

OPPO 多模态大模型端侧化 应用实践

演讲人：宋晓辉

OPPO 端侧化算法组负责人

AiCon
全球人工智能开发与应用大会

目录

- 01 端侧化算法技术概览
- 02 模型稀疏化压缩
- 03 量化感知训练
- 04 编解码加速
- 05 落地实践
- 06 总结和展望

极客邦科技 2026 年会议规划

促进软件开发及相关领域知识与创新的传播



参会咨询



查看会议

北京

1200人

QCon

全球软件开发大会

会议时间：4月16-18日

- Agentic Engineering
- AgentOps
- 下一代模型架构与推理优化
- AI 原生基础设施
- 知识工程实践
- AI 安全

深圳

1000人

AiCon

全球人工智能开发与应用大会

会议时间：8月21-22日

- Agentic AI
- 轻量化与高效推理
- 多模态应用
- AI + IoT 场景实践
- AI 工业化落地

北京

1000人

AiCon

全球人工智能开发与应用大会

会议时间：12月18-19日

- 大模型架构创新
- 多模态 AI 产业融合
- 具身智能
- AI for Science
- 大模型安全

4月

6月

8月

10月

12月

AiCon

全球人工智能开发与应用大会

会议时间：6月26-27日

- AI Infra 系统工程
- 多 Agent 协作与实践
- 多模态融合
- 模型训练与推理创新
- 数据平台与特征服务

上海

1000人

QCon

全球软件开发大会

会议时间：10月22-24日

- AI Agent
- Vibe Coding
- 智能可观测
- 推理基建
- 模型攻防
- AI x 创造力

上海

1200人

01 端侧化算法技术概览



模型端侧落地的困难

珍贵的内存

终端设备内存有限，算法效果需要一定程度上向**模型体积**和**推理精度**妥协，因此如何设计和优化端侧**模型压缩**算法，利用**有限的内存占用**获得**最佳的算法效果**，为用户提供流畅、好用的端侧AI功能，是端侧化算法持续追求的目标之一。

强耦合的业务

为了减少对用户手机ROM空间的占用，所有端侧算法能力共用同一个基模型，因此基模型迭代需要和众多业务需要保持相同的节奏，这对**工程进度管理**，算法的迭代和测试验收都是很大的考验。

有限的电量


为用户提供端侧AI能力的同时，也不能成为“**电老虎**”，不能制造续航焦虑，持续的下探端侧AI的能耗水平，需要端侧算法、工程和芯片团队的共同努力。

较高的OTA成本

端侧模型体积大，不能高频OTA更新，同时缺乏运营日志，难以敏捷迭代修复问题。因此端侧业务的交付，需要在**算法质量**，**稳定性**，**性能功耗热**等多个维度进行严格的测试。



模型端侧化算法技术概览



02 模型稀疏化压缩

模型稀疏化

模型稀疏化三种范式

结构化稀疏 (剪枝)

0.5	0.8	0.0	0.3
0.0	0.0	0.0	0.0
0.2	0.7	0.0	0.6
0.1	0.9	0.0	0.5

整行/整列置零
通过删除整行或整列参数
减少模型层的维度
实际完成了结构剪枝操作
可直接减少计算量和存储

N:M 结构化稀疏

0.5	0.0	0.8	0.0
0.0	0.2	0.0	0.7
0.6	0.0	0.0	0.4
0.0	0.9	0.5	0.0

2:4 结构化稀疏
每连续4个元素中置零2个
利用 NVIDIA Tensor Core
专门硬件加速支持
可获得计算加速效果

非结构化稀疏

0.5	0.0	0.8	0.0
0.2	0.0	0.0	0.0
0.0	0.7	0.0	0.6
0.0	0.0	0.5	0.0

不规则稀疏模式
通过硬件编码减少权重存储大小
降低 Memory Bound 瓶颈
提升解码速度与降低功耗




结构化稀疏-L0正则化方法

核心思想


为每个参数学习一个可微分的「门控值」(0~1), 训练中自动识别重要参数 (门控→1) 和冗余参数 (门控→0), 实现端到端的稀疏化学习



结构化剪枝: 整行/整列门控值演化



结构化稀疏-L0正则化方法




排序和剪枝两个阶段在训练过程中动态交替进行, 实现了较为平缓的剪枝过程。



结构化稀疏-落地实践

基于OPPO的L0改进算法，从Qwen2-7B剪枝到4B，超过了Qwen1.5-4B的效果。


L0正则化剪枝在Qwen7B->4B的结果



在ColorOS 15.0的端侧基模型剪枝和解码加速的draft model上都有应用。支撑OPPO智慧语音端侧化业务。

非结构化稀疏 (内存压缩)

