



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：AI 赋能煤地质学

作者：代世峰，许娜，朱伟，李鹏飞，齐安良煜，刘宇，颜瑞雯，赵正福

DOI: 10.12090/j.issn.1006-6616.2026060

投稿时间：2026-05-21

录用时间：2026-09-04

预出版时间：2026-09-04

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。

AI 赋能煤地质学：进展、挑战与展望

代世峰, 许娜, 朱伟, 李鹏飞, 齐安良煜, 刘宇, 颜瑞雯, 赵正福

DAI Shifeng, XU Na, ZHU Wei, LI Pengfei, QI Anliangyu, LIU Yu, YAN Ruiwen, ZHAO Zhengfu

中国矿业大学（北京）地球科学与测绘工程学院, 北京, 100083

College of Geoscience and Survey Engineering, China University of Mining and Technology (Beijing), Beijing, 100083, China

Artificial Intelligence-Empowered Coal Geology: Advances, Challenges, and Prospects

Abstract: [Objective] The rapid development of artificial intelligence (AI) has reshaped the research paradigm of geosciences. Coal geology focuses on coal, coal seams, coal-bearing strata, coal basins, and coexisting and associated mineral resources in coal-bearing strata. These research objects exhibit highly complex material compositions, multiscale characteristics, and pronounced spatiotemporal variability. Consequently, the major research directions of coal geology, including coal petrology, coal quality evaluation, critical metals in coal-bearing strata, and coalbed methane exploration and development, are particularly well suited to AI-based approaches. [Methods] AI is driving coal geology beyond traditional experience-based identification and local statistical analysis toward a new paradigm integrating multi-source data fusion, intelligent prediction, and mechanistic interpretation. It also provides new opportunities for discovering previously unrecognized geological phenomena. [Results] This paper systematically reviews recent advances in the application of AI to the intelligent identification of coal macerals, intelligent prediction of coal quality, intelligent assessment of the occurrence modes and resource potential of critical metals in coal, and coalbed methane prediction. AI technologies have significantly improved the efficiency and accuracy of maceral image recognition, coal quality parameter prediction, identification of occurrence patterns of critical metals in coal, and comprehensive resource evaluation. However, several challenges remain, including the scarcity of high-quality datasets, limited cross-regional generalization capability, weak model interpretability, insufficient consistency with geological mechanisms, inadequate knowledge constraints, and limited implementation in engineering scenarios. [Conclusions] Future research should strengthen the construction of standardized large-scale databases, promote the deep integration of geological knowledge with data-driven models, develop interpretable and transferable intelligent models, and establish an intelligent research paradigm oriented toward major scientific questions in coal geology and the green and efficient development of critical mineral resources. [Significance] This review highlights the transformative role of AI in advancing coal geology from experience-driven analysis toward knowledge-guided intelligent research, providing methodological support for major scientific discovery and the green, efficient development of coal-related resources.

基金项目: 国家自然科学基金项目 (42372191, 42321002, 42472230)

This research was supported by the National Natural Science Foundation of China (Grants Nos. 42372191, 42321002, 42472230).

第一作者: 代世峰 (1970—), 男, 博士, 教授, 中国科学院院士, 主要从事煤地质学、地球化学和煤系关键金属矿产的科学研究。

Email: dsf@cumtb.edu.cn

通信作者: 许娜 (1982—), 女, 博士, 教授, 主要从事人工智能与地球科学研究。Email: xuna@cumtb.edu.cn

Keywords: artificial intelligence; coal geology; coal maceral; coal quality evaluation; coal-hosted critical metals; coalbed methane

摘要: 人工智能的快速发展正在改变地球科学的研究范式。煤地质学研究对象是煤、煤层、含煤岩系、煤盆地以及煤共伴生矿产,它们物质组成极其复杂,具有强非均质、多尺度性和显著时空变异性。煤地质学研究的主要方向(如煤岩学、煤质学、煤系关键金属及煤层气勘探开发)与人工智能方法高度契合,人工智能正在推动煤地质学由传统经验识别和局部统计分析,向多源数据融合、智能预测、机理解释并重的新范式转变,并且为发现新的地质现象提供了可能。文章系统综述了人工智能在煤显微组分智能识别、煤炭质量智能预测、煤系关键金属赋存状态与资源潜力智能评价、煤层气智能勘探开发等研究中的进展。人工智能技术对提升显微组分图像识别、煤质参数预测、煤系关键金属赋存模式发现和综合评价、煤层气甜点区评价与产能预测的效率与精度等方面具有重要作用,同时也面临高质量数据集不足、跨区域泛化能力有限、模型解释性与地质机理契合性弱、知识约束不够以及工程场景落地不足等问题。未来应加强煤地质学标准化大数据库建设,推动煤地质学知识与数据驱动模型深度融合,发展煤地质学可解释、可迁移的智能模型,构建面向煤地质学重大科学问题与关键矿产资源绿色高效开发的智能研究范式。

关键词: 人工智能; 煤地质学; 显微组分; 煤炭质量评价; 煤系关键金属; 煤层气
中图分类号: P618.11; TP18; P595; **文献标识码:** A **文章编号:** 1006-6616 (2026) 05-0000-00
DOI: 10.12090/j.issn.1006-6616.2026060

0 引言

人工智能(Artificial Intelligence, AI)为改变地球科学研究范式提供了重要工具,其推动地球科学走向数据密集、模型驱动和多学科融合发展方向。AI能够从海量、多源、异构的地质数据中识别出隐藏的规律,帮助揭示复杂地质过程中的非线性关系和时空演化特征,增强地球科学理论解释、资源环境评价、过程模拟和趋势预测能力。

煤地质学是地质学中形成较早的分支学科(杨起和韩德馨, 1979; 韩德馨和杨起, 1980)。它是以地质学理论为基础,研究煤、煤层、含煤岩系、煤盆地以及煤共伴生矿产的物质成分、成因、性质及其分布规律,并依据煤地质学研究对象所记载的地质历史记录,研究地球的结构、物质组成、地球环境演化的学科,具有基础研究与应用研究的双重属性。煤地质学与构造地质学、沉积学、地球物理学、地球化学、矿床学、石油地质学、地层学和古生物学等学科密切相关(Taylor et al., 1998; Thomas, 2002; Hatherly, 2013)。煤地质学包含多个分支学科或交叉学科,如煤岩学(“煤的岩石学”简称)、煤地球化学、煤系关键金属矿产、煤层气(瓦斯)地质学、煤的矿物学、矿井地质学、煤盆地分析、与煤炭安全生产相关地质问题等。煤地质学的各个分支学科既相对独立,又紧密联系,各个分支学科是在密切结合、相互促进、相互渗透的关系中共同发展的,并且衍生出了其他新生的分支学科(例如有机岩石学)。

20世纪初期,显微镜技术在煤炭研究中的广泛应用标志着煤地质学的分支学科煤岩学的建立。1927年,斯塔赫发表了第一张油浸反射光条件下煤的显微组分照片(Stach, 1927; Stach et al., 1975); 1953年,国际煤岩学和有机岩石学委员会(ICCP)建立,1984年国际有机岩石学会(TSOP)成立,这2个国际学术组织的成立是煤地质学发展史上的重要事件。随后,德国、澳大利亚和美国相继开展了大量的聚煤盆地演化,煤的形成,显微组分分类、形成和命名,煤的地球化学和煤矿物学等研究工作(Lin et al., 1986; Diessel, 1992)。20世纪50年代至21世纪初,美国、英国、俄罗斯、澳大利亚和中国等国学者开展的煤地质学等方面的卓有成效的研究(Hutton, 1980; Moore, 1992; Finkelman, 1994),极大地发展了煤岩学,并奠定了煤地球化学、煤矿物学等分支的理论基础。随着对清洁能源需求的逐步提升,美国、澳大利亚和中国等国的科学家开展了煤层气成藏机理、分布规律和开发利用的研究(Karacan et al., 2011; Moore, 2012; 秦勇等, 2013),20世纪80年代初,美国开始试验应用地面钻井开采煤层气并获得突破性进展。目前,煤中战略性关键金属成矿理论和勘探技术,以及深部煤层气成藏和开发已经成为煤地质学研究的前沿(Seredin and

