



基于深度特征的双极化SAR遥感图像岩性自动分类

期刊:	《地球科学》
稿件 ID	ES-2021-0691.R3
稿件类型:	论文
作者提交的日期:	2022-3-17
完整作者列表:	李, 发森 李, 显巨 陈, 伟涛; 中国地质大学, 计算机学院 董, 玉森 李, 雨柯 王, 力哲
关键词:	岩性分类, 迁移学习, 卷积神经网络, 高分三号, SAR
研究方向:	遥感科学与技术

1
2
3
4
5
6
7
8
9
10
11
12
13
14
15
16
17
18
19
20
21
22
23
24
25
26
27
28
29
30
31
32
33
34
35
36
37
38
39
40
41
42
43
44
45
46
47
48
49
50
51
52
53
54
55
56
57
58
59
60

注：以下文件由作者提交进行同行评审，但是无法转换为 PDF。您必须在线查看这些文件（如视频文件）。

论文图件cdr格式.rar

SCHOLARONE™
Manuscripts

in press

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 430074

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: (目的) 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, (方法) 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相应的岩性语义信息; 采用高分三号双极化 SAR 数据, 先进行极化分解, 并构建 3 通道假彩色合成影像, 作为后续模型输入数据; 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, 从而分别实现 5m 和 15m 两种空间分辨率下岩性遥感自动分类。(结果) 实验结果表明: 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%, 且最高精度达到 91%。(结论) 总之, 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。论文创建的双极化 SAR 岩性遥感数据集, 也能作为基于人工智能的岩性遥感分类基准数据集。

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

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

LI Fasen¹, LI Xianju¹, CHEN Weitao¹, DONG Yusen¹, LI Yuke², WANG Lizhe¹

¹. School of Computer Science, China University of Geosciences, Wuhan, Hubei province 430074, China

². Mudanjiang natural resources comprehensive survey center, China Geological Survey, Mudanjiang, Heilongjiang province 57000, China

基金项目: 国家自然科学基金资助项目 (No. U1803117, No. 41925007; U21A2013); 中国地质调查局项目 (DD20208015; MDJZXW2020016)

作者简介: 李发森 (1995-), 男, 硕士研究生, 地学信息工程专业, Email: csersens@cug.edu.cn, [ORCID:0000-0003-2608-5690](https://orcid.org/0000-0003-2608-5690)

通讯作者: 陈伟涛 (1980-), 男, 教授, 博士生导师, 研究方向: 地质环境遥感, Email: wuchen@cug.edu.cn; 李雨柯 (1986-), 男, 工程师, 研究方向: 遥感地质及构造地质学, Email: yuke198673@163.com

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

43 **Key words:** Remote Sensing; Lithology Classification; Transfer Learning; Deep Convolutional Neural
44 Network; GaoFen-3; SAR

46 引言

47 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
48 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
49 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
50 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
51 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
52 形成了一套成熟的技术方法体系，成为是遥感地质解译的主要工作模式（张为等，2019）。
53 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。
54 因此，近年来岩性遥感自动分类成为研究重点（王润生等，2008；张兵等，2018）。

55 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
56 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
57 亚风等，2015；陈国旭等，2018）和光谱匹配法（郑硕等，2013；董新丰等，2020；
58 Sekandari et al., 2020；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
59 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
60 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
61 谱匹配方法很难提取到岩性信息（余先川等，2012）。

62 合成孔径雷达（Synthetic Aperture Radar, SAR）具备全天时、全天候、高分辨率的特
63 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
64 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，
65 2010；王馨爽等，2015；夏伟华等，2021）。当前 SAR 遥感研究主要集中在数字高程模型
66 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
67 （Saepuloh et al., 2017；Liu et al., 2021）、特殊目标探测（Pei et al., 2021），岩性自动分类
68 研究较少。张微等以 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
69 信息提取（张微等，2014）。Xie 等基于支持向量机算法和全极化 SAR 数据，开展了岩性
70 分类（Xie et al., 2015）。Yuan 等利用 ASTER 和 RadarSAT-2 数据进行岩性分类，提高了分
71 类精度（Yuan et al., 2016）。Lu 等基于“哨兵一号”双极化数据，采用人工特征和机器学习

72 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(Lu et al.,
73 2021)。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
74 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。

