arXiv:2603.03097v1 [cs.AI] 3 Mar 2026

Odin：用于知识图谱自主发现的多信号图智能

Muyukani Kizito [1,*] Elizabeth Nyambere [1]

[1]Prescott Data

{muyukani,nyambere}@prescottdata.io

*通讯作者：muyukani@prescottdata.io

摘要

我们介绍了 Odin，这是首个投入生产环境的图智能引擎，能够在无需预先指定的情况下，自主发现知识图谱中的有意义模式。与回答预定义查询的基于检索的系统不同，Odin 通过 COMPASS（复合导向多信号路径评估）分数引导探索。这一全新指标融合了：（1）通过个性化 PageRank 衡量的结构重要性；（2）将神经概率逻辑学习（NPLL）用作判别式过滤器而非生成模型，以评估语义合理性；（3）采用可配置衰减机制衡量时间相关性；以及（4）通过 GNN 识别的桥接实体和社区间亲和度分数提供社区感知引导。这种多信号融合，尤其是桥接评分机制，解决了“回音室”问题，即图探索被困在稠密的局部社区中。我们对自主发现问题进行了形式化，证明了评分函数的理论性质，并展示了在多信号引导下，束搜索能够以 $O(b \cdot h)$ 的复杂度实现高召回率，相较之下，穷举探索则不具备这一优势。据我们所知，Odin 是首个部署于受监管生产环境（医疗保健和保险）的自主发现系统，在模式发现质量和分析师效率方面取得了显著提升。我们的方法保留了完整的来源可追溯性——这对于不容许出现幻觉的受监管行业而言至关重要。

关键词： 知识图谱、图智能、自主发现、神经概率逻辑、束搜索、图探索

1 引言

知识图谱（KG）已成为表示结构化、相互关联的组织数据的强大范式 [1]。与文档存储或关系数据库不同，知识图谱会显式建模实体、类型化关系和多模态证据，从而支持复杂推理。然而，从大规模知识图谱中提取可操作的见解仍然颇具挑战。传统方法依赖查询语言（SPARQL、Cypher、AQL），要求分析人员指定精确模式 [2]：当目标是发现 而非检索时，这构成了一项根本性局限。

设想一个医疗知识图谱，其中包含数百万条患者记录、诊断、治疗和结局。分析人员或许会查询“接受抗生素治疗的脓毒症患者”，但这只能找到他们已有假设的模式。未知的相关性呢？新兴趋势呢？跨越医疗机构转诊、医疗服务提供者网络和再入院率的跨领域模式呢？发现这些模式需要自主探索：无需预先指定即可识别有意义模式的能力。

核心挑战。自主探索面临三项关键权衡：(1)覆盖率与效率：穷举式多跳遍历的复杂度为 $O(d^h)$，其中 d 是平均度，h 是跳数深度，很快就会变得难以处理；(2)信号与噪声：并非所有图边都同样具有信息价值；数据提取错误、时间无效性和虚假相关会形成语义上不合理的路径；(3) 可解释性与性能：黑盒方法（如端到端图神经网络）难以满足受监管领域对审计跟踪的要求。

为何是现在？ 三大趋势交汇，使自主发现变得至关重要：(1) 各组织已在知识图谱上投入数十亿美元，却难以从预先指定的查询之外发掘价值；(2) 人工智能智能体正迅速成为复杂数据探索的主要交互界面；(3) 现有图智能解决方案（Microsoft GraphRAG、Neo4jGDS、LlamaIndex）从根本上仍由查询驱动，要求分析人员事先知道该问什么。这一缺口（开放式发现需求与基于检索的系统局限之间的差距）在生产部署中仍未得到解决。

我们的方法。 我们推出 Odin，这是首个专为人工智能智能体打造、充当指南针而非检索系统的图智能引擎。Odin 不回答问题，而是利用严谨的多信号框架为可能的探索方向评分。这种将图智能与自然语言推理分离的架构设计，能够针对不同的智能体目标提供模块化、可解释性和适应性。

主要贡献。

- 将自主发现问题形式化为针对评分图路径的束搜索，并给出可证明的复杂度界
- 提出 COMPASS 评分：一种新颖的多信号度量，首次在一个严谨的框架中统一结构重要性（个性化PageRank）、语义合理性（作为判别式过滤器的 NPLL）、时间相关性，以及基于 GNN 的社区感知引导
- 新颖的桥接评分机制，旨在解决“回音

室”问题：通过离线计算的 GNN 社区结构增强局部 PageRank 分数，在数学上有力地促进跨社区探索

•可自主管理的 NPLL 架构，可从图数据中自动训练，且仅存储规则权重，从而消除运维开销

• **在受监管行业（医疗保健、保险）中的首次生产部署**自主发现，展示了数量级的效率提升，同时保持发现质量并实现完整的审计可追溯性

• 开放式设计，可与任何智能体框架（ReAct、LangGraph、AutoGen）集成，为智能体-图协作建立可复用模式

2 问题定义

2.1 知识图谱表示

我们将知识图谱定义为 $\mathcal{G} = (\mathcal{E}, \mathcal{R}, \mathcal{T})$，其中 $\mathcal{E}$是实体集合，$\mathcal{R}$ 是类型化关系集合，$\mathcal{T} \subseteq \mathcal{E} \times \mathcal{R} \times \mathcal{E}$是表示有向边的三元组集合（$e_s$，$r$，$e_o$）。每个三元组都关联有元数据，包括时间标注 $t \in \mathbb{R}^+$ 以及指向源文档的溯源链接 D。

