



地质力学学报
Journal of Geomechanics
ISSN 1006-6616, CN 11-3672/P
中文核心期刊
中国科技核心期刊
CSCD 来源期刊（核心库）

《地质力学学报》预出版论文

论文题目：矿产预测中成矿信息智能提取与识别方法及应用

作者：肖克炎，王政尧，柳炳利，李程，曹昌杰，孔韞辉，王瑶

DOI: 10.12090/j.issn.1006-6616.2026098

投稿时间：2026-07-15

录用时间：2026-09-11

预出版时间：2026-09-24

预出版版权说明

预出版，是指在网络出版或纸质版印刷出版之前，文章的电子版本在网上提前公开，是正式出版的预备版本。预出版的文章是通过严格的“三审制”审查后，本刊确定录用的文章，其内容的著作权等受《著作权法》等法律法规保护。预出版的文章将在之后的印刷版上刊发，印刷版的文章可能与预出版的文章略有不同，预出版文章经录用后便以电子版本形式在网站发出，没有经过排版和编校，会存在部分文字及编排格式与正式出版有出入，但文章主体内容是完全一致的。

学者研究或引述预出版文章，应当以印刷纸质版内容为准；但如果牵涉首创权等时间问题，则应当以适当方式注明文章的预出版日期。

引用格式: 肖克炎, 王政尧, 柳炳利, 等, 2026. 矿产预测中成矿信息智能提取与识别方法进展[J]. 地质力学学报, 32 (×): 000-000. DOI: 10.12090/j.issn.1006-6616.2026098

Citation: XIAO K Y, WANG Z Y, LIU B L, et al., 2026. Advances in intelligent extraction and identification of metallogenic information for mineral prospectivity mapping[J]. Journal of Geomechanics, 32(×): 000-000. DOI: 10.12090/j.issn.1006-6616.2026098

矿产预测中成矿信息智能提取与识别方法进展

肖克炎^{1,2,3,4}, 王政尧^{1,2,3}, 柳炳利^{1,2}, 李程^{1,2}, 曹昌杰^{1,2}, 孔韞辉^{1,2}, 王瑶^{1,2,3}
XIAO Keyan^{1,2,3,4}, WANG Zhengyao^{1,2,3}, LIU Bingli^{1,2}, LI Cheng^{1,2}, CAO Changjie^{1,2}, KONG Yunhui^{1,2}, WANG Yao^{1,2,3}

1. 成都理工大学数学科学学院, 四川 成都 610059;

2. 数学地质四川省重点实验室, 四川 成都 610059;

3. 中国地质科学院矿产资源研究所, 北京 100037;

4. 深地探测与矿产勘查全国重点实验室, 北京 100037

1. School of Mathematical Sciences, Chengdu University of Technology, Chengdu 610059, Sichuan, China;

2. Geomathematics Key Laboratory of Sichuan Province, Chengdu 610059, Sichuan, China;

3. Institute of Mineral Resources, Chinese Academy of Geological Sciences, Beijing 100037, China;

4. State Key Laboratory of Deep Earth and Mineral Exploration, Beijing 100037, China

摘要: 深部、隐伏和覆盖区多源地学观测存在尺度差异、背景干扰与响应多解性, 需要明确成矿认识向可计算、可验证预测信息转化的层级关系与技术路径。围绕地质-构造、地球化学、地球物理-遥感及三维空间信息, 系统梳理空间量化、统计分析、传统机器学习、深度学习、地质知识约束及空间验证等方法, 构建“原始数据—地质对象与异常响应—成矿信息—空间表达—预测变量—定量预测—验证”的层级框架, 并比较不同方法的数据组织形式、适用尺度、样本设计、解释能力及验证方式。归纳物质来源、运移通道、成矿空间、沉淀富集、保存条件和已知矿化 6 类成矿系统信息, 总结二维专题图/证据层与三维属性体 2 类主要空间表达, 以及信息空间化、异常与组合提取、传统机器学习识别、深度空间表征、知识约束、空间与工程验证 6 个技术环节。卷积神经网络 (convolutional neural network, CNN) 与图神经网络/图卷积网络 (graph neural network/graph convolutional network, GNN/GCN) 同属深度学习, 分别适用于规则栅格/体素与非规则关系网络。随机样本划分可能产生空间泄漏, 空间分块、留区、跨矿集区及工程资料验证更适于评价模型迁移能力。成矿信息是成矿认识量化后形成的可计算证据, 其质量首先取决于地质语义、尺度相容性、数据质量、样本代表性和独立验证, 而非算法复杂度。智能成矿信息识别应受成矿系统、矿床模型和找矿模型约束, 并加强多源协同、二维—三维融合、不确定性表达和可解释学习。

关键词: 成矿信息; 智能提取与识别; 成矿模型; 预测变量; 矿产预测

中图分类号: P628 文献标志码: A 文章编号: 1006-6616 (202×) 00-0000-00

DOI: 10.12090 / j. issn. 1006-6616.2026098

Advances in Intelligent Extraction and Identification of Metallogenic Information for Mineral Prospectivity Mapping

基金项目: 新疆维吾尔自治区重点研发计划项目 (2024B03009-3); 四川省自然科学基金项目 (2024NSFSC0009, 2026NSFSCZY0043, 2026NSFSC0238)

This research was financially supported by the Science and Technology Department of Xinjiang Uygur Autonomous Region (2024B03009-3) and the Science and Technology Department of Sichuan Province (2024NSFSC0009, 2026NSFSCZY0043, 2026NSFSC0238)

第一作者: 肖克炎 (1963—), 男, 博士, 研究员, 主要从事矿产资源预测、数学地质与成矿规律研究。Email: kyanxiao@sohu.com

通信作者: 王政尧 (2001—), 男, 在读博士, 研究方向为数学地质、矿产资源预测与地学人工智能。Email: wangzhengyao@stu.cdut.edu.cn

收稿日期: 2026-07-15; 修回日期: 2026-08-31; 录用日期: 2026-09-11; 网络出版日期: 2026-X-X; 责任编辑: 范二平

Received: 2026-07-15; Revised: 2026-08-31; Accepted: 2026-09-11; Available online: ; Handling Editor: Fan Erping