Dai, 2012; 代世峰, 2025; Liu et al., 2026)。

煤地质学家们的长期研究, 积累了大量多尺度、多类型数据, 包括但不限于: 工业分析与元素分析、元素地球化学、显微组分图像、矿物学、煤层气地质学、地球物理勘探等。煤及含煤地层具有强非均质性, 煤的物质组成及其成因极其复杂(韩德馨, 1996; Ward, 2002; 任德贻等, 2006), 并具有明显的区域差异, 使得传统基于经验、线性统计或单一指标的研究方法, 在处理这些高维复杂问题时面临明显局限。因此, 煤地质学成为人工智能方法适宜应用的重要领域之一。已有的研究表明, 人工智能能够在煤的显微组分识别、煤质指标预测、关键金属赋存状态推断和煤层气产量预测等方面显著提升研究效率与精度; 另一方面, 人工智能也为从复杂数据中发现新的地质现象, 为揭示泥炭沉积、煤化作用、共伴生矿产成矿/成藏、资源预测提供了新的研究范式。

文章围绕煤地质学中若干具有代表性的研究方向, 系统梳理了人工智能的应用进展, 如显微组分识别、煤炭质量评价、煤系关键金属赋存状态与资源潜力评价、煤层气预测和评价等, 并在此基础上, 进一步讨论当前研究存在的困难和问题, 提出可能的解决方案以及未来重点研究方向。

1 人工智能赋能煤地质学的研究进展

1.1 显微组分的人工智能识别及应用

显微组分的识别和定量统计是煤岩学研究的基础, 也是煤炭分类、煤阶判别、煤炭利用评价以及煤中元素赋存状态研究的重要物质基础。长期以来, 煤中显微组分的识别主要依赖反射光、透射光和荧光显微镜观察, 并以点计数法作为定量分析的基本手段(Glagolew, 1934; Teichmüller, 1974; Ting, 1978; Crelling, 1983; Crelling and Bensley, 1984; Taylor et al., 1998)。这一方法体系在煤岩学研究中具有标准意义, 但也存在明显局限, 即显微组分的识别对观察者的经验依赖性强, 且工作量大, 在大样本和高通量分析中效率明显不足。人工智能逐步被引入煤的显微组分研究, 并推动该领域由传统图像分析向机器学习、再向深度学习语义分割不断发展。

煤的显微组分智能识别大致经历了3个阶段。第一阶段是基于颜色、灰度、形状和纹理等特征的图像分析, 通过自动图像处理减少人工判读负担从而提高效率(Unsworth and Gough, 1989; Lester et al., 2002; O'Brien et al., 2003, 2007)。第二阶段是以传统机器学习为手段, 研究者将K近邻、支持向量机、随机森林(Random Forest, RF)、模糊聚类和人工神经网络(Artificial Neural Network, ANN)等方法引入显微组分图像识别, 实现镜质体、惰质体、类脂体及部分矿物组分的自动识别, 并进一步拓展到镜质体反射率测定等任务(Mlynarczuk and Skiba, 2017; Liu et al., 2019; Wang et al., 2019a, 2019b; Tiwary et al., 2020; Alpana et al., 2021; Onifade et al., 2021)。第三阶段是以U-Net、SegNet、DeepLab和Mask R-CNN等为代表的深度学习阶段, 将某个单组分的识别扩展到对整幅图像进行像素级分割, 并进一步发展到对颗粒形态、粒度、解离特征、反射率及其与密度分选关系的多参数协同表征(Iwaszenko and Rog, 2021; Lei et al., 2021; Santos et al., 2022; Wang et al., 2022; Fan et al., 2023)。煤的显微组分智能识别发展主要技术路径见图1展示。

需要指出的是, 由于煤的显微组分光学特征受煤阶、成因、光照条件和成像模式的影响, 不同煤阶下同一显微组分的反射色、边界特征和荧光响应都可能明显不同。因此, 显微组分识别并不是一个简单的通用图像分割问题。例如, 低阶煤中腐植体通常呈深灰色, 而中、高阶煤中的镜质体则多表现为浅灰至白色; 类脂体与镜质体在高阶煤中甚至可能出现反射色关系的反转(O'Keefe et al., 2013)。这种受煤阶控制的光学差异, 使得模型很难像自然图像识别那样依靠单一表观特征稳定泛化。与此同时, 微粒体、碎屑镜质体和薄壁角质体等细粒、狭长、边界不规则目标在样品中含量低, 同时又易受矿物杂质和图像噪声干扰, 因此是智能识别中的难点(Xu et al., 2025a, 2026a)。

因此, 人工智能对显微组分的识别, 不仅要实现更高的准确度, 而且要推动模型向更强的地质适应性、便捷性和应用性发展, 主要包括3个重要方面: ①建立高质量、标准化、跨煤阶的显微组分图像数据库,

并在样品制备、成像条件和标注方法等方面进行标准化或规范化；②建立并发展半监督、自监督和知识约束模型，以缓解高质量人工标注数量不足的问题；③将显微组分识别与煤阶参数、矿物组成、元素含量与赋存，以及煤的工艺性质等联系起来。实现人工智能对显微组分的识别，不仅能够减轻人工判别负担，提高分析效率和一致性，而且可以帮助推动显微组分的定性和定量研究，从经验识别走向可重复、可量化、可扩展、可应用的智能化研究范式。




图 1 煤显微组分智能识别发展主要技术路径
Fig.1 Development of Coal Maceral Identification by AI

1.2 基于机器学习与可解释性的煤炭质量评价

煤炭质量直接关系到煤炭资源的利用和加工，是煤炭科学与工程应用中最具现实意义的研究方向之一（Shirazi et al., 1995; Ward, 2016; Finkelman et al., 2019; Dai et al., 2021; Hower et al., 2022）。随着工业分析、元素分析、煤岩学、矿物学和地球化学数据的不断积累，人工智能已被用于煤炭质量评价和预测，例如高位发热量（Higher Heating Value，HHV）和哈氏可磨系数（Hardgrove Grindability Index，HGI）等关键煤质指标。煤质评价研究也从传统经验公式和回归分析，逐步转向多源数据驱动发展，形成支撑高精度预测、可解释分析和工程决策的新范式（Vuthaluru et al., 2003; Jorjani et al., 2008; Akkaya, 2013; Tan et al., 2015; Matin and Chelgani, 2016; Matin et al., 2016; Hower et al., 2021; Richards et al., 2021; Hower et al., 2022; Xu et al., 2023a; García-Nieto et al., 2024; Sharma Timilsina et al., 2024; Zhu et al., 2025a; Meng et al., 2026）。

就 HHV 而言，其传统测定依赖氧弹量热计，该方法准确可靠，但存在测试周期长、实验条件要求高、设备维护复杂和结果获取滞后等不足，因此开发其快速预测方法是煤质评价的重要内容之一（Mason and Gandhi, 1983; Richards et al., 2021）。早期研究主要基于工业分析或元素分析建立经验公式和回归模型，这类方法结构简单、便于使用，但存在适用范围窄、对煤样品来源的差异较为敏感、难以刻画复杂的非线性关系等问题（Steuer, 1926; Mott and Spooner, 1940; Mason and Gandhi, 1983; Parikh et al., 2005）。随着机器学习的发展，人工神经网络、支持向量回归（Support Vector Regression，SVR）、随机森林、梯度提升回归树等方法被广泛用于 HHV 预测，其输入特征也由单一工业分析逐步扩展到工业

分析、元素分析乃至矿物学和氧化物含量的联合建模（Akkaya, 2013; Tan et al., 2015; Matin and Chelgani, 2016; Xu et al., 2023a; García-Nieto et al., 2024; Sharma Timilsina et al., 2024）。总体上看，这些方法对不同地区和不同煤阶的样品预测 HHV 中的泛化能力验证方面已具备较好基础，但模型外推能力和解释稳定性仍需要进一步检验（Pes, 2020; Xu et al., 2023a; García-Nieto et al., 2024; Sharma Timilsina et al., 2024）。

