IPADS
INSTITUTE OF PARALLEL
AND DISTRIBUTED SYSTEMS

SJTU

异构算力硬件调度关键技术研究

陈 榕

上海交通大学

2025. 2

个人情况

陈榕

- 并行与分布式系统研究所（IPADS），上海交通大学

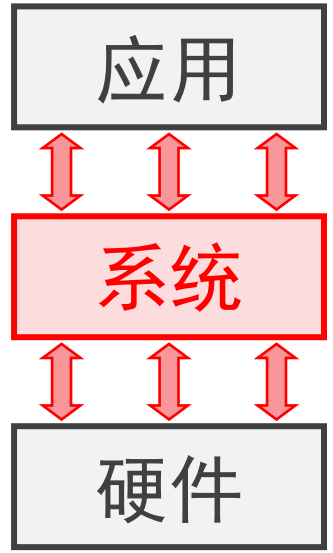

研究领域：基础系统软件（操作系统、分布式系统等）

- ACM Distinguished Member

  “ for contributions to improving the performance and scalability of distributed systems ”

- OSDI/SOSP（13篇）、最佳论文奖（EuroSys 2024/2015）
- 2020年 华为“奥林帕斯先锋奖”（第一完成人）

更多信息请见：https://ipads.se.sjtu.edu.cn/rong_chen

系统软件研究

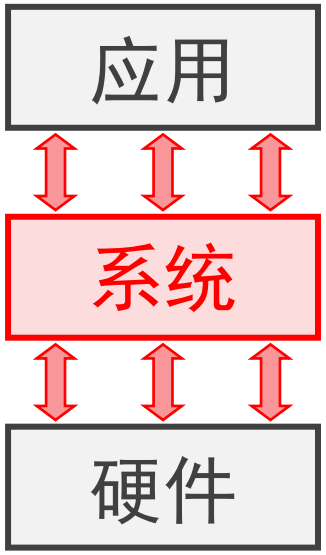

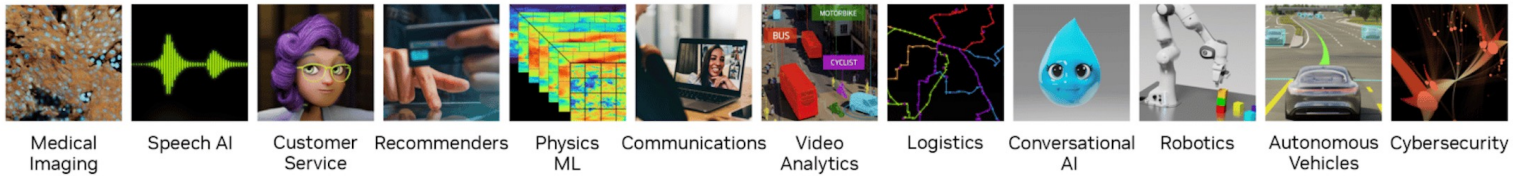

内核、框架、工具 …

系统软件研究

应用

系统

硬件

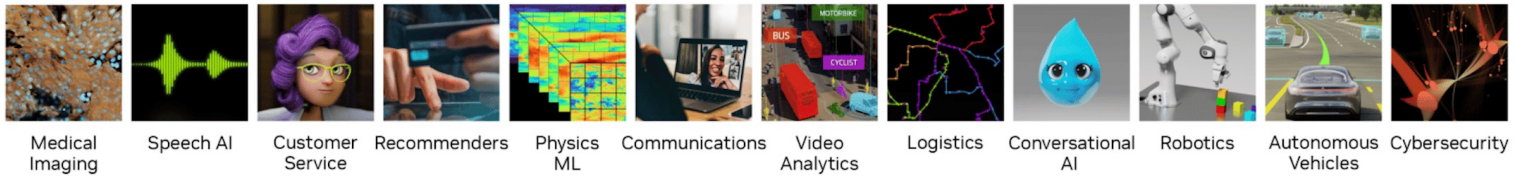

发展快

内核、框架、工具 …

周期长

CPU GPU / TPU / NPU NVM RDMA DPU SmartSSD

演进快

系统软件研究

应用

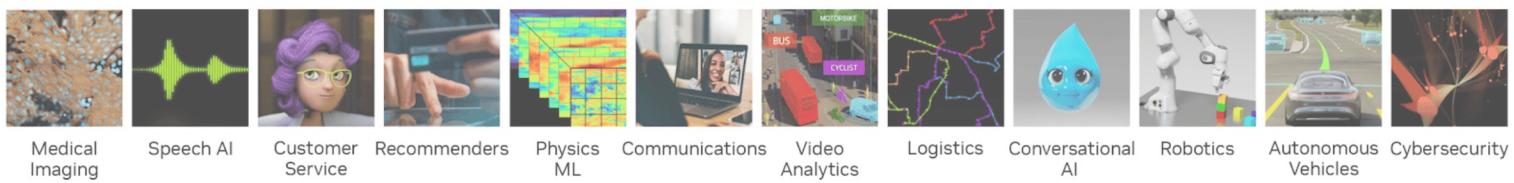

发展快

需求

高吞吐、低时延、可扩展、大规模 …

发展趋势

系统

内核、框架、工具 …

源自"共性"

