

基于电网技术标准知识图谱的神经符号推理方法研究

宋杰¹, 李永², 潘爱强¹, 方陈¹, 时珊珊¹, 王雯丽²

¹国网上海市电力公司, 上海

²上海久隆企业管理咨询有限公司, 上海

收稿日期: 2026年6月4日; 录用日期: 2026年6月15日; 发布日期: 2026年8月5日

摘要

电网技术标准知识兼具确定性规范约束与隐性关联模式两种形态, 单一推理范式难以同时兼顾推理结果的可解释性与隐含关联的发现能力。神经符号推理范式通过将符号逻辑与神经网络相融合, 为上述问题提供了系统化的解决思路。本文围绕电网技术标准知识图谱的推理需求, 开展神经符号推理方法的体系化设计研究。针对标准条款的逻辑结构特征构建基于霍恩子句的领域启发式推理规则集, 通过前向链匹配为候选关联提供可解释的规则支持信号; 采用关系图卷积网络(R-GCN)与双线性解码器构建链路预测模型, 发现图谱中未被显式标注的隐含关联; 设计“候选生成-约束校验”两阶段融合机制, 第一阶段对R-GCN概率得分与规则启发式支持两类软信号加权融合并排序, 第二阶段以图谱中编码的强制性约束对候选进行硬过滤, 使语义发现与合规约束在职责上相互分离。最后结合电网技术标准的典型业务场景, 以典型示例说明所提框架的工作过程。

关键词

电网技术标准, 知识图谱, 神经符号推理, 标准数字化

Research on Neural Symbolic Reasoning Method Based on Knowledge Graph of Power Grid Technical Standards

Jie Song¹, Yong Li², Aiqiang Pan¹, Chen Fang¹, Shanshan Shi¹, Wenli Wang²

¹State Grid Shanghai Municipal Electric Power Company, Shanghai

²Shanghai Jiulong Enterprise Management Consulting Co., Ltd., Shanghai

文章引用: 宋杰, 李永, 潘爱强, 方陈, 时珊珊, 王雯丽. 基于电网技术标准知识图谱的神经符号推理方法研究[J]. 现代管理, 2026, 16(8): 26-34. DOI: 10.12677/mm.2026.168158

Abstract

The knowledge of power grid technical standards possesses both deterministic normative constraints and implicit association patterns. A single reasoning paradigm is difficult to simultaneously achieve interpretability of reasoning results and the ability to discover implicit associations. The neural symbolic reasoning paradigm, by integrating symbolic logic with neural networks, provides a systematic solution to the aforementioned problems. This paper focuses on the reasoning requirements of the power grid technical standards knowledge graph and conducts research on the systematic design of neural symbolic reasoning methods. A set of domain-specific heuristic reasoning rules based on Horn clauses is constructed according to the logical structural characteristics of standard clauses, providing interpretable rule support signals for candidate associations through forward chain matching. A link prediction model is constructed using a relational graph convolutional network (R-GCN) and a bilinear decoder to discover implicit associations that are not explicitly labeled in the graph. A two-stage fusion mechanism, namely “candidate generation - constraint verification”, is designed. In the first stage, two types of soft signals, namely R-GCN probability scores and rule-based heuristic support, are weighted and fused, and then ranked. In the second stage, hard filtering is applied to candidates based on the mandatory constraints encoded in the graph, separating semantic discovery and compliance constraints in terms of responsibilities. Finally, combined with typical business scenarios of power grid technical standards, typical examples are used to illustrate the working process of the proposed framework.

Keywords

Power Grid Technical Standards, Knowledge Graph, Neural Symbolic Reasoning, Standard Digitization

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

电网技术标准是规范电力系统设计、建设、运行等全过程的基础性规范文件，涵盖国家标准、行业标准与企业标准等多个层级。随着标准体系日益庞大，传统的人工检索与比对方法效率低下且容易出错。本文将知识图谱与神经符号推理相结合，为实现标准知识的自动化、智能化管理与应用提供了有效的技术路径，对于提升电网规划、设计、运维的合规性与效率具有重要价值。

知识图谱以其图结构的语义表达能力[1]，为标准知识的结构化组织提供了有效工具，而知识图谱推理是实现标准智能服务的关键技术。当前知识图谱推理方法主要分为三大范式：一是基于符号逻辑的推理，具有完全的可解释性但受限于规则覆盖范围；二是基于知识表示学习的方法，通过几何运算进行链路预测，但对图结构信息的利用相对有限；三是基于图神经网络的方法，能够有效建模异构图结构但推理结果缺乏符号化解释。

