

机器学习在矿床学中的应用进展

钱哪哪, 冯世博, 丁伟*

桂林理工大学地球科学学院, 广西 桂林

收稿日期: 2026年4月11日; 录用日期: 2026年5月11日; 发布日期: 2026年5月29日

摘要

机器学习方法具有处理复杂高维数据的能力, 且具有非线性模式识别优势, 因此, 在矿床学多个核心领域的应用日益深入。本文从矿床成因与类型判别、蚀变矿物光谱识别以及矿产远景预测三个方面, 系统梳理了近年来机器学习在矿床学研究中的主要进展。在矿床成因与类型判别方面, 以黄铁矿、磁铁矿、闪锌矿和磷灰石等矿物的微量元素数据为研究对象, 研究者利用随机森林、支持向量机、XGBoost等算法构建的分类模型准确率普遍超过90%, SHAP等可解释性工具的引入也推动了“黑箱”模型向地质可解释方向的转变。在蚀变矿物光谱识别方面, 短波红外(SWIR)光谱、高光谱遥感和蚀变矿物化学与机器学习的结合, 将蚀变信息从定性描述转变为定量成矿指示工具, 为多尺度、多方法协同的隐伏矿体精细定位提供了技术支撑, 在深部金矿、斑岩铜矿等多类矿床勘查中均取得显著进展。在矿产远景预测方面, 多源数据融合、和三维成矿预测成为当前的重要发展方向, 预测模式正从传统的二维平面靶区圈定快速向三维深部靶区定位转变。目前, 机器学习在矿床学中的应用仍受数据质量参差、地质知识耦合深度不足等因素制约。未来, 将地质先验知识有效嵌入数据驱动模型, 有望成为推动这一领域实现突破的关键路径。

关键词

机器学习, 矿床学, 成因识别, 矿床类型判别, 矿产远景预测

Advances in the Application of Machine Learning to Ore Deposit Research

Nana Qian, Shibo Feng, Wei Ding*

School of Earth Sciences, Guilin University of Technology, Guilin Guangxi

Received: April 11, 2026; accepted: May 11, 2026; published: May 29, 2026

Abstract

Machine learning methods possess the capability to process complex, high-dimensional data and

*通讯作者。

文章引用: 钱哪哪, 冯世博, 丁伟. 机器学习在矿床学中的应用进展[J]. 地球科学前沿, 2026, 16(5): 851-860.

DOI: 10.12677/ag.2026.165077

offer advantages in nonlinear pattern recognition, leading to their increasingly deep application across several core areas of ore deposit research. This paper systematically reviews recent advances in the application of machine learning to ore deposit studies from three perspectives: ore genesis and deposit type discrimination, alteration mineral spectral identification, and mineral prospectivity mapping. In the area of ore genesis and deposit type discrimination, researchers have used trace element data from minerals such as pyrite, magnetite, sphalerite, and apatite to build classification models using algorithms including Random Forest, Support Vector Machine, and XGBoost, with accuracies generally exceeding 90%. The introduction of interpretability tools such as SHAP has also facilitated the transition of “black-box” models toward geologically interpretable frameworks. In alteration mineral spectral identification, the integration of shortwave infrared (SWIR) spectroscopy, hyperspectral remote sensing, and alteration mineral chemistry with machine learning has transformed alteration information from qualitative descriptions into quantitative metallogenic indicator tools. This provides technical support for multi-scale, multi-method synergistic precise localization of concealed ore bodies, with notable progress achieved in the exploration of various deposit types including deep gold deposits and porphyry copper deposits. In mineral prospectivity mapping, multi-source data fusion and three-dimensional metallogenic prediction have emerged as important current development directions, with prediction paradigms rapidly shifting from traditional two-dimensional planar target delineation to three-dimensional deep target localization. At present, the application of machine learning in ore deposit research remains constrained by factors such as uneven data quality and insufficient depth of coupling with geological knowledge. In the future, effectively embedding geological prior knowledge into data-driven models is expected to become a key pathway for achieving breakthroughs in this field.

Keywords

Machine Learning, Ore Deposit Research, Genetic Discrimination, Deposit-Type Classification, Mineral Prospectivity Prediction

Copyright © 2026 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

矿床成因机制的解析和控矿规律的研究，一直是指导找矿实践的核心科学问题。近年来，随着浅部资源逐渐开发殆尽，深部和隐伏矿产的勘查已成为保障战略性矿产资源安全的迫切需求。在这一背景下，矿床学研究所依赖的数据体系发生了根本性的转变——从过去以宏观地质现象描述为主，逐步扩展到涵盖 LA-ICP-MS 微区原位分析、大尺度地球化学扫面以及高精度地球物理探测等多种来源的海量数据[1]-[3]。这些数据普遍具有维度高、非线性强、噪声大等特点，传统的统计图解和人工经验判别方法在处理此类数据时难以发现它们的非线性联系。

