自学习驱动的混合知识推理：方法与案例

田玲[1)] 周靖人[2)] 胡新哲[1)] 张谨川[1)] 丁博麟[2)] 李雅亮[2)]

[1)](电子科技大学, 计算机科学与工程学院, 成都 611731)

[2)](阿里巴巴集团, 通义实验室, 杭州 310051)

摘 要 知识推理作为人工智能迈向认知智能的关键阶段，正经历从符号逻辑向神经符号协同的计算范式变革。针对大语言模型（Large Language Model, LLM）在逻辑严谨性上的固有缺陷，传统知识图谱（Knowledge Graph, KG）在知识更新与泛化能力上的不足，本文论述了知识推理框架的理论方法、核心设计与应用实践，并构建了一种“自学习驱动的混合知识推理”的通用框架。该框架设计了归纳、演绎与溯因三种推理方法的动态协同机制，并有机融合归纳学习、优化学习与反向学习。在归纳推理中，利用大模型的语义抽取能力，自动化归纳学习领域知识；在演绎推理中，利用知识超图逻辑基座，增加确定性约束与事实校验，动态优化学习进行预测；在溯因推理中，利用历史数据进行反向学习，得到可解释性归因。为了验证该框架在处理复杂逻辑约束与高风险动态下游应用中的有效性，本文定义了千问大模型（Qwen）与知识超图的功能接口清单，并以工业规范作业管控场景为例，设计了该框架与 Qwen 适配的全流程。此外，在知识抽取、知识推理、报告生成等任务中，采用两套方案进行实验验证：一是仅由大模型完成推理，二是引入知识超图后的混合推理框架进行推理。实验结果表明，在 duee_test 测试子集上，引入知识超图后，两个测试集上的运行耗时均缩短 70%以上；同时，该框架在保证决策安全性的基础上实现了推理过程的透明化与可解释性，为强逻辑场景下的决策智能提供有效支撑。

关键词 知识推理；混合推理；大语言模型；知识超图；自学习

中图法分类号 TP18

Self-learning-driven Hybrid Knowledge Reasoning: Methods and Cases

Tian Ling[1)] Zhou Jingren[2)] Hu Xinzhe[1)] Zhang Jinchuan[1)] Ding Bolin[2)] Li Yaliang[2)]

[1)](School of Computer Science and Engineering, University of Electronic Science and Technology of China, Chengdu, 611731)

[2)](Alibaba Group, Tongyi Lab, Hangzhou 310051)

Abstract Knowledge reasoning is a critical capability for artificial intelligence systems progressing toward cognitive intelligence and is undergoing a paradigm shift from purely symbolic logic to neuro-symbolic collaborative reasoning. Large language models (LLMs) provide strong semantic understanding and generalization capabilities, but their reasoning processes may lack logical rigor, factual consistency, and controllability. In contrast, traditional knowledge graphs (KGs) support explicit knowledge representation and deterministic reasoning, yet they are often limited by high construction costs, weak adaptability to dynamic knowledge, and insufficient generalization. To address these complementary limitations, this paper

本课题得到国家自然科学基金面上项目（62376055）资助。田玲，教授，博士生导师，中国计算机学会（CCF）会员，主要研究领域为知识图谱、知识推理。周靖人，博士，ACM Fellow，IEEE Fellow，主要研究领域为人工智能、大模型。 胡新哲，博士研究生，主要研究领域为大模型、知识推理。张谨川，博士，博士后，主要研究领域为大模型、知识推理。丁博麟，博士，主要研究领域为机器学习、大模型。 李雅亮，博士，主要研究领域为机器学习、大模型。

systematically analyzes the theoretical foundations, core design principles, and application practices of knowledge reasoning, and proposes a general framework for self-learning-driven hybrid knowledge reasoning. The framework establishes a dynamic collaboration mechanism among inductive, deductive, and abductive reasoning and further integrates three corresponding learning paradigms: inductive learning, optimization learning, and backward learning. In inductive reasoning, the semantic extraction capability of LLMs is used to automatically identify domain entities, relations, events, and candidate rules from unstructured data, thereby supporting the continual acquisition and organization of domain knowledge. In deductive reasoning, a knowledge hypergraph is introduced as a logical foundation to provide explicit structural constraints, factual verification, and rule-based path restriction, while optimization learning is employed to adapt the reasoning process to dynamic task states and improve prediction reliability. In abductive reasoning, historical data and observed outcomes are analyzed in a backward manner to trace potential causes, identify logical breakpoints, and generate interpretable attribution results. At the architectural level, the framework combines an endogenous mode for coordinating different reasoning mechanisms with an exogenous mode for integrating external data and structured knowledge. Through the dynamic flow of information among observations, contextual clues, and persistent knowledge, the two modes jointly support knowledge acquisition, reasoning, verification, and update, forming a unified self-learning loop. To evaluate the applicability of the framework to complex logical constraints and high-risk dynamic downstream applications, this paper defines functional interfaces between the Qwen large language model and the knowledge hypergraph, and develops a complete adaptation workflow for an industrial standardized-operation control scenario. The workflow covers knowledge extraction, knowledge reasoning, and report generation, and is evaluated under two controlled settings: inference using the base LLM alone and inference using the same LLM augmented with the knowledge hypergraph. Experimental results show that, on the duee_test subset, introducing the knowledge hypergraph increases the composite extraction F1 score from 9.24% to 76.12%. Meanwhile, the total running time on both test subsets is reduced by more than 70%. These results indicate that the structured representation and rule constraints provided by the knowledge hypergraph can improve the precision and completeness of domain information extraction while reducing redundant search and generation during reasoning. More importantly, the proposed framework preserves the semantic flexibility of LLMs while introducing explicit logical constraints and traceable reasoning paths, thereby improving the transparency, interpretability, and controllability of the reasoning process. The framework provides a practical approach for integrating data-driven intelligence with structured knowledge reasoning, and supports reliable decision intelligent in applications that require strong logical consistency, dynamic knowledge adaptation, and decision safety.

Key words Knowledge Reasoning; Hybrid Reasoning; Large Language Models; Knowledge Hypergraph; Self-learning

1 引言

推理是人类对事物进行分析、综合和决策的基础认知过程。其过程表现为从已知的事实出发，通过运用已掌握的知识，找出其中蕴含的事实，或归纳出新的事实。形式上，推理可被定义为一系列能力的总称，涵盖了有意识地理解事物、建立和验证事实、运用逻辑，以及基于新的或存在的知识来改变或验证现有体系的能力。

知识推理是利用已知的知识推导出新知识的过程。在人工智能范畴内，这一定义被具体化为：人工智能系统利用已获取的知识（包括显式符号规则、隐式数据模式、模型参数化表示等），通过预设算法、逻辑规则或学习机制，推导出未知知识、隐含关系或解决方案的过程。

知识推理的发展历程系统性地反映了从形式化到智能化的演进。如图 1 所示其发展可划分为五个主要阶段：

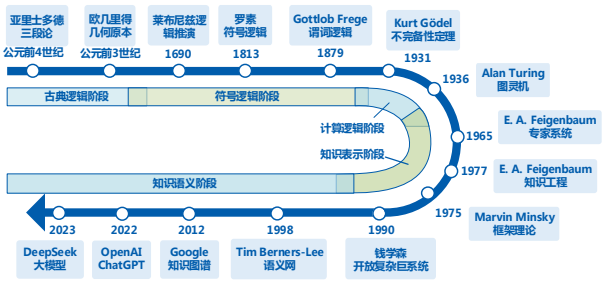

图 1 知识推理的历史发展

古典逻辑体系萌芽阶段：以亚里士多德提出的三段论为起点，将直觉性推理转化为可验证的规则体系[1][2]。

符号逻辑系统构建阶段：莱布尼茨开启了将推理转化为计算的尝试，弗雷引入谓词逻辑为推理提供了严格的符号框架。

形式理论与计算逻辑探索阶段：图灵提出的图灵机理论为后续用机器模拟人类推理奠定了基础。

知识表示发展阶段：专家系统的提出使人工智能研究从推理算法主导转向知识主导，知识工程随之兴起[3]。

知识语义阶段：语义网、知识图谱[4]及大语言模型[5][6]相继出现，推动知识推理进入跨学科融合与大规模应用的新时期[7]。

然而，无论是传统的符号推理、数据驱动方法，还是新兴的大模型，单一的推理范式仍难以同时兼顾逻辑严谨性与灵活泛化能力。例如，纯粹的符号推理难以处理现实世界中的模糊与不完备信息，而数据驱动的方法又常因其黑盒特性而缺乏可解释性与逻辑严谨性。这些局限性限制了知识推理系统在复杂动态环境中的应用效果和持续演化能力。

在此背景下，**混合知识推理**的概念应运而生，并逐渐成为研究热点。该方法通过融合联结主义与符号主义的优势，在推理过程中兼具泛化能力与逻辑精确性，从而构建更加高效、鲁棒且可信的知识推理系统。混合推理的核心优势在于：它不仅克服了传统符号主义方法在应用灵活性方面的固有局限，也在保证推理透明性与结论可靠性的前提下，有效缓解了深度学习模型面临的可解释性不足与鲁棒性欠佳等关键问题。

表 1 现有推理方法对比

推理方法分类		典型方法	主要优点	主要不足
古典逻辑	古典逻辑推理	亚里士多德三段论、欧几里得几何原本、莱布尼茨逻辑演绎	推理结构严谨、逻辑完备、结论可验证性强	过于依赖形式化前提，难以处理模糊性、不确定性与动态知识
符号逻辑	符号主义推理	专家系统、基于规则的推理系统	逻辑严谨、可解释性强、适用于结构化知识	知识获取困难、缺乏灵活性与迁移能力、难以应对动态环境
形式理论与计算逻辑	概率逻辑推理	贝叶斯逻辑、Markov 逻辑网络	能处理不确定性，支持多层知识融合	计算复杂度高、推理效率低、参数依赖性强
	数据驱动推理	机器学习、统计学习方法	学习能力强、适应性好、适合大规模数据	可解释性差、易受数据偏差影响、难以进行知识更新
知识表示	神经符号推理	神经网络 + 符号逻辑（Neural-LP、DeepProbLog 等）	结合符号逻辑的可解释性与神经网络的学习能力	模块间静态耦合，信息单向流动，缺乏动态交互机制
知识语义	知识图谱推理	知识图谱＋图卷积网络、关系图卷积网络（Relational Graph Convolutional Network；R-GCN）	支持显式知识建模、结构化表达良好、具备可扩展性	知识更新与推理过程割裂、推理深度有限、缺乏时间动态性
	大模型驱动推理	基于大型语言模型（GPT、PaLM 等）的混合推理	结合符号逻辑的可解释性与神经网络的学习能力	模块间静态耦合，信息单向流动，缺乏动态交互机制
	案例推理	案例库推理、ECBRF 等	可利用历史案例进行经验复用	依赖案例质量，难以生成新知识，泛化性不足
集成方法	多种推理方法集成	模块化封装的“串行管道”	集成多种范式、实现一定程度融合	推理流程静态、缺乏动态交互与知识反馈机制

当前混合推理研究聚焦在不同推理范式之间的深度融合与协同增效。如表 1 所示，现有研究多停留在松散耦合[8]、静态割裂[9]的集成层面，普遍遵循将一种或多种推理范式进行模块化封装的路径。这种设计忽视了知识与数据在推理过程中的动态流动与演化机制，不同推理单元之间缺乏动态的交互协同机制，难以充分模拟人类灵活的认知推理过程。导致推理流程相对固化、信息单向流动，形成了一种类似“串行管道”的静态结构。

为此，本文提出一种自学习驱动的混合知识推

理框架。旨在突破“静态割裂”的瓶颈。将推理过程解构为两个正交且互补的维度：其一为“内生模式”，聚焦推理机制的内部整合，通过归纳、演绎、溯因三种推理范式的动态协同与灵活切换，形成一个能力互补的统一推理内核；其二为“外生模式”，聚焦信息来源的外部协同，通过融合结构化的显式知识与数据驱动的隐含知识，实现面向开放环境的数据知识动态融合与协同演化。

本文的主要贡献包括：

（1）分析比较传统推理算法。传统符号推理虽具备逻辑严谨性与可解释性，但难以应对开放世界变化；而当前混合推理研究倾向于动态生成，未能实现归纳与演绎的有机协同。

（2）提出混合知识推理通用框架。创新性地构建了归纳、演绎与溯因的动态协同机制，有效结合了静态知识的确定性与动态生成的泛化能力，实现了推理过程中解释性、学习性与高效性的统一。

（3）比较分析了混合知识推理与大模型双向赋能的优势。从该框架与千问大模型在具体场景中结合应用为案例，在知识抽取、知识推理、报告生成等任务中采用两套方案，一是仅由大模型完成推理、二是引入知识超图[10]后的混合推理框架进行推理。验证了该框架处理复杂推理任务的有效性。

