

doi: 10.3969/j.issn.1672-6073.2026.04.012

基于大模型的轨道交通运维知识图谱构建方法

崔玉龙, 王俊彦, 陈景浩, 孙可心

(中车青岛四方机车车辆股份有限公司, 山东青岛 266111)

摘要: 针对轨道交通运维知识图谱构建过程中人工依赖程度高、数据处理复杂、构建效率低等问题, 提出一种基于大语言模型的自动化知识图谱构建方法。首先, 设计面向轨道交通运维领域的双阶段垂域专属提示词模板, 分别用于领域概念层生成和运维数据抽取; 其次, 利用大语言模型的零样本学习能力, 自动生成符合资源描述框架(resource description framework, RDF)语法规则的知识图谱数据; 最后, 构建基于提示词驱动的知识图谱构建框架, 实现轨道交通运维元数据向 RDF 知识图谱的自动转化, 并支持与已有知识图谱的融合。实验结果表明: 与通用 Prompt 相比, 本文方法的实体抽取准确率由 81.2% 提升至 93.8%; 概念层完整性由 68.4% 提升至 91.6%, 复杂关系抽取准确率由 46.7% 提升至 78.9%; 与 OpenNRE、语言技术平台(language technology platform, LTP)、Bert4Keras 3 种三元组抽取方法相比, 本文方法 Prompt+LLM 的精确率为 94%, 召回率为 93%, F1 值为 0.93, 抽取时间为 562 ms, 整体效果最优。该方法有效提高轨道交通运维知识图谱的构建效率和质量, 可为轨道交通智能运维决策及其他领域知识图谱自动构建提供参考。

关键词: 轨道交通; 运维; 知识图谱; 大语言模型; 提示词工程

中图分类号: U231

文献标志码: A

文章编号: 1672-6073(2026)04-0107-07

Construction Method of Rail Transit Operation and Maintenance Knowledge Graphs Based on Large Language Models

Cui Yulong, Wang Junyan, Chen Jinghao, Sun Kexin

(CRRC Qingdao Sifang Locomotive & Rolling Stock Co., Ltd., Qingdao 266111)

Abstract: To address the problems of high manual dependence, complex data processing, and low construction efficiency in constructing knowledge graphs for rail transit operation and maintenance, this paper proposes an automated knowledge graph construction method based on large language models. First, two-stage domain-specific prompt templates for rail transit operation and maintenance are designed for domain concept layer generation and operation and maintenance data extraction, respectively. Second, the zero-shot learning capability of large language models is employed to automatically generate knowledge graph data that conform to RDF syntax specifications. Finally, a prompt-driven knowledge graph construction framework is developed to automatically transform rail transit operation and maintenance metadata into RDF knowledge graphs and support integration with existing knowledge graphs. The experimental results show that, compared with the general prompt, the proposed method improves entity extraction accuracy from 81.2% to 93.8%, an increase of 12.6 percentage points; the completeness of the concept layer increases from 68.4% to 91.6%; and the accuracy of complex relation extraction increases from 46.7% to 78.9%. In the comparison with three triple extraction methods, namely OpenNRE, the Language Technology Platform (LTP), and Bert4Keras,

收稿日期: 2025-07-10 修回日期: 2026-02-26

第一作者: 崔玉龙, 男, 硕士, 正高级工程师, 主要从事动车组网络控制及人工智能等方面研究, cuiyulong@cqsf.com

基金项目: 国家铁路局(KF2024-055)

引用格式: 崔玉龙, 王俊彦, 陈景浩, 等. 基于大模型的轨道交通运维知识图谱构建方法[J]. 都市轨道交通, 2026, 39(4): 107-113.

the proposed Prompt+LLM method achieves a precision of 0.94, a recall of 0.93, an F1-score of 0.93, and an extraction time of 562 ms. The results indicate that the proposed method can effectively improve the efficiency and quality of knowledge graph construction for rail transit operation and maintenance, providing a reference for intelligent rail transit operation and maintenance decision-making and the automated knowledge graph construction in other domains.

