

基于融合地质信息图卷积神经网络的高光谱伟晶岩锂铍识别

别

陈志行¹, 王正海^{1*}, 卜浩坚¹, 田雨欣¹

1 中山大学地球科学与工程学院, 广东珠海 519082

摘要: 高光谱遥感影像凭借其丰富的波段信息, 能够有效提取与识别矿物蚀变特征, 是遥感找矿的重要工具, 特别是与机器学习相结合的方法, 近年来在成矿预测领域取得了众多成功应用。然而, 传统遥感找矿方法其分析多局限于高光谱数据本身, 缺乏与地质信息的协同分析, 这制约了找矿效果的进一步提升。为了解决传统高光谱找矿缺少地质信息的不足, 本文将传统的高光谱数据与岩体、断层位置这类地质信息相结合, 构建高光谱—地质信息 39 通道综合数据集, 首先对图卷积神经网络 (GCN) 模型进行改进, 在网络中加入残差连接模块, 对残差连接模块和卷积层进行批量化归一操作, 提高训练效果。最后采用资源一号 02D 卫星 (ZY-1 02D) 高光谱数据在大红柳滩地区开展实验。结果表明, 改进后的 GCN 模型对研究区内含矿花岗伟晶岩具有较高的识别精度。相比原始 GCN 网络、卷积神经网络模型以及支持向量机模型, 准确率分别提高了 7、22 和 27 个百分点, 实现了高光谱遥感影像中锂铍矿化花岗伟晶岩的高精度自动化预测。

关键词: 高光谱; 资源一号; GCN; 伟晶岩; 锂铍矿

中图分类号: P618

收稿日期: 2025-10-15

A Geology-Informed Graph Convolutional Network for Identifying Lithium- and Beryllium-Rich Pegmatites from Hyperspectral Imagery

Chen Zhixing¹, Wang Zhenghai^{1*}, Bu Haojian¹, Tian Yuxin¹

1. School of Earth Sciences and Engineering, Sun Yat-sen University, Zhuhai, Guangdong province 519082, China

Abstract: Hyperspectral remote sensing imagery, with its abundant spectral information, has proven to be a vital tool in mineral exploration by effectively extracting and identifying mineral alteration features. The integration of hyperspectral data with machine learning methods has led to numerous successful applications in mineral prospectivity mapping in recent years. However, conventional remote sensing-based exploration approaches predominantly focus on the hyperspectral data itself and lack effective integration with geological information, which limits further improvement in exploration effectiveness. To bridge this gap, th

基金项目: 国家自然科学基金重点项目 (No. 42430111)

作者简介: 陈志行 (2001-), 男, 湖北省襄阳人, 硕士研究生, 遥感地质方向, E-mail: chenzhx226@mail2.sysu.edu.cn

通讯作者: 王正海 (1971-), 安徽怀宁人, 博士, 副教授, 博士研究生导师, 主要从事资源环境效应遥感探测机理与方法. Email: wzhengh@mail.sysu.edu.cn

This study develops a novel methodology that integrates hyperspectral imagery with critical geological determinants—specifically pluton boundaries and fault systems, making 39 channel hyperspectral geological information comprehensive data set and introduces an enhanced Graph Convolutional Network (GCN) model. Architectural improvements include the incorporation of residual connections and the systematic application of batch normalization across both residual modules and convolutional layers, substantially stabilizing and accelerating the training process. Validation using ZY-1 hyperspectral data from the Dahongliutan area demonstrates that our refined GCN model achieves superior accuracy in identifying mineralized granitic pegmatites. Quantitative evaluations confirm substantial performance gains, with accuracy improvements of 7, 22, and 27 percentage points over the baseline GCN, Convolutional Neural Network, and Support Vector Machine models, respectively. This work establishes an effective and automated framework for high-precision prediction of lithium- and beryllium-mineralized granitic pegmatites via hyperspectral remote sensing.

Key words: Hyperspectral; ZY-1; GCN(Graph Convolutional Network); Pegmatite; Li-Be Mineralization

0 引言

锂、铍等稀有金属是具有重要战略意义的矿产资源，其应用贯穿于核工业、新能源与航空航天等关键领域，是新兴产业发展必需的战略性金属矿产资源。我国锂铍稀有金属年消费量排行全球第一，而花岗伟晶岩型矿床是锂铍稀有金属的重要矿床类型 (Benson et al., 2017; 涂其军等, 2019)。在我国，花岗伟晶岩型锂铍矿多集中在四川西部、新疆等干旱且较高海拔地区，通常以长条或透镜状伟晶岩脉及其集群的形式产出，规模不等，总体呈带状分布，如新疆大红柳滩、可可托海超大型伟晶岩矿床 (张森等, 2023)。这些地区海拔高、起伏大、面积广，进行实地找矿工作难度较大，勘探耗时长，成本难以控制，因此使用具有无接触探测能力、覆盖范围广的遥感手段来进行找矿工作具有较大优势。

利用遥感手段进行花岗伟晶岩型锂矿勘查的传统方法大致可以分为 2 类：（1）根据含锂铍花岗伟晶岩的光谱特征提取蚀变信息，进行对锂铍矿的间接识别。如前人在新疆大红柳滩地区将 WorldView-3 和 ASTER 卫星数据结合，提取锂矿相关蚀变矿物的遥感蚀变信息，结合金属化探信息，为东昆仑地区伟晶岩型稀有金属矿的勘查提供了方法 (金谋顺等, 2019)；在基于 Landsat 系列、哨兵等 4 种多光谱卫星影像的基础上，有学者提出新的光谱波段组合，采用主成分分析手段突出锂的蚀变信息，以区分含锂伟晶岩与其母岩 (Cardoso-Fernandes et al., 2019)；也可以通过在已知伟晶岩型锂铍矿的光谱曲线特征及其成矿规律的基础上，利用现有的遥感图像增强处理技术和分类技术，高效提取锂铍矿化信息及找矿标志信息，最后圈定找矿靶区 (代晶晶等, 2017; 范玉海等, 2018)。（2）利用遥感手段直接识别与提取地表花岗伟晶岩的分布信息，进而圈定找矿靶区。如基于 GeoEyes-1 数据，直接利用花岗伟

晶岩的纹理、颜色、色调等特征,对甲基卡矿区北部的伟晶岩信息进行定位(潘蒙等,2016);基于GF-2高分辨率卫星影像,结合光谱、纹理、边缘等特征,使用随机森林方法进行花岗伟晶岩的特征分类、选取,提出并引入多个特征变量提高分类效果,最终的花岗伟晶岩分类效果良好(杜晓川等,2023)。

