

大模型在荣耀推荐和广告 场景的应用实践

演讲人：冯晓东

荣耀终端股份有限公司 / AI算法专家

AiCon
全球人工智能开发与应用大会

目录

- 01 荣耀的推荐场景介绍
- 02 推荐算法模型和大模型的特点分析
- 03 基于大模型的特征工程
- 04 基于大模型的训练与推理
- 05 总结与展望
- 06

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

全球领先的AI终端生态公司

14000+
员工

70%+
研发人员占比

11.5%
研发投入营收占比

300+
专利月申请量

52000+
体验店与专区专柜

2.5亿+
在网设备数



荣耀公司新定位

新愿景



以人为本，科技与人
文结合，最大程度释
放人类潜能

新定位

从智能手机制造商转型
成为全球领先的AI终端
生态公司

新战略

第一步 打造智能手机
第二步 构筑智慧生态
第三步 拥抱智慧世界

01 荣耀的推荐场景介绍


搜索、推荐、广告、游戏

荣耀的推荐场景



荣耀的推荐场景

广告业务追求三角的平衡，对算法提出更高要求



多模态内容理解

- 内容侧：图文和视频内容的特征挖掘
- 用户侧：刻画用户对不同类型营销素材的偏好

更精准的排序模型

- 推荐：精准的顺序保证用户体验和分发效率
- 广告：精准的预估分保证流量的收益

20+应用30+场景：多场景

单场景10+目标：多目标

亿级活跃用户：海量样本

用户日均10+行为：超长行为序列

02

推荐算法模型和大模型的特点分析

推荐算法结构演进及特点

大语言模型的演进及优势

大模型与推荐的结合方式



推荐算法结构演进及特点



大语言模型的演进及优势

GPT1	→	GPT5	Qwen3	DeepSeek-V3.2	Llama 4	Gemini 2.5
2018	0.12B	2025	235B	685B	288B	175B

预训练能力

多模态数据（文本、图像、音频、视频）
最高 1,000,000 Token 上下文长度
覆盖更多领域和长尾知识

序列处理能力

Self-Attention
Flash Attention
DeepSeek Sparse Attention

训练推理能力


MOE
KV Cache
强化学习

特征工程和冷启动

用户超长/全生命周期序列

多场景多任务

大模型与推荐的结合方式




03 基于大模型的特征工程

基于LLM的多模态内容理解

基于LLM的embedding提取

基于大模型的特征工程

基于LLM的多模态内容理解




- Prompt设计：限定标签体系和步骤
- 流程编排：利用不同预训练模型的优势

一层分类准确率	二层分类准确率	三层分类准确率
95%	87.5%	90.7%

字段名称	注释
creative_id	创意ID
screen_orientation	素材展示屏幕方向
duration	视频类型资产的时长信息
ratio	素材长宽比例
color	色系
clarity	清晰度
brightness	明暗度
tone	色温
person	人物
text	原始文本
text_length	文本长度
text_key_words	文本关键词
text_color	文字颜色
text_type	广告素材类型
object_type	物体类型

基于大模型的特征工程

基于LLM的embedding特征提取





基于大模型的特征工程


基于LLM的embedding特征提取—广告场景应用实践

文本特征构建


candidate_i_app_package_name	u_candidate_item_time	age	gender	u_item_download_name_seq	u_item_download_time_seq
途游斗地主 (比赛版)	28.20.2	44	0	开心消消乐,开心消消乐,开心消消乐,开心消消乐,开心消消乐,开心消消乐	2014-08-15 21:36
蛋仔派对	04.13.0	44	0	蛋仔派对,火影忍者,巅峰坦克,创造营,极品飞车:集结	2024-08-19 10:01
三国志:战略版	47.38.1	23	1	第五人格,第五人格,天姬变,第五人格:新圣塞季约	2024-07-26 12:06
蛋仔派对	20.53.2	44	1	和平精英,和平精英,第五人格,和平精英,使命召唤手游,使命召唤手游,欢乐斗地主,王者荣耀,和平精英	2024-08-20 20:04

该用户最近的APP点击序列为地铁跑酷、三国志·战略版、APP下载序列为和平精英、和平精英、王者荣耀、贪吃蛇大作战、地铁跑酷、蛋仔派对，其中王者荣耀的分类为动作射击-MOBA;三国志·战略版的分类为经营策略-战争策略;蛋仔派对的分类为休闲益智-休闲竞技;地铁跑酷的分类为动作射击-跑酷;贪吃蛇大作战的分类为休闲益智-IO;和平精英的分类为动作射击-吃鸡游戏。

上线模型



实验效果



Emb size设为32， 离线AUC最优



加user emb特征后，DTR平均提升**0.85%**

04 基于大模型的训练与推理

基于对比学习的方式

基于MOE的方式

基于HSTU的方式



基于大模型的训练与推理

基于对比学习的方式




Figure 3: An intuitive illustration of the CTRL, which is a two-stage framework, in the first stage, cross-modal contrastive learning is used to fine-grained align knowledge of the two modalities. In the second stage, the lightweight collaborative model is fine-tuned on downstream tasks. The red square represents a positive pair in the batch, while the green square represents a negative pair.


Xiangyang Li, et al. (2023) CTRL: Connect Collaborative and Language Model for CTR Prediction.

实现的关键点

- 语义信息如何编写? -- 定制prompt模板
- 选取什么LLM模型? -- 冻结预训练LLM模型
- 预训练阶段, 损失函数如何设计?

-- $L^{textual2tabular}$ 与 $L^{tabular2textual}$ 具有对称性




实验效果: 14天平均提升1.07%





基于大模型的训练与推理

基于MOE的方式




专家群结构关键点：

- 专家数量：数量太多会有负载均衡问题
- 路由方式：无路由与稀疏路由，共享路由与全局路由
- 稀疏路由：样本量小的目标拟合能力弱

基于大模型的训练与推理


基于MOE的方式—广告场景应用实践



设计的关键点

- 专家网络1拆4
- 专家路由经过多轮实验效果不佳，采用无路由方式
- 为了专家计算复杂度，对特征重要度做筛选


实验效果：单位收入平均提升0.63%





基于大模型的训练与推理

基于HSTU的方式





Jiaqi Zhai, et al. (2024) Actions Speak Louder than Words: Trillion-Parameter Sequential Transducers for Generative Recommendations.

基于大模型的训练与推理

基于HSTU的方式

(1) 特征构建：按照用户粒度构建特征和样本，减少数据重复，
保持更多用户信息，保留重要画像和上下文特征


(2) 模型结构：HSTU+ DNN，在传统transformer基础上增加行
为间的相对时间关系和对物料embedding的门控机制




基于大模型的训练与推理

基于HSTU的方式

(3) 训练策略：在用户的每个曝光行为后，都基于该时刻之前的用户特征推理出用户向量embedding，用于预测下一个行为



(4) 线上推理：大模型参数量多具备scaling law，拆分轻量化模型结构上线，推理性能更佳






基于大模型的训练与推理


基于HSTU的方式—广告场景应用实践

模型性能



Base特征数量500+, hstu-based特征50+, 性能极大提升

业务效果



CTR平均提升0.98%，单位收入平均提升0.72%

Q5 总结与展望


快速落地推荐大模型

生成式推荐覆盖推荐全链路

总结：快速落地推荐大模型



展望：生成式推荐覆盖推荐全链路



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