

基于二维卷积神经网络的智能金矿找矿预测方法

——以青海五龙沟地区为例

李金龙¹, 李 华², 薛林福^{1*}, 丁 可¹, 燕 群¹

(1. 吉林大学地球科学学院; 2. 青海省地质调查局)

摘要:随着新一代人工智能技术的突破,深度学习为矿产资源预测提供了新的技术范式。传统找矿方法在处理海量多元异构地质数据时,会面临空间分布不均、非线性关系复杂、特征提取效率低等难题。以五龙沟地区为研究对象,提出一种基于CNN2D模型的智能找矿预测方法,旨在解决多源数据融合与非线性特征挖掘难题。该方法融合了地质、物探、化探3种多元异构数据,设计并训练了二维卷积神经网络金矿找矿预测模型。结果表明:融合地质、化探、物探3种数据的预测效果最优,模型的准确率较高;预测区面积占全区面积10.13%,圈定的P03预测区、P05预测区、P07预测区具有良好找矿条件,可作为找矿靶区进一步布设探矿工程。通过野外调查并对比前人研究成果,认为预测结果符合成矿规律,具有良好的找矿潜力,进一步证明了本方法的有效性。本研究实现了CNN2D模型在高原复杂构造区的找矿应用,为深部矿产预测提供了可解释性强、泛化能力强的智能解决方案。

关键词:二维卷积神经网络;智能找矿;找矿预测;相对属性网格化;数据增强;五龙沟地区;参数对比

中图分类号:TD115 P618.51

文献标志码:A

文章编号:1001-1277(2025)07-0113-10

doi:10.11792/hj20250717

引 言

随着地质调查与矿产勘查的不断推进,地学领域已积累了海量多学科数据。传统找矿方法在处理海量多元异构地质数据时,会面临空间分布不均、非线性关系复杂、特征提取效率低等难题,导致其难以有效捕捉和表达这些关系^[1-2]。多因素相互作用使得地质现象的预测和解释变得更加困难,深度学习的结构及强大分析运算能力在剖析这些复杂地质作用的过程中具有得天独厚的优势^[3]。

随着新一代人工智能技术的突破,深度学习为矿产资源预测提供了新的科研范式。深度学习目前正在岩性识别^[4-5]、矿物图像识别^[6-8]、三维地质建模^[9-10]等领域获得了广泛应用。在找矿预测方面,大量的学者利用深度学习技术进行了研究。XIONG等^[11]为解决负样本的选择问题,采用正样本和未标记样本学习(PUL)算法,在福建西南部进行了铁多金属矿化区成矿潜力研究,获得了相比一类支持向量机(OC SVM)、人工神经网络(ANN)和逻辑回归(LR)

等算法更好的效果。李忠潭等^[12]采用将化探及航磁数据输入卷积神经网络(Convolutional Neural Network, CNN)模型的方法进行找矿预测,在甘肃龙首山地区圈定了5个具有良好找矿前景的铜矿预测区。DING等^[13]提出基于孪生神经网络,利用地质、地球化学和地球物理数据来克服训练样本不足的问题,并实现了一种基于孪生网络的监督式深度学习找矿预测方法。王建邦等^[14]提出了一种利用独热(ONE-HOT)编码与改进的残差神经网络结合化探数据进行找矿预测的方法,并在陕西石泉地区验证了其有效性。徐正林等^[15]提出了一种结合合成少数类过采样技术(SMOTE)和平衡随机森林(BRF)算法的SMOTified-BRF模型,并应用于陕西汉滨—旬阳地区的地球化学金矿化预测中,相较于传统BRF模型展现出更高的AUC值(ROC曲线与坐标轴围成的面积)和更精准的矿化区域圈定,有效解决了样本类不平衡问题并提升了预测性能。研究表明,应用深度学习可以有效识别地质数据的非线性特征,智能化预测矿产资源。

五龙沟地区位于青海省都兰县,成矿地质条件良

收稿日期:2025-01-22; 修回日期:2025-03-24

基金项目:青海省地勘资金科研项目(QDDJ/DKWX(SJZX)2023-08)