能力

算力、存力、带宽、持久、隔离 …

演进趋势

硬件

演进快

系统软件研究——智能时代

应用

需求

系统

能力

硬件

智能应用

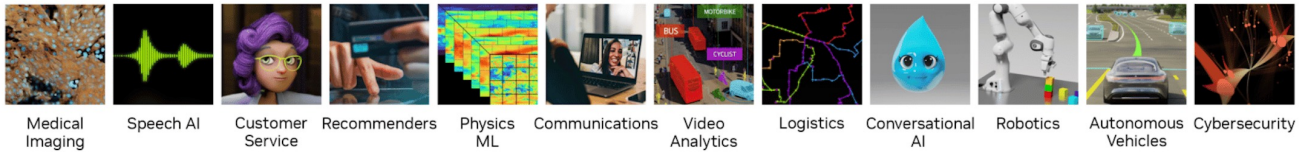

系统软件研究——智能时代

应用

需求

系统

能力

硬件

智能应用

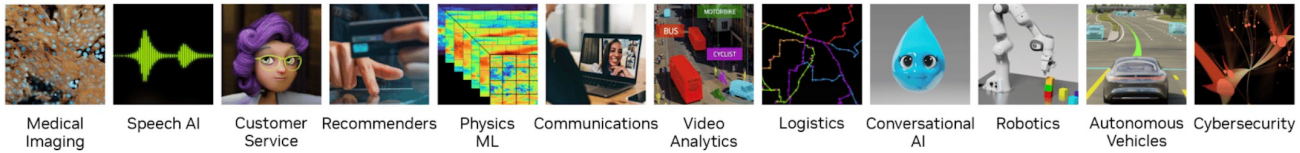

大算力

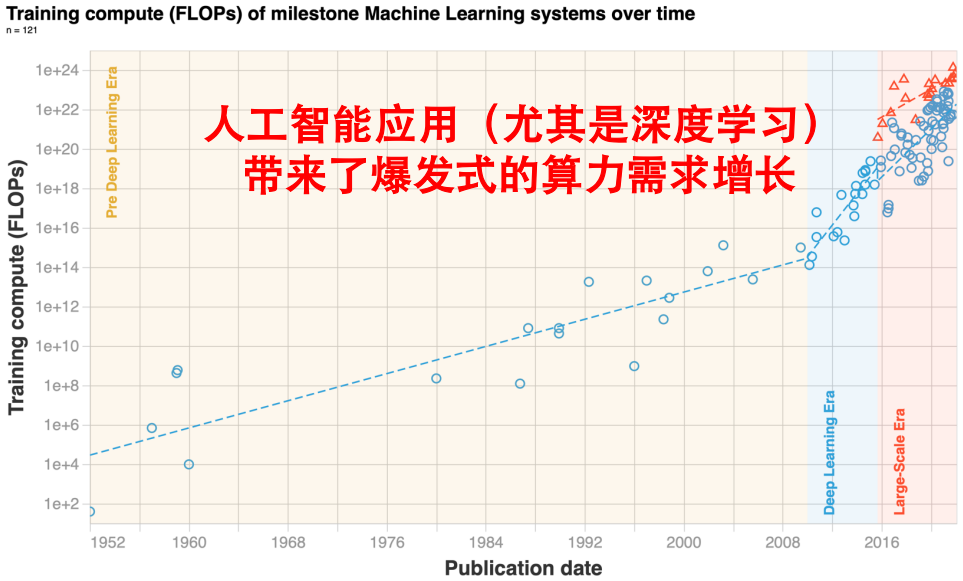

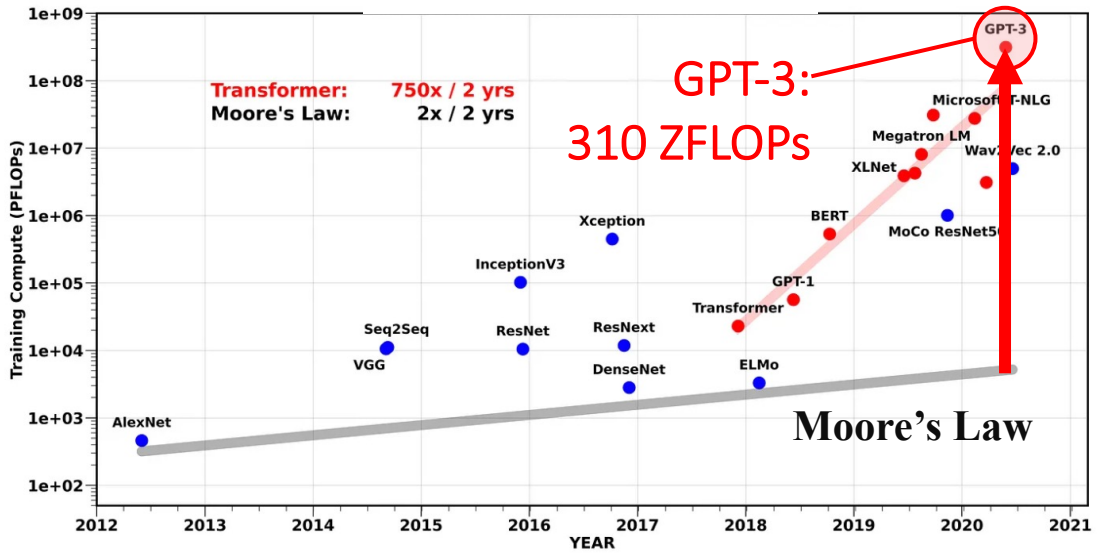

系统软件研究——智能时代

应用

需求

系统

能力

硬件

智能应用

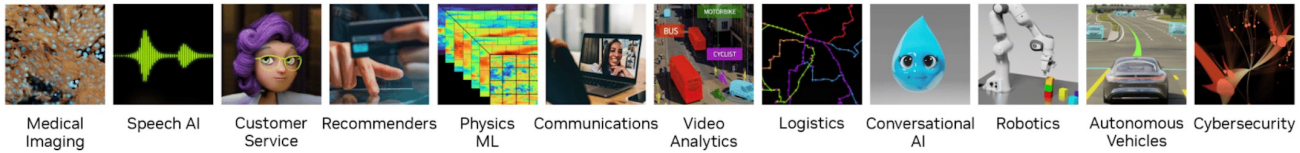

大算力 ＋ 强实时、高性价比、大内存、..

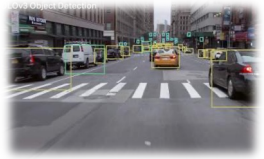

智能车

1. 障碍物检测
2. 红绿灯识别
3. 语音助理
4. 疲劳监测
5. …

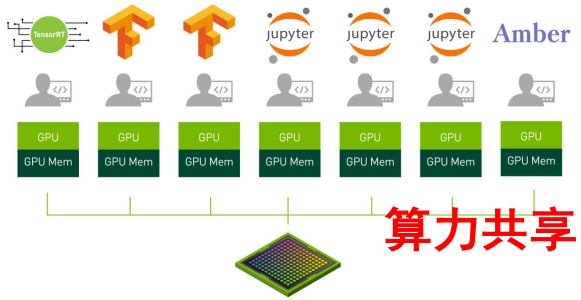

算力共享

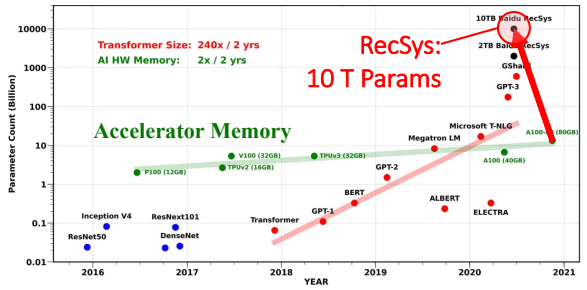

内存墙

典型DNN任务： 3.5～13.6ms

Model	ResNet	DenseNet	VGG	Inception	Bert
#Kernels	307	207	55	146	205
Exec. Time	13.6	3.5	4.4	8.3	5.4

