

DOI:10.3969/j.issn.1003-5060.2025.10.009

基于 ResNet-18 的三维成矿预测方法研究

陈宇恒^{1,2}, 李晓晖^{1,2}, 袁峰^{1,2}, 薛晨^{1,2}, 谢先岗^{1,2}, 郑超杰^{1,2}

(1. 合肥工业大学 资源与环境工程学院, 安徽 合肥 230009; 2. 安徽省矿产资源与矿山环境工程技术研究中心, 安徽 合肥 230009)

摘要:目前深部隐伏矿床成为中国东部地区主要找矿目标,利用基于卷积神经网络(convolutional neural network, CNN)的三维成矿预测方法能够更好地圈定找矿靶区,指导进一步勘探。文章以安徽省宣城市茶亭地区为研究实例,开展基于 ResNet-18 残差网络(residual network, ResNet)的三维成矿预测方法研究。结果表明:基于 ResNet-18 的深层预测模型的训练准确率为 99.62%;相较于逻辑回归模型和基于 LeNet-5 的预测模型,基于 ResNet-18 的三维预测模型能够在更小的成矿远景区范围内预测出更多的矿化单元,具备更优异的预测能力,可为三维成矿预测研究提供更强大的数据综合工具。

关键词:三维卷积神经网络(3DCNN);残差网络(ResNet);三维成矿预测;茶亭地区

中图分类号:P618.2 **文献标志码:**A **文章编号:**1003-5060(2025)10-1357-07

Research on three-dimensional mineral prospectivity modeling using ResNet-18

CHEN Yuheng^{1,2}, LI Xiaohui^{1,2}, YUAN Feng^{1,2}, XUE Chen^{1,2}, XIE Xiangang^{1,2}, ZHENG Chaojie^{1,2}

(1. School of Resources and Environmental Engineering, Hefei University of Technology, Hefei 230009, China; 2. Anhui Province Engineering Research Center for Mineral Resources and Mine Environments, Hefei 230009, China)

Abstract: Currently, deep-seated concealed ore deposits have become the primary exploration target in the eastern region of China. The convolutional neural network(CNN) based three-dimensional mineral prospectivity modeling methods can better delineate favorable exploration areas for mineralization and guide further exploration. This paper focuses on the Chating district in Xuancheng City, Anhui Province, and conducts research on three-dimensional mineral prospectivity modeling using ResNet-18. The results show that the deep prediction model based on ResNet-18 achieves a training accuracy of 99.62%. Compared to the logistic regression model and the prediction model based on LeNet-5, it can predict more mineralized units within a smaller mineral prospectivity area, demonstrating superior predictability. Therefore, it can provide a more powerful data integration tool for research on three-dimensional mineral prospectivity modeling.

Key words: three-dimensional convolutional neural network(3DCNN); residual network(ResNet); three-dimensional mineral prospectivity modeling; Chating district

矿产资源是实现社会经济平稳发展的重要基础。成矿预测作为矿产勘查的先导环节,是提高矿产勘查工作效率的有效手段^[1]。随着计算机科学的不断发展,基于综合信息的成矿预测方

法成为主流,这种方法通过构建不同类型的数学模型,能够高效地整合和分析多源异构的预测信息,进而准确地识别控矿和矿化指示特征、圈定找矿远景区^[2-3]。近年来,人工智能相关方法在诸多

收稿日期:2023-07-12; **修回日期:**2025-09-10

基金项目:地球深部探测与矿产资源勘查国家科技重大专项资助项目(2025ZD1007402);国家自然科学基金资助项目(42230802; 42072321)

作者简介:陈宇恒(1997—),男,江苏南通人,合肥工业大学硕士生;

李晓晖(1986—),男,河北定州人,博士,合肥工业大学教授,博士生导师,通信作者, E-mail: lxhlixiaohui@163.com;

袁峰(1971—),男,广西桂林人,博士,合肥工业大学教授,博士生导师。

行业内飞速发展,大数据和人工智能算法也在逐渐改变地质学的研究方式^[4]。其中,机器学习方法由于其具有非线性的学习能力,能够在不断训练模型和拟合参数的过程中表征潜在的复杂特征,因此被广泛认为能够有效支撑成矿预测方法的进一步发展与应用^[5]。