与 HHV 相比，HGI 的预测更加复杂。HGI 不仅反映煤体破碎难易程度，而且与磨煤能耗、制粉效率和锅炉运行稳定性密切相关，因此在火电系统和配煤工艺中具有重要工程意义（Vuthaluru et al., 2003; Hower et al., 2021）。HGI 受煤阶、显微组分组合、矿物组成、含水状态及配煤工况等多因素共同控制，变量之间存在明显的非线性关系。早期 HGI 研究多采用经验关系或多元回归模型进行快速估计，这类模型结构清晰、计算成本低，但在煤样非均质性较强或跨矿区应用时往往表现出稳定性不足（Vuthaluru et al., 2003; Chelgani et al., 2008; Jorjani et al., 2008; Matin et al., 2016; Hower et al., 2021）。随着人工神经网络、支持向量回归、随机森林、自适应神经模糊推理系统（Adaptive Neuro-Fuzzy Inference System, ANFIS）乃至长短期记忆网络（Long Short-Term Memory, LSTM）等模型的引入，这些方法对非线性关系和时变工况的刻画能力显著增强（Chelgani et al., 2008; Venkoba and Gopalakrishna, 2009; Chelgani et al., 2011; Matin et al., 2016; Lawal et al., 2025）。但从目前研究现状看，HGI 预测的挑战是所建立的模型能否跨区域、跨煤种、跨工况稳定应用。特别是在混煤、水分变化和现场动态工况条件下，单一来源样本训练得到的模型往往难以直接迁移到实际生产系统（Vuthaluru et al., 2003; Pes, 2020; Hower et al., 2021; Lawal et al., 2025）。

为更清楚地比较不同人工智能方法在煤质评价中的应用，对 HHV 和 HGI 预测研究中的代表性工作进行了归纳，见表 1。

表 1 人工智能方法在 HHV 和 HGI 预测中的代表性应用

Table 1 Representative applications of AI methods in HHV and HGI prediction

预测指标	输入变量	人工智能方法	预测效果	代表性文献
HHV	工业分析指标：水分、灰分、挥发分、固定碳	SVR	测试集平均绝对误差为 2.95%（中国煤样）和 2.43%（美国煤样）；相关系数 r 分别为 0.978 和 0.994。	Tan et al., 2015
HHV	工业分析指标：水分、标准灰分、挥发分、固定碳	GBRT、MLR、SVR、GPR、ANN	测试集 R^2 为 0.9862（COALQUAL）和 0.9541（Kentucky）；MAE 为 0.462 和 0.519 MJ/kg；MAPE 均为 0.019。	Xu et al., 2023a
HHV	元素分析指标：C、H、O、N、S	GS/MARS、MLP、MLR	GS/MARS 测试集 $R^2=0.9921$ 、 $r=0.9960$ 、RMSE=0.1626，优于 MLP（ $R^2=0.9345$ ）和 MLR（ $R^2=0.8683$ ）。	Garcia-Nieto et al., 2024
HGI	工业分析、元素分析、氧化物和煤岩参数	RF	$R^2=0.90$ ；99%样品预测误差<4 个 HGI 单位，60%样品预测误差<2 个 HGI 单位；MSE=3.54。	Matin et al., 2016
HGI	发热量、工业分析指标（水分、灰分、挥发分、固定碳）、全硫和黄铁矿含量。	ANN、SVR、LSTM	ANN 模型 $R^2>0.9$ ，整体表现为 ANN 最高、SVR 次之、LSTM 最低。	Lawal et al., 2025

HHV 和 HGI 研究虽然对象不同,但面临的共性问题是一致的,即煤质评价不仅是建立高精度模型,而且需要进行机理揭示(Jorjani et al., 2008; Matin et al., 2016; Ward, 2016; Finkelman et al., 2019; Wood, 2019; Barredo Arrieta et al., 2020; Hower et al., 2021, 2022; Wen et al., 2023b)。长期以来,Dulong 公式、Steuer 公式等经验方法之所以仍具有生命力,并不只是因为其简单,而在于其结果具有明确物理含义,便于理解和工程接受(Steuer, 1926; Mott and Spooner, 1940; Mason and Gandhi, 1983)。相比之下,机器学习模型虽然在不少研究中获得了更高的预测精度,却也带来了典型的“黑箱效应”,也就是模型给出了结果,却难以说明哪些因素起主导作用、不同因素如何共同影响输出、这种影响是否符合煤岩学和煤化学理论常识(Wood, 2019; Barredo Arrieta et al., 2020; Wen et al., 2023b)。对于煤炭质量评价而言,这不仅关系到模型的可用性,还关系到模型能否反过来促进对煤质形成机制和工艺行为的认识。

正因如此,AI 赋能的煤质评价研究正在由高精度预测向高精度、强解释、可决策相融合的模式转变。近年来,可解释人工智能(eXplainable Artificial Intelligence, XAI)方法开始进入该领域,SHAP、特征重要性分析、透明开箱模型以及可审计的混合模型被用于解释发热量、可磨性、灰分等煤质指标的预测结果(Matın et al., 2016; Wood, 2019; Barredo Arrieta et al., 2020; Wang and Lin, 2021; Wen et al., 2023b; Sharma Timilsina et al., 2024)。其核心意义在于:不仅给出数值预测,而且尽可能揭示变量贡献方向、作用强度及其与领域知识的一致性。同时,煤质评价中的解释不能停留在单次结果展示,还应关注解释的稳定性,即不同数据划分、不同模型结构和不同样本区域下,重要特征排序是否一致,模型结论是否具备可复现性(Pes, 2020)。因此,未来煤质模型评价,不应仅比较预测误差,还应考察哪个模型既能获得较高精度,又能提供与煤地质学和工程机理一致的解釋证据链。

AI 赋能的煤质评价的下一步发展应围绕 3 个方向展开:①进一步加强多源特征融合,在工业分析和元素分析基础上,逐步引入煤岩学、矿物学和工况参数,构建更具地质学约束和工程意义的特征体系(Chelgani et al., 2008; Jorjani et al., 2008; Ward, 2016; Finkelman et al., 2019; Hower et al., 2021);②从单纯性能优化转向“预测—解释”一体化,推动透明模型、混合模型和 XAI 框架在煤质预测中的常态化应用(Wood, 2019; Barredo Arrieta et al., 2020; Wang and Lin, 2021);③强化模型的跨区域、跨煤种和跨工况验证,避免只在局部数据集上获得高精度而低通用性的结果(Pes, 2020; Sharma Timilsina et al., 2024; Lawal et al., 2025)。总之,AI 赋能煤炭质量评价研究,不只是用机器学习替代经验公式,而是建立面向资源评价、工艺优化和工业决策的智能煤质分析体系(Barredo Arrieta et al., 2020; Wang and Lin, 2021; Hower et al., 2022; Wen et al., 2023b)。

1.3 人工智能在煤系关键金属研究中的应用

煤系关键金属研究要回答的问题包括元素来源、赋存状态、时空分布规律、资源潜力以及提取开发技术。人工智能方法使得从具有高维、强耦合性质的地球化学数据中识别元素异常组合、推断元素赋存状态、补全历史缺失数据成为可能,也使煤系关键金属赋存状态和经济评价研究从传统描述性统计逐步向可预测的定量化分析发展。

在基于人工智能的煤系关键金属应用研究中,元素赋存状态识别和推断是其解决的基础科学问题之一。传统的微区分析技术设备(例如透射电镜、配备能谱仪和/或波谱仪扫描电和电子探针、配激光烧蚀的电感耦合等离子体质谱仪)能够为关键金属可能的赋存状态提供直接证据,但煤有机质基质复杂、样品非均质性强、微区分析的代表性有限,且以 Li 为代表的低原子序数元素有时难以实现可靠检出和定量,因此仅靠直接测试有时很难全面揭示关键金属在煤中的真实赋存状态和规律(Finkelman et al., 2019; Dai et al., 2020, 2021; Zhu et al., 2026)。正因如此,相关分析、层次聚类等统计方法长期被用于从批量地球化学数据中推断元素与矿物以及有机质(显微组分)之间的关系(Eminagaoglu et al., 2022; Xu et al., 2022, 2023b; Yesenchak et al., 2022)。但是,基于整个煤层或整个矿区尺度的平均数据的传统统计方法,虽然可进行煤系关键金属赋存状态的静态识别,却难以判定赋存状态变化的控制因素及其变化的临

