

# 地电化学勘查技术与机器学习的融合

陈 若

桂林理工大学地球科学学院, 广西 桂林

收稿日期: 2025年12月22日; 录用日期: 2026年1月27日; 发布日期: 2026年2月5日

---

## 摘要

随着浅表矿产资源日益减少, 深部与隐伏矿产勘查成为全球资源勘探的核心挑战。传统地球化学方法在覆盖层厚、地形复杂区域难以提取深部微弱信息。地电化学勘查技术通过外加电场驱动离子迁移, 可强化获取深部矿化信息, 已成为深部找矿的重要手段。与此同时, 大数据与人工智能技术为处理地球化学数据的高维、非线性、小样本等特性提供了新方法。本文系统阐述地电化学技术原理与发展, 探讨其与机器学习融合的技术路径, 并以川西木绒锂矿为例, 详细分析随机森林与概率神经网络在异常识别与靶区预测中的应用。文章总结该融合技术的优势与挑战, 并对未来发展进行展望, 旨在为智能矿产资源勘查体系构建提供参考。

## 关键词

地电化学, 机器学习, 随机森林, 概率神经网络

---

# Integration of Geoelectrochemical Exploration Technology and Machine Learning

Ruo Chen

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

Received: December 22, 2025; accepted: January 27, 2026; published: February 5, 2026

---

## Abstract

As shallow mineral resources are increasingly depleted, the exploration of deep and concealed mineral deposits has become a central challenge in global resource prospecting. Traditional geochemical methods struggle to extract weak deep-seated information in areas with thick overburden or complex terrain. ElectrogEOchemistry exploration technology, which employs an external electric field to drive ion migration, enhances the acquisition of deep mineralization information and has emerged as a critical

**tool for deep mineral exploration. Concurrently, big data and artificial intelligence technologies offer novel approaches for handling the high-dimensional, nonlinear, and small-sample characteristics of geochemical data. This article systematically elaborates on the principles and development of electro-geochemical technology, explores the technical pathways for its integration with machine learning, and provides a detailed analysis of the application of random forest and probabilistic neural networks in anomaly identification and target prediction, using the Muzrong lithium deposit in western Sichuan as a case study. The article summarizes the advantages and challenges of this integrated technology, offers insights into future developments, and aims to provide a reference for constructing an intelligent mineral resource exploration system.**

## Keywords

**Electrogeochemistry, Machine Learning, Random Forest, Probabilistic Neural Network**

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

矿产资源是工业文明的基石。随着浅部资源日益枯竭，勘查工作正向“攻深找盲”阶段推进，面临穿透覆盖层、识别弱信息、处理海量数据等关键挑战[1][2]。传统地球化学方法在覆盖层薄、景观简单区效果显著，但在厚覆盖区、复杂地形下，深部信息被屏蔽，方法往往失效。地电化学勘查作为一种主动源技术，通过人工电场驱动深部离子向地表迁移富集，可有效提取隐伏矿体信息，自 20 世纪 80 年代以来已在多矿种、多景观区得到成功验证[3]-[5]。与此同时，大数据与人工智能为矿产勘查带来新机遇。传统数据处理方法难以应对地球化学数据的非线性、高维、高噪声等特征，而机器学习能够从数据中自动学习复杂关系，建立预测模型，显著提升异常识别与靶区预测的效率和准确性[1][2][6]。

因此，将地电化学技术与大数据分析相结合，构建“智能采集 – 深度挖掘 – 精准预测”的找矿体系，既是技术发展的必然趋势，也是实现深部找矿突破的迫切需求。本文系统梳理该融合领域的最新进展，通过典型案例阐明其技术路径与发展前景。