目前,随着中国东部地区浅部(500 m 以浅)矿产资源被发现殆尽^[6],深部矿、隐伏矿已成为勘查的主要对象^[7]。然而,传统的二维成矿预测主要依赖于地表的地球物理、地球化学、遥感等数据开展,由于深部矿床在地表的地球物理、地球化学、遥感异常方面显示较弱,相对于浅部矿床勘探难度更大,且勘查工程成本较高,地质信息量相对较少,因此越来越难以用二维成矿预测方法对深部隐伏矿床进行有效预测^[8]。相较于二维成矿预测,三维成矿预测通过利用三维地质建模和三维空间分析等方法,能获取更全面的空间预测信息,已被成功应用于多个地区深部隐伏矿床的找矿预测,取得了显著找矿成果^[9]。近年来,机器学习方法也被逐步应用于三维成矿预测研究中^[10],但是,已有研究在处理空间特征时往往会忽略三维结构信息,从而增加了预测的不确定性。

深度学习是机器学习领域的热点方法,已在二维成矿预测领域应用广泛^[11]。其中,卷积神经网络(convolutional neural network, CNN)是深度学习的代表性算法,而三维 CNN(3DCNN)可以有效避免三维成矿预测中数据降维问题。3DCNN 可以综合数据之间的空间关联性以及结构特征,通过深度网络提取高维度特征信息,已有研究者基于 3DCNN 在三维成矿预测领域开展初步的研究,结果显示 3DCNN 在成矿预测方面具有较好的预测能力和研究潜力^[12-13]。但是,上述研究只是采用结构较简单的 LeNet-5 模型进行预测,对于复杂的三维成矿预测任务,由于缺乏足够的参数量和网络深度来捕获丰富的空间特征和空间关联,导致其预测精度下降和不确定性增加^[14]。因此,如何设计更有效的 3DCNN 结构,以提取更深层的控矿和矿化指示特征,提高 3DCNN 的分类精度和稳定性,亟需深入研究。

本文开展基于 ResNet-18 残差网络(residual network, ResNet)的三维成矿预测方法研究,采用安徽省宣城市茶亭地区的实例数据进行验证,并与传统的逻辑回归预测模型和基于 LeNet-5 的预测模型^[13]进行比较,旨在为三维成矿预测方法体系的进一步发展提供新的思路和方法,促进三

维成矿预测方法的实践应用,进而实现找矿突破。

1 三维成矿预测方法

1.1 CNN 算法

CNN 是一类包含卷积计算且具有深度结构和逐层预训练机制的神经网络,是深度学习的代表算法之一,已广泛应用于目标检测、图像处理、语音识别等领域^[15]。受到动物视觉皮层组织的启发,CNN 采用多层感知从数据中挖掘抽象的特征表示,特点在于每一层所学习到的信息都是基于上一层特征图学习得到的,因此能够提取更加深层次的特征。同时,CNN 通过共享权重和局部感知野的设计,能够有效处理大规模数据,并具有较强的适应性和泛化能力。另外,CNN 还具有灵活的网络结构,可以通过增加深度和宽度来增加模型的表达能力,并通过训练过程中的参数优化来提高预测性能。

3DCNN 的基本结构与二维卷积神经网络(2DCNN)相似,包含输入层、卷积层、池化层和全连接层等组件。然而,与 2DCNN 不同的是,3DCNN 在卷积操作中同时考虑 3 个方向上的邻近像素,使得网络能够学习到数据在时间或空间上的特征关系^[16]。

在三维成矿预测中,预测信息(地质、地球物理、地球化学等信息)通常以三维网格单元形式表示,每个单元包含地质属性和特征信息,例如岩性、地球物理属性和地球化学数据等。这些数据通常具有三维空间关系,如地质信息包括地层分布、地下结构和地质演化等。然而在传统的三维成矿预测中,大多都会将这些数据转化为一维的属性向量,尽管运算速度会大幅提高,但在降维过程中,数据特征在某些维度上的变化和差异可能被合并或忽略,这可能导致模型在处理数据时无法充分考虑各个维度之间的关系和权重,进而增加预测结果的偏差和不确定性。3DCNN 能够支持三维网格数据的输入,便于预测模型从数据中提取空间上的特征结构关系,因此将其在三维成矿预测中应用可能有助于提高预测结果的准确性^[12-13]。