作者简介:李金龙(2000—),男,硕士研究生,研究方向为智能找矿预测;E-mail:2273947628@qq.com

*通信作者:薛林福(1962—),男,教授,博士,研究方向为数字地质科学;E-mail:xueli@jlu.edu.cn

好,矿产资源较为丰富,目前已在该地区进行了多个轮次、各种类型的矿产地质调查工作,形成了较为齐全的地质勘探资料^[16-21]。但是,由于该地区海拔高、地形切割强烈,新矿产资源发现难度大,在一定程度上限制了矿产地质调查工作的进一步开展。深度学习在找矿预测方面的应用为解决这一问题提供了良好的技术基础,为矿产预测提供了新方向。因此,本文以五龙沟地区为例,综合利用地质、化探、物探等数据,基于二维卷积神经网络(CNN2D)算法设计并建立了金矿智能找矿预测模型,智能圈定可进一步勘查的

预测区。

1 地质背景

研究区大地构造位置位于昆中地区(见图1)。区域地层由古元古界金水口岩群变质基性火山岩与镁质碳酸盐等共同构成了基底,北部以昆北断裂为界,与柴达木盆地相邻,南部以昆中断裂为界,与巴颜喀拉—松潘甘孜地块相接^[22-25],区域出露侵入岩以花岗岩为主。在矿产区划上,研究区属于东昆仑前寒武纪、晚古生代、中生代金铜铅锌铁成矿带。




图1 研究区大地构造位置图

Fig. 1 Geotectonic location map of the study area

研究区地层主要为古元古界金水口岩群、新元古界丘吉东沟组、奥陶系祁漫塔格群、二叠系浩特洛哇组、新生界油砂山组。研究区断裂及韧性剪切带发育,总体构造线呈北西向延伸,是重要的控矿构造^[24,26]。

研究区岩浆侵入活动强烈,侵入岩广布,以中性侵入岩为主,出露面积较大,约占全区面积的80%。岩石类型以花岗岩和闪长岩为主,有少量基性、超基性侵入岩,主要分布于研究区中东部和西南部,延伸方向与地区构造线方向一致^[26]。侵入岩的形成时间跨度较大,自寒武纪至三叠纪侵入岩均有出露,具有多期次特征。

研究区矿产资源丰富,自20世纪50年代以来,陆续进行了多项矿产普查工作,发现多处大中型矿床及大量矿化点^[19]。矿产种类多样,主要为金及多种有色金属。研究区已发现25个金矿床(点),成因类型主

要为构造蚀变岩型和热液型。

2 预测方法

2.1 CNN2D模型

CNN模型是在计算机视觉领域取得了巨大成功的深度学习模型。CNN模型能够自动提取特征,它的核心思想是利用局部连接和权值共享方式,大大减少模型参数量,提高计算效率^[27-29],这使得它在处理二维图像数据方面具有显著的优势。CNN模型经过多年的发展与改进,往往由输入层、卷积层、池化层、全连接层和输出层等5部分组成,通过不同组合达到最优智能化效果。

本文基于CNN模型设计实现了一种适用于金矿找矿预测的CNN2D模型,该模型由1个输入层、3个卷积层、3个池化层、1个全连接层和1个输出层组成(见图2)。




图2 CNN2D模型架构图

Fig. 2 Architecture diagram of CNN2D model

地质、物探、化探等数据不同于图像数据,数据的组织形式不统一,难以直接输入CNN2D模型中进行训

练和预测。因此,为了将不规则的地质数据转换成CNN2D模型能够处理的规则矩阵形式,需对地质、物

探、化探等数据进行网格化,然后对其进行标准化和归一化处理,去除噪声数据,形成规范的输入数据。

在 CNN2D 模型中,设计了 3 个卷积层,分别包含 32 个、16 个、8 个窗口尺寸为 3×3 的卷积核,这些不同数量的卷积核使得 CNN2D 模型能够捕捉数据的空间模式,从简单到复杂以充分提取不同矿床特征。为了能够表达输入数据更为复杂的非线性关系,CNN2D 模型的每个卷积层使用 $ReLU$ 激活函数(见式 1)来引入非线性关系,使得神经网络可以更好学习和表达数据中的复杂模式。

$$ReLU(x) = \max(0, x) \quad (1)$$

式中: x 为输入到激活函数的值,即卷积层输出的特征图元素值; $\max(0, x)$ 为 0 与 x 之间的较大值,若 $x > 0$,输出为 x ,若 $x \leq 0$,输出为 0,这一操作通过过滤负值并保留正值,为 CNN2D 模型引入非线性能力,使神经网络能够学习复杂的非线性关系。

