

基于陆探一号卫星双极化观测的全极化 SAR 数据重构

孙维东¹, 杜欣玲¹, 杨杰¹, 史磊¹, 黎旻懿², 赵伶俐³, 胡成⁴

1. 武汉大学 测绘遥感信息工程国家重点实验室, 武汉 430079;

2. 德清城市数据经营管理有限公司, 湖州 313200;

3. 武汉大学 遥感信息工程学院, 武汉 430079;

4. 中国人民解放军空军指挥学院, 北京 100097

摘要: 陆地探测一号 (LT-1) 01 组 A/B 双星作为中国首个民用 L 波段分布式合成孔径雷达 (SAR) 卫星系统, 有望进一步推动中国雷达数据产品的应用普及化。LT-1 主要支持的双极化模式能够保持高分辨率和大幅宽成像, 然而与全极化观测系统相比, LT-1 缺失了部分极化信息, 不利于土地精细分类等应用。因此, 本文面向 LT-1 常用的两种双极化组合, 设计了多头多分支卷积神经网络及损失函数, 旨在以双极化数据输入复原缺失的极化信息, 从而实现 LT-1 全极化 SAR 数据重构。考虑到极化、空间特征互补性与幅度、相位数据特性差异, 本文采用不同分支网络分别提取像元级的极化信息和局部感知野内的空间信息, 并通过两个输出头独立预测幅度、相位值以降低输出阶段数据间的串扰风险, 同时提出了顾及相位周期性的幅度/相位组合损失作为优化目标指导重构网络训练。基于 LT-1 在英国城镇区域获取的两景全极化影像, 对本文方法进行了重构质量和地物分类实验验证。验证结果表明, 本文方法的幅度项预测误差为 1—2 dB、相位项预测误差低于 0.5 rad, 优于参数规模相当的 UNet 模型重构精度, 且重构数据与真实数据的统计分布和极化分解效果基本一致, 全极化信息得以良好保持; 与利用真实双极化、真实全极化数据的分类结果相比, 利用本文方法生成重构全极化数据后再进行地物分类, 总体精度与后者相当且比前者提高了约 5%。本文初步验证了利用 LT-1 双极化数据兼顾高分辨率、大幅宽、全极化的可行性, 可为 SAR 土地覆盖/利用分类等应用提供更为丰富的输入信息。

关键词: 合成孔径雷达, 陆地探测一号, 双极化, 全极化, 卷积神经网络, 土地分类

中图分类号: TP701/P2

引用格式: 孙维东, 杜欣玲, 杨杰, 史磊, 黎旻懿, 赵伶俐, 胡成. 2025. 基于陆探一号卫星双极化观测的全极化 SAR 数据重构. 遥感学报, 29(11): 3109–3123

Sun W D, Du X L, Yang J, Shi L, Li M Y, Zhao L L and Hu C. 2025. Reconstruction of full-polarimetric SAR data based on dual-polarimetric observations from the LT-1 satellite. National Remote Sensing Bulletin, 29(11): 3109–3123 [DOI:10.11834/jrs.20254327]

1 引言

合成孔径雷达 SAR (Synthetic Aperture Radar) 作为一种主动成像系统, 通过发射和接收微波波段的电磁波获取地物后向散射信息 (邓云凯等, 2012; 朱良等, 2009)。微波对于云层和雨雾具有一定穿透性, 且主动成像过程并不依赖光照条件,

因此 SAR 具备全天时、全天候的对地观测优势 (Moreira 等, 2013), 在土地分类 (Liu 等, 2019)、目标检测 (Wang 和 Liu, 2015; Zhang 等, 2019)、变化监测 (公茂果等, 2016)、地表参数反演 (高峰等, 2001) 等众多领域均有巨大的应用潜力。极化是电磁波的固有属性, SAR 收发电磁波的极化状态组合不同, 地物的后向散射行为也会发生

收稿日期: 2024-07-30; 预印本: 2025-05-13

基金项目: 国家重点研发计划 (编号: 2022YFB3903605); 国家自然科学基金 (编号: U22A2010, 42071295, 62471337, 42171442, U2033216); 深圳市基础研发计划 (编号: JCYJ20200109150833977); 自然资源部国土卫星遥感应用重点实验室开放基金 (编号: KLSMNR-202110); 资源与环境信息系统国家重点实验室开放基金; 中央高校基本科研业务费专项资金

第一作者简介: 孙维东, 研究方向为合成孔径雷达图像处理。E-mail: widensun2012@whu.edu.cn

通信作者简介: 杨杰, 研究方向为极化 SAR 图像解译。E-mail: yangj@whu.edu.cn

相应变化。一般而言,使用更多的极化状态会更有助于提高对地物散射特性的刻画能力,进而改善土地分类等应用的精度表现,但这需要以牺牲SAR影像的空间分辨率和成像幅宽为代价(Souyris等,2005)。常用的SAR极化模式包括单极化、双极化、全极化(Lee和Pottier,2009),极化信息依次增多,但全极化影像的分辨率和幅宽仅为单极化、双极化影像的一半。高分、宽幅、全极化三者难以兼顾,双极化SAR相对而言已是在保持高分辨率和大幅宽的前提下,保障极化信息丰富度的最佳选择。

由一型两星构成的中国首个民用L波段SAR组网卫星陆探一号(LuTan-1,LT-1),分别于2022年1月26日(A星)和2022年2月27日(B星)发射升空(李永生等,2024),进一步提升了中国SAR遥感卫星技术水平和国际竞争力。虽然LT-1支持全极化观测模式,然而实践中所用LT-1数据往往以单/双极化为主。其原因一方面在于LT-1主要为干涉测量应用服务(Mou等,2024),极化测量次之;另一方面,全极化模式影响成像范围和空间细节保持,不利于应急监测且损失了高分影像可以提供的地物精细轮廓和结构信息(李铭典等,2024)。近年来,随着紧缩极化理论的出现和发展,利用紧缩极化数据重构全极化数据成为了雷达遥感领域的前沿方向之一,这也为解决前述问题提供了可参考的技术途径:如能采用双极化SAR数据重构恢复出全极化信息,即可同时满足对成像范围、空间细节、极化信息的更高需求,促进LT-1数据应用潜力的进一步释放。

最初,以紧缩极化重构全极化的研究聚焦于单纯应用极化先验知识和理论假设进行数学求解,如Souyris等(2005)提出了在 $\pi/4$ 紧缩极化模式下的全极化重构方法:首先引入反射对称性假设减少极化协方差矩阵中的未知量总数,随后建立基于同极化相干系数迭代求解交叉极化项的方程,最后利用求得的交叉极化项解其余未知量;Nord等(2009)对该方法进行了改进,但增加了计算复杂度且不适用于海洋场景;后续又有Yue等(2017)和Yin等(2019)各自针对不同的紧缩极化模式提出了Wishart贝叶斯和最小二乘估计重构方法。目前,深度学习模型被广泛引入到SAR图像解译工作中(Chen和Tao,2018;王俊等,2018;Dong等,2020),其中也包括全极化重构,