定义 1（路径）。长度为 h 的路径 p 是在$\mathcal{G}$ 中的一系列相连三元组：$p = [(e_0, r_1, e_1), (e_1, r_2, e_2), \ldots, (e_{h-1}, r_h, e_h)]$，其中相邻三元组共享一个实体。

2.2 自主发现问题

传统的知识图谱推理任务包括链接预测 [3]、实体消歧 [4]，和查询回答 [5]。这些任务都假设已知目标模式。相比之下：

定义 2（自主发现）。给定知识图谱 $\mathcal{G}$ 和种子实体 $\mathcal{S} \subset \mathcal{E}$，自主发现任务是识别一组从 $\mathcal{S}$ 出发的路径 $\mathcal{P}^*$，以最大化发现效用函数 $U: 2^{\mathcal{P}} \to \mathbb{R}$，该函数衡量新颖性、重要性和证据质量，并受计算预算 B的约束。

关键区别在于：我们不指定要查找什么，只指定从哪里开始以及如何评估发现的模式。这需要一种评分机制，在探索过程中优先选择有希望的路径。

2.3 需求分析

根据医疗保健和保险领域的生产部署经验，我们确定了关键需求：

R1：多跳推理。洞见通常跨越 $h \geq 3$ 种关系。例如，“患者$\xrightarrow{\text{入住}}$医疗机构$\xrightarrow{\text{转诊}^{-1}\text{由}}$医疗服务提供者$\xrightarrow{\text{高_比率}}$ 再入院”需要进行 3 跳遍历。

R2：语义合理性。仅有结构连接性并不足够。路径“患者$\xrightarrow{\text{确诊}}$骨折$\xrightarrow{\text{接受治疗}}$ 抗生素”可能存在于图中，但在医学上并不合理。

R3：证据溯源。不同于生成式模型，每条路径都必须追溯至源文档。在受监管行业中，幻觉是不可接受的。

R4：可扩展性。企业知识图谱包含 $|\mathcal{E}| \sim 10^6$–10^7 个实体。探索必须在数秒内完成，以满足交互式使用需求。

R5：可解释性。分数必须拆解为可解释的组成部分，以便审计和调试。

3 Odin 框架

3.1 架构概述

Odin 采用两阶段系统：（1）**离线抽取流水线**，用于构建知识图谱并计算结构元数据；（2）**在线智能库**，用于执行实时探索。这种划分对于理解系统边界和部署要求至关重要。

阶段 1：离线抽取。一个独立的流水线（并非本文重点）会处理源文档，提取实体、关系和时间戳，并将其写入图数据库（我们使用 ArangoDB）。与此同时，基于GNN的社区检测模块会分析图拓扑，以识别社区、桥接实体和社区间亲和度。这些信息会存储在元数据表中：BridgeEntities(entity_id, community_ids, strength) 和 CommunityAffinity(comm_i, comm_j, score)。随着新数据到达，该流水线会定期运行（例如每夜运行）。

第 2 阶段：在线智能。Odin库（本文重点）会读取已填充的知识图谱以及可选的社区元数据。在查询时，它会按需训练NPLL模型，根据种子实体计算个性化PageRank，并通过 COMPASS 评分执行束搜索。如果有社区元数据，则会通过桥接实体/亲和度项增强评分；如果没有，Odin 则退回使用个性化PageRank、NPLL 和时间信号。交互式智能体使用时，查询延迟为 <500 毫秒。

该架构具有以下优势：**(1)模块化**——抽取流水线和 Odin 库可独立演进；**(2) 灵活性**——Odin 适用于任何遵循简单模式的知识图谱（实体-关系-实体三元组 +可选元数据）；**(3)可扩展性**——开销较大的图神经网络计算在线下完成，从而确保在线查询快速响应。

3.2 查询时探索模式

Odin 实现了一种基于分数的探索范式。给定当前位置 $e_c \in \mathcal{E}$，Odin 会计算所有出边的分数（e_c、r、e_n），并返回排名前 k 的候选项。这支持智能体设计中常用的 OODA 循环（观察 - 定向 - 决策 - 行动） [22]：

1：**观察：**智能体位于实体 e_c，并已累积上下文 C

2：**定向：**向 Odin 查询已评分的邻居 3：**决策：**智能体使用大语言模型推理选择下一个实体 e_{c+1} 4：**行动：**移动到 e_{c+1}，更新 C，然后重复