正是在这样的需求驱动下，机器学习凭借其在高维空间中进行复杂模式识别和特征提取方面的优势，逐步进入矿床学研究者的视野，并在近十年间取得了快速发展[2][4]。回顾其发展历程，大致可以划分为三个阶段：第一阶段(约 1990 年代至 2010 年)，以神经网络和支持向量机为代表的早期算法主要用于地球化学异常的简单识别；第二阶段(约 2010 年至 2020 年)，随机森林等集成学习方法的兴起推动了矿产远景预测和矿床分类研究进入定量化阶段；第三阶段(2020 年至今)，深度学习、可解释机器学习和多源数据融合技术的发展推动研究进一步延伸到成因分析、三维预测等前沿领域[1][3]。特别是 2024 年以来，研究呈现出样本规模向万级跃升、可解释性分析成为标配、三维预测从学术探索走向实际应用等显著趋势[5]-[7]。尤其值得关注的是，以指示矿物微量元素为研究对象的机器学习建模，已逐渐成长为矿床成因研

究的一个重要分支[2] [8]。

虽然机器学习在矿床学成因研究中得到广泛应用，但人工智能技术在矿床学中的应用并不是要取代地质学家的经验判断，而是将其作为一种高维特征提取工具，服务于矿床成因解析的整体证据链构建。本文以“成因识别-类型判别-空间预测”为主线，对该方向的研究进展与发展趋势进行综述，特别需要指出的是，这三个方向并非彼此孤立的平行应用，而是构成了一个逐级递进、相互支撑的机器学习驱动型勘查 workflow：首先，利用矿物地球化学模型深化对区域成矿规律的认识；其次，借助光谱识别模型快速圈定重点蚀变区；最后，将这些知识和信息作为高质量预测变量，输入三维成矿预测模型以实现精准靶区定位。本文旨在为机器学习在矿床学中的后续应用研究提供参考。

2. 核心机器学习方法及地学适用性

目前应用于矿床学研究的机器学习方法，按照学习范式可以大体划分为监督学习、无监督学习与深度学习三个类别[1] [3]。然而，方法的选择不应是随机的，而应基于矿床学数据的固有特性进行匹配。矿床学数据普遍具有维度高、非线性强、样本不均衡(已知矿点远少于无矿点)、空间自相关及测量误差复杂等特点。传统统计方法(如线性判别分析、逻辑回归)在处理此类数据时，常受困于线性假设和多重共线性问题。机器学习，特别是集成学习与深度学习，因其灵活的模型结构和强大的拟合能力，为解析这类复杂数据提供了新范式。

监督学习是目前矿床学中应用最为广泛的范式。它的基本思路是利用已有标签的地质数据集(如已知矿床类型的矿物微量元素数据)，训练模型去学习从输入特征到目标类别的映射关系。在具体算法层面，随机森林(RF)和梯度提升树(如 XGBoost、LightGBM、CatBoost)是目前应用最广的算法。其受青睐的根本原因在于：① 对非线性与高阶交互效应的天然捕获能力，能够自动建模如“Cu 在特定温度区间与 As 协同富集”这类复杂关系；② 对异常值和噪声的鲁棒性，矿化过程往往产生离群值，而树模型的分裂机制对此不敏感；③ 内置的特征重要性评估，可直接输出驱动分类的关键元素，与矿床学中“标型元素”的研究范式高度契合。例如，在黄铁矿成因判别中，XGBoost 模型能自动识别 Cu、Co、As 作为最重要的判别特征，这与热液成矿理论中这些元素对流体氧化还原状态敏感的认知一致。支持向量机(SVM)在小样本、高维数据(如数百个样本、数十种元素)上表现出色，其通过核函数将原始空间映射到高维特征空间，从而找到最优分类超平面。但当样本量超过万级时，SVM 的计算效率和内存开销显著增加，此时集成树模型更具优势。

无监督学习方法不依赖于已有的标签信息，而是通过对数据内在结构的探索来解译数据。常用的算法包括 K-means 聚类、主成分分析(PCA)、t-SNE 和 UMAP 等降维方法。这类方法常作为数据预探索的工具，例如用于识别地球化学数据中的自然集群或离群矿化指纹，为后续监督学习提供样本选择依据[8] [9]。

深度学习(如卷积神经网络 CNN、长短期记忆网络 LSTM、Vision Transformer 等)在处理遥感影像、高光谱数据和空间栅格数据方面展现出较大潜力。卷积神经网络在识别遥感影像中的蚀变晕、钻孔岩芯高光谱序列的空间模式上具有不可替代的优势。但由于矿床学领域的标注样本数量往往有限，深度学习在现阶段总体上仍作为传统机器学习方法的补充[5] [9]。机器学习在矿床学中的整体应用框架如图 1 所示。

3. 机器学习在矿床学中的主要应用

3.1. 基于矿物地球化学的矿床成因与类型判别

矿物的微量元素组成可以作为机器学习建模的有效数据来源，主要原因是矿物的结晶过程记录了成

矿环境的物理化学条件。不同成因类型的矿床在温度、流体性质、物质来源和氧逸度等方面存在显著差异，这些差异会系统地反映在指示矿物的微量元素含量上[2] [10] [11]。正是这种成矿条件与矿物化学之间的内在关联，为机器学习提供了可靠的分类边界。