为了降低数据的计算量,但又不丢失数据重要特征,CNN2D 模型在每个卷积层之后加入了池化层来对卷积层获取的特征图进行下采样。池化操作包含平均池化和最大池化 2 种。前人研究结果表明,采用最大池化往往能够获得比平均池化更优的学习效果。因此,本次研究采用 2×2 的最大池化,降低输入到下一个卷积层中的特征图尺寸。

CNN2D 模型为了减少对某些局部特征的过度依赖,降低过拟合风险,增加模型的鲁棒性,提升泛化能力,在全连接层前加入了“dropout(正则化)”操作,该操作以 10 % 的概率随机丢弃上层神经元。

通过多次卷积和池化操作后,CNN2D 模型建立全连接层将模型输出的特征图展平为一维向量,使每个神经元都能够关联上一层的所有神经元。最后,该模型进一步将输出结果转化为每个类别的概率值,概率值大于 0.5 或某个阈值的位置即为分类结果或预测结果。

2.2 方法流程

基于 CNN2D 模型,提出一种有监督的 CNN 智能找矿预测方法。该方法主要包括数据网格化与数据融合、训练样本数据集构建、训练模型及参数优化、预测与验证等主要步骤。

首先,对地质、化探、物探等数据进行了网格化处理。其次,为了扩大数据集的规模并提高数据的多样性和鲁棒性,增强模型的性能和泛化能力,该方法对网格化后的数据采用滑动窗口技术进行数据增强,形成训练样本数据集。最后,通过将训练样本数据集输入 CNN2D 模型进行训练,获得合适的模型参数,应用于研究区进行金矿找矿有利区圈定。基于 CNN2D 模型的找矿预测流程见图 3。




图 3 基于 CNN2D 模型的找矿预测流程

Fig. 3 Flowchart of prospecting predictions based on CNN2D model

1) 数据网格化与数据融合。

收集研究区内已有地质、化探和物探数据,由于这些数据是在空间上不均匀分布的数据,采用不同插值方法将其归算成规则网格中的代表值,进而对其进行网格化。本次研究将研究区划分为 $461(\text{列}) \times 357(\text{行}) = 164\,577$ 个网格单元,每个网格单元的大小为

$100\text{ m} \times 100\text{ m}$ (见表 1)。为了充分利用研究区的地质数据,本文采用相对属性网格化方法^[30]对 MapGIS 地质数据进行网格化,物探和化探数据分别采用克里格插值法进行网格化。网格化后的数据在标准化后进行叠加实现不同类型数据的融合。

2) 构建训练样本数据集。

表1 数据网格化标准

Table 1 Gridding standard of data

坐标	最小值/m	最大值/m	间距/m	节点数
x方向	724 544.90	770 534.12	100	461
y方向	3 988 505.24	4 024 154.13	100	357

在矿产预测中,已知矿床(点)的数量通常较少,




图4 滑动窗口数据增强方法原理图

Fig. 4 Mechanism diagram of the sliding window data augmentation method

3) 训练CNN2D模型及参数优化。

根据生成的训练数据集建立CNN2D模型,80%样本数据(训练数据集)用于模型训练,20%样本数据(验证数据集)用于模型验证。利用训练数据集对模型进行训练,采用不同参数和超参数对模型进行训练,通过验证数据集选取最优模型。

4) 应用CNN2D模型预测金矿找矿有利区。

对研究区通过滑动窗口方式进行预测,圈定金矿找矿有利区,窗口滑动的步长设定为1。

5) 验证预测结果。

根据矿产地质资料及成矿规律,分析预测结果的可靠性,从而进一步确定预测区。

3 试验与讨论

3.1 数据与数据处理

为验证CNN2D模型的效果,本文选择了五龙沟地区作为试验区,利用地质、化探和物探数据进行预测区的圈定,并分析地质条件。

3.1.1 地质数据

地质图集成了大量地质工作者对该地区的认识,是重要的找矿预测数据。但是,收集到的地质图往往包含同一地质单元分割为不同区、飞点、弧段未完全相交、地质单元属性信息不完整等不规范之处,因此需要对地质图进行编辑修改和补充完善,再通过地质图网格化方法将地质图转换为CNN2D模型可以使用的数据。

