



图2 重庆市遥感大数据应用框架

4.2 农业用地变化

农业用地变化监测工作中需要高频次高精度的监测,因此多源遥感数据可以通过光谱与时序特征的融合,开展高效分析。高时空分辨率数据可以用于监测作物生长周期,识别田间病害。热红外数据用于监测农田水分胁迫。无人机影像和农业传感器可以用于开展田间管理,获取基础信息。可以通过空地协同融合,识别土地类型,监测土地利用状态,做好农业用地分类工作。

4.3 生态与灾害关联

生态环境方面,应用多源遥感数据可以开展森林监测工作。可以快速发现非法砍伐、森林火灾、病虫害等各种类型的植被破坏行为。光学与LiDAR协同,Landsat持续数据会追踪森林覆盖变化情况,而LiDAR提供林冠高度和生物量信息验证砍伐程度^[5]。使用热红外数据辅助监测非法烧荒引起的温度异常,结合多光谱数据区分自然火灾与人为活动。使用多时相动态分析,监测林草地面积的变化情况。例如,中国云南西双版纳的热带雨林监测工作中,便应用了多源遥感数据融合方法。使用Sentinel-1,用于检测夜间伐木引起的地表粗糙度变化,Sentinel-2用于识别橡胶林扩张导致的植被类型转换,应用无人机LiDAR验证单株树木损失,整合这些数据,可以了解到热带雨林面积的变化情况。

开展湿地退化评估工作。可以将光谱与雷达数据结合应用进行动态监测。用于识别湿地范围反映地表湿度变化,从而了解评估湿地萎缩还是扩张。应用时序分析,应对季节性干扰。可以区分湿地退化是自然波动还是人为退化。

开展灾害应急与监测工作。应用多源遥感数据,快速识别地震、洪水、台风等灾害导致的土地利用损害情况,为应急决策提供依据。整合灾前灾后数据,灾难高分影像构建土地利用基线,灾后SAR影像,可以快速获取损毁区域的雷达特征变化情况。使用无人机倾斜摄影评估建筑损毁的程度,搭载InSAR监测地表形变。在多源数据的支持下实现有效融合,采用深度学习模型,深度分析数据。

5 结语

综上所述,在土地利用变化监测工作中应用多源遥感影像融合技术,可以获得更多数据支持,补充单一数据的不足。在应用时要结合具体情况有效整合,发挥不同类型融合方法的优势,满足工作需求。在城市建设扩张、农业用地动态变化、生态与灾害监测的工作中发挥作用,便于提高土地利用效率,为后续的规划利用提供依据。

参考文献

- [1] 廖超明,李宥儒,卢燕,等. 基于Landsat卫星数据的上林县土地利用变化监测研究[J]. 农业与技术,2025,45(1):76-81.
- [2] 李林超,钟良剑,苏庆,等. 基于多源数据融合的城市土地利用精细识别方法[J]. 西南交通大学学报,2025,60(2):326-335.
- [3] 李涛,颜伟. 基于多源遥感数据融合的土地利用类型信息提取研究[J]. 现代园艺,2020,43(13):10-12,14.
- [4] 董甲敏,刁伟. 遥感与测绘数据融合在土地资源管理中的应用[J]. 中国资源综合利用,2025,43(3):89-91.
- [5] 张良,张广法,韩明洋. 空间数据融合技术在土地利用规划中的应用研究[J]. 科技资讯,2024,22(24):185-188.

A high resolution remote sensing image ground object classification method based on deep learning

Anyang Xu

Third Institute of Aerial Survey and Remote Sensing, Ministry of Natural Resources, Chengdu, Sichuan, 610000, China

Abstract

With the continuous advancement of remote sensing technology, especially the widespread use of high-resolution remote sensing images, ground object classification has become increasingly important in environmental monitoring, urban planning, and agricultural surveillance. Traditional methods of remote sensing image classification often suffer from issues such as low accuracy and slow processing speeds. The emergence of deep learning technology has introduced new approaches to ground object classification, enabling the automatic extraction of complex features from images, which significantly enhances classification accuracy. This paper analyzes the current status and advantages of deep learning methods in remote sensing imagery and proposes relevant optimization strategies and future development directions. The application of deep learning technology not only improves the accuracy of ground object classification in remote sensing imagery but also provides strong support for the development of intelligent remote sensing technology.

