

基于知识图谱与反事实提示的跨境供应链韧性增强与可解释性决策研究

张宝明, 林恒好

上海理工大学管理学院, 上海

收稿日期: 2026年2月26日; 录用日期: 2026年3月9日; 发布日期: 2026年4月1日

摘要

全球贸易格局的动荡与不确定性, 使得构建具有韧性的跨境供应链成为企业生存与发展的关键。传统AI决策模型在跨境供应链管理中存在“黑箱”操作、知识滞后与动态适应性不足等问题, 为此提出了一种创新的融合框架——供应链语义网络与Prompt可解释性增强系统, 通过构建结构化的跨境供应链领域知识图谱, 为AI提供可推理的领域知识基础; 进而设计“图谱增强Prompt”范式, 实现自然语言交互下的复杂网络查询与风险诊断; 并创新引入“反事实提示”机制, 通过假设性场景推演生成具有因果解释的韧性优化方案, 显著提升决策透明度与可审计性。基于该框架开发的系统原型, 不但能够提升供应链风险定位效率, 降低潜在损失, 也为人机协同、可信赖的供应链智能决策提供了有效工具与方法。

关键词

供应链韧性, 知识图谱, 提示工程, 可解释人工智能

Research on Cross-Border Supply Chain Resilience Enhancement and Explainable Decision-Making Based on Knowledge Graph and Counterfactual Prompting

Baoming Zhang, Henghao Lin

Business School, University of Shanghai for Science and Technology, Shanghai

Received: February 26, 2026; accepted: March 9, 2026; published: April 1, 2026

文章引用: 张宝明, 林恒好. 基于知识图谱与反事实提示的跨境供应链韧性增强与可解释性决策研究[J]. 电子商务评论, 2026, 15(4): 190-198. DOI: 10.12677/ecl.2026.154386

Abstract

The turbulence and uncertainty of the global trade landscape have made building resilient cross-border supply chains a critical factor for enterprise survival and development. Traditional AI decision-making models in cross-border supply chain management suffer from issues such as “black-box” operations, knowledge lag, and insufficient dynamic adaptability. To address these, this paper proposes an innovative integrated framework—the Supply Chain Semantic Network and Prompt Explainability Enhancement System. By constructing a structured cross-border supply chain domain knowledge graph, it provides AI with a foundational layer of domain knowledge for reasoning. Subsequently, a “Graph-Enhanced Prompt” paradigm is designed to enable complex network queries and risk diagnostics through natural language interaction. Furthermore, a “Counterfactual Prompt” mechanism is innovatively introduced to generate resilient optimization solutions with causal explanations through hypothetical scenario simulations, significantly improving decision transparency and auditability. The system prototype developed based on this framework can not only enhance the efficiency of supply chain risk identification and reduce potential losses but also provide an effective tool and method for human-machine collaborative and trustworthy intelligent decision-making in supply chains.

Keywords

Supply Chain Resilience, Knowledge Graph, Prompt Engineering, Explainable AI (XAI)

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

全球价值链的深化与数字贸易的崛起,使跨境电子商务成为世界经济增长的核心引擎。然而,地缘政治风险、国际贸易摩擦、公共卫生危机与自然灾害等“黑天鹅”事件频发,深刻暴露出全球供应链网络的脆弱性。在此背景下,供应链韧性——即系统在遭受干扰后预防、适应、响应并恢复至原始或更优状态的能力,已成为企业的核心竞争力。对链路漫长、横跨多国法规与市场的跨境电子商务而言,构建韧性体系的需求尤为迫切。

为应对这一挑战,企业日益依赖人工智能进行预测与决策。然而,现有 AI 应用多聚焦于预测准确性或局部优化,在应对全链路、多维度冲击时面临三重突出局限:其一,知识壁垒,通用大模型缺乏如具体关税规则、供应商替代关系等深度结构化领域知识,易产生“幻觉”或给出泛化建议;其二,可解释性缺失,深度学习模型的“黑箱”特性使其决策逻辑难以理解,不仅阻碍管理者信任,亦难以满足贸易合规审计的刚性要求;其三,动态适应性不足,预设模型难以快速响应未预见的中断,缺乏对“假设性情景”进行推演与预案生成的能力。因此,如何构建一个能深度融合领域知识、提供透明可解释决策、并能快速适应动态变化的智能系统,以切实增强跨境供应链韧性,成为一个亟待解决的关键问题。