界阈值，也往往难以捕捉更小尺度赋存差异（例如煤分层），甚至可能出现与地球化学原理不一致的“异常聚类”或“异常相关”。

以自组织映射神经网络（Self-organizing map, SOM）为代表的无监督学习模型，能够将高维元素数据映射为低维拓扑结构，从而更直观地揭示元素组合关系和常规方法不能揭示的赋存状态。在此基础上，增量相关分析、基于同一煤层多分层样品约束的增样策略以及滑动窗口分析等方法，不仅可用于预测和判识元素的赋存状态，还可进一步解析不同物质来源对元素赋存状态的相对贡献，并识别元素在矿物尺度（如黄铁矿）和煤层内部的垂向变化规律。（Xu et al., 2023c; Zhu et al., 2026）。因此，AI 的特点是在更复杂的数据结构下，帮助研究者更好地揭示赋存状态变化及其控制因素。

同时，大量的历史样品中部分元素数据缺失、样本保存条件有限以及较高的重测成本，制约了人工智能在煤系关键金属研究中的广泛应用。机器学习方法可用于填补历史数据缺口，辅助预测缺失元素含量、配分模式及推断元素赋存状态，进而有助于进行大尺度（如全国或跨盆地）的资源潜力分析（Chatterjee et al., 2022; Xu et al., 2025b, 2026b; Zhu et al., 2025b）。同时，煤系关键金属的开发潜力也不同于传统矿床，除了关键金属在煤中的品位、赋存状态和储量等因素外，从粉煤灰等燃煤产物中回收是其重要开发路径之一。因此，原煤-燃烧产物转化过程中元素含量、赋存状态、载体矿物和可浸出性的变化，将直接影响开发效率和经济性，也应成为未来资源经济评价的重要参数（Seredin and Dai, 2012; Taggart et al., 2016; Liu et al., 2025b）。

AI 赋能煤系关键金属研究在赋存状态识别和预测、元素异常组合挖掘和赋存状态的空间差异、资源前景预测和开发潜力评价等方面可发挥重要作用。未来研究应重点加强多源异构数据融合，扩大样本在时空上的覆盖范围，并将地质成因、矿物学、煤岩学与工业价值评价纳入统一框架，让 AI 真正做到从地球化学识别走向资源开发的完整链条。在方法上，可借鉴跨域数据融合研究中的两类思路（Zheng, 2015）：其一是阶段式融合，不同数据不必强行在同一特征表中拼接，而是在历史含量数据补全、赋存状态推断、燃烧产物中元素迁移/富集、提取效率与经济性评价等不同环节分别发挥作用，使元素地球化学、煤岩学、煤的矿物学、提取技术的实验数据形成连续证据链；其二是语义约束的多视图或概率图模型融合，将元素地球化学、矿物组成、显微组分、层位/沉积环境、粉煤灰物性和浸出实验分别作为具有明确地质意义的“视图”或节点，通过多视图学习、多核学习、贝叶斯网络等方法学习各数据源之间的互补关系和依赖关系，最终形成跨领域的可解释的综合评价与决策框架。

1.4 基于人工智能的煤层气应用研究

煤层气勘探开发具有典型的地质-工程耦合特征，涉及储层表征、含气量测试、产量预测、排采优化、风险预警和智能决策等多个环节。与显微组分和煤质评价相比，煤层气研究的数据类型更复杂，既包含测井、地质和储层参数，又包含动态生产数据和工程控制参数，因此适合人工智能处理高维、异构、时序和强非线性问题的特质。正因如此，煤层气也是 AI 在能源地质领域最具工程应用前景的方向之一。

从应用层面看，人工智能已较系统地覆盖煤层气勘探与开发全过程。在勘探评价阶段，ANN 等模型通过综合分析煤层厚度、埋深、瓦斯含量、煤阶、构造条件及顶板封盖能力等信息，识别有利区，并对其开发潜力进行分级评价（Mondal et al., 2024）。在储层参数和含气量预测方面，机器学习结合测井曲线、煤层性质和异常值剔除策略，与传统回归方法相比，能更有效地建立含气量与多参数之间的非线性关系（Guo, 2023; Zhang et al., 2025a）。在生产预测方面，随机森林、深度神经网络、卷积神经网络-双向长短期记忆网络模型（CNN-BiLSTM）、多头注意力模型以及 LSTM 与递减曲线分析的混合模型，被广泛用于单井和井组产量预测，显著提升了对复杂时间序列和气水两相流动态变化的刻画能力（Guo et al., 2021; Zhu et al., 2022; Li et al., 2024; 宋洪庆等, 2024; Wei et al., 2024; Zhang et al., 2025b）。在排采优化和智能管理方面，深度强化学习、遗传算法、粒子群优化及集地质与工程一体化的数字平台等技术，已开始用于排采路径优化、压裂参数调整、甜点区评价和实时预警。AI 在煤层气领域的应用已逐步覆盖勘探开发全过程（Wang et al., 2023; Wen et al., 2023a; Liu et al., 2025a）。

然而，AI 应用于煤层气研究存在从算法向工程实际落地的困难。现有研究虽然在局部区块和特定井组中取得了较好效果，但仍普遍存在通用性不足、依赖模拟数据或小型专有数据集、缺乏统一性能评价标准

以及与地质统计学和实际工程流程结合不够紧密等问题。尤其在中国煤层气智能化开发中，多源异构数据融合困难、复杂地质条件下模型泛化能力差以及跨学科人才匮乏，仍是制约其实际应用的关键瓶颈。当前，AI 应用于煤层气的研究，最大的挑战是所建立的模型能否稳定进入实际生产系统。

因此，煤层气领域未来的发展方向是数据、模型和工程的闭环融合。为了实现这一目标，需要建设更大范围、更高质量、更标准化的数据共享平台，提升模型训练和外部验证的基础条件；同时，应推动深度学习与地质模型、物理模型和工程控制模型的耦合，使预测结果既能反映数据规律，又具备地质与工程机理约束。将来，AI 在煤层气领域的应用目标不仅包括自动化辅助分析，而且应逐步面向实际生产的自主感知、系统评价、动态优化和智慧排采体系的研发，只有如此，人工智能才可能真正改变煤层气勘探与开发方式。

2 研究局限性、面临的问题与未来发展方向

2.1 数据基础薄弱与标准化不足

尽管人工智能已在煤的显微组分识别、煤质评价、煤系关键金属赋存和资源评价、煤层气勘探和开发等方面取得了一定进展，仍存在诸多问题需要解决：①煤地质学领域的数据库基础仍较薄弱，呈现小样本、高维度、强异质性和共享程度低等特征；②煤地质学数据来源分散、专有数据多而共享数据少、测试和评价标准不统一等问题。受上述两方面因素制约，不少研究仍依赖模拟数据或小型专有数据集，从而限制了模型的可比性、可复现性及推广应用。

以显微组分图像为例，其标注高度依赖煤岩学专家经验，获取成本高；同时，不同实验室在样品制备、显微镜的光学参数、显微组分命名标准或习惯等方面存在差异，进一步增加了数据整合难度。当前，显微组分智能识别还有高质量标注数据集稀缺、类别分布不均衡，以及对微粒体、薄壁角质体、小孢子体以及碎屑体等细小复杂目标识别能力不足等问题。在 HHV、HGI 等煤质预测中，不同矿区煤样在煤阶、矿物组成、地质背景及配煤工况等方面的差异，也会显著影响模型训练效果及其适用边界。

2.2 复杂成煤过程、模型可解释性不足与泛化困难

与遥感地质学、金属矿床学和地球物理学等其他地球科学分支学科相比，煤地质学研究对象具有更强的成分异质性和更显著的多阶段复杂地质过程控制特征。煤并非单纯的有机质沉积产物，而是在特定沉积环境中经历有机质富集、埋藏、压实、成岩、变质及后期改造等多阶段演化形成的复杂地质体，其物质组成不仅受到同生阶段蚀源区和火山活动等因素的影响，且在成煤全过程的不同阶段还可能叠加热液流体活动等因素的影响。

