

基于深度学习和遥感大数据的亚洲高山区2020年有时间戳标记的冰川编目

柯长青^{1,2*}, 肖瑶^{1,2}, 范宇宾³, 罗兰花^{1,2}, 蔡宇^{1,2}, 沈校熠⁴, 王根育^{1,2}, 吴娟⁵, 庄立超^{1,2}, 王敬明^{1,2}, 刘伊格^{1,2}, 邵典伟^{1,2}, 何志越^{1,2}, 胡筱舟^{1,2}, 袁腾飞^{1,2}

1. 南京大学地理与海洋科学学院, 江苏省地理信息科学与技术重点实验室, 自然资源部陆地卫星遥感应用重点实验室, 南京 210023

2. 软件新技术与产业化协同创新中心, 南京 210023

3. 池州学院地理与规划学院, 池州 247000

4. 河海大学地球科学与工程学院, 南京 211100

5. 广西壮族自治区水利电力勘测设计研究院有限责任公司, 南宁 530022

* 通讯作者, E-mail: kecq@nju.edu.cn

2025-01-25收稿, 2025-09-04修回, 2025-10-14接受, 2025-12-05网络版发表

江苏省科技计划国际合作项目(BZ2024032)和国家自然科学基金(41830105、42201135)资助

摘要 亚洲高山区拥有全球中低纬度规模最大、分布最广的山地冰川, 是“亚洲水塔”的重要组成部分。以往区域性冰川编目中所使用遥感数据的时间跨度差异影响了冰川研究的定量评估。本研究利用2020年7–9月冰川消融期内的遥感大数据, 包括无云Sentinel-2和Landsat-8光学影像, 以及Sentinel-1 SAR数据, 生成了亚洲高山区新一代有时间戳标记的冰川编目(HMAGI-2020)。采用VGG16-UNET深度学习模型, 综合光谱、极化和地形特征作为输入, 自动识别冰川边界, 精度达到92.8%。基于现有冰川编目对自动提取结果进行分区, 并以Sentinel-2影像为主、Landsat-8为辅开展人工修正。共完成93043条冰川的人工校正, 并基于Copernicus DEM为每条冰川计算了面积、周长和地形参数等15项属性。HMAGI-2020包含97934条面积大于0.01 km²的冰川, 总面积为91837.77±2527.70 km²。通过缓冲区法结合VGG16-UNET模型计算得出冰川识别的平均不确定度为±6.67%。亚洲高山区冰川平均表面高程约5094 m, 平均坡度25.66°, 超过75%的冰川朝向正南、西南或东南方向。与历史冰川编目对比表明, 过去二十年亚洲高山区冰川普遍退缩, 东南部地区冰川面积减少超过20%, 而喀喇昆仑-西昆仑地区相对稳定, 面积仅轻微增加不足1%。凭借数据源一致性和精度优势, HMAGI-2020可提供2020年亚洲高山区精确的冰川边界与属性数据, 有望为全球变暖背景下该区域的冰川学、气候变化及水资源管理研究提供关键数据支撑。

关键词 冰川编目, 遥感, 大数据, 深度学习, 亚洲高山区

1 引言

以青藏高原为核心的亚洲高山区(High Mountain Asia, HMA), 拥有全球中低纬度规模最大的山地冰川分布(Yao等, 2012; Kraaijenbrink等, 2017; Pfeffer等, 2017), 常被誉为“亚洲水塔”和“地球第三极”(Yao等, 2022), 作为长江、黄河、印度河与雅鲁藏布江等著名河

流的发源地, 其具有至关重要的生态战略地位。该地区巨大的冰川储量正经历显著变化, 这些变化可能影响上述河流的径流量, 进而对周边广大人口产生重要影响(Immerzeel等, 2010; Khanal等, 2021)。尤其在干旱地区, 冰川融水已成为当地水资源的关键供给来源(Akhtar等, 2008; Kehrwald等, 2008; Sorg等, 2012; Yao等, 2022)。亚洲高山区始终是冰川研究的重点区域, 最新研

中文引用格式: 柯长青, 肖瑶, 范宇宾, 罗兰花, 蔡宇, 沈校熠, 王根育, 吴娟, 庄立超, 王敬明, 刘伊格, 邵典伟, 何志越, 胡筱舟, 袁腾飞. 2026. 基于深度学习和遥感大数据的亚洲高山区2020年有时间戳标记的冰川编目. 中国科学: 地球科学, 56(1): 250–266, doi: 10.1360/N072025-0030

英文引用格式: Ke C, Xiao Y, Fan Y, Luo L, Cai Y, Shen X, Wang G, Wu J, Zhuang L, Wang J, Liu Y, Shao D, He Z, Hu X, Yuan T. 2026. A new time-stamped glacier inventory of High Mountain Asia based on deep learning and remote sensing big data in 2020. Science China Earth Sciences, 69(1): 236–252, <https://doi.org/10.1007/s11430-025-1725-9>

究表明,该地区正呈现显著的变暖趋势,导致多数冰川加速消融(Brun等, 2017; Hugonnet等, 2021)。其中,青藏高原东南部的冰川消退速率已超过其他高山冰川区(Zhao等, 2022; Luo等, 2023)。然而有趣的是,东帕米尔-喀喇昆仑-西昆仑地区却呈现出冰川前进与物质积累现象,被称为“喀喇昆仑异常”(Gardelle等, 2012; Farinotti等, 2020)。与此同时,越来越多的研究聚焦于冰川水文学领域,特别关注冰川退化引发的冰湖溃决、洪水等灾害对区域水文的影响(Nie等, 2021; Peng M等, 2023)。因此,获取精确的冰川编目数据已成为亚洲高山区冰川研究的基础性工作。在冰川普遍退缩的背景下,这一需求显得尤为迫切。更新现有冰川编目对于减少物质平衡计算、未来冰川演化预测、水文径流模拟等诸多研究中的不确定性具有关键意义(Soheb等, 2022)。

大范围冰川的测量与制图可通过遥感技术有效实现,但目前针对整个亚洲高山区仍缺乏全面统一的冰川编目。现有关于该地区的冰川学研究主要依赖国际冰川编目,包括Randolph Glacier Inventory (RGI)(Pfeffer等, 2017)、全球空间陆地冰川测量(Global Land Ice Measurements from Space, GLIMS),以及中国第一、二次冰川编目(CGI-1和CGI-2)(Guo等, 2015)。尽管已有研究针对特定山系生成了区域冰川编目,但这些数据集在空间覆盖度和制图时间上存在显著差异(Bolch等, 2010; Frey等, 2012; Soheb等, 2022; Mishra等, 2023; Xiao等, 2023; Xie等, 2023)。将这些异构数据整合用于整个亚洲高山区的冰川学研究仍具挑战性。多数冰川编目源于光学影像、地形图或航空像片(Paul等, 2017)。虽然通过阈值分割与人工数字化可实现区域冰川编目制图,但通常需要整合多年遥感数据(时间跨度从数年至数十年不等)。这种制图时间的不一致性可能导致冰川面积的高估或低估,进而给冰川物质平衡和区域冰储量计算带来难以量化的不确定性(Paul等, 2013; Friedl等, 2020)。在夏季云覆盖和降水频繁的区域(如青藏高原东南部),CGI-1的时间跨度甚至长达30年(Guo等, 2015; Xiao等, 2023)。造成这种长时间跨度的原因之一在于早期冰川编目仅依赖单一数据源(如主要使用Landsat影像),仅有少数研究结合了高分辨率商业卫星数据(Paul and Andreasen, 2009; Frey等, 2012; Winsvold等, 2016)。

合成孔径雷达(Synthetic Aperture Radar, SAR)凭借其全天候观测能力(Winsvold等, 2018),近年来在冰川制图中得到广泛应用。然而,传统阈值分割等方法在SAR影像冰川识别中存在局限,尤其在冰川与周边地物的区分方面表现不足。随着深度学习技术的发展,计算机视觉方法日益应用于冰川遥感领域,尤其在表碛覆盖

