

深度神经网络在遥感图像分析中的应用研究

郭 进, 刘 超*, 白颖奇

北京航天世景信息技术有限公司, 北京

收稿日期: 2025年3月28日; 录用日期: 2025年4月20日; 发布日期: 2025年4月29日

摘 要

随着遥感技术飞速发展, 高分辨率遥感图像已成为环境监测、城市规划、农业管理等多个领域的重要手段。然而遥感图像数据量庞大且复杂, 传统分析方法在处理大规模数据时面临计算效率低下和特征提取依赖人工设计等诸多挑战。近年来, 深度神经网络(Deep Neural Networks, DNNs), 凭借强大的自动特征提取和模式识别能力, 在遥感图像分析中展现出卓越的性能。本研究系统地综述了深度神经网络在遥感图像分类、目标检测、语义分割和变化检测等关键任务中的应用, 分析了国内外在该领域的研究现状与进展。此外, 本研究还探讨了多模态数据融合、模型轻量化与实时性优化、以及深度学习模型的可解释性等前沿研究方向。

关键词

遥感影像, 深度学习, 神经网络, 多模态数据融合, 模型轻量化, 模型的可解释性

Research on the Application of Deep Neural Network in Remote Sensing Image Analysis

Jin Guo, Chao Liu*, Yingqi Bai

SpaceWill Info. Co., Ltd, Beijing

Received: Mar. 28th, 2025; accepted: Apr. 20th, 2025; published: Apr. 29th, 2025

Abstract

With the rapid development of remote sensing technology, high-resolution remote sensing images have become an important means in multiple fields such as environmental monitoring, urban planning, and agricultural management. However, the volume and complexity of remote sensing image data pose significant challenges for traditional analysis methods, including low computational efficiency and the reliance on manual feature design for feature extraction when dealing with large-

*通讯作者。

文章引用: 郭进, 刘超, 白颖奇. 深度神经网络在遥感图像分析中的应用研究[J]. 测绘科学技术, 2025, 13(2): 99-108.
DOI: 10.12677/gst.2025.132013

scale data. In recent years, deep neural networks (DNNs), with their powerful capabilities in automatic feature extraction and pattern recognition, have demonstrated outstanding performance in remote sensing image analysis. This study systematically reviews the application of deep neural networks in key tasks such as remote sensing image classification, object detection, semantic segmentation, and change detection, and analyzes the current research status and progress both domestically and internationally in this field. Additionally, this study also explores cutting-edge research directions such as multi-modal data fusion, model lightweighting and real-time optimization, as well as the interpretability of deep learning models.

Keywords

Remote Sensing Imagery, Deep Learning, Neural Networks, Multimodal Data Fusion, Model Lightweight, Model Interpretability

Copyright © 2025 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

遥感技术作为获取地球表面及其环境信息的重要手段,近年来随着卫星、无人机等遥感平台的发展,取得了显著进步。高分辨率、多光谱的遥感图像不仅能够提供细致的地表信息,还能涵盖丰富的光谱特征,使其在环境监测、城市规划、农业管理、灾害评估等多个领域得到广泛应用。例如,在环境监测中,遥感图像可用于监测森林覆盖率、水体污染情况;在城市规划中,可用于分析土地利用变化、交通网络布局;在农业管理中,可用于作物长势监测、病虫害预测;在灾害评估中,则可用于快速评估地震、洪水、火灾等灾害的影响范围和损失程度[1]。

然而,随着遥感图像分辨率和光谱维度的提升,遥感数据量呈现爆炸式增长,单幅图像的数据量可能达到数十兆字节甚至更大。此外,遥感图像具有高维度、空间结构复杂、多源异构等特点,传统的图像分析方法在处理这类高维、大规模数据时,面临计算效率低下、特征提取依赖人工设计、难以充分挖掘图像深层信息等诸多挑战。例如,传统的支持向量机(SVM)和随机森林(Random Forest)等机器学习方法在进行遥感图像分类时,通常需要依赖专家手工设计特征,且在处理大规模数据时计算开销较大,难以满足实际应用需求[2]。