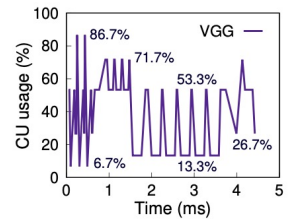

算力需求
亚毫秒级
剧烈波动

系统软件研究——智能时代

应用

智能应用

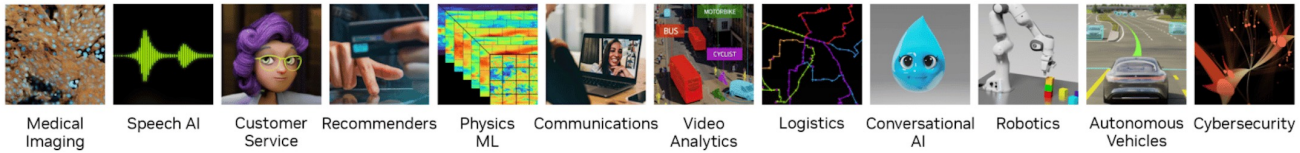

需求

大算力 ＋ 强实时、高性价比、大内存、..

系统

GPU

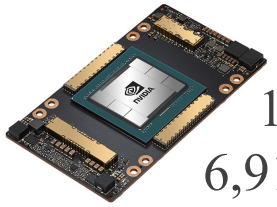

A100
108 SMs
6,912 cores

TPU / NPU / ASIC ...

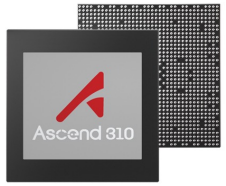

NVLink / NVSwitch / RDMA

900GB/s total

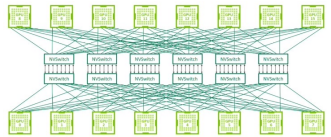

3.6TB/s BW

能力

大算力、领域加速、异构互联

硬件

GPU、NPU/XPU、NVLink/NVSwitch/RDMA

系统软件研究——智能时代

应用

需求

系统

能力

硬件

智能应用

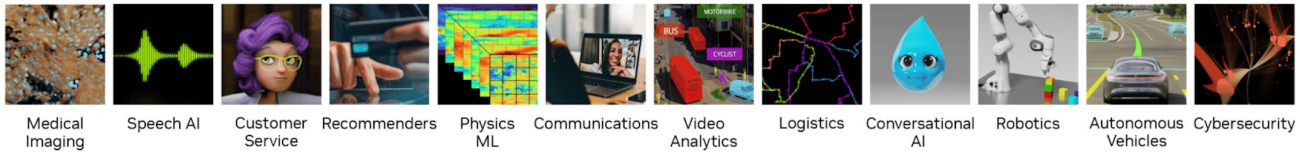

大算力 ＋ 强实时、高性价比、大内存、..

核心功能 — 系统框架/服务

直通式 — 操作系统

异构算力

操作系统

关键技术

大算力、领域加速、高速互联

GPU、NPU/XPU、NVLink/NVSwitch/RDMA

系统软件研究——智能时代

应用

智能应用

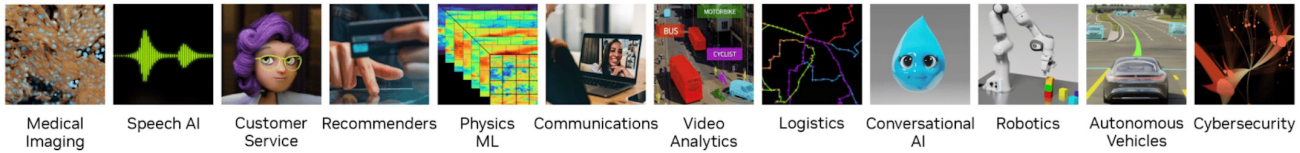

需求

大算力 + 强实时、高性价比、大内存、..

系统

核心功能 — 系统框架/服务

异构算力

操作系统

关键技术

直通式 — 操作系统 — 核心功能

能力

大算力、领域加速、高速互联

硬件

GPU、NPU/XPU、NVLink/NVSwitch/RDMA

算力硬件繁荣

GPU

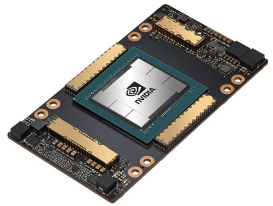

TPU

NPU

SoC

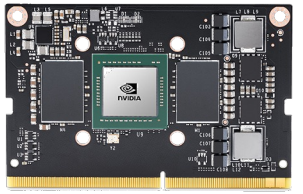

AI·PC

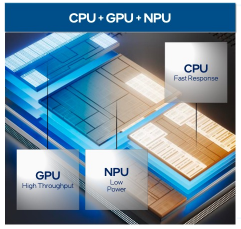

What is an AI PC?

A PC with new NPU silicon that brings new AI experiences in productivity, creativity, and security through a combination of the CPU, GPU, and the NPU.

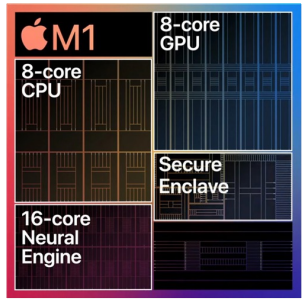

AI·PC 是一个“混合体”

