

<https://doi.org/10.3799/dqkx.2022.129>



基于深度特征的双极化 SAR 遥感图像岩性自动分类

李发森¹, 李显巨¹, 陈伟涛^{1*}, 董玉森¹, 李雨柯^{2*}, 王力哲¹

1. 中国地质大学计算机学院, 湖北武汉 430078

2. 中国地质调查局牡丹江自然资源综合调查中心, 黑龙江牡丹江 157000

摘要: 基于像元基元、极化合成孔径雷达 (Synthetic Aperture Radar, SAR) 数据和传统机器学习算法的岩性分类方法, 易受 SAR 图像固有斑点噪声影响, 精度不高。为了降低噪声的影响, 本研究以大尺度像元邻域为基元, 用于表征地表地质体的遥感图像特征和岩性语义信息; 采用高分三号双极化 SAR 数据进行极化分解构建 3 通道假彩色合成影像; 然后采用深度卷积神经网络 (Deep Convolutional Neural Network, DCNN) 迁移学习的方法, 提取有效的深度特征表示, 分别实现 5 m 和 15 m 两种空间分辨率下岩性遥感自动分类。结果表明: 基于不同分辨率数据和不同 DCNN 算法, 岩性遥感自动分类的总精度均大于 80%, 最高精度达到 91%。基于大尺度像元邻域和 DCNN 迁移学习方法, 能够实现基于 SAR 数据的高精度岩性分类。

关键词: 遥感; 岩性分类; 迁移学习; 卷积神经网络; 高分三号; SAR。

中图分类号: P23

文章编号: 1000-2383(2022)11-4267-13

收稿日期: 2022-05-15

Automatic Lithology Classification Based on Deep Features Using Dual Polarization SAR Images

Li Fasen¹, Li Xianju¹, Chen Weitao^{1*}, Dong Yusen¹, Li Yuke^{2*}, Wang Lizhe¹

1. School of Computer Science, China University of Geosciences, Wuhan 430078, China

2. Mudanjiang Natural Resources Comprehensive Survey Center, China Geological Survey, Mudanjiang 157000, China

Abstract: The lithology classification method based on pixel primitives, polarimetric synthetic aperture radar (SAR) data and traditional machine learning algorithm is easy to be affected by the inherent speckle noise, and the accuracy is not high. In order to reduce the effect of image noise, the neighborhood of large-scale pixels is considered as the primitive to characterize the spatial aggregation characteristics of surface geological units and the corresponding lithologic semantic information. Using GaoFen-3 dual polarization data, the polarization decomposition is carried out first, and a 3-channel color composite image is constructed as the input data of the subsequent model. Then, the deep convolutional neural network (DCNN) based migration learning method is used to extract the effective deep feature representation, so as to realize the automatic lithology classification under 5 m and 15 m spatial resolution conditions. The experiment results show that based on different resolution data and different DCNN algorithms, the total accuracy of automatic lithology classification is greater than 80%, and the highest accuracy is 91%. Generally, based on large-scale pixel neighborhood and DCNN migration learning method, high-precision lithology classification based on SAR data can be realized. The lithology remote sensing dataset based on dual polarization SAR created in this paper can also be used as the

基金项目: 国家自然科学基金资助项目 (Nos. U1803117, 41925007, U21A2013); 中国地质调查局项目 (Nos. DD20208015, MDJZXW2020016)。

作者简介: 李发森 (1995—), 男, 硕士研究生, 地学信息工程专业。ORCID: 0000-0003-2608-5690. E-mail: cseresen@cug.edu.cn

* **通讯作者:** 陈伟涛, E-mail: wtchen@cug.edu.cn; 李雨柯, E-mail: yuke198673@163.com

引用格式: 李发森, 李显巨, 陈伟涛, 董玉森, 李雨柯, 王力哲, 2022. 基于深度特征的双极化 SAR 遥感图像岩性自动分类. 地球科学, 47(11): 4267-4279.

Citation: Li Fasen, Li Xianju, Chen Weitao, Dong Yusen, Li Yuke, Wang Lizhe, 2022. Automatic Lithology Classification Based on Deep Features Using Dual Polarization SAR Images. *Earth Science*, 47(11): 4267-4279.

benchmark of lithology classification based on artificial intelligence.

Key words: remote sensing; lithology classification; transfer learning; deep convolutional neural network; GaoFen-3; SAR.

0 引言

岩性是地球浅地表最重要的基质类型,是区域地质调查、水文地质与工程调查、矿产资源调查、军事地质调查的重要对象之一,在资源环境监测、工程勘察以及国防建设等领域发挥着重要作用.长期以来,研究者利用卫星遥感技术宏观、综合、多尺度、多模态的观测优势(王润生等,2011;付光明等,2017),在岩性分类方面取得了一定的进展.早期阶段,众多研究者基于大量的野外工作和专业技能,在人机交互遥感目视解译技术层面形成了一套成熟的技术方法体系,成为遥感地质解译的主要工作模式(张为等,2019).然而,这种模式主观性强、效率低,特别是在人力难以到达的地方,无法获取准确的信息.因此,近年来岩性遥感自动分类成为研究重点(王润生,2008;张兵,2018).

国内外学者对岩性遥感自动分类进行了大量研究.在裸露区,基于多光谱和高光谱影像成像技术已经形成了一系列有效的技术方法体系,比如光谱指数法(Liu *et al.*, 2014;于亚凤等,2015;陈国旭等,2018)和光谱匹配法(郑硕和付碧宏,2013;董新丰等,2020;Sekandari *et al.*, 2022;李娜等,2021).总体上,光学遥感影像在岩性分类中一直扮演着极其重要的角色(张翠芬等,2020;程三友等,2021);但其成像质量易受天气影响,而且在植被覆盖区岩性信息容易被掩盖,导致岩性信息属于“弱信息”,依靠统计学方法或者光谱匹配方法很难提取到岩性信息(余先川等,2012).

