

基于卷积神经网络模型划分成矿远景区 ——以甘肃大桥地区金多金属矿田为例

蔡惠慧^{1,2}, 徐永洋³, 李孜轩³, 曹豪豪³, 冯雅兴³, 陈思琼³, 李永胜¹
CAI Huihui^{1,2}, XU Yongyang³, LI Zixuan³, CAO Haohao³, FENG Yaxing³,
CHEN Siqiong³, LI Yongsheng¹

1. 中国地质调查局发展研究中心, 北京 100037;

2. 中国地质大学(北京), 北京 100083;

3. 中国地质大学(武汉)智能空间认知实验室, 湖北 武汉 430074

1. *Development Research Center, China Geological Survey, Beijing 100037, China;*

2. *China University of Geosciences, Beijing 100083, China;*

3. *Intelligent Spatial Cognition Laboratory, China University of Geosciences, Wuhan 430074, Hubei, China*

摘要:大数据和高性能计算使得地质学可能突破种种主客观因素的限制,从传统的定性描述和不确定性作为特点转变为更全面的定量化发展阶段,即地质学更加注重通过挖掘复杂的多元地学数据间的关联关系来探究地质成因过程。为了厘清研究区多元化地质数据并划分成矿远景区,结合现代信息化新方法新技术,智能高效地帮助地学工作者提供辅助决策依据。以甘肃省大桥金矿为研究区,提出了利用一维卷积神经网络替代传统的人工计算,通过对研究区金多金属矿的地球化学元素及地球物理元素数据进行训练,挖掘研究区综合成矿信息,依据训练结果划分出4类成矿远景区。研究结果表明,地质成矿过程复杂,每一个成矿预测要素在地质成矿过程中均发挥重要的作用。在大比例尺度上,应用深度学习网络模型划分成矿远景区能客观地反映多元化地质数据本身的非线性特征,识别地质要素的空间特征,深层次提取和挖掘成矿异常信息,实现矿产资源智能化预测评价。

关键词:卷积神经网络;模型;成矿远景区;大桥;矿田

中图分类号:P618.51;P628 **文献标志码:**A **文章编号:**1671-2552(2019)12-1999-11

Cai H H, Xu Y Y, Li Z X, Cao H H, Feng Y X, Chen S Q, Li Y S. The division of metallogenic prospective areas based on convolutional neural network model: A case study of the Daqiao gold polymetallic deposit. *Geological Bulletin of China*, 2019, 38(12):1999-2009

Abstract: Big data and high performance computing make it possible for geology to break through the limitations of various subjective and objective factors and transform from the traditional qualitative description and uncertainty to a more comprehensive quantitative development stage, that is, geology pays more attention to exploring the geological genesis process by mining the correlation between complex and multiple geoscience data. In order to clarify the diversity of geological data in the study area and divide the metallogenic prospective area, the authors aimed to help the geoscientists to make decisions intelligently and efficiently by combining the new methods and technologies of modern informatization. With the Daqiao gold deposit in Gansu Province as the study area, the authors proposed to use one-dimensional convolutional neural network instead of traditional manual calculation and,

收稿日期:2019-04-17; **修订日期:**2019-07-25

资助项目:中国地质调查局项目《地质矿产智能化调查系统开发与应用》(编号:DD20190416)、《智能地质调查系统开发与推广》(编号:DD20160355)和科学技术部项目《深部矿产资源评价理论与方法》(编号:2016YFC0600510)

作者简介:蔡惠慧(1986-),女,博士,助理研究员,从事矿产资源定量预测评价方法技术研究。E-mail: caihuihui6@126.com

通讯作者:徐永洋(1989-),男,博士,副教授,从事人工智能和时空数据挖掘方面研究。E-mail: yongyangxu@cug.edu.cn

through training the geochemical and geophysical element data in the study area, excavated the comprehensive metallogenic information in the study area, and then recognized four types of metallogenic prospective areas based on the training results. The results show that the geological mineralization process is complex, and each element of metallogenic prediction plays an important role in the geological mineralization process. On a large scale, the deep learning network model can objectively reflect the nonlinear characteristics of diversified geological data, identify the spatial characteristics of geological elements, extract and excavate the information of mineralization anomalies, and realize the intelligent prediction and evaluation of mineral resources.

Key words: convolutional neural network; model; metallogenic prospective area; Daqiao; orefield

矿产资源预测一直是中国找矿领域的重要方向^[1-2],随着信息化技术的快速发展和大数据技术的成熟应用,找矿预测的研究也随着主流技术的发展^[3],在一些方法技术流程上结合加快了找矿预测的效率,并通过学科结合,拓宽了地学科学理论和技术的发展^[4-5]。深度学习是一门涉及多领域的交叉学科,如统计学理论、概率论、逼近论、算法复杂度理论等,是近年来人工智能的热门研究领域^[6]。其核心理论是通过设计算法让计算机自动“学习”数据隐含的内在规律^[7],并通过规律对未知数据进行预测,达到由已知预测未知的目的。

利用深度学习模型分析地质找矿信息,提取地质特征,既应用了计算机的智能高效性,又能客观反映多元地质大数据间的非线性关系,对地质成矿的复杂关系进行深度理解^[8-9],以此指导实际找矿勘查工作。在利用深度学习网络模型进行预测的过程中,很重要的一个环节就是数据样本学习库的构建及确定合适的网络模型^[10],包括模型超参数的选择、网络模型优化等过程,这些因素对网络模型的预测结果影响较大。

