

多源遥感数据驱动下耦合深度学习与积雪微波辐射传输模型的降尺度雪深反演算法

赵子胜¹, 郝晓华^{2,3}, 任鸿瑞¹, 罗斯琼⁴, 戴礼云², 邵东航²,
冯天文⁵, 赵琴², 纪文政², 刘艳^{6,7}

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. 中国科学院西北生态环境资源研究院 寒旱区陆面过程与气候变化重点实验室, 兰州 730000;

5. 兰州交通大学 测绘与地理信息学院, 兰州 730070;

6. 中国气象局乌鲁木齐沙漠气象研究所, 乌鲁木齐 830002;

7. 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

摘要: 高时空分辨率雪深数据对水文建模和灾害预报至关重要。目前, 高时间分辨率雪深通常源于被动微波数据, 由于仅依据被动微波数据的空间分辨率较低, 还无法满足区域水文和灾害研究的需求。本研究基于被动微波和光学等多源遥感数据, 提出一种耦合深度学习模型FT-Transformer (Feature Tokenizer + Transformer) 与积雪微波辐射传输模型SMRT (Snow Microwave Radiative Transfer) 的降尺度雪深反演算法。使用深度学习映射AMSR 2亮温差TBD (Brightness Temperature Difference)、积雪覆盖日数SCD (Snow Cover Days) 和积雪面积比例SCF (Snow Cover Fraction) 等特征与雪深的复杂非线性关系, 耦合SMRT拟合等效雪粒径ESG (Effective Snow Grain size) 实现降尺度反演雪深, 并以北疆39个站点数据进行模型训练和验证, 获取北疆500 m降尺度雪深。验证结果表明: 引入SCD独立验证RMSE优化了18%, 有助于提高模型的空间泛化能力; ESG显著优化了深度学习反演雪深的精度, RMSE为6.82 cm, 较未添加ESG的模型提升了15%, 同时大幅度改进了深雪低估。时间序列分析表明ESG符合实测雪深的变化趋势, 能够约束优化模型反演雪深的稳定性。最后, 对比已有的AMSR 2、ERA5-Land和SDDsd雪深产品, 本研究降尺度雪深精度最优, RMSE为6.51 cm, 雪深空间分布也更为精细, 体现了山区复杂的雪深异质性。本研究可为水文建模和灾害预报提供可靠的高时空分辨率雪深反演方法。

关键词: 遥感, 雪深, 降尺度算法, 深度学习, SMRT, AMSR 2, 积雪覆盖日数

中图分类号: TP701/P2

引用格式: 赵子胜, 郝晓华, 任鸿瑞, 罗斯琼, 戴礼云, 邵东航, 冯天文, 赵琴, 纪文政, 刘艳. 2025. 多源遥感数据驱动下耦合深度学习与积雪微波辐射传输模型的降尺度雪深反演算法. 遥感学报, 29(5): 1273-1289

Zhao Z S, Hao X H, Ren H R, Luo S Q, Dai L Y, Shao D H, Feng T W, Zhao Q, Ji W Z and Liu Y. 2025. Snow depth downscaling algorithm using coupled deep learning and microwave radiative transfer model driven by multi-source remote sensing data. National Remote Sensing Bulletin, 29(5): 1273-1289 [DOI:10.11834/jrs.20253540]

1 引言

积雪是全球水循环和气候系统的重要组成部分 (Pulliainen 等, 2020; 车涛和李新, 2005;

李新 等, 2020; 秦大河 等, 2007), 在地表和大气间的能量收支和辐射平衡中发挥重要作用 (Bormann 等, 2018; He 等, 2018; Kim 等, 2015)。积雪融水是干旱和半干旱地区淡水资源的

收稿日期: 2023-12-26; 预印本: 2024-03-27

基金项目: 国家重点研发计划(编号:2022YFF0711702-05); 国家自然科学基金联合基金重点支持项目(编号:U22A20564); 甘肃省重点基金项目(编号:24JRRA082); 中国科学院“西部之光”交叉团队项目(编号:xbzg-zdsys-202102); 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)

第一作者简介: 赵子胜, 研究方向为积雪遥感。E-mail: zhaozisheng2000@163.com

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

主要来源,惠及着全球约17%的人口(Barnett等, 2005; Bormann等, 2018; Landman, 2010)。雪深作为积雪的主要参数之一,时空动态地监测雪深是区域融雪径流、水资源管理和灾害防治等的关键数据。因此,高时空分辨率的雪深信息对于气候研究和水文监测至关重要(黄晓东等, 2019; 施建成等, 2016; 王建等, 2018; 肖雄新和张廷军, 2018)。

被动微波亮度温度TB (Brightness Temperature) 具有高时间分辨率,并且自1978年以来长期记录,是目前全球以及区域尺度估算雪深的有效数据(Xu等, 2022; 黄晓东等, 2019)。早期Chang等(1987)假定雪密度和雪粒径为常数进行模拟发现,干雪条件下穿透能力更强的18 GHz和波长较短易受体散射影响的36 GHz的亮温差与雪深存在线性关系,发展了线性反演算法。由于积雪体散射是积雪微波辐射能量衰减和散射的主要原因,积雪体散射受到下垫面、雪深、密度和粒径等积雪特性的影响,导致微波信号与积雪响应关系存在时空异质性(Pulliainen等, 2020; Tedesco和Jeyaratnam, 2016; 施建成等, 2016)。为减小积雪异质性的影响,已有研究以Chang算法为基础,引入森林覆盖度(Che等, 2008; Foster等, 1997; Kelly, 2009)、土地覆盖类型Lc (Land cover type) (蒋玲梅等, 2014)、温度梯度指数TGI (Temperature Gradient Index) (Josberger和Mognard, 2002)等改善线性反演算法的适用性。然而,由于线性算法将雪深与亮温差的复杂关系简单线性化,缺乏对积雪内部物理特性的考虑,其经验系数无法稳定匹配积雪特性的时空变化,难以准确反演雪深(Jiang等, 2011; Kelly等, 2003; Pulliainen等, 1999; Yang等, 2020)。为准确科学地描述积雪微波辐射能量传输过程,量化积雪物理特性,后续发展了不同的积雪微波模型,如HUT (Helsinki University of Technology) (Lemmetyinen等, 2010; Pulliainen等, 1999)、MEMLS (Microwave Emission Model for Layered Snowpacks) (Mätzler和Wiesmann, 1999; Wiesmann和Mätzler, 1999)以及DMRT (Dense Media Radiative Transfer) (Tsang和Li, 1999; West等, 1993)等。然而,积雪微波模型需要多种积雪先验数据支撑,同时模型的解算耗时耗力,难以直接应用于雪深反演。因此,结合实测数据、遥感数据和模型模拟数据,考虑积雪

物理特性的影响,能够优化雪深反演精度(Jiang等, 2011; Luo等, 2021; Pulliainen等, 1999)。特别的是,引入雪粒径的描述信息具备改善雪深反演的潜力(Durand等, 2009; Durand和Liu, 2012; Luo等, 2021; Richardson等, 2014; Yang等, 2021)。

目前,高时间分辨率雪深数据通常源于被动微波数据,全球较为先进的微波辐射计AMSR 2 (Advanced Microwave Scanning Radiometer 2) 最高提供10 km空间分辨率的亮温数据,然而,仅由亮温反演的雪深分辨率较粗,难以满足区域尺度水文建模和灾害预报的需求(Dai等, 2018; 胡晓静等, 2021; 黄晓东等, 2019; 肖雄新和张廷军, 2018),同时基于点尺度实测数据的验证精度可靠性无法保证(Hou等, 2022; 王静等, 2023)。为提高雪深数据的空间分辨率,改善积雪异质性对雪深反演的影响,已有研究进一步发展了降尺度雪深反演算法。如通过生成无云MODIS积雪覆盖面积数据获取精细的积雪分布信息,分解原始雪深粗分辨率像元,获取高空间分辨率且精度更高的雪深数据(Gao等, 2010);通过光学积雪覆盖数据统计积雪覆盖日数SCD (Snow Cover Days),基于像元积雪发生概率降尺度已有的雪深产品(Mhawej等, 2014)。随着积雪面积比例数据出现,有助于获取混合像元内更精细的积雪信息,为降尺度雪深反演进一步发展提供了数据基础。Dai等(2018)引入积雪面积比例SCF (Snow Cover Fraction)数据区分AMSR 2 TB像元中非雪信息,考虑地面发射率的影响,使用MEMLS模型模拟亮温差BTD (Brightness Temperature Difference)与雪深线性关系的空间动态系数,降尺度反演了青藏高原500 m空间分辨率的雪深。在积雪较深的北疆采用精度更高的SCF数据应用Dai的降尺度算法时,在浅雪表现出良好的反演精度,在深雪却存在明显低估的情况(胡晓静等, 2021)。随着机器学习的发展,因其挖掘大量数据中非线性关系的优势,在雪深反演中已有不少应用(Tedesco等, 2004; Wang等, 2019; Xiao等, 2018; Xu等, 2022)。较于线性反演算法,机器学习虽然能够映射TB等多元特征与雪深的复杂非线性关系,但目前仍未全面结合积雪降尺度因素(SCF和SCD)进行雪深反演。此外,由于缺乏对积雪物理特性时空变化的考虑,导致机器学习模型的泛化性能较弱(Yang