权重稀疏化过程



稀疏化训练过程



稀疏化训练策略







非结构化稀疏-算法效果



在AndesVL-4B 模型分别进行了 50%、65%、70% 和 75% 四个稀疏度的模型训练，并在image caption和多模态信息抽取任务上进行效果验证：

1. 50% 稀疏度模型在两项测试任务中表现优异，其综合性能指标与原始稠密模型基本持平，甚至展现出轻微的性能优势，表明适度的稀疏化可能带来正则化效应。
2. 随着稀疏度提升至 65%–75%，模型性能呈现可控范围内的温和下降，性能衰减曲线显示：稀疏度每增加 15%，性能损失约 2–3 个百分点，即使在 75% 的较高稀疏度下，模型仍保持核心能力，各项关键指标的下滑幅度均小于 5%，为模型部署提供了显著的效率提升空间。



非结构化稀疏-性能收益

在MediaTek天玑9500芯片上，结合硬件压缩能力，实现速度和内存的大幅度优化。



结论：75% 稀疏度下，解码速度提升 **44.7%**，BPV 降低 **33.6%**，有效实现模型压缩与推理加速的双重优化。

03 量化感知训练



端侧基模型量化感知训练

OPPO自研量化感知训练框架，支持以下feature

1. 高度灵活的点位设置和quantizer模式

可以快速适配新模型，支持权重、激活的per tensor/channel/token/group的asym/sym的fakequantizer设置以及动态、静态的QAT训练模式。

2. 动态精度分配策略

可细粒度识别高敏感权重和激活点位，实现自动化的混合精度QAT。

3. 端到端静态量化

与工程团队、片商紧密合作，通过点位对齐和静态QAT训练，可以将QAT得到的量化编码直接导入到端侧模型中，**绕过PTQ过程**，减少算法迭代过程中的效果不确定性，通过这种方式可以支持低bit量化的高效部署（W2, A8等）。

Model	DocVQA (test)	InfoVQA (test)	TextVQA (val)	ChartQA (test)	Overall
AndesVL-4B-Instruct-Base (PTQ)	93.2	89.0	91.4	89.3	90.7
AndesVL-4B-Instruct-Base (QAT+PTQ)	95.4	95.2	97.5	95.1	95.8

Table 17: Top-1 overlap between AndesVL-4B-Instruct-Base (PTQ) and AndesVL-4B-Instruct-Base (QAT+PTQ) on 4 OCR benchmarks.


通过QAT训练，可以将模型端侧和浮点的输出一致性(Top1-Accuracy)保持在0.95以上。



垂域场景落地-QALFT训练框架

纯浮点模型落地过程中的问题：


- **PTQ损失不可控**：浮点lora优化完成之后，各个业务一起做量化时对彼此的影响不可控制。
- **业务间耦合过重**：每次LoRA更新时，必须对基础模型及所有LoRA进行重新量化，产生显著时间成本。
- **测试资源投入较大**：从浮点模型到端侧落地需经历多环节协同。但是如下图所示，一旦效果不达预期，需要重新迭代整个流程。



QALFT训练框架


为解决上述问题，我们开发了量化感知LoRA微调框架（QALFT）。用户能够使用该工具直接在量化后的模型上进行微调，无需关注模型量化的具体技术细节。这一方式将模型训练与部署流程简化为两个核心步骤：

1. 针对业务场景，基于量化模型进行微调。
2. 评估量化模型在业务场景的实际效果。



QALFT训练框架


- **模块解耦架构**：模型、数据、训练器三方解耦，各组件可在不同训练流程中复用。
- **丰富的训练范式**：适配SFT / 蒸馏等多种训练范式。
- **扩展灵活性**：支持新模型、数据格式、训练方法的可插拔接入。
- **底层平台隔离**：MTK/Qualcomm平台库与数据、训练器等上层设施隔离。
- **零代码化部署**：无需额外代码开发，支持微调、验证全流程操作。



QALFT训练框架


使用QALFT具有以下优点：

- **降低人力成本，缩短部署周期：** 显著减少了传统方案中LoRA相互不独立以及两次效果迭代所需的人力与时间投入。
- **更适配1+N LoRA模式：** 流程与“1+N LoRA”模式更加匹配，即量化的基模型保持通用性和业务无关性，并通过LoRA的方式对业务场景进行适配。
- **更好的算法精度：** 片商提供和端侧推理一致的模型量化推理库，实测算法效果显著优于PTQ方案（端侧效果相比浮点微调损失能控制在3%以内。）



平均效果损失: **QAT+PTQ: -3.93% vs QALFT: -1.43%**

04 编解码加速




KV-Cache压缩&KV-Cache压缩感知训练

端侧长上下文存在的挑战

内存：随着输入长度增加，KV缓存呈线性膨胀，内存占用迅速提升。

计算：由于端侧算力有限，长文本下softmax等计算量急剧膨胀、推理延迟显著增加，制约了长上下文能力的广泛应用。

自研training-free压缩方案&压缩感知训练方案在通话摘要场景的对比



压缩感知训练方案能显著降低cache-eviction算法损失。



解码加速 (speculative decoding)