Abstract:[Objective] The exploration of deep, concealed, and covered mineral resources is increasingly affected by scale mismatches, background interference, and ambiguous geoscientific responses. The objective is to clarify the hierarchical relationships and methodological pathways through which metallogenic knowledge can be transformed into computable and verifiable predictive information. **[Methods]** Structural geological, geochemical, geophysical remote-sensing, and three-dimensional spatial information were systematically reviewed. This involved spatial quantification, statistical analysis, conventional machine learning, deep learning, geological-knowledge constraints, and spatial validation. A hierarchical framework of "raw data–geological objects and anomalous responses–metallogenic information–spatial representation–predictive variables–quantitative prediction–validation" was established, and different methods were compared in terms of data organization, applicable scale, sample design, interpretability, and validation strategy. **[Results]** Six classes of mineral system information were synthesized, including material sources, migration pathways, favorable depositional spaces, precipitation and enrichment, preservation conditions, and known mineralization. Two principal spatial representations were summarized, namely two-dimensional thematic maps/evidence layers and three-dimensional attribute volumes. Six technical components were identified: information spatialization, anomaly and multivariate-association extraction, conventional machine-learning recognition, deep spatial representation, knowledge constraints, and spatial or engineering validation. Both convolutional neural networks (CNNs) and graph neural networks/graph convolutional networks (GNNs/GCNs) belong to the field of deep learning, but are suited to different data organizations: CNNs are more appropriate for regular rasters or voxels, whereas GNNs/GCNs are more suitable for irregular relational networks. Random sample splitting may cause spatial leakage, while spatial-block, leave-area-out, cross-district, and engineering validation are more appropriate for evaluating model transferability. **[Conclusions]** Metallogenic information is computable evidence produced by quantifying metallogenic knowledge. Its reliability depends primarily on geological semantics, scale compatibility, data quality, sample representativeness, and independent validation rather than algorithmic complexity. Intelligent extraction and identification of metallogenic information should therefore remain constrained by mineral-system concepts, deposit models, and prospecting models, with future emphasis on multisource integration, coordinated two- and three-dimensional representation, uncertainty characterization, and interpretable learning.

Keywords: metallogenic information; intelligent extraction and identification; metallogenic model; predictive variable; mineral prospectivity mapping

0 引言

深部、隐伏、覆盖区和复杂构造区找矿正在改变矿产预测的基本问题。浅表标志减弱、覆盖层增厚和观测尺度差异,使预测难点由“数据是否充足”转向“多源观测能否形成有效成矿信息”。原始数据只记录地质、地球化学、地球物理、遥感或钻孔响应;只有在成矿系统、矿床模型和找矿模型约束下,经对象识别、空间量化与地质解释,才有可能成为可计算、可检验的预测证据。

矿产资源定量预测经历了“三联式”预测、地理信息系统(geographic information system, GIS)证据层和地球化学异常制图、三维空间预测以及机器学习和深度学习等阶段(Bonham-Carter, 1994; 赵鹏大, 2002, 2007; Yousefi et al., 2021; Sun et al., 2024)。这些方法提高了多源信息综合与非线性关系识别能力,但也暴露出新的问题:传统证据层易受变量选择与尺度参数影响,三维模型可能仅停留于几何形态表达,而数据驱动模型则可能学习到由勘查程度差异和空间自相关所产生的非成矿模式,可解释方法说明的是模型判别机制而非成矿因果。近期 workflow 不确定性、图深度学习、地质约束生成模型和知识嵌入研究进一步表明,算法性能提升不能替代地质语义、样本代表性与独立验证(Zuo et al., 2022; Zuo and Xu, 2023; Zhang et al., 2024; Yan et al., 2025)。

现有研究仍存在数据、异常、成矿信息、预测变量和模型特征层级混用,成矿认识向变量转化不足,二维—三维尺度衔接不稳定,自动学习特征难以回译为地质语义,以及空间与工程验证不足等共性问题。文章不以各类

人工智能算法的分类介绍为重点，而是聚焦成矿认识向可计算、可验证预测信息转化的完整链路。为便于全文讨论，将地质对象识别、异常提取、空间量化及相关信息获取过程概括为“成矿信息提取”，将利用统计学习与智能模型对复杂信息组合和空间模式进行判别的过程概括为“成矿信息识别”。在此基础上，文章从成矿系统角度组织成矿信息及其二维—三维表达，建立“地质对象与异常响应—成矿信息—空间表达—预测变量—定量预测—验证”的层级关系，并从地质约束、空间尺度、不确定性和独立验证等方面讨论智能方法的适用边界。

1 成矿信息的形成、层级及预测作用

1.1 成矿信息的关键输入作用

成矿理论阐释物质来源、运移通道、成矿空间、沉淀富集与保存条件，矿床模型和找矿模型据此组织可观测的控矿因素、找矿标志及空间关系，定量预测模型再将经过量化的证据综合为成矿有利性。成矿信息位于认识与计算之间，其作用不是增加图层数量，而是保持地质语义在空间表达、变量构建和模型解释中的连续性（McCuaig and Hronsky, 2014; Zuo et al., 2025）。

在区域、矿集区和矿床尺度上，同一地质对象可能承担不同的信息角色。区域深大断裂可以表征物质运移背景，矿集区构造交汇可限定有利部位，矿床尺度的断裂面曲率、距离场和连通性则可直接构成变量。因而，成矿信息的有效性既取决于其与目标矿床成因的联系，也取决于观测尺度、表达单元和验证资料是否匹配。

若模型输入只是岩性、断裂、元素和遥感异常的机械堆叠，即使获得较高精度，也可能学习到采样密度、勘查程度或空间自相关，而非矿床形成与保存的地质规律。高质量成矿信息应同时具备成因相关性、矿床类型针对性、空间可表达性、尺度相容性、可计算性、可解释性和可验证性（Nwaila et al., 2024; Zhang et al., 2024）。

矿产预测中理论约束、信息构建、智能模型与预测评价的关系（图1）表明：成矿预测理论和矿床—找矿模型提供知识约束，多源地学数据与三维建模完成数据集成、空间组织和深部结构表达，二者融合后形成成矿信息并进一步构建预测变量；智能预测模型学习多源信息的非线性组合与空间关系，最终服务于二维—三维定量预测、靶区优选和工程验证。三维建模是空间载体与数据组织工具，不与智能模型或定量预测并列。




图 1 矿产预测中理论约束、信息构建、智能模型与预测评价的关系

Fig. 1 Relationships among theoretical constraints, information construction, intelligent models, and prospectivity assessment

(a) Identification of geological objects and anomalous responses: (a1) Original geological map with known mineralization; (a2) Structural object extraction and network construction; (a3) Fault-distance and structural-proximity fields; (a4) Background separation and multi-element anomalies; (a5) Geological objects, attributes, and relationships; (a6) Three-dimensional geological attribute volumes.

(b) Spatial representation of metallogenic information and construction of predictive variables: (b1) Metallogenic-system information matrix; (b2) Two-dimensional thematic and evidence layers; (b3) Three-dimensional attribute and relationship volumes; (b4) Spatial responses of explicit variables; (b5) Variable association structure; (b6) Predictors and data provenance.

(c) Knowledge-data collaborative identification, spatial validation, and feedback updating: (c1) Ore deposit model and knowledge graph constraints; (c2) Multi-representation evidence fusion; (c3) Interpretability and evidence contribution; (c4) Spatial-block and leave-area-out validation; (c5) Probability map; (c6) Uncertainty map; (c7) Target ranking and drilling validation.