1.2 基于 ResNet-18 的三维预测模型

残差网络(ResNet)是由何恺明等提出的一种深度卷积神经网络架构,旨在解决训练过程中出现的梯度消失和梯度爆炸等问题^[17]。网络中所包含的残差结构如图 1 所示,可以让网络在不断增加卷积层数的同时提升模型的准确率,其中

批标准化 (batch normalization, BN) 层通过归一化中间结果来稳定训练并提升泛化, ReLU 激活函数则在引入非线性特征表示的同时保持高效计算。深部矿、隐伏矿一般会经历多次地质演化,成矿过程受到多级地质结构的影响,地质异常也会呈现不同级别^[5]。残差结构允许跨层级传递信息,可以有效地重用、整合不同尺度和层级的特征,有助于多尺度预测信息的融合。

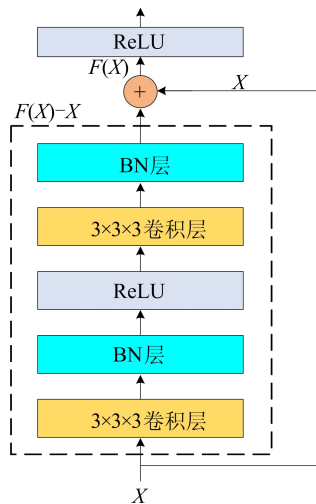


图 1 残差单元结构

残差结构^[16]可以表示为:

$$Y_n = h(X_n) + F(X_n, W_n) \quad (1)$$

$$X_{n+1} = G(Y_n) \quad (2)$$

其中: X_n 、 X_{n+1} 分别为第 n 个残差单元的输入和输出; F 为残差函数; W_n 为卷积核参数; $h(X_n)$ 为 X_n 的恒等映射; G 为 ReLU 激活函数。相比于学习一个复杂的映射函数,让网络学习恒等映射的残差会变得更简单。

本文选用 ResNet-18 网络作为 3DCNN 架构,其包含 17 个卷积层和 1 个全连接层,所采用的网络架构如图 2 所示。




图 2 ResNet-18 网络结构

每个残差模块中包含 2 个残差单元,而每个残差单元中都有 2 个卷积层。同时,为了解三维的地质空间数据,本文将网络中的卷积核修改为

三维形式,如图 3 所示,以此让模型更充分地提取三维预测信息中的空间结构特征,从而更好地捕捉控矿要素与成矿事实之间复杂的空间关联。




图 3 三维卷积结构

2 实例验证

2.1 数据基础

文献^[13]基于 LeNet-5 开展茶亭地区的三维成矿预测研究,建立了三维地质模型,并圈定了找矿靶区。该预测区域被划分为规则六面体网格,单个三维块体单元尺寸为 $100\text{ m} \times 100\text{ m} \times 25\text{ m}$,共计 4 452 800 个块体单元参与分析预测,所构建的三维模型东西方向长度为 23 000 m,南北方向宽度为 16 000 m,垂直覆盖地表 25 m 至地下 -3 000 m。为了将基于 ResNet-18 的三维成矿预测模型和基于 LeNet-5 的预测模型进行对比研究,本文采用与文献^[13]一致的数据基础。

2.1.1 地质背景

茶亭地区位于长江中下游构造-岩浆-成矿带东部,属于下扬子板块和江南板块的交界地带,区内岩浆活动频繁,断裂与褶皱发育,有大规模推覆构造^[18]。茶亭地区被大面积第四系沉积地层覆盖,出露地层主要为志留系—三叠系地层及部分陆相碎屑岩、火山碎屑岩^[19]。区内构造以狸桥背斜为主,断层方向主要为东北、西北方向。区内发育喷溢相-浅成侵入相中酸性岩石,其中浅成侵入相岩石主要为花岗斑岩、闪长玢岩、花岗闪长岩、花岗闪长斑岩、辉石闪长岩等^[20]。