2. 文献综述

供应链韧性管理正经历从传统经验驱动向数据与知识驱动的范式转变,涉及的文献主要包括供应链韧性理论、知识图谱(KG)应用、提示工程(Prompt Engineering)及可解释人工智能(XAI)这四个关键领域。

2.1. 供应链韧性理论与评估

供应链韧性的概念源于对中断风险的响应。早期研究侧重于通过冗余策略提升系统鲁棒性[1]。随后,概念拓展为一个包含准备、响应、恢复与学习的动态能力框架[2],并强调敏捷性与适应性的协同作用。在跨境电子商务情境下,韧性构建更侧重于多元化网络设计和信息协同[3][4]。在评估层面,现有研究建立了包括恢复时间、恢复成本、订单满足率等在内的量化指标体系[5]。

总体上,尽管理论框架日趋成熟,但多数研究聚焦于战略层面的网络设计或事后的绩效评估,对于面向实时中断、支持动态决策的智能系统关注不足。传统优化模型(如随机规划)在面对高频、多源的“黑天鹅”事件时,往往因计算复杂性和模型僵化而难以及时响应[6]。这为 AI 驱动的实时韧性决策支持系统留下了研究空间。

2.2. 知识图谱在供应链中的应用

知识图谱通过实体-关系三元组结构化地表示领域知识,为复杂供应链系统的认知与推理提供了新范式。在供应链领域,KG 的应用主要集中于:(1) 风险传播分析:通过图算法(如随机游走、社区发现)模拟中断事件在供应链网络中的级联影响[7]。(2) 供应商关系管理:利用图谱的链接预测能力,发现潜在或替代供应商,评估其风险[8][9]。(3) 合规性智能检查:将碎片化的贸易法规、关税条款转化为可计算的知识图谱,实现自动化合规校验[10]。

然而,现有研究多将 KG 视为一个静态的知识库或可视化分析工具,其价值主要体现在知识查询与简单推理上。尽管诸多学者[11][12]在关系机器学习方面的综述为 KG 的深度应用提供了理论基础,但如何将 KG 与强大的生成式 AI 能力相结合,使其从“被动查询”转向“主动决策生成”,仍是亟待探索的前沿方向。

2.3. 提示工程前言进展

提示工程是解锁大语言模型(LLMs)在特定领域任务中潜力的关键技术。其发展从简单的指令微调,演进至思维链[13]和程序化提示等复杂方法,旨在引导模型进行分步推理。近期,反事实提示(Counterfactual Prompting)作为一种新兴范式受到关注,它通过构造“如果……那么……”的假设性问题,激发模型进行因果推理与替代场景推演,在医疗诊断[14]和法律案例分析中显示出提升模型解释性的潜力。

目前,提示工程的研究多集中于通用领域或垂直但结构相对单一的领域。在高度复杂、网络化、且依赖深厚领域知识的供应链决策场景中,如何设计有效的提示策略,特别是将领域知识图谱与反事实推理相结合的提示机制,相关研究几乎处于空白。

2.4. 可解释 AI

可解释 AI 旨在解决 AI 模型的“黑箱”问题,对于高风险、高价值的供应链决策至关重要。传统的方法(如 LIME、SHAP)侧重于事后解释,通过近似模型或特征归因来解释单一预测[15][16]。然而,这类方法往往与主决策模型分离,且难以解释复杂的序列决策或策略生成过程。

近年来,研究趋势转向过程性可解释性,即在整个决策交互过程中提供透明、连贯的解释。将解释自然融入人机对话,例如通过结构化、可追溯的问答,被视为一个 promising 的方向[17][18]。在供应链领域,可解释性不仅是技术需求,更是满足贸易合规审计和建立管理信任的刚性要求。