如用于提高交叉极化项求解效率的全卷积网络QPRFCN(Gu等,2020)以及采用复数网络实现重构的CV-DBCNN(Zhang等,2022)。

紧缩极化数据中耦合了全极化信息,因此全极化重构主要表现为从已知量中提取未知分量的解耦任务;而单/双极化数据是全极化数据的子集,此时重构主要表现为基于已知量估计未知量的预测任务。这一本质区别使得上述方法不再适用。虽然近期出现了一些利用单/双极化重构全极化数据幅度、相位的研究(Song等,2018;Aghababaei等,2023),总体来看相关工作仍处于初步阶段。

综上,为达到兼顾高分辨率、大幅宽、全极化观测优势的目的,本文以LT-1双极化数据为研究对象,设计了顾及极化、空间特征互补性的多头多分支卷积神经网络,并以考虑幅度、相位特性差异的组合损失作为优化目标引导网络训练,以期复原缺失的极化通道信息,利用双极化数据实现LT-1全极化SAR数据重构。最终,通过重构数据提供更为丰富的输入信息,从上游数据出发改善土地覆盖/利用分类等应用成效。

2 研究方法

2.1 全极化及双极化数据形式

2.1.1 全极化SAR数据

以H和V分别代表水平、垂直线极化态电磁波。LT-1双极化模式主要包括H发射、H和V同时接收的HH+HV双极化,以及V发射、H和V同时接收的VV+VH双极化两种组合;全极化模式则既有H、V发射,又有H、V接收,形成HH+HV+VH+VV共4个极化通道,相当于两种双极化数据共存。

下文以 S_{HV} 表示HV通道(发射H极化波、接收V极化波)复散射系数,其他通道同理。每个像元的全极化信息可用包含 S_{HH} 、 S_{HV} 、 S_{VH} 和 S_{VV} 的复散射矢量表征。根据互易性定理令交叉极化项相等,即 $S_{HV}=S_{VH}$,可简化散射矢量,再将其与自身的共轭转置相乘后进行集合平均,得到全极化协方差矩阵(Lee和Pottier,2009)如下:

$$\mathbf{C}_F = \begin{bmatrix} \langle |S_{HH}|^2 \rangle & \sqrt{2} \langle S_{HH} S_{HV}^* \rangle & \langle S_{HH} S_{VV}^* \rangle \\ \sqrt{2} \langle S_{HV} S_{HH}^* \rangle & 2 \langle |S_{HV}|^2 \rangle & \sqrt{2} \langle S_{HV} S_{VV}^* \rangle \\ \langle S_{VV} S_{HH}^* \rangle & \sqrt{2} \langle S_{VV} S_{HV}^* \rangle & \langle |S_{VV}|^2 \rangle \end{bmatrix} \quad (1)$$

式中, $\mathbf{C}_F$ 代表全极化模式下的协方差矩阵; $\langle \cdot \rangle$ 表

示空间集合平均，上标*表示复数共轭运算。 C_F 对角线元素为实数，非对角线元素为复数，因其为 Hermitian 矩阵，矩阵中共包含 9 个实数变量。

鉴于 C_F 元素的幅度和相位含有极化通道间的相关性和相位差信息，相比实部、虚部更具物理意义，本文将该矩阵上三角元素的幅度和相位值，作为全极化重构的目标。

2.1.2 双极化 SAR 数据

采用与前类似的过程，可得 HH+HV、VV+VH 双极化协方差矩阵如下：

$$C_{DH} = \begin{bmatrix} \langle |S_{HH}|^2 \rangle & \langle S_{HH} S_{HV}^* \rangle \\ \langle S_{HV} S_{HH}^* \rangle & \langle |S_{HV}|^2 \rangle \end{bmatrix} \quad (2)$$

$$C_{DV} = \begin{bmatrix} \langle |S_{VV}|^2 \rangle & \langle S_{VV} S_{VH}^* \rangle \\ \langle S_{VH} S_{VV}^* \rangle & \langle |S_{VH}|^2 \rangle \end{bmatrix} \quad (3)$$

式中， C_{DH} 和 C_{DV} 为相应模式下得到的协方差矩阵，各含 4 个实数变量，且这些变量同样出现在前述 C_F 的 9 个变量中。唯一的区别在于交叉极化相关变量的系数在双极化、全极化协方差矩阵中有所不同。本文将双极化协方差矩阵的上三角元素幅度和相位值，作为全极化重构的数据输入。

2.2 多头多分支卷积神经网络重构模型

本部分构建用于全极化重构的卷积神经网络。以下分别介绍网络的输入、输出和网络结构。

2.2.1 输入及输出数据

在互易条件下， C_F 的 4 个变量可从 C_{DH} 和 C_{DV} 直接得到，剩余 5 个变量需要在全极化重构时求解。为了进一步降低未知量个数，本文采用重构研究中广泛使用的反射对称性假设 (Souyris 等, 2005)，认为在地表大部分场景下，尤其是自然地物覆盖区域，全极化重构数据中同极化与交叉极化通道不相关。

采用该假设时，全极化协方差矩阵简化为如式 (4) 所示的形式，待求变量总数会进一步减少：对于 HH+HV 双极化而言，其全极化重构过程的输入数据为 C_{DH} 中全部幅度和相位，即其第 1 行第 1 列、第 1 行第 2 列、第 2 行第 2 列元素的幅度及第 1 行第 2 列元素的相位，以下分别记为 A_{DH11} 、 A_{DH12} 、 A_{DH22} 、 φ_{DH12} ；输出的预测数据是 C_F 中第 1 行第 3 列、第 3 行第 3 列元素的幅度及第 1 行第 3 列元

素的相位，分别记为 A_{F13} 、 A_{F33} 、 φ_{F13} 。对于 VV+VH 双极化，重构过程的输入为 C_{DV} 中全部幅度、相位，按上述规律记为 A_{DV11} 、 A_{DV12} 、 A_{DV22} 、 φ_{DV12} ；输出是 C_F 中第 1 行第 1 列元素的幅度和第 1 行第 3 列元素的幅度与相位，分别记为 A_{F11} 、 A_{F13} 、 φ_{F13} 。本文所用幅度值的单位为分贝 (dB)，相位值的单位为弧度 (rad)。后续分别使用两种 LT-1 双极化数据和相应的全极化数据，训练结构相同的两个网络模型，实现不同双极化模式下的全极化重构。

$$C_F = \begin{bmatrix} \langle |S_{HH}|^2 \rangle & 0 & \langle S_{HH} S_{VV}^* \rangle \\ 0 & 2\langle |S_{HV}|^2 \rangle & 0 \\ \langle S_{VV} S_{HH}^* \rangle & 0 & \langle |S_{VV}|^2 \rangle \end{bmatrix} \quad (4)$$

2.2.2 网络结构

卷积神经网络作为深度学习的重要分支之一，特别适用于图像处理任务，在全极化重构方面也已取得一定效果。针对前述输入、输出数据特点，本文构建多头多分支卷积网络实现 LT-1 全极化重构，网络结构如图 1 所示。该网络包括空间上下文提取、极化信息提取 2 个分支，幅度值预测、相位值预测两个回归输出头，以及 1 个融合模块组。每个部分由不同尺寸的卷积模块组成，每个卷积模块串联了卷积层、批归一化层和指数线性单元 ELU (Exponential Linear Unit) 激活层。图中的加号图标代表将其输入按特征维进行拼接；各卷积模块均在图中标有其卷积核的空间尺寸和输出特征图通道数。