与传统遥感方法相比,深度学习及其相关方法在图像信息提取、图像分类等方面具有较大优势(Pathak A R et al., 2018; Zhao Z Q et al., 2019; Wu X et al., 2020)。随着计算机视觉技术的迅速发展,深度学习卷积神经网络的架构演进呈现出显著的多元化趋势,其设计范式主要围绕增加网络深度、降低计算复杂度以及融合多尺度特征等方向展开。如结合高光谱技术和深度学习技术,将含锂铍矿物伟晶岩野外实测光谱和围岩样品光谱结合,使用光谱增强技术凸显光谱特征,对含锂铍花岗伟晶岩进行识别(蒋果等,2023);此外,还有学者基于全卷积神经网络和U-net网络这2种深度学习模型识别伟晶岩脉信息(王海宇,2021)。由于多种地质作用叠加,成矿作用通常是复杂多变的,与成矿有关的地质信息也呈现出非线性特征,具有强空间相关性。前人的遥感找矿研究大多只利用高光谱数据,在其与地质信息的融合方面存在一定不足。其中,传统卷积神经网络往往使用固定、局部的卷积操作,对输入特征本身进行非线性变换。而图卷积神经网络(GCN)结构简单且连接有序,使用具有柔性结构的图作为输入,考虑节点特征和图结构共同进行建模,可以充分考虑非线性、非网格化的地质信息和高光谱信息之间的关系,在遥感结合多源信息找矿领域中具有较高的应用前景(Liang C et al., 2021; Guan Q et al., 2022; 左仁广等, 2023; 左仁广等, 2024)。同时,资源一号02D卫星(ZY-1 02D)作为新兴的国产高光谱遥感卫星,其所搭载的可见光近红外一短波红外高光谱相机可获取高光谱分辨率的遥感数据。目前在地质领域有少量针对该数据的研究,但将该数据用于花岗伟晶岩型锂铍矿勘查的研究应用较少,结合该卫星数据进行实际找矿应用具有重大意义。

针对高光谱遥感图像中复杂的光谱特征以及非线性地质信息的强空间关联性,本文提出了一种基于改进GCN的算法:(1)同时考虑地质信息和高光谱信息,用于矿化异常识别;(2)在卷积网络中加入残差连接和批量化归一模块,优化信息传递,稳定训练动态并防止过拟合。在本文改进后的GCN方法基础上,制作研究区锂铍成矿潜力综合对比图,以期为该区域花岗伟晶岩型锂铍矿勘查工作提供参考。

1 研究区概况与数据源

1.1 研究区概况

大红柳滩-白龙山超大型锂铍稀有金属矿集区主要位于新藏公路大红柳滩驿站附近。其

地理坐标为 $79^{\circ}00' \sim 79^{\circ}20'E$ 、 $35^{\circ}46' \sim 35^{\circ}59'N$ ，面积近 1000 平方千米。行政区划隶属于和田地区，构造上位于青藏高原西北缘的西昆仑-喀喇昆仑造山带，详见图 1。区内断裂构造较为发育，主要呈北西-南东向展布，主要断裂有康西瓦断裂、大红柳滩-郭扎错断裂、奇台达坂断裂等（涂其军等，2019）。矿集区主要锂矿床、矿点围绕大红柳滩花岗岩体、俘虏沟花岗岩体外侧分布，沿北西向延伸 30 余千米，形成多个矿床（带），含矿伟晶岩脉成群、成带分布，分段集中。矿石矿物主要包括锂辉石、绿柱石等（王核等，2023）。研究区位置及 ZY-1 真彩色合成影像如图 2 所示。

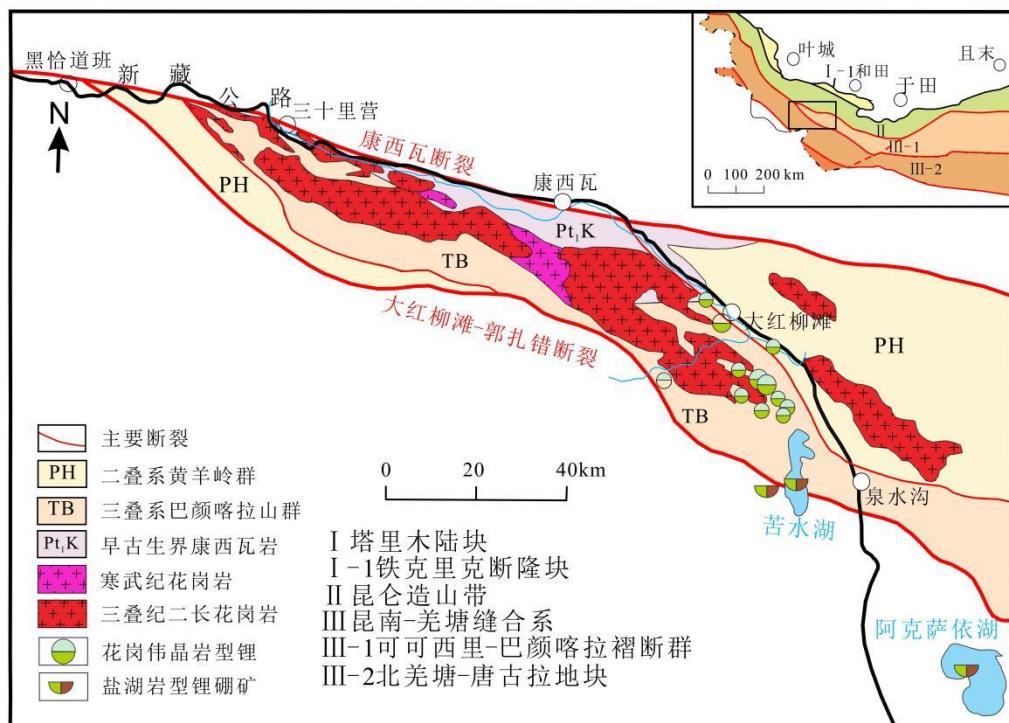


图 1 新疆大红柳滩一带地质矿产图（改自李侃等，2019）

Fig.1 Geological and mineral map of the Dahongliutan area in Xinjiang(adapted from Li K et al., 2019)

