



为 Coding Agent 构建智能上下文： Qoder 的 Context Engineering 实践

夏振华

Qoder 工程师



📍 北京

QCon

全球软件开发大会

会议时间：4月10-12日

- 大模型赋能 AI Ops
- 越挫越勇的大前端
- 云上业务架构演进
- 多模态大模型及应用
- 海外 AI 应用创新实践

📍 北京

AICon

全球人工智能开发与应用大会

会议时间：6月27-28日

- 端侧智能
- AI Agent
- 多模态大模型
- 金融+大模型

📍 上海

QCon

全球软件开发大会

会议时间：10月23-25日

- AI Agent
- 大模型训练推理
- 端侧 AI
- 搜推深度融合
- 数智金融

4月

5月

6月

8月

10月

12月

📍 上海

AICon

全球人工智能开发与应用大会

会议时间：5月23-24日

- 通用大模型
- AI Agent
- 垂直领域应用
- 模型可解释性

📍 深圳

AICon

全球人工智能开发与应用大会

会议时间：8月22-23日

- 模型效率与部署
- 多模态大模型
- 大模型安全
- 智能硬件

📍 北京

AICon

全球人工智能开发与应用大会

会议时间：12月19-20日

- 通用大模型
- 智能硬件
- LM Ops
- 具身智能

极客邦科技 2025 年会议规划

促进软件开发及相关领域知识与创新的传播



参会咨询



查看会议

目录

01 AI Coding 技术发展趋势

02 Qoder Agent 的技术架构

03 Qoder 的上下文工程实践

04 Qoder 功能和案例分享


05 Qoder 未来演讲方向

01


AI Coding 技术发展趋势

从提示词工程到上下文工程

提示词工程




上下文工程




从短任务对话协同到长任务异步委派

对话式人机协同模式




异步委派人机协同模式




从智能代码生成到全链路软件研发

应用场景在扩大，产品边界在延伸



编程智能体正在全面集成传统研发工具

在IDE环境中的编程智能体可以使用MCP协议集成大量传统研发工具。同时异步委派智能体可以与DevOps工具深度集成，增强代码评审、质量检测、部署验证等环节。



沉淀企业研发经验和优质代码改进模型尤为重要

以数智大脑为核心，提供企业核心代码资产和研发组织资产，落地企业数字资产管理及治理能力，构建企业个性化私域知识库和研发过程经验，持续为数智大脑提供养分，提升大模型生成效果。



02


Qoder Agent 的技术架构



Qoder Agent 技术大图



新一代智能工程知识、代码检索技术



具备自优化能力的记忆感知技术



03


Qoder 上下文工程实践

上下文相关的核心问题

模型可以完成的软件工程任务的时长 &
各模型厂商支持的上下文长度都在快速扩大



模型性能随着上下文长度增长却呈现快速下降趋势



参考:

<https://research.trychroma.com/context-rot>

<https://www.oneusefulting.org/p/the-bitter-lesson-versus-the-garbage>

<https://www.meibel.ai/post/understanding-the-impact-of-increasing-llm-context-window>

上下文相关的核心问题

Context Conflict (上下文冲突)

指上下文中包含了相互矛盾或不一致的信息，这会破坏模型的逻辑推理链，导致其无法得出正确的结论或执行正确的操作。

Context Distraction (上下文干扰)


指当上下文窗口过长时，模型会过度关注历史对话信息，倾向于重复历史行为模式，而忽略了当前的用户核心指令。

Context Poisoning (上下文中毒)

指一个初始的错误或幻觉信息污染了上下文，并在后续交互中被反复引用，如同“毒素”一样不断累积和放大，最终导致整个任务失败。


Context Overload (上下文过载)

指上下文中存在过多无关或冗余的信息（例如提供了过多的工具），这会干扰模型的判断，使其难以识别和调用最关键的信息或工具，从而生成低质量的响应。



Context Failures

上下文优化的核心手段



Context Reduction (上下文精简)



Context Compression (压缩)

对历史上下文里的工具执行结果进行压缩，保留关键工具的调用，裁剪工具输出结果



Context Summarization (摘要)

对历史上下文的完整交互历史，结合模型进行压缩，要求保留会话过程核心信息



Context Consolidation (合并)

将多个相关的上下文片段进行智能合并去重，消除冗余信息，保持语义完整性




Context Filtration (过滤)