近年来,深度神经网络(Deep Neural Networks, DNNs),尤其是卷积神经网络(Convolutional Neural Networks, CNNs),在计算机视觉、自然语言处理等领域取得了突破性进展,展示了其强大的自动特征提取和模式识别能力。CNNs 通过多层卷积和非线性变换,能够自动学习遥感图像中的多层次特征,有效提升图像分类、目标检测、语义分割和变化检测等任务的性能。例如,某研究利用深度学习模型对高分辨率遥感图像进行土地覆盖分类,实现了比传统方法更高的分类精度;另有研究采用残差网络(ResNet)对灾害区域进行目标检测,提高了灾害监测的准确性和响应速度。此外,图神经网络(Graph Neural Networks, GNNs)在处理遥感图像中的空间关系和复杂结构时,展现出独特的优势,进一步提升了变化检测的鲁棒性[3]。

本研究系统综述了深度神经网络在遥感图像分析中的关键应用,分析了国内外在该领域的研究现状与进展。此外,本文还探讨了多模态数据融合、模型轻量化与实时性优化、以及深度学习模型的可解释性等前沿研究方向。多模态数据融合通过结合多源遥感数据(如光学影像与雷达影像),能够提供更全面的信息,提升分析效果;模型轻量化与实时性优化则针对实际应用中对计算资源和响应速度的需求,提出

了高效的深度学习模型设计方法；深度学习模型的可解释性研究，旨在提升模型决策过程的透明度，增强用户对模型结果的信任度。

2. 深度神经网络在遥感图像分析中的关键应用

2.1. 遥感图像分类

遥感图像分类是指将遥感获取的图像数据按照预定的类别体系进行归类和标注，以识别和区分不同地物类型，如森林、农田、城市建筑和水体等。这一过程在环境监测、土地利用变化分析、城市规划和农业管理等领域具有重要应用价值。如图 1 所示。

近年来，随着深度学习技术的迅猛发展，遥感图像分类方法也取得了显著进展。卷积神经网络(CNN)及其变种，如残差网络(ResNet)和稠密连接网络(DenseNet)，通过自动特征提取和多层次特征表示，大幅提升了分类精度和模型的泛化能力。此外，迁移学习、多尺度特征融合和注意力机制的引入，使得模型能够更有效地利用有限的标注数据和捕捉图像中的关键信息。图神经网络(GNNs)在建模地物之间的空间关系方面展现出独特优势，进一步增强了分类的鲁棒性。生成对抗网络(GANs)和数据增强技术则有效缓解了样本不均衡和数据不足的问题，提升了模型的性能。同时，多任务学习和模型优化技术，如模型剪枝和量化，促进了分类模型在实际应用中的高效部署和实时性要求。尽管取得了诸多进展，遥感图像分类仍面临多源异构数据融合、模型可解释性和计算资源限制等挑战。总体而言，深度学习在遥感图像分类中的应用不仅克服了传统方法的局限性，还显著提升了分类任务的精度和效率，展现出广阔的研究前景和应用潜力[4]-[6]。




Figure 1. Schematic diagram of remote sensing image classification
图 1. 遥感影像分类示意图

2.2. 遥感图像目标检测

遥感目标检测是指从遥感影像中自动识别并定位特定目标或地物的过程,如建筑物、道路、车辆、船只等。该技术在城市规划、军事侦察、灾害监测和环境保护等领域具有重要的应用价值。如图2所示。