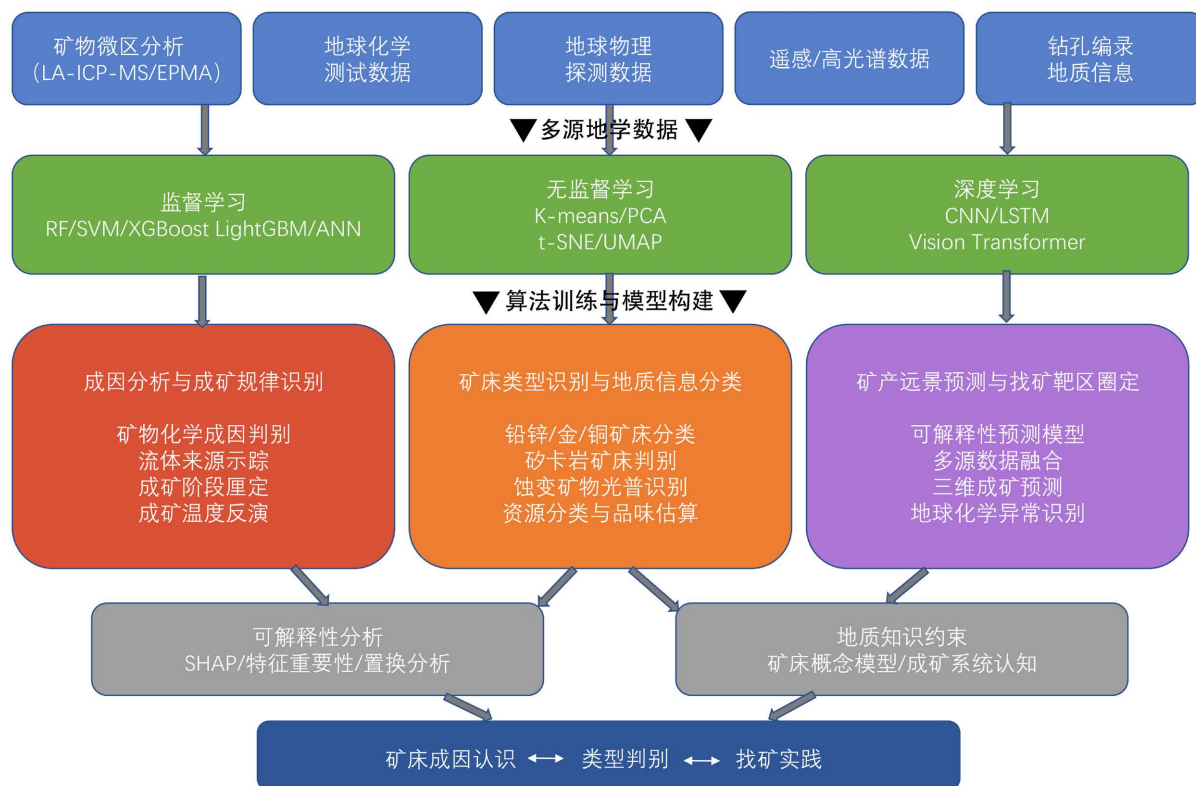


Figure 1. Framework of machine learning applications in ore deposit research
图 1. 机器学习在矿床学中的应用框架

黄铁矿作为热液矿床中分布最为广泛的矿物，黄铁矿的机器学习建模工作起步较早，研究也相对成熟。早期的研究主要集中在验证机器学习方法对矿床成因判别的有效性。例如，Zhong 等[10]通过 SVM 和 ANN 模型对 2104 条黄铁矿数据进行分类，不仅取得了 91/92 的高分类精度，还借助模型输出反演了 Zn-Pb 矿床的多期成矿历史。Deng 等[12]利用 6939 组黄铁矿数据结合主成分分析方法，构建了涵盖七类金矿床的判别图解。随着全球黄铁矿微区数据库的不断积累，研究重心逐渐转向算法比较和特征元素解析。Li 等[13]和和越等[14]分别对多种算法进行了系统对比，结果表明在面对数千条多元素数据时，SVM 等模型能够稳定输出超过 93% 的分类准确率。最近，Mondal 等[6]将样本规模扩展到近万级(8598 条)，在验证梯度提升算法泛化能力的同时，首次系统地引入了 SHAP 可解释性分析，定量识别出 Cu、Co 和 As 是驱动黄铁矿成因分类的关键标型元素。

受黄铁矿研究的带动，机器学习在其他指示矿物上的应用也迅速展开。磁铁矿作为岩浆-热液体系中常见的氧化物矿物，其 Ni、Ga、Sc、V 等微量元素含量对岩浆温度和氧逸度高度敏感。Wang 等[15]和 Zhang 等[16]分别基于 XGBoost 等集成算法，在数千条磁铁矿数据上取得了逾 94% 的分类精度，可以有效区分 BIF、IOA、IOCG、斑岩型和矽卡岩型等不同成因类型。磷灰石因富含稀土元素和挥发分组分，能够记录岩浆演化程度和挥发分逸度的变化，在含矿性评价中具有独特的应用价值。Qiu 等[17]对涵盖五种矿床类型的 8629 条磷灰石数据进行建模，XGBoost 分类器的总体准确率达到 94%，SHAP 分析显示