## 2. 地电化学勘查技术：原理、发展

### 2.1. 基本原理与工作机制

原理是经过人工加设电场，驱动土壤中电活动态元素迁移至地表接收器附近并富集，再通过分析富集的元素信息推断可能存在的矿体/矿化体位置，以达到找矿评价目的一种穿透性地球化学技术[4][7][8]，该方法是基于电场作用的勘探原理，通过外电场驱动处于电活性态的离子或带电元素聚集体，使其迁移至接收电极的载体上；通过采集并分析载体物质中的元素含量来指示矿化信息，因而在本质上兼具地球化学勘查的属性。为此，可将地电化学方法定义为一种非常规化探技术：其借助外部电场，使带电离子或元素聚集体定向迁移至接收载体，经后续样品分析实现找矿与评价目的。其实施过程通常如下：在测线上按一定间距布设采样点，在每个点上埋设一对(或多对)电极(通常为碳棒或金属棒)构成偶极子[3][9]。电极埋深通常至土壤 B 层或 C 层(约 30~50 厘米)，以避开强烈的生物和耕作干扰。通过外部电源(通常为 9~24 V 直流电)在偶极子间建立稳定的电场，持续通电一定时间(通常为 20~48 小时)。在此过程中，电场力、电渗流、电迁移、浓度梯度扩散等多种营力共同作用，驱动深部岩石孔隙水、裂隙水中的可溶性离

子(特别是活动态的金属阳离子)向负极(或正极, 取决于离子性质)迁移, 并被包裹在电极周围的特殊离子收集器(早期使用碳棒, 现多采用经化学处理的高密度泡塑)吸附[10]。

通电结束后, 取出离子收集器, 经过清洗、晾干、消解等前处理, 使用高精度的分析仪器(如 ICP-MS)测定其中目标元素的含量。

## 2.2. 技术发展历程与应用拓展

中国的地电化学研究始于上世纪 80 [2] 年代末, 以桂林理工大学罗先熔教授团队的工作为代表。早期研究主要集中在方法机理探索、装置优化和可行性验证阶段。90 年代至 21 世纪初, 该技术进入推广应用期, 在一系列不同类型和景观区的矿床(如金矿、铜矿)上进行了大量试验[11]-[14], 积累了丰富的经验[5] [10]。

近年来, 地电化学技术呈现出以下几个明显的发展趋势:

**集成化:** 不再作为单一方法使用, 而是与土壤金属量测量、汞气测量、地气测量、电法勘探等方法组合, 形成综合地球化学勘查体系, 实现信息互补与相互验证。

**标准化与规范化:** 针对采样装置、提取时间、电压电流、样品处理、质量监控等环节, 逐步形成更统一、更规范的操作流程, 以提高数据的可比性和重现性。

**面向特殊矿种:** 从最初主要应用于金、铜等矿种, 成功拓展到稀有金属(锂、铌、钽)、稀土、铀等战略性新兴矿产的勘查中, 显示出广阔的应用前景[15] [16]。

**适应复杂景观:** 在青藏高原高寒区[17]、内蒙古戈壁荒漠区[18]、西南原始林区等极端或复杂景观条件下开展了成功应用, 证明了其良好的环境适应性[4] [9] [19]。

## 3. 大数据与机器学习: 赋能地球化学数据分析的新引擎

### 3.1. 机器学习在地学中的应用范式

机器学习是人工智能的核心分支, 其基本思想是让计算机从数据中自动学习规律, 并利用学习到的模型对新的数据进行预测或决策。在地球科学领域, 机器学习应用通常遵循以下范式[1]:

**问题定义与数据准备:** 明确预测目标(如二分类: 成矿/非成矿), 收集和整理已知标签的样本数据(如已知含矿点与无矿点的地球化学数据)。

**特征工程与数据预处理:** 这是关键步骤, 包括数据清洗(处理缺失值与异常值)、特征选择(筛选与成矿最相关的元素或指标)、数据变换(标准化、归一化)等, 以构建高质量的输入特征集。

**模型选择与训练:** 根据数据特点和问题性质, 选择合适的机器学习算法(如决策树、支持向量机、神经网络等), 使用训练集数据对模型参数进行优化学习。

**模型评估与验证:** 使用独立的测试集或交叉验证方法, 评估模型的泛化性能, 常用指标包括准确率、精确率、召回率、F1 分数、受试者工作特征曲线下面积(AUC)等。

**预测与应用:** 将训练好的模型应用于未知区域的样本数据, 生成预测结果(如成矿概率图), 用于指导进一步的勘查工作[20]。

### 3.2. 适用于地球化学数据的常用机器学习算法

在地球化学异常识别和矿产预测中, 以下几类算法应用最为广泛:

**集成学习算法:** 以随机森林[21]为代表。RF 通过构建大量互不关联的决策树, 并对所有树的预测结果进行投票或平均来做出最终决策。其主要优势在于: ① 能够处理高维数据且无需特征降维; ② 对缺失值和噪声不敏感; ③ 能够评估变量的重要性; ④ 不易产生过拟合, 泛化能力强[22]。这些特点使其非常适合处理地球化学数据。