1 地质背景

大桥金矿是甘肃境内的超大型金矿床。矿体呈似层状、透镜状等产出,金矿体赋存于三叠系下部建造层下岩性段(Ta-1)的变质石英砂岩、变质粉砂岩和硅化角砾岩中^[11]。矿石矿物主要为黄铁矿、白铁矿和毒砂,脉石矿物主要为石英,围岩蚀变主要见硅化、黄铁矿化等^[12]。受断层作用控制,硅化角砾岩破碎,并具有明显的硅化胶结特征^[13-14]。酸性岩浆热液有丰富的SiO₂,通过硅化胶结作用,形成硅化角砾岩。沉积成岩期硫化物存在金的预富集(Au=0.34×10⁻⁶~0.47×10⁻⁶)。围岩中经历了绿帘石-阳起石相的区域变质作用(277~327℃)(可能晚于215Ma),在这个过程中炭质和沉积硫化物部分溶解释放出金等成矿物质^[15-16]。SiO₂等物质形成于

岩浆与围岩间的物质交换过程,硅化角砾岩中的炭质为金的富集成矿提供了有利条件。矿石中的硫主要来源于地层,在中生代受岩浆作用的影响,具有混合硫特征^[17-18]。

研究认为,大桥金矿床的类型为沉积-改造型矿床,由中三叠世陆源碎屑沉积时期的热水喷流作用携带大量金等成矿物质与有关热水沉积岩(硅质岩、富碳沉积物)一起形成矿源层^[19],并通过印支期的构造及岩浆活动,使地层中的Au元素经过活化、转移等成矿作用,最终在构造有利位置经过沉淀,形成大桥金矿床^[20-21]。

2 深度卷积神经网络模型构建

卷积神经网络^[22](CNN)是深度学习发展中发展较全面的神经网络之一,其在特征检测、目标分类方面的应用非常广泛。卷积神经网络分为前向传播计算输出和误差反向传播更新参数2个过程;在结构上由卷积层、池化层、全连接层等组成。在训练时,由卷积层从输入数据中提取局部特征,后利用池化层简化特征数量,经过卷积层和池化层的交替运算,最后全连接层整合并由分类器输出分类结果。

经典卷积神经网络算法在计算机视觉领域应用较广泛,能在图片分类、目标检测与识别等问题上取得良好的效果^[23]。近年来深度学习在地质数据处理方法的问题上发展迅速。针对多元化地质大数据的数据结构及数据特点,数据基本单元与数据间的非线性关系是通过一维关系来展示的。地质空间特征以沉积物化探分析样点为基本单元,每个点上集合了地质、地球物理、地球化学、遥感等不同时间和空间的特征,需要网络结构模型通过一维卷积神经网络来挖掘数据间的非线性关系,达到充分特征提取的目的。本文提出的深度一维卷积神经网络模型通过将网络进行结构平展,实现地质找矿预测要素以一维向量形式存储,达到一维卷积深度挖掘数据特征的能力。

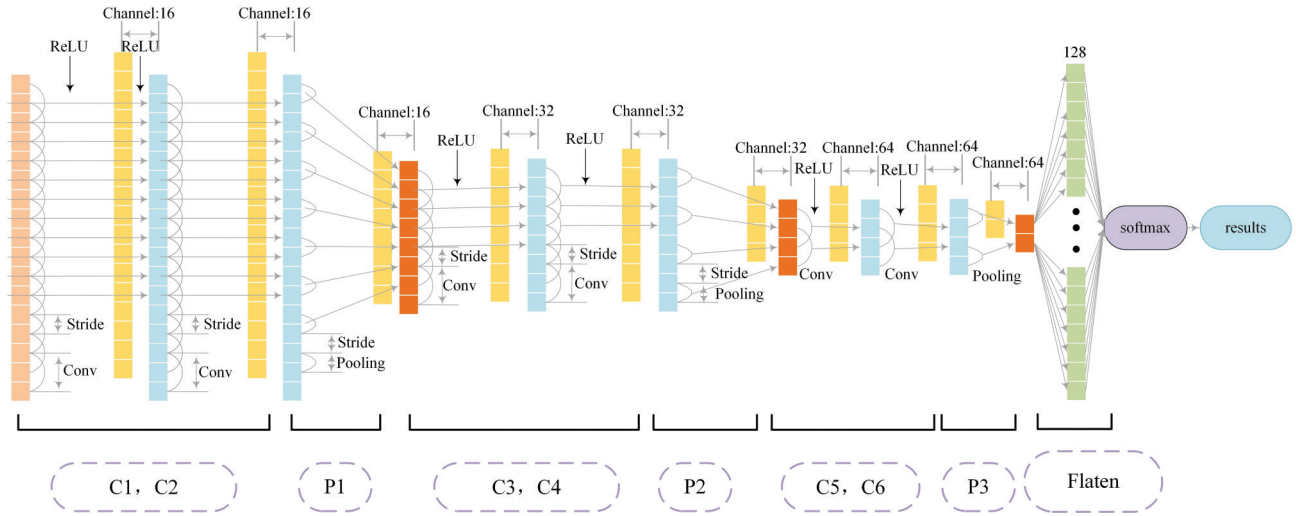


图 1 一维卷积找矿预测神经网络结构图

Fig. 1 Structural diagram of one-dimensional convolutional ore-prospecting prediction neural network

