第 59 卷 第 5 期
2026 年（总 249 期）

西 北 地 质
NORTHWESTERN GEOLOGY

Vol. 59 No. 5
2026(Sum249)



引文格式：张轶飞，裴秋明，王世明，等. 西昆仑阿克陶高寒山区岩性智能填图：基于 ASTER 与 Sentinel-2 数据融合及光谱–空间联合特征学习[J]. 西北地质，2026，59(5)：208−221. DOI：10.12401/j.nwg.2026072

Citation：ZHANG Yifei, PEI Qiuming, WANG Shiming, et al. Intelligent Lithological Mapping in the High-Cold Mountainous Area of Akto, West Kunlun: Based on ASTER and Sentinel-2 Data Fusion and Spectral-Spatial Joint Feature Learning[J]. Northwestern Geology, 2026, 59(5): 208−221. DOI: 10.12401/j.nwg.2026072

西昆仑阿克陶高寒山区岩性智能填图：基于 ASTER 与 Sentinel-2 数据融合及光谱–空间联合特征学习

张轶飞[1]，裴秋明[1,2,*]，王世明[1,2]，罗波[3]，赵德虎[3]，
Safonova Inna[1,4]，沈家乐[1]，张沥[1]

（1. 西南交通大学地球科学与工程学院，四川 成都 611756；2. 四川省环青藏高原交通廊道地质灾害生态化防治工程技术研究中心，四川 成都 611756；3. 重庆市地质矿产勘查开发局川东南地质大队，重庆 400038；4. 俄罗斯科学院西伯利亚分院索博列夫地质与矿物学研究所，俄罗斯 新西伯利亚 630090）

摘 要：针对高海拔、地形复杂地区传统地质填图效率较低、野外调查难度大的问题，笔者以新疆阿克陶地区为研究区，融合 ASTER 可见光–近红外/热红外与 Sentinel-2 多光谱数据，经主成分分析降维构建多源遥感融合特征集，并分别构建一维–二维双分支卷积神经网络（1D-2DCNN）和三维–二维混合卷积神经网络（HybridSN），从光谱–空间特征分支融合和联合卷积两个角度开展岩性智能分类，同时设置 1DCNN 和 2DCNN 单分支模型进行对比。为降低空间自相关导致的精度高估，样本采用空间区块划分并设置缓冲区隔离，通过 3 个随机种子重复划分检验结果的稳健性。结果表明，HybridSN 综合性能最优，总体精度为 95.58%，Kappa 系数为 0.945±0.061，宏平均和加权平均 F1-score 分别为 0.955±0.048 和 0.951±0.056；1D-2DCNN 的总体精度为 92.51%，与 2DCNN 接近，且优于 1DCNN。单源数据对比实验表明，融合数据的总体精度较 ASTER 单源数据提高约 7.3%；TIR 波段消融实验表明，去除热红外波段后总体精度下降约 4.9%，说明热红外信息对研究区硅酸盐岩性单元的识别具有重要作用。随机像素划分对照实验的精度较空间区块划分高估约 7.5%，表明空间独立的样本划分对于客观评价模型性能具有必要性。研究结果表明，ASTER 与 Sentinel-2 多源遥感数据融合结合光谱–空间深度特征学习，在西昆仑高寒复杂地质区岩性智能填图中具有较好的应用潜力，可为类似地区的区域地质调查与战略性矿产勘查提供技术参考。

关键词：岩性填图；多源遥感；数据融合；深度学习；西昆仑

中图分类号：P627 **文献标志码**：A **文章编号**：1009-6248(2026)05-0208-14

Intelligent Lithological Mapping in the High-Cold Mountainous Area of Akto, West Kunlun: Based on ASTER and Sentinel-2 Data Fusion and Spectral-Spatial Joint Feature Learning

收稿日期：2026-08-28；**修回日期**：2026-09-17；**责任编辑**：吕鹏瑞

基金项目：国家自然科学基金项目（W2431031），国家自然科学联合基金重点项目（U25A20404）和四川省大学生创新训练计划项目（2025168）联合资助。

作者简介：张轶飞（2003−），男，硕士研究生，地质资源与地质工程专业。E−mail：coldboiledice_zyf@163.com。

*** 通讯作者**：裴秋明（1989−），男，博士，副教授，主要从事矿产勘查与遥感地质教学及相关科研。E−mail：pqm@swjtu.edu.cn。

© Editorial Office of *Northwestern Geology*. OA under CC BY-NC-ND

ZHANG Yifei[1], PEI Qiuming[1,2,*], WANG Shiming[1,2], LUO Bo[3], ZHAO Dehu[3],
SAFONOVA Inna[1,4], SHEN Jiale[1], ZHANG Li[1]

（1. Faculty of Geosciences and Engineering, Southwest Jiaotong University, Chengdu 611756, Sichuan, China；2. Sichuan Province Engineering Technology Research Center of Ecological Mitigation of Geohazards in Tibet Plateau Transportation Corridors, Chengdu 611756, Sichuan, China；3. Chongqing Bureau of Geology and Minerals Exploration, Chongqing 400038, China；4. Sobolev Institute of Geology and Mineralogy SB RAS, Novosibirsk 630090, Russia）

Abstract：To address the low efficiency of conventional geological mapping and the challenges associated with field surveys in high-altitude areas with rugged terrain, this study selected the Aketao region of Xinjiang, China, as the study area. ASTER visible–near-infrared and thermal-infrared data were integrated with Sentinel-2 multispectral imagery, and principal component analysis was applied for dimensionality reduction to construct a fused multi-source remote-sensing feature set. A one-dimensional–two-dimensional dual-branch convolutional neural network (1D–2DCNN) and a three-dimensional–two-dimensional hybrid convolutional neural network (HybridSN) were then developed for automated lithological classification. These models represent two spectral-spatial learning strategies: branch-based feature fusion and joint convolutional feature extraction. Single-branch 1DCNN and 2DCNN models were also implemented for comparison. To mitigate accuracy overestimation caused by spatial autocorrelation, the samples were partitioned into spatial blocks separated by buffer zones. The partitioning procedure was repeated using three random seeds to assess the robustness of the results. HybridSN achieved the best overall performance, with an overall accuracy of 95.58%, a Kappa coefficient of 0.945±0.061, and macro- and weighted-average F1-scores of 0.955±0.048 and 0.951±0.056, respectively. The 1D–2DCNN achieved an overall accuracy of 92.51%, comparable to that of the 2DCNN and higher than that of the 1DCNN. Single-source comparison experiments showed that the fused dataset improved overall accuracy by approximately 7.3% relative to the ASTER-only dataset. Ablation experiments further showed that removing the thermal-infrared bands reduced overall accuracy by approximately 4.9%, highlighting the importance of thermal-infrared information for identifying silicate lithological units in the study area. In addition, the random pixel-based split overestimated accuracy by approximately 7.5% compared with the spatial block-based split, demonstrating the necessity of spatially independent sample partitioning for objective model evaluation. These results indicate that integrating ASTER and Sentinel-2 data with deep spectral-spatial feature learning has considerable potential for automated lithological mapping in the high-altitude, geologically complex terrain of the West Kunlun region and can provide a valuable technical reference for regional geological surveys and strategic mineral exploration in similar areas.

Keywords：lithological mapping；multi-source remote sensing；data fusion；deep learning；West Kunlun

岩性填图是地质学领域的重要基础性工作, 能为认识区域地质演化、开展矿产资源勘查及支撑重大工程建设提供关键地质信息(Henriques et al., 2015; 邓乃尔等, 2025; 刘磊等, 2025)。传统地质填图主要依赖野外路线调查和露头观测, 其结果具有较高可靠性, 但在高海拔、强切割和交通不便地区往往受到调查周期、人力成本及可达性等因素制约(Grebby et al., 2011)。青藏高原及其周缘高寒山区地域广阔、自然条件恶劣, 地质工作程度整体较低, 难以充分满足区域地质研究和矿产勘查需求。遥感具有覆盖范围广、重复观测能力强和可获取多尺度地表信息等优势, 已成为区域地质调查和矿产勘查的重要技术手段(焦润成等, 2014; 高猛等, 2019; 李斯等, 2023; 裴秋明等, 2024; 赵博等, 2025; Liu et al., 2026)。对于植被稀疏、基岩裸露程度较高的高寒干旱山区, 利用遥感影像快速获取岩性空间分布信息, 对提高地质填图效率具有重要意义。

遥感岩性识别方法已由人工目视解译、波段运算与特征变换, 逐步发展到支持向量机、随机森林等机器学习方法(刘磊等, 2013; Rajan et al., 2019; Cracknell et al., 2014; Wang et al., 2020; 韩海辉等, 2022; Lu et al., 2023; 李志忠等, 2025; 周永章等, 2026)。这些方法能