等, 2021)。因此, 为建立更可靠稳定的模型, 结合科学知识和数据科学的 TGDS (Theory-Guided Data Science) (Karpatne 等, 2017) 或 PIML (Physics Informed Machine Learning) (Karniadakis 等, 2021) 模式正在发展, 并已在水文建模和气候科学等方向通过耦合物理模型的深度学习模型取得了部分进展 (Kashinath 等, 2021)。

因此, 鉴于现有被动微波雪深空间分辨率及其反演算法的不足, 本研究基于被动微波和光学等多源遥感数据, 发展耦合积雪微波辐射传输模型 SMRT (Snow Microwave Radiative Transfer) (Picard 等, 2018) 和深度学习 FT-Transformer (Feature Tokenizer+Transformer) 模型 (Gorishniy 等, 2021) 的降尺度雪深反演算法, 并利用地面实测雪深进行了算法的精度评估。为进一步讨论本研究算法的优势所在, 与已有的被动微波雪深数据进行对比分析, 以期为区域尺度高时空分辨率的雪深数据需求提供可靠的依据。

2 研究区与数据

2.1 研究区概况

新疆是中国新疆维吾尔自治区北部区域 (76°05'E—93°00'E, 40°03'N—50°05'N), 地形起伏大 (http://www.coldregion.com/2024/03/13/downscale_sd/ [2024-12-26]), 主要包括北部的阿尔泰山脉、中部的准噶尔盆地以及南部的天山山脉。北疆地处干旱半干旱地区, 属于温带大陆性气候, 独特复杂的自然地理特征引起北疆水热分布显著的区域差异, 高山地区冬季漫长、寒冷多雪, 夏季短暂凉爽, 在盆地和平原地区冬季寒冷降水较少, 夏季炎热干燥。北疆年平均降水量约为 100—500 mm, 年平均温度约为 5℃, 冬季平均气温低于 -10℃ (谭娇等, 2018)。

北疆是中国三大主要积雪区之一, 年平均 SCD 达 81 d, 冬季雪储量占全国的 33.9%。该地区积雪稳定区约占 73%, 年周期不稳定积雪区约占 24%, 积雪资源主要分布在山区 (胡晓静等, 2021; 赵琴等, 2021a)。在降水贫乏的北疆, 积雪水资源是该地区地表径流的主要来源, 河流以及湖泊大都发源于山地冰川和积雪融水。积雪作为北疆地区主要的水资源, 对该地区水循环、气候变化具有重要的影响。因此, 高时空分辨率的雪深数据是北疆气候变化研究以及水资源管理的

重要数据支撑。

2.2 遥感数据及预处理

2.2.1 AMSR 2 数据

AMSR 2 TBD 数据为本研究降尺度雪深反演模型的基本输入数据之一。AMSR 2 是搭载于日本宇宙局发射的 GCOM-W1 卫星的被动微波辐射计, 提供全球 10 km 空间分辨率的 TB 数据 (<https://gportal.jaxa.jp/gpr/> [2023-12-26])。AMSR 2 拥有 7 种频率: 6.9 GHz、7.3 GHz、10.65 GHz、18.7 GHz、23.8 GHz、36.5 GHz 和 89 GHz, 两种极化方式: 垂直极化 V 和水平极化 H, 共 14 个通道, 每天过境两次, 升轨过境时间为 UTM13:30, 降轨过境时间为 UTM01:30。为减小湿雪的影响且与实测雪深时间保持一致, 同时考虑到垂直极化相较于水平极化与雪深的相关性更强 (Dai 等, 2018; Takala 等, 2011), 本研究采用降轨垂直极化数据反演雪深, 主要使用 6.9 GHz、10.65 GHz、18.7 GHz 分别和 36.5 GHz 的 TBD 数据: TBD6_36、TBD10_36 和 TBD18_36。然而, 积雪中液态水含量的增加会减弱积雪的散射特征, 抑制微波信号对雪的探测能力 (Chang 等, 1997; Che 等, 2008; Luo 等, 2021)。本研究采用以下条件识别干雪 (Chang 等, 2002):

$$15.9 \times (TB_{18.7V} - TB_{36.5V}) > 80 \quad (1)$$

$$TB_{36.5H} < 240 \text{ K} \quad (2)$$

$$TB_{36.5V} < 250 \text{ K} \quad (3)$$

式中, $TB_{18.7V}$ 、 $TB_{36.5V}$ 和 $TB_{36.5H}$ 分别为 AMSR 2 18.7 GHz、36.5 GHz 垂直极化亮温和 36.5 GHz 水平极化亮温。为与 SCF 和 SCD 数据空间匹配, 将亮温数据使用最近邻法重采样到 500 m 空间分辨率。此外, AMSR 2 L3 产品提供全球逐日 10 km 分辨率雪深数据集, 用于对比评估本研究降尺度雪深反演结果。

2.2.2 降尺度特征数据

SCF 数据为雪深反演的降尺度提供数据支撑, 减小混合像元的影响 (Dai 等, 2018)。本研究采用基于空间—光谱—环境端元信息获取的逐日无云 500 m 的 SSEmod-SCF 数据 (Zhao 等, 2020)。该数据基于光学提供了较高分辨率下高精度的积雪识别, 具有 500 m 像元内积雪覆盖的空间比例信息。

SCD数据反映了积雪的长期积累特征,包含了温度、降水、地形等环境因素对积雪的长期影响(Zhao等, 2022),为降尺度雪深反演提供积雪空间分布的差异信息(Mhawej等, 2014; Wang等, 2019),是重要的降尺度特征之一。SCD数据源于国家冰川冻土沙漠科学数据中心(<http://www.ncdc.ac.cn/>[2023-12-26])的中国积雪物候数据集,其中包含2000年—2020年中国逐年500 m的SCD数据(赵琴等, 2021b),由此生成了北疆2012年—2020年多年平均SCD数据。

Lc源于MCD12Q1 V061数据集,为降尺度雪深反演提供地表覆盖相关信息。该数据集提供全球范围内基于IGBP分类标准的年度土地覆盖类型,空间分辨率为500 m。北疆地表覆盖类型主要包含以下5种:水体、森林、灌木、农田和裸地(胡晓静等, 2021; 赵琴等, 2021a)。

2.3 ERA5-Land Hourly再分析数据

ERA5-Land Hourly再分析数据主要为SMRT提供温度和密度等积雪先验信息。该数据由欧洲中期天气预报中心ECMWF(European Centre for Medium-Range Weather Forecasts)的ERA5气候再分析数据的陆地部分生成,时间分辨率为1 h,空间分辨率为10 km。本研究主要使用该数据UTM 02:00的地表温度 T_{soil} 、地表上2 m空气温度 $T_{2\text{m}}$ 、雪层温度 T_{snow} 、雪密度 ρ 和雪深产品,并重采样到500 m以进行数据空间匹配。其中: T_{soil} 和 $T_{2\text{m}}$ 的差为温度梯度TGI,用于间接表征积雪粒径动态变化,参与深度学习反演雪深(Josberger和Mognard, 2002; Xu等, 2022)。 T_{soil} 、 T_{snow} 和 ρ 用于驱动SMRT拟合等效雪粒径ESG(Effective Snow Grain size),雪深产品用于对比本研究的降尺度雪深。

2.4 实测雪深数据

北疆实测雪深数据主要用于模型的训练和验证,源于2012年—2020年中国气象站点雪深数据集(<http://data.cma.cn/en/>[2023-12-26])、玛纳斯河流域和可可托海地区布设的积雪观测站实测数据,研究用的雪深数据选择在早上8:00测量。为了使模型更具普适性,本研究采用以下两个原则筛选站点实测数据:为排除水体对微波信号的干扰,去除了10 km像元内水体占比超过20%的气象