本文提出的一维卷积神经分类网络由一维卷积层、激活层、平均池化层和全连接层 4 种数据处理层组成。卷积层过少,神经网络特征提取不够充分,分类结果不显著;神经网络层数太多,训练效果不会得到明显的提升,而神经网络训练的时间显著增加,效率大幅降低。综合考虑神经网络的训练效率及特征提取的效果,本文采取了如图 1 所示的成矿预测分类一维卷积神经网络结构,分别包括 6 个一维卷积层 $C_t, t=1, 2, \dots, 6$, 3 个平均池化层 P1、P2 和 P3, 3 个激活层及 1 个全连接层 FC 及 Softmax 层。输入数据通过 2 个一维卷积层及 ReLU 激活层处理得到对应的特征图,再经过平均池化层进行降

采样。重复上述操作将 P3 得到的特征图输入全连接层 FC, 最后将一维展开后的特征信息输入 Softmax 层得到分类结果。其中,全连接层采用通用全连接神经网络方法对所得特征进行综合, P3 层的多个找矿预测要素在该层被平展为一维向量。最后,将得到的特征数据与神经元全联接,并通过 sigmoid 函数计算各类别的概率。一维卷积神经分类网络的结构参数表如表 1 所示。

基于一维卷积神经网络的成矿远景区分类模型主要由卷积层、激活层和池化层 3 个网络层构成。

(1)卷积层

在一维卷积层中,输入数据与一维卷积核做一维卷积操作以提取数据特征,通过步长平移的方式提取不同位置的特征。输入数据与可训练的卷积核做卷积运算,通过“滑动平移,加权求和”的方式提取不同位置的特征。本文提出的一维卷积神经分类网络包含 C1 和 C2 两个卷积层,通过特征提取得到特征图,在一维数据集上进行卷积运算。计算过程如公式(1)所示:

$$x_{\beta}^{\gamma} = f\left(\sum_{\alpha \in M_{\beta}} x_{\alpha}^{\gamma-1} k_{\alpha\beta}^{\gamma} + b_{\beta}^{\gamma}\right) \quad (1)$$

公式(1)中: $x_{\alpha}^{\gamma-1}$ 和 x_{β}^{γ} 分别是第 $\gamma-1$ 层、第 γ 层输出特征上相应的值; $k_{\alpha\beta}^{\gamma}$ 为卷积核的权重值; b_{β}^{γ} 为特征的偏置; f 为卷积层神经元的 ReLU 激活函数。在一维卷积操作时,首先输入一个待处理特征序列 $x^{\gamma-1}$, 给定一个卷积核, k^{γ} 卷积核 k^{γ} 依次对输入特征

表 1 一维卷积神经找矿预测分类网络参数

Table 1 Parameters of one-dimensional convolutional neural ore-prospecting prediction classification network

编号	网络层	卷积核大小 / 步长	卷积核数目	输出大小 (宽度*深度)	零补
1	卷积 1	3*1/1	16	17*16	是
2	卷积 2	3*1/1	16	17*16	是
3	池化 1	2*1/2	16	8*16	否
4	卷积 3	3*1/1	32	8*32	是
5	卷积 4	3*1/1	32	8*32	是
6	池化 2	2*1/2	32	4*32	否
7	卷积 5	3*1/1	64	4*64	是
8	卷积 6	3*1/1	64	4*64	是
9	池化 3	2*1/2	64	2*64	否
11	Softmax	4	1	4	

$x^{\gamma-1}$ 进行局部卷积操作得到下一个特征序列 x^γ 。 x^γ 后以本次输出作为下一个数据处理层的输入。

(2) 激活层

激活函数(Activation Function)也被称为非线性映射函数,激活函数对神经网络模型学习、理解非常复杂的目标域具有重要意义。在本文网络结构中,在每个一维卷积操作后加入一个ReLU对神经网络进行激活,能在保证训练效果的同时减少训练时间。激活函数计算如公式(2)所示,其函数示意图如图2所示。

$$f(x) = \max(0, x) \quad (2)$$

(3) 池化层

池化层也是特征提取层,从数据中通过池化操作得到值作为特征并保留,池化方法主要有最大值池化和平均值池化。由卷积层提取得到的特征图,池化层通过窗口滑动的方式对每个池化块进行池化操作。池化可降低特征的维数,避免网络出现过拟合,提高训练效率,具有很强的鲁棒性。池化过程是一个降采样过程,假定池化窗口大小为 $n \times n$,取该窗口区域内 $n \times n$ 个特征值的最大(或平均)作为新的特征值,将新的特征值即为降维后池化层的输出。池化层特征数量为上一层特征数量的 $1/n$ 。由于最大池化会舍弃特征图池化窗口范围内除最大特征外的其余特征,而地质数据的特征多样,需要尽可能多地保留,因此选择平均池化作为池化方式。

本文提出的一维卷积神经网络包含P1和P2两个池化层,降低了噪声对数据分类的干扰。池化层的计算过程可表示为:

$$x_\beta^\gamma = \text{pool}(x_\beta^{\gamma-1}) \quad (3)$$




图2 激活函数示意图

Fig. 2 Schematic diagram of activation function

式中: $x_\beta^{\gamma-1}$ 和 x_β^γ 分别是第 $\gamma-1$ 层、第 γ 层输出特征上相应的值; pool 为平均池化。

本实验采取了平均池化策略,即对卷积层的特征图 f 进行滑窗操作,对窗口中每个特征值加和求平均,产生低维的特征图 f 。计算公式为:

$$f'(n) = \text{mean}(f(n-1)_{d \times d}, f_{nd}) \quad (4)$$

其中, d 为池化窗口尺寸。为确保上层找矿预测要素特征图的全局一致性,池化窗口的大小不宜太小。

3 实验验证与分析

3.1 数据结构

考虑到成矿过程的复杂性与特殊性,在充分利用已有研究成果及资料的基础上,也要顾及与传统证据权重法预测的找矿靶区进行分析对比,尽量削弱人为因素对数据的干扰,以更好地对模型预测结果进行对比验证评价。