合成孔径雷达(Synthetic Aperture Radar, SAR)具备全天时、全天候、高分辨率的特点,并且对地表植被具有一定的穿透性.极化SAR图像利用合成孔径原理记录了地物丰富的极化信息,可以提取地物的物理特性及纹理特征,广泛用于地表环境要素分类(杨涛等,2010;王馨爽等,2015;夏伟华和徐涵,2021).当前SAR遥感研究主要集中在数字高程模型重建(Li *et al.*, 2021)、形变测量(Kim *et al.*, 2019; Kalia *et al.*, 2021)、滑坡等灾害制图(Saepuloh *et al.*, 2017; Liu *et al.*, 2021; Dai *et al.*, 2021)、特殊目标探测(Pei *et al.*, 2021)等方面,岩性自动分类研究较少.张微等(2014)以Radarsat-2全极化影

像为数据源,开展某地区岩性、构造与矿化蚀变信息提取.Xie *et al.*(2015)基于支持向量机算法和全极化SAR数据,开展了岩性分类.Yuan *et al.*(2016)利用ASTER和RadarSAT-2数据进行岩性分类,提高了分类精度.Lu *et al.*(2021)基于“哨兵一号”双极化数据,采用人工特征和机器学习分类器,对白云石、安山岩、石灰岩、砂岩和花岗岩等岩体进行了分类.总之,上述方法以像元为基元,易受SAR图像固有斑点噪声影响,从而导致精度难以提升,而且采用的人工设计特征难以表征地表岩性的高层次语义信息.

近年来,多元多模式对地观测系统和智能计算技术的发展及计算能力的提升,为基于深度学习的遥感分类提供了机遇(Zhang *et al.*, 2017; 张兵, 2018).以卷积神经网络(Convolutional Neural Networks, CNN)为代表的深度学习技术,因其强大的特征提取能力,被广泛应用于基于SAR数据的遥感图像分类(Zhang *et al.*, 2017).如Liu *et al.*(2019)采用生成对抗网络和极化SAR图像,在西安地区开展了土地覆盖分类研究.Zhang *et al.*(2017)基于极化SAR影像的成像机制,建立了复数深度卷积神经网络(Deep CNN, DCNN);并利用极化SAR影像通道间相干相位差蕴含的地物信息,进行了土地利用分类.Zhou *et al.*(2017)基于极化SAR影像和CNN网络,有效提高了土地利用分类精度.张泽宇和刘畅(2020)通过极化分解特征和包含精细高维空间语义信息的膨胀卷积,实现了土地覆盖分类.总之,CNN因其强大的特征提取能力,能够提高土地利用/覆盖的分类精度.Wang *et al.*(2018)基于双极化SAR数据提取的特征和相干矩阵,叠加输入到堆叠稀疏自动编码器,从而开展岩性分类,并取得了较高的分类精度.

同类地质体在不同地质背景、不同尺度遥感图像上有相似的色调、几何形状、纹理特征;就植被覆盖区而言,在遥感场景尺度上,上层植被覆盖无法掩盖不同地质体的地形地貌和纹理特征,这是地质遥感目视解译的基础.与目视解译不同的是,各种遥感自动解译模型均要依赖多样化的定量遥感特征作为输入来完成.同类地质体的线段、边缘等共性浅、中层遥感特征,能够为遥感自动解译提供有

效的特征输入.特别地,SAR影像具有一定的穿透性,可以获取部分“裸地表”信息,处理后的图像立体特征相对光学图像较强,不同岩性遥感场景差异化特性能够通过深度特征进行刻画,这也是遥感岩性场景分类的理论基础.然而,当前基于深度学习技术开展岩性遥感分类的研究依然较少,主要有两个原因.(1)标注岩性遥感数据集困难导致数据集缺乏.深度学习技术需要大量的标注样本进行训练,而SAR图像的标注则依赖经验丰富的专业技术人员,工作量大,导致数据集缺乏.(2)覆盖区岩性信息不能直接探测导致提取有效的深度特征困难.与农田等土地利用/覆盖类型的遥感图像特征不同,岩性是由不同形态、结构以及纹理信息形成的高层次语义信息,是遥感影像上具有一定规模的不规则、不典型地质体的像元集合,需要设计能够精确表达这种语义特征的图像尺度表征方法.因此,为了充分挖掘岩性在场景尺度上的深度特征,本文首先构建了一套基于高分三号(GaoFen-3,GF-3)双极化SAR数据的大尺度邻域岩性数据集(简称CUG_GF3SD);然后,提出了一种基于大尺度像元邻域和深度特征的岩性遥感分类模型,以提升模型的遥感特征获取和表征能力;最后,基于不同空间分辨率数据和不同DCNN算法开展了大量实验,从而验证数据集和模型的有效性.

1 研究区与数据源

1.1 研究区概况

研究区位于黑龙江省南部的尚志市中南区域,牡丹江市西北方向,地貌以低山丘陵区和平原为主,地

形复杂、植被覆盖度高,分布有广泛的侵入岩,以花岗闪长岩和花岗岩为主.区内绝大部分岩浆岩形成于显生宙,古生代岩浆活动较为频繁,中生代则是岩浆集中爆发的高峰期.印支期晚期-燕山早期,该地区受古亚洲洋构造域向环太平洋构造域转换的影响,使得大部分侵入岩呈北-北东向展布.