站点,并通过式(1)—(3)排除湿雪数据;剔除了实测雪深中的异常记录,选用雪季(10月—次年4月)内站点数据进行实验,为确保数据的可靠性,去除了一个雪季内有效数据少于30 d的站点。基于以上原则最终采用39个站点(研究区气象站点分布见http://www.coldregion.com/2024/03/13/downscale_sd/[2023-12-26]),共计27226条有效记录。

2.5 辅助数据

DEM(Digital Elevation Model)数据提供北疆的高程、坡度和坡向等地形数据,尝试为反演雪深提供地形特征。采用源于美国航空航天局NASA(National Aeronautics and Space Administration)发布的SRTM V4数据(<https://srtm.csi.cgiar.org/>[2023-12-26]),空间分辨率为90 m,重采样为500 m。

为对比评估本研究降尺度雪深反演算法效果,除上述AMSR 2和ERA5-Land雪深产品外,还获取了胡晓静等(2021)发展的多源数据融合的空间动态降尺度雪深SDDsd(Spatial Dynamic Downscaling snow depth)数据,该数据参考Dai等(2018)在青藏高原降尺度反演雪深的方法,通过MEMLS模型模拟数据确定亮温差与雪深空间动态的线性关系,利用SCF进行像元分解得到降尺度雪深。

3 研究方法

本研究使用被动微波和光学等多源遥感数据发展了一种北疆降尺度雪深反演算法。考虑AMSR 2空间分辨率较粗,受到混合像元中非雪信息的干扰,难以准确获取有效的积雪信息。此外,微波辐射在浅层积雪不会发生明显的散射效应(Chang等, 1987),而雪深依赖于雪密度与SCF存在积雪衰退曲线SDC(Snow Depletion Curve)的动态关系(Niu和Yang, 2007)。因此,本研究利用SCF先验地判断积雪信息,将降尺度算法分为两大关键部分:(1)当 $\text{SCF} \geq 50$ 时,使用TBD等数据采用耦合SMRT和FT-Transformer模型的方法反演雪深,简称为FTT-SMRT模型;(2)当 $\text{SCF} < 50$ 时,考虑混合像元对被动微波信号影响较大,使用SDC推导雪深。图1展示了算法的主要流程,通过FTT-SMRT模型和SDC方法构建降尺度雪深反演算法FSSD(FTT-SMRT+SDC Downscaling)。




图1 降尺度雪深反演算法 FSSD 主要流程

Fig. 1 The main process of FSSD algorithm for downscaling snow depth retrieval

3.1 FTT-SMRT 雪深反演模型

3.1.1 FT-Transformer 模型

本研究使用 FT-Transformer (Feature Tokenizer+Transformer) 深度学习模型映射 TBD 等特征与雪深的关系反演雪深。FT-Transformer 模型是 Gorishniy 等 (2021) 基于 Transformer 骨干网络 (Vaswani 等, 2017) 改编应用于表格数据的深度学习模型 (图 2)。该模型包含 3 个重要组成模块: Feature Tokenizer、Transformer 和 Prediction 模块。Feature

Tokenizer 模块将输入的数值和类别特征分别采用线性和类别嵌入方式堆叠为嵌入向量 T ; Transformer 模块附加特殊令牌 [CLS] 到 T 得到 T_0 (Devlin 等, 2019), 经过多个 Transformer block 变换为 T_L , 通过 Prediction 模块将 T_L 中的 [CLS] 部分通过线性层输出预测结果。其中, Transformer 模块主要由 Transformer block 组成, 一个 Transformer block 由多头自注意力机制层 MHSA (Multi-Head Self-Attention)、残差连接与层归一化、前馈神经网络 FNN (Feed Forward Networks) 构成, MHSA 和 FNN 都使用了 Dropout 策略增强模型的泛化能力, FNN 的激活函数为性能优秀的 ReGLU; Prediction 模块的激活函数为简单快速的 ReLU。可通过 n_blocks 参数 (Transformer block 个数) 确定该模型的参数组合以选择最优模型参数, 不同参数组合对应的网络深度不同。模型训练时采用的优化器为收敛速度较快且性能优异的 AdamW (Adaptive Moment Estimation + Weight decay), 损失函数为回归任务中常用的均方误差损失 MSE (Mean Squared Error Loss)。




图2 FT-Transformer深度学习模型的组成结构

Fig. 2 Composition structure of the FT-Transformer deep learning model

3.1.2 SMRT 模型

SMRT 模型拟合输出 ESG 用于表征积雪物理特征的时空变化, 为深度学习反演雪深提供物理一致性的特征实例。SMRT 是 Picard 等 (2018) 集成现有不同微波模型对不同雪微观结构的描述, 计算多层积雪热发射以及后向散射的模型。SMRT 将

不同的电磁理论、雪微观结构、辐射传输方程解算器以及介电常数模型等模块化, 可以高度灵活地切换微波辐射传输发展中的各个理论部分, 便于探索和比较不同的方法模拟积雪与微波的相互作用。目前, 该模型集成了 DMRT, IBA 和独立瑞利散射体理论用于计算积雪的介电常数、吸收系数、散射系数、相函数等固有电磁特性, 并且

Löwe 和 Picard (2015) 已证明 IBA 与 DMRT 理论描述积雪微波辐射时的近似等效。本研究选择常用的 IBA 理论中的 SHS (Sticky Hard Spheres) 模型描述积雪微观性质, 辐射传输方程解算使用 DORT 法 (Discrete Ordinate and eigenvalue Radiative Transfer), 下垫面使用 Wegmüller 土壤模型 (Wegmüller 和 Matzler, 1999)。限于不完备的驱动数据, 积雪层设为 1 层, SHS 粘性参数设为 0.15 (Löwe 和 Picard, 2015), 下垫面粗糙度设为 3 cm。

3.1.3 FTT-SMRT 模型

当 $SCF \geq 50$ 时, 运用 Stacking 集成策略以及 TGDS 模式耦合 SMRT 模型和 FT-Transformer 模型反演雪深, 即 FTT-SMRT 模型。Stacking (Breiman, 1996; Wolpert, 1992) 是集成学习中一种著名的方法, 使用初级学习器的预测作为元学习器的输入, 达到优化预测性能的目的 (Pavlyshenko, 2018; 周志华, 2016)。TGDS 模式中协同互补物理模型和机器学习输入输出的方式, 耦合物理模型的科学机理和机器学习的数据知识, 建立更可靠稳定的模型。如图 3 所示, FTT-SMRT 模型通过初级学习器 FT-Transformer1 反演初级雪深, 驱动 SMRT 拟合 ESG 特征以反映积雪物理变化特性, 而后引入 ESG 训练元学习器 FT-Transformer2, 以此协同互补 SMRT 和 FT-Transformer 优化雪深反演。




图 3 FTT-SMRT 模型构建流程

Fig. 3 Process of constructing the FTT-SMRT model

首先, 使用初级学习器 FT-Transformer1 反演初级雪深时, 可能的输入特征为 TBD (TBDV6_36、

TBDV10_36 和 TBDV18_36), T_{soil} 和 T_{2m} 的温度梯度 TGI, 降尺度特征 (SCF、SCD 和 Lc) 和地理地形因素 GeoTerr (经度、纬度、高程、坡度和坡向), 为了减少过拟合风险并简化训练过程, 对 GeoTerr 以及 SCD 特征进行雪深反演精度对比, 选取最优特征组合。

然后, 在 SMRT 模型拟合 ESG 时, 除 3.1.2 中参数外, 驱动 SMRT 模型正演 TB 的变量还包括 T_{soil} , T_{snow} , ρ , 雪层厚度和 SHS 球半径 d_0 。其中, T_{soil} 、 T_{snow} 和 ρ 由 ERA5-Land 再分析数据提供, 雪层厚度为 FT-Transformer1 反演的初级雪深。 d_0 在范围为 $[0, 4]$ mm 步长为 0.01 mm 条件下迭代输入 SMRT, ESG 选择不同微波频率下 SMRT 正演 TB 与 AMSR 2 TB 差平方和最小的 d_0 值 (Luo 等, 2021; Pulliainen, 2006; Takala 等, 2011):

$$\min_{d_0} \sum (TB_{SMRT} - TB_{AMSR2})^2 \quad (4)$$

式中, TB_{SMRT} 为 SMRT 模拟的 10.65 GHz、18.7 GHz 和 36.5 GHz 的 AMSR 2 垂直极化亮温, TB_{AMSR2} 为相应频率极化的 AMSR 2 TB 数据。因此, 本研究中 ESG 是多种先验积雪特性数据通过 SMRT 拟合而来, 与积雪层中实际雪粒径不同, 是用以表征像元尺度积雪整体物理特性的等效雪粒径。