(1) 结合研究区域的成矿地质背景和成矿特征可以发现,甘肃崖湾—大桥重点工作区是省内热液型金矿的主要成矿区,研究区出露的地层主要有中上石炭统、三叠系、古近系。主要断裂为NE向,总体呈枢纽NE向倾伏的缓倾斜背斜褶皱。矿体受地层严格控制,产出于三叠系下岩组硅质角砾岩中。

(2) 地球化学成矿元素分布特征显示,研究区Au、Sb、As、Hg、Ag、Bi、Cd等元素存在大规模区域异常且浓集中心明显,总体受滑石关组、NE向石峡—窑上断裂构造及NW向断裂构造控制,在崖湾地区及大桥矿区形成巨大的元素异常,各异常中心与已知矿床对应关系良好,表明其为找矿标志。

(3) 从重力异常线环构造解译可以看出,崖湾—大桥研究区总体由NE向、NW向构造构成区域构造格局。沿石峡—窑上构造带发育一系列NE向串珠状分布的隆起与凹陷盆地,最西部为水仙坪—马家坪盆地,向东北方向依次为陈家楞—小金厂隆起、崖湾盆地、大桥—石峡盆地、邓家山—厂坝盆地等。此外,根据重力异常线环构造解译与典型矿床位置的空间分布发现,典型矿床多数处于重力异常线环构造缓冲区的中心位置。由此推断,崖湾—大桥研究区的典型矿床受断裂构造控制影响,故将重力异常线环构造解译作为一个重要的要素考虑。

确定好找矿预测要素后,需要对找矿预测要素进

表 2 成矿预测要素

Table 2 Metallogenic prediction elements

成矿预测要素		内容描述
成矿地质条件 与标志	岩石组合	三叠系滑石关组的硅化角砾岩、纹层状硅质岩、硅质胶结角砾岩
	构造控矿标志	NE 向构造及其与 NW 向构造交会部位; 环形构造产状变化部位
地表找矿 标志	硅化或硅质角砾岩	硅化角砾岩、纹层状硅质岩、硅质胶结角砾岩
地球化学 标志	水系、土壤元素组合及 指示元素异常	指示元素 Au、Ag、Cu、Pb、Zn、As、Sb、Hg、W、Sn、Bi、Mo 等元素异常; AuAs-BiWCu ³ Sb ² 组合显示金矿化与岩浆热液有关; 组合元素叠加部位对找寻大型矿床具有重要意义
地球物理 标志	高磁	环形构造与线性构造的交会部位; NE 向线性构造及其与 NW 向线性构造的交会部位。
	航磁	NE 向、NNE 向线性构造及其与 N 向线性构造的交会部位
	重力	NE 向和 NW 向构造交会部位; 环形构造产状变化部位

行数据清洗和准备。为避免数据输入阶段空间信息的干扰,在对数据矢量点线文件构建空间缓冲区时,选取传统证据权成矿预测要素矢量文件的统一缓冲区距离作为标准。成矿预测要素矢量线文件以偏离

中心线 5mm 图面距离构建缓冲区,且为了体现距离异常中心越近成矿概率越高,缓冲区内的矢量点量化采用 1/S(S 为点偏离线的垂直距离)标准赋特征值。成矿预测要素点文件以偏离点中心 3mm 图面距离构