基于相关性评分过滤低价值上下文，保留与当前任务强相关的历史信息

Context Isolation (上下文隔离)

多 Agent 隔离上下文




The Bitter Lesson Warning:

多数 Multi Agent 系统是在为当前模型局限打补丁。
当限制消失时，架构复杂度本身将成为限制。

我们认为：

Multi Agent 的价值不是分解智能，而是隔离污染。

Context Isolation (上下文隔离)



按角色拆分上下文



✅ 拆分子能力到独立上下文

Context Offload (上下文卸载)

外部存储压缩

External Storage

将大量原始数据保存到文件系统或外部存储中，仅向LLM传递摘要或元数据，可实现较高压缩比同时保持信息可恢复性。

分层记忆模式

Layered Storage Pattern

实现临时 TODO 记录和持久化长期记忆两种模式，使 Agent 能够在单次会话中做笔记，并跨会话访问历史沉淀内容。



可逆性原则

Reversibility Principle

压缩信息时保留完整数据的访问路径(如URL、文件路径)，确保需要时可以随时检索完整内容，并精心设计摘要以保持信息召回能力。

易恢复性原则

Easy Restoration Principle

卸载内容应采用模型友好的格式和结构，便于通过原生工具快速加载并恢复上下文理解。

准确率、成本和性能的平衡

准确度 (Accuracy)

通过完善的检索机制和记忆系统，

确保上下文信息的完整性和相关性。采用语义搜索、向量数据库索引和多层级信息过滤策略，提升模型对关键信息的召回率。在长上下文场景中，结合分块存储和智能摘要技术，保证信息传递的精确度，减少幻觉和错误推理。

成本 (Cost)

优先采用缓存机制和压缩策略降低token消耗。

通过KV-cache复用减少重复计算开销，在窗口边界实施智能压缩算法（如滑动窗口、注意力蒸馏）。对于超大规模上下文，利用外部存储卸载非热点数据，按需加载。

结合多模型调度，根据任务、代码仓库的复杂度等多维度信息智能路由，进一步优化成本。



性能 (Performance)

通过缓存优化和最大化并行处理能力提升响应速度。

优化prompt结构保证前缀稳定性，提升KV-cache命中率，减少重复计算开销。采用多Agent并行执行和单Agent内工具并行调用相结合的方式，最大化任务并发度。针对特定工具和场景，使用轻量级小模型加速生成过程