最后, 在特征筛选后的最佳特征组合中引入 ESG, 训练元学习器 FT-Transformer2 以优化雪深反演。

3.2 SDC 雪深反演方法

在 $SCF < 50$ 时, 积雪覆盖较少, AMSR 2 像元难于准确获取积雪信息, 采用 Niu 和 Yang (2007) 开发的 SDC 方法推导雪深, 该方法使用雪密度描述雪深和 SCF 的动态关系。具体公式如下:

$$100 \times SCF = \tanh \left(\frac{100 \times SD}{2.5 \times z_{0g} \left(\rho / \rho_{new} \right)^m} \right) \quad (5)$$

式中, SCF 为积雪面积百分比例, SD 为雪深, 单位为 cm, z_{0g} 为地面粗糙长度, 取 0.03 m, ρ 为雪密度, 由 ERA5-Land 再分析数据提供, ρ_{new} 为新雪密度, 取值为 100 kg/m^3 , m 为融化因子, 取值为 1.4, 由此得到 SDC 反演雪深的计算式:

$$SD = 3.75 \times \left(\rho / 100 \right)^{1.4} \times \ln \left(\frac{100 + SCF}{100 - SCF} \right) \quad (6)$$

3.3 模型评估和精度指标

本研究的降尺度雪深反演算法主要由SDC和深度学习模型输出雪深反演值。在评估SDC反演雪深精度时, SCF<50的站点实测雪深有效记录为10747条。在评估深度学习模型反演雪深精度时, SCF≥50的站点实测雪深有效记录为16479条。为减少过拟合风险, 评估模型的泛化性能, 使用K折交叉验证K-Fold CV (K-Fold Cross Validation) 和独立验证IV (Independent Validation) 方式评估模型精度。将39个站点按空间位置随机划分为训练站点和验证站点, 为平衡训练和验证站点个数以及相应数据量的比例, 随机选取14个作为验证站点, 个数占比约为36%, 对应数据量为6004条, 占比约36%。在训练站点使用5-Fold CV进行模型评估。在验证站点进行独立验证, 评估模型的空间泛化能力。在运用Stacking集成策略时, 元学习器训练集由初级学习器的训练集直接生成的过拟合风险较大, 通过合并初级学习器交叉验证的验证子集作为元学习器的训练输入, 即合并验证子集拟合的ESG特征输入元学习器, 元学习器由验证站点独立验证。

以站点实测雪深为真实值, 通过以下指标评估模型降尺度雪深反演的精度, 具体包括均方根误差RMSE (Root Mean Square Error)、平均绝对误差MAE (Mean Absolute Error) 以及皮尔逊相关系数R (Pearson correlation coefficient):

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (x_i - y_i)^2}{n}} \quad (7)$$

$$MAE = \frac{\sum_{i=1}^n |x_i - y_i|}{n} \quad (8)$$

$$R = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} \quad (9)$$


式中, n 为实测雪深的样本数, x_i 为第 i 个实测雪深值, $\bar{x}$ 为实测雪深平均值, y_i 为第 i 个降尺度反演雪深值, $\bar{y}$ 为降尺度反演雪深的平均值。

4 结果与分析

4.1 FTT-SMRT 模型反演精度


4.1.1 FT-Transformer1 精度

以AMSR 2 TBD等特征训练初级学习器FT-Transformer1 (n_blocks 为3) 反演雪深时, 以TBD、TGI、SCF和Lc特征(M0)为基准, 对比添加GeoTerr (M1)、SCD (M3) 以及GeoTerr和SCD (M2) 特征的反演精度(图4)。可见: 仅添加SCD特征的M3模型整体精度最高, 因此选择M3模型的特征组合反演初级雪深驱动SMRT; 在M0基础上, M1、M2和M3模型交叉验证和独立验证精度均得到提升; M1较M0独立验证精度提升有限, M3模型独立验证精度提升最大, RMSE和MAE分别提升了18%和16%, 且M3较M2精度也有所提升, RMSE和MAE分别提升7%和4%; 独立验证时M3较M2散点拟合线的斜率、截距也有所减小, 散点整体更接近1:1最佳拟合线, 浅雪高估和深雪低估的误差有所改善。此外, 不同特征组合下交叉验证的精度明显优于独立验证, 这是因为交叉验证的验证数据抽取方式未考虑实测数据空间位置, 忽略了积雪的空间异质性。



(a) 交叉验证

(a) Cross validation



(b) Independent validation

图4 不同特征组合的FT-Transformer1模型交叉验证和独立验证结果散点密度图


Fig. 4 Scatter density plot of FT-Transformer1 model cross validation and independent validation of different feature combinations

4.1.2 FT-Transformer2精度

在 $SCF \geq 50$ 时, 使用 FTT-SMRT 模型反演雪深, 由 FT-Transformer1 输出的初级雪深以及温度、密度等数据驱动 SMRT 拟合 ESG 特征, 参与训练元学习器 FT-Transformer2 优化雪深反演, 模型参数 n_blocks 为 2。图 5 (a) 为 FT-Transformer2 反演雪深的独立验证散点密度图。可见 FT-Transformer2 模型的 RMSE、MAE 和 R 分别达到 6.82 cm、4.98 cm 和 0.82, 较 FT-Transformer1 (8.08 cm、6.09 cm 和


0.73) 整体精度得到明显提升。

为进一步分析 FT-Transformer1 和 FT-Transformer2 反演雪深的精度差异, 将站点雪深值以 20 cm 和 40 cm 为间隔分组验证 (图 5 (b))。可见 FT-Transformer2 在各雪深分组的反演精度均优于 FT-Transformer1。其中深雪 (>40 cm) 的反演精度优化较大, RMSE 提升了 35%, 而 <40 cm 的雪深反演精度优化有限, 这是由于 40 cm 以下实测雪深数据约占 90%, 拥有充足的实例数据训练模型。



(a) FT-Transformer2独立验证结果

(a) FT-Transformer2 independent verification result



(b) 雪深分组验证对比

(b) Snow depth group verification comparison

图5 FT-Transformer2精度验证结果

Fig. 5 FT-Transformer2 accuracy verification results

4.2 SDC反演精度

在 $SCF < 50$ 时, 利用 SDC (式 (6)) 推导雪深。其中 $SCF=0$ 时, $SD=0$, 即认为该像元没有积雪, 以实测雪深为真实值进行验证, SCF 将实

测雪深为 0 正确识别的准确率为 87.90% (10081 条记录验证)。在 $SCF > 0$ 且 $SCF < 50$ 时, 图 6 为由 SDC 推导雪深的精度验证的 RMSE、MAE 和 R 分别为 2.12 cm, 1.59 cm 和 0.75 结果 (666 条记录

验证), RMSE、MAE 和 R 分别为 2.12 cm, 1.59 cm 和 0.75。






图6 SDC反演雪深验证

Fig. 6 Verification of SDC retrieval snow depth



(a) 元学习器FT-Transformer2_1

(a) Meta-learner FT-Transformer2_1



(b) 元学习器FT-Transformer2_2

(b) Meta-learner FT-Transformer2_2

图7 元学习器FT-Transformer2_1和FT-Transformer2_2独立验证散点密度图

Fig. 7 Independent verification scatter density plot of meta-learner FT-Transformer2_1 and FT-Transformer2_2

为进一步分析SMRT拟合ESG对于降尺度雪深反演的影响,本研究统计了两个验证站点吉木萨尔站和金格站相应实测雪深、FT-Transformer1、FT-Transformer2和ESG的时间变化曲线(图8)。图8(a)吉木萨尔站的实测雪深小于30 cm, FT-Transformer1模型较实测雪深随时间波动较大,而SMRT拟合的ESG较为符合实测雪深的变化规律,引入ESG特征优化的FT-Transformer2较FT-Transformer1也更接近实测雪深。金格站的实测雪深最深达到70 cm, FT-Transformer1模型较实测雪