综上所述,当前研究呈现“割裂”状态:供应链韧性研究缺乏智能、交互式的决策工具;知识图谱应用未充分结合强大的自然语言生成与推理能力;提示工程尚未深入复杂的商业运营领域;可解释性方

法常游离于主决策流程之外。本文的定位即在于交叉融合这四个领域, 构建一个以知识图谱为基础、以 Prompt 为交互与推理引擎、以内生可解释性为特征的跨境供应链韧性增强系统, 填补该交叉研究空白。

3. 跨境供应链语义网络的构建

3.1. 本体的设计

本体的设计是知识图谱构建的蓝图。为此, 本文定义了跨境供应链的核心概念体系, 包括: (1) 实体类型。具体有物理实体(如: 产品 SKU、原材料、仓库、港口、运输工具)、组织实体(如: 制造商、供应商、物流商、电商平台、海关)、法规实体(如: 贸易协定、关税条款、禁运令)、事件实体(如: 订单、运输批次、清关事件、中断事件), 等等。(2) 关系类型。它定义了实体间的语义链接, 具体如: 位于(locatedIn)、供应(supplies)、运输至(transportTo)、依赖(dependsOn)、受限于(subjectTo)、替代于(alternativeTo)、触发(triggers)、隶属于(belongsTo)。(3) 属性。它描述了实体的特征, 如供应商的可靠性评分、港口的日均处理量、运输路线的标准时长与成本、关税条款的生效日期与税率等。

3.2. 多源数据融合与知识抽取

数据主要来源于企业内部数据(从 ERP、WMS、TMS 中抽取的订单、库存、物流轨迹等结构化数据)、公开数据(爬取港口运营状态、航班/船期表、海关公告、汇率、地缘政治风险指数)、行业报告与新闻(利用 NLP 技术(实体识别、关系抽取)从文本中提取供应商并购、新法规出台、自然灾害等事件)、专家知识(通过访谈与问卷, 形式化管理者的经验规则, 如: “供应商 A 与 B 的产品可相互替代”)。

在得到相关数据之后, 采用 ETL (提取 - 转换 - 加载)流程与实体对齐技术, 将异构数据统一映射到预设本体上, 并存储于图数据库中。

3.3. 图谱的存储、更新与推理

存储: 选用原生图数据库 Neo4j, 以高效存储和遍历复杂的网络关系。

动态更新: 建立事件驱动的更新机制。例如, 当新闻中出现“某港口罢工”事件, 系统自动创建“罢工事件”节点, 并与该港口节点建立影响关系, 同时更新该港口的状态属性为“拥堵”。

规则推理: 预置简单的逻辑规则(如: 若路径 P 上的所有节点状态为“正常”, 则 P 状态为“畅通”; 若任一节点状态为“中断”, 则 P 状态为“中断”), 用于实时状态推断。

4. SC-SNaP 系统

笔者将本系统命名为供应链语义网络与 Prompt 可解释性增强系统(Supply Chain Semantic Network and Prompt-enhanced System, SC-SNaP), 该系统的核心, 主要是图谱增强与反事实提示设计。

4.1. 系统总体架构

SC-SNaP 采用分层架构, 包含数据层、图谱层、Prompt 引擎层和应用层。其中, 数据层提供多源数据; 图谱层负责知识存储与推理; Prompt 引擎层是大脑, 包含 Prompt 模板库、大语言模型接口和解释生成器; 应用层提供自然语言交互界面与可视化看板。

4.2. 图谱增强 Prompt 范式

其核心思想是, 将用户查询、知识图谱子图与大语言模型指令有机结合。具体流程为:

- 1) 解析用户自然语言查询;
- 2) 将其转换为图谱查询语言(如 Cypher), 检索相关子图;