煤的显微组分、矿物组成、煤阶、元素含量与赋存状态之间，以及这些参数与煤炭工艺性质之间，通常不是简单的线性对应关系，而是多种地质作用共同控制的结果。若仅依赖数据相关性或黑箱模型进行拟合，而忽略煤形成与演化过程中的复杂地质作用，则可能只能获得表面相关性，而难以揭示其内在成因机制，产生可解释性不足和模型泛化困难，甚至产生与煤地质学基本原理不一致的结果，进而削弱模型的跨区域、跨煤种迁移能力。

因此，AI 与煤地质学交叉融合的问题，本质上是地质过程、物质组成、AI 预测与解释的耦合关系，以及耦合关系的表征及其机理的问题，是所建立的模型可信性、可用性和科学性的问题。如果 AI 赋能的煤地质学不能实现对结果给出的合理解释，人工智能便难以真正推动煤地质学的理论创新。

2.3 从实验室模型到工程落地的困难

现在很多 AI 赋能煤地质学的研究仍停留在离线样本、静态数据和单任务建模层面，而煤地质学的实际应用场景往往具有非均质的动态变化、噪声来源多样、运行工况复杂（如电厂的燃烧条件）等特点，导致实验室高精度模型向实际生产中的有效且稳定的工具转化困难。例如，在煤质评价和煤系关键金属研究和应用中，实验室条件下建立的 AI 模型未必能够直接适用于选煤、配煤或电厂在线控制；煤系关键金属的赋存状态识别和资源潜力评价模型若不能进一步与关键金属的分选、提取、利用和经济评价衔接，则难以真正转化为可实施的资源开发方案。因此，未来 AI 赋能煤地质学的关键不仅要构建高精度模型，而且要形成数据采集、模型训练、

地质解释、工程应用和反馈的闭环，并不断修正和完善模型。

2.4 未来发展方向与可能突破路径

未来 AI 赋能煤地质学的突破应建立在数据质量可评价、误差可量化、来源可追溯和结果可验证的基础上。既要借鉴其他学科建设数据库和基准测试集的经验，依托显微组分、化学组成和矿物组成等测试标准，建立覆盖不同空间尺度、不同成煤时代和不同煤阶的标准化煤地质学数据库，也应重视对来源复杂、质量不一和部分信息缺失的历史数据进行分级利用。对于显微组分图像，应统一制样流程和光学成像参数、规范标注方法与术语体系；对于煤质参数、元素含量和矿物组成等数据，应完整记录测试方法、测试条件、检出限、精密度及数据来源。通过异常检测、交叉验证、数据修复、可信度分级和不确定性分析等方法，对数据进行筛选、校正和质量控制，剔除或降低错误数据和噪声数据的影响。在此基础上，可进一步引入半监督学习、自监督学习、迁移学习和主动学习等方法，充分挖掘不同质量等级数据的潜在价值，缓解高质量标注样本不足的问题，并提高模型的泛化能力和可靠性。

同时，AI 赋能的煤地质学，不应被理解为单纯的数据驱动拟合，应特别强调地质知识约束人工智能的理念。煤地质学特别强调煤阶属性、煤质特征、显微组分及其组合、矿物种类及其关系、元素地球化学性质以及影响它们的各种地质因素，这些不仅要作为结果讨论和机理解释的依据，而且要应尽可能嵌入 AI 赋能的模型构建过程，该理念对 AI 和煤地质学双向赋能具有重要意义。例如，在煤系关键金属研究中，可将矿物以及关键金属富集和赋存状态的影响因素（如火山灰输入和热液改造）作为指示因子引入模型约束，构建深度学习与物理模型耦合的智能决策体系。

AI 赋能煤地质学的可解释性、稳健性与不确定性分析，与 AI 建模的预测精度同等重要。未来模型评价不仅要提高预测准确率，而且要回答模型主要依据哪些地质因素做出判断、这些判断在不同地区或不同地质背景下是否稳定、从模型中得出的结论是否与煤地质学理论认识相一致等问题。只有把预测结果、解释的证据和不确定性的边界同时纳入研究框架，人工智能才可能真正成为煤地质学中可验证和可迁移的可靠工具。

从学科发展角度看，AI 赋能煤地质学的重要突破也依赖于跨学科协同。煤地质学不是地球科学的孤岛，未来需要不同学科的研究人员共同参与。借鉴其他学科的思路和研究技术与方法，不仅可以让自身得以实质性发展，也可为 AI 的研发提供更多的素材，实现 AI 和煤地质学的双向赋能。同时，煤地质学是一门强调地质背景、样品代表性和成因解释的学科，因此其 AI 赋能不能简单地认为数据越多越大越好、模型越深越好，而应坚持以地学领域的科学问题为核心、以多源证据链为基础、以解释和应用为导向。只有如此，人工智能才可能真正推动煤地质学从经验定性判断走向定量认知，从局部样点分析走向跨尺度综合预测，并进一步服务于能源资源安全和双碳目标等国家重大需求。

2.5 AI 赋能煤地质学揭示重大地球科学问题

煤及含煤岩系不仅是能源和金属以及非金属矿产资源的载体，也是记录陆地生态系统演化、全球碳循环、古气候变化、火山活动、古野火、构造沉降和流体改造的重要地质档案。因而，AI 赋能煤地质学的科学价值不仅要提高显微组分识别、煤质参数预测和资源评价的效率和精度，而且要通过整合跨地质时代和跨盆地空间尺度的多源数据，发现传统局部研究难以识别的时空规律，提出可验证的地质假说，并进一步提出和揭示重大地球科学问题。

（1）全球煤层的时空分布、显微组分和地球化学组成及其组合特征记录了陆生植物演化、泥炭堆积、有机碳埋藏以及大气和古气候变化。通过建立包含成煤时代、古地理位置、沉积环境、工业分析数据、显微组分组成、矿物组成、元素地球化学、同位素和古植物资料的全球数据库，人工智能可用于识别聚煤期与植物演化、古构造、古气候、古地理之间的非线性关系或可能的临界阈值，从而深化对深时陆地生态系统与全球碳循环耦合机制的认识。

（2）煤层及其夹矸能够保存火山灰、汞异常、惰质组、燃烧残留物等信息，为研究火山活动、古生态（如古野火）、古气候突变和重大生物-环境事件提供独特记录。多模态学习、异常检测和地层时间序列分析可以将煤岩学、矿物学、元素地球化学、同位素和古生物证据相互印证，识别火山活动、气候变化、野火特征、植被演化和泥炭地生态系统变化之间可能存在的因果链条。

（3）全球古泥炭堆积和煤层形成是古构造、古地理、古气候、古环境和古生态过程共同作用的结果。利

用时空机器学习、图神经网络和因果推断方法，可以比较不同盆地和不同成煤时代的控制因素，区分全球普遍性规律与区域特有现象的机制，并识别控制煤层形成和保存的关键因素，从而推动泥炭沉积和煤层形成理论由传统的定性模式向跨尺度定量检验。

（4）煤系关键金属的富集涉及物源、火山灰输入、化学风化、热液和盆地流体、有机质吸附、矿物结晶及后期改造等多种过程。通过构建包含地质背景、显微组分、矿物载体、元素组合、同位素、层位和成煤时代的知识图谱与因果网络，人工智能有望区分元素组合关系与成因联系，识别全球煤系关键金属富集的构造环境、富集环境和保存环境，并揭示不同关键金属的共同控制因素和差异化富集机制。

（5）AI 赋能的重大科学发现必须建立在可验证的基础上。模型发现的异常、阈值和关联应转化为可以通过新样品、新测试或独立盆地加以检验的地质假说。未来应建立数据库构建、模式发现、地质解释、假说提出、定向地质勘查和采样、实验验证、模型更新的闭环，让人工智能发展成为推动煤地质科学发现和理论创新的重要研究手段。

3 结束语

人工智能正在重塑煤地质学的研究范式。无论是面向显微尺度的煤中显微组分识别，还是面向样品尺度的煤质参数预测、面向化学组成的元素含量与赋存状态判识，以及面向工程尺度的煤层气开发优化，AI 都已表现出明显的效率优势、精度优势与知识发现潜力。