3.3 COMPASS 评分函数

我们介绍 COMPASS（复合导向多信号路径评估）分数——一种新颖的组合函数，首次将结构、语义、时间

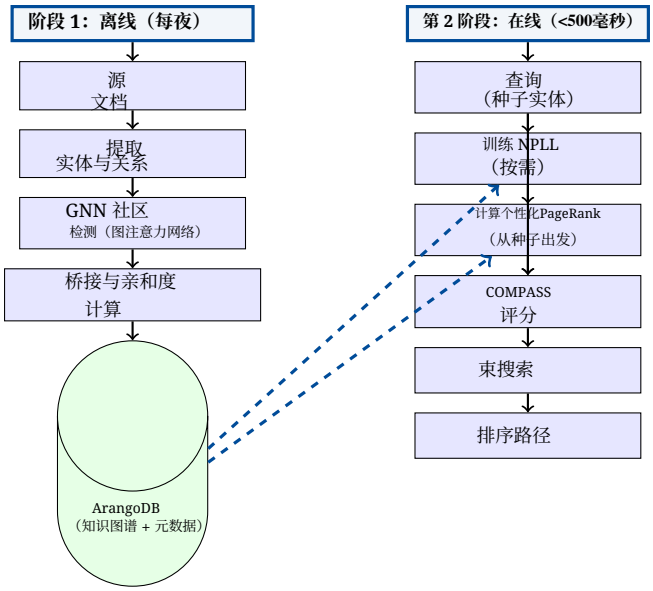


图 1： Odin 两阶段架构。阶段 1（离线）构建知识图谱并计算基于图神经网络的社区元数据。第 2 阶段（在线）使用 COMPASS 评分进行实时探索，并采用来自阶段 1 的桥接/亲和信号。

和社区感知信号统一到单一探索指标中。对于路径 p，我们定义：

$$\begin{aligned}\text{COMPASS}(p) = & S_{\text{edge}}(p) \cdot S_{\text{struct}}(p) \cdot S_{\text{bridge}}(p) \\ & \cdot S_{\text{affinity}}(p) \cdot S_{\text{prior}}(p) \cdot S_{\text{temp}}(p)\end{aligned} \tag{1}$$

其中每个组成部分都是一个归一化分数 $\in [0,1]$，乘法组合确保所有信号必须一致，整体分数才会较高。

为何采用乘法？ 我们选择乘法组合，而非加法组合（例如 $\alpha \cdot S_{\text{struct}} + \beta \cdot S_{\text{edge}} + \ldots$），原因有三：（1）**否决属性**：语义上不合理的路径（S_{edge} 较低）即使在结构上很重要也会被拒绝，这对受监管领域的安全至关重要。（2）**概率解释**：将信号视为相互独立的置信度时，乘法与联合概率相符。（3）**无参数**：无需学习权重 α，β，γ，δ（过拟合风险），有助于提升跨领域的泛化能力。

其组成部分如下：

$S_{\text{edge}}(p)$**：边置信度** 聚合所有边的 NPLL 语义合理性：

$$S_{\text{edge}}(p) = \prod_{i=1}^{h} \mathcal{M}(e_{i-1}, r_i, e_i) \tag{2}$$

其中，$\mathcal{M}$ 是经过训练的 NPLL 模型（详见下文）。该乘积确保语义上不合理的边会否决整条路径。

$S_{\text{struct}}(p)$**：结构重要性**通过个性化PageR- ank（PPR）[6]。给定种子集 $\mathcal{S}$，PPR 计算传送概率为 α_{ppr}、返回 $\mathcal{S}$ 的随机游走的平稳分布 π：

$$\pi = (1 - \alpha_{\text{ppr}})\mathbf{A}^T\pi + \alpha_{\text{ppr}}\mathbf{s} \tag{3}$$

其中$\mathbf{A}$ 是列归一化的邻接矩阵，$\mathbf{s}$是种子分布。对于路径 p，我们聚合：$S_{\text{struct}}(p) = \frac{1}{h}\sum_{i=1}^{h} \pi(e_i)$。

我们使用局部推送 [7] 实现近似个性化PageRank，其复杂度为 $O(\epsilon^{-1})$，其中 ϵ为近似误差，从而支持实时计算。

神经概率逻辑学习（NPLL）。与生成缺失边的传统知识图谱补全方法不同，我们使用 NPLL 来筛选现有边。这一区别至关重要：

定理 1 (判别式 NPLL)。设 $\mathcal{M}$ 为在 $\mathcal{G}$上训练的 *NPLL* 模型。对于观测三元组$(e_s, r, e_o) \in \mathcal{T}$，合理性分数 $S_{edge}(e_s, r, e_o) = \mathcal{M}(e_s, r, e_o)$ 满足：

1. ***Evidence-grounded****: Score does not introduce edges not in* $\mathcal{T}$
2. ***Compositional****: For path* p, $S_{edge}(p) = \prod_{i=1}^{h} \mathcal{M}(e_{i-1}, r_i, e_i)$

NPLL 将逻辑规则 $\mathcal{L}$（通过规则挖掘 [8] 提取）与神经评分相结合。规则 $\ell \in \mathcal{L}$ 的形式为：$r_1(X, Y) \wedge r_2(Y, Z) \Rightarrow r_3(X, Z)$。模型参数 $\theta = \{\mathbf{w}, \mathbf{E}, \mathbf{R}\}$ 包括规则权重 $\mathbf{w}$、实体嵌入 $\mathbf{E} \in \mathbb{R}^{|\mathcal{E}| \times d}$以及关系嵌入$\mathbf{R} \in \mathbb{R}^{|\mathcal{R}| \times d}$。