1.2 数据源及其预处理

本文使用的遥感影像来源为 ZY-1 02D 卫星，影像编号为 ZY1E_AHSI_E79.16_N35.73_20201127_006344_L1A0000199138，获取时间为 2020 年 11 月 27 日。ZY-1 02D 卫星发射于 2019 年 9 月 12 日，卫星轨道高度约为 778km，重访周期 5d，搭载的高光谱相机则具备在 395-2501nm 波段范围内高信噪比条件下的 166 个波段辐射信息获取能力，空间分辨率为 30 m (Lu H et al., 2021)。在数据处理前，使用 ENVI5.6 软件对影像进行预处理，主要包括辐射定标、大气校正、坏波段去除和去噪。使用 ArcGIS10.2 软件，通过前人地质资料研究

结合目视解译,对影像中锂铍矿区进行辨别并精确标注范围,获得含矿伟晶岩特征标签以及位置信息。由于含矿伟晶岩多以较窄的岩脉形式产出,本文将含矿伟晶岩以外100m区域构建缓冲区,视为正样本区域。

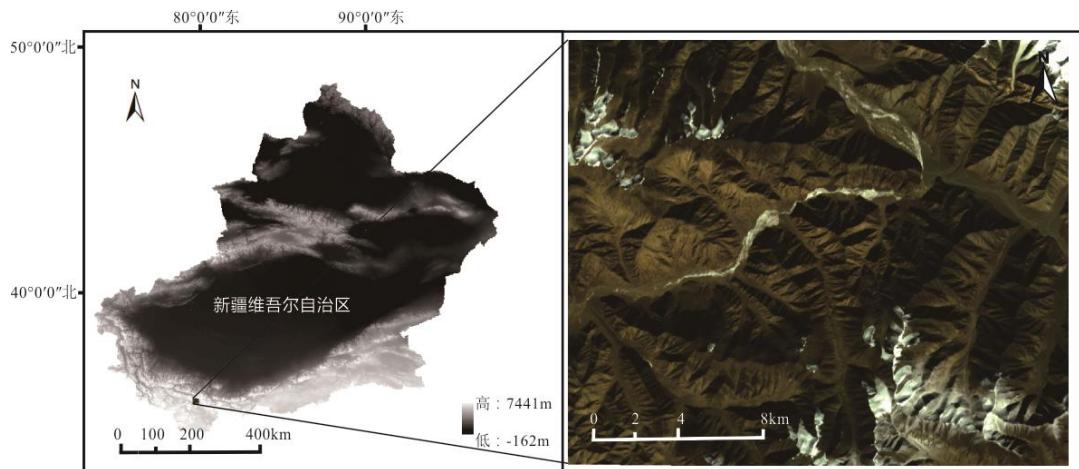


图2 研究区位置及 ZY-1 影像
Fig.2 Location of the study area and ZY-1 imagery

对于高光谱信息,由于高光谱数据信息量大,非相关光谱以及水汽影响、噪声问题会影响实验,应对光谱信息进行选择。锂辉石、绿柱石是花岗伟晶岩型锂铍矿的矿化矿物和特征蚀变矿物,具有较好的指示意义。如图3所示,锂辉石光谱曲线在2207nm具有一处较小的吸收特征峰,绿柱石光谱曲线在830nm具有一处明显的吸收峰,在2055、2155、2200nm附近具有一连串较小的吸收峰(任广利等,2022;徐萍等,2025)。选取ZY-1 02D高光谱图像中波长为782-902、2014-2400nm的37个连续波段参与后续计算,以上波段能避免水汽影响,捕捉特征矿物的较高精度光谱特征。

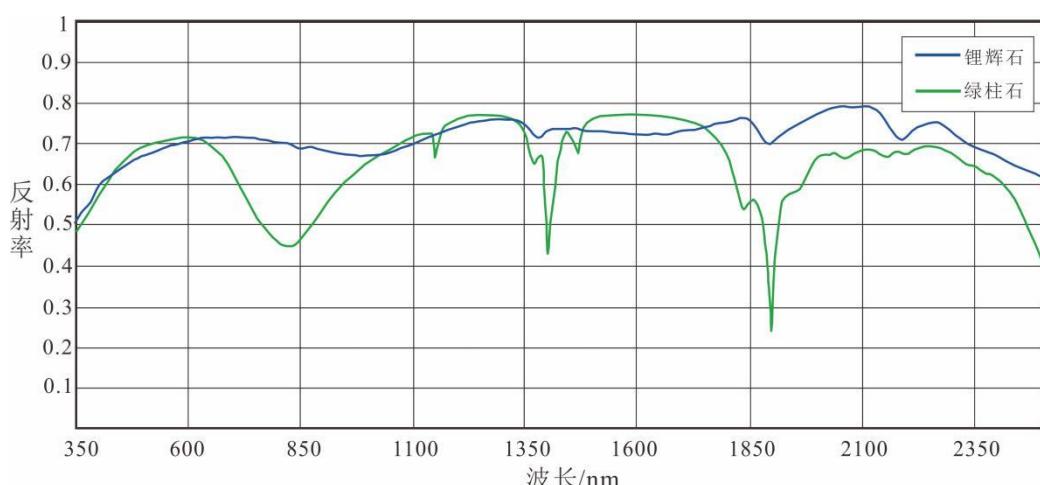


图3 绿柱石、锂辉石的可见-短波红外光谱曲线(改自任广利等,2022;徐萍等,2025)
Fig.3 Visible to near infrared and shortwave infrared spectra curves of beryl and spodumene(adapted from Ren G.L. et al., 2014; Xu P et al., 2025)

前期研究表明,研究区花岗伟晶岩型锂铍矿床与区内岩浆岩岩体位置以及断裂位置强烈相关(熊欣等,2024)。伟晶岩脉由花岗质岩浆结晶分异形成,主要产出于岩体的内外接触带,断层交叉处是花岗伟晶岩型锂铍矿赋存的有利位置。本文综合前人地质资料以及NASA在2000年测量的SRTM30m数字高程模型数据(DEM)结合目视解译,圈定研究区内花岗岩以及断裂的位置,使用反距离权重法对岩体、断裂位置进行插值处理,并重采样至30m分辨率以匹配高光谱数据分辨率。选取区域内岩体距离和断层距离作为地质信息变量,用于有利成矿区预测。

2 研究方法

本文以GCN网络结构为基础,模型包含三层GCN,每层网络后都进行残差连接处理;使用超参数网格搜索的方法系统化搜索最佳超参数组合(隐藏层维度、学习率等),利用全部训练数据训练最终模型。本章节首先对原始GCN网络架构进行简要介绍,然后介绍残差连接模块,最后介绍本文使用的评价指标。

