

# Sentinel-1 和 Sentinel-2 协同反演稀疏非光合植被覆盖度

姬翠翠<sup>1,2</sup>, 骆义峡<sup>1</sup>, 李晓松<sup>2,3</sup>, 徐金鸿<sup>1</sup>, 杨雪梅<sup>4</sup>, 陈茂霖<sup>1</sup>

1. 重庆交通大学 智慧城市学院, 重庆 400074;
2. 可持续发展大数据国际研究中心, 北京 100094;
3. 中国科学院空天信息创新研究院, 北京 100094;
4. 兰州文理学院 旅游学院, 兰州 730000

**摘要:** 精准定量反演光合植被 (PV) 和非光合植被 (NPV) 覆盖度对了解植被碳循环过程至关重要, 同时, 获取的非光合植被覆盖度信息也为土地沙漠化及植被转化机制研究提供重要信息。本文以甘肃省民勤县为研究区、Sentinel-1B IW GRD 和 Sentinel-2A 为数据源, 采用线性指数模型 (LIM) 和随机森林模型 (RFM), 基于控制变量法开展微波与光学遥感数据协同反演 NPV 覆盖度的方法研究, 并参考野外获取样地真实性检验数据, 将均方根误差 (RMSE) 和相对均方根误差 (RMSE, %) 作为指标评价反演结果精度。结果表明: (1) 与仅采用 Sentinel-2 光学遥感数据相比, Sentinel-1 和 Sentinel-2 协同反演 NPV 能够明显提高 NPV 覆盖度的估算精度; (2) 由 Sentinel-1 和 Sentinel-2 获取植被指数构建的 RFM 在 NPV 覆盖度估算上较 LIM 精度更高, RFM 和 LIM 估算 NPV 的 RMSE 分别为 0.0149 和 0.0153, 估算精度提高了 1.4%; (3) 垂直水平极化 (VH) 和垂直极化 (VV) 两种极化方式参与建立 RFM 可有效提高 NPV 覆盖度的估算精度, 尤其 VH 极化对非光合植被信息探测更为敏感, 较 VV 模型估算精度提高了 5.1%; (4) 加入表征土壤信息的比值土壤指数 (RSI) 有效减少了土壤对 NPV 覆盖度估算影响, 提高了 NPV 覆盖度估算精度。综上, 微波和光学遥感数据结合是提高 NPV 覆盖度估算精度的有效方法, 同时, 土壤作为独立重要指标参与模型计算对提高 NPV 覆盖度估算具有重要意义。

**关键词:** 非光合植被, Sentinel-1, Sentinel-2, 线性指数模型, 随机森林回归模型, VV 和 VH 极化, 甘肃省民勤县  
**中图分类号:** TP701/P2

**引用格式:** 姬翠翠, 骆义峡, 李晓松, 徐金鸿, 杨雪梅, 陈茂霖. 2023. Sentinel-1 和 Sentinel-2 协同反演稀疏非光合植被覆盖度. 遥感学报, 27(12): 2873-2881

Ji C C, Luo Y X, Li X S, Xu J H, Yang X M and Chen M L. 2023. Retrieving sparse non-photosynthetic vegetation fractional cover by Sentinel-1 and Sentinel-2. National Remote Sensing Bulletin, 27(12): 2873-2881 [DOI: 10.11834/jrs.20231207]

## 1 引言

干旱和半干旱地区人口承载力低且荒漠化日益严重, 人类生存面临严重挑战。及时、准确评价干旱和半干旱地区生态环境, 为科学评估荒漠化程度及荒漠化科学防治提供重要信息 (Jiapaer 等, 2011)。将植被含有叶绿素能够进行光合作用的部分定义为光合植被 PV (Photosynthetic Vegetation); 枯枝落叶、树干等不能进行光合作用的部分定义

为非光合植被 NPV (Non-Photosynthetic Vegetation) (Guerschman 等, 2009)。在干旱区, 植被退化非常严重, NPV 是干旱区自然植被的重要组成部分 (Li 等, 2016)。因此, 定量估算光合植被覆盖度 ( $f_{PV}$ ) 和非光合植被覆盖度 ( $f_{NPV}$ ) 为调查干旱区植被状况及碳存储具有重要意义 (Reynolds 等, 2007)。

遥感技术能够及时、准确地估算  $f_{PV}$  和  $f_{NPV}$ 。随着遥感技术的发展、数据源的多样化, 多源遥感

收稿日期: 2021-04-16; 预印本: 2021-09-11

基金项目: 国家重点研发计划 (编号: 2020YFC1511602); 国家自然科学基金 (编号: 32060373, 41801394); 重庆市教育委员会科学技术研究项目 (编号: KJQN202000746)