Keywords: rail transit; operation and maintenance; knowledge graph; large language model; prompt engineering

在轨道交通运维领域,构建知识图谱可以支撑故障诊断、维修决策与智能运维^[1-2]。然而,该垂直领域在知识图谱构建过程中仍面临显著挑战,其核心痛点在于运维数据呈现出多源异构、语义复杂、结构差异显著的特征^[3-4],既包括结构化的运维数据,也包含大量非结构化的维修记录、技术文档等^[5]。

传统的轨道交通运维知识图谱构建方法主要依赖规则工程或监督学习模型,需要大量人工参与进行实体与关系标注^[6]。这类方法不仅构建周期长、标注成本高,而且对标注数据规模与覆盖度高度敏感,难以适配运维场景中普遍存在的低频实体、长尾故障模式及复杂因果关系抽取需求。随着大语言模型(large language model, LLM)的快速发展,生成式知识图谱构建方法逐渐兴起^[7-8]。然而,现有生成式知识图谱研究多聚焦于开放或通用语义空间,尚未针对工业级垂直领域的复杂业务逻辑进行系统优化^[9]。

具体到轨道交通运维场景,现有“大模型+提示词”的知识抽取方案多采用通用提示设计,缺乏对领域知识的显式注入^[10-11],未能充分融合设备分类标准、故障演化逻辑及运维流程规范等关键约束条件^[12]。通用提示词仅能抽取基础实体与简单关系,无法识别轨道交通运维的专属术语(如“DMI 触屏无效”、“3 取 2 冗余技术”)、复杂因果链(如“轮对磨损→制动性能下降→列车延误”)。这一不足导致模型在概念层生成与数据层填充之间难以形成一致的语义约束,无法实现“概念层自动生成—数据层精准填充”的全流程自动化构建^[13],同时在复杂关系与低频实体抽取精度方面仍存在明显不足^[14-15]。针对上述问题,本文提出了一种基于大语言模型的轨道交通运维知识图谱构建框架,通过面向领域特性的提示词设计,引导模型在概念层与数据层两个阶段协同工作,通过嵌入领域标准、术语词典、故障逻辑等知识,引导大模型精准生成符合垂域需求的概念层,并高效抽取专属实体与关系,填补通用方法的垂域适配缺口,构建符合领域语义约束的知识图谱。

1 轨道交通运维知识图谱构建

1.1 构建框架

本文设计了一种基于 LLM 的轨道交通运维知识图谱构建方法,整体框架如图 1 所示。该方法以轨道交通运维数据表、运维案例和运维文本为主要数据来源,围绕领域概念层生成和资源描述框架(resource description framework, RDF)数据层填充两个环节展开。首先利用面向轨道交通运维场景设计的提示词,引导 LLM 从运维数据表和运维案例中提取设备、故障、现象、原因、措施等领域核心概念及其关系,生成符合 RDF 语法规则的领域概念模型。为提高概念层质量,对生成结果进行人工校核与规范化调整,主要包括去除无关或重复概念、合并语义相近类别、补充缺失实体及关系、修正不合理的类层级和属性约束。




图1 基于大模型轨道交通运维知识图谱构建框架

Figure 1 Construction framework of a rail transit O&M knowledge graph based on large language models

在 RDF 数据层填充阶段,利用数据抽取提示词引导 LLM 从轨道交通运维文本中抽取实体、关系和属性,并按照概念层结构转化为 RDF 三元组。该过程通过概念层约束抽取范围,通过 RDF 标准化表示保证数据规范性,同时依托 LLM 的零样本学习能力减少人工标注,提高构建效率。生成的 RDF 数据层可进一步

融合到已有知识图谱中,并随新增运维数据持续更新,从而保证知识图谱构建的准确性和可扩展性。

在构建过程中,LLM 不断进行迭代优化,确保抽取出的知识具有较高的准确性和完整性。每当有新的轨道交通运维数据(如新的故障记录或设备更新信息)产生时,新的数据将通过同样的流程进行抽取,并与现有的 RDF 数据进行融合,更新知识图谱。具体的构建流程包括 2 个步骤。

步骤 1: 将故障运维元数据输入大语言模型,并通过 Prompt 1 生成初始知识图谱概念层(RDF Schema),以构建轨道交通故障运维知识图谱的概念层。由于大语言模型生成的概念层可能存在概念冗余、关系缺失或层级划分不准确等问题,因此需要结合领域知识对其进行校核与调整。调整过程主要包括:对重复或语义相近的概念进行合并,对与故障运维业务无关的概念进行删除,对缺失的核心实体、属性及关系进行补充,并对不合理的类层级结构和属性约束进行修正,从而提高概念层的规范性和领域适配性。

