

基于形状上下文的成矿构造形态控矿特征深度学习及三维成矿预测

——以大尹格庄金矿床为例

聂凡, 魏运凤, 郑扬, 邓浩

中南大学地球科学与信息物理学院, 湖南 长沙
Email: niefancsu@163.com, 541854733@qq.com

收稿日期: 2021年1月23日; 录用日期: 2021年2月12日; 发布日期: 2021年2月20日

摘要

随着地质找矿工作逐步向深部空间的发展, 深部矿、隐伏矿已成为找矿的主要对象。在对深部矿、隐伏矿的预测中, 有效的成矿信息提取能够保证预测结果的准确性和可靠性。本文提出一种基于形状上下文的成矿构造形态控矿特征深度学习的方法, 以大尹格庄金矿床为研究对象, 利用胶西北招平断裂带大尹格庄断离面趋势-起伏因素(waF、wbF)、断离面坡度因素(gF)、断离面陡缓转换部位综合场因素(fv)封装的三维形状上下文特征, 利用深度学习中的图卷积神经网络, 学习获得深层次的地质体形态控矿特征。研究表明, 图卷积网络可提取更完备的地质体形态控矿特征, 建立具有较好预测准确性的三维成矿预测模型。

关键词

地质体形态控矿特征, 形状上下文, 深度学习, 图卷积神经网络

Study on Deep Learning of Ore-controlling Characteristics of Geological Morphology and 3D Metallogenic Prediction Based on Shape Context

—A Case Study of Dayingezhuang Gold Deposit

Fan Nie, Yunfeng Wei, Yang Zheng, Hao Deng

School of Geosciences and Info-Physics, Central South University, Changsha Hunan

文章引用: 聂凡, 魏运凤, 郑扬, 邓浩. 基于形状上下文的成矿构造形态控矿特征深度学习及三维成矿预测[J]. 地球科学前沿, 2021, 11(2): 137-146. DOI: 10.12677/ag.2021.112011

Abstract

With the gradual development of geological prospecting to deep space, deep ore and concealed ore have become the main objects of ore prospecting. In the prediction of deep and concealed deposits, the effective extraction of metallogenic information can ensure the accuracy and reliability of the prediction results. This paper proposes a deep learning method based on the shape context of geological morphology based on shape context. Using the 3D shape context features encapsulated by the trend-fluctuation factors (waF, wbF), slope factor (gF), and comprehensive field factors (fV) of the Dayingezhuang gold deposit, the graph convolution neural network in deep learning is used. Learn more complete morphological ore-controlling characteristics of geological bodies. Research shows that the graph convolutional network can extract more complete geological shape ore-controlling characteristics, and establish a three-dimensional ore-forming prediction model with certain prediction accuracy.

Keywords

Ore-Controlling Characteristics of Geological Morphology, Shape Context, Deep Learning, Graph Convolution Neural Network

Copyright © 2021 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

随着已发现的地表、浅部、易识别矿产资源保有量迅速减少,地质找矿工作逐步向第二深度空间发展,深部矿、隐伏矿已成为找矿的主要对象[1],隐伏矿体三维预测已成为深部矿、隐伏矿找矿预测的关键技术。在隐伏矿体三维预测中,有效的成矿信息提取是保证预测准确性和可靠性的关键所在[2] [3] [4]。然而,矿体的形成和就位受到不同尺度下地质体形态和分布的联合控制,地质体形态和分布作为成矿作用的控制因素及边界条件,对成矿物质溶解、聚集、运移、沉淀、保存的影响极为复杂[5] [6]。将地质体形态和分布相关的控矿条件和找矿标志定量化为成矿构造形态初始特征,依赖于地质体形态分析。2.5 维高程面的形态分析在 GIS 数字地形分析中已被广泛研究,尤其是面向地貌分析提出了较为系统的方法[7]。因地质体具有更为复杂的三维形态,2.5 维分析方法所提取的指标难以用于复杂地质体形态的描述。但在这其中,曲率分析方法采用曲面的平均曲率和高斯曲率度量地质体形态的局部变化,并不只局限于 2.5 维地质界面,适用于构造形态描述和找矿指标量化[8]。与 2.5 维高程面分析思想类似,趋势面分析作为一种常用的数学地质方法,亦被用于地质体形态分析[9]。数学形态学方法被引入至地质体形态分析[10] [11]。然而,虽然上述研究在形态分析上取得了一定进展,但存在对形态控矿作用的刻画多关注局部特征而相对忽略整体作用,反映地质体形态控矿客观规律的内在特征尚未充分揭示,影响了隐伏矿体三维预测的准确性与可靠性问题。

