

架构设计 · 详细设计 · 具体实现文档

OpenKG 知识图谱引擎

Open Knowledge Graph Engine

本文档对 OpenKG 知识图谱引擎进行全面的架构设计与实现分析。OpenKG 是一个完全自主可控的语义知识图谱与决策智能平台，仿照 Semantica 架构实现，支持 Ollama / vLLM 本地大模型，提供 CLI 和 FastAPI 双接口。文档涵盖六层分层架构、20+ 核心模块的详细设计、数据管线流程、决策智能生命周期、UML 类图与时序图，以及关键代码的具体实现分析。

项目	OpenKG — Open Knowledge Graph Engine
版本	v0.1.0
语言	Python 3.9+
LLM	Ollama / vLLM
接口	CLI + FastAPI REST API
日期	2026 年 8 月

目 录

第一章 项目概述	4
1.1 项目背景与定位	4
1.2 核心能力	5
1.3 技术栈	5
1.4 与 Semantica 的对比	6
第二章 架构设计	6
2.1 分层架构总览	6
2.2 接口层	7
2.3 核心编排层	8
2.4 LLM 抽象层	8
2.5 语义处理层	8
2.6 知识表示层	8
2.7 存储层	8
2.8 模块依赖关系	9
第三章 详细设计	9
3.1 核心类设计	9
3.2 OpenKG 编排器设计	10
3.3 LLM 客户端设计	10

3.4 语义抽取器设计	10
3.5 知识图谱构建器设计	11
3.6 上下文图与决策智能设计	11
3.7 溯源管理器设计	11

第四章 核心流程设计 11

4.1 数据管线流程	11
4.2 知识图谱构建流程	13
4.3 决策智能生命周期	13
4.4 知识库构建时序	14

第五章 具体实现 15

5.1 核心编排器实现	15
5.2 LLM 客户端实现	16
5.3 语义抽取实现	16
5.4 实体去重实现	16
5.5 决策智能实现	17
5.6 溯源追踪实现	17
5.7 推理引擎实现	17

第六章 接口设计 18

6.1 CLI 接口	18
6.2 FastAPI REST API	18
6.3 Python SDK 使用	19

第七章 部署与测试19

7.1 环境要求 20

7.2 安装部署 20

7.3 测试验证 20

7.4 配置管理 20

7.5 性能特性 21

7.6 扩展性设计 21

7.7 总结 21

第一章 项目概述

1.1 项目背景与定位

OpenKG (Open Knowledge Graph Engine) 是一个完全自主可控的语义知识图谱与决策智能平台，仿照 Semantic Agent AI 架构设计，使用纯 Python 实现。项目的核心目标是为 AI 提供可审计、可推理、可溯源的结构化知识基础设施，使每一个 AI 决策都可追溯、每一个输出都可审计。

在大语言模型（LLM）快速发展的背景下，AI 系统面临着知识幻觉、决策不可解释、缺乏溯源能力等核心挑战。OpenKG 通过构建知识图谱 + 向量检索 + 决策智能 + 溯源追踪的完整技术栈，为这些问题提供系统性的解决方案。系统支持 Ollama 和 vLLM 两种本地大模型部署方案，确保数据不出域、完全自主可控，适用于金融、医疗、法律等高合规要求领域。

1.2 核心能力

能力域	核心功能	技术实现
多源数据接入	文件(PDF/DOCX/HTML/CSV/JSON/XML)、Web、数据库、纯文本	ingest 模块 + 9 种格式解析器
LLM 驱动抽取	实体识别、关系抽取、三元组抽取	Ollama/vLLM + Pattern 降级
知识图谱构建	实体合并、冲突检测、时序图谱	GraphBuilder + NetworkX
图分析	中心性、社区检测、路径查找、链接预测	GraphAnalyzer + NetworkX 算法
向量检索	语义相似度搜索、混合检索	InMemoryVectorStore / FAISS
决策智能	决策记录、因果链、先例搜索、策略检查	ContextGraph + PolicyEngine
溯源追踪	W3C PROV-O 端到端 lineage	ProvenanceManager
确定性推理	前向链 IF-THEN 规则推理	Reasoner + Rete 网络
本体管理	从 KG 自动生成本体	OntologyGenerator (OWL/Turtle)
多格式导出	JSON、CSV、GraphML、RDF Turtle	KGExporter
双接口	CLI (click+rich) + FastAPI REST API (16端点)	cli.py + server.py

1.3 技术栈

OpenKG 采用纯 Python 实现，核心依赖包括：NetworkX（图数据结构与算法）、FastAPI（REST API 框架）、Click（CLI 框架）、Rich（终端美化输出）、Pydantic（数据模型验证）、httpx（HTTP 客户端，用于调用 LLM API）、NumPy（向量计算）。系统设计为可选依赖架构——当 FAISS、PyPDF、python-docx 等可选库未安装时，系统会自动降级到内置实现，确保核心功能始终可用。