第一作者简介: 姬翠翠, 研究方向为生态环境遥感。E-mail: jijingqiang@163.com

通信作者简介: 骆义峡, 研究方向为定量遥感的应用。E-mail: yixia.luo@qq.com

数据协同反演植被覆盖度成为提高反演精度重要手段。总结目前国内外PV和NPV覆盖度估算文献资料,可见PV覆盖度的估算研究已经取得了较大进展。其主要是根据植被在红外与近红外波段的特殊光谱特征,获取植被健康状况(Chen和Vierling, 2006);由于NPV与土壤(Bare Soil, BS)区分难度大,致使NPV覆盖度估算具有一定难度,且NPV覆盖度估算研究相对较少(Okin, 2007),但是Daughtry等基于高光谱影像,根据NPV在短波红外波段由木质素与纤维素等引起的吸收特征,将NPV与土壤有效分离(Daughtry等, 1995; Asner和Lobell, 2000)。然而,由于高光谱数据获取困难,无法实现大范围植被覆盖度估算(Garrigues等, 2006; Lehnert等, 2014)。因此,尽管多光谱数据缺乏详细的光谱特征,依靠其海量数据、覆盖范围大等优势,被广泛应用于NPV覆盖度估算(Clasen等, 2015)。微波遥感特别是合成孔径雷达SAR(Synthetic Aperture Rader)遥感包含了丰富的结构信息,能够有效描述植被冠层信息及植被的水平结构与垂直结构(Pope等, 1994; Kim和van Zyl, 2009),进而实现植被覆盖度估算,被广泛应用于作物类型识别和生长状态监测(Tomppo等, 2019; 田海峰等, 2015)、森林植被监测(Erinjery等, 2018; 董贵威等, 2003)、植被识别(邵京等, 2021)等领域。Kim等(2015)将光学植被指数与雷达植被指数融合为一种综合植被指数(融合植被指数(FVI)),研究表明FVI指数同时具有NDVI指数的绿度信息和RVI指数的冠层结构信息,对植被具有更好的可分离性。FVI指数的提出为微波与多光谱协同反演植被覆盖度提供了参考。目前SAR数据主要应用于光合植被的相关研究,但在NPV覆盖度估算上的研究较少,结合SAR数据与多光谱数据协同反演NPV覆盖度更少。

在PV与NPV覆盖度估算方法上较为常用的有光谱混合分析(SMA)(Adams等, 1986; Roberts等, 1998)、像元三分模型(Guerschman等, 2009)等基于像素的分解模型广泛应用于PV与NPV覆盖度的估算(Meng等, 2017; Quintano等, 2020)。最近新兴的机器学习算法普遍应用于遥感数据分析(Lary等, 2016),例如:随机森林(RF)分类器能充分处理卫星图像的空间复杂性,可避免多重共线性、过度拟合等问题,通过简单、快

速的学习即可获取准确结果等优势(Belgiu和Drăguț, 2016; Lary等, 2016)。考虑到NPV和BS光谱曲线非常相似,在NPV和BS端元转换过程中,不同的进化阶段特征界线模糊,因此很难被区分(姬翠翠, 2018)。考虑到土壤可能是影响NPV覆盖度精准估算的重要因素,因此在模型中加入土壤指标参数能够将植被与土壤有效分离(Serbin等, 2009)。虽然SAR在植被信息提取中得到广泛应用,然而至今采用SAR数据反演NPV覆盖度的研究较少,尚未见采用极化信息结合光谱特征估算NPV覆盖度的报道。因此,为快速、准确地估算干旱区NPV覆盖度,基于地面控制性实验获取的端元光谱与端元丰度信息,利用线性指数模型(LIM)以及随机森林模型(RFM)进行 $f_{NPV}$ 的估算,从而确定LIM以及RFM中最佳非光合植被覆盖度估算模型,探索基于Sentinel-1和Sentinel-2数据的微波与多光谱遥感协同反演NPV覆盖度的可行性,研究Sentinel-1的VV、VH极化方式对NPV覆盖度的敏感性,引入表征土壤特征信息的指标是否对NPV覆盖度估算精度有所提高,以期科学评价干旱区植被覆盖状况提供数据支撑。

## 2 研究区概况

选取试验区位于甘肃民勤绿洲(38°37'42.60"N, 102°55'11.25"E),温带大陆性干旱气候,位于腾格里沙漠和巴丹吉林沙漠的交汇处,其中沙漠、戈壁等占据了全县总面积的91%,农田绿洲仅占9%。年均降水量少,且蒸发量大,蒸发量约为降水量的23倍;同时,人口的急剧增加,致使过度开采地下水资源,导致植被衰败,大量人造林地几近枯死,土地荒漠化十分严重(戴晟懋等, 2008)。除去光合植被与非光合植被间的自然转化,民勤绿洲受到其地理位置及生态失衡等因素影响,致使NPV成为民勤绿洲植被中不可或缺的一部分。

## 3 数据获取与研究方法

### 3.1 影像数据获取及预处理

哨兵(Sentinels)数据是欧洲航空局“哥白尼”计划采集的影像产品,服务于全球环境与安全实时动态监测。本文使用的Sentinel-1B和

Sentinel-2A 影像从 Sentinels 科学数据中心 (<https://scihub.copernicus.eu/> [2021-04-16]) 下载成像时间为 2017 年 7 月, 无云量、成像质量较好的影像。

采用 Sentinel-1B 数据的 VV 和 VH 两种极化模式, 其空间分辨率为 10 m。数据预处理在欧洲航空局发布的哨兵系列数据综合处理平台 SNAP 上进行, 完成 Sentinel-1B 数据辐射校正、滤波去噪、地形校正等数据预处理 (Gašparović 和 Dobrinić, 2020)。

Sentinel-2A 数据使用 ESA 官方发布的 Sen2cor v2.8 插件进行预处理, 获取 L2A 级 Sentinel-2A 数据。研究过程中使用空间分辨率为 10 m 和 20 m 的部分波段, 因此需要将空间分辨率为 20 m 的波段重采样为 10 m。

### 3.2 地面验证数据获取

本研究地面验证数据主要获取样地的纯净端元光谱与端元丰度信息。

纯净端元光谱采集。采用 ASD (Analytical Spectral Devices) Field Space Pro 光谱仪采集纯净端元光谱, 光谱采集范围为 350—2500 nm。端元光谱采集时应选择晴朗无云、风力较小、太阳光照充足稳定的时段 (10:00—14:00) 进行, 采集前应先采集参考白板光谱, 然后将端元材料置于全吸收黑布上, 最后将探针置于地物上方, 每种地物测量 5 次取平均值作为地物的端元光谱。

端元丰度信息采集。民勤绿洲样地植被覆盖度地面数据采集于 2017 年 7 月。在研究区内共选取了 61 块样地, 样地大小为 30 m×30 m, 样地内 PV、NPV 和 BS 各端元均匀分布。采用针刺法 (间隔 1 m) 分别获取每块样地 PV 和 NPV 的丰度信息, 同时利用 GPS 记录样地中心位置。观测者记录每米的物质类型, 当记录的植被仍然附着叶片时应根据叶片颜色判断植被类型。