Th、U、Eu 和 Nd 是区分不同矿床类型的最关键元素。

在铅锌矿床类型判别方面，闪锌矿和方铅矿是两种重要的研究载体。不同地质背景下的铅锌矿床 (MVT、SEDEX、VMS 及矽卡岩型等)，其闪锌矿和方铅矿中的微量元素呈现出系统性的差异，例如 MVT 型通常表现为贫 Mn 富 Ge-Cd 的特征，而 VMS 型则以相对富 Co-Ni 为标志[13] [18]。Li 等[13]编译了全球 95 个矿床的近 3600 条闪锌矿数据，随机森林模型成功判别了五类矿床类型，其中 Mn、Co 和 Ge 的贡献最为突出。此外，黄铜矿微量元素也被用于区分岩浆型和热液型两大成因体系。云母[15]、角闪石[19]、斜方辉石[20]、白钨矿[21]和金红石[22]等矿物也陆续被纳入机器学习判别的框架。表 1 汇总了上述指示矿物微量元素机器学习判别的代表性应用。

Table 1. Representative ML classification results based on indicator mineral trace elements
表 1. 指示矿物微量元素机器学习判别代表性应用

指示矿物	数据量	最优算法	准确率	F1 值	关键元素	文献
黄铁矿	2104	SVM	98.9%	-	-	Zhong <i>et al.</i> , [12]
黄铁矿	8598	XGBoost	>94%	-	Cu, Co, As	Mondal <i>et al.</i> , [6]
黄铁矿	多类	SVM	98%	-	-	Li <i>et al.</i> , [13]
磁铁矿	3865	XGBoost	96%	95%	Ni, Ga, Sc, V	Wang <i>et al.</i> , [15]
磁铁矿	-	RF	有效	-	-	Hong <i>et al.</i> , [33]
磷灰石	8629	XGBoost	94%	89%	Th, U, Eu, Nd	Qiu <i>et al.</i> , [8]
闪锌矿	5255	LightGBM	97.2%	97%	Mn, Ge, Co	张鹏程等[18]
方铅矿	975	RF	97.5%	-	-	Gorai <i>et al.</i> , [34]
黄铜矿	2562	RF	97.2%	-	-	Caraballo <i>et al.</i> , [35]
石榴石	5136	XGBoost	最优	-	FeO _t	Zhou & Zhang [24]
云母	3479	Stacking	99%	99%	F, MgO, FeO	Hu <i>et al.</i> , [36]
锆石	-	ML	有效	-	REE	Hillenbrand [37]

综合上述研究可见，基于矿物微量元素的机器学习判别已成为矿床成因研究的高效手段。随机森林、XGBoost 等集成学习模型凭借其对于高维、非线性数据的鲁棒性以及内置的特征重要性评估能力，在这一领域占据了主导地位。横向对比不同指示矿物，黄铁矿因分布广泛、数据积累丰富而成为建模的“主力军”，其研究范式也最为成熟；磁铁矿和磷灰石则在区分岩浆-热液系列矿床(如斑岩型、矽卡岩型、IOCG 型)方面展现出独特优势；而闪锌矿、云母等矿物的应用则更具矿床类型专属性。然而，当前研究范式仍存在值得审视之处。首先，多数模型追求全局分类精度，但对不同矿床类型间的“模糊地带”(如某些兼具岩浆和热液特征的过渡型矿床)的判别能力往往被忽略。其次，尽管 SHAP 等工具被广泛应用，但将定量化的“关键元素”重新置于成矿动力学背景中解读的研究仍显不足，一个统计上重要的元素(如 Cu、As)究竟如何具体约束成矿的氧逸度、温度或物质来源？这种从“数学分类”到“过程反演”的跨越，是未来需要强化的关键环节。最后，现有模型大多基于全球混合数据库，忽略了区域地质背景的差异性，其跨成矿带、跨时代的泛化能力仍有待严格检验。

3.2. 蚀变矿物光谱识别与矿体定位

蚀变矿物的光谱特征是驱动机器学习分类的另一类重要高维数据来源。在热液蚀变过程中，绢云母、高岭石、绿泥石、明矾石等蚀变矿物因结晶条件的差异而表现出不同的晶体化学特征，这些差异会直接

反映在可见—近红外(VNIR)和短波红外(SWIR)的光谱响应上,例如 Al-OH 吸收峰位的移动、Mg-OH 吸收强度变化和结晶度指数的差异。近年来,随着高光谱钻孔扫描、机载遥感和便携式光谱仪的普及,蚀变矿物光谱数据的获取效率大幅提升,机器学习对这些多维光谱参数的建模能力也因此得以充分发挥。Shirmard 等[23]系统回顾了机器学习在遥感数据矿产勘查中的应用,指出光谱数据与机器学习的结合已成为热液蚀变信息提取的核心技术手段。

在金矿深部勘查方面,SWIR 光谱与机器学习的结合展现出突出的应用价值。Zhou 等[24]将 LSTM 模型应用于绢云母族矿物的 SWIR 光谱数据,发现矿体附近绢云母的 Al-OH 吸收峰向长波方向偏移(>2205 nm),据此在胶东金矿深部钻孔中实现了 82%的矿石预测准确率,为识别隐伏矿体提供了有效的远程探测手段。

在遥感尺度的蚀变填图方面,机器学习在斑岩铜矿和铁氧化物型矿床的热液蚀变识别中应用广泛。Fu 等[17]以西藏多龙矿集区为例,综合利用高光谱遥感影像和地球化学数据,结合随机森林和支持向量机构建蚀变矿物分布预测模型,提取与斑岩铜矿密切相关的钾化、绢英岩化等蚀变异常,显著提升了斑岩矿化靶区的圈定精度。钻孔岩芯的高光谱成像是蚀变矿物识别的另一重要应用场景。Acosta 等[25]提出了一种融合高光谱数据与高分辨率矿物学数据的机器学习框架,通过超像素分割和支持向量机对钻孔岩芯进行矿物精细分类,有效解决了光谱混合像元问题,在伊比利亚黄铁矿带矿床中取得了较好的填图精度。