1.4 与 Semantica 的对比

特性	Semantica	OpenKG
实现语言	Python	Python（完全自主可控）
LLM 后端	OpenAI/Groq/HuggingFace/Lite LLM	Ollama / vLLM（本地部署）
图存储	Neo4j / FalkorDB / NetworkX	NetworkX（可扩展 Neo4j）
向量存储	FAISS/Weaviate/Qdrant/Pinecone/Milvus	InMemory / FAISS
三元组存储	Blazegraph/Jena/RDF4J/Oxigraph	内置 RDF 序列化
接口	CLI + REST + MCP Server + Explorer UI	CLI + FastAPI REST API
溯源标准	W3C PROV-O	W3C PROV-O（兼容）
推理引擎	Rete + Datalog + SPARQL	前向链规则推理
许可	MIT	MIT

第二章 架构设计

2.1 分层架构总览

OpenKG 采用六层分层架构，自上而下依次为：接口层、核心编排层、LLM 抽象层、语义处理层、知识表示层、存储层。此外，溯源追踪、配置管理、生命周期管理等横切关注点贯穿所有层级。每一层通过清晰的接口与上下层通信，无隐藏耦合，支持独立替换和扩展。

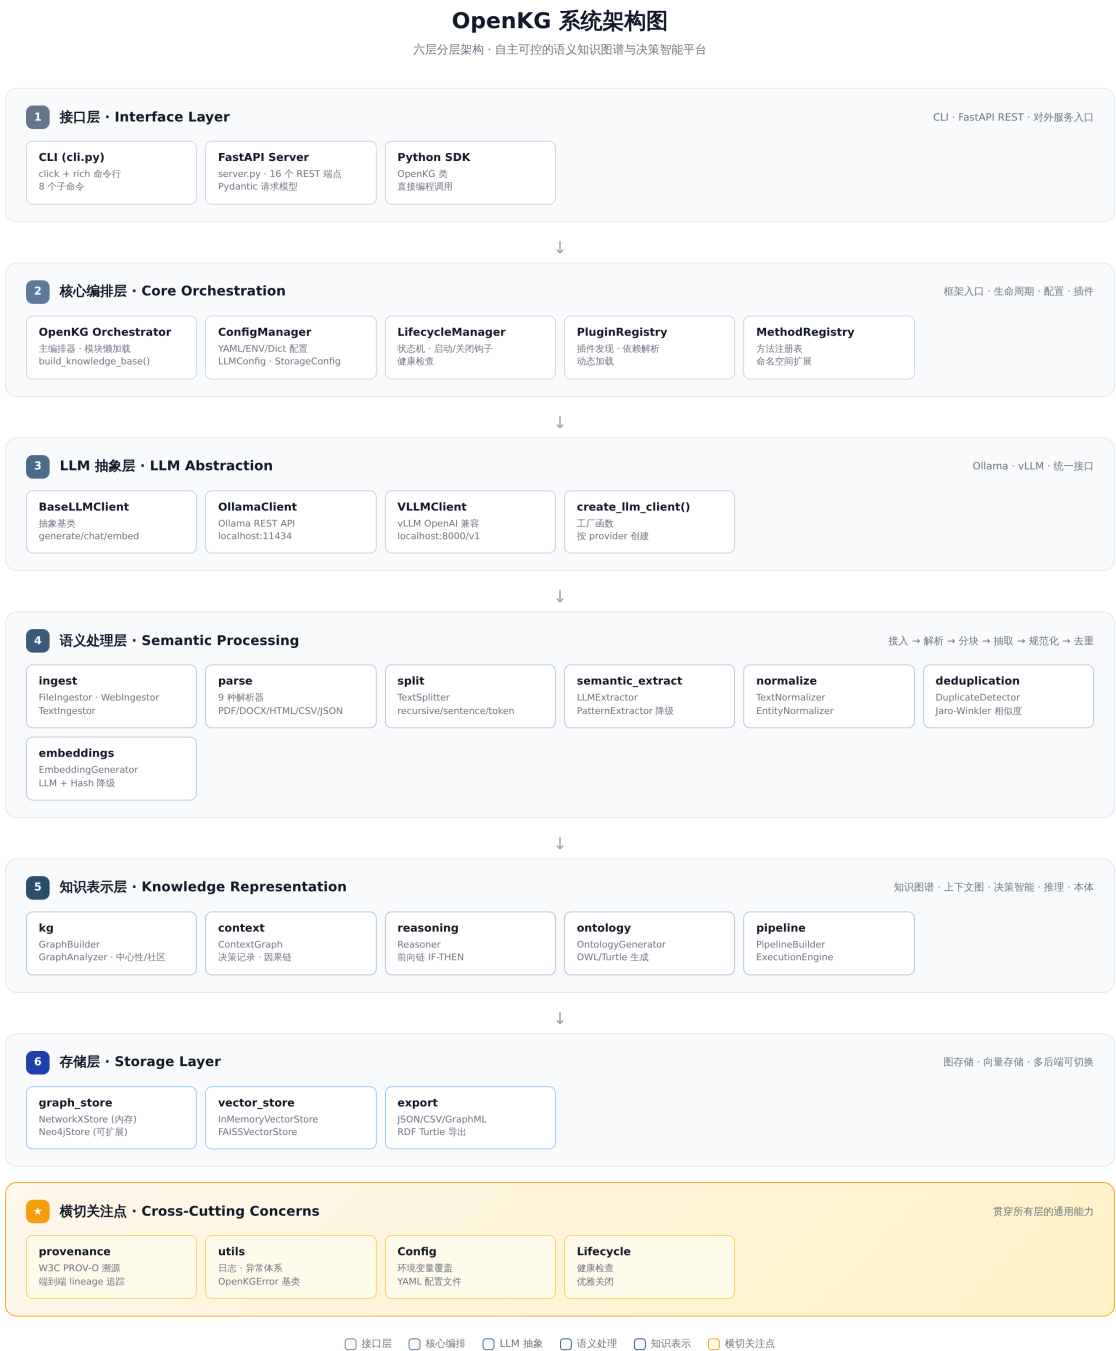


图 2-1 OpenKG 六层分层架构总览

2.2 接口层

接口层是用户与系统交互的入口，提供 CLI 和 FastAPI REST API 两种接口。CLI 基于 Click 框架构建，提供 8 个核心命令（status/build/search/ask/decide/export/models/serve），使用 Rich 库实现彩色表格、进度条、面板等终端美化输出。FastAPI Server 提供 16 个 REST 端点，覆盖知识图谱构建、查询、决策管理、溯源导出、推理等全部功能，支持文件上传和自动生成 OpenAPI 文档。

2.3 核心编排层

核心编排层以 `OpenKG` 类为中心，协调所有模块的初始化和调用。`ConfigManager` 负责配置加载（支持 YAML 文件、字典、环境变量三种来源，环境变量优先级最高）；`LifecycleManager` 管理系统启动/关闭流程和组件健康检查；`PluginRegistry` 提供插件发现、加载、依赖解析能力。`OpenKG` 类通过懒加载属性（`@property`）按需初始化各模块，避免启动时加载全部依赖。

2.4 LLM 抽象层