5 讨论

5.1 SMRT有效性

为评估SMRT拟合ESG特征优化雪深反演的有效性,本研究构建了两种不引入ESG特征的元学习器FT-Transformer2_1(引入初级雪深)和FT-Transformer2_2(引入初级雪深、 T_{soil} 、 T_{snow} 和 ρ),图7为FT-Transformer2_1和FT-Transformer2_2的精度验证结果。验证结果表明,FT-Transformer2_1独立验证精度较FT-Transformer1变化较小,FT-Transformer2_2的反演精度较FT-Transformer1略有提高,但对比发现结合SMRT拟合ESG特征的FT-Transformer2(图5(a))雪深反演精度明显更优,说明在Stacking集成框架下,雪深反演精度的提高得益于耦合了SMRT拟合的ESG特征。

深存在严重低估现象,尤其在深雪(>40 cm), FT-Transformer2模型明显高于FT-Transformer1模型且更接近实测雪深,有效地改善了雪深反演的低估。值得注意的是在雪季后期积雪融化减少阶段ESG的变化较为复杂,雪深反演精度也明显下降。究其原因,一方面是积雪的减少导致雪层对被动微波信号的散射减弱,引起卫星观测TB值增大而SMRT拟合的ESG减小。另一方面是虽然已对TB限制以减少湿雪的影响,但雪季后期的冻融循环难以避免。冻融循环导致雪层内部粒子的聚集

重组会引起ESG增大。因此,受到积雪整体减少、内部结构变化以及积雪液态水等因素的影响,积雪融化减少阶段被动微波信号和积雪的响应关系十分复杂,增大了SMRT模型拟合ESG的难度,导致雪深反演出现较大误差。此外,拟合的ESG特征在雪季中存在一些异常的波动,导致FT-Transformer2模型产生偏离实测雪深的异常值。这

是因为ESG是ERA5-Land等驱动数据通过SMRT模型逼近AMSR 2亮温得到,而驱动数据的误差、SMRT模型自身的不确定性以及不同数据之间的尺度差异,均会导致拟合结果存在异常,从而影响雪深反演。整体来看,SMRT拟合的ESG较为符合实际雪深变化的趋势,优化了雪深反演的稳定性和精度。




图8 不同地面观测站的实测雪深、FT-Transformer1、FT-Transformer2反演雪深和ESG的时间变化序列
Fig. 8 Time series of measured snow depth, FT-Transformer1, FT-Transformer2 reversed snow depth and ESG at different ground stations

5.2 对比其他雪深产品

5.2.1 雪深精度验证对比

将本研究的降尺度雪深FSSDsd与AMSR 2雪深、ERA5-Land雪深和SDDsd进行对比验证。为便于精度对比,整合图5(a)和图6中SCF>0的实测数据用于验证,图9为上述4种雪深的精度验证对比,图中误差竖线代表标准差。

结果表明,AMSR 2、ERA5-Land的雪深产品和SDDsd的验证精度均低于FSSDsd。其中,AMSR 2雪深整体高估,随实测雪深的增大雪深估计值可以保持类似的增长趋势,但标准差较大,

说明会产生偏差较大的估计值。ERA5-Land雪深产品整体精度略优于AMSR 2雪深产品,在浅雪具有接近实测雪深的增大趋势,深雪却过于偏离实测雪深,且同样存在较大标准差。SDDsd具有相对较好的精度,浅雪时高估雪深但标准差较小,深雪时存在明显低估且标准差较大。本研究的降尺度雪深FSSDsd具有最优的精度,RMSE、MAE和R分别为6.51 cm, 4.64 cm和0.85,浅雪的反演值与实测雪深比较接近,在深雪略有低估,但随实测雪深增大能够保持基本一致的增大趋势,且标准差较小反演值更加稳定。




图9 AMSR 2、ERA5-Land、SDDsd和FSSDsd雪深精度验证结果对比

Fig. 9 Comparison of snow depth accuracy validation results for AMSR 2, ERA5-Land, SDDsd and FSSDsd

5.2.2 雪深空间分布对比

为对比评估 AMSR 2、ERA5-Land、SDDsd 和 FSSDsd 的雪深空间分布, 放大北疆南部的部分天山和部分准噶尔盆地, 图 10 为上述 4 种雪深以 2017 年 12 月 1 日以及 2018 年 1 月 1 日为例的空间分布图。

整体来看, 图 10 中不同的雪深产品表现出相近的时空分布规律。2018 年 1 月 1 日较 2017 年 12 月 1 日的雪深整体变大, 各产品均显示山区雪深较深, 平原盆地积雪较浅。对比发现, AMSR 2 和 ERA5-Land 的雪深整体较大, 雪深空间分布过于一致, 与山区复杂的积雪分布不符。在雪深较深的山区 ERA5-Land 的雪深估计值更大, 这与图 9

中验证结果一致。相比之下, 降尺度雪深 SDDsd 和 FSSDsd 获取了北疆更为精细的雪深分布, 尤其在复杂的山区, 体现了山区积雪的异质性。对比分析 2018 年 1 月 1 日两者的雪深空间分布, 发现 FSSDsd 最大雪深为 69.81 cm, 而 SDDsd 的雪深值整体较小, 最大雪深为 39.42 cm, 这与图 9 中 SDDsd 在深雪时的严重低估吻合。此外, 在盆地平原地区, FSSDsd 也展现出更精细的雪深分布, 这是因为 FSSDsd 包含了 SCF、SCD 和 L_c 更加丰富的降尺度信息。但 FSSDsd 仍旧存在部分“大像元”区域, 可能是由于 SCF、SCD 和 L_c 较为相近, 降尺度效果不明显。总体来说, 本研究的 FSSDsd 能够提供区域尺度更精细的雪深空间分布。




图 10 AMSR 2、ERA5-Land、SDDsd 和 FSSDsd 的雪深空间分布对比
Fig. 10 Comparison of snow depth spatial distributions for AMSR 2, ERA5-Land, SDDsd and FSSDsd

6 结 论

为改善现有被动微波雪深产品空间分辨率和精度较低的状况, 本研究基于2012年—2020年8个雪季的AMSR 2 TBD和站点实测雪深等数据, 采用耦合SMRT与FT-Transformer的方法, 构建了北疆的降尺度雪深反演算法FSSD。主要结论如下:

(1) 通过站点实测雪深独立验证发现, 引入SCD特征模型独立验证RMSE提升了18%, 说明SCD特征能够增强模型的空间泛化能力。

(2) SMRT拟合的ESG特征优化了FT-Transformer反演雪深的精度, 较未添加ESG特征的模型RMSE提升了15%, 尤其在深雪提升了35%。ESG特征较为符合实测雪深的变化趋势, 能够约束优化FT-Transformer模型输出雪深的稳定性。

(3) 本研究的算法降尺度效果明显, 比已有的AMSR 2、ERA5-Land和SDDsd雪深产品展现出更加精细的雪深分布, 尤其在山区改善了粗分辨率像元雪深导致的过度同质现象, 体现了山区积雪复杂的异质性。

然而, 在本研究算法的实施和验证过程中, 仍存在一些不足之处, 例如SMRT模型拟合ESG时未考虑驱动数据的不确定性, 并且降尺度特征缺乏与雪深直接相关的信息, 降尺度效果有待改进。近年来, 合成孔径雷达SAR (Synthetic Aperture Radar) 因其高空间分辨率、多模式、多极化等优势, 已在雪深反演领域展现出广泛的应用前景 (Tsokas等, 2022; 郭华东和张露, 2019; 刘洋等, 2018)。因此, 在后续研究中进一步融合SAR数据以提供高分辨率雪深信息, 以期优化降尺度雪深反演算法。

参考文献 (References)

- Barnett T P, Adam J C and Lettenmaier D P. 2005. Potential impacts of a warming climate on water availability in snow-dominated regions. *Nature*, 438(7066): 303-309 [DOI: 10.1038/nature04141]
- Bormann K J, Brown R D, Derksen C and Painter T H. 2018. Estimating snow-cover trends from space. *Nature Climate Change*, 8(11): 924-928 [DOI: 10.1038/s41558-018-0318-3]
- Breiman L. 1996. Stacked regressions. *Machine Learning*, 24(1): 49-64 [DOI: 10.1023/A:1018046112532]
- Chang A T C, Foster J L and Hall D K. 1987. Nimbus-7 SMMR derived global snow cover parameters. *Annals of Glaciology*, 9: 39-

