

DOI:10.3876/j.issn.1000-1980.2026.05.009

知识图谱与大语言模型协同的河涌整治方案 智能决策方法

张凯博¹, 叶枫^{1,2}, 许栋², 李彬权³, 窦身堂⁴

(1. 河海大学计算机与软件学院; 2. 河海大学水利部水循环与水动力系统重点实验室;
3. 河海大学水文水资源学院; 4. 黄河水利科学研究院)

摘要: 针对当前河涌整治方案决策中多源数据整合不足、系统级关联缺失及决策可解释性弱等问题,提出了一种知识图谱与大语言模型协同的河涌整治方案智能决策方法。该方法通过整合河涌、水闸工况、联围拓扑等多源数据构建了河涌整治知识图谱,设计了两阶段分类模型(阶段 1 基于随机森林建模物理特征与工程比值参数;阶段 2 从知识图谱中提取拓扑关系,采用 Node2Vec 算法生成 64 维图嵌入特征输入逻辑回归模型优化决策边界),开发了基于 DeepSeek-R1 的生成式评估引擎,结合领域知识增强的提示学习,通过多步推理生成可解释推理链,用于方案可行性评估与改进建议生成,并通过多标签分类性能对比和消融实验对该方法进行了验证。广州市南沙区 228 条河涌实例验证结果表明:该方法可有效缓解传统方法中多源数据整合不足、系统级关联分析缺失、决策过程可解释性弱的问题,其 F1 值(精确率与召回率的调和平均数)达 0.853,准确率达 0.921,整体性能优于所列基线模型;拓扑嵌入和领域知识增强的多步推理机制均能有效改善方法的性能,本文方法取得了最高的 F1 值和最低的汉明损失,验证了各关键模块的有效性。

关键词: 河涌整治;知识图谱;大语言模型;系统关联分析;可解释决策;方案优选

中图分类号:TV85 文献标志码:A 文章编号:1000-1980(2026)05-0079-12

Intelligent decision-making method for river regulation schemes via collaboration of knowledge graph and large language model

Zhang Kaibo¹, Ye Feng^{1,2}, Xu Dong², Li Binqun³, Dou Shentang⁴

(1. College of Computer Science and Software Engineering, Hohai University;

2. Key Laboratory of Hydrologic-cycle and Hydrodynamic System of Ministry of Water Resources, Hohai University;

3. College of Hydrology and Water Resources, Hohai University; 4. Yellow River Institute of Hydraulic Research)

Abstract: To address problems such as insufficient multi-source data integration, lacking system-level association analysis, and weak decision interpretability in current decision-making of river regulation schemes, an intelligent decision-making method for river regulation schemes via collaboration of knowledge graph and large language model was proposed. In this method, a knowledge graph for river regulation was constructed by integrating multi-source data such as river channels, sluice operating conditions, and dyke-cluster topology. A two-stage classification model was designed (Stage 1 modeled physical features and engineering ratio parameters based on random forests; Stage 2 extracted topological relationships from the knowledge graph and utilized the Node2Vec algorithm to generate 64-dimensional graph embedding features input into a logistic regression model for optimizing decision boundary). A generative evaluation engine based on DeepSeek-R1 was developed, which combined domain-knowledge-enhanced prompt learning to generate interpretable reasoning chains through multi-step reasoning for scheme feasibility assessment and improvement recommendation generation. The proposed method was validated through multi-label classification performance comparison and ablation experiments. Verification results of 228 river channels in Nansha District, Guangzhou indicate that this method can effectively alleviate the problems of insufficient multi-source data integration, missing system-level association analysis, and weak interpretability of decision-making process in traditional methods. Its F1 score (the harmonic mean of precision and recall) reaches 0.853, and the accuracy reaches 0.921, indicating that its overall performance is superior to that of the baseline models considered. Both the topological embedding and

基金项目: 国家重点研发计划项目(2022YFC3202600);国家自然科学基金项目(U2443219);广州市南沙区防洪潮安全系统提升关键技术
研究项目(823005916)

作者简介: 张凯博(2002—),男,硕士研究生,主要从事知识工程研究。E-mail:zhangkaibo@hhu.edu.cn

通信作者: 叶枫(1980—),男,讲师,博士,主要从事水利信息化与数字孪生研究。E-mail:yefeng1022@hhu.edu.cn

the domain-knowledge-enhanced multi-step reasoning mechanism can effectively improve method performance. The proposed method achieves the highest F1 score and the lowest Hamming loss, verifying the effectiveness of each key module.

Key words: river regulation; knowledge graph; large language model; system association analysis; interpretable decision; scheme optimization

本文所指的河涌是珠江三角洲城市内的河汊、支流及人工渠化河道,在城市水系中承担着排涝、水质净化和生态景观等重要职责^[1]。城市化进程加速导致河涌淤积、断面缩窄,防洪能力持续下降;叠加极端天气频发,城市内涝风险显著增加,易引发交通瘫痪、基础设施损毁及公共卫生风险^[2-5]。因此,科学整治河涌对提升城市水系管理效能具有关键意义^[6-7]。

为强化城市对抗内涝灾害的韧性,减小其造成的损害与波及范围,国内外学者围绕城市内涝防灾与河涌整治开展了系列研究。马超等^[8]将示踪方法与水力计算耦合揭示排水分区水量关联性并提出防灾方案,使方案制定时聚焦区域积水量,降低规划成本;Wang 等^[9]结合 CMIP6 数据模拟未来城市降雨和内涝情景,为城市排涝规划提供依据;徐存东等^[10]提出一种基于信息熵权的改进 TOPSIS 综合评价模型,并将其应用于乌海市摩尔沟河道整治方案的优选中;李慧宁等^[11]采用 Infoworks ICM 水力模型分析城市的排水防涝体系,剖析内涝成因并提出治理方案;王凌河等^[12]结合雅砻江流域内的调水工程,选择多指标表征生态环境,设置多种调水方案,利用模糊优选方法对雅砻江调水方案进行优化选择。然而,现有研究多依赖独立数据库,缺乏对多源实体数据(如河涌、水闸、联围等)的动态关联建模。使用传统的水动力数学模型和机器学习模型虽能通过数据分析和评估提出一种可行性高的河涌整治方案,但是未考虑方案组合对河涌整治的影响,并且评估机制具有黑箱性,无法生成领域适配的推理链。

