

https://doi.org/10.3799/dqkx.2026.061



基于空谱-空间关联双分支的 地球化学找矿异常检测模型

向中林¹, 王路阔¹, 郑贺¹, 张博¹, 刘海睿²

1. 河南理工大学资源环境学院, 河南焦作 454000

2. 新疆维吾尔自治区地质局阿勒泰地质大队, 新疆阿勒泰 836500

摘要: 建立能兼顾多元素地球化学空谱特征、有效拟合数据复杂分布的检测模型, 是识别异常区域的关键。针对新疆东昆仑高海拔深切割浅覆盖地区地球化学找矿异常提取难题, 本研究提出一种空谱特征-空间关联双分支模型 (Spatial-Spectral Feature and Global Spatial Correlation Network, SSGSNet), 空谱特征分支基于 ResNet 残差块, 融入双重注意力模块提取局部空谱特征; 空间关联分支通过 patch 嵌入和自注意力机制挖掘全局空间关联特征。融入构造数据提高了地球化学综合异常找矿的准度, SHAP 值也解释了模型中断裂的关键作用。实验结果表明, SSGSNet 模型的 AUC 值达 0.945 3, 显著优于 ResNet、ViT 单模型和普通的空谱双分支模型。野外查证显示, 遥西、巴什干克等 4 处高异常区均发现不同程度金矿化现象, 证实该模型可有效解决复杂背景下地球化学异常信息提取难题, 为覆盖区矿产勘探提供了可靠的技术支撑与靶区指导。

关键词: 地球化学异常; 双分支网络模型; 深度学习; 空谱特征-空间关联; 东昆仑; 大数据。

中图分类号: P612

文章编号: 1000-2383(2026)03-1078-15

收稿日期: 2025-12-25

A Dual-Branch Geochemical Prospecting Anomaly Detection Model with Spectral-Spatial and Spatial Correlation Fusion

Xiang Zhonglin¹, Wang Lukuo¹, Zheng He¹, Zhang Bo¹, Liu Hairui²

1. School of Resources and Environment, Henan Polytechnic University, Jiaozuo 454000, China

2. Altay Geological Team, Geological Bureau of Xinjiang Uygur Autonomous Region, Altay 836500, China

Abstract: Establishing a detection model that can take into account the multi-element geochemical spatial-spectral characteristics and effectively fit the complex distribution of data is the key to identification of abnormal areas. In response to the challenge of extracting geochemical prospecting anomalies in the high-altitude, deep-cutting, and shallow-coverage areas of the Eastern Kunlun Mountains in Xinjiang, this study proposes a Spatial-Spectral Feature and Global Spatial Correlation Network (SSGSNet). Based on ResNet residual blocks, the spatial-spectral feature branch is integrates a dual-attention module to extract local spatial-spectral features, with the spatial correlation branch using patch embedding and self-attention mechanisms to mine global spatial correlation features. Incorporating tectonic data improves the accuracy of geochemical prospecting, and SHAP values explain the critical role of faults within the model. Experimental results show that the AUC value of the SSGSNet model reaches 0.945 3, significantly

基金项目: 深地国家科技重大专项 (No. 2024ZD1001800); 新疆维吾尔自治区重点研发计划项目 (No. 2023B03016)。

作者简介: 向中林 (1976-), 男, 副教授, 博士, 主要从事综合信息成矿预测、人工智能找矿研究。ORCID: 0009-0005-8726-810X. E-mail: xiangzhonglin@hpu.edu.cn

引用格式: 向中林, 王路阔, 郑贺, 张博, 刘海睿, 2026. 基于空谱-空间关联双分支的地球化学找矿异常检测模型. 地球科学, 51(3): 1078-1092.

Citation: Xiang Zhonglin, Wang Lukuo, Zheng He, Zhang Bo, Liu Hairui, 2026. A Dual-Branch Geochemical Prospecting Anomaly Detection Model with Spectral-Spatial and Spatial Correlation Fusion. *Earth Science*, 51(3): 1078-1092.

outperforming the ResNet and ViT single models as well as the conventional spatial-spectral dual-branch model. Field verification shows that gold mineralization phenomena of varying degrees were found in four high-anomaly areas, including Yaoxi and Bashiganike, which confirms that the model can effectively solve the problem of extracting complex background geochemical anomaly information, providing reliable technical support and target area guidance for mineral exploration in covered areas.

Key words: geochemical anomaly; dual-branch network model; deep learning; spatial-spectral features and spatial correlation; eastern Kunlun mountains; big data.

0 引言

地球化学异常识别在矿产勘查中起着非常重要的作用,其目的是指示矿化的存在(Zuo *et al.*, 2016, 2019; Zuo and Xu, 2024).近年来,地球化学异常检测方法得到了广泛的研究,由于地球化学数据蕴含着空间分布和元素组合的双重信息,因此大多数方法被分为基于谱系与基于空间两类:前者以多元统计分析(Harris, 2001; Wang *et al.*, 2017)、探索性数据分析(Reimann *et al.*, 2008; Yousefi *et al.*, 2014; Xiong *et al.*, 2018; Yin *et al.*, 2021)为代表,主要研究元素浓度的频率分布和变量之间的关系,但往往忽略了矿化作用的空间模式;后者如多重分形模型(Cheng *et al.*, 1994, 2000; Cheng and Agterberg, 1996; Zuo *et al.*, 2015; Chen and Cheng, 2018),虽然关注单种元素的空间分布规律,但对多源数据的融合能力有限,且过度依赖人工特征工程,易因主观经验偏差丢失关键成矿信息.

深度学习技术的兴起,为上述局限提供了前沿解决方案.早期地球化学异常检测的深度学习模型多为单分支设计,在空间特征提取与谱系关系建模两大维度实现特征提取的自动化与预测精度的突破,推动找矿预测向端到端的智能化发展.在空间维度,卷积神经网络(Convolutional Neural Network, CNN)(刘艳鹏等, 2020; Zhang and Zuo, 2021; 李忠潭等, 2022)、卷积自编码器(Masci *et al.*, 2011; Xiong and Zuo, 2022),以及图神经网络(Xu *et al.*, 2023; Zuo and Xu, 2023; Xu and Zuo, 2024)凭借层级化特征学习能力成为主流;在谱系维度,循环神经网络(Wang *et al.*, 2024)、自编码器(Zuo *et al.*, 2019; 左仁广, 2019; Luo *et al.*, 2020; Luo and Zuo, 2025)、一维卷积(1DCNN)(Zuo and Xu, 2024)等模型则侧重研究地球化学谱系来区分与矿化相关的地球化学异常.近年来,整合“空间-谱系”的双分支架构已成为主流,能充分挖掘多维度信息,如 Yang *et al.* (2017) 提出 1DCNN+

2DCNN 双分支模型为多类型地质特征整合提供了技术范式;Ding *et al.*(2023)基于 CNN2D-SENet 模型捕捉西藏朱诺铜矿的构造-蚀变空间关联,实现高精度靶区预测;Zuo and Xu(2024)提出了一种由一维卷积神经网络(1DCNN)和图卷积网络(GCN)两种深度学习算法组成的混合架构,实验表明该混合深度学习模型在提取地球化学数据的空间-光谱特征方面表现更好;Xu *et al.*(2024)提出了一种用于识别地球化学异常的无监督空-谱自编码器,它由一个图卷积自编码器(GCN-AE)和一个长短期记忆网络自编码器(LSTM-AE)组成.有效解决了传统方法仅单一提取空间或光谱特征、无监督模型的可解释性与精度不足问题.

但现有双分支模型大多依赖局部感受野提取特征,将成矿控制因素融入地球化学异常识别模型中,能够生成更加符合地质事实的一致性结果(Xiong *et al.*, 2022; 左仁广等, 2024).成矿地质过程中,地球化学元素的浓度分布往往受断裂构造直接控制,常表现出沿断裂带走向的定向延伸、跨不同构造单元的协同变化等特征;同时断裂作为矿化流体运移与富集的关键通道,其空间连续性不仅决定异常区的全局连通性,更主导了异常沿断裂带的串珠状分布、环状等圈层式展布.这类元素组合与构造格局的耦合信息,具有显著的长程空间关联性.为解决当前研究中存在的局部特征主导而全局关联缺失的问题,目前主流的 Transformer 架构模型自注意力机制为其提供了新路径(Yu *et al.*, 2024).基于此,本文针对双分支网络空谱分支局部特征提取的局限性,提出一种融合 CNN 与 Transformer 的双分支架构:空谱分支基于改进的残差结构,结合 CNN、SE 模块和空间注意力机制,增强对局部边界、元素组合等精细特征的提取能力;空间关联分支基于 Transformer 模块构建全局空间关联,双分支可实现局部细节与全局空间依赖关

系的特征互补.研究旨在通过该架构提升高海拔、深切割、浅覆盖环境下新疆东昆仑地区地球化学的异常识别精度,为找矿预测提供兼具局部提取能力与全局关联捕捉能力的技术方法.