够利用多波段光谱差异建立岩性分类模型，不同岩性单元的遥感响应同时受到矿物组成、风化程度、地形阴影及地表覆盖等多种因素影响，易出现明显的“同物异谱”和“异物同谱”现象（沈家乐等，2025）。传统机器学习方法通常依赖预先构建的光谱或统计特征，在复杂地质背景下对空间纹理、邻域结构以及光谱–空间耦合关系的表达能力有限，制约了复杂地质背景下岩性分类精度的进一步提高。

多源遥感融合为增强岩性判别信息提供了重要途径。ASTER 的可见光–近红外和热红外波段能够反映铁染、矿物反射以及与硅酸盐矿物 Si–O 振动相关的热红外响应，在岩性填图和矿产勘查中得到广泛应用（Son et al., 2014; 杨鑫燏等，2026）。Sentinel-2 具有较高空间分辨率、较短重访周期以及红边和短波红外波段配置，在地物边界刻画和多光谱信息获取方面具有优势（Drusch et al., 2012; Adiri et al., 2020）。近期研究进一步表明，不同传感器的光谱和空间信息具有较强互补性，合理组合 ASTER、Sentinel-2 等数据能够改善复杂地质区岩性识别效果（王子烨等，2023; Acar, 2026; Pei et al.,2026）。然而，多源数据同时也带来了波段冗余、空间尺度差异和特征维度增加等问题，如何在保留互补信息的同时降低数据冗余，并进一步挖掘融合数据中的有效判别特征，仍是遥感岩性填图需要解决的关键问题之一。

近年来，卷积神经网络（CNN）能够通过多层非线性变换自动提取高层特征，为光谱–空间信息的联合表达提供了新的技术路径（Talaei et al., 2023; 杨娜，2025; 王智宇等，2025）。仅利用单像元光谱容易受到光谱混淆影响，而仅利用空间纹理又可能弱化矿物组成对应的光谱差异，同时表征光谱特征和空间上下文已成为提高岩性识别能力的重要方向。已有研究通过双通道网络、三维卷积及多尺度 CNN 等方式开展光谱–空间联合特征提取，并显示出较好的岩性识别潜力（Roy et al., 2020; Wu et al., 2025; Pei et al., 2026）。与此同时，遥感样本具有明显的空间自相关性，随机像元划分可能造成训练与测试窗口重叠，从而高估模型精度（Mohamed et al., 2026）。因此，采用空间独立的样本划分方式，也是客观评价模型区域泛化能力的重要前提。

西昆仑地区是中国重要的矿产成矿区带之一，其中新疆阿克陶县布伦口乡–木吉乡一带位于松潘–甘孜–西昆仑花岗伟晶岩型稀有金属成矿带，稀有金属矿产资源潜力较大（李建康等，2023; 孔会磊等，2023; 高永宝等，2025）。研究区地形起伏强烈、野外调查条件较差，但植被稀疏、基岩裸露程度高，为利用遥感信息开展区域岩性识别提供了有利条件。研究区变质地层、中酸性侵入岩及第四系广泛发育，不同地质单元之间既存在光谱相似性，又具有不同的空间结构和纹理特征，为检验多源遥感光谱–空间联合分类方法提供了典型场景。基于此，笔者综合利用 ASTER 可见光–近红外/热红外数据与 Sentinel-2 多光谱数据，探索多源遥感信息融合及光谱–空间特征学习在岩性分类中的应用，重点分析不同数据源及热红外信息对分类结果的贡献，探索多源遥感数据融合与光谱–空间联合特征学习在西昆仑高寒复杂地质区岩性填图中的适用性，为类似地区的区域地质调查和稀有金属矿产勘查提供技术参考。

1 研究区概况及数据源

1.1 研究区概况

研究区位于阿克陶县城约120 km 处，总面积约为 793 km^2，坐标为 N 38°43′12.55″～38°56′30.35″，E 74°24′29.01″～74°46′43.68″。研究区地形以高山峡谷为主，海拔为 3 560～4 738 m，山顶多发育永久性积雪，气候属寒冷干旱高山–山地荒漠气候，年均气温为 3.6 ℃。由于高寒干旱的自然条件，地表植被极为稀疏，基岩裸露程度高，为遥感岩性识别提供了良好的影像解译条件。

从大地构造背景来看，研究区地处西昆仑造山带（图 1a），该造山带是古特提斯洋闭合及多期块体拼合的产物，经历了长期复杂的构造–岩浆演化过程（韩春明等，2021）。区域上岩浆活动强烈，以三叠纪中酸性岩浆侵入最为发育，形成规模巨大的花岗岩基及大量花岗伟晶岩脉，构成松潘–甘孜–西昆仑花岗伟晶岩型稀有金属成矿带的重要组成部分（李建康等，2023; 王利波等，2025; 解程皓等，2025）。

研究区地层区划属秦祁昆地层大区–昆仑–阿尔金地层区–西昆仑地层分区–公格尔地层小区。区域上出露的地层由老到新有：古元古界布伦阔勒岩群（Pt_1B）、志留统（S）及第四系（Q）（图 1b）。

（1）古元古界布伦阔勒群（Pt_1B）：布伦阔勒群出露于勒布隆–布伦口–公格尔山一带，呈 NW–SE 向展布，与志留系达坂沟群均呈断层接触。布伦阔勒群主要

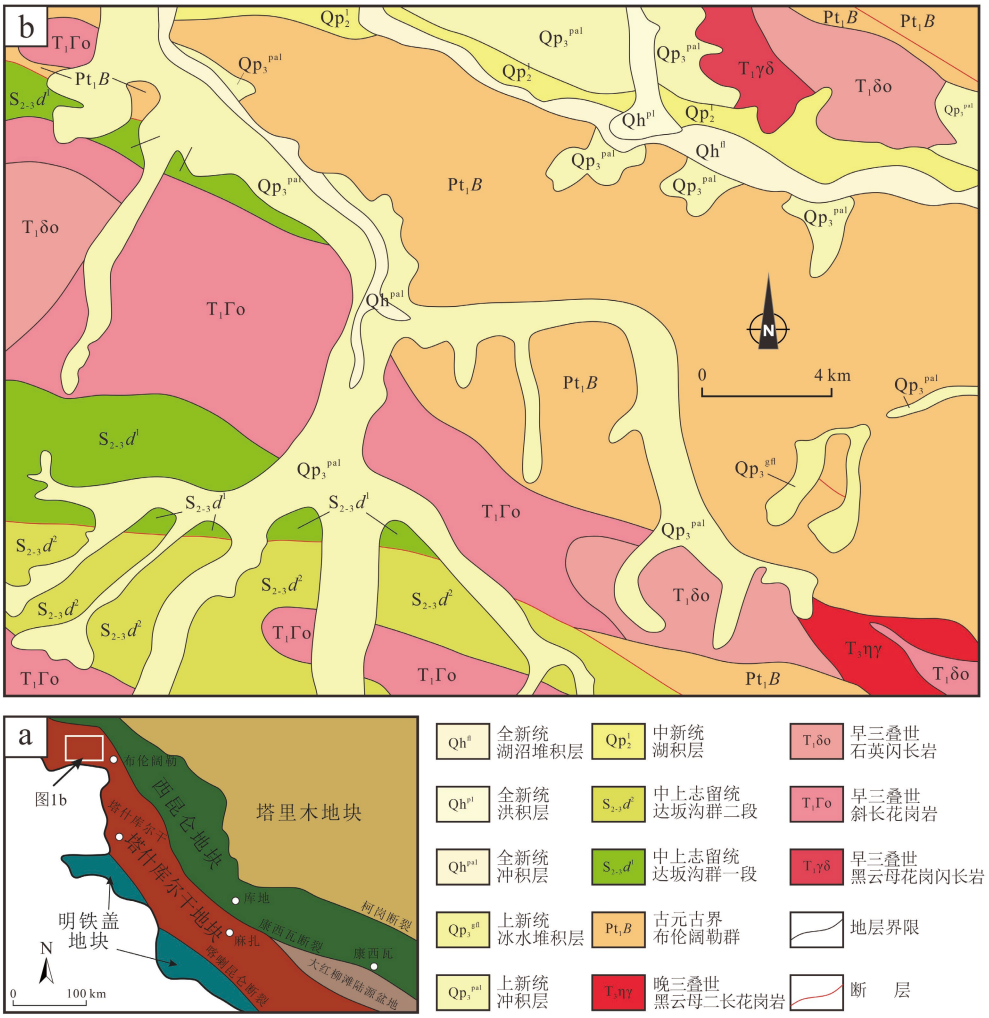


图1　西昆仑构造分区简图(a;据 Song et al.，2025 修改)及研究区地质简图(b; 据 1∶25 万区域地质图修改)

Fig. 1　(a) Simplified tectonic subdivision map of the West Kunlun and (b) simplified geological map of the study area