随着人工智能的快速发展,神经网络^[13-14]、知识图谱(knowledge graph, KG)^[15]、大语言模型(large language model, LLM)^[16]等开始广泛应用于水利信息化领域的研究中。Wang 等^[17]利用图卷积神经网络(graph convolutional network, GCN),以低成本、高精度、广覆盖和细粒度的方式实现了城市内涝监测;Waqas 等^[18]将长短期记忆网络(long short-term memory, LSTM)和循环神经网络(recurrent neural network, RNN)与小波变换(wavelet transform, WT)相结合,在季节性降雨预测中比传统 LSTM 模型具有更高的预测精度;冯钧等^[19]提出了基于 LLM 的水工程调度知识图谱构建法,能高效提炼规则文本,完成数据集与图谱的构建;杨燕等^[20]融合 LangChain 和提示学习,提出了面向数字孪生水利领域的 LLM 知识抽取方法,确保了知识图谱构建质量,实现了该领域图谱的构建。然而,知识图谱与大语言模型在河涌整治中的潜力尚未充分挖掘。

本文以广州市南沙区的河涌为研究对象,提出了一种知识图谱与大语言模型协同的河涌整治方案智能决策方法(以下称为 KG-TS2-LLM),构建了“全域感知-知识融合-动态评估”的全链条决策框架。区别于单一数据驱动方法,本文决策框架通过知识图谱实现结构化工程参数与拓扑关系的系统整合,采用随机森林^[21]与 Node2Vec 算法^[22]构建两阶段分类模型,并结合 DeepSeek-R1^[23]设计领域知识增强的提示学习,进行多维度、多步骤评分修正的评估与优化,筛选高质量方案。需说明的是,本文方法与当前主流的检索增强生成(retrieval-augmented generation, RAG)^[24]范式不同,RAG 依赖单向知识检索辅助生成,而本文方法通过“物理特征→拓扑约束→语义验证”协同机制,知识图谱提供拓扑关联约束,驱动两阶段分类模型动态优化决策边界,LLM 则受思维链(chain-of-thought, CoT)^[25-26]技术启发,通过针对性提示工程模块,以知识图谱信息为事实锚点、评估标准为考量依据,生成可解释推理链并反馈修正模型输出,形成完整优化链路;同时,针对水利工程数据量受限的场景,Node2Vec 算法与随机森林的高效计算特性有助于降低对训练样本量的依赖,结合提示学习注入的防洪排涝标准等先验知识,可为河涌整治建立系统关联约束下的动态决策框架。

1 关键技术基础

1.1 Binary Relevance

Binary Relevance^[27]即二元相关性,通过将多标签分类问题转化为多个二元分类问题简化问题的复杂度,其中每个二元分类器对应一个待预测的标签。该方法适用于因变量之间不存在相关依赖关系的情况,便于快速处理河涌整治多标签决策场景。

1.2 随机森林

随机森林是一种机器学习算法,它通过构建大量决策树进行分类或回归任务,并通过聚合这些树的预测

结果提高整体模型的准确性和鲁棒性。选择随机森林作为基分类器,是因其具有强非线性拟合能力,抗噪声鲁棒性强,可捕捉河涌物理参数与整治方案间的复杂关系。

1.3 Node2Vec 算法

Node2Vec 算法是一种基于随机游走的节点嵌入方法,通过对图中节点进行采样,并利用这些采样结果训练能够表示节点的嵌入向量。这些向量不仅能保留节点的局部邻域信息,还能反映节点在整个图中的全局位置。Node2Vec 算法能平衡捕捉水系网络的局部结构与全局层级关联,较动态图神经网络更具计算效率与工程适配性,能有效解决数据量限制下的系统级关联建模难题。

1.4 逻辑回归模型

逻辑回归模型^[28]使用一个参数化函数(式(1))计算给定输入变量的输出概率。该函数称为 sigmoid 函数,它将输入变量的线性组合映射到 0~1 间的数值,表示预测样本属于正例的概率。sigmoid 函数的特性使其能够将任意实数映射到(0,1)区间,故适用于二分类问题的概率预测。

$$\sigma(x) = \frac{1}{1 + e^{-x}} \tag{1}$$

式中: x 为逻辑回归模型的线性预测量; $\sigma(\cdot)$ 为 sigmoid 函数。

1.5 DeepSeek-R1

DeepSeek-R1 是基于 Transformer 的千亿参数大语言模型,具有推理性能优异、自我演化等特点,采用基于规则的强化学习方法,可观察输出内容,使用预定义的规则计算每个输出的奖励,从而训练模型生成首选方案。由于不使用神经模型生成奖励,该方法简化并降低了训练成本。其中,思维链作为 DeepSeek-R1 的重要推理增强机制,是一种模拟人类逻辑推理过程的技术,它将复杂问题拆解为一系列连续的、具有因果关联的中间推理步骤,通过逐步推导最终得出结论。采用该链式设计,可使复杂决策的逻辑清晰、可追溯,提升推理的准确性。