近年来,随着深度学习技术的迅猛发展,遥感目标检测方法也取得了显著进展。基于卷积神经网络(CNN)的目标检测算法,如Faster R-CNN、YOLO和SSD等,凭借其高效的特征提取和精准的目标定位能力,广泛应用于遥感图像的目标检测任务。此外,区域提议网络(RPN)和多尺度特征融合技术的引入,进一步提升了对小目标和复杂场景下目标检测的性能[7]。近年来,基于Transformer的检测模型,如DETR,因其全局特征建模能力,也开始在遥感目标检测中展现出潜力[8]。图神经网络(GNN)则被用于捕捉地物之间的空间关系,增强检测的准确性和鲁棒性。同时,针对遥感数据的多源异构特性,研究者们探索了融合光学影像与雷达影像的多模态目标检测方法,以提升检测效果。生成对抗网络(GANs)和数据增强技术也被应用于提升模型的泛化能力和处理数据不均衡的问题。尽管取得了诸多进展,遥感目标检测仍面临如目标尺度多样、背景复杂、数据标注困难等挑战。总体而言,深度学习在遥感目标检测中的应用显著提升了检测的精度和效率,展现出广阔的研究前景和应用潜力,为各类实际应用提供了强有力的技术支持[9]。




Figure 2. Schematic diagram of remote sensing image target detection

图2. 遥感影像目标检测示意图

2.3. 遥感图像语义分割

遥感语义分割是指将遥感影像中的每个像素精确分类到预定的类别中,从而实现对地物的细致识别和定位,广泛应用于土地利用/覆盖变化监测、城市规划、环境保护等领域,如图3所示。

近年来,随着深度学习技术的迅猛发展,遥感语义分割方法取得了显著进展。基于全卷积神经网络(FCN)和U-Net的架构,通过逐像素分类和上下文信息融合,大幅提升了分割的精度和细节捕捉能力。

深度金字塔网络(Deep Pyramid Networks)和空洞卷积(Dilated Convolutions)的应用, 进一步增强了多尺度特征提取和语义信息的捕捉能力。此外, 注意力机制(Attention Mechanisms)和 Transformer 模型的引入, 有助于更好地整合全局信息, 提高分割的准确性和鲁棒性。多模态数据融合、生成对抗网络(GANs)以及自监督学习等新兴方法, 也在缓解标注数据不足和提升模型泛化能力方面展现出巨大潜力。尽管取得了诸多进展, 遥感语义分割仍面临诸如复杂地物边界识别、多源数据融合和实时处理等挑战。总体而言, 深度学习在遥感语义分割中的应用不仅有效克服了传统方法的局限性, 还显著提升了分割任务的精度和效率, 展现出广阔的研究前景和应用潜力, 未来有望在更广泛的实际场景中发挥关键作用[10]-[12]。




Figure 3. Schematic diagram of remote sensing image semantic segmentation

图 3. 遥感影像语义分割示意图

2.4. 遥感图像变化检测

遥感变化检测是指通过比较不同时期获取的遥感影像, 自动识别和量化地表环境或人类活动引起的变化, 广泛应用于城市扩张监测、森林砍伐评估、农业动态管理及灾害影响评估等领域。如图 4 所示。

近年来, 随着深度学习技术的快速发展, 遥感变化检测方法取得了显著进展。基于卷积神经网络(CNN)的双流网络和特征差分方法, 能够有效捕捉多时相影像中的变化信息; 生成对抗网络(GAN)和自编码器则被用于学习变化特征和增强数据表示能力。此外, 注意力机制和 Transformer 模型的引入, 提高了对复杂变化模式的识别精度。多模态数据融合技术, 通过整合光学影像、雷达数据等多源信息, 进一步提升了变化检测的鲁棒性和准确性。同时, 迁移学习和自监督学习方法在缓解数据标注不足和提升模型泛化能力方面展现出巨大潜力。尽管取得了诸多进展, 遥感变化检测仍面临变化类型多样、变化幅度细微以及高质量标注数据匮乏等挑战。总体而言, 深度学习在遥感变化检测中的应用不仅显著提升了检测的精度和效率, 还拓展了其在复杂环境和多样应用场景中的适用性, 展现出广阔的研究前景和应用潜力, 未来有望在智能环境监测和精准决策支持中发挥更加重要的作用[13]-[16]。