Keywords

deep learning; high resolution remote sensing image; ground object classification; feature extraction; convolutional neural network

结合深度学习的高分辨率遥感影像地物分类方法

徐安阳

自然资源部第三航测遥感院, 中国·四川成都 610000

摘要

随着遥感技术的不断发展,尤其是高分辨率遥感影像的广泛应用,地物分类在环境监测、城市规划、农业监控等领域中起到了重要作用。传统的遥感影像分类方法存在精度不足、处理速度慢等问题,而深度学习技术的兴起为地物分类提供了新的思路,能够自动提取影像中的复杂特征,显著提高分类精度。本文通过分析当前深度学习技术在遥感影像中的应用现状及其优势,本文还提出了相关优化策略和未来的发展方向。深度学习技术的应用不仅提高了遥感影像地物分类的准确性,也为智能化遥感技术的发展提供了有力支持。

关键词

深度学习; 高分辨率遥感影像; 地物分类; 特征提取; 卷积神经网络

1 引言

遥感影像作为获取地面信息的主要手段之一,在环境监测、农业监控、城市规划等多个领域得到了广泛应用。随着遥感影像分辨率的提高,特别是高分辨率影像的普及,如何高效、准确地进行地物分类成为了研究的热点。传统的分类方法依赖于人工提取特征,容易受到影像质量、环境条件等因素的影响,精度和效率常常不能满足实际需求。近年来,深度学习技术的迅猛发展,尤其是卷积神经网络(CNN)的成功应用,为遥感影像的地物分类提供了新的解决方案。深度学习能够自动从大量数据中学习出有效的特征,克服了

传统方法中人工设计特征的不足。因此,结合深度学习的高分辨率遥感影像地物分类方法成为了一个备受关注的研究方向。

2 深度学习在遥感影像分类中的应用背景

2.1 遥感影像分类的重要性与挑战

遥感影像分类是获取地表信息并进行资源环境分析的重要手段,广泛应用于土地利用调查、城市扩展监测、灾害评估等领域。通过对遥感影像进行准确分类,可以实现对不同地物类型的有效识别和管理,提高空间信息利用效率。随着遥感技术的发展,影像分辨率不断提高,带来了更丰富的纹理和结构特征,也导致影像信息维度增大,地物之间边界更加复杂,增加了分类的难度。传统的分类方法如最大似然法和支持向量机在处理复杂场景时存在精度下降、特征表达不足等问题,难以满足高精度分类的需求。影像数据的多样

【作者简介】徐安阳(1995-),男,中国四川米易人,本科,助理工程师,从事遥感数据获取与处理工作和基础测绘、国土资源调查研究。

性和复杂性要求分类方法具备更强的特征提取能力与鲁棒性，对算法性能提出更高要求。

2.2 高分辨率遥感影像的特点及其对分类方法的要求

高分辨率遥感影像具有较强的空间分辨率和丰富的地物信息。影像分辨率的提升意味着可以获取更为细致的地面细节，因此高分辨率遥感影像在城市监测、农业研究、环境保护等领域的应用越来越广泛。随着影像分辨率的提高，地物分类面临着更加复杂的挑战。影像中的细节更加丰富，各类地物之间的差异往往变得更加微妙，传统的基于像元的分类方法难以有效应对这种高复杂度的情况。分类算法需要具有较强的特征提取能力，以识别影像中微小的地物差异。此外，高分辨率影像通常包含大量的噪声和影像畸变，要求分类方法具有较强的鲁棒性和抗干扰能力。因此，在进行高分辨率遥感影像的地物分类时，算法必须能够处理海量的像素数据，并在精度和计算效率之间实现平衡^[1]。