步骤 2: 完成概念层构建后,进一步开展实例层知识抽取与图谱融合。首先利用 Prompt 2 引导大语言模型对实际故障运维数据进行解析,抽取其中的实体、关系和属性信息,并按照 RDF 标准将其格式化为三元组数据。随后,将生成的 RDF 三元组与已有知识图谱进行匹配和合并,避免重复实体并保持图谱结构的一致性。

该流程可在每次数据更新时重复执行,使知识图谱能够随着新增运维数据的引入而持续更新和完善。

1.2 构建提示

在轨道交通运维领域,知识图谱的构建需要遵循特定的领域知识体系和标准。《城市轨道交通运营规范》(GB/T 30012—2013)^[16]中定义的设备分类标准和故障等级划分逻辑,为设备类型和故障模式的识别提供了明确的框架。通过精心设计的提示词,大语言模型能够基于这些标准和逻辑进行知识图谱的自动化构建。当构建设备类型知识图谱时,Prompt 框架首先会引导 LLM 识别设备的类别,如列车、信号系统等。基于《城市轨道交通运营规范》中的设备分类标准,LLM 能够自动区分不同类型的设备,并将这些类别与其相关属性(如型号、生产日期等)一起生成知识图谱。这种基于行业标准的提示词设计,能够有效提升知识图谱生成的精确性和一致性。

在构建轨道交通运维知识图谱的过程中,设计合适的 Prompt 是关键的一步。以设备类型为例,通过对

这一概念进行精准的定义和结构化表达,提示词可以引导 LLM 根据标准化的分类逻辑来进行设备类型的识别与生成。例如,图 2 是一个与设备类型相关的提示词设计:

“你是一个轨道交通运维领域的知识工程师,现需要根据《城市轨道交通运营规范》对设备类型进行分类。设备类型包括:列车、信号系统、电力设备、通讯设备等。请根据这些设备类型标准,识别并分类给定的设备信息。设备的具体信息如下:[设备信息]。请返回设备类别及其相关属性。”

图 2 提示词设计
Figure 2 Prompt design

为了进一步提升 RDF Schema 建模及三元组抽取的效率和轨道交通运维领域专有属性,本文设计了两种针对轨道交通运维知识图谱构建的 Prompt 模板,分别为领域概念层生成 Prompt 和数据抽取 Prompt。如图 3 示例的领域概念层生成 Prompt 所示,该框架设计了 4 个固定模块,保证 Prompt 输入清晰、输出标准化。

模块 1: 背景信息与历史输入:限定轨道交通运维领域范围;

模块 2: 源文本描述:指明多源异构数据来源,如工单、维修记录、技术文档等;

模块 3: 任务描述:明确目标,如生成概念层 RDF Schema 或抽取三元组;

模块 4: 结构化输出需求:要求输出标准 JSON/RDF 格式,便于自动构建图谱。

示例 Generating Prompt for Domain Concept Layer

功能:引导 LLM 生成知识图谱的顶层概念框架(RDF Schema)

具体内容:

//背景信息

你是一个轨道交通运维领域的知识工程师,需构建符合 RDF 语法的知识图谱。

已有领域知识包括:设备类型(如列车、信号系统)、故障模式、维修流程等。

//源文本描述

输入数据为轨道交通运维原始数据,包含结构化数据、半结构化数据及非结构化数据。

//任务描述

请根据领域知识,生成轨道交通运维知识图谱的概念层结构(RDF Schema)。

要求:

① 定义核心类(Class)及层级关系(如:列车 $\sqsubseteq$ 设备)

② 定义每个类的属性(Property)及数据类型(如:生产日期 $\sqsubseteq$ xs:date)

③ 用 RDF 语法输出

//结构化输出需求

输出格式:

```
{
  "classes": [
    {
      "name": "类名",
      "subClassOf": "父类名",
      "properties": [
        {"name": "属性名", "type": "数据类型"}
      ]
    }
  ]
}
例如:
{
  "classes": [
    {
      "name": "列车",
      "subClassOf": "设备",
      "properties": [
        {"name": "列车标识", "type": "xs: string"},
        {"name": "制造商", "type": "xs: string"},
        {"name": "生产日期", "type": "xs: date"}
      ]
    },
    {
      "name": "运维事件",
      "subClassOf": "事件",
      "properties": [
        {"name": "事件时间", "type": "xs: datetime"},
        {"name": "事件原因", "type": "xs: string"},
        {"name": "解决方案", "type": "xs: string"}
      ]
    }
  ]
}
```