上下文实践的经验总结

追加式设计，避免修改历史

任何对历史上下文的修改都会使缓存失效并成倍增加成本，始终采用只追加（append-only）的设计模式。

保留错误信息，避免重复失败

将错误消息保留在上下文中可以防止 agent 反复犯同样的错误，错误是宝贵的学习机会。

可逆压缩，避免激进裁剪

压缩上下文时必须保留原始数据的恢复能力（如保存文件路径、URL），避免永久丢失关键信息。

先简后繁，避免过早优化

遵循"Bitter Lesson"，随着模型能力提升，简单通用的解决方案往往胜过复杂设计，只在验证必要时才增加复杂度

04

Qoder 功能和案例分享




关键挑战：如何实现复杂真实代码库上的工程理解能力，以及善用工具快速、准确完成任务的能力。

技术能力：代码语义+图谱+wiki+记忆的混合检索能力构建最强上下文工程，确保复杂工程编程效果。



工程知识可视 Repo Wiki



Repo Wiki

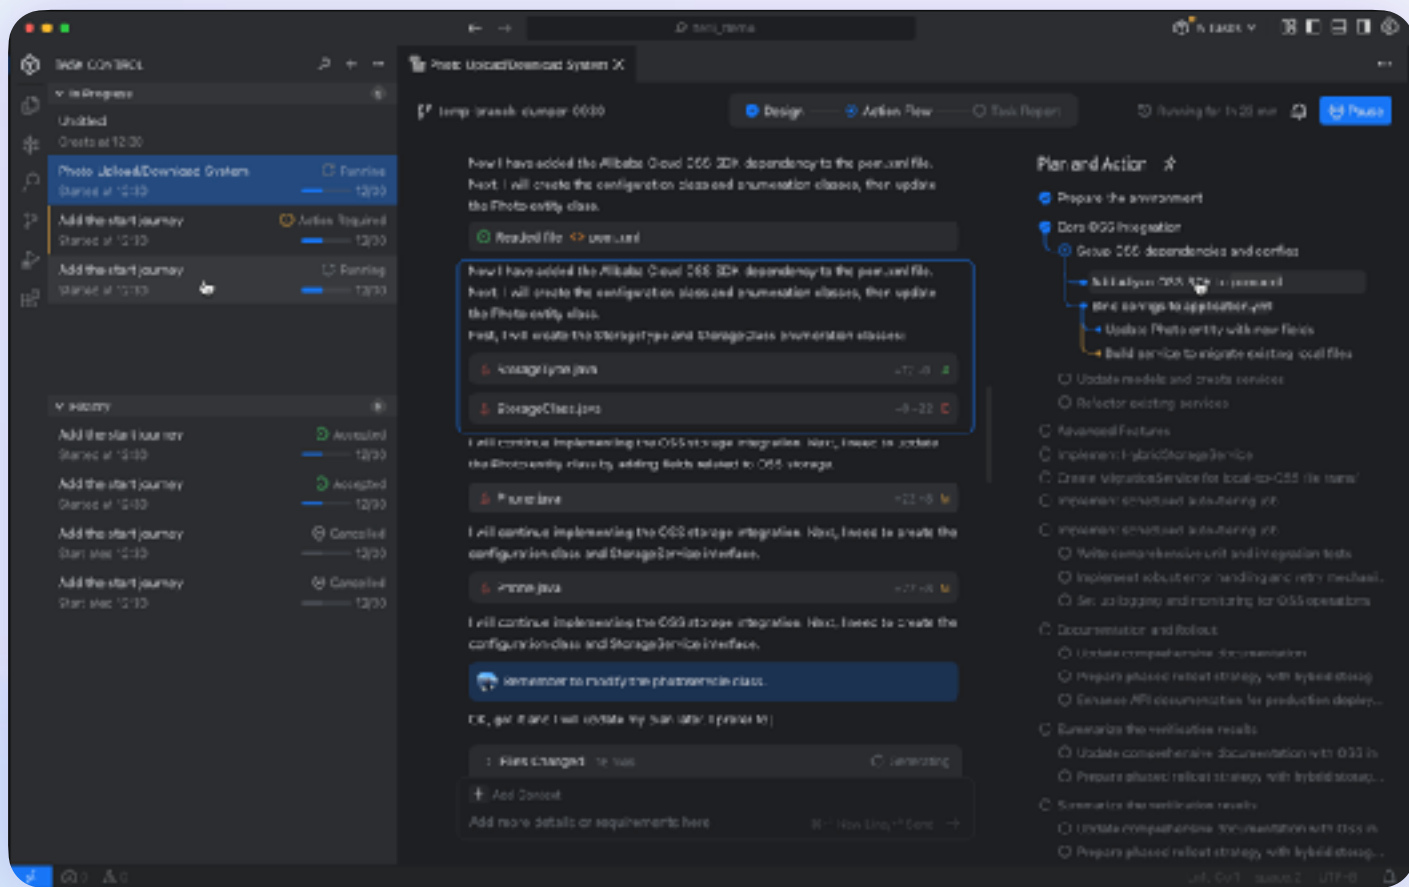
用户价值：在为开发者提供高效的工程知识学习的同时，让编程智能体具备了架构知识理解能力。