1 方法

1.1 空谱特征-空间关联双分支模型

本文提出了一种基于双分支结构的空谱特征-空间关联双分支(Spatial-Spectral Feature and Global Spatial Correlation Network, SSGSNet)模型,模型整体架构如图 1 所示,主要由空谱特征分支、空间关联分支、特征融合模块和分类器组成.

1.1.1 空谱特征分支 CNN 在二维平面数据处理中展现出了独特的优势,其通过卷积层和池化层交替的结构,模拟人脑视觉系统的工作机制.在地球化学数据处理场景下,地球化学数据常以二维平面形式呈现,CNN 能利用卷积核在二维平面上滑动进行卷积操作,提取地球化学数据中的局部空间特征与细节,同时池化层依据图像局部相关性原理对数据进行邻域采样,减少数据量的同时保留关键信息,且通过参数减少和权值共享改善了系统训练时间长的问题.

然而,原始 ResNet 在地球化学异常识别任务中存在明显局限,其残差块仅通过堆叠卷积层实现特征传递,未显示建模通道维度与空间维度的特征重要性——地球化学数据中,不同通道对应

不同元素的含量信息,部分元素对异常识别贡献更高,不同空间位置的元素分布关联性(如矿化异常区的空间聚集)也存在显著差异,原始 ResNet 难以针对性强化谱系特征信息.为解决这一问题,本文在 ResNet 残差块基础上,引入通道-空间双注意力机制(即通道注意力模块与空间注意力模块),构建改进型残差块,专门用于提取地球化学数据的高判别性空间特征,强化异常区域的空谱特征响应,提升识别精度与可靠性.具体设计如下:

(1) 通道注意力模块(Channel Attention, CA).通道注意力模块基于挤压-激励(Squeeze-and-Excitation, SE)机制设计(图 2),通过对特征通道的全局信息建模,自适应分配通道权重——在地球化学数据中,该模块可突出对异常识别贡献显著并与矿化相关的指示元素通道,抑制冗余通道的干扰.其实现过程分为“挤压(Squeeze)”、“激励(Excitation)”和“重校准(Scale)”三步,具体流程及参数见表 1.

挤压操作通过全局平均池化(Global Average Pooling, GAP),将每个通道的二维特征图(空间维度为 $H \times W$)压缩为 1 个标量,实现空间维度信息的聚合,突出通道的全局统计特征.对于输入特征图 $U \in R^{C \times H \times W}$ (C 为通道数,对应地球化学数据的元素种类),第 c 个通道的挤压结果 z_c 可表示为:

$$z_c = F_{sq}(u_c) = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W u_c(i, j), \quad (1)$$

其中, u_c 为输入特征图的第 c 个通道, F_{sq} 表示挤压操

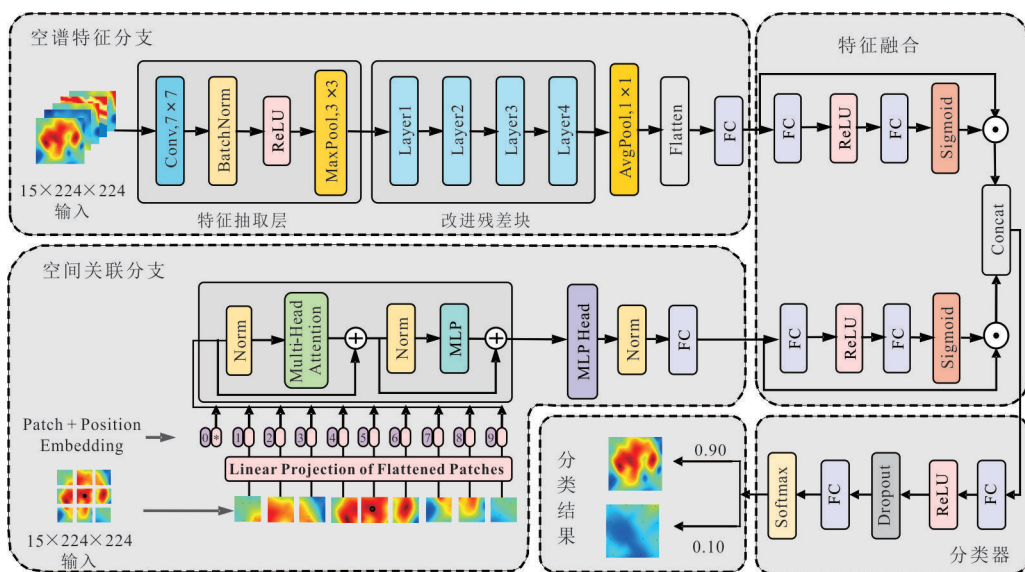


图 1 双分支模型结构

Fig.1 Structure of the two-branch model




图 2 挤压-激励模块示意(据 Hu, 2018)

Fig.2 Schematic diagram of the squeeze-and-excitation module(after Hu, 2018)

作, i, j 分别为空间维度的行、列索引, $H \times W$ 表示空间域的大小。

激励操作通过两级全连接层构建通道间的非线性依赖关系, 学习各通道的重要性权重, 如公式 (2) 所示:

$$S = F_{ex}(z, W) = \sigma(g(z, W)) = \sigma(W_2 \delta(W_1 z)), (2)$$

其中, F_{ex} 表示激励操作, $W_1 \in R^{\frac{C}{r} \times C}$ 为降维全连接层参数, $W_2 \in R^{C \times \frac{C}{r}}$ 为升维全连接层参数, C 代表输入特征的通道数, R 表示实数域, r 为降维系数, δ 为 ReLU 激活函数, σ 为 Sigmoid 激活函数。两级全连接层的设计(本质可视为 1×1 卷积), 既通过降维简化计算, 又通过非线性变换精准拟合通道间的复杂依赖关系, 该模块可学习到“元素 A 与元素 B 协同出现时指示矿化异常”的关联特征, 并为这两个元素通道分配更高权重。

最后, 进行重新校准。将激励操作得到的通道权重与原始输入特征图进行通道级逐元素乘法, 实现对重要通道的强化与冗余通道的抑制。对于第 c 个通道的特征 u_c , 重校准后的输出 \tilde{x}_c 可表示为:

$$\tilde{x}_c = F_{scale}(u_c, s_c) = s_c \cdot u_c, (3)$$

其中, F_{scale} 表示重校准操作, s_c 为第 c 个通道的权重, $\tilde{x}_c \in R^{H \times W}$ 为校准后的通道特征图。最终, 所有通道的校准特征图拼接形成 $X = [\tilde{x}_1, \tilde{x}_1, \dots, \tilde{x}_C] \in R^{C \times H \times W}$, 其作为通道注意力模块的输出, 被传递至后续空间注意力模块。

(2) 空间注意力模块(Spatial Attention, SA)。空间注意力模块通过构建空间位置间的关联, 突出地球化学数据中异常区域的空间位置, 抑制背景区域的干扰。其核心思路是先通过全局池化提取空间维度的统计特征, 再通过卷积层学习空间注意力权重, 具体实现步骤如下:

首先, 进行空间特征压缩。对于通道注意力模块输出的特征图 $X \in R^{C \times H \times W}$, 沿通道维度分别进行全局平均池化与全局最大池化, 得到两个 1 通道的空间特征图, 维度均为 $1 \times H \times W$, 全局平均池化是

聚合每个空间位置的通道平均响应, 突出空间区域的整体特征, 表达式为:

$$A_{avg} = \frac{1}{C} \sum_{c=1}^C \tilde{x}_c. (4)$$

全局最大池化是提取每个空间位置的通道最大响应, 突出空间区域的局部极值特征, 表达式为:

$$A_{max} = \max_{c=1 \rightarrow \{c\}}. (5)$$

随后将两个 1 通道特征图沿通道维度拼接, 得到 2 通道的空间特征融合图 $A_{cat} \in R^{C \times H \times W}$, 该操作通过融合“平均响应”与“最大响应”, 全面捕捉空间维度的重要信息, 避免单一池化方式导致的特征丢失。

然后进行空间权重学习, 对拼接后的特征图 A_{cat} 采用 7×7 卷积层进行卷积操作, 将通道数压缩至 1; 再通过 Sigmoid 激活函数将空间权重归一化至 $[0, 1]$ 区间, 得到空间注意力权重图 $M_s \in R^{1 \times H \times W}$ 。其中, 7×7 卷积核的选择优于 3×3 卷积核, 可扩大感受野, 更充分地捕捉地球化学数据中异常区域的空间关联性。