2.1 GCN图卷积神经网络

图卷积神经网络(Graph Convolution Network, GCN)由Kipf T.N在2016年提出,是一种专门用于处理图结构数据的深度学习模型,它通过将传统卷积操作推广到非欧几里得空间的图数据上,实现对节点特征的提取和传播。GCN的核心是通过局部邻域聚合来更新节点表示:每个节点通过聚合其相邻节点的特征信息来更新自身特征。将研究区的39通道栅格数据划分为多个 10×10 像素的样本,将每个样本转换为具有100个节点的图数据,其中每个节点拥有39维属性信息。节点之间的关系是根据它们对应的地理空间位置之间的距离来确定的,考虑到实际地理空间位置,每个节点之间间隔100m,各个节点被141米半径内的8个节点和200米半径内的12个节点包围。选取两者中点170m作为节点关系确认的阈值,当两个节点在170m范围内时,认为上述节点存在关系(Ding L et al., 2024)。

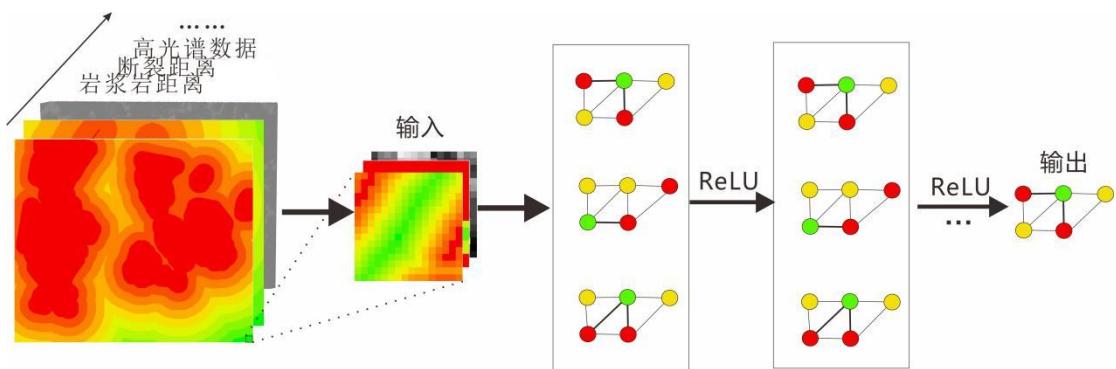


图4 GCN网络结构
Fig.4 GCN network structure

最经典的 GCN 层定义 (Kipf & Welling, 2017) :

$$H(l+1) = \sigma(D^{-1/2}A^TD^{-1/2}H(l)W(l)) \quad (1)$$

式中, $A^T = A + I$, 为带自环的邻接矩阵 (A 为原始邻接矩阵); D 为对角矩阵; $H(l)$ 为第 l 层的节点特征矩阵; $W(l)$ 为可学习的权重矩阵; σ 是激活函数 (如 ReLU)。

在实际应用中, 通常通过多层堆叠来捕获高阶邻域信息, 例如本文使用的 3 层图卷积神经网络定义了三个图卷积层, 将节点特征和边界索引依次经过连接 ReLU 激活函数的三层图卷积层中, 最后输出 64 维的节点特征。最后的池化层进行全局加和池化, 将节点分组并对每个图的所有节点特征按元素求和, 输出每个图的全局表示向量, 完成分类。

2.2 残差连接结合 BN 模块

在传统的 CNN 中, 随着网络层数的不断增加, 模型性能有一定的概率出现退化现象。残差模块通过残差映射学习目标函数与输入之间的差异, 从而更高效地提取特征, 将输入信息更快地传递到更深的层, 这使得网络更容易学习到恒等映射。残差网络背后的策略是让网络去拟合残差映射而非直接学习底层映射。因此, 网络不是去拟合比如 $H(x)$ 这样的初始映射, 而是去拟合 $H(x)-x$ 这样的残差映射。这个过程可以缓解梯度消失, 减少训练初期的波动, 使优化过程更平滑, 并提升特征复用。其计算公式为:

$$y = H(x, WH) + x \quad (2)$$

式中, $H(x, WH)$ 为残差函数, x 为输入特征, y 为输出特征, WH 为可学习的权重参数。

表 1 改进 GCN 网络架构

Table 1 Enhanced GCN network architecture

网络结构	维度
输入层	39
GCN1-BN-ReLU	39-64
GCN2-BN-ReLU	64-256
投影层	64-256
残差连接	256
GCN3-BN-ReLU	256-64
投影层	256-64
残差连接	64
全局池化层	—
输出层	—

此外，在深度网络的迭代训练过程中，网络参数的迭代更新会导致每一层输入数据的分布随之发生改变。分布的不稳定使得后续网络层需要不断适应新的数据模式，从而显著增加了模型优化的复杂性，导致收敛速度减慢。改进后的网络在每一层激活函数前以及残差连接中都对数据进行批量归一化（BN）处理。BN 方法最早由 Ioffe 在 2015 年提出，将卷积后分布各异的数据调整为均值为 0、方差为 1 的标准正态分布形式，即标准化至零均值和单位方差。这一操作通过稳定训练过程中的数据分布，不仅加快了收敛速率，也凭借其正则化效应提升了模型的泛化性能，在一定程度上防止网络出现过拟合现象。综合改进后的 GCN 网络架构如表 1 所示，在三层 GCN 网络每层进行 BN 处理，在第二层 GCN 网络时将第一层 GCN 网络输出结果通过投影层转换为 256 层以匹配网络维度相同，进行后续残差连接，在第三层 GCN 网络时将第二层 GCN 网络输出结果通过投影层转换为 64 层进行后续残差连接，最后经过池化层得到输出结果。

2.3 评价指标

评价系统最终确定使用准确率（Accuracy）、召回率（Recall）、精确率（Precision）以及 F1-score 作为评价指标，对分类的结果进行分析。其中 Accuracy 表示验证集中模型正确分类的含矿样本区域与负样本数量与总样本数量之比；Recall 表示模型中所有正样本标签中预测正确的样本比例；Precision 用于衡量模型在预测所有的正样本中真正为正样本的能力，Precision 越大表示模型的效果越好；F1-score 是 Precision 和 Recall 的调和平均值，着重反映模型遗漏或错误判断正样本的能力，在数据分布不均衡二分类模型中十分重要。F1-score 越高，表示模型在识别和预测正样本的效果越好。表达式如下：

$$\text{Accuracy} = \frac{TP+TN}{TP+FP+TN+FN} \quad (3)$$

$$\text{Recall} = \frac{TP}{TP+FN} \quad (4)$$

$$\text{Precision} = \frac{TP}{TP+FP} \quad (5)$$

$$\text{F1 score} = \frac{2 \cdot (\text{Precision} * \text{Recall})}{\text{Precision} + \text{Recall}} \quad (6)$$

