IPADS
INSTITUTE OF PARALLEL AND DISTRIBUTED SYSTEMS

SJTU

「大模型/AIGC与智能化基础软件」论坛

面向智能应用的算力硬件调度与管理

陈 榕

上海交通大学

南京 · 2024.1

个人情况

陈榕

- 并行与分布式系统研究所（IPADS），上海交通大学（2012）

研究领域：**基础系统软件（操作系统、分布式系统等）**

- OSDI/SOSP（12篇）、EuroSys/ATC（12篇）
- 最佳论文奖：EuroSys 2015、ICPP 2007
- 2020年华为“奥林帕斯先锋奖”（第一完成人）

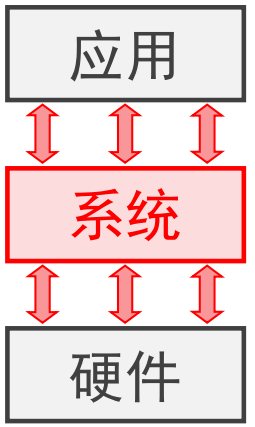

更多信息请见：https://ipads.se.sjtu.edu.cn/rong_chen

系统软件研究

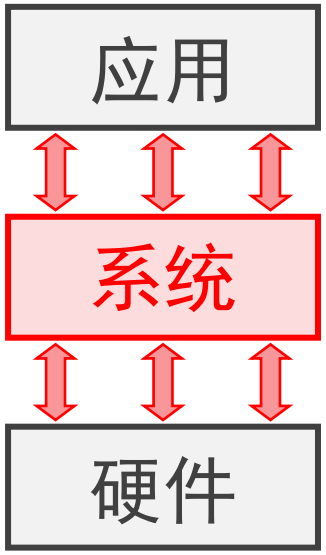