1.2 遥感数据源

本次研究采用国产GF-3C波段双极化(HH和HV)精细条带I级影像,空间分辨率为5 m.GF-3卫星于2016年8月10日成功发射,是中国第一颗分辨率达1 m的C频段多极化SAR卫星(见表1).采用了GF-3卫星单视复数据,影像成像时间为2020年3月1日.

2 研究方法

2.1 遥感数据预处理与通道选择

采用PIE-SAR软件进行数据预处理,主要包括复数据转换、多视处理、极化矩阵转换(C2矩阵)、极化精致LEE波处理、H/A/ α 极化分解、地理编码等.低分辨率数据虽然损失了地物的细节信息,但本研究区地物分布以花岗闪长岩和松散堆积物为主,采用低分辨率数据可以有效减少异常数据点的影响,因此实验使用ArcGIS10.6软件将影像重采样到15 m对比实验.

对于不同波长、极化方式的雷达电磁波,不同粒度、风化程度的岩性表面呈现不同的电磁散射特征.地物目标的极化散射信息能表征丰富的地物特征,因此获取有效的地物极化信息是提高极化SAR图像分类精度的关键.相比于单极化SAR,多极化

表 1 GF-3 卫星有效载荷技术指标 (刘杰和张庆君, 2018)
Table 1 Main technical index of GF-3 satellite payload (Liu and Zhang, 2018)

成像模式名称		分辨率(m)	幅宽(km)	极化方式
滑块聚束(SL)		1	10	单极化
	UFS	3	30	单极化
条带成像模式	FSI	5	50	双极化
	FSII	10	100	双极化
	SS	25	130	双极化
	QPSI	8	30	全极化
	QPSII	25	40	全极化
	NSC	50	300	双极化
扫描成像模式	WSC	100	500	双极化
	GLO	500	650	双极化
波成像模式(WAV)		10	5	全极化
扩展入射角(EXT)	低入射角	25	130	双极化
	高入射角	25	80	双极化




图1 研究区SAR假彩色合成图像
Fig.1 SAR false color composite images
左图为初始图像,右图为线性拉伸后图像

SAR 获取的散射矩阵包含了地物的物理特性和几何特性,如方向、形状、粗糙度、介电常数等,这些特征可以以一定特征表现在 SAR 影像上,这是多极化数据的优势.为了充分利用极化信息,对 GF-3 双极化 SAR 数据进行 Cloude-Pottier 分解,得到了极化散射熵 H 、各向异性度 A 、极化散射角 α .

为了适应主流预训练深度学习模型的输入数据通道数,本次研究基于先验知识(不同通道合成影像与目视解译数据的吻合度)选择 HH、HV 和极化散射角作为 R、G、B 波段,进行彩色合成(如图 1 所示),并作为后续模型输入数据.由于强散射点遮蔽效应,SAR 图像的灰度值一般不均匀,甚至存在负值.本次研究通过线性拉伸的方式将灰度值映射

到 0~255,既保证其符合一般网络模型的数据输入,同时也增强了图像的对比度,有利于深度学习模型提取深层特征.通过线性拉伸,对图像数据进行增强,是一种基于先验知识的操作,能够在一定程度上提升深度学习模型的可解释性.

2.2 CUG_GF3SD SAR 岩性数据集构建

2.2.1 真实标签图构建

首先基于研究区 1:5 万地质图、高分二号全色与多光谱融合影像以及 GF-3 假彩色合成影像,采用人机交互目视解译方式,得到了研究区遥感岩性和地表水的初步解译结果.然后,在野外实地验证的基础上进行修改完善,形成了最终的岩性和地表水分布结果.将其作为真值标签图(图 2),用于数据集构建和模型性能测试.研究区包括板岩、花岗闪长岩、片岩、黄土、松散堆积物以及水体.

2.2.2 CUG_GF3SD SAR 数据集制作

首先,利用 ArcGIS10.6 软件在研究区每个类的区域内随机选取一定数量采样点;然后裁取以采样点为中心的大尺度邻域范围影像.如果像元邻域太小,则信息丢失严重,若尺寸太大,研究区数据集影像会严重重复,因此本文选择 48×48 作为邻域范围,像元大小分别为 15 m 和 5 m;最后,将裁剪影像分别存储在相应类别文件夹下,从而构成岩性数据集.该过程用 Python 编程自动实现.每类样本点的个数根据研究区内相应地物的分布面积确定(具体比例见表 2).




图2 研究区岩性和地表水分布图及野外验证点与照片
Fig.2 Constructed lithology and surface water distribution, field verification points and photos in the study area

首先,分别构建 5 m 和 15 m 分辨率的数据集 (CUG_GF3SD_5, CUG_GF3SD_15), 每个数据集均含 6 750 张样本,其中板岩 300 张,花岗闪长岩 2 500 张,黄土 150 张,片岩 300 张,松散堆积物 2 000 张,水体 1 500 张. 由于水体分布呈线状的特殊性,对水体采样较多. 此外,对于 5 m 分辨率的大尺度邻域影像,又构建了一个数据集 (CUG_GF3SD_M5), 各类别数量为数据集 CUG_GF3SD_5 的 2.5 倍,共 16 875 张影像.

数据集 (图 3) 涵盖 6 类地物类型,分别为 15 m 分辨率影像 (如图 4 所示) 以及 5 m 分辨率影像 (如图 5 所示); 存储为“tif”格式,不同数量的数据集总大小分别为 48.6 MB 和 129 MB; 分别为每一个类别分配一个数字标签 (0、1、2、…、5), 模型训练时转为有效编码 (OneHot).