75 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
76 深度学习的遥感分类提供了机遇(Zhang et al., 2016; 张兵等, 2018)。以卷积神经网络
77 (Convolutional Neural Networks, CNN)为代表的深度学习技术,因其强大的特征提取能
78 力,被广泛应用于基于 SAR 数据的遥感图像分类(Zhang et al., 2016)。如 Liu 等采用生成
79 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(Liu et al., 2019)。
80 Zhang 等人基于极化 SAR 影像的成像机制,建立了复数深度卷积神经网络(Deep CNN,
81 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
82 (Zhang et al., 2017)。Zhou 等人基于极化 SAR 影像和 CNN 网络,有效提高了土地利用分
83 类精度(Zhou et al., 2017)。张泽宇等通过极化分解特征和包含精细高维空间语义信息的
84 膨胀卷积,实现了土地覆盖分类(张泽宇等, 2020)。总之, CNN 因其强大的特征提取能
85 力,能够提高土地利用/覆盖的分类精度。Wang 等基于双极化 SAR 数据提取的特征和相干
86 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
87 (Wang et al., 2018)。

88 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
89 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
90 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
91 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、
92 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
93 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
94 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
95 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。

96 (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
97 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。

98 (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
99 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
100 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
101 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
102 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
103 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
104 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
105 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。

106 1.研究区与数据源

107 1.1 研究区概况

108 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(如图 1 所示),地
109 貌。研究区以低山丘陵区和平原为主,地形复杂、植被覆盖度高,并分布有广泛的侵入岩,
110 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
111 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
112 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。



图 1 研究区地理位置示意图

Fig.1 Geographical location of the study area

1.2 遥感数据源

本次研究采用国产 GF-3 C 波段双极化 (HH 和 HV) 精细条带 I 级影像, 空间分辨率为 5m。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 1m 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。

表 1 GF-3 卫星有效载荷技术指标 (刘杰等, 2018)

Table 1 Main technical index of GF-3 satellite payload (Liu, et al.,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	
条带成像模式	UFS	3	单极化	
	FSI	5	双极化	
	FSII	10	双极化	
	SS	25	双极化	
	QPSI	8	全极化	
	QPSII	25	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

122


123 2.研究方法

124 2.1 遥感数据预处理与通道选择

125 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
 126 (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
 127 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
 128 辨率数据可以有效减少异常数据点的影响，因此实验使用 ArcGIS 10.6 软件将影像重采样到
 129 15m 对比实验。

130 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
 131 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
 132 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 SAR 获取的散
 133 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
 134 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，
 135 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、
 136 极化散射角 α 。

137 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
 138 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，
 139 进行彩色合成（如图 2 所示），并作为后续模型输入数据。由于强散射点遮蔽效应，SAR
 140 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
 141 0-255 之间，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
 142 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
 143 的操作，能够在一定程度上提升深度学习模型的可解释性。



144 图 2 研究区 SAR 假彩色合成图像（左图为初始图像，右图为线性拉伸后图像）

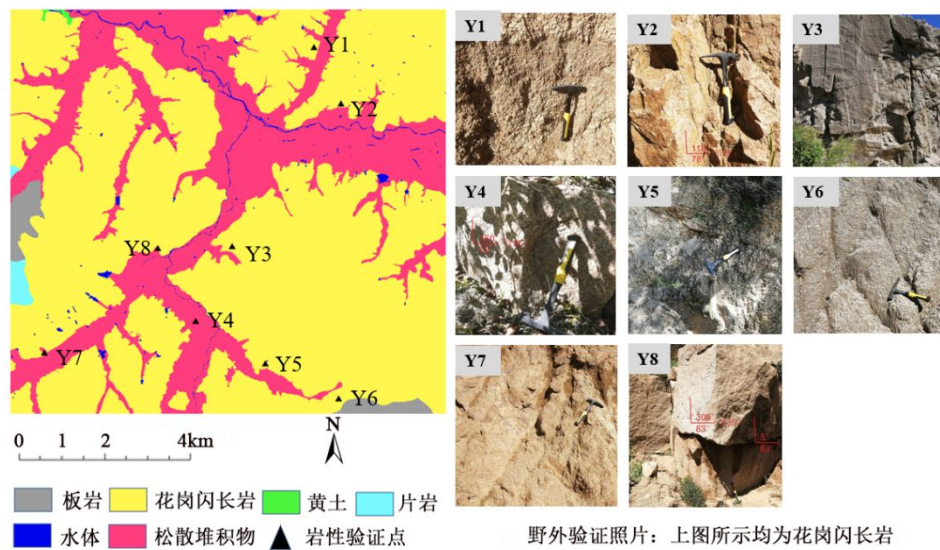
145 Fig 1. SAR false color composite image (The left is the initial image,
 146 the right is linear stretched image)
 147

148 2.2 CUG_GF3SD SAR 岩性数据集构建

149 2.2.1 真实标签图构建

150 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
 151 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。