图 3 领域概念层生成 Prompt 示例

Figure 3 Example of prompt generation at the domain concept layer

在知识图谱的增量更新过程中, Prompt 的动态调整机制是确保图谱持续扩展的重要环节。当新的设备实体如“5G 车载通信模块”出现时,领域概念层 Prompt 需要自动补充该实体的类定义和属性。在数据抽取 Prompt 中, LLM 会根据新的设备特征和故障模式, 自动调整数据抽取规则, 识别并抽取新型设备的故障属性和相关信息。这一机制确保了知识图谱在面对新兴设备和技术时, 能够自动进行扩展和更新。

1.3 检索增强生成模块

检索增强生成(retrieval-augmented generation, RAG)是一种结合检索和生成的自然语言处理技术。它通过将信息检索和生成式模型相结合, 使得模型能够在生成过程中充分利用外部知识库的信息, 从而提高生成内容的准确性和相关性。RAG 的核心思想是将传统的生成模型与信息检索相结合, 利用检索模块从大量非结构化文本或结构化知识库中检索到相关信息, 再结

合这些信息生成。

在本文中, 知识图谱作为外部知识库, 与 RAG 中的检索模块紧密集成。当用户输入查询时, 模型首先通过查询生成器生成与输入任务相关的查询条件, 然后从构建的轨道交通运维知识图谱中检索出相关的实体、关系及事件信息。这些信息将作为辅助知识输入到生成模块中, 帮助生成模型生成具有高语义一致性和专业性的推理结果。此举不仅提高了模型在任务中的准确性, 也提升了生成结果的领域相关性。具体而言, RAG 的推理流程包括 3 个步骤。

步骤 1: 查询生成。基于用户输入的轨道交通运维相关任务或问题, 生成与之相关的查询条件。对应的函数式为

$$q = \text{QueryGenerator}(x) \quad (1)$$

式中, q 表示生成的查询条件; x 是用户输入的轨道交通运维相关任务或问题; QueryGenerator 是查询生成器模型。这个函数根据用户输入的内容, 生成与之相关的查询条件。

步骤 2: 知识检索。通过查询生成器, 从知识图谱中检索轨道交通运维相关实体和关系, 并作为辅助信息。对应的函数式为

$$R = \text{Retrieve}(q, G) \quad (2)$$

式中, R 表示检索到的轨道交通运维相关实体及其关系; G 表示轨道交通运维知识图谱, 包含实体集 $E = \{e_1, e_2, \dots, e_n\}$ 和关系集 $R = \{r_1, r_2, \dots, r_m\}$ 。通过函数 Retrieve , 从知识图谱 G 中检索出与查询条件 q 相关的实体和关系。

步骤 3: 结果生成。结合检索到的轨道交通运维相关知识, 通过生成模块生成最终的推理结果, 提供任务所需的详细信息或解决方案。对应的函数式为

$$y = \text{GenerationModel}(q, R) \quad (3)$$

式中, y 表示最终生成的推理结果; GenerationModel 表示生成模型, 该模型根据查询条件 q 和检索到的轨道交通运维相关知识 R , 生成最终的结果。该生成过程可视为一个条件生成过程, 条件是查询与检索结果, 目标是生成与任务相关的精确输出。知识图谱的自动化推理与 RAG 的生成能力相结合, 能够有效地处理轨道交通运维领域中的复杂任务。

2 实验结果与分析

2.1 实验设置

为验证本文方法在轨道交通运维知识图谱构建

任务中的有效性,从数据来源、模型选择以及抽取效果 3 个方面展开实验。考虑到轨道交通运维数据具有多源异构、专业性强和长尾故障突出等特点,本文构建了包含结构化、半结构化和非结构化数据的实验数据集,并在统一大语言模型基础上,对提示词机制下的知识抽取效果进行对比分析。

实验数据集: 实验中采用多源异构数据,包括以下 3 类: ①结构化数据。指轨道交通设备故障领域的数据集,包含 9 000 条维修工单记录。每条工单详细记录了设备编号、所属部门与人员 ID、维修时间、设备地点、故障现象、维修记录等信息; ②半结构化数据。包括检修台账、运维日志文件、报表数据等,总计 13 300 条; ③非结构化数据。包括维修记录文本、设备技术手册、历史故障报告、专家经验文档等,总文本量约 80 万字。