如图 4 和图 5 所示的数据,15 m 分辨率包含更大范围的信息,能表达地质场景语义信息,而 5 m 分辨率反映的更多是局部范围的信息,局部信息丰富.

表 2 不同数据集采样点数量在相应类别的比例

Table 2 Proportion of corresponding categories of sampling points of different data sets

数据集	松散堆积物(%)	板岩(%)	水体(%)	片岩(%)	花岗闪长岩(%)	黄土(%)
CUG_GF3SD_5	1.85	4.48	51.51	16.35	0.91	34.96
CUG_GF3SD_15	1.85	4.48	51.51	16.35	0.91	34.96
CUG_GF3SD_M5	0.13	0.34	3.65	1.09	0.06	3.44



图 3 CUG_GF3SD 数据集描述图
Fig.3 Content description of CUG_GF3SD dataset




图 4 CUG_GF3SD_15 数据集各类型部分影像块
Fig.4 CUG_GF3SD_15 dataset display of various classes




图5 CUG_GF3SD_5数据集各类型部分影像块
Fig.5 CUG_GF3SD_5 dataset display of various classes




Fig.6 Polarimetric SAR lithology classification model based on migration learning and large-scale neighborhood

2.3 模型构建

DCNN需要大量的标记样本才能有效训练,否则容易出现过拟合等问题.由于当前尚没有公开发表的岩性遥感数据集,本次研究提出了一种基于迁移学习的岩性遥感分类模型.该模型训练时,输入图像为已裁剪的 48×48 的大尺度像素邻域图像数据集;而使用滑动窗口逐像素点构建 48×48 邻域图像进行预测并评价精度.具体地,首先迁移基于ImageNet数据集(Deng *et al.*, 2009; Krizhevsky *et al.*, 2012)的预训练模型和权重;然后采用岩性数据集进行微调,从而提取SAR影像的有效深度特征;最后,使用SoftMax分类器进行分类.

虽然ImageNet的自然图像数据与SAR影像数据有较大差异,但是ImageNet预训练的网络模型,能学习到图像的一些通用特征,如颜色和边缘等.这些浅层、中层的通用特征,能服务于基于SAR影像数据的岩性分类.

本次研究选取了VGG16, ResNet101v2,以及DenseNet121等3个不同连接方式的预训练模型.其中VGG16是经典的神经网络,结构相对简单,相较于其他两种网络更浅,因而需要训练的参数量也小(Simonyan and Zisserman, 2015). ResNet101v2通过跳跃连接的方式来加深网络,降低了数据中信息的冗余度,训练速度更快(He *et al.*, 2016);而

DenseNet121 通过 DenseBlock 设计直接将所有层连接起来,减少了参数量,能避免梯度消失的问题(Huang *et al.*, 2017).通过实验,一是验证本次研究构建的 CUG_GF3SD 数据集的可靠性;二是评价 3 种主流的深度特征提取网络对双极化 SAR 影像岩性特征的表征能力.图 6 是构建的基于迁移学习和大尺度邻域的极化 SAR 岩性分类模型.

岩性是高层次的语义信息,需要深度网络提取高层次、抽象的可区分特征,因此选用上述 3 个 DCNN 模型.而研究区数据集样本量较少,因此采用了预训练模型迁移和微调的策略.选用的 3 个模型中,VGG16 是相对轻量的网络,DenseNet121 和 ResNet101v2 是相对重型的网络.之所以在研究区数据集样本量较少的前提下,仍选用相对重型网络,一是可以综合评价迁移-微调的有效性;二是测试提出的数据集适用的 DCNN 模型的边界,即是否适用于较重型的 DCNN 模型.

2.4 精度评价指标

采用单类精度、总体精度 (Overall Accuracy, OA)、混淆矩阵以及 Kappa 系数来评价分类结果.其中,单类精度即为每类正确分类数量在相应类别的占比,OA 是分类结果的总体评价,如式(1)所示.Kappa 系数是用于一致性检验的指标,可以更加客观地反映分类结果和真实数据之间的一致程度,如式(2)所示.

$$OA = \frac{\sum_i N_i}{\sum_i T_i}, \quad (1)$$

N_i 代表所有正确分类的样本数量, $\sum_i T_i$ 代表所有测试样本数量;

$$Kappa = \frac{P_o - P_c}{1 - P_c}, \quad (2)$$

其中, P_o 为分类正确的样本数除以总样本数; P_c 为混淆矩阵中每一行的和乘以每一列的和,然后再将其相加除以样本总数的平方.

3 实验及结果分析

3.1 实验环境及参数设置

实验在 64 位 Linux 环境下,基于深度学习框架 TensorFlow1.13.1、PyCharm 软件等进行;硬件配置为 NVIDIA GeForce RTX 2080ti 显卡,显存为 11 GB;采用 CUDA10.0 进行 GPU 加速计算.训练集和验证集的划分比例为 9:1,最后进行全图预测并进行精度评价;3 个模型的实验均采用相同的训练

参数,并根据验证集的训练情况设置,批大小 (Batch Size) 为 512,学习率为 0.000 1,迭代次数 (epoch) 为 500,优化器使用 Adam,动量参数为 0.9.