**神经网络算法:** 包括传统的人工神经网络(ANN)和更专门化的模型。概率神经网络(Probabilistic Neural Network, PNN)是一种基于贝叶斯决策理论和 Parzen 窗概率密度估计的前馈神经网络。它具有结构简单、训练速度快、无需迭代训练、能够包容一定错误样本、对小样本分类效果好等优点。其四层结构(输入层、模式层、求和层、输出层)能直接输出样本属于各个类别的概率，非常直观[23] [24]。

**支持向量机(SVM):** 通过寻找一个最优超平面来最大化不同类别样本间的间隔，适用于小样本、非线性、高维模式识别，在地球化学异常分离中效果良好[25]。

**深度学习算法:** 如卷积神经网络(CNN)、自编码器(AE)、图神经网络(GNN)等，在处理具有空间结构的地球化学数据、进行无监督异常检测等方面展现出潜力，但对数据量和计算资源要求较高[25]。

### 3.3. 特征提取与降维：从原始数据到有效指标

在地球化学领域，特征工程尤为重要。直接使用所有原始元素含量作为模型输入，往往会引入冗余和噪声。因此，常借助多元统计方法进行预处理：

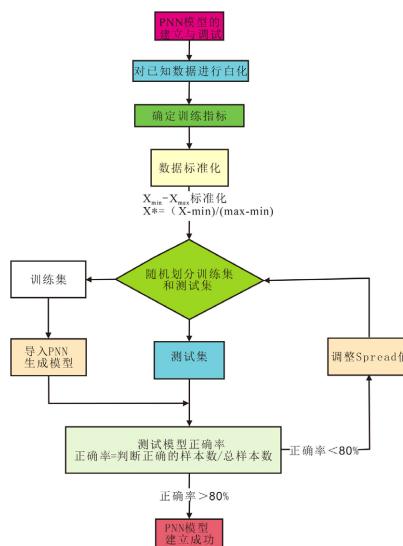
**因子分析(Factor Analysis):** 用于揭示众多观测变量之间的内在依赖关系，用少数几个不可观测的“公共因子”来解释原始变量的协方差结构。在地球化学中，这些公共因子常代表不同的成矿作用、岩性控制或表生过程[26]。

**R 型聚类分析(R-mode Cluster Analysis):** 根据元素之间的相关系数或相似性，将元素逐次聚合，形成谱系图。它可以直观地展示哪些元素具有相似的地球化学行为，常与因子分析结果相互印证。

**主成分分析(PCA):** 一种线性降维方法，将原始变量转换为一组线性不相关的主成分，保留数据中的主要变异信息。

通过这些方法，可以从原始的高维元素数据中，提炼出少数几个具有明确地质意义的“组合指标”(如 F1、F2 因子)或元素组合(如 Li-Rb-Cs)，作为机器学习模型的核心输入特征，这被称为数据的“白化”或“降维”。