近年来，以深度学习为代表的机器学习方法已取得了重要的研究进展。深度学习方法利用多层神经网络结构，通过对数据的多重抽象，能够直接从数据中学习获得内在的“高层次”特征，发现其中隐含模式。在地学领域，深度学习已在岩石矿物识别[12]、地球化学勘查及找矿预测[13]等领域展现了其应用价值。

为刻画地质体成矿构造形态对成矿空间的整体控矿作用，本文利用三维形状上下文对胶西北大尹格庄成矿构造形态特征进行量化描述，通过这一特征描述成矿构造形态的整体控矿作用；为定量刻画地质体形态控矿的非线性规律，本研究构建基于封装的三维形状上下文的图卷积神经网络，希望通过深度学习中的图卷积网络，从对封装的胶西北大尹格庄三维形状上下文特征中学习出更完备的地质体形态控矿特征，为发现更客观、深层次的胶西北形态控矿规律打下坚实的数据理论基础。

2. 研究区地质概况

胶东半岛位于华北克拉通东部，是我国最大的金成矿地区，金资源量超过 4500 t [14]。胶东金矿中超过 90% 的金资源集中产于胶西北的伸展构造内，主要的控矿断裂带是三山岛断裂带、焦家断裂带和招平断裂带。断裂总体走向呈 NE 向，与三条主干断裂平行展布的一组近 NE 向次级断裂发育，少量 NW 向和近 EW 向断裂。三山岛断裂倾向 SE，焦家断裂倾向 NW，招平断裂倾向 SE，三者形成“向、背”组合样式[15]。招平断裂带总体展布方向为 NE 30°~40°，局部向东或向西偏转，倾向东，倾角 30°~50°。玲珑、台上、阜山、九曲、大尹格庄、夏甸和旧店等金矿床赋存于该断裂带中。大尹格庄金矿床位于招平断裂带中段。招平断裂带是胶东地区区规模最大的一条金矿控容矿断裂，它本质上是玲珑花岗岩与基底变质岩系的接触带，并在此基础上承生发育并经后期多期次构造活动改造的一组断裂构造的叠加组合[16]。矿区内招平断裂带宽度为 40~80 m，总体走向为北东 35°~60°，倾向南东，沿走向、倾向均呈舒缓波状展布。矿区内招平断裂带主要沿岩性接触面发育，上盘为胶东群变质岩，下盘为玲珑花岗岩，在构造面附近存在明显的韧性、脆性变形[17]。如图 1 所示为该研究区的平面示意图。




Figure 1. Plan of Zhaoping fault Dayingezhuang (revised from Mao X. *et al.*, 2019 [18])

图 1. 招平断裂带大尹格庄平面示意图(改自 Mao X. *et al.*, 2019 [18])

3. 研究方法

3.1. 三维形状上下文描述符的构建

3.1.1. 三维形状上下文的分析目标

为了定量表达成矿空间与构造样式的关联关系，建立构造样式描述符对发现构造样式对矿体定位的潜在制约关系具有重要意义。因此，我们引入三维形状上下文描述符，通过将样式特征抽象为高维特征向量，通过将模糊的构造样式映射至高维特征空间，以表示成矿空间立体单元受构造样式的制约关系。

3.1.2. 三维形状上下文

三维形状上下文以三维形状直方图的方式分别表达某参考点与形状的距离、方位等空间关系。直方图基于对象所在的空间的划分，即对与直方图的区间对应的单元的完全和不相交的分解。图 2 显示了三种基本空间分解的 2D 示例[19]：壳模型，扇区模型和组合模型。




Figure 2. (a) Shell model; (b) Sector model; (c) Combined model

图 2. (a) 壳模型；(b) 扇区模型；(c) 组合模型

图 2(a)为壳模型，3D 空间被分解为围绕中心点的同心壳。该表示特别独立于物体的旋转，即物体围绕中心点的任何旋转产生相同的直方图。通过归一化形状延伸和壳半径的[0, 1]参数化，可以容易地实现尺度的不变性。然而，在半径相等的情况下，壳体积随壳指数呈二次方增长。