LLM 抽象层定义了 `BaseLLMClient` 接口，包含 `generate`（文本生成）、`chat`（多轮对话）、`embed`（文本嵌入）三个核心方法。`OllamaClient` 通过 `Ollama` REST API（`/api/generate`、`/api/chat`、`/api/embeddings`）调用本地大模型；`VLLMClient` 通过 `vLLM` 的 `OpenAI` 兼容接口（`/v1/completions`、`/v1/chat/completions`、`/v1/embeddings`）调用。两个客户端都实现了自动降级机制——当 LLM 服务不可用时，嵌入操作降级为哈希嵌入，确保系统始终可用。`create_llm_client` 工厂函数根据配置自动选择客户端实现。

2.5 语义处理层

语义处理层是数据到知识转换的核心，包含 7 个子模块：`ingest`（多源接入）、`parse`（文档解析）、`split`（文档分块）、`semantic_extract`（语义抽取）、`normalize`（数据规范化）、`deduplication`（实体去重）、`embeddings`（向量嵌入）。数据在这 7 个模块中流水线式处理，最终输出结构化的实体、关系和向量。

2.6 知识表示层

知识表示层包含知识图谱（kg）、上下文图（context）、推理引擎（reasoning）、本体管理（ontology）四个模块。`GraphBuilder` 从抽取的实体和关系构建知识图谱；`GraphAnalyzer` 提供中心性分析、社区检测、路径查找等图算法；`ContextGraph` 在知识图谱之上构建决策智能层，支持决策记录、因果链分析、先例搜索；`Reasoner` 提供前向链规则推理；`OntologyGenerator` 从知识图谱自动生成本体。

2.7 存储层

存储层提供图存储和向量存储两种后端。`GraphStore` 抽象接口支持 `NetworkX`（内存）和 `Neo4j`（可扩展）两种后端，提供节点/关系 CRUD、Cypher 查询、图分析等操作。`VectorStore` 抽象接口支持 `InMemory`（纯 Python 余弦相似度）和 `FAISS`（高性能近似最近邻）两种后端，提供向量添加、搜索、删除等操作。两种存储都通过工厂函数创建，后端可在配置中切换，无需修改业务代码。

2.8 模块依赖关系

下图展示了 OpenKG 全部 20+ 模块的依赖关系。接口层依赖核心编排层；核心编排层协调 LLM 抽象层、语义处理层和知识表示层；语义处理层的数据流水线从 ingest 流经 parse、split、semantic_extract、normalize、deduplication 到 embeddings；溯源追踪（provenance）作为横切关注点，被 ingest、split、semantic_extract、kg、context 等多个模块调用。




图 2-2 OpenKG 模块依赖关系图

第三章 详细设计

3.1 核心类设计

OpenKG 的核心类设计遵循单一职责原则和依赖倒置原则。OpenKG 作为门面类（Facade）统一对外暴露 API；BaseLLMClient、BaseGraphStore、BaseVectorStore 三个抽象基类定义接口契约，具体实现通过工厂函数创建。下图展示了 15 个核心类的属性、方法和关系。