### 3.3 线性指数模型

LIM 是结合线性光谱混合模型 (姬翠翠 等, 2016; 郑国雄 等, 2016) 与像元三分模型 (李涛 等, 2015) 的思路, 由多光谱数据计算得到的指数替换影像波段, 建立线性模型, 进而求解各个端元覆盖度的方法。像元三分模型假设像元由 PV-NPV-BS 三组分组成, 采用 NDVI 指数表征光合植被、干枯燃料指数 (DFI) (Cao and Chen, 2010) 表征非光合植被, 建立 NDVI、DFI 指数与 PV、

NPV、BS 之间的线性关系从而估算各组分丰度。本文 LIM 中在传统的像元三分模型基础上增加比值土壤指数 (RSI) (骆义峡 等, 2022), 减小土壤的干扰对 NPV 覆盖度的影响, 因此本文选取 NDVI 表征 PV、DFI 表征 NPV、RSI 表征 BS, 建立 LIM。

$$\text{NDVI} = ((B8 - B4) / (B8 + B4)) \quad (1)$$

$$\text{DFI} = 100 \times (1 - (B12/B11)) \times (B4/B8) \quad (2)$$

$$\text{RSI} = (B4/B8) \times (B12/B11) \quad (3)$$

式中, B4、B8、B11、B12 分别为 Sentinel-2A 数据的第 4、8、11、12 波段。

本文使用的 LIM 是基于 NDVI、DFI 与 RSI 3 个指数建立, 由式 (4) — (10) 组成 LIM:

$$N = \sum [f_i N_i] = [f_{PV} N_{PV} + f_{NPV} N_{NPV} + f_{BS} N_{BS}] \quad (4)$$

$$D = \sum [f_i D_i] = [f_{PV} D_{PV} + f_{NPV} D_{NPV} + f_{BS} D_{BS}] \quad (5)$$

$$R = \sum [f_i R_i] = [f_{PV} R_{PV} + f_{NPV} R_{NPV} + f_{BS} R_{BS}] \quad (6)$$

$$\sum f_i = [f_{PV} + f_{NPV} + f_{BS}] = 1 \quad (7)$$

式中,  $N$  为 Sentinel-2A 数据的 NDVI 值,  $D$  为 Sentinel-2A 数据的 DFI 值,  $R$  为 Sentinel-2A 数据的 RSI 值。 $N_{PV}$ 、 $D_{PV}$  和  $R_{PV}$  为 PV 的 NDVI、DFI 与 RSI 端元特征值,  $N_{NPV}$ 、 $D_{NPV}$  和  $R_{NPV}$  为 NPV 的 NDVI、DFI 与 RSI 端元特征值,  $N_{BS}$ 、 $D_{BS}$  和  $R_{BS}$  为 BS 的 NDVI、DFI 与 RSI 端元特征值,  $f_{PV}$ 、 $f_{NPV}$ 、 $f_{BS}$  分别代表像元内 PV、NPV 和 BS 的所占比例。

### 3.4 随机森林

随机森林是一种机器学习算法, 可用于解决分类与回归问题。在构建森林时, 采取随机抽样, 大约抽取 75% 的样本作为训练数据集, 然后随机选择输入变量定义节点 (Liaw 和 Wiener, 2001), 剩余样本数据用于交叉验证评估模型 (Breiman, 2001)。在 RF 的研究中, 决策树数量 (ntree), 决策树节点数 (mtry) 是随机森林回归模型的 2 个重要参数, 决策树的数量默认值一般为 500 (Collins 等, 2018; Quintano 等, 2020), 在每棵树的分裂节点随机选择  $\sqrt{n}$  个特征变量作为该节点的分裂特征 (其中  $n$  为变量数量), 最小分裂特征数量为 1。本文基于不同变量组合, 使用 RFM 预测 NPV 覆盖度, 最终输出结果是由多棵决策树决定, 取每棵树预测值的平均值作为最终预测值, 并计算 RMSE 评价估算的准确性 (图 1)。

所有随机森林回归分析基于 Python 的 “sklearn” 包实现的。




图1 随机森林回归模型

Fig.1 Random forest regression model

### 3.5 精度评估模型

各模型估算精度主要通过NPV覆盖度估算值与样地验证数据的均方根误差（RMSE）、相关系数（ $R^2$ ）以及相对均方根误差（RMSE(%)）（Heinz和Chang, 2001; Fan等, 2009）来评价。RMSE主要反映估算结果与地面实测端元丰度的接近性。RMSE(%)主要反映各模型估算NPV覆盖度的相对估算精度，值越小模型估算精度越高。

$$RMSE = \sqrt{\left( \sum_{i=1}^n (X_i - Y_i)^2 / n \right)} \quad (8)$$

$$R^2 = \frac{\left( \sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y}) \right)^2}{\sum_{i=1}^n (X_i - \bar{X})^2 \sum_{i=1}^n (Y_i - \bar{Y})^2} \quad (9)$$

表1 多种数据组合模式下NPV覆盖度求解的模型精度

Table 1 Accuracy of NPV fractional cover estimated based on various data combination models

| 序号 | 模型   | 数据组合               | $R^2$  | RMSE   | RMSE/% |
|----|------|--------------------|--------|--------|--------|
| 1  | 线性指数 | NDVI、DFI、RSI       | 0.7095 | 0.0153 | 48.0%  |
| 2  | 随机森林 | NDVI、DFI、RSI       | 0.7563 | 0.0148 | 46.6%  |
| 3  | 随机森林 | VV、VH              | 0.6158 | 0.0207 | 64.9%  |
| 4  | 随机森林 | NDVI、DFI、VV、VH、RSI | 0.7731 | 0.0135 | 42.6%  |
| 5  | 随机森林 | NDVI、DFI、VV、VH     | 0.7681 | 0.0137 | 43.0%  |
| 6  | 随机森林 | NDVI、VV、VH、RSI     | 0.8175 | 0.0112 | 35.3%  |
| 7  | 随机森林 | VV、VH、RSI          | 0.8418 | 0.0104 | 32.7%  |
| 8  | 随机森林 | NDVI、VV、RSI        | 0.7809 | 0.0123 | 38.8%  |
| 9  | 随机森林 | NDVI、VH、RSI        | 0.8619 | 0.0107 | 33.7%  |

