

专家级 Agent 技术演进及应用

—— 从通用到专业，跨越产业化门槛

演讲人：梁家恩 博士

云知声智能科技股份有限公司 董事长/CTO

AiCon

全球人工智能开发与应用大会

目录

01 学以致用——大模型为学，智能体致用

02 专家级 Agent 技术架构——通用为基，专业破局

03 实践出真知——跨越产业化门槛

04 展望未来——认知与产业升级

极客邦科技 2026 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

北京

1200人

QCon

全球软件开发大会

会议时间：4月16-18日

- Agentic Engineering
- AgentOps
- 下一代模型架构与推理优化
- AI 原生基础设施
- 知识工程实践
- AI 安全

深圳

1000人

AiCon

全球人工智能开发与应用大会

会议时间：8月21-22日

- Agentic AI
- 轻量化与高效推理
- 多模态应用
- AI + IoT 场景实践
- AI 工业化落地

北京

1000人

AiCon

全球人工智能开发与应用大会

会议时间：12月18-19日

- 大模型架构创新
- 多模态 AI 产业融合
- 具身智能
- AI for Science
- 大模型安全

4月

6月

8月

10月

12月

AiCon

全球人工智能开发与应用大会

会议时间：6月26-27日

- AI Infra 系统工程
- 多 Agent 协作与实践
- 多模态融合
- 模型训练与推理创新
- 数据平台与特征服务

上海

1000人

QCon

全球软件开发大会

会议时间：10月22-24日

- AI Agent
- Vibe Coding
- 智能可观测
- 推理基建
- 模型攻防
- AI x 创造力

上海

1200人

01 学以致用

—— 大模型为学，智能体致用

AGI 进入“学以致用”阶段

大模型提供“语义与推理”的可计算框架

1、Scaling Law 深化

- ✓ 预训练(Pre-train)
- ✓ 后训练(Post training)
- ✓ 推理(Inference)



2、多模态融合


- ✓ 原生多模态
- ✓ 语义对齐多模态

3、推理与规划 加强

- ✓ 基础层: CoT/ToT
- ✓ 核心层: RLVVR 等
- ✓ 框架层: Agent

4、世界模型/具身智能

- ✓ 大脑-小脑 分层协作
- ✓ 端到端 VLA 模型
- ✓ 仿真-现实 迁移



■ AGI 从“大模型能力”走向“智能体系统”竞争



大模型(LLM)是基础，也是成本投入，要真正创造价值，在于解决实际问题的智能体(Agent)系统。

从能力到价值



深入场景，打造“大脑(LLM) + 五官四肢”智能体(Agent)协同体系，解决实际问题，才能跨越产业化“最后一公里”。

躬身入局，解决问题



如何将通用 LLM 能力，转化为专业领域高能力、高可靠、低成本的专家级智能体(Agent)，是推动产业升级的关键。

突破瓶颈，升级产业

■ 智能体创造价值的核心挑战

- 1、实用，解决实际问题，引发效率质变，突破能力上限
- 2、可靠，克服“幻觉”——不合逻辑或时宜的“涌现”
- 3、普惠，成本可控，可规模化应用



02


专家级 Agent 技术架构

—— 通用为基，专业破局

2. 智能体演进三模式

智能体打造关键：

- 1、完整技术能力
- 2、优质数据闭环
- 3、场景应用优化
- 4、工程成本优化
- 5、高效算力平台



2.1 打造专业Agent模型




2.1.1 专业基座增强：专业数据扩充+模态扩充

通用增量训练

1. 现有通用基模，专业知识会被海量通用语料“稀释”，现有模型没有经过高质量专业数据训练
2. 现有基模基本是文本数据，部分多模态模型更多建模的是自然图像或者闲聊语音，对比专业领域比如医学影像、工程图纸、医学语音等存在明显的分布差异，所以现有的对齐策略不完全适用

基于行业多模态数据特点，
定制化增量训练策略和多模态对齐策略



基于差分注意力的视觉文本模态对齐算法

2.1.2 专业智能体强化训练：任务规划能力


别人走向“聪明”，我们走向“可信”。

现有训练方案


1. 通用模型在数学、代码任务上追求形式逻辑上的绝对正确，而真实专业场景在过程中充满不确定性
2. 专业规划数据量少，知识密度高，现有算法样本学习效率低下，利用不够充分