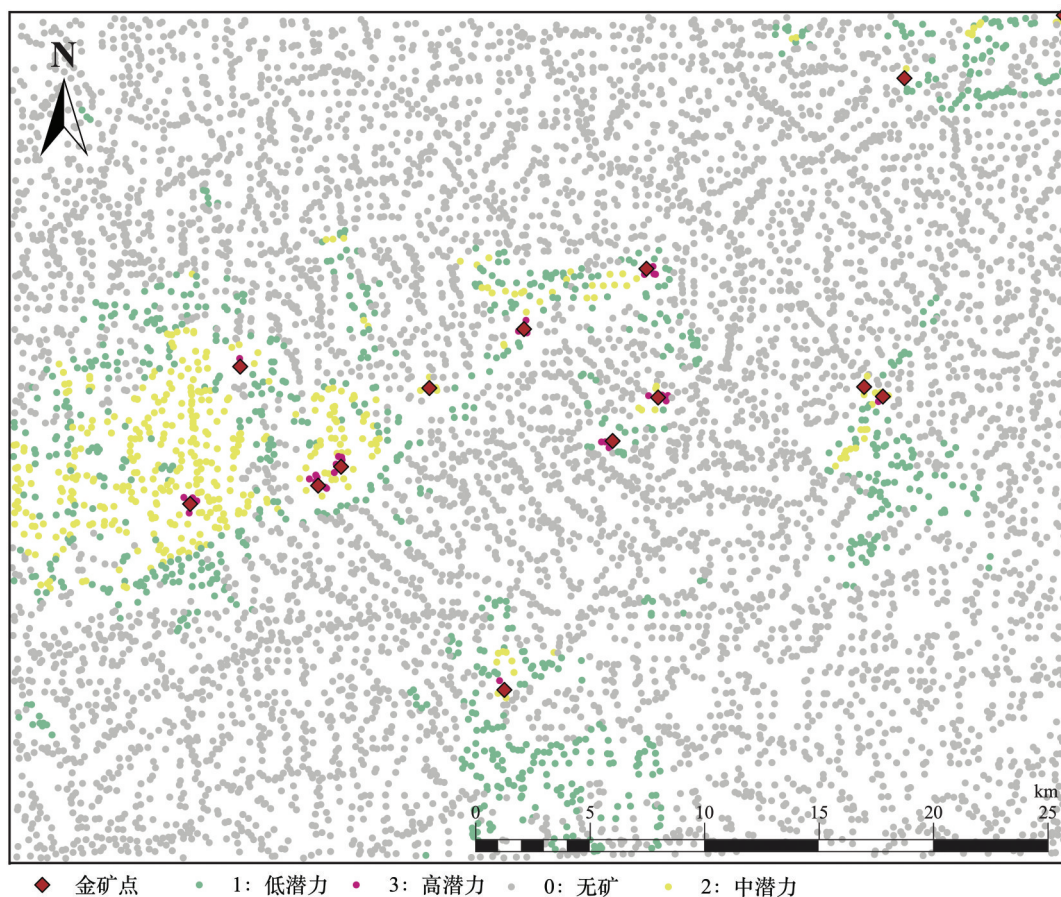


图 3 神经网络分类模型样本学习点位图

Fig. 3 The sample learning point of neural network classification model

建缓冲区,量化原则同线缓冲区。

将收集到的芦家庄幅(I48E014013)、叶家坝幅(I48E015013)、石峡幅(I48E014014)和平洛幅(I48E015014)四幅标准图幅的研究区地质、地球物理、地球化学等数据矢量叠加后,以水系沉积物采样点(图3)为基本单元,水系沉积物采样点落在成矿预测要素缓冲区外的全部赋真值为0,认为没有成矿可能位置。水系沉积物采样点位于三叠系内的赋真值为1,认为属于低潜力成矿可能位置。水系沉积物采样点位于三叠系内又在重力线环构造解译缓冲区内赋真值为2,认为属于中潜力成矿可能位置。水系沉积物采样点既位于三叠系又位于硅质角砾岩上的赋真值为3,认为属于高潜力成矿可能位置。

数据类型主要有地质数据、地球物理数据和地球化学数据三大类。为了更好地分析各类数据与成矿远景区的关系,在化探单元异常数据的基础上,分别单独或组合叠加其他类型数据,通过改变不同输入数据结构类型得到不同的模型预测结果。

在本研究区中,根据找矿要素将网络模型的原始输入数据分为4类(表3):地球化探单元异常数据、地球化探单元异常数据叠加三叠系数据和硅质角砾岩数据、地球化探单元异常数据叠加地球物理重力异常线环构造解译数据及三类地质数据综合叠加,一共4类数据组合类型。在原始输入数据的基础上,还需要将样本学习库的真值样本数据输入,作为网络模型对原始输入数据学习后判断的标准。

3.2 超参数选择

在深度卷积神经网络模型对研究区训练学习的过程中,超参数的选择及模型的设置占很大比重。本文研究重点在于利用地球化探、地球物理和地质数据训练得到的神经网络模型对未知的数据进行预测。由于训练数据与待预测数据之间存在

差异,不能简单地利用模型对训练数据的表现评判其预测能力。

因此,确定网络模型后,需要对网络模型样本库的数据不停地训练,选择合适的迭代轮数以达到最佳的训练结果。迭代轮数过少,网络模型训练达不到最佳结果;反之,迭代轮数过多,可能会出现过拟合数据而导致对未知数据无法做出可靠的预测。

通过输入数据样本集的迭代训练(图4)发现,迭代轮数为800次的时候,模型的损失函数值(Loss值)趋于稳定,而当迭代轮数为1000次的时候,模型的损失函数值近乎收敛效果最佳,因此选择迭代轮数为1000次对网络模型进行训练。

学习率(Learning Rate)指在训练网络模型时,控制参数更新幅度的指标。若学习率过大,参数将可能会在最优点附近震荡,无法收敛到最优值。通过网络模型反复地训练学习样本集,并对比不同学习率下的模型预测精度,确定最优学习率,以确保预测结果最优。如图5显示,在反复地训练模型后,选取LR为0.001、0.002和0.003训练模型,得到的模型预测精度整体较高,均达到95%以上。为了进一步验证学习率更小状态时的学习精度,又设置LR=0.0005时对模型进行训练,预测精度为97.41%,比LR=0.002时的精度稍低,因此认为LR=0.002时候网络模型的预测精度达到最优。

确定好网络模型的学习率之后,对学习样本库的不同数据结构分别进行epochs为1000次的迭代轮数训练,随机选取样本数据库的80%数据集作为训练数据,剩下的20%数据集用来做预测数据,得到

表3 网络模型学习样本库数据结构类型
Table 3 Data structure types of network model learning sample database

数据集编号	数据结构类别
1	地球化探
2	地球化探叠加地球物理
3	地球化探叠加地质数据
4	地球化探,地质数据,地球物理三者叠加




图4 网络模型不同迭代轮数下的模型损失函数趋势图
Fig. 4 Trend diagram of model loss function under different iteration rounds of network model




图5 不同学习率下预测精度图

Fig. 5 Prediction accuracy diagram at different learning rates

了不同数据结构下的预测精度。

如图6所示,随着数据结构的增加,网络模型的预测精度也相应提高。单一地输入化探数据进行预测的精度为96.08%;化探数据叠加地质数据的预测精度为96.37%,且化探数据叠加地球物理数据的预测精度为96.73%,相较单一的化探数据预测精度有所提高。