2 推理方法分类

根据美国实用主义哲学家皮尔士提出的推理三分法[11]，推理范式可划分为归纳、演绎与溯因三类。长期以来，人工智能领域通常将这三种推理模式视为彼此独立的静态任务。然而，从更高层次的视角观察，这三种推理形式分别对应从数据中提炼规律、从规则中推导结论以及从结果反推原因的不同认知路径。本节从“静态划分”的视角出发，对归纳推理、演绎推理与溯因推理的典型研究进行系统比较分析。

2.1 归纳推理

归纳推理是从有限实例中总结规律并将其推广应用于新情境的过程。其核心思想在于通过数据驱动的方式获取知识，与依赖既有规则的演绎推理形成互补。归纳推理在人工智能与机器学习中具有基础性作用，许多算法和模型的本质都体现了“由个别到一般”的逻辑，即从观测到的具体实例中提取可泛化的模式和规律，用以指导未知情境下的推理与预测。

归纳推理的常用方法包括规则学习、规则验证、规则优化等。

规则学习是从具体实例分析并总结出通用模式或规律的过程，其目的是将个别案例推广到一般经验。传统方法的研究重点主要集中于从结构化数据中挖掘统计模式或显式逻辑规则。代表性工作包括通过信息增益归纳分类规则的 C4.5 决策树[12]、用于发现“频繁项集”的 Apriori 关联挖掘算法[13]，以及通过归纳簇中心总结数据分布的 K-Means 聚类[14]。在函数关系方面，线性回归[15]提供了基础的函数拟合能力。随着研究深入，更特定的关联模式被探索，例如析取型关联规则[16]、图路径关联规则[17]，以及更鲁棒的聚类方法[18]。同时，函数拟合也从传统统计模型发展到基于深度学习的矩阵补全[19]和概率图模型（如马尔可夫逻辑网络[20]）。随着知识图谱（KG）的兴起，规则学习进一步向符号逻辑领域发展。归纳逻辑编程（Inductive Logic Programming, ILP）是该领域的早期代表，例如 nFOIL[21]探索了将朴素贝叶斯与 ILP 结合的方法。针对大型知识图谱，AMIE[1]及其高效改进版 AMIE+[22]是专门用于离线挖掘 Horn 规则的经典算法。Schoenmackers 等[23]则探索了从开放域 Web 文本中自动提取 Horn 子句的方法。

LLM 将规则学习范式从“统计挖掘”转换为“语义理解”，相较于传统方法，能够处理非结构化文本，同时具备零样本泛化能力。为评估其直接从自然语言事实中归纳规则的能力组合式语言理解与文本关系推理（Compositional Language Understanding with Text-based Relational Reasoning, CLUTRR）[24]为模型从文本中进行归纳推理提供了诊断基准。Rule[25]从人类认知的视角出发，探索了构建更类人的学习模型。在技术实现上，RNNLogic[26]利用循环神经网络与逻辑规则的交互，实现在知识图谱上从有限事实到通用逻辑规则的高效归纳与自动学习。

规则验证是评估一个已生成规则或假设的过程，其目的是通过分析新证据是“增强”还是“削弱”规则，判断该规则的正确性和可信度。传统方法通常依赖于人工构建的逻辑基准或特定的统计指标，侧重于评估模型在特定约束下的表现。为评估模型的验证能力，研究界提出了一系列基准。例如，Rudinger 等[27]的工作评估了模型在面对新证据时，是否能像“怀疑论者”一样进行可废止推理（即判断新证据是“增强”还是“削弱”一个已有假设）。Lampinen 等[28]进一步测试了模型在上下文中获得解释时，是否能正确泛化或修正已有假设。

LLM 的兴起使它成为规则的生成者，验证的重

点转向了其输出的逻辑一致性与事实准确性，相较于传统方法，在生成多样化假设方面表现更为出色。Chen 等[29]全面评估了其在归纳推理和问题解决上的能力，并与其模拟人类认知的过程进行对比。而在知识图谱领域，Tang 等[30]提出了 RulE 框架，通过规则嵌入的方式来校验 KG 推理的逻辑一致性。Pellegrina 等[31]研究了如何通过采样实现可扩展的规则列表学习，这本身也依赖于对规则的有效验证。

规则优化是系统通过反馈和迭代，持续改进、提炼或更新规则库的动态过程，其目的是提高规则的准确性和适用性。传统方法主要通过基于反馈的参数调整或可微的神经符号学习来实现，旨在提升规则库的精确度与覆盖率。例如 Huang 等[32]关注规则的时间有效性，提出了一种能根据新观察到的事实对规则库进行增量式修正的框架。为了将规则学习与深度学习的优化机制结合，可微规则学习成为热点。Minervini P 等[33] 进一步探索了可微证明中的推理策略优化，通过端到端的可微架构实现了复杂逻辑命题的自动化证明，增强了神经符号系统的可组合性。Gao 等[34]则实现了可微的一阶规则学习器。相应地，如何从这些可微模型中提取忠实的规则也成为关键，Finrule[35]和 Wang 等[36]分别在特征交互和忠实性提取方面进行了探索。

LLM 的出现开辟了“自我进化”的新路径，相较于传统方法具有更强的反思与规划能力，能够作为智能体主动探索环境反馈，实现超越传统参数优化的动态适应。ReAct [37]通过将思维链推理与外部环境动作进行深度协同，为模拟人类在开放领域下的推理过程提供了新的技术框架。TabLLM[38]证明了预训练语言模型在表格数据任务中具有显著的少样本泛化潜力，为跨模态逻辑建模提供了有力支持。此外，规则优化技术也被用于反向寻找 Datalog 引擎中的跨规则优化缺陷[39]。

2.2 演绎推理

演绎推理是从一般性前提推导出特定结论的必然性推理过程，其核心在于依据逻辑规则从已知规律中得出确定性结论。在人工智能与知识推理领域，典型应用包括逻辑证明、知识图谱补全、规则引擎推理、自然语言蕴含判断以及程序验证等。演绎推理具有保真性：若前提成立，则结论必然成立。这类推理强调从确定规则或公理出发，通过严格逻辑演算将潜在信息显性化，而不产生新的知识。

演绎推理的常用方法包括表示学习、规则泛化、规则匹配等。

表示学习是将符号信息映射为低维、稠密的表示向量，其目的是有效地捕捉数据中的潜在结构和语义关系。传统方法致力于将符号逻辑映射到低维向量空间，以便在保留逻辑结构的同时利用深度学习的计算优势。早期的知识图谱嵌入（Knowledge Graph Embedding, KGE）模型为演绎推理提供了基础表示，代表性工作包括基于关系建模的 RotatE[40]和基于张量分解的 RESCAL[41]。随后，更复杂的神经网络结构被引入，例如 ConvE[42]利用卷积神经网络进行 2D 知识图谱嵌入，而 R-GCN[43]则使用图卷积网络来建模关系数据。为了更好地支持多跳逻辑推理，研究者进一步设计了更具针对性的嵌入方法。例如，Query2box[44]使用“盒子”嵌入在向量空间中进行推理，而 Beta Embeddings[45]则利用 Beta 分布的概率特性来处理更复杂的多跳逻辑。Pan 等[46]系统性地构建了表示学习技术路线图，为知识推理研究提供了理论指引。

规则泛化是对已有规则进行精炼或简化的过程，其目的是使这些规则能够应用于未曾见过的新实例上。传统方法主要关注如何通过网络结构设计，使模型具备类似于人类的组合性与系统性思维。一个核心挑战是模型是否能将训练中见过的元素组合成新颖的组合，即组合性泛化。Riveland 等[47]的研究表明，自然语言指令可以诱导神经网络实现组合泛化。Loconte 等[48]探索了如何将 KGE 转化为生成模型以提升泛化能力。泛化能力也体现在系统性和迁移能力上，如 Hu 等[49]对零阶随机梯度下降（Stochastic Gradient Descent, SGD）稳定性的研究。Qi 等[50]结合结构化知识和文本知识来提升归纳式 KG 补全的泛化能力。Liu 等[51]则研究了大型知识图谱上的“迁移规则学习”。

LLM 的出现将规则泛化推向了新的高度，相较于传统方法，展现了惊人的上下文学习能力。研究者更关注其是否真正掌握了逻辑规则的本质，例如，Zeng 等[52]提出将其与基于规则的决策系统进行对齐，以提升其泛化的鲁棒性。Bai 等[53]设计了一个从从一般到具体（General-to-Specific, G2S）的学习框架，利用 LLM 进行时序知识图谱的补全。

规则匹配是规则的执行过程，其目的是系统从一组已知事实出发，遵循给定的规则路径，推导出逻辑上的必然结论。传统方法多致力于利用神经网络或强化学习算法，在巨大的搜索空间中高效寻找逻辑路径。DeepPath[54]是一个早期的代表性工作，它使用强化学习方法在知识图谱中进行路径发现。

演绎推理的本质是逻辑蕴含，后续研究也从此角度切入。Tafjord 等[55]开发的 ProofWriter 模型，能够生成自然语言的蕴含、证明和溯因语句。Dalvi 等[56]则通过“蕴含树”来解释答案。

LLM 促使规则匹配向“神经-符号协同”模式演进，利用其自然语言理解能力作为“翻译器”或“调度器”，结合传统求解器的严谨性，成为了解决复杂匹配问题的有效途径。Pan 等[57]提出的 Logic-LM 框架，授权 LLM 使用外部符号求解器来保证演绎的鲁棒性。Sun[58]等则评估了其在超越指令遵循之外的“推理性规则遵循”能力。Ling 等[59]甚至使用演绎验证来核查其思维链（Chain-of-Thought, CoT）推理过程推理过程。

2.3 溯因推理

溯因推理从观测到的现象出发，推断最可能的原因，是一种非演绎性的推理形式。其核心目标是通过有限证据和已知信息，寻找能够合理解释观察结果的假设。不同于演绎推理的“由一般到特殊”或归纳推理的“由特殊到一般”，溯因推理遵循“从结果到原因”的逻辑，其重点在于识别本质原因，排除干扰因素，从而为下游任务提供可靠的解释与决策依据。这一特性使溯因推理在高度依赖可解释性的场景中，如医学诊断、事件因果分析及风险评估等，具有重要价值。溯因推理的常用方法包括假设生成、因果发现、事件归因等。

假设生成是根据观测现象生成潜在“原因”或“缺失前提”的过程，其目的是提供能够合理解释这些现象的候补假设。传统方法侧重于理论框架的构建以及基于特定领域知识的符号生成。随着 Transformer 架构的成功，研究者开始利用其强大的生成能力进行溯因。COMET[60]是基于 Transformer 自动构建常识知识图谱的经典模型。AbductionRule[61]则专门训练 Transformer 来解释“意外”的输入。ProofWriter[55]不仅能进行演绎，也能生成溯因假设语句。

LLM 具有显式推理能力，相较于传统方法能够实现生成过程的可控性与演化性。Gao 等[62]提出了可控的逻辑假设生成框架 CtrlHGen 用于知识图谱。Movva 等[63]则尝试利用稀疏自动编码器（SAE）从其内部探测假设的来源，以理解其生成机制。

因果发现是从观测数据中推断变量之间因果关系的静态过程，其目的是揭示数据生成背后的底层因果结构，并区分出真正的因果效应与虚假的统计相关性。传统方法主要依赖于统计独立性测试与因果结构学习算法，致力于从观测数据中剥离出真实的因果骨架。该领域的发展依赖于理论与基准，例如 Mooij 等[64]提出的 Tübingen 因果基准，为从观测数据中区分因果提供了方法和基准。Ganian 等[65]从计算复杂性的视角重新审视了因果发现算法。

LLM 的介入打破了仅依赖统计数据的局限，相较于纯数据驱动的方法，利用海量世界知识辅助因果推断。Kıcıman 等[66]系统性地探讨了其在因果推理中的应用，特别是利用世界知识进行“基于知识的因果图生成”。Wang 等[67]提出的 Scimon 则专注于利用 AI 生成具有“新颖性”的科学灵感（假设）。

在具体事件层面，Liu 等[68]提出了知识增强的事件因果识别方法。Du 等[69]开发的 ExCAR 框架，则利用因果事件图和神经逻辑网络来进行可解释的因果推理。

事件归因是追溯已发生事件关键因素或根本原因的动态过程，其目的是为事件的发生寻求合理解释，并评估不同因素对结果的贡献程度。传统方法常结合时序知识图谱（Temporal Knowledge Graph, TKG），通过逻辑规则与常识推理来填补缺失环节。例如，Cüppers 等[70]通过本地因果归因来从事件序列中发现因果。Niu 等[71]利用逻辑和常识引导 TKG 补全，Wang 等[72]则利用 LLM 引导动态自适应的 TKG 推理。

