doi: 10.20239/j.issn.1671-9492.2026.08.003

基因矿物加工与工艺流程智能决策研究

——以铜硫矿物浮选分离为例

杨佳伟[1,2],周俊武[1,2],王庆凯[1,2],朱阳戈[1,3],宋振国[1,3],邹国斌[1,2],高希宇[1,3]

(1. 矿冶科技集团有限公司,北京 100160;
2. 矿冶过程智能优化制造全国重点实验室,北京 102628;
3. 矿物加工科学与技术全国重点实验室,北京 102628)

摘　要: 孙传尧院士提出的“基因矿物加工”理念深刻改变了传统选矿技术的研究范式,将矿床成因、矿石性质与矿物特性等“基因”特征作为工艺决策的核心依据,实现了从经验驱动向知识-数据双驱动的范式跃迁。本文以铜硫矿为研究对象,系统阐述了基因矿物加工的理论与方法体系:基于规则推理(RBR)和案例推理(CBR)构建知识驱动的流程决策框架,实现原则流程设计与浮选回收率预测;针对高维度-小样本条件下的潜在逻辑关系挖掘问题,提出基于机器学习的分段建模与多分类决策模型,完成磨矿制度、选别工艺、药剂制度的个性化推荐;在此基础上,创新性地构建了“RBR+CBR+ML+LLM”多算法融合决策架构,通过先验知识补偿解决数据稀疏条件下的泛化难题。试验验证结果表明,该系统推荐的工艺流程方案与专家设计方案的吻合度达到85%以上,显著缩短了工艺设计周期并降低了试验成本,为基因矿物加工从理论走向工程应用提供了技术支撑,也为选矿工艺的智能化转型开辟了新的路径。

关键词: 基因矿物加工;智能决策;知识推理;机器学习;混合架构;铜硫矿

中图分类号: TD923;TP18　　**文献标志码:** A　　**文章编号:** 1671-9492(2026)08-0026-15

Research on Genetic Mineral Processing and Intelligent Decision-Making for Process Flowsheets: A Case Study on Copper-Sulfide Mineral Flotation Separation

Yang Jiawei[1,2], Zhou Junwu[1,2], Wang Qingkai[1,2], Zhu Yangge[1,3],
Song Zhenguo[1,3], Zou Guobin[1,2], Gao Xiyu[1,3]

(1. BGRIMM Technology Group, Beijing 100160, China;
2. State Key Laboratory of Intelligent Optimized Manufacturing in Mining & Metallurgy Process, Beijing 102628, China;
3. State Key Laboratory of Mineral Processing, Beijing 102628, China)

Abstract: The concept of “Genetic Mineral Processing” (GMP) proposed by Academician Sun Chuanyao has profoundly transformed the research paradigm of traditional mineral processing, elevating genetic characteristics-such as ore deposit genesis, ore properties, and mineralogical features-to the core basis for process decision-making. This shift realizes a paradigm transition from experience-driven to knowledge-data dual-driven approaches. Taking copper-sulfide ores as the research object, this paper systematically presents the theoretical framework and methodological system of GMP: a knowledge-driven process decision-making framework is constructed based on Rule-Based Reasoning (RBR) and Case-Based Reasoning (CBR), enabling flowsheet design and flotation recovery prediction. To address the challenge of mining latent logical relationships under high-dimensional, small-sample conditions, a machine learning-based piecewise modeling and multi-classification decision model is proposed for personalized recommendation of grinding regimes, separation stages, and reagent schemes. A novel

收稿日期: 2026-07-03
基金项目: 国家科技重大专项(2024ZD1002000);矿冶科技集团有限公司先导计划项目(02-2419)
作者简介: 杨佳伟(1982—),男,内蒙古乌兰察布人,博士,高级工程师,主要从事选矿过程智能化相关领域的科研工作。
通信作者: 朱阳戈(1985—),男,山东临沂人,博士,正高级工程师,博士生导师,主要从事复杂多金属矿产高效浮选分选研究。

"RBR＋CBR＋ML＋LLM" multi-modal hybrid decision-making architecture is innovatively developed, which leverages prior knowledge compensation to overcome generalization difficulties in data-sparse scenarios. Industrial validation demonstrates that the process routes recommended by this system achieve over 85% agreement with expert-designed schemes, significantly reducing design cycle time and experimental costs. This work provides technical support for translating GMP from theory to engineering practice and opens a new pathway toward intelligent transformation of mineral processing operations.

Key words: genetic mineral processing; intelligent decision-making; knowledge reasoning; machine learning; hybrid architecture; copper-sulfide mineral

0　引言

随着全球矿产资源禀赋的不断恶化，复杂难选矿石的比例持续上升，传统选矿技术面临着前所未有的挑战。据统计，我国铜矿平均品位已从20世纪80年代的约0.9%下降到目前的约0.5%，且矿石类型日趋复杂，硫化矿、氧化矿及混合矿并存的现象愈发普遍。在此背景下，如何科学、精准地设计和优化选矿工艺流程，已成为矿物加工领域亟待解决的关键问题。

选矿工艺设计是矿山开发的核心环节，传统方法高度依赖专家经验和小试、中试试验。面对日益复杂的矿石性质和绿色低碳的发展要求，传统"经验驱动＋试验验证"的模式已难以满足高效、精准的设计需求[1]。孙传尧院士于2015年提出的"基因矿物加工"理念为解决上述问题提供了全新的思路。该理念的核心思想是：矿床成因、矿石性质和矿物特性等"基因"特征决定了矿石的可选性，通过系统分析这些基因特征与选矿工艺之间的内在关系，可以实现从矿石本质属性到工艺流程的智能映射[2]。这一理念的提出标志着选矿技术从经验驱动向知识-数据双驱动的范式转变，具有重要的理论价值和工程意义。

然而，如何将"基因"特征转化为可计算、可推理的流程决策模型，仍然是当前研究的难点。一方面，选矿领域的先验知识丰富但结构化程度低，难以直接用于计算机辅助决策；另一方面，矿物加工流程的设计数据呈现高维小样本特征，纯数据驱动方法容易产生过拟合，并且缺乏可解释性。因此，构建融合知识推理与机器学习的智能决策体系，是基因矿物加工走向工程应用的关键突破口。

近年来，规则推理(RBR)和案例推理(CBR)已在选矿领域得到深入应用[3-6]，随机森林、支持向量机等机器学习算法被用于浮选回收率预测和工艺参数优化[7-10]。但选矿数据的高维小样本特点造成模型训练难度大，同时纯数据驱动方法可解释性不足，很难得到工程技术人员的认可。大语言模型(LLM)在工业领域的应用为知识推理开辟了新的思路[11-14]，但如何将大语言模型与选矿专业知识进行深度融合，依旧是目前亟待攻克的前沿问题。

本文以铜硫矿为研究对象，围绕基因矿物加工与流程智能决策开展相关研究：提取核心基因特征，搭建矿床-矿石-矿物三级基因特征体系，构建基于RBR和CBR的知识推理框架，提出基于机器学习的分段建模策略，创新性搭建"RBR＋CBR＋ML＋LLM"多模态混合决策架构，利用有限试验验证该架构的可行性，最终采用工业试验对整套系统的使用效果进行评价。

1　基因矿物加工理论

孙传尧院士提出的"基因矿物加工"理念，将生物学中的"基因"概念引入选矿领域。在矿物加工语境下，"基因"指矿床形成过程中由地质作用决定的、对矿石可选性具有决定性影响的内在属性集合。其核心内涵包括：遗传性—矿床成因决定了矿石的基本性质，同一成矿类型的矿石具有相似的可选性特征；表达性—基因特征通过矿物组成、嵌布特性等表现出来；可识别性—通过系统的地质-矿物学研究可以提取和量化基因特征。

基因矿物加工的技术路线如图1所示。基因数据库及大数据是基因矿物加工的基础，智能决策系统以基因数据库的数据为支撑，基于特定的决策模型对具备相应基因特性的矿石初选选矿工艺流程及技术指标，随后通过选矿验证试验确定选矿流程方案及技术指标，依据该方案开展选矿厂的设计和建设；选矿厂工艺流程的设计与优化可依托虚拟选矿厂校核完善，并借助选矿智能服务云平台，为行业转型升级提供支撑[2]。

基于以铜硫矿为对象的系统研究，建立矿床-矿石-矿物三级基因特征体系：矿床基因，包括矿床的

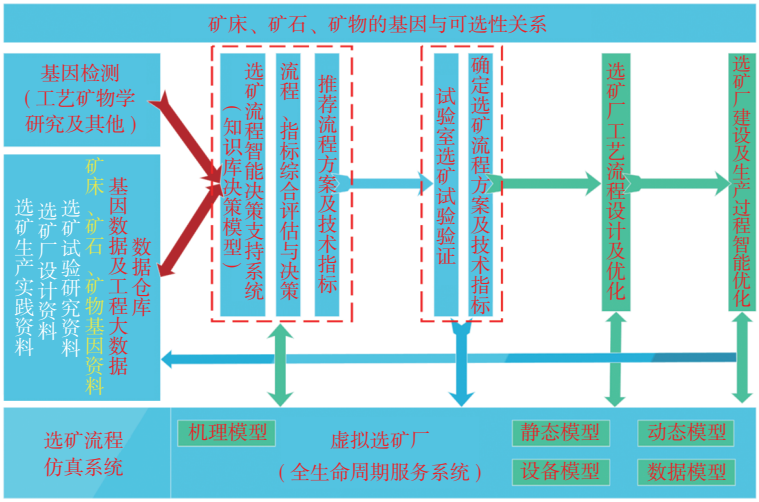


图 1　基因矿物加工技术路线图[2]