冰川检测方面表现出显著优势,已被广泛用于区域尺度冰川制图(Alifu等, 2020; Robson等, 2020; Peng Y等, 2023)。深度学习的引入,以及融合SAR与光学数据,显著提升了冰川自动提取的效率和精度(Peng Y等, 2023; Sun等, 2024)。当前主流的深度学习模型包括卷积神经网络(Convolutional Neural Networks, CNN)系列(如U-Net、DeepLab、SegNet),以及新兴的Transformer架构。这些模型在遥感影像语义分割中表现出色,并逐渐应用于冰川制图。例如Xie等(2022)开发的GlacierNet系列在表碛覆盖冰川与消融区识别中表现优异; Maslov等(2025)提出的Glacier-VisionTransformer-U-Net即使在训练数据匮乏区域也能实现高精度冰川边界提取,其结果与专家人工勾绘精度相当,突出了深度学习方法在大规模冰川编目工作中的扩展性与泛化能力。尽管如此,当前大多数冰川制图研究仍基于CNN架构且通常采用单一遥感数据类型,全面融合SAR与光学影像等多源数据的研究仍显不足。因此,有必要整合多源遥感数据集并应用强健的算法,以进一步提升冰川提取效率。相较于传统方法,光学与SAR数据的融合可显著缩短因数据获取限制导致的时间滞后(Zhang等, 2021; Xiao等, 2023),有望在单一年度内实现完整且时效性强的区域冰川制图。

鉴于亚洲高山区冰川在过去数十年间持续消融的背景,以及该区域缺乏覆盖全域且没有统一时间基准的冰川编目,因此,获取区域内高精度、时序一致的冰川编目数据显得尤为重要,理想情况下应采用同一年度数据以确保时效性。为满足这些要求,本研究采用2020年冰川消融期(7-9月)的Sentinel-2和Landsat-8影像,两者兼具高分辨率与短重访周期特点,是理想的冰川监测数据源。同时辅以同期的Sentinel-1 SAR数据,利用其云层穿透能力捕获冰川表面特征,有效弥补光学影像受云层及阴影遮挡造成的数据缺失。通过深度学习自动识别与人工数字化修正相结合的方式,完成全域冰川边界制图工作,并进一步提取、计算了面积、周长和表面地形特征等冰川基本属性,生成2020年亚洲高山区有时间戳标记的冰川编目(HMAGI-2020)(Xiao等, 2024)。最后,通过与已有冰川编目的对比评估,验证新编目数据的可靠性。

2 研究区

亚洲高山区位于亚洲中部,以青藏高原及其周边山脉为核心,发育着全球中低纬度规模最大、分布最广的山地冰川(Brun等, 2017)。该区域由喜马拉雅山脉、昆仑山脉、冈底斯山脉、祁连山脉和天山山脉等主要山系组成。根据Randolph冰川编目的划分标准,亚洲高山区

被划分为15个不同的冰川区(Pfeffer等, 2017)(图1)。该地区主要受3种季风环流模式影响(Wang等, 2008):西部和北部主要受西风环流控制,西南部受印度季风强烈影响,而东部和东南部则主要受东亚季风支配。区域内冰川总面积超过 $1.2 \times 10^5 \text{ km}^2$ (Pfeffer等, 2017),其冰川与积雪分布对全球气候变化具有重要影响(Kraaijenbrink等, 2017; Dehecq等, 2019)。在全球气候变暖背景下,区域内气温上升导致过去几十年间多数冰川面积快速缩减,并伴随冰川物质损失的加速(Wang等, 2021; Fan等, 2023)。与此同时,预测研究表明“喀喇昆仑异常”现象也将在未来逐渐终结(Hugonnet等, 2021; Xu等, 2023)。

3 数据与方法

3.1 数据

本研究采用多源数据集(表1),包括2020年7–9月消融期内的光学与SAR影像。其中Sentinel-2 Level-2A数据作为冰川边界提取的首选数据源,Landsat-8数据用于补充Sentinel-2中云覆盖区域的提取,而Sentinel-1数据则作为光学影像云覆盖区的替代数据。所用遥感影像数据总量约22923 GB,覆盖亚洲高山区15个冰川区的所有冰川,是生成HMAGI-2020的真正遥感大数据(表2)。研究

采用Copernicus DEM产品计算冰川坡度、坡向及高程等地形指标,生成的坡度数据同时作为深度学习训练数据集之一。此外,利用RGI冰川编目辅助冰川边界的矢量化工作。

3.2 数据处理

在Google Earth Engine(GEE)云平台上,对2020年7–9月覆盖冰川的Sentinel-2和Landsat-8光学数据进行了去云处理(图2)。去云算法严格遵循官方云掩膜目录中Sentinel-2和Landsat-8的去云代码示例。雪在可见光/红外波段的反射率显著高于裸冰和表碛覆盖冰川,为减少降雪对冰川及周边区域的影响,通过去除云层并取所有影像波段的最小值生成图像合成结果,最终生成了Sentinel-2与Landsat-8的合成影像。与此同时,计算了特定波段组合(近红外、红光、绿光波段)及归一化积雪指数(Normalized Snow Deposition Index, NDSI)。

针对SAR影像在山地地区存在的几何畸变和地形效应导致的后向散射变化等固有局限,本研究采用SNAP(Sentinel应用平台)中的地形校正(Radiometric Terrain Correction, RTC)方法对Sentinel-1影像进行处理。使用Copernicus 30 m DEM校正地形引起的后向散射变化,尽可能减少叠掩和阴影效应。预处理后,将经过RTC校正的SAR后向散射影像与配准后的光学影像(Sentinel-2或




图1 亚洲高山区数字高程模型(DEM)、区域划分及冰川与主要河流分布,分别基于Copernicus DEM和Randolph冰川编目(RGI)数据绘制

表1 本研究生成HMAGI-2020所使用的卫星影像与数据

数据集	年份	分辨率	来源	使用目的
Sentinel-2	2020/7–2020/9	10 m	https://earthengine.google.com/	冰川范围制图
Landsat-8	2020/7–2020/9	30 m		
Sentinel-1	2020/7–2020/9	10 m		
Copernicus DEM	2010–2015	30 m	https://dataspace.copernicus.eu/	地形参数提取
RGI	2000–2014	/	https://www.glims.org/RGI/	流域划分、辅助矢量化

表2 HMAGI-2020冰川编目生成过程中使用的卫星影像
(单位: 景)

序号	区域	Sentinel-2	Landsat-8	Sentinel-1
1	希萨尔阿莱	750	107	181
2	帕米尔	733	87	216
3	西天山	1729	195	419
4	东天山	1601	149	389
5	西昆仑	614	78	207
6	东昆仑	1445	151	447
7	祁连山	1496	129	409
8	青藏高原内流区	2554	209	740
9	青藏高原东南部	888	73	417
10	兴都库什	913	99	252
11	喀喇昆仑	525	69	204
12	西喜马拉雅	799	92	271
13	中喜马拉雅	359	37	229
14	东喜马拉雅	240	18	244
15	横断山	427	38	396
16	整个亚洲高山区	15073	1531	5021

Landsat-8)堆叠生成多通道输入数据: SAR波段提供结构与表面粗糙度信息, 光学波段则提供光谱与辐射信息。这种数据级融合使深度学习模型能够利用互补信息, 提升在光学影像云覆盖或缺失区域的性能。

尽管我们认可GEE的优势并将其用于数据选择与光学影像筛选等其他任务, 但本研究中Sentinel-1的RTC校正采用SNAP平台, 因其能提供更精确的控制、DEM选择及结果可复现性, 这对确保山地冰川边界提取的高精度至关重要。为保持空间分辨率一致性, 使用双线性插值法将Sentinel-1和Sentinel-2数据重采样至30 m分辨率。