蚀变矿物的化学成分被用来构建成矿矢量指示体系。绿泥石作为热液系统中广泛发育的蚀变矿物,其微量元素组成对流体温度和矿化程度高度敏感。Freij 等[26]将无监督机器学习聚类方法应用于绿泥石地球化学数据,通过自然类型聚类识别出不同热液事件对应的绿泥石世代,为构建以绿泥石成分为核心的成矿矢量指示体系提供了新思路。在 IOCG 矿床的蚀变研究方面,Dmitrijeva 等[27]对奥林匹克大坝矿区的勘探区 4864 个岩芯样品开展了多元统计分析,系统刻画了 IOCG 矿化-蚀变的地球化学印记,为依托蚀变特征建立矿化矢量指示体系提供了重要的参考。

蚀变矿物光谱与化学成分的机器学习识别,已从单一的技术验证走向多方法、多尺度的协同应用。在数据源上,从地面遥感、机载高光谱到钻孔 SWIR 扫描,形成了立体探测网络;在方法上,从传统的光谱角填图发展到 LSTM 时序建模、超像素分割等高级方法,显著提升了对微弱蚀变信号的捕捉能力。尤其值得强调的是,光谱识别与化学聚类两种路径正在走向融合:前者提供快速、无损的矿物识别,后者提供精细的成矿物理化学条件约束,二者结合有望构建更加可靠的找矿指标体系。当前该方向的主要挑战在于:第一,光谱数据的解释仍存在多解性,不同蚀变矿物组合可能产生相似的光谱特征,单纯依靠光谱识别容易产生误判;第二,从光谱参数(如峰位、结晶度)到成矿温压条件的定量反演模型尚不成熟,多数研究仍停留在定性或半定量阶段;第三,钻孔岩芯尺度的高光谱数据与区域尺度的遥感数据之间的尺度转换仍是一个未很好解决的问题。

3.3. 矿产远景预测与找矿靶区圈定

如何将来源不同、尺度各异、物理含义差别较大的多种地学数据有机整合,是成矿远景预测面临的核心难题之一。传统的空间分析方法(如证据权重法、模糊逻辑法)通常要求各证据层之间满足条件独立性假设,而机器学习的非线性建模能力可以在不受这些假设约束的条件下,捕捉多源变量之间的复杂交互关系。李庆哲等[28]以大兴安岭巴彦高勒地区为例,将地质、遥感、地球化学和地球物理四类数据系统整合,提取了赋矿围岩、控矿构造、岩浆活动、高磁异常、化探组合异常和矿化蚀变等多项预测要素,分别构建了 ANN 和 SVM 两套模型。经过 1000 次迭代优化的 ANN 模型 AUC 值最高,所圈定的 8 处远景区对已知矿化的预测命中率达到 80.95%。

三维成矿预测正在成为成矿预测研究的一个重要发展方向。与传统二维远景填图只能刻画地表投影概率分布不同，三维预测的目标是将找矿靶区的定位从平面推向深部空间，这对于覆盖区和隐伏矿体的勘查部署具有直接的指导意义。实现三维预测的技术路径通常是：首先通过三维地质建模和多套地球物理数据反演构建三维属性场，提取控矿要素的三维特征值；然后以已知矿体为正样本训练机器学习模型，将其外推至整个三维空间进行预测。Fu 等[17]在朱溪钨矿床开展三维远景评价，将重力、磁力、大地电磁和宽频带地震四套地球物理数据的三维反演结果与地质建模相融合，对比了 KNN、BP 神经网络和 SVM 三种算法，其中 SVM 模型以仅 2.07% 的体素量捕获了 75.69% 的已知含矿样本。

矿产远景预测正经历从二维平面向三维空间、从定性经验向定量数据驱动的深刻转型。机器学习的引入使得多源地质、地球化学、地球物理和遥感数据能够在统一的框架下协同建模，显著提升了靶区圈定的精度和效率。三维预测方法的兴起，特别是与高精度地球物理反演的结合，为覆盖区和深部隐伏矿的勘查提供了新的技术路径。然而，该方向仍面临若干核心挑战：第一，“负样本”的定义困境，在低勘探程度区域，“无矿”样本的真实属性往往未知，这可能导致模型学习到错误的决策边界；第二，预测模型的地质可解释性普遍较弱，高概率靶区的地质含义往往不够清晰；第三，三维预测对计算资源和数据质量要求较高，目前仍以典型矿床的案例研究为主，尚未形成可推广的技术流程。