- 44 [DOI: 10.3189/S0260305500200736]
- Chang A T C, Foster J L, Hall D K, Goodison B E, Walker A E, Metcalfe J R and Harby A. 1997. Snow parameters derived from microwave measurements during the BOREAS winter field campaign. *Journal of Geophysical Research: Atmospheres*, 102(D24): 29663-29671 [DOI: 10.1029/96JD03327]
- Che T and Li X. 2005. Spatial distribution and temporal variation of snow water resources in China during 1993-2002. *Journal of Glaciology and Geocryology*, 27(1): 64-67 (车涛, 李新. 2005. 1993-2002年中国积雪水资源时空分布与变化特征. 冰川冻土, 27(1): 64-67) [DOI: 10.3969/j.issn.1000-0240.2005.01.009]
- Che T, Li X, Jin R, Armstrong R and Zhang T J. 2008. Snow depth derived from passive microwave remote-sensing data in China. *Annals of Glaciology*, 49: 145-154 [DOI: 10.3189/172756408787814690]
- Dai L Y, Che T, Xie H J and Wu X J. 2018. Estimation of snow depth over the Qinghai-Tibetan Plateau based on AMSR-E and MODIS data. *Remote Sensing*, 10(12): 1989 [DOI: 10.3390/rs10121989]
- Devlin J, Chang M W, Lee K and Toutanova K. 2019. BERT: pre-training of deep bidirectional transformers for language understanding//Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, Volume 1 (Long and Short Papers). Minneapolis: Association for Computational Linguistics: 4171-4186 [DOI: 10.18653/v1/N19-1423]
- Durand M, Kim E J and Margulis S A. 2009. Radiance assimilation shows promise for snowpack characterization. *Geophysical Research Letters*, 36(2): L02503 [DOI: 10.1029/2008GL035214]
- Durand M and Liu D S. 2012. The need for prior information in characterizing snow water equivalent from microwave brightness temperatures. *Remote Sensing of Environment*, 126: 248-257 [DOI: 10.1016/j.rse.2011.10.015]
- Foster J L, Chang A T C and Hall D K. 1997. Comparison of snow mass estimates from a prototype passive microwave snow algorithm, a revised algorithm and a snow depth climatology. *Remote Sensing of Environment*, 62(2): 132-142 [DOI: 10.1016/S0034-4257(97)00085-0]
- Gao Y, Xie H J, Lu N, Yao T D and Liang T G. 2010. Toward advanced daily cloud-free snow cover and snow water equivalent products from Terra - Aqua MODIS and Aqua AMSR-E measurements. *Journal of Hydrology*, 385(1/4): 23-35 [DOI: 10.1016/j.jhydrol.2010.01.022]
- Gorishniy Y, Rubachev I, Khrulkov V and Babenko A. 2021. Revisiting deep learning models for tabular data//Proceedings of the 35th International Conference on Neural Information Processing Systems. Curran Associates Inc.: 1447
- Guo H D and Zhang L. 2019. 60 years of radar remote sensing: four-stage development. *Journal of Remote sensing (in Chinese)*, 23(6): 1023-1035 (郭华东, 张露. 2019. 雷达遥感六十年: 四个阶段的发展. 遥感学报, 23(6): 1023-1035) [DOI: 10.11834/jrs.20199398]
- Hall D K, Kelly R E J, Riggs G A, Chang A T C and Foster J L. 2002. Assessment of the relative accuracy of hemispheric-scale snow-

- cover maps. *Annals of Glaciology*, 34: 24-30 [DOI: 10.3189/172756402781817770]
- He C L, Liou K N, Takano Y, Yang P, Qi L and Chen F. 2018. Impact of grain shape and multiple black carbon internal mixing on snow albedo: parameterization and radiative effect analysis. *Journal of Geophysical Research: Atmospheres*, 123(2): 1253-1268 [DOI: 10.1002/2017jd027752]
- Hou Y X, Huang X D and Zhao L. 2022. Point-to-Surface upscaling algorithms for snow depth ground observations. *Remote Sensing*, 14(19): 4840 [DOI: 10.3390/rs14194840]
- Hu X J, Hao X H, Wang J, Dai L Y, Zhao H Y and Li H Y. 2021. Snow depth downscaling algorithm based on the fusion of AMSR2 and MODIS data: a case study in northern Xinjiang, China. *Remote Sensing Technology and Application*, 36(6): 1236-1246 (胡晓静, 郝晓华, 王建, 戴礼云, 赵宏宇, 李弘毅. 2021. 基于 AMSR2 和 MODIS 数据融合的雪深降尺度算法研究—以北疆地区为例. *遥感技术与应用*, 36(6): 1236-1246) [DOI: 10.11873/j.issn.1004-0323.2021.6.1236]
- Huang X D, Li X B, Liu C Y, Zhou M Q and Wang J S. 2019. Remote sensing inversion of snow cover extent and snow depth/snow water equivalent on the Qinghai-Tibet Plateau: advance and challenge. *Journal of Glaciology and Geocryology*, 41(5): 1138-1149 (黄晓东, 李旭冰, 刘畅宇, 周敏强, 王健顺. 2019. 青藏高原积雪范围和雪深/雪水当量遥感反演研究进展及挑战. *冰川冻土*, 41(5): 1138-1149) [DOI: 10.7522/j.issn.1000-0240.2019.0529]
- Jiang L M, Shi J C, Tjuatja S, Chen K S, Du J Y and Zhang L X. 2011. Estimation of snow water equivalence using the polarimetric scanning radiometer from the cold land processes experiments (CLPX03). *IEEE Geoscience and Remote Sensing Letters*, 8(2): 359-363 [DOI: 10.1109/LGRS.2010.2076345]
- Jiang L M, Wang P, Zhang L X, Yang H and Yang J T. 2014. Improvement of snow depth retrieval for FY3B-MWRI in China. *Science China Earth Sciences*, 44(3): 531-547 (蒋玲梅, 王培, 张立新, 杨虎, 杨俊涛. 2014. FY3B-MWRI 中国区域雪深反演算法改进. *中国科学: 地球科学*, 44(3): 531-547) [DOI: 10.1360/zd-2014-44-3-531]
- Josberger E G and Mognard N M. 2002. A passive microwave snow depth algorithm with a proxy for snow metamorphism. *Hydrological Processes*, 16(8): 1557-1568 [DOI: 10.1002/hyp.1020]
- Karniadakis G E, Kevrekidis I G, Lu L, Perdikaris P, Wang S F and Yang L. 2021. Physics-informed machine learning. *Nature Reviews Physics*, 3(6): 422-440 [DOI: 10.1038/s42254-021-00314-5]
- Karpatne A, Atluri G, Faghmous J H, Steinbach M, Banerjee A, Ganguly A, Shekhar S, Samatova N and Kumar V. 2017. Theory-Guided data science: a new paradigm for scientific discovery from data. *IEEE Transactions on Knowledge and Data Engineering*, 29(10): 2318-2331 [DOI: 10.1109/TKDE.2017.2720168]
- Kashinath K, Mustafa M, Albert A, Wu J L, Jiang C, Esmaeilzadeh S, Azizzadenesheli K, Wang R, Chattopadhyay A, Singh A, Manepalli A, Chirila D, Yu R, Walters R, White B, Xiao H, Tchelepi H A, Marcus P, Anandkumar A, Hassanzadeh P, and Prabhat. 2021. Physics-informed machine learning: case studies for weather and climate modelling. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 379 (2194): 20200093 [DOI: 10.1098/rsta.2020.0093]
- Kelly R. 2009. The AMSR-E snow depth algorithm: description and initial results. *Journal of The Remote Sensing Society of Japan*, 29(1): 307-317 [DOI: 10.11440/rssj.29.307]
- Kelly R E, Chang A T, Tsang L and Foster J L. 2003. A prototype AMSR-E global snow area and snow depth algorithm. *IEEE Transactions on Geoscience and Remote Sensing*, 41(2): 230-242 [DOI: 10.1109/TGRS.2003.809118]
- Kim Y, Kimball J S, Robinson D A and Derksen C. 2015. New satellite climate data records indicate strong coupling between recent frozen season changes and snow cover over high northern latitudes. *Environmental Research Letters*, 10(8): 084004 [DOI: 10.1088/1748-9326/10/8/084004]
- Landman W. 2010. Climate change 2007: the physical science basis. *South African Geographical Journal*, 92(1): 86-87 [DOI: 10.1080/03736245.2010.480842]
- Lemmetyinen J, Pulliainen J, Rees A, Kontu A, Qiu Y B and Derksen C. 2010. Multiple-Layer adaptation of HUT snow emission model: comparison with experimental data. *IEEE Transactions on Geoscience and Remote Sensing*, 48(7): 2781-2794 [DOI: 10.1109/TGRS.2010.2041357]
- Li X, Che T and Li X W. 2020. *Remote Sensing of Cryosphere*. Beijing: Science Press (李新, 车涛, 李新武. 2020. *冰冻圈遥感学*. 北京: 科学出版社)
- Liu Y, Li L H, Yang J M, Chen X and Zhang R. 2018. Snow depth inversion based on D-InSAR method. *National Remote Sensing Bulletin*, 22(5): 802-809 (刘洋, 李兰海, 杨金明, 陈曦, 张润. 2018. D-InSAR 技术的积雪深度反演. *遥感学报*, 22(5): 802-809) [DOI: 10.11834/jrs.20187125]
- Löwe H and Picard G. 2015. Microwave scattering coefficient of snow in MEMLS and DMRT-ML revisited: the relevance of sticky hard spheres and tomography-based estimates of stickiness. *The Cryosphere*, 9(6): 2101-2117 [DOI: 10.5194/tc-9-2101-2015]
- Luoju K, Pulliainen J, Takala M, Lemmetyinen J, Mortimer C, Derksen C, Mudryk L, Moisander M, Hiltunen M, Smolander T, Ikonen J, Cohen J, Salminen M, Norberg J, Veijola K and Venäläinen P. 2021. GlobSnow v3.0 Northern Hemisphere snow water equivalent dataset. *Scientific Data*, 8(1): 163 [DOI: 10.1038/s41597-021-00939-2]
- Mätzler C and Wiesmann A. 1999. Extension of the microwave emission model of layered snowpacks to coarse-grained snow. *Remote Sensing of Environment*, 70(3): 317-325 [DOI: 10.1016/S0034-4257(99)00047-4]
- Mhawej M, Faour G, Fayad A and Shaban A. 2014. Towards an enhanced method to map snow cover areas and derive snow-water equivalent in Lebanon. *Journal of Hydrology*, 513: 274-282 [DOI: 10.1016/j.jhydrol.2014.03.058]
- Niu G Y and Yang Z L. 2007. An observation-based formulation of snow cover fraction and its evaluation over large North American river basins. *Journal of Geophysical Research: Atmospheres*, 112