最后进行空间特征重校准。将空间注意力权重图 M_s 与通道注意力模块的输出 X 进行空间级逐元素乘法, 实现对空间位置的权重赋值。权重高的异常区域特征被强化, 权重低的背景区域特征被抑制。最终输出重校准后的特征图 $X_s = M_s \cdot X \in R^{C \times H \times W}$, 作为双注意力模块的整体输出, 其流程及具体参数见表 1。

(3) 改进型残差块(Improved Residual Block)。改进型残差块以“卷积特征提取+双注意力增强+残差连接”为核心架构, 既保留原始 ResNet 的梯度传递优势, 又通过双注意力模块提升特征判别性, 可在提取地球化学数据局部空间特征的同时, 通过双注意力模块从“通道”与“空间”两个维度强化异常相关特征, 为后续特征融合提供高判别性的空间特征基础。具体结构如表 1 所示。

1.1.2 空间关联分支 空间关联分支采用主流的 ViT (Vision Transformer) 架构 (Dosovitskiy et al., 2020), 其目的在于突破卷积网络局部感受野的局限, 通过全局关联建模捕捉地球化学数据中元素分布与断裂构造的长程依赖关系, 与空谱分支的局部精细特征形成互补结构。

该分支的运行逻辑可概括为“空间信息序列化-全局关联深度挖掘-特征聚合输出”, 对应三大组件: Patch 嵌入层承担着将二维空间数据转化为序列

表 1 改进型残差块的结构
Table 1 Structure of the improved residual block

单元	残差块	层	内核大小	步长	输入/输出	填充
Layer1	ResidualBlock1	Conv1+BN+ReLU	3×3	1	64/64	1
		Conv2+BN	3×3	1	64/64	1
		CA			64/64	
		SA			64/64	
		Shortcut(Identity)+ReLU				
	ResidualBlock2	Conv1+BN+ReLU	3×3	1	64/64	1
		Conv2+BN	3×3	1	64/64	1
		CA			64/64	
		SA			64/64	
		Shortcut(Identity)+ReLU				
Layer2	ResidualBlock3	Conv1+BN+ReLU	3×3	2	64/128	1
		Conv2+BN	3×3	1	128/128	1
		CA			128/128	
		SA			128/128	
		Shortcut(Conv3+BN)+ReLU	1×1	2	64/128	
	ResidualBlock4	Conv1+BN+ReLU	3×3	1	64/128	1
		Conv2+BN	3×3	1	128/128	1
		CA			128/128	
		SA			128/128	
		Shortcut(Identity)+ReLU				
Layer3	ResidualBlock5	Conv1+BN+ReLU	3×3	2	128/256	1
		Conv2+BN	3×3	1	256/256	1
		CA			256/256	
		SA			256/256	
		Shortcut(Conv3+BN)+ReLU	1×1	2	128/256	
	ResidualBlock6	Conv1+BN+ReLU	3×3	1	256/256	1
		Conv2+BN	3×3	1	256/256	1
		CA			256/256	
		SA			256/256	
		Shortcut(Identity)+ReLU				
Layer4	ResidualBlock7	Conv1+BN+ReLU	3×3	2	256/512	1
		Conv2+BN	3×3	1	512/512	1
		CA			512/512	
		SA			512/512	
		Shortcut(Conv3+BN)+ReLU	1×1	2	256/512	
	ResidualBlock8	Conv1+BN+ReLU	3×3	1	512/512	1
		Conv2+BN	3×3	1	512/512	1
		CA			512/512	
		SA			512/512	
		Shortcut(Identity)+ReLU				

数据的关键角色,它通过非重叠划分将原始数据拆解为若干空间单元(Patch),既保留每个单元内的局部元素组合信息,又通过卷积映射将高维空间特征压缩为固定维度的嵌入向量;同时,为嵌入序列叠加可学习的位置编码,以维持原始数据的空间拓扑

关系——这一步确保了后续关联分析中“空间位置”这一关键要素的有效性;Transformer编码器是全局关联建模的核心,由多个堆叠的Transformer块构成,每个块通过“多头自注意力(Multi-Head Self-Attention, MSA)-层归一化-多层感知机

(Multilayer Perceptron, MLP)-层归一化”的残差结构,实现对序列中任意空间单元的关联强度计算与动态聚合.其中,MSA机制通过线性投影将输入 X 转换为查询(Q)、键(K)和值(V),再拆分为多个并行的头,每个头独立计算注意力权重,基于缩放点积注意力公式为:

$$\text{Attention}(Q, K, V) = \text{Softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V, \quad (6)$$

其中, d_k 为头维度, $\sqrt{d_k}$ 用于缓解维度过高导致的权重值过大问题,Softmax函数将权重归一化至 $[0, 1]$ 区间,确保权重总和为1.

量化不同空间单元的关联权重,并通过多组并行注意力头捕捉多样化的关联模式,如元素异常沿断裂带的定向延伸、跨区域元素组合的协同变化等.经多层迭代后,序列中的关联信息被逐步深化,最终由[CLS]令牌聚合为包含全局特征关系的向量.特征输出层则将[CLS]令牌的高维向量压缩至适配后续融合模块的维度,完成从全局关联信息到特征向量的转化.该分支通过VIT的全局建模能力,将地质学家对“构造控矿”、“元素空间耦合”的经验性认知转化为可量化的特征关联,为双分支模型提供了关键的全局空间关联支撑.

1.1.3 双分支融合模块 融合模块如图1所示,输入数据首先分别进入空谱特征分支和空间关联分支,然后将两个分支输出的特征送入特征融合模块,最终由融合模块输出分类结果.特征融合模块的数学表示如下:

$$a_{ss} = \sigma(W_{ss2} \cdot \text{Relu}(W_{ss1} \cdot f_{ss})), \quad (7)$$

$$a_{sc} = \sigma(W_{sc2} \cdot \text{Relu}(W_{sc1} \cdot f_{sc})), \quad (8)$$

其中, a_{ss} 表示空谱分支特征注意力权重, a_{sc} 表示空间关联特征注意力权重, f_{ss} 表示空谱特征分支提取的原始特征, f_{sc} 表示空间关联分支提取的原始特征. $W_{ss1} \in R^{256 \times 32}$ 、 $W_{ss2} \in R^{32 \times 256}$ 表示空谱分支注意力模块的学习参数(权重矩阵), W_{ss1} 用于对空谱特征 f_{ss} 进行第一次线性变换, W_{ss2} 用于对ReLU激活后的特征进行第二次线性变换; $W_{sc1} \in R^{256 \times 32}$ 、 $W_{sc2} \in R^{32 \times 256}$ 表示空间关联分支注意力模块的学习参数(权重矩阵), W_{sc1} 用于对空间全局特征 f_{sc} 进行第一次线性变换, W_{sc2} 用于对ReLU激活后的特征进行第二次线性变换, σ 为Sigmoid函数.

$$\tilde{f}_{ss} = f_{ss} \times a_{ss}, \quad (9)$$

$$\tilde{f}_{sc} = f_{sc} \times a_{sc}, \quad (10)$$

$$f_{\text{fused}} = [\tilde{f}_{ss}; \tilde{f}_{sc}] \in R^{512}, \quad (11)$$

其中, \tilde{f}_{ss} 表示加权后的空谱特征, \tilde{f}_{sc} 表示加权后的空间全局特征, f_{fused} 表示最终融合的特征.

通过这种融合方式,模型能够同时利用地球化学数据元素间光谱关联特征和空间分布特征,从而更有效地识别异常结果.

2 研究区概况及数据

2.1 研究区概况

研究区位于新疆东昆仑增生型碰撞造山带(图3),以高海拔、深切割和浅覆盖的独特地貌为显著特征,地处泛华夏古陆块群南侧与古特提斯主洋盆北部陆缘系统的关键位置,地质构造演化与成矿作用受特提斯洋和泛华夏古陆(地)块群相互作用控制(于小亮,2025),且构造格局被阿尔金断裂、勒什尔-阿其克库勒-恰孜断裂(昆中断裂带)、布喀达坂-鲸鱼湖-木孜塔格断裂(康西瓦-木孜塔格结合带)三条深大断裂主导.研究区内重要的控矿构造是区域性断裂的次级北东向和北东东向断裂,其控制了研究区内蚀变带的展布.更低序次的构造形成层间破碎带和密集裂隙带,为金成矿提供了良好的场所,是重要的容矿、储矿构造.

