doi: 10. 20238/j. issn. 1671-4172. 2026. 06. 011
朱梦琦, 李建斌, 朱合华, 等. 深部金属矿山TBM智能掘进感知与决策框架研究[J]. 有色金属(矿山部分), 2026, 78(6): 111-123.
Zhu Mengqi, Li Jianbin, Zhu Hehua, et al. A perception and decision-making framework for intelligent TBM excavation in deep metal mines[J]. Nonferrous Metals (Mining Section), 2026, 78(6): 111-123.

深部金属矿山TBM智能掘进感知与决策框架研究

朱梦琦[1], 李建斌[2], 朱合华[3], 刘永胜[4], 姚诞圣[5], 白孟琦[5], 孙诗尧[3]
(1. 同济大学 机械工程与机器人学院, 上海 200092;
2. 中铁高新工业股份有限公司, 北京 100071;
3. 同济大学 土木工程学院, 上海 200092;
4. 盾构及掘进技术国家重点实验室, 郑州 450001;
5. 上海自主智能无人系统科学中心, 上海 201210)

摘　要: 随着深部金属矿山开采向高地应力、高地温及复杂地质环境延伸, 隧道掘进机(TBM)施工过程面临多源异构数据融合困难、复杂工况感知不足, 以及施工决策高度依赖人工经验等挑战。与交通隧道工程不同, 深部金属矿山巷道掘进遭遇的围岩条件变化更为剧烈且频繁, 矿岩界面交替、高应力诱导的岩爆倾向以及多灾害耦合效应, 使TBM施工过程具有极强的非线性和动态不确定性。现有研究多聚焦于参数预测、地质识别或风险预警等单一任务, 尚未形成贯穿数据底层融合、状态信息提取、演化规律认知与施工决策生成的统一智能体系。针对上述问题, 本文从智能体视角出发, 提出一种面向深部金属矿山TBM智能掘进的感知与决策框架。该框架构建了逐层递进的四个核心层次: 数据认知层基于“人-机-岩”耦合机理, 实现多源数据融合与统一特征表达; 状态感知层融合知识驱动与数据驱动方法, 实现装备状态、地质状态及风险状态的快速识别; 时空分析层揭示围岩条件和设备响应的时空演化规律, 实现边界识别、可掘性表征及未来运行响应预测; 决策生成层依托大语言模型、知识图谱及多维证据融合机制, 生成风险预警、参数优化及施工决策。最终形成“数据认知-状态感知-时空分析-决策生成”的闭环, 实现了由数据驱动向知识-数据协同驱动、由被动响应向主动前瞻决策的范式转变, 为深部金属矿山TBM智能掘进提供可行的理论框架和技术路径。

关键词: 金属矿山; 隧道掘进机(TBM); 智能掘进; 感知与决策智能体; 认知智能
中图分类号: TD421　　**文献标志码:** A　　**文章编号:** 1671-4172(2026)06-0111-13

A perception and decision-making framework for intelligent TBM excavation in deep metal mines

Zhu Mengqi[1], Li Jianbin[2], Zhu Hehua[3], Liu Yongsheng[4], Yao Dansheng[5], Bai Mengqi[5], Sun Shiyao[3]
(1. School of Mechanical Engineering, Tongji University, Shanghai 200092, China;
2. China Railway Hi-Tech Industry Corporation Limited, Beijing 100071, China;
3. College of Civil Engineering, Tongji University, Shanghai 200092, China;
4. State Key Laboratory of Shield Machine and Boring Technology, Zhengzhou 450001, China;
5. Shanghai Research Institute for Intelligent Autonomous Systems, Shanghai 201210, China)

Abstract: As deep metal mining advances toward environments characterized by high in-situ stress, elevated ground temperature, and complex geological conditions, Tunnel boring machine (TBM) excavation faces critical challenges, including difficulties in multi-source heterogeneous data fusion, insufficient perception of complex operating conditions,

收稿日期: 2026-06-30
基金项目: 国家自然科学基金资助项目(52408437)
作者简介: 朱梦琦, 博士, 副教授, 主要从事隧道智能掘进、地下工程数字孪生及风险智能决策分析等方面的研究。

and excessive dependence on human experience for construction decision-making. Unlike conventional transportation tunnel projects, deep metal mine roadways experience more drastic and frequent variations in surrounding rock conditions. The alternating occurrence of ore-rock interfaces, high-stress-induced rockburst potential, and coupled multi-hazard effects introduce strong nonlinearity and dynamic uncertainty into TBM excavation processes. Existing studies mainly focus on individual tasks, such as performance prediction, geological identification, or risk warning, and have not yet established a unified intelligent system that integrates underlying data fusion, state information extraction, evolutionary mechanism understanding, and construction decision generation. To address these challenges, this paper proposes an agent-oriented perception and decision-making framework for intelligent TBM excavation in deep metal mines. The proposed framework consists of four progressively hierarchical layers: the Data Cognition Layer, which integrates multi-source data and achieves unified feature representation based on the human-machine-rock coupling mechanism; the State Perception Layer, which combines knowledge-driven and data-driven approaches to enable rapid identification of equipment states, geological states, and risk states; the Spatiotemporal Analysis Layer, which uncovers the spatiotemporal evolution patterns of surrounding rock conditions and machine responses, enabling boundary detection, boreability characterization, and future operational response prediction; and the Decision Generation Layer, which leverages large language models, knowledge graphs, and multi-dimensional evidence fusion mechanisms to generate risk warnings, parameter optimization strategies, and intelligent construction decisions. Ultimately, the proposed framework establishes a closed-loop architecture spanning data cognition, state perception, spatiotemporal analysis, and decision generation, enabling a paradigm shift from data-driven intelligence toward knowledge-data collaborative intelligence, and from passive response toward proactive and forward-looking decision-making. This framework provides a feasible theoretical foundation and technical pathway for the development of intelligent TBM excavation systems in deep metal mines.

Key words: metal mines; tunnel boring machine (TBM); intelligent excavation; perception and decision-making agent; cognitive intelligence

浅部矿产资源日趋枯竭,推动全球矿业开发持续向深部延伸[1]。深部金属矿山普遍具有埋深大、地应力高、地质构造复杂及施工环境恶劣等特征,对巷道快速掘进与安全保障提出了更加严峻的挑战[2-3]。特别是随着开采深度不断增大,高地应力诱发的岩爆等动力灾害风险显著增高;同时,井下巷道断面尺寸受限,通风散热条件恶劣,且掘进过程中矿岩界面频繁交替出现,多重因素叠加,大幅提升了施工环境的复杂程度与施工风险的不确定性。隧道掘进机(Tunnel Boring Machine, TBM)作为集机械、电气、液压及自动控制于一体的大型地下施工装备,凭借其掘进效率高、施工连续性好及作业环境安全等优势,已成为深部矿山巷道建设的重要技术装备[2,4]。与此同时,随着智能矿山建设推进,TBM施工全过程逐渐形成了涵盖设备运行响应、地质环境信息及施工管理记录的多源异构数据体系,为实现掘进过程的智能感知与自主决策奠定了数据基础[5-6]。

近年来,人工智能技术在TBM领域得到广泛应用。在设备运行参数预测方面,研究人员利用支持向量机、随机森林、神经网络及集成学习等方法,建立了推力、扭矩及推进速度的预测模型[6-10]。针对掌子面前方地质条件难以直接获取的瓶颈,学者们利用TBM运行响应开展围岩识别与地质预报,构建了多种地质分类与灾害预警模型[11-15]。此外,深度学习、强化学习及数字孪生等新技术的引入,使得复杂工况下的岩体边界识别、参数优化及自主控制能力得到了显著提升[16-19]。然而,上述研究大多以交通隧道等常规TBM施工场景为对象,其围岩条件相对均一、地质信息先验性较强。相比之下,深部金属矿山巷道掘进过程中围岩类别转换更为频繁,地应力场时空变异特征显著,导致现有模型在处理频繁穿越矿岩界面以及高应力诱发的突变工况时,泛化能力与鲁棒性存在明显不足。同时,这些研究多围绕单一预测任务独立展开,未能充分正视推力、扭矩、推进速度与围岩条件等目标间的内在耦合关系[5]。这种“分而治之”的建模方式,导致各模型间缺乏协同,感知结果难以为整体工程决策提供有效支撑。