3.2 实验结果与分析

为了对比 3 个模型对 5 m 和 15 m 分辨率影像的分类精度,我们构建了两个数量相同但分辨率不同的数据集 (CUG_GF3SD_5, CUG_GF3SD_15),并进行了 2 组实验.图 7 和图 8 分别是 15 m 分辨率真值标签图与不同特征提取网络分类结果及对应的混淆矩阵,图 9 和图 10 为 5 m 分辨率的结果.表 3 是 CUG_GF3SD_5 和 CUG_GF3SD_15 影像在不同特征提取网络下各类别的分类精度对比.

此外,5 m 分辨率的总数据量约为 15 m 数据的 10 倍,因此我们又构建了一个 5 m 的数据集 (CUG_GF3SD_M5) 进行实验 (数据占比见表 2),其中每一类的数量均提升 2.5 倍,以此来体现 5 m 数据的特点 (即所含信息多,但是也复杂;冗余信息多,模型需要较多数据学习可区分的特征),分类结果如图 11、图 12、表 4 所示.

各数据集各自相应类别占比见表 2.

3.2.1 CUG_CF3SD_5 和 CUG_CF3SD_15 数据集实验结果对比与分析 由表 3 知,在相同分辨率下,3 个模型对于花岗闪长岩和松散堆积物的分类精度都相对较高.并且在假彩色影像上,二者与其他类之间的区分度较高,如花岗闪长岩呈现明亮的蓝色.此外,在不同类别的分界处容易出现错分,这是由于本次研究时,训练采用大尺度邻域,在截取邻域图像时,会有相邻类的一部分被截取,这会导致边界不好识别,因而类别分界线不准.而花岗闪长岩与所有的类别都相邻,因而从图 8 和图 10 来看,3 个模型都将其他类的部分错分为花岗闪长岩.水体在图像上呈现线状,因此截取邻域图片时不可避免包含其他类,使得模型分类结果在水体的周围形成了类似缓冲区的效果 (图 7, 图 9),并且 5 m 分辨率的水体分类结果更加精细.

就 3 个模型而言,在板岩、黄土以及片岩等样本数量少的情况下,模型越复杂,这些数量少的类就容易出现过拟合,导致精度不准.因而 VGG16 的分类结果是最好的,其次是参数量稍小的 DenseNet 网络. ResNet 的 Kappa 系数要低于其他两个模型,将许多其他类误分为花岗闪长岩,因而一致性较低.

通过对不同分辨率影像的分类结果进行分析可知:对于总体分类结果来说,基于低分辨率的数




图7 CUG_GF3SD_15真实标签图和分类结果

Fig.7 Classification results of CUG_GF3SD_15
a. 真值标签;b.VGG16;c.ResNet;d.DenseNet




图8 CUG_GF3SD_15分辨率混淆矩阵

Fig.8 Confusion matrix of CUG_GF3SD_15
a.VGG16; b. DenseNet; c. ResNet.0. 板岩;1. 花岗闪长岩;2. 黄土;3. 片岩;4. 水体;5. 松散堆积物

据集分类结果与真值一致性较高(Kappa),这是由于低分辨率影像可以有效消除周围噪声的影响.对于板岩、片岩、黄土等类,高分辨影像包含着丰富的信息,模型可以有效区分不同的类别,总体来说,平均精度要比低分辨率高10%以上.但是对于高分辨率影像来说,信息量增多的同时

也会包含更多的冗余信息(如噪声等),因而出现了许多错分,Kappa系数较低,总体精度也较低.从图9来看,5 m 分类结果也有更多的噪点.

3.2.2 CUG_GF3SD_M5数据集实验结果与分析

在样本数量增加2.5倍时,相较于CUG_GF3SD_5结果,松散堆积物、片岩、花岗闪长岩、板岩等类别,




图9 CUG_GF3SD_5分类结果

Fig.9 Classification results of CUG_GF3SD_5

a. 真值标签; b. VGG16; c. ResNet; d. DenseNet




图10 CUG_GF3SD_5分辨率混淆矩阵

Fig.10 Confusion matrix of CUG_GF3SD_5

a. VGG16; b. DenseNet; c. ResNet. 0. 板岩; 1. 花岗闪长岩; 2. 黄土; 3. 片岩; 4. 水体; 5. 松散堆积物

精度平均提升超过5%;特别是对于板岩来说,精度提升20%.相较于图9的结果,3个模型的Kappa系数均提升约10%,分类结果与真值的一致性有了巨大的提高.这说明5 m分辨率影像有着更为丰富的局部信息,模型可以区分更细小的类间差异,减小冗余信息的干扰,因而精度提高.并且,CUG_GF3SD_M5数据和总数据量的比例非常小

(如表2所示),这也反映了5 m数据的优势.

综上所述,在使用基于大尺度邻域的分类方法时,像素中心点周围的其他地物分布对分类结果有较大影响.低分辨率SAR影像舍弃了一部分信息来减小周围噪声的影响,这对于具有天然噪声的SAR影像分类有一定的正作用,但会降低边界区域精度.而高分率SAR影像信息丰富,但也会蕴含更多冗余

表 3 不同分辨率下各特征提取网络分类精度

Table 3 Classification accuracy of backbone networks under different resolutions

特征提取网络	数据集	松散堆积物	板岩	水体	片岩	花岗闪长岩	黄土	OA	Kappa
VGG16	CUG_GF3SD_15	0.79	0.86	0.87	0.65	0.94	0.69	0.89	0.78
	CUG_GF3SD_5	0.86	0.65	0.93	0.89	0.87	0.82	0.86	0.71
DenseNet121	CUG_GF3SD_15	0.76	0.57	0.86	0.55	0.94	0.62	0.88	0.73
	CUG_GF3SD_5	0.86	0.64	0.93	0.89	0.87	0.82	0.85	0.68
ResNet101v2	CUG_GF3SD_15	0.64	0.47	0.78	0.35	0.95	0.67	0.85	0.66
	CUG_GF3SD_5	0.84	0.60	0.92	0.82	0.84	0.75	0.84	0.67