- 3) 将子图信息(以文本或结构化形式)与精心设计的 Prompt 指令组合, 发送给 LLM;
- 4) 解析并呈现 LLM 的响应。

4.3. 实例

一家名为“AlphaTech(化名)”的公司, 主营产品为智能 Wi-Fi 插座、智能照明系统, 市场主要为美国(占营收 65%)和德国(占 25%)。供应链网络“设计-制造-销售”跨越多国, 其中, 设计中心位于深圳, 负责核心元器件选型、固件开发等; 产品制造大部分位于越南海防市, 大约占总产能的 70%, 其余 30% 由东莞的一家备用工厂承接。

涉及的核心元器件供应商主要有: 微控制器(MCU): 主要来自台湾供应商 TS, 次级为美国供应商 MS; Wi-Fi 模块: 独家来自中国供应商 WF (深圳); 塑胶外壳: 来自越南本地供应商 VP。

涉及的物流路径主要是: 主路径: 越南海防港→(海运)→美国洛杉矶港→(卡车)→亚马逊 ONT8 仓库(美国)。平均航程 25 天。备用路径: 越南海防港→(海运)→美国西雅图港/或中国盐田港→(海运)→洛杉矶港。航程增加 5~7 天。紧急路径: 深圳/香港机场→(空运)→美国 LAX 机场。成本是海运的 5 倍。

1) 多源数据融合。为了构建知识图谱, 首先需要收集相关数据并进行必要的处理。为节省篇幅, 收集的 AlphaTech 数据源及其处理方式见表 1 所示。

Table 1. AlphaTech data sources and processing methods

表 1. AlphaTech 数据源与处理方式

| 数据源类别 | 具体内容示例 | 抽取的实体/关系/属性 | 处理方法 |
|---------|---------------|--|---------------------------------------|
| 内部结构化数据 | ERP 订单(BOM 表) | 实体: 产品 SKU, 原材料 关系: 产品 - 包含->原材料 | 直接映射, ETL 工具导入 |
| | 供应商主数据 | 实体: 供应商 属性: 名称, 地理位置, 合作层级 | 同上 |
| | WMS 库存记录 | 实体: 仓库 属性: 实时库存水平, 安全库存阈值 | 定期同步 |
| | TMS 物流轨迹 | 实体: 运输批次, 港口, 运输工具 关系: 批次 - 途经->港口, 港口 - 位于->城市 | 解析事件日志, 生成“途经”关系链 |
| 外部公开数据 | 全球港口船舶 AIS 数据 | 属性(动态): 港口当前拥堵指数, 预计离港时间 | API 接入, 每 4 小时更新 |
| | 海关总署关税数据库 | 实体: HS 编码, 关税条款 关系: 产品 - 归类于->HS 编码, HS 编码 - 受限于->关税条款 | 网络爬虫与官方数据购买, 关联企业产品 HS 编码 |
| | 航运公司船期表 | 属性: 航线的标准航程, 每周班次 | 结构化解析 |
| | 新闻/社交媒体 | 实体: 中断事件(如罢工、台风) 关系: 事件 - 影响->港口/地区 | NLP 事件抽取模型(基于 BERT), 识别事件类型、影响实体和严重程度 |
| 专家知识 | 采购经理访谈 | 关系: 供应商 A - 可替代->供应商 B(置信度: 0.8) 规则: “若 MCU 供应商中断, 切换需重测 firmware, 导致额外 21 天延迟” | 设计结构化问卷录入, 转化为图谱中的替代关系和影响规则节点 |

2) 图谱构建。运用相关工具, 如 Protégé、DeepKE、HuggingFace、Dedupe 等工具, 通过本体设计、数据抽取、知识融合, 构建一个知识图谱并存放于 Neo4j 数据库中, 其模式片段示例见表 2 (这里采用 Cypher 语言模式, 其中, () 表示节点, --> 或 <-- 表示关系, {} 表示属性)。

Table 2. Constructed knowledge graph schema (fragment)