从本质上看,深部金属矿山TBM智能掘进并非若干预测模型的简单叠加,而是一个由数据认知、状态感知、时空分析与决策生成共同构成的连续认知过程。其中,数据认知层解决“数据如何统一表征”的基础问题;状态感知层回答“当前工况状态是什么”,实现装备、围岩及风险的快速识别;时空分析层进一步回答“状态将如何演化”,揭示围岩边界、可掘性及设备响应的时空规律;决策生成层则回答“该如何处置”,将多层次认知结果转化为可执行方案。

因此，亟需突破传统任务驱动范式，从认知智能角度构建贯通感知、认知与决策全过程的技术体系。

针对上述问题，本文面向深部金属矿山TBM施工场景，提出一种“数据认知-状态感知-时空分析-决策生成”四层递进式智能体架构。该架构以“人-机-岩”耦合机理为理论基础，由数据认知层、状态感知层、时空分析层和决策生成层四个层次构成。其中，数据认知层负责将多源异构数据映射为统一特征空间；状态感知层实现装备状态、地质及风险状态的快速识别；时空分析层揭示围岩与设备响应的时空演化规律；决策生成层依托大语言模型实现知识推理与自主决策。四层间形成“数据→信息→知识→决策”的转化链路，为深部金属矿山TBM智能掘进提供统一的理论框架和技术路径。在该架构中，不同智能模型按照认知粒度分层组织：浅层机器学习模型侧重于快速状态识别与风险初筛，深度学习模型面向多尺度时序演化、地层过渡过程及未来运行响应预测，二者最终由大语言模型智能体统一调度，并转化为可执行的工程决策。

1　TBM智能掘进的数据基础与特征表达

数据认知层承担着连接深部金属矿山TBM实际掘进过程与智能认知系统的关键桥梁作用。TBM智能掘进所产生的海量监测数据、地质资料及施工记录，本质上是“人-机-岩”系统持续交互作用的数字化映射。然而，深部金属矿山的高地应力、高地温、频繁岩性变化及强施工扰动，使设备运行响应与围岩环境间呈现更强的非线性耦合，数据表现出显著的非平稳性和多尺度特征。TBM施工原始数据来源多样、结构各异、时空尺度不统一，难以直接满足上层智能分析需要。因此，须从TBM施工机理出发，厘清多源异构数据的演化规律，建立其统一表征体系，实现从原始观测量向可计算特征空间的转换，为后续状态感知、时空分析与决策生成提供数据底座。

1.1　“人-机-岩”互馈系统机理分析

深部金属矿山TBM掘进过程是一个由作业人员、掘进装备与围岩环境共同参与的复杂动态系统，其运行状态受装备控制、围岩力学响应及人工决策共同影响，如图1所示。

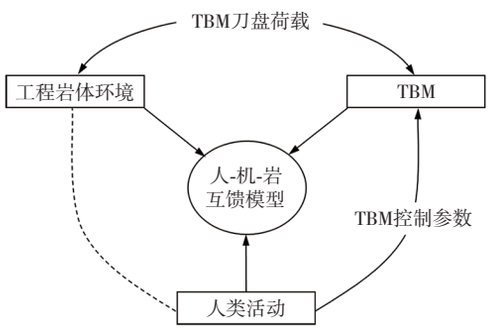
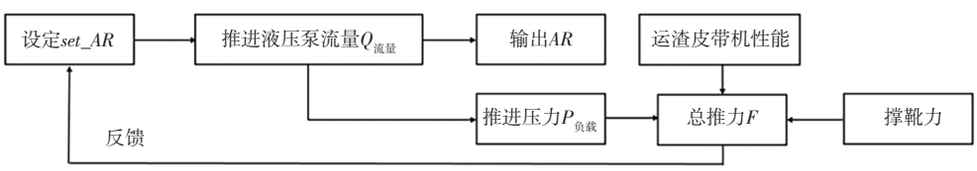


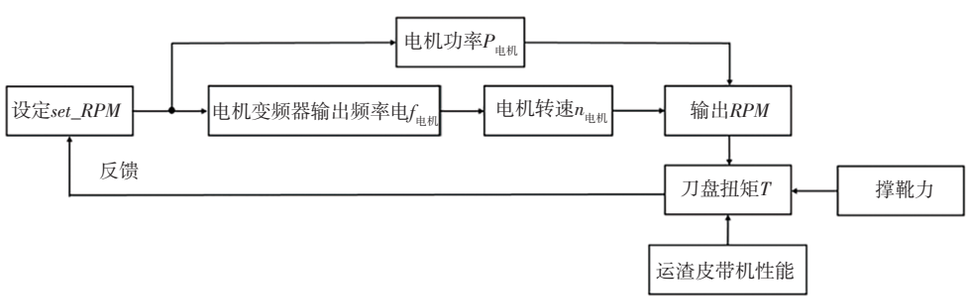
图1　TBM掘进过程人-机-岩互馈模型

Fig. 1　Human-machine-rock interactive feedback model in TBM tunneling process

在“人-机”交互层面，操作员借助上位机监控界面获取TBM运行状态，结合工程经验设定推进速度和刀盘转速等关键参数。TBM控制系统主要包括推进控制系统和刀盘驱动控制系统两部分，其控制流程如图2所示。PLC接收操作指令后，通过调节液



(a)TBM推进系统控制流程



(b)TBM刀盘驱动系统控制流程

图2　TBM系统控制流程

Fig. 2　Control flows of TBM system

压缸电磁阀流量和驱动电机变频器输出，实现推进速度、刀盘转速及推力等关键参数的闭环控制，并将设备响应实时反馈给操作人员，为后续施工决策提供依据[20-21]。

“机-岩”作用是系统的核心耗能环节，表现为盘形滚刀与围岩的接触及岩体断裂行为。如图3所示，盘形滚刀在推力和扭矩作用下滚压侵入岩体，岩体经历应力场建立、压碎区形成、裂纹萌生与扩展等过程，最终形成岩屑剥落。图4给出了滚刀在破岩过程中的三维受力状态，法向力、滚动力及侧向力共同决定了岩体破碎模式及TBM运行载荷响应。该过程遵循能量守恒，设备负载受围岩物理力学特性严格制约。在深部金属矿山高应力环境下，围岩往往表现出脆-延性转变特征，破岩比能增高，滚刀磨损加剧，这使得“机-岩”耦合响应显著区别于浅部工况。

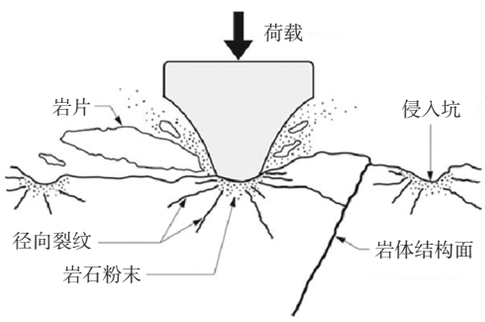


图3 单刀破岩原理示意图[22]

Fig. 3 Schematic diagrams of rock breaking principle by a single disc cutter[22]

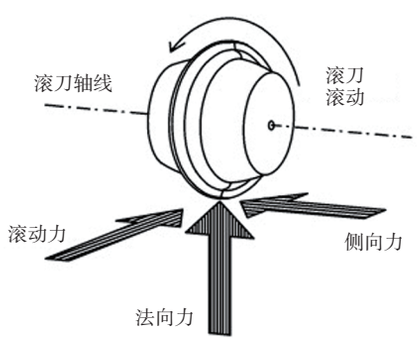


图4 滚刀三维受力示意图[23]

Fig. 4 Schematic diagrams of 3D forces on a disc cutter[23]

“人-岩”互馈则依赖间接的数据感知机制。操作员无法直接观察掌子面前方地质环境，而是通过TBM运行响应间接反演围岩特征。因此，推力、扭矩、转速、振动等参数不仅是设备状态的表征，也是围岩信息的载体。TBM监测数据本质上记录了“人-机-岩”系统动态交互的轨迹。对于深部金属矿山而言，高地应力作用下的围岩渐进破坏、频繁穿越矿岩界面以及局部断层破碎带等复杂工况，使设备运行数据蕴含着围岩演化及灾害孕育的关键信息，这要求数据认知层必须具备更强的特征表达与对非平稳信号的适应能力。