图 2(b)为扇区模型，3D 空间被分解成从形状的中心点出现的扇区。显然，这种表示在规模上是不变的，但不是旋转的。3D 扇形直方图的定义和计算更加复杂。

图 2(c)为组合模型，组合模型比纯壳模型和纯扇形模型表示更详细的信息。两个细粒度 3D 空间分解的简单组合导致高维度。然而，由于空间分解的分辨率在任何情况下都是参数，因此尺寸的数量可以容易地适应特定应用。

深部成矿构造三维形状上下文分析建立在组合模型的基础上，将 2D 模型扩展为 3D 模型：将球体在经度上 36 等分，维度上 12 等分，将球模型在 3D 空间中分解为围绕中心点的 6 个同心壳。将球体分为 2592 个部分。根据成矿空间大小和成矿空间某点受断裂成矿形态控制作用范围，球体的半径设定为 2 km。

3.2. 图卷积神经网络

传统的卷积神经网络能够很好的处理图像数据，但对于高维的图数据，传统的图卷积神经网络并不能够很好的处理，本文三维形状上下文封装的数据为高维的图数据，在处理图数据领域，图卷积神经网络弥补了传统卷积神经网络的短板，图卷积神经网络可以很好的处理高维图数据[20] [21] [22] [23] [24]。

为了探寻在胶西北大尹格庄三维形状上下文潜在的成矿规律，本文基于图卷积神经网络构建深度网络模型。

目前主流的 GNNS(Graph Neural Networks)模型用于分类时,标准的方法是将图中所有的节点生成簇,然后再对所有节点的簇进行全局池化操作,这种全局池化的方法将会忽略图中可能存在的层次结构。三维形状上下文的数据具有良好的层级结构,简单的 GNNS 模型并不能很好的拟合,因此本文采用 DIFFPOOL-GNN 模型[25] [26] [27]。

DIFFPOOL-GNN 模型建立在 GraphSAGE 的框架之上, GraphSAGE 通过采样邻居的策略将 GCN 有全图的训练方式改造成以节点为中心的小批量训练方式,同时还聚合邻居的操作进行了拓展。GraphSAGE 算法的计算过程完全没有拉普拉斯矩阵的参与,每个节点的特征学习仅仅只和其 k 阶邻居相关,不需要考虑全图的结构信息。

DIFFPOOL-GNN 模型在图神经网络的基础上,用一种端到端的方式为图分类学些一种有用的表示。采用如式(1)通用的“消息传递”的 GNNS:

$$H^k = M(A, H^{k-1}; \theta^k) \tag{1} [28]$$

其中 $H^k \in \mathbb{R}^{n \times d}$ 是第 k 层 GNN 的节点簇,这就是本文说的“消息”, M 是一个消息传播函数,依赖于邻接矩阵 A 和可训练参数 θ^k ,关于传播函数 M 的实现有很多。本文采用的是 GraphSAGE。当 $k=1$, 输入的节点簇为 $H^0 = F$, 我们采用的 DIFFPOOL-GNN 模型不需要了解 M 的实现方式,因此直接抽象为 $Z = \text{GNN}(A, X)$ 。

一个进行 K 次迭代公式(1)的 GNN 可以生成最终的节点簇, $Z = H^K \in \mathbb{R}^{n \times d}$, 其中 K 的范围通常为 2~6。

为了更好的学习三维形状上下文中的层次结构,采用一种新的粗化图的方式就是给定一个 GNN 模块的输出 $Z = \text{GNN}(A, X)$ 和一个图的邻接矩阵 $A \in \mathbb{R}^{n \times n}$, 目标就是寻找一种方式可以得一个新的包含 $m < n$ 个节点的粗化图,其中这个新图的邻接矩阵为 $A' \in \mathbb{R}^{m \times m}$, 节点嵌入矩阵为 $Z' \in \mathbb{R}^{m \times d}$ 。这个新的粗化图作为下一层 GNN 的输入,重复 L 次就可以得到具有 L 层 GNN 的模型。