4. 存在问题与展望

4.1. 当前面临的关键挑战与前沿探索

尽管机器学习在矿床学多个方向展现出了较大的应用潜力，但客观来看，当前的研究仍面临一系列制约性难题。近年来，学术界围绕这些挑战已开展了诸多前沿探索。

1) 负样本定义与数据不平衡问题。在矿产远景预测中，“无矿”样本的真实性存疑(高覆盖区可能埋藏隐伏矿)，且正负样本比例悬殊(已知矿点数远少于无矿点数)。传统随机欠采样易丢失关键信息。前沿探索：① 生成对抗网络(GAN)与变分自编码器(VAE)被用于生成合成矿化样本，以平衡数据集；② 异常检测框架将找矿视为“从大量背景中识别稀有矿化模式”的问题，不再强依赖负样本；③ 迁移学习可将高勘探区训练好的模型迁移到数据匮乏的低勘探区，缓解样本不足[29] [30]。

2) 多源异构数据的空间融合与多尺度问题。地质图(面状)、地球化学(点状)、地球物理(体元/场)和遥感(栅格)数据在尺度、精度和物理意义上各异。简单叠置会丢失空间结构信息。前沿探索：① 图神经网络(GNN)能够将地质体、断层、采样点建模为图结构，自然地融合不同尺度的空间关系和属性特征；② 多模态深度学习设计专门的网络分支(如一个分支处理化探数据，另一个分支处理地球物理反演体)来分别提取特征后再融合[31]。

3) 地质先验知识的有效嵌入。纯数据驱动模型可能学习到与成矿规律相悖的虚假关联，且外推能力差。如何让模型“懂地质”是核心瓶颈。前沿探索：① 物理信息神经网络(PINN)将控制成矿过程的偏微分方程(如流体流动、热传导)作为损失函数的正则化项，引导模型在物理定律的约束下学习；② 知识图谱增强的可解释性框架[12]将矿床模型中的实体(如“斑岩”、“绢英岩化”)和关系关联到机器学习模型的特征上，使决策路径可追溯、可地质解释；③ 人机协同建模开发交互式平台，允许地质学家通过调整特征权重或约束决策边界来注入专业知识[1] [4]。

4) 模型的跨区域泛化能力。一个在特定成矿带训练出的高精度模型，应用到地质背景不同的新区域时，性能往往显著下降。这要求模型不仅要记住数据模式，更要学习到与成矿动力学相关的“不变性”特征。解决方法与上述迁移学习、物理信息嵌入等密切相关。

4.2. 未来发展方向

基于上述分析，作者认为以下几个方向可能是未来的重要突破口。

1) 多源异构数据的深度融合。随着多模态数据获取能力的增强,将地质、地球化学、地球物理和遥感等不同来源、不同尺度的数据有机整合到统一的建模框架中是提升预测能力的关键。多模态和多尺度的联合建模是一个值得深入探索的方向[31]。

2) 可解释性增强与地质约束嵌入。在提高模型精度的同时,使模型的决策过程对地质学家而言“可理解、可追溯”,是推动机器学习在矿床学中走向实用化的必要条件。物理信息神经网络(PINN)、迁移学习[29][30]以及人机协同建模等思路,有望在这方面取得进展[1][4]。Zhang 等[32]提出的知识图谱辅助可解释性框架也是一种有前景的探索。

3) 从二维到三维的预测范式转型。随着三维地质建模技术和深度学习新架构的发展,矿产预测正从传统的二维平面快速向三维深部延伸。将数值模拟与深度学习相结合的三维预测方法,在定位深部隐伏矿体方面可能发挥重要作用[5][7][12]。

5. 结论

综合来看,机器学习正在深刻改变矿床学的数据处理方式和研究范式。在矿床成因判别方面,以指示矿物微量元素为高维输入、辅以特征归因算法的方法,不仅取得了较高的分类精度,而且通过 SHAP 等工具逐步实现了从数学分类到地质解释的转化。在矿产远景预测方面,多源数据融合和三维建模技术的引入,使预测体系从传统的二维图解向三维深部空间快速推进,为复杂地质背景下隐伏矿体的勘查提供了新的定量手段。

目前机器学习在矿床学中的应用尚处于快速发展但仍不成熟的阶段。数据标签质量的不对称、模型地质解释深度的匮乏仍是制约该领域进一步发展的关键问题。未来,如何将地质学的先验知识与算法的底层逻辑进行深度融合,是突破上述瓶颈、真正实现高精度智能成矿预测的关键所在。