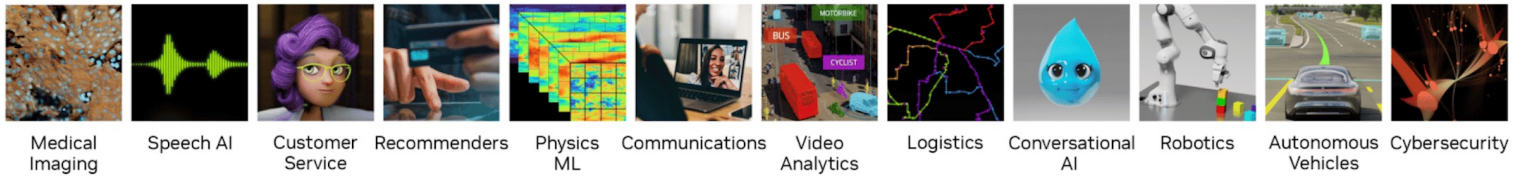

内核、框架、工具 …

系统软件研究

应用

系统

硬件

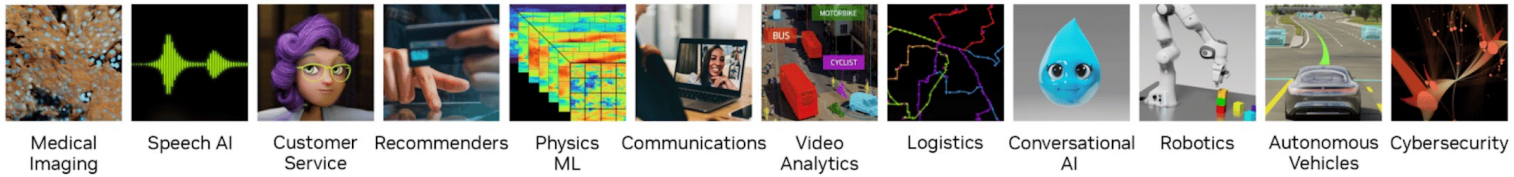

发展快

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

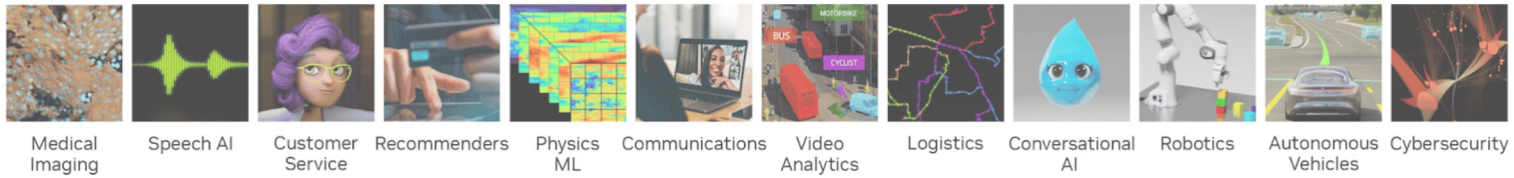

发展快

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

应用

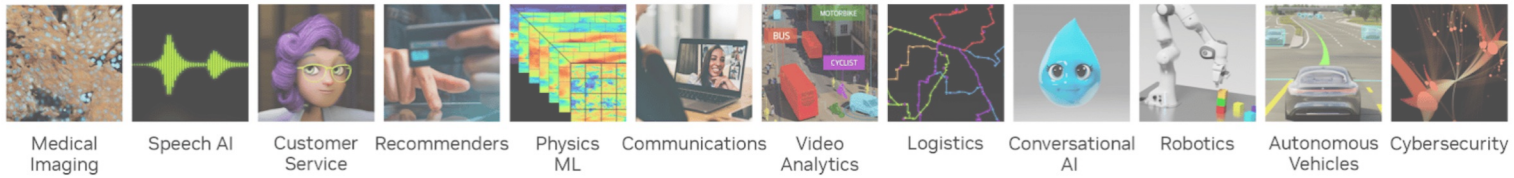

发展快

需求

高吞吐、低时延、可扩展、大规模 …

发展趋势

顺势而为

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

应用

发展快