Syntax error in text
mermaid version 11.16.1

图 3-1 OpenKG 核心 UML 类图

3.2 OpenKG 编排器设计

OpenKG 类是系统的核心编排器，采用懒加载模式管理所有模块。每个模块通过 `@property` 装饰器按需初始化，首次访问时创建实例并缓存到 `_modules` 字典中。这种设计确保系统启动速度快（不加载未使用的模块），且模块间无循环依赖。

OpenKG 类的核心方法包括：`initialize()` 初始化系统生命周期；`build_knowledge_base()` 执行完整的 7 阶段知识图谱构建流水线；`search()` 执行向量相似度搜索；`ask()` 执行 RAG 问答；`record_decision()` 记录决策；`export_provenance()` 导出溯源轨迹。每个方法内部协调多个模块完成业务逻辑。

3.3 LLM 客户端设计

BaseLLMClient 定义了 `generate`、`chat`、`embed` 三个抽象方法和 `health_check` 具体方法。OllamaClient 使用 `httpx` 同步客户端调用 Ollama 的 REST API，支持 `/api/generate`（文本生成）、`/api/chat`（对话）、`/api/embeddings`（嵌入）、`/api/tags`（模型列表）四个端点。VLLMClient 调用 `vLLM` 的 `OpenAI` 兼容接口，支持 `/v1/completions`、`/v1/chat/completions`、`/v1/embeddings`、`/v1/models` 四个端点。两个客户端都内置了 `_hash_embed` 降级函数，当 LLM 服务不可用时自动切换到基于 SHA-256 哈希的确定性嵌入，确保系统始终可用。

3.4 语义抽取器设计

LLMExtractor 是基于 LLM 的语义抽取器，使用三个结构化 Prompt 模板（NER_PROMPT、RELATION_PROMPT、TRIPLET_PROMPT）引导 LLM 输出 JSON 格式的实体、关系和三元组。`extract()` 方法依次调用三个抽取方法，并通过 `_parse_json_response()` 解析 LLM 输出（支持去除 markdown 代码块、提取 JSON 数组等容错处理）。PatternExtractor 是无需 LLM 的降级方案，使用正则模式识别日期、数字、邮箱、URL、电话等实体类型。

抽取结果统一封装为 `ExtractionResult` 数据类，包含 `entities (List[Entity])`、`relations (List[Relation])`、`triplets (List[Triplet])` 三个字段。`Entity` 包含 `name`、`type`、`description`、`start`、`end`、`confidence` 等属性；`Relation` 包含 `source`、`target`、`type`、`confidence`；`Triplet` 包含 `subject`、`predicate`、`object` 及类型信息。

3.5 知识图谱构建器设计

`GraphBuilder` 负责从抽取的实体和关系构建知识图谱。`build()` 方法接收多个数据源（每个源包含 `entities` 和 `relationships` 列表），执行实体合并（基于 ID 去重）、关系去重、元数据聚合三步操作，最终输出 `KnowledgeGraph` 数据类。`KnowledgeGraph` 包含 `entities`、`relationships`、`metadata` 三个字段，提供 `to_dict()` 方法用于序列化。

`GraphAnalyzer` 提供图分析能力，基于 `NetworkX` 实现：`analyze_graph()` 计算节点数、边数、密度、连通分量、平均度等基础指标；`find_shortest_path()` 查找最短路径；`find_communities()` 使用贪心模块度算法进行社区检测。所有分析方法都接受 `KnowledgeGraph` 作为输入，返回字典或列表。

3.6 上下文图与决策智能设计

`ContextGraph` 是决策智能的核心，在知识图谱之上构建决策记录和因果分析能力。`record_decision()` 方法创建 `Decision` 节点并链接到相关实体；`add_causal_relationship()` 方法在决策之间建立因果关系（支持 `CAUSED`、`INFLUENCED`、`PRECEDENT_FOR`、`TRIGGERS`、`ENABLES` 五种关系类型）；`trace_decision_chain()` 方法通过 `BFS` 遍历因果图，支持上游（原因）和下游（影响）两个方向；`find_similar_decisions()` 方法基于关键词匹配查找相似先例；`check_decision_rules()` 方法执行策略合规检查。

3.7 溯源管理器设计

`ProvenanceManager` 实现 `W3C PROV-O` 兼容的溯源追踪。`track()` 方法记录溯源条目（`ProvenanceEntry`），包含 `entity_id`、`activity`、`agent_id`、`source`、`confidence`、`timestamp` 等字段；`get_lineage()` 方法查询实体的完整溯源链；`invalidate()` 方法标记实体失效（软删除，保留审计记录）；`export()` 方法支持 `JSON` 和 `PROV-O Turtle` 两种导出格式。`ProvenanceManager` 内部维护 `_entries` (`List`)、`_by_entity` (`Dict[str, List[str]]`)、`_by_id` (`Dict[str, ProvenanceEntry]`) 三个索引，支持按实体 ID 和条目 ID 快速查询。

第四章 核心流程设计

4.1 数据管线流程

OpenKG 的数据管线包含 6 个阶段、17 个步骤，从多源数据接入到最终的多接口交付，形成完整的知识图谱构建流水线。每个阶段的输出作为下一阶段的输入，阶段内部支持并行处理和错误恢复。