3.3 冰川制图

基于已有冰川制图的研究(Paul and Andreassen, 2009; Soheb等, 2022), 本研究采用深度学习与人工修正相结合的两步法进行冰川边界提取: 首先通过融合SAR与光学影像的深度学习模型自动提取冰川区域, 随后对自动生成的冰川边界进行人工精细化修正, 最终实现2020年亚洲高山区冰川(包含纯净冰川和表碛覆盖冰

川)的高精度制图。在训练数据集构建过程中, 通过结合传统阈值法提升模型训练质量。具体而言, 对光谱特征明显区域应用阈值分割($NDSI>0.4=冰/雪$)(Bolch等, 2010; Xie等, 2023), 快速生成二值化冰川掩膜, 从中提取高置信度冰川样本用于训练深度学习模型。该方法有效增强了模型识别复杂场景(如表碛覆盖区与阴影区冰川)的能力, 显著提升了冰川识别的鲁棒性。针对光学与SAR影像的自动冰川识别, 首先创建标注数据集(图3)。对2020年Sentinel-2与Landsat-8影像应用阈值法生成网络标注所需的冰川样本轮廓, 基于获得的二值影像与真彩色合成影像, 结合RGI数据采用人工修正方法绘制冰川样本标注(包含表碛覆盖冰川)。修正过程中确保样本在不同山系的均匀分布。在构建深度学习训练数据集时, 将所有冰川样本(含洁净冰与表碛覆盖冰川)作为二分类任务中的单一类别(冰川/非冰川)。从多源卫星影像中共生成14515个标注冰川样本, 其中Sentinel-2占比82%, Landsat-8占比18%。虽未在标注阶段显式区分表碛覆盖冰川, 但视觉检查证实大量样本来自西喜马拉雅等表碛覆盖占比较多的区域, 确保模型在训练中能学习到与洁净冰川和表碛覆盖冰川相关的光谱及后向散射特征。将样本裁剪为256×256尺寸, 共获得14515个图像块, 按6:2:2比例随机划分为训练集、验证集和测试集。采用左右翻转、上下翻转及对角线翻转等数据增强方法扩展数据集(Zhang等, 2021), 提升模型泛化能力。最终将训练好的模型应用于同年覆盖整个区域的完整场景影像(独立于测试集), 生成自动化的冰川轮廓数据。

然后对深度学习网络进行训练与验证, 深度学习网络已被广泛应用于冰川编目研究(Maslov等, 2025)。模型训练采用12个参数: Sentinel-2和Landsat-8的近红外、红、绿波段共6个参数, 分别计算的NDSI值, Sentinel-1的VV与VH极化数据, 以及DEM高程和坡度两个地形因子。选择VGG16作为深度学习模型的编码器以提取遥感影像中的潜在纹理与几何特征, 并采用UNET框架作为模型结构与解码器, 对提取的特征进行冰川识别分析(Xie等, 2020; Marochov等, 2021)。网络参数设置与




图2 基于深度学习与遥感大数据的HMAGI-2020生成流程图

结构参考了Xiao等(2023)在研究青藏高原东南部冰川识别时采用的方案。

在深度学习得到冰川二值化结果的基础上,通过形态学开闭运算消除冰川外围区域的孤立积雪像元,并填充冰川内部表碛覆盖区域的空隙。将最终结果转换为Shapefile格式,在ArcGIS中与光学影像图层及ArcGIS Online提供的高分辨率影像底图进行叠加验证。对深度学习预测结果进行逐一手动数字化修正,对于因云覆盖或影像质量问题无法数字化的区域,保留深度学习识别结果(图2)。

在大多数情况下,冰川边界勾绘严格遵循RGI冰川编目规范。对于少数新发现且面积大于 0.1 km^2 但未包含在RGI数据集中的冰川,予以完整保留。

3.4 不确定性

在遥感影像冰川识别中,不确定性主要源于源数据特性及后续人工修正引入的误差(Frey等, 2012; Paul等, 2017)。前者包括云覆盖、季节性积雪、阴影和冰川碎片等因素,导致遥感影像识别方法中出现误分类。然而这些不确定性难以量化,因其大多可通过人工数字化修正(参见第3.3节)(Soheb等, 2022; Xie等, 2023)。人工修正误差主要受遥感影像分辨率影响,本研究采用缓冲区法(Paul等, 2017)评估空间分辨率引起的不确定性:

对所有冰川边界应用统一的1个像素双向缓冲区(与冰川大小和形状无关),通过该方法在考虑边界勾绘变异性的同时估算面积不确定性,特别适用于不规则冰川边界区域。对于未经过人工修正的冰川,其不确定性还取决于深度学习方法引入的误差。在深度学习冰川识别中,我们采用交并比(IoU)、平均交并比(mIoU)、总体精度(OA)、精确率、召回率和F1分数等评估指标(Xie等, 2020; Marochov等, 2021),最终采用总体精度作为不确定性评估标准。

基于深度学习的冰川制图总体精度达到92.80%,这意味着在同时缺少Sentinel-2和Landsat-8数据的区域,冰川提取不确定性为7.20%。需特别说明的是,该不确定性并非仅反映Sentinel-1数据本身的局限,而是由单纯依赖Sentinel-1影像、光学观测缺失,以及缺乏人工后处理等多重因素共同导致,这些条件共同造成数据稀疏区域精度下降。此外,整体mIoU达到0.84,平均边界偏差约为1.2像素(约36 m),表明预测冰川边界与参考边界具有高度空间一致性。最终根据缓冲区法,面积大于 0.01 km^2 冰川的平均不确定性为6.67%。具体而言,面积小于 0.1 km^2 冰川的平均不确定性为11.55%,而大于 0.1 km^2 冰川的平均不确定性为4.83%。单条冰川的具体不确定性取决于影像分辨率及其自身规模,通常面积越大不确定性越低。




图3 冰川深度学习网络训练样本的创建及不同数据集输入至VGG-UNET16网络的示例。(A) Landsat-8影像；(B) Sentinel-2影像；(C) 基于Landsat-8的NDSI；(D) ArcGIS在线全球影像；(E) Sentinel-1 VV影像；(F) Sentinel-1VH影像；(G) Copernicus DEM高程；(H) 基于Copernicus DEM的坡度

4 结果

4.1 HMAGI-2020基本属性

在数字化过程中，同步提取了冰川属性信息，主要包括：冰川面积与周长、中心点经纬度、冰川编号(基于冰川中心点坐标按“G+中心经度+W+中心纬度+N”规则生成，如G080613E42430N代表中心经度80.613°E、中心纬度42.430°N的冰川)、山脉名称(基于RGI二级山脉分类，对应亚洲高山区15个山系)。其他属性还包括用于冰

川绘制的主要影像日期，以及来源(冰川制图主要遥感数据：Sentinel-2、Landsat-8或Sentinel-1)、平均坡度与坡向、冰川最高/最低/平均高程，以及不确定性(计算方法详见第3.4节)。

HMAGI-2020数据集共包含97934条冰川，总面积 $91837.77\pm2527.7\text{ km}^2$ 。VGG16-UNET模型总体精度达92.80%，显示其有较好的冰川识别能力。为获得更精确的冰川编目，基于模型结果进行了人工修正：主要依托光学影像叠加验证，其中91373条冰川采用Landsat 8影像

修正, 1670条冰川采用Sentinel-2影像修正(图4A)。由于大部分区域覆盖高分辨率光学影像, 绝大多数冰川识别结果均经过人工优化。仅有4891条位于光学影像缺失区域、仅能获取SAR数据的冰川保留了VGG16-UNET的自动识别结果而未经人工修正。这些影像来源信息可在已发布的HMAGI-2020数据库中查询。

喀喇昆仑和帕米尔地区的冰川数量约占24.82% (24306条), 其冰川面积占比接近34.71% (31878.94±730.75 km²)。喜马拉雅地区贡献约18.70%的冰川数量 (18313条), 面积占比约17.18% (15777.10±672.16 km²)。天山和昆仑山共占约26.94%的冰川数量 (26384条), 面积占比约24.96% (22923.65±525.46 km²)。其余山脉的冰川数量与面积占比较小。大量小型冰川虽数量众多但面积占比较小(表