## 4. 融合实践：川西木绒锂矿智能找矿案例深度剖析



**Figure 1.** Flowchart for the establishment and debugging of the PNN model [15]

**图 1. PNN 模型建立与调试流程图[15]**

四川省雅江县木绒锂矿是近年来在松潘 - 甘孜造山带发现的超大型花岗伟晶岩型锂矿床，其发现过

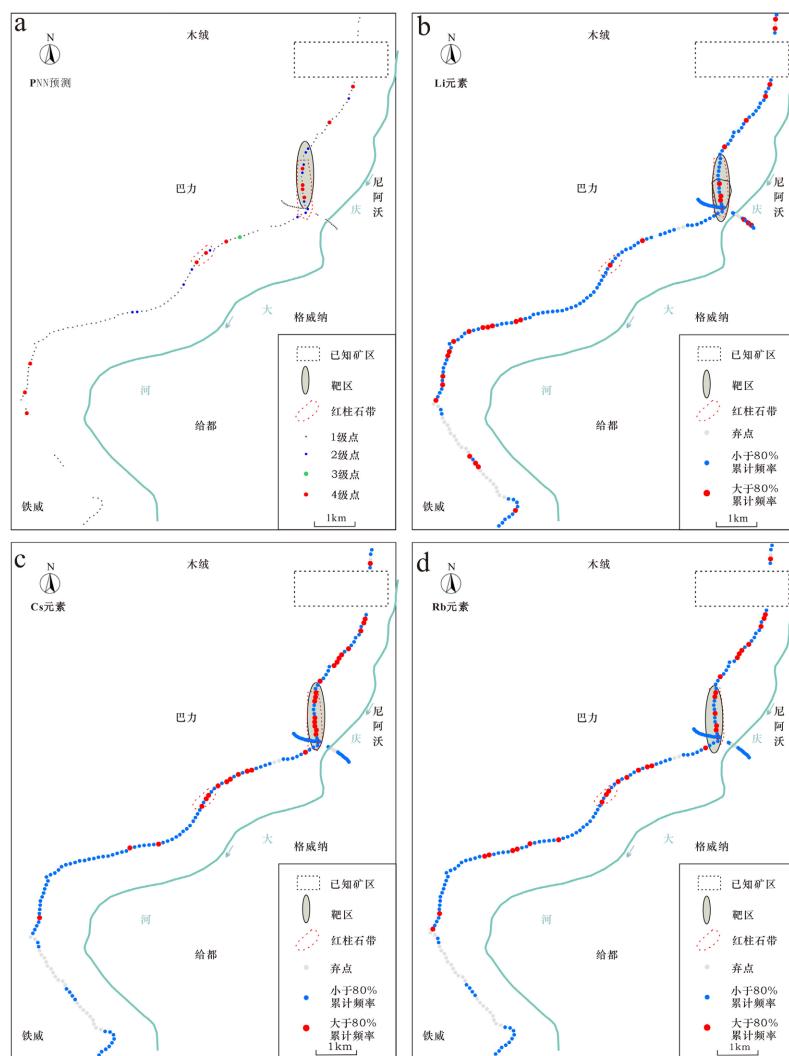
程本身就体现了新方法、新技术的巨大价值。该矿区地形切割强烈，覆盖层分布不均，给传统找矿方法带来困难。研究团队在该区系统开展了地电化学测量，并分别应用随机森林和概率神经网络进行数据处理与靶区预测，为我们提供了对比研究两种方法的绝佳范例[15] [16]。

#### 4.1. 地质与地电化学工作概况

木绒矿区出露地层主要为三叠系上统新都桥组砂板岩，发育多条含锂辉石的伟晶岩脉[27]-[29]。研究分为已知区(已钻探验证)和外围预测区。在已知区以较密网度( $100\text{ m} \times 40\text{ m}$  或  $80\text{ m} \times 40\text{ m}$ )布设采样线，在预测区以较稀网度或剖面形式采样。使用偶极提取装置，采集样品经 ICP-MS 分析 Li、Be、Rb、Cs、Nb、Ta、Th、U、Al、Fe 等多种元素。

#### 4.2. 概率神经网络(PNN)模型的应用流程与结果

**特征选择：**同样经过因子分析和 R 型聚类，该研究选取了 Li、Rb、Cs、Al、Fe 五种元素作为 PNN 的输入特征。其中，Al、Fe 作为常量元素，可能反映了与成矿有关的围岩蚀变或地球化学背景场信息。



**Figure 2.** Verification map of PNN model-predicted mineral exploration targets for Li, Cs, and Rb elements [15]  
**图 2.** PNN 模型预测的找矿靶区与 Li、Cs 和 Rb 元素验证图[15]

样本标签制定：将已知区 111 个点详细分为 4 个等级：1 级(无潜力)、2 级(低潜力，C 类靶区)、3 级(中潜力，B 类靶区)、4 级(高潜力，A 类靶区)。分类依据是各点地电提取的 Li、Rb、Cs 异常强度、规模及其与已知矿体的空间关系[15]。