在硬件上集成了混合AI算力单元

且能够本地运行个人大模型

创建个性化的本地知识库

实现自然语言交互

——《AI·PC产业（中国）白皮书》

算力硬件多任务调度现状

GPU　　TPU　　NPU　　SoC

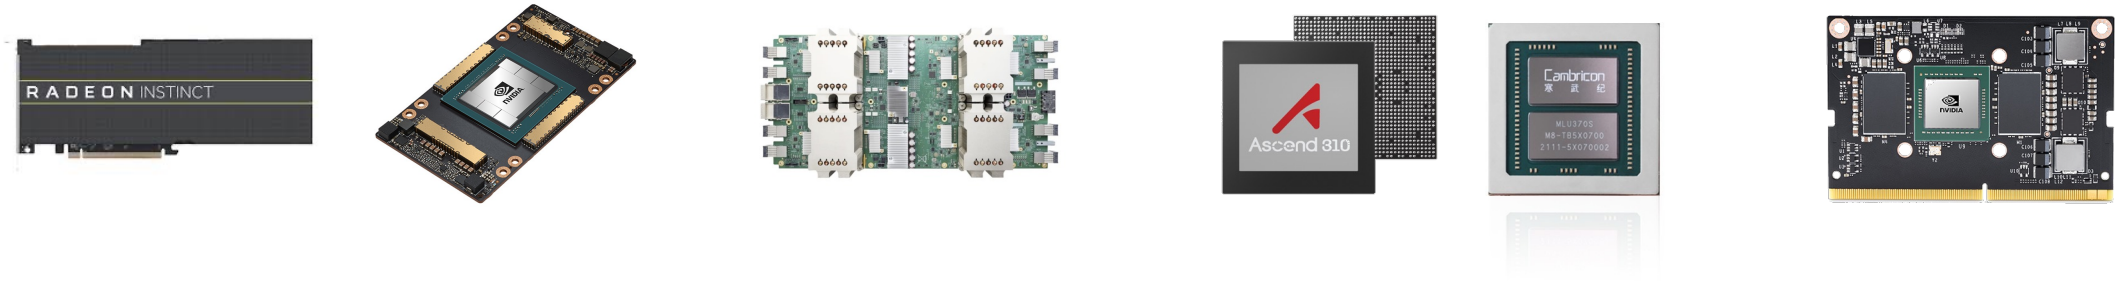

现有算力硬件（XPU: GPU / NPU / DSA / …）**任务调度方法**

× **硬件调度**：功能有限（First-Come-First-Serve, RR）、不同硬件差异巨大

× **软件调度**：绑定特定软硬件功能（+修改）、实现工作量大、方法迁移困难

多任务调度问题演示

NPU
原生调度

NPU
抢占式调度

XPU
协同调度

App#1: https://github.com/fangfufu/Linux-Fake-Background-Webcam
App#2: https://github.com/ggerganov/whisper.cpp

GPU多任务调度

GPU

高并发算力

GPU Architecture
(Nvidia Ampere)

1 GPU
x 8 GPCs / GPU
x 8 TPCs / GPC
x 2 SMs / TPC

= 128 SMs*

Streaming
Multiprocessor

2048 Thds/SM

GPU任务调度

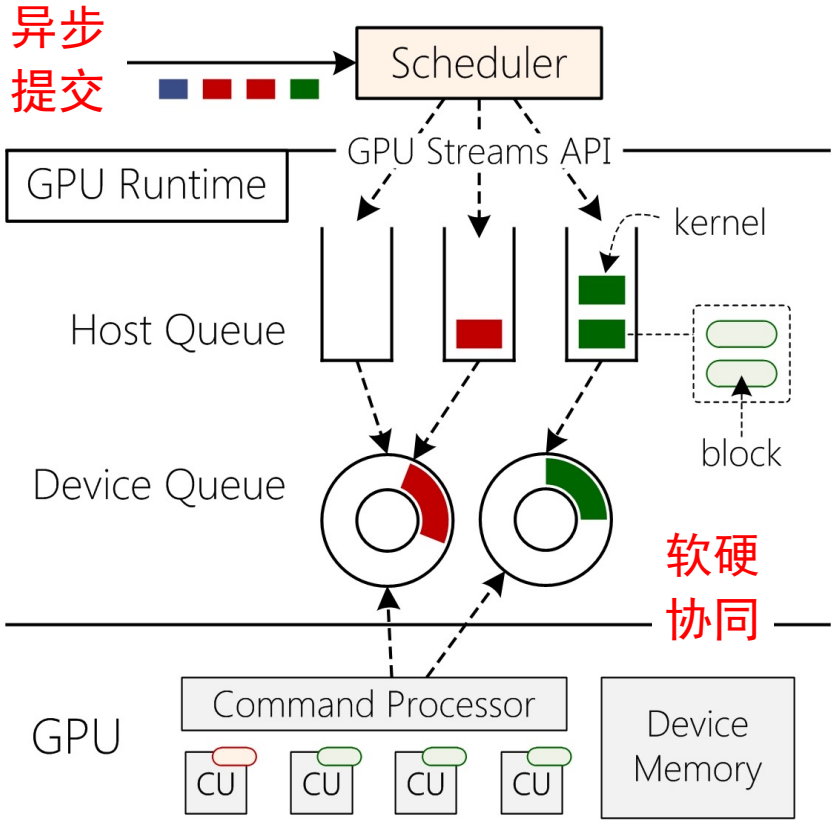

* GPU调度单元 NVIDIA使用SM、ARM使用CU

GPU多任务调度

GPU 

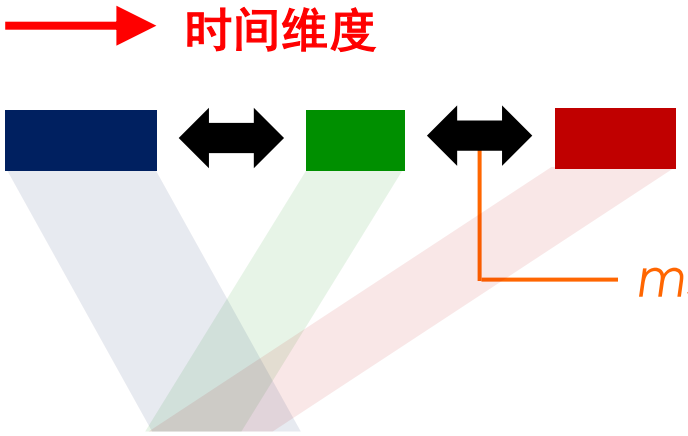

vs. CPU 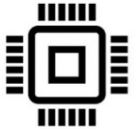

- 执行时间更长（5~100*ms*）
- 调度延迟更低（~5*μs*）

典型DNN推理任务：3.5～13.6*ms*

Model	ResNet	DenseNet	VGG	Inception	Bert
#Kernels	307	207	55	146	205
Exec. Time	13.6	3.5	4.4	8.3	5.4