3), 而少数大型冰川则占据总面积的主要部分: 84.10%的冰川(82364条)面积小于1 km², 仅2.81%的冰川(2753条)面积超过5 km²。但小于1 km²的冰川仅覆盖总面积的20.00% (20752.31±734.42 km²), 而大于5 km²的冰川则占据45.57%的面积 (44624.99±1063.08 km²)。这种分布格局与中国第二次冰川编目结果一致(Guo等, 2015)。

不同山脉内冰川的面积等级分布呈现显著差异(图4B)。HMAGI-2020识别出114条大于50 km²的冰川, 主要分布于喀喇昆仑、西昆仑、西天山和帕米尔地区, 分别占各自山脉冰川总面积的35.37%、22.62%、17.65%和15.10%。喀喇昆仑地区最大冰川为锡亚琴冰川(Siachan), 面积达1084±8.63 km²。其他山脉大于50 km²冰川占比偏低, 说明小型冰川占主导地位, 尤其在东天山、祁连山和希萨尔阿莱不存在大于50 km²的冰川。




图4 亚洲高山区冰川分布。(A) 15个子区域内遥感数据源的空间分布及统计; (B) 15个子区域内冰川面积排名分布, 圆圈大小与冰川面积成比例

表3 2020年亚洲高山区不同规模冰川的面积与数量

类别(km ²)	面积(km ²)	数量
0–0.1	1503.26±155.46	26591
0.1–0.5	10432.80±573.66	43248
0.5–1	8816.26±333.96	12525
1–5	26460.47±730.20	12817
5–10	11053.54±236.00	1608
10–50	19230.59±346.63	1031
50–100	5285.69±62.48	74
>100	9055.16±89.31	40

4.2 HMAGI-2020地形属性

对不同高程、坡度和坡向区间内的冰川分布特征进行了统计分析(表4)。结果表明,亚洲高山区冰川呈现多样化的海拔分布特征,各山脉间分布差异显著(图5)。HMAGI-2020显示冰川平均海拔为5093.99 m,中值海拔为5201.82 m,最高与最低海拔平均值分别为5329.24和4868.70 m。冰川面积的高程分布表明,大多数山脉的冰川集中在5000–7000 m海拔区间。然而,西天山、东天山和希萨尔阿莱的冰川中值海拔较低,约为3900–4100 m。青藏高原内流区的中值海拔最高(5860.55 m),西昆仑略低(5627.65 m),但从南到北急剧下降,在东天山达到最低中值海拔(3908.13 m)。

图6展示了15个山脉在不同坡度和坡向类别内的冰川面积分布。HMAGI-2020的冰川表面坡度中值为25.66°,平均坡度为26.03°。喀喇昆仑、东天山和祁连山的冰川表面最陡,坡度中值超过27°。相比之下,青藏高原内流区、东昆仑和西昆仑的冰川表面较为平缓,大部分冰川面积分布在15°以下,分别占52.82%、49.96%和47.04%。在西喜马拉雅,这一比例为31.00%。而在喀喇昆仑、帕米尔、青藏高原东南部,以及中喜马拉雅,该比例仅约

为10.00%。

冰川面积在不同坡向范围内的分布呈现显著的空间异质性。一个共同特征是朝南冰川(南向、东南向和西南向)占主导地位,总面积达70352.45±1671.65 km²,占比76.61%。此外,东南方向的冰川分布比西南方向更为广泛。相比之下,朝北冰川(北向、东北向和西北向)仅占5.16%,面积为4739.31±251.12 km²。

在15个子区域中,大多数区域呈现朝南冰川占主导的分布格局,特别是在昆仑山,该比例超过85.00%。在横断山,超过50.00%的冰川朝向东南。此外,在帕米尔、西昆仑和喀喇昆仑地区,东南向冰川的比例比西南向高10.00%。

5 讨论

5.1 复杂冰川类型的性能分析

表碛覆盖冰川和积雪覆盖岩壁区域因其复杂地形和异常光谱特征,对冰川边界的识别构成重大挑战。传统阈值法在这些区域常导致遗漏或误分类,从而降低冰川编目精度(Paul等, 2013; Soheb等, 2022)。为应对这一挑战,我们在深度学习模型训练和后续人工修正中实施了针对性策略,确保最终冰川制图结果的可靠和精度。具体而言,表碛覆盖冰川的训练样本通过阈值法从光谱可识别冰川区域提取,并结合人工筛选表碛密集覆盖的冰川(尤其在西喜马拉雅地区)。对于积雪覆盖岩壁区域,通过光学影像识别陡峭岩壁上的高反照率积雪斑块及SAR后向散射异常生成样本,并人工验证其边界以确保准确性。这些精心构建的样本被纳入深度学习训练数据集,使模型能学习这些复杂冰川类型的光谱与几何特征。在训练数据集构建过程中,我们特意增加了西喜马拉雅地区表碛覆盖冰川、青藏高原内流区和喀喇昆仑山脉积

表4 2020年不同地形类别(海拔、坡度和坡向)下的冰川面积与数量

高程(m)			坡度(°)			坡向		
类别	面积(km ²)	数量	类别	面积(km ²)	数量	类别	面积(km ²)	数量
<3500	157.62±6.00	435	<5	116.04±0.98	32	北	62.43±5.88	1120
3500–4000	4167.41±133.61	8272	5–10	4185.72±36.71	543	东北	2473.74±129.77	12306
4000–4500	9337.73±269.52	12660	10–15	15601.47±289.23	5598	东	9632.77±336.15	15518
4500–5000	15304.03±401.70	16104	15–20	27337.09±682.32	16516	东南	24259.72±588.40	14835
5000–5500	29046.69±869.02	29597	20–25	23120.23±674.23	23136	南	29279.12±628.28	14954
5500–6000	26808.28±689.58	25539	25–30	12959.82±434.81	22398	西南	16813.60±454.97	14175
>6000	7016.01±158.28	5327	30–35	5706.09±257.34	17491	西	7113.23±268.80	13975
/	/	/	35–40	2075.01±109.83	8652	西北	2203.14±115.46	11051
/	/	/	>40	736.28±42.25	3568	/	/	/




图5 亚洲高山区15个子区域的冰川分布高程曲线(100 m高程间隔)。虚线表示相应山脉的中位高程

雪覆盖岩壁区域的样本数量。这确保模型能学习与这些复杂冰川类型相关的光谱和后向散射特征。此外,在人工修正过程中,重点关注这些区域边界的精确修正,以最小化系统误差和偏差。为独立评估模型在复杂冰川区域的性能,我们选取西喜马拉雅(表碛覆盖)、青藏高原内流区和喀喇昆仑山脉(表碛覆盖与积雪覆盖岩壁)的代表性区域,人工数字化高精度参考边界。验证结果汇总于表5。

VGG16-UNET模型在3个典型复杂类型冰川区域均表现出优异性能。对于所有冰川类型,交并比(IoU)介于78.14%–79.66%之间,平均交并比(mIoU)介于87.56%–88.46%,总体精度(OA)达91.68%–92.66%,表明模型在不同地形条件下均能实现稳健的冰川边界界定。针对表碛覆盖冰川和积雪覆盖岩壁区域,由于光谱或后向散射特征复杂,且地形挑战性大,各项指标略低:表碛覆盖冰川的IoU为71.23%–75.63%,OA为89.16%–90.04%;积雪覆盖岩壁区域的IoU为74.39%–76.06%,OA为90.11%–92.04%。尽管数值低于所有冰川平均值,但这些结果仍显示出良好的识别性能。总体而言,该模型能可靠识别复杂冰川类型,结合人工后处理确保了表碛覆盖与积雪覆盖岩壁区域的高精度划分,为建立

