



2025 AI+ Development
Digital Summit

AI+ 研发数字峰会

拥抱AI 重塑研发

05/23-24 | 上海站



2025 AI+研发数字峰会

拥抱AI 重塑研发 AI+ Development Digital Summit

下一站预告

08/08-09 | 北京站

11/14-15 | 深圳站



查看会议详情

北京站论坛设置

大模型和 AI 应用评测

智能存储与检索技术

下一代知识工程

AI+ 金融业务创新

智能需求工程

智能体与研发效率工具

AI 产品运营与出海策略

大模型安全与对齐

大模型应用开发框架与实践

智能体经济 (Agentic Economy)

智能测试工具的开发与应用

具身智能与机器人

代码生成及其改进

AI+ 新能源汽车

AI 前沿技术探索与实践

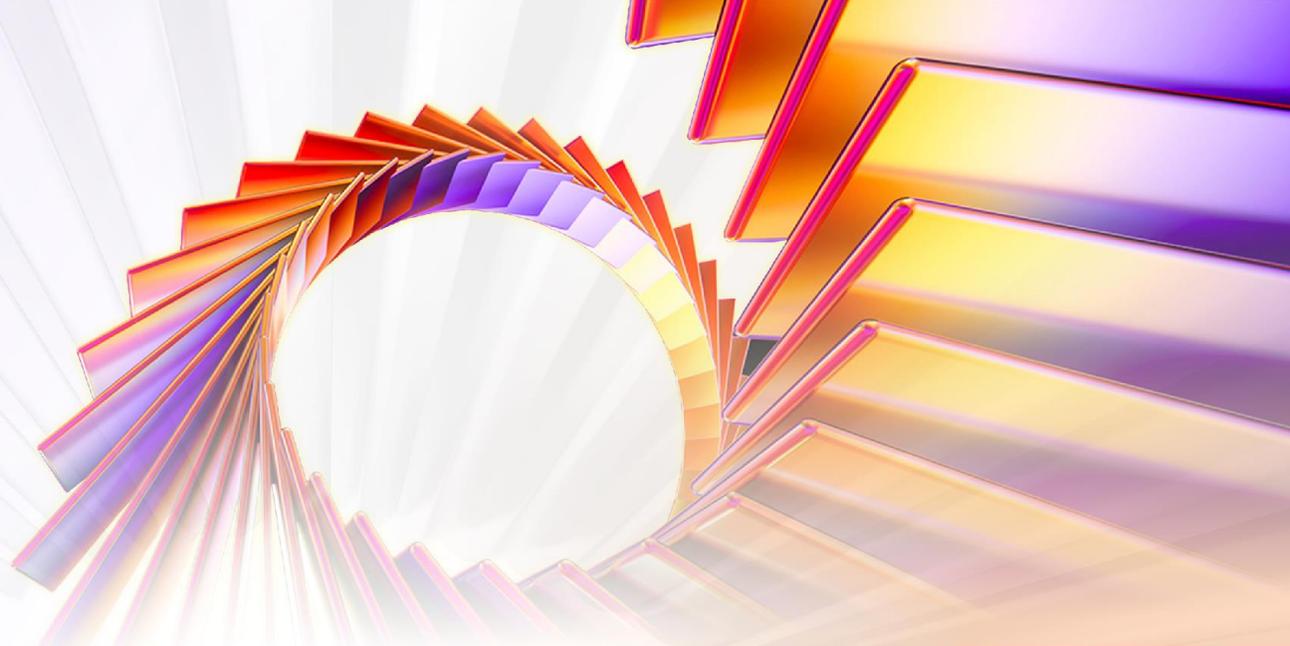


| 05/23-24 | 上海站

2025 AI+ Development
Digital Summit

AI+研发数字峰会

拥抱AI 重塑研发



抖音性能LLM分析体系建设 从智能诊断到决策推荐

姚凡、李文博 | 字节跳动



姚凡

抖音测试开发专家

毕业于悉尼大学计算机专业，现就职于抖音专项测试团队，负责抖音体验平台的性能诊断、大模型应用等方向的开发工作。



李文博

抖音测试开发专家

毕业于悉尼大学计算机专业，毕业后即加入抖音，现就职于抖音基础体验团队，专注于客户端性能体验分析、测试效率优化等专项技术。

目录

CONTENTS

1. 背景
2. 整体解决方案
3. 核心模块 - 智能诊断
4. 核心模块 - 策略推荐
5. 总结与展望

PART 01

背景

▶▶ 性能优化的重要性

降低用户流失

加载速度直接影响
用户留存率

提高品牌信任

性能问题会导致用
户评分下降

驱动营收增长

加载速度与用户留
存率直接相关

李女博3824


性能优化挑战：从表现层问题到优化落地

1. 性能问题归因复杂

- 分析数据繁多：性能问题涉及客户端、网络、服务端等多个维度，数据源多，数据量大。
- 分析门槛高：需熟练使用不同端/数据源的多个分析工具，如 Android Profiler、Instruments；需熟悉编程语言、技术实现原理等。