RLVR + 行业“审查”器，增强在不确定性规划上的可用性



通过条件熵针对性强化专业任务规划能力，完成少量数据的高效学习



2.1.3专业智能体强化训练：工具调用能力

现有工具调用方案

- 交互模式**: 以单轮生成结果为主，根据结果做只做一次反馈
- 工具箱**: 大量无法使用的通用工具集，缺乏专业工具箱来应对专业问题

通用工具: 模型通过单次调用工具结果反馈
专家级工具: 在动态环境中持续多轮交互反馈

通用Tools

专家级Tools

单次调用工具反馈

多轮环境交互行为数据

通用知识

隐性专业知识

通用工具



专家级能力沉淀
+

医学专家级工具





2.1.4 专业智能体强化训练：任务相关记忆优化



通用智能体的记忆

1.1 短期记忆依赖上下文工程，基本是扁平的 token 序列数据

1.2 对于长期记忆：用传统的文档库，普遍召回效率差，幻觉高



知识萃取：无结构化知识的降噪提纯



HTML



社交媒体



Latex




Token化

利用强化学习训练使得模型可以动态地、自主地控制这些结构化记忆的构建、演化和修剪


短期记忆内化：萃取精炼相关信息

历史精炼和萃取结构化数据作为上下文





长期记忆内化：动态加载可靠信息


根据信息的重要性和稳定性决定注入哪些信息



专业任务数据构建闭环



工程化整合



03 实践出真知

——跨越产业化门槛



AGI 技术产业化格局

产业层次	核心要素 焦点	主要挑战
基础设施层	算力芯片、智算集群、数据服务、电力网络 NVIDIA、AMD、Google、华为、寒武纪等	1.算力瓶颈：中国算力规模约为先进国家的15%，高端芯片（如GPU）供给受制于人 2.能源消耗：超大规模智算集群部署面临能源瓶颈，需推进“算电协同” 3.生态依赖：国产软硬件全栈技术生态仍在构建中，需突破CUDA等固有生态壁垒
模型层	基础大模型、多模态、世界模型、开源生态 OpenAI、Google、Meta、DeepSeek、千问、豆包、混元等	1.技术代差：在视频生成、多模态、世界模型等前沿领域与国际顶尖水平尚有差距 2.数据制约：高质量、专业化数据集缺乏，数据流通和治理体系不完善 3.可信与可靠：模型存在“黑箱”不可解释性，引发安全、隐私和伦理担忧
中间层/工具层 专业化	AI智能体、开发工具链、行业模型微调 Anthropic的MCP协议、各厂商智能体平台 行业模型专业化、Prompt工程、RAG技术等	1.技术复杂性：智能体在复杂环境中的感知、规划与可靠执行仍是技术难点 2.标准化缺失：工具调用、交互协议等标准尚未统一，开发效率与interoperability受影响 3.落地门槛：将大模型能力与特定行业知识、业务流程深度结合的成本高、难度大
行业应用层	千行百业智能化解决方案、AI硬件等： • 金融：智能投顾、风险控制 • 工业：智能工艺设计、能耗优化 • 医疗：AI辅助诊断、药物研发 • 汽车：AI座舱、端到端自动驾驶 • 机器人：具身智能	1.场景深度：应用从“单点尝试”迈向“全局重构”，对业务理解和技术适配要求极高 2.人才缺口：兼具AI技术和行业知识的复合型高端人才严重短缺 3.投入产出评估：部分场景的商业模式需持续探索，难以快速验证商业价值并规模化

云知声 AGI 技术及产业化布局



2012 创立入局

- 语音交互+深度学习+智慧物联
- 2014 “云端芯” 一体化战略
- 福布斯成长最快科技企业

2016 全栈升级

- Atlas 平台+知识图谱+智慧医疗
- 吴文俊、北京市科技进步一等奖等
- 2018 年起入选全球 AI 独角兽

2022 AGI 升级

- 山海大模型: 通用一流+医疗顶尖
- 北京市大模型伙伴, 十大应用案例
- 2025 港交所 AGI 第一股上市

聚焦技术产业化的四大支柱

“高素质”：通用大模型基座

覆盖广度：见多识广，能言善辩，能思善学
顶级院校本科生，高素质、高潜力

“进化力”：Atlas 基础设施

高效训练：动态调度扩展，高效模型迭代
数据飞轮：技术优势转化为数据与模型壁垒



“高水准”：专业级大模型

攻克深度：做得到、做得好、低幻觉
百万年薪专家水准，引领行业突破与变革

“低成本”：端侧芯片优化

端云协同：端侧大模型与芯片级优化
规模化应用：AGI普惠，深入千行百业

智慧医疗实践：从效率工具到决策支持



智慧医疗体系：由浅入深

- 语音电子病历、病历自动生成
- 医院智能化：导医/分诊/随访/辅诊...
- 病历质控、医疗质量监管
- 医保控费、商业保险
- 数字医生：助手/同事/专家/导师
- 三医协同：医疗/医保/医药

技术驱动，应用牵引，闭环迭代！

智能体实践：如何从幻觉角度选择场景

幻觉率

大模型能力成熟度

- 文本理解
- 文本生成
- 医疗知识
- 临床推理
- Agent能力（规划，记忆，反思，工具使用等）

幻觉容忍度

应用场景能否容错

- 大模型的鲁棒性
- 大模型的可靠性

幻觉可检测性

用户能否识别出幻觉

- 大模型输出的可溯源性
- 大模型输出的校验成本

理想的应用场景：幻觉率低，幻觉容忍度高，幻觉可检测性高

■ 医疗智能体应用场景分析(示意性)