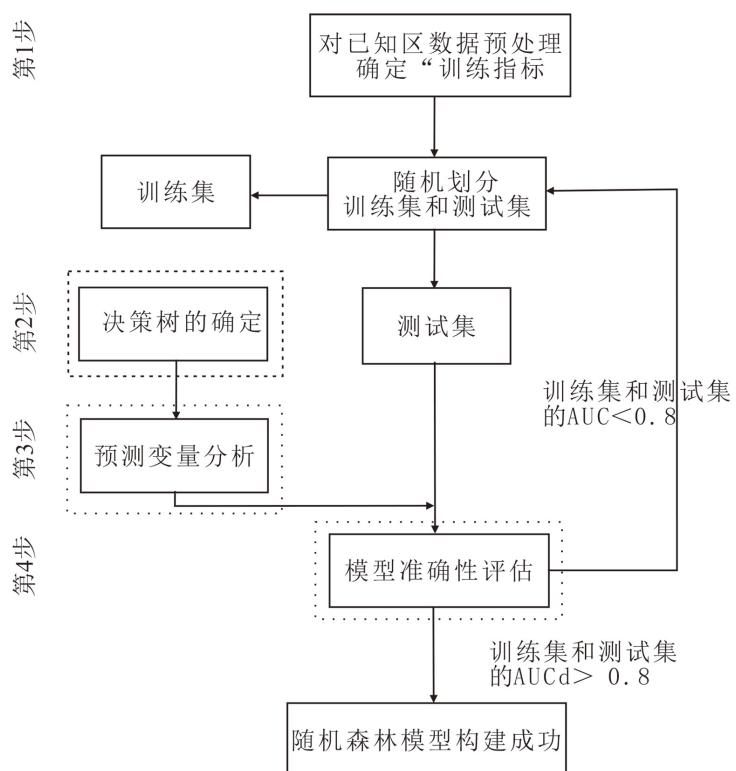
数据标准化：使用 Min-Max 归一化方法，将各元素含量映射到 [0, 1] 区间，以消除量纲影响，满足 PNN 的输入要求[15]。

模型训练与 Spread 值调优：PNN 模型的关键超参数是平滑参数 Spread 值，它控制着概率密度估计窗口的宽度。Spread 值过大，模型过于平滑，区分能力下降；过小则易过拟合。研究通过反复试验，发现当 Spread 值设为 0.08 时，模型在训练集(95 个样本)上的准确率达到 88.42%，在独立测试集(16 个样本)上的准确率达到 81.25%，取得了最佳平衡(见图 1)[15]。

预测与应用：将优化后的 PNN 模型应用于预测区 162 个样本，预测结果为：1 级点 135 个，2 级点 14 个，3 级点 1 个，4 级点 12 个。将预测的 4 级点和部分 3 级点在空间上投图，圈定出一处找矿靶区(见图 2)[15]。

### 4.3. 随机森林(RF)模型的应用流程与结果

数据预处理与特征选择：对已知区地电化学数据进行因子分析和 R 型聚类分析。结果显示，Li、Rb、Cs、Th 元素在 F1 因子上具有高载荷( $>0.5$ )，且 R 型聚类也将其归为一类。这与锂辉石伟晶岩矿床的典型元素共生组合(Li、Rb、Cs 同属碱金属，地球化学性质相似)相符。因此，确定以 Li、Rb、Cs、Th 的单元素含量及其组合因子 F1 的得分作为模型的“训练指标”[16]，模型构建流程见图 3。



**Figure 3.** Flowchart of random forest model construction [16]

**图 3. 随机森林模型构建流程图[16]**

样本标签制定：根据已知区地质认识和已有异常图，将采样点按成矿潜力分为 A (高潜力)、B (中高

潜力)、C(低潜力)及无潜力四类。通过对比实验,发现将A、B类合并为“1号点”(成矿潜力大),C类及无潜力点合并为“0号点”(成矿潜力小)的二分法,比四分类的模型准确率更高(86.74% vs 72.07%),故采用二分法建模[16]。

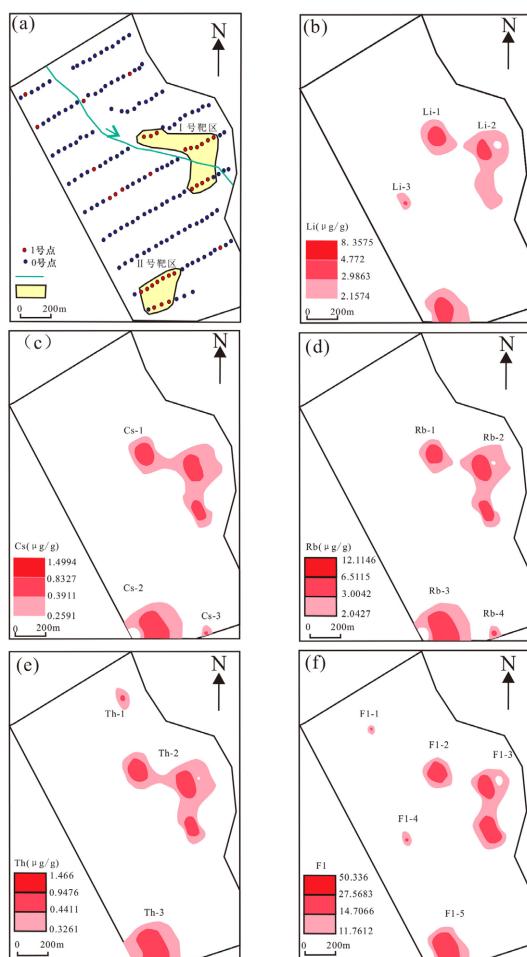
**模型训练与调优:** 使用R语言中的randomForest包构建模型。关键参数是决策树的数量(ntree)和每棵树分裂时随机考虑的特征数(mtry)。通过绘制模型误差随树数量变化的曲线,确定当树数量达到350棵时,误差趋于稳定,故设定ntree=350。变量重要性分析显示,Li、Cs、Rb对模型分类的贡献最大[16]。