Fig. 1　Technology roadmap for Genetic Mineral Processing[2]

成因、矿床内矿物的分布规律以及矿物的共生关系等综合特征，矿床基因决定了矿石的基本矿物组合和结构构造特征，是流程设计的“顶层设计”依据[15-18]；矿石基因，包括矿石的矿物组成、结构特征以及物理化学性质等，这一层级是流程设计的核心参数，直接确定磨矿细度、选别次数和药剂制度等[19-21]；矿物基因，包括表面能、表面电荷等微观特征，这些“深层基因”决定了矿物在特定工艺条件下的行为规律，是辨析可选性差异的本质依据[22-25]。

矿石的“基因性”不仅影响着分选的难度，还直接决定了选矿工艺的选择和设计。通过深入研究这些“基因性”之间的关系，能够为矿物加工流程决策提供理论依据：矿物组成对可选性的决定作用，矿石中的矿物成分及其相对含量，决定了矿物分选的可行性；嵌布粒度对磨矿制度的制约，嵌布粒度的粗细直接决定了磨矿细度要求，粗粒嵌布的矿石可采用较粗的磨矿细度，而微细粒嵌布的矿石则需要更细的磨矿细度和更复杂的药剂制度；矿物表面性质对浮选行为的影响，矿物的表面电荷和亲疏水性决定了矿物是否能够与气泡黏附并形成矿化泡沫。

基于上述理论体系，提出“基因检测→知识推理→数据验证→智能决策→有限验证”的技术路线，其核心思想是以矿石的基因特征为输入，通过知识推理和机器学习的双轮驱动机制，输出最优的选矿工艺流程方案。包含以下关键环节：基因特征的提取与量化表征，将矿床成因、矿石性质和矿物特性等定性描述转化为可计算的定量参数；知识库构建，基于专家经验和历史案例，建立规则库和案例库；数据驱动的模型训练，用机器学习算法挖掘基因特征与可选性之间的潜在关系；混合决策输出，综合知识推理和数据验证的结果，生成工艺流程方案并提供可解释的决策依据。

需要指出的是，在前期研究过程中发现，该领域数据呈现典型的“高维度-小样本”特性，其多维矿物特性参数与有限的工艺案例数据量形成显著矛盾，难以满足传统机器学习算法对训练数据规模的基本要求。同时，矿物加工技术开发积累了大量的理论和经验等先验知识，这些先验知识可以作为基因矿物加工智能决策的推理依据。这一发现共同指向一个关键结论——基因矿物加工流程智能化决策必须突破单一算法的应用范式，转而构建“知识引导＋数据验证”的双轮驱动架构，这正是后续开展基于多智能算法融合决策系统研发的理论基石与实践起点。

2　基于多智能算法融合的基因矿物加工流程决策

本文首先基于规则推理和案例推理算法开展了基因矿物加工流程知识推理决策研究，通过提取共伴生矿物、矿石构造等与选矿工艺流程匹配的6大类专家规则，形成可量化的知识推理体系，实现铜硫矿浮选回收率预测误差＜5%；建立了包括8类基因描述特征与7类工艺结果特征的案例库，提出改进的加权欧氏-余弦相似度匹配算法，使铜硫矿浮选药剂制度推荐合理度达到88%。针对基因特性与工艺参数间潜在的复杂非线性关系，开发了基于XGBoost的机器学习决策模型，通过K-Means聚类分析将输入特征维度由585维降低至64维，采用分段建模策略实现粗选/精选/扫选次数的多目标决策，流程设计关键参数预

测准确率达到85.3%。针对决策过程中遇到的单一决策方法高度依赖历史案例数据深度及准确性，导致难以精准决策的问题，研究了“规则推理(RBR) —案例推理(CBR) —机器学习(ML) —大模型(LLM)”四级多模态混合决策系统，融合结构化知识图谱与领域微调的大语言模型的语义推理能力，形成动态特征交互机制，系统整体决策准确率达到89.6%。

2.1　基于知识推理的流程决策方法

矿物加工技术历经长期实践积累，已形成包含工艺机理、试验数据及专家经验的多维度知识体系，但在传统的研究与开发模式中没有得到有效的统计、分析和利用。知识推理是将获取到的领域知识以规则或案例的形式应用于决策的过程，在基因矿物加工智能决策系统中，这些先验知识的应用路径为：在数据稀缺条件下提供可靠的推理依据；为机器学习模型提供可解释性的约束框架；通过规则的形式化表达实现知识的系统化传承。本文重点探讨2种推理方法在基因矿物加工流程决策中的应用，规则推理用于建立专家规则快速推断适用的选矿工艺；案例推理通过借鉴历史案例，灵活解决复杂的矿物加工问题。

2.1.1　基于规则推理的流程决策方法

规则推理(Rule-Based Reasoning，RBR)基于已知规则和事实，通过推理引擎对矿物加工过程中的基因特性进行分析，从而得出最佳决策结果，适用于能够通过明确规则进行归纳和推理的问题，帮助决策者在复杂的矿石特性与选矿工艺之间做出科学合理的选择。经典规则推理系统有三个重要组件：规则库、事实库和规则推理引擎。

1)规则库：作为符号推理系统的核心组件，规则库构建了基于产生式规则的认知基元体系。其采用三元组结构化存储范式(规则ID、前提条件、执行动作)，通过哈希索引实现知识的高效检索。产生式规则作为基因矿物加工领域确定性决策的知识表征范式，标准语法结构可形式化表述为：If $P(x)$ Then $Q(y)$，其中$P(x)$表征规则触发的判断条件集合(由布尔组合构成)，$Q(y)$对应规则满足后的触发行为集[26]。这种“条件达标→行为触发”的严格因果链机制，通过离散状态迁移实现了加工决策过程的可解释性与确定性控制。在工艺决策知识获取中，针对不同的工艺决策子问题(如工艺选择、药剂选择等)，采用了对现有工艺资料分析、讨论、提问等方式进行工艺决策知识的收集、总结与归纳。在此基础上，进行整理与概括，形成可信度高、覆盖面宽的知识条款，并根据具有丰富工艺设计经验的工程师的评价，逐条进行讨论、确认，最后进行标准化。表1为易浮易泥化脉石矿物与工艺流程匹配规则示例。

2)事实库。包含了矿石加工中涉及的各种具体数据，这些数据通常是通过试验、现场检测或历史记录获得的。例如，矿石的粒度、矿物组成、元素含量等。这些数据被作为输入提供给推理系统，与规则库中的规则进行匹配。

3)规则推理引擎。在基因矿物加工的规则推理的驱动方面，通过测试对比后，选择专家系统作为推理机。通过符号化建模工具建立不同几何形态的节点表征体系，其中各拓扑构型对应特定类型的决策路径节点。基于形式化知识表示方法，为每个决策节点构建基于布尔代数的条件约束规则集，规则集采用条件触发结构进行编码，其中复合判定条件通过运算符连接。图2为原则流程设计推理过程。

2.1.2　基于案例推理的流程决策方法

案例推理(Case-Based Reasoning，CBR)作为一种工程化类比推理范式，其技术内核植根于经验复用机制和类比映射能力两大人类认知进化的基本维度。CBR方法基于基因与工艺流程匹配，结合矿物加工流程知识，为新的矿物加工流程方案提供设计建议。

基于CBR的基因矿物加工决策算法流程如图3所示，首先根据新问题的特征，对比在案例库中的历

表1　易浮易泥化脉石矿物与工艺流程匹配规则

Table 1　Matching rules of readily floatable and slime-prone gangue minerals with flowsheet

序号	判断条件	触发行为	矿物特性说明
1	滑石含量≥决策阈值m_1	预先浮选脱除	强天然疏水性，易浮，对药剂具有吸附能力
2	决策阈值m_1＞滑石含量＞决策阈值m_2	添加抑制剂	
3	碳质脉石含量≥决策阈值m_3	预先浮选脱除	强天然疏水性，易浮，对药剂具有吸附能力
4	决策阈值m_3＞碳质脉石含量＞决策阈值m_4	添加抑制剂	
5	蛇纹石含量≥决策阈值m_5	添加抑制剂	易泥化，药剂吸附能力
6	绿泥石含量≥决策阈值m_6	添加抑制剂	易泥化
7	云母含量≥决策阈值m_7	添加抑制剂	易泥化
8	高岭石含量≥决策阈值m_8	添加抑制剂	易泥化
⋮	⋮	⋮	⋮