2 河涌整治方案智能决策方法

河涌整治方案智能决策方法包括知识图谱构建、多模态特征融合、生成式评估优化 3 个核心模块,可完成从原始数据到决策方案的全流程处理。

2.1 双驱动协同决策体系架构

双驱动机制即数据驱动与知识驱动的协同:数据驱动聚焦物理参数建模,为知识驱动提供数据基础;知识驱动则通过知识图谱编码拓扑关系约束,以修正数据驱动的结果。双驱动协同决策体系架构,自顶向下分别为感知层、认知层和决策层(图 1):①感知层整合多源异构数据,包括河涌信息、水闸分布统计、政府排涝规划等数据,通过知识图谱实现知识对齐;②认知层采用两阶段多标签分类器,阶段 1 基于物理参数生成基础方案概率,阶段 2 引入图嵌入特征优化决策边界;③决策层设计领域知识引导的 LLM 评估引擎,对认知层中得到的方案进行多维评估和多步推理,融合数据特征与知识图谱关系,通过评分机制评估并优化方案,从而得到最优整治方案。

2.2 河涌整治知识图谱构建

知识图谱在逻辑架构上分为模式层和实例层,模式层在实例层之上,是知识图谱的核心^[29]。河涌整治知识图谱采用自顶向下与自底向上结合的研究范式构建领域知识图谱(图 2)。①进行模式层构建。模式层采用自顶向下的方式,结合专家经验、业务机理、产业准则等领域知识,设计出河涌整治所涉及的实体、实体属性和关系,实现河涌整治知识图谱的本体设计和模式层构建。②进行实例层构建。实例层采用自底向上的方式,对河涌断面观测统计、防洪排涝规划等多源异构数据进行收集和预处理,从中抽取实体及关系,利用 DeepSeek-R1 进行知识融合与加工,实现知识对齐,完成实例层的构建。

2.2.1 模式层构建

本体是一个描述性的形式化概念体系,是知识图谱的模式层,包含点类型、点类型属性以及边类型、边类型属性。领域本体是指领域概念体系的形式化规范定义。本文关注河涌整治领域的相关知识,采用七步法构建该领域的本体模型(图 3),结合领域知识定义了河涌、水闸、排涝片、联围、镇街、整治方案 6 种本体类(实体类型),以及各本体类的属性(表 1)和本体类之间的关系(表 2)。




图 1 双驱动协同决策体系架构

Fig. 1 Dual-driven collaborative decision-making system architecture




图 2 河涌整治知识图谱构建框架

Fig. 2 Construction framework of knowledge graph for river regulation



图 3 七步法构建本体模型流程

Fig. 3 Seven-step process for constructing ontology model

表 1 模式层本体类及其属性

Table 1 Ontology classes and their attributes in the schema layer

本体类(实体类型)	属性
河涌	ID、名称、河底高程、河长、河口宽、河底宽、水深、流速、过流能力、天然来水、是否满足排峰要求
水闸	ID、名称、净宽、闸底板高程、过流能力、天然来水、是否满足排峰要求
排涝片	ID、名称、最高水位、水面率、泵站流量、规划排涝标准
联围	ID、名称、总面积、围内面积、河涌面积、围内河涌水面率、堤防长度、岸线长度
镇街	ID、名称、负责人、联系电话
整治方案	ID、名称、推理链

2.2.2 实例层构建

知识图谱的实例层一般以三元组为基本单位,用于存储具体的数据信息^[30],一般表示为:

$$G = \{E, R, F\} \tag{2}$$

式中: G 为知识图谱; E 、 R 、 F 分别为实体集合 $\{e_1, e_2, \cdots, e_{n_E}\}$ 、关系集合 $\{r_1, r_2, \cdots, r_{n_R}\}$ 和事实集合 $\{f_1, f_2, \cdots, f_{n_F}\}$ 。 F 中每个事实均表示为一个三元组 (h, r, t) , 其中, h 为头实体, r 为关系边, t 为尾实体。

收集的数据类型包括结构化数据、半结构化数据和非结构化数据,如图 4 所示。结构化数据为表格形式的数据,如河涌信息汇总表、现状涝片最高水位统计表等;半结构化数据为嵌入在文本里的表格和具有固定格式的文本;非结构化数据为排涝分析报告和河涌水系规划等文本内容。




图 4 与河涌整治相关的多模态数据类型

Fig. 4 Multimodal data types related to river regulation

对于结构化数据,结合本体模型批量提取关键信息。对于半结构化数据,通过定义正则表达式从固定格式的文本中提取关键信息,人工抽取文本中的表格。对于非结构化数据,利用 DeepSeek-R1 通过少样本提示和上下文提示的方式,根据本体模型提取文本中的关键信息。具体流程如下:①降噪处理。对非结构化数据进行降噪处理,保留文本内容,并利用切片做到“文章→段落”,把得到的段落内容存入 JSON 格式文件中。②段落分析与填充。发挥 DeepSeek-R1 的长上下文推理能力,通过深度语义理解,将段落中“该河道”“如上措施”等模糊指代词汇精准映射为具体名称。③实体与关系抽取。调用 DeepSeek-R1 对已经处理好的段落进行实体识别并提取出它的名称和类型,结合本体模型,构造 Prompt 进行提示学习(图 5),将输出的实体以 JSON 格式进行保存。④知识融合与加工。将抽取的三元组经过 DeepSeek-R1 过滤,剔除同义和近义的表达。




图 5 Prompt 设计模板

Fig. 5 Prompt design template

对提取的知识进行融合与加工之后,将 JSON 格式的实体-属性、实体-关系三元组存入 Neo4j 图数据库中,实现对河涌整治知识图谱的构建与存储。

2.3 拓扑嵌入的两阶段分类模型

构建两阶段分类模型,通过物理特征与拓扑嵌入的级联融合,输出9种预定义整治方案的多标签概率分布。其中,拓扑嵌入指从知识图谱提取拓扑关系(如河涌-水闸连接),通过 Node2Vec 算法编码为 64 维向量的过程;预定义的整治方案参照《广州市南沙新区防洪(潮)排涝规划标准》,包括维持现状、清淤、拓宽、延伸、部分调整、局部改道、改道、开挖为人工湖、开挖为水库。如图 6 所示,模型采用“物理特征→拓扑嵌入”的双阶段特征传递机制:阶段 1 为物理特征分类,采用 Binary Relevance 分解多标签任务,通过随机森林学习河涌特征与方案间的映射关系,基于水文参数生成基础概率分布;阶段 2 为拓扑特征融合,融合知识图谱的拓扑特征进行方案修正,将阶段 1 输出的概率向量与 Node2Vec 算法生成的图嵌入拼接,利用逻辑回归建模系统级约束。