目前,茶亭地区内已发现茶亭、荞麦山、长山、茶山、双井等矿床^[21],矿床类型以斑岩型和矽卡岩型矿床为主。其中,以茶亭地区北部的茶亭斑岩型铜金矿床(下文简称“茶亭矿床”)和茶亭地区西南部的荞麦山矽卡岩型铜钨矿床(下文简称“荞麦山矿床”)为主要代表,规模也最大^[18]。茶亭矿床为该区近年来发现的大型斑岩型铜金矿床,矿床内地层主要为志留系到白垩系上统,赋矿岩体

为早白垩系斑状石英闪长岩;矿床铜金属量约 5.3×10^5 t,平均品位 0.52%;金金属量约 79 t,平均品位 0.77 g/t^[22]。荞麦山矿床是区内发育的典型矽卡岩型铜钨矿床;其位于荞麦山—茶山倒转背斜的南西倾伏端,矿区主要出露上泥盆统、中上石炭统、上二叠统和第四系地层单元;侵入岩岩体平行于褶皱轴沿断裂带狭长形展布,岩体呈层状、树枝状分布,接触交代作用和热变质作用强烈,主要由斜长石、钾长石、石英、角闪石、黑云母、榍石及少量辉石、磷灰石、磁铁矿等组成;矿体主要赋存于燕

山晚期花岗闪长斑岩与石炭系灰岩接触带;矿床铜金属量约 5.9×10^4 t,钨金属量约 8.3×10^3 t^[23]。

2.1.2 三维地质模型

本文三维地质模型采用若干幅覆盖全区、依靠地质与地球物理数据综合解释的地质剖面图、地质平面图以及钻孔数据等进行约束和构建,建模细节详见文献[13],这些数据共同描述了茶亭地区深部地质结构。三维地质模型如图 4 所示。从图 4 可以看出研究区内各地层的埋深、厚度、形态以及相互之间的接触关系。

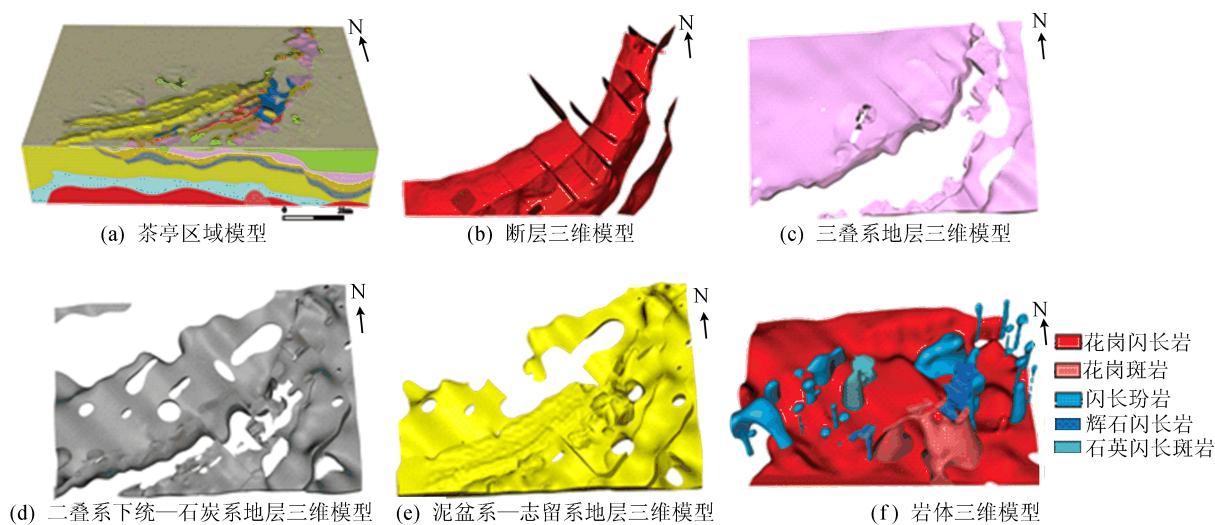


图 4 茶亭地区及各地质体模型

2.1.3 三维预测数据集

本文将三维预测空间划分为相同大小的立方体单元网格,用于承载区域内的三维预测信息,以此定义地层、岩体的三维空间分布特征。在总结研究区域沉积单元、侵入岩体、构造、地球物理特征,认识研究区的地质结构构造特征的基础上,针对斑岩型-矽卡岩型矿化,选择与文献[13]一致的三维成矿概念模型,并采用相同的三维空间分析方法进行数据提取,具体见表 1 所列。