1.2 多源异构数据特征分析

随着矿山数字化发展，TBM施工积累了来源各异、结构多样的工程数据，包含高频设备运行数据、低频地质环境数据以及文本形式的施工记录，以上共同构成数据基础。

从来源看，TBM多源数据主要包括三类。第一类为设备运行数据，由PLC及传感器实时采集，包括总推力、刀盘扭矩、推进速度、转速、液压压力、电流及振动等，具有高频、连续、海量的特点[9]；第二类为地质环境数据，来源于超前地质预报、钻探取芯及现场编录，包括岩性、完整性、单轴抗压强度及耐磨性等，空间属性强且更新频率低；第三类为施工数据，包括换刀、维护、异常事件及管理信息，多为文本或半结构化形式，反映人为干预。

深部矿山复杂环境使上述数据呈现显著的非平稳性和异构性。在矿岩交界、断层破碎带及高应力集中区，设备响应常表现出突变、阶段性跃迁及强非线性特征，传统基于单一数据源或时间尺度的分析难以准确描述真实状态。一方面，高频运行数据与低频地质数据存在采样频率和表达形式差异，难以直接融合；另一方面，TBM掘进包含启动、空推、试掘、稳定掘进及停机等多种工况，参数分布差异显著。此外，井下高温、高湿、强振动及电磁干扰还会导致数据缺失、异常波动和噪声污染。特别是金属矿山巷道断面通常较小，传感器安装空间受限，进一步增加了数据采集的难度和不稳定性。因此，建立统一的数据表达体系，实现多源异构信息的有效融合与语义对齐，是构建TBM智能认知体系的首要前提。

1.3 多源数据融合与认知特征构建

如图5所示，为实现多源异构数据向统一认知空间的映射，需首先进行数据质量提升与时空对齐处理。针对异常值、缺失值及噪声问题，采用物理约束与统计分析相结合的策略进行识别、修正与恢复。针对高频噪声，结合小波分解等方法提取真实趋势，提升数据可靠性。

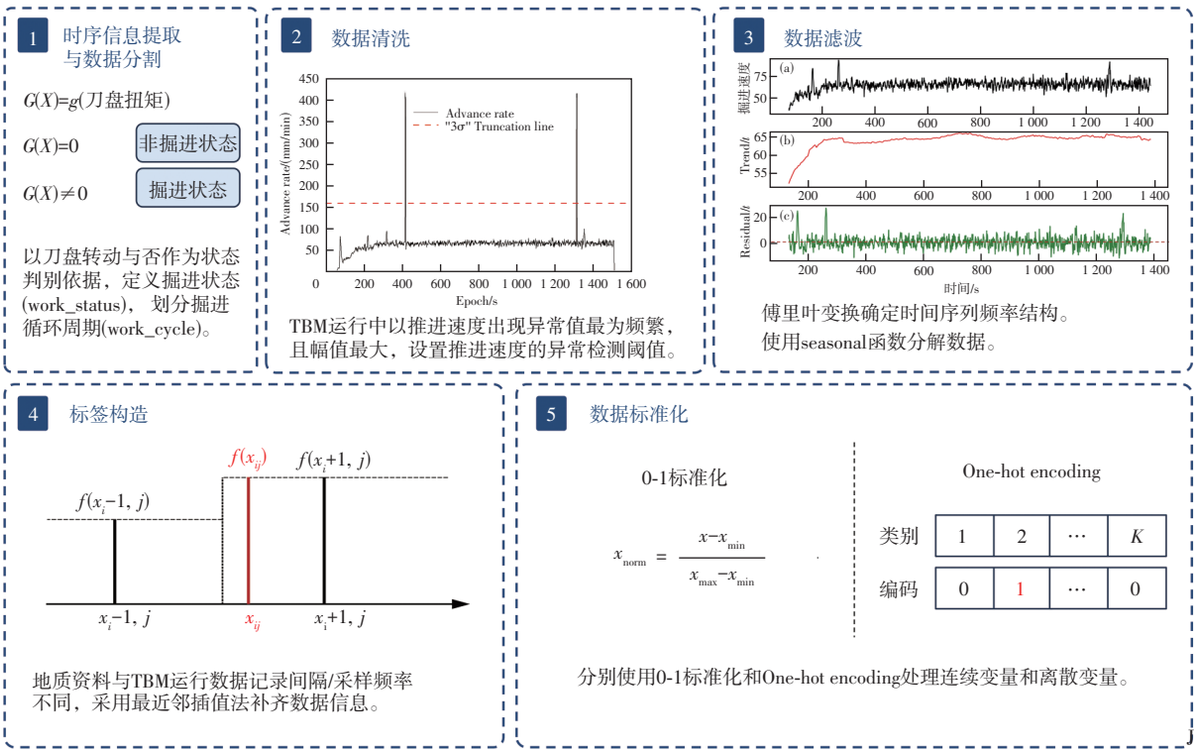


图 5　TBM 掘进数据处理流程

Fig. 5　Data processing flowchart of TBM tunneling

数据融合中，设备运行数据以时间序列记录，地质资料按空间桩号描述，两者间存在天然的时空错位。为此，以掘进循环为基本分析单元，建立时间-空间映射，结合 TBM 尺寸及刀盘位置对地质信息进行空间校正，实现设备响应与围岩特征的精准匹配。需要指出的是，构建的统一特征空间主要实现多源数据的一致性表达，并不直接对应装备状态或围岩状态，而是作为后续状态感知与时空分析共享的数据表征基础。

完成数据融合后，进一步开展特征工程。以单次有效掘进循环为窗口，对推力、扭矩、推进速度及转速等关键变量提取统计特征、频域特征及能量特征。结合矿山 TBM 破岩机理构建反映“机-岩”相互作用的物理衍生指标，如破碎比能、贯入度指标等，以强化对高应力围岩响应特征的表达。

随后，采用知识约束与数据驱动相结合的策略进行特征筛选。首先依据 TBM 破岩力学机理保留具有明确物理意义的关键参数；其次利用相关性分析与降维方法消除冗余信息；最后结合树模型重要度评价筛选出对目标任务贡献最大的核心特征。经过上述处理后，原始监测数据被映射为由机械响应特征、地质表征特征及能量衍生特征构成的统一特征空间。该空间作为整个智能体架构的数据底座，为状态感知层的状态识别、时空分析层的演化建模提供统一输入。

2　基于知信机器学习的状态感知

状态感知层的核心任务是回答“当前工况状态是什么”，即通过数据认知层提供的统一特征空间，建立状态空间的映射，实现对装备运行状态、围岩条件及施工风险的快速识别，为施工监测、诊断和预警提供实时依据。

传统方法多依赖经验或单一指标分析，难以揭示复杂工况下多源变量之间的非线性耦合关系[7]。近年来，机器学习技术在 TBM 性能预测、地质识别及灾害预警等领域取得了广泛应用，但纯数据驱动模型往往缺乏物理机理约束，容易产生过拟合和可解释性不足等问题。特别在深部金属矿山环境下，围岩条件复杂多变、极端地质样本稀缺，单纯依赖统计规律构建的模型难以满足工程应用需求。以东北某工程为例，该项目沿线地质条件复杂，围岩以花岗岩硬岩为主，局部发育断层破碎带、节理裂隙及岩溶等不良地质体，导致围岩完整性和力学性质沿掘进方向呈现显著的空间非均质性。在实际掘进中，TBM 可能由完整硬岩快速进入破碎或软弱地层，引起刀盘负载、推进阻力及振动等运行响应的突变，并进一步

诱发卡机、刀具异常磨损等风险。因此，仅依赖单一时刻或单一变量进行状态判断难以准确反映复杂地质条件下“人-机-岩”系统的真实状态。

为此，本文构建融合知识驱动与数据驱动的知信机器学习(Knowledge-Informed Machine Learning)感知框架。该框架以“人-机-岩”耦合机理为知识基础，将破岩力学、控制逻辑及工程经验融入模型构建，通过机理约束增强模型对复杂工况的适应能力。基于统一特征空间，分别构建装备、地质及风险状态感知模型，为上层时空分析与决策生成提供状态基础。