研究区内已发现屈库勒克东金锑矿床与巴什干克金矿床两个大型金矿床,其成因类型均属中-

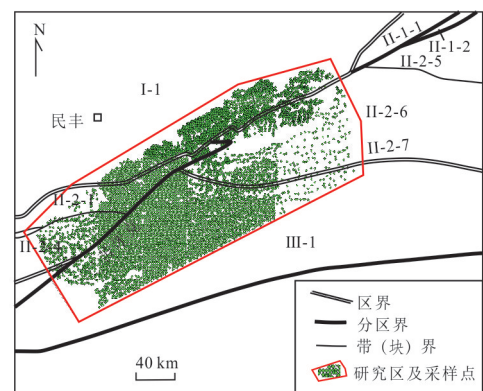


图3 研究区构造单元划分及采样点分布

Fig.3 Tectonic unit subdivision and sampling site distribution of the study area

底图据郭利(2020);大地构造单元划分:I-1.塔里木陆块;II-1.阿尔金弧盆系;II-1-1.阿中地块;II-1-2.阿南蛇绿构造混杂岩;II-2-1.西昆仑北带;II-2-2.库地-其曼于特蛇绿混杂岩带;II-2-4.西昆仑南带;II-2-5.东昆仑柴南(祁曼塔格弧后)弧盆系;II-2-6.东昆仑南带;II-2-7.康西瓦-木孜塔格结合带;III-1.巴颜喀拉地块

低温岩浆热液脉型,成矿时代集中于晚三叠世(208~202 Ma),与区域碰撞-碰撞后伸展背景下的中酸性岩浆活动密切相关.屈库勒克东金锑矿床位于阿尔金大断裂东南侧,受其次级近EW向与NE向断裂控制.矿体主要赋存于上石炭统哈拉米山河群碳质粉砂岩、砂岩及晚三叠世闪长玢岩中.矿石矿物组合以黄铁矿、毒砂、辉锑矿为主,可见少量黄铜矿、方铅矿、白钨矿等,金主要以自然金形式产出.围岩蚀变发育硅化、绢云母化、黄铁矿化、绿泥石化及碳酸盐化(邢令,2023).巴什干克金矿床距屈库勒克东金锑矿西南约140 km,矿体主要赋存于奥陶系祁漫塔格群白云岩、灰岩及玄武岩中,少量产于晚三叠世斜长花岗斑岩及花岗细晶岩内.矿化受NE向韧性剪切带控制.矿石矿物以黄铁矿、毒砂、辉锑矿为主,含少量自然金、黄铜矿、磁黄铁矿等.围岩蚀变以硅化、黄铁绢英岩化、绿泥石化、碳酸盐化为特征.上述典型矿床在成因类型、成矿时代、控矿构造和蚀变矿化组合上具有高度一致性,为本研究构建地球化学异常识别模型提供了统一且可靠的地质框架.

2.2 金(锑)矿床找矿预测模型

基于区内屈库勒克东和巴什干克等典型金矿床地质特征(表2),总结区域综合信息找矿预测模型如下:

(1)构造控矿:矿体受NE向、近EW向断裂及其次级裂隙控制,断裂交汇处、转折部位为成矿有利部位.

(2)岩浆岩条件:晚三叠世中酸性侵入岩(如花岗闪长岩、闪长玢岩)发育,岩体接触带及内外蚀变带是找矿重点区域.

(3)蚀变组合:硅化、黄铁绢英岩化、绿泥石化、碳酸盐化等热液蚀变发育.

(4)地球化学标志: Au-As-Sb-Hg-Cu-Pb-Zn 元素组合异常,其中 Au、As、Sb 为直接指示元素.

(5)矿物组合:黄铁矿、毒砂、辉锑矿等硫化物普遍发育,见自然金.

该勘查模型为本研究小样本增强提供了地质约束,也为深度学习模型的特征选择、样本构建与结果解释提供了依据.

表 2 典型金(锑)矿床主要地质特征

Table 2 Main geological characteristics of typical gold (antimony) deposits

地质特征	屈库勒克东	巴什干克
赋矿地层	上石炭统哈拉米山河群上亚群(C_2H^2)为主要的含矿地层,赋矿岩性主要有粉砂岩、砂岩、断层破碎蚀变岩、灰岩、闪长玢岩及石英脉等.	下奥陶统库拉甫河岩组第三段(O_1K^3)地层的灰岩、白云岩、玄武岩、安山岩等岩石及其碎裂岩、构造角砾岩中.
控矿构造	矿体分布主要受近EW向F2断裂控制,在挤压揉皱构造作用较发育地段,一般Au、Sb含量较高.	F1、F2(阿尔金南缘断裂衍生次级断裂)控制赋金的韧-脆性剪切带分布,韧-脆性剪切带中的次级构造破碎蚀变带控制着主矿体的空间位置.
岩体岩脉	主要为中酸性脉岩,包括闪长玢岩脉、石英脉、石英方解石脉.闪长玢岩脉呈细-大脉状、透镜状产出,碎裂岩化较强.	基性-中酸性岩体均有出露,金矿(化)主要分布于闪长玢岩和花岗闪长岩岩体边缘及其周围的地层中.
围岩蚀变	断层破碎带、硅化、褐铁矿化、黄钾铁矾化、黄铁矿化是寻找矿(化)体的重要标志,而辉锑矿化、锑华是寻找金锑的直接标志.	蚀变类型主要以黄铁矿化、毒砂化、硅化、碳酸盐化、绢云母化为主,在石英脉、碳酸盐脉充填贯入的部位,矿体含金品位高.
矿体特征	近EW向展布,产状总体为 $340^\circ\sim 15^\circ\angle 53^\circ\sim 75^\circ$.矿体形态较规则,呈似层状、脉状,局部具有分支复合现象.矿石主要金属矿物为辉锑矿、自然金、黄铁矿,氧化矿物有锑华、褐铁矿、孔雀石等.平均品位Au为 7.68×10^{-6} 、Sb为3.05%.金资源量为18 023.32 kg,锑资源量为71 685.82 t.	总体走向为NE-SW向,倾向NW,平均倾角 $45^\circ\sim 75^\circ$.空间上呈叠瓦式或雁列式排列展布,多呈脉状、似层状,少量呈透镜状产出.载金矿物主要为黄铁矿、毒砂、辉锑矿、钛铁矿、赤(褐铁矿)等.平均品位 3.9×10^{-6} ,金资源量70.78 t.
地球化学特征	1:5万水系沉积物测量圈定异常元素组合为Au、Sb、As、Pb元素,主成矿元素为Au、Sb.钻孔原生晕显示各指示元素的分带序列从上到下依次为As-Sb-Pb-Zn-Au-Ag-W.	Cu、Au以及部分Zn、Pb、Ag的高背景异常区,可作为形成Cu-Au(多金属)矿床的矿源层,地化剖面显示Au与As、Sb、Hg等元素套合较好.

2.3 数据处理

本研究采用水系沉积物测量数据以及主要控制矿床分布的线性构造作为模型的特征输入.系统收集了研究区1:25万水系沉积物地球化学数据,共计7326个有效采样点.每个采样点包含32种主量及微量元素含量,为降低维度,同时增强特征可解释性,本研究通过描述性统计、皮尔逊相关系数分析、主成分分析法,选择了14种金矿指示元素(Au、As、Sb、Hg、Cu、Pb、Zn、Bi、Sn、Mo、W、Co、Li、Ag)(表3).为适配深度学习模型对规则网格数据的输入要求,采用反距离权重法(Inverse Distance Weighting, IDW)进行空间插值处理,生成100 m×100 m分辨率的元素浓度栅格图.对断裂、剪切带等数据执行500~3000 m共6个等级的多环缓冲区,旨在模拟构造对其周边地质体的影响力.对生成的缓冲区进行重分类操作,量化构造的影响程度.最终生成15个能清晰反映地球化学浓度和构造控矿影响范围的栅格特征图层(图4).

2.4 正负样本点划分

本研究以已知矿点(屈库勒克区域11个已知矿点)作为正样本,负样本筛选则以金(Au)元素的K-means非监督分类结果为核心依据.Au元素浓度分布图主要以元素浓度为核心分级,常忽视空间分布的均衡性,导致不同浓度等级的分布面积差异极大.相比之下,K-means非监督分类方法基于数据自身的统计特性完成自动聚类,可真实还原Au元素的空间分布格局,且在实现自动聚类时,可同时兼顾数据自身的统计特征与空间分布的均衡性,使各聚类区域的空间面积保持相对平

衡,能显著提高负样本筛选的可靠性和合理性.结合聚类分析结果(图5)可见:已知金矿点主要集中分布于聚类4与聚类5对应的区域,据此将聚类1、聚类2、聚类3锁定为负样本选取的核心区域.为进一步提升筛选精度,考虑研究区构造控矿空间分布特征,优先选取远离断裂带及已知金矿点的区域,选择了11个无矿点作为负样本点.