地质图网格化是将地质信息应用于智能找矿预测

难以满足深度学习对训练样本数量的需求。为了应对这一挑战,本研究采用滑动窗口数据增强方法(见图4)扩展训练样本集,增加数据集的规模^[31]。通过这一方法,将包含金矿床(点)和含矿钻孔点的窗口标记为正样本,反之标记为负样本。将采用数据增强方法产生的正负样本混合,打乱顺序并进行随机划分,形成训练数据集,这样可以得到泛化能力更强的网络,增加结果的可靠性。

的关键步骤。通过地质图网格化方法可将地质图表示的信息转化为CNN2D模型能够使用的多维数组形式。本研究采用指数函数对地质图的地质边界(弧段)、断裂进行网格化,每个弧段对应1个网格化层,网格化层上每个网格单元的值(I)可由式(2)计算。

$$I = ae^{-by} \quad (2)$$

式中: I 为影响强度,该值越大,表明与成矿的关系越密切; a 为影响幅度值,通常取1.0; b 为衰减系数,该值越大衰减速率越快; y 为每个网格单元距地质要素的距离。

以断裂影响强度为例,对研究区某条断裂,求取各网格单元与断裂之间的最短距离,根据式(2)计算断裂对每个网格单元的影响强度,依次可计算出研究区内所有断裂影响强度。

与断裂影响强度的计算方法相似,提取研究区的地质界线,并计算其影响强度,结果见图5-a)。由图5-a)可知:高值区均分布于金水口岩群、中三叠世侵入岩中,金矿床(点)主要分布于中—高影响强度带或过渡带上。地质界线高影响强度带主要呈北西向展布,与区内构造格架展布方向一致。五龙沟地区复杂的多期地质构造演化过程为金矿床(点)形成创造了有利的地质条件。

断裂影响强度见图5-b)。由图5-b)可知:中等成矿影响强度带主要沿断裂发育;较高成矿影响强度带主要分布于断裂中心、多条断裂和韧性剪切带的交会部位。具有高影响强度的断裂主要沿研究区东部的北西向韧性剪切带发育。研究区内韧性剪切带的




图 5 成矿影响强度与金矿关系图

Fig. 5 Diagram for the relationship between metallogenic influence intensity and gold deposits


影响强度最高,断裂交会部位影响强度呈现为中等,金矿床(点)主要分布于高影响强度带与中影响强度带。

在相对属性网格化基础上生成的断裂影响强度图、地质界线影响强度图可以很好揭示矿床(点)与断裂、地质界线的空间关系,为下一步找矿分析预测提供依据。

3. 1. 2 化探数据

化探数据能够直接反映研究区元素分布状态。对收集到的 Ag、As、Au、Bi、Cd、Co、Cr、Cu、Fe、Hg、Mo、Ni、Pb、Sb、Sn、Ti、V、W、Zn 等共 19 种元素水系沉积物测量数据进行网格化处理,采用的方法主要是克里格插值法^[32]。已知金矿床(点)与各元素的关系显示,研

究区 Au、Cu、Mo、Zn、Co、As 等 6 种元素对金矿的找矿指示作用较大,其元素地球化学等值线图见图 6。由图 6 可知:这些元素的地球化学异常分布面积大、形态规整、强度高、组合齐全、浓度分带明显且套合性较好。异常多分布在构造及侵入岩发育的地质环境中。异常的长轴延伸方向由西往东呈北西向近等间距串珠状断续展布,反映出北西向韧性断裂对异常的显著控制作用,暗示该地区具有良好的找矿远景区。结合金矿床(点)与化探异常的关系,认为金矿床(点)在西北部深水潭地区分布最为密集,Au、Zn、Mo、Cu、Co、As 的化探高值区与金矿床(点)的空间位置吻合程度较高。这 6 种元素的化探高值区与其他零散分布的金矿床(点)空间吻合度亦较高。



a—Au 元素地球化学等值线图 b—Cu 元素地球化学等值线图 c—Mo 元素地球化学等值线图 d—Zn 元素地球化学等值线图 e—Co 元素地球化学等值线图 f—As 元素地球化学等值线图