DIFFPOOL 是首个将图粗化过程与 GNN 结合起来进行图分类的算法。DIFFPOOL 提出了一个可学习的簇分配矩阵。具体来说,就是通过一个 GNN 对每个节点进行特征学习,然后通过另一个 GNN 为每个节点学习出所属每个簇的概率分布。

$$Z^{(l)} = \text{GNN}_{l, \text{embed}}(A^{(l)}, X^{(l)}) \tag{2} [28]$$

$$S^{(l)} = \text{softmax}\left(\text{GNN}_{l, \text{pool}}(A^{(l)}, X^{(l)})\right) \tag{3} [28]$$

这里学习出来的 S 矩阵是一个软分配器,其值表示节点被分配到任意一个簇的概率,由于概率值不为 0,因此这是一个下层超级节点到上层所有节点之间的全连接结构。 $\text{GNN}_{l, \text{embed}}$ 、 $\text{GNN}_{l, \text{pool}}$ 是两个独立的 GNN 层,二者的输入相同,但是参数不同,学习的目的不同。需要强调的是,对于最后一层的簇分配矩阵,需要将该矩阵固定成一个全“1”的矩阵,我们此时将图粗化成一个超级节点,由此获取图的全局表示。

有了上述公式(2)和公式(3)的输出结果,我们可以对图进行粗化:

$$X^{(l+1)} = S^{(l)T} Z^{(l)} \in \mathbb{R}^{n_{l+1} \times d} \tag{4} [28]$$

$$A^{(l+1)} = S^{(l)T} A^{(l)} S^{(l)} \in \mathbb{R}^{n_{l+1} \times n_{l+1}} \tag{5} [28]$$

定义第 l 层学到的簇分配矩阵为 $S^{(l)} \in \mathbb{R}^{n_l \times n_{l+1}}$, n_l 表示在第 l 层的节点数, n_{l+1} 表示在第 $l+1$ 层的节点数, $n_l > n_{l+1}$ 。

DIFFPOOL 层 $(A^{(l+1)}, X^{(l+1)}) = \text{DIFFPOOL}(A^{(l)}, Z^{(l)})$ 表示粗化的输入图,式(4)是对簇内的信息执行融合操作,依据矩阵乘法的行向量计算方式,可以清楚地知道 $S^{(l)T} Z^{(l)}$ 表示的是对簇内所有节点的特征向量

进行加和处理。通过式(5)可以算出簇内邻接矩阵的计算。

我们将 GCN 和 DIFFPOOL 合在一起看成一层，对输入的图数据进行任意的重新编号，输出到下一层的特征矩阵与邻接矩阵并不会改变，这种性质是非常符合直觉的：节点是否重新排序并不应该影响节点聚合成簇的结果。

本文使用的图卷积神经网络有三层基于 GraphSAGE 框架的 GCN 层加上一层 DIFFPOOL 层构成如图 3 所示。




Figure 3. Architecture of DIFFPOOL graph convolutional neural network

图 3. DIFFPOOL 图卷积神经网络结构基础

3.3. 技术路线

本文的技术路线如图 4 所示。

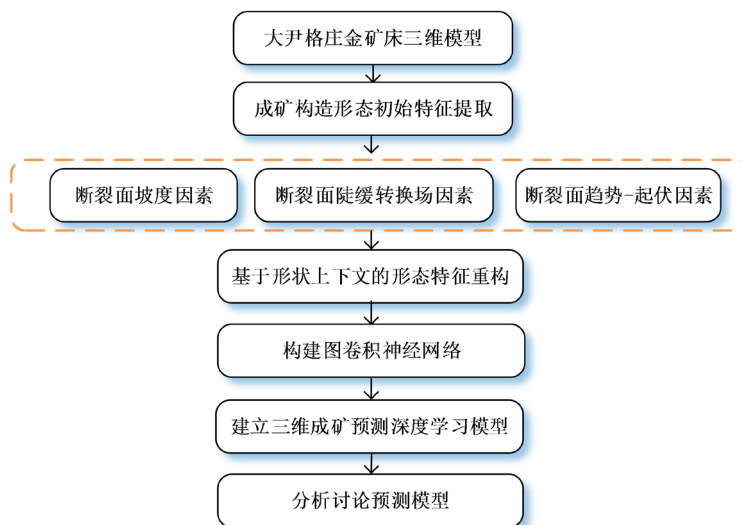


Figure 4. The technical route of this article

图 4. 本文的技术路线

4. 结果

4.1. 数据

本文结合胶西北招平断裂带大尹格庄金矿区的三维形状上下文数据封装成的图数据对图卷积神经网络的深度学习进行研究，因此，需要大尹格庄金矿区所有的三维形状上下文数据，通过这些三维形状上下文数据封装成堆积的图卷积神经网络的数据集，研究三维形状上下文这一特征在深度学习中的是否能够学习到有用的信息。