2.1 TBM掘进性能感知

装备运行状态直接反映施工效率与负载，是参数优化与施工组织决策的重要依据。在深部复杂地质环境下，TBM运行响应受到围岩性质、设备性能及人为控制的共同影响，呈现出强非线性与动态演化特征，传统基于经验公式或静态岩体参数的预测方法难以准确反映其复杂变化规律。

基于统一特征空间，本文建立面向装备状态感知的性能预测模型。考虑到TBM推进过程具有明显的阶段性特征，将单次掘进循环划分为启动、空推、试掘和稳定掘进等不同阶段，并结合控制系统响应延迟特性，提取“正常掘进试掘阶段前30秒”的动态运行参数作为输入，预测“稳定掘进阶段”的核心目标参数：刀盘总推力(F)、刀盘扭矩(T)和推进速度(AR)。

针对掘进过程的强非线性与多维特征映射需求，引入支持向量机(SVM)、随机森林(RF)、梯度提升树(GBDT)与人工神经网络(ANN)四类算法建模。如图6所示，四类模型对F和T的拟合能力极强，决定系数(R^2)绝大多数优于0.95；受地质变异性影响，对AR的预测精度略低，平均R^2为0.892，但整体仍具备工程指导价值。

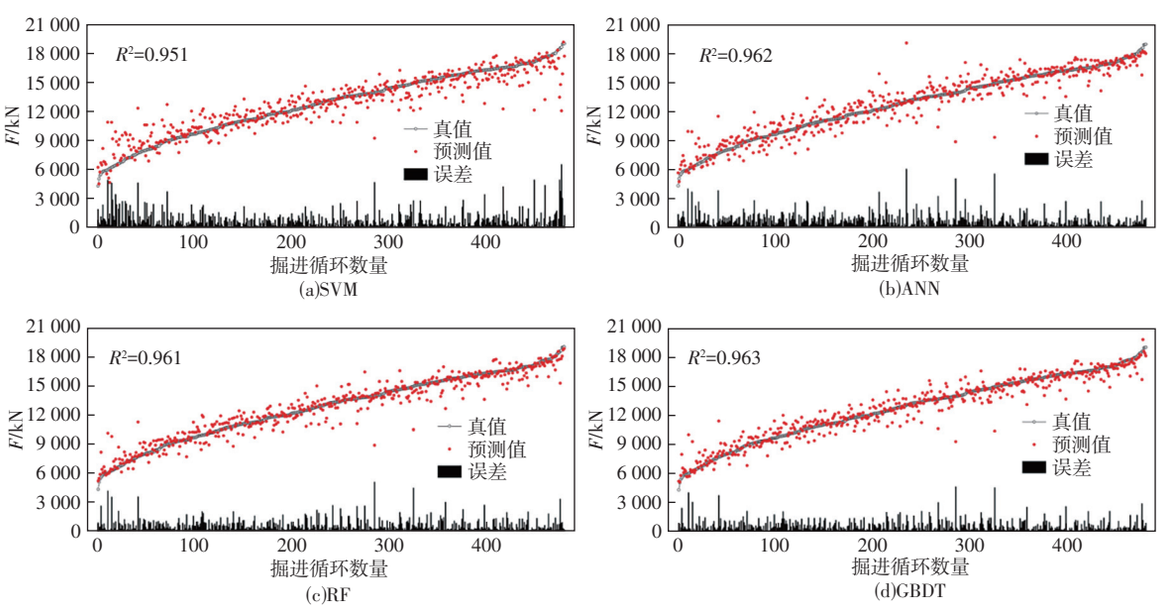


图6 四种机器学习模型对F的预测效果比较

Fig. 6 Comparison of prediction performance of four machine learning models for the total thrust force of the TBM cutterhead

2.2 围岩工程地质感知

掌子面前方围岩条件直接决定TBM掘进效率与施工风险。然而，受地下空间封闭环境限制，TBM无法直接观测前方地质，只能通过设备运行响应反演地层特征。对于深部金属矿山，矿体与围岩频繁交替、断层破碎带及蚀变带广泛发育，围岩状态呈现显著的空间非均质性，其准确识别不仅影响效率，更关乎岩爆、失稳及塌方等灾害风险防控。

基于“机-岩”作用机理，不同岩体在推力、扭矩、贯入度及能耗上留有特征性响应。理论上可建立运行响应与围岩类别的映射。然而，实际工程数据通常呈现不平衡分布，稳定岩层占据绝大多数，软弱破碎岩体样本较少，传统分类模型此时倾向于多数类。为此，本文引入并改进自适应代价敏感提升算法(AdaCost)[24]。该模型基于自适应增强算法(AdaBoost)的集成学习框架，引入非对称误判代价机制，并将其融入基分类器权重更新过程，以提升模型对不同误判类型的识别能力。在训练阶段，模型定义了代价调整因子，通过提高高风险样本的误判代价，引导模型主动关注少数类地质状态，从而增强对

软弱围岩的识别能力。同时，将破岩机理知识融入特征构建过程，以提高模型对围岩特征变化的敏感性。

为全面评价模型的分类识别性能，本文采用精度、召回率和F1分数作为评价指标。其中，精度用于衡量模型预测结果中正确识别样本的比例，召回率反映模型对目标类别样本的识别完整性，F1分数则综合考虑精度与召回率的平衡性能。如表1所示，相较于未引入代价敏感机制的模型，AdaCost在不平衡数据上的识别性能显著提升：坚硬岩体分类精度提升38%，可有效支撑刀具异常磨损预判；软弱破碎围岩识别精度跃升68%，大幅增强了工程安全预警效能。

表1　三种分类器的预测结果

Table 1　Prediction results of three classifiers

	SVM			RF			AdaCost		
	坚硬岩体	中硬岩体	软弱岩体	坚硬岩体	中硬岩体	软弱岩体	坚硬岩体	中硬岩体	软弱岩体
精度	0.00	0.99	0.13	0.00	0.96	0.21	0.38	0.88	0.89
召回率	0.00	0.83	0.72	0.00	0.90	0.55	0.85	0.90	0.57
F1分数	0.00	0.90	0.22	0.00	0.93	0.30	0.62	0.89	0.73
样本数量	58	715	99	58	715	99	58	715	99
正确率	0.83			0.82			0.82		

2.3　不良地质推断

相比装备和地质状态，不良地质风险更具突发性和隐蔽性，是影响施工安全的关键。断层破碎带、软弱夹层等易塌方区常导致设备负载异常波动、推进效率骤降甚至施工中断。因此，如何从复杂运行数据中识别潜在风险状态，是智能掘进的重要任务。

现有风险识别方法多采用黑盒机器学习模型建立输入与风险标签之间的映射关系，这种方法虽然能够获得较高预测精度，但难以解释风险产生的原因，不利于工程人员理解和应用。针对这一问题，本文开发了闭环特征设计算法(Closed-Loop Algorithm for Feature Design，CLA-FD)[25]，该算法将遗传编程(GP)与符号回归(SR)的演化机制深度嵌入特征工程，提供了一种客观、自动的特征生成方案。

经过CLA-FD算法的闭环迭代筛选，模型从高频时序运行参数中成功降维并剥离出两个核心灾变预警衍生指标：扭矩功率(P_t)与推力功(W_f)。

$$P_t = RPM \times T \tag{1}$$

$$W_f = L \times F \tag{2}$$

式(1)中，RPM、T分别为TBM的刀盘转速和刀盘扭矩；式(2)中，L、F分别为TBM的推进距离和刀盘总推力。这两个衍生指标形式紧凑，直观表征了TBM破岩过程中的能量耗散速率与“机-岩”互馈累积做功的物理本质。如图7所示，在低地应力塌方风险预测的实证应用中，仅以P_t与W_f构建二维输入分类器，即可对塌方灾变数据与正常掘进数据实现98%的精准区分。该降维方法成功将极度复杂的高维特征空间映射至清晰的二维平面，使灾变识别的决策边界完全可视化，显著提升了模型的可解释性和工程公信力。