式中，TP（真阳性）表示真实为正类的像元被正确预测为正类的数量；TN（真阴性）表示真实为负类的像元被正确预测为负类的数量；FP（假阳性）表示真实为负类的像元被错误预测为正类的数量；FN（假阴性）表示真实为正类的像元被错误预测为负类的数量。

3 实验与分析

3.1 模型训练

本实验使用 Windows11 操作系统，显卡配置为 RTX4060，使用 Python 语言进行编程并采用 PyTorch 作为深度学习框架。考虑系统处理能力，使用网格搜索法确定参数，经过多次训练，确定当中间隐藏层维度为 256，学习率为 0.001 时，使用 Adam 优化器进行参数更新所获得的模型效果最好。使用 ReLU 激活函数，将训练迭代次数设定为 200 轮。在训练过程中，每轮迭代后均在验证集上计算损失值，并最终选取验证集上性能最优的模型作为最终网络。

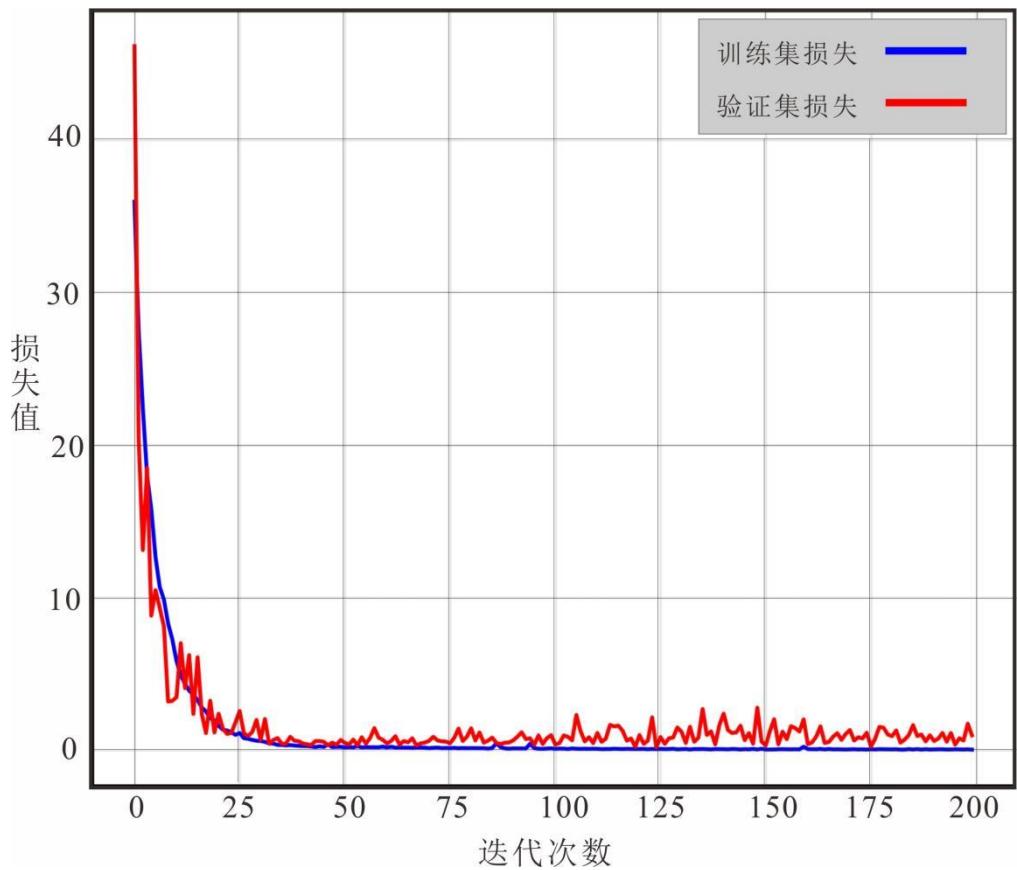


图 5 训练集和验证集损失函数曲线图

Fig.5 Loss function curve for training set and validation set

资源一号光谱-地质信息综合数据集包含 646 个负样本，218 个正样本，每个样本都具有 39 通道的信息作为模型特征输入，其中前 37 个通道为高光谱信息，后 2 个通道为地质信息。按 7:3 的比例和均匀空间分布划分出训练集和验证集，输入改进的 GCN 网络进行训练，绘制训练网络时训练集和验证集的损失函数变化曲线，如图 5 所示。随着训练过程中网络迭代次数的增加。验证集和训练集损失值都呈下降趋势，两者收敛且相差很小，确认未观察到过拟合现象，表明模型具有较强的可靠性。

3.2 对照实验

为了验证本方法所带来的精度效果提升，实验引入了传统的支持向量机 SVM、经典卷

积神经网络 CNN 和原始 GCN 模型和本文方法进行对比实验。其中，SVM 模型只使用了高光谱数据以代表传统方法，未添加地质信息。其他模型采用相同的 ZY-1 数据和地质数据进行训练，模型精度评价图如图 6。