152 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
 153 其作为真值标签图（图 3），用于数据集构建和模型性能测试。研究区包括板岩，花岗闪
 154 长岩，片岩，黄土，松散堆积物，以及水体。



野外验证照片：上图所示均为花岗闪长岩

155

156

图 3 研究区岩性和地表水分布图及野外验证点与照片

157

Fig. 3 Constructed lithology and surface water distribution, field verification points and photos in the study area

158

159 2.2.2 CUG_GF3SD SAR 数据集制作

160 首先，利用 ArcGIS 10.6 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
 161 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
 162 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
 163 别为 15m 和 5m；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。
 164 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
 165 （具体比例见表 2）。首先，分别构建 5m 和 15m 分辨率的数据集（CUG_GF3SD_5，
 166 CUG_GF3SD_15），每个数据集均含 6750 张样本，其中板岩 300 张，花岗闪长岩 2500 张，
 167 黄土 150 张，片岩 300 张，松散堆积物 2000 张，水体 1500 张。由于水体分布呈线状的特
 168 殊性，对水体采样较多。此外，对于 5m 分辨率的大尺度邻域影像，又构建了一个数据集
 169 （CUG_GF3SD_M5），各类别数量为数据集 CUG_GF3SD_5 的 2.5 倍，共 16875 张影像。

170 数据集（图 4）涵盖 6 类地物类型，分别为 15m 分辨率影像（如图 5 所示）以及 5m
 171 分辨率影像（如图 6 所示）；存储为“tif”格式，不同数量的数据集总大小分别为 48.6MB
 172 和 129MB；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
 173 效编码（OneHot）。

174 如图 5 和图 6 所示的数据，15m 分辨率包含更大范围的信息，能表达地质场景语义信
 175 息，而 5m 分辨率反映的更多是局部范围的信息，局部信息丰富。

176

表 2 不同数据集采样点数量在相应类别的比例

177

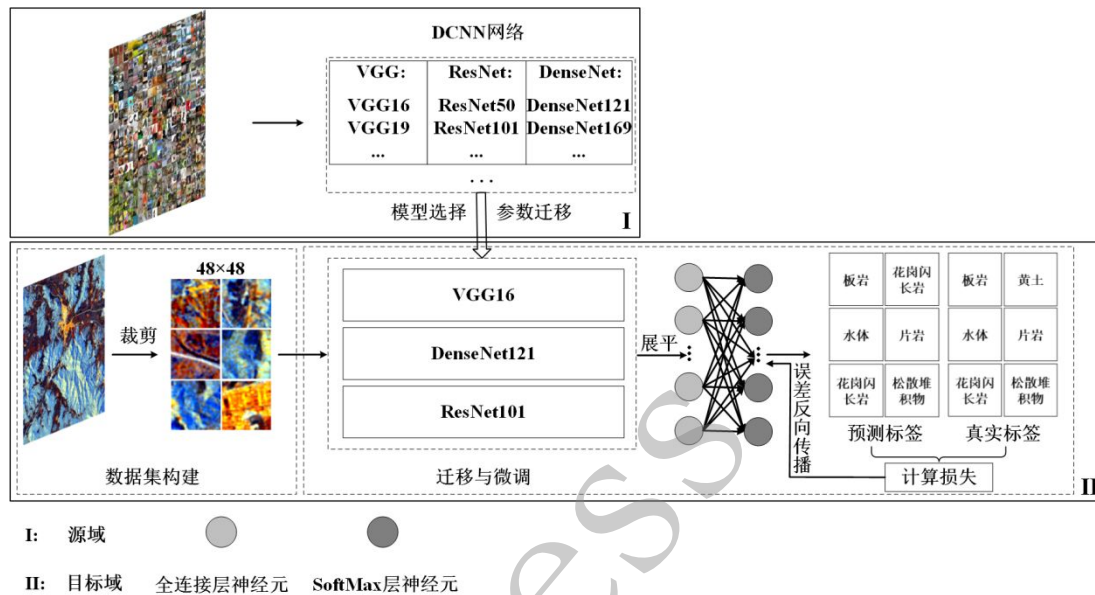
Table 2 Proportion of corresponding categories of sampling points of different data sets

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

178

190 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。
 191 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
 192 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
 193 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
 194 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。

195 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
 196 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，
 197 能服务于基于 SAR 影像数据的岩性分类。



198

199 图 7 基于迁移学习和大尺度邻域的极化 SAR 岩性分类模型

200

Fig 7. Polarimetric SAR lithology classification model based on migration learning and large-scale neighborhood