Figure 4. Schematic diagram of remote sensing image transformation detection

图 4. 遥感影像变换检测示意图

3. 前沿研究方向

深度学习在遥感领域的各行各业都起着非常重要的作用，而随着技术的不断进步，深度学习在遥感领域的应用也正逐步向更高效、更精准、更智能的方向发展，但在部分领域仍存在一定的瓶颈。目前研究者们正在探索多模态数据融合、可解释性、轻量化等新兴方法，以应对遥感数据的高维度、复杂性以及实时处理的挑战。这些前沿方向不仅能够提升现有模型的性能，还将推动遥感技术在灾害监测、环境保护、城市规划等重要领域中的应用边界。

3.1. 多模态数据融合

多模态数据融合是一种通过整合来自不同来源和类型的数据，如图像、文本、音频、传感器信息等，以提升信息的完整性、准确性和鲁棒性的技术方法。其基本原理在于利用不同模态数据之间的互补性，通过在数据层、特征层和决策层等不同层次上进行有效的结合，从而捕捉和挖掘数据中潜在的复杂模式和关系。

在数据层融合中，直接将不同模态的原始数据进行合并，例如将图像的像素数据与文本的词向量拼接在一起；在特征层融合中，首先对各模态数据进行特征提取，然后将提取到的特征进行组合，如通过特征连接、特征选择或特征变换等方法；在决策层融合中，各模态数据分别进行独立处理和分类，最后将各自的决策结果进行整合，如通过投票、加权平均或贝叶斯方法等进行融合。

多模态数据融合的发展经历了多个阶段，早期主要依赖于统计学和信号处理技术，强调信息的线性

组合和简单融合,应用于军事、医学和遥感等领域。随着计算能力的提升和机器学习技术的进步,多模态融合方法逐渐向非线性、多层次方向发展,支持向量机(SVM)、隐马尔可夫模型(HMM)等机器学习算法被广泛应用于多模态融合任务中。进入 21 世纪后,深度学习技术的兴起极大地推动了多模态数据融合的发展,深度神经网络(DNN)、卷积神经网络(CNN)、循环神经网络(RNN)等深度模型被用于复杂的多模态任务,如图像与文本的联合理解、视频与音频的同步分析等,进一步提升了多模态融合在计算机视觉、自然语言处理、医疗诊断和智能驾驶等领域的应用效果。例如,在医学诊断中,融合影像数据(如 X 光片、CT 图像)与电子病历和基因数据,可以显著提高疾病检测的准确性和诊断的全面性;在智能驾驶系统中,结合来自摄像头、雷达、激光雷达(LiDAR)等多种传感器的数据,实现环境感知、障碍物检测和路径规划,从而增强自动驾驶系统的安全性和可靠性;在多模态情感分析中,融合文本、语音和面部表情等多种模态的数据,可以更准确地识别和理解用户的情感状态,提升人机交互的自然性和智能性。此外,多模态数据融合在视频内容检索、人机交互、智能助手和虚拟现实(VR)等领域也展现出广泛的应用前景。

虽然通过融合这些不同来源的数据,可以提高对目标的识别精度和决策的可靠性,但多模态数据融合也存在一些挑战和缺点。首先,由于数据来源不同,数据的处理方式、尺度和格式可能存在差异,这就要求对异构数据进行预处理和统一,增加了系统设计的复杂度。其次,数据融合需要较高的计算成本,尤其在大规模数据集的情况下,实时处理可能面临性能瓶颈。再者,不同模态的数据可能具有不同的精度和信噪比,导致融合效果受到影响。例如,视频数据可能受到光照、遮挡等因素的干扰,而声音数据可能受到噪音污染的影响,如何有效融合这些信息以减少噪声干扰,成为实现高效融合的难点。