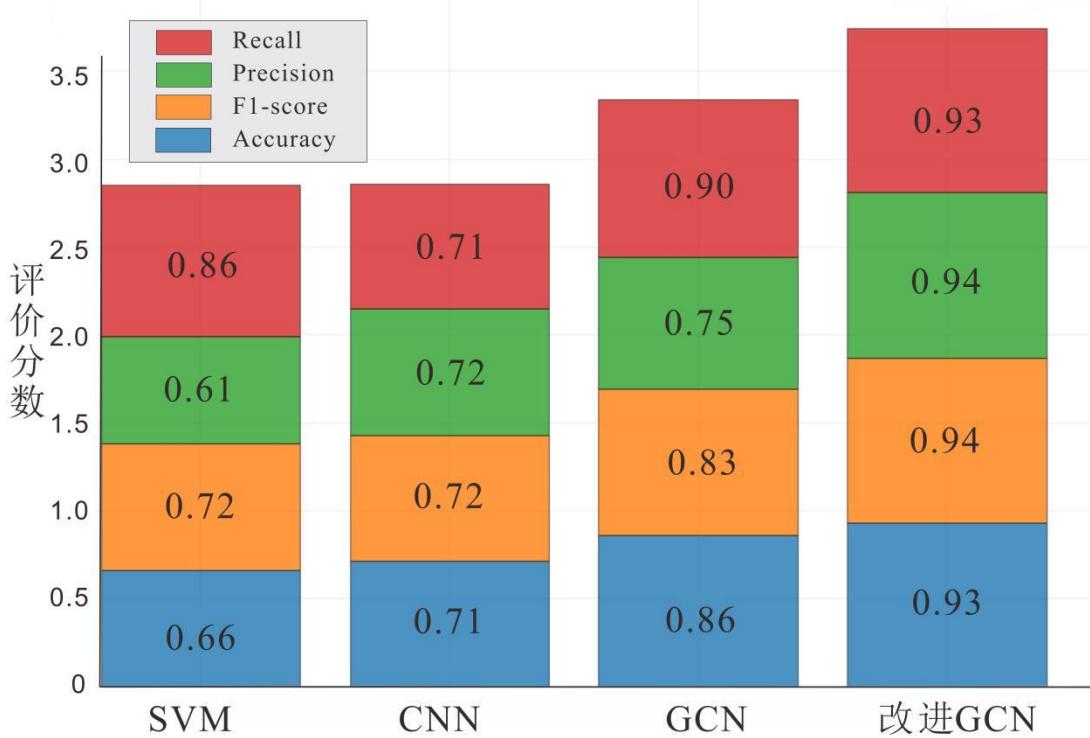


图 6 对比模型精度评价图

Fig.6 Comparison of model accuracy evaluation charts

由图 6 可知，本文的改进 GCN 方法对花岗伟晶岩型矿床的识别精度较高，验证集准确率为 93%，F1-score 为 94%，相比原始 SVM 模型、CNN 网络模型、原始 GCN 模型，准确率分别提高了 27%、22%、7%，F1-score 等其他性能指标也都有所提升。相比之下，传统机器学习模型 SVM 性能较差，准确率仅为 66%；CNN 模型在精确率提升较大的情况下，召回率过低，仅为 71%，辨别正样本的能力存在不足；GCN 模型具有较高的召回率，较低的精确率，对正样本存在明显的误判现象。改进 GCN 模型的多项指标优秀，同其他模型相比具有较大优势，证明了本文方法的有效性。

3.3 基于改进 GCN 的矿产预测

为了评估本文改进 GCN 方法的可解释性以及模型的泛化能力，将本文方法应用于四川九龙地区的矿产预测中，本文在四川省九龙地区生成了改进 GCN 模型的预测图，以及其他三个模型的对比图（图 7）。九龙地区位于四川省西部，和大红柳滩地区同属于较低植被覆盖区，海拔高、切割深，在地理和地质环境上具有相似性。将研究区域内的每个样本输入到模型中，生成每个样本的矿化概率。通过合并每个样本的地理空间坐标并按坐标将其排列，

最终生成花岗伟晶岩型锂铍矿的预测热图，对矿床的预测结果进行可视化。

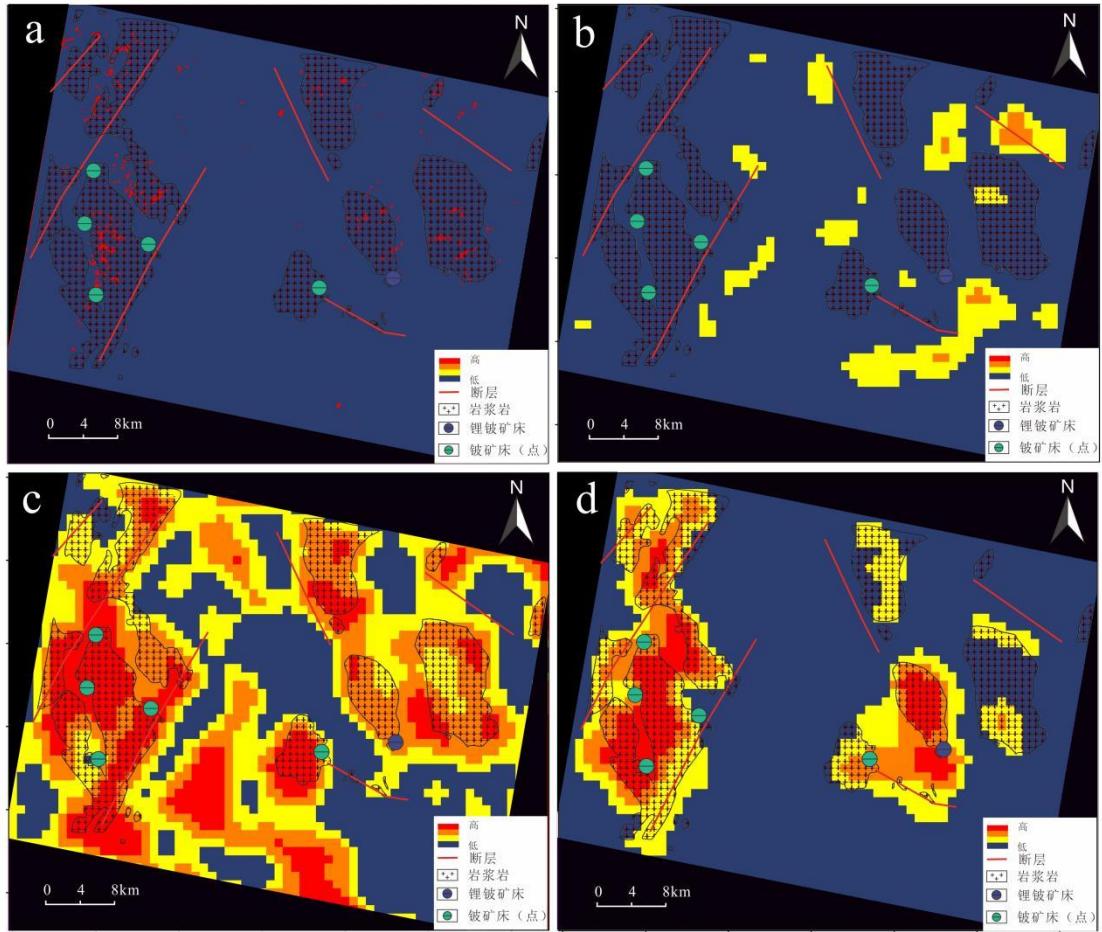


图 7 四种模型综合预测热图 (a-SVM,b-CNN,c-GCN,d-改进 GCN)