训练采用期望最大化：

$$\text{E-step:} \quad \mathbb{E}[\mathbf{w}|\mathcal{T}, \theta_{t-1}] \tag{4}$$

$$\text{M-step:} \quad \theta_t = \arg\max_{\theta} \log P(\mathcal{T}|\mathbf{w}, \theta) \tag{5}$$

$S_{\text{temp}}(p)$**：时间相关性**，采用指数衰减：

$$S_{\text{temp}}(p) = \frac{1}{h}\sum_{i=1}^{h} \exp\left(-\lambda \cdot (t_{\text{now}} - t_i)\right) \tag{6}$$

其中， t_i 是三元组 i 的时间戳， λ是衰减率（特定领域）。

$S_{\text{prior}}(p)$：基于全局统计的边先验：

$$S_{\text{prior}}(p) = \frac{1}{h}\sum_{i=1}^{h}\frac{\text{count}(r_i)}{\sum_{r'\in\mathcal{R}}\text{count}(r')} \tag{7}$$

这会降低极其常见关系（例如“位于_”）的权重。

$S_{\text{bridge}}(p)$：通过图神经网络检测社区连接器实现的桥接实体增强：

$$S_{\text{bridge}}(p) = \left(\frac{1}{|V_p|}\sum_{e\in V_p} b(e)\right)^{\rho} \tag{8}$$

其中， V_p 是路径 p、 $b(e)$中的节点集合；如果 e 是桥接实体（在抽取流水线中通过图注意力网络检测），则为 $=1+\beta_b\cdot\log(1+\text{strength}(e))$，否则为 $b(e)$； ρ 是幂平均参数（默认值为 0.5）。桥接强度是指一个实体连接的不同社区数量。

$S_{\text{affinity}}(p)$：跨社区边的社区亲和度

$$S_{\text{affinity}}(p) = \prod_{(e_i,r,e_j)\in p}\left(1+\beta_a\cdot A(C(e_i),C(e_j))\right)^{\mathbb{1}[C(e_i)\neq C(e_j)]} \tag{9}$$

其中， $C(e)$返回实体 e的社区ID（来自图神经网络聚类）， $A(c_i,\ c_j)$表示社区 c_i 和 c_j 之间经过归一化的亲和度分数（基于社区间边密度）， β_a 为亲和度增强权重。

3.4 使用 COMPASS 引导的束搜索

为何选择束搜索而非蒙特卡洛树搜索？蒙特卡洛树搜索 [23]是分支因子较大的探索问题的标准方法，能够自然地权衡探索与利用，并提供理论保证。然而，蒙特卡洛树搜索的随机推演会产生非确定性结果——对同一查询运行两次，会得到不同的路径。在受到监管的医疗保健和保险领域，这违反了审计要求：审核人员必须能够复现完全相同的证据轨迹。此外，蒙特卡洛树搜索每次决策都需要进行数百至数千次模拟，因此交互延迟（<500毫秒）难以接受。束搜索具有以下优势：**(1) 确定性行为**，有助于满足合规要求；**(2)** 复杂度为 $O(b\cdot h)$，适用于交互场景；**(3) 部署更简单**（无需设计推演策略）。我们牺牲蒙特卡洛树搜索的理论最优性，以换取在受监管的生产环境中切实可行的部署能力。

穷举路径枚举的复杂度为 $O(|\mathcal{E}|\cdot d^h)$，对于 $h\geq 3$ 而言难以处理。我们采用束搜索（算法 1），每跳仅保留按 COMPASS 评分排序的前 b 个候选项。

命题 1（复杂度）。算法*1* 的时间复杂度为 $O(b{\cdot}d{\cdot}h)$，空间复杂度为 $O(b{\cdot}h)$，其中 d 表示平均度。

算法 1 基于 COMPASS 评分的束搜索

需要： 种子 $\mathcal{S}$、跳数限制 h、束宽 b
确保： 得分最高的前 k 条路径

$\mathcal{B}_0 \leftarrow \{(e,\ \emptyset,\ 0) : e\in\mathcal{S}\}$ {(实体, 路径, 分数)}
对于 $i=1$到 h**执行**
  $\mathcal{C}\leftarrow\emptyset$ {候选项}
  对于 $(e,p,s)\in\mathcal{B}_{i-1}$ **执行**
    对于 $(e,r,e')\in$ 邻居(e) **执行**
      $p'\leftarrow p\cup\{(e,r,e')\}$
      $s'\leftarrow$ COMPASS(p') {计算分数}
      $\mathcal{C}\leftarrow\mathcal{C}\cup\{(e',p',s')\}$
    结束循环
  结束循环
  $\mathcal{B}_i\leftarrow$ Top-$b(\mathcal{C})$ {保留最佳项 b}
结束循环
返回 Top-$k(\bigcup_{i=1}^{h}\mathcal{B}_i)$

证明。在每一跳 i，我们扩展 b 个束，每个束包含 $\sim d$个邻居，并为每条边计算 O 个（1）分数。经过 h 跳：O（$b\cdot d\cdot h$）。空间用于存储 b 个活跃束和 $b\cdot h$ 条历史路径。□