图 6 两阶段分类模型框架

Fig. 6 Framework of two-stage classification model

2.3.1 物理特征分类

阶段 1 的基本输入特征为河涌参数(表 1),输出的概率分布为各种预定义方案的可能性。由于在河涌整治实践中经常出现组合型决策(如清淤并拓宽),故整治方案具有多标签特性。为此,本模型设计为多标签分类任务,以实现复合整治方案的识别与概率量化。在完成去除缺失值、重复值、异常值的数据清洗后,需要根据数据特征进行特征工程的处理。根据水利领域知识,新增断面形态系数(S)、流速效率(V_e)、过流容纳率(ρ_{cn})3 项特征:

$$S = \frac{W_b}{W_{ot}} \quad V_e = \frac{v}{\sqrt{gh_1}} \quad \rho_{cn} = \frac{Q_c}{Q_n} \tag{3}$$

式中: W_b 、 W_{ot} 分别为河底宽和河口宽; v 为流速; g 为重力加速度(取 9.8 m/s^2); h_1 为水深; Q_c 为过流能力; Q_n 为天然来水量。

阶段 1 将 Binary Relevance 多标签分类方法与随机森林模型结合,共同预测河涌整治方案的基础概率分布。Binary Relevance 将多标签任务分解为 M 个相互独立的二分类子任务。给定 N 个样本,对第 j 个标签训练随机森林分类器,则样本 i 对应的预测概率及二值预测结果表示为:

$$p_{ij} = f_j(\mathbf{x}_i) \quad \hat{y}_{ij} = I(p_{ij} \geq \tau) \quad (i = 1, 2, \dots, N, j = 1, 2, \dots, M) \tag{4}$$

式中: N 为样本数; M 为标签数; $\mathbf{x}_i \in \mathbb{R}_{d_p}$ 为样本 i 的物理特征向量; $d_p = 12$ 为物理特征维数; $f_j(\cdot)$ 为第 j 个标签对应的随机森林概率预测函数; $p_{ij} \in [0, 1]$ 为预测概率; $\hat{y}_{ij} \in \{0, 1\}$ 为预测结果; $I(\cdot)$ 为示性函数,当括号内条件成立时取 1,否则取 0; $\tau = 0.5$ 为分类阈值。

融合河涌的水文参数和领域知识引导的新增特征参数作为输入特征,采用表 3 中参数,利用 Binary Relevance 和随机森林得到阶段 1 的基础概率分布 $\mathbf{P}$:

$$\mathbf{P} = f_{\text{BR-RF}}(\mathbf{X}_{\text{phys}}) = (p_{ij})_{N \times M} \tag{5}$$

式中: $f_{\text{BR-RF}}(\cdot)$ 为 Binary Relevance 与随机森林组合模型的整体概率预测映射; $\mathbf{X}_{\text{phys}} \in \mathbb{R}_{N \times d_p}$ 为物理特征矩阵; $\mathbf{P} \in [0, 1]_{N \times M}$ 为基础概率矩阵。

2.3.2 拓扑特征融合

阶段 2 的输入特征为阶段 1 得到的基础概率分布 $\mathbf{P}$ 和河涌的拓扑特征,其中拓扑特征即为河涌在知识图谱中的关联信息。对于拓扑特征的提炼,首先通过图数据库查询语言 Cypher 从 Neo4j 中提取有关该河涌

表 3 阶段 1 关键参数

Table 3 Key parameters of Stage 1

参数	取值	作用
决策树数量	200	平衡精度与计算成本
最大深度	10	控制过拟合,经交叉验证确定
类别权重	'balanced'	缓解类别不平衡问题

的关联信息,包括其出口连接的水闸,所处的排涝片等信息;其次,由于传统的机器学习方法难以直接处理图数据,故引入 Node2Vec 算法,将节点映射为低维向量,使其能够被应用到分类任务中。需要说明的是,“河涌-计划-整治方案”关系仅在决策完成后用于存储输出结果,不参与 Node2Vec 训练及阶段 2 的特征构建; Node2Vec 仅利用河涌与水闸、排涝片、联围和镇街之间的既有拓扑关系生成图嵌入。此外,采用逻辑回归作为阶段 2 的分类算法,由于该算法适用于二分类问题,故本研究将其与 Binary Relevance 相结合,使算法能够适用于多标签分类任务。在得到图嵌入矩阵 $\mathbf{Z} \in \mathbb{R}_{N \times d_e}$ (d_e 为图嵌入特征维数, $d_e=64$) 后,将其与基础概率矩阵 $\mathbf{P}$ 进行水平拼接,并输入逻辑回归模型,基于表 4 中参数得到最终多标签预测矩阵 $\hat{\mathbf{Y}}$:

$$\hat{\mathbf{Y}} = I \{ \sigma [\text{Concat}(\mathbf{P}, \mathbf{Z}) \mathbf{W} + \mathbf{b}] \geq \tau \}$$

(6)

式中:Concat(·)为矩阵水平拼接; $\mathbf{W} \in \mathbb{R}_{(M+d_e) \times M}$ 为权重矩阵; $\mathbf{b} \in \mathbb{R}_M$ 为偏置向量,并按样本维度逐行参与运算; $\sigma(\cdot)$ 为逐元素作用的 sigmoid 函数; $\hat{\mathbf{Y}} \in \{0,1\}_{N \times M}$ 为最终预测矩阵。