Fig.7 Comparison of 4 Model Comprehensive Prediction Heatmaps
(a-SVM,b-CNN,c-GCN,d-Enhanced-GCN)

为了更直观地理解模型预测结果与矿床实际分布之间的关系，本文对比分析了目前已知锂铍矿床的真实位置，以及和已知大型断层、岩体空间分布的关系。不同模型的预测效果存在显著差异（图 7）。SVM 模型（图 7a）的泛化能力最弱，未能有效圈定研究区东部的矿化集中区。在深度学习模型中，CNN 模型（图 7b）表现出明显的过拟合，其在验证集的评价指标相对较低，对新研究区矿点的预测能力不佳；GCN 模型（图 7c）虽能准确预测所有已知矿点，但其对矿点周边区域的预测误差较大，表明其空间泛化能力仍有局限；相比之下，本研究提出的改进 GCN 模型（图 7d）表现最佳，其高概率预测区范围更为聚焦，显著降低了冗余面积，并成功定位了所有已知矿床（如东部的打枪沟、洛莫以及西部的多个小型矿点），表明其对锂铍矿床具有更高的预测可信度。

值得注意的是，对于花岗伟晶岩型锂铍矿，矿体多以较窄的矿脉形式产出，规模较小，预测图中的一个小像素通常对应于实际区域中的较大区域，在正负样本不均衡的二分类任务中预测准确率可能较低。

4 结论

为实现高光谱影像中锂铍矿化花岗伟晶岩的精准信息提取，本文提出了一种改进的GCN模型，并通过与SVM、CNN和GCN模型的对比实验证明了其优越性。主要结论如下：

(1) 本文使用的改进GCN模型对花岗伟晶岩型锂铍矿床的具有较高的识别精度，准确率为93%，F1-score为0.94，相比支持向量机模型、CNN模型、原始GCN模型，准确率分别提高了27%、22%、7%，精确率分别提高了33%、22%、19%，F1分数等其他指标也都有所提升。

(2) 本文改进GCN方法在识别含矿伟晶岩过程中结合了岩浆岩、断层等地质信息，相比于传统的高光谱遥感方法，弥补了地质信息方面的缺失，可靠性和可行性均在本文得到了验证。

(3) 本文利用ZY-1 02D影像对四川省九龙地区内的花岗伟晶岩型锂铍矿进行成矿潜力评价，证明了利用国产高光谱卫星影像进行伟晶岩型锂铍矿床勘查的可能性，识别结果与已知矿床分布相符合。

本工作所研究的花岗伟晶岩型锂铍矿矿床规模较小，多以脉状产出，预测条件和精度存在较大限制，后续工作将围绕规模较大的矿床类型进行研究，如斑岩铜矿等类型，需要对样本、模型参数进行调整，后续研究计划引入地球化学、地球物理等多源数据，与高光谱数据相结合，旨在实现基于广域地质信息的多矿种预测任务。

References

Benson T R., Coble M A., Rytuba J J., et al., Lithium enrichment in intracontinental rhyolite magmas leads to Li deposits in caldera basins[J]. *Nature communications*, 2017, 8(1): 270.

Cardoso-Fernandes J., Teodoro A C., Lima A., Remote sensing data in lithium (Li) exploration: A new approach for the detection of Li-bearing pegmatites[J]. *International Journal of Applied Earth Observation and Geoinformation*, 2019, 76: 10-25.

Ding L, Chen B, Zhu Y., et al. Mineral prediction based on prototype learning[J]. *Computers & Geosciences*, 2024, 184: 105540.

Du, X.C., Lou, D.B., Xu, L.G., et al., Extracting granite pegmatite information based on GF-2 images and the random forest algorithm[J]. *Remote Sensing for Natural Resources*, 2023, 35(4): 53-60(in Chinese with English abstract). doi:10.6046/zrzyyg.20222280

Guan Q, Ren S, Chen L, et al., Recognizing multivariate geochemical anomalies related to mineralization by using deep unsupervised graph learning[J]. *Natural Resources Research*, 2022, 31(5): 2225-2245.

Ioffe S, Szegedy C., Batch normalization: Accelerating deep network training by reducing internal covariate shift[C]//*International conference on machine learning*. pmlr, 2015: 448-456.

Jiang, G, Zhou K.F., Wang Y.L., et al., Identification of lithium-beryllium granitic pegmatites based on deep learning[J]. *Earth Science Frontiers*, 2023, 30(5): 185-196(in Chinese with English abstract). doi:10.13745/j.esf.sf.2023.5.20

Jiang Q, Dai J, Wang D, et al., Application of optical remote sensing to identifying granite pegmatite lithium deposits[J]. *Mineral Deposits*, 2021, 40(04): 793-804(in Chinese with English abstract). doi:<https://doi.org/10.16111/j.0258-7106.2021.04.009>

Jin M.S., Gao Y.B., Li K, et al., Remote Sensing Prospecting Method for Pegmatite Type Rare Metal Deposit——Taking Dahongliutan Area in Western Kunlun for Example[J].

Northwestern Geology, 2019, 52(4): 222-231(in Chinese with English abstract).doi:10.3969/j.issn.1009-6248.20

19.04.017

Kipf T.N., Semi-supervised classification with graph convolutional networks[J]. arXiv preprint arXiv:1609.02907, 2016.

Liang C, Xiao B, Cheng B., GCN-based semantic segmentation method for mine information extraction in GAOFEN-1 imagery[C]//2021 IEEE International Geoscience and Remote Sensing Symposium IGARSS. IEEE, 2021: 3432-3435.

Li K, Gao Y.B., Teng J.X., et al., Metallogenetic Geological Characteristics,Mineralization Age and Resource Potential of the Granite-Pegmatite-Type Rare Metal Deposits in Dahongliutan Area,Hetian County,Xinjiang[J]. *Northwestern Geology*, 2019, 52(4): 206-221(in Chinese with English abstract). doi:<https://doi.org/10.3969/j.issn.1009-6248.2019.04.016>

Lu H, Qiao D, Li Y, et al., Fusion of China ZY-1 02D hyperspectral data and multispectral data: which methods should be used?[J]. *Remote Sensing*, 2021, 13(12): 2354.