岩性为黑云石英片岩、黑云斜长片麻岩和黑云斜长片岩、黑云石英片岩夹石英岩、大理岩等。整体可以分为上、下两部分，总片褶厚度大于3 392.55 m。下部以片麻岩为主、夹片岩，上部以片岩为主、夹片麻岩。下部主要岩性为浅灰色黑云斜长片麻岩、二云斜长片麻岩，少量黑云斜长片岩、矽线黑云石英片岩、黑云石英片岩、白云黑云石英片岩，片褶厚度大于 1 753.91 m。上部主要岩性为浅灰黑色黑云石英片岩、含石榴黑云石英片岩、灰色黑云斜长片岩、含矽线黑云斜长片岩、少量黑云斜长片麻岩、石榴矽线黑云石英片岩、矽线黑云石英片岩等，片褶厚度大于 1 638.64 m。该套变质地层总体呈 NW–SE 向展布，大体上北东部走向 NW–SE 向，倾向 NE，倾角为 35°～57°；南西部倾向 SW，倾角约为 38°，该套地层为研究区内稀有金属矿化的伟晶岩脉产出部位。

(2)中—上志留统达坂沟群($S_{2\text{-}3}d$)：主要分布于区域南部，两侧以断裂与其他地质单元相接。地层呈 NWW–SEE 向带状延伸，是区内最主要的岩石地层之一，南与温泉沟群断层接触，东、西、北侧均大部分延出区外，局部被岩体破坏，少许被第四系覆盖。岩性主要为变长石石英砂岩、变粉砂岩为主，夹细晶灰岩、绿泥绢云石英千枚岩等。地层中发育有少量的锑等单元素异常。根据岩石组合特征，区域上达坂沟群自南向北可划分为两个岩性段。达坂沟群一段($S_{2\text{-}3}d^1$)：主要为灰色变质细粒长石石英砂岩、杂砂岩，灰色变质石英粉砂岩，灰色粉砂粘土板岩，灰色薄层粉晶灰岩(少量)；具变余细粒砂状结构，变余粉砂显微鳞片变晶结构，粉晶、微晶结构，变余层状构造，块状构造，板状构造。轴面劈理发育。达坂沟群二段($S_{2\text{-}3}d^2$)：主要为淡绿灰色变质细粒长石砂岩，变质不等粒长石石英砂岩，淡绿灰色片理化细粒长石石英杂砂岩，淡绿灰色片理化长石杂砂岩，深灰色粉砂黏土板岩；具变

余细粒砂状结构，变余粗粒砂状结构，变余泥质结构，平行构造，块状构造，板状构造。

（3）第四系（Q）：区域内在山间河谷及两侧分布，出露有中更新统、上更新统及全新统。其中中更新统（Qp^2）主要出露于布伦口湖附近，岩性主要为冰碛及湖积层等；上更新统（Qp^3）主要分布于大的支流上部水系附近，在大的支流两侧也有少量分布，岩性主要为冰水堆积、冰川堆积及冲洪积层；全新统（Qh）主要分布于大的支流水系中，冰水堆积、沼泽堆积、风积层、冲洪积物及冲积物等。

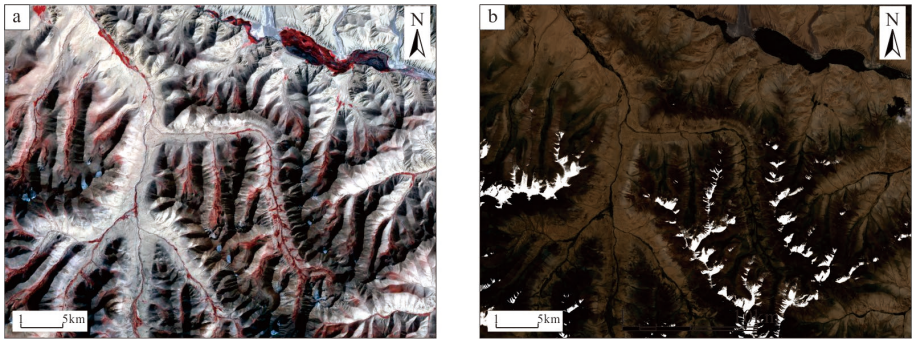
区内岩浆岩较为发育，主要产出于喀喇昆仑造山带，大致以志留系为界，明显分为 SN 两条 NW 向不规则带状，与区域构造线基本一致。岩石类型以三叠纪中酸性侵入岩为主，中酸性岩类又以英云闪长岩占绝对优势，另为二长花岗岩、花岗闪长岩、石英闪长岩。石炭纪—二叠纪基性–超基性侵入岩及少量火山岩。三叠纪岩浆岩大面积分布于研究区西南一带，呈 NW–SE 向展布。岩性由老到新依次为早三叠世斜长花岗岩（$T_1\Gamma o$）、早三叠世石英闪长岩（$T_1\delta o$）、早三叠世黑云母花岗闪长岩（$T_1\gamma\delta$）和晚三叠世黑云母二长花岗岩（$T_3\eta\gamma$），并形成多达上千条的花岗伟晶岩脉，为调查区内稀有金属矿产主要赋存部位，同时在小的二云花岗岩中还见有铌钽矿化。

1.2 数据源及其预处理

ASTER 数据来源于 NASA EOS Terra 卫星的存档数据，产品编号为 AST_09T_00409122024051013_20251007020810 和 AST_09_00409112003055729_20250315075745，产品级别为 L2 级，已进行大气校正。数据以 HDF-EOS 格式存储，包含 VNIR（3 波段，分辨率 15 m）及 TIR（5 波段，分辨率 90 m）两个光学子系统共 8 个波段的辐射亮度信息。选取 ASTER 数据的原因在于：其可见光—近红外波段可提供铁染及矿物反射特征信息，热红外波段对硅酸盐矿物的 Si–O 振动特征敏感，在火成岩广泛分布的地区具有良好的岩性区分效果，长期以来被广泛用于岩性填图与矿产勘查（Son et al., 2014; 裴秋明等, 2024; Acar, 2026）。考虑到 ASTER 短波红外（SWIR）探测器已于 2008 年失效、研究区可用的历史 SWIR 数据质量不佳，仅选用其 VNIR 与 TIR 共 8 个波段参与融合。

Sentinel-2 数据通过欧空局的哥白尼开放数据访问中心获取，采用 Sentinel-2B 卫星于 2024 年 7 月 3 日通过研究区上空的同一轨道相邻两景影像，编号分别为 S2B_MSIL2A_20240703T054639_N0510_R048_T43SDC_20240703T081922 与 S2B_MSIL2A_20240703T054639_N0510_R048_T43SDD_20240703T081922。产品级别为 MSIL2A，即经过 Sen2Cor 处理器大气校正后的地表反射率产品，免去了传统 L1C 级数据繁琐的大气校正流程。Sentinel-2 L2A 级数据产品直接提供 13 个波段的地表反射率，可直接用于波段运算与指数构建，提供了丰富的光谱信息。研究区海拔高且深入内陆，干旱寒冷，无明显植被覆盖，最大的干扰因素为终年积雪区，积雪区随着气温降低扩大。因此数据时相选择 7 月份，积雪区范围小，对后续处理影响较小。

辐射一致性是多源遥感数据融合的基础前提。ASTER 数据采用 NASA 发布的 AST_09/AST_09T 地表反射率产品，该产品已基于辐射传输模型完成大气校正。笔者在此基础上进行几何精校正、波段合成与重采样，将 VNIR 波段统一至目标分辨率以满足多源数据融合要求（图 2）。Sentinel-2 采用 L2A 级大气底层反射率产品，该产品已由 ESA 完成 Sen2Cor 大气校



a. 研究区 ASTER 影像（假彩色，R=B3N，G=B2，B=B1）；b. 研究区 Sentinel-2 影像（真彩色）

图2 研究区遥感影像

Fig. 2 Remote sensing images of the study area

正处理, 文中使用 SNAP 软件将所有波段统一重采样至 10 m 空间分辨率(图 2)。为实现多源数据在空间维度的严格对准, 笔者以 Sentinel-2 的 B4(红波段)和 ASTER 的 3N(后视近红外)波段为基准, 采用 Image-to-Image 几何配准方法。在影像重叠区域内, 基于地形特征点手动采集 30 个均匀分布的地面控制点, 配准误差控制在 1 个像元以内。ASTER VNIR 波段采用双线性插值法重采样至 10 m 分辨率。最终数据源统一至 WGS-84 坐标系和 UTM 投影下 10 m 空间分辨率格网, 为多源波段融合奠定基础。在统一空间参考框架后, 笔者对 ASTER 和 Sentinel-2 的波段进行互补性融合(图 3)。ASTER 的 TIR 波段(B10–B14)具有连续的光谱采样能力, 可敏感识别硅酸盐矿物的 Si–O 振动特征并有效区分岩石类型; Sentinel-2 的红边波段(B5、B7)及短波红外波段(B11、B12)则在植被覆盖区矿物蚀变信息提取方面具有优势(Adiri et al., 2020)。