Testbed：AMD Radeon Instinct MI50 GPU

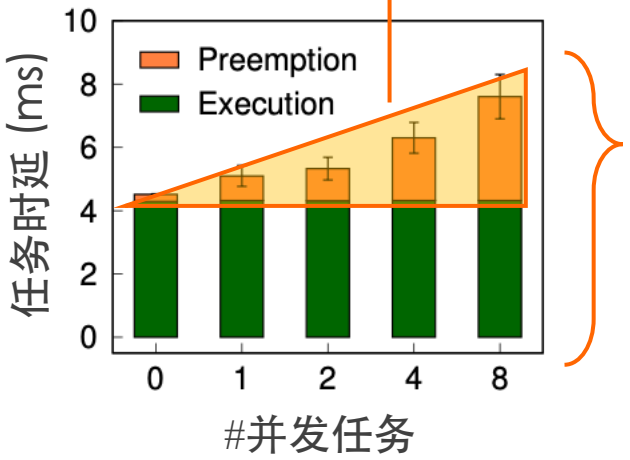

调度开销
接近一半 *

关键技术：GPU实时任务抢占

* 未考虑GPU内存切换、任务加载等开销

GPU实时任务抢占

问题/挑战

1. 大算力硬件状态多
任务切换慢 } 300μs

GPU A100 

- 128 SMs
- 256 KB regs/SM
- 164 KB shmem/SM

 CPU

$<1\mu s$

切换延迟

思路/方法

关键洞见：GPU任务多有“幂等性”

重置执行中的任务（不保存状态）

切换延迟 $5\mu s$

GPU实时任务抢占

问题/挑战

1. 大算力硬件状态多
   任务切换慢 } 300μs

GPU A100 

- 128 SMs
- 256 KB regs/SM
- 164 KB shmem/SM

CPU 

$<1\mu s$

切换延迟

2. 软硬协同异步提交
   任务清理慢 } >1ms

典型DNN推理: 50~300+任务

- ResNet(307), BERT(205), VGG(55)

思路/方法

关键洞见：GPU任务多有“幂等性”

重置执行中的任务（不保存状态）

切换延迟 $5\mu s$

关键设计：垂直全栈清理

[软] Host Qs: 软件重置队列

[软-硬] Dev Qs: 编译插桩+主动退出

[硬] GPU SM: 硬件指令重置

} ~30μs 清理延迟

GPU多任务调度

Microsecond-scale Preemption for Concurrent GPU-accelerated DNN Inferences

- 平台：量产GPU（AMD MI50 GPU）、开源软件栈（AMD ROCm）
- 支持优先级调度：高优先级（实时任务 / RT）、低优先级（后台任务 / BE）
- 多任务执行：<2% RT任务延迟影响、7.7×吞吐提升、百倍任务抢占延迟降低

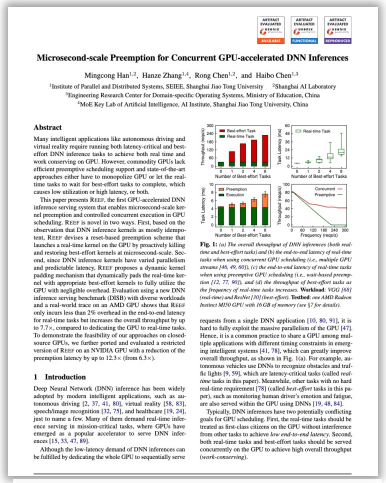
Microsecond-scale Preemption for Concurrent GPU-accelerated DNN Inferences

OSDI 2022

“首次在量产GPU上实现了微秒级任务抢占和动态可控算力共享[1]”

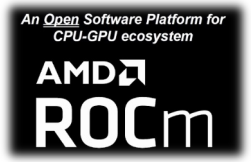

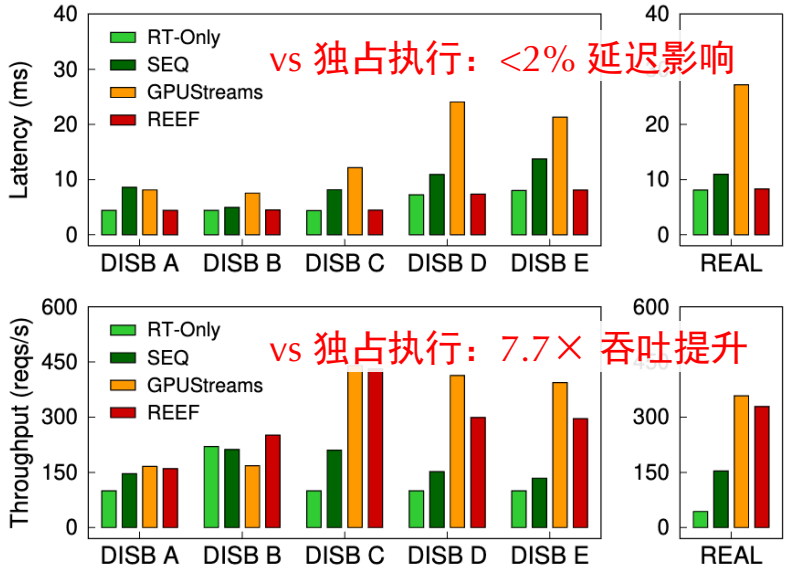

[1] Microsecond-scale Preemption for Concurrent GPU-accelerated DNN Inferences. OSDI 2022.

从“专用”到“通用”

- 利用AMD GPU 重置能力
- 修改驱动、运行时、应用
- 实现：5,500 LoC（C++）

AMD GPU

开源软件栈
（ROCm）

✓ 抢占性能好、灵活性高

× 硬件/软件栈依赖性强

× 开发/部署/升级难度大

OSDI 22

成果得到学界权威会议认可

[1] Microsecond-scale Preemption for Concurrent GPU-accelerated DNN Inferences. OSDI 2022.