3 深度学习算法概述

3.1 卷积神经网络 (CNN) 原理与应用

卷积神经网络 (CNN) 是一种特殊的前馈神经网络，特别适用于图像处理任务。其主要优势在于能够通过卷积层自动提取图像的空间特征，而无需人工设计特征提取方法。CNN 通过一系列的卷积操作，可以捕捉到局部特征并在网络深层逐渐构建出全局特征，这使得它在遥感影像分类中具有非常高的表现力。CNN 的基本结构包括卷积层、池化层、全连接层等。卷积层通过滤波器提取输入图像的特征，池化层则通过降维减少计算量，同时保留重要信息。通过多层卷积和池化操作，CNN 能够提取出影像中从低级到高级的各种特征。在遥感影像的地物分类中，CNN 能够有效地识别不同地物的边界、纹理等特征，提升分类精度。研究表明，使用 CNN 进行遥感影像分类时，分类准确率可达到 90% 以上，远高于传统的支持向量机 (SVM) 和决策树等方法。

3.2 深度学习模型的训练与优化

深度学习模型的训练过程包括数据预处理、模型构建、训练优化等多个步骤。首先，数据预处理包括影像的去噪、增强、标准化等操作，目的是提高模型的鲁棒性并消除数据中的不相关因素。在模型构建方面，选择合适的网络结构至关重要。常见的网络结构有 AlexNet、VGG、ResNet 等，它们分别适用于不同类型的遥感影像数据。在训练过程中，模型的权重通过反向传播算法进行更新，使用梯度下降方法优化损失函数。为了防止过拟合，常用的优化技巧包括数据增强、正则化、dropout 等。优化过程中，还可以通过调节学习率、批量大小等超参数进一步提升模型性能。以 ResNet 为例，在遥感影像分类中，使用深度为 50 层的网络结构时，分类精度提高了约 5%，达到 95%。通过不断迭代优化，深度学习模型能够在大规模遥感数据集上实现高效且准确的地物分类。

3.3 遥感影像分类中深度学习模型的选择与对比

在遥感影像分类中，不同的深度学习模型各有优劣。卷积神经网络 (CNN) 是最常用的模型之一，但随着网络结构的不断创新，其他模型如 U-Net、DeepLab 等也被广泛应用于遥感影像分类。U-Net 由于其对称的编码器-解码器结构，在影像分割任务中表现优异，特别适合于提取遥感影像中的地物边界信息。在对比实验中，使用 U-Net 进行地物分类时，分类准确率可达到 93%，高于传统 CNN 模型的 89%。此外，深度卷积神经网络 (如 ResNet) 通过引入残差连接，克服了深层网络训练中的梯度消失问题，能在更深的层次上提取特征，尤其在复杂地形或高分辨率影像上效果显著。研究表明，ResNet50 在多分类任务中的分类精度可达到 95%，而 VGG16 和 AlexNet 的精度分别为 91% 和 89%。综上所述，不同深度学习模型在遥感影像分类中的应用效果有所不同，选择合适的模型需要根据具体的任务需求和数据特性来决定，详见表 1。

表 1 深度学习模型在遥感影像分类中的表现

模型名称	分类准确率	特点与优势
CNN	≥90%	适合图像处理任务，通过卷积层提取图像空间特征，无需人工特征提取，能够有效识别地物
U-Net	93%	采用编码器-解码器结构，适合影像分割，特别擅长提取地物边界信息
ResNet50	95%	引入残差连接克服梯度消失问题，适用于复杂地形与高分辨率影像，能够在深层次提取特征
VGG16	91%	深度网络结构，适用于不同地物的分类任务，精度较高
AlexNet	89%	传统的深度学习模型，适合基础分类任务，精度略低

4 高分辨率遥感影像的预处理与特征提取

4.1 影像去噪与增强处理方法

高分辨率遥感影像通常受到噪声的影响，噪声会导致图像细节丢失并降低分类精度。常用的去噪方法包括中值滤波、低通滤波以及小波变换等。这些方法在去除高频噪声的同时，能够有效保留影像的边缘和纹理特征。以高分辨率卫星影像为例，通过中值滤波去噪后，影像的信噪比提高了约

12%，而在低通滤波处理后，噪声的去除率提高了 15%。此外，影像增强处理方法如直方图均衡化和对比度拉伸能够提升影像的可视化效果，使得地物信息更加突出。应用这些技术后，影像的对比度提高了 20% 以上，有助于提高后续分类阶段的地物识别率^[2]。

4.2 地物特征的提取与表征

地物特征提取是遥感影像分类的核心。常见的特征