需求

高吞吐、低时延、可扩展、大规模 …

发展趋势

顺势而为

系统

内核、框架、工具 …

迎难而上

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

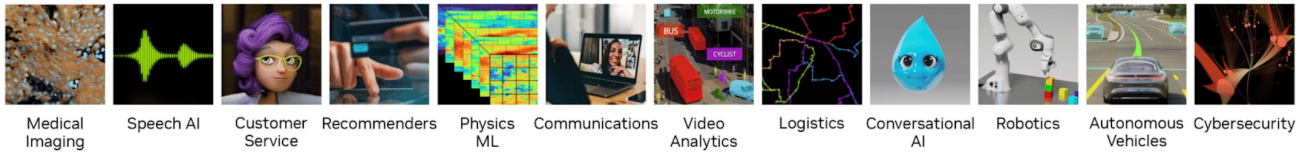

系统软件研究——智能时代

应用

需求

系统

能力

硬件

智能应用

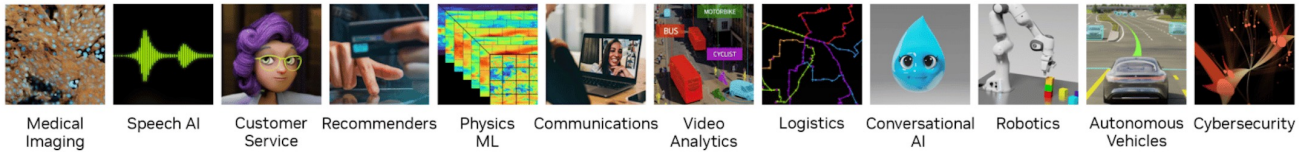

大算力

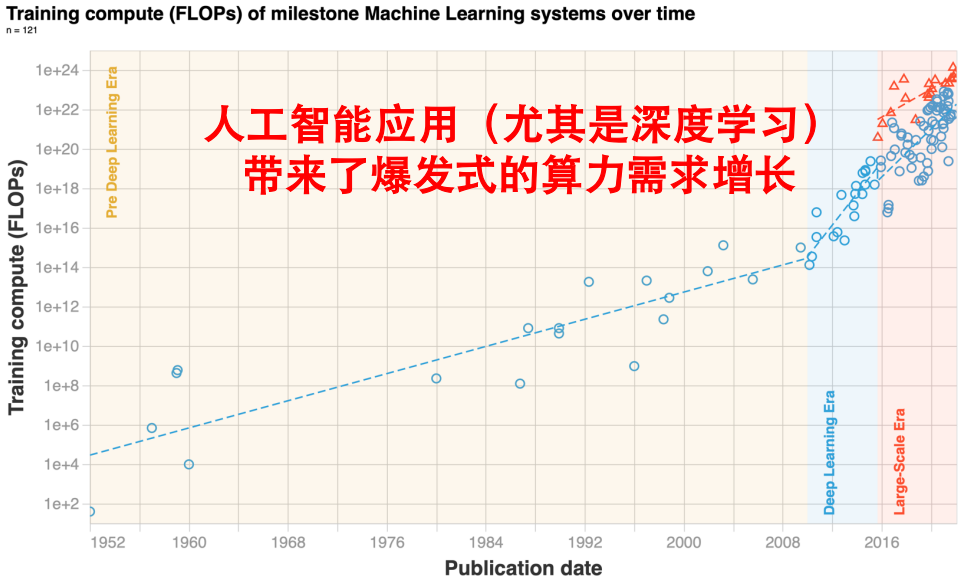

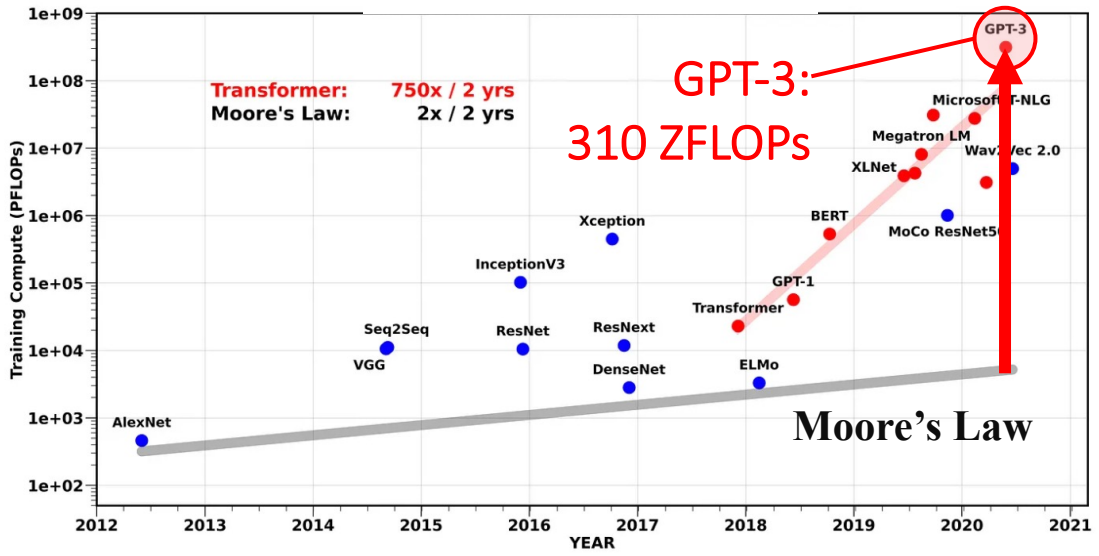

系统软件研究——智能时代

应用

需求

系统

能力

硬件

智能应用

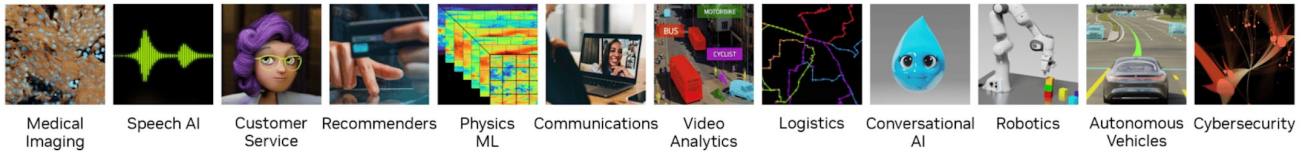

大算力 ＋ 强实时、高性价比、大内存、..