注：NDVI为归一化植被指数，DFI为干枯燃料指数，RSI为比值土壤指数，VV和VH分别代表垂直极化和垂直水平极化， $R^2$ 为相关系数，RMSE为均方根误差。

为进一步探寻Sentinel-1数据与多光谱指数协同反演NPV覆盖度方法，以RFM为基础，控制建模数据组合，设计了4组对比试验。从表1中可以看出：仅使用Sentinel-1B数据（图2(c)）估算

$$RMSE(\%) = \left( \frac{RMSE}{2\lambda} \right) \times 100\% \quad (10)$$

$$\lambda = \sqrt{\frac{\sum_{i=1}^n (X_i - \bar{X})^2}{n}} \quad (11)$$

式中， $X_i$ 、 $Y_i$ 分别为估算值和实测值， $\bar{X}_i$ 、 $\bar{Y}_i$ 分别为估算值和实测值的均值， $n$ 为验证样本数量， $\lambda$ 为验证样本标准差。

## 4 结果与分析

### 4.1 Sentinel-1和Sentinel-2协同反演NPV覆盖度

通过设置多组对比实验相互印证，研究适用于干旱区稀疏NPV覆盖度估算的最佳估算模型，并探寻VV、VH极化方式对NPV覆盖度估算的敏感性，多种数据组合模式下NPV覆盖度估算实验结果见表1，VV、VH极化方式参与估算时 $f_{NPV}$ 估算精度分别提高了7.8%和12.9%。因此，Sentinel-1B数据的VV、VH极化方式均能有效提高 $f_{NPV}$ 的估算精度，且VH极化方式对NPV更加敏感。通过上述实验结果可以看出微波与多光谱数协同反演NPV覆盖度能够有效提高 $f_{NPV}$ 的估算精度。

NPV覆盖度效果较差，其RMSE、RMSE(%)分别为0.0207、64.9%，与仅使用光谱指数（图2(b)）估算 $f_{NPV}$ 相比估算精度大幅降低，RMSE(%)降低了18.3%。其次，Sentinel-1结合Sentinel-2协同反

演NPV覆盖度可有效提高 $f_{\text{NPV}}$ 估算精度, RMSE与RMSE(%)最大为0.0137和43.0%, 估算精度均高于仅采用单一数据源估算NPV覆盖度的估算精度; 其中, VV、VH、RSI模型估算精度最高, RMSE与RMSE(%)分别为0.0104和32.7%, 且拟合线与参考线近乎重合, 散点合理分布于参考线两侧。最后, 通过表1中结果可见光谱植被指数中, RSI指数在 $f_{\text{NPV}}$ 的估算中起着重要作用, RSI指数是参考BS的光谱特征曲线总结得出, 在模型

中用于表征BS, 旨在增加模型对BS的辨识能力, 降低BS的误分概率。总之, 在NDVI、DFI、VV、VH、RSI模型和VV、VH、RSI模型的基础上, 排除RSI指数时, NPV覆盖度估算精度均呈现出降低的趋势, RMSE(%)分别从42.6%和32.7%增至43.0%和64.9%, 结合 $f_{\text{NPV}}$ 估算结果验证精度散点图(图2(c—g))表明, RSI指数加入能够有效提高NPV覆盖度估算精度。




图2 采用线性指数模型和随机森林模型 $f_{\text{NPV}}$ 估算与实测覆盖度散点分布图及其拟合线

Fig. 2 Scatterplots and the best fit regression lines of the estimated and measured  $f_{\text{NPV}}$  by Linear index and RF models

## 4.2 不同估算模型比较分析

表1为基于LIM和RFM使用Sentinel-2A数据获取的植被指数估算NPV覆盖度的估算精度。可见：RFM的RMSE为0.0148，RMSE(%)为46.6%，LIM的RMSE为0.0153，RMSE(%)为48.0%，RFM较LIM估算精度提高了1.4%。分析LIM（图2(a)）和RFM（图2(b)）的估算与实测覆盖度残差图可知，RFM估算效果较好，散点大多分布在参考线（1:1等值线）附近，拟合线更加靠近参考线，且RFM的散点在参考线附近分布更加均匀；因此，综合 $R^2$ 、RMSE以及RMSE(%)3个评价指标表明：RFM要优于LIM。

## 5 讨论

### 5.1 随机森林模型潜力

本研究采用LIM和RFM估算NPV覆盖度，通过比较发现，RFM估算精度高于LIM。图2(a)和(b)展示了2个模型估算值与实测值散点图，图2中可以看出LIM和RFM均呈现出轻微的低估现象，且均无异常值存在，但RFM的散点分布更加合理。通过多组实验验证，LIM和RFM均能有效运用于干旱区稀疏NPV覆盖度估算。像元混合分解模型中端元数量及端元纯净光谱的确定是光谱混合模型成功的关键（姬翠翠等，2016），但本研究所用的端元数量较为精简，且电磁波与复杂地物的相互作用过程较为复杂，因此本研究选用LIM，该模型是使用多个波段计算光谱指数构建模型，能够减少端元数量不足、端元光谱异质性、影像成像质量等起的误差，有助于 $f_{NPV}$ 的估算；RFM是一种机器学习方法，能够同时分析多个随机选取的特征变量、减轻机器学习固有的过度拟合问题（Breiman，2001）、计算效率高（Montorio等，2020）等特点，作为一种有效的估算工具常用于遥感解译。RFM与LIM相比，RFM跟偏向于数据分析，对数据缺失或数据异常具有更强的容错率。此文的研究结果表明RF能够更有效地定量估算干旱区稀疏NPV覆盖度的估算，与前人已有的研究结果一致（Collins等，2018；Mitsopoulos等，2019；Parks等，2019；邵京等，2021）。在不考虑数据源对NPV覆盖度估算影响的前提下，基于LIM估算NPV覆盖度RMSE为0.0153，但基于RFM估算NPV覆盖度估算精度略有提高，RMSE为0.0148。