在电网技术标准领域，标准知识同时具备两种形态：以“应”“不应”等强制性措辞表达的确定性约束，以及标准之间未被显式标注但客观存在的隐含关联。单一推理范式难以同时处理两种形态，纯符号

推理会遗漏潜在关联,纯神经网络则可能产生违反强制性约束的预测结果。神经符号推理(Neuro-Symbolic Reasoning)范式通过将符号逻辑与神经网络相融合,为解决上述两难问题提供了系统化思路。

2. 相关工作

2.1. 电网领域知识图谱研究

电网领域是知识图谱技术的重要应用方向之一。在故障诊断方面,基于知识图谱与图神经网络的混合方法成为近年研究热点,张建良等[2]在面向新型电力系统故障诊断技术的综述中,将“知识引导的网络结构设计”列为重要发展方向,强调利用专家规则等先验知识对图神经网络架构进行约束,以提升模型的可解释性与泛化能力。在电力设备运维管理方面,谢庆等[3]提出基于 ALBERT 的电力变压器运维知识图谱构建方法,通过深度学习实体抽取与关系抽取实现了电力变压器运维知识的结构化组织。

整体来看,电网领域知识图谱研究呈现出三个特征:一是研究焦点从单一设备类型管理逐步扩展到多业务场景协同;二是从静态知识库逐步转向支持知识动态更新与演化的体系;三是从纯数据驱动方法逐步向数据驱动与规则约束相结合的混合方法发展。然而,针对电网技术标准体系本身的知识图谱推理方法研究相对有限,现有研究多聚焦于设备故障诊断与运维等具体业务场景,对标准之间的引用关系、适用范围等结构化语义的推理建模尚未形成系统化方案。

2.2. 神经符号推理范式研究

神经符号推理通过将符号逻辑的可解释性与神经网络的泛化能力相融合,是当前知识图谱推理的前沿研究方向。Marra 等[4]系统综述了神经符号 AI 的发展现状,将其与统计关系 AI 对比并归纳了多个共享维度。Hitzler 等[5]进一步指出,神经符号方法在工程领域应用中需要重点保障推理过程的可追溯性,这对涉及合规审查的工程场景尤为重要。Yu 等[6]从挑战、方法、应用等多个视角系统综述了神经符号学习系统的研究进展,将主流融合策略归纳为三类:一是规则约束注入神经网络训练过程,通过软约束项引导嵌入学习;二是神经网络辅助规则发现,利用学习模型挖掘潜在逻辑规则;三是两种推理结果的后融合,通过显式的融合机制整合符号推理与神经推理的输出。侯中妮等[7]在知识图谱可解释推理综述中将神经符号推理列为提升推理可解释性的关键路径之一。

在上述提到的三类策略中,规则正则化方法与本文采用的后融合策略最具可比性,二者的差异集中体现在三个方面。其一,可解释性:规则正则化通常将规则知识分散吸收进实体与关系的嵌入参数,因此单条预测结果与具体规则之间的对应关系相对弱化;后融合保持符号推理与神经推理两路输出的独立性,每条结论均可追溯至具体的规则触发或模型打分。其二,性能:从作用机理看,规则正则化通过将规则约束引入嵌入学习过程,有助于优化实体与关系表示,因此在规则质量较高且覆盖充分的情况下,可能提升链路预测性能;后融合策略不参与嵌入参数训练,其主要作用是利用规则结果对神经模型输出进行校验、过滤或重排序,因此对表示学习本身不产生影响,但可能改善最终结果的可靠性与一致性。其三,实现与维护复杂度:规则正则化需要将规则编码为可优化约束并参与模型训练,当规则体系发生变化时,通常需要重新训练或增量更新模型参数;后融合策略中规则引擎与神经模型相互解耦,规则可独立维护并即时生效,但需要额外设计融合机制与冲突裁决策略。

本文面向的电网技术标准合规场景有两点硬性需求:一是每条推理结论须可追溯,以支撑合规审查;二是强制性约束不可违反、且须随标准频繁修订独立更新。在这一类强调合规可审查、规则需独立演化的场景下,后融合相较规则正则化在可解释性与可维护性上具有明确优势,并能将不可违反的约束置于显式的硬过滤环节,因而是更契合的选择。