表 2. 构建的知识图谱模式(片段)

```
(产品:Product {id: 'SKU_101', name: '智能插座 WIFI 版'})
(供应商_TS:Supplier {id: 'S_MCU_01', name: 'TS', location: '台湾', risk_level: '中'})
(供应商_WF:Supplier {id: 'S_WIFI_01', name: 'WF', location: '深圳', risk_level: '高'})
(港口_海防:Port {id: 'P_VN', name: '海防港', country: '越南', current_congestion: 0.2})
(港口_洛杉矶:Port {id: 'P_USLAX', name: '洛杉矶港', country: '美国', current_congestion: 0.7})
(关税_US: Tariff {id: 'T_US_8517', hs_code: '8517.69', rate: 0.035, effective_date: '2023-01-01'})

(产品)-[:CONTAINS {quantity: 1}]->(供应商_TS)
(产品)-[:CONTAINS {quantity: 1}]->(供应商_WF)
(供应商_TS)-[:SHIPS_FROM {lead_time: 15}]->(港口_海防)
(港口_海防)-[:SAILING_TO {transit_time: 25, carrier: 'CMA CGM'}]->(港口_洛杉矶)
(产品)-[:CLASSIFIED_AS]->(hs_code:HS_Code {code: '8517.69'})
(hs_code)-[:SUBJECT_TO]->(关税_US)
```

3) 解析用户自然语言查询并转换为图谱查询语言

假设用户在系统中输入自然语言:

“如果我们的 Wi-Fi 模块独家供应商 WF (深圳) 因为突发事件停产两周, 这会如何影响我们下个季度发往美国的智能插座订单? 我们应该怎么做?”

这时, 系统将会启动一个称为“分层混合架构”算法, 结合规则匹配、语义解析和图谱元信息, 实现从自然语言到结构化查询的转换。具体算法见附录。

在进行语义解析时, 会识别出相应的关键实体: Supplier: WF, Event: 停产两周, Product: 智能插座, Market: 美国, 生成的系列 Cypher 查询见表 3 所示。

Table 3. Generated Cypher query examples

表 3. 生成的 Cypher 查询示例

```
// 查询 1: 找出所有依赖 WF 的产品
MATCH (wf:Supplier {id:'S_WIFI_01'})<[:CONTAINS]->(p:Product)
RETURN p.name AS 受影响产品

// 查询 2: 查找 WF 的已定义的替代供应商
MATCH (wf:Supplier {id:'S_WIFI_01'})<[:CAN_BE_REPLACED_BY]->(alt:Supplier)
RETURN alt.name AS 替代供应商, alt.location AS 地点

// 查询 3: 查找受影响产品的在途和在制品库存
MATCH (p:Product {id:'SKU_101'})<[:LOCATED_AT]->(w:Warehouse)
RETURN w.name AS 仓库位置, r.quantity AS 可用库存
```

执行以上查询, 得到的结果和对应的子图见表 4 所示。

Table 4. Query results and subgraphs
表 4. 查询结果与子图

| Cypher 查询 | 查询结果 | 对应的子图 |
|-----------|--|---|
| 查询 1 | 受影响产品 ----- 智能插座 WIFI 版 智能灯泡 智能网关 | <pre> (:Product {name: '智能插座 WIFI 版'}) [:CONTAINS] ↓ (:Supplier {id: 'S_WIFI_01', name: 'WF', location: '深圳'}) ↑ [:CONTAINS] (:Product {name: '智能灯泡'}) ↑ [:CONTAINS] (:Product {name: '智能网关'}) </pre> |
| 查询 2 | 替代供应商 地点 WF_BACKUP_1 东莞 Microchip_Tech 上海 | <pre> (:Supplier {id: 'S_WIFI_01', name: 'WF', location: '深圳'}) [:CAN_BE_REPLACED_BY] ↓ (:Supplier {name: 'WF_BACKUP_1', location: '东莞'}) ↑ [:CAN_BE_REPLACED_BY] (可能还有 其他关系) (:Supplier {name: 'Microchip_Tech', location: '上海'}) </pre> |
| 查询 3 | 仓库位置 可用库存 CM 越南 - 产线仓 500 海防港在途仓 1200 洛杉矶港保税仓 800 亚马逊 ONT8 仓 300 | <pre> (:Product {id: 'SKU_101', name: '智能插座 WIFI 版'}) ----- [:LOCATED_AT] [:LOCATED_AT] [:LOCATED_AT] {quantity:500} {quantity:1200} {quantity:800} ↓ (:Warehouse {name: 'CM 越南-产线仓'}) (:Warehouse {name: '海防港在途仓'}) (:Warehouse {name: '洛杉矶港保税仓'}) [:LOCATED_AT] {quantity:300} ↓ (:Warehouse {name: '亚马逊 ONT8 仓'}) </pre> |

