

Summary

拥有全栈工程背景的 AI 工程师,致力于通过强大的 MLOps 和推理优化,实现深度学习模型的生产化落地。实践证明能成 功构建高速、稳定且可监控的 AI 服务。技术栈方面,拥有超过五年的 Go 和 Java 开发经验,并对 Python 有着深厚的专业 积累。热衷于打通模型研发与规模化、高可用产品部署之间的壁垒,将 AI 技术真正转化为商业价值。

Experience

2024年1月 - 至今 家族办公室

首席 AI 工程师

阿布扎比

- **端到端产品领导开发:** 主导两个 AI 项目从概念验证 (PoC) 到成熟产品的完整研发生命周期。独立负责技术架构设计、 基础设施管理及部署发布,成功将项目从 Demo 阶段推进到可运营的商业产品。
- 全栈与云原生架构: 使用 Python 和 React 架构并开发了核心应用。同时,基于 Kubernetes 在 AWS 和 Azure 上管理 云原生基础设施,确保系统的高扩展性与高可用性。
- MLOps 与自动化: 从零到一搭建了完整的 MLOps 体系,实现了从数据接入、模型训练到部署监控的全流程自动化, 极大缩短了新功能的上线周期 (Time-to-Market)。
- **性能优化:** 聚焦于生产环境的就绪度,主导了模型推理的深度优化,显著降低了 AI 服务的响应时间与计算成本。
- 前沿 AI 技术实践: 开发并落地了复杂的 AI 解决方案,包括实现自主智能体 (Agent) 框架和检索增强生成 (RAG) 系 统,使产品能够提供具备上下文感知和事实依据的智能回复。
- AI 安全与可信度: 集成了关键的内容安全机制,包括文本审核与回复内容溯源,从而大幅提升了 AI 输出结果的可信度 与安全性。
- 数据工程: 使用 Apache Spark 构建了高弹性的数据管道,用于处理海量新闻及市场行情数据,为 RAG 知识库及其他 下游模型提供了稳定、纯净的数据源。

2022年8月 - 2023年8月 Autonomic

AIOps 工程师

上海

https://autonomic.com/

- 智能告警与响应: 开发了一套智能告警系统,可自动分析并分诊故障,并精准推荐相应的处理预案 (Runbook),最终 将平均故障解决时间 (MTTR) **缩短了 60%**。
- **主动式扩容平台:**基于对历史数据和实时流量模式的分析,构建了一个主动式扩容平台,能有效预判并应对流量洪 峰,成功防止了多次系统过载。
- AI 赋能开发者: 开发了一款 AI 聊天机器人 (Chatbot),极大简化了基础设施即代码 (IaC) 的管理流程,赋能开发人员 实现基础设施的自助式服务。

Informatica

2017年12月 - 2022年8月

全栈工程师

Chicago, US

硕士

https://www.informatica.com

- 云原生现代化改造: 作为公司云现代化项目的核心成员,深度参与了核心服务向可扩展、容器化的 Kubernetes 环境 迁移,为提升系统整体性能与稳定性做出了关键贡献。
- **核心微服务开发:** 负责公司业务中枢微服务的工程实现与维护,包括核心调度引擎、客户授权许可系统以及基于角色 的访问控制 (RBAC) 系统的功能开发。
- **文件服务开发:** 从零到一开发了一套高鲁棒性的文件服务 API,负责用户及系统文件的安全上传、存储与检索,确保了 关键数据的完整性与高可用性。

Education

2015年9月 - 2017年12月 Illinois Institue of Technology

计算机