典型场景分析	幻觉率	幻觉容忍度	幻觉可检测性
AI 健康咨询 (非诊断)	低	较高	低
AI 问诊 (面向患者)	较高	低	低
辅助诊断 (面向高年资医生)	较高	较高	高
辅助诊断 (面向低年资或基层医生)	较高	较低	低
病历生成 (书写辅助)	低	较高	高
病历质控	低	较高	高
医保审核	低	较低	高

案例1：门诊病历生成系统

利用AI大模型可快速生成符合模版规范逻辑清晰、内容表达丰富、易读性好、可解释性强的结构化医疗文书。



在门诊场景下，医生对患者进行问诊并查体，给出初步诊断和处理方案，这些内容需要录入门诊电子病历，但该工作会挤占宝贵的门诊时间。门诊病历生成系统基于医患对话，自动生成门诊病历，大幅提升了该项工作的质量和效率。

应用流程



功能特点



对话识别

门诊医患对话语音实时采集，并识别转写



角色分离

采用麦克风定向+声纹识别+大模型语义级理解进行角色分离



信息摘要

基于山海大模型对医患对话文本进行分析、理解、标化，从而完成摘要



病历撰写

结合《电子病历书写基本规范》，应用山海大模型的文本生成能力，自动生成满足要求的门诊电子病历



实时质控

门诊同时进行问诊质控，及时提醒问诊遗漏

案例2：智能病历质控系统


病历环节质控

病历终末质控

病案首页质控

门诊病历质控

单病种质控



1. 质控点完整覆盖 (内涵质控、重点专业质控)
2. 对国家上报病种、填报明细、上报要求采取同步处理机制, 动态满足最新要求
3. 多模态医疗信息统一解析与关联分析, 实现交叉验证, 自动发现潜在的不一致与异常
4. 病历审查覆盖度从2-5%提升至100%
5. 检出缺陷的查准率达90%+, 查全率达85%

案例3：智能医保审核系统

医院端：智能提醒客户端

嵌入HIS系统，诊疗过程中提醒医生可能违规的收费项目，从源头避免违规情况的发生



医保监管端：智能监管平台

提供多维度的统计分析图表，层层下钻，精准掌握医院运营和医保违规情况



医保自动审核控费率较当前人工抽审方式提升4倍至8%以上，即每100元医保支出可节约8元。

产业化实战分享



04 展望未来

——认知与产业升级

■ AGI 三维度拓展

工程维度

- 1、需求提炼，系统集成与优化，解决实际问题
- 2、优质高效数据闭环构建，持续高效迭代
- 3、工程优化及成本控制，支持规模化应用

AGI
智能体

产业维度

- 1、能力输出到价值创造，人机协同机制
- 2、可信数据平台构建，数据资源参与产业分配
- 3、标准规范及生态构建，治理体系完善

科学维度

- 1、原创算法提升能力上限，完善模型能力
- 2、从“炼丹术”到“化学”，提升可解释、可控和可靠性
- 3、AI4S 探索新知识，新一轮认知与哲学革命



迎接超级智能与人机协同时代到来



这是最好的时代，也是最坏的时代，谨慎乐观推进：

- 1、当确定目标的有效可计算框架取得突破，机器超越人类只是时间问题，超级智能的出现不可避免
- 2、机器要在与人互动中成长，人类会拥有智能伙伴，并在互动中重新调整定位与模式
- 3、复杂世界并非单一目标，平衡内在矛盾与非理性因素，仍需人类参与并负责
- 4、机器有不同于人的“意识”，人类认知也将迎来变革

极客邦科技 2026 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

北京

1200人

QCon

全球软件开发大会

会议时间：4月16-18日

- Agentic Engineering
- AgentOps
- 下一代模型架构与推理优化
- AI 原生基础设施
- 知识工程实践
- AI 安全

深圳

1000人

AiCon

全球人工智能开发与应用大会

会议时间：8月21-22日

- Agentic AI
- 轻量化与高效推理
- 多模态应用
- AI + IoT 场景实践
- AI 工业化落地

北京

1000人

AiCon

全球人工智能开发与应用大会

会议时间：12月18-19日

- 大模型架构创新
- 多模态 AI 产业融合
- 具身智能
- AI for Science
- 大模型安全

4月

6月

8月

10月

12月

AiCon

全球人工智能开发与应用大会

会议时间：6月26-27日

- AI Infra 系统工程
- 多 Agent 协作与实践
- 多模态融合
- 模型训练与推理创新
- 数据平台与特征服务

上海

1000人

QCon

全球软件开发大会

会议时间：10月22-24日

- AI Agent
- Vibe Coding
- 智能可观测
- 推理基建
- 模型攻防
- AI x 创造力

上海

1200人

THANKS

探索 AI 应用边界

Explore the limits of AI applications

AiCon

全球人工智能开发与应用大会