表 4 阶段 2 关键参数

Table 4 Key parameters of Stage 2

参数	取值	作用
图嵌入维度	64	平衡信息量与维度灾难
节点遍历的步长	20	反映平均路径长度
随机游走的次数	10	生成一系列随机游走路径,这些路径将用于训练模型
惩罚项	11	特征选择,提升模型可解释性
正则化系数	0.1	控制正则化强度,防止过拟合

2.4 生成式决策评估优化引擎

基于 DeepSeek-R1 的生成式决策评估优化引擎,通过自然语言推理与领域知识注入,引入思维链技术,将评估过程分解为多步推理,通过提示学习对 DeepSeek-R1 进行启发式引导,为方案的可行性论证提供依据。图 7 为生成式决策评估优化引擎的流程框架。



注: 箭头旁序号表示信息流转顺序; 步骤①~③为并行的信息准备环节; 步骤⑦~⑨仅在评估得分低于4分时执行, 步骤⑩为最终输出。

图 7 生成式决策评估优化引擎流程框架

Fig. 7 Process framework of generative decision evaluation and optimization engine

从认知层中得到两阶段分类模型给出的结果,将其作为待评估的决策方案;并从感知层中通过 Cypher 语法提取有关河涌的关联信息,包括河涌的属性、出口水闸、联围等,将这些关联信息转换成自然语言作为接下来评估的领域信息依据。此外,从《广州市防洪排涝建设标准》中提炼 4 个关键点,包括技术可行性、经济效益、环境影响和实施难度,将其作为评估标准。

受 CoT 技术的启发,提出推理链启发式提示策略。模型在推理过程中以知识图谱中的信息为事实锚点,以评估标准为考量依据,采用多步推理的方式,首先根据领域信息和评估标准给出待评估方案存在的关键问题;其次,基于关键问题的严重性、方案的可行性与河涌及周边设施的现状对方案进行综合性评分(五分制)。若评分在 4 分及以上,则视为方案通过,推理链需要总结推理过程,给出简短且具有可解释性的评估理由;若评分在 4 分以下,则需要结合河涌现状和方案存在的问题,对决策库中的 9 种整治方案进行五分制的评分,选取评分在 4 分及以上的方案进行组合,作为最终的确定方案,并在推理链中给出修正理由。

3 实例验证

3.1 研究区概况

南沙区位于广州市最南端,珠江虎门水道西岸,是西江、北江、东江三江汇流入海口,东邻东莞,西接中山、佛山,南濒伶仃洋,总面积 803 km²(其中陆域 570 km²,水域 233 km²),其概况如图 8 所示。地属亚热带季风气候,年均降水量达 1 700 mm,汛期占全年 80%以上,且 7—9 月台风多发,最大风力超 9 级。区域内河涌众多,共有 228 条,但是水面率仅 3.64%,调蓄能力有限。作为粤港澳大湾区核心枢纽,南沙区亟须通过优化系统性防洪排涝规划,提升城市韧性,以支撑其国际化滨海新城的定位。




图 8 南沙区概况
Fig. 8 Overview of Nansha District

3.2 实验数据与环境

实验选用广州市南沙区截至 2022 年底的水利数据,涵盖河涌、水闸、排涝片、联围、镇街及整治方案等信息,来源于 106 个结构化表格和非结构化文档。基于上述数据构建的南沙区河涌整治知识图谱包含 509 个实体节点,其中河涌 228 个、水闸 228 个、排涝片 25 个、联围 11 个、镇街 8 个、整治方案 9 个;包含 1 237 条关系边,如出口连接、流经等,以及 4 401 个属性字段,如名称、底高程、过流能力等。在感知层中,上述数据经融合后存储于 Neo4j 图数据库。针对两阶段分类模型,将数据集按照 7 : 3 随机划分为训练集和测试集。实验所用的实际方案(即真实值)由水利领域专家小组制定,方案已经过为期一年的观察调研,具有极高的可行性。

实验在 Windows 10 操作系统下进行,具体的实验环境有: Intel (R) Core (TM) i7-10750H CPU @ 2.60 GHz; GPU 型号: NVIDIA GeForce GTX 1650 Ti; 编程工具、语言和关键库包括: PyCharm 2024.3.3、Neo4j Community 5.26.3、Python 3.12、scikit-learn 1.6.1、py2neo 2021.2.4、node2vec 0.5.0、networkx 3.4.2、numpy 1.26.4、pandas 2.2.3。其中,生成式决策评估优化引擎通过 API 调用 DeepSeek-R1 模型。

3.3 评价指标

为了综合考量实验方法的效果,采用准确率、精确率、召回率、F1 值(精确率与召回率的调和平均数)、汉

明损失^[31]对实验的结果进行分析。汉明损失是多标签分类问题中的一种评价指标,用于衡量预测结果与实际标签之间的差异。它定义为预测错误的标签比例,即错误标签的个数占总标签数量的比值。汉明损失的取值范围为[0,1],值越小表示预测越准确。本文采用样本级 Jaccard 准确率,精确率和召回率采用宏平均方式计算,F1 值由宏平均精确率与宏平均召回率的调和平均得到,汉明损失按照全部样本和标签中错误标签所占的比例计算。

3.4 基线对比实验

在基线模型的选择上,鉴于南沙区河涌的数据量限制,难以充分训练深度学习模型参数,故主要参考常见的多标签分类模型,在神经网络的基线选取上仅选择 GNN-MLP。所选的基线模型如下:①BR-RF,融合二元关联法和随机森林,将多标签任务分解为多个独立的二分类问题,每个标签单独训练一个随机森林模型;②CC-LR,融合分类器链和逻辑回归,将标签预测顺序串联,每个逻辑回归模型输入包含原始特征及前面标签的预测结果;③ML-KNN^[32],多标签 K_{NN} 近邻算法,即在多标签场景下,根据 K_{NN} 个近邻样本的标签分布预测目标样本标签;④RAKEL,即随机标签子集集成方法,每次随机选择包含 K_{sub} 个标签的子集构建 Label Powerset 分类器,并通过投票得到最终结果;⑤GNN-MLP,即融合图神经网络和多层感知机。将 KG-TS2-LLM 与以上 5 种基线模型进行对比实验,结果见表 5。