参考文献

- [1] 余韵, 郑远馨, 刘浩杰, 等. 人工智能和机器学习在矿产勘查领域的应用现状与展望[J/OL]. 中国地质: 1-28. <https://link.cnki.net/urlid/11.1167.P.20260224.0936.002>, 2026-05-27.
- [2] 王智宇, 王达, 邱昆峰, 等. 机器学习在矿物岩石地球化学大数据挖掘中的应用与展望[J]. 成都理工大学学报(自然科学版), 2025, 52(5): 844-858.
- [3] 郑楠楠, 冉祥金, 薛林福, 等. 智能找矿预测方法研究综述[J]. 黄金, 2026, 47(4): 1-11.
- [4] 左仁广, 张振杰, 杨帆帆, 等. 大数据人工智能驱动的矿产预测[J]. 地球科学, 2026, 51(3): 779-792.
- [5] 吴以婕, 李晓晖, 袁峰, 等. 基于 Vision Transformer 的深部隐伏矿体三维成矿预测方法[J]. 地球科学, 2026, 51(3): 896-908.
- [6] Mondal, A., Saha, R., Upadhyay, D., Mallick, S.P., Pruseth, K.L. and Chakraborty, A. (2026) A Machine Learning Approach in Type-Discrimination and Exploration of Gold Deposits Using Pyrite Trace Element Chemistry. *Journal of Geochemical Exploration*, **284**, Article ID: 108011. <https://doi.org/10.1016/j.gexplo.2026.108011>
- [7] Cotrina-Teatino, M.A., Marquina-Araujo, J.J. and Riquelme, Á.I. (2025) Comparison of Machine Learning Techniques for Mineral Resource Categorization in a Copper Deposit in Peru. *Natural Resources Research*, **34**, 2007-2025. <https://doi.org/10.1007/s11053-025-10505-x>
- [8] Qiu, K., Zhou, T., Chew, D., Hou, Z., Müller, A., Yu, H., et al. (2024) Apatite Trace Element Composition as an Indicator of Ore Deposit Types: A Machine Learning Approach. *American Mineralogist*, **109**, 303-314. <https://doi.org/10.2138/am-2022-8805>
- [9] 刘宇曦, 黄勇, 刘洪, 等. 多种机器学习模型在冈底斯成矿带东部铜矿地球化学异常信息识别中的应用[J/OL]. 沉积与特提斯地质: 1-18. <https://doi.org/10.19826/j.cnki.1009-3850.2025.12006>, 2026-05-27.
- [10] Zhong, R., Deng, Y., Li, W., Danyushevsky, L.V., Cracknell, M.J., Belousov, I., et al. (2021) Revealing the Multi-Stage Ore-Forming History of a Mineral Deposit Using Pyrite Geochemistry and Machine Learning-Based Data Interpretation. *Ore Geology Reviews*, **133**, Article ID: 104079. <https://doi.org/10.1016/j.oregeorev.2021.104079>
- [11] Cui, H., Zhong, R., Li, W., Yu, C., Danyushevsky, L.V., Belousov, I., et al. (2023) Revealing the Orogenic Genesis of

- Huogeqi Cu-Pb-Zn Deposit: Evidence from the Machine Learning-Based Data Interpretation of Pyrite Geochemistry. *Ore Geology Reviews*, **154**, Article ID: 105350. <https://doi.org/10.1016/j.oregeorev.2023.105350>
- [12] Deng, Y., Zhang, J., Zhong, R., He, X. and Wang, X. (2024) Application of Principal Component Analysis Method Based on Machine Learning to Gold Deposit Type Discrimination: A Case Study of the Geochemical Characteristics of Pyrite. *Acta Petrologica Sinica*, **40**, 1801-1816. <https://doi.org/10.18654/1000-0569/2024.06.07>
- [13] Li, X., Zhang, Y., Li, Z., Zhao, X., Zuo, R., Xiao, F., *et al.* (2023) Discrimination of Pb-Zn Deposit Types Using Sphalerite Geochemistry: New Insights from Machine Learning Algorithm. *Geoscience Frontiers*, **14**, Article ID: 101580. <https://doi.org/10.1016/j.gsf.2023.101580>
- [14] 和越, 崔亮杰, 曾庆文, 等. 冀东峪耳崖金矿床成因研究: 来自黄铁矿地球化学数据机器学习的证据[J]. 岩石学报, 2026, 42(2): 557-575.
- [15] Wang, P., Su, S., Wang, G., Dong, Y. and Yu, D. (2024) Discrimination of Deposit Types Using Magnetite Geochemistry Based on Machine Learning. *Ore Geology Reviews*, **170**, Article ID: 106107. <https://doi.org/10.1016/j.oregeorev.2024.106107>
- [16] Zhang, P., Zhang, Z., Yang, J. and Cheng, Q. (2023) Machine Learning Prediction of Ore Deposit Genetic Type Using Magnetite Geochemistry. *Natural Resources Research*, **32**, 99-116. <https://doi.org/10.1007/s11053-022-10146-4>
- [17] Fu, Y., Cheng, Q., Jing, L., Ye, B. and Fu, H. (2023) Mineral Prospectivity Mapping of Porphyry Copper Deposits Based on Remote Sensing Imagery and Geochemical Data in the Duolong Ore District, Tibet. *Remote Sensing*, **15**, Article 439. <https://doi.org/10.3390/rs15020439>
- [18] 张鹏程, 谢渊, 李洪梁, 等. 闪锌矿微量元素特征在铅锌矿床成因判别中的应用: 基于机器学习与可解释性分析[J/OL]. 地球化学: 1-18. <https://link.cnki.net/urlid/44.1398.P.20251209.1438.002>, 2026-05-27.
- [19] 黄明波, 柏中杰, 高剑峰, 等. 基于机器学习的角闪石温压计及其地质应用[J]. 岩石学报, 2026, 42(3): 1109-1121.
- [20] 李敏, 毛亚晶, 吕鹏飞, 等. 基于斜方辉石成分的机器学习模型判别基性-超基性岩成因类型与成矿潜力[J]. 岩石学报, 2026, 42(3): 1090-1108.
- [21] 罗川杨, 李伟, 刘海明, 等. 白钨矿微量元素机器学习对脉状 Au-Sb-W 矿床成因的指示意义[J/OL]. 矿物岩石地球化学通报: 1-19. <https://link.cnki.net/urlid/52.1102.P.20251223.1408.001>, 2026-05-27.
- [22] Chen, Y., Liu, Z., Wang, R., Yang, B. and Mao, X. (2024) New Insights into the Metallogenic Genesis of the Xiadian Au Deposit, Jiaodong Peninsula, Eastern China: Constraints from Integrated Rutile *In-Situ* Geochemical Analysis and Machine Learning Discrimination. *Ore Geology Reviews*, **171**, Article ID: 106184. <https://doi.org/10.1016/j.oregeorev.2024.106184>
- [23] Shirmard, H., Farahbakhsh, E., Müller, R.D. and Chandra, R. (2022) A Review of Machine Learning in Processing Remote Sensing Data for Mineral Exploration. *Remote Sensing of Environment*, **268**, Article ID: 112750. <https://doi.org/10.1016/j.rse.2021.112750>
- [24] Zhou, S. and Zhang, Z. (2025) Machine Learning-Driven Skarn Deposit Classification with SHAP-Enhanced Garnet Geochemistry Analysis. *Journal of Asian Earth Sciences*, **294**, Article ID: 106780. <https://doi.org/10.1016/j.jseaes.2025.106780>
- [25] Acosta, I.C.C., Khodadadzadeh, M., Tusa, L., Ghamisi, P. and Gloaguen, R. (2019) A Machine Learning Framework for Drill-Core Mineral Mapping Using Hyperspectral and High-Resolution Mineralogical Data Fusion. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, **12**, 4829-4842. <https://doi.org/10.1109/jstars.2019.2924292>
- [26] Freij, N., Gregory, D.D., Zhang, S. and Morrison, S.M. (2023) Chlorite Geochemical Vectoring of Ore Bodies: A Natural Kind Clustering Approach. *Frontiers in Earth Science*, **11**, Article 1222291. <https://doi.org/10.3389/feart.2023.1222291>
- [27] Dmitrijeva, M., Ciobanu, C.L., Ehrig, K.J., Cook, N.J., Metcalfe, A.V., Verdugo-Ihl, M.R., *et al.* (2019) Mineralization-alteration Footprints in the Olympic Dam IOCG District, South Australia: The Acropolis Prospect. *Journal of Geochemical Exploration*, **205**, Article ID: 106333. <https://doi.org/10.1016/j.gexplo.2019.106333>
- [28] 李庆哲, 王京彬, 和志军, 等. 基于机器学习算法的找矿预测方法与模型研究——以大兴安岭中南段巴彦高勒地区为例[J]. 地质与勘探, 2026, 62(2): 243-262.
- [29] Wang, J., Zhou, Y. and Xiao, F. (2020) Identification of Multi-Element Geochemical Anomalies Using Unsupervised Machine Learning Algorithms: A Case Study from Ag-Pb-Zn Deposits in North-Western Zhejiang, China. *Applied Geochemistry*, **120**, Article ID: 104679. <https://doi.org/10.1016/j.apgeochem.2020.104679>
- [30] Mantilla-Dulcey, A., Goyes-Peñafiel, P., Báez-Rodríguez, R. and Khurama, S. (2024) Porphyry-Type Mineral Prospectivity Mapping with Imbalanced Data via Prior Geological Transfer Learning. *Gondwana Research*, **136**, 236-250. <https://doi.org/10.1016/j.gr.2024.09.004>
- [31] 张振杰. 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, 2026, 51(3): 849-861.