图 11 CUG_GF3SD_M5分类结果
Fig.11 Classification results of CUG_GF3SD_M5
a. 真值标签;b.VGG16;c.ResNet;d.DenseNet

信息,需要较多数据集来支撑模型。

实验结果表明:(1)3个模型的效果均较好,即迁移-微调是有效的;(2)基于少样本的两个数据集,重型网络效果略差;而多样本的数据集下,3个网络总体效果基本无差异。总之,少样本数据集适用于VGG16等轻量网络;多样本数据集更适用于重型网络。

此外,实验结果也表明:少样本数据集下,VGG16模型能充分训练,DenseNet121和ResNet101v2存在一定程度的欠拟合;而多样本数据集下,3个模型均能充分训练。

所训练出的深度学习分类模型,具有一定的泛化能力。例如,本文在东北高植被覆盖区训练获取的模型,在邻近区域可以直接使用,或者再使用极少量样本微调后使用。在我国西北地区等地质背景差别较大的区域,效果或许不会太好,但是可以作为预训练模型,




图 12 CUG_GF3SD_M5分辨率混淆矩阵

Fig.12 Confusion matrix of CUG_GF3SD_M5

a.VGG16;b.DenseNet;c.ResNet. 0. 板岩;1. 花岗闪长岩;2. 黄土;3. 片岩;4. 水体;5. 松散堆积物

表 4 CUG_GF3SD_M5分辨率各特征提取网络分类精度

Table 4 CUG_GF3SD_M5 classification accuracy of backbone networks

特征提取网络(5 m)	松散堆积物	板岩	水体	片岩	花岗闪长岩	黄土	OA	Kappa
VGG16	0.90	0.84	0.93	0.89	0.91	0.85	0.91	0.80
DenseNet121	0.90	0.84	0.93	0.91	0.90	0.82	0.90	0.78
ResNet101v2	0.89	0.82	0.93	0.87	0.90	0.80	0.90	0.77

用西北地区少量样本作微调,即可得到适用于西北地区的遥感岩性分类模型.尤其是,相比于直接使用 ImageNet 的预训练模型,微调所需的样本会更少,一定程度上提升了模型的泛化能力.

4 结论

针对遥感岩性解译面临的自动化程度低、精度低的问题,本文提出了一种基于深度学习的遥感岩性自动分类框架.利用以 GF-3 双极化数据,采用 H/A/ α 分解获取极化特征,合成 RGB 假彩色影像,构建了基于双极化 GF-3 影像的两种高分辨率岩性遥感场景数据集.针对极化 SAR 岩性分类面临的遥感特征表达问题,构建大尺度邻域基元策略,高效表征地质体的语义信息,并减小 SAR 图像噪声的影响,迁移 DCNN 预训练模型进行微调训练提取有效的影像特征后输入分类器,从而实现不同空间分辨率下岩性遥感自动分类.实验结果表明,基于大尺度像元邻域和 DCNN 迁移学习方法,能够实现基于 SAR 数据的高精度岩性分类.

后续工作将重点关注 SAR 的不同散射和极化特征用于岩性识别的效能,采用光学影像数据开展岩性分类的效果,即用光学岩性数据(最好是和 SAR 影像有着相似语义)训练好的模型作为特征提取网络来微调训练,实现少样本 SAR 数据的岩性分类.

References

- Chen, G.X., Li, P.P., Liu, S.D., et al., 2018. Extraction and 3D Visualization of Surface Lithology Based on GF-1 Satellite Images. *Geography and Geo-Information Science*, 34(5): 31–36, 2 (in Chinese with English abstract).
- Cheng, S.Y., Chen, J., Lin, H.X., et al., 2021. Application of Geometric Precision Correction Based on High-Resolution Remote Sensing Image in 1: 50 000 Geological Mapping. *Geological Bulletin of China*, 40(4): 520–526 (in Chinese with English abstract).
- Dai, C., Li, W., Wang, D., et al., 2021. Active Landslide Detection Based on Sentinel-1 Data and InSAR Technology in Zhouqu County, Gansu Province, Northwest China. *Journal of Earth Science*, 32(5): 1092–1103.
- Deng, J., Dong, W., Socher, R., et al., 2009. Imagenet: A Large-Scale Hierarchical Image Database. 2009 IEEE Conference on Computer Vision and Pattern Recognition, Miami Beach, 248–255.
- Dong, X.F., Gan, F.P., Li, N., et al., 2020. Fine Mineral Identification of GF-5 Hyperspectral Image. *Journal of Remote Sensing*, 24(4): 454–464 (in Chinese with English abstract).
- Fu, G.M., Yan, J.Y., Zhang, K., et al., 2017. Current Status and Progress of Lithology Identification Technology. *Progress in Geophysics*, 32(1): 26–40 (in Chinese with English abstract).