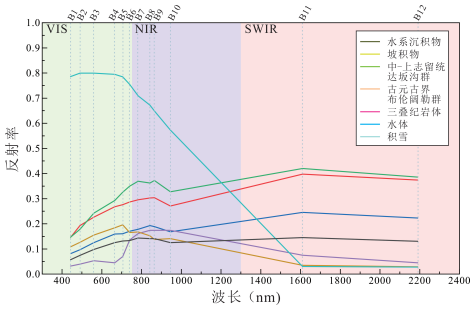


图3　研究区主要岩性单元光谱曲线

Fig. 3　Spectral curves of lithological units

2　研究方法

2.1　多源数据融合与降维

2.1.1　主成分分析法

高维特征空间中波段间相关性会导致信息冗余并降低计算效率。主成分分析(Principal Component Analysis, PCA)通过正交线性变换将高维相关特征转换为少数相互独立的主成分, 在保留主要信息的同时实现数据降维(Anowar et al., 2021)。文中先对融合后的 20 维特征向量进行标准化, 再基于相关系数矩阵进行 PCA 变换, 并按累计方差贡献率选取主成分个数。

$$\eta_k=\frac{\lambda_k}{\sum_{i=1}^{p}\lambda_i},\ \sum_{k=1}^{m}\eta_k=\frac{\sum_{k=1}^{m}\lambda_k}{\sum_{i=1}^{p}\lambda_i}$$

式中: λ_k为第k个主成分的特征值; p为原始特征维数; m为保留的主成分个数。

结果表明, 前 6 个主成分的累计方差贡献率超过 98%, 可有效代表原始数据的主要信息, 因此选取前 6 个主成分构建最终的融合特征集。

2.1.2　t 分布随机邻域嵌入

t-SNE(t-distributed Stochastic Neighbor Embedding, t-SNE)是一种非线性降维可视化方法, 可将高维特征映射至低维空间以直观评估类别聚类效果(Van Der Maaten et al., 2008)。t-SNE 已应用于高维化探数据的降维与可视化(陈军林等, 2021)、揭示矿化模式等(Shi et al., 2023)方面, 展现了 t-SNE 在捕捉信息非线性结构方面的独特价值。为直观评估 PCA 降维后各类别在特征空间中的聚类效果, 文中采用 t-分布随机邻域嵌入进行可视化分析。

基于 PCA 降维后的 6 维特征, 对区内 7 类岩性单元进行 t-SNE 二维可视化, 参数设置为目标维度 2、困惑度(perplexity)50、迭代次数 1 000。结果表明, 7 类岩性单元在特征空间中呈现明显的聚类趋势, 同类样本聚集度较高, 异类间边界清晰, 验证了多源融合特征对研究区主要岩性类型的良好可区分性, 为后续深度学习分类模型训练提供了可靠的特征基础(图 4)。

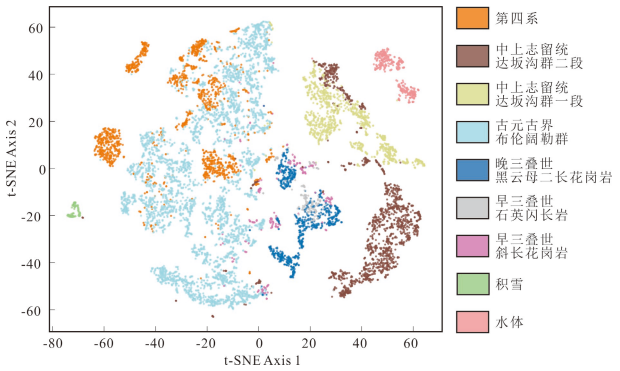


图4　t-SNE 降维可视化结果

Fig. 4　The result of t-SNE

2.2　1D-2D 双分支卷积神经网络

1D-2D 双分支 CNN(图 5)的核心思想是将光谱特征与空间特征解耦提取后再联合决策。一维卷积沿光谱方向滑动, 捕捉波段间连续的吸收谷与反射峰模式; 二维卷积在空间域操作, 提取纹理结构、边缘轮廓及邻域上下文信息。两个分支可在岩性边界模糊、光谱特征相近的复杂地质场景中取得优于单分支模型的效果(Pei et al., 2026)。

网络整体由光谱分支、空间分支与融合分类模块

组成(表 1)。光谱分支以中心像元的光谱向量(1×C)为输入,经两层 Conv1D 提取 128 维光谱特征;空间分支以 C×15×15 像元图像块为输入,经两层 Conv2D 提取 128 维空间特征。两分支特征在通道维度拼接为 256 维联合特征,经全连接层与 Softmax 映射至岩性类别概率。网络的两分支输出维度统一设为 128,保证光谱与空间特征在融合时表征能力相当,避免单一模态主导联合表示。最终的信息融合采用特征层拼接融合而非决策层加权,使两类特征在浅层即完成交互,有利于学习光谱与空间特征间的非线性关联。

表 1 双分支卷积神经网络(1D-2DCNN)参数

Tab. 1 Parameters of dual-branch CNN (1D-2DCNN)

分支路径	层	输出通道	卷积核尺寸	输出维度
Branch 1(1D)	Input(Center Pixel)	/	/	1×C
	Conv 1d	64	5	64×C
	Conv 1d	128	3	128×C
	Avgpool 1d	/	output 1	128
Branch 2 (2D)	Input(Patch)	/	/	C×15×15
	Conv 2d	64	3×3	64×15×15
	Conv 2d	128	3×3	128×15×15
	Avgpool 2d	/	output 2	128
Merge	Concatenate	/	/	256
	Dense(Linear)	/	/	128
	Output(Softmax)	/	/	Num classes

2.3 3D-2D 混合神经网络

3D-2D 混合神经网络(HybridSN)(图 5)采用另一种技术路径(Roy et al., 2020):利用三维卷积(3D Convolution)同时沿光谱与空间两个维度提取联合特征,再通过二维卷积进行高层空间语义抽象。相较于 1D-2DCNN 的显式解耦策略,HybridSN 更强调光谱–空间特征的联合表征能力,其残差连接设计有助于缓解深层网络中的信息退化问题(He et al., 2016),使浅层的光谱细节能够直接传递至深层参与分类决策。

模型输入首先经过光谱特征增强模块(Spectral),该模块由两个 Spectral 块构成。每个 Spectral 块内部包含两层三维卷积:第一层采用 1×1×1 卷积核调整通道维度,第二层采用 3×1×1 卷积核沿光谱方向进行一维卷积;块内设置恒等映射捷径连接,将输入与卷积输出相加形成残差路径,两个 Spectral 块均配置 16 个输出通道。增强后的特征进入两层三维卷积,逐层扩展三维感受野,每层后接 BN 与 ReLU 激活。输出张量经 Reshape 展平光谱与特征通道后,输入一层 3×3 二维卷积完成高层空间语义抽象,再经自适应平均池化展平为 512 维向量,最终由含 Dropout 的全连接层与 Softmax 输出分类结果,以降低训练样本有限时的过拟合风险。

网络中 Spectral 块的 3×1×1 卷积仅在光谱维度扩展感受野而保持空间维度不变,避免空间信息在浅层被过度平滑,三维卷积同步在光谱与空间维度提取联合特征,相较 1D-2D CNN 的分离式分支结构,能够在早期阶段建模特定波段区间在空间邻域内的联合响应,对具有空间异质性的岩性单元更具判别力。3D 卷积–2D 卷积的混合架构,先建模光谱–空间耦合模式,再进行高层空间抽象,设置网络各层参数(表 2),兼顾特征表达能力与计算开销。

2.4 对比实验设计

为系统评估双分支架构中光谱特征与空间特征各自对分类性能的贡献,文中在两种主模型之外,另行构建两个单分支对比模型:①一维光谱卷积网络(1DCNN),即 1D-2DCNN 中仅保留光谱分支,输入为中心像元光谱向量,经光谱特征增强模块处理,两层 Conv1D 操作后直接接入分类层,用于检验纯光谱信息的分类能力;②二维空间卷积网络(2DCNN),即 1D-2DCNN 中仅保留空间分支,输入为 15×15 图像块,经光谱特征增强模块处理,两层 Conv2D 后直接分类,用于检验纯空间纹理信息的分类能力。两个对比模型与 1D-2DCNN、HybridSN 采用完全相同的训练配置、样本划分及评估流程,确保实验结果的可比性。模型性能采用总体精度(Overall Accuracy, OA)、Kappa 系数、精确率、召回率及 F1-score 等指标综合评价。

3 结果与分析

3.1 模型训练

研究区经预处理后得到的有效数据范围为 2 473 像素×3 207 像素。根据处理后数据光谱可分性与目标区域地物特性划分岩性单元:第四系覆盖物颗粒较大,当前空间分辨率下类内区分性差,故按照含水量划分为两类;三叠纪岩体不同时期光谱区分度较小,划分为一个单元。每个像素样本的真值以 1∶50 000 地质图为准进行手动标定。为降低空间自相关导致的训练集与测试集信息泄漏,文中采用空间区块划分