201

202 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 et al., 2014）。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；二是评价三种主流的深度特征提取网络对双极化 SAR 影像岩性特征的代表能力。图 7 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。

210 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 ResNet101 v2 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。

216 2.4 精度评价指标

217 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

218

219 的总体评价, 如式 (1) 所示。Kappa 系数是用于一致性检验的指标, 可以更加客观的反映
220 分类结果和真实数据之间的一致程度, 如式 (2) 所示。

$$221 \quad OA = \frac{\sum_i N_i}{\sum_i T_i} \quad (1)$$

222 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;

$$223 \quad Kappa = \frac{P_o - P_c}{1 - P_c} \quad (2)$$

224 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于每一列的
225 和, 然后再将其相加除以样本总数的平方。

226 3.实验及结果分析

227 3.1 实验环境及参数设置

228 实验在 64 位 Linux 环境下, 基于深度学习框架 TensorFlow 1.13.1、PyCharm 软件等进
229 行; 硬件配置为 NVIDIA GeForce RTX 2080ti 显卡, 显存为 11GB; 采用 CUDA 10.0 进行
230 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;
231 三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
232 Size) 为 512, 学习率 0.0001, 迭代次数 (epoch) 为 500, 优化器使用 Adam, 动量参数为
233 0.9。

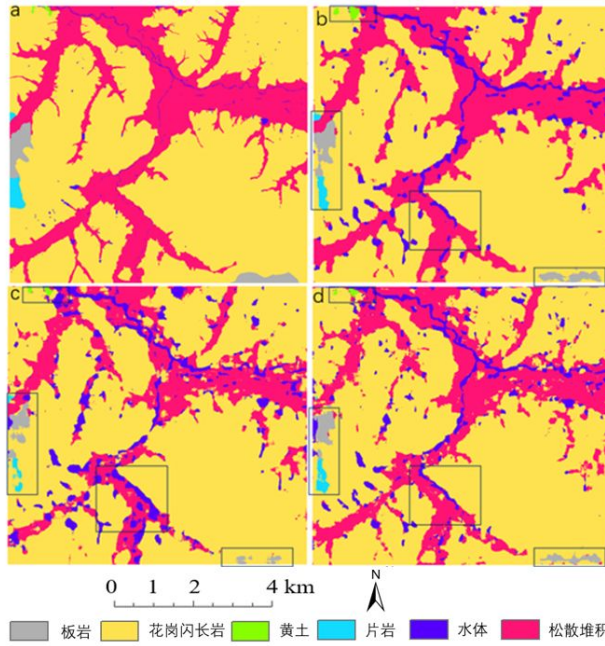
234 3.2 实验结果与分析

235 为了对比 3 个模型对 5m 和 15m 分辨率影像的分类精度, 我们构建了两个数量相同但
236 分辨率不同的数据集 (CUG_GF3SD_5, CUG_GF3SD_15), 并进行了 2 组实验。图 8 和
237 图 9 分别是 15m 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 10
238 和图 11 为 5m 分辨率的结果。表 3 是 CUG_GF3SD_5 和 CUG_GF3SD_15 影像在不同特征
239 提取网络下各类别的分类精度对比。

240 此外, 5m 分辨率的总数据量约为 15m 数据的 10 倍, 因此我们又构建了一个 5m 的数
241 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,
242 以此来体现 5m 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
243 据学习可区分的特征), 分类结果如图 12、图 13、表 4 所示。


244 各数据集各自相应类别占比见表 2。

245 3.2.1 CUG_GF3SD_5 和 CUG_GF3SD_15 数据集实验结果对比与分析



246
247
248

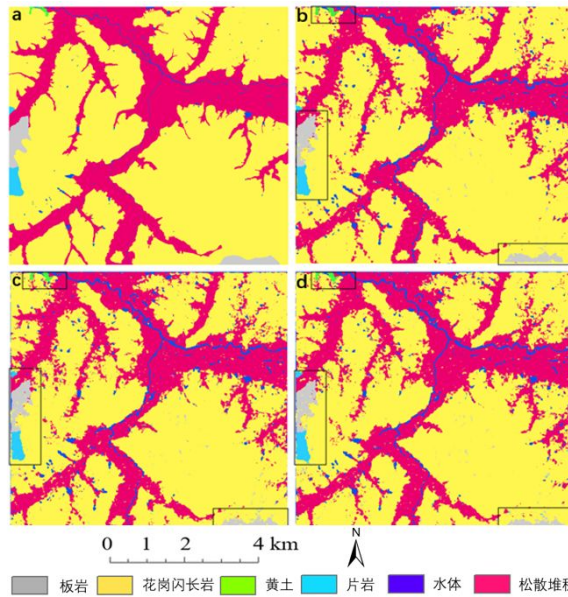
图 8 CUG_GF3SD_15 真实标签图和分类结果 (a-真值标签, b-VGG16, c-ResNet, d-DenseNet)
Fig 8. Classification results of CUG_GF3SD_15 (a-True label, b-VGG16,c-ResNet,d-DenseNet)