1.2 从原始数据到预测特征的层级转换

原始地学数据经质量控制和地质解释形成地质对象或异常响应；这些对象与响应只有在成矿系统、矿床模型或找矿模型约束下，才能转化为具有指示意义的成矿信息。成矿认识经量化后形成可计算的成矿信息，并以二维专题图、证据层或三维属性体等形式进行空间表达；进一步经过尺度匹配、编码和特征构建后，可转化为定量预测模型使用的预测变量。模型特征则是预测变量经选择、组合、降维或深度网络学习后的表示，不应与找矿标志或空间表达形式互换使用。

成矿模式侧重解释矿床形成的过程和机制，矿床模型概括特定矿床类型的诊断性特征组合，找矿模型将这些认识转化为可观测、可量化和可验证的标志，成矿预测模型则综合预测变量并估计空间有利性。为便于方法梳理，将空间量化和信息获取统称为“提取”，将统计学习与智能模型对复杂组合和空间模式的判别称为“识别”；这一划分服务于技术讨论，并非严格的方法学分界。知识图谱和关系嵌入为地质语义结构化提供了新的实现路径（Yan et al., 2024, 2025）。多源地学观测由对象识别、信息提取与空间表达，到预测变量构建、智能建模、空间验证和工程反馈的转换链条如图2所示。




图 2 成矿信息形成及其向预测变量转换的基本框架

Fig. 2 Framework for the formation of metallogenic information and its transformation into predictive variables

(a) Data assembly and spatial representation: (a1) Geochemical data; (a2) Fault network; (a3) Fault-distance field; (a4) Known mineralization and geological background; (a5) Spatial units; (a6) Integrated feature table. (b) Label construction, model training, and spatial validation: (b1) Distance buffers and sample labeling; (b2) Random split; (b3) Spatial group cross validation; (b4) Candidate model performance matrix; (b5) PR curves and calibration assessment; (b6) ROC curves and model selection; (b7) Feature contributions. (c) Model interpretation, evidence testing, and robustness analysis: (c1) SHAP feature attribution; (c2) Counterfactual evidence replacement; (c3) Mean response changes; (c4) Threshold sensitivity; (c5) Donor robustness; (c6) Evidence types and confidence intervals. (d) Target delineation, prioritization, and engineering validation: (d1) Predicted probability map; (d2) High-potential units; (d3) Stability-screened units; (d4) Spatial aggregation and candidate targets; (d5) Target prioritization; (d6) Drilling profile and mineralization validation.

1.3 成矿模型指导下的成矿信息分类

成矿信息分类不宜仅按地质、化探、物探和遥感等数据来源进行机械划分。更合理的做法是先依据成矿系统和矿床模型明确需要识别的成矿要素，再从不同数据源中提取相应信息。成矿系统观点强调金属物质来源、能量来源、流体或物质运移通道、成矿空间、沉淀富集机制和矿化保存条件等要素的耦合（Wyborn et al., 1994; McCuaig and Hronsky, 2014）。

据此，文章以物质来源、运移通道、成矿空间、沉淀富集、保存条件和已知矿化为主线，联系典型地质响应、数据来源、成矿信息表达、预测变量与验证依据（表1）。其目的不是建立固定清单，而是强调从成矿系统要素到观测证据再到模型变量的转换路径；不同矿床类型、尺度和勘查阶段需对具体指标进行调整。

叶天竺等（2007）在综合地质信息矿床模型与矿产资源潜力评价研究中，较早强调利用矿床模型组织地质、物探、化探和遥感等多源信息，使不同来源的观测数据服务于统一的矿床模型和找矿标志体系。这一思路与该综述强调的成矿信息分类一致：数据来源可以是多样的，但信息组织必须回到成矿模型，形成从成矿要素到观测标志再到预测变量的对应关系。

表 1 成矿系统要素及其预测信息表达

Table 1 Mineral-system elements and their representation as predictive information					
成矿系统要素	典型地质响应	主要数据来源	成矿信息表达	预测变量示例	主要验证依据
物质来源	成矿岩体、源岩、含矿层位	地质、地球化学、同位素	源区、岩体专题图或三维体	距岩体、岩性编码、元素丰度	已知矿化与源区关系
运移通道	断裂、剪切带、裂隙系统	地质、物探、三维模型	构造专题图、结构面属性	距断裂、密度、交汇、连通性	矿体沿构造展布关系
成矿空间	接触带、褶皱虚脱、岩性界面	地质、钻孔、三维模型	接触关系、有利空间体	距接触带、界面曲率、邻接编码	矿体赋存位置
沉淀富集	蚀变分带、元素组合、物性响应	地球化学、遥感、物探	异常组合、蚀变专题信息	对数比、异常强度、纹理特征	蚀变-矿化对应关系
保存条件	覆盖层、剥蚀面、后期断裂	地质、遥感、第四纪与构造资料	保存或破坏条件专题信息	覆盖厚度、剥蚀距离、断裂切割	矿体保存状态
已知矿化	矿点、矿体、工程见矿	矿产地、钻孔、槽探、坑探	标签或约束区	正样本、距离标签、品位属性	空间独立与工程验证

2 成矿认识约束下的成矿信息提取与表达

成矿信息提取通常始于成矿系统和目标矿床模型，由此确定需要关注的地质对象、异常响应与空间关系。多源数据经质量控制、地质解释和空间量化后形成成矿信息，并以二维专题图/证据层或三维属性体表达。这些空间表达经过尺度匹配、编码与特征构建后，才成为定量预测模型的预测变量。二维成矿信息专题图和三维属性体是后续定量预测的重要信息载体，其质量直接影响预测变量构建及预测结果的可靠性。

2.1 地质-构造成矿信息提取

地质-构造成矿信息提取的研究重点已由判断地质对象是否存在逐步转向对象之间空间关系的定量表达。早期预测常以距断裂、距岩体等简单指标表示有利性；随着数字矿床模型、三维地质-地球物理建模和空间分析发展，断裂级次与交汇、岩体-地层接触、构造连通性以及三维形态属性被纳入预测变量体系。三维随机森林和深部智能预测研究进一步强调地质界面、体素属性与矿化空间关系的联合约束（向杰等，2016; Xiang et al., 2020; 毛先成等，2026）。

这一进展的关键不在于把更多图层输入模型，而在于辨明哪些关系对目标矿床的形成和定位具有约束。断裂的预测意义可能来自级次、产状、交汇或连通性，岩体的意义可能来自期次、边界与围岩组合，蚀变的意义则取决于分带、强度及其与矿体的空间对应。二维地质图可支持区域对象及其邻近关系提取，三维模型进一步提供界面距离、曲率、方向变化和体素占比等深部属性。

变量构建应随矿床类型改变。斑岩型矿床通常关注侵入体边部、环状-放射状构造与蚀变分带的组合；矽卡岩型矿床更重视成矿岩体与碳酸盐岩接触带的延伸及邻近关系；构造蚀变岩型金矿则需突出断裂级次、剪切带连通性和韧-脆性转换部位。相同的距离、密度或拓扑指标因地质对象和成矿过程不同而具有不同含义，其参数和阈值必须由已知矿化关系与尺度敏感性检验共同约束。

三维构造模型能够把断裂由二维线性要素转化为空间结构面或实体，进一步表达断裂的产状、延伸、切割关系和组合样式。三维断裂系统的空间展布如图 3 所示，其中不同断裂实体可进一步量化为距离场、方位差、交汇关系、曲率、连通性以及与岩体、矿体和地层界面的空间关系。这类三维构造属性比单纯的二维断裂缓冲区更适合描述深部控矿通道和有利构造部位。




图 3 三维断裂系统及其空间形态表达
Fig. 3 Three-dimensional fault system and its spatial geometric representation