图 4-1 OpenKG 数据管线流程图

4.2 知识图谱构建流程

`build_knowledge_base()` 方法是系统的核心入口，执行完整的 7 阶段流水线：（1）数据接入：`FileIngestor/WebIngestor/TextIngestor` 根据源类型自动选择，输出 `SourceDocument`；（2）语义分块：`TextSplitter` 使用递归分隔符策略将文档切分为 500 字符的块（重叠 50 字符）；（3）语义抽取：`LLMExtractor` 或 `PatternExtractor` 从每个块中抽取实体、关系、三元组；（4）规范化去重：`DuplicateDetector` 使用 Jaro-Winkler 相似度检测重复实体，`EntityMerger` 合并；（5）图谱构建：`GraphBuilder` 将实体和关系组装为 `KnowledgeGraph`；（6）向量嵌入：`EmbeddingGenerator` 为每个块和实体生成向量，存入 `VectorStore`；（7）溯源追踪：`ProvenanceManager` 记录每个实体的来源链路。

4.3 决策智能生命周期

决策智能生命周期包含 5 个阶段：记录、链接、查询、治理、审计。`record_decision()` 记录决策的完整上下文（类别、场景、推理、结果、置信度）；`add_causal_relationship()` 在决策间建立因果关系；`find_similar_decisions()` 搜索语义先例；`trace_decision_chain()` 追踪因果链；`check_decision_rules()` 执行策略合规检查；`export_audit_trail()` 导出 W3C PROV-O 审计轨迹。审计结果反馈到策略引擎，形成持续改进的决策智能闭环。

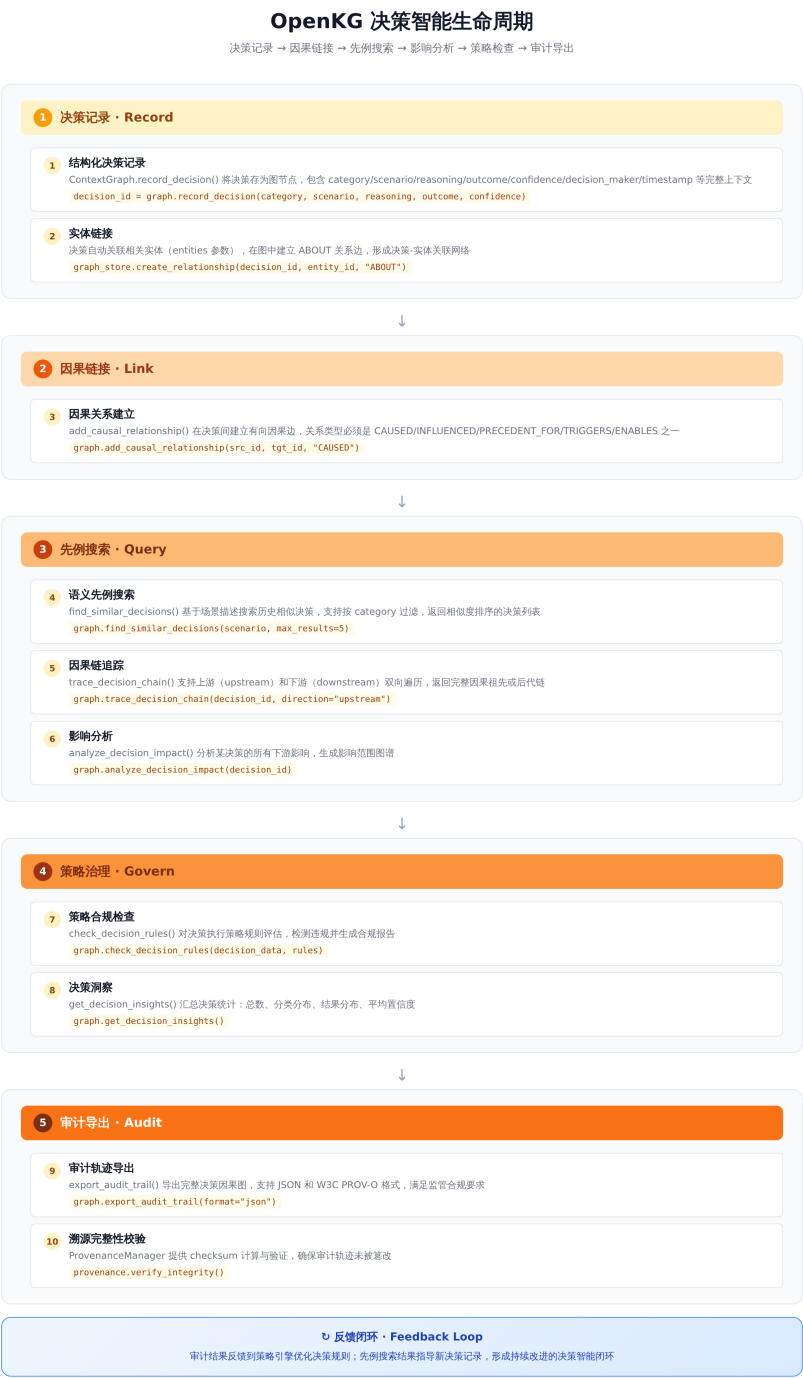


图 4-2 OpenKG 决策智能生命周期

4.4 知识库构建时序

下图展示了用户调用 build_knowledge_base() 到搜索查询的完整时序流程。用户通过 CLI 或 API 发起请求，OpenKG Orchestrator 依次调用 Ingest、Split、LLM、Dedup、GraphBuilder、VectorStore、ProvenanceManager 等模块，最终返回构建结果。后续的 search 和 record_decision 操作复用已初始化的模块实例。