HMAGI-2020奠定了坚实基础。

5.2 不同深度学习方法的对比如

图7基于Sentinel-2真彩色合成影像(2020年7月)对比展示了VGG16-UNET模型与传统NDSI阈值法提取的冰川边界结果。结果表明,深度学习方法在精度和完整性方面均具有显著优势:VGG16-UNET模型能更精确地勾绘表碛覆盖冰川边界并保持边界连续性,而NDSI方法往往遗漏光谱特征模糊区域或产生破碎轮廓,尤其在阴影区和表碛覆盖区更为明显。这一对比凸显了基于深度学习的冰川制图方法能够学习复杂空间与光谱模式,突破简单反射率阈值的局限。同时证明了该模型在不同地形与冰川类型间具备良好泛化能力,为亚洲高山区复杂山地环境的大规模冰川编目提供了可靠工具。

本研究统一采用VGG-UNET架构处理不同类型遥感影像及不同冰川表面状况下的边界提取。该模型在既往冰川制图研究中已展现出强稳定性、较低计算成本及优异的光谱-空间特征提取能力(Xiao等, 2023),故被选为核心方法。尽管诸如DeepLabv3+(Zhang等, 2021; Xie等, 2022)和基于Transformer的模型(Peng Y等, 2023)在语义分割与冰川提取任务中表现出色,但经实验对比(包




图6 亚洲高山区15个子区域在不同坡度和坡向区间内的冰川面积分布

表5 VGG16-UNet在复杂冰川类型中的制图精度验证

冰川类型	指标	喜马拉雅	青藏高原内流区	喀喇昆仑
所有冰川	样本数	2766	1826	3704
	交并比(%)	79.66	78.64	78.14
	平均交并比(%)	87.56	88.23	88.46
	总体精度/%	92.66	91.68	92.33
表碛覆盖冰川	样本数	877	436	1053
	交并比(%)	71.23	75.63	72.66
	平均交并比(%)	81.02	82.68	78.46
	总体精度(%)	90.04	89.39	89.16
积雪覆盖岩壁	样本数	0	276	671
	交并比(%)	/	74.39	76.06
	平均交并比(%)	/	81.41	81.57
	总体精度(%)	/	90.11	92.04




图7 基于VGG16-UNET与NDSI阈值法提取的不同区域冰川边界对比示例。背景为2020年7月的Sentinel-2真彩色合成影像

括将Swin Transformer与U-Net结合的Swin-UNet), 发现这些模型在不同评估指标上各有优势, 但总体精度与采用VGG16-UNet模型相当(表6)。需要说明的是, 无论采用何种模型, 自动提取的冰川边界在最终编目前均需经过人工校正, 这降低了模型性能差异对最终结果的影响。选择VGG16-UNET模型是因其结构相对简单、训练过程稳定, 并能有效提取遥感影像中的纹理与几何特征——这些特性使其特别适合在二分类场景下处理冰川表面的

复杂空间模式。此外, H MAGI-2020项目目标之一是在整个高山区建立统一且可扩展的冰川识别框架。通过统一使用VGG-UNET模型, 保持了训练、验证与推理阶段的方法一致性, 从而最大限度避免了因模型切换带来的可比性问题。尽管本研究未对表碛覆盖冰川进行单独评估, 未来研究可探索集成学习方法或引入更先进的Transformer架构以提升表碛覆盖冰川等复杂区域的识别精度。

5.3 与已有冰川编目的对比

已有许多关于亚洲高山区特定区域的冰川面积变化,研究表明西昆仑地区1970–2018年冰川面积呈扩张趋势,尤其在2010–2018年增长了4.70 km²(Cao等, 2020)。HMAGI-2020在该区域的观测结果与这一变化趋势一致,不过我们观测到的扩张幅度略大(分别为13.71和79.52 km²)。这种差异可归因于区域界线划分与时间段的选取不同。Wang等(2020)报告称2001–2018年祁连山冰川面积年均减少率为0.87%,该数据与HMAGI-2020在祁连山观测到的冰川退缩趋势相符。Ji等(2022)分析了1990–2015年整个喜马拉雅地区的冰川分布与变化,表明冰川面积减少了10.99%,这一发现与HMAGI-2020在喜马拉雅地区的结果相互印证。这些与HMAGI-2020在不同区域观测结果相吻合的研究发现,进一步验证了HMAGI-2020的可靠性。

此外,近年来已发布多个针对亚洲高山区的区域性冰川编目。我们选择将HMAGI-2020与部分时段相近的编目进行对比,包括2017–2018年中国西部冰川编目(CGI-2018)(冉伟杰等, 2021)、喀喇昆仑冰川编目(KGI-2020s)(Xie等, 2022)、印度河上游流域冰川编目(UIB_GI-2019)(Soheb等, 2022),以及青海省冰川编目(QH_GI)(Xue等, 2022)(表7)。

我们将HMAGI-2020与上述编目在相应区域进行了对比,并统计了不同规模等级冰川的分布情况(表8)。与CGI-2018相比, HMAGI-2020在不同规模等级的冰川面积和数量上存在差异:部分等级表现出相似特征(如面积与数量接近),而其他等级则呈现明显区别。值得注意的是, HMAGI-2020在多个规模等级中显示出略大的面积和数量,且这一趋势在较大冰川等级(>100 km²)中更为

显著。在人工修正过程中,我们观察到早期编目中的许多大型冰川被分割为两个或多个独立冰川。HMAGI-2020的冰川总面积和总数低于CGI-2018,考虑到CGI-2018数据主要来自2014–2018年,这一结果是合理的。在喀喇昆仑地区, KGI-2020s与HMAGI-2020的冰川面积和数量分布总体相似,尤其在总面积方面高度吻合。对于小于100 km²的冰川, HMAGI-2020报告的冰川面积和数量略高,特别是在较小规模等级(0–0.1和0.1–0.5 km²)中。然而在中等规模等级(1–10 km²),两者冰川数量高度一致,但HMAGI-2020的冰川面积略大。对于大于100 km²的冰川, HMAGI-2020的数量和面积均小于KGI-2020s。这种差异可归因于喀喇昆仑地区大型冰川分布密集,在HMAGI-2020生产过程中,更多空间连续的大型冰川被划分为独立的小型冰川。

与UIB_GI-2019相比, HMAGI-2020的冰川总面积略小但数量更多(表9),这主要因为UIB_GI-2019未包含小于0.5 km²的冰川。此外,与QH_GI的对比表明: HMA-GI-2020与QH_GI在各规模等级的冰川面积相对一致,但HMAGI-2020的冰川数量略高于QH_GI。

我们对特殊冰川的边界进行了详细对比(图8)。可以看出, HMAGI-2020中大多数冰川边界与CGI-2018保持一致(图8B、8C、8D、8H),存在微小差异的原因可能源于冰川退缩,这是一个合理的解释,因为HMAGI-2020基于2020年卫星数据,而CGI-2018使用的是2014–2018年遥感影像数据。部分冰川边界在CGI-2018中被低估(图8A、8D、8G),这解释了为何HMAGI-2020在这些区域显示出更大的冰川面积。对于发生显著退缩的小型冰川, HMAGI-2020的边界明显小于CGI-2018。KGI-2020s的冰川边界呈现锯齿状形态,可能是自动化处理导

表6 冰川制图中不同深度学习模型的精度对比

模型	精确率(%)	召回率(%)	F1分数(%)	交并比(%)	平均交并比(%)	总体精度(%)
VGG16-UNET	86.57	88.56	86.00	78.43	84.89	92.80
DeepLabv3+	85.78	90.70	87.64	79.00	83.89	92.47
Swin-UNET	86.87	89.66	88.24	78.96	83.80	93.04