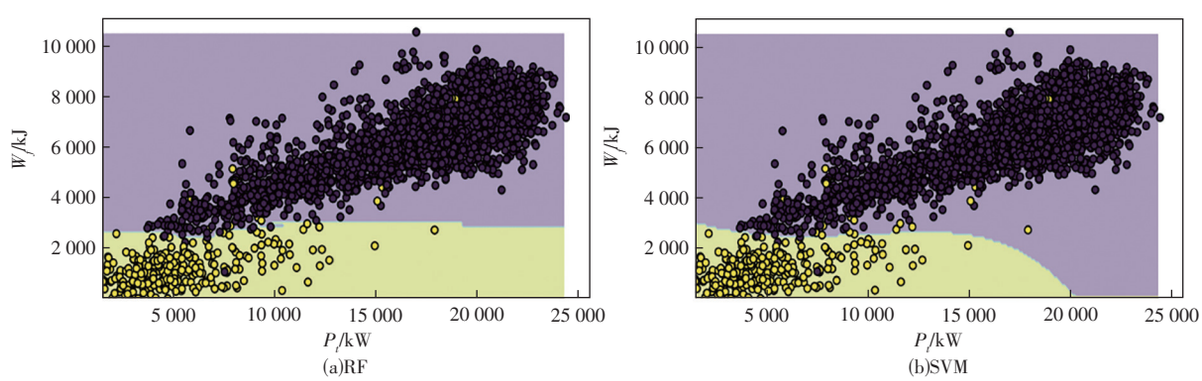


图7　RF与SVM可视化决策边界

Fig. 7　Visualized decision boundaries of RF and SVM

状态感知层完成了从特征空间向状态空间的映射，通过知信机器学习实现了装备、地质及风险的快速识别，为施工提供了实时状态认知。上述结果既能服务于监测、诊断和预警，也为时空分析层的演化建模提供了初始状态基础。

3 基于深度学习的时空分析

状态感知层提供了当前时刻局部区段的“快照式”，但无法揭示围岩、设备及掘进风险的连续演化规律。时空分析层的核心任务是回答“状态如何演化”，即在状态感知的基础上，建立向演化空间的映射，实现从静态认知到动态认知的提升。对于具有强时变性和空间非均质性的深部金属矿山，真正影响决策的是未来演化趋势与突变时机。因此，时空分析层通过深度学习方法对状态演化进行建模，主要包括围岩变化边界感知、可掘性表征及运行响应预测三个部分。

3.1 围岩变化边界感知

围岩变化边界是地层性质发生变化的重要过渡区域，也是设备负载波动和施工风险增加的关键位置。在深部矿山中，岩性转换、断层破碎带及软硬岩交界区域常伴随高应力释放，其对应的设备响应呈现复杂渐变过程。前述方法将地层视为独立离散变量，忽略了非突变边界，即过渡区的连续演化特征，导致边界滞后识别和状态振荡等问题。

本文将围岩边界识别重新定义为面向地层演化过程的动态感知任务。考虑到边界区域同时包含长期地质背景信息、局部扰动信息及周期性破岩特征，构建融合多尺度时序特征的深度感知模型(图8)，通过长期趋势分支提取围岩性质缓慢变化特征，局部动态分支捕获边界附近的短时扰动，周期分支学习稳定破岩过程中的重复模式，并以注意力机制实现多尺度信息融合。

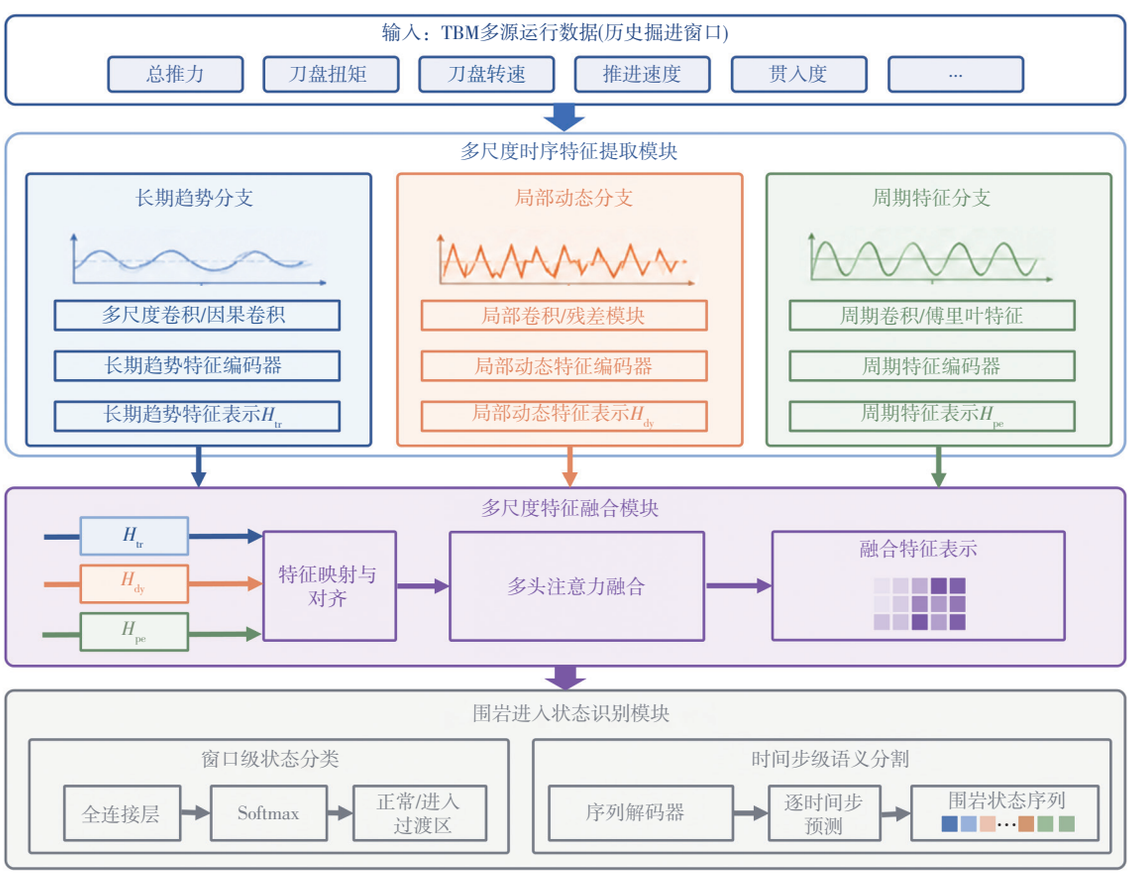


图8 面向过渡区间的多分支围岩进入状态识别模型总体结构

Fig. 8 Overall structure of the multi-branch recognition model for surrounding rock entry state in transition zones

在窗口级分类任务中，该模型取得了0.928 8的宏平均F1值以及0.984 4的宏平均受试者工作特征曲线下面积(AUC)；在时间步级围岩语义分割任务中，模型的平均交并比(IoU)达到了0.799 5，平均F1值达到0.886 8。与多层感知机(MLP)、长短期记忆网络(LSTM)、时间序列分块Transformer模型(PatchTST)及图卷积网络(GCN)等主流基线模型相比，该方法在包含复杂混合响应的过渡区段内展现出

显著优势，平均分类准确率达到 0.91，大幅优于对比模型。

3.2　可掘性语义表征

边界感知能够识别“地层正在变化”，但无法解释“这种变化对 TBM 施工意味着什么”。传统围岩分级体系主要服务于稳定性评价和支护设计，侧重工程地质属性，而非 TBM 破岩行为。特别是对深部金属矿山，同一围岩级别下，因地应力水平、节理发育程度及矿岩组合不同，岩体可掘性可能差异显著，传统标签难以准确描述真实施工难度。

为此，本文提出面向 TBM 施工过程的可掘性表征方法，将围岩等级视为弱监督语义约束，引导模型从运行数据中自主学习反映破岩难易程度的连续表征空间[26]。如图 9 所示，该方法利用局部响应相似性和地层连续性约束构建深层特征表示，通过弱监督学习保留传统工程经验所蕴含的宏观语义，同时利用数据驱动方式挖掘运行数据内部隐藏的结构规律。