3. 神经符号推理方法设计

3.1. 问题设定与总体框架

本文研究的电网技术标准知识图谱形式化定义为 $G = (E, R, T)$ 。其中实体集合 E 涵盖标准名称、标准条款、电力设备、技术要求、运行状态、指标参数、约束条件、应用领域等核心类型；关系集合 R 涵盖引用、替代、适用于、规定、应满足、具备等典型语义关系；三元组集合 T 以三元组 (h, r, t) 表示头实体 h 通过关系 r 与尾实体 t 相连。在此基础上，本文研究的推理任务可定义为：对于给定的查询模式 $(h, r, ?)$ 或 $(?, r, t)$ ，预测缺失的实体，并为预测结果提供可追溯的推理依据。

该任务的难点在于，电网技术标准知识同时包含以强制性措辞表达的确定性约束，以及标准间未被显式标注的隐含关联，二者对推理提出了相互掣肘的要求：发现隐含关联需要神经网络的泛化能力，而保证不违反强制性约束又要求符号逻辑的确定性。为此，本文设计的神经符号推理方法整体由三个核心模块构成：基于霍恩子句的启发式规则推理模块，负责为候选关联提供可解释的领域规则支持；基于 R-GCN 的链路预测模块，负责隐含关联的概率性发现；融合控制模块，通过“候选生成 - 约束校验”两阶段流程实现两类推理结果的整合。

三个模块以候选三元组为中心串联为统一的推理流程，如图 1 所示。R-GCN 链路预测模块与规则推理模块分别对候选三元组产出概率得分与规则支持信号；融合控制模块在第一阶段对两类信号加权融合并降序排序，在第二阶段以图谱中编码的强制性约束对排序结果进行硬过滤；最终输出附带推理依据的有效关联，被剔除的候选连同触发的约束记入冲突报告。由此，语义发现与合规约束在职责上相互分离，推理结果兼具隐含关联的发现能力与强制约束下的可追溯性。




Figure 1. Overall architecture diagram of neural symbolic reasoning

图 1. 神经符号推理总体架构图

3.2. 知识图谱数据基础

本文图谱以电力行业技术标准 PDF 文本为数据来源。考虑到标准文本中不同知识要素的结构特征差异，抽取环节采用分类处理的混合策略。元数据(起草单位、起草人、发布与实施日期等)位置固定、句式

规整,采用正则匹配与句式模板的规则方法抽取;领域实体(标准、条款、设备、技术要求等)内嵌于正文且边界依赖语境,采用 BERT-BiLSTM-CRF 序列标注模型识别;实体间关系(引用、替代、适用于、规定等)句式多样且标注语料稀缺,借助大语言模型在受控模式下抽取。三路抽取结果经标准编号规范化、同义实体归并、合规相关三元组人工校核后,融合为统一图谱,并以属性图形式存储于 Neo4j,如图 2 所示。最终图谱包含实体约 6800 个、三元组约 25,300 个。




Figure 2. Partial of the knowledge graph for power grid technical standards
图 2. 电网技术标准知识图谱局部

3.3. 基于霍恩子句的启发式规则推理

电网技术标准文本中包含“引用……条款”“替代……标准”“应满足……要求”等典型句式，分别对应引用链传递、版本替代继承、技术要求传播等领域推断逻辑。需要说明的是，这些推断在领域内多数情形下成立，但并非在任何情形下都绝对可靠(例如“替代继承”在被替代条款发生实质性修订时未必成立)，因此本文将其作为启发式正向信号而非确定性证明加以使用；真正不可违反的合规条文则由 2.4 节的强制性约束单独承担。本文将上述领域逻辑形式化为霍恩子句(Horn Clause)。结合电网标准的结构特征，经人工抽取与领域专家校验，构建了包含 10 条核心逻辑的启发式规则集，覆盖标准替代、要求传递等高频推断场景，如表 1 所示。