实验模型: 不同大语言模型在基础抽取能力上存在差异,但本文关注的重点在于提示词机制对运维知识图谱构建质量的影响,因此后续实验统一采用通义千问大模型进行对比分析。

在轨道交通运维领域,高频故障模式通常已固化于既有的规则与经验中,而各类低频、长尾的异常事件(如“DMI 触屏无效”“站台门关闭但列车门未关”等)恰恰是运维应急决策的痛点与难点,其能否被有效识别直接关系到知识图谱在应急处置等关键场景中的支撑能力。为进一步评估方法在真实运维场景中的实用性,本实验针对低频实体抽取效果进行了专项分析与验证,并分析其复杂关系的抽取效果。

2.2 专属提示词对知识图谱质量的影响

本节将探讨专属提示词和通用提示词对知识图谱构建质量的影响。实验在相同数据集、相同大语言模型及相同计算环境下,仅以提示词设计方式作为控制变量,分别构建专属提示词和通用提示词两组实验方案。

方案 1: 专属提示词组。采用本文设计的两阶段定制化提示词体系,即领域概念层生成 Prompt(Prompt 1)与数据抽取 Prompt(Prompt 2)。该提示词在设计中显式嵌入轨道交通运维领域知识,包括设备分类体系、典型故障术语、运维事件结构及故障演化逻辑,用于引导模型先生成符合领域规范的 RDF Schema,再完成数据层三元组填充。

方案 2: 通用提示词组。采用通用知识抽取提示词,不引入任何领域约束,仅要求模型“从轨道交通运维文本中抽取实体、关系并生成 RDF 图谱”,模拟

当前通用大模型直接抽取或通用 Prompt 的常见使用方式。

为全面评估提示词设计对运维知识图谱构建质量的影响,本文从概念层完整性、实体抽取准确率以及复杂关系抽取准确率 3 个与行业应用高度相关的核心指标进行对比分析。

指标 1: 概念层完整性。用于衡量生成的 RDF Schema 是否覆盖轨道交通运维领域的核心概念体系。评价基准参考实际运维业务需求,重点关注设备类、故障现象类、故障原因类、运维事件类、处理措施类及其层级关系是否完整生成。

指标 2: 实体抽取准确率。用于评估图谱中实体识别的准确性,重点考察领域专属实体(如设备子系统、专业故障术语、技术方案名称等)的识别效果。

指标 3: 复杂关系抽取准确率。用于评估模型对运维领域中隐含逻辑关系的抽取能力,重点包括多级因果关系与影响链条(如“设备部件磨损→系统性能下降→行车影响”)的识别与建模效果。

实验结果如表 1 所示。由表 1 可知: 专属 Prompt 相比通用 Prompt,概念层完整性由 68.4%提升至 91.6%,实体抽取准确率由 81.2%提升至 93.8%,复杂关系抽取准确率由 46.7%提升至 78.9%。可见,在 3 项核心指标上,采用专属提示词的实验组均显著优于通用提示词组。轨道交通运维知识图谱构建质量的提升并非仅依赖大语言模型本身的通用能力,而在很大程度上取决于是否采用面向垂域特性的专属提示词设计。专属提示词通过将领域知识显式注入模型推理过程,有效弥补了通用方法在垂域语义理解与结构化表达方面的不足,是实现高质量运维知识图谱构建的关键技术环节。

表 1 提示词对知识图谱构建质量的影响

Table 1 The impact of prompts on the quality of knowledge graph construction %

提示词	概念层完整性	实体抽取准确率	复杂关系抽取准确率
通用 Prompt	68.4	81.2	46.7
专属 Prompt	91.6	93.8	78.9

2.3 现有方法对三元组抽取对比

为了进一步验证本文提出的方法的有效性,将本文方法 Prompt+LLM 与一些常见的中文自然语言处理方法包括 OpenNRE、语言技术平台(language technology platform, LTP)和 Bert4Keras 等进行对比。实验中,以三元组抽取效果作为评价指标,使用精确率(Precision)、

召回率(Recall)、F1 值(F1-score)及时间 T 作为性能衡量标准, 实验结果如表 2 所示。

表 2 4 种方法进行三元组抽取的效果对比
Table 2 Performance comparison of four triple extraction methods

方法	精确率/%	召回率/%	F1-score	T /ms
OpenNRE	90	92	91	1 131
LTP	94	94	94	981
Bert4Keras	89	91	90	1 268
Prompt+LLM	94	93	93	562