表7 与HMAGI-2020对比所用既有冰川编目的关键信息

冰川编目	年份	主要影像来源和DEM源	下载地址
RGI 6.0	1999–2010	Landsat 5/7、SPOT-5、ASTER、IKONOS和SRTM、ASTER DEM	https://doi.org/10.5067/f6jmovy5navz
GGI18	1999–2010	Landsat5/7和ASTER GDEM2	Sakai, 2019
CGI-2018	2017–2018	Landsat8 OLI和SRTM DEM	https://cstr.cn/31253.11.sciencedb.j00001.00227
KGI-2020s	2018–2020	Landsat8 OLI和ASTER GDEM3	https://doi.org/10.12072/ncdc.glacier.db2386.2022
UIB_GI-2019	2018–2020	Landsat8 OLI和ASTER GDEM3	https://doi.org/10.1594/PANGAEA.940994
QH_GI	2018–2021	GF-1/2/6和SRTM DEM	https://cstr.cn/31253.11.sciencedb.j00001.00321

表8 CGI-2018、KGI-2020s与HMAGI-2020在不同规模等级下冰川面积(km²)与数量

冰川类别(km ²)	CGI-2018		中国西部HMAGI-2020		KGI-2020s		喀喇昆仑HMAGI-2020	
	面积	数量	面积	数量	面积	数量	面积	数量
0-0.1	908	18988	755	15844	156	2750	222	4224
0.1-0.5	4898	20249	4461	18342	924	3752	1237	4993
0.5-1	4197	5955	3896	5520	1018	1439	1279	1797
1-5	13577	6552	12581	6014	4215	1950	4397	2055
5-10	5933	858	5520	801	2262	326	2283	331
10-50	10786	572	9501	513	4305	225	4685	252
50-100	3018	42	2623	37	2200	30	2396	32
>100	3856	22	2839	18	7431	26	5321	20
总和	47174	53238	42177	47089	22511	10498	21821	13704

表9 UIB_GI-2019、QH_GI与HMAGI-2020在不同规模等级下冰川面积(km²)与数量

冰川类别(km ²)	UIB_GI-2019		UIB HMAGI-2020		QH_GI		青海HMAGI-2020	
	面积	数量	面积	数量	面积	数量	面积	数量
0-0.1	0	0	4.94	136	52.55	1072	58.83	1242
0.1-0.5	0	0	114.42	311	364.66	1473	373.91	1506
0.5-1	688.12	969	616.23	874	354.92	496	366.34	512
1-5	2204.3	1052	2201.07	990	1237.82	585	1266.97	594
5-10	860.36	124	902.31	129	598.75	87	592.22	86
10-50	1616.67	84	1543.67	76	936.52	54	953.44	55
50-100	673.99	10	652.64	8	140.02	2	140.91	2
>100	1876.11	7	1803.63	5	0	0	0	0
总和	7922.95	2248	7838.91	2529	3685.25	3769	3752.63	3997

致边界平滑度不足的结果。需要指出的是,这种锯齿状边界可能会轻微高估冰川面积(图8A、8B、8E、8H)。HMAGI-2020的边界略大于QH_GI(图8G),这可归因于所用影像数据的差异。

为验证HMAGI-2020的可靠性,我们将其与全球权威冰川编目进行了一致性评估。由于亚洲高山区缺乏最新的区域级冰川编目,我们选择与RGI 6.0(Pfeffer等, 2017)和GAMDAM冰川编目第二版(GGI18, Sakai, 2019)进行对比(表10和11)。高亚洲的GGI18冰川编目已整合进RGI,成为RGI7.0的一部分(Maussion等, 2023)需要说明的是,尽管这些数据集采用的卫星数据获取时间存在差异(RGI6.0最新数据约至2010年,GGI18主要使用1999-2010年数据),可能因过去十年冰川变化引入偏差,但对比结果仍能有效反映HMAGI-2020的质量特征。结果显示,HMAGI-2020与RGI6.0和GGI18在冰川面积和数量上存在显著差异:相较于RGI6.0总面积减少5762.97 km²(-5.90%),相较于GGI18减少7624.83 km²(-7.67%)。在各子区域中,中喜马拉雅,东喜马拉雅,西喜马拉雅,青藏高原东南部,以及横断山等地区的面

积差异尤为显著,这反映了亚洲高山区地区(特别是东南部)的冰川动态变化,研究表明这些区域正好位于快速冰川消融区(Brun等, 2017; Fan等, 2023; Luo等, 2023)。值得注意的是,在喀喇昆仑地区,HMAGI-2020记录的冰川面积(约21820.56 km²)高于GGI18,这与该地区众所周知的“喀喇昆仑异常”现象相吻合(Gardelle等, 2013; Farinotti等, 2020; Wu等, 2021)。

5.4 HMAGI-2020的意义与局限性

与现有冰川编目相比,HMAGI-2020实现了多项改进:(1) 集成多源遥感数据,SAR数据的云层穿透能力增强了冰川表面特征提取,弥补了光学影像中云覆盖与阴影造成的数据缺失;(2) 超过80%的冰川基于哨兵二号影像(10 m分辨率)进行人工修正,显著降低了边界不确定性;(3) 采用2020年单一年份(7-9月)的遥感大数据,生成具有时间一致性的冰川编目,解决了区域尺度冰川编目的时间模糊性问题;(4) 所有影像均取自冰川消融期(7-9月),最小化了季节性积雪对边界识别的影响;(5) 使用2010-2015年TerraSAR-X/TanDEM-X生成的




图8 不同冰川编目的对比。包括CGI-2018、KGI-2020s、UIB_GI-2019、QH-GI 和 HMAGI-2020。冰川分布区域：(A) 喀喇昆仑，(B) 喀喇昆仑，(C) 喜马拉雅，(D) 天山，(E) 喀喇昆仑，(F) 西藏南部与东部，(G) 喀喇昆仑，(H) 祁连山。背景为2020年的Landsat-8影像

Copernicus DEM，相比早期广泛使用的SRTM DEM (2000年)，更接近实际地形特征。这些改进使HMAGI-2020为冰川变化研究提供了更可靠的数据基础。

针对多年积雪与洁净冰川光谱相似易导致高估的问题(Huang等, 2021)，我们采取三重应对策略：首先严格限定使用消融期影像，确保季节性积雪最小化；其次通过人工验证排除无冰流结构、缺乏连续高程梯度等非冰川特征区域；最后通过与RGI 6.0等现有编目对比，确认新增冰川主要源于更高分辨率影像对表碛冰川的识别改进而非积雪误判。

然而HMAGI-2020仍存在局限：(1) DEM精度制约冰川地形特征捕获，尽管采用较新的Copernicus DEM，但与其与分类影像的时间差可能影响深度学习识别精度；(2) 尽管使用消融期影像，年际雪线波动仍增加边界判定复杂性；(3) 不同专业人员的解译差异可能引入边界误差。尽管存在这些局限，本数据集首次基于单一年份

(2020年消融期)遥感大数据提供了全亚洲高山区相对精确的冰川编目，为冰川研究做出了重要贡献。后续工作可聚焦提升DEM精度(通过DEM融合等技术)、确保多源数据时间一致性、优化去云算法及考虑季节性融雪模式，以提供更可靠的冰川动态信息，深化对气候变化响应与水资源管理的认知。

6 结论

本研究通过处理海量遥感大数据(包括Sentinel-2、Landsat-8和Sentinel-1)，构建了亚洲高山区2020年时间统一的冰川编目(HMAGI-2020)。基于GEE平台创建2020年7–9月无云合成影像，生成深度学习训练样本标签。采用VGG16-UNET模型实现冰川自动识别，精度达92.80%。由冰川专家结合光学与SAR影像进行人工校正。通过基于缓冲区的最邻近像元法计算制图不确定性，平均不确定性为 $\pm 6.67\%$ 。该编目最终包含冰川面积、地