双极化 SAR 数据输入后，首先并行地经过极化信息提取和空间上下文提取两个分支。前者只使用 1×1 卷积，因此该分支的作用是从各像元自身的原始极化信息逐层非线性提取新的极化特征表达，聚焦于充分挖掘极化信息；后者使用若干 3×3 卷积不断扩大感知野，聚焦于学习空间上下文信息以弥补全极化信息缺失的不足。该处理与 Zhang 等 (2022) 的思路类似。融合模块组结合以上两个侧重点不同的分支输出，综合极化、空间信息提取关键特征。最后由两个回归头分别输出幅度项和相位项的预测结果，再联合原始双极化数据形成全极化重构结果。

需要说明的是，幅度和相位的物理意义不同，且相位值具有幅度不具备的周期性，因而采用多头输出机制以便网络可以对二者在输出前进行独

立处理,降低相互干扰程度。此外,在输出回归头的输入中又一次加入了极化信息提取分支的输出特征图。这是为了防止随着网络层数加深,空

间上下文信息淹没像元自身极化信息导致的像元间信息严重串扰问题。




图1 多头多分支全极化重构网络结构

Fig. 1 Multi-head multi-branch network structure

2.3 多通道幅度/相位联合损失函数

幅度值是不小于0且无明确上界的浮点数,而相位值是取值在 $\pm\pi$ 之间且存在周期性的角度。在设计多头网络之外,还需要在优化目标上考虑两者之间的区别。因此,本文设计了多通道幅度/相位联合损失函数。对于两种LT-1双极化模式,网络的输出均为两个幅度项和1个相位项,故该损失函数由3个子函数之和构建。

前两个子函数为幅度损失,对应于幅度回归头输出的两个幅度通道,均采用深度学习中常用的 l_1 损失函数计算网络输出的预测值与真实幅度值之间的差距,计算公式如下:

$$\text{loss}_{A_1} = (1/n) \sum_{i=1}^n |A_{1i} - \hat{A}_{1i}| \quad (5)$$

$$\text{loss}_{A_2} = (1/n) \sum_{i=1}^n |A_{2i} - \hat{A}_{2i}| \quad (6)$$

式中, A_{1i} 和 $\hat{A}_{1i}$ 表示某像元处第一个幅度通道预测结果和相应真实值, A_{2i} 和 $\hat{A}_{2i}$ 同理; n 为1个训练批次的全部像元总数。

最后一个子函数为相位损失。周期性特点使

相位值存在整周跳变。当相位预测结果与真实值分别处于跳变临界值 $\pm\pi$ 两侧时,虽然二者数值差异较大,但对极化协方差矩阵的影响相近,因而直接使用常规的损失函数指导训练过程并不适合。面向这一情况,本部分首先双向旋转真实相位值,并取旋转前后与相位预测结果差异最小的相位值作为实际参考,引导网络优化。此时相位损失可表达为

$$\text{loss}(\varphi) = (1/n) \sum_{i=1}^n \text{Min}(|\varphi_i - \hat{\varphi}_i|, |\varphi_i - \hat{\varphi}_i + 2\pi|, |\varphi_i - \hat{\varphi}_i - 2\pi|) \quad (7)$$

式中, φ_i 和 $\hat{\varphi}_i$ 分别为相位通道预测结果和相应真实值。该损失能够更准确地捕捉相位差异。

3 实验设计与结果分析

3.1 实验数据简介

为探索LT-1全极化数据重构的可行性同时验证本文方法效果,搜集了LT-1在国内外多个区域获取的11景全极化观测影像,其中的9景用于训

练，两景用于测试。成像区域涵盖中国、巴西、捷克、英国等多国城镇及周边地区，区域包含林地、耕地、水体、建筑区、裸土等多种地物类型。数据基本信息以及训练、测试数据划分情况如表 1

表 1 数据集参数信息
Table 1 Dataset parameter information

序号	地区	数据集类型	地物类型	入射角/(°)	景号
1	以色列	训练集	林地、裸土、水体、建筑区	27.67	364297
2	中国湖南省	训练集	耕地、水体、建筑区、林地	16.57	2818
3	巴西	训练集	热带雨林	39.81	43914
4	捷克	训练集	林地、裸土	14.65	59684
5	中国吉林省	训练集	山体、建筑区、林地、耕地、水体	36.75	97116
6	以色列	训练集	农田、林地、建筑区	28.96	190168
7	中国青海省	训练集	山体、建筑区	34.92	3126
8	中国北京市	训练集	林地、建筑区、裸土	39.79	112184
9	中国天津市、河北省一带	训练集	农田、建筑区、水体	33.50	22236
10	英国	测试集	耕地、建筑区、林地、裸土	29.00	354463
11	英国	测试集	耕地、林地、建筑区、水体	27.04	358043

3.2 实验设置

每景 LT-1 全极化影像经笔者提出的定标方法 (Shi 等, 2021, 2023; 史磊 等, 2021, 2025) 验证、处理后, 再使用 PolSARPro v4.2.0 软件完成多视、极化协方差矩阵生成等预处理; 随后按 50% 的相邻切片重叠率, 将影像划分成 16 像素×16 像素大小的图像切片。最终, 9 景训练影像形成训练切片 165550 个, 2 景测试影像形成测试切片 30226 个。实验中根据双极化模式的不同, 按 2.2 小节描述, 从切片抽取相应数据的幅度、相位作为输入和真值数据。

提出的重构网络在 Pytorch 深度学习框架下构建、训练和使用, 计算环境包括: 中央处理器型号 E5-2678, 运行内存 64 GB, 图形处理器为英伟达 GeForce RTX 2080Ti (显存容量 11 GB), 以及 64 位 Windows 10 专业版操作系统。训练阶段采用 Adam 优化器迭代更新网络参数, 学习率固定为 0.001, 以 128 个切片作为批处理量, 共完成 50 轮训练。测试阶段先逐切片进行网络预测, 随后拼接成整景全极化重构数据, 再开展精度测试和效果验证。由于幅度数据动态范围较大, 在网络使用前均做 Z 分数标准化预处理, 其均值和标准差参数统一从训练集统计得到; 而相位数据动态范围较小, 且计算相位损失时需要保证其取值范围不

所示。实验所用影像的地区、时间、地表覆盖条件多样, 且测试集成像区域在训练集中并未出现过, 以此保证测试结果的客观性和合理性。

变, 因此未做标准化预处理。

后续实验分为两部分: (1) LT-1 全极化重构效果验证, 主要从网络预测结果和全极化信息保持效果等方面分析重构质量; (2) LT-1 全极化重构数据分类测试, 主要以土地分类作为典型应用, 评估全极化重构数据的利用潜力。虽然目前全极化重构研究通常仅关注重构精度, 但考虑到重构环节属于 SAR 数据处理链的中间节点, 有必要通过下游应用效果, 证明增益极化信息的优势。