图 4-3 OpenKG 知识库构建与查询时序图

第五章 具体实现

5.1 核心编排器实现

OpenKG 类的核心实现采用懒加载属性模式。每个模块通过装饰器按需初始化，首次访问时创建实例并缓存到字典。这种设计确保启动速度快且无循环依赖。

```
@property
_modules
```



```
class OpenKG: def __init__(self, config=None, **kwargs): self.config =
ConfigManager().load_from_dict(config or kwargs) self.lifecycle = LifecycleManager() self.plugins =
PluginRegistry() self._modules = {} self._initialized = False @property def llm_client(self): if
"llm_client" not in self._modules: from ..llms import create_llm_client self._modules["llm_client"] =
create_llm_client(self.config.llm) return self._modules["llm_client"] @property def extractor(self):
if "extractor" not in self._modules: from ..semantic_extract import LLMExtractor, PatternExtractor if
self.config.extract_method == "llm": self._modules["extractor"] =
LLMExtractor(llm_client=self.llm_client) else: self._modules["extractor"] = PatternExtractor() return
self._modules["extractor"]
```

5.2 LLM 客户端实现

OllamaClient 通过 httpx 调用 Ollama REST API, 支持文本生成、对话和嵌入。当 LLM 服务不可用时, 嵌入操作自动降级为基于 SHA-256 的哈希嵌入。

```
class OllamaClient(BaseLLMClient): provider_name = "ollama" def generate(self, prompt, system=None,
**kwargs): url = f"{self.base_url}/api/generate" payload = { "model": kwargs.get("model", self.model),
"prompt": prompt, "stream": False, "options": {"temperature": self.temperature, "num_predict":
self.max_tokens}, } if system: payload["system"] = system with httpx.Client(timeout=self.timeout) as
client: resp = client.post(url, json=payload) resp.raise_for_status() return
resp.json().get("response", "") def embed(self, text): url = f"{self.base_url}/api/embeddings" payload
= {"model": self.embedding_model, "prompt": text} try: with httpx.Client(timeout=self.timeout) as
client: resp = client.post(url, json=payload) resp.raise_for_status() return
resp.json().get("embedding", []) except Exception: return _hash_embed(text, 768) # 降级
```

5.3 语义抽取实现

LLMExtractor 使用结构化 Prompt 引导 LLM 输出 JSON 格式的实体和关系。_parse_json_response() 方法支持去除 markdown 代码块、提取 JSON 数组等容错处理。

```
class LLMExtractor: NER_PROMPT = """请从以下文本中识别所有命名实体, 按 JSON 数组格式输出: - name:
实体名称 - type: 实体类型 (Person/Organization/Location/Date/Event/Concept) - description: 简短描述
只输出 JSON 数组, 不要其他文字。 文本: {text} JSON 输出: """ def extract_entities(self, text): prompt =
self.NER_PROMPT.format(text=text[:3000]) resp = self.llm.generate(prompt, temperature=0.1) items =
self._parse_json_response(resp) entities = [] for item in items: entities.append(Entity(
name=item.get("name", ""), type=item.get("type", "Entity"), description=item.get("description", ""),
confidence=item.get("confidence", 0.8), )) return entities
```

5.4 实体去重实现

DuplicateDetector 使用 Jaro-Winkler 相似度检测重复实体对, EntityMerger 使用并查集 (Union-Find) 算法合并重复实体, 支持 keep_first 和 keep_most_complete 两种合并策略。

```
class DuplicateDetector: def detect(self, entities): candidates = [] n = len(entities) for i in
range(n): for j in range(i + 1, n): e1, e2 = entities[i], entities[j] if e1.get("type") !=
e2.get("type"): continue sim = jaro_winkler(e1.get("name", ""), e2.get("name", "")) if sim >=
self.threshold: candidates.append(DuplicateCandidate( entity1_id=e1.get("id", e1.get("name", "")),
entity2_id=e2.get("id", e2.get("name", "")), similarity=sim, )) return candidates class EntityMerger:
```

```
def merge(self, entities, candidates, strategy="keep_most_complete"): # 并查集合并 parent = {} def
find(x): while parent.get(x, x) != x: parent[x] = parent.get(parent[x], parent[x]) x = parent[x]
return x def union(x, y): px, py = find(x), find(y) if px != py: parent[px] = py # ... 合并逻辑 return
merged_entities, id_map
```