4) Prompt 组装与 LLM 调用

系统将查询结果填入预设计的反事实提示模板，见表 5 所示。

Table 5. Prompt template examples

表 5. Prompt 模板示例

你作为供应链韧性分析员，请基于以下真实情况生成报告：

- 1) 事件：核心供应商 WF(深圳，Wi-Fi 模块独家供应商)停产 14 天。
- 2) 受影响产品：{{query1_result}}(主要是 SKU_101)。
- 3) 已定义的替代方案：{{query2_result}}(暂无已认证的替代供应商)。
- 4) 当前库存情况：{{query3_result}}(海防工厂有 7 天库存，在途海运有 30 天库存)。

请执行以下任务：

- 1) 影响推演：量化分析对下季度美国订单履行的影响(延迟订单比例、潜在收入损失)。
- 2) 根因诊断：基于“无已认证替代”这一事实，指出最脆弱的环节。
- 3) 应急策略生成：
 - a) 短期(未来 2 周)：建议立即行动(如：联系 WF 评估恢复情况，启动现货市场采购)。
 - b) 中期(2~8 周)：建议韧性构建方案(如：紧急认证备用供应商“供应商 B”，流程需 21 天)。
- 4) 反事实对比：如果我们在 6 个月前就完成了对“供应商 B”的认证，本次影响可以减轻多少？(请估算)

请以结构化、量化的方式回答，并始终引用提供给你的数据。

5) LLM 响应的结果

将以上反事实提示模板的内容提交给 LLM 后，将会得到如下的可视化报告(摘要)：

a) 影响分析仪表盘：

显示未来 12 周订单履行缺口预测图。

b) 关键发现卡片：

最脆弱节点：Wi-Fi 模块供应(单一来源，无备份)。

预计影响：可能导致未来第 5~8 周高达 40% 的美国订单延迟，潜在收入损失约 \$2.5M。

c) 行动建议列表：

立即：联系 WF，确认停产范围与恢复计划。(负责人：采购总监)

72 小时内：启动现货市场扫描，询价采购 5K 件 Wi-Fi 模块。(负责人：采购员)

本周内：成立跨职能团队，启动对预审供应商“B”的紧急认证流程。(负责人：质量经理)

d) 反事实洞见：

若已认证供应商 B，可将影响期缩短至 3 周，损失降低至约 \$0.8M。这突显了对独家供应商进行备用认证的 ROI 极高。

5. 总结

知识图谱作为“稳定器”：有效约束了 LLM 的“幻觉”，使其回答扎根于企业真实数据与领域知识，大幅提升了专业性。反事实提示作为“探照灯”：它不仅生成了预案，更重要的是提供了一种“韧性压力测试”的方法论，使企业能从被动反应转向主动规划。可解释性即生产力，将可解释性内置于交互过程(通过结构化的 Prompt 和事实引用)，直接降低了使用门槛，增强了人机协作的粘性。

然而，受限于知识图谱的完备性与数据质量以及对大语言模型的依赖，事实上，本系统不可避免地会存在 API 成本与数据隐私风险，需在今后加以关注。

参考文献

- [1] Sheffi, Y. (2005) The Resilient Enterprise: Overcoming Vulnerability for Competitive Advantage. MIT Press.