2. 优化方案选型复杂

- 决策困难：优化路径多，效果不明确，导致试错成本高，难以快速确定适合业务的最优方案。
- 专家依赖：优化策略依赖少数资深专家，存在经验主观性、知识孤岛与人才瓶颈问题。




李女博3824

PART 02

整体解决方案

性能分析整体架构



😞 分析数据繁多?
?

多数据同时采集
与联合分析

😞 分析门槛高?

用户层问题的自动分析能力

😞 专家依赖?

经验知识沉淀



AI

- 数据整合与理解能力
 - 多模态模型：图片/视频理解
 - 代码理解模型：代码/函数理解
- RAG：
 - 相似场景的历史经验复用。
- SFT：
 - 专家知识应用于LLM中。



覆盖率

准召率

采纳率

下面将分两个章节重点介绍AI在诊断分析与策略推荐中的难点与方案。

李女博3824




PART 03

核心模块 - 智能诊断

Trace分析平台现状

- 可视化分析
- 异常堆栈
- 规则分析

😊 录屏+Trace同时采集,
协同分析



刘女博3824



Trace分析平台现状

- 可视化分析
- 异常堆栈
- 规则分析

😊 自上而下对慢函数/高频函数的异常堆栈定位

😞 未与场景结合，无法确定问题影响的具体阶段



李女博3824




Trace分析平台现状

- 可视化分析
- 异常堆栈
- 规则分析

😊 支持组件耗时长、无效UI更新等L1/L2的部分规则

😞 但不支持L2+的规则



李女博3824

很多规则无法靠硬编码实现，需要借助AI的语义理解、推理能力、图像理解等能力。

如何判断资源的创建/渲染时机是否合理？

如何判断多个堆栈在做同一件事情，需要聚合分析？


如何判断主线程与子线程之间的调度关系？

如何判断诊断出的问题具体影响的是哪个阶段？

李女博3824



AI智能诊断整体流程




李女博3824



Trace裁剪 - 为什么要裁剪？

Trace数据量过大，一个完整Trace文件在几百M左右。



单个堆栈的数据量就已超出LLM上下文token限制



对大量数据进行分析可能造成准确率降低、处理耗时过久


李女博3824



Trace裁剪 - 裁剪方式

- 线程裁剪：主线程/子线程
- 堆栈裁剪：丢弃 root 节点耗时小于阈值的堆栈
- 单堆栈slice裁剪
 - 高频聚合
 - 最小耗时阈值
 - 黑白名单
 - 相似函数/相似子树

可根据不同的场景，选择不同的裁剪方式。




单堆栈slice裁剪

李女博3824

阶段划分Agent - 为什么要划分阶段？

合理的阶段划分可以**提高**问题发现的**准召率与采纳率**。




存在多个小堆栈在处理同一任务且整体耗时较长的情况，需聚合在一起分析




单纯的问题罗列，不绑定阶段场景的话，用户难以理解与消费

阶段划分Agent - 录屏场景识别

录屏理解 + Trace裁剪 => 阶段划分



录屏



```
{
  "appRunDescription": "用户在用户主页 · 点击Story后，页面跳转到Story详情页。",
  "pagesDetail": [
    {
      "name": "用户主页",
      "detail": "页面顶部有用户头像和名称'Matt Navarra'，右上方有Done按钮。下方有Dark mode、Active Status、xxx"
    },
    {
      "name": "Story详情页",
      "detail": "页面顶部显示xxx"
    }
  ]
}
```