未来,多模态数据融合将继续朝着算法优化、跨领域应用拓展、数据隐私与安全保障、标准化与互操作性发展以及与人工智能深度结合等方向迈进。融合算法将进一步优化,结合强化学习、自监督学习等新兴技术,提升融合模型的自适应能力和泛化性能,能够更加高效和智能地处理复杂的多模态数据;跨领域应用将进一步拓展到智慧城市、工业互联网、环境监测等更多领域,推动各行业的智能化和数字化转型;数据隐私与安全问题将成为研究重点,如何在保证数据隐私和安全的前提下,实现高效的多模态数据融合,将是未来的重要挑战;标准化与互操作性的发展将有助于实现不同系统和平台之间的无缝数据融合,制定统一的数据格式和接口标准,促进多模态数据的共享与融合;此外,多模态数据融合将与人工智能技术深度结合,推动智能系统在理解、推理和决策等方面取得更大突破,如基于多模态数据的智能机器人将具备更强的环境感知和任务执行能力。同时,随着融合模型复杂性的增加,其可解释性和透明性问题也将受到更多关注,未来的研究将致力于开发具有可解释性的多模态融合模型,增强用户对智能系统的信任和理解。总体而言,多模态数据融合作为一种强大的信息处理方法,凭借其综合多源数据的优势,正在各个领域展现出巨大的应用潜力和价值。通过不断优化融合算法、拓展应用场景、解决隐私安全问题以及推动标准化发展,多模态数据融合将在未来的信息时代发挥更加重要的作用,推动智能技术的持续创新与进步,助力各行业实现更高水平的智能化和数字化转型[17][18]。

3.2. 模型轻量化与实时性优化

模型轻量化与实时性优化是当前人工智能领域的重要研究方向,旨在通过减小模型规模、降低计算复杂度和提升处理速度,以适应资源受限的设备和满足实时应用需求。其原理主要包括参数压缩、模型剪枝、量化和知识蒸馏等技术。

参数压缩通过减少模型中的参数数量来减小模型尺寸,模型剪枝则通过移除冗余或不重要的神经元和连接简化模型结构,量化技术通过降低参数的表示精度(如从 32 位浮点数降至 8 位整数)来减少存储和

计算需求,而知识蒸馏则通过训练一个较小的学生模型模仿大型教师模型,从而在保持性能的同时实现模型简化。随着深度学习的发展,模型轻量化与实时性优化也经历了从手工设计到自动化工具和算法(如神经架构搜索和自动剪枝算法)的演变,推动了诸如 MobileNet、ShuffleNet 和 EfficientNet 等轻量级网络架构的出现,这些架构在保证模型精度的同时,大幅度降低了计算资源消耗,广泛应用于智能手机、无人机和物联网设备等领域。例如,MobileNet 利用深度可分离卷积显著减少了参数和计算量,使其在移动设备上实现高效的图像分类和物体检测成为可能;在智能驾驶领域,优化后的深度神经网络被用于实时环境感知和路径规划,提升了自动驾驶系统的响应速度和安全性。

虽然轻量化后的模型通常具有较低的内存占用和计算开销,从而降低了对硬件资源的依赖,提升了实时处理能力和响应速度,但模型轻量化也存在一些明显的缺点。首先,轻量化过程中可能会损失一部分精度,尤其是在处理复杂任务或需要大量特征提取的场景下。由于减少了网络的深度、宽度或参数量,模型可能无法捕捉到一些重要的细节或高维信息,从而影响其预测准确性。其次,轻量化方法的选择和优化非常依赖任务的特点和数据分布,可能需要多次实验来确定最佳的轻量化策略,增加了调试和优化的难度。此外,轻量化后的模型可能会在一些特殊情况下无法达到原始大模型的性能,尤其是在处理复杂的场景或高精度要求的任务时。

展望未来,随着硬件技术的进步和新型算法的涌现,模型轻量化与实时性优化将进一步发展,结合稀疏表示、动态计算图优化和混合精度计算等创新方法,提升模型在不同应用场景下的适应性和性能。同时,随着 5G 和边缘计算的普及,实时性优化的重要性将更加凸显,推动低延迟、高吞吐量的模型设计和部署策略。此外,模型的可解释性和安全性也将成为优化过程中关注的重点,确保在高效运行的同时,模型决策过程透明且安全。总体而言,模型轻量化与实时性优化将持续推动人工智能技术在各类实际应用中的广泛应用,助力智能设备和系统实现更高效、更智能的运行[19] [20]。