由表 2 可知: 基于 Prompt 与 LLM 的组合方法在三元组抽取任务中表现出色, 精确率达到 94%, 召回率为 93%, F1 值为 0.93, 且运行时间显著低于其他深度学习模型; 相比于 Open-NRE、LTP 和 Bert4Keras 等基于深度学习的工具, 基于提示的 LLM 方案具有更低的计算成本和更高的处理效率, 尤其在低代码平台中具有较高的可操作性和响应性。

综上, 基于 LLM 的知识图谱构建方法相较于传统深度学习模型, 能够更加高效、便捷地完成三元组抽取, 并且在处理大规模数据时具有较大的优势。

2.4 低频实体抽取分析

本文在实验数据集上依据实体出现频次将其进行排序, 并根据 20%、60%、20%的比例将实体划分为高、中、低 3 个频次区间。针对出现频次后 20%的低频实体的专项分析实验中, 设置召回率(Recall)和 F1 值(F1-score)用于评估抽取效果。针对低频实体抽取任务, 选取 OpenNRE、LTP、Bert4Keras 和 Prompt+LLM 4 种方法进行对比, 结果如表 3 所示。

表 3 低频实体抽取效果对比
Table 3 Performance comparison of low-frequency entity extraction

方法	召回率/%	F1-score
OpenNRE	56	62
LTP	41	49
Bert4Keras	58	65
Prompt+LLM	75	72

由表 3 可知: 在低频实体抽取任务中, 本文所提出的方法展现出了显著优势, 在低频测试集上的 Recall 和 F1 值分别达到了 75%与 0.72, 显著优于对比方法; LTP 在高频实体抽取任务上表现稳健, 但召回率在低频实体上急剧下降至 41%; OpenNRE 与 Bert4Keras 两

者 F1 值分别降至 0.58 和 0.65, 表明了监督学习模型对数据分布的强依赖性。本文引入的 LLM 推理机制有效弥补了传统方法在零样本/少样本场景下的能力短板, 通过利用领域知识进行逻辑推理, 实现了对低频实体的精准捕捉。

3 结论

本文主要研究了基于大语言模型的轨道交通运维知识图谱构建方法, 提出了一种双阶段垂域专属提示词机制, 实现了轨道交通运维原始数据向领域知识图谱的自动化构建, 并对 OpenNRE、LTP 和 Bert4Keras 等传统方法进行了实验, 得出如下结论:

1) 与通用 Prompt 相比, 本文提出的专属 Prompt 能够有效提升知识图谱构建质量, 其中实体抽取准确率由 81.2%提高到 93.8%; 概念层完整性由 68.4%提高到 91.6%; 复杂关系抽取准确率由 46.7%提高到 78.9%。

2) 在 OpenNRE、LTP、Bert4Keras 和 Prompt+LLM 4 种三元组抽取算法对比中, 本文采用的 Prompt+LLM 方法取得了较好的综合效果, 其 F1 值为 0.93, 召回率为 93%, 同时抽取时间为 562 ms, 表现出较高的抽取效率和应用价值。

未来研究将进一步探索面向多领域的知识图谱自动构建方法, 研究 Prompt 自动生成技术, 并完善知识图谱构建效果的评价指标体系, 以提升方法的通用性和智能化水平。

参考文献

[1] 桂林, 李远峰, 陈剑佳, 等. 轨道交通规范知识图谱构建技术研究[J]. 计算机应用文摘, 2025, 41(3): 52-54.
Gui Lin, Li Yuanfeng, Chen Jianjia, et al. Research on construction of knowledge graph of rail transit design specification[J]. Computer Application Abstracts, 2025, 41(3): 52-54.

[2] 司春宁. 基于知识图谱技术的轨道交通设备智能运维系统[J]. 交通世界, 2021(增刊 1): 12-14.

