

基于U-Net++模型的多源数据高时空分辨率 积雪面积重建——以祁连山区为例

高博¹, 郝晓华^{2,3}, 和栋材¹, 赵琴², 纪文政², 任鸿瑞¹,
李弘毅^{2,3}, 刘艳^{4,5}, 朱平⁶

1. 太原理工大学 矿业工程学院, 太原 030024;

2. 中国科学院西北生态环境资源研究院甘肃省遥感重点实验室, 兰州 730000;

3. 中国科学院西北生态环境资源研究院黑河遥感试验研究站, 兰州 730000;

4. 中国气象局乌鲁木齐沙漠气象研究所, 乌鲁木齐 830002;

5. 新疆塔克拉玛干沙漠气象国家野外科学观测研究站, 乌鲁木齐 830002;

6. 成都信息工程大学 电子工程学院, 成都 610225

摘要: 明确山区季节性积雪的时空变化对山区水资源管理、水文过程和生态保护至关重要。高时空分辨率的积雪面积数据是监测山区积雪变化的重要手段, 然而, 由于现有积雪面积遥感产品受传感器性能的限制, 短时间和高空间分辨率无法兼得, 难以准确捕捉高度异质的山区斑状积雪的细微变化。为监测积雪面积的时空动态变化, 本研究选取祁连山北麓山区为研究对象, 利用MODIS和Landsat 8两种卫星数据, 构建了基于U-Net++网络多源数据融合获取高时空分辨率积雪面积的方法, 并使用高分辨率的Landsat数据和Sentinel数据对新发展的方法进行验证, 与融合高时空反射率数据间接重建积雪面积的STARFM和DMNet时空融合算法从不同角度进行对比验证。结果表明: (1) 基于U-Net++网络的30 m空间分辨率积雪面积重建算法有效恢复了山区积雪的细节特征。算法精度较高, 总体精度为90.4%, 制图精度为89.9%, 用户精度为88.4%, Kappa系数为0.80。重建结果鲁棒性较好, 在不同积雪覆盖度、不同地表下垫面和不同云量的条件下, 总体精度相差<3%, 且均高于88%。(2) 相较于STARFM和DMNet时空融合间接重建积雪面积的方法, 本算法总体精度提高了8.7%和5.2%, 制图精度提高了24.1%和18.4%, Kappa系数提高了0.20和0.12。总之, 本研究开发的基于U-Net++网络的30 m空间分辨率逐日积雪面积重建算法, 可以有效重建高精度高时空分辨率积雪面积数据, 对山区径流模拟、积雪水储量估算和灾害防治等具有重要意义。

关键词: 积雪面积, 深度学习, 多源融合, MODIS, Landsat

中图分类号: TP701/P2

引用格式: 高博, 郝晓华, 和栋材, 赵琴, 纪文政, 任鸿瑞, 李弘毅, 刘艳, 朱平. 2025. 基于U-Net++模型的多源数据高时空分辨率积雪面积重建——以祁连山区为例. 遥感学报, 29(4): 867-882

Gao B, Hao X H, He D C, Zhao Q, Ji W Z, Ren H R, Li H Y, Liu Y and Zhu P. 2025. Reconstruction of high spatiotemporal resolution snow cover remote sensing range data from multiple sources based on deep learning model: A case study in the Qilian Mountains. National Remote Sensing Bulletin, 29(4): 867-882 [DOI: 10.11834/jrs.20253541]

1 引言

积雪是冰冻圈最活跃的元素之一, 在维持地
球能量收支和调节地表水热平衡方面发挥着关键

作用 (Dietz 等, 2012)。积雪是水文、生态和气候
系统的重要组成部分 (王静 等, 2023), 也是干旱
和半干旱地区淡水的重要补给来源 (Li 等, 2019)。
积雪面积SCA (Snow Cover Area) 是描述积雪时空

收稿日期: 2023-12-26; 预印本: 2024-07-29

基金项目: 国家自然科学基金联合基金重点支持项目 (编号: U22A20564); 国家重点研发计划 (编号: 2022YFF0711702-05); 甘肃省自然科学基金重点支持项目 (编号: 24JRR082); 冰冻圈科学与冻土工程重点实验室自主部署项目 (编号: CSFSE-ZZ-2402, CSFSE-ZZ-2409)

第一作者简介: 高博, 研究方向为积雪遥感。E-mail: gaobo1125@link.tyut.edu.cn

通信作者简介: 郝晓华, 研究方向为积雪遥感、积雪与气候变化。E-mail: haoxh@lzb.ac.cn

分布的重要积雪参数之一,也是部分气候模式、水文模型的重要输入参数。准确监测积雪的分布变化,对区域水资源管理和气候变化等研究具有重要作用(Beria等,2018;Choi等,2010)。

山区积雪是影响区域能量平衡、水循环和水利用的关键因素。在中国干旱半干旱山区,75%以上的河水都源自积雪融化的径流(He等,2017;Wang等,2014)。在地形复杂的山区,积雪分布具有高度异质性,斑状积雪分布广泛。遥感是获取山区积雪信息的有效手段(李新等,2020)。高空间分辨率的积雪面积数据可以精确描绘山区积雪的分布格局。然而,现有的积雪面积遥感产品存在其固有局限性。广泛应用于全球雪盖监测的MOD10A1产品,其相对较粗的空间分辨率(500 m)难以精确反映山区积雪的空间分布细节;而空间分辨率更高的Landsat系列(30 m),其16 d的重访周期无法有效捕捉积雪消融变化的时相特征。因此,开发兼具高时间分辨率和高空间分辨率的积雪面积数据,对于改善地形复杂的山区积雪监测精度尤为重要(Han等,2019)。

目前,为获取高时空分辨率的积雪面积数据,常基于MODIS逐日积雪面积产品,将500 m的MODIS数据降尺度为30 m分辨率。常用于积雪面积降尺度的算法可分为3类。首先是以积雪面积比例为基础数据的物理经验模型降尺度算法。例如:Walters等(2014)通过山区地形差异,结合30 m DEM数据模拟融雪期MODIS积雪面积比例数据在亚像元30 m尺度积雪的分布;Li等(2015)使用空气温度和太阳辐射驱动的经验融雪模型,模拟MODIS积雪面积比例数据在亚像元30 m尺度积雪的消融,保留亚像元未消融的积雪,从而得到30 m积雪面积数据。但此方法依赖于MODIS产品的准确性,难以应对突然的降雪事件,导致获得的30 m积雪面积数据精度较低。其次是基于多特征变量的机器学习降尺度算法,Rittger等(2021)基于随机森林模型,输入MODIS反射率及环境地形等12个特征变量,建立多特征和30 m分辨率积雪产品之间的映射关系,重建了30 m积雪面积。但受MODIS特征变量影响,重建的积雪面积存在较为严重的伪影现象,边缘完整性部分缺失。最后是基于多时相遥感数据的时空融合降尺度算法,Liu和Zhang(2022)基于时空融合ESTARFM算法,先重建高分辨率的反射率数据,再通过积雪识别算法重建

积雪面积,但受到ESTARFM算法本身限制,在面對积雪等快速变化的对象,会产生模糊变化的边界(杨广奇等,2022)。Wang等(2022)使用SMPG时空融合算法,两次重建高分辨率反射率数据,再进行积雪识别重建高分辨率积雪面积。这类方法通过重建反射率再识别生成积雪面积会带来不可避免的累计误差。