3.3. 深度学习模型的可解释性

深度学习模型的可解释性是指理解和解释模型内部决策过程的能力,这在实际应用中尤为重要,特别是在医疗、金融和自动驾驶等高风险领域。其原理主要包括通过可视化方法揭示模型的特征关注点、利用梯度和激活映射分析关键输入因素,以及采用模型简化和代理模型等技术来解释复杂模型的行为。

随着深度学习的迅猛发展,模型可解释性研究也从最初的简单特征重要性分析,逐步发展到复杂的层级可视化、因果推断和基于注意力机制的解释方法。例如,在医疗诊断中,可解释性模型能够帮助医生理解 AI 系统的诊断依据,提高信任度和决策质量;在金融领域,通过解释信用评分模型,确保决策过程的透明和公平。

虽然模型的可解释性能够帮助开发者理解模型的决策机制,从而提高模型的可靠性和调试效率,但深度学习模型的可解释性也存在一些缺点。首先,为了提高模型的可解释性,通常需要对模型结构进行简化或额外的后处理,这可能会牺牲模型的性能,尤其是对于复杂任务和大规模数据集。其次,可解释性并不总是能够直接提升预测准确度,在一些高精度要求的任务中,复杂的模型可能会被迫做出一些折衷。再者,深度学习模型的可解释性方法多种多样,如局部解释、全局解释、可视化技术等,这些方法的实现复杂度较高,且有时解释结果可能因方法不同而有所差异,增加了模型理解的困难。

展望未来,深度学习模型的可解释性将进一步融合先进的算法和理论,如因果学习和自监督学习,提升解释的深度和广度。同时,随着法规和伦理要求的提升,模型的透明性和可解释性将成为标准配置,推动更多行业采用可信赖的 AI 系统。此外,跨学科的合作也将促进可解释性技术的发展,结合认知科学和人机交互设计,打造更直观和用户友好的解释工具,确保深度学习模型在复杂应用场景中的广泛应用和社会接受度,从而实现更加安全、可靠和公平的人工智能系统[21] [22]。

4. 总结与展望

本文系统综述了深度神经网络在遥感图像分类、目标检测、语义分割和变化检测等关键任务中的应用,深入分析了国内外在该领域的研究现状与最新进展,揭示了多模态数据融合、模型轻量化与实时性优化以及深度学习模型的可解释性等前沿研究方向的重要性的发展态势。通过对现有文献的梳理与比较,本文指出,尽管深度神经网络在遥感图像处理领域取得了显著成果,显著提升了图像分析的精度和效率,但仍面临数据获取与处理的复杂性、模型计算资源需求高、实时性要求严格以及模型解释性不足等诸多挑战。展望未来,随着遥感技术与人工智能的深度融合,多模态数据融合将进一步增强遥感图像的综合分析能力,模型轻量化与实时性优化将使复杂深度模型能够在资源受限的环境中高效运行,而增强模型的可解释性则有助于提高用户对人工智能系统的信任度和决策透明度。此外,随着 5G、边缘计算和物联网技术的发展,遥感图像处理将更加依赖于高效、低延迟的计算架构,推动实时监测与响应系统的广泛应用。在实际应用方面,遥感图像分析技术将在环境监测、城市规划、农业管理和灾害预警等领域发挥越来越重要的作用,为相关决策提供更加精准和可靠的技术支持。未来的研究需持续关注新算法的开发与优化,推动理论与应用的紧密结合,解决现有技术瓶颈,实现遥感图像处理技术的持续创新与突破。