通过上述条件的综合约束,既发挥地质规律对样本筛选的约束作用,又借助算法的量化分析规避人为主观偏差,为深度学习模型提供高质量的负向训练样本,进而保障模型训练的稳定性与预测的准确性.

2.5 训练数据集样本构建

在矿产资源预测研究中,研究区已知矿点数量往往较少,而样本数量不足会直接制约深度学习模型的训练效果,导致模型泛化能力减弱.为充分利用已知矿点的空间信息并构建结构化样本,本研究采用滑动窗口法进行基础数据集的构建.该方法原理是设定固定尺寸的滑动窗口(窗口大小为 $k \times k$ 个网格单元),结合研究区网格化处理结果,使窗口在研究区范围内按预设步长滑动,将窗口覆盖区域作为一个独立样本单元.

本研究中,综合考虑研究区网格分辨率与成矿信息的空间关联性,最终确定滑动窗口大小为 32×32 网格单元.若研究区内共有 n 个已知矿床(点),则以每个已知矿床(点)为核心,选取包含该矿床(点)的滑动窗口作为“含矿样本单元”,并标记为正样本;负样本的构建逻辑与正样本一致,选取负样本为核心的滑动窗口,标记为“不含矿样本单元”.同时

表3 筛选的水系沉积物地球化学元素及依据

Table 3 Geochemical elements of water system sediments screened and their basis

单元素	地质意义	统计支持
Au	目标矿种,高偏度/峰度指示局部富集,成矿因子核心元素	描述性统计、PC3
Sb	目标矿种,与Au共生,成矿因子核心元素,高偏度反映断裂控矿特征	描述性统计、PC3、相关系数
Hg	热液前缘晕指示元素,高峰值反映深部矿体挥发性组分迁移,与Au、Sb正相关	描述性统计、地质类比
Bi、Mo、Sn	热液型矿床伴生元素,高偏度指示隐伏岩体接触带	描述性统计、PC3
W、Co	高熔点热液元素,常见于花岗岩相关热液矿床(如钨金共生),Co与基性岩背景相关	PC3、地质类比
Zn	中低温热液元素,可能指示多金属硫化物阶段	PC3、相关系数
As	低温热液标型元素,与Sb密切相关(如辉铋矿-毒砂组合)	PC3、聚类分析
Pb、Cu	多金属硫化物组合成员,反映热液成矿多阶段特征	PC3、相关系数
Li	隐伏花岗岩体接触带,热液蚀变	PC3
Ag	亲硫性元素,在热液活动中易于富集	聚类分析

注:PC3为PCA分析中第3因子,体现主要成矿元素.




图 4 多元素地球化学浓度分布(a~n)和断裂影响域(o)

Fig.4 Multi-element geochemical concentration distribution (a~n) and fracture influence zones(o)

通过复制、旋转、添加随机噪点等数据增强方法(图 6),最终获得研究区已知样本 5 632 个,包含 2 816 个负样本和 2 816 个正样本.同时划分研究区内 7 490 个未知样本,用于后续模型预测.为确保模型训练的科学性,采用随机划分的方式,选取正样本与负样本总数的 20% 作为验证集,用于监控模型训练过程中的拟合程度与泛化能力;其余 80% 的正、负样本作为训练集,用于模型参数的学习与优化,以保障模型在训练过程中能够稳定收敛至最优状态.

3 结果与分析

3.1 双分支模型异常识别

3.1.1 预测结果 模型训练依托百度飞桨(Paddle-Paddle)提供的在线工作平台开展,核心参数设置如下:批次大小(batch_size)设为 32,优化器选用 Adam,通过配置 0.9 的动量(Momentum)参数更新卷积神经网络的权重与偏差;学习率动态调整范围设定为 1×10^{-5} (最大)至 1×10^{-6} (最小).针对地球化

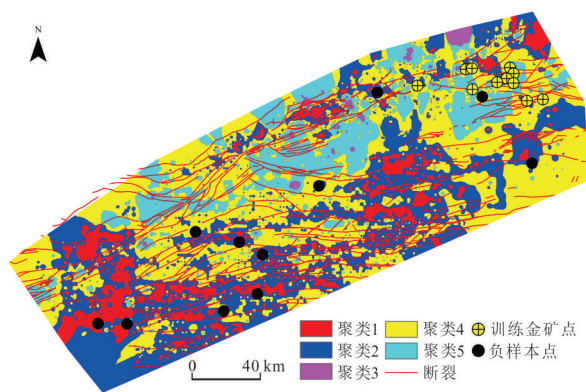


图 5 Au 元素 K-means 聚类及正负样本分布

Fig.5 K-means clustering of Au elements and distribution of positive and negative samples

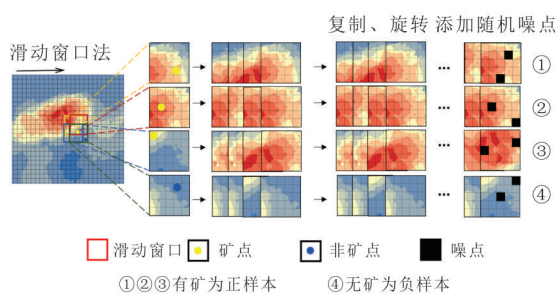


图 6 数据集构建

Fig.6 Dataset construction

学异常检测这一二分类任务,本研究选取交叉熵损失函数(CrossEntropy Loss)作为模型优化目标。

模型经 50 轮迭代训练后,在训练集与验证集上的性能均实现最优收敛,表明模型经充分学习已得到研究区的控矿地质特征及成矿信息关联模式。将独立测试集数据输入训练完成的 SSGSNet 模型,依据输出的成矿概率值对研究区成矿异常区域进行分级圈定,即根据 SoftMax 计算结果,剔除背景无效值,依据直方图分布(一般呈正态分布或对数正态分布的单峰),选择峰值(相当于处理后单峰正态分布的均值)到极值进行等间距分割,结合已知矿点进行适当微调确定分级阈值,最终构建出三级成矿潜力区的空间分布格局(图 7a)。具体分级标准为:成矿概率处于 0.95~0.99 区间的区域标注为深红色,对应成矿潜力等级 A 类(重点成矿远景区);概率处于 0.90~0.95 区间的区域标注为红色,对应等级 B 类(次重点成矿远景区);概率处于 0.85~0.90 区间的区域标注为浅粉色,对应等级 C 类(一般成矿潜力区)。

圈定的高异常区域在空间分布上与已知金矿

存在显著关联性,其多沿已知的屈库勒克-巴什干克金矿的东北向控矿断裂带延伸,在已知矿床周边呈带状或集群分布,且通过图 7a 与图 7b 的结果可以明显看出加入构造断裂数据提取的异常区域具有更强的空间指向性、更高的异常矿床匹配度,且有效抑制了非控矿区域的干扰。从空间展布特征来看,A 类重点成矿远景区呈现显著的“构造控矿”规律——主要沿研究区 NE 向、近 EW 向构造破碎带呈条带状集中分布,且与前人通过地球化学勘查圈定的 Au-As-Sb 元素组合高值区高度重叠。其中,巴什干克、硝尔库勒南、卧龙岗北三处已探明的已知金矿点,完全落于 A 类深红色重点区内。野外查证表明,模型圈定的 A 类异常区中,巴什干克金矿床已探明为特大型岩浆热液脉型金矿,金资源量 70.78 t,平均品位 3.9×10^{-6} ,矿体受 NE 向断裂控制,围岩蚀变以硅化、黄铁绢英岩化、绿泥石化为主,矿石中见黄铁矿、毒砂、辉锑矿及自然金。该实例直接证实了 SSGSNet 模型在高效识别隐伏矿化信息方面的有效性与可靠性。此外,B 类次重点区与 C 类一般潜力区呈现明显的“伴生分布”特征,围绕 A 类重点区呈环带状延展,符合“成矿中心向周边矿化强度递减”的地质规律。

为从野外实践层面验证 SSGSNet 模型预测结果的可靠性,新疆维吾尔自治区地质局区域地质调查中心针对模型圈定的 A 类重点异常区域开展了专项野外地质查证。野外调查结果显示,本次首次圈定的遥西、萨纳拉克、红土滩 3 处异常区域,在野外均发现不同程度的金矿化现象,充分证明 SSGSNet 深度学习模型能够有效挖掘隐蔽性矿化信息,为研究区后续矿产勘查工作提供精准的靶区指导,体现智能找矿优势。

3.1.2 模型可解释性分析 深度学习驱动的找矿预测模型常因可解释性不足而被视为“黑箱”,难以直接揭示预测结果背后的地质成因。为增强模型的可解释性,本研究引入 SHAP 方法,定量评估地球化学元素与构造特征对异常识别的贡献程度。通过 SHAP 蜂群图(图 8)可直观展示各特征在模型决策中的重要性分布。