基于物理经验模型的降尺度算法,理论严谨,但输入的辅助参量数据不确定性因素较多,且依赖于MODIS积雪面积产品的准确性。在山区积雪变化不均匀的区域,如受到风吹雪等不确定降雪事件的影响,重建积雪面积的准确度会降低。基于机器学习的降尺度算法,在进行特征融合重建积雪面积时,受MODIS特征的影响,重建积雪面积边缘完整性欠佳。基于时空融合的降尺度算法,需先重建反射率或遥感指数数据,再通过积雪识别算法重建积雪面积,会不可避免的产生累计误差。随着深度学习在遥感领域广泛应用(Li等,2023),深度学习超分辨率被引入到遥感空间降尺度研究领域。重建高时空分辨率积雪面积,可看作判断粗分辨率影像亚像元尺度网格上是否为雪,在深度学习中对图像像素的分类任务称为语义分割(田萱等,2019)。U-Net++网络为语义分割U-Net网络的一种变体,在U-Net的基础上改进了跳跃连接结构,缩小了语义差距,能高效融合不同尺度的语义信息。在U-Net++网络解码器部分添加注意力机制,能让有限的训练资源获取更多有效信息(张宸嘉等,2021),使网络更具鲁棒性。受时空融合算法的启发,使用不同传感器的多时相数据作为网络融合的特征输入,可以有效避免仅使用单一遥感影像所带来的伪影问题。以30 m分辨率积雪面积数据直接作为网络分类的语义标签,建立其与多时相遥感数据之间的映射关系,可以避免时空融合算法通过重建反射率再识别积雪所带来的累计误差。

鉴于现有积雪面积数据及其重建技术在复杂积雪条件下的局限性,尤其在海拔、地形多变的山区精确获取积雪分布信息面临挑战。本研究拟以祁连山北麓山区为研究区,通过时间分辨率为1 d的MODIS和空间分辨率30 m的Landsat数据,构建一种基于U-Net++网络直接重建山区逐日30 m积雪面积的算法,并利用Landsat和Sentinel数据从不同积雪覆盖度和不同地表覆盖对该算法进行验

证，同时与两种间接重建积雪面积的时空融合算法进行对比以获取最优的重建算法，为祁连山区的水资源管理、积雪生态过程等研究提供高时空分辨率、高精度的积雪面积参考。

2 研究区与数据

2.1 研究区概况

研究区位于亚洲高山区东北部河西走廊地区各内陆河流域出山口以上的祁连山北麓山区（93.0°E—103.5°E，37.1°N—40.0°N），面积约为73901 km²，海拔高度1719—5732 m，属于中国西北干旱半干旱荒漠地区。积雪分布为稳定季节性高山积雪。祁连山脉是河西走廊三大内陆河流的重要水源涵养区（Bourque和Mir，2012），上游有限的冰雪融水是中下游农业和生态用水的主要来源，由于降水不确定性大、温度升高等气候变化，导致冰川退缩、积雪消融提前，加剧了该地区的生态问题。

2.2 数据及预处理

2.2.1 MOD09GA

MOD09GA地表反射率产品（MOD09GA.061）是本研究的主要输入之一，数据来自NASA（<https://lpdaac.usgs.gov> [2023-12-26]），研究使用可见光红波段、可见光绿波段、近红外波段、短红外波段和数据QA质量评估波段，时间分辨率为1 d，空间分辨率为500 m。利用反射率波段计算归一化积雪指数NDSI（Normalized Difference Snow Index），归一化植被指数NDVI（Normalized Difference Vegetation Index），归一化森林积雪指数NDFS（Normalized Difference Forest Snow Index）。具体计算公式如下：

$$\text{NDSI} = \frac{\text{Green} - \text{SWIR}}{\text{Green} + \text{SWIR}} \quad (1)$$

$$\text{NDVI} = \frac{\text{NIR} - \text{Red}}{\text{NIR} + \text{Red}} \quad (2)$$

$$\text{NDFS} = \frac{\text{NIR} - \text{SWIR}}{\text{NIR} + \text{SWIR}} \quad (3)$$

式中，Green为可见光绿波段，SWIR为短红外波段，NIR为近红外波段，Red为可见光红波段。并使用质量评估波段QA生成云掩膜数据。

2.2.2 Landsat 8 OLI地表反射率数据

Landsat 8 OLI地表反射率数据来自USGS

（<https://www.usgs.gov> [2023-12-26]），选取可见光红波段、可见光绿波段、近红外波段、短红外波段和QA质量评估波段，时间分辨率为16 d，空间分辨率为30 m。利用2.2.1中的公式，计算得到基于Landsat 8 OLI的NDSI、NDVI和NDFS等3个归一化遥感指数，通过质量控制波段QA生成云掩膜数据。

2.2.3 Sentinel-2 MSI数据

Sentinel-2 MSI地表反射率数据由欧洲航天局（<https://dataspace.copernicus.eu> [2023-12-26]）提供，选取可见光红波段、可见光绿波段、近红外波段和短红外波段，通过重采样与积雪识别算法得到30 m空间分辨率积雪面积数据，用作重建积雪面积的独立验证数据。

2.2.4 训练样本

本研究使用MOD09GA和Landsat 8 OLI地表反射率制作包含两个时刻（分别用 t_1 和 t_2 表示）的影像组作为训练数据样本。为减少云像元对实验的影响，同时也为保证数据样本的可靠性，本研究选取Landsat 8 OLI地表反射率影像原则如下：（1） t_1 时刻影像积雪覆盖度<10%， t_2 时刻影像积雪覆盖度在30%—80%，以确保网络检测到积雪变化；（2） t_1 时刻影像云覆盖度<5%， t_2 时刻影像云覆盖度<10%，以保证训练样本充足。由于研究区云具有较强的移动性，MOD09GA与Landsat 8 OLI地表反射率影像的云量及云位置存在差异，本研究对两时刻的影像同时使用对应的云掩膜数据标注云像元，部分影像中标注为云的像元>10%；（3）影像空间分布对研究区域全覆盖。

利用最近邻插值法将 t_1 和 t_2 时刻的MOD09GA影像重采样到与Landsat 8 OLI地表反射率影像同一空间分辨率（30 m），并使影像像元匹配。使用改进的SNOMAP积雪识别算法（Wang等，2018；Chen等，2020）对 t_2 时刻Landsat 8 OLI地表反射率影像进行处理，生成30 m积雪面积影像，作为网络训练的真值标签。最终在2013年到2020年积雪期共选取101组影像数据，将影像裁剪为256×256大小的影像切片，去除全为云的影像切片，训练样本切片共有80859个，以4:1的比例随机划分为训练集和验证集，影像空间时间分布如图1所示。




图 1 重建积雪面积算法的训练影像在不同空间位置 and 不同年份的数量分布
Fig. 1 Distribution of the number of training images for snow area reconstruction algorithm at different spatial positions and different years

2.2.5 验证样本

选取 Landsat 8 OLI 地表反射率和 Sentinel-2 MSI 地表反射率作为检验模型的测试集数据和独立验证数据。网络以 t_1 、 t_2 时刻 MOD09GA 和 t_1 时刻 Landsat 8 OLI 地表反射率数据作为输入，重建 t_2 时刻高分辨率积雪面积数据。将 t_2 时刻无云影像（云

量<5%）的 Landsat 8 OLI 地表反射率和 Sentinel-2 MSI 地表反射率生成的积雪面积数据作为真实数据对重建的积雪面积数据进行验证。为验证网络对积雪变化的检测能力，选取 t_1 、 t_2 时刻积雪覆盖度有显著变化的影像， t_2 时刻积雪覆盖度大于 t_1 时刻。选取验证数据如表 1 所示。