我们选取了胶西北招平断裂带大尹格庄金矿区中的 16,450 个地质体单元，以工业品位水平 10 g/t 为标准。将 Au 品位(g/t)值域离散化为无矿[0.0 g/t, 1.0 g/t)和有矿[1.0 g/t, ∞]两个区间。16,450 个地质体单元则划分为：12,157 个无矿地质体单元和 4293 个有矿地质体单元。部分无矿地质体单元数据和部分有矿地质体单元数据分别如表 1 和表 2 所示。

Table 1. The data table of some ore free geological bodies

表 1. 部分无矿地质体单元数据表

X坐标(m)	Y坐标(m)	Z坐标(m)	Au品位(g/t)
40530650	4121350	25	0.1
40530650	4121375	25	0.1
40530975	4120925	0	0.08
40530975	4120900	0	0.08

Table 2. The data table of some ore geological bodies

表 2. 部分有矿地质体单元数据表

X坐标(m)	Y坐标(m)	Z坐标(m)	Au品位(g/t)
40531150	4120750	-50	1.41
40531075	4120850	-75	1.12
40531100	4120850	-75	1.15
40531100	4120875	-75	1.13

控矿地质因素是根据已有的地质资料和相关的地质知识，考虑与控矿最相关的指标因素，并根据其特点通过建立的大尹格庄三维模型(如图 5 所示)，对其进行提取和分析，对于胶西北的大尹格庄，确定了断离面趋势 - 起伏因素(waF、wbF)、断离面坡度因素(gF)、断离面陡缓转换部位综合场因素(fV)为成矿构造形态初始特征。




Figure 5. Dayingezhuang 3D model

图 5. 大尹格庄三维模型

为了更好的体现三维形状上下文的控矿作用，还加入了 waF、wbF、gF、fV 等特征。部分地质体单元的 waF、wbF、gF、fV 的数据见表 3。


Table 3. The data table of geological bodies' waF、wbF、gF、fV
表 3. 部分地质体单元的 waF、wbF、gF、fV 的数据

X坐标	Y坐标	Z坐标	waF	wbF	gF	fV	Au品位
40527800	4108750	125	-2.87	-9.08	42.28	-189.91	0.1443
40527800	4108750	100	-2.72	-11.01	42.25	-198.47	0.1443
40527875	4108825	75	0.08	1.81	41.69	-192.62	3.7242
40527900	4108800	50	-0.11	-0.51	48.31	-198.7	0.1446

计算图卷积神经网络需要每个地质体单元的邻接矩阵、每个地质体单元的标签和每个地质体单元的属性。本文根据三维形状上下文的组合模型抽象出来的三维空间结构构建的邻接矩阵，组合模型将球体在经度上 36 等分，维度上 12 等分，将球模型在 3D 空间中分解为围绕中心点的 6 个同心壳。将球体分为 2592 个部分，我们将 2592 个部分抽象成一个个节点，每一个节点按照位置的相邻关系抽象出它们的边，那么每一个地质体单元的邻接矩阵的维度为 2592×2592 。每一个地质体单元根据 Au 品位(g/t)值域离散化为无矿[0.0 g/t, 1.0 g/t)和有矿[1.0 g/t, ∞]两个区间，无矿区间[0.0 g/t, 1.0 g/t)的分类为无矿地质体单元和有矿区间[1.0 g/t, ∞]分类为有矿地质体单元。每一个地质体单元都是一副图。本文将无矿地质体单元的标签记为 0，有矿地质体单元的标签记为 1。每个地质体单元中的每一个节点，它的属性为初始输入的特征，本文将初始特征设定为属性，它是地质体单元根据三维形状上下文的组合模型抽象出来的三维空间结构和控矿相关指标计算出的三维形状上下文。