结果表明,断裂特征的 SHAP 贡献度最高,印证了东昆仑地区“断裂控矿”的地质规律。Au、Hg、As 等元素的 SHAP 值分布离散且明显偏离零轴,说明它们是影响模型预测的关键因子;其中 Au 的高浓度对应正 SHAP 值,是金成矿预测的直接标志,

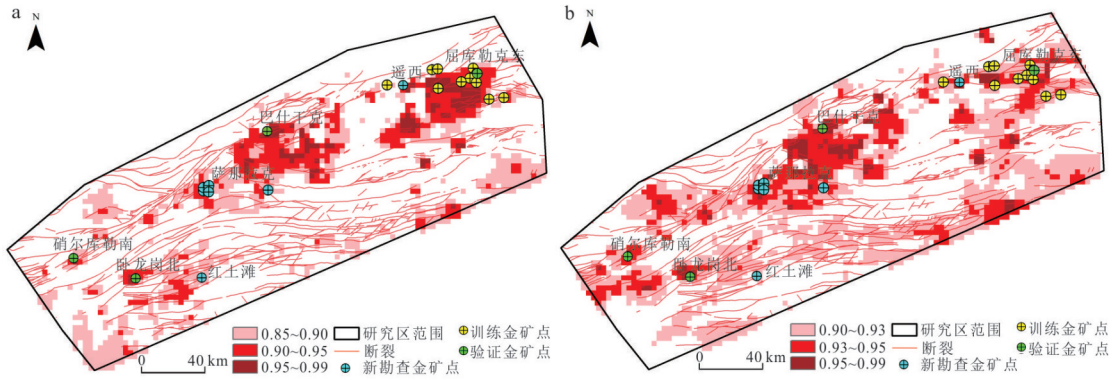


图7 不同特征输入的双分支模型异常识别结果

Fig.7 Anomaly recognition results of the dual-branch model with different feature inputs

a. 化探+构造; b. 化探

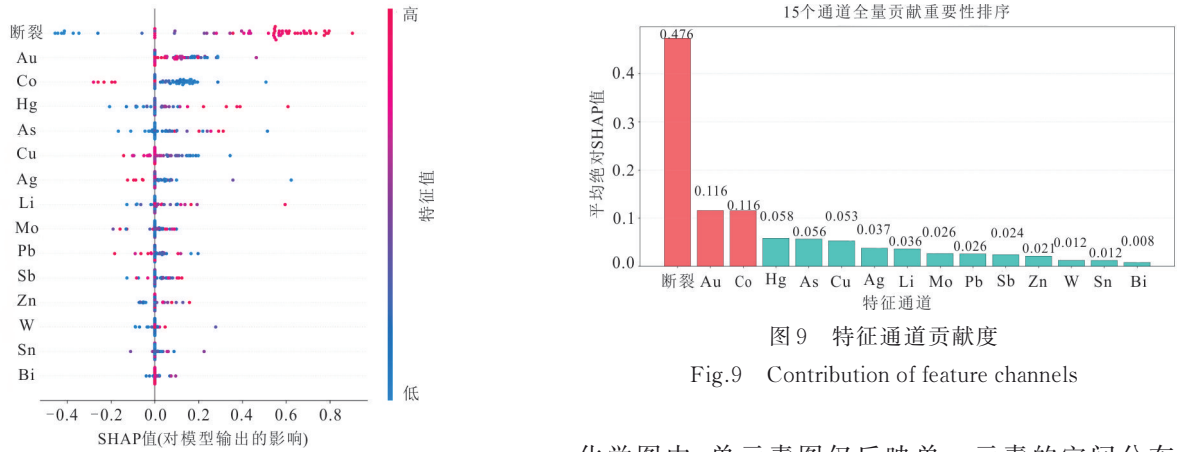


图8 SHAP因子重要性分析

Fig.8 Analysis of the importance of SHAP factors

Hg 与 As 也表现出一定的正向指示作用。相比之下, Bi、Sn、W 等元素的 SHAP 值多聚集在零附近, 对预测结果影响微弱。图 9 进一步对平均贡献量排序验证了上述结论。综合来看, SHAP 分析不仅验证了断裂构造在成矿预测中的主导地位, 也揭示了 Au、As、Hg 等元素组合对金矿的指示意义, Cu、Mo 等元素则可能反映了岩浆热液系统的参与。模型通过空谱分支提取的元素组合信息与空间关联分支捕捉的构造、多元素异常空间展布的全局形态特征, 共同揭示了研究区金矿化受“构造-岩浆-热液”协同控制的成矿机制, 体现了深度学习模型在融合多维信息与增强成因解释方面的潜力。

3.1.3 相较于传统地球化学异常识别的优势
SSGSNet 在地球化学异常检测应用中, 相较于传统的地球化学图(如单元素地化图、组合异常图、衬值异常图等), 在信息融合能力、异常识别精度、可解释性与智能化水平等方面具有显著优势。传统地球

化学图中, 单元素图仅反映单一元素的空间分布, 忽略了元素间共生/伴生关系; 组合异常图(如累加异常指数)通过简单加权或阈值叠加多元素, 缺乏对非线性耦合关系的建模, 同时对空间结构利用不足, 传统成图多为“点→插值→栅格”流程(如反距离加权、克里金), 未显式建模局部空间上下文(如纹理、边缘、邻域梯度); 而 SSGSNet 模型能够深度融合“元素组合”与“空间形态”信息, 同步学习“哪些元素组合异常”+“异常在空间上如何表现”。如图 4 中 Au、As、Bi、Mo、Co、Cu、Sb 和 Zn 等多元素异常呈现出的 NE 向延伸特征, 可实现端到端联合优化; 同时支持多尺度、多源数据融合, 如本文中融合了构造数据, 甚至各源数据可分别输入不同模态, 实现异构信息协同增强。在异常识别精度上, 传统的地球化学图多采用均值±2 倍标准差、分位数等统计方法设定阈值, 假设数据服从正态或对数正态分布, 难以适应复杂地质背景下的多模态分布, 且异常圈定多依赖专家经验调整参数, 可重复性差。如图 4 单元素异常中, 已知矿点没有很好地套合 Au 单元素高值异常, 而本模型通过训练数据自动学习局

图9 特征通道贡献度

Fig.9 Contribution of feature channels

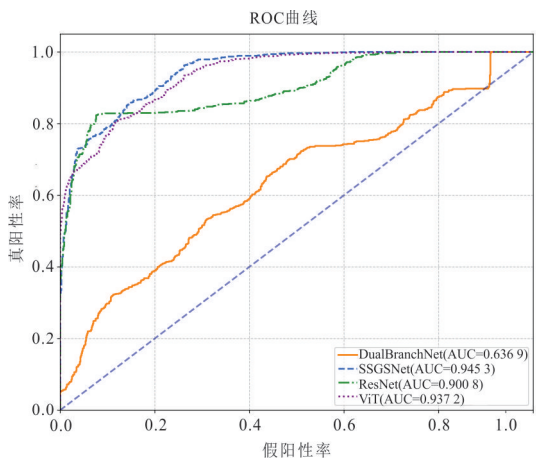


图 10 四种模型 ROC 曲线

Fig.10 ROC curves of the four models

部背景场,无需预设全局统计分布,对于构造复杂区(如造山带、盆地边缘),能识别弱异常、隐伏异常,避免传统方法因“高背景”掩盖矿化信号;同时抗噪能力强、鲁棒性高,空间分支可抑制孤立高值点(采样误差或污染点),光谱分支可过滤不具成矿意义的单元元素峰值.此外本模型能输出可量化、可解释的概率异常图,结合 XAI 技术(如本文的 SHAP),挖掘异常中主要贡献元素或驱动因素,并适应大规模、多区域快速评价需求.空谱-空间关联双分支模型代表了地球化学异常识别从“经验或统计制图”向“智能感知”的范式跃迁,不仅提升了找矿效率与精度,也为数字地质、智慧勘查提供了核心技术支撑.

3.2 不同模型对比试验分析

3.2.1 模型精度对比 为验证本研究提出的 SSGSNet 模型在东昆仑金矿成矿异常识别中的优越性,以 ResNet、ViT、DualBranchNet 三种深度学习模型为参照,使用训练集对四种网络分别进行训练,并使用验证集进行评估,其中 DualBranchNet 为空谱特征融合的简易双分支网络,采用 2 层 2DCNN 结合池化层提取空间特征,同时对 15 通道全局平均池化后,再用 MLP 学习元素组合,获得光谱特征.训练过程中通过 Loss 曲线和精度来评估深度学习算法对找矿信息的学习效果,除 DualBranchNet 不够理想外,其他 3 种模型均表现出良好的收敛趋势,验证了深度学习算法在本任务中的普适性.