- (D21) [DOI: 10.1029/2007JD008674]
- Pavlyshenko B. 2018. Using stacking approaches for machine learning models//Proceedings of 2018 IEEE Second International Conference on Data Stream Mining and Processing (DSMP). Lviv: IEEE: 255-258 [DOI: 10.1109/DSMP.2018.8478522]
- Picard G, Sandells M and Löwe H. 2018. SMRT: an active – passive microwave radiative transfer model for snow with multiple micro-structure and scattering formulations (v1.0). Geoscientific Model Development, 11(7): 2763-2788 [DOI: 10.5194/gmd-11-2763-2018]
- Pulliainen J. 2006. Mapping of snow water equivalent and snow depth in boreal and sub-arctic zones by assimilating space-borne microwave radiometer data and ground-based observations. Remote Sensing of Environment, 101(2): 257-269 [DOI: 10.1016/j.rse.2006.01.002]
- Pulliainen J, Luojus K, Derksen C, Mudryk L, Lemmetyinen J, Salminen M, Ikonen J, Takala M, Cohen J, Smolander T and Norberg J. 2020. Patterns and trends of Northern Hemisphere snow mass from 1980 to 2018. Nature, 581(7808): 294-298 [DOI: 10.1038/s41586-020-2258-0]
- Pulliainen J T, Grandell J and Hallikainen M T. 1999. HUT snow emission model and its applicability to snow water equivalent retrieval. IEEE Transactions on Geoscience and Remote Sensing, 37(3): 1378-1390 [DOI: 10.1109/36.763302]
- Qin D H, Chen Z L, Luo Y, Ding Y H, Dai X S, Ren J W, Zhai P M, Zhang X Y, Zhao Z C, Zhang D E, Gao X J and Shen Y P. 2007. Updated understanding of climate change sciences. Climate Change Research, 3(2): 63-73 (秦大河, 陈振林, 罗勇, 丁一汇, 戴晓苏, 任贾文, 翟盘茂, 张小曳, 赵宗慈, 张德二, 高学杰, 沈永平. 2007. 气候变化科学的最新认知. 气候变化研究进展, 3(2): 63-73) [DOI: 10.3969/j.issn.1673-1719.2007.02.001]
- Richardson M, Davenport I and Gurney R. 2014. Global snow mass measurements and the effect of stratigraphic detail on inversion of microwave brightness temperatures//Bengtsson L, Bonnet R M, Calisto M, Destouni G, Gurney R, Johannessen J, Kerr Y, Lahoz W A, Rast M, eds. The Earth's Hydrological Cycle. Dordrecht: Springer: 785-812 [DOI: 10.1007/978-94-017-8789-5_14]
- Shi J C, Xiong C and Jiang L M. 2016. Review of snow water equivalent microwave remote sensing. Science China Earth Sciences, 59(4): 731-745 (施建成, 熊川, 蒋玲梅. 2016. 雪水当量主被动微波遥感研究进展. 中国科学: 地球科学, 46(4): 529-543) [DOI: 10.1360/N072015-00031]
- Takala M, Luojus K, Pulliainen J, Derksen C, Lemmetyinen J, Kärnä J P, Koskinen J and Bojkov B. 2011. Estimating northern hemisphere snow water equivalent for climate research through assimilation of space-borne radiometer data and ground-based measurements. Remote Sensing of Environment, 115(12): 3517-3529 [DOI: 10.1016/j.rse.2011.08.014]
- Tan J, Ding J L, Zhang J Y and Wu P F. 2018. Spatiotemporal variation of temperature in North Xinjiang during the period of 1961-2014. Arid Zone Research, 35(5): 1181-1191 (谭娇, 丁建丽, 张钧泳, 武鹏飞. 2018. 1961—2014年新疆北部地区气温时空变化特征. 干旱区研究, 35(5): 1181-1191) [DOI: 10.13866/j.azr.2018.05.23]
- Tedesco M and Jeyaratnam J. 2016. A new operational snow retrieval algorithm applied to historical AMSR-E brightness temperatures. Remote Sensing, 8(12): 1037 [DOI: 10.3390/rs8121037]
- Tedesco M, Pulliainen J, Takala M, Hallikainen M and Pampaloni P. 2004. Artificial neural network-based techniques for the retrieval of SWE and snow depth from SSM/I data. Remote Sensing of Environment, 90(1): 76-85 [DOI: 10.1016/j.rse.2003.12.002]
- Tsang L and Li Q. 1999. Microwave remote sensing theory//Webster J G, ed. Wiley Encyclopedia of Electrical and Electronics Engineering. New York: John Wiley [DOI: 10.1002/047134608X.W3615]
- Tsokas A, Rysz M, Pardalos P M and Dipple K. 2022. SAR data applications in earth observation: an overview. Expert Systems with Applications, 205: 117342 [DOI: 10.1016/j.eswa.2022.117342]
- Vaswani A, Shazeer N, Parmar N, Uszkoreit J, Jones L, Gomez A N, Kaiser Ł and Polosukhin I. 2017. Attention is all you need//Proceedings of the 31st International Conference on Neural Information Processing Systems. Long Beach: Curran Associates Inc.: 6000-6010
- Wang J, Che T, Dai L Y, Yue S N and Zheng 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, 岳珊珊, 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, Che T, Li Z, Li H Y, Hao X H, Zheng Z J, Xiao P F, Li X F, Huang X D, Zhong X Y, Dai L Y, Li H X, Ke C Q and Li L H. 2018. Investigation on snow characteristics and their distribution in china. Advance in Earth Sciences, 33(1): 12-15 (王建, 车涛, 李震, 李弘毅, 郝晓华, 郑照军, 肖鹏峰, 李晓峰, 黄晓东, 钟歆玥, 戴礼云, 李红星, 柯长青, 李兰海. 2018. 中国积雪特性及分布调查. 地球科学进展, 33(1): 12-15) [DOI: 10.11867/j.issn.1001-8166.2018.01.0012]
- Wang Y L, Huang X D, Wang J S, Zhou M Q and Liang T G. 2019. AMSR2 snow depth downscaling algorithm based on a multifactor approach over the Tibetan Plateau, China. Remote Sensing of Environment, 231: 111268 [DOI: 10.1016/j.rse.2019.111268]
- Wegmuller U and Matzler C. 1999. Rough bare soil reflectivity model. IEEE Transactions on Geoscience and Remote Sensing, 37(3): 1391-1395 [DOI: 10.1109/36.763303]
- West R, Tsang L and Winebrenner D P. 1993. Dense medium radiative transfer theory for two scattering layers with a Rayleigh distribution of particle sizes. IEEE Transactions on Geoscience and Remote Sensing, 31(2): 426-437 [DOI: 10.1109/36.214919]
- Wiesmann A and Mätzler C. 1999. Microwave emission model of layered snowpacks. Remote Sensing of Environment, 70(3): 307-316 [DOI: 10.1016/S0034-4257(99)00046-2]
- Wolpert D H. 1992. Stacked generalization. Neural Networks, 5(2): 241-259 [DOI: 10.1016/S0893-6080(05)80023-1]
- Xiao X X and Zhang T J. 2018. Passive microwave remote sensing of snow depth and snow water equivalent: overview. Advances in