249
250
251

0-板岩 1-花岗闪长岩 2-黄土 3-片岩 4-水体 5-松散堆积物

图 9 CUG_GF3SD_15 分辨率混淆矩阵 (a-VGG16, b-DenseNet, c-ResNet)
Fig 9. Confusion matrix of CUG_GF3SD_15 (a-VGG16, b-DenseNet, c-ResNet)




252

253

254

图 10 CUG_GF3SD_5 分类结果 (a-真值标签, b-VGG16, c-ResNet, d-DenseNet)

Fig 10. Classification results of CUG_GF3SD_5(a-True label, b-VGG16,c-ResNet,d-DenseNet)



255

256

257

258

259

260

261

262

0-板岩 1-花岗闪长岩 2-黄土 3-片岩 4-水体 5-松散堆积物

图 11 CUG_GF3SD_5 分辨率混淆矩阵 (a-VGG16, b-DenseNet, c-ResNet)

Fig 11. Confusion matrix of CUG_GF3SD_5 (a-VGG16, b-DenseNet, c-ResNet)

表 3 不同分辨率下各特征提取网络分类精度

Table 3 Classification accuracy of backbones 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

263

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

264 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
265 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
266 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
267 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 9 和图 11 来看，三个模型
268 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
269 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 8，图
270 10），并且 5m 分辨率的水体分类结果更加精细。


271 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
272 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
273 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
274 类误分为花岗闪长岩，因而一致性较低。

275 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
276 分辨率的数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
277 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
278 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
279 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
280 错分，Kappa 系数较低，总体精度也较低。从图 10 来看，5m 分类结果也有更多的噪点。

281 3.2.2 CUG_GF3SD_M5 数据集实验结果与分析

282 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
283 长岩、板岩等类别，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
284 于图 10 的结果，三个模型的 Kappa 系数均提升约 10%，分类结果与真值的一致性有了巨
285 大的提高。这说明 5m 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
286 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
287 比例非常小（如表二所示），这也反映了 5m 数据的优势。

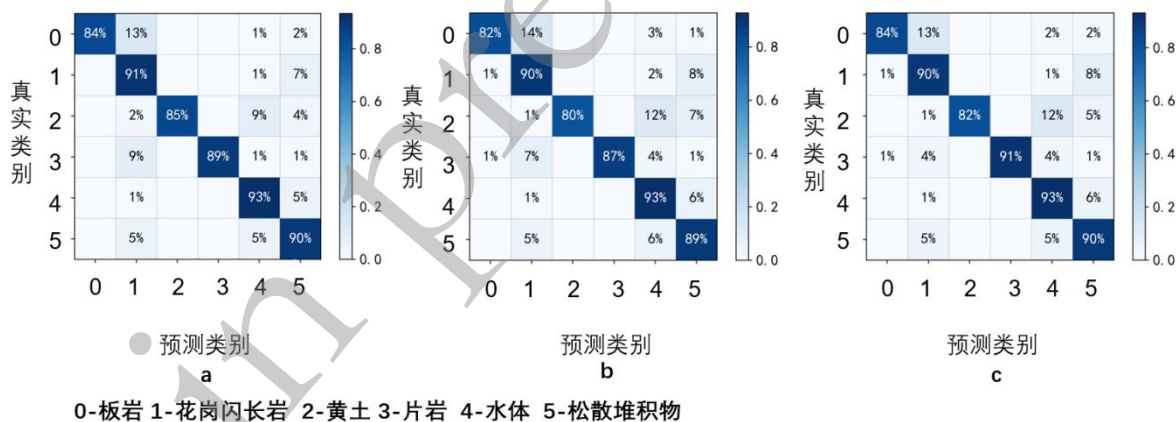
288



289
290
291

图 12 CUG_GF3SD_M5 分类结果 (a-真值标签, b-VGG16, c-ResNet, d-DenseNet)

Fig 12. Classification results of CUG_GF3SD_M5 (a-True label, b-VGG16, c-ResNet, d-DenseNet)



292
293
294
295
296

图 13 CUG_GF3SD_M5 分辨率混淆矩阵 (a-VGG16, b-DenseNet, c-ResNet)

