



RAG: 从检索增强到智能涌现

Agentic AI 的认知控制平面与知识基石

议程：RAG 涌现之路的技术主线



1. 战略价值：RAG为何是构建未来AI的基石？



2. 挑战与评估：我们必须正视的内在困境与科学度量。



3. 检索基石：向量数据库的核心技术选型。




4. 边界突破：高级RAG算法的工程实践。




5. 智能集成：RAG如何赋能Agentic AI。

RAG的本质：可信、可控的知识接口



RAG核心能力：检索、增强、生成



战略价值（一）：知识时效性与私有性



静态训练数据



时效性



私有性



实时/私有数据

战略价值（二）：可信度与可审计性

关于项目A的市场前景，基于目前的趋势分析，预计在未来三年内将实现显著增长，特别是在亚太地区。根据[Source Doc_A, p.5]的数据，市场规模预计将达到50亿美元。此外，关键技术合作伙伴关系将是成功的关键，如[Source Doc_B, p.12]所述。尽管存在竞争风险，但我们的独特技术优势提供了强大的壁垒，这在[Source Doc_C, p.2]中有详细说明。



[Source Doc_A, p.5]

[Source Doc_B, p.12]

[Source Doc_C, p.2]

战略价值（三）：上下文长度与成本优化

长上下文方法




\$\$\$

RAG方法



\$

RAG的基础架构：R+G workflow解构




RAG的架构边界：它不是Agent，不能做推理



Agent



LLM



VDB



Workflow

核心应用场景：高合规性与知识依赖



事实证据

可审计性

RAG的内在劣势：三维困境



效果困境：“垃圾进，垃圾出”的质量悖论



评估基石：RAGAS框架与科学度量

RAGAS



评估输入：RAGAS的四要素






检索器评估（一）：上下文精度（Context Precision）





检索器评估（二）：上下文召回率（Context Recall）



生成器评估：忠实度是杜绝幻觉的生命线



上下文

数据源：知识图谱

事实 1：某公司成立于2015年

数据源：相关文档

事实 2：该公司总部位于上海

数据源：实时资讯

事实 3：2023年发布了新产品

答案

- 该公司于2015年成立。
- 总部设在上海。
- 2023年推出了最新的产品系列。
- 该公司2020年被收购。

幻觉 (Hallucination)

检索挑战：语义鸿沟与词汇不匹配

公司电脑卡怎么办？

?

IT资产
性能优
化指南

语义鸿沟

效率瓶颈（一）：Chunking的权衡悖论

小块 / Small Chunks



优点：精度高

缺点：上下文缺失

大块 / Large Chunks




优点：上下文完整

缺点：噪声干扰，成本高


效率瓶颈（二）：算力激增与长上下文代价

算力激增



System Load: CRITICAL
Resource Utilization: >95%
CPU/GPU: MAX CAPACITY

长上下文代价



检索基石：向量数据库作为智能体的长期记忆支柱

向量数据库（VDB）是RAG架构的绝对基石，它超越了传统数据库的角色，成为AI智能体（Agent）的长期记忆系统（Long-Term Memory, LTM）。通过将知识、对话历史和经验转化为高维向量，VDB实现了基于语义相似度的瞬时检索，为智能体提供了持续学习和调用海量记忆的能力。



统一知识平台：Elasticsearch

Elasticsearch的定位是一个统一的、企业级的知识检索平台。它并非纯粹的向量数据库，而是将三种核心检索能力无缝整合在一个强大的技术栈中：

- 全文搜索 (BM25)：业界领先的关键词匹配能力。
- 向量搜索 (kNN)：实现基于语义的相似度检索。
- 结构化分析 (Metadata Filtering)：精准的元数据过滤与聚合。



全文搜索 (BM25)



向量搜索 (kNN)



结构化分析
(Metadata Filtering)