4.2. 结果

本文通过每个地质体单元的邻接矩阵、每个地质体单元的标签和每个地质体单元的属性作为堆积好的图卷积神经网络的数据输入，对胶西北招平断裂带大尹格庄金矿区 16,450 个地质体单元则划分为的 12,157 个无矿地质体单元和 4293 个有矿地质体单元进行图卷积神经网络的训练，由此建立三维成矿预测模型。训练结果如图 6 所示：每一幅图的横坐标为训练的轮数(单位：epoch)，纵坐标为训练的精度(单位：%)。






Figure 6. (a) The accuracy of Dayingezhuang’s training set; (b) The accuracy of Dayingezhuang’s validation set; (c) The accuracy of Dayingezhuang’s training set AUC; (d) The accuracy of Dayingezhuang’s validation set AUC; (e) The loss of Dayingezhuang’s training set; (f) The loss of Dayingezhuang’s validation set

图 6. (a) 大尹格庄训练精度; (b) 大尹格庄验证精度; (c) 大尹格庄训练集 AUC 精度; (d) 大尹格庄验证集 AUC 精度; (e) 大尹格庄训练集 loss; (f) 大尹格庄验证集 loss

从图 6(a)和图 6(b)可以看出胶西北招平断裂带大尹格庄金矿区深度学习训练的精度为 92%，验证集的精度为 88%，这说明本文建立的三维成矿深度学习的模型有良好的拟合度，可以提取出有效的成矿构造形态的整体控矿特征。我们进一步采用受试者工作特征(Receiver Operating Characteristic, ROC)曲线评价预测准确性。AUC(Area Under Curve)是 ROC 曲线下与坐标轴围成的面积，AUC 的值越接近 1.0，说明预测方法的准确性越高。

从图 6(c)和图 6(d)可以看出胶西北招平断裂带大尹格庄金矿区深度学习的训练集 AUC 为 0.94，验证集 AUC 为 0.85，均远远大于 0.5，本文建立的三维成矿预测模型具有较好的预测准确性。

5. 结论

三维形状上下文保证了从总体上刻画形态控矿作用，图卷积网络表征了成矿构造形态对矿体形成与分布，由此引出建立了基于形状上下文的构造形态控矿特征深度学习，将从更好地刻画构造整体形态与矿化定位间的非线性关联。验证结果表明，基于形状上下文深度学习建立的三维成矿预测模型具有较好的预测准确性。

参考文献

- [1] 赵鹏大. 成矿定量预测与深部找矿[J]. 地学前缘, 2007, 14(5): 1-10.
- [2] 陈建平, 吕鹏, 吴文, 赵洁, 胡青. 基于三维可视化技术的隐伏矿体预测[J]. 地学前缘, 2007, 14(5): 54-61.
- [3] 王功文, 郭远生, 杜杨松, 范玉华, 郭欣, 庞振山, 陈建平. 基于 GIS 的云南普朗斑岩铜矿床三维成矿预测[J]. 矿床地质, 2007, 26(6): 651-658.
- [4] 肖克炎, 李楠, 孙莉, 邹伟, 李莹. 基于三维信息技术大比例尺三维立体矿产预测方法及途径[J]. 地质学报, 2012, 36(3): 229-236.
- [5] 赵鹏大. 成矿多样性与矿床谱系[M]. 北京: 中国地质大学, 2009.
- [6] 於崇文. 成矿作用动力学[M]. 北京: 地质出版社, 1997.
- [7] 汤国安, 龚健雅, 陈正江, 成燕辉, 王占宏. 数字高程模型地形描述精度量化模拟研究[J]. 测绘学报, 2001, 30(4): 361-365.
- [8] Mejía-Herrera, P., Royer, J.J., Caumon, G., et al. (2015) Curvature Attribute from Surface-Restoration as Predictor Variable in Kupferschiefer Copper Potentials. *Natural Resources Research*, **24**, 275-290. <https://doi.org/10.1007/s11053-014-9247-7>
- [9] 毛先成, 赵莹, 唐艳华, 彭正林, 陈进, 邓浩. 基于 TIN 的地质界面三维形态分析方法与应用[J]. 中南大学学报(自然科学版), 2013, 44(4): 1493-1499.
- [10] 邓浩. 面向隐伏矿体预测的三维地质建模与空间分析若干技术研究[D]: [硕士学位论文]. 长沙: 中南大学, 2008.