表 5 不同模型性能对比
Table 5 Performance comparison of different models

模型	准确率	精确率	召回率	F1 值	汉明损失
GNN-MLP	0.610	0.462	0.314	0.374	0.073
CC-LR	0.654	0.700	0.507	0.588	0.061
BR-RF	0.807	0.820	0.686	0.747	0.029
ML-KNN	0.846	0.726	0.769	0.747	0.037
RAKEL	0.864	0.811	0.708	0.756	0.026
KG-TS2-LLM	0.921	0.885	0.823	0.853	0.011

由表 5 可知,KG-TS2-LLM 表现出较为明显的优势,其准确率达 0.921,F1 值为 0.853,能够精准识别正类方案并减少误判,使输出结果更接近真实情况。相比之下,GNN-MLP 由于数据量限制导致过拟合,学习能力受限,导致各项指标表现不佳;CC-LR 由于标签预测误差累积影响精度;BR-RF 仅仅将多标签任务独立分解,导致召回率低影响 F1 值;ML-KNN 因邻域统计难以捕捉复杂关联特征,致使精度与 KG-TS2-LLM 相比有所差距;RAKEL 随机选择标签子集构建分类器的方式在数据量有限时无法充分利用标签信息,不能很好代表数据集特征,整体性能不如 KG-TS2-LLM。因此,KG-TS2-LLM 通过整合多源数据构建知识图谱实现图嵌入、设计两阶段分类模型、开发生成式评估引擎等措施,实现系统性风险量化与决策逻辑透明化,性能优于其他基线模型。

3.5 消融实验

为验证 KG-TS2-LLM 各关键组成部分对整体性能的贡献,分别开展感知-认知层消融实验和决策层消融实验。

感知-认知层消融实验是将感知层中构建的领域知识图谱与认知层中的两阶段分类模型相结合,探究图嵌入在多标签分类中的关键作用。实验设计了 3 种变体模型:①BR-RF,仅保留阶段 1 中的 Binary Relevance 和随机森林,针对河涌基本水文参数进行建模;②FC-BR-RF,在①模型的基础上添加特征工程(式(3));③KG-TS2,即本文方法,在②模型的基础上引入 Node2Vec 图嵌入技术。将 KG-TS2 与以上两种变体模型进行对比,实验结果如图 9(a)所示。

决策层消融实验的目的是探究生成式评估引擎中各个环节对整体性能的影响。本实验的待评估方案统一为 KG-TS2 方法的输出内容。实验设计了 3 种变体模型:①LLM,直接使用 DeepSeek-R1 生成最终确定方案;②KG-LLM,在①模型的基础上引入感知层中的领域知识图谱,生成最终确定方案;③KG-TS2-LLM,即最终方法,在②模型的基础上结合领域知识增强的提示学习,通过多步推理,生成最终确定方案和可解释推理链。将 KG-TS2-LLM 与以上两种变体模型进行对比,实验结果如图 9(b)所示。

通过上述实验,清晰地揭示了本文方法中各关键部分对整体性能的影响。认知层中物理特征与图嵌入的融合显著扩展了特征空间并提升决策准确率,决策层中 LLM 利用其语义推理与自然语言生成能力,构建




图9 消融实验结果

Fig.9 Ablation experiments results

可解释的决策方案及推理链,提供透明化决策依据。而领域知识增强的提示学习通过将结构化知识注入提示模板并约束分步推理过程,有助于降低 LLM 生成无依据内容的风险,提升方案修正可靠性。

4 结 论

- a. 构建的河涌整治知识图谱通过整合多源异构数据,可实现跨部门数据动态对齐,缓解了传统方法中多源数据整合不足的难题,为后续分析提供了结构化知识基础。
- b. 融合物理特征与拓扑嵌入的两阶段分类模型,在当前数据量限制下有效提升了整治方案的决策精度。相较于单一随机森林模型,其通过拓扑嵌入机制捕捉系统级关联,感知-认知层消融实验验证了小数据场景下经典技术的适配性。
- c. 基于 DeepSeek-R1 和领域知识增强的生成式评估引擎实现了可解释决策优化。该引擎结合知识图谱和预定义的评估标准,对认知层输出的方案进行多步推理和多维评估,生成包含具体扣分/加分项和修正建议的可解释推理链。决策层消融实验表明,该引擎可有助于降低 LLM 生成无依据内容的风险。
- d. 提出的知识图谱与 LLM 协同的河涌整治方案智能决策方法,可有效缓解传统方法中多源数据整合不足、系统级关联分析缺失、决策过程可解释性弱的问题。实验验证了本文方法在静态数据集上的有效性(F1 值达 0.853,准确率达 0.921),较基线模型提升显著,为河涌整治提供了可解释、可扩展的智能决策范式。但是其基于 Node2Vec 静态图算法的特性,难以捕捉河涌水系随季节、气候、城市发展的动态演变。
- e. 为拓展框架在长周期、前瞻性决策中的应用,未来可从两方面优化:①接入实时传感器数据构建时序知识图谱,引入动态图神经网络捕捉水系拓扑的时序变化;②在数据量充足时,将两阶段分类模型升级为深度学习框架(如 Transformer),结合注意力机制增强复杂关联特征的提取能力。

参考文献:

[1] 谭超,刘达,黄本胜,等. 基于河涌纳污能力的特大城市中心城区初期雨水截流标准[J]. 水电能源科学,2024,42(2):125-128. (Tan Chao,Liu Da,Huang Bensheng,et al. Initial rainwater interception standard for central urban area of megacities based on river in welling capacity[J]. Water Resources and Power,2024,42(2):125-128. (in Chinese))