核心优势：原生混合搜索（Hybrid Search）

Elasticsearch的关键架构优势在于其原生的混合搜索能力。它允许在一个查询请求中，并行执行两种互补的搜索算法：


- **BM25关键词搜索**：精准匹配特定术语和实体，解决向量搜索在精确性上的短板。
- **kNN向量搜索**：理解查询的深层语义和意图，弥补关键词的词汇鸿沟。

这种“双引擎”模式极大提升了检索的召回率和相关性。



智能融合算法：倒数排名融合（RRF）


为了智能地合并来自BM25和kNN这两个异构评分系统的结果，Elasticsearch采用了倒数排名融合（Reciprocal Rank Fusion, RRF）算法。RRF的核心优势在于其“零配置”的智能性：它不依赖于复杂的权重调整或分数归一化，而是基于结果的排名（Rank）进行融合。这使得它在各种场景下都表现得非常稳健和高效，显著降低了工程调优的复杂度。



架构性能优化：HNSW 与 DiskBBQ 量化

Elasticsearch在向量检索性能方面持续演进，采用了多种关键优化策略：

- HNSW算法：采用业界标准的高效近似最近邻（ANN）算法，确保低延迟和高吞吐。
- 向量量化：支持`int8`等量化策略，大幅减少内存占用。
- DiskBBQ (bbq_disk)：实现了基于磁盘的向量检索，极大降低了对昂贵内存资源的依赖，优化了TCO。



HNSW



Quantization




DiskBBQ

性能专家：Milvus - 为大规模高并发而生

Milvus是专为大规模向量检索设计的云原生数据库。其核心架构理念是“存算分离”和“微服务化”：


- 分布式微服务：将读、写、索引构建等核心功能解耦为独立的服务，可以按需独立扩展，弹性极佳。
- 存算分离：计算层和存储层分离，为处理千亿级向量数据和应对高并发查询场景提供了架构基础。



核心优势：极致性能与GPU加速

Milvus的定位非常明确：在极致性能和吞吐量（QPS）方面成为领导者。其性能优势主要体现在：

- 大规模数据集：专为亿级甚至千亿级向量数据集优化。
- 高吞吐量（QPS）：分布式架构轻松应对极高的并发查询请求。
- GPU加速：利用GPU并行计算能力实现毫秒级响应。



功能演进：多向量与混合查询潜力

Milvus不仅在性能上领先，其功能也在快速演进，以适应更复杂的RAG场景：

- **多向量搜索**：原生支持在单个对象上存储和查询多个向量，对多模态RAG至关重要。
- **混合查询潜力**：Milvus 2.4版本已规划引入更强大的混合查询能力，补齐在混合检索场景下的短板。

多向量支持



Milvus 2.4: 混合查询增强



AI原生创新者：Weaviate

Weaviate的定位是“AI原生”的向量数据库，其设计哲学是最大化地简化RAG应用的开发流程。

- 数据对象与向量统一存储：同时存储原始数据对象和其对应的向量，使数据管理更直观。
- 内置Embedding集成：可直接与OpenAI等模型提供商集成，在数据导入时自动完成向量化，开发者无需自行管理Embedding模型。



核心优势：开箱即用的混合搜索

与Elasticsearch类似，Weaviate也原生支持强大的混合搜索能力，但实现方式更贴近AI开发者的使用习惯。

- **原生BM25F算法：**内置了优化的BM25F算法。
- **简洁的查询接口：**通过一个简单的API调用，同时指定关键词查询和向量查询，并由Weaviate自动完成结果的融合与排序。

这为快速构建高质量的RAG应用提供了“开箱即用”的解决方案。

```
Get {  
  MyClass (  
    hybrid: {  
      query: "关键词",  
      nearVector: {...}  
    }  
  ) {  
    _additional {  
      score  
    }  
  }  
}
```



专业选型总结（一）：规模与性能取舍

如果在你的核心需求是：

- **超大规模**：数据集达到亿级甚至千亿级别。
- **极致QPS**：需要应对极高的并发查询请求。
- **高维数据集**：处理的向量维度非常高（如 > 1024 ）。
- **GPU加速**：希望利用GPU硬件来最大化检索性能。