## 5.2 极化方式及NPV覆盖度估算

Sentinel-1数据是同极化和交叉极化通道中接收的波的反向散射强度提供了有关目标的信息。多项研究采用此数据利用其反向散射强度识别作物类型（Mandal等，2018；Whelen和Siqueira，2018；Arias等，2020）和估算作物生物物理参数（Kumar等，2018）。本研究初步探讨了Sentinel-1数据用于干旱区稀疏NPV覆盖度估算研究，发现VH极化对NPV更加敏感，能够显著提高 $f_{NPV}$ 估算精度。经早前一些研究结果表明：（1）Sentinel-1数据的VV与VH极化分别对地物表面散射和体积散射更敏感（Gašparović和Dobrinić，2020），植被的散射机制主要是复杂的体积散射（Vreugdenhil等，2018）；同时，VH极化的后向散射系数值随植被覆盖度和叶面积指数的增加而增加（Macelloni等，2001）；（2）研究区内主要由结构明显、生产力低下的梭梭和白刺灌丛为主（Ji等，2020）。其中，梭梭叶片呈针状且稀疏分布于树枝上，垂直结构明显；白刺灌丛均较为矮小，垂直结构并不明显。因此，在垂直结构上难以区分PV与NPV。但是，PV与NPV在冠层结构上具有较大的差异。Vreugdenhil等（2018）和Gašparović和Dobrinić（2020）研究指出VH极化能够较好地描述植被的冠层信息，且与植被覆盖度具有较好的相关性，与本文研究结果VH极化对NPV更加敏感完全契合。因此，极化特性、研究区植被结构与NPV覆盖度估算密切相关，然而本文仅实现了SAR数据不同极化方式的后向散射系数在估算干旱区稀疏NPV覆盖度初步应用，未来如何充分应用SAR数据，实现稀疏植被覆盖度定量估算仍然是一个重点研究方向。

## 6 结论

本文旨在通过光学遥感数据介入微波遥感数据尝试提高干旱区稀疏NPV覆盖度估算精度的目的，因此，基于微波数据Sentinel-1B影像和光学遥感数据Sentinel-2A影像，从甘肃省民勤县稀疏NPV覆盖区域选择样地，采用LIM和RFM估算该区域内NPV覆盖度，得出主要结论如下：

（1）RFM能够有效运用于干旱区稀疏植被覆盖度估算，RMSE最小为0.0104，RMSE(%)最小为32.7%，RFM在植被覆盖度估算方面表现出巨大

的应用潜力。

(2) 实现了 LIM 在干旱区稀疏植被覆盖度的准确估算, 估算 RMSE 为 0.0153, RMSE (%) 为 48.0%。RFM 相较于 LIM 具有更好的估算效果, RMSE 和 RMSE (%) 分别为 0.0148 和 46.6%, 估算精度较 LIM 提高了 1.4%。

(3) Sentinel-1 结合 Sentinel-2 能够有效提高干旱区稀疏 NPV 覆盖度估算精度, 估算精度最低提高了 3.6%, 最高提高了 13.9%; VV、VH、RSIRFM 估算精度最高, RMSE 为 0.0104, RMSE (%) 最小为 32.7%。其中, 在 Sentinel-1 数据中 VV 与 VH 极化方式相比, VH 极化对 NPV 覆盖度更加敏感。