录屏信息

李女博3824



▶ 阶段划分Agent - Trace裁剪

录屏理解 + Trace裁剪 => 阶段划分



- 裁剪方式：保留主线程，root耗时 > 5ms的堆栈，并进行重度精简
- 格式转换，提取函数名称、耗时、频次、开始/结束时间信息

```
activityStart(dur=81ms, freq=1, ts=3999, tsEnd=4081)
  XXXActivity: onCreate(dur=52ms, freq=1)
    xxx
activityResume(dur=19ms, freq=1, ts=4135, tsEnd=4154)
  binder transaction(dur=4ms, freq=7)
  XXXActivity: onResume(dur=6ms, freq=1)
Choreographer#doFrame(dur=39ms, freq=1, ts=3956, tsEnd=3996)
  traversal(dur=39ms, freq=1)
    measure(dur=27ms, freq=1)
      xxx
      layout(dur=7ms, freq=1)
      draw(dur=3ms, freq=1)
  xxx
xxx
```

堆栈信息

李女博3824



▶ 阶段划分Agent - 阶段拆分


录屏理解 + Trace裁剪 => 阶段划分

```
{  
  "appRunDescription": "用户在用户主页 · 点击Story后,  
  页面跳转到Story详情页。",  
  "pagesDetail": [  
    xxx  
  ]  
}
```

录屏信息

```
activityStart(dur=81ms, ts=3999, tsEnd=4081)  
  XXXActivity: onCreate(dur=52ms, freq=1)  
  xxx  
xxx
```

堆栈信息




- 阶段一：
 - 时间范围：ts=3999 至 ts=4898
 - 任务：用户主页渲染
 - 关键堆栈：
 - FuncA 进行view创建
 - FuncB 进行渲染
- 阶段二：
 - 时间范围：ts=5012 至 ts=5054
 - 任务：处理点击事件
 - 关键堆栈：
 - FuncC 处理点击事件
- 阶段三：
 - xxx

阶段划分



阶段划分Agent - 分阶段分析


阶段划分完成后，**阈值初筛**出需要分析的堆栈，再根据堆栈与场景特征分别进行分析。



李女博 5041




▶ L3分析Agent - 主线程空闲分析流程



李女博3824

▶ L3分析Agent - 子线程行为语义识别



李女博3824

PART 04

核心模块 - 策略推荐

问题难定位

- 用户在不同场景下遇到的各类体验缺陷分布于多渠道数据中，缺乏归纳和映射，导致定位和复现困难。
- 传统问题排查多依赖研发个人经验，从表现层问题到技术根因的排查链路长

策略难复用

- 性能优化方案分散于各个团队，优化经验非标准化，难以有效传递，重复造轮子，试错成本高昂。
- 具体业务的优化策略通用性不足，难以抽象出普适优化思路，跨场景迁移应用难。

优化难落地

- 性能优化涉及技术领域广泛，解决思路多样、优化手段接入路径复杂且不明确。
- 缺乏清晰的决策支持与收益评估，导致优化决策难以获得业务方认可与投入。

李女博3824



智能Agent：多源聚合精准推荐

- 结合大模型Agent的任务规划能力，聚合日志、监控、反馈等多渠道表现层数据，联通知识库和归因技术自动定位体验问题。使用专家系统多角度提升问题定位效率和准确性，降低对人工经验的依赖。

体验知识库：打破信息孤岛

- 使用LLM能力自动抽取和结构化沉淀优化方案、最佳实践、实验收益等多源信息，构建统一知识库，实现跨团队、跨业务实现知识共享和高效检索，支撑科学决策与快速复用。



抽象推理：策略泛化创新

- LLM具备优化策略的抽象归纳和迁移能力。从历史案例中总结通用方法，不仅提升优化策略的适用性，还能发现并推荐新的创新优化思路。

李女博3824



体验知识库构建



1. 事实性提问
2. 技术垂类策略检索 & 优化手册生成
3. 产品表现层问题解决方案推荐

李女博3824




体验优化推荐Agent设计

专家系统问题分析



- **技术实现：**基于多领域专家系统（网络、客户端、服务端、多媒体）构建智能诊断框架，结合RAG技术从知识库精准召回优化方案。
- **价值亮点：**自动化归因与方案推荐，显著降低性能优化试错成本，提升用户体验与业务指标。

多源知识图谱融合



- **技术实现：**根据技术方案、实验报告、最佳实践等多源知识构建知识库。通过知识图谱与RAG技术，实现跨文档、跨业务的深度语义检索与召回。
- **价值亮点：**为个性化优化方案提供精确支撑，实现全景知识的深度聚合与智能推理。