表10 亚洲高山区各子区域冰川面积与两个全球冰川编目的对比

区域	HMAGI-2020	RGI 6.0			GGI18		
	面积(km ²)	面积(km ²)	差异(km ²)	百分比(%)	面积(km ²)	差异(km ²)	百分比(%)
希萨尔阿莱	2033.28	1846.03	187.25	10.14	1953.55	79.45	4.07
帕米尔	10058.39	10233.55	-175.16	-1.71	10465.34	-407.34	-3.89
西天山	8666.38	9531.29	-864.91	-9.07	9299.18	-633.18	-6.81
东天山	2925.18	2854.05	71.13	2.49	3082.89	-157.89	-5.12
西昆仑	8200.51	8186.80	13.71	0.17	8121.48	79.52	0.98
东昆仑	3132.58	3251.26	-118.68	-3.65	3211.74	-79.74	-2.48
祁连山	1615.89	1637.22	-21.33	-1.30	1666.32	-50.32	-3.02
青藏高原内流区	7872.63	8380.18	-507.55	-6.06	8813.04	-940.04	-10.67
青藏高原东南部	3532.90	4139.55	-606.65	-14.65	4595.06	-1062.06	-23.11
兴都库什	2691.90	3055.18	-363.28	-11.89	3155.86	-463.86	-14.70
喀喇昆仑	21820.56	22638.20	-817.64	-3.61	21813.25	7.75	0.04
西喜马拉雅	6808.67	7937.54	-1128.87	-14.22	8674.61	-1865.61	-21.51
中喜马拉雅	4911.08	5150.95	-239.87	-4.66	6997.85	-2086.85	-29.82
东喜马拉雅	4056.35	4576.89	-520.54	-11.37	5761.24	-1704.24	-29.58
横断山	3511.40	4182.03	-670.63	-16.04	4229.22	-718.22	-16.98
亚洲高山区	91837.77	97600.74	-5762.97	-5.90	99461.83	-7624.83	-7.67

表11 亚洲高山区各子区域冰川数量与两个全球冰川编目的对比

区域	HMAGI-2020	RGI 6.0			GGI18		
	数量	数量	差异	百分比(%)	数量	差异	百分比(%)
希萨尔阿莱	3145	3151	-6	-0.19	5340	-2191	-41.03
帕米尔	10602	10245	357	3.48	15745	-5164	-32.8
西天山	9883	9761	122	1.25	14684	-4788	-32.61
东天山	5220	5229	-9	-0.17	6255	-1033	-16.51
西昆仑	7768	7906	-138	-1.75	7926	-174	-2.2
东昆仑	3513	3519	-6	-0.17	3854	-341	-8.85
祁连山	2722	2730	-8	-0.29	3256	-503	-15.45
青藏高原内流区	9327	9492	-165	-1.74	11325	-1949	-17.21
青藏高原东南部	5008	5117	-109	-2.13	7449	-2544	-34.15
兴都库什	4461	4406	55	1.25	6863	-2462	-35.87
喀喇昆仑	13704	13688	16	0.12	17649	-3940	-22.32
西喜马拉雅	9863	9871	-8	-0.08	13224	-3307	-25.01
中喜马拉雅	4428	4496	-68	-1.51	6251	-1786	-28.57
东喜马拉雅	4022	4247	-225	-5.30	5566	-1403	-25.21
横断山	4268	4326	-58	-1.34	6984	-2685	-38.45
亚洲高山区	97934	98184	-250	-0.25	131769	-33668	-25.55

形参数及不确定性等15个属性。

2020年亚洲高山区共识别冰川97934条，总面积91837.77±2527.70 km²，其中面积超50 km²的冰川114条。喀喇昆仑地区冰川数量(13704条)与面积(21820.56±483.54 km²)均居首位。全区冰川平均表面高程约5094 m，青藏高原内流区平均高程最高(超过5882 m)。平均坡度25.66°，主导朝向为南向(南、西南、

东南方向冰川占比超75%)。与现有编目对比显示：冰川持续退缩趋势显著，青藏高原东南部和喜马拉雅地区过去二十年超20%冰川消失，而喀喇昆仑-西昆仑地区冰川相对稳定且略增，与“喀喇昆仑异常”现象一致。

本编目集成2020年冰川消融期多源遥感数据，确保冰川边界提取具有高度时间一致性；尤其多数冰川基于10 m分辨率Sentinel-2影像，有效降低了分辨率限制带来

的不确定性。相比现有时间跨度较长的HMA冰川编目, HMAGI-2020的时间统一性具有独特优势。针对积雪岩壁和表碛覆盖冰川等难点区域, 通过实验验证了深度学习方法的准确性, 确保在传统冰川制图困难区域的可靠性。本数据集可为GLIMS提供更新的基准冰川边界, 支持已有冰川编目的更新, 并为相关科学研究提供坚实的数据基础。

致谢 HMAGI-2020数据集已发布于国家青藏高原/第三极环境数据中心(<https://doi.org/10.11888/Cryos.tpd.301594>)。数据集包含完整的冰川矢量边界文件(shp格式), 并附有详细的数据说明文档。作者对所有数据提供者表示感谢。