-
- [2] Christopher, M. and Peck, H. (2004) Building the Resilient Supply Chain. *The International Journal of Logistics Management*, **15**, 1-14. <https://doi.org/10.1108/09574090410700275>
- [3] Ivanov, S., Gretzel, U., Berezina, K., Sigala, M. and Webster, C. (2019) Progress on Robotics in Hospitality and Tourism: A Review of the Literature. *Journal of Hospitality and Tourism Technology*, **10**, 489-521. <https://doi.org/10.1108/jhtt-08-2018-0087>
- [4] 蔡梦思, 魏婉莹, 谭索怡. 复杂供应链网络建模: 研究进展与展望[J]. 系统管理学报, 2025, 34(6): 1613-1634.
- [5] Hosseini, S.S., Khodaiyan, F., Kazemi, M. and Najari, Z. (2019) Optimization and Characterization of Pectin Extracted from Sour Orange Peel by Ultrasound Assisted Method. *International Journal of Biological Macromolecules*, **125**, 621-629. <https://doi.org/10.1016/j.ijbiomac.2018.12.096>
- [6] 王旭坪, 王悦, 李娅, 等. 果蔬采后分级和预冷车辆协同调度模型与算法[J]. 系统管理学报, 2024, 33(1): 76-89.
- [7] Birge, J.R., Capponi, A. and Chen, P. (2022) Disruption and Rerouting in Supply Chain Networks. *Operations Research*, **71**, 750-767. <https://doi.org/10.1287/opre.2022.2409>
- [8] Zhao, T., Chen, Y., Li, Y., Wang, J., Chen, S., Gao, N., *et al.* (2021) Disome-Seq Reveals Widespread Ribosome Collisions That Promote Cotranslational Protein Folding. *Genome Biology*, **22**, Article No. 16. <https://doi.org/10.1186/s13059-020-02256-0>
- [9] 吴凯佳, 王铭聪. 能源企业可持续供应链知识图谱构建与应用研究[J]. 科技经济市场, 2024(2): 35-37.
- [10] 张夏恒. 新质生产力与现代化产业体系双向赋能机理和路径研究[J]. 产业经济评论, 2025(3): 5-18.
- [11] 王晶晶, 周超. 大数据背景下机器学习算法适用性及分析[J]. 科技与创新, 2026(2): 29-32.
- [12] 周宇, 朱浩, 刁佳宁, 等. 机器学习技术在畜禽育种上的应用现状及发展趋势[J/OL]. 中国畜禽种业, 1-11. <https://doi.org/10.19543/j.cnki.1673-4556.20260122.014>, 2026-02-11.
- [13] Bosma, M., Chi, E., Ichter, B., Le, Q.V., Schuurmans, D., Wang, X., *et al.* (2022) Chain-of-Thought Prompting Elicits Reasoning in Large Language Models. *Advances in Neural Information Processing Systems*, **35**, 24824-24837. <https://doi.org/10.52202/068431-1800>
- [14] Kassner, N., Dufter, P. and Schütze, H. (2021) Multilingual LAMA: Investigating Knowledge in Multilingual Pretrained Language Models. *Proceedings of the 16th Conference of the European Chapter of the Association for Computational Linguistics*, Online, April 2021, 3250-3258. <https://doi.org/10.18653/v1/2021.eacl-main.284>
- [15] Lipton, Z.C. (2018) The Mythos of Model Interpretability: In Deep Learning, the Concept of Interpretability Is Both Important and Slippery. *Queue*, **16**, 31-57. <https://doi.org/10.1145/3236386.3241340>
- [16] 郭漩, 张金雪, 魏伊冰. 大语言模型提示学习增强的轨迹知识图谱构建方法[J]. 地球信息科学学报, 2025, 27(12): 2789-2801.
- [17] 徐立祥, 许巍, 陈恩红, 等. KENN: 线性结构熵的图核神经网络[J]. 软件学报, 2024, 35(5): 2430-2445.
- [18] 卢新元, 徐安琪, 张进澳. 探寻可解释人工智能(XAI)的“解释奇点”: 基于 AIGC 信息采纳视角[J]. 数据分析与知识发现, 2026, 10(1): 76-87.