

徐鑫

AI Infra Tech Leader

+8613603043209

277040271@qq.com

www.dreamrounder.com

广州



我目前就职于字节智能创作-AI平台部门，该部门提供了抖音剪映(C端)以及火山引擎(B端)的绝大多数AI能力。而我则负责其中基础架构方向的研发团队，涉及的主要技术包括网关、模型存储、工程框架、SRE、研发规范以及推理交付平台等，上接AI工程团队，下接字节基础设施，为团队打造高质高效的AI交付链路。此前在腾讯游戏负责容器平台的研发，为上层业务提供推理与训练平台，推动大量游戏业务向云原生转型，积累了丰富的云原生经验。工作之余也热爱参与开源，为ApacheAPISIX的PMC Member，也贡献/参与过不少开源项目，详情请移步Github个人页。

WORK EXPERIENCE

AI Infra Tech Leader

ByteDance | 2021 - Present

带领AIP的基础架构团队，从B端业务切入，积累了可靠的基础技术解决方案，并以此为基础，将野蛮生长的C端平台技术进行了技术革新，在工程交付、服务运维、技术基建等几大方向上，一边偿还技术债务一边从0到1去构建体系化的解决方案，在各个方向上都取得了一定成果：

- AI中台 - 交付提效：建设贯穿AI能力全生命周期（调试、工程化、部署、运维、接入以及体验）的技术平台，提供快速的AI开发流程、稳定的服务托管质量、高效的资源调度与全面的度量指标（如用量、成本与资源），包括开发工具（如工作台、AI专业版、风格定制等）、体验工具（如模型广场、批量生图等）与技术中台（如交付中心、模型中心等），满足不同角色的不同诉求——如零代码孵化AI能力、AI能力接入等。将交付效率从 > 5d 提升到零工程交付的程度，无需投入工程化人力，业务自行在平台自助进行交付，截止2024年为止平台月均交付AI能力过百。
- AI中台 - AIGC生态：以SD+Comfy为基础，沉淀AIGC相关的核心资产，如Workflow、插件、模型等，资产来自多方输入，如ByteArtist自研、开源引入、智创算法团队以及外部优秀UGC等。这些资产结合高效的AI交付，为平台的业务方在AIGC的探索上提供最有力的支持，截止2024年为止平台资产超过10w级别并为抖T、剪C、Flow等业务提供多个爆款特效。
- 基础服务：从0到1构建资源中心解决方案，用于解耦业务对算力与存储资源的依赖，实现混合多云的资源调度能力。在计算资源上支持了音视频转码、编辑、模板创作等核心能力的多云调度与动态切流，达到分钟级别的异构容灾。在存储资源上支持了基于磁盘的分级缓存、数据加密、秒传、并行传输等核心能力，作为所有线上服务的底层对象存储，日峰值QPS10w+，峰值带宽100GB/s以上；孵化出包括网关、IAM、跨域同步、私有化架构、推理框架与研发基础库等基础能力，覆盖日常研发50%以上的需求场景，极大提升研发效能，规范日常研发质量，支撑BC端70%以上的平台需求与AI工程场景
- SRE：组建完善的SRE体系，涉及商品化、稳定性与资源管理。商品化方向上，建立了完整的定价模式与自动估价体系，让之前混乱的账单回归正常，并在2024年配合业务完成亿级别的成本梳理；稳定性上沉淀了BC端共用的治理规范（可观测性、容灾、应急预案等方向），并以此推动BC端各个方向完成了大量从一个9到四个9的转变；资源管理上通过拉起各类技术优化专项，如镜像瘦身、分层，ModelMultiplexing，模型分级缓存，依赖分发加速，自动扩缩容，智能运维等手段把整体推理GPU的日均利用率从10%提升到了30%，部分方向AI能力在60%以上。

Senior Software Engineer

Tencent | 2019.5 - 2021.9

主导平台的微服务架构设计和开发，同时为我们的用户提供技术咨询与集群资源管理，平台使用k8s提供调度能力，GO编写管控服务，截止2020年底，平台服务于公司数十种产品，部署POD数十万。