Pathak A R, Pandey M, Rautaray S., Application of deep learning for object detection[J]. *Procedia computer science*, 2018, 132: 1706-1717.

Pan M, Tang Y, Xiao R.Q., et al., The Discovery of the Superlarge Li Ore Vein X03 in the Jiajika Ore District[J]. *Acta Geologica Sichuan*, 2016, 36(3):422-425,430(in Chinese).doi:<https://doi.org/10.3969/j.issn.1006-0995.2016.03.016>

Ren G.L., Kong H.L., Zhao K.D., et al., Spectral Characteristics and Prospecting Implications of Lithium Deposits in Dahongliutan Area,Karakoram,Xinjiang[J]. *Northwestern Geology*, 2022, 55(04): 103-114(in Chinese with English abstract).doi: 10.19751/j.cnki-1149/p.2022.04.009

Tu Q.j., Han Q., Li P., et al., Basic characteristics and exploration progress of the spodumene ore deposit in the Dahongliutan area, West Kunlun[J]. *Acta Geologica Sinica*, 2019, 93(11): 2862-2873(in Chinese with English abstract). doi:<https://doi.org/10.3969/j.issn.0001-5717.2019.11.011>

Tu Q.J., Li J.K., Wang G, et al., Mineralization comparisons of the major pegmatite type spodumene deposits and their prospecting potential in West China[J]. *Geological Survey Of China*, 6(6):36-47(in Chinese). doi:10.19388/j.zgdzdc. 2019.06.05

Wang H.Y., Research on pegmatite dike information extraction from remote sensing i

images based on deep semantic segmentation[D]. China University of Geosciences, Beijing, 2021

Wang H, Huang L, Ma H.d., et al., Geological characteristics and metallogenetic regularity of lithium deposits in Dahongliutan-Bailongshan area, West Kunlun, China[J]. *Acta Petrologica Sinica*, 2023, 39(07): 1931-1949(in Chinese with English abstract). doi:<https://doi.org/10.18654/1000-0569/2023.07.04>

Wu X, Sahoo D, Hoi S C H., Recent advances in deep learning for object detection[J]. *Neurocomputing*, 2020, 396: 39-64.

Xiong X, Li J.K., Yan Q.G., et al., The ore-forming mechanism and geological indicators of the Zhawulong pegmatite-type rare-metal deposit in Sichuan[J]. *Acta Petrologica Sinica*, 40(9): 2863-2877(in Chinese with English abstract). doi: 10.18654/1000-0569/2024.09.15

Xu P, Jia L, Bao H.J., et al., A study on visible shortwave infrared and thermal infrared spectral characteristics of beryl: implications to the beryllium resource exploration using remote sensing technology[J]. *Acta Mineralogica Sinica*, 1-9(in Chinese with English abstract). doi:<https://doi.org/10.3724/j.1000-4734.2025.45.001>.

Zhang S, Ju N, Wu Y, et al., Distribution characteristics, main types and exploration and development status of beryllium deposit[J]. *Geology In China*, 2023, CSCD(02): 410-424(in Chinese with English abstract). doi:<https://doi.org/10.12029/gc20210723002>

Zhao Z Q, Zheng P, Xu S, et al., Object detection with deep learning: A review[J]. *IEEE transactions on neural networks and learning systems*, 2019, 30(11): 3212-3232.

Zuo R, Xu Y., A physically constrained hybrid deep learning model to mine a geochemical data cube in support of mineral exploration[J]. *Computers & Geosciences*, 2024, 182: 105490.

Zuo R, Xu Y., Graph deep learning model for mapping mineral prospectivity[J]. *Mathematical Geosciences*, 2023, 55(1): 1-21.

附中文参考文献

杜晓川, 娄德波, 徐林刚, 等. 基于 GF-2 影像和随机森林算法的花岗伟晶岩提取[J]. 自然资源遥感, 2023, 35(4): 53-60.

蒋果, 周可法, 王金林. 基于深度学习的花岗伟晶岩型锂铍矿物识别研究[J]. 地学前缘, 2023, 30(5): 185-196.

蒋琪, 代晶晶, 王登红, 等. 光学遥感在识别花岗伟晶岩型锂矿床中的应用[J]. 矿床地质, 2021, 40(04): 793-804.

金谋顺, 高永宝, 李侃, 等. 伟晶岩型稀有金属矿的遥感找矿方法——以西昆仑大红柳滩地区为例[J]. 西北地质, 2019, 52 (4):222-231.

李侃, 高永宝, 腾家欣, 等. 新疆和田县大红柳滩一带花岗伟晶岩型稀有金属矿成矿地质特征、成矿时代及找矿方向[J]. 西北地质, 2019, 52(04): 206-221.

潘蒙, 唐屹, 肖瑞卿, 等. 甲基卡新 3 号超大型锂矿脉找矿方法[J]. 四川地质学报, 2016, 36(3):422-425,430.

任广利, 孔会磊, 赵凯东, 等. 新疆喀喇昆仑大红柳滩一带锂矿光谱特征及其找矿指示意义[J]. 西北地质, 2022, 55(04): 103-114.

涂其军, 韩琼, 李平, 等. 西昆仑大红柳滩一带锂辉石矿基本特征和勘查新进展[J]. 地质学报, 2019, 93(11): 2862-2873.

涂其军, 李建康, 王刚, 马宏超. 2019. 中国西部主要伟晶岩型锂辉石矿床成矿作用对比及找矿前景[J]. 中国地质调查, 6(6):36-47.

王海宇. 基于深度语义分割的遥感影像伟晶岩脉信息提取研究[J]. 中国地质大学（北京）, 2021.

王核, 黄亮, 马华东, 等. 西昆仑大红柳滩-白龙山矿集区锂矿成矿特征与成矿规律初探[J]. 岩石学报, 2023, 39(07): 1931-1949.

熊欣, 李健康, 严清高. 四川扎乌龙伟晶岩型稀有金属矿床的成矿机制及找矿标志[J]. 岩石学报, 2024, 40(9): 2863-2877.

徐萍, 贾磊, 包虹剑, 等. 绿柱石可见-短波红外与热红外光谱特征研究及其对铍资源遥感勘查的启示[J]. 矿物学报, 2025.

张森, 鞠楠, 伍月, 等. 铍矿分布特点、主要类型与勘查开发现状[J]. 中国地质, 2023, 50(2): 410-424.