

马晓晖

电话 13500038851 ☎ mason_joe

🏠 joey.gq ✉ joejoey.ma@gmail.com

技能

- Web开发：React、ReactNative(Expo)、Capacitor、Electron、TypeScript、Tailwind / CSS-in-JS、Redux、Zustand、Zod、Tanstack Query
后端: Node.js、Next.js、Nestjs封装CRUD RESTful API、GraphQL、WebSocket，Middleware、Serverless Vercel、Cloudflare、AWS Lambda/ECS冷启动、Edge分布式微服务，API网关、Redis、Kafka、gRPC
- Web框架：Medusajs、Better Auth、GSAP Motion animations、Aceternity /shadcn UI AntD，熟悉构建工具 Webpack、Vite、Turborepo、Monorepo、pnpm workspaces项目管理性能优化的实现例如代码优化、打包优化、资源优化，能结合实际业务场景进行优化
- DevOps：Prisma、Drizzle ORM、PostgreSQL/D1, R2/S3,并使用Docker镜像容器部署,Kubernetes集群，CDN缓存、负载均衡，Sentry.io事件抓捕、Elastic日志Kibana监控，CI/CD / MLOps、自动化Jest测试、灰度发布、A/B，熟悉 Azure 或其他云计算平台（如 AWS、Google Cloud、Vultr、阿里云等）

工作

HKBN 香港宽频 Hong Kong Broadband Network (2023.8- NOW)

AI ITBS Senior software Engineer

- 从0到1的基建部署上线AI Portal赋权BS-CS、API-Dev-向量知识库体系的AI驱动工具链。

广东力进物流股份有限公司 (2021.2-2023.7)

工程化 全栈架构组 信息主管

- 三端（Web,APP,桌面端）ERP系统(框架重构)数据流并发高，跨部门协作集成，容器部署容灾挑战。

广州新中英跨境有限公司 (2020.2-2021.2)

DevOps 前端开发

- 基于业务跨境电商平台研发,埋点，关联分析，风控数据运营，优化落地上线。

项目

AI Portal业务数据统筹Prompt

Next.js RAG Pipeline Data Lake Kubeflow PyTorch Airflow GSAP

- 从 0 到 1 企业级 AI 中台主导 LLMOps、Microservices 接入检索系统、数据管道、成本与 SLA 通过 API Gateway 聚合多模型与多检索链路 Prompt、检索命中策略、Token 成本、Re-rank、延迟与模型参数以**数据驱动决策集成 Langfuse** 实现用户反馈并推动**全链路观测异步化**，Query / Vector / Prompt 多级缓存体系，引入 **A/B 测试与灰度发布机制**迭代具备可回溯性与可量化结果。整体吞吐能力提升 3 倍、P95 延迟下降 60%+，同时将 **单请求 LLM Token 成本压缩 40%**。
- 构建 **Data Lake + RAG Pipeline** 并由 **Kubeflow + Airflow** 编排实现多业务以文档**TB级**（25,000+ 份工单（表格）、手册（图文混合ppt/pdf）、手写/扫描案例和长合同）语音（销售电话客服记录，访谈例会总结）的自动化接入持续更新 **pgvector + OpenSearch** 分离存储并结合 **HNSW + BM25 + RRF Hybrid Retrieval** 推动**检索体系从“可用”升级为“可验证”**，Top-K 命中率提升50%，上下文噪声降低 30%+，并降低接入成本，覆盖运营、风控、数据分析与企业知识检索等基于 **1M Menu Agent 多 Agent 架构与可配置规则 40+ 核心业务场景** 直接将 AI 回答从反馈 → Q&A 循环以持续改进 **提升为>95%的 recall@k并附带证据链接响应一致性**。使人工平均查询时间 **从10分钟至<30秒** 与重复沟通成本 **整体下降 60%+**，显著提升跨团队协作效率
- 平安钟**视频监控视觉 AI 自建**数据标注、关键帧抽取、LoRA 微调与**模型蒸馏**的训练流水线并推动模型端侧化部署，在真实场景中实现 **误报率降低约 45%（基于 30 天生产监控）** 检出率稳定标注评估集上达到 **92% 准确率**
- AI Portal 前端整体按Figma还原及UX动画参与以CSS-JS、动画GSAP完整交付用户体验与性能目标 **Next.js App Router** 设计多会话并发、流式响应与多模态（对话/绘画/视频生成）输出高复杂度交互系统，通过 **PPR / SSR、组件级 Cache与 Compiler** 优化在持续叠加 AI 功能的情况下保持 **首屏 FCP 秒级稳定、交互延迟降低 50%+**，并系统性解决 SSR Hydration。

ERP/业务财务一体化/进销存物流管理SAAS

WebView PWA Service Worker monorepo Redux ant-design Apollo Cluster

- React + Nest.js + Capacitor + Electron 构建的企业级物流管理系统，Monorepo + 微服务三端部署响应式适配服务于省级/区域/分拨中心、手持终端、司机智控等解决千万级吨数运输业务动态调度订单性能痛点。
- 重构redux状态管理引入以请求缓存重试并发控制实现了实时同步+Optimistic更新+支持弱网离线缓存解决抖动中断业务连续性提高至80%，IndexedDB并封装分页/排序/虚拟滚动、表单验证等加入事件速率优化,解决初始渲染从17秒降低至3秒。
- 实现通信车辆,货车地图导航可视即时人工同步秒级调整、解析Excel、CSV、回单付水印章电子面单等组件结合业务逻辑实现从路由成本控制审批流转使对账周期缩短天 → 小时，四级地址结算体系，末端落地配派拼单抢单、网约车智能合单使空驶低装载率单票成本等以可用绩效指标展现使运输效率整体提升两倍。
- BFF层微服务分析聚合API并实施基于Redis Lua的分级限流与熔断机制，DataLoader解决了 GraphQL N+1 查询难题包含DB Query数响应时间显著下降、JWT令牌动态判断权限、五层权限模型，支持1000+并发连接，处理600+车辆实时位置推送延迟<500ms。
- 构建Kafka数据管道+Kubernetes容器化部署CI/CD自动化Jest/e2e集成测试与持续交付、Sentry性能监控、WebSocket轮询卡顿心跳重连机制，支持40+Topic集群扩展系统高可用架构。

基于node的独立站电商平台集POS线下一体购物系统

Express.js ORM react-i18next Stripe ChatWoot

- 全栈node线上线下一体购物(POS)系统开发，RESTful API 和 MVC架构 ORM封装CRUD接口结合react-scanner扫码入库结账,Express.js定制Stripe支付网关回调WebHook路由转跳。驱动层实现扫码枪小票打印机的硬件级交互打通O2O交易闭环。
- 搭建覆盖率超90% 的用户行为追踪系统，sendBeacon页面关闭时的数据发送，基于采集的各类指标及转化漏斗数据针对性优化LCP/CLS/PU/UV等指标给予运营决策。
- i18next实现多语言资源按需分块加载并定制开发基于ChatWoot的智能工单系统实现了7x24小时自动化客服响应转化率相比提升28%。

教育

华南理工大学-本科-计算机科学与技术-学士学位证书

全国英语等级考试 PETS-3证书 口语5/5