对于分类测试实验, 本文基于测试影像的地物类型真值图, 采用随机采样和人工勾绘感兴趣区 ROI (Region of Interest) 两种方式建立有监督分类训练像元集。然后利用随机森林 RF (Random Forest) 分类器对剩余像元样本进行地物分类, 并以总体分类精度 OA (Overall Accuracy)、Kappa 一致性系数评价分类表现。RF 的决策树数量统一设置为 100, 分裂节点抽取的特征子集维度设置为特征总数的平方根并向上取整。随机采样方式在空间上随机取每类 1000 个像元样本作为训练集, 重复采样、训练、测试这一过程 10 次, 取精度指标平均值对比真实全极化数据、两种双极化数据及其重构结果的地物鉴别能力。勾绘 ROI 方式则人工为每类地物框选 3 个 ROI 区域, 区域内的像元作为训练样本, 进行分类器训练、测试。经统计,

ROI采集样本数平均每类 1000—1200 个像元，与随机采集的样本数基本一致。两景测试数据下文简称为数据一（景号 354463）、数据二（景号 358043），其PauliRGB图像与各类别的ROI样本区位置如图2所示。

这两种方式的区别在于：随机采样选取的训练样本多样性更强，训练和测试数据也更接近独立同分布假设，因此能在较理想的条件下摸底分类性能；勾绘 ROI 选取的样本仅来源于若干局部区域，训练数据多样性较差且与测试数据分布差异更大，但这种方式更接近于实际应用的操作流程，可以更好地测试分类鲁棒性。

3.3 LT-1全极化重构效果验证

3.3.1 网络预测结果分析

图3展示了真实全极化数据（ FP_{Truth} ）、两种双极化数据（ DP_{HHHV} 和 DP_{VVVH} ）及其全极化重构数据（ FP_{HHHV} 和 FP_{VVVH} ）的伪彩色图像，全部使用 PolSARPro 软件生成。其中前两列展示的双极化伪彩色图的波段组合方式为，红波段：同极化幅度、绿波段：交叉极化幅度、蓝波段：同极化—交叉

极化相关项幅度；其余图像均为全极化 SAR 数据可视化最常用的 PauliRGB 伪彩色图。




图2 人工勾绘训练区位置
Fig. 2 Manually mark the locations of the training areas




图3 真实数据与重构数据伪彩色图像
Fig. 3 Pseudo color images of real and reconstruction data

由图3可见，相比于真实全极化数据 FP_{Truth} ，重构数据 FP_{HHHV} 和 FP_{VVVH} 大体上还原了全极化信息，

但在 PauliRGB 图像上部分区域存在一些色调偏差。由图3（b）中最右侧两张图像可见，无论在哪种

双极化模式下，重构影像中水体都表现出从蓝色到紫色的变化。其原因可能在于训练数据与测试数据间存在差异。当水面受风力等因素影响粗糙度增加时，同极化散射差异变强，导致 PauliRGB 红色通道分量升高使水体呈现紫色调，因此该现象在真实全极化数据上也会出现。训练数据中存在这种非平静水面的样本时就会造成这一问题。随着训练样本更加丰富，该问题将得到缓解。

为了定量评价重构精度，分别计算重构项网络预测值与真实值的平均绝对误差，结果见表2。可见幅度项重构误差整体处于1—2 dB，相位项重构误差处于20°—30°。参考星载SAR系统的辐射校正精度水平（0.6—1 dB），证明本文方法的幅度项重构效果良好；相比于通道间相位失衡水平（0.2°—10.0°），相位项的重构质量仍然有待提升。

值得一提的是，对比使用不同双极化数据的重构结果，图3中 $\mathbf{FP}_{HHHV}$ 目视效果优于 $\mathbf{FP}_{VVVH}$ ，但

表2表明 $\mathbf{FP}_{VVVH}$ 的重构误差整体上低于 $\mathbf{FP}_{HHHV}$ 。这一现象的原因在于 PolSARPro 生成伪彩色图像时，会根据数据值分布和动态范围自适应量化拉伸数据以增强对比度。结合下文图4可知， $\mathbf{C}_F$ 中变量的重构结果在统计分布和动态范围两方面均存在一定偏差，从而造成了图像各色彩通道灰度级量化结果的不确定性。

表2 全极化数据各通道重构误差

Table 2 The channel reconstruction errors of full-polarimetric data

采用的双极化模式	重构项	平均绝对误差	
		数据一	数据二
HH+HV	A_{F13}/dB	2.2330	1.4225
	A_{F33}/dB	1.4463	1.2678
	φ_{F13}/rad	0.4996	0.3889
VV+VH	A_{F11}/dB	1.2988	1.1914
	A_{F13}/dB	1.8109	1.2981
	φ_{F13}/rad	0.4983	0.3746




图4 真实数据与重构数据的概率密度曲线

Fig. 4 Probability density curves between real and reconstruction data

本研究采用核密度估计技术获得重构项和真实数据的概率密度曲线图，详见图4。可见：对于 $\mathbf{C}_F$ 对角线元素的幅度重构结果而言，无论是 $\mathbf{FP}_{HHHV}$ 中的 A_{F33} 还是 $\mathbf{FP}_{VVVH}$ 中的 A_{F11} ，概率密度曲线均与真实情况较为接近，只有图4（f）中展示的重构结果分布过于集中；非对角线元素的幅度 A_{F13} 和相位 φ_{F13} 在两种双极化数据输入条件下均需由网络预测输出，对比图4（c）和（g）发现，在数据一上


$\mathbf{FP}_{HHHV}$ 和 $\mathbf{FP}_{VVVH}$ 重构质量相似，但对于数据二， $\mathbf{FP}_{HHHV}$ 分布曲线与真实数据重合度明显更高。这一现象在一方面表明整体重构误差低并不等同于数据分布趋势偏差小，因此在评价全极化重构质量时需要从多方面综合考量；另一方面，这也是造成图3中数据二 $\mathbf{FP}_{VVVH}$ 的 PauliRGB 图像视觉效果较差的重要原因。至于图4（d）和（h）展示的 φ_{F13} 分布情况，不同双极化数据均未能取得与真实相

位数据高度接近的概率密度。这与前述定量分析结果一致,也说明相位项的精确预测是全极化数据重构技术面临的一大难题。

总体来看,本文提出的重构方法分别基于HH+HV、VV+VH双极化数据,均可得到较高质量的全极化SAR重构数据。但二者之间各有优劣:前者重构结果的统计分布更接近真实分布,后者重构误差更低,精确性更强。测试区域包含城区、水体、林地等地物类型,且空间分布错落。本文方法在高地表覆盖复杂性和空间异质性的条件下,取得了误差低于2 dB/0.5 rad的总体测试结果,表现出较好的泛化能力,证明了方法的有效性。