表 1 斑岩型-矽卡岩型三维成矿概念模型及控矿要素提取方法

类别	三维控矿要素	要素提取方法
成矿有利地层	石炭系上统黄龙组 (C ₂ h)、船山组 (C ₂ P ₁) 地层,二叠系中统栖霞组地层 (P ₁ q),三叠系下统殷坑组 (T ₁ y)、和龙山组 (T ₁ h)、南陵湖组 (T ₁ n) 地层等灰岩地层接触面	三维地质体表面提取、三维距离场分析

续表

类别	三维控矿要素	要素提取方法
成矿岩体	成矿岩体表面	三维地质体表面提取、三维距离场分析
控矿构造	断层,向、背斜轴,岩体接触面隆凹部位	三维距离场分析、三维离散变换、三维数学形态学方法
地球物理性质	高重力异常单元、高磁力异常单元	三维反演算法、三维距离场分析

2.2 样本集构建

由于研究区内主要发育斑岩型和矽卡岩型铜、金、铅锌多金属矿化,且矽卡岩型和斑岩型矿床都是热液成矿系统的产物,在成因机制和成矿环境上都有一定的关联性,因此本文以茶亭矿床和荞麦山矿床作为实例,构建用于训练 3DCNN 的样本集。

样本集构建过程中,选取茶亭和荞麦山 2 个矿床范围内矿体所在的块体单元作为正样本,共 1 144 个正样本。同时,为了让预测模型能够更加全面地学习控矿和矿化指示特征,本文根据已有勘探结果所约束的非矿化空间分布,将距离 2 个矿床 300 m 以内的非矿体单元块作为负样本单元块。

最后,从所构建的负样本单元块中选择 1 500 个块体单元进行训练,以保持正、负样本数量的平衡。

为了充分综合样本中心点周围的空间预测信息,并利用三维卷积和池化操作有效提取三维控矿和矿化指示特征,本文以选取的样本单元块体为中心,在 3 个维度方向上分别向外扩展 4 个块体长度,即构建形状为 $9 \times 9 \times 9$ 的立方体块,其尺寸扩展到 $900 \text{ m} \times 900 \text{ m} \times 225 \text{ m}$,如图 5 所示。对提取的控矿要素进行归一化处理,然后将其作为预测信息输入所构建的立方体块中,组成立方体块中的每个小块体都包含一维的属性向量,最后将立方体块作为三维成矿预测模型的输入数据。




图 5 单个输入样本扩充构建过程

3 结果与讨论

3.1 模型训练

本文使用基于 ResNet-18 的三维预测模型来学习样本集中所蕴含的控矿和矿化指示特征。在训练过程中,采用随机梯度下降法(stochastic gradient descent,SGD)进行网络训练,以有效减少冗余计算,批量大小设置为 32,初始学习率设置为 0.1,使其随着训练时间的增加而线性衰减;最终得到基于 ResNet-18 的三维成矿预测模型,其训练曲线如图 6 所示。




图 6 基于 ResNet-18 的预测模型训练曲线

从图 6 可以看出,通过 50 次训练可获得最佳模型参数,其准确率能达到 99.62%,且曲线相对平稳,没有大幅度的波动或震荡,未出现过拟合现象,表明模型具有良好的泛化能力^[24]。

3.2 性能分析

为了能准确分析本文模型的性能,将本文结果与文献[13]中基于 LeNet-5 的预测模型和逻辑回归预测模型的结果进行比较分析,对比不同模型的训练曲线、捕捉效率曲线及构建的泛化性指标。

