCM: Multi-Label Confusion Matrix. *IEEE Access*, 10, 19083-19095. <https://doi.org/10.1109/ACCESS.2022.3151048>
- Howard, A., Sandler, M., Chen, B., et al. (2019). Searching for MobileNetV3. 2019 IEEE/CVF International Conference on Computer Vision (ICCV). <https://doi.org/10.1109/ICCV.2019.00140>
- Huether, B. M., Gustafson, S. C., Broussard, R. P. (2001). Wavelet preprocessing for high range resolution radar classification. *IEEE Transactions on Aerospace and Electronic Systems*, 37(4), 1321-1332. <https://doi.org/10.1109/7.976968>
- Hung-Chih, C., Moses, R. L., Potter, L. C. (2000). Model-based classification of radar images.

- IEEE Transactions on information theory*, 46(5), 1842-1854.
<https://doi.org/10.1109/18.857795>
- Jakob, M., Lambert, S. (2009). Climate change effects on landslides along the southwest coast of British Columbia. *Geomorphology*, 107, 275-284.
<https://doi.org/10.1016/j.geomorph.2008.12.009>
- Khan, A., Sohail, A., Zahoor, U., et al. (2020). A survey of the recent architectures of deep convolutional neural networks. *Artificial intelligence review*, 53(8), 5455-5516.
<https://doi.org/10.1007/s10462-020-09825-6>
- La, R., Lv, T., Bai, P., et al. (2022). Research on Collaborative and Optimal Deployment and Decision Making Among Major Geological Disaster Rescue Subjects. *Geotechnical and Geological Engineering*, 40(1), 57-71.
<https://doi.org/10.1007/s10706-021-01883-z>
- Li, Z., Liu, F., Yang, W., et al. (2022). A Survey of Convolutional Neural Networks: Analysis, Applications, and Prospects. *IEEE Transactions on Neural Networks and Learning Systems*, 33(12), 6999-7019. <https://doi.org/10.1109/TNNLS.2021.3084827>
- Lin, T. Y., Dollár, P., Girshick, R., et al. (2017). Feature Pyramid Networks for Object Detection. 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). <https://doi.org/10.1109/CVPR.2017.106>
- Litjens, G., Kooi, T., Bejnordi, B. E., et al. (2017). A survey on deep learning in medical image analysis. *Medical image analysis*, 42, 60-88.
<https://doi.org/10.1016/j.media.2017.07.005>
- Liu, S., Hu, K., Li, H., et al. (2025). Radar-Based Deep Learning for Debris Flow Identification Amid the Environmental Disturbances. *Geophysical Research Letters*, 52(2), e2024GL112351. <https://doi.org/10.1029/2024GL112351>
- Liu, Z., Mao, H., Wu, C. Y., et al. (2022). A ConvNet for the 2020s. 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR).
<https://doi.org/10.1109/CVPR52688.2022.01167>
- Michellini, A., Viviani, F., Bianchetti, M., et al. (2020). A new radar-based system for detecting and tracking rockfall in open pit mines Slope Stability 2020: Proceedings of the 2020 International Symposium on Slope Stability in Open Pit Mining and Civil Engineering, Online. https://papers.acg.uwa.edu.au/p/2025_79_Stopka/
- Rawat, W., Wang, Z. (2017). Deep Convolutional Neural Networks for Image Classification: A Comprehensive Review. *Neural Computation*, 29(9), 2352-2449.
https://doi.org/10.1162/neco_a_00990
- Rickenmann, D. (1999). Empirical Relationships for Debris Flows. *Natural Hazards*, 19(1), 47-77. <https://doi.org/10.1023/A:1008064220727>
- Ristic, B., Kim, D. Y., Rosenberg, L., et al. (2022). Exploiting Doppler in Bernoulli Track-Before-Detect for a Scanning Maritime Radar. *IEEE Transactions on*