Table 1. Heuristic reasoning rule set
表 1. 启发式推理规则集

规则名称	逻辑表达式	推理场景
间接引用	$\text{RefersTo}(A,B) \wedge \text{RefersTo}(B,C) \rightarrow \text{IndirectRef}(A,C)$	引用链传递
引用链闭包	$\text{RefersTo}(A,B) \wedge \text{IndirectRef}(B,C) \rightarrow \text{IndirectRef}(A,C)$	多级引用链传递
替代继承	$\text{Replaces}(S2,S1) \wedge \text{RefersTo}(X,S1) \rightarrow \text{RefersTo}(X,S2)$	版本替代继承
替代链传递	$\text{Replaces}(S3,S2) \wedge \text{Replaces}(S2,S1) \rightarrow \text{Replaces}(S3,S1)$	多版本连续替代

续表

版本解析	$\text{RefersTo}(X,N) \wedge \text{CurrentVersion}(S,N) \rightarrow \text{RefersTo}(X,S)$	不注日期引用解析
要求继承	$\text{Replaces}(S2,S1) \wedge \text{Specifies}(S1,R) \rightarrow \text{Specifies}(S2,R)$	替代后要求承继
领域继承	$\text{AppliesTo}(S,D2) \wedge \text{SubDomain}(D1,D2) \rightarrow \text{AppliesTo}(S,D1)$	适用范围扩展
要求传递	$\text{Specifies}(C,R) \wedge \text{AppliesTo}(C,E) \rightarrow \text{Requires}(E,R)$	技术要求传播
处置匹配	$\text{Occurs}(E,\text{Cond}) \wedge \text{HandledBy}(\text{Cond},M) \rightarrow \text{Requires}(E,M)$	运行处置匹配
处置继承	$\text{SubType}(E2,E1) \wedge \text{Occurs}(E1,\text{Cond}) \rightarrow \text{Occurs}(E2,\text{Cond})$	设备子类工况承继

推理执行采用基于 Python 的前向链匹配引擎：遍历规则集中每条规则，在三元组知识库中进行模式匹配，逐条前提缩小候选范围；当所有前提模式均被满足时，根据变量绑定生成受规则支持的候选三元组并写入候选集。整个过程通过多轮迭代实现，直至无新候选产生或达到预设最大迭代轮数。规则推理对待评估三元组给出的支持信号形式化定义为：

$$f_{rule}(h,r,t) = \begin{cases} 1, & \text{若}(h,r,t) \text{获得规则集启发式支持} \\ 0, & \text{其他情况} \end{cases} \quad (1)$$

3.4. 基于 R-GCN 的链路预测

电网技术标准知识图谱具有典型的多关系异构图特征：节点类型多样(标准、条款、设备、参数等)，关系类型丰富(引用、替代、适用等)。在多种图神经网络方法中，本文选用关系图卷积网络(R-GCN)作为编码器，主要考虑以下两点：一是 R-GCN 为每种关系类型设计独立的权重变换矩阵，能够建模不同关系下邻居信息的差异化贡献，这与电网标准知识图谱中引用、替代、适用等关系语义差异显著的特征相匹配；二是相较于 TransE、DistMult 等仅依赖实体与关系嵌入的平移或双线性表示模型，R-GCN 通过消息传递机制在编码阶段显式聚合图结构与邻居信息，更适合刻画标准间经由多步邻接路径建立的隐含关联。在此基础上，解码阶段采用双线性打分函数衡量头尾实体嵌入在特定关系下的匹配程度。

R-GCN 推理模块采用编码器 - 解码器结构。编码器采用两层 R-GCN 算子[8]，第 $l+1$ 层的节点更新逻辑为：

$$h_i^{(l+1)} = \sigma \left(\sum_{r \in \mathcal{R}} \sum_{j \in \mathcal{N}_i^r} \frac{1}{c_{i,r}} W_r^{(l)} h_j^{(l)} + W_0^{(l)} h_i^{(l)} \right) \quad (2)$$

其中 $\mathcal{N}_i^r$ 为节点 i 在关系 r 下的邻居集合， $c_{i,r} = |\mathcal{N}_i^r|$ 为归一化常数， $W_r^{(l)}$ 为关系 r 在第 l 层的权重矩阵， $W_0^{(l)}$ 为自环权重矩阵， σ 为非线性激活函数。节点初始特征由文本语义向量与实体类型特征共同构建。其中，节点文本语义向量由预训练语言模型编码获得，用于表征标准名称、条款内容及技术术语所蕴含的语义信息；实体类型特征采用 One-hot 方式表示，两者拼接后作为 R-GCN 输入特征。为降低多关系导致的参数量，引入基底分解技术将 $W_r^{(l)}$ 表示为多个共享基底矩阵的线性组合。