2.2 地球化学成矿信息提取

地球化学成矿信息提取已由单元素阈值圈异常转向元素组合、分带结构和地质背景的联合分析。主成矿元素、伴生元素及前缘晕—近矿晕—尾晕的空间关系，只有与目标矿床的成矿过程和赋矿地质位置一致，才具有稳定的预测意义；孤立高值首先是候选异常，而不是已经解释的成矿信息。

地球化学数据具有组成约束，闭合效应可能造成元素间虚假相关，因此在多元素组合识别中有必要采用成分数据分析（CoDA）及对数比变换，并结合稳健统计和多元统计降低极端值与非正态分布的影响（Aitchison, 1986）。同时，区域背景与局部背景并不等同，岩性背景分区、不同采样介质的可比性、采样粒度、分析批次和质量控制都会影响异常位置与强度；近期地质约束异常识别研究也表明，纯数据驱动的高值模式仍需回到矿床模型解释（Sabbaghi et al., 2024）。

分形与多重分形方法可刻画背景-异常分异和多尺度结构（Cheng et al., 1994），但统计分异仍需经过地质载体、元素组合和空间分带解释。钻孔品位、矿化强度及多元素异常可在统一坐标框架中进行三维插值或体素化表

达，从二维异常图进一步转化为具有深度约束的三维地球化学属性体。钻孔约束下三维地球化学信息的空间表达形式如图 4 所示，其可用于识别异常体的形态、连续性、叠置关系及深部延伸。具体插值方法、异常阈值和体素尺度应开展敏感性分析，并结合已知矿化和独立钻孔检验其稳定性，避免将插值伪影或局部高值误判为稳定的深部成矿信息。



a—TFe 三维地球化学分布图；b—Nb₂O₅ 三维地球化学分布图；c、TR₂O₃—三维地球化学分布图
图 4 三维地球化学属性体的空间表达

Fig. 4 Three-dimensional spatial representation of geochemical attribute volumes (a) three-dimensional geochemical distribution of TFe; (b) three-dimensional geochemical distribution of Nb₂O₅; (c) three-dimensional geochemical distribution of TR₂O₃

2.3 地球物理与遥感成矿信息提取

地球物理与遥感信息提取的重点已由单纯圈定场值高低转向异常边界、梯度、方向、连续性以及与隐伏地质体和控矿构造的对应。重磁电资料可约束隐伏岩体、断裂系统、深部界面和物性体，遥感资料可识别铁染、羟基、碳酸盐化、硅化及线性构造；机器学习正在促进多传感器特征提取，但其结果仍受训练样本、传感器尺度和地表覆盖条件制约（Shirmard et al., 2022）。

连续场的结构特征可通过梯度、边缘、方向、纹理和多尺度分解等方式量化，并与断裂、岩体、接触界面和已知矿化进行空间对照。对于物探资料，应优先解释异常所对应的地质体、界面或物性差异；对于遥感资料，则应将蚀变矿物组合、线环构造和覆盖条件纳入判别。只有当异常位置、形态和方向与目标矿床模型及控矿关系相一致时，物探-遥感响应才能稳定转化为预测变量。

2.4 三维空间成矿信息提取

三维地质模型用于集成地质、物探、钻孔和解释成果，表达断裂、褶皱、岩体、接触面、矿体以及地球化学和物性属性场的深部结构；其本身不是三维成矿预测模型，也不直接等同于预测结果。三维成矿信息提取是在统一空间载体上，将断裂结构面、地球化学属性体、矿体与其他地质界面转化为距离场、方向差、曲率、连通性、体素属性和空间邻接关系，再经尺度匹配和编码形成预测变量（Deng et al., 2022; Zheng et al., 2024; 毛先成等, 2026）。三维构造与三维地球化学信息的典型空间表达如图 3、图 4 所示，说明深部预测所使用的信息既包括几何关系，也包括连续属性场。

围绕模型约束下的三维矿产预测，相关研究形成了较为连续的技术演进路径。在甲玛铜多金属矿案例中，Xiao et al. (2015) 将 GIS 思路扩展到三维空间，通过三维证据层表达控矿构造、成矿地质体和矿化空间关系；Li et al. (2016) 进一步改进模型约束的三维缓冲分析，把断裂、岩体、接触带等地质对象转化为适合体素预测的距离和邻近关系；Xiang et al. (2020) 在铜陵矿集区引入随机森林开展三维矿产预测，体现了三维预测变量与非线性识别模型的结合；Xiao et al. (2021) 以拉拉铜矿为例，将深部成矿预测理论、三维建模和定量预测相衔接，强调深部靶区应受成矿认识和三维证据共同约束；Deng et al. (2022) 从三维地质模型中学习成矿有利性；Zheng et al. (2024) 进一步通过深度多模态融合整合三维地质模型与数值模拟数据，表明三维信息识别应同时考虑地质结构与成矿动力过程。上述研究说明，深度学习可识别复杂空间模式，但其有效性仍依赖三维地质语义和已知矿化约束。

同时，上述工作形成了较为清晰的技术路径：成矿模型确定深部信息类型，三维建模提供统一空间载体，构造实体、地球化学属性体、距离场和体素属性完成量化，机器学习或深度学习识别多源组合，最终通过已知矿体和新增工程进行检验。三维矿体、成矿高概率区与预测靶区的空间关系示例（图 5）表明，预测结果以三维高概率体表达，并在与矿体空间对应及工程可实施性综合判断的基础上进一步圈定靶区。因此，三维预测成果不应停留在概率体展示，而应完成“预测高值—地质解释—靶区圈定—工程验证”的转换。




图 5 三维矿体、成矿高概率区与预测靶区的空间关系

Fig. 5 Spatial relationship among three-dimensional orebodies, high-probability mineralization zones and prospecting targets

3 成矿信息智能提取与识别方法

成矿信息的提取与识别构成连续的信息处理过程。在实际矿产预测中，地质对象识别、异常提取、空间量化和模式判别通常相互交织。将空间量化和信息获取统称为“提取”，将利用统计学习和智能模型辨识复杂组合与空间模式称为“识别”；这一技术划分不改变二者共同受成矿认识、数据质量、空间尺度和验证条件约束的事实。

从技术层级看，地学信息首先通过 GIS 和三维空间分析实现对象、关系与尺度的量化，统计分析进一步识别背景—异常分异及元素组合；传统机器学习和深度学习分别处理显式变量组合与复杂空间表征；成矿模型、专家知识和知识图谱贯穿变量筛选、关系约束和结果解释，空间分块、跨区及工程验证则检验方法能否推广。文章据此归纳了各技术环节的主要作用与局限（表 2）。

3.1 地学信息空间量化与特征构建

GIS 空间分析构成地质认识进入计算的基础。距离、密度、缓冲、方向和拓扑方法可描述断裂、岩体、接触带、蚀变带与矿化之间的二维关系；三维建模进一步支持界面距离、曲率、方向变化、体素占比与连通性分析。研究重点已由单一对象邻近性转向多对象复合关系及其尺度稳定性。