从“专用”到“通用”

- 利用AMD GPU 重置能力
- 修改驱动、运行时、应用
- 实现：5,500 LoC（C++）

- 利用NV GPU时间片机制
- 进程级调度、不兼容MPS
- 实现：100 LoC（C++）

AMD GPU

开源软件栈
（ROCm）

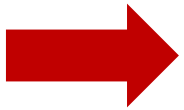

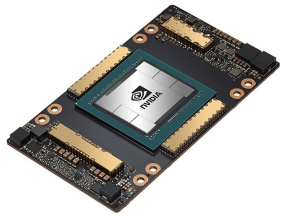

NV GPU

闭源软件栈
（CUDA）

✓ 开发/部署难度低

× 硬件/软件栈依赖性强

× 功能和应用场景受限

滴滴

滴滴当代及下一代
自动驾驶组成部分

从“专用”到“通用”

- 利用AMD GPU 重置能力
- 修改驱动、运行时、应用
- 实现：5,500 LoC（C++）

- 利用NV GPU时间片机制
- 进程级调度、不兼容MPS
- 实现：100 LoC（C++）

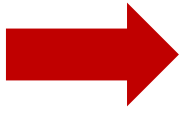

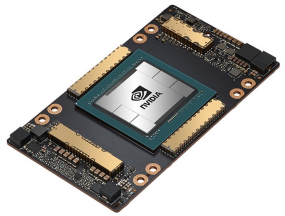

AMD GPU

开源软件栈
（ROCm）

NV GPU

闭源软件栈
（CUDA）

高优先级　　低优先级

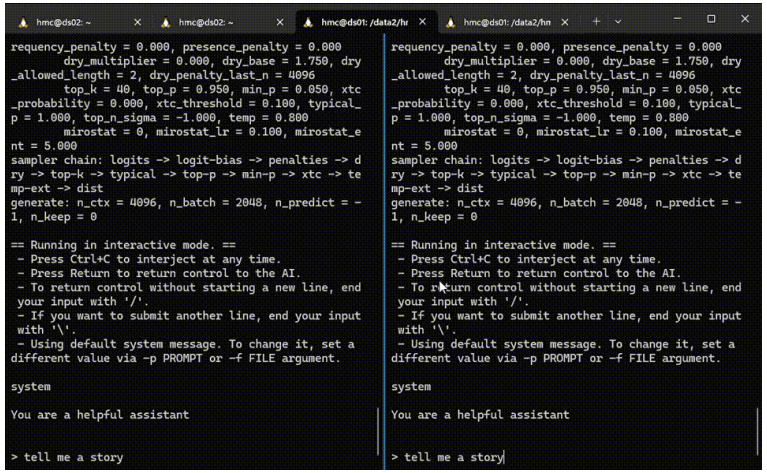

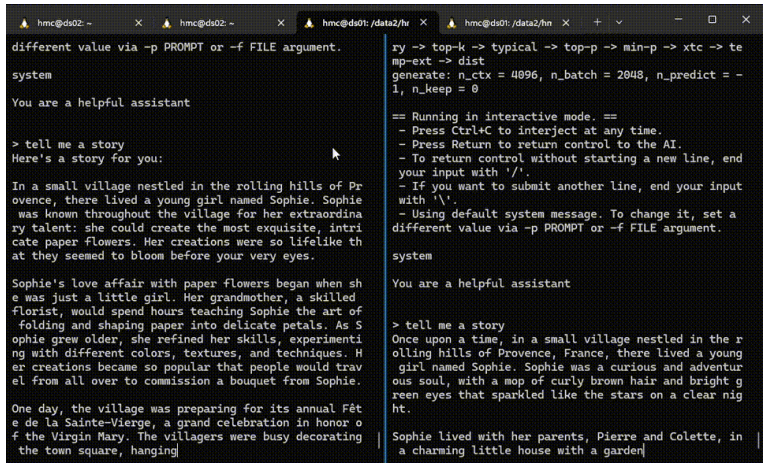

从“专用”到“通用”

- 利用AMD GPU 重置能力
- 修改驱动、运行时、应用
- 实现：5,500 LoC（C++）

- 利用NV GPU时间片机制
- 进程级调度、不兼容MPS
- 实现：100 LoC（C++）

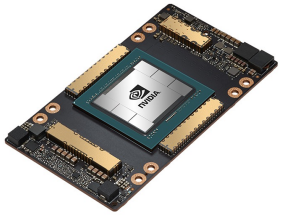

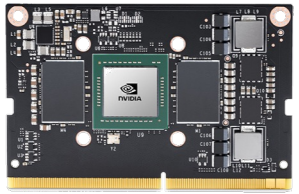

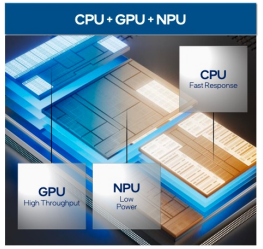

AMD GPU

开源软件栈
（ROCm）

NV GPU

闭源软件栈
（CUDA）

XPU多任务调度需求

Portability: **方法难以跨硬件移植**

- × 依赖特定硬/软件特征，难以复用
- × NPU/AI芯片：无抢占调度方法

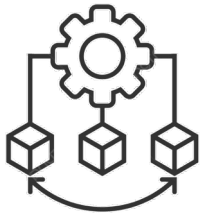

Uniformity: **调度抽象和接口不统一**

- × 调度策略难以在不同平台迁移
- × 难以实现多XPU的混合协同调度

Evolvability: **软硬件实现紧密耦合**

- × 很难集成新发布或未公开硬件特性
- × 很难排除对过时或禁用功能的依赖

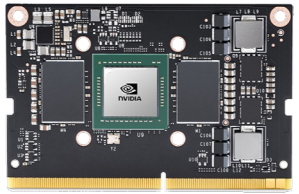

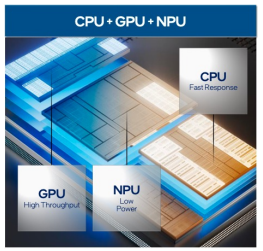

通用XPU多任务调度

问题/挑战

1. 如何提供XPU通用调度？

× XPU软件栈闭源、复杂

包括：驱动、运行时、应用

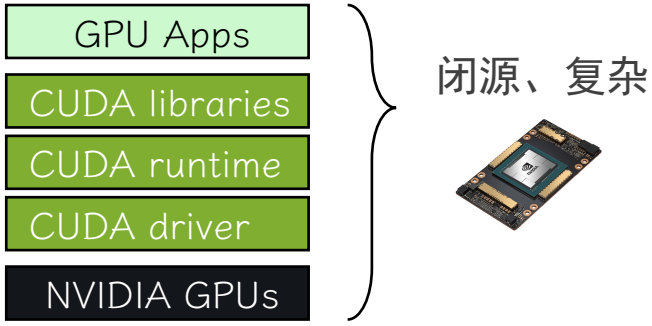

× XPU软件栈不兼容

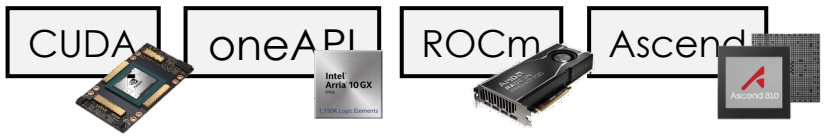

思路/方法

关键思路：借鉴内核的统一抽象设计

	文件系统	任务调度
抽象：	File	Preemptive Queue
接口：	read/write +OPTs	submit/wait +OPTs
架构：	VFS: EXT3, NFS, ..., RAMFS	VQueue: GPU, NPU, ..., Remote

统一接口

~500 LoC

~50 LoC

Cloud

通用XPU多任务调度

问题/挑战

2. 如何支持不同种类XPU？

× XPU硬件架构差异大

GPU: CUDA/ROCm 程序

NPU: 预设命令/功能

× XPU硬件实现差异大

- 提交/等待（基础）
- 中断
- 计算单元重置
- 内存刷新
- . . .