图 6 研究区主要元素地球化学等值线图


Fig. 6 Geochemical contour map of major elements in the study area

3.1.3 物探数据

根据磁偏角和磁倾角,对研究区的地磁测量数据进行了化极处理和100 m、300 m、500 m、1 000 m和2 000 m向上延拓变换,结果见图7。将6种地磁数据按照表1的标准进行网格化,得到6种地磁数据的网格化数据。

地磁异常综合图见图7。由图7-a可知:研究区

金矿床(点)多分布于磁异常梯度带或磁异常高值区的边缘,与磁异常关系密切;北西向条带状磁异常主要由中二叠世二长花岗岩引起,该区域分布的金水口岩群地层表现为中等强度磁异常,与成矿有关的多条韧性剪切带、脆性断裂多分布在金水口岩群地层中。研究区磁异常分布及其与古元古代地层的关系到下一步找矿预测具有指导意义。



a—化极地磁异常图 b—向上延拓100 m异常图 c—向上延拓300 m异常图 d—向上延拓500 m异常图 e—向上延拓1 000 m异常图 f—向上延拓2 000 m异常图

图7 地磁异常综合图

Fig. 7 Comprehensive map of geomagnetic anomalies

由图7-b~f可知:随着上延高度由100 m增加到2 000 m,浅部地质体的磁性差异对于区域整体磁异常形态的影响逐渐消除。高磁异常主要分布在2处区域,即深水潭北西向展布异常带、大水沟东沟北西向展布异常带。这2处磁异常区反映了基底磁性地质体的分布区域。金矿床(点)主要分布在高磁性地质体引起的磁异常梯度带附近。

3.2 试验结果

软件及硬件试验环境见表2。

表2 软件及硬件试验环境

Table 2 Software and hardware configurations for the testing

参数	规格
CPU	i9-12900KF
内存	128 G
GPU	NVIDIA GeForce RTX 3090 24G
CUDA 版本	8.0
深度学习框架	Keras 作为前端, TensorFlow2.0 为后端

本文使用CNN2D模型对研究区进行金矿预测。对研究区内的地质、化探和物探数据按照表1的标准进行网格化处理,作为模型的输入层。

模型包含3个卷积层,为减少网络参数数量和计算复杂度,同时提高网络的泛化能力和训练效率,卷积核的数量逐层递减:第一层为64个,第二层为32个,第三层为16个。每个卷积层的卷积核大小均为3×3。池化层采用最大池化方法,池化窗口尺寸为2×2。

研究区内共有25个金矿床(点)。通过数据增强方法,共生成了20 680个训练数据,其中,80%(16 544个)用于训练,20%(4 136个)用于验证。

使用上述参数和数据集对模型进行训练和验证,共进行了100轮训练。在40轮训练后,模型逐渐趋于稳定,最终模型的准确率达到了98.1%(见图8)。

3.2.1 窗口尺寸对预测结果的影响

窗口尺寸对训练数据集大小、模型性能、计算速度等都有显著影响。窗口越小、训练数据集数量越少,越可能丢失地层、断裂、化探异常等一些重要的信息,导致模型学习能力下降。相反,窗口大、训练数据集数量多,会增加模型的计算复杂度,导致模型过拟合或训练困难。为了获得合适的窗口尺寸,本文在试验中分别使用8×8、12×12、14×14、16×16、20×20、24×24共6种窗口尺寸进行预测,结果见图9。





图8 基于CNN2D模型的准确率曲线

Fig. 8 Accuracy curve based on CNN2D model



a—窗口尺寸为8×8 b—窗口尺寸为12×12 c—窗口尺寸为14×14 d—窗口大小为16×16 e—窗口尺寸为20×20 f—窗口尺寸为24×24

图9 不同窗口尺寸预测结果图

Fig. 9 Diagram of prediction results based on varying window sizes

模型可能出现欠拟合现象;当正负样本比值较小时,模型偏向预测负样本,可以达到很高的准确率,但可能会出现过拟合现象。结合地质数据资料分析,当正负样本比为1:6时,预测效果最好,故选用1:6作为正负样本比。

3.2.3 不同数据集对预测结果的影响

为了比较不同数据集对预测结果的影响,选取化探数据、物探数据、化探数据+物探数据、化探数据+物探数据+地质数据等进行对比分析,结果见图11。

由图11可知:仅使用化探数据、物探数据的预测结果与自身异常对应较好,但部分已知金矿床(点)与金矿找矿有利区相距较远,故不能将其用作最终预测数据集。化探数据+物探数据预测结果不能将已知金矿床(点)包括进金矿找矿有利区中,预测效果较差。结合地质资料分析可得,研究区地质因素影响较大,