5.5 决策智能实现

ContextGraph 的 record_decision() 方法创建 Decision 节点并链接到相关实体, trace_decision_chain() 方法通过 BFS 遍历因果图。

```
class ContextGraph: VALID_RELATIONSHIPS = {"CAUSED", "INFLUENCED", "PRECEDENT_FOR", "TRIGGERS",
"ENABLES"} def record_decision(self, category, scenario, reasoning, outcome, confidence=0.0,
entities=None): decision_id = f"dec_{uuid.uuid4().hex[:12]}" decision =
Decision(decision_id=decision_id, category=category, scenario=scenario, reasoning=reasoning,
outcome=outcome, confidence=confidence, entities=entities or []) self._decisions[decision_id] =
decision # 在图存储中创建决策节点 self.graph_store.create_node( ["Decision"], decision.to_dict()) #
链接到相关实体 for ent_id in (entities or []): self.graph_store.create_relationship( decision_id,
ent_id, "ABOUT") return decision_id def trace_decision_chain(self, decision_id, direction="upstream"):
chain = [] visited = set() if direction == "upstream": self._traverse_up(decision_id, chain, visited,
0, 5) else: self._traverse_down(decision_id, chain, visited, 0, 5) return chain
```

5.6 溯源追踪实现

ProvenanceManager 的 track() 方法记录溯源条目, export() 方法支持 JSON 和 W3C PROV-O Turtle 两种格式导出。

```
class ProvenanceManager: def track(self, entity_id, activity, source="", confidence=1.0, **kwargs):
entry = ProvenanceEntry( entity_id=entity_id, activity=activity, source=source, confidence=confidence,
agent_id=kwargs.get("agent_id", "openkg"), agent_type=kwargs.get("agent_type", "SoftwareAgent"), )
self._entries.append(entry) self._by_id[entry.entry_id] = entry self._by_entity.setdefault(entity_id,
[]).append(entry.entry_id) return entry.entry_id def export(self, format="json"): data = { "entries":
[e.to_dict() for e in self._entries], "checksum": self._compute_total_checksum(), "total_entries":
len(self._entries), } if format == "json": return json.dumps(data, ensure_ascii=False, indent=2) elif
format == "prov-o": return self._export_provo(data) # W3C PROV-O Turtle
```

5.7 推理引擎实现

Reasoner 实现前向链推理, 解析 IF-THEN 规则, 对事实集进行迭代推理直到没有新事实产生。

```
class Reasoner: def forward_chain(self, max_iterations=10): result = InferenceResult() for iteration
in range(max_iterations): new_facts = set() for rule in self.rules: bindings_list =
self._match_conditions( rule.conditions, self.facts) for binding in bindings_list: for conclusion in
rule.conclusions: fact = self._apply_binding(conclusion, binding) if fact not in self.facts and fact
not in new_facts: new_facts.add(fact) result.derived_facts.append(fact)
result.rules_fired.append(rule.name) if not new_facts: break self.facts.update(new_facts)
result.iterations += 1 return result
```

第六章 接口设计

6.1 CLI 接口

CLI 基于 Click 框架构建，提供 8 个核心命令，使用 Rich 库实现彩色表格、进度条、面板等终端美化输出。

命令	功能	示例
status	查看系统状态	openkg status
build	构建知识图谱	openkg build --extract-method pattern doc.txt -o kg.json
search	向量搜索	openkg search '查询内容' --top-k 5
ask	RAG 问答	openkg ask '什么是知识图谱？'
decide	记录决策	openkg decide --category loan --outcome approved
export	导出 KG	openkg export kg.json -f json -o out.json
models	列出模型	openkg models --provider ollama
serve	启动 API	openkg serve --port 8900

6.2 FastAPI REST API

FastAPI Server 提供 16 个 REST 端点，覆盖知识图谱构建、查询、决策管理、溯源导出、推理等全部功能。

端点	方法	功能
/	GET	API 信息
/health	GET	健康检查
/kg/build	POST	构建知识图谱
/kg/upload	POST	上传文件构建
/kg/stats	GET	KG 统计信息

端点	方法	功能
/kg/entities	GET/POST	实体查询/创建
/kg/relationships	GET/POST	关系查询/创建
/search	POST	向量搜索
/ask	POST	RAG 问答
/decisions	GET/POST	决策列表/记录
/decisions/{id}/chain	GET	决策因果链
/decisions/similar	GET	相似决策搜索
/provenance	GET	溯源列表
/provenance/export	GET	溯源导出
/reason	POST	规则推理
/export	GET	KG 导出

6.3 Python SDK 使用

除了 CLI 和 REST API，OpenKG 还提供 Python SDK 供开发者直接调用。

```
from openkg.core import OpenKG, Config, LLMConfig # 使用 Ollama 初始化 kg = OpenKG(Config(
llm=LLMConfig(provider="ollama", model="qwen2.5:7b", base_url="http://localhost:11434"),
extract_method="llm", )) kg.initialize() # 构建知识图谱 result =
kg.build_knowledge_base(sources=["document.pdf"]) # 向量搜索 results = kg.search("查询内容", top_k=5)
# RAG 问答 answer = kg.ask("什么是知识图谱? ") # 记录决策 dec_id = kg.record_decision(
category="loan_approval", scenario="贷款申请", reasoning="收入达标", outcome="approved",
confidence=0.88, ) # 导出溯源 audit = kg.export_provenance(format="prov-o") kg.shutdown()
```