LLM 出现后，事件归因开始利用其强大的叙事理解与跨模态处理能力，相较于传统方法在解释事件深层机制上更具优势。Koupaee 等[73]利用生成的事件因果图作为辅助机制，帮助其明确事件间的因果关系，进而用于事件预测与解释。Liu 等[74]进一步将这一问题扩展到跨模态领域，探索了事件级的视觉问答（VQA）因果推理。

在上述三种推理模式的神经符号化演进中，核心挑战是，如何平衡大模型的生成灵活性与符号逻辑的严谨性。目前，主流的融合方案主要包括以检索增强生成（RAG）为代表的“外挂语料型”和以 KG-BERT[4]为代表的“特征增强型”。相较而言，RAG 方法主要侧重于通过语义空间的文本检索来缓解幻觉，但在处理长链条逻辑推演时仍存在模糊性；KG-BERT 等方法则侧重于利用 LLM 对知识图谱三元组进行语义向量化，难以直接处理复杂的因果逻辑与时序约束。本文提出的混合推理框架设计内生模式与外生模式的解耦协同机制，缓解了 RAG 方法处理长链条逻辑推演时存在的模糊性问题；并利用知识超图提供的显式符号约束与确定性演化

路径，缓解了 KG-BERT 类方法难以直接处理复杂因果逻辑与时序约束的问题。

综上，本节按照推理的逻辑分类及研究领域对比分析了知识推理现有代表性算法，如表 2 所示。

表 2 代表性推理算法对比分析

推理模式		代表性算法	优势	局限
归纳推理	规则学习	C4.5 决策树[12], RNNLogic[26], Apriori[13], 关联规则挖掘[16], PARM[17], K-Means[14], SACC[18], 线性回归分析[15], DLMC[19], Markov Logic Networks[20], nFOIL[21], AMIE[1], AMIE+[22], SHERLOCK[23], HL[25], CLUTRR[24]	传统方法：1. 从结构化数据中挖掘统计模式和显式规则； 2. 从 KG 中生成形式化、可解释的 Horn 规则。 LLM 方法： 1. 处理非结构化文本，直接从自然语言中归纳规则； 2. 零样本泛化能力，生成多样化、精准的规则集。	1. 对噪声和稀疏数据鲁棒性差；易过拟合训练样本； 2. 开放域文本或长尾事实上迁移性弱； 3. 模型的归纳能力需专门的基准来评估和验证。
	规则验证	可废止推理任务与评估框架[27], multilevel modeling[28], RulE[30], 符号化评测[29], SamRule[31]	传统方法：1. 稳定评估模型特定逻辑约束下的表现；2. 侧重评估模型对已有假设的可废止推理和修正能力。 LLM 方法： 1. 更强的逻辑一致性与事实准确性；2. 通过规则嵌入等方式校验 KG 推理的逻辑一致性。	1. 验证标准依赖额外数据或假设（缺正例/负例）； 2. 对 LLM 生成的隐式规则，解释性和可验证性不足； 3. 引入了“幻觉”等挑战。
	规则优化	时序规则置信度模型[32], 可微证明中推理策略优化[33], DFORL[34], DiffNSR, Finrule [35], DRUM 规则优化[36], ReAct[37], TabLLM[38], CROOK[39]	传统方法：1. 通过迭代细化和增量式修正提升规则库的准确性和时间有效性；2. 结合深度学习的优化机制进行大规模优化。 LLM 方法： 1. 反思与规划能力（自我优化）；2. 作为智能体主动探索环境，实现动态适应。	1. 迭代过程可能引入“确认偏差”（重复强化错误）； 2. 需高质量的监督或反馈信号； 3. 优化目标多样（准确性、覆盖、可解释性）难以兼顾。
演绎推理	表示学习	RotatE[40], RESCAL[41], ConvE[42], R-GCN[43], Query2Box[44], BetaE[45], 系统建立表示学习技术路线[46]	1. 将符号逻辑映射到低维向量空间； 2. 支持复杂多跳逻辑推理。	1. 隐向量难以直接解释或映射符号规则； 2. 表示可能丢失结构化逻辑约束（如量词、可换位性）； 3. 组合推理与系统泛化能力有限。
	规则泛化	ADRD[52], Liu et al.[51], G2S[53], TE-rules[50], GenKGE[48], Instruction-conditioned Sensorimotor RNN[47], ZO-DSGD[49]	传统方法： 通过网络结构设计实现组合性泛化，模仿人类的系统性思维。 LLM 方法： 1. 强上下文学习能力和零样本泛化潜力； 2. 与基于规则的决策系统对齐，提升泛化能力。	1. 量化泛化边界困难； 2. LLM 的泛化路径（CoT）可能含非形式化逻辑步骤，可靠性不足； 3. 推理机制的逻辑基础存在争议。
	规则匹配	DeepPath[54], ProofWriter[55], Entailment Tree[56], 推理规则遵循能力评估框架[58], Logic-LM[57], 思维链演绎验证框架[59]	传统方法：1. 利用强化学习在知识图谱中高效寻找逻辑路径； 2. 基于逻辑蕴含，生成可解释的证明过程。 LLM 方法： 1. 促使规则匹配向“神经-符号协同”演进，利用 LLM 作为翻译器和调度器； 2. 结合符号求解器，保证演绎的鲁棒性与严谨性。	1. 纯符号匹配在规模化知识库与不完备事实下效率低下； 2. 难以容忍噪声或模糊表述，对自然语言输入需额外解析； 3. 需要对齐其“推理性规则遵循”能力，以确保内在逻辑的一致性。
溯因推理	假设生成	CtrlHGen[62], COMET[60],	传统方法： 常识知识和溯因假设生成（基于	1. 难以保证候选的真实度与相关

	AbductionRules[61], ProofWriter[55], HypotheSAEs[63]	Transformer）。 LLM 方法：1.生成过程可控性与演化性；2. 探索 LLM 内部机制以理解假设来源。	度； 2. 生成模型易出现虚构/不可信假设； 3. 评估标准主观且难以自动化； 4. 假设的质量受模型本身知识限制。
因果发现	LLM 因果推理[66], Scimon[67], Causal Discovery[65], EMMG[68], ExCAR[69], ANM[64]	传统方法： 从观测数据中抽象因果骨架，测试基准广泛。 LLM 方法： 1. 打破仅依赖统计数据的局限，利用 LLM 的世界知识辅助因果推断；2. 适用科学发现场景。	1. 因果图的准确性和可信度需外部验证； 2. 纯从观测数据恢复因果关系存在不可辨识性（混淆变量、事实缺失）； 3. 对样本量、干预数据依赖强，噪声与时序错配影响大。
事件归因	CASCADE[70]， CCGG[73]，LCGE[71]， LLM-DA[72]，CMCIR[74]	传统方法： 1. 结合 TKG 进行归因； 2. 通过本地因果归因从事件序列中发现因果。 LLM 方法： 1. 强叙事理解与跨模态处理能力；2. 构建因果图。	1. 模型需应对动态因果关系的非平稳与延迟效应； 2. 事件序列存在观测缺失、异步与模态差异； 3. 跨模态归因的复杂性高。

2.4 知识推理常用数据集

数据集是评估混合知识推理框架性能的基石，决定了模型在不同逻辑模式下的泛化与适应能力。为了验证混合知识推理框架的有效性，表 3 梳理了主流的基准数据集，涵盖静态知识图谱、时序知识图谱及逻辑推理文本等多种模态。

表 3 知识推理常用数据集

推理模式	数据集	核心任务	统计规模				
			实体数（个）	关系数（条）	训练集（个）	验证集（个）	测试集（个）
归纳推理	FB15k-237[75]	基于密集图谱挖掘组合特征与规则	14541	237	272115	17535	20466
	WN18RR[42]	稀疏图谱下语义层级归纳	40943	11	86835	3034	3134
	NELL-995[76]	开放域含噪图谱路径发现	75492	200	126176	5000	5000
	CLUTRR[24]	从叙事文本中提取逻辑规则	-	22 种关系		灵活可变	
演绎推理	ICEWS14[77]	基于历史事实演绎未来事件趋势	7128	230	72826	8941	8963
	ICEWS05-15[77]	跨度十一年的长周期历史依赖推演	10488	251	386962	46275	46092
	GDELT[78]	海量流式数据的实时演绎	7691	240	2735685	341961	341961
	ProofWriter[55]	生成完整思维链	-	-	~280000	~40000	~80000
溯因推理	ART[79]	为观测结果选择最佳解释	-	-	169656	1532	13191
	Sherlock[80]	基于图像线索推断隐含原因	-	-	90000	6600	6600

归纳推理方面，数据集主要用于评估模型在不完备知识库中发现隐含模式与补全缺失事实的能力。FB15k-237[75]是从 Freebase 中抽取的经典基准。相较于原始 FB15k，它剔除了逆关系以防止信息泄露，强制模型学习“祖父 → 父亲”这类组合逻辑，极具挑战性。WN18RR[42]则源自 WordNet，包含 40943 个实体但仅有 11 种关系，图结构稀疏且呈现严格的层级特征，适合测试模型对层级语义规则的归纳能力。NELL-995 源自卡内基梅隆大学开发的永续语言学习器（Never-Ending Language Learner, NELL）项目[76]，保留了大量真实环境中的噪声与长尾数据，是验证模型在含噪环境下进行多跳归纳推理的理想基准。

此外，CLUTRR[24]提供了半合成的叙事文本，专门用于诊断模型从自然语言中归纳多跳关系规则（如$k = 2$到$k > 4$步）的系统性泛化能力。

演绎推理方面，数据集重点考察模型在时序动态变化或严格逻辑约束下的推演准确性。TKG 数据

集是此类任务的核心。ICEWS14[77]记录了国际政治事件的动态演化，包含 7128 个实体与 365 天的时间戳，评估模型基于历史事实序列演绎未来的事件趋势。ICEWS05-15[77]则提供了长达 11 年 4017 个时间戳的历史跨度，用于测试长程依赖下的逻辑推演。GDELT[78]是规模最大的社会事件数据库之一，包含超过 273 万条训练事件，时间粒度精细至 15 分钟，极高的并发性与噪声使其成为测试系统在高频流式数据下实时演绎能力的极限基准。此外，ProofWriter[55]等逻辑数据集要求模型生成完整的证明树，为验证演绎过程的显式逻辑链提供了监督信号。

3 混合知识推理方法

为克服传统混合推理框架中推理流程静态割裂、模块间缺乏动态交互的局限性，学者们开始探索更具适应性和透明性的混合推理框架。典型方法是将推理过程解耦为两种正交且互补的维度：内生模式和外生模式，以实现知识与推理的动态协同与自适应演进。

3.1 内生模式

内生模式聚焦于推理机制的内部整合，旨在打破不同推理范式之间的信息壁垒，通过将多种推理类型进行有机协同，形成一个能力互补、更为鲁棒的统一推理内核。

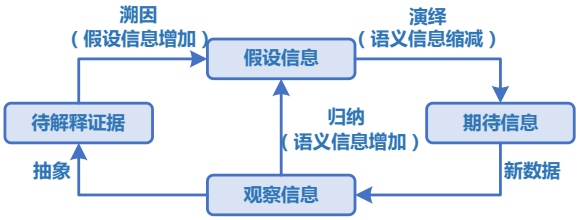

图 2 内生模式知识推理

图 2 中呈现了推理过程中的信息动态变化。推理主体以客观观察为起点，通过归纳推理分析前提对结论的支持度，从而生成一般性假设，此过程伴随着语义信息的扩充。同时，观察信息亦可被抽象为待解释的证据，经由溯因推理，为主体推断出可能的成因或解释，形成解释性假设，这一过程实现了假设信息的增殖。进而，从假设信息出发，通过演绎推理实现从前提到结论的逻辑映射，收窄可能情况的范围，并断定必然结论，由此获得期望信息；最后，借助新数据获取的观察信息对该期望进行验证，此过程则表现为语义信息的收敛。

溯因推理方面，数据集中包含的丰富因果链条能够为观测到的异常或结果生成合理解释。溯因推理任务（Abductive Reasoning Task, ART）[79]是首个大规模叙事溯因基准，包含约 2 万个叙事语境，要求模型根据两个观测事件（O_1, O_2）推断最可能的中间原因（H），直接对应了工业场景中根据故障现象反推原因的诊断任务。Sherlock[80]则将溯因扩展至视觉领域，包含 10.3 万张图像与 36.3 万条推论，测试模型基于视觉线索推断场景隐含意图的能力，可以验证混合推理框架向多模态推理迁移的潜力。这些数据集共同构建了从静态结构到动态时序、从单一模态到多模态的评估矩阵。

3.2 外生模式

外生模式聚焦于信息来源的外部协同，是指知识和数据的融合模式。

美国心理学家理查德·阿特金森和理查德·谢夫林提出多重记忆系统模型，将记忆分为：感觉记忆、短时记忆和长时记忆三个部分，其更新速度由快至慢、容量空间由少至多，奠定了人类认知过程中短期-长期记忆的整体框架，并提出三个记忆部分存在关联。该模型为动态混合知识推理的外生模式提供了理论方法基础。面对开放世界持续输入的数据信息，外生模式结合不同推理模式实现对数据的多阶段分析处理，并最终实现数据和知识的深度融合。