关键挑战：如何更快、更低成本、更准确的生成复杂真实工程的架构知识，同时让智能体完成更复杂任务。

技术能力：精调WIKI专用多智能体，专用WIKI模型，以及智能体代码混合检索技术。



异步委派任务 Quest Mode



Quest Mode

用户价值：通过Spec-Driven Development模式，实现智能体端到端交付各种编程任务。

关键挑战：如何实现Spec生成准确性，以及长程任务的完成准确、成本、安全问题。

技术能力：顶级代码大模型，多智能体架构，远程执行容器，以及云端代码检索技术，让异步委派编程模式得以落地。



命令行工具 Qoder CLI

```
+ Welcome to Qoder CLI
cwd: /Users/leon/qoder

Tips for getting started:
1. Ask questions, edit files, or run commands.
2. Be specific for the best results.
3. Type /help for more information.

> Build a cryptocurrency price tracking H5 app with Go that displays the real-time price of Bitcoin.

• task-executor (Create crypto tracker H5 app)
  ... +3 messages (ctrl+r to expand)
  • let me check the current directory to understand the project structure better.
  • Bash (command: pwd && ls -la, background: false)
    /Users/leon/qoder
    total 0
    drwxr-xr-x@ 3 leon staff  96 10 13 20:48 .
    drwxr-xr-x@ 99 leon staff 3168 10 13 19:14 ..
    drwxr-xr-x@ 3 leon staff  96 10 13 20:48 .qoder
    ... +2 lines (ctrl+r to expand)
  • I see we're in an empty directory. Let me create the necessary files for our Go-based H5 application that
    tracks Bitcoin prices. First, I'll initialize a Go module.
  • Bash (command: go mod init crypto-tracker, background: false)
    go: creating new go.mod: module crypto-tracker
```

Qoder CLI

用户价值：让开发者在终端内完成从构思到实现的完整开发流程，无需切换工具，保持专注和高效的开发状态。

关键挑战：如何在纯命令行环境中实现代码库深度理解、自然语言交互、多工具集成，以及复杂开发任务的自动化编排。

技术能力：顶级大模型驱动的代码理解和生成能力，MCP 协议实现的工具生态集成，智能代理（Agents）系统支持任务分解与自动执行。


05

Qoder 未来演讲方向

从设计、执行到验证全链路软件研发实现更高准确率



多智能体架构应对更长更复杂任务



图表引用: <https://cognition.ai/blog/dont-build-multi-agents#a-theory-of-building-long-running-agents>

问题、挑战、应对

关键问题：在 Coding 任务中是否需要引入多智能体架构，其收益和问题有哪些，适用于什么场景？

关键挑战：多智能体架构可以有效解决单智能体上下文窗口受限问题，但引入了多智能体之间信息共享、同步问题，反而让多智能体架构更易失败，消耗更多 token。

应对思路：独立边界任务，完整的信息传递，谨慎采用并行化。



更多专用领域模型突破复杂任务成本和性能瓶颈

专用模型的必要性

性能：在基础模型之上通过合成专项数据进行后训练，可以让模型在特定提示词下表现更加稳定，并提升基础模型专项性能。

成本：更小参数模型更强性能的专用模型必然带来成本和速度优势。

智能体大模型

支持长上下文下复杂长程任务的运行

记忆类模型

在记忆提取、记忆融合、记忆评估等方面更优

检索类模型

针对复杂代码场景具备更高的召回率，成本更低

Wiki生成模型

具备复杂代码理解和wiki生成能力，速度更快

工具专用模型

代码应用、会话总结等专用模型，带来更优上下文能力

补全 / NES 模型

模拟用户代码编辑轨迹专项训练，兼顾准确率与速度



Qoder

Think Deeper. Build Better.

官网: <https://qoder.com/>

Twitter: https://x.com/qoder_ai_ide

📍 北京

QCon

全球软件开发大会

会议时间：4月10-12日

- 大模型赋能 AI Ops
- 越挫越勇的大前端
- 云上业务架构演进
- 多模态大模型及应用
- 海外 AI 应用创新实践

📍 北京

AiCon

全球人工智能开发与应用大会

会议时间：6月27-28日

- 端侧智能
- AI Agent
- 多模态大模型
- 金融+大模型

📍 上海

QCon

全球软件开发大会

会议时间：10月23-25日

- AI Agent
- 大模型训练推理
- 端侧 AI
- 搜推深度融合
- 数智金融

4月

5月

6月

8月

10月

12月

📍 上海

AiCon

全球人工智能开发与应用大会

会议时间：5月23-24日

- 通用大模型
- AI Agent
- 垂直领域应用
- 模型可解释性

📍 深圳

AiCon

全球人工智能开发与应用大会

会议时间：8月22-23日

- 模型效率与部署
- 多模态大模型
- 大模型安全
- 智能硬件

📍 北京

AiCon

全球人工智能开发与应用大会

会议时间：12月19-20日

- 通用大模型
- 智能硬件
- LM Ops
- 具身智能

极客邦科技 2025 年会议规划

促进软件开发及相关领域知识与创新的传播



参会咨询



查看会议

THANKS

大模型正在重新定义软件

Large Language Model Is Redefining The Software