3.3.2 极化信息重构质量分析

为了进一步验证重构数据对极化信息的恢复情况,图5展示了两幅测试影像真实与重构全极化数据的极化分解结果,采用的分解方法为Freeman-Durden三分量分解(FD3)(Freeman和Durden, 1998),以及H/Alpha极化分解(Cloude和Pottier, 1996, 1997)。图5(a)和(b)为FD3分解的伪彩色图,波段组合方式为,红波段:偶次散射功率、绿波段:体散射功率、蓝波段:表面散射功率;图5(c)、(d)和(e)、(f)分别对应于H/Alpha分解得到的极化熵(H)和平均Alpha角。




(a) 数据一 FD3 分解

(a) FD3 decomposition of Data 1




(b) 数据二 FD3 分解

(b) FD3 decomposition of Data 2




(c) 数据一 H/Alpha 分解得到的极化熵(H)

(c) Entropy (H) obtained via H/Alpha decomposition of Data 1




(d) 数据二 H/Alpha 分解得到的极化熵(H)

(d) Entropy (H) obtained via H/Alpha decomposition of Data 2



(e) 数据一 H/Alpha 分解得到的平均 Alpha 角

(e) Average alpha obtained via H/Alpha decomposition of Data 1



(f) 数据二 H/Alpha 分解得到的平均 Alpha 角

(f) Average alpha obtained via H/Alpha decomposition of Data 2

图5 真实数据与重构数据FD3、H/Alpha极化分解结果对比

Fig. 5 FD3 and H/Alpha polarimetric decomposition results between real and reconstruction data

FD3将原始全极化数据分解为表面散射、二次散射和体散射3种基本散射类型;极化熵H代表着散射机制统计意义上的无序性;Alpha与散射过程也存在关联,其值从小到大分别对应从表面散射到偶极子散射,再到二面角散射的变化。因此,两种分解结果均能更直接地反映地物属性。由图5可见

测试影像场景较为复杂,既包括以表面散射为主的水体,也包含以体散射为主的森林以及散射机制较为混杂的城区。以图5第1、4列真实数据 FP_{Truth} 的分解结果为参考,其余列中重构数据 FP_{HHHV} 、 FP_{VVVH} 的分解结果与真实数据情况非常一致,在复杂场景下仍然能够较为准确地复原出全极化信息,

并且较好地保持了空间上的图像细节变化。

图5第2和第5列分别展示了数据一和数据二的HH+HV双极化的重构数据分解结果。可见：虽然整体分解结果较好，但在部分区域仍存在一定的散射成分估计偏差，例如图5（d）中数据二 FP_{HHHV} 的极化熵图像水体区域。图5第3列和第6列分别展示了VV+VH双极化的重构数据分解结果。可见： FP_{VVVH} 在地物相近的区域表现出相似的散射成分，对于林地、水体等覆盖区极化信息重构效果较好，但在图5（a）中，数据一 FP_{VVVH} 的FD3分解结果存在散射成分偏差较大的大面积耕地区域。

以上分析表明，本文提出的重构方法能够有效保持极化信息和散射成分。但使用不同双极化数据的极化信息复原实效，对于不同区域场景而言存在一定差异。综合上述重构数据的伪彩色图像、重构项误差及极化分解结果，全面证明了本文方法对于LT-1主要采用的双极化模式，能够有效捕捉地物散射特性，并基于有限的双极化信息

重构出完整全极化数据。在与训练集完全无关的测试集成像区域，实现了复杂地物覆盖类型下的高精度重构效果，也表明该方法具备较强的泛化能力。

3.3.3 重构模型对比分析

本文的网络模型主要由空间上下文提取分支、极化信息提取分支、融合模块组、幅度/相位多输出头几部分组成。为验证各组分作用，从完整网络中分别删除这些部分中的某一个但保留其他部分，以此构建4个不完整的网络；随后，在训练集、测试集、超参数设置等实验配置完全一致的前提下，训练它们并进行重构测试。每个模型在两景测试数据上的整体重构误差列于表3。完整网络在HH+HV、VV+VH这2种双极化模式下得到的共计6个重构项中，取得了3项最优（表中加粗数字）；即便是非最优的重构项，完整网络的重构误差也与表3相应项的最低值极为接近。可见完整网络的每个主要组成部分均有正向贡献。

表3 对比模型幅度及相位项重构误差

Table 3 Amplitude/phase reconstruction errors of comparison models

采用的双极化模式	重构项	平均绝对误差					
		完整网络	无空间分支	无极化分支	无融合模块	单一输出头	轻量UNet
HH+HV	A_{F13}/dB	1.825	2.187	1.853	1.883	1.822	2.064
	A_{F33}/dB	1.356	2.135	1.423	1.353	1.479	1.841
	φ_{F13}/rad	0.444	0.462	0.451	0.457	0.460	0.458
VV+VH	A_{F11}/dB	1.245	1.429	1.464	1.272	1.258	1.268
	A_{F13}/dB	1.553	1.637	1.795	1.659	1.539	1.552
	φ_{F13}/rad	0.436	0.464	0.462	0.443	0.458	0.460

注：黑体表示最优结果。

对比表3中无空间分支、无极化分支、无融合模块和仅采用单一输出头的4个网络发现：（1）分别删除空间上下文提取分支和极化信息提取分支后，重构精度在不同项上互有高低，且均差于完整网络，说明两个分支学习到的特征确实具有互补性；（2）去除融合模块组后，空间分支和极化分支输出的特征图将在拼接后直接作为多输出头部分的输入，导致两种特征图的信息融合不够充分，因此表3中完整网络的全部精度指标均优于或至少持平于无融合模块组的网络；（3）将多输出头替换为单输出头后，幅度、相位项在网络中会全程被统一处理，造成输出前的串扰影响，因而其大部分重构项误差显著高于完整网络。虽然采用单

输出头的网络对 A_{F13} 项的重构误差更低，但与完整网络差距不大。综合来看，使用多头结构以保障输出前幅度和相位的独立处理，是很有必要的。

此外，本文还参考UNet（Ronneberger等，2015）的网络架构，设计了一个符合常规卷积网络构建范式的模型，以开展另一组对比实验，称之为轻量级UNet。为保证公平性，需要使该网络模型与本文模型参数规模大体一致：本文模型可训练参数总量约21万；轻量级UNet完全采用UNet思想构建，但降采样次数从4次降为3次，首个卷积层仅输出16个通道的特征图，后续输出通道数按UNet原本的构建规律设置。由此轻量级UNet的可训练参数总量约27万，其实验配置同前，重构误差见

表3, 可见各项指标明显差于本文模型。

造成轻量级 UNet 表现欠佳的主要原因, 是这种先降采样再升采样的主流网络架构可能并不适合全极化重构任务。级联的多次降采样处理有利于扩大感知野以提取更高抽象层级的特征知识, 但是这也极大地加剧着近邻像元的信息串扰。本文构建的模型虽然也在空间上下文提取分支中引入了不同像元间的信息, 但极化信息提取分支的使用确保了重构任何像元的全极化数据时, 不会随网络层数的加深而丢失该像元自身的原有信息。2组对比实验均验证了本文重构模型设计的合理性和有效性。