2 种 3DCNN 模型训练曲线对比如图 7 所示。从图 7 可以看出,在经过 50 次迭代后,不同预测模型的训练准确率都趋于平稳,LeNet-5 模型的准确率达到 97.32%,ResNet-18 模型的准确率能够达到 99.62%,有显著提升。由此可见,基于 ResNet-18 的预测模型具有更强大的表达能力和学习能力^[25],相较于结构简单的 LeNet-5 模型,能够更好、更快速地拟合预测数据与成矿事实之间的非线性关系,从而更加准确地识别矿化和非矿化块体。

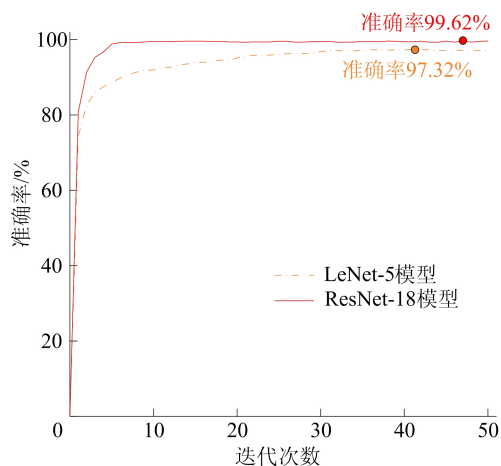


图 7 2 种模型训练曲线对比

在评价预测结果可靠性方面,捕捉效率曲线能够通过已知成矿块体与总块体之间的累积比例关系表征模型的预测准确度和区分能力,同时该曲线也用于确定能够有效区分高概率和低概率成矿区域的阈值;曲线的横坐标为研究区内块体根据矿化概率由高到低排列的累积比例,纵坐标为已知成矿块体根据矿化概率由高到低排列的累积比例^[26]。3 种模型捕捉效率曲线对比如图 8 所示。从图 8a 可以看出,本文基于 ResNet-18 的预测模型相较于其他 2 种模型,其曲线下面积(area under curve, AUC)更大。由图 8b 可知,在逻辑回归模型和 LeNet-5 模型得到的结果中,前 1% 的高成矿概率

块体范围分别能够覆盖 65.47%、82.86%的已知矿体,而本文 ResNet-18 模型得到的结果中,前 1%的高成矿概率块体范围能够覆盖 95.43%的已知矿体,表明其能够用更小的预测范围预测出更多的已知矿体,模型的结果更加可靠。




图 8 3 种模型捕捉效率曲线对比

为了测试模型在研究区内的泛化能力,本文构建一个指标用于表征不同模型的泛化性能,该指标

被定义为高成矿概率区域中未作为预测数据的已知矿床数量(A)与高成矿概率区域中的块体数量(B)的比值,3 种模型在研究区内的泛化能力见表 2 所列。

结合文献[13]和表 2 可知,基于 ResNet-18 的三维预测模型能够用更小的高成矿概率块体范围预测出所有未用于数据驱动的已知矽卡岩型矿床,这可能是由于该预测模型具有较复杂的网络结构,能够利用强大的表征能力同时捕捉斑岩型和矽卡岩型矿化与三维预测数据之间的非线性关联。

表 2 3 种模型在研究区内的泛化能力

模型	高成矿概率区域 已知矿床数量(A)	高成矿概率区域 块体数量(B)	A/B
逻辑回归模型	4	28 802	$1.388 8 \times 10^{-4}$
LeNet-5 模型	6	28 955	$2.072 2 \times 10^{-4}$
ResNet-18 模型	6	21 039	$2.851 8 \times 10^{-4}$

综上对比结果可知,ResNet-18 模型的性能明显优于逻辑回归模型和 LeNet-5 模型。其可能原因是 ResNet-18 的网络深度和残差连接的设计允许通过多个残差块的堆叠,网络可以学习到不同尺度和层级的特征,并通过跳跃连接将这些特征有效地传递和整合。这种设计使得 ResNet-18 模型能够更好地利用 CNN 的非线性建模能力,对复杂的地质信息能够进行更深入的挖掘和分析。