变量必须与矿床类型和成矿位置相对应：斑岩型矿床可围绕侵入体边部、环状—放射状构造和蚀变分带构建变量；矽卡岩型矿床应突出岩体—碳酸盐岩接触关系及其三维延伸；构造蚀变岩型金矿则更关注断裂级次、剪切带连通性和韧—脆性转换。此类例子说明，空间分析方法可以通用，变量的地质含义却不能脱离矿床模型。

尺度选择决定空间特征能否保持地质意义。像元大小、搜索半径、缓冲距离和体素尺度若与矿床规模、地质图比例尺及采样密度不匹配，可能造成信息平滑、边界偏移或虚假关联（Zhang et al., 2024）。因此，应比较多组尺度并以已知矿化和空间稳定性检验参数，而非固定套用经验阈值。

3.2 统计分析 with 异常信息提取

统计分析主要服务于背景-异常分离、元素组合识别和候选变量筛选。稳健统计可降低极端值影响，多元统计和 CoDA 适于处理元素协同及组成约束，分形与多重分形方法用于描述尺度相关的异常结构；证据权重和逻辑回归可估计成矿信息与已知矿化之间的条件联系（Agterberg et al., 1993）。这些方法形成的是异常或组合证据，仍需地质背景解释后才能认定为成矿信息。

统计判别的价值在于比较信息组合的稳定性，而非把单一高值等同于有利性。例如，断裂邻近、有利地层、岩体接触和多元素异常的共同出现，比任一单变量更接近完整的成矿证据链；但组合关系还应在岩性背景分区、不同采样介质和分析批次之间检验，避免把背景差异误判为成矿分异。

统计相关不能证明成因联系。变量贡献可能受勘查程度、采样密度、负样本设置和空间自相关影响，阈值也可能随局部背景与尺度变化。因而，候选信息应同时接受异常阈值稳定性、成矿模式一致性和空间独立性检验，明确其适用范围和失效条件。

3.3 机器学习与空间模式识别

3.3.1 传统机器学习

随机森林、支持向量机、梯度提升、贝叶斯网络和集成学习等传统机器学习方法，以人工构建或统计筛选的预测变量为输入，适用于样本规模有限而地质变量相对明确的情形（Yousefi et al., 2021）。其优势在于处理非线性、变量交互和条件依赖，并可结合特征重要性分析；主要风险来自标签偏差、类别不平衡、勘查程度差异和空间泄漏，样本代表性与负样本构建因而需要单独检验（Parsa and Cumani, 2025; Zhang et al., 2025）。

3.3.2 深度学习

深度学习可在多源、高维数据中学习复杂空间表征。卷积神经网络（CNN）适于规则栅格中局部纹理、边界与多尺度组合的识别，三维 CNN 面向规则体素中的界面和属性关系，自编码器可用于降维与潜在结构学习（Xiong et al., 2018; Deng et al., 2022; Yang et al., 2022; Zuo et al., 2022; Sun et al., 2024）。

图神经网络或图卷积网络（GNN/GCN）同属深度学习，但数据组织和信息传播机制不同于 CNN。样点、钻孔或地质单元可作为节点，断裂连通、地层接触、岩体邻接和属性相似可作为边，因此更适合非规则样点、地质单元和关系网络（Zuo and Xu, 2023; Sihombing et al., 2024）。若边仅由任意距离阈值构建而缺乏地质含义，关系学习仍可能失去解释基础。

深度模型减少了部分人工特征设计，却未摆脱成矿模型和样本设计的约束。自动学习特征需通过响应区域、局部扰动、敏感性分析和地质空间对比回译为地质语义；训练与验证样本若空间邻近，模型还可能利用空间自相关获得虚高精度。因此，深度学习结果应重点检验跨区适用性，而不能只依据训练区指标评价。

3.4 地质知识约束、模型解释与结果验证

知识与数据协同是一种信息组织和预测建模范式，而不是与统计学习、机器学习或深度学习并列的独立算法。矿床模型、找矿模型、专家知识和知识图谱可前置参与变量筛选、关系定义、样本设计与规则约束；数据驱动方法负责识别高维变量组合，知识约束则用于排除不符合成矿逻辑的关联并支撑结果解释。

特征重要性、部分依赖、Shapley 加性解释（SHapley Additive exPlanations, SHAP）值和敏感性分析揭示模型采用了哪些变量以及响应方向（Lundberg and Lee, 2017; Zuo et al., 2024; Mou et al., 2025; Luo et al., 2026），但其解释的是模型判别机制，不能直接证明矿床成因。解释结果仍需核对重要变量是否对应控矿因素、响应方向是否符合成矿认识、高贡献区是否位于合理地质位置，以及多类信息能否构成完整证据链。

模型验证必须显式处理空间依赖。随机样本划分容易因邻近样本共享地质背景而造成空间泄漏和精度虚高；空间分块交叉验证可降低相邻训练-测试样本的信息重叠，留区验证可检验模型对未参与训练区域的推广能力，留

矿集区或跨矿集区验证则进一步检验关系能否迁移。资料条件允许时，还应按不同勘查阶段实施时间独立验证，并最终以钻孔、槽探、坑探或野外地质事实进行工程验证（Nwaila et al., 2024; Zhang et al., 2024; Parsa et al., 2025）。

验证的目的不是只比较受试者工作特征曲线下面积（Area under the Receiver Operating Characteristic Curve, AUC），而是判断预测信息及模型关系能否推广到未勘查空间。可靠流程应形成“模型约束—信息提取—模式识别—地质解释—空间与工程验证—信息更新”的闭环；只有在统计稳定性、地质合理性、空间连续性和外部可验证性方面均获得支持的特征，才可作为定量预测的有效信息。

表 2 成矿信息提取、智能识别与验证的技术层级

Table 2 Technical hierarchy for metallogenic information extraction, intelligent identification, and validation				
技术环节	技术类别	代表方法	主要作用	主要局限
信息空间化	GIS 与三维空间分析	距离、密度、缓冲、拓扑、曲率、体素化	将地质对象和空间关系转化为可计算表达	参数与尺度敏感，依赖地质解释质量
异常与组合提取	统计与地球化学分析	稳健统计、CoDA、分形、多元分析	分离背景与异常并识别元素组合	统计异常不必然具有成矿意义
模式识别	传统机器学习	RF、SVM、梯度提升、贝叶斯网络	识别显式预测变量的非线性组合	受标签偏差、空间自相关和类别不平衡影响
深度空间表征	深度学习	CNN、3D CNN、自编码器、GNN/GCN	学习规则栅格、体素或关系网络中的复杂特征	解释性、样本需求与跨区迁移能力受限
知识约束	知识—数据协同	矿床模型、规则约束、知识图谱、关系嵌入	约束变量、关系与结果的地质语义	知识结构化成本高，规则可能带入主观性
结果检验	空间与工程验证	空间分块、留区、跨区、钻探与野外验证	检验模型推广性和找矿有效性	独立资料不足，验证成本高

注：CoDA—成分数据分析（compositional data analysis）；RF—随机森林（random forest）；SVM—支持向量机（support vector machine）；3D CNN—三维卷积神经网络（three-dimensional convolutional neural network）。