表 1 Landsat 8 OLI 和 Sentinel-2 MSI 数据验证影像对信息统计表
Table 1 Statistical table of verification image pair information from Landsat 8 OLI and Sentinel-2 MSI data

数据类型	影像日期	位置信息	积雪覆盖度/%
Landsat 8 OLI	2015-12-20	131034	26.37
	2014-12-08	132034	17.67
	2018-12-10	133033	47.06
	2018-11-08	133034	66.82
	2016-01-26	134033	47.11
	2019-02-03	134034	51.47
	2019-02-10	135033	72.49
	2017-11-03	135034	31.38
	2018-12-15	136032	27.95
	2016-01-24	136033	67.50
	2018-02-05	137032	36.16
	2017-01-17	137033	39.18
Sentinel-2 MSI	2022-02-02	T46SGH/T46SGJ/T47SKD/T47SKD/T47SLC/T47SLD	30.96/44.37/24.52/46.6/ 18.46/ 25.63
	2022-02-05	T46SGJ/T47SKD/T47SLD	26.62/31.72/38.98
	2022-02-07	T46SGJ/T47SKD/T47SLD/ T47SMC/ T47SMD	54.72/61.48/67.30/71.45/79.86
	2022-02-15	T46SFJ/T46SGH/T46SGJ/ T47SKC/T47SKD/T47SLD	22.55/58.39/49.35/62.15/ 53.19/60.74
	2022-02-20	T46SFJ/T46TFK/T47SKD/ T47SLD	50.35/28.22/68.13/71.7
	2022-03-02	T46SEJ/T46SGH/T46SGJ/ T47SKD	29.35/44.56/54.67/51.57
	2022-03-04	T46SGH/T46SGJ/T47SKD/ T47SKC/T47SLC/T47SLD	61.98/44.35/55.14/45.43/35.19/ 30.59

3 研究方法


本研究使用U-Net++ (Zhou 等, 2018) 深度学习网络重建高时空分辨率积雪面积。如图2 (a) 所示, 在训练阶段, 首先对 t_1 时刻的Landsat 8 OLI地表反射率数据和 t_1 、 t_2 两时刻MOD09GA反射率进行重采样并使像元配准, 分别计算3张影像的NDSI、NDFSI和NDVI遥感指数, 其中 L'_1 代表 t_1 时刻的Landsat 8 OLI获取的3个遥感指数数组, M'_1 和 M'_2 分别代表 t_1 、 t_2 两时刻MOD09GA获取的3个遥感指数数组; 其次是特征值选取, 本研究选择 L'_1 和 $M'_1-M'_2$ 作为特征值, 其中 $M'_1-M'_2$ 表示

MOD09GA在 t_1 、 t_2 时刻的遥感指数差; 第三步将 t_2 时刻的Landsat 8 OLI利用改进的SNOMAP算法 (Wang 等, 2018; Chen 等, 2020) 生成积雪面积数据作为像元的语义分类标签; 第四步将特征值作为网络输入, 真值作为网络标签对网络进行训练。如图2 (b) 所示, 在预测阶段重新选取 t_1 时刻无云MOD09GA和Landsat 8 OLI地表反射率影像, 并分别计算影像NDSI、NDFSI和NDVI遥感指数数组, 选取预测当天 t_n 时刻MOD09GA影像并计算3个遥感指数数据, 将特征值输入到训练好的网络中预测得到 t_n 时刻积雪面积, 并进行精度评估。



(a) 训练阶段

(a) Training stage



(b) 预测阶段

(b) Prediction stage

图2 基于U-Net++深度学习网络重建积雪面积的技术路线图

Fig. 2 Technology flowchart of reconstructing snow area based on U-Net++ deep learning network

3.1 基于U-Net++深度学习网络重建积雪面积

3.1.1 U-Net++网络结构

U-Net++网络 (Zhou 等, 2018) 常用于语义分割, 是U-Net网络的一种改进网络。网络结构可分为编码器、解码器和跳跃连接3部分, 编码器通过降低特征图分辨率, 增加通道数来捕捉不同尺度的语义信息。解码器则是将提取的语义信息重新恢复并映射到原有影像空间。U-Net++网络在U-Net网络编码器子网络与解码器子网络的跳跃路径之间嵌套密集卷积块, 将不同尺度的语义特征聚合在

解码器子网络, 填补了编码器和解码器特征图之间语义差距, 改善了网络梯度传播过程。本研究在U-Net++网络的基础上在解码器部分引入scSE (Spatial and Channel Squeeze and Excitation) 注意力机制模块 (Roy 等, 2019)。注意力机制可以获得不同特征之间的重要性, 通过聚焦高权重的重要信息, 忽略低权重的信息, 使网络能在特征图上深度挖掘对训练目标有用的关键信息, 使模型更具鲁棒性 (张宸嘉 等, 2021)。本研究U-Net++网络结构如图3所示。




图3 本研究使用的U-Net++网络

Fig. 3 U-Net++ network used in this study

3.1.2 训练与参数设置

基于MOD09GA反射率计算 t_2 时刻3个遥感指数 (NDSI、NDVI和NDFS) 分别与 t_1 时刻的3个遥感指数作差, 得到3个残差特征。MOD09GA指数差值的残差影像提供两时刻的时间变化特征。 t_1 时刻Landsat 8 OLI地表反射率计算的3个遥感指数数据作为提供空间细节的3个特征。将6个特征共同作为U-Net++网络的输入特征。通过积雪识别算法和 t_2 时刻的Landsat 8 OLI地表反射率获取的 t_2 时刻积雪面积数据作为6个特征对应的真值语义标签。使用MOD09GA与Landsat 8 OLI地表反射率的云掩膜数据, 对6个特征数据和真值数据添加云掩膜。真值语义标签分为是雪、非雪和无效值3类。

采用交叉熵损失函数 L_{CE} 和Dice Loss损失函数 L_{Dice} (Drozdal 等, 2016) 相结合的复合损失函数作为网络的损失函数。交叉熵损失函数是卷积神经网络

语义分割最常用的损失函数, 其基于概率来度量预测概率分布和真实概率分布之间的差异, 数值越小两个分布之间差异越小, 准确率越高。具体计算公式如下:

$$L_{CE} = -\frac{1}{N} \sum_{i=1}^C \sum_{c=1}^C y_{ic} \ln x_{ic} \quad (4)$$

式中, N 为样本数量, C 为分类的数量, y_{ic} 为第 c 类第 i 个真实值为0或1, x_{ic} 为预测概率分布范围为0到1。Dice Loss损失函数是常用于图像分割的损失函数, Dice系数通过计算预测概率和真实值的交集之比来度量两者相似度, 值越大, 预测值与真实值越相似, Dice Loss损失函数计算公式如下:

$$L_{Dice} = 1 - \frac{2}{C} \sum_{c=1}^C \frac{\sum_i y_{ic} x_{ic} + \varepsilon}{\sum_i y_{ic} + \sum_i x_{ic} + \varepsilon} \quad (5)$$

式中, C 为分类的数量, y_{ic} 为第 c 类第 i 个真实值为0或1, x_{ic} 为预测概率分布范围为0到1, ε 为一正

数用于数值稳定性防止分母为0。模型所使用的损失函数为 $L=L_{CE}+L_{Dice}$ 。

将输入特征与真值影像裁剪为 256×256 像元大小，使用 ResNet-101 网络（Demir 等，2019）作为编码器子网络主干，网络深度为 5，经过 5 次下采样获取不同尺度的特征图。优化器选择 Adam 优化器，初始学习速率为 0.001，每 10 个 epoch 学习速率下降为原学习速率的十分之一，训练迭代次数设置为 40。