解码器采用双线性打分函数：

$$f_{rgcn}(h,r,t) = \text{Sigmoid}(e_h^T W_r e_t) \quad (3)$$

其中 e_h, e_t 为经 R-GCN 编码后的嵌入向量， W_r 为关系 r 的可训练双线性打分矩阵(可取对角形式以等价于 DistMult 打分，或取满秩形式以增强关系表达能力；本文取对角形式以控制参数规模)。模型采用监督学习方式完成参数训练，相关超参数与训练设置见表 2。

Table 2. R-GCN hyperparameters and training settings
表 2. R-GCN 超参数与训练设置

类别	项目	取值
编码器	R-GCN	层数 2、隐藏维 64、基数 10、ReLU、含自环、反向边
解码器	双线性打分函数	$f_{rgcn}(h, r, t) = \text{Sigmoid}(e_h^T W_r e_t)$
训练目标	损失函数	带负采样的二元交叉熵(BCE Loss)，负采样比例 10
正则	权重衰减/dropout	1e-5/0.1
优化	优化器/学习率/轮数/批	Adam/0.01/300/1024

3.5. 两阶段协同融合机制

为整合规则推理与 R-GCN 推理两类异质结果，本文设计“候选生成 - 约束校验”两阶段融合机制。第一阶段对候选三元组进行打分排序；第二阶段对通过排序筛选的候选进行强制约束校验。

第一阶段：候选打分。对任一待评估三元组 (h, r, t) ，融合 R-GCN 与规则推理的输出计算候选综合得分：

$$S_{candidate}(h, r, t) = \alpha \cdot f_{rgcn}(h, r, t) + \beta \cdot f_{rule}(h, r, t) \quad (4)$$

其中 α 和 β 为两种推理策略的权重系数 $\alpha + \beta = 1$ ； $f_{rgcn}(h, r, t) \in [0, 1]$ 为 R-GCN 置信度得分； $f_{rule}(h, r, t) \in \{0, 1\}$ 为规则启发式支持信号，取值 1 表示候选获得规则集支持、0 表示无规则支持。 α 和 β 的取值反映两种推理策略在领域中的相对可靠程度，可由领域专家根据应用场景进行设定。该阶段输出为按 $S_{candidate}$ 降序排列的候选三元组列表。

第二阶段：约束校验。对第一阶段产生的候选列表逐条进行强制性约束校验。本文将强制性约束形式化为一组否定型完整性约束 C ，每条约束 $c \in C$ 刻画一种被明确禁止的三元组模式，涵盖两类：一是标准条款规定的物理性硬限(如特定电压等级下的绝缘距离、特定环境下的设备类型限制等)；二是本体层面的规制对象类型一致性约束(若某标准所规制的对象类型与候选客体的对象类型不匹配，例如“保护配置与整定”类标准与“设备本体运维”类对象，则即便二者业务场景存在重叠，该“适用”关系仍被禁止)。校验依据为图谱中已显式编码的上述约束与领域本体。在系统实现中，强制性约束主要采用 Datalog 逻辑编程语言或图数据库知识查询语言进行形式化表达。约束校验的判定过程为：

$$\text{Validate}(h, r, t) = \begin{cases} \text{True, 若 } (h, r, t) \text{ 未违反任何强制性约束} \\ \text{False, 若 } (h, r, t) \text{ 违反至少一条强制性约束} \end{cases} \quad (5)$$

校验通过的候选三元组保留并作为有效推理结果输出；校验未通过的候选三元组从结果中剔除，同时记录至冲突日志，其内容包括触发的具体约束规则与冲突依据，供领域专家审查。

两阶段流程的核心设计逻辑在于将“评分”与“约束”职责分离。评分回答“哪些候选更可能成立”，约束回答“哪些候选必须被剔除”。在电网技术标准领域，存在不可违反的强制性约束条文。即使 R-GCN 与规则推理在第一阶段共同给出较高的综合得分，一旦预测结果违反强制性约束，第二阶段将确保其被过滤。这种“先评分、后校验”的设计避免了将硬约束与软评分混淆的逻辑问题，使推理过程的可追溯性显著增强。