从 AI 赋能煤地质学的发展方向看，人工智能在煤地质学中的作用正在由“识别”走向“预测”，再由“预测”走向“解释”和“决策”。除了提升模型的预测精度，未来煤地质学中的 AI 研究应更加重视模型结果与地质过程机理之间的一致性。这意味着 AI 的价值不仅是替代人工处理海量数据，而且是要帮助研究者发现传统方法不易识别的非线性规律、构建跨尺度关联并服务于资源评价与开发利用以及开发决策。AI 赋能煤地质学未来可重点从以下几个方面推进：

（1）构建质量可评价、误差可量化、来源可追溯的煤地质学数据体系。建设高质量标准化基准数据集，同时通过数据清洗、异常识别、可信度分级和不确定性分析，合理利用不同质量等级的历史数据，推动多源煤地质数据的规范化集成，提升模型的可靠性与泛化能力。

（2）推动地质知识、煤地质学专家经验与机器学习模型深度融合，发展知识引导、煤的物理特征和化学组成约束与可解释人工智能方法。

（3）加强跨不同维度的数据验证，包括跨矿区—煤田—盆地—区域尺度、跨不同学科（如煤岩学、煤地球化学、煤矿物学、煤矿地球物理学等）、跨煤炭能源属性和关键金属资源属性尺度、跨有机质（矿产）和无机质（矿产）尺度，提升模型的泛化能力、稳健性与适用边界。

（4）强化人工智能模型在能源（煤和煤层气）和资源（如关键金属）评价、靶区优选、勘探开发中的工程落地，并在煤炭及其伴生资源的综合开发利用中发挥预测作用，构建从基础研究到应用落地以及政策决策的闭环链条。

（5）关注大模型、多模态模型与智能体技术的发展，充分发挥其在煤地质学中的应用潜力，探索面向复杂地质问题的新型研究工具。

（6）人工智能可以通过融合跨时代、跨盆地和多尺度煤地质学数据，识别传统方法难以发现的地质现象时空规律与成因联系，提出可验证的地质假说，进而揭示陆地生态演化、全球碳循环、重要地质事件等重大地球科学问题。

（7）应以 AI 赋能煤地质学科发展为牵引，推动煤地质学专业人才的教育和培养向地质基础、数据思维和智能方法相融合的模式转型。

随着数据基础不断积累、算法能力的持续提升、学科交叉融合不断深入，人工智能将成为推动煤地质学理论创新、煤炭及其伴生资源综合利用与绿色低碳发展的关键方法支撑。

作者贡献声明：代世峰和许娜负责论文构思与论文写作；朱伟、李鹏飞、齐安良煜参与文献调研、验证核对、绘图；刘宇、颜瑞雯、赵正福参与论文写作和修改。所有作者均阅读并同意稿件的提交和发表。

Author's Contributions: DAI Shifeng and XU Na conceived the study and drafted the manuscript. ZHU Wei, LI Pengfei, and QI Anliangyu participated in literature review, validation and visualization. LIU Yu, YAN Ruiwen, and ZHAO Zhengfu participated in review and manuscript revision. All authors have read and approved the submission and publication of the manuscript.

利益冲突声明：本文所有作者声明本研究无任何利益冲突。

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

References

- AKKAYA A V, 2013. Predicting coal heating values using proximate analysis via a neural network approach[J]. *Energy Sources, Part A: Recovery, Utilization, and Environmental Effects*, 35(3): 253-260.
- ALPANA, CHAND S, MOHAPATRA S, et al., 2021. An intelligent system to identify coal maceral groups using Markov-fuzzy clustering approach[J]. *Journal of Intelligent & Fuzzy Systems*, 41: 5701-5707.
- BARREDO ARRIETA A B, DÍAZ-RODRÍGUEZ N, DEL SER J, et al., 2020. Explainable Artificial Intelligence (XAI): concepts, taxonomies, opportunities and challenges toward responsible AI[J]. *Information Fusion*, 58: 82-115.
- CHATTERJEE S, MASTALERZ M, DROBNIK A, et al., 2022. Machine learning and data augmentation approach for identification of rare earth element potential in Indiana Coals, USA[J]. *International Journal of Coal Geology*, 259: 104054.
- CHELGANI S C, DEHGHAN F, HOWER J C, 2011. Estimation of some coal parameters depending on petrographic and inorganic analyses by using genetic algorithm and adaptive neuro-fuzzy inference systems[J]. *Energy Exploration & Exploitation*, 29(4): 479-494.
- CHELGANI S C, HOWER J C, JORJANI E, et al., 2008. Prediction of coal grindability based on petrography, proximate and ultimate analysis using multiple regression and artificial neural network models[J]. *Fuel Processing Technology*, 89(1): 13-20.
- CRELLING J C, 1983. Current uses of fluorescence microscopy in coal petrology[J]. *Journal of Microscopy*, 132(3): 251-266.
- CRELLING J C, BENSLEY D F, 1984. Characterization of coal macerals by fluorescence microscopy[M]//WINANS R E, CRELLING J C, eds. *Chemistry and characterization of coal macerals*. Washington: American Chemical Society: 33-45.
- DAI S F, BECHTEL A, EBLE C F, et al., 2020. Recognition of peat depositional environments in coal: a review[J]. *International Journal of Coal Geology*, 219: 103383.
- DAI S F, FINKELMAN R B, FRENCH D, et al., 2021. Modes of occurrence of elements in coal: a critical evaluation[J]. *Earth-Science Reviews*, 222: 103815.
- DAI S F, 2025. Critical metals in coal and coal-bearing sequences: a comparison between China and the United States[J]. *Journal of China Coal Society*, 50(1): 506-515. (in Chinese with English abstract)
- DIESSEL C F K, 1992. Coal facies and depositional environment[M]//DIESSEL C F K. *Coal-bearing depositional systems*. Berlin: Springer: 161-264.
- EMINAGAOGLU M, OSKAY R G, KARAYIGIT A I, 2022. Evaluation of elemental affinities in coal using agglomerative hierarchical clustering algorithm: a case study in a thick and mineable coal seam (km²) from Soma Basin (W. Turkey)[J]. *International Journal of Coal Geology*, 259: 104045.
- FAN J W, DU M L, LIU L, et al., 2023. Macerals particle characteristics analysis of tar-rich coal in northern Shaanxi based on image segmentation models via the U-Net variants and image feature extraction[J]. *Fuel*, 341: 127757.
- FINKELMAN R B, 1994. Modes of occurrence of potentially hazardous elements in coal: levels of confidence[J]. *Fuel Processing Technology*, 39(1-3): 21-34.
- FINKELMAN R B, DAI S F, FRENCH D, 2019. The importance of minerals in coal as the hosts of chemical elements: a review[J]. *International Journal of Coal Geology*, 212: 103251.
- GARCÍA-NIETO P J, GARCÍA-GONZALO E, PAREDES-SÁNCHEZ J P, 2024. Estimation of the coal higher heating value for energy systems relied on ultimate analysis with machine learning techniques[J]. *Fuel*, 357: 130037.
- GLAGOLEW A, 1934. Quantitative analysis with the microscope by the point method[J]. *Engineering and Mining Journal*, 135: 339-340.**
- GUO Y S, 2023. Selection of machine learning algorithms in coalbed methane content predictions[J]. *Applied Geophysics*, 20(4): 518-533.