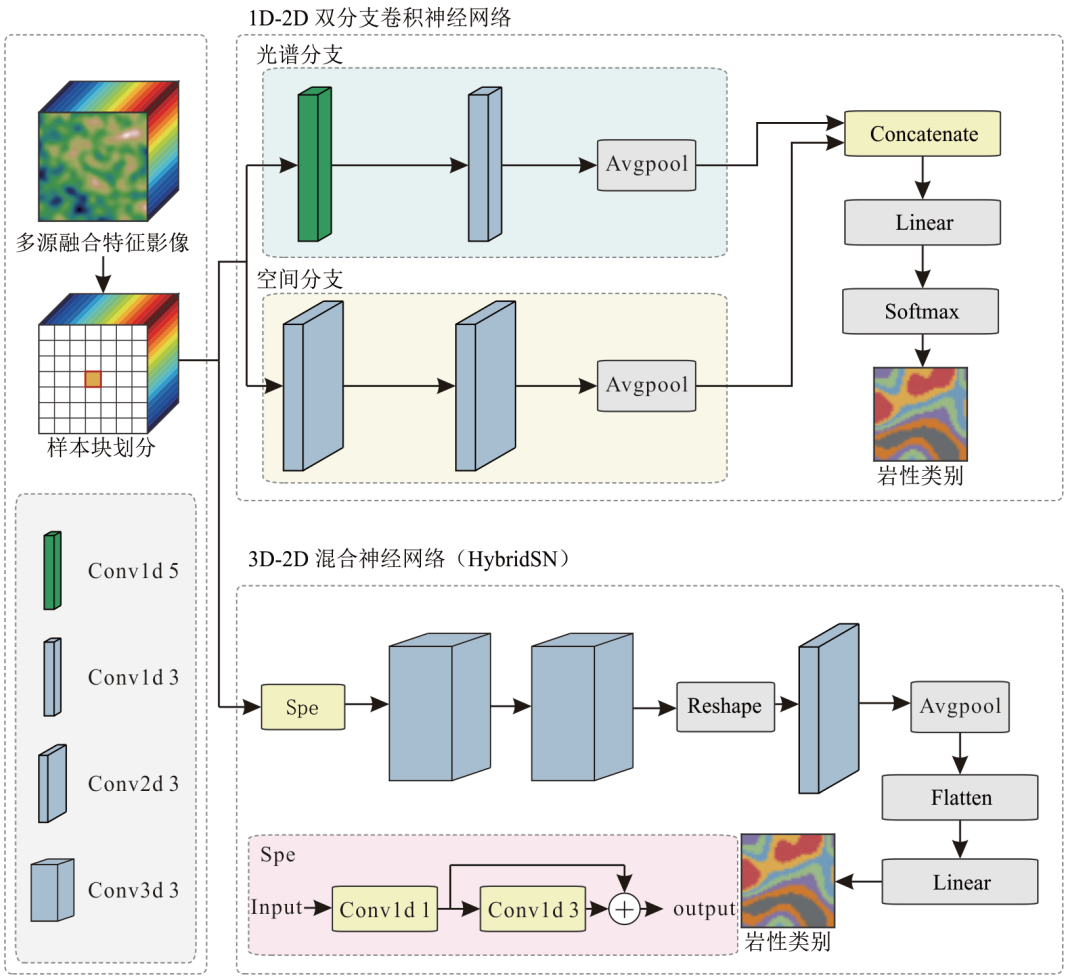


图5　模型结构

Fig. 5　Model structure

表 2　3D-2D 混合神经网络（HybridSN）参数

Tab. 2　Parameters of 3D-2D hybrid neural network (HybridSN)

模块	层	输出通道	卷积核尺寸	输出维度
Input	/	/	/	1×C×15×15
Spectral Block 1	Conv 3d	16	1×1×1	16×C×15×15
	Conv 3d	16	3×1×1	16×C×15×15
	Shortcut	/	/	16×C×15×15
Spectral Block 2	Conv 3d	16	1×1×1	16×C×15×15
	Conv 3d	16	3×1×1	16×C×15×15
	Shortcut	/	/	16×C×15×15
3D-2D Convolution	Conv 3d	32	3×3×3	32×C×15×15
	Conv 3d	64	3×3×3	64×C×15×15
	Reshape（3D to 2D）	/	/	（64·C）×15×15
	Conv 2d	128	3×3	128×15×15
	Avgpool 2D	/	（output 2x2）	128×2×2
	Flatten	/	/	512
	Dense（Linear）	/	/	128
	Dropout	/	/	128
Output	Dense（Softmax）	/	/	Num classes

策略：将研究区划分为 100×100 像元的区块，按 7∶1.5∶1.5 的比例将区块分配至训练集、验证集与测试集，并沿训练集边界设置 7 像元宽度的缓冲区，剔除缓冲区内样本 12 714 个，以保证 3 个子集在空间上相互独立。主成分分析仅在训练集样本上拟合，再应用于全部样本，以避免数据泄漏；验证集用于训练过程中的早停与模型选择，测试集仅在训练结束后评估一次。为检验结果对划分随机性的稳健性，上述划分以 3 个不同随机种子重复进行（表 3），文中报告 3 次实验的均值与标准差。

表 3 研究区分类单元样本统计

Tab. 3 Sample statistics of classification units

岩性单元	训练集	验证集	测试集
积雪	1 995	2 014	176
水体	1 680	75	1 146
水系沉积物	609	198	414
坡积物	26 295	2 683	3 793
古元古界布伦阔勒群	10 491	1 460	1 834
三叠纪岩体	15 910	2 791	2 259
中上志留统达坂沟群	15 570	1 898	4 615
总计	72 550	11 119	14 237

4 种模型采用统一的训练配置。输入数据以目标像元为中心，取 15×15 像元的空间窗口构建样本块。经 PCA 降维后，光谱维度压缩至 6 个主成分。模型训练使用 Adam 优化器，初始学习率设为 0.000 1，采用 StepLR 学习率衰减策略，每经过 10 个 epoch 将学习率乘以 0.5，批大小设为 64。损失函数选用交叉熵损失（Cross-Entropy Loss）。模型训练最多进行 50 个 epoch，训练过程中以验证集损失进行早停监控（patience=10），并保存验证集损失最低时的模型权重作为最终参数。两种主模型在训练集与验证集上的损失与精度曲线（图 6）显示，模型均快速收敛，训练与验证指标间差距较小，未见明显过拟合特征。

3.2 分类结果

基于相同样本集与训练配置，对 1D-2DCNN、HybridSN 及两个单分支对比模型进行岩性分类实验，各模型均以 3 个不同随机种子的空间区块划分重复实验，获取了 1D-2DCNN 与 HybridSN 在测试集上的逐类评估指标（表 4、表 5），包括 3 次重复的均值（样本数以首次划分为例），4 种模型的综合精度对比结果（表 6）和分类填图结果（图 7）。

表 4 双分支卷积神经网络（1D-2DCNN）评估指标（3 次重复划分均值）

Tab. 4 Classification accuracy of 1D-2DCNN (mean of 3 repeated partitions)

类别	精确率	召回率	F1-score	样本数
积雪	0.917	1.000	0.952	176
水体	0.667	0.527	0.585	1 146
水系沉积物	1.000	0.690	0.711	414
坡积物	1.000	1.000	1.000	3 793
古元古界布伦阔勒群	0.983	0.942	0.960	1834
三叠纪岩体	0.975	1.000	0.987	2 259
中上志留统达坂沟群	0.830	1.000	0.897	4 615
宏平均	0.910	0.880	0.870	14 237
加权平均	0.898	0.925	0.904	14 237

表 5 3D-2D 混合神经网络（HybridSN）评估指标（3 次重复划分均值）

Tab. 5 Classification accuracy of HybridSN (mean of 3 repeated partitions)

类别	精确率	召回率	F1-score	样本数
积雪	1.000	1.000	1.000	176
水体	1.000	0.721	0.808	1 146
水系沉积物	1.000	1.000	1.000	414
坡积物	1.000	1.000	1.000	3 793
古元古界布伦阔勒群	0.981	0.941	0.958	1834
三叠纪岩体	0.975	1.000	0.987	2 259
中上志留统达坂沟群	0.888	1.000	0.935	4 615
宏平均	0.978	0.952	0.955	14 237
加权平均	0.966	0.956	0.951	14 237

OA代表分类正确的样本个数占所有样本个数的比例，其计算公式为 $OA=\frac{\sum_{i=1}^{c} TP_i}{N_{total}}$。其中 TP_i 代表预测为正且真实为正的样本数，N_{total} 为总样本数。Kappa 系数衡量预测标签与真实标签之间超出随机水平的一致性，计算公式为 $k=(p_o-p_e)/(1-p_e)$。式中：p_o 表示观察到的一致性（即准确率），p_e 表示随机水平下的预期一致性。k 值为 0.81～1.00 时表示基本一致。