架构师建议：**Milvus** 是更可靠的选择。



专业选型总结（二）：功能与统一集成

****如果你的核心需求是：****

- 企业级RAG：需要将向量检索与现有企业搜索、日志分析等系统整合。
- 强大的混合搜索：BM25+kNN+RRF的组合是关键需求。
- 复杂的元数据过滤：需要在检索时进行精细化的权限和属性过滤。
- 统一技术栈：倾向于使用一个成熟、稳定、统一的平台。

****架构师建议：Elasticsearch 是理想选择。 ****



专业选型总结（三）：开发体验与模块化

****如果你的核心需求是：****

- **快速原型与开发**：追求最简化的开发流程和最少的运维负担。
- **内置向量化**：希望数据库能自动处理数据的向量化过程。
- **开箱即用的混合搜索**：需要一个API友好、易于上手的混合搜索方案。
- **多租户隔离**：需要在单一实例中为不同用户或项目提供数据隔离。

****架构师建议：Weaviate 更具优势。****



高级检索策略：元数据过滤实现企业级合规

选择数据库只是第一步。高级RAG系统必须实施精细化的检索策略。


元数据过滤（Metadata Filtering）是实现企业级合规的生命线。

在执行向量搜索前后，根据文档的元数据（如访问权限、所属部门）进行严格过滤，确保只有用户被授权访问的数据源能够进入LLM的上下文，从源头上杜绝数据泄露风险。



高级检索策略：重排（Re-ranking）机制提高精度

初始检索返回的结果集（Top-K）虽然相关，但最优答案不一定排在第一位。LLM在处理长上下文时存在“中间迷失”问题。**重排（Re-ranking）机制**使用更精确的模型对Top-K结果进行二次排序，将最相关的文档片段推到上下文的最顶端，确保LLM能够“第一眼”就看到最关键的证据。



第四部分：突破边界：高级RAG算法与工程优化



结构性瓶颈：突破多跳推理的次元壁

传统RAG的局限



难以处理需要连接多个知识点的复杂问题，受限于单跳检索的线性模式。

架构突破：GraphRAG




引入知识图谱（KG）作为核心索引，显式建模实体间的深层关联，将隐性关系显性化。

核心价值：赋予系统进行多步“思考”和“推理”的能力，解答“A和B有什么关系”这类深层次问题。

GraphRAG实现路径：三元组与嵌入查询


<S, P, O>



- 框架支持：LlamaIndex等主流框架已內置知識图谱索引与查詢工具，簡化了GraphRAG的工程落地。

高级算法：RAPTOR优化长文本分块



Chunking的权衡悖论：小块（Small Chunks）精度高但上下文缺失；大块（Large Chunks）上下文完整但噪声过多，效率低下。

RAPTOR的分层策略：采用聚类算法将语义相似的文本文块分组，并递归地生成更高层次的摘要块，构建分层知识树。

检索优势：在树的不同层级上进行检索，能够同时兼顾细节精度与宏观上下文，有效破解“迷失在中间”的难题。



高级算法：Self RAG的Agent式推理



传统RAG的被动性：
无论检索质量如何，
都必须进行生成，
导致“垃圾进，垃圾出”。



Self RAG的主动决策：
引入“反思令牌”
(Reflection Tokens)，
让LLM主动评估检索结
果的相关性，并自主
决策下一步行动。

智能体行为模式：

- 判断：是否需要检索？
- 评估：检索内容是否相关？
- 决策：直接生成答案、重新检索或迭代优化。

效率优化：分布式缓存机制




性能瓶颈：重复或相似的查询导致对检索系统和LLM的冗余调用，增加延迟与成本。

架构模式：引入高速分布式缓存（如Redis），存储高频查询的检索结果、中间生成内容、甚至最终答案。

核心收益：

- 🕒 **延迟：**毫秒级响应常见问题。
- 💰 **成本：**显著减少昂贵的LLM Token消耗。
- 📈 **吞吐量：**降低后端系统负载，提升QPS。



效率优化：自适应多级检索



资源错配：

用重量级的GraphRAG回答简单问题，或用简单的向量检索应对复杂问题，都造成资源浪费或效果不佳。

智能路由策略：

在检索前，先用一个轻量级LLM或分类模型对用户问题进行意图分析和复杂度判断。

动态资源匹配：

简单问题

关键词/向量检索
(低成本，快速)