- GUO Z X, ZHAO J Z, YOU Z J, et al., 2021. Prediction of coalbed methane production based on deep learning[J]. *Energy*, 230: 120847.
- HAN D X, YANG Q, 1980. Coalfield geology of China: volume II[M]. Beijing: China Coal Industry Publishing House. (in Chinese)
- HAN D X, 1996. Coal petrology of China[M]. Xuzhou: China University of Mining and Technology Press. (in Chinese)
- HATHERLY P, 2013. Overview on the application of geophysics in coal mining[J]. *International Journal of Coal Geology*, 114: 74-84.
- HOWER J C, BAGHERIEH A H, DINDARLOO S R, et al., 2021. Soft modelling of the Hardgrove grindability index of bituminous coals: an overview[J]. *International Journal of Coal Geology*, 247: 103846.
- HOWER J C, FINKELMAN R B, EBLE C F, et al., 2022. Understanding coal quality and the critical importance of comprehensive coal analyses[J]. *International Journal of Coal Geology*, 263: 104120.
- HUTTON A C, COOK A C, 1980. Influence of alginite on the reflectance of vitrinite from Joadja, NSW, and some other coals and oil shales containing alginite[J]. *Fuel*, 59(10): 711-714.
- IWASZENKO S, RÔG L, 2021. Application of deep learning in petrographic coal images segmentation[J]. *Minerals*, 11(11): 1265.
- JORJANI E, HOWER J C, CHEHREH CHELGANI S, et al., 2008. Studies of relationship between petrography and elemental analysis with grindability for Kentucky coals[J]. *Fuel*, 87(6): 707-713.
- KARACAN C Ö, RUIZ F A, COTÈ M, et al., 2011. Coal mine methane: a review of capture and utilization practices with benefits to mining safety and to greenhouse gas reduction[J]. *International Journal of Coal Geology*, 86(2-3): 121-156.
- LAWAL A I, BADA S O, ONIFADE M, 2025. Prediction of HGI of South African coalfields: a comparative application of ANN, SVR and LSTM models[J]. *International Journal of Coal Preparation and Utilization*, 45(2): 325-341.
- LEI M, RAO Z Y, WANG H D, et al., 2021. Maceral groups analysis of coal based on semantic segmentation of photomicrographs via the improved U-net[J]. *Fuel*, 294: 120475.
- LESTER E, WATTS D, CLOKE M, 2002. A novel automated image analysis method for maceral analysis[J]. *Fuel*, 81(17): 2209-2217.
- LI X X, LI X J, XIE H G, et al., 2024. Enhanced coalbed methane well production prediction framework utilizing the CNN-BL-MHA approach[J]. *Scientific Reports*, 14(1): 14689.
- LIN R, DAVIS A, BENSLEY D F, et al., 1986. Vitrinite secondary fluorescence: its chemistry and relation to the development of a mobile phase and thermoplasticity in coal[J]. *International Journal of Coal Geology*, 6(3): 215-228.
- LIU C, GONG B, WU H Q, et al., 2025a. Intelligent coalbed methane drainage optimization: a deep reinforcement learning-driven life-cycle strategy[J]. *Energy and AI*, 22: 100598.
- LIU C, YANG Y, CHEN L, et al., 2025b. Rare earth resource in fly ashes from coal power plants of China: based on machine learning model and unit-based estimation[J]. *International Journal of Coal Geology*, 303: 104743.
- LIU M, WANG P Z, CHEN S M, et al., 2019. The classification of inertinite macerals in coal based on the multifractal spectrum method[J]. *Applied Sciences*, 9(24): 5509.
- LIU Y, FENG J Y, WANG C X, et al., 2026. Hydrocarbon resources resulting from plant terrestrialization: a review[J]. *Earth-Science Reviews*, 277: 105457.
- MASON D M, GANDHI K N, 1983. Formulas for calculating the calorific value of coal and coal chars: development, tests, and uses[J]. *Fuel Processing Technology*, 7(1): 11-22.
- MATIN S S, CHELGANI S C, 2016. Estimation of coal gross calorific value based on various analyses by random forest method[J]. *Fuel*, 177: 274-278.
- MATIN S S, HOWER J C, FARAHZADI L, et al., 2016. Explaining relationships among various coal analyses with coal grindability index by Random Forest[J]. *International Journal of Mineral Processing*, 155: 140-146.
- MENG L C, ZHU W, XU N, et al., 2026. Explainable AI for coal Hardgrove grindability index prediction: a genetic programming and linear regression approach[J]. *Fuel*, 404: 136072.
- MLYNARCZUK M, SKIBA M, 2017. The application of artificial intelligence for the identification of the maceral groups and mineral components of coal[J]. *Computers & Geosciences*, 103: 133-141.
- MONDAL D, HAN S J, SANG S X, et al., 2024. Application of artificial neural network to evaluate coalbed methane exploration potential: a case study from Permian Longtan Formation, Shuicheng, Guizhou[J]. *Natural Resources Research*, 33(2): 609-636.
- MOORE T A, FERM J C, 1992. Composition and grain size of an Eocene coal bed in southeastern Kalimantan, Indonesia[J]. *International Journal of Coal Geology*, 21(1-2): 1-30.

- MOORE T A, 2012. Coalbed methane: a review[J]. *International Journal of Coal Geology*, 101: 36-81.
- MOTT R A, SPOONER C E, 1940. The calorific value of carbon in coal: the Dulong relationship[J]. *Fuel*, 19: 226-231, 242-251.
- O'BRIEN G, JENKINS B, ESTERLE J, et al., 2003. Coal characterisation by automated coal petrography[J]. *Fuel*, 82(9): 1067-1073.
- O'BRIEN G, JENKINS B, OFORI P, et al., 2007. Semi-automated petrographic assessment of coal by coal grain analysis[J]. *Minerals Engineering*, 20(5): 428-434.
- O'KEEFE J M K, BECHTEL A, CHRISTANIS K, et al., 2013. On the fundamental difference between coal rank and coal type[J]. *International Journal of Coal Geology*, 118: 58-87.
- ONIFADE M, LAWAL A I, ABDULSALAM J, et al., 2021. Development of multiple soft computing models for estimating organic and inorganic constituents in coal[J]. *International Journal of Mining Science and Technology*, 31(3): 483-494.
- PARIKH J, CHANNIWALA S A, GHOSAL G K, 2005. A correlation for calculating HHV from proximate analysis of solid fuels[J]. *Fuel*, 84(5): 487-494.
- PES B, 2020. Ensemble feature selection for high-dimensional data: a stability analysis across multiple domains[J]. *Neural Computing and Applications*, 32(10): 5951-5973.
- QIN Y, YUAN L, CHENG Y P, et al., 2013. Scenario predication for the mid-term and long-term coalbed methane production scale of surface drilling wells in China[J]. *Acta Petrolei Sinica*, 34(3): 489-495. (in Chinese with English abstract)
- REN D Y, ZHAO F H, DAI S F, et al., 2006. *Geochemistry of trace elements in coal*[M]. Beijing: Science Press. (in Chinese)
- RICHARDS A P, HAYCOCK D, FRANDSEN J, et al., 2021. A review of coal heating value correlations with application to coal char, tar, and other fuels[J]. *Fuel*, 283: 118942.
- SANTOS R B M, AUGUSTO K S, IGLESIAS J C Á, et al., 2022. A deep learning system for collotelinite segmentation and coal reflectance determination[J]. *International Journal of Coal Geology*, 263: 104111.
- SEREDIN V V, DAI S F, 2012. Coal deposits as potential alternative sources for lanthanides and yttrium[J]. *International Journal of Coal Geology*, 94: 67-93.
- SHARMA TIMILSINA M S, SEN S, UPRETY B, et al., 2024. Prediction of HHV of fuel by machine learning algorithm: interpretability analysis using Shapley additive explanations (SHAP)[J]. *Fuel*, 357: 129573.
- SHIRAZI A R, BÖRTIN O, EKLUND L, et al., 1995. The impact of mineral matter in coal on its combustion, and a new approach to the determination of the calorific value of coal[J]. *Fuel*, 74(2): 247-251.
- SONG H Q, DU S Y, YANG J S, et al., 2024. Forecasting and influencing factor analysis of coalbed methane productivity utilizing intelligent algorithms[J]. *Chinese Journal of Engineering*, 46(4): 614-626. (in Chinese with English abstract)
- STACH E, 1927. Der Kohlenreliefschliff, ein neues Hilfsmittel für die angewandte Kohlenpetrographie[J]. *Mitteilungen der Abteilung für Gesteins-, Erz-, Kohle- und Salzuntersuchungen*, 2: 75-94.
- STACH E, MACKOWSKY M T, TEICHMÜLLER M, et al., 1975. *Stach's textbook of coal petrology*[M]. 2nd ed. Berlin, Stuttgart: Gebrüder Borntraeger.
- STEUER W, 1926. General formulas for calculating the heating value of fossil fuels from their elementary analyses[J]. *Brennstoff-Chemie*, 7: 344-347.
- TAGGART R K, HOWER J C, DWYER G S, et al., 2016. Trends in the rare earth element content of U.S.-based coal combustion fly ashes[J]. *Environmental Science & Technology*, 50(11): 5919-5926.
- TAN P, ZHANG C, XIA J, et al., 2015. Estimation of higher heating value of coal based on proximate analysis using support vector regression[J]. *Fuel Processing Technology*, 138: 298-304.
- TAYLOR G H, TEICHMULLER M, DAVIS A, et al., 1998. *Organic petrology: a new handbook incorporating some revised parts of Stach's Textbook of coal petrology; with 70 tables in the text*[M]. Berlin: Borntraeger.
- TEICHMÜLLER M, 1974. Über neue Macerale der Liptinit-Gruppe und die Entstehung von Micrinit[J]. *Fortschritte in der Geologie von Rheinland und Westfalen*, 24: 37-64.
- THOMAS L, 2002. *Coal geology*[M]. Chichester: Wiley.
- TING F T C, 1978. *Petrographic techniques in coal analysis*[M]/KARR C JR. Analytical methods for coal and coal products. New York: Academic Press: 3-26.
- TIWARY A K, GHOSH S, SINGH R, et al., 2020. Automated coal petrography using random forest[J]. *International Journal of Coal Geology*, 232: 103629.
- UNSWORTH J F, GOUGH H, 1989. Characterization of coals by automated optical image analysis 1. Vitrinite reflectance[J]. *Journal of Microscopy*, 156(3): 313-326.
- VENKOBABAO B, GOPALAKRISHNA S J, 2009. Hardgrove grindability index prediction using support vector regression[J]. *International Journal of Mineral Processing*, 91(1-2): 55-59.
- VUTHALURU H B, BROOKE R J, ZHANG D K, et al., 2003. Effects of moisture and coal blending on Hardgrove Grindability Index of Western Australian coal[J].