Fig 13. Confusion matrix of CUG_GF3SD_M5 (a-VGG16, b-DenseNet, c-ResNet)

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 backbones networks

特征提取网络 (5m)	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

297
298
299

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

300 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
301 影像信息丰富, 但也会蕴含更多冗余信息, 需要较多数据集来支撑模型。

302 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
303 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
304 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。

305 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
306 ResNet101 v2 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。

307 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
308 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
309 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,
310 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
311 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
312 泛化能力。

313 4.结论

314 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
315 习的遥感岩性自动分类框架。利用以 GF-3 双极化数据为, 采用 H/A/ α 分解获取极化特征,
316 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。
317 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
318 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
319 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
320 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
321 岩性分类。

322 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
323 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
324 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。

326 References

- 327 Chen, G.X., Li, P.P., Liu, S.D., et al., 2018.Extraction and 3D Visualization of Surface Lithology Based on GF-1
328 Satellite Images. *Geography and Geo-Information Science*, 34(05):31-36+2.Doi: 10.3969/j.issn.1672-
329 0504.2018.05.006.
- 330 Cheng, S.Y., Chen, J., Lin, H.X., et al., 2021.Application of geometric precision correction based on high-resolution
331 Remote Sensing Image in 1:50000 geological mapping. *Geological Bulletin of China*, 40(04):520-526.
- 332 Dong, X.F., Gan, F.P., L, N., 2020.Fine mineral identification of Gf-5 hyperspectral image. *National Remote Sensing
333 Bulletin*,24(04):454-464.
- 334 Deng J, Dong W, Socher R, et al.,2009. Imagenet: A large-scale hierarchical image database[C]//2009 IEEE
335 conference on computer vision and pattern recognition. IEEE: 248-255.
- 336 Fu, G.M., Yan, J.Y., Zhang, K., et al.,2017. Current status and progress of lithology identification technology.
337 *Progress in Geophysics*,32(01):26-40. Doi: CNKI: SUN: DQWJ.0.2017-01-004.
- 338 He K, Zhang X, Ren S, et al.,2016. Identity mappings in deep residual networks. arXiv 2016[J]. arXiv preprint
339 arXiv:1603.05027.
- 340 Huang, G., Liu, Z., V.D.M., Laurens, et al.,2017. Densely connected convolutional networks[C]//*Proceedings of the
341 IEEE conference on computer vision and pattern recognition.*: 4700-4708.