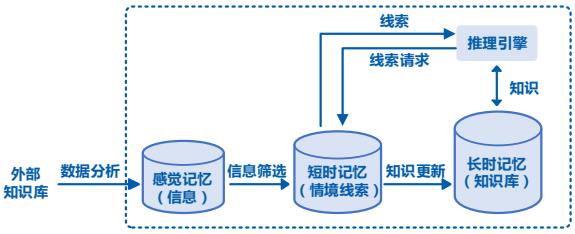

图 3 外生模式知识推理

图 3 呈现了外生模式推理过程中的信息动态变化。在推理任务执行过程中，外生模式支持从外部环境的持续数据获取，并通过协同归纳推理、演绎推理的数据分析机制，提取其中的信息作为感觉记忆。实时信息筛选与短期存储：感觉记忆中的信息，基于其可靠性、必要性，被筛选并移入短时记忆，作为推理线索，支撑非单调推理的决策。知识的固化与演进：短时记忆中的知识，在经过内生模式的推理验证后，可移入长时记忆（即知识库），从而完成知识库的持续更新与演进。联合驱动与动态流转：同时，内生模式可以围绕“事件”等推理对象，基于对象状态及中间推理结果，动态调整感觉记忆、

短时记忆中的信息，包括信息的补充、更新以及信息获取需求等。这种机制实现了数据和知识的联合驱动，使得推理方法从封闭处理模式转化为面向动态外部环境的信息流转模式。

3.3 混合知识推理框架

为进一步应对复杂动态环境中知识的演化与外部信息的不确定性，本文提出自学习驱动的混合知识推理框架，该框架以知识超图[10]为核心，动态协同归纳推理、演绎推理与溯因推理三大模块，协同运用归纳学习、优化学习与反向学习等方法，构建知识与数据双驱动的推理体系。如图 4 所示。

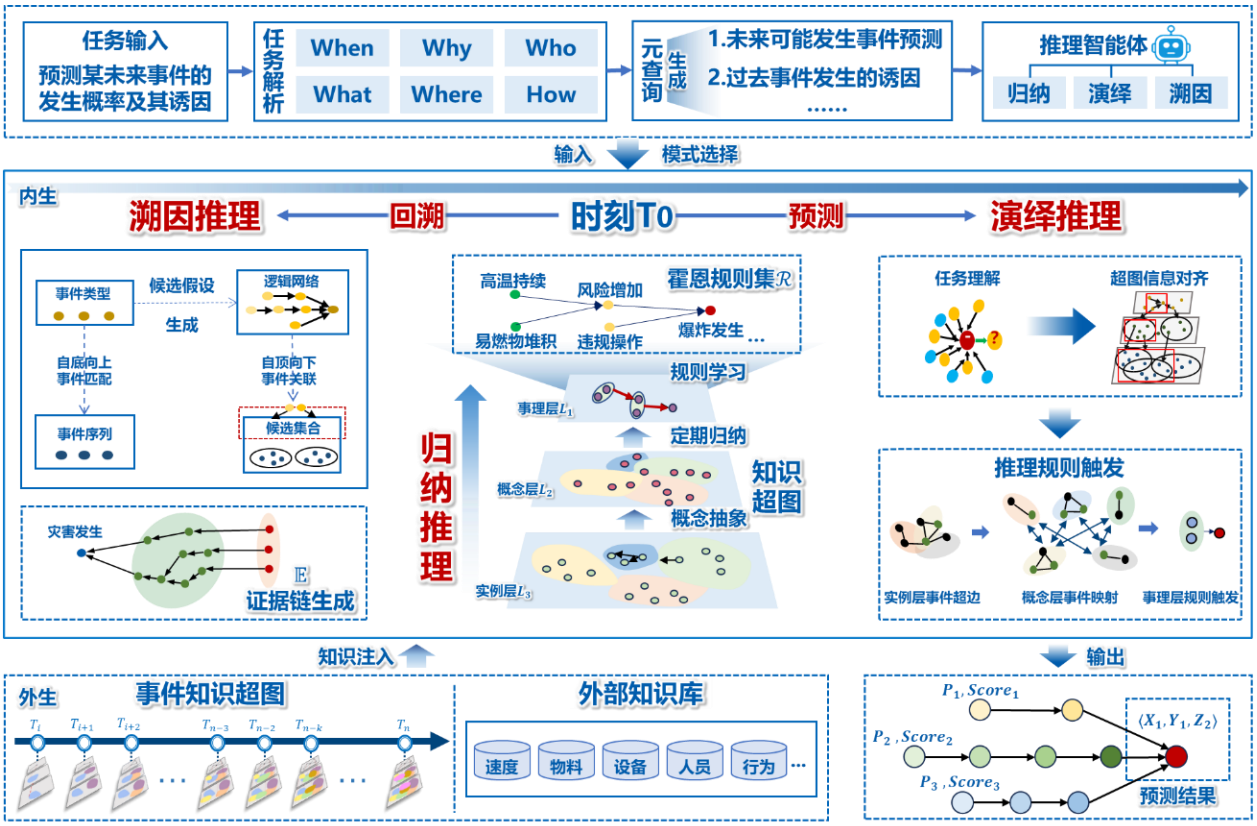

图 4 基于知识超图的混合推理框架

该框架由内生模式与外生模式协同驱动。首先利用推理智能体识别任务类型特征V，调用两大模式。在内生模式中，不同推理方式根据任务需求灵活协作，以事件预测为例，演绎推理主导事件演化趋势分析，溯因推理补充事件诱因与背景，归纳推理从目标事件中提炼模式以完善推理链条，形成自学习机制，确保了推理过程的可解释性与知识的自主进化。在外生模式下，框架通过推理智能体实现推理模式的动态切换。当输入非结构化领域文本D_{raw}时，激活归纳推理模式，利用归纳学习提取多维要素，输出霍恩规则集R并更新逻辑基座G；当接收到任务执行请求Q_{req}与多源状态数据S_{rt}时，框架切换至演绎推理模式，利用优化学习关联动态环境变化并施加确定性约束，输出推理路径P与对应的置信度分数$score$；当监测到非预期结果或观测到异常信号O_{obs}输入时，触发溯因推理模式，通过反向学习验证多源信息的合理性，并追溯底层逻辑断点以推断潜在诱因，输出相关事件集$\mathbb{E}$。上述流程如算法 1 所示。

算法 1．混合知识推理模式选择算法

输入：输入流I（包含$D_{raw}, Q_{req}, S_{rt}, O_{obs}$）；知识超图$\mathcal{G}$；

输出：霍恩规则集$\mathcal{R}$；推理路径 P 及其分数 $score$；相关事件集$\mathbb{E}$；更新后的知识超图$\mathcal{G}$

$V \leftarrow Intent_Recognition(I)$

IF V 涉及“多维协同任务” then

内生模式：

$P, score \leftarrow deductive_reason\ (\mathcal{G}, \mathcal{R})$

$\mathbb{E} \leftarrow abductive_reason\ (h_t^1, \mathcal{R})$

$\mathcal{R} \leftarrow inductive_reason\ (\mathcal{G}, \mathbb{E}_T)$

ELSE

外生模式

IF $D_{raw} \in I$ THEN

$\mathcal{R} \leftarrow inductive_reason\ (\mathcal{G}, \mathbb{E}_T, D_{raw})$

$G \leftarrow Update\ (\mathcal{G}, \mathcal{R})$

ELSE IF $\{Q_{req}, S_{rt}\} \subseteq I$ THEN

$P, score \leftarrow deductive_reason\ (\mathcal{G}, \mathcal{R}, Q_{req}, S_{rt})$

ELSE IF $O_{obs} \in I$ THEN

$\mathbb{E} \leftarrow abductive_reason\ (h_I^1, \mathcal{R}, Q_{req})$

IF $New\ Patterns\ Detected$ THEN

$G \leftarrow Self_Learning\ (\mathcal{G}, p)$

RETURN p, score, $\mathcal{G}$

在事件预测任务中，该框架通过三层知识超图构建历史事件间的时序、因果与关联结构，实现复杂场景下的模式发现与规则泛化。框架以超边结构表示事件的多维要素（实体、关系、时间等），并在概念层完成抽象映射，从而提炼出可迁移的高层逻辑规则。基于关联规则挖掘与置信度计算，框架自动生成事件演化的霍恩规则，用于指导未来事件的推理与预测。该框架有效提升了推理过程的可解释性和预测结果的泛化能力，为高风险场景下的智能决策提供了理论方法支持。

3.4 自学习混合知识推理算法

本文提出的混合知识推理过程包含三种推理动态耦合，也体现了三种学习方法在算法执行层面的深度集成。归纳学习实现了从海量原始数据到领域知识规则的自主发现；优化学习实现了推理逻辑约束与预测路径动态修正；反向学习实现了历史数据解析与逻辑归因。本节将详细阐述支撑自学习框架的具体算法流程。

归纳推理从现实世界的具体事件中得出事件发展的基本规律，形成逻辑规则。为了增强规则的适应性，归纳推理需要对历史事件进行挖掘和概括，经过规则挖掘和置信度验证，将逻辑规则以超边形式保留在事件规则层中。具体来说，归纳推理中目标事件类型对应于概念层超边。要获取规则，需要识别满足实例层超边条件的前序事件。对于每个目标事件类型，令h_C^{target}表示其对应的概念层超边，构建关联挖掘事务集。如算法 2 所示。

规则优化：通过归纳推理得到所有事件推理规则后，根据需要对事件规则层中存储的推理规则进行优化，其目的是增加推理规则的适用性，并通过减少推理规则数量来提高后续演绎和溯因推理的计算效率。

算法 2．混合知识推理中的归纳推理

输入：目标事件类型$\mathbb{E}_T = \{h_C^i | i = 0, \dots, n\}$，知识超图$\mathcal{G}$；

输出：霍恩规则集$\mathcal{R} = \{r_k | k = 0, \dots, n\}$.

FUNCTION *Pre_event_retrieval*(h_I^i):

$H_I[\,].push(h_I^i)$

WHILE $H_I \neq \emptyset$:

$h_I^t \leftarrow H_i.pop()$

FOR h_I^j in L_I

IF $\exists\ h_I^j.entity \in h_I^t.entities$:

IF $interval(h_I^j, h_I^i) < WINDOW$:

$H_I[\,].push(h_I^j)$

result[ ].append$\left(HKG_gen\left(h_I^j\right)\right)$

RETURN result

FOR h_C^i in $\mathbb{E}_T$:

$\mathbb{E}[\,] \leftarrow HKG_inst(h_C^i)$

$\mathbb{E}'[\,] \leftarrow [\,]$

FOR h_I^i in $\mathbb{E}$:

$\mathbb{E}'[\,].append\left(Pre_event_retreival(h_I^i)\right)$

$\mathcal{R}.append(rule_mining(\mathbb{E}'))$

$\mathcal{R} \leftarrow optimize(\mathcal{R})$

RETURN $\mathcal{R}$

演绎推理从真实事件出发，基于归纳推理得出的逻辑规则，匹配目标事件及其前序事件，递归计算事件的置信度。具体来说，针对当前发生的实例层超边事件h_C^1，首先构造前向超边事件集，然后通过逆向推理选取置信度最高的推理规则头作为最终的推理预测结论。如算法 3 所示。

算法 3．混合知识推理中的演绎推理

输入：前序事件集$\mathbb{E} = \{h_I^i | i = 0, \dots, n\}$，霍恩规则集$\mathcal{R} = \{r_k | k = 0, \dots, n\}$

输出: 推理路径P及其分数$score$

FUNCTION *deduction_reason*($\mathbb{E}, r_i$):

matched←*0*

$\mathcal{R}'[\,] \leftarrow [\,]$

FOR b_i in $r_i.body$:

IF $\exists h_I^i \in \mathbb{E}\ s.t.\ HKG_gen\ (h_I^i) \vDash b_i$:

$matched \leftarrow matched + 1$

ELSE IF $\exists r_j \in \mathcal{R}\ s.t.\ r_j.head \vDash b_i$:

$score', \mathcal{R}'' \leftarrow deduction_reason(\mathbb{E}, r_j)$

$matched \leftarrow matched + score'$

$\mathcal{R}'[\,].extend(\mathcal{R}'')$

ELSE RETURN 0, [ ]

$\mathcal{R}'[\,].append(r_i)$

$score \leftarrow \left(\frac{matched}{\#(r_i.body)}\right) * r_i.confidence$

RETURN $score, \mathcal{R}$

FOR $r_i \in \mathcal{R}$:

$score, \mathcal{R}' \leftarrow deduction_reason(\mathbb{E}, r_i)$

$result[\,].append((score, \mathcal{R}'))$

$P, score \leftarrow sort\ \&reconstruct(result)$

RETURN $P, score$

溯因推理从时间逆序的角度追溯事件因果链，生成证据链，通过考察线索之间的联系来增强推理结论的可靠性。对于当前发生的实例层超边事件h_C^1，首先构造一组导致实例层超边事件h_I^1发生的先行超边事件，然后通过逆向推理选取置信度最高的推理规则体，作为导致实例层超边事件h_I^1发生的原因解释。如算法 4 所示。

算法 4．混合知识推理中的溯因推理

输入：前序事件h_I^1，霍恩规则集$\mathcal{R} = \{r_k | k = 0, \dots, n\}$

输出：相关事件集$\mathbb{E}$

FUNCTION *abduction_reason*($h_C^1, r_i, \mathbb{E}'$):

IF $h_C^1 \vDash r_i.head$:

FOR $b_i \in r_i.body$:

IF $\exists h_I^i \in \mathbb{E}' s.t.\ HKG_gen\,(h_I^i)$:

$result[\,].append(h_I^i)$

ELSE IF $\exists r_j \in \mathcal{R}\ s.t.\ r_j.head \vDash b_i$:

$h_C^2 \leftarrow reflect(b_i)$

$results[\,].extend$

$\left(abduction_reason\left(h_C^2, r_j, \mathbb{E}'\right)\right)$

RETURN result

ELSE RETURN [ ]

$\mathbb{E}' \leftarrow pre_event_retrieval\left(h_I^i\right)$

$h_C^1 \leftarrow HKG_gen\,(h_I^1)$

FOR $r_i \in \mathcal{R}$:

$\mathbb{E}[\,].extend\left(abduction_reason(h_C^1, r_i, \mathbb{E}')\right)$

$\mathbb{E} \leftarrow filter(\mathbb{E})$

RETURN $\mathbb{E}$

算法内符号以及函数含义分别如表 4、表 5 所示。

表 4 符号注释表

符号	含义
V	任务特征向量
$\mathbb{E}_T$	目标事件类型
$\mathcal{G}$	知识超图
$\mathcal{R}$	霍恩规则集
h_I^i	实例层的第i条超边
L_I	实例层
h_C^i	概念层的第i条超边
$\mathbb{E}$	实例层超边集合
r_i	第i条规则
b_i	规则体
P	推理路径
$score$	置信度分数

表 5 函数注释表

函数	含义
HKG_gen(h_I^i)	实例层超边到对应的概念层超边的映射
HKG_inst(h_C^i)	概念层超边到对应的实例层超边的检索
pre_event_retrieval(h_I^i)	实例层特定超边的前序事件检索
rule_mining($\mathbb{E}'$)	规则挖掘算法

给出归纳、演绎与溯因三类基础推理算法后，可进一步将这些基本范式按照组合方式进行集成，以支持在知识超图上执行更复杂的混合推理任务。表 6 给出单模式与多模式推理的主要类别及其结构关系。

单模式推理是指针对特定业务目标，独立调用归纳、演绎或溯因算法中的某一种。它主要用于解决边界清晰的原子化任务；多模式推理是本框架实现“自学习”特性的核心，指在推理智能体的驱动下，多种推理模式按序协同或嵌套运行，形成协同推理机制。以多模式协同中的“归纳+演绎”范式为例，在面向业务的事件预测场景中，混合推理框架展现了显著优势。框架首先利用归纳推理从历史数据的知识超图结构中挖掘深层时序模式，将离散的实例事件通过概念层映射与关联挖掘，泛化为通用霍恩规则；随后，演绎推理以此规则库为逻辑基座，针对当前实时观测的事件序列进行确定性的前向推导。这种协同机制实现了从“历史模式发现”到“未来趋势预判”的逻辑演进，既发挥了归纳推理对动态规律的自适应提取能力，又通过演绎推理保证了预测结果的逻辑严谨性与可解释性，有效支撑事件预警及决策。

表 6 混合推理方法

推理方法		描述
单模式推理	归纳	历史事件 ➔ 普遍规律
	演绎	当前事件 ➔ 发展趋势
	溯因	当前事件 ➔ 发生原因

多模式推理	归纳+演绎	历史事件 → 普遍规律 当前事件 → 发展趋势
	归纳+溯因	历史事件 → 普遍规律 发生原因 ← 当前事件
	演绎+溯因	发生原因 ← 当前事件 当前事件 → 发展趋势 发生原因 → 相关事件 → 趋势理由
	归纳+演绎+溯因	历史事件 → 普遍规律 发生原因 ← 当前事件 当前事件 → 发展趋势 发生原因 → 相关事件 → 趋势理由

4 知识推理与大语言模型双向赋能

近年来，以LLM为代表的联结主义推理方法，凭借海量数据学习能力、卓越的自然语言理解与生成能力，以 CoT、RAG 等技术的应用，在多种复杂推理任务中取得了突破性进展。然而，LLM 仍面临推理过程缺乏解释性、难以实时更新知识以及存在“幻觉”现象导致逻辑严谨性下降等固有局限。

因此，将逻辑严谨的知识推理框架与泛化能力强大的 LLM 进行深度融合，已成为该领域的前沿方向。

4.1 知识推理赋能的大模型

该模式旨在利用知识推理框架（如知识图谱、符号规则）作为外部约束和事实来源，以增强 LLM 的可靠性、逻辑一致性和可解释性，克服其在严谨推理和知识准确性方面的不足。知识推理框架在这一过程中扮演着事实校验器和逻辑向导的角色。

知识语义理解：在知识表示层面，研究通过融合结构化信息的特征增强，将知识图谱的结构化特征（如节点度、关系类型）融入输入表示层。通过注入高质量的结构信息，使其能够更好地理解概念间的内在关联和拓扑特性，进而提升其语义理解的深度。

事实校验生成：在逻辑推理流程中，通过知识引导的思维链，要求 LLM 在生成每一步推理时，都同步生成针对外部知识库的查询以验证或补充事实。这使推理过程不再完全依赖其内部参数化知识，而是借助外部知识图谱或知识库提供的结构化证据进行动态修正和论证支撑，从而显著提升其在复杂多步推理中的逻辑鲁棒性。

推理逻辑向导：在智能体行为策略规划等应用场景中，知识推理框架还可将智能体的行为规划转化为目标导向的演绎推理问题，指导 LLM 生成并验证精确、可靠的动作序列，确保行为的安全性与逻辑性。

幻觉偏差缓解：在结果输出层面，知识推理框架作为独立的外部模块，充当事实核查与修正的角色，对生成内容中的事实性陈述进行审查。例如，通过逻辑检查器或嵌入模型评估三元组置信度，以缓解幻觉偏差，确保结论的准确性。

4.2 大模型赋能的知识推理

该模式旨在利用 LLM 强大的自然语言理解、语义抽取和泛化能力，弥补传统知识推理框架在知识获取、接口交互和语义建模上的局限性。LLM 在这一过程中扮演着语义处理器和前端接口的角色。

前端数据增强：知识抽取与语义增强方面，LLM 充当“知识抽取专家”，能够通过自动化方式实现大规模知识库的扩充，例如高效进行实体链接、关系抽取和事件模式识别。同时，还能为知识图谱中的实体和关系生成高质量、高泛化性的向量表示，提升基于嵌入的推理模型（如 TransE[81]、RotatE[40]）的性能。

后端推理辅助：在框架交互与接口构建方面，LLM 作为“智能翻译官”，将用户的自然语言问题转化为知识推理框架能够识别的形式化查询语言，如 SPARQL 协议与 RDF 查询语言（SPARQL Protocol and RDF Query Language, SPARQL）[82]、结构化查询语言（Structured Query Language, SQL）[83]或特定的规则查询，这极大地降低了知识推理框架的使用门槛和交互复杂度。

推理线索增强：LLM 的生成能力能够为传统的知识推理框架提供丰富的推理线索与假设生成，例如根据上下文生成多种解释性假设，然后由符号推理引擎进行验证和筛选，这有助于提高推理的效率和覆盖面。

4.3 大模型驱动的混合知识推理

该模式代表了 LLM 与知识推理的高级集成形式，其目标是构建一个动态的、相互调用的框架，实现两种模式优势的实时协同。旨在克服静态、模块化集成方法中，信息单向流动和推理链条割裂的不足，形成一种协同迭代的机制。

这种模式模拟人类“提出假说-验证-修正”的

认知过程，构建了一个动态、双向、迭代的推理框架。其运作流程主要分为三个阶段：首先是假设生成，利用 LLM 的泛化能力和创造力，根据用户输入或当前状态，生成初步的解决方案或假设（类似于溯因或归纳的初步尝试）。其次是验证与反馈，知识推理框架作为逻辑检查官，依据已有的结构化知识和规则，验证 LLM 生成的假设是否符合事实、是否存在逻辑冲突。最后是修正与迭代，如果存在冲突或不一致，知识推理框架会生成明确的“反例”或“修正建议”，并将其反馈给 LLM。此外，基于这些反馈修正假设，并生成新版本。循环上述过程直至结论在逻辑和事实层面都达到收敛。这种协同迭代模式兼具了其创造性和泛化能力与知识推理的逻辑严谨性，是未来混合知识推理研究的重要方向。

5 应用案例

混合知识推理已广泛应用于复杂场景的安全生产与管控决策等，其核心能力涵盖设备故障诊断、工艺参数优化、危险事件预测、合规性审查、风险溯因分析等。已广泛应用于金融、医疗、电力、冶金、石化等多个重点行业领域。

本节详细阐述了 Qwen3 30B 与知识超图逻辑底座组成的混合知识推理框架的落地应用实践。设计了对比实验验证该框架的有效性。主要通过三个关键步骤实现：1.知识库构建；2.知识推理；3.报告生成。

5.1 Qwen 与超图交互机制

Qwen 与知识超图之间的数据交互贯穿全流程。分为三个阶段，其中知识库构建属于知识超图构建，知识推理以及报告生成阶段则属于知识超图应用。其核心逻辑映射如图 5 所示。



图 5 Qwen 与知识超图数据交互

知识库构建阶段：数据流表现为“非结构化文档→结构化知识”。Qwen 利用其语义抽取能力，从化工标准作业程序（Standard Operating Procedure, SOP）、化学品安全说明书等文档中识别实体与规则意图，并将其转化为结构化的 API 调用指令，通过表 8 中的查询与统计接口校验并写入知识超图，构建起逻辑基座。

知识推理阶段：数据流表现为“自然语言意图→形式化指令→逻辑结果”。当接收到操作员请求时，Qwen 首先执行任务拆解，将模糊意图编排为针对知识超图的推理请求。随后，数据流进入知识超图引擎，调用推理接口在封闭逻辑空间内执行演算。此阶段确保了推理过程不受模型幻觉干扰，输出结果具有确定性。

报告生成阶段：数据流表现为“逻辑结论与证据链→自然语言报告”。推理引擎生成的确定性结论及其支撑证据（三元组路径）回传给 Qwen。Qwen 充当“证据融合专家”，将逻辑路径与实时工况数据进行语义润色，生成具备逻辑追溯能力的自然语言通知单，实现协同交互。

为了实现上述三大步骤，下面给出 Qwen 与知识超图的功能结构。

Qwen 的接口主要负责提示词模板的构造、工具调用信息的灌入以及模型输出结果的解码，通过标准的推理调用实现语义空间的转换。如表 7 所示。

表 7 Qwen 接口清单与功能描述

序号	接口名称	功能描述
1	tokenizer.apply_chat_template	由提示词模板构造模型的输入，其中灌入工具调用和知识库返回信息
2	tokenizer.decode	解码模型返回的结果，例如：思考过程
3	client.chat.completions.create	模型接收输入，并给出回答

知识超图则通过一套原子化接口提供确定性事实支撑。原子化操作是指将复杂逻辑解构为一系列独立的、功能单一的调用单元，确保每个步骤均能产生确定性的输出。如表 8 所示。

表 8 超图接口清单与功能描述

接口类别	序号	接口名称	功能描述
查询统计	1	findEntityByName	根据名称查找实体

	2	findEntityByTimeRange	根据时间范围查找实体
	3	findEntityByNumberRange	根据数值范围查找实体
	4	findEntityByCategory	根据分类名称查找实体
	5	findEntityRelationById	根据唯一标识符获取实体所有的关系名称
	6	getNodeById	根据唯一标识符获取实体或事件的详细信息
	7	getNeighbors	根据实体唯一标识符获取它邻边信息
	8	findEvents	根据实体唯一标识符、时间范围、关键词多条件查询事件
	9	findEntityEventById	根据实体唯一标识符查询关联的所有事件类型
	10	findSimilarEvents	根据事件唯一标识符推荐相似的事件
	11	findSimilarEntities	根据实体唯一标识符推荐相似实体
	12	findShortestPath	根据给定的头实体和尾实体，查找连接二者最短的 Top-N 条路径
	13	getCurrentTime	获取当前时间，并格式化为 YYYY-MM-DD hh:mm:ss 形式
	14	getCurrentDate	获取当前日期，并格式化为 YYYY-MM-DD 形式
	15	countEntities	基于分类标签、实体属性及关键词等多维筛选条件，统计符合条件的实体总数
	16	countEvents	基于事件分类、时间区间及关键词等多维筛选条件，统计符合条件的事件总数
知识推理	1	deductiveReasoning	演绎推理：预测事件发展趋势
	2	abductiveReasoning	溯因推理：推理事件发生的原因
	3	inductiveReasoning	归纳推理：挖掘事件发生的规律
事件匹配	1	matchEvent	根据输入事件的完整文本描述，查询知识超图历史事件库中的相似事件