3.1.3 重建积雪面积

重建阶段，前一时刻 t_1 影像对选取云量 <5% 的无云 MOD09GA 与 Landsat 8 OLI 地表反射率影像，后一时刻 t_2 影像为当天 MOD09GA 影像，对影像进行云掩膜处理。将预测特征输入到训练好的网络中，网络输出重建的 t_2 时刻 30 m 积雪面积后，进行云掩膜处理，最终得到 t_2 时刻积雪面积重建结果。

3.2 验证方法

本研究使用两种方法对 U-Net++ 网络重建的积雪面积数据进行验证。第一种是直接验证，将 Landsat 8 OLI 和 Sentinel-2 MSI 的积雪面积作为验证数据，结合混淆矩阵方法评估 U-Net++ 网络重建的积雪面积数据的准确性；第二种是间接验证对比，利用基于权重的 STARFM 时空融合算法和基于深度学习的 DMNet 网络时空融合算法获取反射率数据，间接生成积雪面积。与 U-Net++ 网络重建的积雪面积数据进行间接比较。

3.2.1 直接验证

利用二进制混淆矩阵（Binary Confusion Matrix）评估本研究重建积雪面积的准确性。预测积雪面积与真实积雪面积对应像元有以下 4 种结果：SS 表示预测像元为雪且真实像元为雪；NN 表示预测像元为非雪且真实像元为非雪；NS 表示预测像元为雪而真实像元为非雪；SN 表示预测像元为非雪而真实像元为雪。

本研究使用了 5 种评估指标，分别是总体精度 OA（Overall Accuracy）、生产者精度 PA（Producer's Accuracy）、使用者精度 UA（User's Accuracy）、Kappa 系数和 Bias。其中，OA 表示正确识别的像元数与总像元数的比值；PA 表示正确识别为雪的像元数与实际积雪像元数的比值，与漏分误差 OE 对

应， $OE=1-PA$ ；UA 表示正确识别为雪的像元数与总识别为雪的像元数的比值，与错分误差 CE 对应， $CE=1-UA$ ；Kappa 系数用来衡量重建积雪面积与真实积雪面积两者之间的一致性；Bias 是对重建积雪面积高低估的度量，当 $Bias>1$ 表示高估， <1 表示低估。具体计算公式如下：

$$OA = \frac{SS + NN}{SS + NS + SN + NN} \times 100 \quad (6)$$

$$PA = \frac{SS}{SS + SN} \times 100 \quad (7)$$

$$UA = \frac{SS}{SS + NS} \times 100 \quad (8)$$

Kappa =

$$\frac{(SS + NS)(SS + SN) + (NN + NS)(NN + SN)}{(SS + SN + NS + NN)^2} \quad (9)$$

$$Bias = \frac{SS + NS}{SS + SN} = \frac{PA}{UA} \quad (10)$$

3.2.2 方法比较

选取同样使用 2 个时刻影像信息重建高时空分辨率影像的 STARFM 时空融合算法和 DMNet 网络时空融合算法作为本研究的对比方法。

(1) 基于 STARFM 算法重建积雪面积。STARFM 算法是基于权重的时空融合算法（Gao 等，2006），利用 STARFM 时空融合算法间接获取积雪面积数据，与 U-Net++ 网络重建的同一时刻积雪面积数据进行比较。STARFM 时空融合算法使用 t_1 时刻的一对 MODIS-Landsat 低、高分辨率影像对和 t_2 时刻的 MODIS 低分辨率影像作为输入，预测 t_2 时刻高分辨率影像反射率。通过加入滑动窗口引入邻近相似像元的信息，使用光谱差值、时间差值和空间距离来计算相似像元对中心像元的贡献权重， t_2 时刻窗口中心的像元反射率则表示为

$$L(x_{w/2}, y_{w/2}, t_2) = \sum_{i=1}^w \sum_{j=1}^w \sum_{k=1}^n W_{ijk} * \quad (11)$$

$$(M(x_i, y_j, t_2) + L(x_i, y_j, t_1) - M(x_i, y_j, t_1))$$

式中， w 为窗口大小， n 为窗口内邻近相似像元的个数， W_{ijk} 为对相似像元加权后的权重函数， $M(x_i, y_j, t_2)$ 为窗口 (x_i, y_j) 位置的相似像元在 t_2 时刻的 MODIS 反射率， $L(x_i, y_j, t_1)$ 和 $M(x_i, y_j, t_1)$ 为 t_1 时刻对应位置 Landsat 和 MODIS 的反射率。使用该方法重建 t_2 时刻高分辨率反射率，再使用积雪识别算法将反射率识别为积雪面积。

(2) 基于 DMNet 网络重建积雪面积。DMNet

网络是基于深度学习多尺度卷积的时空融合算法 (Li 等, 2020), 利用 DMNet 网络结构间接获取积雪面积数据, 与 U-Net++ 网络预测的同一时刻积雪面积数据进行比较。输入 t_2 时刻与 t_1 时刻 MODIS 反射率影像的差值影像, 作为时间变化特征; 输入 t_1 时刻的 Landsat 8 OLI 反射率影像, 作为空间细节特征。DMNet 网络使用两种不同的多尺度特征提取机制, 并添加 3 个跳跃连接来增加网络捕捉特征信息的能力。后通过 1×1 卷积层将输出特征映射通道控制为 1, 以匹配单波段反射率影像。使用忽略云干扰的损失函数, 将 t_1 时刻和 t_2 时刻的 MOD09 GA 和 Landsat 8 OLI 地表反射率标注为云的像元同时掩膜处理, 具体公式如下:

$$MC - MSE = \frac{1}{N} \sum_{h=1}^H \sum_{w=1}^W \begin{cases} (y_{h,w} - \hat{y}_{h,w})^2, y_{h,w} & \text{无云} \\ (y_{h,w} - y_{h,w})^2, y_{h,w} & \text{有云} \end{cases} \quad (12)$$

式中, N 为有效像元个数, H, W 为行列数, h, w 为像元所在位置, y 为 t_2 时刻 Landsat 8 OLI 反射率真值, $\hat{y}$ 为网络预测值。当像元被两时刻任一景影像标注为云时, 损失函数值为 0, 不参与向后传播对模型优化的过程。在训练时将影像裁剪为 256×256 像元大小, 真值为 t_2 时刻单波段 Landsat 8 OLI 地表反射率。优化器选择 Adam 优化器, 初始学习速率为 0.001, 每 10 个 epoch 学习速率下降为原学习速率的十分之一, 训练迭代次数设置为 60。与 STARFM 算法相同, DMNet 网络同样先重建 t_2 时刻高分辨率反射率, 再利用积雪识别算法将反射率识别为积雪面积。

4 结果与分析

4.1 直接验证结果

4.1.1 总体验证

使用 Landsat 8 OLI 地表反射率影像生成的积雪面积和 Sentinel-2 MSI 地表反射率影像生成的积雪面积对 U-Net++ 网络重建的积雪面积进行精度验证。验证结果如表 2 所示, 可见: 使用 Landsat 8 OLI 数据验证 OA 为 90.85%, Sentinel-2 MSI 数据验证 OA 为 89.66%, 总体精度较高, 恢复效果较好; PA 分别 90.19% 和 89.44%, 重建积雪面积的漏分误差在 10% 左右, 漏分的雪较少; UA 分别为 88.64% 和 87.96%, 重建积雪面积的错分误差在 12% 左右, 效果较好; Kappa 系数在 0.8 左右, 整体上重建积