由图9可知:当窗口尺寸为16×16时,总预测面积占比10.13%,预测区训练数据集数量适中,随机剔除几个矿点后的金矿找矿有利区包含已剔除的矿点,预测效果较好。故选用窗口尺寸为16×16。

3.2.2 正负样本比对预测结果的影响

在CNN2D模型中,正负样本比通常指训练数据集中正样本和负样本的比例。本文通过随机抽取未知区域来构建负样本数据。不同正负样本比对模型预测结果产生不同的影响。

不同正负样本比预测结果见图10。由图10可知:当正负样本比较大时,可以得到更大的预测面积,


故化探数据+物探数据不能全面反映金矿找矿有利区实际情况。综上,应采用化探数据+物探数据+地质数据的数据集。

综合分析不同超参数及数据集的影响,最终选择窗口尺寸为16×16,正负样本比1:6的超参数,采用化探数据+物探数据+地质数据的数据集进行结果预测。

4 预测结果分析与可靠性验证

4.1 预测结果及地质分析


基于CNN2D模型的预测结果见图12。预测区面积占全区面积10.13%,主要位于研究区东北部中支沟、深水潭附近,大园山附近也有一部分预测区。考虑到地质情况和已有商业探矿权设置,认为P03预测区、P05预测区、P07预测区具有良好找矿条件,可作为找矿靶区进一步布设探矿工程。



a—正负样本比为1:2 b—正负样本比为1:3 c—正负样本比为1:4 d—正负样本比为1:5 e—正负样本比为1:6 f—正负样本比为1:7

图10 不同正负样本比预测结果

Fig. 10 Prediction results based on varying positive and negative sample ratios



a—化探数据 b—物探数据 c—化探数据+物探数据 d—化探数据+物探数据+地质数据

图11 不同数据集预测结果图

Fig. 11 Diagram of prediction results based on varying data sets

P03 预测区:位于研究区北侧的戈壁滩西北部,主要出露金水口岩群。整体走向北西,倾向北东。利用特征相似性类比方法,该预测区地质条件与萤石沟—红旗沟剪切带内的岩金沟金矿床等金矿床(点)的成矿地质条件极为相似,应属于同一成矿系列,只是不同位置的矿化强度不相同,导致矿床规模不同。结合研究区成矿地质条件等,认为该预测区具备良好的成矿地质条件。

P05 预测区:呈孤岛状,出露地层为金水口岩群,岩性组合以各类片麻岩为主,夹有条带状大理岩,斜长角闪岩次之。侵入岩为晚志留世中粒花岗闪长岩。该预测区东部为智能断裂识别区,有能够反映断裂存在的磁异常,推测该预测区东部断裂发育并存在热液成矿有利区。

P07 预测区:出露地层为金水口岩群,花岗岩脉发育,强烈的岩浆活动不仅提供了热源,还携带了成

矿物质,通过热液交代作用在围岩中形成矿体。该预测区紧邻北西向智能断裂识别区,由主断裂派生的次级断裂发育,为成矿热液提供了运移通道和沉淀空间。该预测区与Au、As等元素异常套合较好,同时位于较高的磁异常内,反映隐伏岩体或矿化蚀变为有利找矿部位。

4.2 预测结果的可靠性与精度

在采用CNN2D模型及优化参数情况下,由地质、化探和物探数据构成的验证数据集(占学习数据集的20%)获得的模型识别准确率为98.1%。预测区面积占全区面积10.13%,已知金矿床(点)的覆盖率>95%,并且能够在有金矿床(点)和开展了勘查项目的区域之外发现新找矿靶区。通过向专家咨询,认为这些找矿靶区具有良好的找矿潜力。综合分析认为,预测结果进一步证明了本方法的有效性。本研究首次实现了CNN2D模型在高原复杂构造区的找矿应