通过上述接口的原子化能力组合，Qwen 能够根据场景意图灵活调度，从而完成从知识库构建到报告生成的全周期闭环。

5.2 知识库构建

知识库构建是实现混合知识推理的基础。在化工厂危险作业智能合规管控场景中，其目的是将化工厂沉淀的大量非结构化文本（工艺操作规程、安全管理制度、化学品安全说明书及历史事故报告等）转化为机器可理解、可计算的领域知识超图。这一过程不再依赖传统的人工规则编写，而是利用 LLM 的指令微调能力，实现对作业要素的自动化抽取与关联。

首先，模型执行细粒度的**实体抽取**任务，旨在从复杂的作业文本中精准识别关键对象。相较于传统方法，大模型能够基于上下文语义消除专业术语的歧义。例如，在处理 $<\xrightarrow{\text{前置条件}}$ 开启 V－1201 阀门 >这一规程时，能分别识别出“V-1201” “R-101”“80℃”为不同实体类别。

其次，在实体识别的基础上，框架通过**关系抽取**进一步捕获实体间的工艺逻辑与空间拓扑。化工厂的作业逻辑往往隐含在跨段落的文本描述中，传统方法难以处理此类长距离依赖。而利用大模型的语义理解能力，框架能够抽取隐式的因果与互锁关系。例如，从 SOP 中解析出< R－101 温度达标 $\xrightarrow{\text{前置条件}}$ V－1201 开启 >，或者识别出规则三元组 < 甲醇，禁忌，强氧化剂 >，从而构建起设备与规则交织的逻辑网络。

最后，针对作业流程的动态特性，框架引入**事件抽取**机制，将静态的文本描述转化为具有时序结构的动态事件链。通过特定的提示词引导，模型能够抽取出包含< 动作,对象,条件,后果 >的四元组结构。例如，在作业场景中，模型能够结构化地表示出< 滴加混酸，核心动作，硝化反应投料 >，及其关联的< 温升过快，触发处置，冷却水开启 >。这些结构化知识最终汇聚成领域知识超图，为后续知识推理提供了坚实的数据基础。提示词示例见附录一。

5.3 知识推理

知识推理是混合知识推理框架的核心环节。其目的是利用大模型处理复杂自然语言交互，并动态编排任务指令，由知识超图引擎基于实时状态执行严谨的逻辑演算法则。

在化工厂危险作业智能合规管控场景中，当操

作人员通过手持终端或语音助手发起作业请求时，框架需要实时判断该操作在当前工况下是否合规。此环节充分发挥了混合架构的优势：利用 LLM 处理复杂的自然语言交互，利用知识超图引擎执行严谨的演绎推理。以“储罐区物料输送作业”为例，假设操作员发出指令:“准备将 T-201 储罐的甲醇输送至 R-305 反应釜，请确认是否具备输送条件。”

在**场景理解**阶段，LLM 首先对操作员的非规范自然语言进行语义解析，准确识别出 $<$ 作业意图、源节点、目标节点、涉及物料 $>$。随后，LLM 将这一宏观任务拆解为一系列可执行的原子查询任务，包括查询相关设备的实时液位与压力、检索 SOP 中的互锁规则库、检查管线阀门状态以及验证是否存在冲突作业。

紧接着，框架进入**思维过程**阶段。首先，LLM 利用思维链规划推理任务，但并不直接生成合规性结论，以避免大模型可能产生的幻觉。然后，调用知识超图推理引擎，子任务推理过程由确定性的知识超图推理引擎完成。该引擎基于实时采集的数据和预置的规则库，执行严格的演绎推理。例如，检查路径 $<\mathrm{T}-201\rightarrow \mathrm{Pump}-\mathrm{A}\rightarrow \mathrm{R}-305>$ 在当前工况下是否满足规则集。规则库明确规定 $<\mathrm{R}-101$ 温度达标 $\xrightarrow{\text{前置条件}}\mathrm{V}-1201$ 开启 $>,<$ 釜内压力必须小于 $0.3\mathrm{MPa}\wedge$ 泄压阀 $\mathrm{V}-309$ 开启 $\rightarrow$ 向 $\mathrm{R}-305$ 进料 $>$。推理引擎将实时事实与规则前提进行比对，输出 $<$ 压力超标 $\wedge$ 阀门关闭 $\rightarrow$ 操作禁止 $>$。这一过程确保了决策结果具有数学层面的逻辑保真性，杜绝了模糊判断。提示词示例见附录二。

5.4 报告生成

报告生成是混合知识推理的终端环节。在化工厂危险作业智能合规管控场景中，其目标是将推理引擎返回的逻辑状态转化为操作员可理解、可执行的作业许可单或违规警示。

在此阶段，LLM 主要承担**多源证据融合**的职责。它充当“安全签证官”，将来自不同模态的信息进行有机整合：包括确定性推理结论、工业物联网感知的实时数据快照、SOP 文档中的原始条款以及历史类似违规记录。通过将这些分散的证据汇聚，LLM 构建出一份内容详实、依据充分的违规分析报告。

更重要的是，框架通过**推理链构建**实现了决策的可解释性。LLM 将知识超图内部复杂的逻辑运算路径转化为自然语言表述，清晰地向操作员解释违规原因：拒绝执行。原因如下：根据 SOP 第 4.2 条，反应釜压力需小于 0.3MPa（当前 0.5MPa），且泄压阀 V-309 未开启。该状态同时违反了“物料平衡”的基本原则。

最终的问答呈现通常采用双栏排版架构：左侧展示由 LLM 生成的自然语言及具体的整改建议；右侧通过关系图模块动态展示当前的工艺流程图，高亮显示违规节点，实现所见即所得的隐患定位，极大提升了现场作业的决策效率与安全性。提示词示例见附录三。

综上，基于自学习的混合知识推理方法与 Qwen 适配的优势如表 9 所示。

表 9 与 Qwen 适配的优势

推理流程		适配 Qwen 的优势
知识库构建	实体抽取	LLM 基于指令微调和语义理解，快速适应领域，准确识别复杂实体。
	关系抽取	LLM 利用上下文理解力，从复杂文本中识别潜在的多跳关系，提高准确率。
	事件抽取	LLM 通过定制 Prompt，准确抽取事件类型、触发词及完整的时间、主体、行为结构。
任务理解	场景理解	LLM 充当智能翻译官，分析意图、任务类型（溯因）并将复杂问题分解为可执行的子查询。
	思维过程	LLM 生成思维链，负责调度知识推理模块、外部计算模块等工具，但不执行最终逻辑。
	推理过程	互相驱动赋能，推理结果增强。
报告生成	证据融合	LLM 融合知识推理的确定性结果、历史证据链和规章制度，形成逻辑连贯、支持充分的报告文本。
	推理链构建	LLM 将知识超图的推理路径以自然语言清晰阐述，并配合关系图模块可视化，增强结果可信度。

混合推理框架通过引入知识超图，成功将推理逻辑与大模型的概率生成解耦，有效确立了逻辑层面的正确性。然而，在报告生成等高度依赖自然语言输出的环节，框架在生成内容的精准度与领域知识的严格对齐方面仍有进一步提升的空间。针对这一挑战，目前作者团队采用了两种优化策略，并已经取得了可观的成效：一是引入智能体并进行强化学习，构建基于知识超图事实的奖励模型，通过强化学习训练模型抑制通用知识检索，专注于忠实转述逻辑链；二是实施基于知识超图的严格生成控制，

在解码阶段引入约束解码算法，动态限制候选词表仅包含知识超图内的术语与工况数据，从物理上切断虚假信息的来源，确保安全管控的严谨性。

5.5 对比分析

为了验证自学习混合知识推理框架在知识库构建、知识推理及报告生成流程中的有效性，本节分别针对构图阶段的知识抽取、用图阶段的逻辑推理以及报告生成任务，进行了对比验证。采用百度 DuEE 通用数据集，并划分为两个测试子集。其中 duee_test 包含推理结果示例，示例中包括推理结果的时效性，实质性，可验证性等特征；duee_test_normal 为标准测试集，不包含推理结果示例。两者都包含共同的 3499 条测试样本。其中，duee_test 中的推理结果示例仅作为结果格式模板使用，用于规定模型输出的组织形式及需要包含的要素。该示例随提示信息提供给模型，但不包含当前测试样本的真实推理结果或标注答案，也不参与评价指标计算。以 Qwen3 0.6B 作为基座模型，在 NVIDIA GeForce RTX 4090 单卡的环境下，采用两套方案进行实验验证，一是仅由大模型进行推理、二是引入知识超图后的混合推理框架进行推理。等效 Batch Size 为 32。考虑到本文实验旨在验证知识超图对大语言模型推理性能的增益，而非比较不同规模模型的能力上限，因此统一选用轻量级 Qwen3-0.6B 作为基座模型，以降低实验的计算资源需求。基础大语言模型与知识超图增强模型两种方案，均采用相同的基座模型、测试数据与推理参数设置，以排除模型规模和配置差异的影响，便于直观评估知识超图对知识抽取、知识推理与报告生成效果的提升作用。

首先，在知识库构建阶段，验证框架对领域文本的自动化处理能力。本文采用其基于最长公共子序列计算的召回率，以表征标准结果中的关键信息被模型生成结果覆盖的程度。F1 用于综合表征样本级结果准确性与基于子序列匹配的召回能力，其计算方式为：$F1 = 2 \times Precision \times ROUGE-L/(Precision + ROUGE-L)$其中，Precision 表示模型输出结果与测试集标准标注结果完全一致的样本数占测试样本总数的比例，由模型预测结果与 DuEE 测试集对应的标准标注逐样本比对得到；ROUGE-L 表示基于最长公共子序列计算得到的召回率。本文所采用的 F1 是 Precision 与 ROUGE-L 的调和平均值，用于综合反映模型输出的样本级准确性与标准信息覆盖能力。以 duee_test 测试子集为例，如表 10 所示，引入知识超图后，模型的 ROUGE-L 由 8.76%提升至 74.81%，BLEU-4 由 6.13%提升至 63.68%，综合评价指标 F1 由 9.24%提升至 76.12%，表明知识超图提供的结构化知识与规则约束能够有效提升领域信息抽取的准确性与完整性，并减少长尾事实抽取过程中的语义漂移。与此同时，两个测试集上的运行耗时均缩短 70%以上。其主要原因是，知识超图通过实例层、概念层和事件规则层对知识进行分层组织：实例层定位具体事件及实体信息，概念层通过抽象映射聚合同类事件，事件规则层利用霍恩规则约束推理路径。三层结构能够在大模型推理前逐级筛选相关知识与候选路径，将开放式语义搜索转化为结构化的定向检索与规则匹配，从而减少无关上下文、无效路径及冗余生成。因此，在基座模型和计算环境保持一致的情况下，知识超图通过缩小实际推理空间降低了整体运行耗时。

表 10 知识推理性能对比

推理模式	数据集划分	BLEU-4 (%)	ROUGE-1 (%)	ROUGE-2 (%)	ROUGE-L (%)	综合 F1 (%)	运行耗时 (s)	步长效率 (steps/s)	幻觉率 (%)
Qwen3	duee_test	6.13	21.63	8.50	8.76	9.24	506.49	0.051	32.80
	duee_test_normal	7.27	24.26	12.11	10.71	11.58	506.46	0.051	30.62
Qwen3 +知识超图	duee_test	**63.68**	**75.29**	**71.72**	**74.81**	**76.12**	**119.74**	**0.217**	**19.25**
	duee_test_normal	**31.87**	**40.62**	**34.33**	**35.02**	**36.45**	**143.99**	**0.181**	**27.21**

在知识推理阶段，验证框架的推理严谨性。以“汽轮机支持轴承同轴承不同瓦温度测点差值大”这一典型异常现象为例，Qwen3 输出的“轴承磨损”和“油压不足”虽然在语义上与轴承温升相关，但仅属于通用性的常识归因，无法解释为何“同轴承不同瓦”会出现显著温差。

相比之下，本文框架通过外生模式执行精准的任务意图路由，将该异常信号映射至知识超图的特定事件节点。在内生模式溯因推理过程中，框架利用逻辑基座中定义的物理约束，排除了全局性的油