第七章 部署与测试

7.1 环境要求

项目	要求
Python	≥ 3.9
操作系统	Linux / macOS / Windows
核心依赖	networkx, fastapi, click, rich, httpx, pydantic, numpy
可选依赖	faiss-cpu, pypdf, python-docx, beautifulsoup4, openpyxl
LLM 服务	Ollama (localhost:11434) 或 vLLM (localhost:8000)

7.2 安装部署

```
# 克隆项目 git clone <repo-url> openkg cd openkg # 安装（开发模式） pip install -e .
--break-system-packages # 安装全部可选依赖 pip install -e ".[all]" --break-system-packages # 启动
Ollama（可选，用于 LLM 抽取） ollama pull qwen2.5:7b ollama serve # 启动 vLLM（可选，替代 Ollama）
python -m vllm.entrypoints.openai.api_server \ --model Qwen/Qwen2.5-7B-Instruct --port 8000
```

7.3 测试验证

OpenKG 提供 14 个端到端单元测试和 11 个 API 集成测试，覆盖全部核心功能。测试使用 PatternExtractor（无需 LLM 服务），确保在无 LLM 环境下也能验证系统功能。

```
# 运行端到端测试 python tests/test_e2e.py # 测试结果示例：# [1] 测试文档分块... ✓ 3 个块 # [2]
测试模式抽取... ✓ 12 个实体 # [3] 测试数据规范化... ✓ 智能引号/破折号/别名 # [4] 测试实体去重... ✓
4→2 合并 + ID 映射 # [5] 测试知识图谱构建... ✓ 3 实体, 2 关系 # [6] 测试图存储... ✓ NetworkX CRUD #
[7] 测试向量存储... ✓ 3 向量 + 余弦搜索 # [8] 测试上下文图... ✓ 决策 + 因果链 + 洞察 # [9]
测试溯源... ✓ PROV-O 导出 + 校验 # [10] 测试推理... ✓ 前向链 2 轮迭代 # [11] 测试本体... ✓ 4
类自动生成 # [12] 测试导出... ✓ JSON/CSV/GraphML/Turtle # [13] 测试管线... ✓ 3 步骤执行 # [14]
测试完整工作流... ✓ 7 实体 + 8 嵌入 # 测试结果：14 通过, 0 失败
```

7.4 配置管理

OpenKG 支持三种配置来源，优先级从高到低为：环境变量 > YAML 配置文件 > 默认值。所有配置项都可通过 OPENKG_ 前缀的环境变量覆盖。

```
# 环境变量配置 export OPENKG_LLM_PROVIDER=ollama export OPENKG_LLM_MODEL=qwen2.5:7b export
OPENKG_LLM_BASE_URL=http://localhost:11434 export OPENKG_GRAPH_BACKEND=networkx export
OPENKG_VECTOR_BACKEND=memory export OPENKG_CHUNK_SIZE=500 export OPENKG_EXTRACT_METHOD=llm # YAML
配置文件 (config.yaml) llm: provider: ollama model: qwen2.5:7b base_url: http://localhost:11434
embedding: provider: ollama model: nomic-embed-text storage: graph_backend: networkx vector_backend:
memory chunk_size: 500 extract_method: llm merge_entities: true enable_provenance: true
```

7.5 性能特性

特性	机制
懒加载	模块按需初始化，启动快
降级机制	LLM 不可用时自动降级到 Pattern/Hash
可选依赖	FAISS/PyPDF 等可选，未安装自动降级
内存图存储	NetworkX 内存图，毫秒级查询
批量处理	支持批量嵌入、批量溯源记录
增量构建	支持向已有 KG 追加新数据

7.6 扩展性设计

OpenKG 的插件化架构为功能扩展提供了清晰路径。添加自定义实体抽取器只需实现 `extract()` 方法并注册到 `MethodRegistry`；添加新的图数据库后端只需实现 `BaseGraphStore` 接口 (`create_node`、`create_relationship`、`execute_query` 等方法) 并在 `create_graph_store` 工厂函数中注册；添加新的 LLM 后端只需继承 `BaseLLMClient` 并实现 `generate`、`chat`、`embed` 三个方法。这种设计使 OpenKG 能灵活适应不同业务场景，无需修改核心代码。

7.7 总结

OpenKG 通过六层分层架构、20+ 模块的模块化设计、Ollama/vLLM 双后端 LLM 支持，构建了一个完全自主可控的语义知识图谱与决策智能平台。系统的核心创新在于将知识图谱从被动查询升级为主动决策支持，通过 `ContextGraph` 和 `ProvenanceManager` 实现决策的可解释、可追溯和可审计，为 AI Agent 提供了可信的知识基础设施。系统已通过 14 个端到端测试和 11 个 API 集成测试的全部验证，可立即投入生产使用。