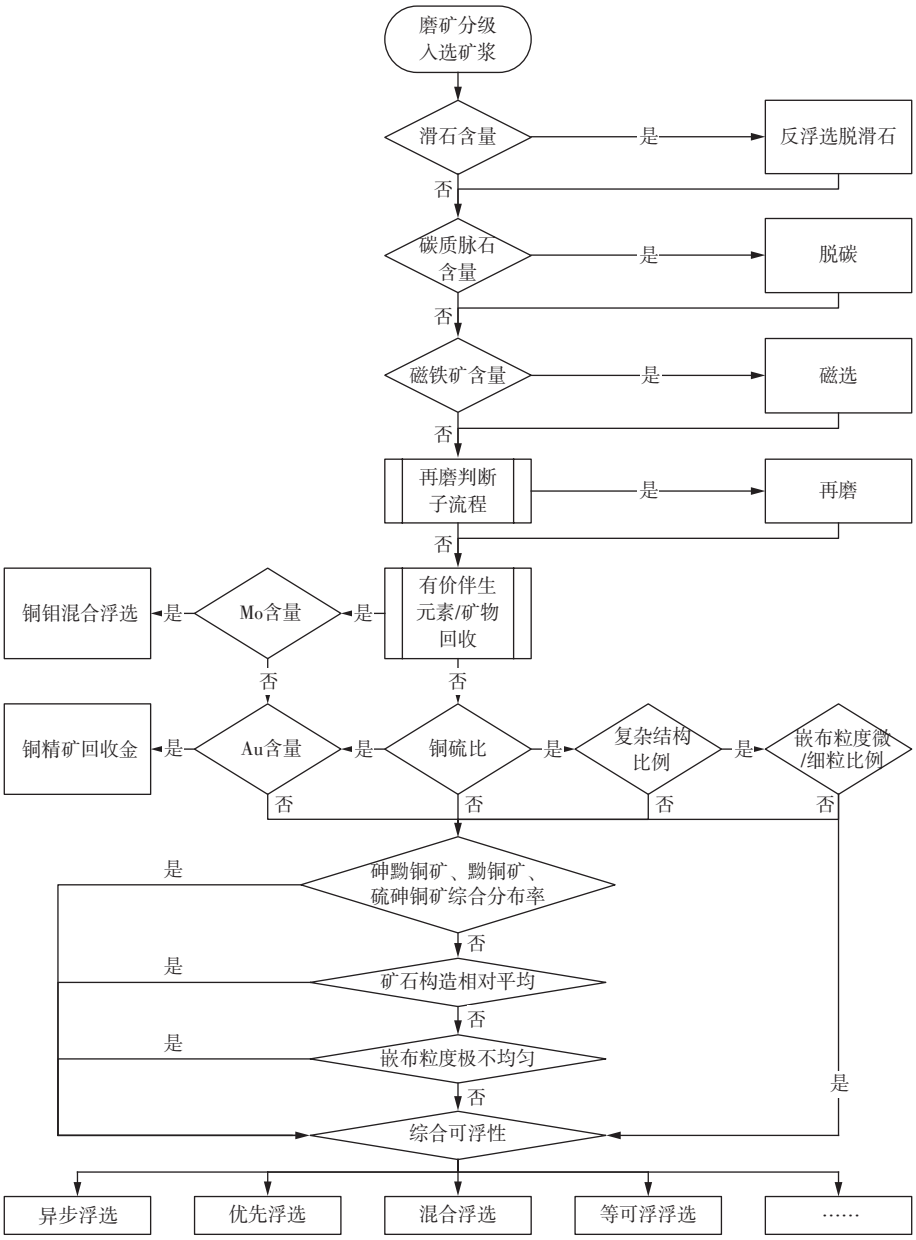


图 2　原则流程设计过程

Fig. 2　Principal flowsheet design process

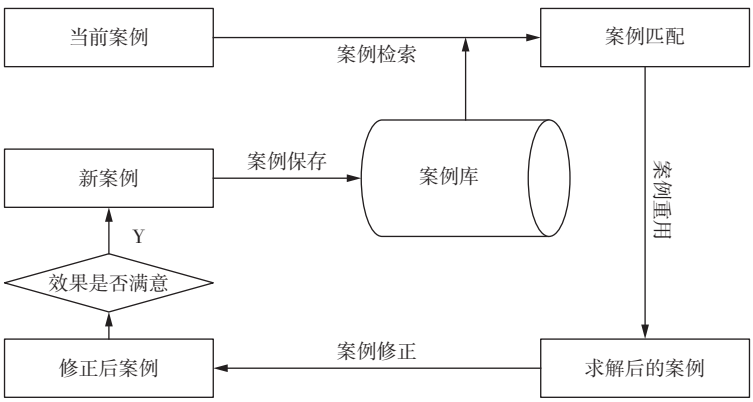


图 3　案例推理算法流程

Fig. 3　Flowsheet of the case-based reasoning algorithm

史案例的相关性，从案例库中筛选出满足一定相似度的一个或几个案例。将相似的案例解通过一定的修改将其作为新问题的解。通过解决问题的效果决定是否将新问题的案例存入到案例库中，以便对之后的问题进行求解。

决策过程由案例库建立、案例检索、案例重用和案例保存几个主要步骤组成。

1）案例库建立。每个基因矿物加工案例至少应该包含问题描述和解描述两部分信息，问题描述通常包括矿石的基因特征，这些特征将作为案例的输入参数；解描述则包括矿物加工的具体工艺流程参数，这些参数将作为问题的求解方案。在建立基因矿物加工的案例库时，案例描述为矿床性质f_1、矿石构造f_2、矿石结构f_3、矿物组成f_4、矿物粒度f_5、元素含量f_6、元素赋存状态f_7、矿物组成f_8等基因参数；案例解为矿物加工流程的磨矿制度j_1、预处理流程j_2、选别原则流程j_3、选别具体参数j_4、再磨制度j_5、有价元素回收j_6、药剂制度j_7等，案例结构见表2。

表2　案例结构

Table 2　Case structure

案例描述F	案例解J
$f_1,f_2,f_3,f_4,f_5,f_6,f_7,f_8$	$j_1,j_2,j_3,j_4,j_5,j_6,j_7$

其中，$F=\{f_1,f_2,f_3,f_4,f_5,f_6,f_7,f_8\}$，$J=\{j_1,j_2,j_3,j_4,j_5,j_6,j_7\}$

经过现场调研，采集历史数据库，构架案例库，每条案例的结构如下：

$$C_k=(F_k,J_k),k=1,\cdots,m \tag{1}$$

式中，C_k为案例库中第k个案例；m为案例数量。

2）案例检索。案例检索是CBR的核心步骤。该过程的目的是将新问题与案例库中的历史案例进行对比，筛选出最相似的案例，以便根据历史经验来推导解决方案。常用最近相邻法来完成案例检索，按照案例相似度的大小进行排序。检索出案例相似度排在前面的k个案例，将此k个案例的解作为下一步案例重用的条件，具体计算过程如下。

算法1：案例检索算法

输入：当前案例$C=\{f_1,f_2,\cdots,f_8\}$.
案例库$D=(C_k),k=1,\cdots,38$
权重向量$W=(w_1,w_2,\cdots,w_8),\sum_{i=1}^{8}w_i=1$
相似度阈值$\theta=0.7$，返回案例数$k=5$

输出：Top-k相似案例列表.

1：// 特征预处理
2：**for each** $f_k\in\{f_{连续特征}\}$ **do**
3：　$f_k^{'}\leftarrow\dfrac{f_k-\min(f_k)}{\max(f_k)-\min(f_k)}$　// 数值特征归一化
4：**for each** $f_m\in\{f_{离散特征}\}$ **do**
5：　$f_m^{''}\leftarrow\mathrm{OneHot}(f_m)$　// 离散特征编码
6：$\vec{V}_c\leftarrow\mathrm{Concat}(f_1^{''},f_2^{''},f_3^{''},f_4^{'},f_5^{'},f_6^{'},f_7^{'},f_8^{'})$　// 构建当前案例向量
7：// 并行相似度计算
8：$S\leftarrow\varnothing$　// 结果初始化
9：**for each** $C_i\in D$ **do in parallel**
10：　$\vec{V}_i\leftarrow\mathrm{LoadEncodedVector}(C_i)$
11：　$sim\leftarrow\sum_{i=1}^{8}w_i\mathrm{SIM}(V_c,V_i)$·
12：　**if** $sim\geqslant\theta$ · **then**
13：　　$S\leftarrow S\cup\{(sim,C_i)\}$
14：// 结果输出
15：Sort S by sim in descending order
16：**return** $S[0:\min(k,|S|)]$

3）案例重用。案例重用阶段是将检索到的相似案例的解决方案用于当前问题的求解。在这个过程中，通过计算各个案例的相似度，利用相似案例的解描述（即工艺参数）来推导出当前问题的最优解决方案。当面临新案例时，通过案例检索得到了与新案例相似的3个案例，即C_1，C_2，C_3检索到的案例描述为F_k，当前工况下的案例描述为F，它们之间的相似度为$\mathrm{SIM}(F,F_k)$，$k=1,2,3$，得案例解为$J_k=\{j_{1,k},j_{2,k},j_{3,k},j_{4,k},j_{5,k},j_{6,k},j_{7,k},\}$，$k=1,2,3$，则可以根据每个案例与当前工况的相似度，按照加权平均的方式推导出新的解决方案：

$$J=\frac{\sum_{k=1}^{3}\mathrm{SIM}(F,F_k)\cdot J_k}{\sum_{k=1}^{3}\mathrm{SIM}(F,F_k)} \tag{2}$$