思路/方法

关键思路：基于能力的多级硬件模型

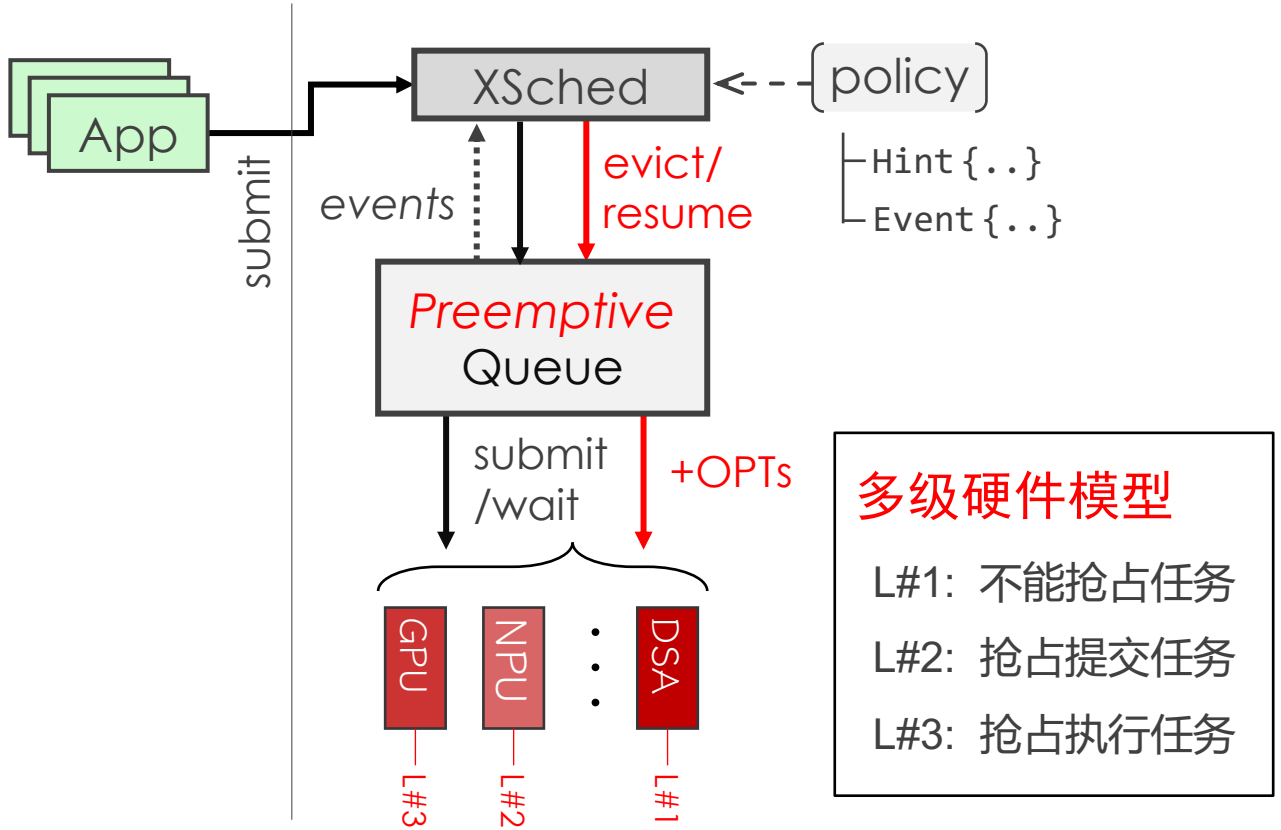

通用XPU多任务调度

Preemptive Scheduling for Diverse XPUs using Multi-level Hardware Model

- 支持各类XPU（类型、品牌、型号）
- 动态调用劫持、统一调度接口、灵活分级实现

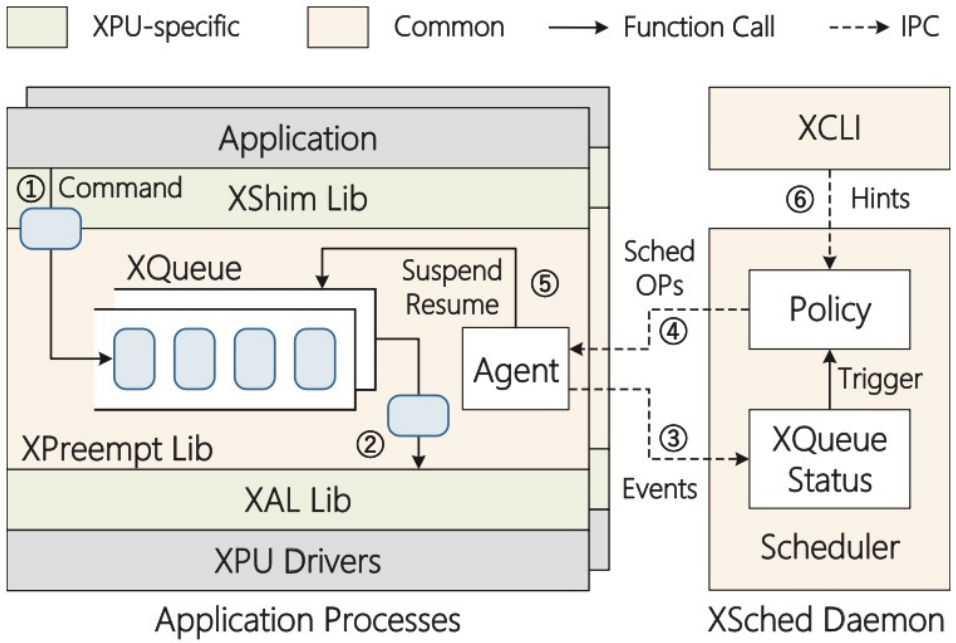

Hardware	Driver	XShim	Lv1	Lv2	Lv3
NVIDIA K40m NVIDIA GV100	CUDA	486	**549**	622 693	○ 265
AMD MI50	HIP	504	**912**	●	●
Intel Arc iGPU Intel NPU3720	LevelZero	456	**301**	● 240	● ○
Ascend 910b	ACL	177	**291**	●	○
NVIDIA DLA	CUDLA	213	**232**	○	○
NVIDIA OFA NVIDIA PVA	VPI	220	**206**	○ ○	○ ○