-
- [32] Zhang, Z., Yang, Z., Jian, F., Ban, S. and Wang, Y. (2026) Interpretability-enhanced Mineral Prospectivity Models: A Synergistic Approach Using Large Language Models, Knowledge Graphs, and Machine Learning. *Mathematical Geosciences*, **58**, 195-231. <https://doi.org/10.1007/s11004-025-10231-3>
- [33] Hong, S., Zuo, R., Huang, X. and Xiong, Y. (2021) Distinguishing IOCG and IOA Deposits via Random Forest Algorithm Based on Magnetite Composition. *Journal of Geochemical Exploration*, **230**, Article ID: 106859. <https://doi.org/10.1016/j.gexplo.2021.106859>
- [34] Gorai, S., Dalai, B., Kumar, T.V. and Sreenivas, B. (2025) Machine Learning Applications in Trace Element Analysis: Decoding the Origin of Galena in the Zawar Zn-Pb Deposit, India. *Earth Science Informatics*, **18**, Article No. 472. <https://doi.org/10.1007/s12145-025-01961-3>
- [35] Caraballo, E., Beaudoin, G. and Dare, S. (2026) Trace Element Composition of Chalcopyrite as a Tool for Deposit Type Discrimination from Magmatic and Hydrothermal Settings: A Machine Learning Approach. *Mineralium Deposita*, **61**, 299-326. <https://doi.org/10.1007/s00126-025-01388-2>
- [36] Hu, Z., Zhang, D., Chen, S., Xu, H., Zeng, S. and Kou, J. (2025) Discriminating Deposit and Mineralization Types Using Major Elements and Fluorine in Mica: A Machine Learning Approach. *Natural Resources Research*, **34**, 1833-1859. <https://doi.org/10.1007/s11053-025-10498-7>
- [37] Hillenbrand, I.W. (2025) Zircon as a Pathfinder to REE Mineralisation. *Geochemical Perspectives Letters*, **37**, 18-23. <https://doi.org/10.7185/geochemlet.2540>