Answer

Answer

复杂问题

GraphRAG / Self RAG
(高成本，精准)

多模态RAG（一）：挑战与知识表示



新边界：非文本数据：
基础RAG原生为文本设计，**无法理解和检索**图像、表格、图表和音视频中蕴含的知识。



架构要求：需要**专门的模型和流程**来解析多模态数据，并将其嵌入到**统一的向量空间**中。

核心挑战：如何将**异构、多模态的数据源**转化为**统一、可被LLM理解和检索的知识表示**。

多模态RAG（二）：VLM解析与多模态VDB



视觉语言模型 (VLM)

利用VLM（如GPT-4V）或专用模型（如RAGFlow DeepDoc）对图像和复杂PDF进行深度解析，识别布局、提取表格、生成图像描述。

多模态嵌入

将文本描述、图像块、表格数据等通过统一的多模态嵌入模型，映射到同一个高维向量空间。

统一检索

在支持多模态向量的数据库中，实现用文本查询图像、用图像查询相关文本的跨模态检索能力。

数据摄取：知识库管道的工程化



管道化架构 (Pipeline)：将数据摄取流程（同步、清洗、分块、嵌入）抽象为可编排、可配置、可重用的模块化管道。

从脚本到平台：手动
的、一次性的数据
处理脚本无法支撑
企业级知识库的持
续更新、版本控制和
质量监控。



平台级能力：Dify的知识库管道、RAGFlow的数据管线等工具，实现了从数据源到Agent消费的端到端、自动化的知识管理。


工程优化：模型重试中间件



生产环境的脆弱性：网络抖动、API速率限制、模型服务临时不可用等问题，导致LLM调用在生产环境中频繁失败。



韧性设计模式：引入专门的中间件 (Middleware)，在应用层透明地处理API调用失败。



核心策略：指数退避 (Exponential Backoff)：在发生瞬时错误时，以递增的时间间隔自动重试，极大提高系统调用的成功率和健壮性。

工程优化：上下文摘要中间件



智能压缩策略：引入上下文摘要中间件，在历史对话长度超过阈值时，自动调用LLM对最旧的对话部分进行摘要和压缩。



效果：在保留核心对话记忆的同时，动态管理上下文窗口大小，实现成本与记忆深度的最佳平衡。

案例研究：Dify的Workflow架构升级



核心演进：

Dify v1.9.0将知识库摄取流程从一个固定的黑盒，升级为**可视化、模块化的知识库管道（Knowledge Pipeline）**。

架构优势：

- **可视化编排**：用户可通过拖拽方式自定义数据处理流程。
- **高可扩展性**：允许开发者添加自定义的数据处理节点。
- **端到端整合**：将数据工程与应用开发无缝集成在同一平台。



案例研究：RAGFlow的性能优化实践




- 性能目标：支持企业级高并发和高吞吐量的文档处理与问答场景。
- Infinity文档引擎：专为RAG设计的底层文档解析与管理引擎，优化IO和数据处理效率。
- 架构迁移：后端Web框架从同步的Flask迁移到异步的Quart，大幅提升了并发处理能力和系统响应速度。