式中，$J=\{j_1,j_2,j_3,j_4,j_5,j_6,j_7\}$。

4）案例保存。在新问题的解决方案得到确认后，CBR系统将保存新的案例。这一过程有助于不断充实案例库，提高系统的决策能力。首先，计算当前案例与案例库中所有历史案例的最大相似度$\mathrm{SIM}_{\max}$；然后，设定储存阈值λ_1和修正阈值λ_2，满足$0.5<\lambda_2<\lambda_1<1$，经过使用现场实际数据对比调试，确定了$\lambda_1=0.9$，$\lambda_2=0.8$。当新案例与已有案例的最大相似度小于阈值$\lambda_2$时，新的案例将被加入案例库，反之则不加入。

2.2　基于机器学习的流程决策方法

基于知识推理的决策方法虽具备逻辑透明性，但其依赖先验知识的覆盖度与质量，难以解决矿物基因特性与工艺参数间复杂、非线性的潜在关联问题。随着机器学习等人工智能技术的迅猛发展，这一领域的决策方式正逐步向智能化转型。针对基因矿物加工中无法通过机理模型或经验规则量化的决策问题，以历史试验数据为基础，研究基于机器学习的工艺流程和参数预测方法，通过构建数据预处理、特征工程与算法优化的全流程技术框架，突破传统知识推理的局限性，

为复杂矿石的智能化决策提供数据驱动支撑，实现原则流程和选别次数等部分具体工艺参数的建模决策。

在矿物加工决策过程中，数据预处理是构建有效模型的关键步骤之一。通过分析不同条件属性数据，采用多种技术对数据进行处理，从而构建了一个包含有效案例的数据集。本研究中矿床、矿石、矿物特征的原始数据维度达到了585维，包含了广泛的连续与分类变量。这种高维数据虽然信息丰富，但也带来了计算负担重、建模复杂度高、模型泛化能力下降等问题。针对这一问题，提出一种融合无监督聚类与监督学习的混合式特征选择算法(K-Means-XGBoost)，通过多阶段协同优化实现特征空间的智能压缩。核心思想是先将PCA降维后的128维特征空间动态划分为35个特征簇，引入自适应簇数校准机制，当连续5次聚类结果的相似度低于0.8时，自动增加簇数直至满足稳定性条件。在每个特征簇内，通过模型贡献度和信息相关度构建双模态评价指标，平衡模型依赖特征与数据本质关联特征的选择权重，如式(3)所示。

$$\mathrm{Imp}(f)=0.6\times\frac{\sum\text{机器学习算法增益}}{\text{分裂次数}}+0.4\times\max_{\text{bins}}\frac{I(f;y)}{\log(\min(m,n))} \tag{3}$$

在基因矿物加工流程决策系统中，矿石类型、成分、粒度结构等属性高度复杂且非线性。为了从众多特征中提取有效规则、实现准确分类与参数预测，决策树(Decision Tree)成为一种重要的基础模型，基本思想是依据信息增益、信息增益率或基尼指数等准则，选择最优属性对数据进行逐层划分，生成子节点，直到满足预设的终止条件或叶子节点纯度达到某一阈值为止。通过模型测试发现，由于基因矿物加工数据横向维度高的特点，决策树具有容易过拟合、准确性不太高的缺点，一种有效的优化思路是借鉴实际决策过程中的经验，通过组合大量的决策树，从而提高预测效果。为了确定最适合的决策算法，使用相同的数据分别建立了SVM、Decision Tree、Random Forest、AdaBoost、XGBoost等机器学习的模型，并对模型的关键指标进行了对比，模型ROC曲线对比如图4所示。

在ROC曲线中，决策树模型的AUC值为0.70，随机森林模型的AUC值为0.82，XGBoost模型的AUC值为0.94，随机森林模型模型的分类决策效果好于决策树模型，XGBoost模型的分类决策效果好于随机森林模型，而且XGBoost模型的AUC值高于0.9，决策的准确性较高，是三种模型中决策效果最好、最适应基

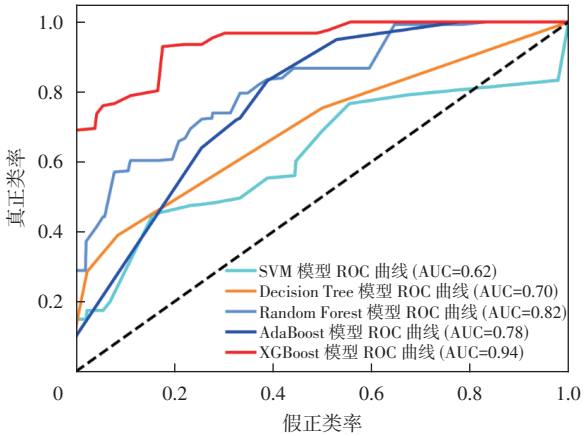


图4 不同智能算法ROC曲线

Fig. 4 ROC curves of different intelligent algorithms

因矿物加工流程浮选流程结构推荐的模型。

以原则流程决策为例，训练模型时，将基因矿物历史数据中特定的数据规模分别选为训练集和测试集，选取数据中的“三矿”基因作为模型输入，原则流程作为Label进行模型学习，具体学习过程如下所示。

算法2：原则流程决策算法

输入：基因特征 $x\in\mathbb{R}^{m\times n}$

工艺流程 $y\in${磨矿制度，浮选流程结构，回收率，···}

约束条件集合 C

输出：最优流程方案 P^*

```
// 数据预处理
x' ← MinMaxScaler(x_连续特征)        // 连续特征归一化
x'' ← Concat(x', OneHot(x_离散特征))        // 离散特征编码
params ← {booster='gbtree', objective='multi: softmax', eta=0.05,
  max_depth=7, min_child_weight=1, subsample=1, colsample_bytree=1,
  gamma=0, lambda=1, verbosity=0, metrics='mlogloss'}
// 模型参数初始化
custom_loss ← CrossEntropy+EnergyPenalty        // 定义损失函数
构建DMatrix        //80%的数据训练，20%的数据验证
// 训练与解释增强
for t=1 to 300 do        // 迭代训练
    model.update(x'', y)
    if t mod 20 = 0 then
        Φ ← SHAP(model, x'')        // 特征贡献度分析
        w ← UpdateWeights(Φ, threshold=0.1)        // 动态调整特征权重
// 实时决策流程
Function Predict(x_new):
    p ← model.predict(x_new)        // 概率分布
    top_3 ← argsort(p)[-3:]
    for i ∈ top_3 do
        if CheckConstraints(i, C) then
            P* ← i
            break
// SHAP可解释性引擎
explainer ← shap.TreeExplainer(model)        // 初始化解释器
shap_values ← explainer(x_new)
R ← GenerateReport(shap_values)        // 特征贡献度绘图
return P*, R
```

图5为模型SHAP的汇总图，全局展示了特征重要性及方向性影响(正/负相关)，并对关键驱动因素从上至下按重要性降序排列，宽度越大特征对预测结

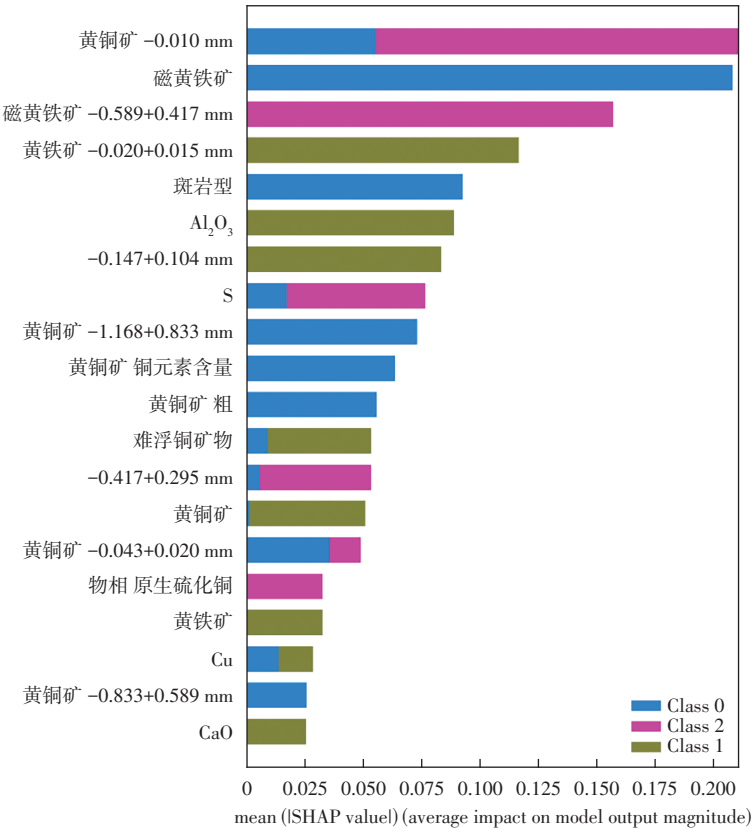


图 5　原则流程决策模型 SHAP 汇总图

Fig. 5　SHAP summary plot of principle flowsheet decision model

果的波动影响越显著，顶部特征对模型预测影响最大。通过特征重要性分析，对铜硫矿浮选原则流程选择影响比重最大的驱动特征为黄铜矿 −0.010 mm 含量、磁黄铁矿含量、磁黄铁矿 −0.589+0.417 mm 含量、黄铁矿 −0.02+0.015 mm 含量、矿床类型、−0.147+0.104 mm 含量、S 含量、黄铜矿 −1.168+0.833 mm 含量、黄铜矿粗粒含量、难选铜矿物含量和黄铜矿、黄铁矿含量等，分类分析发现主要元素含量(铜、硫)、主要矿物嵌布粒度(黄铜矿、黄铁矿等)、矿物组成(难选矿物含量)以及矿床种类是决策浮选原则流程类型的主要因素，这与矿物加工的经验相符。