3.4 LT-1全极化重构数据分类测试

3.4.1 随机采样方案测试结果


采用随机采样构建训练集, 基于RF分类器得到的地物分类精度如表4所示。可见: 直接利用真

实双极化数据 DP_{HHHV} 和 DP_{VVVH} 的分类表现无法与使用真实全极化数据 FP_{Truth} 相比, 大体存在 4%—5% 的 OA 指标差距, Kappa 指标差距甚至更大; 反观由 DP_{HHHV} 和 DP_{VVVH} 重构的全极化数据 FP_{HHHV} 和 FP_{VVVH} , 相应分类精度在 FP_{Truth} 精度上下浮动且指标差距较小。以上证实了即便是重构生成的伪全极化数据, 也可以像真实全极化数据一样给予分类器更丰富的极化信息, 提升实际应用效果。在本文实验中, 重构数据相较原始双极化数据, 能够提高约 5% 的总体分类精度和平均接近 0.07 的 Kappa 系数值, 对分类结果的改善效果显著。


使用不同数据作为 RF 输入时的分类结果见图 6。可见: FP_{Truth} 、 FP_{HHHV} 和 FP_{VVVH} 的分类结果更加干净且一致, 也更接近地物分布的真实情况; DP_{HHHV} 和 DP_{VVVH} 由于缺失了部分极化信息, 分类结果更不准确且呈现出更多的错分斑点, 该情况在图 6 (d) 中表现得尤为明显。

表 4 随机采样条件下地物分类精度评估表
Table 4 Evaluation of classification accuracy with random sampling


输入数据	数据一				数据二			
	OA/%	STD/%	Kappa	STD	OA/%	STD/%	Kappa	STD
DP_{HHHV}	75.17	0.26	0.5804	0.0043	75.47	0.29	0.6511	0.0033
DP_{VVVH}	75.78	0.21	0.5908	0.0033	74.63	0.37	0.6393	0.0043
FP_{Truth}	80.49	0.27	0.6695	0.0039	77.54	0.35	0.6796	0.0043
FP_{HHHV}	79.96	0.30	0.6618	0.0046	79.65	0.34	0.7093	0.0043
FP_{VVVH}	79.72	0.18	0.6569	0.0023	79.33	0.60	0.7041	0.0074



(a) 数据一地物分类结果及真值图
(a) Classification maps and ground truth of Data 1




(b) 图 6(a) 的局部放大图
(b) Partial enlarged detail of Fig. 6 (a)



(c) 数据二地物分类结果及真值图

(c) Classification maps and ground truth of Data 2



(d) 图 6(c)的局部放大图

(d) Partial enlarged details of Fig. 6 (c)




图 6 真实数据与重构数据地物分类结果(随机采样)

Fig. 6 Classification maps based on real and reconstruction data (random sampling)

需要说明的是，该实验旨在测试重构得到的全极化信息是否能够对地物分类应用产生增益。故分类器的输入特征即为各像元极化协方差矩阵元素的幅度、相位值，并未引入除极化信息之外的其他特征，如通过纹理参数提取获取空间上下文描述，或者采用卷积网络作为分类器以自适应学习空间特征表达。在仅利用极化信息的前提下，重构数据的分类精度即可达到 80% 左右，如能进一步提供更多的可用信息，分类效果将得到明显改善。考虑到本文的焦点在于探索 LT-1 全极化重构可行性，而上述联合多源特征改善分类效果的相关工作并不属于本文讨论范畴，此处不作展开讨论。

3.4.2 ROI 采样方案测试结果

采用图 2 (b)、(d) 所示 ROI 区域内的像元构建训练集，基于 RF 分类器得到的地物分类精度列于表 5，相应地物分类结果见图 7。图表内容组织方式同表 4 和图 6，唯一的区别是因为人工勾绘 ROI 效率较低，实验中仅勾绘了 1 次 ROI，因而无多次重复实验，故表 5 中没有精度指标的标准差可以提供。

如“3.2 实验设置”一节所述，相比于在空间上随机选取训练样本，ROI 选取方式更接近训练样本的真实获取途径。样本仅来源于若干局部区域令其多样性欠佳，导致分类难度相对更大，有利于测试分类鲁棒性。因此，表 5 展示的分类精度普

遍低于表 4，然而相对趋势没有发生变化： FP_{HHHV} 、 FP_{VVHH} 的分类精度在 FP_{Truth} 上下浮动； DP_{HHHV} 和 DP_{VVHH} 表现差于前三者，甚至对于部分分类结果，双极化数据与重构数据的精度差别进一步被拉大。例如，测试数据一 DP_{HHHV} 和 FP_{HHHV} 的 OA 值分别为 71.06% 与 77.88%，产生了近 7% 的差距，Kappa 系数之差同步扩大至约 0.12。这些情况再次证明了全极化重构对下游应用效果的改善作用；此外还表明，在比随机采样更为严苛和更接近真实训练样本生成条件时，全极化重构的优势会进一步凸显。

表 5 ROI 采样条件下地物分类精度评估表


Table 5 Evaluation of classification accuracy with ROI sampling

输入数据	数据一		数据二	
	OA/%	Kappa	OA/%	Kappa
DP_{HHHV}	71.06	0.5097	73.79	0.6217
DP_{VVHH}	72.75	0.5447	73.55	0.6174
FP_{Truth}	78.99	0.6473	75.61	0.6481
FP_{HHHV}	77.88	0.6275	77.92	0.6825
FP_{VVHH}	77.67	0.6246	77.00	0.6655


图 7 所示不同数据的分类结果同样与图 6 类似，真实全极化、重构全极化数据分类结果更加准确和干净；双极化数据由于部分极化通道缺失，分类结果更易受噪声等因素干扰，会更频繁地出现局部错分问题。综上所述，无论以何种采样方

式构建训练集, 重构数据分类效果都要明显优于直接使用双极化数据的效果。在两种双极化模式中, HH+HV 组合的 HH 通道对表面散射和粗糙度敏感, HV 通道对体散射敏感。这两种特性的结


合, 使得 HH+HV 组合在捕捉地表不同类型的散射机制上较为全面。这可能是其重构数据分类精度略优于 VH+VV 重构数据的原因, 但两者的差距非常微小。




(a) 数据一地物分类结果及真值图
(a) Classification maps and ground truth of Data 1



(b) 图 7(a) 的局部放大图
(b) Partial enlarged detail of Fig. 7 (a)



(c) 数据二地物分类结果及真值图
(c) Classification maps and ground truth of Data 2



(d) 图 7(c) 的局部放大图
(d) Partial enlarged detail of Fig. 7 (c)



图 7 真实数据与重构数据地物分类结果(ROI 采样)

Fig. 7 Classification maps based on real and reconstruction data (ROI sampling)

4 结 论

本研究为兼顾高分辨率、大幅宽、全极化观测优势, 面向 LT-1 卫星双极化模式数据特性, 提出多头多分支数据重构网络模型, 通过最小化多通道幅度/相位联合损失函数, 实现了 LT-1 全极化

SAR 信息重构, 并进行了重构质量、分类应用验证。主要结论如下:

(1) 本文提出的模型能够基于双极化数据输入有效重构全极化信息, 重构结果在精度、统计分布、极化分解效果各方面均与真实全极化数据相近, 且重构质量优于同等参数规模的 UNet 模型;