**模型评估:** 采用5折交叉验证评估模型稳健性。最终模型在训练集上的AUC值为0.963,在测试集上的AUC值为0.822,表明模型具有优秀的拟合能力和较好的泛化能力。混淆矩阵也显示对正负样本的预测准确率均较高。

**预测与应用:** 将训练好的RF模型应用于预测区180个样本数据,预测出33个“1号点”。将这些点在空间上投图,圈定出两处异常集中区,划为I号和II号找矿靶区,见图4[16]。

RF模型识别出的Th元素重要性高,除其统计意义外,可能暗示其与锂矿化在成因或迁移过程中的特殊关联,其具体的地球化学机制值得未来专门研究。

#### 4.4. 两种方法的对比分析与启示



**Figure 4.** Verification map of random forest-predicted mineral exploration targets for individual elements Li, Cs, Rb, Th, and the combined element F1 [16]

图4. 随机森林预测的找矿靶区和Li、Cs、Rb、Th单元素、F1组合元素验证图[16]

**方法有效性：**两项研究均成功圈定了经地球化学和地质证据验证的找矿靶区，证明了地电化学数据与机器学习方法结合的有效性。

**问题定义的灵活性：**RF 研究采用了更简洁的二分法，而 PNN 研究尝试了更精细的四分法。二分法可能更稳健，而多分类能提供更丰富的潜力分级信息，但难度更大。

**特征选择的差异性：**RF 选择了 Li、Rb、Cs、Th+F1；PNN 选择了 Li、Rb、Cs、Al、Fe。这说明特征工程没有唯一最优解，不同的模型可能对不同的特征组合敏感，结合地质认识的专家判断至关重要。

**优势互补：**RF 的优势在于可解释性(变量重要性)和稳健的泛化性能；PNN 的优势在于训练速度和对小样本分类的天然适应性。在实际工作中，可以尝试多种模型，对比其结果，形成共识性更强的预测结论。

**地质验证的核心地位：**无论模型多么复杂，其预测结果必须接受地质事实的检验。木绒案例中，红柱石带的野外发现，是连接地球化学异常与地质成矿模型的关键桥梁，使智能预测结果落地生根。

## 5. 优势、挑战与未来发展方向

### 5.1. 融合技术体系的突出优势

**探测深度与信息质量的提升：**地电化学技术直接获取来自深部的活动态离子信息，从根本上克服了厚覆盖层的屏蔽效应。机器学习则能从中提取非线性弱异常，实现了“探得深”且“认得准”。

**预测过程的客观化与定量化：**数据驱动模型减少了人为设定异常下限、圈定异常时的主观随意性，使预测结果更具可重复性和可比性。模型的概率输出(如成矿概率图)为风险评估和勘查决策提供了定量依据。

**勘查效率的飞跃：**实现了从数据到靶区图的(半)自动化流程，极大缩短了资料解释周期，能够快速对大面积勘查区进行扫描和优选，实现“快速锁定、重点详查”。

**多源信息融合能力：**机器学习框架易于整合地电化学、地质、地球物理、遥感等多源异构数据，构建综合信息找矿模型，实现“ $1+1>2$ ”的信息增益。

### 5.2. 