图 6 是原则流程决策模型中，XGBoost 算法中随机选取的结果为优先浮选的 15 颗决策树，横轴为 SHAP 累积值，纵轴为特征排序，曲线从基线开始逐步叠加特征贡献，不同颜色曲线代表不同样本，交叉点标识决策分歧位置。从图 6 中可以看到每个决策树都是一个窄领域的若分类器，叠加同一类别样本得到共性驱动特征。

2.3　基于算法融合的流程决策方法

矿物加工决策的核心目标是根据不同矿石的特性优化选矿工艺流程，以提高资源利用率和经济效益。传统知识推理方法依赖先验知识覆盖度，机器学习模型受限于数据质量与可解释性，单一决策方法难以全面应对矿物加工中基因特性与工艺参数间复杂的非线性关系。所以需要通过“知识-数据-算法”协同驱动的混合决策框架，将知识决策体系与机器学习模型的多模态融合，提升基因矿物加工过程的智能决策水平。

2.3.1　知识推理与机器学习模型融合

通过构建知识-数据融合的混合模型推理体系，弥补单一方法的不足；通过优化机器学习模型嵌入方式，提高决策的智能水平；通过优化结果输出与优先级，提高模型预测结果的可用性；最后，通过模型验证与优化，确保机器学习系统的可靠性与准确性。

智能算法融合推理系统由三个核心模块构成。1)专家规则推理模块：基于矿物加工领域知识库，构建包含工艺参数约束、流程配置规则的多层次专家规则

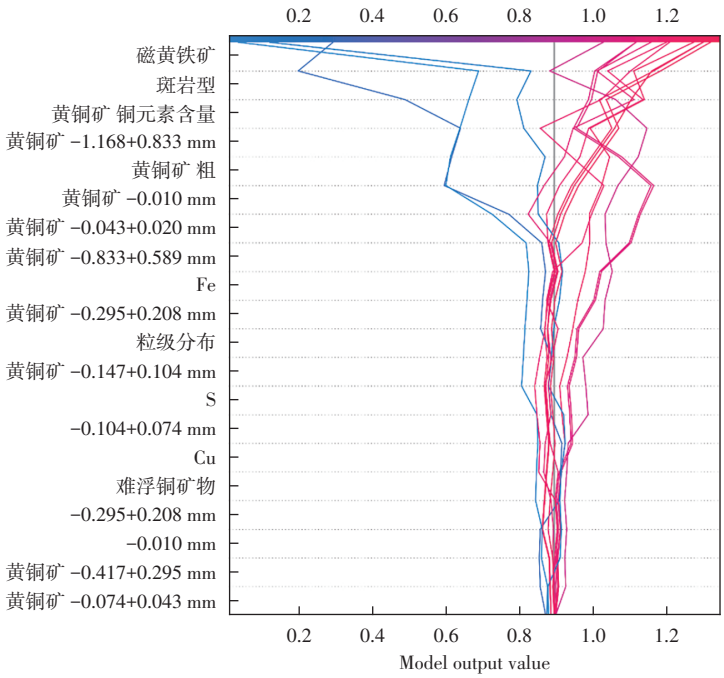


图 6　原则流程决策过程 XGBoost 算法决策树(随机选取 15 颗)

Fig. 6　Illustrative trees from the XGBoost model in principle process flowsheet decision

库；2)机器学习模块：针对基因矿物加流程设计中的细分任务，分别建立 XGBoost 模型；3)融合决策引擎：设计加权融合机制，集成规则推理的确定性约束与数据驱动的概率性预测，通过多目标优化生成全局最优方案。

如图 7 所示，该架构内知识驱动与数据驱动的深度协同，规则推理模块提供符合行业规范的工艺要求的方案，案例库支持历史经验的类比迁移，而机器学习模型则通过非线性映射捕捉复杂工艺参数间的隐式关联，既能保证决策过程的可解释性，又能提高对复杂非线性关系的决策能力。实验表明，这种融合机制使系统决策的 $F1$-score 指标提升 27.6%，同时保持决策路径的透明可追溯。

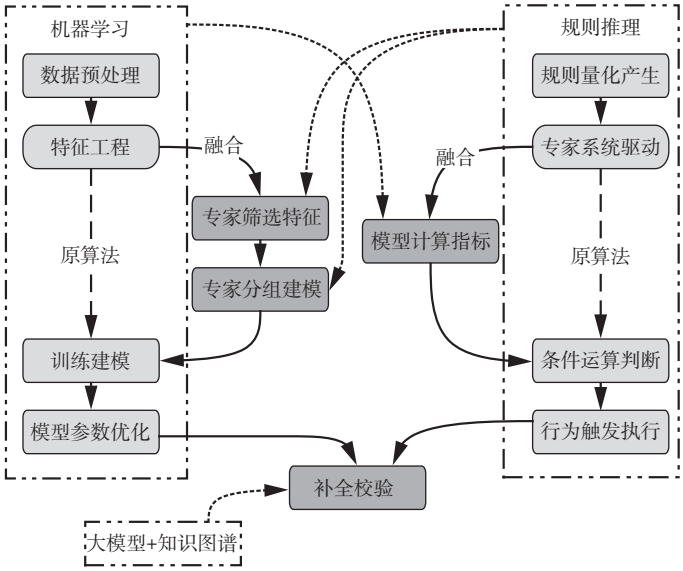


图 7　知识推理与机器学习模型融合方法

Fig. 7　Fusion method of knowledge reasoning and machine learning models

2.3.2　基于大模型的知识推理框架

随着大数据、人工智能(Artificial Intelligence，AI)、自然语言处理(Nature Language Process，NLP)、知识图谱与深度学习等技术的发展，决策系统进入了智能化的新阶段。现代智能决策系统集成了语义理解、数据挖掘、知识建模与推理等多种能力，逐步从静态规则执行向动态知识生成与因果推理转型，极大提升了对复杂、模糊、多目标决策问题的处理能力。其在矿物加工领域的应用突破了传统专家系统对结构化规则的依赖，通过非结构化信息解析、知识链动态构建与多维度可解释输出三大核心能力，实现了复杂决策任务的智能化升级。总体框架如图8所示。

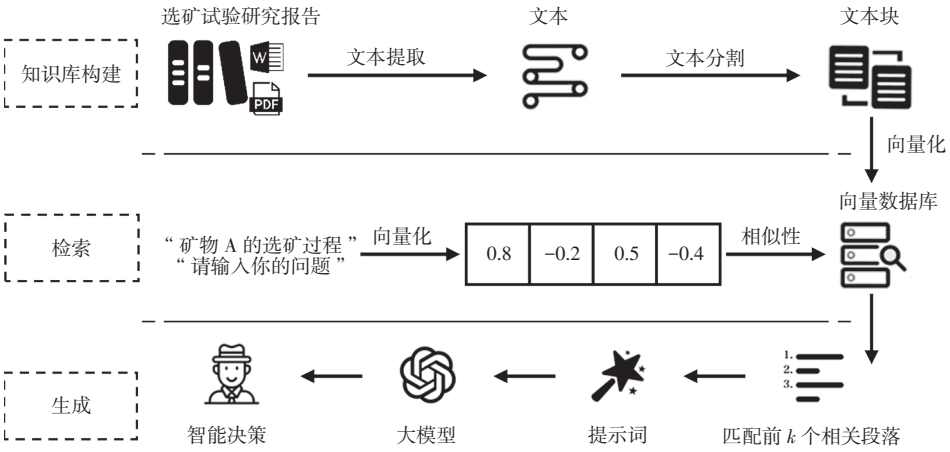


图8　基于知识推理的智能决策系统总体框架

Fig. 8　Overall framework of knowledge-inference-based intelligent decision-making system

1)语义驱动的多模态知识推理。区别于基于符号逻辑的专家系统，LLM通过注意力机制实现自然语言描述、工艺参数矩阵、矿物基因图谱等多模态输入的联合语义建模。系统构建的语义等价空间(Semantic Equivalence Space，SES)模型可以理解“黄铜矿＋黄铁矿＋高硫”意味着可能存在浮选过程中的抑制问题，并进一步联想到应优先选择“优先浮选＋抑制剂A＋调整剂B”的组合策略。这种语义驱动机制使推理过程不再局限于预设规则，而是通过语言理解建构逻辑图谱，并根据当前任务动态检索与组合相关知识路径，从而提升推理的通用性与灵活性。