雪面积与真实积雪面积几乎完全一致, 具有较高的一致性; 总体 Bias 为 1.017, 相较于真实积雪面积, 重建积雪面积总体略微高估。总之, Sentinel-2 MSI 数据验证结果相较于 Landsat 8 OLI 数据验证结果略差, 但结果相差不大 (<2%)。

表 2 验证影像积雪面积重建的验证结果

Table 2 Verification results of snow area reconstruction in the verification image

数据类型	OA/%	PA/%	UA/%	Kappa	Bias
Landsat 8 OLI	90.85	90.19	88.64	0.814	1.017
Sentinel-2 MSI	89.66	89.44	87.96	0.791	1.016
总体	90.36	89.87	88.35	0.804	1.017

4.1.2 不同积雪覆盖度的验证

为对比评估 U-Net++ 在不同积雪覆盖度重建积雪面积的精度, 依据积雪覆盖度 <30%、30%—50% 和 >50% 将验证数据划分为低覆盖、中覆盖和高覆盖 3 类, 以验证模型对不同积雪覆盖度积雪面积的重建能力。如表 3 所示, 3 种不同积雪覆盖度影像的重建效果均较好, 总体 OA 为 90.58%、91.81% 和 89.26%。在中高覆盖重建的积雪面积 PA 和 UA 较高, 是因为在积雪覆盖度较高的影像中稳定积雪分布较广泛, 模型的重建能力较好。在低覆盖样本中, 可能是非雪像元较多导致 OA 较高。但 PA 和 UA 较差, 这与低覆盖度地区积雪分布不均匀且不稳定有关, 相较而言, 积雪面积重建效果较差。中覆盖度地区验证结果优于高覆盖度地区, 这可能与训练样本的选取有关。训练样本高中低覆盖度占比约为 2:3:2, 中覆盖度的训练影像数量较多可能导致其验证结果优于高覆盖度。

表 3 不同积雪覆盖度下积雪面积重建的验证结果

Table 3 Verification results of snow area reconstruction under different snow coverage

数据类型	积雪覆盖	OA/%	PA/%	UA/%	Kappa	Bias
Landsat 8 OLI	低覆盖	89.95	81.10	78.03	0.729	1.039
	中覆盖	92.64	91.26	90.26	0.847	1.011
	高覆盖	89.26	92.01	90.55	0.773	1.016
Sentinel-2 MSI	低覆盖	91.54	79.54	85.65	0.769	0.929
	中覆盖	89.98	89.85	86.51	0.794	1.038
	高覆盖	88.61	92.02	89.31	0.761	1.030
总体	低覆盖	90.58	80.47	80.92	0.744	0.994
	中覆盖	91.81	90.81	89.02	0.830	1.021
	高覆盖	89.26	92.01	90.55	0.773	1.016

4.1.3 不同地表覆盖的验证

为验证不同地表覆盖下重建积雪面积的精度，验证区根据 CGLS-LC100 数据 (<https://land.copernicus.eu/global/products/lc> [2023-12-26]) 划分为裸土区与植被区。验证结果见表 4，可以看出总体验证结果中裸土区的 OA 较植被区高 2.15%，分别为 91.20% 和 89.05%；裸土区的 PA 较植被区高 1.82%，分别为 90.73% 和 88.91%；裸土区的 UA 较植被区高 0.73%，分别为 88.60% 和 87.87%；裸土区的 Kappa 系数较植被区高 0.04，分别为 0.820 和 0.780，裸土区与植被区重建的积雪面积效果均较好。总之，裸土区的积雪面积重建效果优于植被区，这可能与植被区较裸土区的混合像元问题严重有关，但裸土区与植被区重建效果相差不大，表明不同土地覆盖下模型都有较好的适用性。

表 4 不同地表覆盖下积雪面积重建的验证结果

Table 4 Verification results of snow cover reconstruction under different land cover

数据类型	地表覆盖	OA/%	PA/%	UA/%	Kappa	Bias
Landsat 8 OLI	裸土区	91.69	91.04	89.32	0.829	1.019
	植被区	89.91	89.91	87.87	0.796	1.023
Sentinel-2 MSI	裸土区	90.63	90.56	88.01	0.810	1.029
	植被区	87.17	87.00	87.86	0.743	0.990
总体	裸土区	91.20	90.73	88.60	0.820	1.023
	植被区	89.05	88.91	87.87	0.780	1.011

4.2 3种积雪面积重建方法对比

为对比不同方法重建积雪面积的效果，使用研究区域全覆盖的 12 景 Landsat 8 OLI 地表反射率生成的积雪面积数据作为方法对比的验证数据。

4.2.1 总体验证

对比基于 STARFM 算法、基于 DMNet 网络与基于 U-Net++ 网络 3 种方法重建的积雪面积验证结果 (图 4 和图 5)，可以发现基于 U-Net++ 网络直接重建的积雪面积整体精度优于其他两种间接重建的积雪面积，并且在不同空间区域展现了良好的稳定性。如图 4 所示，在不同验证影像中基于 U-Net++ 网络直接重建积雪面积的 OA 均更高，说明该方法具有较高的稳定性。而基于 STARFM 算法和基于 DMNet 网络间接重建的积雪面积 OA 较差，并且在不同影像中差别较大，说明重建的稳定性较差。图 5 (a) 中基于 U-Net++ 网络的 OA 分布更为紧凑也表明其较强的稳定性。图 5 (b) 中显示基于 U-Net++ 网络的 PA 比基于 STARFM 算法和基于 DMNet 网络高 24.1% 和 18.4%，说明 U-Net++ 网络有更低的漏分误差，能够正确重建更多的雪。然而，U-Net++ 网络的 UA 指标分别低其他 2 种方法 0.2% 和 3.6% (图 5 (c))，这是因为 U-Net++ 重建了更多的雪，导致错分的雪较多。此外，U-Net++ 网络重建的积雪面积 Kappa 值也更优 (图 5 (d))。




图 4 不同验证影像中 3 种方法的 OA 对比柱状图

Fig. 4 Histogram of OA comparison of the three methods in different validation images





图5 不同验证影像中3种方法的OA、PA、UA和Kappa统计箱线图

Fig. 5 Boxplots of OA, PA, UA and Kappa statistics for the three methods in different validation images

4.2.2 不同积雪覆盖度对比

在低、中和高3种不同积雪覆盖度影像中分别选取无云区域 (50 km×50 km) 重建积雪面积, 积雪占比为 22%、33% 和 67%。重建的积雪面积和验证结果如图6所示, 发现在低覆盖度区域, 基于U-Net++网络重建的积雪面积PA比基于STARFM算法和基于DMNet网络重建积雪面积方法高32.6%和25.8%。基于STARFM算法和基于DMNet网络重建的积雪面积在区域左下方丢失了较多的雪, 存在较为严重的漏分。基于U-Net++网络重建的积雪面积虽然存在较多错分的雪, 但漏分的雪较少, 能更有效的监测到低覆盖区域积雪的变化。在中覆盖度区域, 基于U-Net++网络的积雪面积在区域下方斑状的积雪处重建效果较好, 优于其他两种