当前面临的主要挑战

**样本瓶颈问题：**地电化学采样成本高，导致有精确地质标签(尤其是“含矿”标签)的样本数量非常有限。小样本量制约了复杂模型(如深度学习)的应用，也影响了模型的泛化能力。

**机理与数据的平衡：**当前研究多为纯粹的数据驱动，对地电提取过程中离子迁移、富集的具体物理化学机理结合不够。如何构建“机理约束下的数据驱动模型”，提高预测的地质合理性，是一个重要课题。

**模型的可解释性焦虑：**尽管 RF 等模型提供了一定可解释性，但许多高性能模型(如复杂神经网络)仍是“黑箱”。地质学家需要理解“为什么这里被预测成矿”，而不仅仅是“哪里被预测成矿”。

**成果转化的“最后一公里”：**如何将机器学习输出的概率图、分类图有效地转化为野外可操作的探矿工程布设方案，并与矿产经济评价相结合，仍需探索成熟的流程。

**数据标准化与共享壁垒：**不同单位、不同项目的地电化学数据在采样、分析、质量控制上存在差异，缺乏统一的行业标准，阻碍了大规模数据集的构建与共享。

### 5.3. 未来重点发展方向

**发展面向小样本的机器学习方法：**积极研究迁移学习、元学习、主动学习等范式，利用已有矿床的

模型知识辅助新区预测，或通过智能算法选择最具价值的样本进行补充采样，以缓解样本瓶颈。

**推进多模态数据深度融合：**构建统一平台，整合地电化学元素含量、高光谱遥感矿物信息、地球物理反演属性(如电阻率、极化率)、三维地质模型等多维度数据，利用图神经网络、多模态深度学习等技术进行联合建模。

**增强模型的可解释性与地质知识嵌入：**大力发展可解释人工智能(XAI)技术，如 SHAP 值、LIME 方法等，量化每个特征对单个预测结果的贡献。同时，探索将成矿系统理论、矿床模型等先验地质知识作为规则或约束条件嵌入到机器学习模型中。

**构建云端智能勘查平台：**研发基于云计算和 WebGIS 的在线智能找矿系统，实现地电化学等数据的云端上传、自动化处理、模型调用、在线预测和可视化，降低技术门槛，推广实用化。

**加强基础理论研究与标准化建设：**深入开展地电化学迁移机理的精细实验和模拟研究，为特征选择和模型构建提供理论指导。推动行业协会和机构制定地电化学技术规范与数据标准。

**拓展应用领域：**不仅限于金属矿产，可尝试将地电化学与机器学习结合应用于地热资源勘查、油气微渗漏探测、环境污染溯源、工程地质调查等领域。

## 6. 结论

地电化学与大数据、人工智能的深度融合，正推动矿产勘查从经验驱动向数据驱动、智能化的新范式转变。本文系统阐述了地电化学技术的原理与数据特性，论证了机器学习方法处理此类数据的必要性与优势。以川西木绒锂矿为例，通过随机森林(RF)和概率神经网络(PNN)的全流程应用，展示了该融合方法在识别深部弱异常、精准圈定找矿靶区方面的显著效能。

尽管仍面临样本量有限、模型可解释性不足、多源数据融合困难等挑战，但其发展前景清晰。未来通过发展小样本学习、推动多模态数据融合、加强可解释性研究、构建云端智能平台，地电化学与大数据的结合将更加紧密。这一交叉领域不仅将助力深部找矿突破、保障资源安全，也为地球科学迈向“智慧”时代提供了重要范式。