通过以上对比发现,大桥地区金矿成矿受三叠系和硅质角砾岩体的影响较大,即矿体受地层严格控制,产出于三叠系下岩组硅质角砾岩中,这与已知的研究结论相符,进一步证实了大桥地区金矿层位控制论。最后将3类数据结构叠加进行综合信息预测的精度为97.43%,相较前3个预测结果,精度最高。这也侧面证实了地质成矿是一个复杂而综合的过程,每一类数据可能只侧重反映了地质成矿的某一方面,而综合地质信息的叠加更加全面地体现了成矿过程的整体性。

3.3 预测结果分析

为了详细说明不同成矿要素对成矿远景区划分预测的影响,基于已有的成矿要素信息,本次研究分别对比了通过地球化学叠加地球物理及地质数据、地球化学叠加地球物理数据、地球化学叠加地质数据,以及单独输入地球化学数据划分的成矿远景区结果。同时,从不同角度分析了不同成矿要素下成矿预测的区别和联系。通过结合地质背景解释模型预测结果,验证模型的合理性和先进性。

从全局角度分析,4类数据结构的预测结果整体分布一致,多数中高潜力远景区范围与已知金矿床(点)位置高度吻合,能成功地预测出研究区内的




图6 学习率为0.002时不同数据结构的预测精度

Fig. 6 Prediction accuracy of different data structures when the learning rate is 0.002

中高潜力成矿远景区。

从局部角度分析,4类数据结构的预测结果也略有差别,但是基于综合信息叠加预测的中高潜力成矿远景区范围更聚合(图7),中高潜力远景区范围多数位于三叠系层位上,说明模型能够充分学习到成矿模式下的各类成矿要素之间的关系,并预测出不同输入要素在区域成矿中所占的比重和作用,反映出成矿要素在成矿过程中的不可或缺性。

由于地球化学数据异常是矿化异常的直观表现,虽然基于单独地球化学预测结果相对较离散,但通过预测结果分析,其整体分布对成矿结果指示性较强。同时,模型直接通过地球化学元素进行成矿预测,结果与Au元素F3异常组合异常(Au-Ag-As-Sb-Tl-U)的分布范围大致吻合(图8)。网络模型可以直接通过分析地球化学元素与成矿结果之间关系而不需要建立复杂模型,充分体现模型的先进性。

地球物理中重力异常线环构造解译数据对于推测深部隐伏岩体有至关重要的作用,已知典型金矿床(点)集中于重力异常线环构造解译缓冲区。基于地球化学叠加地球物理训练的学习模型能够顾及成矿要素中隐伏岩体对成矿作用的影响,在细节上优化成矿预测结果,使得成矿远景区划分较精细化(图9)。图9的c1图显示仅地球化学数据预测的结果,图中安子山金矿点高值显示不明显,但是在叠加重力异常线环构造解译数据之后(c2图),安子山金矿点的高值范围明显扩大,且金矿点完全位于高值范围区。c3图和c4图分别代表叠加重力异常线环构造解译数据前后西和县朱家河砂(金)矿

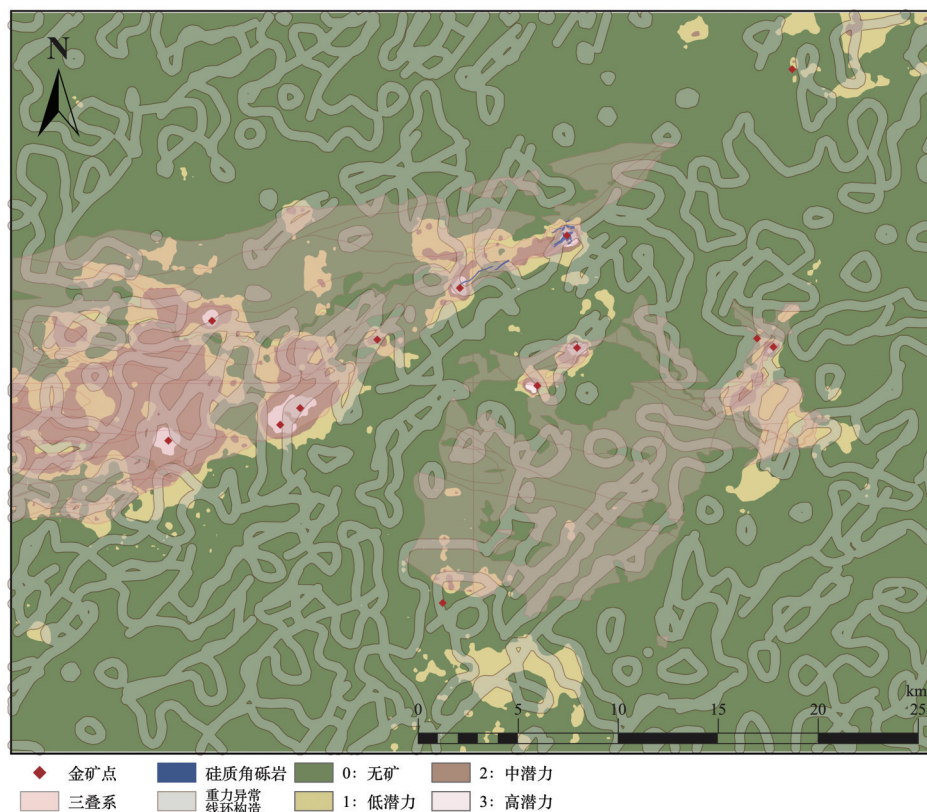


图7 分类网络模型综合信息预测图

Fig. 7 Classification network model comprehensive information prediction diagram

附近的预测结果。通过对比发现,仅输入地球化学数据时,西和县朱家河砂金矿附近主要位于低中潜力成矿有利区位置,叠加重力线环构造解译异常数据后,西和县朱家河砂金矿明显位于中高潜力成矿有利区位置,且中高潜力范围明显扩大,成矿有利度明显增加。