Fuel Processing Technology, 81(1): 67-76.

WANG H D, LEI M, CHEN Y L, et al., 2019a. Intelligent identification of maceral components of coal based on image segmentation and classification[J]. Applied Sciences, 9(15): 3245.

WANG H D, LEI M, LI M, et al., 2019b. Intelligent estimation of vitrinite reflectance of coal from photomicrographs based on machine learning[J]. Energies, 12(20): 3855.

WANG H Y, WANG Q Q, HUANG L, et al., 2023. Intelligent decision-making system for integrated geological and engineering of deep coalbed methane development[J]. Energy & Fuels, 37(18): 13976-13984.

WANG T, LIN Q H, 2021. Hybrid predictive models: when an interpretable model collaborates with a black-box model[J]. The Journal of Machine Learning Research, 22(1): 137.

WANG Y, BAI X F, WU L L, et al., 2022. Identification of maceral groups in Chinese bituminous coals based on semantic segmentation models[J]. Fuel, 308: 121844.

WARD C R, 2002. Analysis and significance of mineral matter in coal seams[J]. International Journal of Coal Geology, 50(1-4): 135-168.

WARD C R, 2016. Analysis, origin and significance of mineral matter in coal: an updated review[J]. International Journal of Coal Geology, 165: 1-27.

WEI X Y, HUANG W S, LIU L L, et al., 2024. Low-rank coalbed methane production capacity prediction method based on time-series deep learning[J]. Energy, 311: 133247.

WEN H, YAN L, JIN Y F, et al., 2023a. Coalbed methane concentration prediction and early-warning in fully mechanized mining face based on deep learning[J]. Energy, 264: 126208.

WEN Z P, LIU H T, ZHOU M Q, et al., 2023b. Explainable machine learning rapid approach to evaluate coal ash content based on X-ray fluorescence[J]. Fuel, 332(Pt 1): 125991.

WOOD D A, 2019. Transparent open-box learning network provides auditable predictions for coal gross calorific value[J]. Modeling Earth Systems and Environment, 5(2): 395-419.

XU N, XU C P, FINKELMAN R B, et al., 2022. Coal elemental (compositional) data analysis with hierarchical clustering algorithms[J]. International Journal of Coal Geology, 249: 103892.

XU N, WANG Z W, DAI Y C, et al., 2023a. Prediction of higher heating value of coal based on gradient boosting regression tree model[J]. International Journal of Coal Geology, 274: 104293.

XU N, ZHU W, HUANG B, et al., 2023b. Modes of occurrence of elements in high-germanium coals using correlation analysis algorithm[J]. Applied Geochemistry, 152: 105647.

XU N, ZHU W, WANG R, et al., 2023c. Application of self-organizing maps to coal elemental data[J]. International Journal of Coal Geology, 277: 104358.

XU N, WANG Q F, LI P F, et al., 2025a. Intelligent identification of coal macerals using improved semi-supervised semantic segmentation methods[J]. International Journal of Coal Geology, 300: 104712.

XU N, LI F, ZHU W, et al., 2025b. Predicting the concentrations of rare earth elements and yttrium in coal using self-organizing map[J]. Natural Resources Research, 34(3): 1467-1479.

XU N, JIAO F Y, HOWER J C, et al., 2026a. An improved U-net model for the identification of coal macerals[J]. International Journal of Coal Preparation and Utilization, doi: 10.1080/19392699.2026.2613015.

XU N, LI P F, KONG J P, et al., 2026b. Predicting the prospect of rare earth elements and yttrium recovery from coal using machine learning[J]. International Journal of Coal Preparation and Utilization, doi: 10.1080/19392699.2026.2613010.

YANG Q, HAN D X, 1979. Coalfield geology of China: volume I[M]. Beijing: China Coal Industry Publishing House. (in Chinese)

YESENCHAK R, SHARMA S, MAXWELL A E, 2022. Modes of occurrence, elemental relationships, and economic viability of rare earth elements in West Virginia coals: a statistical approach[J]. Minerals, 12(8): 1060.

ZHANG H, CAI X L, NI P, et al., 2025a. Prediction of coalbed methane content based on composite logging parameters and PCA-BP neural network[J]. Journal of Applied Geophysics, 236: 105681.

ZHANG H Y, LI K W, SHI S H, et al., 2025b. Prediction of coalbed methane production using a modified machine learning methodology[J]. Energies, 18(6): 1341.

ZHENG Y, 2015. Methodologies for cross-domain data fusion: an overview[J]. IEEE Transactions on Big Data, 1(1): 16-34.

ZHU J, ZHAO Y H, HU Q J, et al., 2022. Coalbed methane production model based on random forests optimized by a genetic algorithm[J]. ACS Omega, 7(15): 13083-13094.

ZHU W, XU N, HOWER J C, 2025a. Unveiling the predictive power of machine learning in coal gross calorific value estimation: an interpretability perspective[J]. Energy, 318: 134781.

ZHU W, SHEN L S, XU N, et al., 2025b. Rare earth elements and yttrium in Chinese coals: distribution and economic significance[J]. Renewable and Sustainable Energy Reviews, 212: 115423.

ZHU W, LIU W, XU N, et al., 2026. Modes of occurrence of critical elements in coals from the Guanbanwusu mine, Inner Mongolia, China: a novel stratigraphy-constrained sliding-window correlation approach[J]. Applied Geochemistry, 196: 106638.

附中文参考文献

代世峰, 2025. 煤系关键金属矿产研究: 中美对比[J]. 煤炭学报, 50 (1): 506-515.

韩德馨, 杨起, 1980. 中国煤田地质学: 下册[M]. 北京: 煤炭工业出版社.

韩德馨, 1996. 中国煤岩学[M]. 徐州: 中国矿业大学出版社.

秦勇, 袁亮, 程远平, 等, 2013. 中国煤层气地面井中长期生产规模的情景预测[J]. 石油学报, 34 (3): 489-495.

任德貽, 赵峰华, 代世峰, 等, 2006. 煤的微量元素地球化学[M]. 北京: 科学出版社.

宋洪庆, 都书一, 杨焦生, 等, 2024. 基于机器学习的煤层气产能标定智能算法及影响因素分析[J]. 工程科学学报, 46 (4): 614-626.

杨起, 韩德馨, 1979. 中国煤田地质学: 上册[M]. 北京: 煤炭工业出版社.