4 关键问题与发展趋势

4.1 成矿认识向预测特征转化仍不充分

传统综合信息预测体系长期依赖矿床模型、专家经验和找矿标志，当前问题并非矿产预测缺少专家知识，而是成矿认识常以定性规则或经验图层存在，尚未稳定、可复现地转化为模型可使用的预测特征。若直接按数据可得性选择地层、岩体、断裂、元素和物探遥感变量，模型可能获得统计区分能力，却未必表征矿床形成、定位与保存过程。

改进的重点是建立“成矿认识—找矿标志—空间表达—预测变量”的可追溯转换。成矿模式解释过程，矿床模型概括诊断性组合，找矿模型明确可观测标志；随后才通过对对象识别、关系量化、尺度匹配和编码构建变量。每一步都应记录数据来源、参数、阈值和适用尺度，并接受已知矿化及独立区域检验，使专家知识既不被否定，也不以不可复现的隐性判断进入模型。

需要指出的是，现有研究尚未针对不同矿床类型形成统一的预测变量及定量参数体系，具体变量形式、尺度和阈值仍需结合矿床类型、数据条件和勘查阶段进行确定与验证。

4.2 多源成矿信息的尺度一致性与不确定性表达不足

地质图、地球化学样品、物探场、遥感影像、钻孔和三维地质模型分别反映不同空间尺度、不同观测深度和不同精度层次的地质现象。地质图具有制图综合性，地球化学数据受采样介质和地表过程影响，物探数据具有间

接性和多解性，遥感信息主要反映地表响应，钻孔数据可靠但空间覆盖有限。若未经尺度协调便直接叠置，容易将位置误差、分辨率差异和模型解释误差转化为虚假的空间关联。

未来应从单一分辨率统一转向多尺度协同表达。区域尺度重点识别成矿背景、深大构造和岩浆活动，矿集区尺度突出控矿构造、岩体接触关系和异常组合，矿床尺度则关注矿体定位、蚀变分带和深部空间关系。同时，应记录信息来源、精度等级、约束强度和解释不确定性，使成矿信息不仅包含预测值，也包含可信程度； workflow 选择造成的空间差异尤其需要通过模型集合与共识评价显式传播 (Nwaila et al., 2024; Zhang et al., 2024)。

4.3 数据异常、地质异常与成矿信息尚未得到严格区分

异常是相对于背景的统计偏离，但统计异常并不必然具有成矿意义。单元素高值可能源于岩性背景、表生富集或采样误差；重磁电异常可能对应非成矿地质体；遥感蚀变异常也可能由区域变质、风化作用或非成矿热液活动形成。即使模型识别出稳定的高值区，也可能只是对数据空间结构或已知矿点聚集特征的重复表达。

因此，成矿信息识别不能停留在异常强度判断，而应建立“数据异常—地质载体—成矿过程—矿化验证”的解释链。只有当异常的元素组合、空间形态、地质位置和尺度特征与目标矿床模型一致，并得到控矿构造、蚀变矿化或工程资料支撑时，异常才可转化为有效成矿信息。未来研究应强化异常成因判别，区分数据异常、地质异常和成矿异常，避免将异常提取直接等同于找矿信息提取。

4.4 智能识别结果的地质语义与可验证性仍显不足

机器学习和深度学习能够识别高维数据中的非线性组合和复杂空间模式，但模型所学习的特征未必具有明确地质含义。特征重要性、SHAP 值、敏感性分析和注意力权重可以揭示模型的统计判别依据，却不能直接证明变量与成矿过程之间存在因果联系。若缺乏地质语义回译，智能识别结果仍可能停留在“模型为何给出高值”的计算解释层面，而无法回答“该高值为何具有找矿意义”。

提高模型解释力，需要将成矿模型贯穿于变量构建、样本设计、模型训练和结果验证全过程。一方面，应通过知识约束、关系建模和空间规则，使算法识别的特征能够对应成矿地质体、运移通道、容矿空间和矿化响应；另一方面，应采用空间分块、跨区验证和工程资料检验，判断识别结果能否推广至未勘查区域。只有同时满足统计稳定性、地质合理性、空间连续性和工程可验证性，智能识别结果才能成为可靠的成矿信息。

4.5 发展趋势

成矿信息提取与识别将由数据驱动的特征构建，进一步转向成矿模型约束下的知识-数据协同。矿产预测大模型、地质知识图谱和多层次预测数据体系正在促进文本知识、空间证据与模型表征的连接，但跨区泛化、知识可信度和数据治理仍是核心约束 (Yan et al., 2025; 师路易和左仁广, 2026; 张振杰, 2026; 左仁广等, 2026)。

多尺度和二维-三维协同将成为深部成矿信息表达的重要方向。二维信息适用于区域成矿背景分析、有利区筛选和证据组织，三维信息用于刻画控矿构造、成矿地质体、接触界面、矿化体素和深部有利空间。二者应在统一成矿模型和坐标框架下衔接，实现由区域筛选、矿集区聚焦到深部靶位定位的尺度递进 (Zheng et al., 2024; 毛先成等, 2026)。

成矿信息识别还需由确定性结果输出转向不确定性约束和动态验证。模型不仅应说明哪些信息具有成矿意义，还应给出证据来源、可靠程度、适用尺度和失效条件。随着钻孔、物探和地质调查资料持续更新，成矿信息体系也应动态修正，形成“模型指导提取—智能识别—地质验证—信息更新”的闭环；半监督学习和可解释框架为少样本、强不平衡条件提供了新途径 (Luo et al., 2026)。

5 结论

(1) 成矿信息是成矿认识量化后形成的可计算证据, 连接原始地学观测与定量预测。二维专题图/证据层和三维属性体属于成矿信息的空间表达, 经尺度匹配、编码和特征构建后方可转化为预测变量; 找矿标志、预测变量和模型特征处于不同层级, 不能互换使用。

(2) 成矿信息提取与识别是相互交织的连续过程。空间分析和统计分析分别支撑地质关系量化与背景-异常分离, 传统机器学习处理显式变量的非线性组合, CNN 与 GNN/GCN 作为深度学习分支分别面向规则栅格或体素和非规则关系网络; 知识与数据协同贯穿变量构建、模型解释和结果约束, 而非独立算法门类。

(3) 智能方法的有效性取决于地质语义、尺度相容性和独立验证。随机划分可能因空间自相关造成精度虚高, 应结合空间分块、留区或跨矿集区验证, 条件允许时开展时间独立验证, 并由钻孔、槽探、坑探或野外事实最终检验。未来应加强模型约束下的多源信息组织、二维-三维协同、不确定性表达和可解释学习。

作者贡献声明

肖克炎负责论文选题构思、总体框架设计和学术把关; 王政尧负责文献整理、研究进展梳理、图表组织和论文初稿撰写; 柳炳利、李程参与文献核查、方法归纳和图件整理; 曹昌杰、孔韞辉、王瑶参与资料整理、内容讨论和稿件修改。所有作者均阅读并同意稿件的提交和发表。

Author's Contributions: XIAO Keyan conceived the topic, designed the overall framework, and supervised the academic content; WANG Zhengyao organized the literature, summarized the research progress, prepared the figures and tables, and drafted the manuscript; LIU Bingli and LI Cheng participated in reference checking, methodological synthesis and figure preparation; CAO Changjie, KONG Yunhui and WANG Yao contributed to data organization, discussion and manuscript revision. All authors have read and approved the manuscript.