(2) 重构得到的全极化数据相比双极化数据能够提供更为丰富的极化信息, 可以显著提高土地分类精度, 证明本文提供的模型可为高分宽幅成像条件下的高精度地物解译应用提供优质的数据源;

(3) 与幅度项相比, 相位项的重构误差更大, 这会引起地物散射机制的畸变, 导致主导散射成分与实际情况之间存在一定差异。因此, 相位项仍需进一步提升重构质量。

鉴于极化SAR多通道之间的相位差是区分部分地物和识别特定弱散射目标的有力特征, 下一步工作将聚焦于提升相位数据重构精度。另外, 为了保障评估全极化信息对分类精度改善的客观性, 本文分类实验并未采用除极化协方差矩阵之外的其他特征作为输入, 如空间纹理; 也未使用卷积网络等可自适应挖掘空间信息的分类模型, 因此分类精度仍有很大的提升空间。后续也将联合重构数据的极化与空间特征, 开展地物分类性能改善的相关研究。

参考文献(References)

- Aghababaei H, Ferraioli G, Stein A and Vitale S. 2023. Deep-learning-based polarimetric data augmentation: Dual2Full-pol extension. *IEEE Transactions on Geoscience and Remote Sensing*, 61: 5213016 [DOI: 10.1109/TGRS.2023.3299419]
- Chen S W and Tao C S. 2018. PolSAR image classification using polarimetric-feature-driven deep convolutional neural network. *IEEE Geoscience and Remote Sensing Letters*, 15(4): 627-631 [DOI: 10.1109/LGRS.2018.2799877]
- Cloude S R and Pottier E. 1996. A review of target decomposition theorems in radar polarimetry. *IEEE Transactions on Geoscience and Remote Sensing*, 34(2): 498-518 [DOI: 10.1109/36.485127]
- Cloude S R and Pottier E. 1997. An entropy based classification scheme for land applications of polarimetric SAR. *IEEE Transactions on Geoscience and Remote Sensing*, 35(1): 68-78 [DOI: 10.1109/36.551935]
- Deng Y K, Zhao F J and Wang Y. 2012. Brief analysis on the development and application of spaceborne SAR. *Journal of Radars*, 1(1): 1-10 (邓云凯, 赵凤军, 王宇. 2012. 星载SAR技术的发展趋势及应用浅析. *雷达学报*, 1(1): 1-10) [DOI: 10.3724/SP.J.1300.2012.20015]
- Dong H W, Zou B, Zhang L M and Zhang S Y. 2020. Automatic design of CNNs via differentiable neural architecture search for PolSAR image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 58(9): 6362-6375 [DOI: 10.1109/TGRS.2020.2976694]
- Freeman A and Durden S L. 1998. A three-component scattering model for polarimetric SAR data. *IEEE Transactions on Geoscience and Remote Sensing*, 36(3): 963-973 [DOI: 10.1109/36.673687]
- Gao F, Wang J M, Sun C Q and Wen J. 2001. Advances in study on microwave remote sensing of soil moisture. *Remote Sensing Technology and Application*, 16(2): 97-102 (高峰, 王介民, 孙成权, 文军. 2001. 微波遥感土壤湿度研究进展. *遥感技术与应用*, 16(2): 97-102) [DOI: 10.3969/j.issn.1004-0323.2001.02.006]
- Gong M G, Su L Z, Li H and Liu J. 2016. A survey on change detection in synthetic aperture radar imagery. *Journal of Computer Research and Development*, 53(1): 123-137 (公茂果, 苏临之, 李豪, 刘嘉. 2016. 合成孔径雷达影像变化检测研究进展. *计算机研究与发展*, 53(1): 123-137) [DOI: 10.7544/issn1000-1239.2016.20150662]
- Gu F, Zhang H and Wang C. 2020. Quad-pol reconstruction from compact polarimetry using a fully convolutional network. *Remote Sensing Letters*, 11(4): 397-406 [DOI: 10.1080/2150704X.2020.1723169]
- Lee J S and Pottier E. 2009. *Polarimetric Radar Imaging: from Basics to Applications*. Boca Raton: CRC Press
- Li M D, Xiao S P and Chen S W. 2024. A review of progress in super-resolution reconstruction of polarimetric radar image target. *Journal of Electronics and Information Technology*, 46(5): 1806-1826 (李铭典, 肖顺平, 陈思伟. 2024. 极化雷达图像目标超分辨率重建研究进展. *电子与信息学报*, 46(5): 1806-1826) [DOI: 10.11999/JEIT231249]
- Li Y S, Li Q, Jiao Q S, Jiang W L, Li B Q, Zhang J F and Luo Y. 2024. Application of Lutan-I SAR satellite constellation to earthquake industry and its prospect. *Geomatics and Information Science of Wuhan University*, 49(10): 1741-1752 (李永生, 李强, 焦其松, 姜文亮, 李兵权, 张景发, 罗毅. 2024. 陆地探测一号SAR卫星星座在地震行业的应用与展望. *武汉大学学报(信息科学版)*, 49(10): 1741-1752) [DOI: 10.13203/j.whugis20230498]
- Liu X, Jiao L C, Tang X, Sun Q G and Zhang D. 2019. Polarimetric convolutional network for PolSAR image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 57(5): 3040-3054 [DOI: 10.1109/TGRS.2018.2879984]
- Moreira A, Prats-Iraola P, Younis M, Krieger G, Hajnsek I and Papathanassiou K P. 2013. A tutorial on synthetic aperture radar. *IEEE Geoscience and Remote Sensing Magazine*, 1(1): 6-43 [DOI: 10.1109/MGRS.2013.2248301]
- Mou J W, Wang Y, Hong J, Wang Y C, Wang A C, Sun S Y and Liu G K. 2024. Interferometric calibration model for the Lutan-I mission: enhancing digital elevation model accuracy. *Remote Sensing*, 16(13): 2306 [DOI: 10.3390/rs16132306]
- Nord M E, Ainsworth T L, Lee J S and Stacy N J S. 2009. Comparison of compact polarimetric synthetic aperture radar modes. *IEEE Transactions on Geoscience and Remote Sensing*, 47(1): 174-188 [DOI: 10.1109/TGRS.2008.2000925]