2)多尺度场景感知与约束融合。在推理策略设计中，大模型具备“场景感知能力”，即通过上下文嵌入机制，将这些异构因素融合建模，构建完整的问题语境。以“药剂选择”场景为例，大模型不仅要识别矿石中的主矿物与伴生矿物，还可以考虑当前浮选设备的特点是否影响药剂的选择、样本所在地区温度气候等是否会干扰药剂效果、环保要求是否限制某类药剂的使用等。通过将这些信息作为辅助输入与背景提示(Prompt embedding)引入，模型可实现决策过程的定制化与精准化。

3)层级化验证的决策优化机制。在实际决策任务中，大模型推理首先进入初级判断层，识别问题类型，检索历史类似案例或专家知识，快速生成初步建议；然后进入精细化微调层，对关键参数(磨矿细度、浮选时间、药剂配比等)进行细致预测与优化；模拟若干备选路径，推演出不同选择可能导致的结果差异，增强推荐结果的鲁棒性。最后对每一轮的输出进行置信评分，供专家或系统决策模块参考采纳。

通过大模型知识推理进行基因矿物加工决策结果验证和完善的算法设计如下。

算法3：大模型知识推理流程验证算法

输入：基因矿物加工领域数据和知识源S，“三矿”基因数据G，流程设计数据D
输出：验证结果R，优化建议P

```
Initialize KnowledgeGraph KG ← ∅    // 初始化知识图谱
// 知识图谱动态构建模块
for each source s in S do
    entities ← LLM_Extract (s, ["三矿基因", "流程结构", "技术参数", ···])    // 实体抽取
    relations ← LLM_Relate (entities, ["需要", "冲突", "优化"])    // 关系抽取
    KG ← KG ∪ ConstructSubgraph (entities, relations)    // 建立知识图谱
end for
// 多模态特征解析
design_features ← {
```

```
10:  flowchart_topology: LLM_ParseGraph(D.diagram),  //流程图解析
11:  grinding_matrix: LLM_Analyze(D. grinding),  //磨矿制度解析
12:  reagents_matrix: LLM_Analyze(D.reagents),  //药剂制度解析
13:  flowsheet_specs: LLM_Analyze(D.paras),  //其他参数解析
14: }
15: // 验证引擎
16: violations ← []
17: // Stage 1: 硬约束验证
18: for each step in design_features.flowchart_topology  do
19:  if KG.QueryCompatibility(step. grinding, G.gene) == False then //磨矿制度验证
20:  violations.append("磨矿制度冲突: " + step. grinding + "vs" + G. gene)
21:  end if
22:  if KG.QueryCompatibility(step. reagents, G.gene) == False then //药剂制度验证
23:  violations.append("药剂制度冲突: " + step. reagents + "vs" + G. gene)
24:  end if
25:  param_range ← KG.GetParamRange(step. process_type)
26:  if step.parameters ∉ param_range then  //设计参数验证
27:  violations.append("参数越界: " + step. paras + "∉" + param_range)
28:  end if
29: end for
30: // Stage 2: 图结构推理验证
31: critical_path ← KG.FindCriticalPath(design_features.mineral_type)
32: missing_nodes ← ComparePaths(critical_path, design_features.flowchart_topology) //工艺环节缺失
33: conflict_edges ← KG.DetectConflicts(design_features.flowchart_topology) //工序冲突
34: // Stage 3: 交叉模拟验证
35: simulation_results ← LLM_Simulate(
36:  process_graph = KG,
37:  input_design = design_features,
38:  iterations = 5
39: )
40: // 结果综合与优化
41: if violations ≠ ∅ || missing_nodes ≠ ∅ || simulation_results.recovery_rate < 0. 85 then
42:  P ← LLM_GenerateOptimization(
43:  KG = KG,
44:  violations = violations,
45:  simulation = simulation_results,
46:  objectives = ["max_recovery", "min_cost"]
47:  )
48:  R.status ← "Rejected"  //验证不通过
49: else
50:  R.status ← "Approved"  //验证通过
51: end if
52: return R, P
```

3 交叉验证与试验验证

3.1 数据交叉验证

为了验证决策系统整体的准确性,从已有的案例库中挑选出了10个典型的铜硫矿案例,通过以上决策系统生成流程设计需要的各个关键参数。通过对比试验,流程参数完全相同的案例占30%,原则流程相同的案例占90%,初步验证了决策系统的整体功能和性能。并且,针对对比试验发现的个别分歧点进行了详细的研究,比如验证过程中分歧最大的中矿再磨流程的决策,均可从工艺角度得到解释。具体对比情况见表3、4。

3.2 选矿试验验证

为了进一步验证基因矿物加工决策系统的实际效果,选择了具有代表性的国内某新建铜矿山为对象,利用上述流程智能决策方法建立了工艺流程方案,并分别针对采用传统方法建立的流程和采用基因矿物加工智能决策方法确定的流程进行选矿试验,测试两种方案的流程表现。

在传统研究方法下,该铜矿采用铜硫优先浮选工艺,进行铜粗选磨矿细度、石灰用量、捕收剂种类和用量,铜精选再磨细度、石灰用量,硫粗选硫酸用量、丁基黄药用量和浮选时间条件试验。在条件试验的基础上进行了一段细磨—铜粗精矿再磨工艺闭路试验,试验流程见图9,试验结果见表5。

根据基因矿物加工系统的流程决策,得到一段粗磨—中矿再磨工艺流程,对该工艺进行了闭路试验,试验流程见图10,试验结果见表6。

传统模式选矿工艺试验研究所获得工艺流程铜浮选作业采用一段细磨(−0.074 mm占80%)−粗精矿再磨(再磨细度−0.038 mm占78.4%)一粗三精两扫工艺流程,基因矿物加工系统决策所获得工艺流程铜浮选作业采用一段粗磨(−0.074 mm占65%)−中矿再磨(铜精选1尾矿和铜扫选1泡沫合并再磨至−0.038 mm占87.4%)−一粗三精两扫工艺流程,两种方式所获得工艺流程流程结构基本相似,所获得选矿工艺指标(Cu、Au等回收率)也基本相近。两者的区别在于磨矿方式和磨矿细度的不同,即基因矿物加

表 3　历史数据交叉验证

Table 3　Cross-validation of historical data

序号	矿样名称	传统研究方法设计结果	决策系统智能推荐结果	备注
1	沙溪铜矿	顺序优先浮选(一粗二扫三精)	顺序优先浮选(一粗二扫三精)—中矿再磨	中矿再磨不同
2	李家湾铜矿	顺序优先浮选(一粗三扫三精)	顺序优先浮选(一粗三扫三精)—中矿再磨	中矿再磨不同
3	齐华铜硫矿	铜硫混合浮选(二粗三扫三精)—粗精矿再磨—铜硫分离(一粗三扫)	铜硫混合浮选(二粗三扫三精)—粗精矿再磨—铜硫分离(一粗三扫)	完全相同
4	城门山铜矿	铜硫混合浮选—粗精矿再磨再选(一粗二扫三精)—铜硫分离(一粗二扫一精)	铜硫混合浮选(一粗二扫三精)—中矿再磨—铜硫分离(一粗一扫一精)	粗精矿再磨不同
5	铜山口铜矿	顺序优先浮选(二粗一扫二精)—中矿再磨	顺序优先浮选(二粗一扫二精)	中矿再磨不同
6	冬瓜山铜矿	顺序优先浮选(二粗二扫二精)—中矿再磨再选(一粗二扫二精)	顺序优先浮选(二粗二扫二精)—中矿再磨(二粗二扫二精)	基本完全相同
7	子尼铜硫矿	铜硫混合浮选(二粗二扫三精)—铜硫分离(一粗一扫三精)	铜硫混合浮选(二粗二扫三精)—铜硫分离(一粗一扫三精)	完全相同
8	呼的合铜矿	顺序优先浮选(一粗二扫三精)	顺序优先浮选(一粗二扫三精)—中矿再磨	中矿再磨不同
9	德兴铜矿	铜快速浮选—铜硫混合浮选—粗精矿再磨—铜硫分离	铜硫混合浮选(二粗三扫三精)—铜硫分离(一粗一扫二精)	原则流程不同
10	生权铜矿	铜快速浮选—铜硫混合浮选—粗精矿再磨再选—铜硫分离	铜快速浮选—铜硫混合浮选—粗精矿再磨再选—铜硫分离	扫二泡沫返回不同