步骤 1: 草稿模型生成 5 个 token, 验证模型接受前 1 个

今天的天气

很好

, 天上 没有 云朵

✓ 接受

✗ 拒绝 (重新生成)

步骤 2: 重新生成, 接受前 3 个

今天的天气很好,

蓝蓝 的 天

, 白白 的

✓ 接受

✗ 拒绝

3次推理
接受 $1+3+3=7$ 个token。

步骤 3: 重新生成, 全部接受, 完成!

今天的天气很好,

蓝蓝的天白白的云

[END]


✓ 全部接受

解码加速的核心优化问题:

1. 提升草稿的接受率和接受长度。
2. 降低草稿模型的执行成本。

解码加速

采样树(topk & total tokens):



1. topk


- 每次调用小模型时，都只选出topk个词往后扩展，避免层数过大爆炸。
- 草稿模型的ARN \geq topk

2. total_tokens

- 用于最后排序出得分最高的total_tokens个路径进行一次并行验证。
- 目标模型的ARN \geq total_tokens

解码加速

训练流程



推理优化

路径选择、路径扩展策略优化；早停机制。

业务效果

多模态理解场景：

- AndesVL2-4B(aimv2+qwen3-4B): 通过算法和工程侧的联合优化，得到6.7x的端到端加速效果 ($23.3 \text{ t/s} \rightarrow 157 \text{ t/s}$)
- AndesVL-4B(internvit+qwen2.5-3B)，峰值速度达到240+tok/s

05 落地实践

业务落地

智慧语音端侧化

- OS14.0 行业首个端侧7B大模型落地
- OS15.0 自研剪枝蒸馏算法，**升级1+N lora架构**，支持通话、三方应用、视频摘要和实体组合。
- OS16.0 **升级端侧多模态大模型基座**，实现更多场景基模型复用，极致的模型压缩和解码加速，**大幅度降低模型运行内存功耗**。



AI搜索、记忆仓（多模态能力）

- 提供端侧相册caption能力，支撑AI搜索业务。
- 提供端侧相册卡证信息抽取能力，支撑记忆仓-自动填充业务。

技术预研

融合芯片级上下文加速技术

(Prompt 压缩技术和 kv cache eviction 技术)

端侧支持处理

128K 超长上下文

可本地处理

20 万字级文档

(如 300 页书籍)

赋能法律、医疗、
教育等专业场景分析

突破端侧能力边界

端侧超长上下文支持



技术预研

极致模型内存压缩技术结合先进解码加速技术，
通用场景峰值推理速度达

240 t/s
高效办公快人一步

端侧极速生文





技术预研

AI一键闪记端侧版，全场景啥都能记

端侧高效多模态信息处理

4s 完成多次 4B 模型推理

响应速度不输云侧，无网也能随心记

端侧一键闪记



06 总结和展望

总结与展望

可能用在哪里



端云协同的agent应用

隐私和个性化

新硬件、具身智能

开放的端侧算力算法服务

技术上还需要优化什么



面向NPU的高性能架构

模型量化压缩、推理加速

OS层面的资源调度、模型更新

成熟稳定的开发工具链

极客邦科技 2026 年会议规划

促进软件开发及相关领域知识与创新的传播



参会咨询



查看会议

北京

1200人

QCon

全球软件开发大会

会议时间：4月16-18日

- Agentic Engineering
- AgentOps
- 下一代模型架构与推理优化
- AI 原生基础设施
- 知识工程实践
- AI 安全

深圳

1000人

AiCon

全球人工智能开发与应用大会

会议时间：8月21-22日

- Agentic AI
- 轻量化与高效推理
- 多模态应用
- AI + IoT 场景实践
- AI 工业化落地

北京

1000人

AiCon

全球人工智能开发与应用大会

会议时间：12月18-19日

- 大模型架构创新
- 多模态 AI 产业融合
- 具身智能
- AI for Science
- 大模型安全

4月

6月

8月

10月

12月

AiCon

全球人工智能开发与应用大会

会议时间：6月26-27日

- AI Infra 系统工程
- 多 Agent 协作与实践
- 多模态融合
- 模型训练与推理创新
- 数据平台与特征服务

上海

1000人

QCon

全球软件开发大会

会议时间：10月22-24日

- AI Agent
- Vibe Coding
- 智能可观测
- 推理基建
- 模型攻防
- AI x 创造力

上海

1200人

THANKS

探索 AI 应用边界

Explore the limits of AI applications

AiCon

全球人工智能开发与应用大会