[3] 何小兵, 陈学锋, 陈俊, 等. 多源异构数据实时主动处理技术在城市轨道交通供电智能运维中的应用研究[J]. 城市轨道交通研究, 2022, 25(9): 16-22.
He Xiaobing, Chen Xuefeng, Chen Jun, et al. Research on application of multi-source heterogeneous data real-time active processing technology in urban rail transit power

- supply smart operation and maintenance[J]. Urban Mass Transit, 2022, 25(9): 16-22.
- [4] 任超. 铁路智能运维系统中多源异构数据融合技术研究[D]. 兰州: 兰州交通大学, 2021.
- Ren Chao. Research on multi-source heterogeneous data fusion technology in railway intelligent operation and maintenance systems[D]. Lanzhou: Lanzhou Jiaotong University, 2021.
- [5] Fan B S, Shao C F, Liu Y T, et al. A new approach in developing an urban rail transit emergency knowledge graph based on operation fault logs[J]. Journal of Transportation Safety & Security, 2023, 15(10): 1057-1085.
- [6] 王兴鹏, 籍仲轩, 王为鑫. 基于知识图谱的地铁施工质量验收标准的知识组织与应用[J]. 都市快轨交通, 2025, 38(6): 107-115.
- Wang Xingpeng, Ji Zhongxuan, Wang Weixin. Knowledge organization and application of metro construction quality acceptance standards based on knowledge graphs[J]. Urban Rapid Rail Transit, 2025, 38(6): 107-115.
- [7] 洪钊, 黄鸿发. 生成式知识图谱构建综述[J]. 人工智能与机器人研究, 2026, 15(1): 168-179.
- Hong Zhao, Huang Hongfa. A survey on generative knowledge graph construction[J]. Artificial Intelligence and Robotics Research, 2026, 15(1): 168-179.
- [8] Ye H B, Zhang N Y, Chen H, et al. Generative knowledge graph construction: a review[C]//Proceedings of the 2022 Conference on Empirical Methods in Natural Language Processing. Abu Dhabi, 2022: 1-17.
- [9] 于皓, 张杰, 吴明辉, 等. 领域知识图谱快速构建和应用框架[J]. 智能系统学报, 2021, 16(5): 870-884.
- Yu Hao, Zhang Jie, Wu Minghui, et al. A framework for rapid construction and application of domain knowledge graphs[J]. CAAI Transactions on Intelligent Systems, 2021, 16(5): 870-884.
- [10] 于秋波, 魏秋实, 冯培, 等. 城市轨道交通智慧运维研究现状及展望[J]. 兰州交通大学学报, 2025, 44(2): 53-58.
- Yu Qiubo, Wei Qiushi, Feng Pei, et al. Current research and future prospects of intelligent operation and maintenance in urban rail transit[J]. Journal of Lanzhou Jiaotong University, 2025, 44(2): 53-58.
- [11] 于松伟, 刘巍, 夏秀江, 等. 基于知识图谱的城轨大模型 RAG 检索增强知识库构建研究[J]. 都市快轨交通, 2025, 38(2): 1-7.
- Yu Songwei, Liu Wei, Xia Xiujiang, et al. Constructing a retrieval-augmented generation knowledge base for urban rail transit large language models: a knowledge graph-based approach[J]. Urban Rapid Rail Transit, 2025, 38(2): 1-7.
- [12] 吴志强. HaloChat 运维大模型与数字化轨道交通的共赢之路[J]. 城市轨道交通, 2024(3): 57-58.
- [13] 周炫余, 李璇, 卢笑, 等. 多层次知识增强提示的中文无监督关键词抽取方法研究[J]. 北京航空航天大学学报, 2025. DOI: 10.13700/j.bh.1001-5965.2024.0933.
- Zhou Xuanyu, Li Xuan, Li Xiao, et al. Research on Chinese unsupervised keyphrase extraction with multi-level knowledge enhanced prompting[J/OL]. Journal of Beijing University of Aeronautics and Astronautics, 2025. DOI: 10.13700/j.bh.1001-5965.2024.0933.
- [14] 徐声, 刘志远. 城市轨道交通车辆智能运维指标体系及其应用[J]. 机械与电子控制工程, 2023, 5(10): 233-235.
- [15] Wang J, Zhang Z C, Gao S B, et al. Framework and key technologies of intelligent operation and maintenance of traction transformer based on knowledge graph[C]//Proceedings of the 5th International Conference on Electrical Engineering and Information Technologies for Rail Transportation (EITRT) 2021. Singapore: Springer, 2022: 476-485.
- [16] 国家质量监督检验检疫总局, 中国国家标准化管理委员会. 城市轨道交通运营管理规范: GB/T 30012—2013[S]. 北京: 中国标准出版社, 2014.
- General Administration of Quality Supervision, Inspection and Quarantine of the People's Republic of China, Standardization Administration of the People's Republic of China. Regulations for operation management of urban rail transit: GB/T 30012—2013[S]. Beijing: Standards Press of China, 2014.

(编辑: 王艳菊)