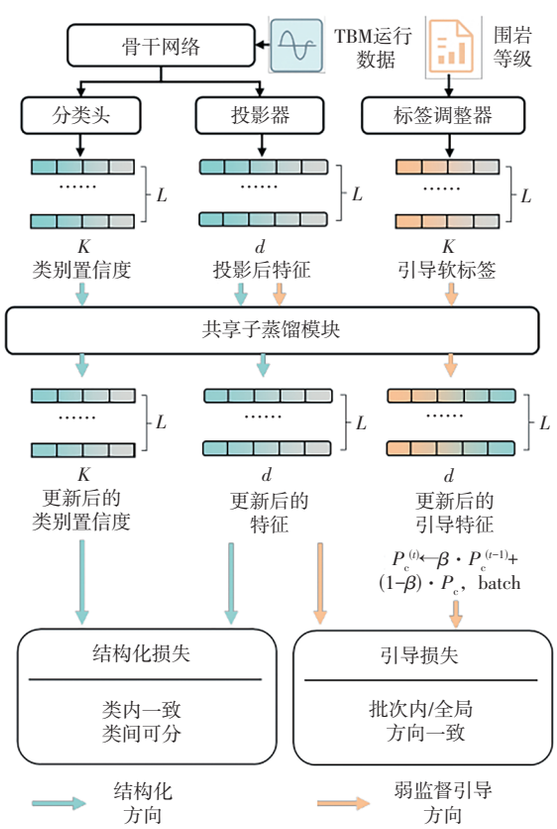


图 9　弱监督结构感知表征框架的整体网络架构

Fig. 9　Overall network architecture of the weakly-supervised structure-aware representation framework

实验表明，学习所得的表征在区段尺度上与传统分级标签一致性达 0.76，且对隐伏破碎带等不良地质具备更高的敏感性，能有效前置识别传统标签未能涵盖的局部高风险异常。在下游载荷参数预测任务中，以该可掘性表征替代传统标签作为先验输入，主流机器学习模型的 R^2 获得了 9.8% 至 34.3% 的显著提升。

3.3　未来运行响应预测

围岩边界感知揭示了“何时发生变化”，可掘性表征解释了“变化对 TBM 掘进性能和施工难度的影响”，但智能掘进最终仍需回答“未来将发生什么”。TBM 运行响应是人 - 机 - 岩共同作用的结果，具有显著的时变性和累积效应。尤其在深部复杂地层条件下，未来响应不仅受到历史运行状态影响，还受到前方待掘地质环境以及操作参数调整的约束。传统时间序列模型多依赖历史观测，难以充分考虑未来施工行为和地质语义，长时序预测中容易出现误差累积和漂移。

本文构建了融合历史响应、控制行为及地层语义的运行响应仿真模型(图 10)[27]。模型以历史状态为动力学基础，以未来控制参数为主动干预变量，引入可掘性表征作为地质先验，通过结构化注意力机制实现多源信息融合与联合预测。该框架在底层解耦并构建了三条并行的特征演化通路：1) 历史响应通路：利用时序卷积网络(TCN)编码自回归规律，捕获系统动力学惯性；2) 未来控制输入通路：显式嵌入参数化的前瞻性操作指令序列，以评估不同决策对系统响应的主动效应；3) 语义特征通路：将上文获取的离散可掘性表征与开挖工况进行向量化映射与对齐。模型引入结构化注意力，在时域与通道域构建分层权重矩阵，自适应融合历史惯性、未来指令与地质语义。

面向未来 30 个时间步(约等效于步长为 1.5 m 的 TBM 单次掘进长度)的长序列仿真实验，模型对 F 和 T 的预测 R^2 分别达到 0.941 2 和 0.935 6，平均绝对百分比误差(MAPE)控制在 4.2% 以内。相较于标准 Transformer 等模型，其累计误差发散速率降低约 28.4%，展现出卓越的稳定性，为金属矿山 TBM 掘进参数的动态寻优提供了可靠的虚拟仿真平台。

时空分析层完成了由状态空间向演化空间的映射，通过围岩变化边界感知、可掘性表征及未来运行响应预测，实现了对 TBM 施工过程的动态认知，为决策生成层提供了时空演化的信息基础。

4　基于大语言模型的决策生成

数据认知层实现了多源异构数据向统一特征空间的映射，状态感知层完成了装备状态、地质状态及

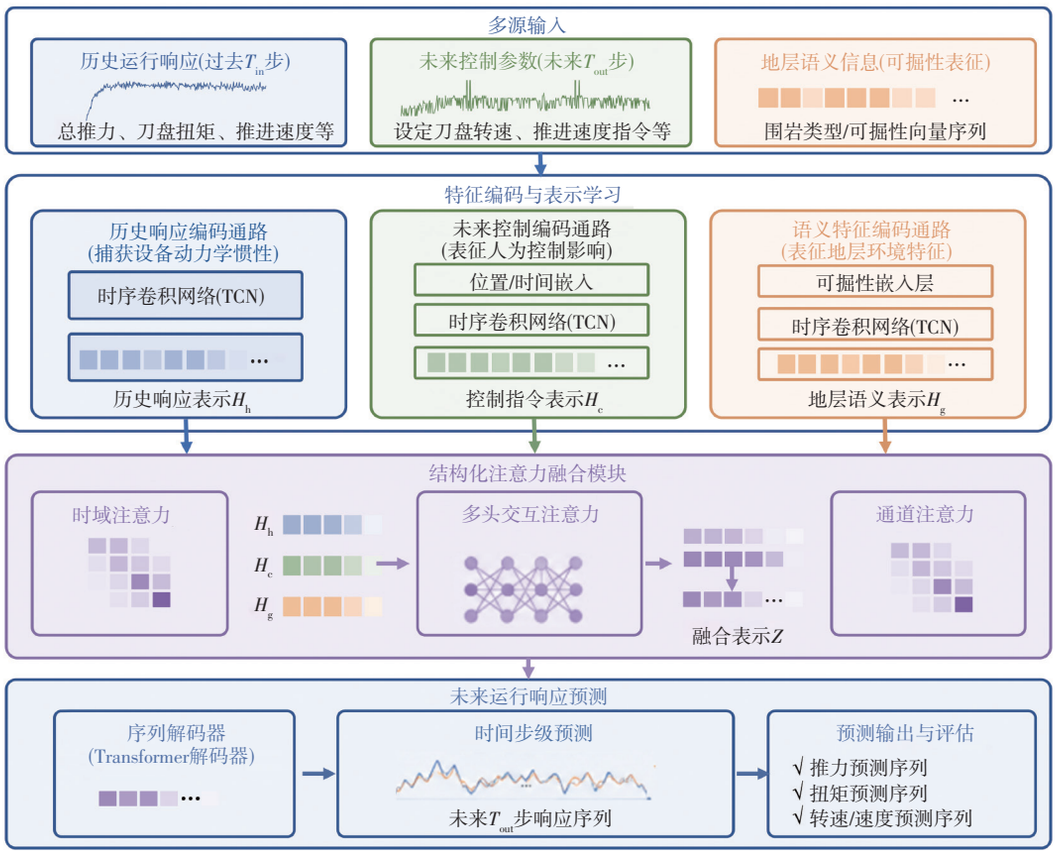


图 10　基于结构化注意力的TBM运行响应仿真模型总体框架

Fig. 10　Overall framework of TBM operational response simulation model based on structured attention

风险状态的识别，时空分析层进一步揭示了围岩条件与设备响应的演化规律。然而，对于实际工程应用而言，认知结果本身并非最终目标，其价值在于辅助施工人员进行参数调整、风险处置及施工组织优化。

对于深部金属矿山TBM施工而言，高地应力、高地温、多灾害耦合使施工决策具有更强的不确定性和时效性。工程人员不仅需要了解当前状态，更需综合分析未来趋势、历史经验以及施工规范，形成安全、高效且可解释的方案。传统人工决策存在认知负荷大、响应慢、难以充分利用高维认知结果等问题。随着大语言模型推理能力与工具调用能力的发展，其为构建能够理解工程语义、调用专业模型并生成决策建议的智能决策系统提供了新路径。