通用XPU多任务调度

Preemptive Scheduling for Diverse XPUs using Multi-level Hardware Model

- 支持各类XPU（类型、品牌、型号）
- 动态调用劫持、统一调度接口、灵活分级实现

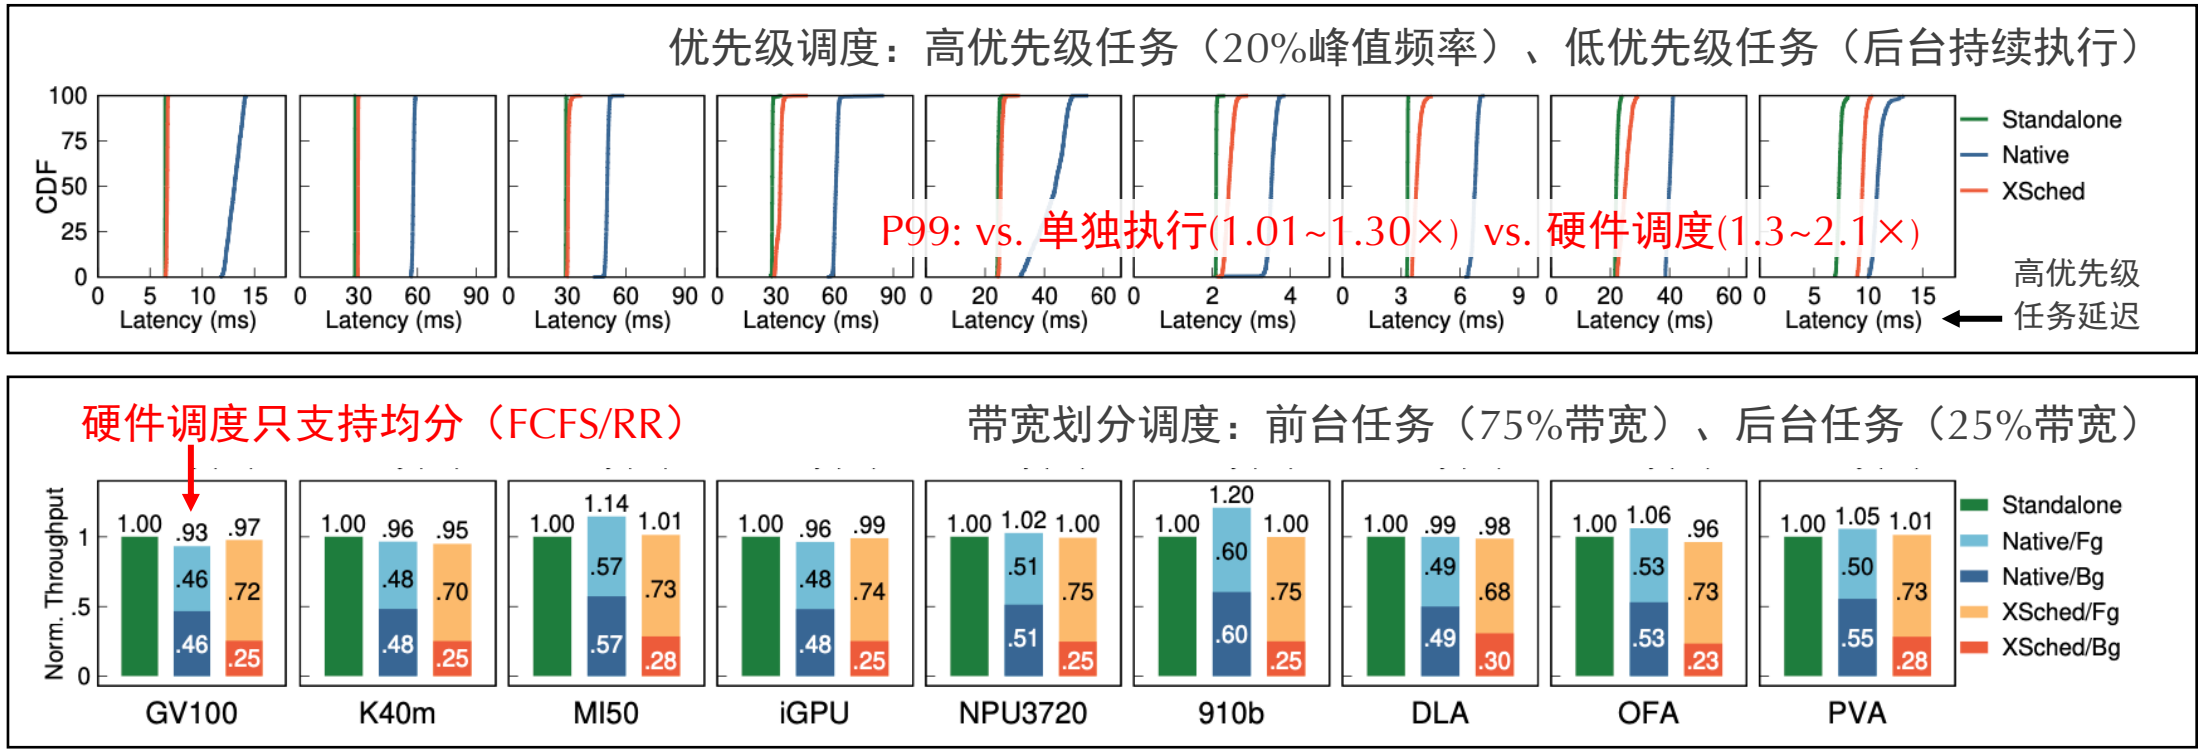

小结 & 感谢

应用和硬件的发展演进是系统软件研究的**原动力**

“应用需求”与“硬件能力”是系统软件研究的**重要抓手**

“赋能赋智”带来**算力外需求**，亟需基础系统软件的**关键支撑**

我们的一些初步探索——**异构算力硬件调度**

感谢！

更多信息请见：https://ipads.se.sjtu.edu.cn/rong_chen