- 1
2
3 342 Kalia, A. C., Spreckels, V., Lege, T.,2021.Comparison of L-and C-Band SAR data in the Saar Mining District,
4 343 Germany[C]//*EGU General Assembly Conference Abstracts.* : EGU21-12736.
- 5 344 Kim, J. W., Lu, Z., Kaufmann, J.,2019. Evolution of sinkholes over Wink, Texas, observed by high-resolution optical
6 345 and SAR imagery[J]. *Remote Sensing of Environment*, 222: 119-132.
- 7 346 Krizhevsky, A., Sutskever, I., Hinton, G.E.,2012. Imagenet classification with deep convolutional neural networks[J].
8 347 *Advances in neural information processing systems*, 2012, 25: 1097-1105.
- 9 348 Li, N., Dong, X.F., Gan, F.P., et al., 2021.Application of hyperspectral remote sensing technology to regional
10 349 geological survey and mapping in bedrock area. *Geological Bulletin of China*,40(01):13-21.
- 11 350 Li, P., Li, Z., Dai, K., et al.,2021. Reconstruction and Evaluation of DEMs from Bistatic TanDEM-X SAR in
12 351 Mountainous and Coastal Areas of China[J]. *IEEE Journal of Selected Topics in Applied Earth Observations*
13 352 *and Remote Sensing*, 14: 5152-5170.
- 14 353 Liu L, Zhou J, Jiang D, et al, 2014. Lithological Discrimination of the Mafic-Ultramafic Complex, Huitongshan,
15 354 Beishan, China: Using ASTER Data[J]. *Journal of Earth Science*, 25(3): 529-536.
- 16 355 Liu X, Zhao C, Zhang Q, et al.,2021, Integration of Sentinel-1 and ALOS/PALSAR-2 SAR datasets for mapping
17 356 active landslides along the Jinsha River corridor, China[J]. *Engineering Geology*, 284: 106033.
- 18 357 Liu F, Jiao L, Tang X,2019, Task-oriented GAN for PolSAR image classification and clustering[J]. *IEEE*
19 358 *transactions on neural networks and learning systems*,30(9): 2707-2719.
- 20 359 Liu, J., Zhang, Q.J., 2018.GF-3 Satellite and Its Application. *Satellite Application*,(06):12-16.
- 21 360 Lu, Y., Yang, C., Meng, Z.,2021. Lithology Discrimination Using Sentinel-1 Dual-Pol Data and SRTM Data[J].
22 361 *Remote Sensing*, 13(7): 1280.
- 23 362 Pei, J.F., Huo, W.B., Wang, C.W., et al., 2021. Multiview Deep Feature Learning Network for SAR Automatic
24 363 Target Recognition[J]. *Remote Sensing*,13(8).
- 25 364 Sekandari, M., Masoumi, I., Pour, A. B., et al.,2021. ASTER and WorldView-3 satellite data for mapping lithology
26 365 and alteration minerals associated with Pb-Zn mineralization[J]. *Geocarto International*: 1-31.
- 27 366 Saepuloh, A., Bakker, E., Suminar, W.,2017. The significance of SAR remote sensing in volcano-geology for hazard
28 367 and resource potential mapping[C]//AIP Conference Proceedings. AIP Publishing LLC,1857(1): 070005.
- 29 368 Simonyan, K., Zisserman, A.,2014. Very deep convolutional networks for large-scale image recognition[J]. arXiv
30 369 preprint arXiv:1409.1556, 2014.
- 31 370 Shi, X, G., Xu, J, H., Jiang, H, J., Zhang, L., Liao, M, S., 2021.Slope Stability State Monitoring and Updating of
32 371 The Outang Landside, Three Gorges Area Time Series InSAR Analysis. *Earth Science*, 44(12):4284-4292.
- 33 372 Wang, R.S., Gan, F.P., Chen, W., et al.,2011. Research on remote sensing geological exploration technology and
34 373 Application. *Acta Geologica Sinica*, Doi: 11-1951/P.20111025.0834.009.
- 35 374 Wang, R.S., 2008.On the development strategy of remote sensing technology in geology. *Remote Sensing for Natural*
36 375 *Resources*, (1):13. Doi:JournalArticle/5aeb74a7c095d709440998ab.
- 37 376 Wang, X.S., Chen, E.X., Li, Z.Y., et al., 2015.Multi-temporal and Dual-polarization interferometric SAR for Land
38 377 Cover Type Classification. *Acta Geodaetica et Cartographica Sinica*, 44(05):533-540.Doi:
39 378 10.11947/j.AGCS.2015.20130244.
- 40 379 Wang, W., Ren, X., Zhang, Y., et al.,2018. Deep learning based lithology classification using dual-frequency Pol-
41 380 SAR data[J]. *Applied Sciences*, 8(9): 1513.
- 42 381 Xia, W.H., X, H., 2021.Study on Geological Hazards in Mining Areas Based on D-InSAR Technology. *Geomatics*
43 382 *& Spatial Information Technology*, 44(02):125-129+134.Doi: 10.3969/j.issn.1672-0504.2018.05.006
- 44 383 Xie, M., Zhang, Q., Chen, S., et al.,2015. A lithological classification method from fully polarimetric SAR data
45 384 using Cloude-Pottier decomposition and SVM[C]//AOPC 2015: Optical and Optoelectronic Sensing and
46 385 Imaging Technology. *International Society for Optics and Photonics*, 9674: 967405.
- 47
48
49
50
51
52
53
54
55
56
57
58
59
60