3.3 预测结果

本文进一步基于 ResNet-18 模型形成的预测结果对成矿远景区进行圈定。依据捕捉效率曲线,选取成矿概率 0.58 作为高成矿概率阈值,圈定的找矿靶区如图 9 所示。

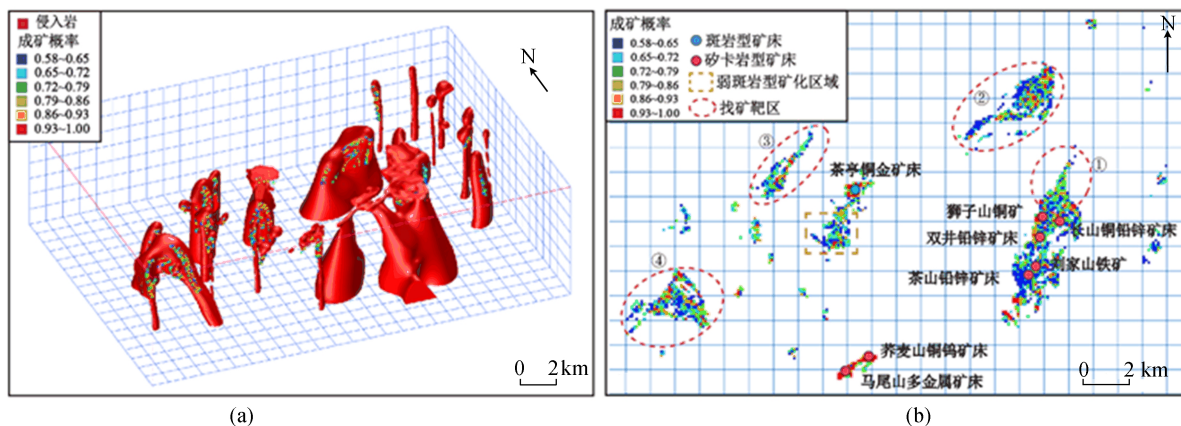


图 9 本文三维成矿预测模型预测结果

本文圈定的找矿靶区不仅能够覆盖作为训练数据的茶亭矿床和荞麦山矿床所处的空间范围,还包括区内几个未作为样本集的已知矽卡岩型矿床和 1 个弱斑岩型矿化区域。这些结果表明,基于 ResNet-18 的三维成矿预测模型在茶亭地区具有良好的泛化能力。同时,预测结果暗示研究区存在若干成矿概率相对较高的区域,可作为进一步找矿勘查的优选目标,开展更大比例尺的矿产勘查工作。

4 结 论

本文将基于 ResNet-18 的三维成矿预测模型与传统的逻辑回归模型和 LeNet-5 CNN 模型进行对比分析,结果表明,ResNet-18 模型的深层卷积结构和残差连接机制可以进一步提升 3DCNN 的性能和泛化能力,显著提高三维预测数据融合模型的预测准确率。因此,本文所构建的基于 ResNet-18 的三维预测模型具有更优异的性能,可为三维成矿预测研究提供更强大的数据综合工具。

基于 ResNet-18 模型实例应用结果所获得的高成矿概率区域不仅覆盖作为数据驱动的茶亭矿床和荞麦山矿床,也包括研究区内其他已知的矽卡岩型矿床;同时,该模型还圈定一些新的未被发现的高矿化概率区域,可作为进一步找矿勘查的优选目标,开展更大比例尺的矿产勘查工作。

[参 考 文 献]