算法重建的积雪面积; 基于STARFM算法的积雪面积在区域下方的斑状积雪处存在较多错分, 在区域左上部分大块积雪的边缘处漏分较严重; 基于DMNet网络的积雪面积则在斑状积雪处的漏分较严重, 在大面积积雪边缘丢失了部分积雪。在高覆盖度区域, 基于STARFM算法和基于DMNet网络的积雪面积在区域左下部分丢失了大量的雪。此外, 基于STARFM算法的积雪面积在中部丢失了大量的雪, 基于DMNet网络的积雪面积在区域左上部存在较多错分的雪。基于U-Net++网络的积雪面积在高覆盖度区对大面积积雪的重建效果较好, 漏分与错分的雪都较少。综上, 基于U-Net++网络的积雪面积在不同覆盖度区域重建的积雪准确度均优于基于STARFM算法和基于DMNet网络重建的积雪面积。






图6 不同积雪覆盖度下3种积雪面积重建方法对比
Fig. 6 Comparison of three snow area reconstruction methods under different snow coverages

4.2.3 不同地表覆盖对比

在裸土区和植被区域选取不同地表覆盖的两个区域 (50 km×50 km) 重建积雪面积, 重建的积雪面积和验证结果如图7所示。可以发现, 在裸土区域, 基于STARFM算法和基于DMNet网络重建的积雪面积均丢失了大量的积雪, 存在较为严重的漏分。基于U-Net++网络的积雪面积在区域中部预测到了更多的雪, 但错分的雪较多, 这可能与积雪分布过于驳杂有关。在植被区域, 基于STARFM

算法的积雪面积存在较为严重的漏分, 在区域中部丢失了大量细碎的积雪, 基于DMNet网络的积雪面积在整个区域内存在大量错分的积雪, 尤其是斑状积雪周边, 错分问题较为严重。基于U-Net++网络的积雪面积则较好地重建了积雪的分布, 错分与漏分的雪都相对较少。综上, 基于U-Net++网络重建的积雪面积在不同的地表覆盖恢复积雪的效果较好, 稳定性强。




图7 不同土地覆盖下3种积雪面积重建方法对比
Fig. 7 Comparison of three snow area reconstruction methods under different land covers

4.3 云覆盖对模型的影响分析

选取5景不同云量覆盖的 Landsat 8 OLI 影像作为验证数据，评估云量对模型的影响。影像验证结果如表 5 所示。在不同云量覆盖下验证结果准确

度都较高，OA 均在 90% 以上，重建积雪面积数据与真实积雪面积数据几乎完全一致。在相同位置不同云量覆盖下，验证数据 OA 相差<5%，表明云量对模型积雪面积重建影响较小。

表 5 不同云覆盖度下 Landsat 8 OLI 影像积雪面积重建的验证结果

Table 5 Verification results of snow area reconstruction in Landsat 8 OLI images under different cloud cover conditions

位置信息	云覆盖/%	OA/%	PA/%	UA/%	Kappa	Bias
135034	35.68	93.56	95.47	93.72	0.866	1.018
135034	41.41	97.54	93.95	92.31	0.9163	1.017
135034	63.51	95.43	95.54	95.52	0.907	1.00
134034	68.18	96.38	90.75	98.79	0.918	0.918
134034	87.14	93.46	92.83	92.96	0.868	0.998

4.4 时间间隔对模型的影响分析

选取相同位置处 5 景无云 Sentinel-2 MSI 影像，与时间间隔为 16 d 相同位置 5 景 Landsat 8 OLI 影像作为验证数据。验证结果如表 6 所示，在 Sentinel-2 MSI 验证结果中，时间间隔 14 d 的验证数据结果略低于间隔 12 d 与间隔 22 d 验证数据，不同时间间

隔验证数据 OA 相差<6%。在 Landsat 8 OLI 验证数据中，最优验证结果为间隔 80 d，不同时间间隔的 OA 相差<5%。在不同时间间隔下，模型预测的积雪面积准确度并没有因为时间间隔的变化而产生显著变化趋势。

表 6 不同时间间隔下积雪面积重建的验证结果

Table 6 Verification results of snow area reconstruction under different time intervals

数据类型	时间间隔/d	OA/%	PA/%	UA/%	Kappa	Bias
Sentinel-2 MSI	9	91.54	89.14	92.13	0.829	0.968
	12	88.68	79.56	82.76	0.730	0.961
	14	86.68	84.55	92.90	0.727	0.910
	22	88.34	87.02	90.38	0.767	0.963
	27	85.99	87.19	91.67	0.688	0.951
Landsat 8 OLI	16	91.93	88.88	89.46	0.827	0.994
	32	91.77	87.73	88.22	0.817	0.994
	48	89.78	89.16	88.97	0.795	1.002
	64	90.71	92.17	96.01	0.729	0.960
	80	93.56	95.47	93.72	0.866	1.018

4.5 NDVI 与 NDFS I 对模型作用分析

使用 NDSI、NDVI 和 NDFS I 3 个遥感指数作为网络输入重建的积雪面积结果优于输入单一 NDSI 遥感指数重建的积雪面积结果。NDSI 为积雪识别算法的重要光谱特征，但在 NDVI 较高的林区，NDSI 阈值较低（Wang 等，2018）。高伟强（2023）在使用机器学习方法制备积雪面积比例时引入 NDVI 和 NDFS I 来提高植被区域制图精度。在本研究验证数据中植被区占比多达 42%，为提高模型预测

准确性，选取 NDVI、NDFS I 和 NDSI 作为网络输入特征训练模型。为求证 NDVI 和 NDFS I 指数对模型精度的影响，使用单一的 NDSI 遥感指数训练模型，并与 3 个遥感指数训练的模型进行对比。使用研究区域全覆盖的 12 景 Landsat 8 OLI 影像作为方法对比的验证数据（图 8 和图 9），可以发现结合 NDVI、NDFS I 和 NDSI 模型重建积雪面积的精度更高，并且在不同空间位置具有更强的稳定性。如图 8 所示，在不同空间位置的影像中引入 NDVI

和NDFS I重建的积雪面积均比单一NDSI指数预测的积雪面积展现了更高的OA指标。统计多个影像的验证指标,结果如图9所示,可见引入NDVI

和NDFS I重建的积雪面积的OA提高1.53%,PA提高0.7%,UA提高3.01%,Kappa系数提高0.039。




图8 不同验证影像中3指数与单一指数的OA对比柱状图

Fig. 8 Histogram of OA comparison of the three indices and single index in different validation images




图9 不同验证影像中3个指数与单一指数的OA、PA、UA和Kappa统计箱线图

Fig. 9 Boxplots of OA, PA, UA and Kappa statistics for three indices and single index in different validation images

5 结 论

本研究基于MODIS和Landsat 8 OLI多时相数据,使用U-Net++网络能够有效地重建祁连山区30 m积雪面积,可为山区积雪时空变化监测、山区径流模拟、积雪水储量估算和灾害防治等研究提供高分辨率积雪面积数据,图10展示了重建的2020年12月15日积雪面积制图。本文构建的积雪面积重建方法经过多角度的验证和分析,主要结论如下:

(1) 引入注意力机制的U-Net++网络深度学习模型适用于高分辨率积雪面积的重建,并在祁连

山北麓山区重建的积雪面积具有较高的精度,OA达到90.36%,优于基于STARFM时空融合算法(8.7%)和基于DMNet时空融合算法(5.2%)重建反射率再识别积雪面积的方法。

(2) 基于U-Net++网络重建积雪面积方法在不同积雪覆盖度和地表类型均有较好的重建效果,能够良好地重建大面积积雪和斑状积雪,在裸土和植被区域的重建具有较强的稳定性。并且云覆盖和 t_1 、 t_2 的时间间隔对模型影响较小,展现了较强的鲁棒性。