(4) 比值土壤指数的加入各模型建模均能提高 NPV 覆盖度估算精度, 可以有效减少土壤对 NPV 覆盖度估算影响。

## 参考文献 (References)

- Adams J B, Smith M O and Johnson P E. 1986. Spectral mixture modeling: a new analysis of rock and soil types at the Viking Lander 1 site. *Journal of Geophysical Research: Solid Earth*, 91(B8): 8098-8112 [DOI: 10.1029/JB091iB08p08098]
- Arias M, Campo-Bescós M Á and Álvarez-Mozos J. 2020. Crop classification based on temporal signatures of sentinel-1 observations over Navarre Province, Spain. *Remote Sensing*, 12(2): 278 [DOI: 10.3390/rs12020278]
- Asner G P and Lobell D B. 2000. A biogeophysical approach for automated SWIR unmixing of soils and vegetation. *Remote Sensing of Environment*, 74(1): 99-112 [DOI: 10.1016/S0034-4257(00)00126-7]
- Belgiu M and Drăguț L. 2016. Random forest in remote sensing: a review of applications and future directions. *ISPRS Journal of Photogrammetry and Remote Sensing*, 114: 24-31 [DOI: 10.1016/j.isprsjprs.2016.01.011]
- Breiman L. 2001. Random forests. *Machine Learning*, 45(1): 5-32 [DOI: 10.1023/A:1010933404324]
- Cao X, Chen J, Matsushita B, Imura H. 2010. Developing a MODIS-based index to discriminate dead fuel from photosynthetic vegetation and soil background in the Asian steppe area. *International Journal of Remote Sensing*, 31(6): 1589-1604 [DOI: 10.1080/01431160903475274]
- Chen X X and Vierling L. 2006. Spectral mixture analyses of hyperspectral data acquired using a tethered balloon. *Remote Sensing of Environment*, 103(3): 338-350 [DOI: 10.1016/j.rse.2005.05.023]
- Clasen A, Somers B, Pipkins K, Tits L, Segl K, Brell M, Kleinschmit B, Spengler D, Lausch A and Förster M. 2015. Spectral unmixing of forest crown components at close range, airborne and simulated sentinel-2 and EnMAP spectral imaging scale. *Remote Sensing*, 7(11): 15361-15387 [DOI: 10.3390/rs71115361]
- Collins L, Griffioen P, Newell G and Mellor A. 2018. The utility of Random Forests for wildfire severity mapping. *Remote Sensing of Environment*, 216: 374-384 [DOI: 10.1016/j.rse.2018.07.005]
- DAI S M, QIU G Y and ZHAO M. 2008. Study on land desertification and its prevention and control measures in the Minqin oasis in Gansu Province. *Arid Zone Research*, 25(3): 319-324 (戴晟懋, 邱国玉, 赵明. 2008. 甘肃民勤绿洲荒漠化防治研究. 干旱区研究, 25(3): 319-324) [DOI: 10.13866/j.azr.2008.03.018]
- Daughtry C S T, McMurtrey III J E, Chappelle E W, Dulaney W P, Irons J R and Satterwhite M B. 1995. Potential for discriminating crop residues from soil by reflectance and fluorescence. *Agronomy Journal*, 87(2): 165-171 [DOI: 10.2134/agronj1995.00021962008700020005x]
- Dong G W, Yang J, Peng Y N, Wang C and Zhang H. 2003. Forest characteristic detection with Pol-SAR. *Journal of Tsinghua University (Science & Technology)*, 43(7): 953-956 (董贵威, 杨健, 彭应宁, 王超, 张红. 2003. 极化 SAR 遥感中森林特征探测. 清华大学学报(自然科学版), 43(7): 953-956) [DOI: 10.16511/j.cnki.qhdxxb.2003.07.024]
- Erinjeri J J, Singh M and Kent R. 2018. Mapping and assessment of vegetation types in the tropical rainforests of the Western Ghats using multi-spectral Sentinel-2 and SAR Sentinel-1 satellite imagery. *Remote Sensing of Environment*, 216: 345-354 [DOI: 10.1016/j.rse.2018.07.006]
- Fan W Y, Hu B X, Miller J and Li M Z. 2009. Comparative study between a new nonlinear model and common linear model for analysing laboratory simulated-forest hyperspectral data. *International Journal of Remote Sensing*, 30(11): 2951-2962 [DOI: 10.1080/01431160802558659]
- Garrigues S, Allard D, Baret F and Weiss M. 2006. Influence of landscape spatial heterogeneity on the non-linear estimation of leaf area index from moderate spatial resolution remote sensing data. *Remote Sensing of Environment*, 105(4): 286-298 [DOI: 10.1016/j.rse.2006.07.013]
- Gašparović M and Dobričić D. 2020. Comparative assessment of machine learning methods for urban vegetation mapping using multi-temporal sentinel-1 imagery. *Remote Sensing*, 12(12): 1952 [DOI: 10.3390/rs12121952]
- Guerschman J P, Hill M J, Renzullo L J, Barrett D J, Marks A S and Botha E J. 2009. Estimating fractional cover of photosynthetic vegetation, non-photosynthetic vegetation and bare soil in the Australian tropical savanna region upscaling the EO-1 Hyperion and MODIS sensors. *Remote Sensing of Environment*, 113(5): 928-945 [DOI: 10.1016/j.rse.2009.01.006]
- Heinz D C and Chang C I. 2001. Fully constrained least squares linear spectral mixture analysis method for material quantification in hyperspectral imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 39(3): 529-545 [DOI: 10.1109/36.911111]
- Ji C C, Jia Y H, Li X S and Wang J Y. 2016. Research on linear and nonlinear spectral mixture models for estimating vegetation fractional cover of nitraria bushes. *Journal of Remote Sensing*, 20(6): 1402-1412 (姬翠翠, 贾永红, 李晓松, 王金英. 2016. 线性/非线性光谱混合模型估算白刺灌丛植被覆盖度. 遥感学报, 20(6): 1402-1412) [DOI: 10.11834/jrs.20166020]
- Ji C C. 2018. Research on Muti-Scale Spectral Mixture Analysis Method for Sparse Photosynthetic/Non-Photosynthetic Vegetation in Arid Area. Wuhan: Wuhan University (姬翠翠. 2018. 干旱区稀疏光合