- [11] 毛先成, 唐艳华, 邓浩. 地质体的三维形态分析方法与应用[J]. 中南大学学报(自然科学版), 2012, 43(2): 588-595.
- [12] 徐述腾, 周永章. 基于深度学习的镜下矿石矿物的智能识别实验研究[J]. 岩石学报, 2018, 34(11): 3244-3252.
- [13] 刘艳鹏, 朱立新, 周永章. 卷积神经网络在矿床找矿预测中的应用——以安徽招吉口铅锌矿床为例. 岩石学报, 2018, 34(11): 3217-3224.
- [14] 宋明春, 伊丕厚, 徐军祥, 崔书学, 沈昆, 姜洪利, 袁文花, 王化江. 胶西北金矿阶梯式成矿模式[J]. 中国科学: 地球科学, 2012, 42(7): 992-1000.
- [15] 宋明春. 胶东三山岛北部海域超大型金矿床的发现及其构造——岩浆背景[J]. 地质学报, 2015, 89(2): 365-383.
- [16] 戴雪灵, 邓湘伟, 彭省临, 杨斌. 玲珑花岗岩在大尹格庄金矿成矿系统中的作用[J]. 地质与勘探, 2011, 47(3): 370-379.
- [17] 陈进, 毛先成, 邓浩. 山东大尹格庄金矿床深部三维定量成矿预测[J]. 地球学报, 2020, 41(2): 179-191.
- [18] Mao, X., Ren, J., Liu, Z., *et al.* (2019) Three-Dimensional Prospectivity Modeling of the Jiaojia-Type Gold Deposit, Jiaodong Peninsula, Eastern China: A Case Study of the Dayingezhuang Deposit. *Journal of Geochemical Exploration*, **203**, 27-44. <https://doi.org/10.1016/j.gexplo.2019.04.002>
- [19] Körtgen, M., Park, G.J., Novotni, M., *et al.* (2003) 3D Shape Matching with 3D Shape Contexts. *Central European Seminar on Computer Graphics*, Bonn, 164.
- [20] Wu, Z., Pan, S., Chen, F., *et al.* (2019) A Comprehensive Survey on Graph Neural Networks. *IEEE Transactions on Neural Networks and Learning Systems*, **32**, 4-24.
- [21] Goyal, P. and Ferrara, E. (2018) Graph Embedding Techniques, Applications, and Performance: A Survey. *Knowledge-Based Systems*, **151**, 78-94. <https://doi.org/10.1016/j.knosys.2018.03.022>
- [22] Kipf, T.N. and Welling, M. (2016) Semi-Supervised Classification with Graph Convolutional Networks.
- [23] Hamilton, W.L., Ying, R. and Leskovec, J. (2017) Inductive Representation Learning on Large Graphs. *Proceedings of the 31st International Conference on Neural Information Processing Systems*, Long Beach, 4-9 December 2017, 1025-1035.
- [24] Hamilton, W.L., Ying, R. and Leskovec, J. (2017) Representation Learning on Graphs: Methods and Applications. *IEEE Data Engineering Bulletin*, **40**, 52-74.
- [25] Aranha, P.S., Monteiro, F.P., Pontes, P.A.I., *et al.* (2015) Supervised Classification of Satellite Images to Analyze Multi-Temporal Land Use and Coverage: A Case Study for the Town of MARABA, State of PARA, Brazil. *Second International Conference on Computer Science and Information Technology*, Marabá City, 9-19. <https://doi.org/10.5121/csit.2015.50602>
- [26] Hu, P., Niu, Z., He, T., *et al.* (2018) Learning Deep Representations in Large Integrated Network for Graph Clustering. 2018 *IEEE First International Conference on Artificial Intelligence and Knowledge Engineering (AIKE)*, Laguna Hills, 26-28 September 2018, 101-105. <https://doi.org/10.1109/AIKE.2018.00022>
- [27] Ye, J., Zhao, J., Ye, K., *et al.* (2020) How to Build a Graph-Based Deep Learning Architecture in Traffic Domain: A Survey. <https://doi.org/10.1109/TITS.2020.3043250>
- [28] Lv, J., Zhong, J., Liang, J., *et al.* (2019) ACE: Ant Colony Based Multi-Level Network Embedding for Hierarchical Graph Representation Learning. *IEEE Access*, **7**, 73970-73982. <https://doi.org/10.1109/ACCESS.2019.2920671>