参考文献

- 冉伟杰, 王欣, 郭万钦, 等. 2021. 2017–2018年中国西部冰川编目数据集. 中国科学数据, 6: 195–204
- Akhtar M, Ahmad N, Booi M J. 2008. The impact of climate change on the water resources of Hindukush-Karakoram-Himalaya region under different glacier coverage scenarios. *J Hydrol*, 355: 148–163
- Alifu H, Vuillaume J F, Johnson B A, et al. 2020. Machine-learning classification of debris-covered glaciers using a combination of Sentinel-1/2 (SAR/optical), Landsat 8 (thermal) and digital elevation data. *Geomorphology*, 369: 107365
- Bolch T, Yao T, Kang S, et al. 2010. A glacier inventory for the western Nyainqentanglha Range and the Nam Co Basin, Tibet, and glacier changes 1976–2009. *Cryosphere*, 4: 419–433
- Brun F, Berthier E, Wagnon P, et al. 2017. A spatially resolved estimate of High Mountain Asia glacier mass balances from 2000 to 2016. *Nat Geosci*, 10: 668–673
- Cao B, Guan W, Li K, et al. 2020. Area and mass changes of glaciers in the West Kunlun Mountains based on the analysis of multi-temporal remote sensing images and DEMs from 1970 to 2018. *Remote Sens*, 12: 2632
- Dehecq A, Gourmelen N, Gardner A S, et al. 2019. Twenty-first century glacier slowdown driven by mass loss in High Mountain Asia. *Nat Geosci*, 12: 22–27
- Fan Y, Ke C Q, Zhou X, et al. 2023. Glacier mass-balance estimates over High Mountain Asia from 2000 to 2021 based on ICESat-2 and NASADEM. *J Glaciol*, 69: 500–512
- Farinotti D, Immerzeel W W, de Kok R J, et al. 2020. Manifestations and mechanisms of the Karakoram glacier Anomaly. *Nat Geosci*, 13: 8–16
- Frey H, Paul F, Strozzi T. 2012. Compilation of a glacier inventory for the western Himalayas from satellite data: Methods, challenges, and results. *Remote Sens Environ*, 124: 832–843
- Friedl P, Weiser F, Fluhrer A, et al. 2020. Remote sensing of glacier and ice sheet grounding lines: A review. *Earth-Sci Rev*, 201: 102948
- Gardelle J, Berthier E, Arnaud Y. 2012. Slight mass gain of Karakoram glaciers in the early twenty-first century. *Nat Geosci*, 5: 322–325
- Gardelle J, Berthier E, Arnaud Y, et al. 2013. Region-wide glacier mass balances over the Pamir-Karakoram-Himalaya during 1999–2011. *Cryosphere*, 7: 1263–1286
- Guo W, Liu S, Xu J, et al. 2015. The second Chinese glacier inventory: Data, methods and results. *J Glaciol*, 61: 357–372
- Huang L, Li Z, Zhou J M, et al. 2021. An automatic method for clean glacier and nonseasonal snow area change estimation in High Mountain Asia from 1990 to 2018. *Remote Sens Environ*, 258: 112376
- Hugonnet R, McNabb R, Berthier E, et al. 2021. Accelerated global glacier mass loss in the early twenty-first century. *Nature*, 592: 726–731
- Immerzeel W W, van Beek L P H, Bierkens M F P. 2010. Climate change will affect the Asian water towers. *Science*, 328: 1382–1385
- Ji Q, Yang T B, Li M Q, et al. 2022. Variations in glacier coverage in the Himalayas based on optical satellite data over the past 25 years. *Catena*, 214: 106240
- Kehrwald N M, Thompson L G, Yao T, et al. 2008. Mass loss on Himalayan glacier endangers water resources. *Geophys Res Lett*, 35: 2008GL035556
- Khanal S, Lutz A F, Kraaijenbrink P D A, et al. 2021. Variable 21st century climate change response for rivers in High Mountain Asia at seasonal to decadal time scales. *Water Resour Res*, 57: e2020WR029266
- Kraaijenbrink P D A, Bierkens M F P, Lutz A F, et al. 2017. Impact of a global temperature rise of 1.5 degrees Celsius on Asia's glaciers. *Nature*, 549: 257–260
- Luo L H, Ke C Q, Fan Y B, et al. 2023. Accelerated glacier mass loss in the southeastern Tibetan Plateau since the 1970s. *Adv Clim Change Res*, 14: 372–386
- Marochov M, Stokes C R, Carbonneau P E. 2021. Image classification of marine-terminating outlet glaciers in Greenland using deep learning methods. *Cryosphere*, 15: 5041–5059
- Maslov K A, Persello C, Schellenberger T, et al. 2025. Globally scalable glacier mapping by deep learning matches expert delineation accuracy. *Nat Commun*, 16: 43
- MauSSION F, Hock R, Paul F, et al. 2023. The Randolph Glacier Inventory Version 7.0 User Guide v1.0. Zenodo
- Mishra A, Nainwal H C, Bolch T, et al. 2023. Glacier inventory and glacier changes (1994–2020) in the Upper Alaknanda Basin, Central Himalaya. *J Glaciol*, 69: 591–606
- Nie Y, Pritchard H D, Liu Q, et al. 2021. Glacial change and hydrological implications in the Himalaya and Karakoram. *Nat Rev Earth Environ*, 2: 91–106
- Paul F, Andreassen L M. 2009. A new glacier inventory for the Svartisen region, Norway, from Landsat ETM+ data: Challenges and change assessment. *J Glaciol*, 55: 607–618
- Paul F, Barrant N E, Baumann S, et al. 2013. On the accuracy of glacier outlines derived from remote-sensing data. *Ann Glaciol*, 54: 171–182
- Paul F, Bolch T, Briggs K, et al. 2017. Error sources and guidelines for quality assessment of glacier area, elevation change, and velocity products derived from satellite data in the Glaciers_cci project. *Remote Sens Environ*, 203: 256–275
- Peng M, Wang X, Zhang G, et al. 2023. Cascading hazards from two recent glacial lake outburst floods in the Nyainqentanglha range, Tibetan Plateau. *J Hydrol*, 626: 130155
- Peng Y, He J, Yuan Q, et al. 2023. Automated glacier extraction using a Transformer based deep learning approach from multi-sensor remote sensing imagery. *ISPRS-J Photogramm Remote Sens*, 202: 303–313
- Pfeffer W T, Arendt A A, Bliss A, et al. 2017. The Randolph Glacier Inventory: A globally complete inventory of glaciers. *J Glaciol*, 60: 537–552
- Robson B A, Bolch T, MacDonell S, et al. 2020. Automated detection of rock glaciers using deep learning and object-based image analysis. *Remote Sens Environ*, 250: 112033
- Sakai A. 2019. Brief communication: Updated GAMDAM glacier inventory over high-mountain Asia. *Cryosphere*, 13: 2043–2049
- Soheb M, Ramanathan A, Bhardwaj A, et al. 2022. Multitemporal glacier inventory revealing four decades of glacier changes in the Ladakh region. *Earth Syst Sci Data*, 14: 4171–4185
- Sorg A, Bolch T, Stoffel M, et al. 2012. Climate change impacts on glaciers and runoff in Tien Shan (Central Asia). *Nat Clim Change*, 2: 725–731
- Sun Z, Hu Y, Racoviteanu A, et al. 2024. TPROGI: A comprehensive rock

- glacier inventory for the Tibetan Plateau using deep learning. *Earth Syst Sci Data*, 16: 5703–5721
- Wang B, Bao Q, Hoskins B, et al. 2008. Tibetan Plateau warming and precipitation changes in East Asia. *Geophys Res Lett*, 35: 2008GL034330
- Wang Q, Yi S, Sun W. 2021. Continuous estimates of glacier mass balance in High Mountain Asia based on ICESat-1,2 and GRACE/GRACE follow-on data. *Geophys Res Lett*, 48: e2020GL090954
- Wang S, Yao T, Pu J. 2020. Spatial and temporal variations in mass balance of Qiyi Glacier in Qilian Mountains. *J Nat Resour*, 35: 399–412.
- Winsvold S H, Kääb A, Nuth C. 2016. Regional glacier mapping using optical satellite data time series. *IEEE J Sel Top Appl Earth Observations Remote Sens*, 9: 3698–3711
- Winsvold S H, Kääb A, Nuth C, et al. 2018. Using SAR satellite data time series for regional glacier mapping. *Cryosphere*, 12: 867–890
- Wu K, Liu S, Jiang Z, et al. 2021. Quantification of glacier mass budgets in the Karakoram region of Upper Indus Basin during the early twenty-first century. *J Hydrol*, 603: 127095
- Xiao Y, Ke C Q, Cai Y, et al. 2023. Glacier retreating analysis on the Southeastern Tibetan Plateau via multisource remote sensing data. *IEEE J Sel Top Appl Earth Observations Remote Sens*, 16: 2035–2049
- Xiao Y, Ke C Q, Fan Y. 2024. The 2020 glacier inventory dataset of the High Mountain Asia. National Tibetan Plateau. Third Pole Environment Data Center
- Xie F, Liu S, Gao Y, et al. 2023. Interdecadal glacier inventories in the Karakoram since the 1990s. *Earth Syst Sci Data*, 15: 847–867
- Xie Z, Haritashya U K, Asari V K, et al. 2020. GlacierNet: A deep-learning approach for debris-covered glacier mapping. *IEEE Access*, 8: 83495–83510
- Xie Z, Haritashya U K, Asari V K, et al. 2022. GlacierNet2: A hybrid Multi-Model learning architecture for alpine glacier mapping. *Int J Appl Earth Observation GeoInf*, 112: 102921
- Xu X, Wang W, Huang D, et al. 2023. Assessment of interannual and seasonal glacier mass changes in the Karakoram during 2018–2022 using ICESat-2 data. *J Hydrol*, 626: 130223
- Xue J, Yao X J, Chu X D, et al. 2022. A dataset of boundary and length of glaciers in Qinghai Province in 2020. *CSD*, 7, doi: 10.11922/11-6035.csd.2021.0082.zh
- Yao T, Thompson L, Yang W, et al. 2012. Different glacier status with atmospheric circulations in Tibetan Plateau and surroundings. *Nat Clim Change*, 2: 663–667
- Yao T, Bolch T, Chen D, et al. 2022. The imbalance of the Asian water tower. *Nat Rev Earth Environ*, 3: 618–632
- Zhang E, Liu L, Huang L, et al. 2021. An automated, generalized, deep-learning-based method for delineating the calving fronts of Greenland glaciers from multi-sensor remote sensing imagery. *Remote Sens Environ*, 254: 112265
- Zhao F, Long D, Li X, et al. 2022. Rapid glacier mass loss in the Southeastern Tibetan Plateau since the year 2000 from satellite observations. *Remote Sens Environ*, 270: 112853

(责任编辑: 王宁练)