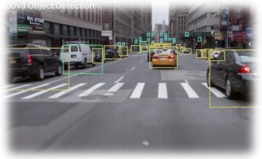

智能车

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

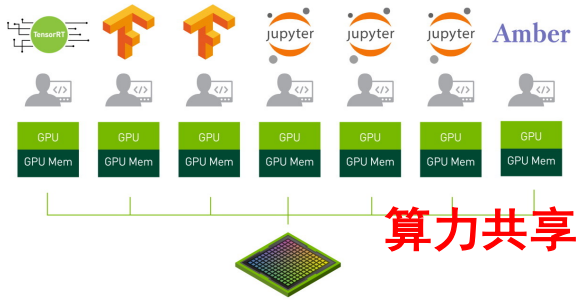

算力共享

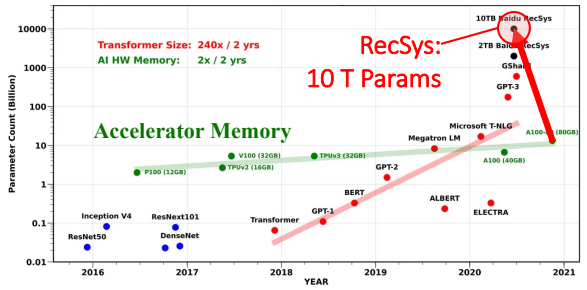

内存墙

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

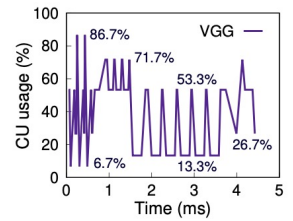

算力需求
亚毫秒级
剧烈波动

系统软件研究——智能时代

应用

智能应用

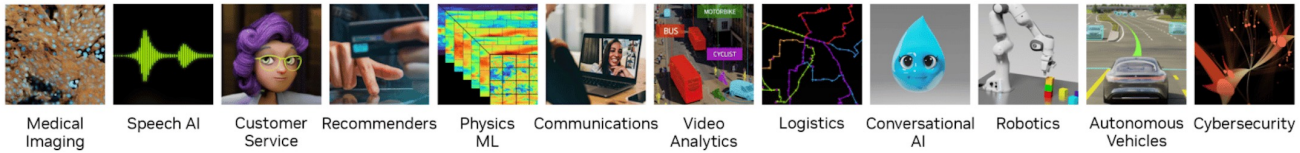

需求

大算力 ＋ 强实时、高性价比、大内存、..

系统

GPU

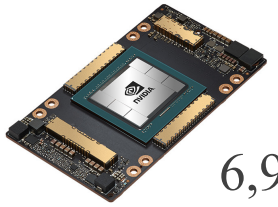

A100
108 SMs
6,912 cores

TPU / NPU / XPU ...

NVLink / NVSwitch

900GB/s total

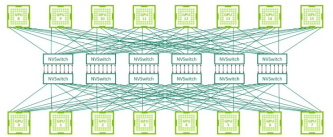

3.6TB/s BW

能力

大算力、领域加速、高速互联

硬件

GPU、NPU/XPU、NVLink/NVSwitch/CXL

系统软件研究——智能时代

应用

智能应用

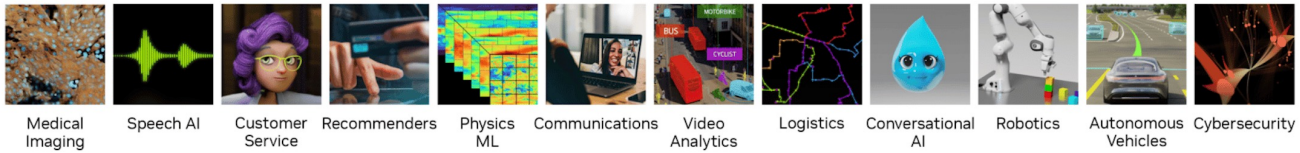

需求

大算力 ＋ 强实时、高性价比、大内存、..