(3) 引入NDVI和NDFS I特征比单一NDSI特征重建积雪面积的精度更高,OA、PA、UA和Kappa

系数分别提高了1.53%、0.7%、3.01%和0.039。

总而言之,本研究基于多时相输入,利用U-Net++网络重建积雪面积的算法,具有较强的稳定性与鲁棒性,能够重建较高精度的祁连山北麓山区30 m分辨率积雪面积数据,对山区积雪监测、水资源管理等具有重要意义。同时本研究也存在一些不足,在重建积雪面积时仅考虑光谱信息并未考虑地形环境等因素。有研究表明(孙兴亮等,

2022)在山地等受地形影响较大的区域,积雪反演过程中加入成像角度、地形、地表温度、降雪等环境信息可以提高反演精度。此外,基于MOD09GA数据重建的积雪面积,时间分辨率为1 d,算法对1 d内快速变化积雪的响应有待验证,后续考虑加入更高时间分辨率的数据,如FY-4A搭载的AGRI数据,以重建更高时间分辨率的积雪面积,来应对1 d内积雪的快速变化。




图10 重建的祁连山北麓2020年12月15日30 m积雪面积

Fig. 10 Reconstructed 30 m snow area in the northern foothills of the Qilian Mountains on 2020-12-15

参考文献(References)

- Beria H, Larsen J R, Ceperley N C, Michelon A, Vennemann T and Schaepli B. 2018. Understanding snow hydrological processes through the lens of stable water isotopes. *WIREs Water*, 5(6): e1311 [DOI: 10.1002/wat2.1311]
- Bourque C P A and Mir M A. 2012. Seasonal snow cover in the Qilian Mountains of Northwest China: its dependence on oasis seasonal evolution and lowland production of water vapour. *Journal of Hydrology*, 454-455: 141-151 [DOI: 10.1016/j.jhydrol.2012.06.008]
- Chen S Y, Wang X Y, Guo H, Xie P Y, Wang J and Hao X H. 2020. A conditional probability interpolation method based on a space-time cube for MODIS snow cover products gap filling. *Remote Sensing*, 12(21): 3577 [DOI: 10.3390/rs12213577]
- Choi G, Robinson D A and Kang S. 2010. Changing northern hemisphere snow seasons. *Journal of Climate*, 23(19): 5305-5310 [DOI: 10.1175/2010JCLI3644.1]
- Demir A, Yilmaz F and Kose O. 2019. Early detection of skin cancer using deep learning architectures: resnet-101 and inception-V3// 2019 Medical Technologies Congress (TIPTKNO). Izmir: IEEE: 1-4 [DOI: 10.1109/TIPTKNO47231.2019.8972045]
- Dietz A J, Kuenzer C, Gessner U and Dech S. 2012. Remote sensing of snow-a review of available methods. *International Journal of Remote Sensing*, 33(13): 4094-4134 [DOI: 10.1080/01431161.2011.640964]
- Drozdzal M, Vorontsov E, Chartrand G, Kadoury S and Pal C. 2016. The importance of skip connections in biomedical image segmentation//First International Workshop, and Second International Workshop on Deep Learning and Data Labeling for Medical Applications. Athens: Springer: 179-187 [DOI: 10.1007/978-3-319-46976-8_19]
- Gao F, Masek J, Schwaller M and Hall F. 2006. On the blending of the Landsat and MODIS surface reflectance: predicting daily Landsat surface reflectance. *IEEE Transactions on Geoscience and Remote Sensing*, 44(8): 2207-2218 [DOI: 10.1109/TGRS.2006.872081]
- Gao W Q. 2023. Research on the Preparation of Daily Cloudless Fractional Snow Cover Products in High Mountains Asia Based on MODIS. Taiyuan: Taiyuan University of Technology (高伟强). 2023. 基于MODIS的亚洲高山区逐日无云积雪面积比例产品制备研究. 太原: 太原理工大学 [DOI: 10.27352/d.cnki.gylgu.2023.001951]
- Han P F, Long D, Han Z Y, Du M D, Dai L Y and Hao X H. 2019. Improved understanding of snowmelt runoff from the headwaters of China's Yangtze River using remotely sensed snow products and

- hydrological modeling. *Remote Sensing of Environment*, 224: 44-59 [DOI: 10.1016/j.rse.2019.01.041]
- He G J, Feng X Z, Xiao P F, Xia Z H, Wang Z, Chen H, Li H and Guo J J. 2017. Dry and wet snow cover mapping in mountain areas using SAR and optical remote sensing data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 10(6): 2575-2588 [DIO: 10.1109/JSTARS.2017.2673409]
- Li H Y, He Y Q, Hao X H, Che T, Wang J and Huang X D. 2015. Downscaling snow cover fraction data in mountainous regions based on simulated inhomogeneous snow ablation. *Remote Sensing*, 7(7): 8995-9019 [DOI: 10.3390/rs70708995]
- Li H Y, Li X, Yang D W, Wang J, Gao B, Pan X D, Zhang Y L and Hao X H. 2019. Tracing snowmelt paths in an integrated hydrological model for understanding seasonal snowmelt contribution at basin scale. *Journal of Geophysical Research: Atmospheres*, 124(16): 8874-8895 [DOI: 10.1029/2019JD030760]
- Li W S, Zhang X Y, Peng Y D and Dong M L. 2020. DMNet: a network architecture using dilated convolution and multiscale mechanisms for spatiotemporal fusion of remote sensing images. *IEEE Sensors Journal*, 20(20): 12190-12202 [DOI: 10.1109/JSEN.2020.3000249]
- Li X, Che T, Li X W. 2020. *Remote Sensing of Cryosphere*. Beijing: Science Press: 50-51 (李新, 车涛, 李新武. 2020. 冰冻圈遥感学. 北京: 科学出版社: 50-51)
- Li X, Feng M, Ran Y H, Su Y, Liu F, Huang C L, Shen H F, Xiao Q, Su J B, Yuan S W and Guo H D. 2023. Big Data in Earth system science and progress towards a digital twin. *Nature Reviews Earth and Environment*, 4(5): 319-332 [DOI: 10.1038/s43017-023-00409-w]
- Liu Q and Zhang Y. 2022. Study on snow cover change based on the fusion of sentinel-2 and modis images. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, V-3-2022: 333-338 [DOI: 10.5194/isprs-annals-V-3-2022-333-2022]
- Rittger K, Krock M, Kleiber W, Bair E H, Brodzik M J, Stephenson T R, Rajagopalan B, Bormann K J and Painter T H. 2021. Multi-sensor fusion using random forests for daily fractional snow cover at 30 m. *Remote Sensing of Environment*, 264: 112608 [DOI: 10.1016/j.rse.2021.112608]
- Roy A G, Navab N and Wachinger C. 2019. Recalibrating fully convolutional networks with spatial and channel "Squeeze and Excitation" blocks. *IEEE Transactions on Medical Imaging*, 38(2): 540-549 [DOI: 10.1109/TMI.2018.2867261]
- Sun X L, Hao X H, Wang J, Zhao H Y and Ji W Z. 2022. Research on retrieval of MODIS fraction snow cover based on spectral environmental random forest regression model. *Journal of Glaciology and Geocryology*, 44(1): 147-158 (孙兴亮, 郝晓华, 王建, 赵宏宇, 纪文政. 2022. 基于光谱-环境随机森林回归模型的MODIS积雪面积比例反演研究. *冰川冻土*, 44(1): 147-158) [DOI: 10.7522/j.issn.1000-0240.2022.0026]
- Tian X, Wang L and Ding Q. 2019. Review of image semantic segmentation based on deep learning. *Journal of Software*, 30(2): 440-468 (田萱, 王亮, 丁琪. 2019. 基于深度学习的图像语义分割方法综述. *软件学报*, 30(2): 440-468) [DOI: 10.13328/j.cnki.jos.005659]
- Walters R D, Watson K A, Marshall H P, McNamara J P and Flores A N. 2014. A physiographic approach to downscaling fractional snow cover data in mountainous regions. *Remote Sensing of Environment*, 152: 413-425 [DOI: 10.1016/j.rse.2014.07.001]
- Wang J, Che T, Dai L Y, Yue S N and Zhang Z J. 2023. Spatio-temporal comparison of snow depth between passive microwave remote sensing inversion data and meteorological station observation data. *National Remote Sensing Bulletin*, 27(9): 2060-2071 (王静, 车涛, 戴礼云, 岳珊娜, 郑照军. 2023. 被动微波遥感反演雪深与气象站观测雪深时空对比. *遥感学报*, 27(9): 2060-2071) [DOI: 10.11834/jrs.20221653]
- Wang J, Li H X, Hao X H, Huang X D, Hou J L, Che T, Dai L Y, Liang T G, Huang C L, Li H Y, Tang Z G and Wang Z Y. 2014. Remote sensing for snow hydrology in China: challenges and perspectives. *Journal of Applied Remote Sensing*, 8(1): 084687 [DOI: 10.1117/1.JRS.8.084687]
- Wang X Y, Wang J, Che T, Huang X D, Hao X H and Li H Y. 2018. Snow cover mapping for complex mountainous forested environments based on a multi-index technique. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 11(5): 1433-1441 [DOI: 10.1109/JSTARS.2018.2810094]
- Wang Y H, Gu L J, Li X F, Gao F, Jiang T and Ren R Z. 2022. An improved spatiotemporal fusion algorithm for monitoring daily snow cover changes with high spatial resolution. *IEEE Transactions on Geoscience and Remote Sensing*, 60: 5413617 [DOI: 10.1109/TGRS.2022.3224126]
- Yang G Q, Liu H, Zhong X W, Chen L, Qian Y R. 2022. Temporal and spatial fusion of remote sensing images: a review. *Computer Engineering and Applications*, 58(10): 27-40 (杨广奇, 刘慧, 钟锡武, 陈龙, 钱育蓉. 2022. 遥感图像时空融合综述. *计算机工程与应用*, 58(10): 27-40) [DOI: 10.3778/j.issn.1002-8331.2111-0131]
- Zhang C J, Zhu L and Yu L. 2021. Review of attention mechanism in convolutional neural networks. *Computer Engineering and Applications*, 57(20): 64-72 (张宸嘉, 朱磊, 俞璐. 2021. 卷积神经网络中的注意力机制综述. *计算机工程与应用*, 57(20): 64-72) [DOI: 10.3778/j.issn.1002-8331.2105-0135]
- Zhou Z W, Siddiquee M M R, Tajbakhsh N and Liang J M. 2018. UNet++: a nested U-net architecture for medical image segmentation//4th International Workshop on Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support. Granada: Springer: 3-11 [DOI: 10.1007/978-3-030-00889-5_1]