- 从0到1落地了容器平台，并技术BP 10+ 项目从传统架构转型到云原生，其中包含日访问量亿级的项目
- 为平台搭建一套完整的分布式指标采集组件，负责采集整个平台百万级别POD的性能指标与业务指标，截止2020年底，每秒写入指标超过千万级别。
- 编写的高性能分布式任务流框架在中心内推广到了各个小组，帮助解决复杂的工作流，如k8s、redis集群的运维管理，富容器的管理等。
- 基于自研的工作流框架实现了k8s集群节点的自动伸缩与快上快下，只需指定期望数量，其他一切自动完成。
- 负责整个平台的基础设施，包括网关和鉴权等，保证平台的稳定，截止2020年，日请求量千万级别。
- 在公司内推广ApacheApisix，支持7款产品成功落地网关

Software Developer

万汇互联 | 2018.5 - 2019.5

负责社交产品的网关开发与微服务架构设计开发

- 引入Kong作为网关，解放了微服务在AOP层的工作
- 使用DSL构建了一个事件系统，优雅地解决了基于用户行为的虚拟币分发功能

Software Developer

深圳巨鼎医疗设备有限公司 | 2016.3 - 2018.5

负责医院报告打印系统的基础框架设计和开发、带领web团队完成业务需求

- 在两年内通过不断沉淀、优化基础框架与组件，帮助公司核心产品愈发稳定，最后成功孵化，只留下定制化工程师，核心团队解散
- 第一次带团队，带领3人左右的小团队按时按质完成web需求，并且完成了从传统jQuery -> MVC的web转型

Assistant Software Developer

AbeamSystem | 2014.9 - 2016.3

负责ERP系统的二次开发与文档编写

- 接触到了很多项目，所以语言栈丰富，包括：c#/VB/c++/js等

- 由于日企的代码都需要反复review, 培养了自己对代码质量要求高的习惯
- 在日本的一年里, 不断提升日语技能, 能够正常以日语和同事进行工作交流

PROJECTS

ApacheApisix

PMC

Apache下毕业最快的顶级项目之一, 是一个基于 Openresty 的网关项目, 在腾讯服务于数个百万DAU的产品。作为其PMC, 为其贡献过诸如 CORS, BatchRequest等特性, 同时也会参与项目的设计评审与CR。

Kubernetes

Developer

内部云平台的调度层, 是我们为用户提供基础服务的根本, 我一般会编写一些 controller、webhook 以及 operator 来为平台用户提供特性功能。

Prometheus

Developer

CNCF 的毕业项目, 云原生下的观测性大多都是基于本项目实现, 我用于为整个平台提供指标监控和采集方案, 采集每秒千万级别的性能指标和业务指标。

go-restful

Contributor

k8s 用于内部组件通信的 http 框架, 没有任何外部依赖, 同时性能也较高, 该框架也是 go-chassis 的路由框架, 我为其贡献了GoogleAPI 设计规范的 CustomMethod。

go-chassis

Contributor

华为开源的微服务框架, 我用于内部微服务开发, 迭代过程帮助项目提升了性能与稳定性, 因此受邀作为讲师参加了华为赞助的Gopher线下沙龙。

hydra

Contributor

一个实现了oauth2的开源项目, 我用其实现了平台的Oauth2授权, 在使用过程中为项目贡献了一些fixs。

EDUCATION

电子信息工程

大连大学

2010 - 2014

AWARDS

ApachePMC

ApacheApisixPMC

2020

系统架构设计师

软考高级职称——系统架构设计师

2019

PMP

项目管理专业人士资格认证

2019

SKILLS

语言栈

Go/DotNet/Javascript

Lua/C++/Python

HTLM/Css

存储

Mysql/SqlServer/Oracle

Mongo/Etcd/Redis

RabbitMQ/Kafak/Es

LANGUAGES

中文 (Native)

英文 (Good RW/Poor LS)



Designed with ❤️ by [Xiaoying Riley](#) for developers

2024 © Ported to Hugo by [CowboySmall](#)