表 4　案例交叉验证结果统计

Table 4　Cross-validation result statistics

序号	对比内容	案例数量	相同比例/%
1	基本完全相同	3	30
2	原则流程相同	9	90
3	粗精矿再磨相同	9	90
4	中矿再磨相同	6	60

工系统的决策工艺采用一段粗磨＋中矿再磨，而传统模式选矿工艺试验所获得工艺流程采用一段细磨＋粗精矿再磨，从工艺指标和经济效益等方面综合考虑，两种方案各有优劣。

以上验证表明，基因特性测试提取的参数能够较好的表征被测样品的矿床成因、矿石性质和矿物特

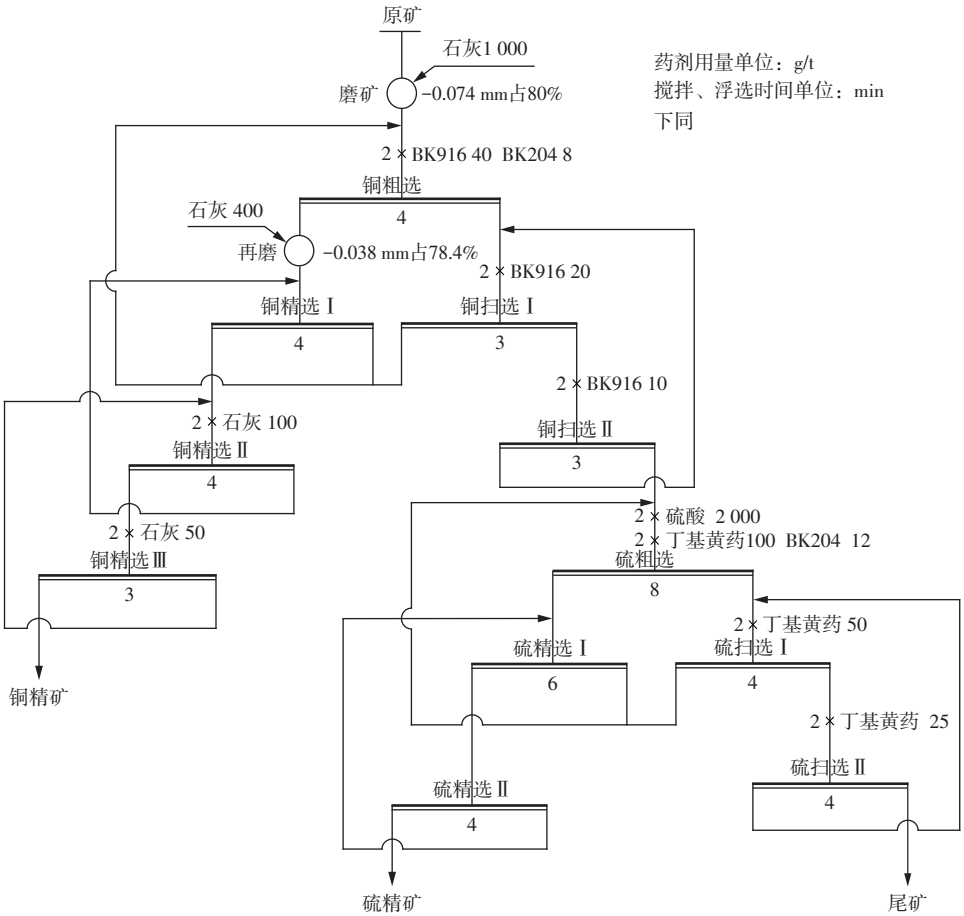


图 9　传统模式闭路试验流程

Fig. 9　Flowsheet of the locked-cycle test of the conventional mode

表 5 传统模式闭路试验结果

Table 5 Results of the locked-cycle test of the conventional mode /%

产品名称	产率	品位			回收率		
		Cu	Au①	S	Cu	Au	S
铜精矿	1.70	22.50	74.76	28.77	94.04	57.53	4.93
硫精矿	19.35	0.064	4.36	47.89	3.04	38.19	93.40
尾矿	78.95	0.015	0.12	0.21	2.92	4.28	1.67
原矿	100.0	0.41	2.21	9.92	100.0	100.0	100.0

注:①单位为g/t,下同。

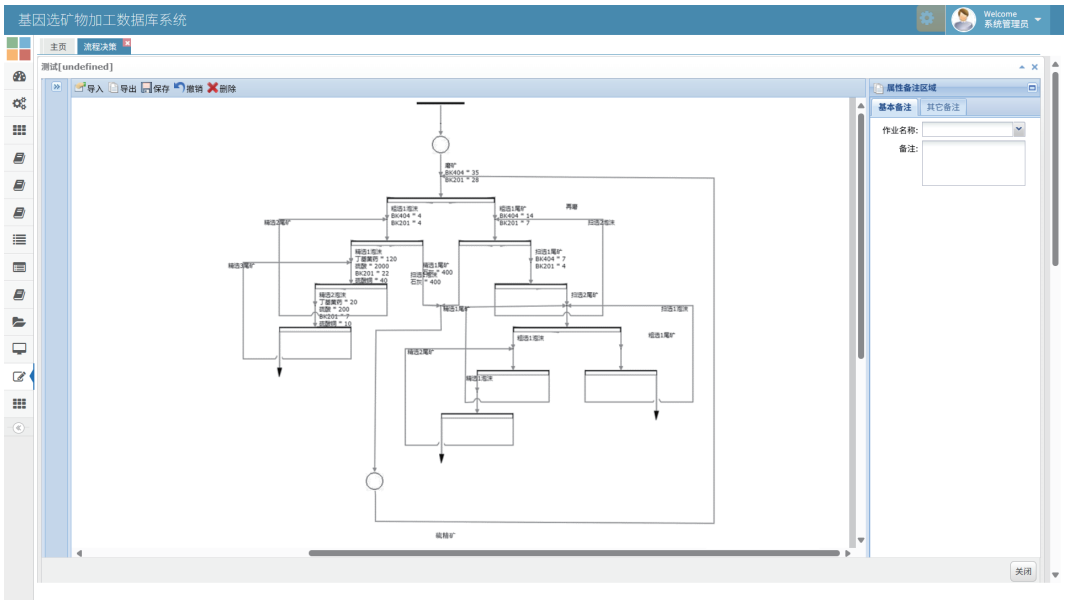


图 10 决策系统自动绘制的决策流程图

Fig. 10 Flowsheet generated by the decision-making system

表 6 基因选矿决策流程闭路试验结果

Table 6 Results of locked-cycle test for gene-based mineral processing decision-making flowsheet /%

产品名称	产率	品位			回收率		
		Cu	Au①	S	Cu	Au	S
铜精矿	2.01	19.18	67.98	25.08	92.54	60.87	5.16
硫精矿	19.45	0.083	3.87	46.54	3.88	33.53	92.70
尾矿	78.54	0.019	0.16	0.27	3.58	5.60	2.14
原矿	100.0	0.42	2.24	9.77	100.0	100.0	100.0

性,使用基因矿物加工决策技术智能设计的原则流程、磨矿制度和选别次数等选矿厂工艺流程关键参数总体与实际应用结果一致。

4 结论与展望

本文以基因矿物加工理论为指导,针对传统矿物加工工艺流程设计存在的经验依赖性强、开发周期长、知识传承效率低等瓶颈问题,以铜硫矿物浮选分离为例,通过多学科交叉与智能算法融合,构建了面向复杂矿石特性的智能决策系统,探索了矿物加工流程的精准化、智能化决策。

分别基于规则推理和案例推理算法开展了知识推理协同决策的研究,解决了传统经验知识碎片化、长期积累的丰富理论研究成果和大量试验案例数据无法有效利用和传承的难题,形成可继承的决策知识资产;构建基于XGBoost集成学习的机器学习决策框架,采用分段建模策略实现粗选/精选/扫选次数的多目标决策,验证了数据驱动模型在决策过程中的补充强化作用,挖掘了矿物加工过程中存在的无法量化描述的基因与可选性之间的潜在逻辑关系;构建“RBR-CBR-ML-LLM”四级决策链,形成动态特征交互机制,打破了知识推理和机器学习单一算法存在的局限性,解决了高维基因数据与稀疏经验知识的协同优化难题,决策时间相对传统人工设计显著缩短;

最后，利用10个历史案例数据对决策算法进行了整体的交叉验证，流程决策整体准确率超过80%。选取典型实际场景的数据开展了对比试验验证，初步验证了决策系统的功能和性能。

尽管在矿物加工智能决策方向上取得了一定突破，但仍存在局限：推理知识库对矿石种类的覆盖率不足(目前实例中局限于铜硫矿及其伴生矿)；机器学习模型对样本均衡性敏感，样本整体数量偏低，再磨制度预测偏差达15%左右；大模型的知识提取与蒸馏效率有待提升，领域专用预训练语料覆盖率低于60%。

后续研究将重点针对以下方向开展：构建跨矿种迁移学习框架，将研究扩展至铅锌矿、锂铍矿等战略资源领域；研发知识图谱的动态演化机制，实现工艺知识的自主更新与冲突消解；开发基于数字孪生的虚实交互系统，建立“决策-仿真-优化”闭环验证体系。未来将通过跨学科交叉与工程化实践，努力推动矿物加工开发向“数据驱动、知识赋能、智能决策”模式迈进。

参考文献

[1] 赵杰，李航谦，张博文，等. 矿物加工过程智能化的进展[J]. 生态产业科学与磷氟工程，2024，39(11)：75-80.
Zhao Jie，Li Hangqian，Zhang Bowen，et al. Progress in intelligent mineral processing[J]. Eco-industry Science & Phosphorus Fluorine Engineering，2024，39(11)：75-80.