- He, K., Zhang, X., Ren, S., et al., 2016. Identity Mappings in Deep Residual Networks. *Lecture Notes in Computer Science*, 630—645.
- Huang, G., Liu, Z., Laurens, V.D.M., et al., 2017. Densely Connected Convolutional Networks. 2017 IEEE Conference on Computer Vision and Pattern Recognition, Honolulu, 4700—4708.
- Kalia, A. C., Spreckels, V., Lege, T., 2021. Comparison of L- and C-B and SAR Data in the Saar Mining District, Germany. EGU General Assembly Conference Abstracts, Online, EGU21—12736. <https://doi.org/10.5194/egusphere-egu21-12736>
- Kim, J. W., Lu, Z., Kaufmann, J., 2019. Evolution of Sinkholes over Wink, Texas, Observed by High-Resolution Optical and SAR Imagery. *Remote Sensing of Environment*, 222: 119—132.
- Krizhevsky, A., Sutskever, I., Hinton, G.E., 2012. ImageNet Classification with Deep Convolutional Neural Networks. *Advances in Neural Information Processing Systems*, 25: 1097—1105.
- Li, N., Dong, X.F., Gan, F.P., et al., 2021. Application of Hyperspectral Remote Sensing Technology to Regional Geological Survey and Mapping in Bedrock Area. *Geological Bulletin of China*, 40(1): 13—21 (in Chinese with English abstract).
- Li, P., Li, Z., Dai, K., et al., 2021. Reconstruction and Evaluation of DEMs from Bistatic TanDEM-X SAR in Mountainous and Coastal Areas of China. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 14: 5152—5170.
- Liu, F., Jiao, L., Tang, X., 2019. Task-Oriented GAN for PolSAR Image Classification and Clustering. *IEEE Transactions on Neural Networks and Learning Systems*, 30(9): 2707—2719. <https://doi.org/10.1109/tnnls.2018.2885799>
- Liu, J., Zhang, Q.J., 2018. GF-3 Satellite and Its Application. *Satellite Application*, (6): 12—16 (in Chinese with English abstract).
- Liu, L., Zhou, J., Jiang, D., et al., 2014. Lithological Discrimination of the Mafic-Ultramafic Complex, Huitongshan, Beishan, China: Using ASTER Data. *Journal of Earth Science*, 25(3): 529—536. <https://doi.org/10.1007/s12583-014-0437-3>
- Liu, X., Zhao, C., Zhang, Q., et al., 2021. Integration of Sentinel-1 and ALOS/PALSAR-2 SAR Datasets for Mapping Active Landslides along the Jinsha River Corridor, China. *Engineering Geology*, 284: 106033.
- Lu, Y., Yang, C., Meng, Z., 2021. Lithology Discrimination Using Sentinel-1 Dual-Pol Data and SRTM Data. *Remote Sensing*, 13(7): 1280.
- Pei, J.F., Huo, W.B., Wang, C.W., et al., 2021. Multiview Deep Feature Learning Network for SAR Automatic Target Recognition. *Remote Sensing*, 13(8): 1455.
- Saepuloh, A., Bakker, E., Suminar, W., 2017. The Significance of SAR Remote Sensing in Volcano-Geology for Hazard and Resource Potential Mapping. *AIP Conference Proceedings*, 1857(1): 070005. <https://doi.org/10.1063/1.4987093>
- Sekandari, M., Masoumi, I., Pour, A. B., et al., 2022. ASTER and WorldView-3 Satellite Data for Mapping Lithology and Alteration Minerals Associated with Pb-Zn Mineralization. *Geocarto International*, 37(6): 1782—1812.
- Simonyan, K., Zisserman, A., 2015. Very Deep Convolutional Networks for Large-Scale Image Recognition. International Conference on Learning Representations (ICLR), San Diego, 1—14.
- Wang, R.S., 2008. On the Development Strategy of Remote Sensing Technology in Geology. *Remote Sensing for Land & Resources*, 85(1): 1—12, 42 (in Chinese with English abstract).
- Wang, R.S., Xiong, S.Q., Nie, H.F., et al., 2011. Remote Sensing Technology and Its Application in Geological Exploration. *Acta Geologica Sinica*, 85(11): 1699—1743 (in Chinese with English abstract).
- Wang, W., Ren, X., Zhang, Y., et al., 2018. Deep Learning Based Lithology Classification Using Dual-Frequency Pol-SAR Data. *Applied Sciences*, 8(9): 1513.
- Wang, X.S., Chen, E.X., Li, Z.Y., et al., 2015. Multi-Temporal and Dual-Polarization Interferometric SAR for Land Cover Type Classification. *Acta Geodaetica et Cartographica Sinica*, 44(5): 533—540 (in Chinese with English abstract).
- Xia, W.H., Xu, H., 2021. Study on Geological Hazards in Mining Areas Based on D-InSAR Technology. *Geomatics & Spatial Information Technology*, 44(2): 125—129, 134 (in Chinese with English abstract).
- Xie, M., Zhang, Q., Chen, S., et al., 2015. A Lithological Classification Method from Fully Polarimetric SAR Data Using Cloude-Pottier Decomposition and SVM. AOPC 2015: Optical and Optoelectronic Sensing and Imaging Technology. *International Society for Optics and Photonics*, 9674: 967405.
- Yang, T., Gong, H.L., Li, X.J., et al., 2010. Application of SAR to Remote Sensing of Geological Disasters. *Journal of Natural Disasters*, 19(5): 42—48 (in Chinese with English abstract).