3.3 模型性能对比与误差分析

根据评估指标和分类填图输出（图 7），4 种模型在七类岩性分类任务中均取得了较高的整体精度，其中 HybridSN 综合表现最优，1D-2DCNN 与 2DCNN 次之且二者接近，1DCNN 最低。HybridSN 的宏平均 F1-score 高于 1D-2DCNN，表明其在小样本类别上的识别

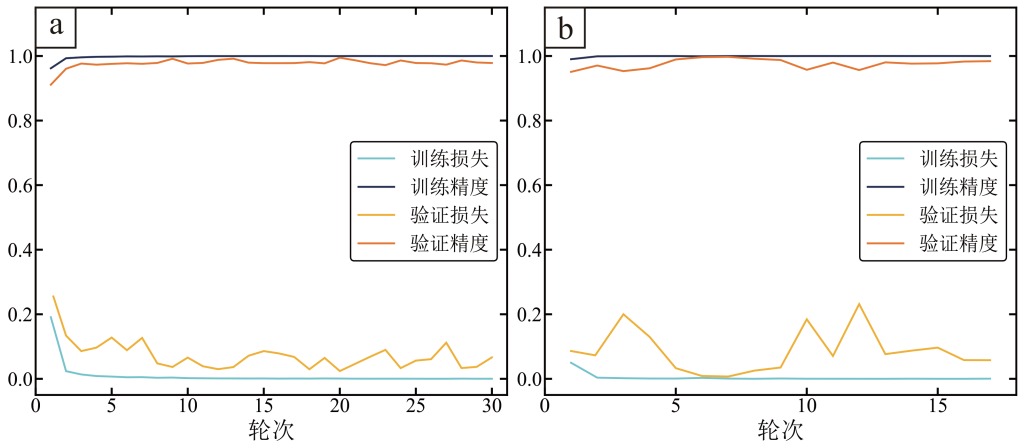


图6　1D-2DCNN 模型(a)与 HybridSN 模型(b)训练曲线

Fig. 6　(a) 1D-2DCNN and (b) HybridSN models training curves

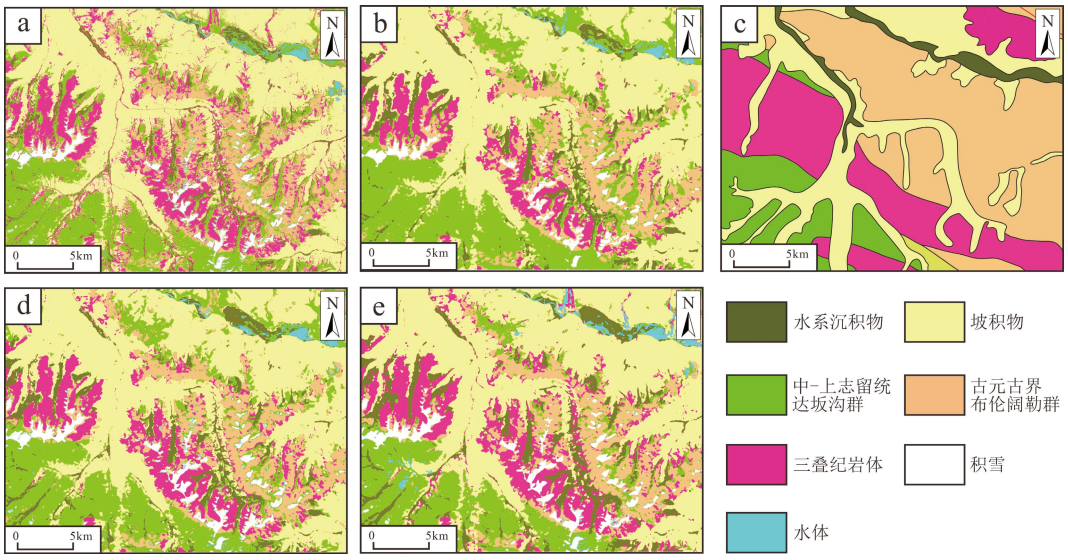
表 6　四种模型综合精度对比(3 次重复划分均值±标准差)

Tab. 6　Comparison of comprehensive accuracy of four models (mean ± std of 3 repeated partitions)

指标	1DCNN	2DCNN	1D-2DCNN	HybridSN
OA/%	90.4±5.5	92.3±6.6	92.5±6.8	95.6±4.9
Kappa系数	0.878±0.067	0.903±0.081	0.906±0.084	0.945±0.061
宏F1	0.886±0.057	0.910±0.077	0.870±0.085	0.955±0.048
加权F1	0.887±0.065	0.902±0.091	0.904±0.093	0.951±0.056

更为均衡; 1D-2DCNN 对坡积物、三叠纪岩体等大面积出露的优势类别识别稳定, 而 3D 卷积的光谱—空间联合特征提取使 HybridSN 在水体等小样本类别上获得了更高的召回率。

水体是所有模型识别中的难点类别。1D-2DCNN 对水体的召回率仅为 0.526 8, 超过 40% 的该类样本被分配到其他类别, 形成典型的保守型漏检; HybridSN 对水体的召回率提高到 0.721 3, 为 4 种模型中最高, 但仍是其各类别中的最低值。水体在近红外及短波红外波段具有强烈的吸收特征(图 3), 与某些暗色岩性、水系沉积物及积雪外围消融区域存在一定光谱混淆; 且区域内水系宽度较小, 在 15×15 像元的图像块中, 小规模溪流水体易被作为深色纹理识别, 从而引起错误分类。此外, 志留系达坂沟群、坡积物样本量相对较大, 模型预测时倾向输出这些类别, 预测图中河道位置可观察到志留系达坂沟群的噪点, 验证



a. 1D-2DCNN; b. HybridSN; c. 参考地质图; d. 1DCNN; e. 2DCNN

图7　岩性分类填图结果

Fig. 7　Lithological classification mapping results

了以上分析。

古元古界布伦阔勒群与三叠纪岩体之间的光谱混淆是误差的主要来源。布伦阔勒群在本区主要由变质程度较深的片岩、片麻岩及大理岩组成，岩性组合复杂、光谱变异程度大，其中相当一部分样本与三叠纪中酸性侵入岩光谱几乎一致（图 3）。4 种模型对布伦阔勒群的 F1-score 分别为 1DCNN 的 0.885 3、2DCNN 的 0.953 7、1D-2DCNN 的 0.959 8 和 HybridSN 的 0.958 0，纯光谱的 1DCNN 明显低于其他 3 种模型，仅依靠光谱信息难以准确区分这两个单元，而空间纹理与邻域上下文信息的引入显著改善了识别效果。相对而言，1D-2DCNN 的光谱分支对连续吸收形态和波段间相对关系的保留更为完整，与空间分支互补后取得了对布伦阔勒群较好的综合识别能力。

单分支对比实验进一步表明，仅使用光谱信息的 1DCNN 在四种模型中精度最低，且对布伦阔勒群的误判最为严重，其周围大量像元被误分为三叠纪岩体；仅使用空间信息的 2DCNN 整体精度与 1D-2DCNN 接近，说明在光谱特征相近的变质岩与侵入岩分布区，地物的空间相关性等空间信息是本研究区岩性识别的关键，而光谱与空间信息的联合建模能够在此基础上进一步提高分类性能。

需要指出的是，样本划分方式对精度评价结果有显著影响。作为对照，文中采用随机像素划分，对 1D-2DCNN 进行了实验，训练集与测试集按 7:3 随机分配、不设空间隔离，其 OA、Kappa 系数、宏平均与加权平均 F1-score 均达到 1.000 0，明显高于空间区块划分下的 0.925 1±0.067 6。随机划分时，测试像元的空间邻域往往已出现在训练集中，模型可通过记忆局部空间模式获得虚高的评价指标，属于典型的空间自相关导致的信息泄漏；而空间区块划分配合缓冲区隔离保证了测试集的空间独立性，所得精度更能反映模型在未知区域的真实泛化能力。

为定量评估多源融合的贡献，在相同划分与训练配置下，分别以单一 ASTER 数据、单一 Sentinel-2 数据及融合数据训练 1D-2DCNN，并设置了剔除 ASTER 热红外波段的消融实验（表 7）。融合数据的 OA 较单一 ASTER 数据提高约 7.3%，且在 3 次重复划分中均一致高于两种单源数据，表明多源融合有效增强了岩性可分性；融合数据与单一 Sentinel-2 数据精度接近，说明可见光–短波红外多光谱信息已提供主要的判别能力；剔除 TIR 波段后 OA 降至 87.7%，较完整融合数据降低约 4.9%，表明 ASTER 热红外信息对区分研究区硅酸盐岩性单元具有重要贡献。

表 7 不同数据组合的分类精度对比（1D-2DCNN，3 次重复划分均值±标准差）

Tab. 7 Classification accuracy comparison among data combinations (1D-2DCNN, mean ± std of 3 repeated partitions)