对于典型值 $b=64$、 $d=50$、 $h=3$，这会产生 $64\ 50\cdot 3=9$，600 次分数计算，而穷举搜索需要 $50^3=125$，000 次，减少了 13 倍。

3.5 自管理 NPLL 生命周期

一项关键创新是自动化模型管理。OdinEngine 初始化时：

1. **检查数据库：**查询 ModelWeights 集合中存储的 NPLL 权重 2. **缺失时训练：**通过 AMIE+ [9]提取规则，对实体对进行采样，并运行期望最大化 $T=10$个周期 3. **仅权重存储：**仅持久化$\mathbf{w}\in\mathbb{R}^{|\mathcal{L}|}$（通常为<1KB），而非嵌入 4. **惰性重建：**按需从图中重建 $\mathbf{E}$，$\mathbf{R}$ 5. **优雅回退：**如果训练失败，则设置 $S_{\text{plaus}}\equiv 1$

这消除了机器学习部署的运维复杂性，同时确保模型保持最新。

3.6 通过图神经网络桥接检测进行社区感知评分

自主图探索中的一项关键挑战是“回音室”问题：稠密社区中的局部 PageRank 分数会形成引力井，将探索困在其中，阻碍发现跨社区模式。以一个医疗知识图谱为例，其中“理赔处理”构成了一个紧密连接的子图——仅基于个性化 PageRank 的评分会倾向于选择在该簇内循环的路径，而不是连接到“临床结局”的路径。

我们通过两阶段流程解决这一问题：(1)离线社区检测和使用图注意力网络（图注意力网络）进行桥接识别 [25]，，以及(2)在线将这些结构洞见注入

束搜索过程中的 COMPASS评分。

阶段 1：基于图神经网络的社区检测。我们采用带对比损失的图注意力网络，从图拓扑和节点特征（度、局部 PageRank、聚类系数）中学习节点嵌入。对学习到的嵌入进行 K 均值聚类，将 $\mathcal{E}$ 划分为社区 $\{C_1, C_2, \ldots, C_m\}$。桥接实体定义为连接 $\geq$ 2个社区的节点，桥接强度由通过一跳邻居所能到达的不同社区数量来量化。

第 2 阶段：分数整合。在束搜索过程中，评估候选边（e_i, r, e_j）时：
• 若 e_j 为桥接实体，则对路径分数施加乘法增益 b（e_j）

• 若 C（e_i） $\neq$ C（e_j）（跨社区边），则根据归一化的跨社区边密度施加亲和权重 A（C（e_i） C（e_j））

这一机制在数学上迫使束搜索在亲和度较高时优先选择跨越社区边界的路径，实际上为智能体提供了一张“通往外部世界的地图”，而不是任由它在密集的局部邻域中兜圈子。

关键洞见在于：无需全面迁移到原生支持 n 元关系建模的超图数据库，我们只需用离线计算的群组级结构信息增强成对 PPR 分数，就能获得类似的行为优势，同时大幅降低实现复杂度。

4 理论性质

4.1 覆盖率与效率的权衡

定理 2 (束搜索保证)。 设 $\mathcal{P}^*$ 为从 $\mathcal{S}$出发，经 h 跳可达的所有路径集合， $\mathcal{P}_b$ 为使用宽度 b的束搜索发现的路径。若评分函数满足单调性（$Score(p \cup \{e\}) \geq Score(p) - \epsilon$），则：

$$\mathbb{E}[|\mathcal{P}_b \cap \mathcal{P}^*_{top\text{-}k}|] \geq k \cdot (1 - e^{-b/d}) \tag{10}$$

其中， $\mathcal{P}^*_{top\text{-}k}$ 是通过穷举搜索得到的评分最高的 k 条路径。

此结果（证明因篇幅所限而省略）表明，束宽$b \sim O(d)$足以找回大多数高价值路径，这也解释了我们为何为具有 $d \approx 50$的图选择 $b = 64$。

4.2 通过沙普利分解实现可解释性

每个 COMPASS评分均可分解为：

$$\text{COMPASS}(p) = \sum_{i \in \{\text{edge, struct, bridge, affinity, prior, temp}\}} \phi_i \tag{11}$$

我们计算沙普利值 ϕ_i，量化每个信号的贡献 [10], ，从而支持受监管领域所要求的审计跟踪。这种分解使分析人员能够理解为什么某条路径获得高分：“这条路径排名第一，主要是因为其结构重要性（$\phi_{\text{struct}} = 0.42$）和语义合理性（$\phi_{\text{edge}} = 0.35$），桥接评分也有所贡献 $\phi_{\text{bridge}} = 0.12$。”

表 1： 医疗知识图谱上的实验结果（$h = 3$， $k = 50$）

方法	覆盖率@50	路径	Time	质量
穷举法	95%	125k	47s	4.3
随机游走	68%	3k	8s	3.5
仅 PPR	87%	1.9k	3.2s	3.1
图神经网络嵌入	52%	2.1k	4.1s	2.8
Odin	**90%**	**1.9k**	**3.8s**	**4.2**