利益冲突声明

所有作者声明不存在任何利益冲突。

Conflict of Interests: All authors declare no conflict of interests.

参考文献

- AGTERBERG F P, BONHAM-CARTER G F, CHENG Q, et al., 1993. Weights of evidence modeling and weighted logistic regression for mineral potential mapping[M]//DAVIS J C, HERZFELD U C. Computers in geology: 25 years of progress. New York: Oxford University Press: 13-32.
- AITCHISON J, 1986. The statistical analysis of compositional data[M]. London: Chapman and Hall.
- BONHAM-CARTER G F, 1994. Geographic information systems for geoscientists: modelling with GIS[M]. Oxford: Pergamon.
- CHENG Q M, AGTERBERG F P, BALLANTYNE S B, 1994. The separation of geochemical anomalies from background by fractal methods[J]. Journal of Geochemical Exploration, 51(2): 109-130, doi: 10.1016/0375-6742(94)90013-2.
- DENG H, ZHENG Y, CHEN J, et al., 2022. Learning 3D mineral prospectivity from 3D geological models using convolutional neural networks: application to a structure-controlled hydrothermal gold deposit[J]. Computers & Geosciences, 161: 105074, doi: 10.1016/j.cageo.2022.105074.
- LI N, BAGAS L, LI X H, et al., 2016. An improved buffer analysis technique for model-based 3D mineral potential mapping and its application[J]. Ore Geology Reviews, 76: 94-107, doi: 10.1016/j.oregeorev.2015.12.002.
- LUNDBERG S M, LEE S I, 2017. A unified approach to interpreting model predictions[C]//Proceedings of the 31st international conference on neural information processing systems. Long Beach: Curran Associates Inc.: 4768-4777.

LUO Z J, FARAHBAKHSH E, HORE S, et al., 2026. DEEP-SEAM: an explainable semi-supervised deep learning framework for mineral prospectivity mapping[J]. *Geoscientific Model Development*, 19(7): 2593-2625, doi: 10.5194/gmd-19-2593-2026.

MAO X C, DUAN X M, DENG H, et al., 2026. Intelligent 3D prediction of deep mineral resources: theory, methods, and challenges[J]. *Earth Science*, 51(3): 793-815, doi: 10.3799/dqkx.2025.227. (in Chinese with English abstract)

MCCUAIG T C, HRONSKY J M A, 2014. The mineral system concept: the key to exploration targeting[M]//KELLEY K D, GOLDEN H C. Building exploration capability for the 21st century. Littleton: Society of Economic Geologists: 153-175, doi: 10.5382/SP.18.08.

MOU N N, CARRANZA E J M, XUE J L, et al., 2025. Interpretable machine learning for mineral prospectivity mapping in the Qulong-Jiama district, Tibet, China[J]. *Ore Geology Reviews*, 182: 106659, doi: 10.1016/j.oregeorev.2025.106659.

NWAILA G T, ZHANG S E, BOURDEAU J E, et al., 2024. Mineral reconnaissance through scientific consensus: first national prospectivity maps for PGE-Ni-Cu-Cr and Witwatersrand-type Au deposits in South Africa[J]. *Natural Resources Research*, 33(6): 2357-2384, doi: 10.1007/s11053-024-10390-w.

PARSA M, CUMANI R, 2025. Class label representativeness in machine learning-based mineral prospectivity mapping[J]. *Natural Resources Research*, 34(4): 1901-1925, doi: 10.1007/s11053-025-10468-z.

PARSA M, LAWLEY C J M, CAWOOD T, et al., 2025. Pan-Canadian predictive modeling of lithium-cesium-tantalum pegmatites with deep learning and natural language processing[J]. *Natural Resources Research*, 34(2): 639-668, doi: 10.1007/s11053-024-10438-x.

SABBAGHI H, TABATABAEI S H, FATHIANPOUR N, 2024. Geologically-constrained GANomaly network for mineral prospectivity mapping through frequency domain training data[J]. *Scientific Reports*, 14(1): 6236, doi: 10.1038/s41598-024-56644-8.

SHI L Y, ZUO R G, 2026. Foundation model for mineral prospectivity mapping[J]. *Earth Science*, 51(3): 832-848, doi: 10.3799/dqkx.2025.190. (in Chinese with English abstract)

SHIRMARD H, FARAHBAKHSH E, MÜLLER R D, et al., 2022. A review of machine learning in processing remote sensing data for mineral exploration[J]. *Remote Sensing of Environment*, 268: 112750, doi: 10.1016/j.rse.2021.112750.

SIHOMBING F M H, PALIN R M, HUGHES H S R, et al., 2024. Improved mineral prospectivity mapping using graph neural networks[J]. *Ore Geology Reviews*, 172: 106215, doi: 10.1016/j.oregeorev.2024.106215.

SUN K, CHEN Y S, GENG G S, et al., 2024. A review of mineral prospectivity mapping using deep learning[J]. *Minerals*, 14(10): 1021, doi: 10.3390/min14101021.

WYBORN L A I, HEINRICH C A, JAKES A L, 1994. Australian Proterozoic mineral systems: essential ingredients and mappable criteria[C]//Proceedings of the AusIMM annual conference. Darwin: Australasian Institute of Mining and Metallurgy: 109-115.

XIANG J, CHEN J P, HU B, et al., 2016. 3D metallogenic prediction based on 3D geological-geophysical model: a case study in Tongling mineral district of Anhui[J]. *Advances in Earth Science*, 31(6): 603-614. (in Chinese with English abstract)

XIANG J, XIAO K Y, CARRANZA E J M, et al., 2020. 3D mineral prospectivity mapping with random forests: a case study of Tongling, Anhui, China[J]. *Natural Resources Research*, 29(1): 395-414, doi: 10.1007/s11053-019-09578-2.

XIAO K Y, LI N, PORWAL A, et al., 2015. GIS-based 3D prospectivity mapping: a case study of Jiama copper-polymetallic deposit in Tibet, China[J]. *Ore Geology Reviews*, 71: 611-632, doi: 10.1016/j.oregeorev.2015.03.001.

XIAO K Y, XIANG J, FAN M J, et al., 2021. 3D mineral prospectivity mapping based on deep metallogenic prediction theory: a case study of the Lala copper mine, Sichuan, China[J]. *Journal of Earth Science*, 32(2): 348-357, doi: 10.1007/s12583-021-1437-8.

XIONG Y H, ZUO R G, CARRANZA E J M, 2018. Mapping mineral prospectivity through big data analytics and a deep learning algorithm[J]. *Ore Geology Reviews*, 102: 811-817, doi: 10.1016/j.oregeorev.2018.10.006.

YAN Q, ZHAO J, XUE L F, et al., 2024. Mineral prospectivity mapping based on spatial feature classification with geological map knowledge graph embedding: case study of gold ore prediction at Wulonggou, Qinghai Province (western China)[J]. *Natural Resources Research*, 33(6): 2385-2406, doi: 10.1007/s11053-024-10386-6.