- [1] 陈衍景. 造山型矿床、成矿模式及找矿潜力[J]. 中国地质, 2006, 33(6): 1181-1196.
- [2] 袁峰, 李晓晖, 张明明, 等. 隐伏矿体三维综合信息成矿预测方法[J]. 地质学报, 2014, 88(4): 630-643.
- [3] 郑通科, 袁峰, 张明明, 等. 基于 GIS 和证据权重法的钟姑铁矿成矿预测[J]. 合肥工业大学学报(自然科学版), 2015, 38(6): 851-856.
- [4] 周永章, 左仁广, 刘刚, 等. 数学地球科学跨越发展的十年: 大数据、人工智能算法正在改变地质学[J]. 矿物岩石地球化学通报, 2021, 40(3): 556-573.
- [5] 周永章, 陈烁, 张旗, 等. 大数据与数学地球科学研究进展: 大数据与数学地球科学专题代序[J]. 岩石学报, 2018, 34(2): 255-263.
- [6] 曹新志, 张旺生, 孙华山. 我国深部找矿研究进展综述[J]. 地质科技情报, 2009, 28(2): 104-109.
- [7] 翟裕生, 邓军, 王建平, 等. 深部找矿研究问题[J]. 矿床地质, 2004(2): 142-149.
- [8] 陈建平, 于萍萍, 史蕊, 等. 区域隐伏矿体三维定量预测评价方法研究[J]. 地学前缘, 2014, 21(5): 211-220.
- [9] 袁峰, 李晓晖, 张明明, 等. 三维成矿预测研究进展[J]. 甘肃地质, 2018, 27(1): 32-36.
- [10] 李苍柏, 肖克炎, 李楠, 等. 支持向量机、随机森林和人工神经网络机器学习算法在地球化学异常信息提取中的对比研究[J]. 地球学报, 2020, 41(2): 309-319.
- [11] 路英川, 李鹏, 王浩, 等. 大数据时代矿床学研究发展状况综述[J]. 世界核地质科学, 2021, 38(3): 295-310.
- [12] LI S, CHEN J P, LIU C, et al. Mineral prospectivity prediction via convolutional neural networks based on geological big data[J]. Journal of Earth Science, 2021, 32(2): 327-347.
- [13] LI X H, XUE C, CHEN Y H, et al. 3D convolutional neural network-based 3D mineral prospectivity modeling for targeting concealed mineralization within Chating area, middle-lower Yangtze River metallogenic belt, China[J]. Ore Geology Reviews, 2023, 157: 105444.
- [14] 李洪安, 郑峭雪, 陶若霖, 等. 基于深度学习的图像超分辨率研究综述[J]. 图学学报, 2023, 44(1): 1-15.
- [15] 周飞燕, 金林鹏, 董军. 卷积神经网络研究综述[J]. 计算机学报, 2017, 40(6): 1229-1251.
- [16] 刘冰, 余旭初, 张鹏强, 等. 联合空-谱信息的高光谱影像深度三维卷积网络分类[J]. 测绘学报, 2019, 48(1): 53-63.
- [17] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition. [S. l.]: IEEE, 2016: 770-778.
- [18] 岳书仓, 周涛发. 长江中下游铜、金成矿带形成的背景[J]. 安徽地质, 1998(4): 1-3.
- [19] 周涛发, 范裕, 袁峰. 长江中下游成矿带成岩成矿作用研究进展[J]. 岩石学报, 2008, 24(8): 1665-1678.
- [20] 陈安国, 周涛发, 刘东甲, 等. 长江中下游成矿带宣城矿集区重磁场特征与找矿启示[J]. 矿床地质, 2020, 39(5): 879-892.
- [21] 胡训宇. 南陵—宣城矿集区成矿过程数值模拟与三维成矿预测[D]. 合肥: 合肥工业大学, 2020.
- [22] 肖庆玲, 周涛发, 袁峰, 等. 安徽茶亭铜金矿床赋矿石英闪长玢岩黑云母成分特征及成岩成矿指示意义[J]. 矿床地质, 2018, 37(6): 1179-1194.
- [23] 安昱华. 安徽南陵—宣城地区岩浆岩地质地球化学特征及与成矿的关系[D]. 合肥: 合肥工业大学, 2019.
- [24] FABBRI A G, CHUNG C J. On blind tests and spatial prediction models [J]. Natural Resources Research, 2008, 17(2): 107-118.
- [25] SRIVASTAVA N, HINTON G E, KRIZHEVSKY A, et al. Dropout: a simple way to prevent neural networks from over fitting [J]. Journal of Machine Learning Research, 2014, 15(1): 1929-1958.
- [26] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks [J]. Communications of the ACM, 2012, 25(2): 84-90.

(责任编辑 张淑艳)