## 参考文献

- [1] 左仁广. 基于数据科学的矿产资源定量预测的理论与方法探索[J]. 地学前缘, 2021, 28(3): 49-55.
- [2] 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, 777.
- [3] 罗先熔. 地电化学成晕机制、方法技术及找矿研究[D]: [博士学位论文]. 合肥: 合肥工业大学, 2005.
- [4] 刘攀峰, 罗先熔, 文美兰, 等. 我国地电化学技术主要研究进展与展望[J]. 金属矿山, 2022(11): 10-22.
- [5] 刘吉敏, 刘占元. 地电化学勘探法在厚层覆盖区的应用研究[J]. 物探与化探, 1990(4): 255-265.
- [6] 郑超杰, 刘攀峰, 罗先熔, 等. 岩石地球化学数据挖掘及弱异常识别——以新疆阿舍勒铜矿为例[J]. 大地构造与成矿学, 2022, 46(1): 86-101.
- [7] 孙彬彬, 张学君, 刘占元, 等. 地电化学异常形成机理初探[J]. 物探与化探, 2015, 39(6): 1183-1187.
- [8] 王学求. 深穿透地球化学迁移模型[J]. 地质通报, 2005(Z1): 18-22.
- [9] 孙彬彬, 刘占元, 周国华. 地电化学方法技术研究现状及发展趋势[J]. 物探与化探, 2015, 39(1): 16-21.
- [10] 罗先熔. 地球电化学勘查及深部找矿[M]. 北京: 冶金工业出版社, 1996.
- [11] 文美兰, 罗先熔, 欧阳菲, 等. 地电化学法寻找隐伏金矿的应用研究[J]. 矿产与地质, 2008(4): 347-352.
- [12] 张向文, 文美兰, 熊健. 地电化学法寻找隐伏铜、镍矿研究[J]. 岩土工程界, 2009, 12(10): 87-90.
- [13] 张向文, 文美兰, 熊健. 地电化学法在红旗岭铜、镍矿预测中的应用[J]. 甘肃地质, 2010, 19(4): 65-69.
- [14] 文美兰, 罗先熔, 熊健, 等. 地电化学法在南澳大利亚寻找隐伏金矿的研究[J]. 地质与勘探, 2010, 46(1): 153-159.

- 
- [15] 杨青松, 罗先熔, 岳大斌, 等. 基于概率神经网络的智能找矿方法——以四川雅江县木绒锂矿为例[J]. 地质与勘探, 2023, 59(5): 985-999.
  - [16] 甘盟, 刘攀峰, 岳大斌, 等. 基于随机森林算法的川西木绒锂矿区及外围地电化学技术找矿预测[J]. 地质与勘探, 2025, 61(2): 359-370.
  - [17] 邱炜, 任华, 林艳海, 等. 地电化学提取技术在青藏高原干旱荒漠区的参数对比研究及找矿预测——以拉陵高里河西地区为例[J]. 矿产勘查, 2017, 8(1): 117-123.
  - [18] 陈亚东, 孙彬彬, 刘占元, 等. 地电化学提取有效性及提取条件试验——以半干旱草原风成砂浅覆盖景观区为例[J]. 物探与化探, 2015, 39(5): 1008-1012.
  - [19] 刘攀峰, 罗先熔, 文美兰, 等. 近三十年来我国地电化学技术研究回顾与展望[J]. 桂林理工大学学报, 2018, 38(1): 47-55.
  - [20] 刘斌, 郭星, 朱宇恩. 基于随机森林模型的土壤重金属源解析——以晋中盆地为例[J]. 干旱区资源与环境, 2019, 33(1): 106-111.
  - [21] McKay, G. and Harris, J.R. (2015) Comparison of the Data-Driven Random Forests Model and a Knowledge-Driven Method for Mineral Prospectivity Mapping: A Case Study for Gold Deposits around the Huritz Group and Nueltin Suite, Nunavut, Canada. *Natural Resources Research*, **25**, 125-143. <https://doi.org/10.1007/s11053-015-9274-z>
  - [22] Breiman, L. (2001) Random Forests. *Machine Learning*, **45**, 5-32. <https://doi.org/10.1023/a:1010933404324>
  - [23] 焦李成, 杨淑媛, 刘芳, 等. 神经网络七十年: 回顾与展望[J]. 计算机学报, 2016, 39(8): 1697-1716.
  - [24] 姚舜才. 神经网络与深度学习——基于 MATLAB 的仿真与实现[M]. 北京: 清华大学出版社, 2022.
  - [25] 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.
  - [26] 黄宁宁, 罗先熔, 易超, 等. 因子分析在内蒙东胜地区寻找隐伏铀矿中的应用[J]. 桂林理工大学学报, 2019, 39(4): 856-862.
  - [27] 李健康. 川西典型伟晶岩型矿床的形成机理及其大陆动力学背景[D]: [博士学位论文]. 北京: 中国地质大学, 2006.
  - [28] 付小方, 黄韬, 郝雪峰, 等. 川西花岗细晶岩-伟晶岩型锂矿含矿性评价与示矿标志[J]. 地学前缘, 2023, 30(5): 227-243.
  - [29] 付小方, 侯立玮, 王登红, 等. 四川甘孜甲基卡锂辉石矿矿产调查评价成果[J]. 中国地质调查, 2014, 1(3): 37-43.