????LLM???

??????????????

???????

□□□□□□□□□□□□□□□□□□□□□□□□□□□□□□□□

□□□□□□□□□□□□□□□□□□□□□□□□□□□□□□□□□□

????

- AI □□□□□□□□□□□□□□□□□□□□□□□□□□□□□□□□
- top-K chunks □□□□□□□□□□□□□□□□□□□□□□□□□□□□□□□□□□□□
- □□□□□□□□□ “□□□ ”□□□□□□□□ “□□□□□ ”□
- GraphRAG □□□□□□□□□□□□□□□□□□□□□□□□□□□□□□□□□□□□
- □ AI □□□
- □□□□□□□□□□□□□□□□□□□□□□□□□ AI □□□□□□□□□□□□□□□□□□□□□□□□

LLM????????

1. LLM□□□□□□□
    1. □□□□□□□□□□□□□□□□□ □□□□□□□□□□□□□□□□
    2. □□
    3. □□□□□□□□□□ “□□□ ”□□□
    4. □□□□□□□□□□□□ MoE
2. KVCache □□□□□□□□
    1. □□□□□□□□□□□□□□□□□
        1. □□□□□□□□ KVCache□□□□□□□ token □□□□□□□□□□□□□□□□□□□□□□□□□□□□□□□□
    2. □□□□□□□□□□□□□□□□□

1. CoT可能出现前后矛盾的表达，长上下文之后，模型的准确性下降
3. 计算资源消耗稍大
1. 潜式思维链（ Latent Chain-of-Thought）是一个改进方向
3. 外部专用数据存储系统
1. 容量大
2. 抽象层级最低 ，存储密度最低，能力差
3. 资源消耗小
4. 支持动态 “增删改 ”

Revision #2
Created 2026-05-05 14:38:32 UTC by Colin Updated 2026-05-16 04:11:08 UTC by Colin