- 与非光合植被多尺度光谱混合解析方法研究. 武汉: 武汉大学)
- Ji C C, Li X S, Wei H D and Li S K. 2020. Comparison of different multispectral sensors for photosynthetic and non-photosynthetic vegetation-fraction retrieval. *Remote Sensing*, 12(1): 115 [DOI: 10.3390/rs12010115]
- Jiapaer G, Chen X and Bao A M. 2011. A comparison of methods for estimating fractional vegetation cover in arid regions. *Agricultural and Forest Meteorology*, 151(12): 1698-1710 [DOI: 10.1016/j.agrformet.2011.07.004]
- Kim Y and van Zyl J J. 2009. A time-series approach to estimate soil moisture using polarimetric radar data. *IEEE Transactions on Geoscience and Remote Sensing*, 47(8): 2519-2527 [DOI: 10.1109/TGRS.2009.2014944]
- Kim Y H, OH J H and Kim Y I. 2015. Development of a fusion vegetation index using full-PolSAR and multispectral data. *Journal of the Korean Society of Surveying, Geodesy, Photogrammetry and Cartography*, 33(6): 547-555 [DOI: 10.7848/ksgpc.2015.33.6.547]
- Kumar P, Prasad R, Gupta D K, Mishra V N, Vishwakarma A K, Yadav V P, Bala R, Choudhary A and Avtar R. 2018. Estimation of winter wheat crop growth parameters using time series Sentinel-1A SAR data. *Geocarto International*, 33(9): 942-956 [DOI: 10.1080/10106049.2017.1316781]
- Lary D J, Alavi A H, Gandomi A H and Walker A L. 2016. Machine learning in geosciences and remote sensing. *Geoscience Frontiers*, 7(1): 3-10 [DOI: 10.1016/j.gsf.2015.07.003]
- Lehnert L, Meyer H, Thies B, Reudenbach C and Bendix J. 2014. Monitoring plant cover on the Tibetan Plateau: a multi-scale remote sensing based approach//Proceedings of the EGU General Assembly 2014. Vienna, Austria: [s.n.]
- Li T, Li X S and Li F. 2015. Estimating fractional cover of photosynthetic vegetation and non-photosynthetic vegetation in the Xilingol steppe region with EO-1 hyperion data. *Acta Ecologica Sinica*, 35(11): 3643-3652 (李涛, 李晓松, 李飞. 2015. 基于Hyperion的锡林郭勒草原光合植被、非光合植被覆盖度估算. *生态学报*, 35(11): 3643-3652) [DOI: 10.5846/stxb201308142075]
- Li X S, Zheng G X, Wang J Y, Ji C C, Sun B and Gao Z H. 2016. Comparison of methods for estimating fractional cover of photosynthetic and non-photosynthetic vegetation in the otindag sandy land using GF-1 wide-field view data. *Remote Sensing*, 8(10): 800 [DOI: 10.3390/rs8100800]
- Liaw A and Wiener M. 2001. Classification and regression by Random Forest. *R News*, 2-3: 18-22
- Luo Y X, Ji C C, Li X S, Xu J H and Yang X M. 2022. Vegetation index model for estimating sparse photosynthetic/non-photosynthetic vegetation fractional cover in arid zone. *Remote Sensing Information*, 37(3): 57-64 (骆义峡, 姬翠翠, 李晓松, 徐金鸿, 杨雪梅. 2022. 植被指数模型估算干旱区稀疏光合/非光合植被覆盖度. *遥感信息*, 37(3): 57-64)
- Macelloni G, Paloscia S, Pampaloni P, Marliani F and Gai M. 2001. The relationship between the backscattering coefficient and the biomass of narrow and broad leaf crops. *IEEE Transactions on Geoscience and Remote Sensing*, 39(4): 873-884 [DOI: 10.1109/36.917914]
- Mandal D, Kumar V, Bhattacharya A, Rao Y S, Siqueira P and Bera S. 2018. Sen4Rice: a processing chain for differentiating early and late transplanted rice using time-series sentinel-1 SAR data with Google earth engine. *IEEE Geoscience and Remote Sensing Letters*, 15(12): 1947-1951 [DOI: 10.1109/LGRS.2018.2865816]
- Meng R, Wu J, Schwager K L, Zhao F, Dennison P E, Cook B D, Brewster K, Green T M and Serbin S P. 2017. Using high spatial resolution satellite imagery to map forest burn severity across spatial scales in a Pine Barrens ecosystem. *Remote Sensing of Environment*, 191: 95-109 [DOI: 10.1016/j.rse.2017.01.016]
- Mitsopoulos I, Chrysafi I, Bountis D and Mallinis G. 2019. Assessment of factors driving high fire severity potential and classification in a Mediterranean pine ecosystem. *Journal of Environmental Management*, 235: 266-275 [DOI: 10.1016/j.jenvman.2019.01.056]
- Montorio R, Pérez-Cabello F, Alves D B and García-Martín A. 2020. Unitemporal approach to fire severity mapping using multispectral synthetic databases and Random Forests. *Remote Sensing of Environment*, 249: 112025 [DOI: 10.1016/j.rse.2020.112025]
- Okin G S. 2007. Relative spectral mixture analysis — A multitemporal index of total vegetation cover. *Remote Sensing of Environment*, 106(4): 467-479 [DOI: 10.1016/j.rse.2006.09.018]
- Parks S A, Holsinger L M, Koontz M J, Collins L, Whitman E, Parisien M A, Loehman R A, Barnes J L, Bourdon J F, Boucher J, Boucher Y, Caprio A C, Collingwood A, Hall R J, Park J, Saperstein L B, Smetanka C, Smith R J and Soverel N. 2019. Giving ecological meaning to satellite-derived fire severity metrics across North American forests. *Remote Sensing*, 11(14): 1735 [DOI: 10.3390/rs11141735]
- Pope K O, Rey-Benayas J M and Paris J F. 1994. Radar remote sensing of forest and wetland ecosystems in the Central American tropics. *Remote Sensing of Environment*, 48(2): 205-219 [DOI: 10.1016/0034-4257(94)90142-2]
- Quintano C, Fernández-Manso A and Roberts D A. 2020. Enhanced burn severity estimation using fine resolution ET and MESMA fraction images with machine learning algorithm. *Remote Sensing of Environment*, 244: 111815 [DOI: 10.1016/j.rse.2020.111815]
- Reynolds J F, Smith D M S, Lambin E F, Turner II B L, Mortimore M, Batterbury S P J, Downing T E, Dowlatabadi H, Fernandez R J, Herrick J E, Huber-Sannwald E, Jiang H, Leemans R, Lynam T, Maestre F T, Ayarza M and Walker B. 2007. Global desertification: building a science for dryland development. *Science*, 316(5826): 847-851 [DOI: 10.1126/science.1131634]
- Roberts D A, Gardner M, Church R, Ustin S, Scheer G and Green R O. 1998. Mapping chaparral in the Santa Monica mountains using multiple endmember spectral mixture models. *Remote Sensing of Environment*, 65(3): 267-279 [DOI: 10.1016/S0034-4257(98)00037-6]
- Serbin G, Hunt E R, Daughtry C S T, McCarty G W and Doraiswamy P C. 2009. An improved ASTER index for remote sensing of crop residue. *Remote Sensing*, 1(4): 971-991 [DOI: 10.3390/rs1040971]
- Shao J, Li X S, Yang J T and Liu D C. 2021. Study on large scale grassland shrub monitoring based on optical and radar remote sensing. *Journal of Arid Land Resources and Environment*, 35(2): 130-135 (邵京, 李晓松, 杨珺婷, 刘代超. 2021. 光学与雷达遥感协同的大尺度草地灌丛化监测研究. *干旱区资源与环境*, 35(2): 130-135) [DOI: 10.13448/j.cnki.jalre.2021.050]
- Tian H F, Wu M Q, Niu Z, Wang C Y and Zhao X. 2015. Dryland