业务画像驱动策略推荐



- **技术实现：**结合业务画像主动理解业务场景和用户需求。智能发现推理链路中的信息缺口，自动补全关键信息，保障方案完整性和准确性。
- **价值亮点：**显著提升推荐系统的可解释性、信任度及准召率。

智能推理和方案生成



- **技术实现：**结合CoT推理与专家知识融合，自动生成结构化、可落地的优化方案。具备策略泛化、举一反三与创新能力，支持跨场景的最佳实践迁移。
- **价值亮点：**方案推理过程透明可溯源，提升方案创新性、适应性与落地效率。

李女博3824




多领域专家系统协同推荐

- 基于大模型的规划、拆解能力构建虚拟专家系统

- 主Agent通过语义分类和关键词匹配，智能分发问题至对应专家Agent。


- 各领域专家Agent利用大模型上下文理解，生成针对性子问题，去各技术领域知识库中检索。



李女博3824


业务画像驱动策略推荐

- 利用大模型的语义理解能力，结合业务画像（如业务场景、核心指标、用户群体特征、技术上下文），主动解析业务需求和痛点。
- 通过上下文推理和知识图谱关联，智能发现推理链路中的信息缺口（如未提及的用户设备分布对性能影响）。
- 自动补全关键信息，基于历史数据或跨领域知识推测缺失维度（如“弱网用户占比高可能导致支付环节卡顿”）。



跨业务知识图谱融合

- 利用大模型构建跨业务、多源知识图谱，整合技术方案、实验报告、最佳实践等多源知识，形成立体化知识库。
- 借助图数据库检索方法，加速知识图谱中的关联推理，提升知识间关联性，确保高效精准推荐。



▶ 基于CoT的推理和方案生成

- 设计动态优先级评估机制，通过加权评分模型综合考量用户痛点紧急度、业务指标影响、方案可行性和收益预估，精准排序各专家建议，确保核心问题优先解决。
- 针对不同业务场景（如电商、短视频）总结定制不同思维范式，确保推理贴合业务需求。

应用场景

针对某页面加载慢问题，主专家，利用评分模型综合评估业务影响、方案可行性，排序图片格式优化和CDN调度优化建议，优先推荐“图片格式优化”，因其效果显著且接入成本低。

李女博3824



PART 05

总结与展望

智能归因

全链路多模态融合：融合日志、监控、用户反馈、业务数据、代码运行态等全链路数据，实现体验问题的智能溯源与因果洞察，实现体验问题“全景式”智能归因。

代码级主动归因：自动收集与分析代码特征，推动归因深度延伸至架构和底层逻辑，实现异常实时智能发现。

智能推荐

全生命周期闭环优化：推荐系统直达代码层，自动生成修复方案并驱动落地。打通归因、推荐、修复、验证全流程，实现体验问题自闭环，推动体验优化从“被动响应”到“主动发现”。支撑业务高质量发展。

跨域知识迁移：拓展不同技术垂类的知识体系，聚合客户端、网络、图片、音视频等多技术领域的优化经验，智能迁移和复用最佳实践，赋能各类互联网产品的体验持续提升。

李文博3824






| 05/23-24 | 上海站

2025 AI+ Development
Digital Summit

AI+研发数字峰会


拥抱AI 重塑研发



大模型在得物部署优化实践

孟令公 | 得物

参与调研您将优先获得



AiDD定制版
《AI+软件研发精选案例》



专属学习顾问
1对1需求对接

AiDD会后小调研

AiDD峰会致力于协助企业利用AI技术深化计算机对现实世界的理解，推动研发进入智能化和数字化的新时代。作为峰会的重要共建者，您的真知灼见对我们至关重要。衷心感谢您的参与支持！

2025 AI+研发数字峰会

拥抱 AI 重塑研发



扫码参与调研

科技生态圈峰会 + 深度研习

—1000+ 技术团队的选择



敦煌站

K+ 思考周®研习社

时间: 2025.08.29-30



上海站

K+ 金融专场

时间: 2025.09.26-27



香港站

K+ 思考周®研习社

时间: 2025.11.17-18



K+峰会详情



上海站

AI+研发数字峰会

时间: 2025.05.23-24



北京站

AI+研发数字峰会

时间: 2025.08.08-09



深圳站

AI+研发数字峰会

时间: 2025.11.14-15



AIDD峰会详情





2025 AI+研发数字峰会
AI+ Development Digital Summit

感谢聆听!

扫码领取会议PPT资料