4.1　感知能力工具化封装

时空分析层的各模型能提供丰富的认知结果，但彼此独立，输出各异，难以直接参与复杂决策过程。大语言模型虽然具备语义理解能力，却无法直接处理高频时序信号。因此，需要建立连接认知模型与决策系统的统一接口。为此，本文采用工具化封装思想，将前述状态感知与时空分析模型抽象为具有独立功能的认知工具。各类模型通过标准化接口向外提供状态感知、边界感知、风险评估及未来预测等能力，并统一输出结构化结果。通过这种方式，原本分散的算法模型被转化为可被大语言模型自主调用的专业技能模块。

在运行过程中，当系统接收到实时监测数据或操作人员提出诊断请求时，大语言模型首先解析任务目标，识别当前决策需求，并自主选择所需认知工具进行调用。各工具完成推理后，将状态结果、风险概率及预测信息返回至决策中枢，从而实现认知能力的统一调度与协同利用。工具化封装成功建立了从底层感知模型到高层语义决策之间的桥梁，实现了认知能力的模块化组织与动态编排。

4.2　基于知识图谱的因果推理

感知模型能识别当前状态和预测未来趋势，但其输出主要反映数据层面的统计规律，难以回答“为什么会发生”以及“如何处置”等操作层面的问题。为增强决策系统的工程知识理解能力，本文构建TBM施工领域知识图谱(图11)，以施工机理和工程规范为指导，建立地质环境、设备系统、施工行为、运行响应

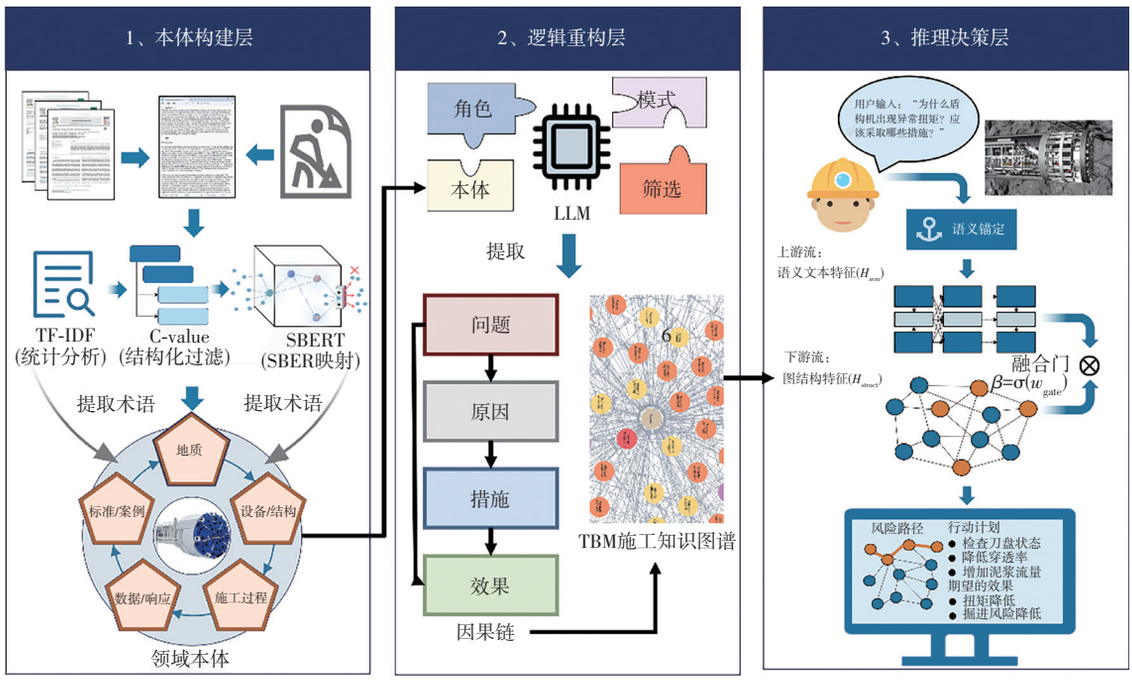


图 11　融合领域本体约束与图谱推理的神经符号双驱动决策框架

Fig. 11　Neuro-symbolic dual-driven decision framework integrating domain ontology constraints and knowledge graph reasoning

及工程案例之间的关联，将长期积累的工程经验转化为可计算的知识网络[28]。该图谱特别融入了深部金属矿山典型的灾害链式演化关系，如“高应力→岩爆”、“断层破碎带→塌方”等因果路径，使其更贴合矿山工程实际。

在此基础上，构建融合语义理解与图结构推理的因果分析机制。当感知模型发现推力异常增大、扭矩波动或围岩突变时，系统将异常特征映射至知识图谱中的对应实体节点，沿因果链推理分析，关联历史案例、设备故障机理及地质演化规律，追溯异常产生原因，并识别潜在风险传播路径。该机制能够将设备异常、围岩变化及施工风险纳入统一知识框架，实现从“状态异常”到“原因分析”的认知提升，为决策生成提供逻辑依据，同时增强决策过程的可解释性和工程可信度。

4.3　多维证据融合与决策生成

实际工程决策需综合考虑监测数据、模型预测、领域知识及历史经验。不同证据来源存在认知粒度差异和不确定性，而仅依赖单一信息源容易导致误判。因此，如何实现多维证据融合并形成可靠决策，是智能掘进系统的核心任务。

基于工具化感知和知识推理，本文构建多维证据融合决策机制。大语言模型作为统一中枢，同时接收来自状态感知层和时空分析层的量化结果，以及知识图谱提供的因果解释和案例信息。通过链式推理建立由状态感知、风险评估、原因解释及处置建议组成的完整推理链。

当证据间出现冲突时，系统引入基于工程安全原则的仲裁机制，动态评估证据可信度。对于深部矿山典型高风险场景，优先采用保守决策策略，提高预警等级；对于低风险场景，则结合设备效率与施工目标进行综合优化，实现安全与效率的平衡。如图 12 所示，TBM 智能体将复杂认知结果转化为可执行的工程决策，包括风险预警信息、施工参数调整建议、设备维护策略及应急处置方案，以自然语言和结构化报告反馈给现场操作人员，实现智能决策与人机协同。

决策生成层完成了由演化空间向决策空间的映射，以大语言模型为中枢，综合调用专业感知模型、领域知识图谱及历史工程经验，生成施工策略、风险处置建议及参数优化等决策，最终构建了“数据认知 - 状态感知 - 时空分析 - 决策生成”四层递进式 TBM 智能掘进框架，为深部金属矿山 TBM 智能建造提供了完整的技术路径。



图12 TBM智能体

Fig. 12 TBM agent

5 结论

针对深部金属矿山TBM掘进过程中多源异构数据融合困难、复杂地层条件感知不足以及施工决策高度依赖人工经验等核心问题，本文从智能认知的视角出发，构建了面向TBM智能掘进的感知与决策框架，形成了从数据认知、状态预测、时空分析到决策生成的全流程智能化闭环，主要结论如下：

1）构建了面向“人-机-岩”耦合系统的数据认知层，实现了多源异构数据的统一表达。针对深部金属矿山TBM施工过程中设备运行、地质环境、施工行为三类数据来源多样、时空尺度不统一的特点，通过多源融合、时空对齐及特征工程，建立了融合机械响应、地质表征及物理衍生特征的统一特征空间，解决了“数据如何统一表征”的问题，为上层分析提供了共享数据底座。

2）构建了融合知识驱动与数据驱动的状态感知层，实现了由特征空间向状态空间的映射。通过装备、围岩及风险状态感知，建立了设备运行响应与围岩条件的关联，实现了对TBM当前运行状态及潜在风险的快速识别，回答了“当前工况状态是什么”，为施工监测、运行诊断及风险预警提供了可靠支撑。

3）构建了基于深度学习的时空分析层，实现了由静态状态认知向动态演化认知的提升。通过围岩变化边界感知、地层可掘性表征及未来运行响应预测，揭示了围岩与设备响应随时间与空间的演化规律，回答了“状态如何演化”，为复杂地质条件下的主动干预和动态调控提供了理论依据。

4）构建了基于大语言模型的决策生成层，实现了由认知结果向工程决策的转化。通过感知工具化封装、知识图谱因果推理及多维证据融合，建立了集状态识别、趋势分析、原因解释及决策生成于一体的TBM智能体，回答了“该如何处置”，实现了风险预警、施工参数优化及方案推荐等智能决策功能，提高了深部矿山TBM施工决策的自主性和可解释性。

综上，本文提出的“数据认知-状态感知-时空分析-决策生成”四层递进式智能体架构，贯通了深部金属矿山TBM施工从数据获取到工程决策的完整技术链路。各层之间形成了“数据→信息→知识→决策”的转化逻辑和“特征空间→状态空间→演化空间→决策空间”的逐层映射关系，最终构成“感知-认知-决策”的智能闭环，实现了由数据驱动向知识-数据双驱动、由被动响应向主动决策的范式转变。该框架不仅为深部金属矿山TBM智能掘进提供了统一的理论与技术路径，也为实现地下工程智能建造中多源感知、认知推理、自主决策三者深度融合提供了新的研究思路。

参 考 文 献

[1] 蔡美峰，薛鼎龙，任奋华. 金属矿深部开采现状与发展战略[J]. 工程科学学报，2019，41(4)：417-426.
Cai Meifeng，Xue Dinglong，Ren Fenhua. Current status and development strategy of metal mines[J]. Chinese Journal of Engineering，2019，41(4)：417-426.