[2] 刘丁蓉,杨凯,孙仕. 珠三角城市群内涝灾害韧性综合评估及障碍因子识别[J]. 水利经济,2024,42(4):23-29. (Liu Dingrong,Yang Kai,Sun Shi. Comprehensive assessment and obstacle factor recognition of waterlogging disaster resilience in Pearl River Delta urban agglomeration[J]. Journal of Economics of Water Resources,2024,42(4):23-29. (in Chinese))

[3] 徐宗学,卢兴超,施奇妙. 城市暴雨洪涝灾害特征与风险评估研究进展[J]. 水利水电科技进展,2025,45(1):1-9. (Xu Zongxue,Lu Xingchao,Shi Qimiao. Research progress on urban flooding disaster characteristics and risk assessment[J]. Advances in Science and Technology of Water Resources,2025,45(1):1-9. (in Chinese))

[4] 徐宗学,叶陈雷. 城市暴雨洪涝模拟:原理 模型与展望[J]. 水利学报,2021,52(4):381-392. (Xu Zongxue,Ye Chenlei. Simulation of urban flooding/waterlogging processes:principle,models and prospects[J]. Journal of Hydraulic Engineering,2021,52(4):381-392. (in Chinese))

[5] 张金良,罗秋实,王冰洁,等. 城市极端暴雨洪涝灾害成因及对策研究进展[J]. 水资源保护,2024,40(1):6-15. (Zhang Jinliang,Luo Qiushi,Wang Bingjie,et al. Research progress on causes and countermeasures for extreme rainstorm-induced urban

- flood disasters[J]. Water Resources Protection,2024,40(1):6-15. (in Chinese))
- [6] Wang Yongheng,Li Chunlin,Liu Miao,et al. Spatial characteristics and driving factors of urban flooding in Chinese megacities [J]. Journal of Hydrology,2022,613:128464.
- [7] Wang Shuo,Peng Hui. Multiple spatio-temporal scale runoff forecasting and driving mechanism exploration by K-means optimized XGBoost and SHAP[J]. Journal of Hydrology,2024,630:130650.
- [8] 马超,赵凯,齐文超,等. 基于示踪方法的沿海城市内涝防灾方案研究[J]. 水资源保护,2022,38(1):91-99. (Ma Chao, Zhao Kai,Qi Wenchao,et al. Formulation of flood mitigation scheme in coastal cities based on source tracking method[J]. Water Resources Protection,2022,38(1):91-99. (in Chinese))
- [9] Wang Yiwen,Zhang Zhiming,Zhao Zhiyong,et al. Prediction of future urban rainfall and waterlogging scenarios based on CMIP6: a case study of Beijing urban area[J]. Water,2023,15(11):2045.
- [10] 徐存东,翟东辉,张硕,等. 改进的 TOPSIS 综合评价模型在河道整治方案优选中的应用[J]. 河海大学学报(自然科学版),2013,41(3):222-228. (Xu Cundong,Zhai Donghui,Zhang Shuo,et al. Application of improved TOPSIS comprehensive evaluation model to optimization of river regulation schemes[J]. Journal of Hohai University (Natural Sciences),2013,41(3):222-228. (in Chinese))
- [11] 李慧宁,毛斌,解铭,等. 基于 Infoworks ICM 模型的老城区排涝安全研究:以中部某城市为例[J]. 环境工程,2023,41(增刊2):1137-1140. (Li Huining,Mao Bin,Xie Ming,et al. Study on the drainage safety of old urban areas based on Infoworks ICM model:taking a city in central China as an example[J]. Environmental Engineering,2023,41(S2):1137-1140. (in Chinese))
- [12] 王凌河,王浩,周惠成,等. 基于模糊优选方法的雅鲁江调水方案优化[J]. 南水北调与水利科技,2015,13(5):990-994. (Wang Linghe,Wang Hao,Zhou Huicheng,et al. Scheme optimization of water transfer in the Yalong River based on fuzzy optimization method [J]. South-to-North Water Transfers and Water Science & Technology, 2015, 13 (5): 990-994. (in Chinese))
- [13] 周飞燕,金林鹏,董军. 卷积神经网络研究综述[J]. 计算机学报,2017,40(6):1229-1251. (Zhou Feiyan,Jin Linpeng,Dong Jun. Review of convolutional neural network[J]. Chinese Journal of Computers,2017,40(6):1229-1251. (in Chinese))
- [14] 张驰,郭媛,黎明. 人工神经网络模型发展及应用综述[J]. 计算机工程与应用,2021,57(11):57-69. (Zhang Chi,Guo Yuan,Li Ming. Review of development and application of artificial neural network models [J]. Computer Engineering and Applications,2021,57(11):57-69. (in Chinese))
- [15] 王萌,王昊奋,李博涵,等. 新一代知识图谱关键技术综述[J]. 计算机研究与发展,2022,59(9):1947-1965. (Wang Meng,Wang Haofen,Li Bohan,et al. Survey on key technologies of new generation knowledge graph[J]. Journal of Computer Research and Development,2022,59(9):1947-1965. (in Chinese))
- [16] 刘学博,户保田,陈科海,等. 大模型关键技术与未来发展方向:从 ChatGPT 谈起[J]. 中国科学基金,2023,37(5):758-766. (Liu Xuebo,Hu Baotian,Chen Kehai,et al. Key technologies and future development directions of large language models: insights from ChatGPT[J]. Bulletin of National Natural Science Foundation of China,2023,37(5):758-766. (in Chinese))
- [17] Wang Jingbin,Zhang Weijie,Yu Zhiyong,et al. Route selection for opportunity-sensing and prediction of waterlogging[J]. Frontiers of Computer Science,2024,18(4):184503.
- [18] Waqas M,Humphries U W,Hlaing P T,et al. Seasonal WaveNet-LSTM:a deep learning framework for precipitation forecasting with integrated large scale climate drivers[J]. Water,2024,16(22):3194.
- [19] 冯钧,畅阳红,陆佳民,等. 基于大语言模型的水工程调度知识图谱的构建与应用[J]. 计算机科学与探索,2024,18(6):1637-1647. (Feng Jun,Chang Yanghong,Lu Jiamin,et al. Construction and application of knowledge graph for water engineering scheduling based on large language model[J]. Journal of Frontiers of Computer Science and Technology,2024,18(6):1637-1647. (in Chinese))
- [20] 杨燕,叶枫,许栋,等. 融合大语言模型和提示学习的数字孪生水利知识图谱构建[J]. 计算机应用,2025,45(3):785-793. (Yang Yan,Ye Feng,Xu Dong,et al. Construction of digital twin water conservancy knowledge graph integrating large language model and prompt learning[J]. Journal of Computer Applications,2025,45(3):785-793. (in Chinese))
- [21] Breiman L. Random forests[J]. Machine Learning,2001,45(1):5-32.
- [22] Grover A, Leskovec J. Node2vec: scalable feature learning for networks [C]//Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. San Francisco:ACM,2016:855-864.
- [23] Guo D,Yang D,Zhang H,et al. DeepSeek-R1 incentivizes reasoning in LLMs through reinforcement learning[J]. Nature,2025,645:633-638.
- [24] 文森,钱力,胡懋地,等. 基于大语言模型的问答技术研究进展综述[J]. 数据分析与知识发现,2024,8(6):16-29. (Wen