4. 典型应用场景示例

为说明方法在电网技术标准业务场景中的工作过程，本节围绕标准知识的智能发现与合规校验，给

出三个典型示例。三个示例所涉标准均为电力行业技术标准体系中的现行有效标准。

场景背景。在知识发现过程中，R-GCN 推理模块基于语义相似性会产生大量候选关联三元组：其中既有标准文本支持、却在抽取阶段被遗漏的合理关联，也有语义相近、却违反领域强制性约束的违规关联。如何在充分保留 R-GCN 语义发现能力的同时，既不漏掉合理关联、又确保结果不违反工程合规性要求，是方法在工程应用中需要回答的关键问题。

示例一。R-GCN 推理模块对 DL/T 2957-2025《光储系统接入配电网继电保护技术要求》¹的关联关系进行分析，产生候选三元组(DL/T 2957-2025, 适用于, 户外高压开关设备)，其 R-GCN 语义置信度得分 f_{rgcn} 较高。该候选的产生可归因于两个方面：一是两类标准在一二次设备协同、配电自动化控制及分布式电源倒闸操作等重合业务场景上的语义嵌入相似度较高；二是图谱中存在多条经由“保护装置联动断路器跳闸”等交互路径建立的潜在联系。在第一阶段候选打分中，由于规则推理未触发支持该候选的规则， $f_{rule} = 0$ ，候选综合得分 $S_{candidate}$ 等于 $\alpha \cdot f_{rgcn}$ ，仍在排序列表中处于较前位置。进入第二阶段约束校验时，规则引擎对该候选执行规制对象类型一致性校验。校验依据为 DL/T 2957-2025 在标准文本中明确限定的适用范围——“光储系统接入配电网”场景，其保护配置要求针对光储系统公共连接点与电网侧的继电保护；而户外高压开关设备的运行规程遵循 DL/T 1081-2025《12 kV~40.5 kV 户外高压开关运行规程》²等一次设备专项规程。二者虽在配电自动化、断路器联动等业务场景上存在交集，但所规制的对象类型并不一致。两者的适用对象存在本质差异：DL/T 2957-2025 面向“二次保护配置与整定”，户外高压开关设备属于“一次本体运行维护”，前者并不构成后者标准合规引用的直接适用依据。约束校验函数 $\text{Validate}(h, r, t)$ 返回 False，该候选的“适用于”关系被判定违规并从输出结果中剔除，同时生成冲突报告记录冲突触发的具体约束与依据。

示例二。DL/T 1081-2025 在第 6.1 条 b)、c)中对“含分布式电源线路的户外高压开关倒闸操作”作出了专门规定，但在图谱抽取阶段，该适用关系常因散见于“安全操作”章节而未被显式标注。在知识发现中，R-GCN 基于该标准与分布式电源、配电自动化终端、倒闸操作等节点的语义邻接关系，产生候选三元组(DL/T 1081-2025, 适用于, 含分布式电源配电网的开关倒闸操作场景)，其 R-GCN 语义置信度得分较高；由于规则集未对其给出支持(规则支持信号取 0)，候选综合得分仅由 R-GCN 得分加权构成，在排序列表中位置靠前。进入第二阶段约束校验时，该候选未触及任何强制性约束，DL/T 1081-2025 的适用对象本就涵盖户外高压开关的倒闸运行操作，候选客体与其适用范围一致，不存在规制对象类型不匹配的冲突，校验函数返回 True。该候选遂作为有效隐含关联被采纳并写入图谱，补全了一条有标准文本支持、却在抽取阶段被遗漏的适用关系。

示例三。DL/T 2157-2020 在其规范性引用文件中以不注日期方式引用了“GB/T 14286 带电作业工具设备术语”，即图谱中存在 RefersTo (DL/T 2157-2020, GB/T 14286)；而该引用名当前对应的现行有效版本为 GB/T 14286-2021 (其替代了已废止的 GB/T 14286-2008)，即图谱中存在 CurrentVersion (GB/T 14286-2021, GB/T 14286)。在知识发现中，R-GCN 对候选三元组(DL/T 2157-2020, 引用, GB/T 14286-2021)给出中等偏上的置信度得分 f_{rgcn} ，二者间缺乏直接的显式引用边，仅凭 R-GCN 难以稳定地将该候选排至列表前列。与此同时，规则推理模块的“版本解析”规则被触发：由 RefersTo (DL/T 2157-2020, GB/T 14286) 与 CurrentVersion (GB/T 14286-2021, GB/T 14286)经前向链匹配，生成受规则支持的候选 RefersTo (DL/T 2157-2020, GB/T 14286-2021)，故该候选的规则支持信号 $f_{rule} = 1$ 。在第一阶段候选打分中，综合得分 $S_{candidate}$ 因规则项的加入而显著高于仅靠 R-GCN 的情形，候选排序位置相应前移。进入第二阶段约束校验，该“引用”关系不触及任何强制性约束，校验函数返回 True，候选被采纳。