- with English abstract).
- Yu, X.C., Zhou, X., Kang, Z.J., et al., 2012. Hierarchical Classification of Rock and Soil Based on Characteristic Multi-Band Image. *Journal of Jilin University (Earth Science Edition)*, 42(6): 1825—1833 (in Chinese with English abstract).
- Yu, Y.F., Yang, J.Z., Chen, S.B., et al., 2015. Lithologic Classification from Remote Sensing Images Based on Spectral Index. *Earth Science*, 40(8): 1415—1419 (in Chinese with English abstract).
- Yuan, W., Yan, M., Liu, S., 2016. Application of Radar and Optical Remote Sensing Data in Lithologic Classification and Identification. 2016 IEEE International Geoscience and Remote Sensing Symposium (IGARSS), Beijing, 6370—6373.
- Zhang, B., 2018. Remotely Sensed Big Data Era and Intelligent Information Extraction. *Geomatics and Information Science of Wuhan University*, 43(12): 1861—1871 (in Chinese with English abstract).
- Zhang, C.F., Hao, L.N., Wang, S.J., et al., 2020. Geological Units Classification with Texture-Spectral Synergy of Multi-Sourced Remote Sensing Images. *Earth Science*, 45(5): 1844—1854 (in Chinese with English abstract).
- Zhang, W., Li, Y.Y., Zhang, T.L., et al., 2019. Remote Sensing Interpretation of Landslide Geological Hazards in High Vegetation Coverage Area Based on Hazard Sensitivity Analysis. *Safety and Environmental Engineering*, 26(3): 28—35 (in Chinese with English abstract).
- Zhang, W., Lin, J., Chen, L., et al., 2014. Geological Information Extraction Using Polarimetric SAR Based on Polarization Decomposition. *Remote Sensing Information*, 29(1): 10—14 (in Chinese with English abstract).
- Zhang, Z., Wang, H., Feng, X., et al., 2017. Complex-Valued Convolutional Neural Network and Its Application in Polarimetric SAR Image Classification. *IEEE Transactions on Geoscience and Remote Sensing*, (12):1—12.
- Zhang, Z.Y., Liu, C., 2020. Terrain Classification of Pol-SAR Based on Dilated Convolution and Polarization Decomposition. *Microelectronics & Computer*, 37(12): 70—76 (in Chinese).
- Zheng, S., Fu, B.H., 2013. Lithological Mapping of Granitoids in the Western Junggar from ASTER SWIR-TIR Multispectral Data: Case Study in Karamay Pluton, Xinjiang. *Acta Petrologica Sinica*, 29(8): 2936—2948 (in Chinese with English abstract).
- Zhou, Y., Wang, H., Xu, F., et al., 2017. Polarimetric SAR Image Classification Using Deep Convolutional Neural Networks. *IEEE Geoscience & Remote Sensing Letters*, 13(12):1935—1939.
- ### 附中文参考文献
- 陈国旭, 李盼盼, 刘盛东, 等, 2018. 基于高分一号卫星遥感影像的地表岩性特征提取及三维可视化. *地理与地理信息科学*, 34(5): 31—36, 2.
- 程三友, 陈静, 林海星, 等, 2021. 高分辨率遥感图像几何校正正在高山峡谷区 1: 5 万地质填图中的应用. *地质通报*, 40(4): 520—526.
- 董新丰, 甘甫平, 李娜, 等, 2020. 高分五号高光谱影像矿物精细识别. *遥感学报*, 24(4): 454—464.
- 付光明, 严加永, 张昆, 等, 2017. 岩性识别技术现状与进展. *地球物理学进展*, 32(1): 26—40.
- 李娜, 董新丰, 甘甫平, 等, 2021. 高光谱遥感技术在基岩区区域地质调查填图中的应用. *地质通报*, 40(1): 13—21.
- 刘杰, 张庆君, 2018. 高分三号卫星及应用概况. *卫星应用*, (6): 12—16.
- 王润生, 2008. 遥感地质技术发展的战略思考. *国土资源遥感*, 85(1): 1—12, 42.
- 王润生, 熊盛青, 聂洪峰, 等, 2011. 遥感地质勘查技术与应用研究. *地质学报*, 85(11): 1699—1743.
- 王馨爽, 陈尔学, 李增元, 等, 2015. 多时相双极化合成孔径雷达干涉测量土地覆盖分类方法. *测绘学报*, 44(5): 533—540.
- 夏伟华, 徐涵, 2021. 基于 D-InSAR 技术的矿区地质灾害研究. *测绘与空间地理信息*, 44(2): 125—129, 134.
- 杨涛, 宫辉力, 李小娟, 等, 2010. 成像雷达遥感地质灾害应用. *自然灾害学报*, 19(5): 42—48.
- 余先川, 周鑫, 康增基, 等, 2012. 一种基于多特征波段岩石层次分类方法. *吉林大学学报(地球科学版)*, 42(6): 1825—1833.
- 于亚凤, 杨金中, 陈圣波, 等, 2015. 基于光谱指数的遥感影像岩性分类. *地球科学*, 40(8): 1415—1419.
- 张兵, 2018. 遥感大数据时代与智能信息提取. *武汉大学学报(信息科学版)*, 43(12): 1861—1871.
- 张翠芬, 郝利娜, 王少军, 等, 2020. 多源遥感数据图谱协同岩石单元分类方法. *地球科学*, 45(5): 1844—1854.
- 张为, 李远耀, 张泰丽, 等, 2019. 基于孕灾敏感性分析的高植被覆盖区滑坡地质灾害遥感解译. *安全与环境工程*, 26(3): 28—35.
- 张微, 林健, 陈玲, 等, 2014. 基于极化分解的极化 SAR 数据地质信息提取方法研究. *遥感信息*, 29(1): 10—14.
- 张泽宇, 刘畅, 2020. 基于极化分解和膨胀卷积的极化 SAR 地物分类. *微电子学与计算机*, 37(12): 70—76.
- 郑硕, 付碧宏, 2013. 基于 ASTER SWIR-TIR 多光谱数据的西准噶尔花岗岩类岩性信息提取与识别——以克拉玛依岩体为例. *岩石学报*, 29(8): 2936—2948.