图 12 基于 CNN2D 模型的预测结果

Fig. 12 Prediction results based on CNN2D model

用,为深部矿产预测提供了可解释性强、泛化能力高的智能解决方案。

5 结 论

- 1)基于CNN2D模型的金矿智能找矿预测方法在五龙沟地区的应用表明,该方法可以有效融合地质图、化探、物探等多元异构数据,能够快速、高效地圈定金矿找矿有利区,提高了找矿预测的效率。
- 2)不同的样本窗口尺寸、正负样本比、数据源丰富程度等对模型的预测结果影响较大。试验结果表明,窗口尺寸为16×16、正负样本比为1:6、数据类型越多,预测结果越理想。
- 3)基于CNN2D模型圈定了3处预测区,综合地质特征及成矿地质条件,认为预测区可为进一步开展金矿找矿提供方向。

[参 考 文 献]

[1] 严光生,薛群威,肖克炎,等.地质调查大数据研究的主要问题析[J].地质通报,2015,34(7):1 273-1 279.
[2] 于晓飞,吕志成,孙海瑞,等.全国整装勘查区成矿系统研究与矿

产勘查新进展[J].吉林大学学报(地球科学版),2020,50(5): 1 261-1 288.
[3] 左仁广.基于深度学习的深层次矿化信息挖掘与集成[J].矿物岩石地球化学通报,2019,38(1):53-60.
[4] ZHENG D Y, ZHONG H T, CAMPS-VALLS G, et al.Explainable deep learning for automatic rock classification [J].Computers & Geosciences,2024,184:105511.
[5] 管耀,王清辉,冯进,等.基于机器学习的蚀变火成岩测井综合岩性识别——以南海北部珠江口盆地惠州26-6井区为例[J].吉林大学学报(地球科学版),2024,54(1):345-358.
[6] 王婷婷,黄志贤,王洪涛,等.基于MobileNetV2的岩石薄片岩性识别[J].吉林大学学报(地球科学版),2024,54(4):1 432-1 442.
[7] AGRAWAL N, GOVIL H. A deep residual convolutional neural network for mineral classification[J].Advances in Space Research, 2023,71(8):3 186-3 202.
[8] 吴博,李永胜,王睿,等.基于自训练的多标签岩石薄片分类方法[J].黄金,2024,45(2):61-67.
[9] CHEN G H, LIU Z K, CHEN G D, et al.Deep gold prospectivity modeling in the Jiaojia gold belt, Jiaodong Peninsula, eastern China using machine learning of geometric and geodynamic variables [J]. Frontiers in Earth Science,2024,12:1308426.
[10] HILLIER M, WELLMANN F, DE KEMP E A, et al.GeoINR 1.0:

- An implicit neural network approach to three-dimensional geological modelling [J]. *Geoscientific Model Development*, 2023, 16 (23): 6 987–7 012.
- [11] XIONG Y H, ZUO R G. A positive and unlabeled learning algorithm for mineral prospectivity mapping [J]. *Computers & Geosciences*, 2021, 147: 104667.
- [12] 李忠潭, 薛林福, 冉祥金, 等. 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[J]. *吉林大学学报(地球科学版)*, 2022, 52(2): 418–433.
- [13] DING K, XUE L, RAN X, et al. Siamese network based prospecting prediction method: A case study from the Au deposit in the Chongli mineral concentrate area in Zhangjiakou, Hebei Province, China [J]. *Ore Geology Reviews*, 2022, 148: 105024.
- [14] 王建邦, 薛林福, 于晓飞, 等. 基于地质图编码及深度残差网络的找矿预测方法——以陕西石泉地区金矿为例[J]. *黄金*, 2023, 44(12): 55–63.
- [15] 徐正林, 王晰, 薛林福, 等. 基于SMOTified-BRF模型的地球化学金矿化异常预测研究——以陕西汉滨—旬阳地区为例[J]. *黄金*, 2025, 46(1): 11–19.
- [16] 陈柏林. 东昆仑五龙沟金矿田地质特征与成矿地质体厘定[J]. *地质学报*, 2019, 93(1): 179–196.
- [17] 陈柏林, 王永, 韩玉, 等. 东昆仑五龙沟矿田岩金金矿床成矿时代新认识[J]. *矿床地质*, 2019, 38(3): 541–556.
- [18] 李君阳, 薛春纪, 王斌, 等. 东昆仑五龙沟金矿田平台岩体岩相学、年代学、地球化学特征及其构造意义[J]. *地球科学与环境学报*, 2023, 45(5): 1 176–1 191.
- [19] 赵昌新. 青海省都兰县五龙沟地区红旗沟—深水潭金矿区详查报告[R]. 海东: 青海省第一地质矿产勘查院, 2010.
- [20] 于涛. 东昆仑五龙沟地区打柴沟金矿地质特征及矿床成因[D]. 长春: 吉林大学, 2022.
- [21] 赵伟策, 赵晓波, 赵呈祥, 等. 东昆仑五龙沟金成矿系统: 基本特征、成矿控制与勘查标志[J]. *地质科学*, 2023, 58(2): 635–661.
- [22] ZHANG M, LIU Y, CHEN A, et al. The tectonic links between Palaeozoic eclogites and mafic magmatic Cu–Ni–Co mineralization in East Kunlun orogenic belt, western China [J]. *International Geology Review*, 2023, 65(7): 1 158–1 178.
- [23] 李厚民, 沈远超, 胡正国, 等. 青海东昆仑五龙沟金矿床成矿条件及成矿机理[J]. *地质与勘探*, 2001, 37(1): 65–69.
- [24] 张健, 张正虎, 李小亮, 等. 东昆仑造山带东段色日金矿床地质特征及成因[J]. *黄金*, 2025, 46(2): 62–71.
- [25] 张宇婷. 青海东昆仑中段五龙沟矿集区金矿成矿作用研究[D]. 长春: 吉林大学, 2018.
- [26] 李华, 蒋少涌, 李世金, 等. 东昆仑造山带岩浆型镍钴矿床地质特征、成因机制与找矿标志分析[J]. *岩石学报*, 2023, 39(4): 1 041–1 060.
- [27] 李涛, 孙琰, 侯建硕, 等. 人工智能在矿山设备预测性维护中的应用研究[J]. *黄金*, 2025, 46(1): 1–5, 19.
- [28] 胡荣华, 安冬, 史梦圆, 等. 智能矿用机器人研究现状及发展趋势[J]. *黄金*, 2023, 44(9): 59–68.
- [29] 冯国庆, 莫海帅, 吴宝峰. 基于U-Net和CNN深度学习求取地质属性建模变差函数参数[J]. *石油地球物理勘探*, 2024, 59(4): 692–701.
- [30] 薛林福, 冉祥金, 于晓飞, 等. 一种地质图的向量化表示方法: 202110068210.4[P]. 2021–05–14.
- [31] DING K, XUE L, RAN X, et al. CNN2D–SENet-based prospecting prediction method: A case study from the Cu deposits in the Zhunuo mineral concentrate area in Tibet [J]. *Minerals*, 2023, 13(6): 730.
- [32] 杨明莉. 基于深度学习的重磁地质解释方法研究[D]. 长春: 吉林大学, 2022.

Intelligent gold prospecting prediction based on 2D convolutional neural networks

—A case study of the Wulonggou area, Qinghai

Li Jinlong¹, Li Hua², Xue Linfu¹, Ding Ke¹, Yan Qun¹

(1. College of Earth Sciences, Jilin University; 2. Qinghai Geological Survey)

Abstract: With breakthroughs in next-generation artificial intelligence technologies, deep learning has introduced a novel paradigm for mineral resource prediction. Traditional prospecting methods often encounter challenges when handling large-scale, heterogeneous geological datasets, such as uneven spatial distribution, complex nonlinear relationships, and low feature extraction efficiency. Taking the Wulonggou area as a case study, this paper proposes an intelligent gold prospecting prediction method based on the CNN2D model, aiming to address the integration of multi-source data and the mining of nonlinear features. The method integrates 3 types of heterogeneous data—geological, geophysical, and geochemical—and designs and trains a CNN2D model for gold prospecting prediction. Results show that the model achieves the best prediction performance when all 3 data types are integrated, with high accuracy. The predicted area accounts for 10.13 % of the total study area, with the delineated targets P03, P05, and P07 exhibiting favorable metallogenic conditions, making them viable targets for further exploration. Field investigations and comparison with previous research indicate that the prediction results are consistent with known metallogenic patterns and demonstrate strong prospecting potential, further validating the method’s effectiveness. This study marks application of the CNN2D model for prospecting in a complex tectonic region on the plateau, offering an interpretable and generalizable intelligent solution for deep mineral prediction.

Keywords: 2D convolutional neural network; intelligent prospecting; prospecting prediction; relative attribute gridding; data augmentation; Wulonggou area; parameter comparison