Sen,Qian Li,Hu Maodi,et al. Review of research progress on question-answering techniques based on large language models[J]. Data Analysis and Knowledge Discovery,2024,8(6):16-29. (in Chinese))

[25] Li Binglei,Liu Tong,Ma Jian,et al. Evolving chain-of-thought and automatic text annotation based intent classification method for wireless network[J]. Computer Networks,2025,259:111074.

[26] 刘畅成,桑磊,李炜,等. 大语言模型驱动的多元关系知识图谱补全方法[J]. 计算机科学,2025,52(1):94-101. (Liu Changcheng,Sang Lei,Li Wei,et al. Large language model driven multi-relational knowledge graph completion method[J]. Computer Science,2025,52(1):94-101. (in Chinese))

[27] Zhang Minling,Li Yukun,Liu Xuying,et al. Binary relevance for multi-label learning;an overview[J]. Frontiers of Computer Science,2018,12(2):191-202.

[28] Lavalley M P. Logistic regression[J]. Circulation,2008,117(18):2395-2399.

[29] 张才科,李小龙,郑胜,等. 基于大语言模型的知识图谱构建及应用研究[J]. 计算机科学与探索,2024,18(10):2656-2667. (Zhang Caike,Li Xiaolong,Zheng Sheng,et al. Research on construction and application of knowledge graph based on large language model[J]. Journal of Frontiers of Computer Science and Technology,2024,18(10):2656-2667. (in Chinese))

[30] Wang Yu,Ye Feng,Li Binqun,et al. UrbanFloodKG: an urban flood knowledge graph system for risk assessment [C]// Proceedings of the 32nd ACM International Conference on Information and Knowledge Management. Birmingham:ACM,2023: 2574-2584.

[31] Butucea C,Ndaoud M,Stepanova N A,et al. Variable selection with Hamming loss[J]. The Annals of Statistics,2018,46(5): 1837-1875.

[32] Zhang Minling,Zhou Zhihua. ML-KNN:a lazy learning approach to multi-label learning[J]. Pattern Recognition,2007,40(7): 2038-2048.

(收稿日期:2025-07-04 编辑:刘晓艳)

(上接第 48 页)

[26] Elmaz F,Eyckerman R,Casteels W,et al. CNN-LSTM architecture for predictive indoor temperature modeling[J]. Building and Environment,2021,206:108327.

[27] Ishida K,Ercan A,Nagasato T,et al. Use of one-dimensional CNN for input data size reduction in LSTM for improved computational efficiency and accuracy in hourly rainfall-runoff modeling[J]. Journal of Environmental Management,2024,359: 120931.

[28] 黄克威,王根绪,宋春林,等. 基于 LSTM 的青藏高原冻土区典型小流域径流模拟及预测[J]. 冰川冻土,2021,43(4): 1144-1156. (Huang Kewei,Wang Genxu,Song Chunlin,et al. Runoff simulation and prediction of a typical small watershed in permafrost region of the Qinghai-Tibet Plateau based on LSTM[J]. Journal of Glaciology and Geocryology,2021,43(4):1144-1156. (in Chinese))

[29] Zhang Tianpeng,Huang J C,Lei Qiuliang,et al. Empirical estimation of soil temperature and its controlling factors in Australia: implication for interaction between geographic setting and air temperature[J]. CATENA,2022,208:105696.

[30] 蔡哲,段里成,郭瑞鸽,等. 江西省土壤温度变化特征及其与气象要素的关系[J]. 中国农学通报,2024,40(4):118-125. (Cai Zhe,Duan Licheng,Guo Ruige,et al. Characteristics of soil temperature variation in Jiangxi province and its relationship with meteorological elements[J]. Chinese Agricultural Science Bulletin,2024,40(4):118-125. (in Chinese))

[31] 刘娣,孙佳倩,余钟波. 基于机器学习模型的多层土壤湿度反演[J]. 河海大学学报(自然科学版),2024,52(3):7-14. (Liu Di,Sun Jiaqian,Yu Zhongbo. Multi-layer soil moisture inversion based on machine learning models [J]. Journal of Hohai University (Natural Sciences),2024,52(3):7-14. (in Chinese))

(收稿日期:2025-09-06 编辑:刘晓艳)