为进一步量化评估不同模型对矿床和非矿床进行分类的能力,本研究将 4 种模型在验证集上的成功曲线率与 AUC 值两项关键指标进行性能对比,其中 ResNet、ViT、DualBranchNet、SSGSNet 模

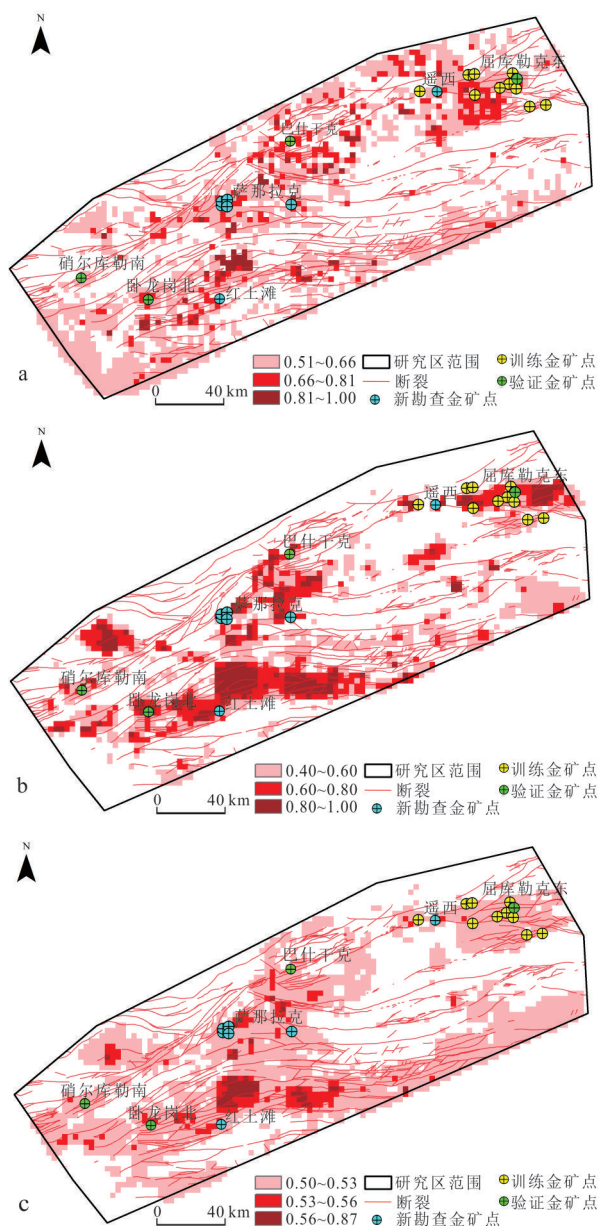


图 11 不同模型异常识别结果对比

Fig.11 Comparison of anomaly recognition results of different models

a. ResNet 结果; b. ViT 结果; c. DualBranchNet 结果

型 AUC 值分别为 0.900 8、0.937 2、0.636 9、0.945 3 (图 10). SSGSNet 曲线下面积最大且 AUC 值最高,表明其综合分类性能最优.结合成功率曲线,说明该双分支模型可以通过同时整合空间-光谱信息以及全局空间关联特征,有效识别潜在矿床,从而提取地球化学模式空间分布的细微变化,整体表现优于其他单模型和普通的空谱双分支模型.

3.2.2 模型预测结果评价 对四种模型的预测结果进行可视化对比与分析(图 11 和图 7a),可以发

现不同模型在异常空间格局的刻画上存在显著差异.可以看出,ResNet模型的预测结果呈现出明显的局部性与“孤岛化”特征,高异常值区域空间不连续,未能有效捕捉成矿系统的整体关联(图 11a).ViT模型的结果在空间上更为连续,反映了NE和EW向异常延伸形态(可能受构造影响),但与已知矿点套合性较差,特别是屈库勒克和巴什干克两个已知大型金矿床没有呈现局部高异常特征(图 11b).DualBranchNet模型的识别结果存在CNN的毛病,异常连续性差,出现“孤岛化”特征(特别是分布范围较小的高值异常区),异常分带不明显,跟已知矿点套合性最差,可能与选择的简易空谱双分支模型有关(图 11c).相比之下,本研究提出的SSGSNet双分支模型取得了最优的预测效果:其圈定的异常区形态精细、空间连续性佳,且与已知断裂构造及矿点展布高度吻合(图 7a).SSGSNet模型能更准确地学习到受构造控制的成矿空间规律,从而输出地质意义更明确、可靠性更高的异常靶区.

4 结论

地球化学数据蕴含了宝贵的光谱与空间信息,本文通过对其与地质构造数据的综合挖掘,显著提升了勘查地球化学数据的解析深度,进而为找矿预测提供了更为可靠的数据支撑.本文提出了一种结合空谱特征-空间关联的双分支结构网络,用于地球化学找矿异常识别.以新疆东昆仑屈库勒克-巴什干克矿集区为例,对双分支模型和与其相关的3种单模型进行了对比研究.结果表明:(1)空谱特征-空间关联双分支模型兼顾了地球化学异常的空谱特征及其受控矿条件约束(这里为构造控制)的全局空间关联,提升了模型的识别精度,更深化了对成矿空间格局的理解;(2)将地质构造等先验知识作为输入特征进行融合学习,结合SHAP值分析,知识和数据混合驱动的深度模型更具有可解释性,其决策过程也更具地质意义;(3)地球化学数据的空间信息(包括局部和全局分布特征)和谱系特征十分重要,全面挖掘地球化学数据内蕴含的空间与谱系信息,将是构建下一代更强大混合模型、获取更多找矿信息的关键,从而更好赋能资源勘查.

致谢:本次野外工作,得到了新疆维吾尔自治区地质局区域地质调查中心韩建华、刘兵、冯红刚、陈威、于洋等,中国地质大学(北京)顾雪祥、章永梅、赵钰、胡运行等,吐鲁番金源矿冶有限责任公司聂俊

杰、朱伟、时浩、马福、余亮、金正斌、石洞等,新疆蓝景能源有限公司杨全宏等的大力支持与帮助,谨此致谢!

References

- Chen, G. X., Cheng, Q. M., 2018. Fractal-Based Wavelet Filter for Separating Geophysical or Geochemical Anomalies from Background. *Mathematical Geosciences*, 50(3): 249–272. <https://doi.org/10.1007/s11004-017-9707-9>
- Cheng, Q. M., Agterberg, F. P., 1996. Multifractal Modeling and Spatial Statistics. *Mathematical Geology*, 28(1): 1–16. <https://doi.org/10.1007/BF02273520>
- Cheng, Q. M., Agterberg, F. P., Ballantyne, S. B., 1994. The Separation of Geochemical Anomalies from Background by Fractal Methods. *Journal of Geochemical Exploration*, 51(2): 109–130. [https://doi.org/10.1016/0375-6742\(94\)90013-2](https://doi.org/10.1016/0375-6742(94)90013-2)
- Cheng, Q. M., Xu, Y. G., Grunsky, E., 2000. Integrated Spatial and Spectrum Method for Geochemical Anomaly Separation. *Natural Resources Research*, 9(1): 43–52. <https://doi.org/10.1023/A:1010109829861>
- Ding, K., Xue, L. F., Ran, X. J., et al., 2023. CNN2D-SENet-Based Prospecting Prediction Method: A Case Study from the Cu Deposits in the Zhunuo Mineral Concentrate Area in Tibet. *Minerals*, 13(6): 730. <https://doi.org/10.3390/min13060730>
- Dosovitskiy, A., Beyer, L., Kolesnikov, A., et al., 2020. An Image Is Worth 16×16 Words: Transformers for Image Recognition at Scale. *arXiv*, 2010.11929. <https://arxiv.org/abs/2010.11929>
- Guo, L., Bai, H., Xing, L., et al., 2020. Metallogenic Regularity and Metallogenic Model of Late Paleozoic Hydrothermal Gold-Antimony Deposits in the Muztag Area, East Kunlun, Xinjiang. *West-China Exploration Engineering*, 32(5): 114–117 (in Chinese with English abstract).
- Harris, R. J., 2001. A Primer of Multivariate Statistics (3rd Edition). Psychology Press, New York. <https://doi.org/10.4324/9781410600455>
- Hu, J., Shen, L., Sun, G., 2018. Squeeze- and -Excitation Networks. 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City. <https://doi.org/10.1109/CVPR.2018.00745>
- Li, Z. T., Xue, L. F., Ran, X. J., et al., 2022. Intelligent Prospect Prediction Method Based on Convolutional Neural Network: A Case Study of Copper Deposits in