- Ronneberger O, Fischer P and Brox T. 2015. U-Net: convolutional networks for biomedical image segmentation//Proceedings of the 18th International Conference on Medical Image Computing and Computer-Assisted Intervention. Munich: Springer: 234-241 [DOI: 10.1007/978-3-319-24574-4_28]
- Shi L, Sun W D, Yang L, Yang J, Zhao L L, Li P X and Liu Y B. 2025. Evaluation of radiometric and polarimetric errors in the LT-1A satellite data based on tropical forests in the amazon. *Journal of Radars*, 14(2): 405-423 (史磊, 孙维东, 杨乐, 杨杰, 赵伶俐, 李平湘, 刘亚波. 2025. LT-1A 卫星全极化 SAR 辐射与极化系统误差稳定性分析: 以热带雨林场景为例. *雷达学报(中英文)*, 14(2): 405-423) [DOI: 10.12000/JR24102]
- Shi L, Yang J, Li P X, Yang L and Zhao L L. 2021. Research process of full-polarimetric SAR calibration without using corner reflectors. *National Remote Sensing Bulletin*, 25(11): 2211-2219 (史磊, 杨杰, 李平湘, 杨乐, 赵伶俐. 2021. 不依赖人工定标器的全极化 SAR 定标研究进展. *遥感学报*, 25(11): 2211-2219) [DOI: 10.11834/jrs.20219310]
- Shi L, Yang L, Sun W D, Yang J, Li P Z and Zhang L P. 2023. Amplitude-optimized UZH for polarimetric channel imbalance calibration in PolSAR data. *IEEE Transactions on Geoscience and Remote Sensing*, 61: 5217523 [DOI: 10.1109/TGRS.2023.3321046]
- Shi L, Yang L, Zhao L L, Li P X, Yang J and Zhang L P. 2021. NESZ estimation and calibration for Gaofen-3 polarimetric products by the minimum noise envelope estimator. *IEEE Transactions on Geoscience and Remote Sensing*, 59(9): 7517-7534 [DOI: 10.1109/TGRS.2020.3033534]
- Song Q, Xu F and Jin Y Q. 2018. Radar image colorization: converting single-polarization to fully polarimetric using deep neural networks. *IEEE Access*, 6: 1647-1661 [DOI: 10.1109/access.2017.2779875]
- Souyris J C, Imbo P, Fjortoft R, Mingot S and Lee J S. 2005. Compact polarimetry based on symmetry properties of geophysical media: the $\pi/4$ mode. *IEEE Transactions on Geoscience and Remote Sensing*, 43(3): 634-646 [DOI: 10.1109/TGRS.2004.842486]
- Wang J, Zheng T, Lei P and Wei S M. 2018. Study on deep learning in radar. *Journal of Radars*, 7(4): 395-411 (王俊, 郑彤, 雷鹏, 魏少明. 2018. 深度学习在雷达中的研究综述. *雷达学报*, 7(4): 395-411) [DOI: 10.12000/JR18040]
- Wang Y H and Liu H W. 2015. PolSAR ship detection based on super-pixel-level scattering mechanism distribution features. *IEEE Geoscience and Remote Sensing Letters*, 12(8): 1780-1784 [DOI: 10.1109/LGRS.2015.2425873]
- Yin J J, Papathanassiou K P, Yang J and Chen P. 2019. Least-squares estimation for pseudo quad-pol image reconstruction from linear compact polarimetric SAR. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 12(10): 3746-3758 [DOI: 10.1109/JSTARS.2019.2910395]
- Yue D X, Xu F and Jin Y Q. 2017. Wishart - Bayesian reconstruction of quad-pol from compact-pol SAR Image. *IEEE Geoscience and Remote Sensing Letters*, 14(9): 1623-1627 [DOI: 10.1109/LGRS.2017.2727280]
- Zhang F, Cao Z Y, Xiang D L, Hu C B, Ma F, Yin Q and Zhou Y S. 2022. Pseudo quad-pol simulation from compact polarimetric SAR data via a complex-valued dual-branch convolutional neural network. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 15: 901-918 [DOI: 10.1109/JSTARS.2021.3138781]
- Zhang T, Jiang L F, Xiang D L, Ban Y F, Pei L and Xiong H L. 2019. Ship detection from PolSAR imagery using the ambiguity removal polarimetric notch filter. *ISPRS Journal of Photogrammetry and Remote Sensing*, 157: 41-58 [DOI: 10.1016/j.isprsjprs.2019.08.009]
- Zhu L, Guo W and Yu W D. 2009. Analysis of SAR satellite development history and tendency. *Modern Radar*, 31(4): 5-10 (朱良, 郭巍, 禹卫东. 2009. 合成孔径雷达卫星发展历程及趋势分析. *现代雷达*, 31(4): 5-10) [DOI: 10.16592/j.cnki.1004-7859.2009.04.001]

Reconstruction of full-polarimetric SAR data based on dual-polarimetric observations from the LT-1 satellite

SUN Weidong¹, DU Xinling¹, YANG Jie¹, SHI Lei¹, LI Minyi², ZHAO Lingli³, HU Cheng⁴

1. State Key Laboratory of Information Engineering in Surveying, Mapping and Remote Sensing, Wuhan University, Wuhan 430079, China;

2. Deqing City Data Management Co., Ltd, Huzhou 313200, China;

3. School of Remote Sensing and Information Engineering, Wuhan University, Wuhan 430079, China;

4. Chinese People's Liberation Army Air Force Command College, Beijing 100097, China

Abstract: The LuTan-1 (LT-1) 01A/B satellite constellation, China's first civilian L-band distributed Synthetic Aperture Radar (SAR) satellite system, is expected to further promote the widespread application of domestic radar data products. While LT-1's dual-polarization

mode supports high-resolution and wide-swath imaging, it lacks certain polarization information compared to full-polarization observation systems, which limits its applications such as land cover classification. To address this, this study designs a multi-head multi-branch Convolutional Neural Network (CNN) and a tailored loss function for two commonly used dual-polarization modes of LT-1. The goal is to restore missing polarization information from dual-polarization inputs, thereby achieving full-polarization SAR data reconstruction. Considering the complementary nature of polarization and spatial features, as well as the distinct characteristics of amplitude and phase data, the network employs separate branches to extract pixel-level polarization information and local spatial features within receptive fields. Two independent heads predict amplitude and phase values to mitigate data crosstalk during output. Additionally, an amplitude/phase combined loss function incorporating phase periodicity is proposed to guide network training. Experiments conducted on two full-polarization SAR images acquired by LT-1 over urban areas in the UK demonstrate that, the proposed method achieves amplitude prediction errors of 1—2 dB and phase errors below 0.5 rad. These results surpass the reconstruction accuracy of a U-Net model with comparable parameter scale. The reconstructed data exhibit statistical distributions and polarization decomposition effects nearly identical to the ground-truth data, confirming effective preservation of full-polarization information. Furthermore, land cover classification experiments show that, classification maps using the reconstructed data achieve overall accuracy comparable to those using real full-polarization data, with a 5% improvement over dual-polarization based classification maps. This study preliminarily validates the feasibility of leveraging LT-1's dual-polarization data to achieve high-resolution, wide-swath imaging while retaining full-polarization capabilities, providing richer input information for SAR land cover/use classification applications.

Key words: SAR, LT-1, dual polarization, full polarization, CNN, terrain classification

Supported by National Key Research and Development Program of China (No. 2022YFB3903605); National Natural Science Foundation of China (No. U22A2010, 42071295, 62471337, 42171442, U2033216); Shenzhen Fundamental Research Program (No. JCYJ20200109150833977); Open Fund of the Key Laboratory of Land Satellite Remote Sensing Application of the Ministry of Natural Resources of the People Republic of China (No. KLSMNR-202110); Open Fund of the State Key Laboratory of Resources and Environmental Information System; the Fundamental Research Funds for the Central Universities