系统

系统框架/服务

操作系统

顺势而为

“人工智能”操作系统关键技术

能力

大算力、领域加速、高速互联

硬件

GPU、NPU/XPU、NVLink/NVSwitch/CXL

系统软件研究——智能时代

应用

智能应用

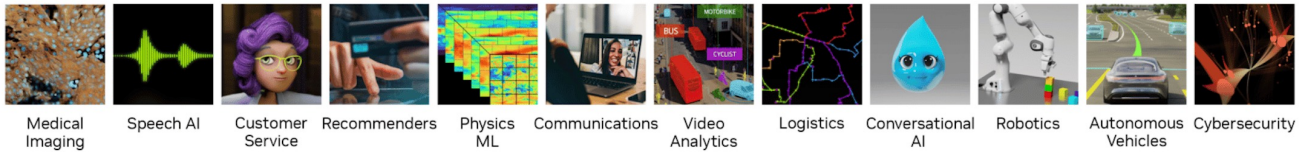

需求

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

直通式 —— 操作系统

顺势而为

“人工智能”操作系统关键技术

能力

大算力、领域加速、高速互联

硬件

GPU、NPU/XPU、NVLink/NVSwitch/CXL

系统软件研究——智能时代

应用

智能应用

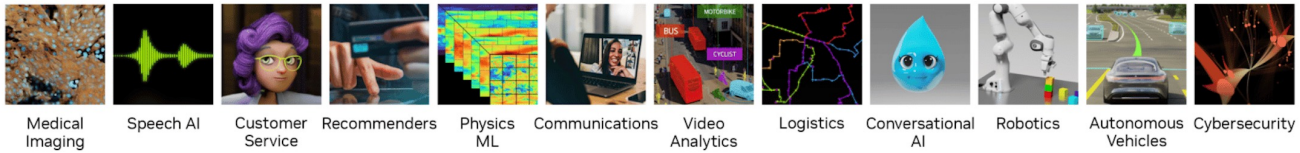

需求

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

直通式 — 操作系统 — 核心功能

迎难而上

面向“大算力+X”需求

调度与管理

能力

大算力、领域加速、高速互联

硬件

GPU、NPU/XPU、NVLink/NVSwitch/CXL

GPU调度与管理——大算力+X

GPU

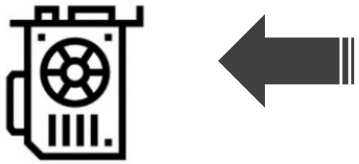

高并发算力

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调度单元 NVIDIA使用SM、ARM使用CU

GPU调度与管理——大算力+X

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