YAN Q, PEI Y, XUE L F, et al., 2025. Mineral prospectivity mapping: an interpretable classifier combining catchment basin and knowledge graph embedding[J]. *Ore Geology Reviews*, 184: 106758, doi: 10.1016/j.oregeorev.2025.106758.

YANG N, ZHANG Z K, YANG J H, et al., 2022. Mineral prospectivity prediction by integration of convolutional autoencoder network and random forest[J]. *Natural Resources Research*, 31(3): 1103-1119, doi: 10.1007/s11053-022-10038-7.

- YE T Z, XIAO K Y, YAN G S, 2007. Methodology of deposit modeling and mineral resource potential assessment using integrated geological information[J]. Earth Science Frontiers, 14(5): 11-19. (in Chinese with English abstract)
- YOUSEFI M, CARRANZA E J M, KREUZER O P, et al., 2021. Data analysis methods for prospectivity modelling as applied to mineral exploration targeting: state-of-the-art and outlook[J]. Journal of Geochemical Exploration, 229: 106839, doi: 10.1016/j.gexplo.2021.106839.
- ZHANG S E, LAWLEY C J M, BOURDEAU J E, et al., 2024. Workflow-induced uncertainty in data-driven mineral prospectivity mapping[J]. Natural Resources Research, 33(3): 995-1023, doi: 10.1007/s11053-024-10322-8.
- ZHANG S E, COUTTS D, PARSA M, et al., 2025. Recursive annotation for negative labeling in data-driven mineral prospectivity mapping[J]. Natural Resources Research, 34(5): 2373-2402, doi: 10.1007/s11053-025-10510-0.
- ZHANG Z J, 2026. Construction of multilayered mineralization prediction data based on geological big data and artificial intelligence[J]. Earth Science, 51(3): 849-861, doi: 10.3799/dqkx.2026.010. (in Chinese with English abstract)
- ZHAO P D, 2002. "Three-component" quantitative resource prediction and assessments: theory and practice of digital mineral prospecting[J]. Earth Science: Journal of China University of Geosciences, 27(5): 482-489. (in Chinese with English abstract)
- ZHAO P D, 2007. Quantitative mineral prediction and deep mineral exploration[J]. Earth Science Frontiers, 14(5): 1-10. (in Chinese with English abstract)
- ZHENG Y, DENG H, WU J J, et al., 2024. Deep multimodal fusion for 3D mineral prospectivity modeling: integration of geological models and simulation data via canonical-correlated joint fusion networks[J]. Computers & Geosciences, 188: 105618, doi: 10.1016/j.cageo.2024.105618.
- ZUO R G, LUO Z J, XIONG Y H, et al., 2022. A geologically constrained variational autoencoder for mineral prospectivity mapping[J]. Natural Resources Research, 31(3): 1121-1133, doi: 10.1007/s11053-022-10050-x.
- ZUO R G, XU Y, 2023. Graph deep learning model for mapping mineral prospectivity[J]. Mathematical Geosciences, 55(1): 1-21, doi: 10.1007/s11004-022-10015-z.
- ZUO R G, CHENG Q M, XU Y, et al., 2024. Explainable artificial intelligence models for mineral prospectivity mapping[J]. Science China Earth Sciences, 67(9): 2864-2875, doi: 10.1007/s11430-024-1309-9.
- ZUO R G, YANG F F, CHENG Q M, et al., 2025. A novel data-knowledge dual-driven model coupling artificial intelligence with a mineral systems approach for mineral prospectivity mapping[J]. Geology, 53(3): 284-288, doi: 10.1130/G52970.1.
- ZUO R G, ZHANG Z J, YANG F F, et al., 2026. Big data and artificial intelligence-driven mineral prospectivity mapping[J]. Earth Science, 51(3): 779-792, doi: 10.3799/dqkx.2026.006. (in Chinese with English abstract)

附中文参考文献

- 毛先成, 段新明, 邓浩, 等, 2026. 深部矿产三维智能预测理论、方法与挑战[J]. 地球科学, 51(3): 793-815, doi: 10.3799/dqkx.2025.227.
- 师路易, 左仁广, 2026. 矿产预测大模型[J]. 地球科学, 51(3): 832-848, doi: 10.3799/dqkx.2025.190.
- 向杰, 陈建平, 胡彬, 等, 2016. 基于三维地质—地球物理模型的三维成矿预测: 以安徽铜陵矿集区为例[J]. 地球科学进展, 31(6): 603-614.
- 叶天竺, 肖克炎, 严光生, 2007. 矿床模型综合地质信息预测技术研究[J]. 地学前缘, 14(5): 11-19.
- 张振杰, 2026. 基于地学大数据和人工智能的多层次矿产预测数据构建[J]. 地球科学, 51(3): 849-861, doi: 10.3799/dqkx.2026.010.
- 赵鹏大, 2002. "三联式"资源定量预测与评价: 数字找矿理论与实践探讨[J]. 地球科学: 中国地质大学学报, 27(5): 482-489.
- 赵鹏大, 2007. 成矿定量预测与深部找矿[J]. 地学前缘, 14(5): 1-10.
- 左仁广, 张振杰, 杨帆帆, 等, 2026. 大数据人工智能驱动的矿产预测[J]. 地球科学, 51(3): 779-792, doi: 10.3799/dqkx.2026.006.

获奖者简历:



肖克炎, 男, 1963年11月生, 湖南石门人, 二级研究员, 博士生导师, 俄罗斯科学院与工程院外籍院士。1991年毕业于长春地质学院, 获数学地质专业博士学位; 1991—1993年在中国地质大学(武汉)矿产普查与勘探博士后流动站从事博士后研究, 1993年进入中国地质科学院矿产资源研究所工作, 1996年破格晋升研究员, 曾任成矿远景区划研究室总工程师、主任及矿产资源研究所副总地质师等职。长期从事数学地质、矿产资源评价、成矿预测、深部矿产资源预测及矿产资源大数据智能评价研究。长期以来, 肖克炎围绕矿产资源预测评价理论与技术开展系统研究, 建立了成矿系列综合地质信息预

测理论方法和“找矿模型—三维建模—定量预测”深部矿产资源预测理论方法体系，研发了区域矿产资源预测评价方法平台（MRAS）及“探矿者”软件系统，并负责或参与全国重要矿产资源潜力评价、深部资源预测等重大科研工作。近年来进一步开展大数据、人工智能与地质知识融合的智能矿产预测研究，研究方向由数字化矿产预测逐步拓展至大数据智能评价和知识—数据联合驱动的智能找矿。已出版专著 16 部，发表论文 300 余篇。先后获国家科学技术进步奖二等奖 3 项、省部级科学技术奖一等奖 4 项、二等奖 2 项；2023 年获第十八次李四光地质科学奖科研奖。享受国务院政府特殊津贴，入选新世纪百千万人才工程国家级人选，并获原国土资源部百名跨世纪科技人才、自然资源部科技创新人才、湘江学者、楚天学者、珠峰人才等荣誉。

《地质力学学报》预出版