系统故障，转而锁定了“局部瓦块卡涩”这一变量，并由溯因算法进一步穿透至“球面间隙小于设计下公差”等底层安装缺陷。这种从“模糊常识”向“精准证据链”的推演，不仅在结论上更具针对性，更通过显式的逻辑路径消解了决策过程的“黑盒”属性。

在报告生成阶段，验证框架的可靠性。以 duee_test 测试子集为例，由表 10 数据可见，在无约束环境下，由于生成式的发散特性，仅依赖 Qwen3 自身输出的幻觉率达 32.80%。而接入知识超图并施加约束算法后，模型幻觉率下降至 19.25%。实验表明，Qwen3 接入知识超图后，实现了从语义理解到逻辑判读的知识约束，有效弥补了联结主义模型在处理确定性因果关系时的概率性局限，保障了模型在复杂高风险场景下的合规输出能力。

6 结语与展望

随着人工智能技术从单一符号逻辑或统计学习向神经符号协同计算演进，混合知识推理成为认知智能领域的重要范式。本文提出了一种基于自学习的混合知识推理框架，构建了以 LLM 为认知中枢、以知识超图为逻辑基座的新型架构，实现了知识推理与大模型的双向赋能。

展望未来，混合知识推理仍具广阔演进空间。**架构层面**，推动系统从文档驱动的被动构建向基于实时数据的“知识自主进化”转型，结合强化学习对齐与约束解码技术，从源头切断虚假信息生成，保障推理的安全可信；**模型层面**，突破混合推理架构单一文本模态限制，向多模态感知、具身智能环境感知等演进，支撑高维度认知系统构建；**应用层面**，提出的“规则+模型”协同范式具有普适性，可进一步泛化迁移至电力、医疗、金融等更广泛的强逻辑决策领域。

参 考 文 献

[1] Galárraga L, Teflioudi C, Hose K, et al. AMIE: Association rule mining under incomplete evidence in ontological knowledge bases//Proceedings of the 22nd International World Wide Web Conference. Rio de Janeiro, Brazil, 2013: 413-422.

[2] Clark P, Etzioni O, Khashabi D, et al. From “F” to “A” on the N.Y. Regents Science Exams: An overview of the Aristo project. AI Magazine, 2020, 41(4): 39-53.

[3] Besold T R, d’Avila Garcez A, Bader S, et al. Neural-symbolic learning and reasoning: A survey and interpretation//Hitzler P, Sarker M K, eds. Neuro-Symbolic Artificial Intelligence: The State of the Art. Amsterdam: IOS Press, 2021: 1-51.

[4] Wu Xin-Dong, Huang Man-Zong, Bu Chen-Yang. BEKO: Bidirectional enhancement of large language models and knowledge graphs. Chinese Journal of Computers, 2025, 48(7): 1572-1588 (in Chinese)
(吴信东，黄满宗，卜晨阳. BEKO: 大语言模型与知识图谱的双向增强. 计算机学报, 2025, 48(7): 1572-1588)

[5] Zhou Kun, et al. YuLan-Chat: A large language model based on multi-stage curriculum learning. Chinese Journal of Computers, 2025, 48(1): 1-18 (in Chinese)
(周昆，等. YuLan-Chat: 基于多阶段课程学习的大语言模型. 计算机学报, 2025, 48(1): 1-18)

[6] Du Meng-Yao, et al. Construction of a privacy-preserving user-review benchmark dataset and evaluation of large-language-model reasoning capability. Chinese Journal of Computers, 2025, 48(7): 1529-1550 (in Chinese)
(杜梦瑶，等. 面向隐私保护的用户评论基准数据集构建与大模型推理能力评估. 计算机学报, 2025, 48(7): 1529-1550)

[7] Creswell A, Shanahan M, Higgins I. Selection-inference: Exploiting large language models for interpretable logical reasoning//Proceedings of the 11th International Conference on Learning Representations. Kigali, Rwanda, 2023.

[8] Shen Ying-Han, et al. A survey of reasoning over temporal knowledge graphs. Chinese Journal of Computers, 2023, 46(6): 1272-1301 (in Chinese)
(沈英汉，等. 时态知识图谱的推理研究综述. 计算机学报，2023, 46(6): 1272-1301)

[9] Wang Jian-Hui, et al. Token-level parallel collaborative reasoning with multiple models. Chinese Journal of Computers, 2025, 48(11): 2579-2593 (in Chinese)
(王建辉，等. Token 级多模型并联协作推理. 计算机学报，2025, 48(11): 2579-2593)

[10] Tian Ling, et al. A survey of knowledge graphs: Representation, construction, reasoning, and knowledge hypergraph theory. Journal of Computer Applications, 2021, 41(8): 2161-2186 (in Chinese)
(田玲，等. 知识图谱综述——表示、构建、推理与知识超图理论. 计算机应用, 2021, 41(8): 2161-2186)

[11] Burks A W. Peirce’s theory of abduction. Philosophy of Science, 1946,

13(4): 301-306.

[12] Quinlan J R. C4.5: Programs for Machine Learning. San Mateo, USA: Morgan Kaufmann, 1993.

[13] Agrawal R, Srikant R. Fast algorithms for mining association rules in large databases//Proceedings of the 20th International Conference on Very Large Data Bases. Santiago de Chile, Chile, 1994: 487-499.

[14] MacQueen J. Some methods for classification and analysis of multivariate observations//Proceedings of the 5th Berkeley Symposium on Mathematical Statistics and Probability. Berkeley, USA, 1967, 1: 281-297.

[15] Montgomery D C, Peck E A, Vining G G. Introduction to Linear Regression Analysis. 6th ed. Hoboken, USA: John Wiley & Sons, 2021.

[16] Jabbour S, Raddaoui B, Sa ïs L. A symbolic approach to computing disjunctive association rules from data//Proceedings of the 32nd International Joint Conference on Artificial Intelligence. Macao, China, 2023: 2133-2141.

[17] Sasaki Y, Karras P. Mining path association rules in large property graphs//Proceedings of the 33rd ACM International Conference on Information and Knowledge Management. Boise, USA, 2024: 1994-2003.

[18] Deng X Z, Huang D, Chen D H, et al. Strongly augmented contrastive clustering. Pattern Recognition, 2023, 139: 109470.

[19] Fan J C, Cheng J. Deep learning based matrix completion. Neurocomputing, 2017, 266: 540-549.

[20] Richardson M, Domingos P. Markov logic networks. Machine Learning, 2006, 62(1-2): 107-136.

[21] Landwehr N, Kersting K, De Raedt L. nFOIL: Integrating na ïve Bayes and FOIL//Proceedings of the 20th National Conference on Artificial Intelligence. Pittsburgh, USA, 2005: 795-800.

[22] Gal árraga L, Teflioudi C, Hose K, et al. Fast rule mining in ontological knowledge bases with AMIE+. The VLDB Journal, 2015, 24(6): 707-730.

[23] Schoenmackers S, Etzioni O, Weld D S, et al. Learning first-order Horn clauses from Web text//Proceedings of the 2010 Conference on Empirical Methods in Natural Language Processing. Cambridge, USA, 2010: 1088-1098.

[24] Sinha K, Sodhani S, Dong J, et al. CLUTRR: A diagnostic benchmark for inductive reasoning from text//Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing. Hong Kong, China, 2019: 4506-4515.

[25] Rule J S. The Child as Hacker: Building More Human-Like Models of Learning. Cambridge, USA: Massachusetts Institute of Technology, 2020.

[26] Qu M, Chen J, Huang L, et al. RNNLogic: Learning logic rules for reasoning on knowledge graphs//Proceedings of the 9th International Conference on Learning Representations. Virtual, 2021.

[27] Rudinger R, Shwartz V, Hwang J D, et al. Thinking like a skeptic: Defeasible inference in natural language//Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing. Online, 2020: 4661-4675.

[28] Lampinen A K, Dasgupta I, Chan S C Y, et al. Can language models learn from explanations in context?//Findings of the Association for Computational Linguistics: EMNLP 2022. Abu Dhabi, United Arab Emirates, 2022: 537-563.

[29] Chen Z, Lu H, Wang Y, et al. A comprehensive evaluation of inductive reasoning capabilities and problem solving in large language models//Findings of the Association for Computational Linguistics: EACL 2024. St. Julian's, Malta, 2024: 323-339.

[30] Tang J, Lu S, Zhang L, et al. RulE: Knowledge graph reasoning with rule embedding//Findings of the Association for Computational Linguistics: ACL 2024. Bangkok, Thailand, 2024: 4316-4335.

[31] Pellegrina L, Vandin F. Scalable rule lists learning with sampling//Proceedings of the 30th ACM SIGKDD Conference on Knowledge Discovery and Data Mining. Barcelona, Spain, 2024: 2352-2363.

[32] Huang S, Zhang Y, Wang W, et al. Confidence is not timeless: Modeling temporal validity for rule-based temporal knowledge graph forecasting//Proceedings of the 62nd Annual Meeting of the Association for Computational Linguistics. Bangkok, Thailand, 2024: 10783-10794.

[33] Minervini P, Riedel S, Stenetorp P, et al. Learning reasoning strategies in end-to-end differentiable proving//Proceedings of the 37th International Conference on Machine Learning. Virtual Conference, 2020: 6938-6949.

[34] Gao K, Inoue K, Cao Y, et al. A differentiable first-order rule learner for inductive logic programming. Artificial Intelligence, 2024, 331: 104108.

[35] Yu L, Li M, Zhang Y L, et al. FINRule: Feature interactive neural rule learning//Proceedings of the 32nd ACM International Conference on Information and Knowledge Management. Birmingham, United Kingdom, 2023: 3020-3029.

[36] Wang X, Tena Cucala D J, Cuenca Grau B, et al. Faithful rule extraction for differentiable rule learning models//Proceedings of the 12th International Conference on Learning Representations. Vienna, Austria, 2024.

[37] Yao S, Zhao J, Yu D, et al. ReAct: Synergizing reasoning and acting in

language models//Proceedings of the 11th International Conference on Learning Representations. Kigali, Rwanda, 2023.

[38] Hegselmann S, Buendia A, Lang H, et al. TabLLM: Few-shot classification of tabular data with large language models//Proceedings of the 26th International Conference on Artificial Intelligence and Statistics. Valencia, Spain, 2023: 5549-5581.

[39] Zhang C, Wang L Z, Rigger M. Finding cross-rule optimization bugs in Datalog engines. Proceedings of the ACM on Programming Languages, 2024, 8(OOPSLA1): 110-136.

[40] Sun Z Q, Deng Z H, Nie J Y, et al. RotatE: Knowledge graph embedding by relational rotation in complex space//Proceedings of the 7th International Conference on Learning Representations. New Orleans, USA, 2019.

[41] Nickel M, Tresp V, Kriegel H P. A three-way model for collective learning on multi-relational data//Proceedings of the 28th International Conference on Machine Learning. Bellevue, USA, 2011: 809-816.

[42] Dettmers T, Minervini P, Stenetorp P, et al. Convolutional 2D knowledge graph embeddings//Proceedings of the 32nd AAAI Conference on Artificial Intelligence. New Orleans, USA, 2018: 1811-1818.

[43] Schlichtkrull M, Kipf T N, Bloem P, et al. Modeling relational data with graph convolutional networks//Proceedings of the 15th Extended Semantic Web Conference. Heraklion, Greece, 2018: 593-607.

[44] Ren H, Hu W, Leskovec J. Query2box: Reasoning over knowledge graphs in vector space using box embeddings//Proceedings of the 8th International Conference on Learning Representations. Virtual Conference, 2020.

[45] Ren H, Dai H, Dai B, et al. Beta embeddings for multi-hop logical reasoning in knowledge graphs. Advances in Neural Information Processing Systems, 2020, 33: 19716-19726.

[46] Pan S, Luo L, Wang Y, et al. Unifying large language models and knowledge graphs: A roadmap. IEEE Transactions on Knowledge and Data Engineering, 2024, 36(7): 3580-3599.

[47] Riveland R, Wang S, Lee M, et al. Natural language instructions induce compositional generalization in networks of neurons. Nature Neuroscience, 2024, 27: 988-999.

[48] Loconte L, Gala G, Sidheekh S, et al. How to turn your knowledge graph embeddings into generative models. Advances in Neural Information Processing Systems, 2023, 36: 77713-77744.

[49] Hu Y, Zhang X, Chen X, et al. Stability and generalization of zeroth-order decentralized stochastic gradient descent with changing topology//Proceedings of the 39th AAAI Conference on Artificial Intelligence. Philadelphia, USA, 2025: 17342-17350.

[50] Qi J, Zhao Z, Li Q, et al. Learning from both structural and textual knowledge for inductive knowledge graph completion. Advances in Neural Information Processing Systems, 2023, 36: 26546-26562.

[51] Liu Y, Chen J, Zhang Y, et al. Transfer rule learning over large knowledge graphs//Proceedings of the ACM Web Conference 2025. Sydney, Australia, 2025: 2135-2143.