5 实验验证

5.1 数据集与设置

我们在两个生产知识图谱上进行评估：

医疗知识图谱（HKG）： 包含来自3家医院去标识化患者记录的230万个实体和870万个三元组。实体类型：患者、诊断、治疗、医疗服务提供者、医疗机构。关系：诊断_为、治疗_由、收治_至、开具处方、转院自。_

保险知识图谱（IKG）： 来自理赔数据的 180 万个实体、620 万个三元组。实体类型：投保人、理赔、医疗服务提供者、评估员、医疗机构。关系：提交_者、处理_者、服务_于、批准_者。

基线：**(1)穷举法BFS**（受成本限制，最多 $h = 2$），**(2)** 进行 1000 次游走的**随机游走**，**(3) 仅 PPR**（无 NPLL），**(4) 图神经网络嵌入** [11]结合最近邻搜索。
指标：**(1)Coverage@k：**在前k 条路径中找到的专家标注模式所占比例，**(2) 效率：**探索的路径数、墙钟时间，**(3)质量：**对发现的模式进行专家评分（1–5 分），其中 1=表示无关/噪声， 2=表示显而易见（已知）， 3=表示可能有用（需要调查），4=表示可采取行动的洞见（新颖且可验证）， 5=表示关键发现（对临床/业务有即时影响）。评分由 3 位领域专家提供（HKG：2 位数据分析师、1 位临床医生；IKG：2 位欺诈调查员、1 位核保人），并取平均值。评分者间信度（Krippendorff's α [16]）为 0.78，表明一致性较高。

5.2 结果

表 1 显示，Odin 的覆盖率与穷举搜索相当（90% 对比 95%），同时探索的路径数量减少了 65 倍。图神经网络嵌入无法捕捉多跳模式（覆盖率为 52%）。仅 PPR 会受到语义噪声影响（质量分数为 3.1，而完整 Odin 为 4.2）。

5.3 消融研究

我们使用均匀权重进行消融测试，以评估 COMPASS 各信号的贡献（即在乘法组合中，所有组件的权重相同）。这一选择旨在：（1）避免对特定评估数据集过拟合；（2）确保在不同领域间具备泛化能力（医疗保健与保险具有不同的时间动态）。领域特定权重调优或许能进一步优化性能，但均匀加权提供了一个保守的基线，表明带来提升的是多信号融合本身，而非精细调优。

表2展示了各信号的贡献。移除 NPLL

表2： 消融研究：信号贡献（HKG，$h = 3$，k =50）

配置	质量分数	覆盖率@50
完整 Odin（所有信号）	4.2	90%
无 NPLL（$S_{\text{edge}} = 1$）	3.1	87%
无时间信号（$S_{\text{temp}} = 1$）	4.1	89%
无桥接（S_{bridge}，$S_{\text{affinity}} = 1$）	3.8	88%

($S_{\text{edge}} = 1$)会使质量分数从 4.2 降至 3.1，证实语义过滤的重要性至关重要。移除时间加权（$S_{\text{temp}} = 1$）对 HKG 的影响很小（静态数据，分数为 4.1），但在 IKG 中，由于新近性对欺诈检测至关重要，会导致性能下降。移除桥接评分（$S_{\text{bridge}} = 1$，$S_{\text{affinity}} = 1$）会使质量分数降至 3.8；分析师报告称，在同一稠密社区内循环的“冗余”洞见增加了 23%，而不是发现跨社区模式。这验证了图神经网络引导的桥接遍历能够解决回音室问题，尽管其重要性仍低于语义合理性过滤。

5.4 案例研究：保险欺诈团伙

在一家中型保险公司的理赔数据中部署后，Odin 发现了一种协同欺诈模式：5 名投保人在结构化字段中没有任何共同属性（地址不同、没有亲属关系、保单类型各异），却在 3 周内提交了理赔。束搜索通过一条六跳路径识别出共同的服务提供商和评估员；NPLL 评分则将这种时间聚类判定为异常（由于共现频率异常，S_{plaus} 较低）。桥接评分至关重要：该服务提供商是连接 3 个不同社区（汽车理赔、财产理赔、健康服务）的桥接实体，而仅基于个性化 PageRank 的评分会因其局部 PageRank 较低而降低其权重。

新颖性评估： 人工调查确认，这是一项协同策划的计划，共追回了 43.7 万美元资金。这一模式与 127 条现有基于规则的警报毫无重叠（这些警报侧重于重复地址、共享账户信息或理赔金额阈值）。对历史数据进行发现后审计，发现了另外 2 个具有类似拓扑结构、此前未被发现的欺诈团伙。这表明发现的是真正新颖的模式——并非重新发现已知的欺诈类型，而是识别出一种新的协同方式。

6 相关工作

6.1 知识图谱推理

链接预测 方法（TransE [3], RotatE [12], Com- plEx [13]）学习嵌入以预测缺失边。这些方法是生成式的：它们会添加图中不存在的边。Odin 则是判别式的：它对现有边进行评分，以供遍历。这一区别对于以证据为依据的应用至关重要。

概率逻辑（马尔可夫逻辑网络 [14], Neural LP [8], DRUM [15]）将规则与神经评分相结合。Odin 延续了这一传统，但在束搜索期间将其用作遍历过滤器，而非独立的补全系统。