参考文献

- [1] 王健. 基于深度学习的遥感影像变化检测方法研究[D]: [硕士学位论文]. 哈尔滨: 东北林业大学, 2023.
- [2] 孙伟伟, 杨刚, 陈超, 等. 中国地球观测遥感卫星发展现状及文献分析[J]. 遥感学报, 2020, 24(5): 479-510.
- [3] 李兰, 张建国, 相双, 等. 关于国内深度学习研究的回顾与展望[J]. 宁夏师范学院学报, 2024, 45(11): 72-76.
- [4] 单飞龙, 吕鹏远, 李梦晨. 基于 CNN-Transformer 半监督交叉学习的遥感图像场景分类方法[J]. 宁夏大学学报(自然科学), 2024, 45(3): 325-332.
- [5] 吴媛媛, 郝延彪, 刘行, 等. 基于多尺度注意力的光学遥感场景分类[J]. 海军航空大学学报, 2025, 40(1): 171-178, 204.
- [6] 王江杰, 王星河. 基于底质分类的浅海海域遥感水深反演[J]. 北京测绘, 2024, 38(8): 1172-1178.
- [7] 陶健. 基于空洞卷积与空间注意力的遥感影像小目标检测方法[J]. 测绘与空间地理信息, 2024, 47(10): 104-107+111.
- [8] 张立夏, 马致明, 刘战东, 等. 基于改进 YOLOv4 的遥感目标检测算法[J]. 计算机与数字工程, 2024, 52(10): 2863-2868+2896.
- [9] 梁海翔, 唐艳慧, 王宇庆, 等. 高分辨率遥感图像的目标检测[J]. 液晶与显示, 2024, 39(10): 1350-1360.
- [10] Xiang, S., Xie, Q. and Wang, M. (2022) Semantic Segmentation for Remote Sensing Images Based on Adaptive Feature Selection Network. *IEEE Geoscience and Remote Sensing Letters*, **19**, Article ID: 8006705. <https://doi.org/10.1109/lgrs.2021.3049125>
- [11] Ma, Y., Wang, Y., Liu, X. and Wang, H. (2024) SWINT-RESNet: An Improved Remote Sensing Image Segmentation Model Based on Transformer. *IEEE Geoscience and Remote Sensing Letters*, **21**, Article ID: 8003005. <https://doi.org/10.1109/lgrs.2024.3433034>
- [12] Qi, Z., Zou, Z., Chen, H. and Shi, Z. (2022) Remote-Sensing Image Segmentation Based on Implicit 3-D Scene Representation. *IEEE Geoscience and Remote Sensing Letters*, **19**, Article ID: 6016205. <https://doi.org/10.1109/lgrs.2022.3227392>
- [13] 谢国波, 廖文康, 林志毅, 等. 基于 MCRASN 的遥感影像变化检测[J]. 应用光学, 2024, 45(2): 430.
- [14] 刘莺迎, 周刚. 基于孪生 Transformer 的双时相遥感影像变化检测方法[J]. 遥感信息, 2024, 39(3): 67-74.
- [15] 石卫超. 集成 CNN 和 Transformer 的高分辨率遥感影像变化检测[D]: [硕士学位论文]. 宜昌: 三峡大学, 2024.
- [16] 吴国盼, 王蒙蒙, 李辛莹, 等. 基于三维卷积神经网络的遥感影像变化检测[J]. 遥感信息, 2024, 39(4): 61-67.
- [17] 方正楠, 赵春廷, 刘琦, 等. 多模态遥感数据融合中的深度学习技术分析[J]. 电子技术, 2023(7): 49-51.
- [18] 郑远驰. 基于多模态融合的遥感图像分割方法研究[D]: [硕士学位论文]. 成都: 电子科技大学, 2024.

- [19] 邵仁荣, 刘宇昂, 张伟, 等. 深度学习中知识蒸馏研究综述[J]. 计算机学报, 2022(8): 45.
- [20] 方维维, 陈爱方, 孟娜, 程虎威, 王清立. 基于知识蒸馏的目标检测模型增量深度学习方法[J]. 工程科学与技术, 2022, 54(6): 59-66.
- [21] 卢绍鹏. 多智能体强化学习算法评测及可解释性研究[D]: [硕士学位论文]. 杭州: 电子科技大学, 2023.
- [22] 耿宇, 丁卫平, 黄嘉爽, 等. MGRW-Transformer: 多粒度随机游走可解释性 Transformer 模型[J/OL]. 电子学报: 1-15. <https://ieeexplore.ieee.org/abstract/document/10313013>, 2024-12-11.