- 386 Yu, Y.F., Yang, J.Z., Chen, S.B., et al., 2015.Lithologic Classification from Remote sensing Images Based on
387 Spectral Index. *Earth Science*,40(08):1415-1419.Doi: 10.3799/dqkx.2015.127.
- 388 Yu, X.C., Zhou, X., Kang, Z.J., et al., 2012.Hierarchical Classification of Rock and Soil Based Characteristic Multi-
389 Band Image. *Journal of Jilin University(Earth Science Edition)*, 42(06):1825-1833.Doi:
390 10.13278/j.cnki.jjuese.2012.06.039
- 391 Yang, T., Gong, H.L., Li, X.J., et al., 2010.Application of SAR to remote sensing of geological disasters. *Journal of*
392 *Natural Disasters*, 19(05):42-48. Doi: CNKI: SUN: ZRZH.0.2010-05-007.
- 393 Yuan, W., Yan, M., Liu, S.,2016. Application of radar and optical remote sensing data in lithologic classification
394 and identification[C]//2016 *IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*. *IEEE*:
395 6370-6373.
- 396 Zhang, W., Li, Y.Y., Zhang, T.L., et al., 2019.Remote Sensing interpretation of Landslide Geological Hazards in
397 High Vegetation Coverage Area Based on Hazard Sensitivity Analysis. *Safety and Environmental*
398 *Engineering*,26(03):28-35. Doi: CNKI: SUN: KTAQ.0.2019-03-005
- 399 Zhang, B., 2018.Remotely Sensed Big Data Era and Intelligent Information Extraction. *Geomatics and Information*
400 *Science of Wuhan University*, (1):13. Doi: 10.13203/j. whugis20180172
- 401 Zheng, S., Fu, B.H.2013.Lithological mapping of granitoids in the western Junggar from ASTER SWIR-TIR
402 multispectral data: Case study in Karamay pluton, xinjiang. *Acta Petrologica Sinica*,29(08):2936-2948.
- 403 Zhang, W., Lin, J., Chen, L., et al., 2014.Geological information Extraction Using Polarimetric SAR Based on
404 Polarization Decomposition. *Remote Sensing Information*,29(01):10-14.Doi: 10.3969/j.issn.1000-
405 3177.2014.01.003
- 406 Zhang, Z., Wang, H., Feng, X., et al.,2017. Complex-Valued Convolutional Neural Network and Its Application in
407 Polarimetric SAR Image Classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, PP(12):1-
408 12.
- 409 Zhuo, G, C., Dai, K, r., Zhou, F, J., Shen, Y., Xu, C., Xu, Q., 2021.Monitoring Typical Construction Sites of
410 SiChuan-Tibet Railway by InSAR and intensive Distortion Analysis[J].*Earth Science*,1-25[2022-01-
411 09].<http://kns.cnki.net/kcms/detail/42.1874.P.20211223.1149.012.html>.

412 附中文参考文献

- 413 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[J].地
414 理与地理信息科学, 34(05):31-36+2.
- 415 程三友, 陈静, 林海星, 等, 2021.高分辨率遥感图像几何精校正高山峡谷区 1:5 万地质填图中的应用[J].
416 地质通报, 40(04):520-526.
- 417 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[J].遥感学报, 24(04):454-464.
- 418 付光明, 严加永, 张昆, 等, 2017.岩性识别技术现状与进展[J].地球物理学进展, 32(01):26-40.
- 419 王润生, 2008.遥感地质技术发展的战略思考[J]. 国土资源遥感, (1):13.
- 420 王润生, 熊盛青, 聂洪峰, 等, 2011.遥感地质勘查技术与应用研究[J].地质学报, 85(11):1699-1743.
- 421 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[J].测绘学报,
422 44(05):533-540.
- 423 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[J].地质通报,
424 40(01):13-21.
- 425 刘杰, 张庆君. 高分三号卫星及应用概况[J]. 卫星应用, 2018(06):12-16.
- 426 史绪国, 徐金虎, 蒋厚军, 张路, 廖明生. 时序InSAR技术三峡库区藕塘滑坡稳定性监测与状态更新 [J]. 地
427 球科学, 2019,44(12):4284-4292.
- 428 夏伟华, 徐涵.2021.基于 D-InSAR 技术的矿区地质灾害研究[J].测绘与空间地理信息, 44(02):125-129+134.

- 1
2
3 429 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[J].地球科学(中国地质大学学报),
4 430 40(08):1415-1419.
5
6 431 余先川, 周鑫, 康增基, 等, 2012.一种基于多特征波段岩土层次分类方法[J].吉林大学学报(地球科学版),
7 432 42(06):1825-1833.
8
9 433 杨涛, 宫辉力, 李小娟, 等, 2010.成像雷达遥感地质灾害应用[J].自然灾害学报, 19(05):42-48.
10 434 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[J].遥感信息,
11 435 29(01):10-14.
12 436 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[J].安全与
13 437 环境工程, 26(03):28-35.
14 438 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[J].地球科学, 2020,
15 439 45(5): 1844-1854.
16 440 张兵, 2018.遥感大数据时代与智能信息提取[J].武汉大学学报(信息科学版), 43(12):1861-1871.
17 441 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
18 442 拉玛依岩体为例[J].岩石学报, 29(08):2936-2948.
19 443 卓冠晨, 戴可人, 周福军, 沈月, 陈晨, 许强.川藏铁路典型工点 InSAR 监测及几何畸变精细判识[J/OL].
20 444 地球科学: 1-25[2022-01-09].
21
22
23
24 445
25 446
26
27
28
29
30
31
32
33
34
35
36
37
38
39
40
41
42
43
44
45
46
47
48
49
50
51
52
53
54
55
56
57
58
59
60