- Aerospace and Electronic Systems*, 58(1), 720-728.
<https://doi.org/10.1109/TAES.2021.3098117>
- Roldan, I., del-Blanco, C. R., Duque de Quevedo, Á., et al. (2020). DopplerNet: a convolutional neural network for recognising targets in real scenarios using a persistent range-Doppler radar. *IET Radar, Sonar & Navigation*, 14(4), 593-600.
<https://doi.org/10.1049/iet-rsn.2019.0307>
- Romeo, S., Cosentino, A., Giani, F., et al. (2021). Combining Ground Based Remote Sensing Tools for Rockfalls Assessment and Monitoring: The Poggio Baldi Landslide Natural Laboratory. *Sensors*, 21(8), 2632. <https://doi.org/10.3390/s21082632>
- Simonyan, K., Zisserman, A. (2014). Very Deep Convolutional Networks for Large-Scale Image Recognition. *Computer Science*. <https://doi.org/10.48550/arXiv.1409.1556>
- Szegedy, C., Wei, L., Yangqing, J., et al. (2015). Going deeper with convolutions. 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR).
<https://doi.org/10.1109/CVPR.2015.7298594>
- Vaswani, A., Shazeer, N., Parmar, N., et al. (2017). Attention is all you need. *Advances in neural information processing systems*, 30.
<https://doi.org/10.48550/arXiv.1706.03762>
- Viviani, F., Michelini, A., Mayer, L. (2020). *RockSpot: an Interferometric Doppler Radar for Rockfall/Avalanche Detection and Tracking*.
<https://doi.org/10.1109/RadarConf2043947.2020.9266677>
- Wang, J., Zhu, H., Lei, P., et al. (2019). CNN Based Classification of Rigid Targets in Space Using Radar Micro-Doppler Signatures. *Chinese Journal of Electronics*, 28(4), 856-862. <https://doi.org/10.1049/cje.2018.08.003>
- Yu, F., Koltun, V. (2016). *Multi-Scale Context Aggregation by Dilated Convolutions*. 4th International Conference on Learning Representations (ICLR 2016), San Juan, Puerto Rico. <http://arxiv.org/abs/1511.07122>
- Zhou, Z., Cao, Z., Pi, Y. (2019). Subdictionary-Based Joint Sparse Representation for SAR Target Recognition Using Multilevel Reconstruction. *IEEE Transactions on Geoscience and Remote Sensing*, 57(9), 6877-6887.
<https://doi.org/10.1109/TGRS.2019.2909121>
- 昌开馨. (2019). 为救援提前归队,永远倒在岗位上——记阿坝州消防支队汶川县大队水磨镇政府专职队班长更斯穷. *消防界(电子版)*, 5(15), 38-39.
<https://doi.org/10.16859/j.cnki.cn12-9204/tu.2019.15.009>
- 沈妍琰, 黄兴友, 黄书荣, 等. (2020). 基于贝叶斯分类器的多普勒天气雷达海浪回波识别和效果检验. *海洋科学*, 44(06), 83-90.
<https://doi.org/10.11759/hyhx20191011001>
- 崔鹏, 刘世建, 谭万沛. (2000). 中国泥石流监测预报研究现状与展望. *自然灾害学报*, 9(002), 10-15.

- 何思明, 王东坡, 吴永, 等. (2014). 崩塌滚石灾害的力学机理与防治技术. *自然杂志*, 36(5), 336-345. Online.
https://www.nature.shu.edu.cn/CN/abstract/article_8008.shtml
- 李明威, 唐川, 陈明, 等. (2021). 四川省汶川县板子沟8·20泥石流成因与易损强度分析. *防灾减灾工程学报*, 41(02), 238-245.
<https://doi.org/10.13409/j.cnki.jdpme.202004071>
- 李巧, 戚友存, 张哲, 等. (2024). 基于贝叶斯分类器和回波物理特征的C波段雷达非气象回波识别方法和性能分析. *大气科学*, 48(3), 823-836.
<https://doi.org/10.3878/j.issn.1006-9895.2205.22003>
- 刘石狮. (2024). *基于CNN和Transformer混合架构的混凝土结构裂缝检测研究* [硕士, 湖北工业大学]. <https://d.wanfangdata.com.cn/thesis/D03499199>
- 罗璟. (2020). “8.3”鲁甸地震斜坡动力响应及巨型岩质滑坡堵江机制研究 [博士, 成都理工大学]. <https://link.cnki.net/doi/10.26986/d.cnki.gcdlc.2020.000041>
- 罗玉婷. (2021). 汶川县“8.20”堵江型泥石流灾害链及风险定量评价 [硕士, 成都理工大学]. <https://link.cnki.net/doi/10.26986/d.cnki.gcdlc.2021.001373>
- 马腾, 周兰凤, 李建鑫. (2024). 基于宽带雷达RCS数据的空间物体识别方法. *Journal of Ordnance Equipment Engineering*, 45(7).
<https://doi.org/10.11809/bqzbgcxb2024.07.037>
- 石岩, 孟宪虎. (2014). 云南鲁甸“8·3”地震纪实. *中国报道*(09), 46-47.
- 王琨鹏, 颜春林, 杨辉. (2014). 基于模板匹配的雷达辐射源信号识别研究. *舰船电子对抗*, 37(05), 31-33+41. <https://doi.org/10.16426/j.cnki.jcdzdk.2014.05.017>
- 修济刚, 陈宇鸣. (2014). 鲁甸应急——云南鲁甸“8·3”6.5级地震应急救援启示. *防灾博览*(05), 28-35.
- 张林, 杨洪平, 邓鑫, 等. (2014). 基于模板匹配法的长乐雷达强超折射回波识别. *气象*, 40(03), 364-372.
<https://doi.org/http://dx.doi.org/10.7519/j.issn.1000-0526.2014.03.012>
- 张鹏宇, 申亮, 黄晓涛, 等 (2022). 基于对称结构特征的探地雷达图像模板匹配算法. *地球物理学进展*, 37(6), 2657-2666. <https://doi.org/10.6038/pg2022GG0054>
- 赵延广, 雷斌. (2022). 超声波泥位计应用问题及解决措施. *分析仪器*(3), 40-43.
<https://doi.org/10.3969/j.issn.1001-232x.2022.03.009>
- 左力艳, 杨建锋. (2023). 我国突发性地质灾害调查监测进展、成效与未来趋势. *中国矿业*, 32(S2), 7-12. <https://doi.org/10.12075/j.issn.1004-4051.20230724>