- crops recognition under complex planting structure based on Radarsat-2 images. Transactions of the Chinese Society of Agricultural Engineering, 31(23): 154-159 (田海峰, 郭明权, 牛铮, 王长耀, 赵昕. 2015. 基于 Radarsat-2 影像的复杂种植结构下旱地作物识别. 农业工程学报, 31(23): 154-159) [DOI: 10.11975/j.issn.1002-6819.2015.23.020]
- Tomppo E, Antropov O and Praks J. 2019. Cropland classification using sentinel-1 time series: methodological performance and prediction uncertainty assessment. Remote Sensing, 11(21): 2480 [DOI: 10.3390/rs11212480]
- Vreugdenhil M, Wagner W, Bauer-Marschallinger B, Pfeil I, Teubner I, Rüdiger C and Strauss P. 2018. Sensitivity of sentinel-1 backscatter to vegetation dynamics: an Austrian case study. Remote Sensing, 10(9): 1396 [DOI: 10.3390/rs10091396]
- Whelen T and Siqueira P. 2018. Time-series classification of Sentinel-1 agricultural data over North Dakota. Remote Sensing Letters, 9(5): 411-420 [DOI: 10.1080/2150704X.2018.1430393]
- Zheng G X, Li X S, Zhang K X and Wang J Y. 2016. Spectral mixing mechanism analysis of photosynthetic/non-photosynthetic vegetation and bared soil mixture in the hunshandake (Otindag) sandy land. Spectroscopy and Spectral Analysis, 36(4): 1063-1068 (郑国雄, 李晓松, 张凯选, 王金英. 2016. 浑善达克沙地光合/非光合植被及裸土光谱混合机理分析. 光谱学与光谱分析, 36(4): 1063-1068) [DOI: 10.3964/j.issn.1000-0593(2016)04-1063-06]

## Retrieving sparse non-photosynthetic vegetation fractional cover by Sentinel-1 and Sentinel-2

JI Cuicui<sup>1,2</sup>, LUO Yixia<sup>1</sup>, LI Xiaosong<sup>2,3</sup>, XU Jinhong<sup>1</sup>, YANG Xuemei<sup>4</sup>, CHEN Maolin<sup>1</sup>

1. School of Civil Engineering, Chongqing Jiaotong University, Chongqing 400074, China;

2. International Research Center of Big Data for Sustainable Development Goals, Beijing 100094, China;

3. Aerospace Information Research Institute, Chinese Academy of Sciences, Beijing 100094, China;

4. Tourism school, Lanzhou University of Arts and Science, Lanzhou 730000, China

**Abstract:** Quantitatively estimating the fractional cover of photosynthetic vegetation, non-photosynthetic vegetation (NPV), and bare soil plays an important role in establishing carbon dynamics models. Accurately obtaining the fractional cover of NPV provides the important information for the study of land desertification and vegetation transformation mechanisms. Although some progress has been made in obtaining NPV fractional cover ( $f_{NPV}$ ) by optical remote sensing in previous studies, many interfering factors and difficulties are still present. We will attempt to combine microwave and optical remote sensing information to obtain NPV fractional cover for further improving the accuracy of the fractional cover estimation of NPV.

In this study, we used Minqin County in Gansu Province as the research area, and we employed Sentinel-1B IW GRD and Sentinel-2A as data sources. The experiments employed the control variable method with the linear index model and the random forest regression (RFR) model to conduct the fractional cover estimation of NPV by using microwave and optical remote sensing data. Then, the estimated endmember fractions were validated with reference to fraction measurements. In addition, the Root Mean Square Error (RMSE) and Relative Root Mean Square Error (RMSE%) were employed as indicators to evaluate the inversion accuracy.

Results show that (1) using cooperative Sentinel-1 and Sentinel-2 remote sensing data to estimate the fractional cover of NPV can effectively improve the estimated accuracy compared with using Sentinel-2 data alone. (2) The RFR model is an effective method for the fractional cover estimation of sparse NPV, and its estimation accuracy is higher than that of the linear index model. The validation RMSE of the random forest model and the estimated  $f_{NPV}$  of the linear index model are 0.0149 and 0.0153, respectively. Obviously, the accuracy of  $f_{NPV}$  estimation increases by 1.4% when using the RFR model instead of the linear index model. (3) The VH and VV polarization bands of Sentinel-1 data can effectively detect the characteristics of NPV. Especially, VH band is more sensitive to NPV, and its estimation accuracy is improved by 5.1% compared with that of VV band. (4) The accuracy of  $f_{NPV}$  estimation can be improved when soil index is considered in each model, which illustrates that incorporating the soil characteristic information in the models is important for NPV extraction.

Overall, the combination of Sentinel-1 and Sentinel-2 remote sensing data can effectively improve the accuracy of the fractional cover estimation of NPV by employing the RFR model. VV and VH polarization modes are sensitive to NPV vegetation detection, especially VH polarization mode. The accuracy of NPV extraction can be further improved by considering the soil index, which reflects the soil characteristics. Therefore, the combination of microwave and optical remote sensing data is an effective method to improve the accuracy of  $f_{NPV}$  estimation. Incorporating polarization information with vegetation structure information and soil parameters with soil characteristic information is important for improving the accuracy of the fractional cover estimation of NPV.

**Key words:** non-photosynthetic vegetation, Sentinel-1, Sentinel-2, linear index model, random forest regression model, VV and VH polarization, Minqin County in Gansu province

**Supported by** National Key Research and Development Program (No. 2020YFC1511602); National Natural Science Foundation of China (No. 32060373, 41801394); Science and Technology Research Program of Chongqing Municipal Education Commission (No. KJQN202000746)