Reconstruction of high spatiotemporal resolution snow cover remote sensing range data from multiple sources based on deep learning model : A case study in the Qilian Mountains

GAO Bo¹, HAO Xiaohua^{2,3}, HE Dongcai¹, ZHAO Qin², JI Wenzheng², REN Hongrui¹,
LI Hongyi^{2,3}, LIU Yan^{4,5}, ZHU Ping⁶

1. College of Mining Engineering, Taiyuan University of Technology, Taiyuan 030024, China;

2. Key Laboratory of Remote Sensing of Gansu Province, Northwest Institute of Eco-Environment and Resources, Chinese Academy of Sciences, Lanzhou 730000, China;

3. Heihe Remote Sensing Experimental Research Station, Northwest Institute of Eco-Environment and Resources, Chinese Academy of Sciences, Lanzhou 730000, China;

4. Institute of Desert Meteorology, China Meteorological Administration, Urumqi 830002, China;

5. Xinjiang Taklamakan Desert Meteorological National Field Scientific Observation and Research Station, Urumqi 830002, China;

6. College of Electronic Engineering, Chengdu University of Information Technology, Chengdu 610225, China

Abstract: High spatial and temporal resolution snow cover remote sensing range data are the key driving data for hydrological simulation. The accuracy of snow cover range directly determines the reliability of simulation results. Existing snow range remote sensing products, limited by sensor performance, often cannot achieve high temporal and spatial resolution and are stretched when facing highly spatially heterogeneous patchy snow distribution. As an important driving data for hydrological simulation, daily snow cover extent data with a spatial resolution of 30 m is crucial to improving the accuracy of basin-scale hydrological simulation. The purpose of this study is to prepare 30 m daily high-precision snow coverage data in the Qilian Mountains, in order to achieve dynamic monitoring of spatiotemporal changes in snow cover area.

This study used the U-Net++ deep learning network to predict the snow cover range with high spatiotemporal resolution. First, the Landsat 8 SR reflectance data at the previous time t_1 and the MOD09GA reflectance at t_1 and t_2 were resampled, and the pixels were matched. L'_1 , M'_1 , and M'_2 were obtained by calculating NDSI, NDVI, and NDFS index data for the three images. $M'_1-M'_2$ and L'_1 were used as feature inputs to the U-Net++ network. The snow range obtained from the Landsat 8 SR reflectance at time t_2 by the snow accumulation recognition algorithm was used as the network training truth value. Finally, any two moments corresponding to the features of the network were input, and the network reconstructed the high-resolution snow extent data corresponding to the latter moment.

The reconstruction result based on the U-Net++ algorithm effectively restored the snow range information under the complex underlying surface. The overall accuracy verified in the northern foothills of the Qilian Mountains was 90.4%, the producer accuracy was 89.9%, and the user accuracy was 88.4%; the kappa coefficient was 0.804, which is almost completely consistent with the real snow range. Among different snow coverages, the overall accuracies of low, medium, and high coverage were 89.26%, 92.91%, and 90.55%. Among different land surface covers, the overall accuracy of the bare soil area was 91.20%, and the overall accuracy of the vegetation area was 89.05%. It was compared with spatiotemporal fusion algorithms that indirectly reconstruct snow cover information based on satellite data fusion reflectivity, such as STARFM and DMNet networks; the overall accuracy increased by 8.7% and 5.2%, respectively.

The snow coverage reconstruction method based on U-Net++ network is suitable for the reconstruction of snow coverage data with high spatial and temporal resolution. The snow coverage range data reconstructed on the basis of this method in the northern foothills of the Qilian Mountains has high accuracy and has good reconstruction results at different snow coverage levels and different surface types. It has good reconstruction results for large areas of snow in high coverage areas and patchy snow in medium and low coverage areas. It also has good reconstruction results for bare soil areas and vegetation areas and has strong stability.

Key words: snow cover area, deep learning, multi-source fusion, MODIS, Landsat

Supported by National Natural Science Foundation of China (No. U22A20564); National Key Research and Development Program of China (No. 2022YFF0711702-05); Key Project of Natural Science Foundation of Gansu Province (No. 24JRRA082); Program of the Key Laboratory of Cryospheric Science and Frozen Soil Engineering, CAS (No. CSFSE-ZZ-2402, CSFSE-ZZ-2409)