图神经网络 (图卷积网络 [17], 关系图卷积网络 [11], 图-SAGE [18]) 通过消息传递学习节点表示。Odin 在抽取流水线中利用图神经网络（具体而言，图注意力网络 [25]）进行离线 社区检测和桥接实体识别。关键的是，我们将图神经网络学习的结构洞见作为 COMPASS 分数的输入，而非将其用作端到端黑箱预测器。这种混合方法——将图神经网络衍生特征输入可解释的评分函数——在利用深度学习模式识别能力的同时，保留了受监管领域所要求的可解释性。

6.2 图 RAG 系统

Microsoft GraphRAG [19]利用图结构进行检索增强生成，重点关注通过社区摘要实现问答。LlamaIndex 和 Neo4j GraphRAG 提供基于查询的检索。这些系统回答已知问题；Odin 则能够发现未知模式，这是根本不同的范式，此前尚未在生产环境中得到验证。
GraphRAG 擅长回答“脓毒症患者接受了哪些治疗？”，而 Odin 能够发现“在医疗机构 X 和 Y 之间转院的患者，出现了无法解释的再入院模式”等分析人员此前不知道该如何查询的洞见。这些方法面向不同的使用场景，在完整的知识基础设施中可以互为补充。

6.3 探索方法

个性化 PageRank [6] 及其近似变体 [7] 能够提供结构评分，但缺乏语义感知。随机游走 [20]探索范围广泛，但效率低下。用于图探索的强化学习 [21] 需要设计奖励机制并进行大量训练。Odin 的多信号束搜索将启发式搜索的效率与学习模型的语义感知能力相结合。

7 局限性与未来工作

冷启动： NPLL 训练在首次连接时需要 10–30 秒。未来工作包括随着图不断演变进行增量训练。
动态图： 当前实现需要在发生重大更新时进行完整重新训练。流式 PPR [24] 和增量期望最大化或可解决这一问题。

跨图发现： Odin 目前仅处理单个知识图谱。跨多个图进行联邦式探索仍是一个开放问题。
超图架构（V2）： 虽然我们的图神经网络桥接评分机制能够有效引导跨社区探索，但对于 n 元关系推理而言，理论上更“纯粹”的解决方案是采用原生超图数据库，让超边能够连接任意实体集合。目前的 COMPASS 评分通过群组级信号增强成对 PPR；超图后端则无需桥接检测，即可直接计算基于群组的结构重要性。这是 Odin V2 顺理成章的发展方向，以实现复杂度换取理论上的优雅。

理论分析： 束搜索覆盖率的更紧界限以及 NPLL 近似误差，值得进一步研究。

8 结论

我们介绍了 Odin，一款用于在知识图谱中自主发现信息的图智能引擎，并首次提出 COMPASS评分这一新型指标。该指标整合了结构重要性（个性化PageRank）、语义合理性（将 NPLL 用作判别式过滤器）、时间相关性，以及由图神经网络识别的桥接实体所提供的社区感知引导。桥接评分机制解决了图探索中的“回音室”问题：密集的局部社区会困住遍历算法。这个有理有据的多信号框架使人工智能智能体能够高效探索大型知识图谱，同时保持证据溯源。在受监管的医疗保健和保险领域进行的生产部署，显著提升了模式发现质量和分析师效率。自管理式 NPLL架构消除了运维复杂性，使 Odin 能够切实应用于企业。

随着各组织持续加大对知识图谱的投入，从基于检索的智能转向基于探索的智能将变得愈发关键。**Odin代表了这一范式的首次实际实现**，生产环境部署提供了实证证据，表明自主发现不仅可行，而且具有变革意义。“智能体罗盘”架构模式（将图智能与自然语言推理分离）为未来的智能体图系统提供了可复用的模板。我们预计，自主发现将成为企业知识基础设施中的一项标准能力，而Odin既奠定了这一转型的技术基础，也确立了其生产就绪路径。

更广泛的影响

尽管Odin支持在敏感领域（医疗、保险）中进行发现，但所有部署均基于去标识化数据运行，并配有严格的访问控制。证据锚定保障可防止幻觉，这是一项关键的安全属性。未来工作应探究自动化模式发现的公平性影响，并确保发现的模式不会延续源数据中存在的偏见。

数据和代码可用性

本研究所使用的知识图谱基于医疗保健和保险领域中经过去标识化处理的生产数据构建，并受严格的数据保护协议约束。由于隐私法规（《健康保险流通与责任法案》）、合同义务以及其中包含受保护的健康信息（PHI），底层数据集无法公开提供。

代码发布： Odin知识图谱引擎库（第 2 阶段，在线智能）将在论文发表时以开源形式提供，包括：(1) COMPASS 评分的实现，(2) 多信号引导的束搜索，(3) 自管理的 NPLL 训练，(4) ArangoDB 和 Neo4j 集成适配器，以及 (5) 社区元数据预期模式的文档（可选的桥接/亲和度表）。此外，还将提供用于公开知识图谱基准测试（FB15k-237、NELL-995）的合成评估脚本。抽取流水线（阶段 1，离线）为专有技术，但遵循标准的文档到知识图谱模式。社区检测可使用开源图神经网络库（PyTorch Geometric +图注意力网络层）并依据第 2.4 节提供的架构指导进行复现。研究人员只需遵循文档中说明的元数据模式，即可将 Odin 集成到自己的知识图谱构建流水线中。