数据组合	OA（%）	Kappa系数	宏F1	加权F1
ASTER	85.3±6.0	0.814±0.071	0.740±0.123	0.831±0.076
Sentinel-2	91.2±4.0	0.887±0.049	0.880±0.055	0.884±0.056
ASTER+Sentinel-2 融合	92.5±6.8	0.906±0.084	0.870±0.085	0.904±0.093
融合（不含TIR）	87.7±3.5	0.842±0.041	0.814±0.019	0.834±0.044

4 结论

（1）多源遥感数据融合可有效增强岩性可分性。ASTER 可见光–近红外、热红外波段与 Sentinel-2 多光谱波段具有较好的信息互补性，经 PCA 降维获得的 6 个主成分在减少特征冗余的同时保留了主要地物信息。单源数据对比结果表明，融合数据的分类精度较 ASTER 单源数据提高约 7.3%；热红外波段消融后，总体精度下降约 4.9%，表明 TIR 信息对研究区硅酸盐岩性单元的识别具有重要作用。

（2）光谱–空间联合建模架构在区域地层填图中具有优势。HybridSN 的总体精度达到 95.58%，Kappa 系数和宏平均 F1-score 分别为 0.945±0.061 和 0.955±0.048，综合性能在 4 种模型中最佳，其光谱—空间联合特征提取方式对小样本类别具有更为均衡的识别能力。1D-2DCNN 的总体精度为 92.51%，其双分支结构对大范围出露的优势类别表现出较好的分类稳定性。2DCNN 的总体精度接近 1D-2DCNN，而 1DCNN 精度最低，进一步说明空间纹理与邻域上下文信息是区分研究区光谱特征相近的变质岩和侵入岩的重要依据。

（3）合理的样本划分策略是保证精度评价客观可靠的关键。随机像素划分受空间自相关影响，会导致分类精度高估约 7.5%；采用空间区块划分与缓冲区隔离，可有效降低训练样本与测试样本之间的空间依赖，使评价结果更能反映模型的实际泛化能力。研究结果表明，多源遥感数据与光谱–空间深度学习方法适用于西昆仑高寒山区复杂地质条件，可为类似地区的

区域岩性填图与战略性矿产勘查提供技术参考。

利益冲突声明(Conflict of Interests):

所有作者声明不存在利益冲突。

All authors disclose no relevant conflict of interests.

参考文献(References):

陈军林, 闫岩, 彭润民. 基于 t-SNE 降维算法的区域化探数据中地质体空间分布信息可视化: 以英格兰西南部为例[J]. 地质科技通报, 2021, 40(2): 186−196.

CHEN Junlin, YAN Yan, PENG Runmin. Visualization of spatial distribution information of geological bodies in regional geochemical data based on t-SNE dimensionality reduction algorithm: A case study of southwest England[J]. Bulletin of Geological Science and Technology, 2021, 40(2): 186−196.

邓乃尔, 徐浩, 周文, 等. 基于深度学习的岩石矿物智能识别研究进展与发展趋势[J]. 成都理工大学学报 (自然科学版), 2025, 52(1): 64−93.

DENG Naier, XU Hao, ZHOU Wen, et al. Research progress and development trends of intelligent recognition of rock minerals based on deep learning[J]. Journal of Chengdu University of Technology (Science& Technology Edition), 2025, 52(1): 64−93.

高猛, 付翰泽, 陈川. 遥感技术在和田玉成矿要素识别与找矿预测中的应用——以南阿尔金塔什萨依一带为例[J]. 西北地质, 2019, 52(3): 240−252.

GAO Meng, FU Hanze, CHEN Chuan. Hetian Jade Metallogenic Factors Identification and Prospecting Prediction by Remote Sensing Technology: Example from Tashisayi Area in South Altyn[J]. Northwestern Geology, 2019, 52(3): 240−252.

高永宝, 吴欢欢, 李文渊, 等. 新疆 509 道班西锂矿电气石矿物学及 40Ar-39Ar 同位素年代学特征[J]. 西北地质, 2025, 58(4): 207−222.

GAO Yongbao, WU Huanhuan, LI Wenyuan, et al. Tourmaline Mineralogy, 40Ar-39Ar Dating and Implications for the 509 Daobanxi Lithium Deposit in Xinjiang Province[J]. Northwestern Geology, 2025, 58(4): 207−222.

韩春明, 肖文交, 方爱民, 等. 西昆仑及邻区成矿规律和成矿系列[J]. 岩石学报, 2021, 37(12): 3615−3644.

HAN Chunming, XIAO Wenjiao, FANG Aimin, et al. Metallogenic regularity and metallogenic series of West Kunlun and its adjacent areas[J]. Acta Petrologica Sinica, 2021, 37(12): 3615−3644.

韩海辉, 张转, 任广利, 等. 一种快速识别基性-超基性岩的新方法: 基性度遥感指数法[J]. 西北地质, 2022, 55(2): 71−81.

HAN Haihui, ZHANG Zhuan, REN Guangli, et al. A New Method for Fast Identification of Basic-ultrabasic Rocks: Basic Degree Index from Remote Sensing Image[J]. Northwestern Geology, 2022, 55(2): 71−81.

焦润成, 秦彦平, 张淑云, 等. Worldview-2 数据在沉积岩地区的遥感岩性增强方法初探: 以新疆喀什阿尔塔什地区为例[J]. 西北地质, 2014, 47(4): 277−283.

JIAO Runcheng, QIN Yanping, ZHANG Shuyun, et al. A Preliminary Exploration of Methods to Enhance Remote Sensing Lithology with Worldview-2 Data in Sedimentary Rocks Area: A Case Study in Kashi Altas District of Xinjiang[J]. Northwestern Geology, 2014, 47(4): 277−283.

孔会磊, 任广利, 李文渊, 等. 西昆仑大红柳滩东含锂辉石花岗伟晶岩脉年代学和地球化学特征及其地质意义[J]. 西北地质, 2023, 56(2): 61−79.

KONG Huilei, REN Guangli, LI Wenyuan, et al. Geochronology, Geochemistry and Their Geological Significances of Spodumene Pegmatite Veins in the Dahongliutandong Deposit, Western Kunlun, China[J]. Northwestern Geology, 2023, 56(2): 61−79.

李建康, 李鹏, 严清高, 等. 松潘-甘孜-西昆仑花岗伟晶岩型稀有金属成矿带成矿规律[J]. 中国科学: 地球科学, 2023, 53(8): 1718−1740.

LI Jiankang, LI Peng, YAN Qinggao, et al. Geology and mineralization of the Songpan-Ganze-West Kunlun pegmatite-type rare-metal metallogenic belt in China: An overview and synthesis [J]. Science China: Earth Sciences, 2023, 53(8): 1718−1740.

刘磊, 王乐, 张凯南, 等. 基于机器学习的新疆东天山黄山地区遥感岩性自动分类及其识别精度分析[J]. 地质通报, 2025, 44(7): 1187−1200.

LIU Lei, WANG Le, ZHANG Kainan, et al. Automatic classification of remote sensing lithology in the Huangshan Area of the Eastern Tianshan Mountains in Xinjiang Based on machine learning and analysis of its recognition accuracy[J]. Geological Bulletin of China, 2025, 44(7): 1187−1200.

刘磊, 周军, 冯敏, 等. 甘肃北山辉铜山地区镁铁岩体遥感识别方法研究[J]. 遥感技术与应用, 2013, 28(3): 520−525.

LIU Lei, ZHOU Jun, FENG Min, et al. Lithological discrimination of the mafic rocks, Huitongshan, Beishan, Gansu, using remote sensing data[J]. Remote Sensing Technology and Application, 2013, 28(3): 520−525.

李斯, 李冬月, 鲁佳, 等. 秘鲁奇克拉约东部斑岩型铜矿带遥感找矿预测[J]. 矿产勘查, 2023, 14(11): 2135−2142.

LI Si, LI Dongyue, LU Jia, et al. Remote sensing prospecting prediction of the porphyry copper belt, eastern Chiclayo, Peru[J].

Mineral Exploration, 2023, 14(11): 2135−2142.

李志忠, 陈圣波, 刘德长, 等. 近年国内外遥感地质找矿主要进展[J]. 西北地质, 2025, 58(3): 183−195.

LI Zhizhong, CHEN Shengbo, LIU Dechang, et al. Progress of Remote Sensing Geological Prospecting Domestic and Abroad in Recent Years[J]. Northwestern Geology, 2025, 58(3): 183−195.

裴秋明, 沈家乐, 王世明, 等. 多源遥感卫星数据在脉状萤石矿床中的找矿预测应用: 以内蒙古水头萤石矿床为例[J]. 西北地质, 2024, 57(4): 121−134.

PEI Qiuming, SHEN Jiale, WANG Shiming, et al. Exploring Fluorite Veins Using Multi-source Remote Sensing Satellite Data: A Case Study from the Shuitou Fluorite Deposit in Inner Mongolia, China[J]. Northwestern Geology, 2024, 57(4): 121−134.