[2] 孙传尧，周俊武，贾木欣，等. 基因矿物加工工程研究[J]. 有色金属(选矿部分)，2018(1)：1-7.
Sun Chuanyao，Zhou Junwu，Jia Muxin，et al. Research on genetic mineral processing engineering[J]. Nonferrous Metals (Mineral Processing Section)，2018(1)：1-7.

[3] Moore P，Pham H V. Intelligent context with decision support under uncertainty[C]//2012 Sixth International Conference on Complex，Intelligent，and Software Intensive Systems. Palermo，Italy，2012：977-982.

[4] Zheng Peng，Liu Dongliang，Guo Junke，et al. A new method for optimizing process parameters of active measurement grinding based on grey target decision making[J]. Proceedings of the Institution of Mechanical Engineers，Part C：Journal of Mechanical Engineering Science，2020，234(23)：4645-4658.

[5] Finnie G，Sun Zhaohao. R 5 model for case-based reasoning[J]. Knowledge-Based Systems，2003，16(1)：59-65.

[6] Sun Zhaohao，Finnie G. A unified logical model for CBR-based e-commerce systems[J]. International Journal of Intelligent Systems，2005，20(1)：29-46.

[7] Gomez-Flores A，Ilyas S，Heyes G W，et al. A critical review of artificial intelligence in mineral concentration[J]. Minerals Engineering，2022，189：107884. DOI：10.1016/j.mineng.2022.107884.

[8] Ai Mingxi，Xie Yongfang，Xie Shiwen，et al. Data-driven-based adaptive fuzzy neural network control for the antimony flotation plant[J]. Journal of the Franklin Institute，2019，356(12)：5944-5960.

[9] Ai Mingxi，Xie Yongfang，Tang Zhaohui，et al. Deep learning feature-based setpoint generation and optimal control for flotation processes[J]. Information Sciences，2021，578：644-658.

[10] Aldrich C，Avelar E，Liu Xiu. Recent advances in flotation froth image analysis[J]. Minerals Engineering，2022，188：107823. DOI：10.1016/j.mineng.2022.107823.

[11] Pan Jeff Z，Simon R，Jan-Christoph K，et al. Large language models and knowledge graphs：opportunities and challenges[J]. Transactions on Graph Data and Knowledge，2023，1(1)：1-38.

[12] Pan Shirui，Luo Linhao，Wang Yufei，et al. Unifying large language models and knowledge graphs：a roadmap[J]. IEEE Transactions on Knowledge and Data Engineering，2024，36(7)：3580-3599.

[13] Zhao Mingxiong，Wang Han，Guo Jin，et al. Construction of an industrial knowledge graph for unstructured Chinese text learning[J]. Applied Sciences，2019，9(13)：2720. DOI：10.3390/app9132720.

[14] Ko H，Witherell P，Lu Yan，et al. Machine learning and knowledge graph based design rule construction for additive manufacturing[J]. Additive Manufacturing，2021，37：101620. DOI：10.1016/j.addma.2020.101620.

[15] 于宏东，孙传尧. 不同成因黄铁矿的物性差异及浮游性研究[J]. 中国矿业大学学报，2010，39(5)：758-764.
Yu Hongdong，Sun Chuanyao. Study of divergences of floatability and physical property of pyrite from different geo-genetic deposits[J]. Journal of China University of Mining & Technology，2010，39(5)：758-764.

[16] 王海明，邢运涛，王瑞丰. 浅谈砂岩型矿矿床地质特征及其成因[J]. 能源与节能，2014(12)：110-111，167.
Wang Haiming，Xing Yuntao，Wang Ruifeng. On the geological characteristics and causes of formation of sandstone-type ore deposits[J]. Energy and Energy Conservation，2014(12)：110-111，167.

[17] 刘恩法，李书文，刘向阳. 砂岩型铜矿成矿机制分析[J]. 价值工程，2014，33(31)：317-318.
Liu Enfa，Li Shuwen，Liu Xiangyang. Analysis of

sandstone type copper mine metallogenic mechanism[J]. Value Engineering, 2014, 33(31): 317-318.

[18] 李德东, 王玉往, 龙灵利, 等. 中国岩浆型铜镍硫化物矿床类型浅谈[J]. 矿产勘查, 2014, 5(2): 124-130.
Li Dedong, Wang Yuwang, Long Lingli, et al. Discussion on the classification of magmatic type of copper-nickel sulfide deposits in China[J]. Mineral Exploration, 2014, 5(2): 124-130.

[19] 陈述文, 胡熙庚. 黄铁矿化学组成不均匀性与可浮性关系[J]. 湖南有色金属, 1991, 7(5): 278-283.
Chen Shuwen, Hu Xigeng. Relationship between chemical composition heterogeneity and floatability of pyrite[J]. Hunan Nonferrous Metals, 1991, 7(5): 278-283.

[20] 印万忠. 基于晶体化学的硫化铁矿物浮选特性研究[D]. 沈阳: 东北大学, 2015.
Yin Wanzhong. Study on flotation characteristics of iron sulfide minerals based on crystal chemistry[D]. Shenyang: Northeastern University, 2015.

[21] 洪秋阳, 汤玉和, 王毓华, 等. 磁黄铁矿结构性质与可浮性差异研究[J]. 金属矿山, 2011, 40(1): 64-67.
Hong Qiuyang, Tang Yuhe, Wang Yuhua, et al. Investigation on properties and structure of pyrrhotite and the difference of its floatability[J]. Metal Mine, 2011, 40(1): 64-67.

[22] 印万忠, 孙传尧. 硅酸盐矿物浮选原理的研究进展[C]//第四届全国矿山采选技术进展报告会. 张家界, 2001: 138-143.
Yin Wanzhong, Sun Chuanyao. Research progress on flotation principle of silicate minerals[C]//The 4th National Symposium on Mining and Mineral Processing Technology Progress. Zhangjiajie, 2001: 138-143.

[23] Wen Shuming, Deng Jiushuai, Xian Yongjun, et al. Theory analysis and vestigial information of surface relaxation of natural chalcopyrite mineral crystal[J]. Transactions of Nonferrous Metals Society of China, 2013, 23(3): 796-803.

[24] 胡岳华, 刘晓文, 邱冠周, 等. 一水硬铝石型铝土矿铝硅浮选分离溶液化学Ⅰ: 晶体结构与可浮性[J]. 矿冶工程, 2000, 20(2): 11-14.
Hu Yuehua, Liu Xiaowen, Qiu Guanzhou, et al. Solution chemistry of flotation separation of diaspore-type bauxite(I): crystal structure and floatability[J]. Mining and Metallurgical Engineering, 2000, 20(2): 11-14.

[25] 陈建华, 冯其明, 卢毅屏. 电化学调控浮选能带模型及应用(Ⅰ)①: 半导体能带理论及模型[J]. 中国有色金属学报, 2000, 10(2): 240-244.
Chen Jianhua, Feng Qiming, Lu Yiping. Energy band model of electrochemical flotation and its application (Ⅰ)①: theory and model of energy band of semiconductor solution interface[J]. The Chinese Journal of Nonferrous Metals, 2000, 10(2): 240-244.

[26] 瞿幼苗. 面向智能决策的推理引擎技术[D]. 西安: 西北工业大学, 2018.
Qu Youmiao. Key technologies of reasoning engine for intelligient decision[D]. Xi′an: Northwestern Polytechnical University, 2018.

(本文编辑 刘水红)

【缅怀寄语】

恩师孙传尧院士离开我们已整整一年。每当面对选矿智能模型,眼前不时会浮现先生伏案批注的身影,耳畔回响起他的叮嘱:“选矿人要读懂矿山的‘基因’。”这句话,已成为我科研生涯中不灭的精神坐标。

先生的嘱托,指向了他最重要的学术创见之——“基因矿物加工”。这一理念是对传统选矿范式的颠覆性创新,他始终坚信,选矿技术必须从矿石本质属性出发,只有破译每一座矿山独特的“基因密码”,才能找到最优工艺路径。正是追循先生对选矿本质非同一般的执着,我有幸参与基因矿物加工的研究,走上了传统选矿工艺与人工智能的深度融合之路。

先生以六十余年选矿经验与前沿技术融汇的前瞻思维,为我们打开了全新的学术视野。他总能从繁杂数据中一眼洞穿关键,用最朴素的物化原理解释最复杂的现象,令人豁然开朗。“做有用的研究,解决真问题”——这份求真务实的学风,连同他宽厚严正的为人品格,早已融入弟子们的科研底色。

先生将毕生心血倾注于选矿事业,足迹遍及祖国各大矿区,为我国矿产资源高效开发做出了不可磨灭的贡献。他倡导的“基因选矿、和谐选矿、绿色选矿”,以超越当下的学术远见,为行业发展标定了方向。本文正是沿着先生开拓的道路探索实践所得,也是对先生栽培之恩的深切回馈。

先生虽已远行,但他的学术基因早已植根于我们的血脉。我定当传承“从本质出发”的科学精神,继续深耕基因矿物加工领域,不负师门厚望,不负选矿事业。山高水长,先生千古,永怀感念。

——杨佳伟