- Longshouan Area, Gansu Province. *Journal of Jilin University (Earth Science Edition)*, 52(2): 418–433 (in Chinese with English abstract).
- Liu, Y. P., Zhu, L. X., Zhou, Y. Z., 2020. Experimental Research on Big Data Mining and Intelligent Prediction of Prospecting Target Area—Application of Convolutional Neural Network Model. *Geotectonica et Metallogenia*, 44(2): 192–202 (in Chinese with English abstract).
- Luo, Z. J., Xiong, Y. H., Zuo, R. G., 2020. Recognition of Geochemical Anomalies Using a Deep Variational Auto-encoder Network. *Applied Geochemistry*, 122: 104710. <https://doi.org/10.1016/j.apgeochem.2020.104710>
- Luo, Z. J., Zuo, R. G., 2025. Causal Discovery and Deep Learning Algorithms for Detecting Geochemical Patterns Associated with Gold-Polymetallic Mineralization: A Case Study of the Edongnan Region. *Mathematical Geosciences*, 57(1): 193–220. <https://doi.org/10.1007/s11004-024-10153-6>
- Masci, J., Meier, U., Cireşan, D., et al., 2011. Stacked Convolutional Auto-Encoders for Hierarchical Feature Extraction. Springer, Berlin. https://doi.org/10.1007/978-3-642-21735-7_7
- Reimann, C., Filzmoser, P., Garrett, R. G., et al., 2008. Statistical Data Analysis Explained: Applied Environmental Statistics with R. Wiley, Hoboken. <https://doi.org/10.1002/9780470987605>
- Wang, J., Zuo, R. G., Caers, J., 2017. Discovering Geochemical Patterns by Factor-Based Cluster Analysis. *Journal of Geochemical Exploration*, 181: 106–115. <https://doi.org/10.1016/j.gexplo.2017.07.006>
- Wang, Z. Y., Li, T., Zuo, R. G., 2024. Leucogranite Mapping via Convolutional Recurrent Neural Networks and Geochemical Survey Data in the Himalayan Orogen. *Geoscience Frontiers*, 15(1): 101715. <https://doi.org/10.1016/j.gsf.2023.101715>
- Xin, L., 2023. Genesis of the Large Qukulekedong Au-Sb Deposit, East Kunlun Orogen, China (Dissertation). Chengdu University of Technology, Chengdu (in Chinese with English abstract).
- Xiong, Y. H., Zuo, R. G., Luo, Z. J., et al., 2022. A Physically Constrained Variational Autoencoder for Geochemical Pattern Recognition. *Mathematical Geosciences*, 54(4): 783–806. <https://doi.org/10.1007/s11004-021-09979-1>
- Xiong, Y. H., Zuo, R. G., Wang, K. X., et al., 2018. Identification of Geochemical Anomalies via Local RX Anomaly Detector. *Journal of Geochemical Exploration*, 189: 64–71. <https://doi.org/10.1016/j.gexplo.2017.06.021>
- Xu, Y., Shi, L. Y., Zuo, R. G., 2024. Geologically Constrained Unsupervised Dual-Branch Deep Learning Algorithm for Geochemical Anomalies Identification. *Applied Geochemistry*, 174: 106137. <https://doi.org/10.1016/j.apgeochem.2024.106137>
- Xu, Y., Zuo, R. G., 2024. An Interpretable Graph Attention Network for Mineral Prospectivity Mapping. *Mathematical Geosciences*, 56(2): 169–190. <https://doi.org/10.1007/s11004-023-10076-8>
- Xu, Y., Zuo, R. G., Zhang, G. B., 2023. The Graph Attention Network and Its Post-Hoc Explanation for Recognizing Mineralization-Related Geochemical Anomalies. *Applied Geochemistry*, 155: 105722. <https://doi.org/10.1016/j.apgeochem.2023.105722>
- Yang, J. X., Zhao, Y. Q., Chan, J. C., 2017. Learning and Transferring Deep Joint Spectral-Spatial Features for Hyperspectral Classification. *IEEE Transactions on Geoscience and Remote Sensing*, 55(8): 4729–4742. <https://doi.org/10.1109/TGRS.2017.2698503>
- Yin, B. J., Zuo, R. G., Xiong, Y. H., et al., 2021. Knowledge Discovery of Geochemical Patterns from a Data-Driven Perspective. *Journal of Geochemical Exploration*, 231: 106872. <https://doi.org/10.1016/j.gexplo.2021.106872>
- Yousefi, M., Kamkar-Rouhani, A., Carranza, E. J. M., 2014. Application of Staged Factor Analysis and Logistic Function to Create a Fuzzy Stream Sediment Geochemical Evidence Layer for Mineral Prospectivity Mapping. *Geochemistry: Exploration, Environment, Analysis*, 14(1): 45–58. <https://doi.org/10.1144/geochem2012-144>
- Yu, S. Y., Deng, H., Liu, Z. K., et al., 2024. Identification of Geochemical Anomalies Using an End-to-End Transformer. *Natural Resources Research*, 33(3): 973–994. <https://doi.org/10.1007/s11053-024-10334-4>
- Yu, X. L., Li, H., Wei, X. L., et al., 2025. Zircon U-Pb Age and Geochemical Characteristics of Granitic Magmatic Rocks in Mailong Gold Deposit, East Kunlun, and Their Geological Significance. *Earth Science*, 50(6): 2107–2123 (in Chinese with English abstract).
- Zhang, C. J., Zuo, R. G., Xiong, Y. H., 2021. Detection of the Multivariate Geochemical Anomalies Associated with Mineralization Using a Deep Convolutional Neural Network and a Pixel-Pair Feature Method. *Applied Geochemistry*, 130: 104994. <https://doi.org/10.1016/j.apgeochem.2021.104994>

- Zuo, R. G., 2019. Exploration Geochemical Data Mining and Weak Geochemical Anomalies Identification. *Earth Science Frontiers*, 26(4): 67–75 (in Chinese with English abstract).
- Zuo, R. G., Carranza, E. J. M., Wang, J., 2016. Spatial Analysis and Visualization of Exploration Geochemical Data. *Earth-Science Reviews*, 158: 9–18. <https://doi.org/10.1016/j.earscirev.2016.04.006>
- Zuo, R. G., Cheng, Q. M., Xu, Y., et al., 2024. Explainable Artificial Intelligence Models for Mineral Prospectivity Mapping. *Scientia Sinica (Terrae)*, 54(9): 2917–2928 (in Chinese with English abstract).
- Zuo, R. G., Wang, J., Chen, G. X., et al., 2015. Identification of Weak Anomalies: A Multifractal Perspective. *Journal of Geochemical Exploration*, 148: 12–24. <https://doi.org/10.1016/j.gexplo.2014.05.005>
- Zuo, R. G., Xiong, Y. H., Wang, J., et al., 2019. Deep Learning and Its Application in Geochemical Mapping. *Earth-Science Reviews*, 192: 1–14. <https://doi.org/10.1016/j.earscirev.2019.02.023>
- Zuo, R. G., Xu, Y., 2023. Graph Deep Learning Model for Mapping Mineral Prospectivity. *Mathematical Geosciences*, 55(1): 1–21. <https://doi.org/10.1007/s11004-022-10015-z>
- Zuo, R. G., Xu, Y., 2024. A Physically Constrained Hybrid Deep Learning Model to Mine a Geochemical Data Cube in Support of Mineral Exploration. *Computers & Geosciences*, 182: 105490. <https://doi.org/10.1016/j.cageo.2023.105490>

中文参考文献

- 郭利, 柏辉, 邢令, 等, 2020. 新疆东昆仑木孜塔格地区晚古生代热液型金锑矿成矿规律及成矿模式. *西部探矿工程*, 32(5): 114–117.
- 李忠潭, 薛林福, 冉祥金, 等, 2022. 基于卷积神经网络的智能找矿预测方法: 以甘肃龙首山地区铜矿为例. *吉林大学学报(地球科学版)*, 52(2): 418–433.
- 刘艳鹏, 朱立新, 周永章, 2020. 大数据挖掘与智能预测找矿靶区实验研究: 卷积神经网络模型的应用. *大地构造与成矿学*, 44(2): 192–202.
- 邢令, 2023. 东昆仑屈库勒克东大型 Au-Sb 矿床成因研究(博士学位论文). 成都: 成都理工大学.
- 于小亮, 李华, 魏小林, 等, 2025. 东昆仑迈龙金矿区花岗质岩浆岩锆石 U-Pb 定年和地球化学特征及其地质意义. *地球科学*, 50(6): 2107–2123.
- 左仁广, 2019. 勘查地球化学数据挖掘与弱异常识别. *地学前缘*, 26(4): 67–75.
- 左仁广, 成秋明, 许莹, 等, 2024. 可解释性矿产预测人工智能模型. *中国科学: 地球科学*, 54(9): 2917–2928.