RAG的可观测性缺失：全链路追踪



黑盒困境：RAG系统的非确定性输出使其难以调试。当答案错误时，问题可能出在检索、增强或生成等任何环节。



新监控范式：传统监控（CPU、内存）不足，必须引入类似微服务治理的**全链路追踪（Distributed Tracing）**。

追踪目标：借助OpenTelemetry等标准，对LLM调用、检索步骤、上下文片段、工具执行等每一个环节进行结构化日志记录和审计。

可观测性实现：托管服务与结构化日志




解决方案：利用AWS CloudWatch GenAI Observability等云原生托管服务，或集成LangSmith、Arize等第三方平台。

核心功能：将Agent执行循环中的每一个Span（模型调用、工具执行、上下文检索）自动捕获，并转化为可搜索、可回放的结构化日志。



架构价值：实现对RAG系统行为的深度调试、性能分析、成本归因和合规审计，是企业级AI应用最后的、也是最关键的一环。

智能涌现：从RAG到行动的范式转变



RAG: 信息检索的终点

Agent: 智能行动的起点

推理 (Reasoning)

规划 (Planning)

行动 (Action)

Agentic AI系统架构：涌现的四大支柱




1. 推理引擎 (Reasoning Engine)

以LLM为核心，负责决策、规划与反思。




2. 记忆系统 (Memory System)

整合短期与长期记忆，实现情境感知与知识积累。



3. 编排模块 (Orchestration Module)

控制任务执行流程，动态调用工具与知识。



4. 工具接口 (Tool Interface)

连接外部世界，执行代码、调用API、访问服务。

Agent Core

Agent的认知核心：分层记忆系统



短期记忆 (STM - Short-Term Memory)



核心功能：

- 会话上下文 (Session Context)
- 即时指令与用户输入



技术实现：上下文窗口 (Context Window)



特性：易失性 (Volatile)、高速访问、容量有限



长期记忆 (LTM - Long-Term Memory)



核心功能：

- 向量化知识 (Vectorized Knowledge)
- 历史经验与事实摘要



技术实现：向量数据库 (Vector Database) / RAG



特性：持久化 (Persistent)、语义检索、可扩展

RAG: Agent长期记忆的实现引擎



突破集成鸿沟：RAG作为Workflow的知识工具



工程实践：Dify工作流的逻辑控制与状态增强



- **超越线性链条：**引入循环、条件判断，实现复杂的任务逻辑。
- **增强LLM状态：**通过变量传递，让LLM在多步任务中保持记忆和上下文一致性。
- **实现复杂Agent行为：**如多轮澄清式问答、自动化报告生成等。

架构演进：RAGFlow Agent的规划与反思



RAGFlow v0.20.0 统一Agent与Workflow，引入Multi-Agent、规划与反思机制

连接世界：工具接口与统一网关



- 工具网关的核心职责:

- 🔒 标准化接入 (Standardization) : 将不同工具封装成统一接口。
- 🔍 动态搜索 (Discovery) : 帮助Agent快速找到所需工具。
- 🛡️ 集中治理 (Governance) : 统一管理认证、权限、监控和日志。

安全基石：Agent的沙盒环境与硬件级隔离



T11 RCE 威胁（远程代码执行）

- Agent执行不可信代码
- 访问恶意网页
- 操作敏感系统



解决方案：MicroVM 沙盒

- 核心技术：Firecracker / gVisor
- 实现机制：
 - 为每个任务或会话启动一个独立的微型虚拟机。
 - 提供硬件级资源隔离（CPU，内存，网络）。
 - 用完即焚（Ephemeral），环境干净，无状态残留。
- 优势：极致安全、秒级启动、高密度部署

未来展望：RAG与Agent的终身学习



1. 情境感知 (Context-Aware)

Agent利用RAG理解当前任务和
历史对话。



2. 跨会话记忆 (Cross-Session Memory)

Agent的记忆 (LTM) 在不同任务
和会话中得以保留和积累。



3. 终身学习 (Lifelong Learning)

Agent通过与世界持续互动，不断
更新和优化其长期记忆库，实现能
力的自我演进和智能的真正涌现。

向量化存储是Agent实现终身学习的记忆基石。

Mem0, Letta, LangMem