三叠系是大桥金矿成矿的必要条件,硅质角砾岩对于研究区金矿成矿模式属于控矿条件。图10中d2显示,在地球化探数据的基础上叠加三叠系及硅质角砾岩的约束,大桥金矿床的高潜力区沿NW方向展布,且二房沟脑金矿点的中高潜力区沿NE方向展布与大桥的中高潜力区连成一体,形成新的中潜力重点区域,整个特征提取过程与大桥矿区三叠系赋矿论及硅质角砾岩的控矿观点吻合。

4 成矿远景区划分

根据样本学习库分为4类真值标签,每一类标签按照成矿要素叠加程度不同,指示的找矿意义也不一

样。从图11可以看出,深度卷积神经网络模型按照专家知识划分样本学习库划分成矿远景区,从区域上整体缩小了找矿预测范围,且除已知典型矿床周边区域,在其他区域也呈现一些异常高值区,整体分布与崖湾大桥研究区的地质分布方向一致,总体呈枢纽NE向倾伏的缓倾斜背斜褶皱,主要为NE向。

针对图中标识的已知AU 1号矿点、2号矿点和3号矿点与其他矿点相比,成矿等级较低,从成矿预测的递进式研究思想出发,进一步缩小找矿预测范围,提高找矿预测效率,故在下一步找矿预测工作中,暂不考虑1号矿点、2号矿点和3号矿点周边区域。综合考虑已知典型矿床及区域成矿地质背景,重点研究大桥金矿及崖湾附近的矿床(点)对周边区域的影像,将图中虚线位置标示为选定的9处中高潜力成矿远景区,作为下一步找矿预测的重点工作区域。

5 结论

本文通过构建卷积神经网络模型,对比分析了




图 8 化探数据网络模型预测结果与 F3 异常对比图

Fig. 8 Comparison between prediction results of geochemical data network model and F3 anomaly




图 9 地球化学数据叠加地球物理数据前后结果(c1 和 c3:叠加前;c2 和 c4:叠加后)

Fig. 9 Results before and after geochemical data overlaid with geophysical data (c1 and c3: before superposition; c2 and c4: after superposition)

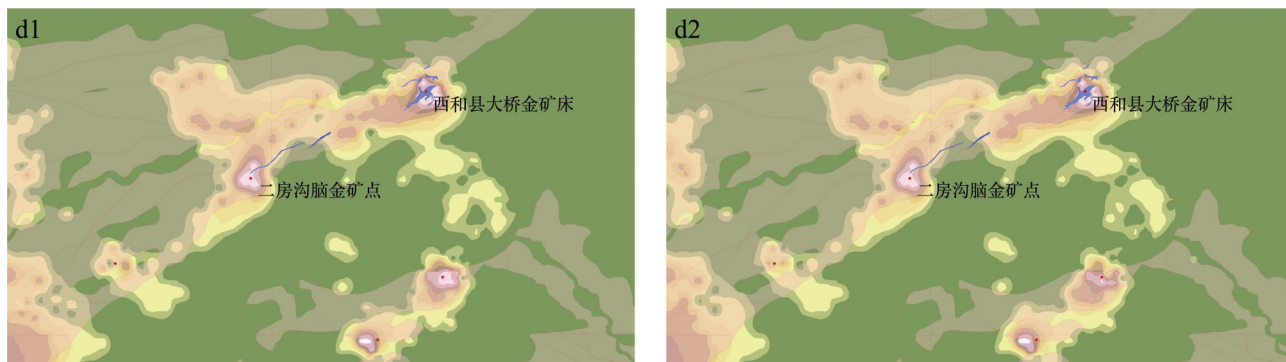


图10 地球化学数据叠加地质数据前后结果(d1:叠加前;d2:叠加后)

Fig. 10 Results before and after geochemical data overlaid with geological data (d1: before the superposition; d2: superimposed)

不同成矿要素对成矿远景区划分的影响。通过结果得知,成矿过程是跨越时间和空间的复杂过程,不同的成矿预测要素在整个成矿过程中均扮演重要的角色。卷积神经网络算法在成矿远景区划分时表现出了很好的优势,但是在实验分析的过程中,通过对比分析发现,其在细节预测层面没有很好的收敛优势。在接下来的研究中,会继续专注找

矿预测在更大比例尺层面及更大更复杂的数据层面的研究,并通过与传统的证据权法等进行对比验证研究。

致谢:在模型调试阶段得到了中国地质大学(武汉)国家地理信息系统工程技术研究中心智能空间认知实验室团队的大力帮助,在样本库构建过程中得到了吉林大学地球科学学院薛福林和杨言