沈家乐, 裴秋明, 张沥, 等. 基于喀喇沁旗大西沟萤石矿区 SPOT-5、Landsat-9 和 ASTER 影像的多元信息提取和找矿预测[J]. 地质论评, 2025, 71(5): 1774−1786.

SHEN Jiale, PEI Qiuming, ZHANG Li, et al. Multi-information extraction and prospecting prediction based on SPOT-5, Landsat-9 and ASTER images in the Daxigou fluorite mining area, Harqin Banner[J]. Geological Review, 2025, 71(5): 1774−1786.

王利波, 王威, 姚宗全, 等. 新疆和田县 509 道班西锂铍稀有金属矿床石榴子石特征及其岩浆演化意义[J]. 西北地质, 2025, 58(4): 223−233.

WANG Libo, WANG Wei, YAO Zongquan, et al. Characteristics of Garnet in the 509 Daobaxi Lithium Beryllium Rare Metal Deposits in Hotan County, Xinjiang and Indicative Significance of Magmatic Evolution[J]. Northwestern Geology, 2025, 58(4): 223−233.

王智宇, 王达, 邱昆峰, 等. 机器学习在矿物岩石地球化学大数据挖掘中的应用与展望[J]. 成都理工大学学报 (自然科学版), 2025, 52(5): 844−858.

WANG Zhiyu, WANG Da, QIU Kunfeng, et al. Applications and perspectives of machine learning in geochemical big data mining of minerals and rocks[J]. Journal of Chengdu University of Technology (Science & Technology Edition), 2025, 52(5): 844−858.

王子烨, 左仁广. 基于多源数据融合的喜马拉雅淡色花岗岩识别[J]. 地学前缘, 2023, 30(5): 216−226.

WANG Ziye, ZUO Renguang. Mapping Himalayan leucogranites by machine learning using multi-source data[J]. Earth Science Frontiers, 2023, 30(5): 216−226.

解程皓, 李永, 刘伟, 等. 新疆和田县 509 道班西锂矿地质构造特征及控矿构造研究[J]. 西北地质, 2025, 58(4): 234−249.

XIE Chenghao, LI Yong, LIU Wei, et al. Geological Structural Characteristics and Ore-controlling Structures of the West 509-Daoban Li Deposit, Hetian, Xinjiang[J]. Northwestern Geology, 2025, 58(4): 234−249.

杨娜. 多尺度特征融合算法及其在智能成矿预测中的应用[J]. 矿物岩石地球化学通报, 2025, 44(3): 478−491.

YANG Na. Multi-scale feature fusion extraction algorithm and its application in intelligent mineral prospectivity prediction[J]. Bulletin of Mineralogy, Petrology and Geochemistry, 2025, 44(3): 478−491.

杨鑫燏, 李晨伟, 孙文博, 等. 集成多光谱与数字高程模型的机器学习找矿方法——以老挝华潘省离子吸附型稀土为例[J/OL]. 成都理工大学学报 (自然科学版), 2026: 1−20.

YANG Xinyu, LI Chenwei, SUN Wenbo, et al. Machine learning-based prospectivity prediction integrating ASTER multispectral and digital elevation model data: A case study of ion-adsorption-type rare earth elements in Huaphan Province, Laos[J/OL]. Journal of Chengdu University of Technology (Science & Technology Edition), 2026: 1−20.

赵博, 张德会, 陈其慎, 等. 遥感大数据解译及仿遥感地学知识发现[J]. 矿物岩石地球化学通报, 2025, 44(3): 462−477.

ZHAO Bo, ZHANG Dehui, CHEN Qishen, et al. The interpretation of remote sensing bigdata and discovery of the remote sensing-mimetic geoscientific knowledge[J]. Bulletin of Mineralogy, Petrology and Geochemistry, 2025, 44(3): 462−477.

周永章, 刘刚, 毛先成, 等. 地球科学智能: 进展、挑战与未来方向[J]. 矿物岩石地球化学通报, 2026, 45(3): 693−711.

ZHOU Yongzhang, LIU Gang, MAO Xiancheng, et al. AI for geoscience: Progress, challenges and future directions[J]. Bulletin of Mineralogy Petrology and Geochemistry, 2026, 45(3): 693−711.

Acar R U. Comparative evaluation of ASTER, Landsat 8, and Sentinel-2A data for lithological mapping in the Emet-Hisarcık Borate Basin (Türkiye) using machine learning[J]. Advances in Space Research, 2026, 77(9): 8863−8883.

Adiri Z, Lhissou R, El Harti A, et al. Recent advances in the use of public domain satellite imagery for mineral exploration: A review of Landsat-8 and Sentinel-2 applications[J]. Ore Geology Reviews, 2020, 117: 103332.

Anowar F, Sadaoui S, Selim B, 2021. Conceptual and empirical comparison of dimensionality reduction algorithms (PCA, KPCA, LDA, MDS, SVD, LLE, ISOMAP, LE, ICA, t-SNE)[J]. Computer Science Review, 2021, 40.

Cracknell M J, Reading A M. Geological mapping using remote sensing data: a comparison of five machine learning algorithms, their response to variations in the spatial distribution of training data and the use of explicit spatial information[J]. Computers & Geosciences, 2014, 63: 22−33.

Drusch M, Del Bello U, Carlier S, et al. Sentinel-2: ESA's optical high-resolution mission for GMES operational services[J]. Remote Sensing of Environment, 2012, 120: 25−36.

Grebby S, Naden J, Cunningham D, et al. Integrating airborne multispectral imagery and airborne LiDAR data for enhanced lithological mapping in vegetated terrain[J]. Remote Sensing of Environment, 2011, 115(1): 214−226.

He Kaiming, ZHANG Xiangyu, REN Shaoqing, et al. Deep residual learning for image recognition[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas, NV, USA: IEEE, 2016: 770−778.

Henriques C, Zêzere J L, Marques F. The role of the lithological setting on the landslide pattern and distribution[J]. Engineering Geology, 2015, 189: 17−31.

Liu L, Yin C, Wen H, et al. Mapping lithium hosting claystone using WorldView-3 image and deep learning method[J]. Gondwana Research, 2026, 151: 18−35.

Lu J, Han L, Liu L, et al. Lithology classification in semi-arid area combining multi-source remote sensing images using support vector machine optimized by improved particle swarm algorithm[J]. International Journal of Applied Earth Observation and Geoinformation, 2023, 119: 103318.

Mohamed Ali El-Omairi, Abdelkader El Garouani. Satellite based lithological Mapping: A review of Sensors, Methods, and emerging Machine-Learning approaches[J]. International Journal of Applied Earth Observation and Geoinformation, 2026, 149: 105309.

Pei Qiuming, Shen Jiale, Zhang Li, et al. A Spectrally Enhanced Multi-Scale CNN for Limited-Sample Lithological Mapping Using Band-Integrated ASTER and Sentinel-2A Imagery[J]. Remote Sensing, 2026, 18(13): 2163.

Rajan Girija R, Mayappan S. Mapping of mineral resources and lithological units: a review of remote sensing techniques[J]. International Journal of Image and Data Fusion, 2019, 10(2): 79−106.

Roy S K, Krishna G, Dubey S R, et al. HybridSN: Exploring 3-D-2-D CNN feature hierarchy for hyperspectral image classification [J]. IEEE Geoscience and Remote Sensing Letters, 2020, 17(2): 277−281.

Shi Z, Zuo R, Xiong Y, et al. Revealing geochemical patterns associated with mineralization using t-distributed stochastic neighbor embedding and random forest[J]. Mathematical Geosciences, 2023, 55(3): 321−344.

Son Y S, Kang M K, Yoon W J. Lithological and mineralogical survey of the Oyu Tolgoi region, Southeastern Gobi, Mongolia using ASTER reflectance and emissivity data[J]. International Journal of Applied Earth Observation and Geoinformation, 2014, 26: 205−216.

Song Yue, Li Liang, Gao Yuan, et al. Genesis and Evolution of the Qieliekeqi Siderite Deposit in the West Kunlun Orogen: Constraints from Geochemistry, Zircon U-Pb Geochronology, and Carbon-Oxygen Isotopes[J]. Minerals, 2025, 15(7): 699.

Talaei Khoei T, Ould Slimane H, Kaabouch N. Deep learning: systematic review, models, challenges, and research directions[J]. Neural Computing and Applications, 2023, 35(31): 23103−23124.

Van Der Maaten L, Hinton G. Visualizing data using t-SNE[J]. Journal of Machine Learning Research, 2008, 9: 2579−2605.

Wang Z, Zuo R, Dong Y. Mapping of Himalaya leucogranites based on ASTER and Sentinel-2A datasets using a hybrid method of metric learning and random forest[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2020, 13: 1925−1936.

Wu S, Liu Y. Interpretable Dual-Channel Convolutional Neural Networks for Lithology Identification Based on Multisource Remote Sensing Data[J]. Remote Sensing, 2025, 17(7): 1314.