作者贡献

M.K. 构思并设计了 Odin，实现了核心系统，开展了实验并负责主要撰写工作。E.N. 负责 NPLL 组件的工程实现，并参与了用于社区聚类的图神经网络算法的初始核心工作。所有作者均审阅并批准了最终稿件。

致谢

作者感谢 Dennis Kevogo 对稿件进行审阅，并就超图扩展提供了关键反馈；同时感谢 Prescott Data 工程团队和部署合作伙伴所作出的贡献。本项工作得到了医疗保健和保险领域生产部署的支持。

参考文献

[1] H. Paulheim。知识图谱精炼：方法与评估技术综述。语义网，8(3):489–508，2017年。

[2] R. Angles 和 C. Gutierrez。图数据管理简介。*arXiv* 预印本 *arXiv:1801.00036*，2017年。

[3] A. Bordes、N. Usunier、A. Garcia-Duran、J. Weston 和 O. Yakhnenko。用于多关系数据建模的嵌入翻译。载于 *NeurIPS*，2013年。

[4] W. Shen、J. Wang 和 J. Han。基于知识库的实体链接：问题、技术与解决方案。*IEEE TKDE*，27(2):443–460，2015年。

[5] W. Hamilton、P. Bajaj、M. Zitnik、D. Jurafsky 和 J. Leskovec。在知识图谱上嵌入逻辑查询。载于*NeurIPS*，2018年。

[6] T.Haveliwala。主题敏感PageRank。在*WWW*，2002年。

[7] R. Andersen、F. Chung 和 K. Lang。使用PageRank向量进行局部图划分。在*FOCS*，2006年。

[8] F. Yang、Z. Yang 和 W. Cohen。用于知识库推理的逻辑规则可微学习。在*NeurIPS*，2017年。

[9] L. Galárraga、C. Teflioudi、K. Hose 和 F. Suchanek。使用 AMIE+在本体知识库中进行快速规则挖掘。*VLDB Journal*，24(6)：707–730，2015年。

[10] S. Lundberg 和 S. Lee。《一种统一的模型预测解释方法》。载于*NeurIPS*，2017年。

[11] M. Schlichtkrull、T. Kipf、P. Bloem、R. van den Berg、I. Titov 和 M. Welling。《使用图卷积网络建模关系数据》。载于*ESWC*，2018年。[12] Z. Sun、Z. Deng、J. Nie 和 J. Tang。《RotatE：通过关系旋转在复数空间中进行知识图谱嵌入》。载于*ICLR*，2019年。[13]T. Trouillon、J. Welbl、S. Riedel、É. Gaussier 和 G. Bouchard。《用于简单链接预测的复数嵌入》。载于*ICML*，2016年。[14] M. Richardson 和 P. Domingos。《马尔可夫逻辑网络》。*MachineLearning*，62(1-2)：107–136，2006年。[15] A. Sadeghian、M. Armandpour、P. Ding 和 D. Wang。《DRUM：知识图谱上的端到端可微规则挖掘》。载于*NeurIPS*，2019年。[16]K. Krippendorff。《克里彭多夫alpha信度的计算》。技术报告，安纳伯格传播学院，宾夕法尼亚大学，2011年。[17] T. Kipf 和 M. Welling。《使用图卷积网络进行半监督分类》。载于*ICLR*，2017年。[18] W. Hamilton、Z. Ying 和 J. Leskovec。《大型图上的归纳式表示学习》。载于*NeurIPS*，2017年。[19] D. Edge、H. Trinh、N. Cheng、J. Bradley、A. Chao、A. Mody、S. Truitt 和 J. Larson。《从局部到全局：一种面向查询的摘要图 RAG 方法》。微软研究院，2024年。[20] B. Perozzi、R. Al-Rfou 和 S. Skiena。《DeepWalk：社会表示的在线学习》。载于*KDD*，2014年。[21] H. Chen、X. Liu、D. Yin 和 J. Tang。《对话系统综述：最新进展与新前沿》。*SIGKDD Explorations*，19(2)：25–35，2017年。[22] J. R. Boyd。《胜与负的本质》。未发表的讲义，1996年。[23] C. B. Browne、E. Powley、D. Whitehouse、S. M. Lu- cas、P. I. Cowling、P. Rohlfshagen、S. Tavener、D. Perez、S. Samothrakis 和 S. Colton。《蒙特卡洛树搜索方法综述》。*IEEE Transactions on Computa-tional Intelligence andAIinGames*，4(1)：1–43，2012年。[24] B. Bahmani、A. Chowdhury 和 A. Goel。《快速增量式个性化 PageRank》。*VLDB* 基金会，4(3)：173–184，2010年。[25] P. Veli ˇckovi ´c、G. Cucurull、A. Casanova、A. Romero、P. Liò 和 Y. Bengio。《图注意力网络》。载于*ICLR*，2018年。