

Kboss 2.0

开元云（北京）科技有限公司

2024年7月

Kboss 1.0 回顾

- 开元云业务云上
 - 供应商产品上云
 - 分销商业务过程上云
 - 客户购买体验上云
 - 供应商分销商结算
 - 业务考核上云


Kboss 2.0概要

- Kboss平台持续改进
 - 更多资源方接入
 - 服务平台接入
 - MaaS平台接入
- 服务平台
 - 监控与运维
 - 持续集成与部署
 - 安全合规
 - 公共服务部署
- MaaS平台
 - API连接主要LLM，提供客户大模型体验
 - RAG，微调，定制化模型服务
 - 离线或微调模型定制化部署
 - 在线智能体开发，调试，发布
 - 模型Pipeline定义，混合模型应用开发和发布

关于大模型和大模型应用

- 什么是大模型
- 从业公司如何分类，都在做什么
- 我们做什么

大语言模型 (Large Language Model)




模型开发

- 巨量数据准备 (Q/A数据)
 - 训练环境 (万卡规模)
 - 长时间训练
 - 验证与回归测试
 - 定版与发布
- Transformers框架
 - 模型规模
 - 一个模型可以配置多个编码器和解码器
 - 不同的编码器适配不同的输入
 - 不同的解码器适配不同的输出

MoE模型 (Mixture of Experts)

- 更快的训练速度
- 更少的GPU需求
- 同等参数量推理速度更快
- 需要更大的显存




模型量化

- **模型量化 (Model Quantization)** 就是通过某种方法将浮点模型转为定点模型。比如说原来的模型里面的权重 (weight) 都是float32，通过模型量化，将模型变成权重 (weight) 都是8bits, 4bits, 2bits或1bits的定点模型
- 模型量化就是建立一种浮点数据和定点数据间的映射关系，使得以较小的精度损失代价获得了较大的收益

量化前的浮点模型	量化后的定点模型
参数量大 (float32)	压缩参数 (int8)
计算量大	提升速度
内存占用多	内存占用少
精度高	精度损失

RAG (Retrieval-Augmented Generation)

- 搜索增强生成（大语言模型体外知识库）
- 向量数据库
- 生成知识库：领域知识的正文文本一次性转化为高维向量数据，并保存在向量数据库中
- 知识检索：问题文本转化为向量，并在知识库中检索空间距离最短的向量，逆向转化为文本返回，通常按具体从小大大的排序返回几个结果




模型微调 (fine tuning)

- 专业知识文本准备 (Q/A格式文本)
- 选择模型微调工具
- 选择基座模型 (参数越多需要的算力越大, 微调时间越长)
- 执行微调
- 验证与回归测试
- 定版与发布

函数调用

- 作用：将用户的一句话翻译成一个预先定义的函数集中中的一个函数，json格式以函数名，所需参数名称和值的形式返回。
- 大模型不执行所定义的函数
- 用户需实现将函数按照大模型约定格式要求预先定义函数，可以定义多个函数
- 需要体外设置函数识别规则，并有能力执行函数



- 1 函数定义 + 用户输入
- 2 函数名, 函数参数
- 3 API调用
- 4 返回调用结果
- 5 函数定义+调用结果
- 6 返回应答

LLM总结

- 大语言模型（稠密模型，主要性能指标：参数规模）
- MOE模型（稀疏模型，主要性能指标：参数规模）
- 量化模型（小体量模型，主要性能指标：参数规模，位数）
- 微调模型（在基座模型上用特定知识文本训练后的模型，主要性能指标与基座模型相同）
- RAG（模型体外知识库）
- 函数调用（大模型需理解函数，需外部系统执行函数）


从业分类与专注

- 大模型公司
 - 生产大模型
- 平台公司
 - 融合大模型平台,
 - 提供agent, 角色扮演
- 应用商店
 - 应用上架展示
 - 在线购买
 - 下载
- 应用开发
 - 行业大模型微调, 知识库以及应用集成
 - 功能性应用开发

我们做什么

- 大模型平台 (MaaS)
- 应用商店 (为Kboss2.0提供大模型应用产品)
- 大模型行业应用
- 大模型功能性应用开发


Kboss 2.0部署架构




Kboss平台架构



MaaS平台架构



服务平台架构



Kboss平台持续改进

- 更多的资源方接入
 - 阿里云, AWS, 首都云, 火山云, ucloud, 算法互联, . . .
- 独立分销部署
 - 独立的软件部署
 - 与Kboss之间API链接
 - 客户支付给分销商
 - 与开元云定期结算
- 服务平台作为资源方接入
- MaaS平台作为资源方接入
- 基于大模型的比价与推荐

MaaS平台

- 与Kboss平台对接，作为资源方提供下列产品
 - 大模型对话式体验
 - 客制化模型独立部署（含硬件客制化，模型客制化）
 - 智能体
 - 混合模型应用
- 定位：模型应用开发平台
 - 联通主流在线模型
 - 部署主流离线模型
 - 在线开发调试部署外部应用连接
 - 提供知识库，模型微调开发，测试，部署
 - 智能体开发，测试和部署
 - 混合模型应用开发，测试和部署

MaaS平台开发里程碑

- 国内主要文生文在线模型联通 - 已完成
- 在线模型用户体验上线 - 8月10日
- Kboss大模型体验产品接口开通 - 8月10日
- 国内主要文生图在线模型联通 - 9月10日
- 国内主要文生视频在线模型 - 9月20日
- 国内主流短视频厂商上传视频接口开通 - 10月20日
- 短视频生成发布平台上线 - 11月30日
- 企业私有化知识库服务搭建 - 12月30日

需销售市场部门协调办理

- 代理协议

- 阿里千问
- 百度千帆
- 百川
- 智普
- Minimax (已确定)
- 月之暗面
- 火山豆包
- deepseek

- 行业应用需求

- 高校

服务平台

- 与Kboss集成，作为资源方提供
 - 监控和运维服务
 - 持续集成与部署
 - 安全合规
 - 公共服务部署
- 定位：在线应用服务
 - 定制化应用监控与运维
 - 支持git的CI/CD
 - 常用服务的一键式部署
 - 安全与合规服务