- Earth Science, 33(6): 590-605 (肖雄新, 张廷军. 2018. 基于被动微波遥感的积雪深度和雪水当量反演研究进展. 地球科学进展, 33(6): 590-605) [DOI: 10.11867/j.issn.1001-8166.2018.06.0590]
- Xiao X X, Zhang T J, Zhong X Y, Shao W W and Li X D. 2018. Support vector regression snow-depth retrieval algorithm using passive microwave remote sensing data. Remote Sensing of Environment, 210: 48-64 [DOI: 10.1016/j.rse.2018.03.008]
- Xu X C, Liu X P, Li X, Shi Q, Chen Y M and Ai B. 2022. Global snow depth retrieval from passive microwave brightness temperature with machine learning approach. IEEE Transactions on Geoscience and Remote Sensing, 60: 4302917 [DOI: 10.1109/TGRS.2021.3127202]
- Yang J W, Jiang L M, Lemmetyinen J, Pan J M, Luo J K and Takala M. 2021. Improving snow depth estimation by coupling HUT-optimized effective snow grain size parameters with the random forest approach. Remote Sensing of Environment, 264: 112630 [DOI: 10.1016/j.rse.2021.112630]
- Yang J W, Jiang L M, Luo J K, Pan J M, Lemmetyinen J, Takala M and Wu S L. 2020. Snow depth estimation and historical data reconstruction over China based on a random forest machine learning approach. The Cryosphere, 14(6): 1763-1778 [DOI: 10.5194/tc-14-1763-2020]
- Zhao H Y, Hao X H, Wang J, Li H Y, Huang G H, Shao D H, Su B, Lei H J and Hu X J. 2020. The spatial - spectral - environmental extraction endmember algorithm and application in the MODIS fractional snow cover retrieval. Remote Sensing, 12(22): 3693 [DOI: 10.3390/rs12223693]
- Zhao Q, Hao X H, He D C, Wang J, Li H Y and Wang X F. 2021a. The relationship between the temporal and spatial changes of snow cover and climate and vegetation in northern Xinjiang from 1980 to 2019. Remote Sensing Technology and Application, 36(6): 1247-1258 (赵琴, 郝晓华, 和栋材, 王建, 李弘毅, 王旭峰. 2021a. 1980~2019年北疆积雪时空变化与气候和植被的关系. 遥感技术与应用, 36(6): 1247-1258) [DOI: 10.11873/j.issn.1004-0323.2021.6.1247]
- Zhao Q, Hao X H, Wang J, Luo S Q, Shao D H, Li H Y, Feng T W and Zhao H Y. 2022. Snow cover phenology change and response to climate in China during 2000-2020. Remote Sensing, 14(16): 3936 [DOI: 10.3390/rs14163936]
- Zhao Q, Hao X H, Wang J, Sun X L and Li H Y. 2021b. A dataset of snow phenology in China based on MODIS from 2000 to 2020. National Cryosphere Desert Data Center (赵琴, 郝晓华, 王建, 孙兴亮, 李弘毅. 2021b. 2000-2020年MODIS中国积雪物候数据集. 国家冰川冻土沙漠科学数据中心)
- Zhou Z H. 2016. Machine Learning. Beijing: Tsinghua University Press (周志华. 2016. 机器学习. 北京: 清华大学出版社)

Snow depth downscaling algorithm using coupled deep learning and microwave radiative transfer model driven by multi-source remote sensing data

ZHAO Zisheng¹, HAO Xiaohua^{2,3}, REN Hongrui¹, LUO Siqiong⁴, DAI Liyun², SHAO Donghang², FENG Tianwen⁵, ZHAO Qin², JI Wenzheng², LIU Yan^{6,7}

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.Key Laboratory of Land Surface Process and Climate Change in Cold and Arid Regions, Northwest Institute of Eco-Environment and Resources, Chinese Academy of Sciences, Lanzhou 730000, China;

5.Faculty of Geomatics, Lanzhou Jiaotong University, Lanzhou 730070, China;

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

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

Abstract: High spatiotemporal resolution snow depth data are crucial for hydrological modeling and disaster forecasting. Currently, high temporal resolution snow depth data are typically derived from passive microwave measurements, which has not been able to meet the needs of regional hydrological and disaster studies due to the low spatial resolution based only on passive microwave data. On the basis of passive microwave brightness temperature data and combined with high-resolution optical remote sensing data, this paper aims to develop a high-precision downscale snow depth inversion algorithm to provide high spatial and temporal resolution snow depth data for regional-scale hydrology and climate research.

This study proposes a downscaling snow depth retrieval algorithm based on multi-source remote sensing data such as passive microwave and optical, coupled with a deep learning model (Feature Tokenizer + Transformer, FT-Transformer) and a Snow Microwave Radiative Transfer (SMRT) model. Deep learning is used to map the complex nonlinear relationship between features such as AMSR 2

brightness temperature difference (TBD), Snow Cover Days (SCD), Snow Cover Fraction (SCF), and snow depth. Considering the influence of the physical properties of snow, the coupled SMRT is fitted with the Effective Snow Grain size (ESG) to characterize the spatiotemporal dynamic snow properties, and it is input into the deep learning model to achieve downscale inversion of snow depth.

This algorithm was used to obtain downscaled snow depth data at 500 m spatial resolution in northern Xinjiang. Model training and validation were conducted using observed data from 39 stations in northern Xinjiang. The validation results revealed that SCD can effectively represent the snow accumulation process. Independent validation showed an 18% improvement in RMSE, indicating enhanced spatial generalization capability of the model. The inclusion of the ESG feature significantly improved the overall accuracy of the deep learning-based downscaled snow depth retrieval, resulting in an RMSE of 6.82 cm. This represents a 15% improvement compared with the model without the ESG feature. Additionally, the inclusion of the ESG feature greatly mitigated the underestimation of deep snow (>40 cm), leading to a 35% improvement in RMSE for such conditions. Furthermore, the time series analysis shows that ESG is consistent with the trend of measured snow depth, thereby constraining and stabilizing the output of the FT-Transformer model. Finally, compared with existing snow depth products such as AMSR2, ERA5-Land, and SDDsd, the downscaled snow depth data from this study exhibited superior validation accuracy, with an RMSE of 6.51 cm. The spatial distribution of snow depth was also refined, particularly capturing the complex snow depth heterogeneity in the mountainous regions of northern Xinjiang.

This study explored the feasibility of combining the SMRT model with deep learning for downscaled snow depth retrieval. It obtained a downscaled snow depth product with high accuracy performance in northern Xinjiang, providing a reliable snow depth inversion method with high spatial and temporal resolution for hydrological modeling and disaster forecasting.

Key words: remote sensing, snow depth, downscaling algorithm, deep learning, SMRT, AMSR 2, snow cover days

Supported by National Key Research and Development Program of China (No. 2022YFF0711702-05); National Natural Science Foundation of China (No. U22A20564); Key Project of Natural Science Foundation of Gansu Province (No. 24JRRA082); West Light Foundation of the Chinese Academy of Sciences (No. xbzg-zdsys-202102); Program of the Key Laboratory of Cryospheric Science and Frozen Soil Engineering, CAS (No. CSFSE-ZZ-2402)