[52] Zeng F Z, Wang S Q, Zhu C Z, et al. ADRD: LLM-driven autonomous driving based on rule-based decision systems. arXiv preprint arXiv:2506.14299, 2025.

[53] Bai J X, Wang Y, Wang B, et al. G2S: A general-to-specific learning framework for temporal knowledge graph forecasting with large language models//Proceedings of the 63rd Annual Meeting of the Association for Computational Linguistics. Vienna, Austria, 2025: 20927-20938.

[54] Xiong W, Hoang T, Wang W Y. DeepPath: A reinforcement learning method for knowledge graph reasoning//Proceedings of the 2017 Conference on Empirical Methods in Natural Language Processing. Copenhagen, Denmark, 2017: 564-573.

[55] Tafjord O, Dalvi B, Clark P. ProofWriter: Generating implications, proofs, and abductive statements over natural language//Findings of the Association for Computational Linguistics: ACL-IJCNLP 2021. Online, 2021: 3621-3634.

[56] Dalvi B, Jansen P, Tafjord O, et al. Explaining answers with entailment trees//Proceedings of the 2021 Conference on Empirical Methods in Natural Language Processing. Punta Cana, Dominican Republic, 2021.

[57] Pan L, Albalak A, Wang X, et al. Logic-LM: Empowering large language models with symbolic solvers for faithful logical reasoning//Findings of the Association for Computational Linguistics: EMNLP 2023. Singapore, 2023: 3806-3824.

[58] Sun W T, Zhang C X, Zhang X Y, et al. Beyond instruction following: Evaluating inferential rule following of large language models. arXiv preprint arXiv:2407.08440, 2024.

[59] Ling Z, Fang Y, Li X, et al. Deductive verification of chain-of-thought reasoning. Advances in Neural Information Processing Systems, 2023, 36: 36407-36433.

[60] Bosselut A, Rashkin H, Sap M, et al. COMET: Commonsense transformers for automatic knowledge graph construction//Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics. Florence, Italy, 2019: 4762-4779.

[61] Young T, Cambria E, Chaturvedi I, et al. AbductionRules: Training transformers to explain unexpected inputs//Findings of the Association for Computational Linguistics: ACL 2022. Dublin, Ireland, 2022: 218-227.

[62] Gao Y S, Bai J X, Zheng T S, et al. Controllable logical hypothesis generation for abductive reasoning in knowledge graphs//Proceedings

of the 14th International Conference on Learning Representations. Rio de Janeiro, Brazil, 2026.

[63] Movva R, Peng K, Garg N, et al. Sparse autoencoders for hypothesis generation//Proceedings of the 42nd International Conference on Machine Learning. Vancouver, Canada, 2025: 44997-45023.

[64] Mooij J M, Peters J, Janzing D, et al. Distinguishing cause from effect using observational data: Methods and benchmarks. Journal of Machine Learning Research, 2016, 17(32): 1-102.

[65] Ganian R, Hamm T, Ordyniak S, et al. Revisiting causal discovery from a complexity-theoretic perspective//Proceedings of the 33rd International Joint Conference on Artificial Intelligence. Jeju, Republic of Korea, 2024: 3377-3385.

[66] Kıcıman E, Ness R, Sharma A, et al. Causal reasoning and large language models: Opening a new frontier for causality. Transactions on Machine Learning Research, 2023.

[67] Wang Q Y, Downey D, Ji H, et al. SciMON: Scientific inspiration machines optimized for novelty//Proceedings of the 62nd Annual Meeting of the Association for Computational Linguistics. Bangkok, Thailand, 2024: 279-299.

[68] Liu J F, Chen Y B, Liu K, et al. Knowledge-enhanced event causality identification with mention masking generalizations//Proceedings of the 30th International Joint Conference on Artificial Intelligence. Montreal, Canada, 2021: 3608-3614.

[69] Du L, Ding X, Xiong K, et al. ExCAR: Event graph knowledge enhanced explainable causal reasoning//Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th International Joint Conference on Natural Language Processing. Online, 2021: 2354-2363.

[70] Cüppers F, et al. Causal discovery from event sequences by local cause-effect attribution. Advances in Neural Information Processing Systems, 2024, 37: 24216-24241.

[71] Niu G, Li B, Han B, et al. Logic and commonsense-guided temporal knowledge graph completion//Proceedings of the 37th AAAI Conference on Artificial Intelligence. Washington, USA, 2023: 4569-4577.

[72] Wang Y, Li Z, Zhang R, et al. Large language models-guided dynamic adaptation for temporal knowledge graph reasoning. Advances in Neural Information Processing Systems, 2024, 37: 8384-8410.

[73] Koupaee M, Bai X Y, Chen M D, et al. Causal graph based event reasoning using semantic relation experts//Proceedings of the 63rd Annual Meeting of the Association for Computational Linguistics. Vienna, Austria, 2025: 26169-26199.

[74] Liu Y, Li G, Hu Q, et al. Cross-modal causal relational reasoning for event-level visual question answering. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2023, 45: 11624-11641.

[75] Toutanova K, Chen D. Observed versus latent features for knowledge base and text inference//Proceedings of the 3rd Workshop on Continuous Vector Space Models and their Compositionality. Beijing, China: Association for Computational Linguistics, 2015: 57-66.

[76] Mitchell T, Cohen W, Hruschka E, et al. Never-ending learning. Communications of the ACM, 2018, 61(5): 103-115.

[77] Garc á-Durán A, Dumančić S, Niepert M. Learning sequence encoders for temporal knowledge graph completion//Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing. Brussels, Belgium: Association for Computational Linguistics, 2018: 4816-4821.

[78] Leetaru K, Schrodt P A. GDELT: Global database of events, language, and tone//Proceedings of the 2013 International Studies Association Annual Convention. San Francisco, USA, 2013.

[79] Bhagavatula C, Bras R L, Malaviya C, et al. Abductive commonsense reasoning//Proceedings of the 8th International Conference on Learning Representations. Virtual Conference, 2020.

[80] Hessel J, Hwang J D, Park J S, et al. The abduction of Sherlock Holmes: A dataset for visual abductive reasoning//Proceedings of the 17th European Conference on Computer Vision. Tel Aviv, Israel, 2022: 558-575.

[81] Bordes A, Usunier N, Garcia-Duran A, et al. Translating embeddings for modeling multi-relational data. Advances in Neural Information Processing Systems, 2013, 26: 2787-2795.

[82] P érez J, Arenas M, Guti érrez C. Semantics and complexity of SPARQL. ACM Transactions on Database Systems, 2009, 34(3): Article 16, 1-45.

[83] Date C J. A Guide to the SQL Standard. Reading, USA: Addison-Wesley, 1989.

附录一：知识库构建提示词

”””

- Role - Chemical Safety Expert
- Task - Extract key entities, relationships, and operational events from the provided process operation procedure text to construct structured knowledge.
- Attentions -
- Must extract all "Preconditions" as relationship attributes.
- Strictly distinguish the hierarchy and dependency of actions (e.g., Core Action vs. Precondition).
- The output must strictly follow the specified JSON Schema format.
- Subject-
- Chemical Safety Expert
- Process Operation Procedure Text
- Object -
- Key Entities
- Relationships
- Operational Events
- Structured Knowledge
- Candidate Relative Options-
- Upstream Equipment
- Interlock Condition
- Incompatible
- Has Precondition
Output:

”””

附录二：知识推理提示词

”””

- Role - Intelligent Operation Dispatcher
- Task - Parse user operation requests and generate logic verification instructions based on the knowledge hypergraph.
- Context - User requests to execute [Methanol Transfer Operation], current context involves source equipment, target equipment, and material information.
- Attentions-
- Use Chain of Thought (CoT) analysis: Identify key elements→Retrieve KPIs→Match interlock rule IDs.
- Do not generate compliance conclusions directly; must call external tools for verification.
- Tool call instructions must contain specific parameters (Source, Target, Material).
- Subject -
- Intelligent Operation Dispatcher
- User
- Object-
- Operation Request
- Logic Verification Instructions
- Key Elements
- KPIs
- Interlock Rule IDs
- Candidate Relative Options-
- Matches Rule
- Involves Equipment
- Requires Verification
- Calls Tool
Output:

”””

附录三：报告生成提示词

”””

- Role - Chemical Safety Visa Officer
- Task - Generate an [Operation Rejection Notice] based on the violation conclusion returned by the reasoning engine and SOP clauses.
- Input –
- Conclusion: $\mathrm{Status} = \mathrm{Denied}$
- Violation: $\mathrm{P_R305} > 0.3MPa$
- Basis: "Methanol Transfer Regulations" Article 4.2
- Attentions-
- Tone must be serious, highlighting the urgency of safety hazards.
- Use natural language to reconstruct the reasoning chain, clearly explaining why conditions are not met.
- Must provide specific rectification suggestions.
- Mandatory citation of SOP original text as basis.
- Subject -
- Chemical Safety Visa Officer
- Reasoning Engine
- Object-
- Operation Rejection Notice
- Violation Conclusion
- SOP Clauses

- Reasoning Chain
- Rectification Suggestions
- Candidate Relative Options-
- Based On
- Violates
- Results In
- Suggests

Output:

”””



TIAN Ling, Ph.D., professor,Ph.D. supervisor. Her research interests mainly focus on knowledge graphs and knowledge reasoning.

ZHOU Jing-Ren, Ph.D. His research interests mainly focus on artificial intelligence and large language models.

HU Xin-Zhe, Ph.D. candidate. His research interests mainly focus on large language models and knowledge reasoning.

ZHANG Jin-Chuan, Ph.D., postdoctoral researcher. His research interests mainly focus on large language models and knowledge reasoning.

DING Bo-Lin, Ph.D. His research interests mainly focus on machine learning and large language models.

LI Ya-Liang, Ph.D. His research interests mainly focus on machine learning and large language models.

Background

Knowledge reasoning is a fundamental research topic in artificial intelligence and an important technical basis for the transition from perceptual intelligence to cognitive intelligence. Traditional symbolic reasoning represents knowledge through explicit facts and logical rules, thereby providing deterministic conclusions, transparent reasoning paths, and strong interpretability. However, such methods usually depend on manually constructed knowledge bases and predefined rules, making them difficult to adapt to incomplete information, continuously changing knowledge, and open environments. Data-driven methods and large language models have substantially improved semantic understanding, information extraction, and generalization, but their probabilistic generation mechanisms may introduce factual inconsistency, hallucination, insufficient logical rigor, and limited controllability. Consequently, neither symbolic reasoning nor data-driven reasoning alone can simultaneously provide flexible generalization, reliable logical constraints, dynamic knowledge evolution, and interpretable decision support.

Recent studies have explored neural-symbolic reasoning, knowledge-graph-enhanced language models, retrieval-augmented generation, temporal knowledge graph reasoning, and external symbolic solvers. These methods promote the integration of structured knowledge with neural models, but many existing systems still organize knowledge acquisition, logical reasoning, causal attribution, and knowledge updating as relatively independent or loosely coupled modules. Information is often transferred through a fixed pipeline, while different reasoning paradigms lack dynamic coordination and bidirectional feedback. This limits the ability of reasoning systems to continuously acquire knowledge from data, verify generated conclusions, trace possible causes, and update their knowledge bases in response to new observations.

To address these limitations, this paper proposes a self-learning-driven hybrid knowledge reasoning framework that dynamically coordinates inductive, deductive, and abductive reasoning. The three reasoning paradigms are respectively combined with inductive learning, optimization learning, and backward learning. The framework further introduces an endogenous mode to coordinate different reasoning mechanisms and an exogenous mode to support the dynamic flow and integration of external data and structured knowledge. A three-layer knowledge hypergraph, consisting of an instance layer, a concept layer, and an event-rule layer, provides the logical foundation. The instance layer represents concrete events and entities, the concept layer abstracts reusable event patterns, and the event-rule layer stores Horn rules for constraining and explaining reasoning paths. Through these mechanisms, knowledge extraction, rule induction, logical prediction, causal attribution, factual verification, and knowledge updating are incorporated into a unified iterative process.

The framework is implemented through functional interfaces between Qwen and the knowledge hypergraph and is applied to an industrial standardized-operation control scenario. The complete workflow covers knowledge-base construction, knowledge reasoning, and report generation. Qwen is responsible for semantic understanding, task decomposition, and natural-language generation, while the knowledge hypergraph performs structured retrieval, rule matching, logical verification, and reasoning-path tracing. Experimental comparisons are conducted between the base language model and the same model augmented with the knowledge hypergraph. On the duee_test subset, the composite extraction $F1_{comp}$ score increases from 9.24% to 76.12%, while the running time on both test subsets is reduced by more than 70%. These results indicate that the proposed framework can combine the semantic flexibility of large language models with explicit logical constraints and structured knowledge organization, providing a practical basis for transparent, interpretable, and reliable intelligent decision-making in logic-intensive and safety-sensitive applications.