

# DeclK

1605224559@qq.com | hongkun20sme@gmail.com | 上海  
算法工程师 | 大模型推理优化



## 教育背景

南京大学 - 电子信息 - 硕士	2020.09 - 2023.06
研究方向: 三维感知算法	
南京大学 - 材料物理 - 本科	2016.09 - 2020.06
GPA 4.43 / 5.0, 综合排名 11 / 135	

## 工作经历

理想汽车 - 多模态大模型量化、投机采样负责人	2023.07 - 2025.11
-------------------------	-------------------

### • VLM/VLA 模型车端交付

利用 mlc-llm 的机器学习编译系统, 核心参与构建了车端多模态认知大模型, 成为全行业首个全量推送用户的车端大模型。在 mlc-llm 框架中从 0 到 1 构建了 SigLIP、SAM、跨模态 projector 以及 diffusion head 模块, 与 Qwen2 模型构建完整的 VLM/VLA。通过引入 memory bank 流式视频推理机制, 显著压缩视觉编码时延, 最终使 2.1B 参数的 VLM 推理延迟稳定低于 250 ms, 大幅超越原定 500 ms 的基准线

### • 车端大模型量化体系

领导打造了车端 VLM/VLA 模型的高效量化框架, 该框架能够在 10 分钟内完成对模型的量化、编译以及精度评测的完整链路, 以支持上游算法快速发版需求。通过优化 GPTQ 与 AWQ 算法, 完成对模型的 4-bit 压缩, 最终实现的模型精度损失在 0.5% 以内

### • 投机采样训练以及推理框架

领导设计并实现了车端 VLM/VLA 模型的多模态投机采样训练以及推理框架, 实现了 Medusa & EAGLE 双引擎, 分别能够将 decode 时延加速 3x 和 6.9x。通过深度优化 EAGLE 方案, 单步平均命中 15+ tokens, 结合词表裁剪和动态 draft length, 将 decode 时延降低到 50-80 ms, 成为业界首个将多模态 EAGLE 投机采样部署到车端的 SOTA 方案

### • 大模型推理优化服务

领导开发了 FQT (FullQuantTransformer) 通用量化框架, 以及 EasyEagle 通用投机采样框架为整个自动驾驶部门提供大模型推理优化服务。FQT 覆盖 GPTQ/AWQ/SmoothQuant 等主流量化算法, 支持 W4/W8/A4/A8/A16 多种精度, 兼容 Qwen dense、MoE、ViT 等多样模型, 并适配 vLLM、SGLang 等云端量化格式。EasyEagle 在训练侧提供 FSDP、torch compile、梯度累计、张量并行等高效 trick, 并具备了强大的兼容性, 能够将任意 transformers 库当中的模型作为 base model 进行投机采样训练与推理。最新迭代的多模态 EAGLE3 将云端 Agent 模型的投机命中率从 3.86 提升至 5.53 (+43%)

宏景智驾 - 算法实习生	2022.08 - 2022.10
--------------	-------------------

- 在自动泊车场景下负责分割与检测模型的量化感知训练, 将量化模型在地平线芯片以及 Orin 上高效部署

仙途智能 - 算法实习生	2022.04 - 2022.07
--------------	-------------------

- 优化点云目标检测模型, 集成 SC-Conv 自矫正卷积、角点辅助模块及 IoU 修正分支, 提升 mAP 4.71%

## 项目经历

基于角点辅助网络的自集成点云目标检测	2022.01 - 2023.01
--------------------	-------------------

- 通过角点辅助网络与教师-学生蒸馏提升点云目标检测器性能, 利用 SECOND backbone 融合角点与 BEV 特征, 一致性损失提升泛化性。在 ONCE 数据集上 mAP 从 57.03 提升至 63.04。

## 专业技能

- 技术栈: PyTorch, TensorRT, MLC-LLM, CUDA, Transformers
- 算法方向: 多模态大模型、投机采样、模型量化、点云检测、BEV 感知、时序分析

## 其他

- 学业奖学金一等奖 (硕士)
- 人民奖学金二等奖 (本科)
- 语言: 英语 (CET-6)
- 兴趣: 网球 (大网赛全国总决赛男团第六名)