¹<https://std.samr.gov.cn/hb/search/stdHBDetailed?id=461E291C92B4AB7EE06397BE0A0A7DFF>

²<https://std.samr.gov.cn/hb/search/stdHBDetailed?id=461E291C9292AB7EE06397BE0A0A7DFF>

应用价值。上述三个示例共同展示了本文方法三个模块的协同工作过程：R-GCN 负责“发现可能性”，规则引擎负责“判定合法性与提供支持”，两阶段融合机制负责“权衡与裁决”。这种协同模式既保留了 R-GCN 从图结构中发现隐含关联的能力，又通过领域规则的启发式支持与强制性约束，确保推理结果可解释、可追溯且不偏离工程合规边界，是单一推理范式无法独立实现的。此外，冲突报告本身也为标准管理人员审查图谱质量提供了线索：若某类冲突反复出现，可能反映 R-GCN 对该类语义边界的学习不足，或图谱中相关约束条文的编码尚不完整。

5. 结论与展望

本文围绕电网技术标准知识图谱的推理需求，开展了神经符号推理方法的体系化框架设计研究。通过基于霍恩子句的启发式规则集为候选关联提供可解释的领域支持，通过 R-GCN 编码器与双线性解码器实现隐含关联发现，通过“候选生成-约束校验”两阶段融合机制实现两类推理策略的协同。本文在方法层面将神经符号推理范式系统化地引入电网技术标准领域，在应用层面为标准智能化管理提供了一套可解释、可扩展的推理方法框架。未来工作将探索在更大规模知识图谱上的方法适应性，并研究将大语言模型作为第三类推理引擎纳入协同框架的可行性。

基金项目

国家电网有限公司科技项目资助(项目编号：520940250006)。

参考文献

- [1] Hogan, A., Blomqvist, E., Cochez, M., D'amato, C., Melo, G.D., Gutierrez, C., *et al.* (2021) Knowledge Graphs. *ACM Computing Surveys*, **54**, 1-37. <https://doi.org/10.1145/3447772>
- [2] 张建良, 麻坚, 季瑞松, 等. 面向新型电力系统的故障诊断技术研究进展(一): 机理建模和信号分析[J]. 实验技术与管理, 2025, 42(11): 38-51.
- [3] 谢庆, 蔡扬, 谢军, 等. 基于 ALBERT 的电力变压器运维知识图谱构建方法与应用研究[J]. 电工技术学报, 2023, 38(1): 95-106.
- [4] Marra, G., Dumančić, S., Manhaeve, R. and De Raedt, L. (2024) From Statistical Relational to Neurosymbolic Artificial Intelligence: A Survey. *Artificial Intelligence*, **328**, Article ID: 104062. <https://doi.org/10.1016/j.artint.2023.104062>
- [5] Hitzler, P., Eberhart, A., Ebrahimi, M., Sarker, M.K. and Zhou, L. (2022) Neuro-Symbolic Approaches in Artificial Intelligence. *National Science Review*, **9**, nwac035. <https://doi.org/10.1093/nsr/nwac035>
- [6] Yu, D., Yang, B., Liu, D., Wang, H. and Pan, S. (2023) A Survey on Neural-Symbolic Learning Systems. *Neural Networks*, **166**, 105-126. <https://doi.org/10.1016/j.neunet.2023.06.028>
- [7] 侯中妮, 靳小龙, 陈剑赞, 等. 知识图谱可解释推理研究综述[J]. 软件学报, 2022, 33(12): 4644-4667.
- [8] Schlichtkrull, M., Kipf, T.N., Bloem, P., van den Berg, R., Titov, I. and Welling, M. (2018) Modeling Relational Data with Graph Convolutional Networks. In: Gangemi, A., *et al.*, Eds., *The Semantic Web*, Springer International Publishing, 593-607. https://doi.org/10.1007/978-3-319-93417-4_38