[2] 刘泉声，潘玉丛，余宏淦，等. 深部金属矿山巷道TBM掘进技术应用现状及研究进展[J]. 有色金属(矿山部分)，2024，76(6)：25-41.
Liu Quansheng，Pan Yucong，Yu Honggan，et al. Application status and research progress of TBM tunnelling technology in deep metal mine roadways[J]. Nonferrous Metals (Mining Section)，2024，76(6)：25-41.

[3] 黄丹，杨小聪，陈何. TBM在地下金属矿山应用中的发展现状与趋势[J]. 有色金属工程，2019，9(11)：108-121.
Huang Dan，Yang Xiaocong，Chen He. Development status and trend of tunnel boring machine in underground metal mine application[J]. Nonferrous Metals Engineering，2019，9(11)：108-121.

[4] Huang Xing，Liu Quansheng，Shi Kai，et al. Application and prospect of hard rock TBM for deep roadway construction

in coal mines[J]. Tunnelling and Underground Space Technology, 2018, 73: 105-126.

[5] Cao Yupeng, Luo Wei, Xue Yadong, et al. Model-based offline reinforcement learning framework for optimizing tunnel boring machine operation[J]. Underground Space, 2024, 19: 47-71.

[6] Li Jianbin, Chen Zuyu, Li Xu, et al. Feedback on a shared big dataset for intelligent TBM Part Ⅰ: feature extraction and machine learning methods[J]. Underground Space, 2023, 11: 1-25.

[7] Xu Chen, Liu Xiaoli, Wang Enzhi, et al. Prediction of tunnel boring machine operating parameters using various machine learning algorithms[J]. Tunnelling and Underground Space Technology, 2021, 109: 103699.

[8] 周小雄，龚秋明，殷丽君，等. 基于BLSTM-AM模型的TBM稳定段掘进参数预测[J]. 岩石力学与工程学报, 2020, 39(增刊2): 3505-3515.
Zhou Xiaoxiong, Gong Qiuming, Yin Lijun, et al. Predicting boring parameters of TBM stable stage based on BLSTM networks combined with attention mechanism[J]. Chinese Journal of Rock Mechanics and Engineering, 2020, 39(S2): 3505-3515.

[9] Wu Yongxin, Yang Hanzhi, Zhang Houle, et al. Real-time prediction of tunnel boring machine thrust based on multi-resolution analysis and online learning[J]. Computer-Aided Civil and Infrastructure Engineering, 2025, 40(28): 5212-5227.

[10] Wang Kunyu, Zhang Limao, Fu Xianlei. Time series prediction of tunnel boring machine (TBM) performance during excavation using causal explainable artificial intelligence (CX-AI)[J]. Automation in Construction, 2023, 147: 104730.

[11] Li Jianbin, Chen Zuyu, Li Xu, et al. Feedback on a shared big dataset for intelligent TBM Part Ⅱ: application and forward look[J]. Underground Space, 2023, 11: 26-45.

[12] Zhang Qianli, Liu Zhenyu, Tan Jianrong. Prediction of geological conditions for a tunnel boring machine using big operational data[J]. Automation in Construction, 2019, 100: 73-83.

[13] Zhao Junhong, Shi Maolin, Hu Gang, et al. A data-driven framework for tunnel geological-type prediction based on TBM operating data[J]. IEEE Access, 2019, 7: 66703-66713.

[14] Zhang Chenhao, Wang Yu, Wu Leijie, et al. Physics-informed and data-driven machine learning of rock mass classification using prior geological knowledge and TBM operational data[J]. Tunnelling and Underground Space Technology, 2024, 152: 105923.

[15] Wu Zhijun, Huo Dongbo, Chu Zhaofei, et al. Advanced identification method for adverse geological conditions in TBM tunnels based on stacking ensemble algorithm and Bayesian theory[J]. Tunnelling and Underground Space Technology, 2025, 163: 106741.

[16] Lin Penghui, Wu Maozhi, Xiao Zhonghua, et al. Physics-informed deep reinforcement learning for enhancement on tunnel boring machine's advance speed and stability[J]. Automation in Construction, 2024, 158: 105234.

[17] Zhang Limao, Guo Jing, Fu Xianlei, et al. Digital twin enabled real-time advanced control of TBM operation using deep learning methods[J]. Automation in Construction, 2024, 158: 105240.

[18] Lin Penghui, Ji Ankang, Zhou Yunxiang, et al. Automated position control of tunnel boring machine during excavation using deep reinforcement learning[J]. Applied Soft Computing, 2024, 167: 112234.

[19] Cao Yuan, Li Shifan, Shen Qiping, et al. Intelligent dynamic control of shield parameters using a hybrid algorithm and digital twin platform[J]. Automation in Construction, 2025, 169: 105882.

[20] 李建斌，武颖莹，李鹏宇，等. 基于局部线性嵌入和支持向量机回归的TBM施工参数预测[J]. 浙江大学学报(工学版), 2021, 55(8): 1426-1435.
Li Jianbin, Wu Yingying, Li Pengyu, et al. TBM tunneling parameters prediction based on Locally Linear Embedding and Support Vector Regression[J]. Journal of Zhejiang University (Engineering Science), 2021, 55(8): 1426-1435.

[21] Zhang Yakun, Gong Guofang, Yang Huayong, et al. Precision versus intelligence: autonomous supporting pressure balance control for slurry shield tunnel boring machines[J]. Automation in Construction, 2020, 114: 103173.

[22] Bruland A. Hard rock tunnel boring: the boring process (Vol. 7)[D]. Trondheim: Norwegian University of Science and Technology, 1998: 7.

[23] Rostami J. Development of a force estimation model for rock fragmentation with disc cutters through theoretical modeling and physical measurement of crushed zone pressure[D]. Golden: Colorado School of Mines, 1997: 56.

[24] Zhu Mengqi, Gutierrez M, Zhu Hehua, et al. Performance Evaluation Indicator (PEI): a new paradigm to evaluate the competence of machine learning classifiers in predicting rockmass conditions[J]. Advanced Engineering Informatics, 2021, 47: 101232.

[25] Zhu Mengqi, Zhu Hehua, Gutierrez M, et al. Predicting tunneling-induced ground collapse based on TBM operational data and geological data[J]. International Journal of Computational Methods, 2022, 19(8): 2142015.

[26] Yao Dansheng, Zhu Mengqi, Zhu Hehua, et al. A weakly supervised prototype-based network for excavatability-oriented ground condition representation in TBM operations[J]. Advanced Engineering Informatics, 2026, 74: 104644.

[27] Yao Dansheng, Zhuang Xiaoying, Zhu Mengqi, et al. Semantic fusion and structured attention for intelligent simulation and optimization in underground excavation[J]. Automation in Construction, 2026, 189: 107050.

[28] Bai Mengqi, Zhu Mengqi, Zhu Hehua, et al. OC-LLM: a causal decision-making framework for TBM construction integrating ontology-constrained LLMs with knowledge graph reasoning[J]. Advanced Engineering Informatics, 2026, 76: 105017.