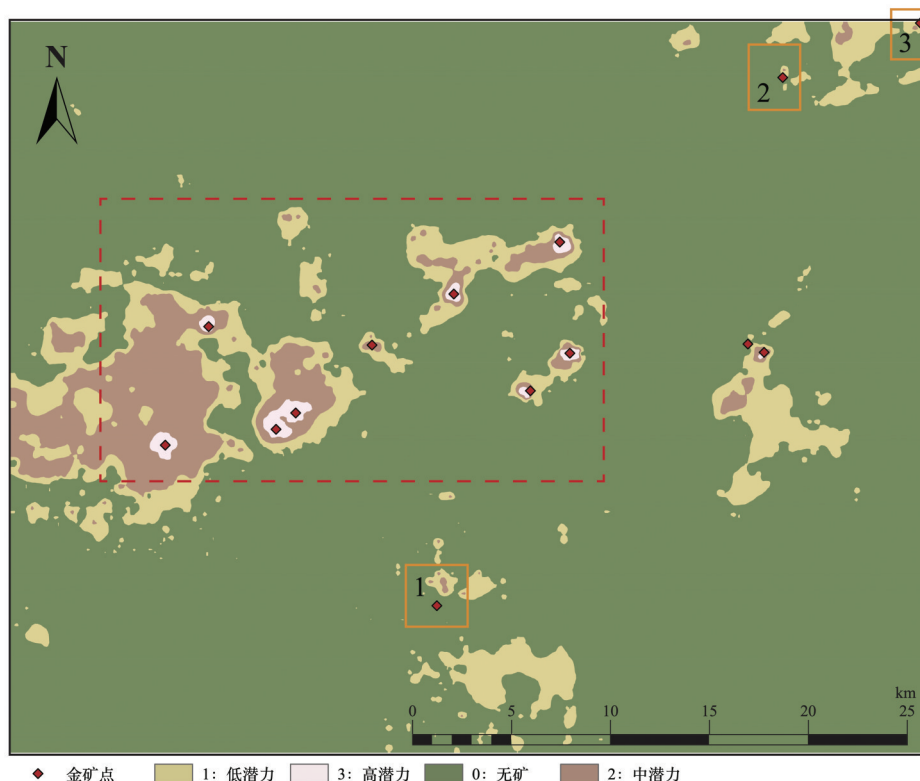


图11 深度卷积神经网络模型预测图(加虚线框9处远景区范围)

Fig. 11 Prediction diagram of deep convolutional neural network model (dotted box with 9 perspective areas)

辰教授的悉心指导,在此表示衷心的感谢。

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分析[J].地质通报,2015,34(7):1273-1279.
- [2]Chen L R, Guan Q F, Xiong Y H, et al. A Spatially Constrained Multi- autoencoder Approach for Multivariate Geochemical Anomaly Recognition[J]. Computers and Geosciences, 2019: 43-54.
- [3]陈建平,李靖,崔宁,等.大数据背景下的地质云的构建[J].地质通报,2015,34(7):1260-1265.
- [4]Chen L R, Guan Q F, Feng B, et al. A Multi- convolutional Autoencoder Approach to Multivariate Geochemical Anomaly Recognition[J]. Minerals, 2019:1-23.
- [5]蔡惠慧,朱伟,李孜轩,等.基于深度学习的钨钼多金属矿产资源预测评价[J].地球信息科学学报,2019,(6):
- [6]Xiong Y H, Zuo R G. Recognition of Geochemical Anomalies Using a Deep Autoencoder Network[J]. Computers & Geosciences, 2016: 75-82.
- [7]吴冲龙,刘刚.大数据与未来地质的发展[J].地质通报,2019,38(7):1081-1088.
- [8]吴冲龙,刘刚,张夏林,等.地质科学大数据及其利用的若干问题探讨[J].科学通报,2016,61(16):1797-1807.
- [9]李德仁,王树良,李德毅.空间数据挖掘理论与应用[M].北京:科学出版社,2013.
- [10]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.
- [11]刘月高,吕新彪,张振杰,等.甘肃西和县大桥金矿床的成因研究[J].矿床地质,2011,30(6):1085-1099.
- [12]卢欣祥,董有,常秋玲,等. Indosinian Shahewan rapakivi granite in Qinling and its dynamic significance[J]. Science in China, 1996, 39(3): 266-272.
- [13]张宗清,张国伟,唐索寒,等.秦岭沙河湾奥长环斑花岗岩的年龄及其对秦岭造山带主造山期结束时间的限制[J].科学通报,1999,44(9):981-984.
- [14]Zhong N C, Wang W, Yao P, et al. Prevalence of chronic obstructive pulmonary disease in China: a large, population-based survey[J]. American Journal of Respiratory & Critical Care Medicine, 2006, 176(8): 753.
- [15]刘建宏,张新虎,赵彦庆,等.西秦岭成矿系列、成矿谱系研究及其找矿意义[J].矿床地质,2006,25(6):727-734.
- [16]闫玉梅,李永军.西秦岭礼县长安一带西汉水群牙形刺特征及时代讨论[J].甘肃地质,1994,(2):18-26.
- [17]张复新,季军良,龙灵利,等.南秦岭卡林型-似卡林型金矿床综合地质地球化学特征[J].地质论评,2001,47(5):492-499.
- [18]尤关进,张忠平.甘肃大桥金矿地质特征及其发现的意义[J].甘肃地质,2009,18(4):1-8.
- [19]李永琴,赵建群,赵彦庆.西秦岭金成矿系统分析[J].甘肃地质,2006,15(1):47-52.
- [20]孙则明,王自翔,徐亮,等.甘肃大桥金矿硅质岩地球化学特征及其地质意义探讨[J].地球化学,2016,45(5):499-509.
- [21]张凤霞,吴玉雯,张玉辉,等.甘肃大桥金矿地球化学异常特征对比[J].甘肃地质,2015,24(3):36-41.
- [22]常亮,邓小明,周明全,等.图像理解中的卷积神经网络[J].自动化学报,2016,42(9):1300-1312.
- [23]张文宇,刘畅.卷积神经网络算法在语音识别中的应用[J].信息技术,201,8(10):147-152.