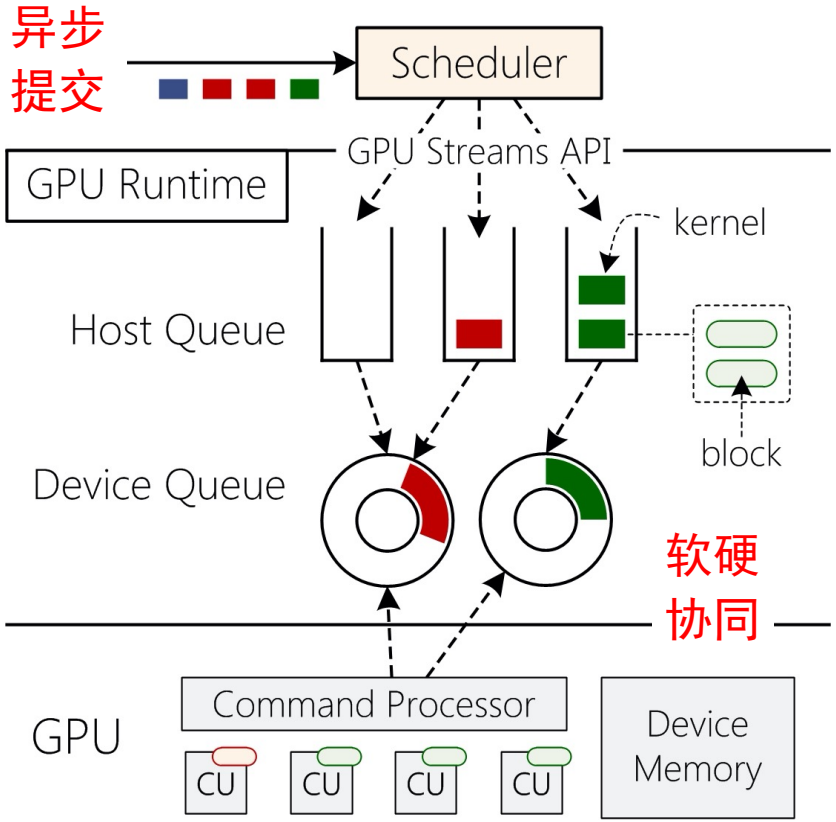

* GPU调度单元 NVIDIA使用SM、ARM使用CU

应用需求: 大算力 + 实时性

GPU 

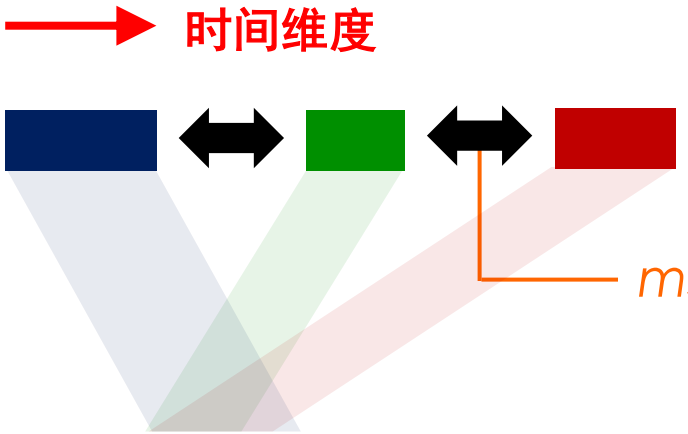

vs. CPU 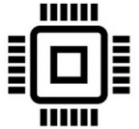

- 执行时间更长（5~100*ms*）
- 调度延迟更低（~5*μs*）

ms 级任务调度延迟

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

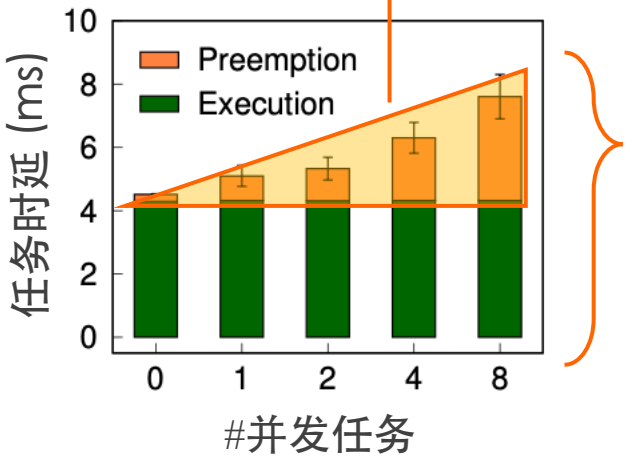

调度开销
接近一半 *

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

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 $5\mu s$

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

算力硬件的调度与管理

GPU抢占调度 ☆ “首次在量产GPU上实现了微秒级任务抢占[1]”

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

算力硬件的调度与管理——更“深”探索

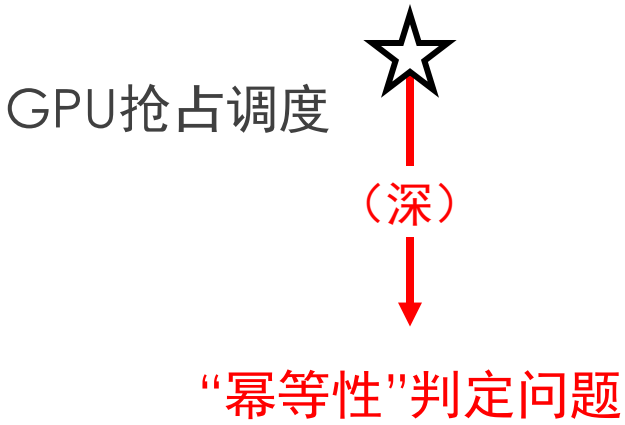

GPU程序“幂等性”——优化基石

大量优化系统基于幂等性

大算力硬件场景中效果尤为突出

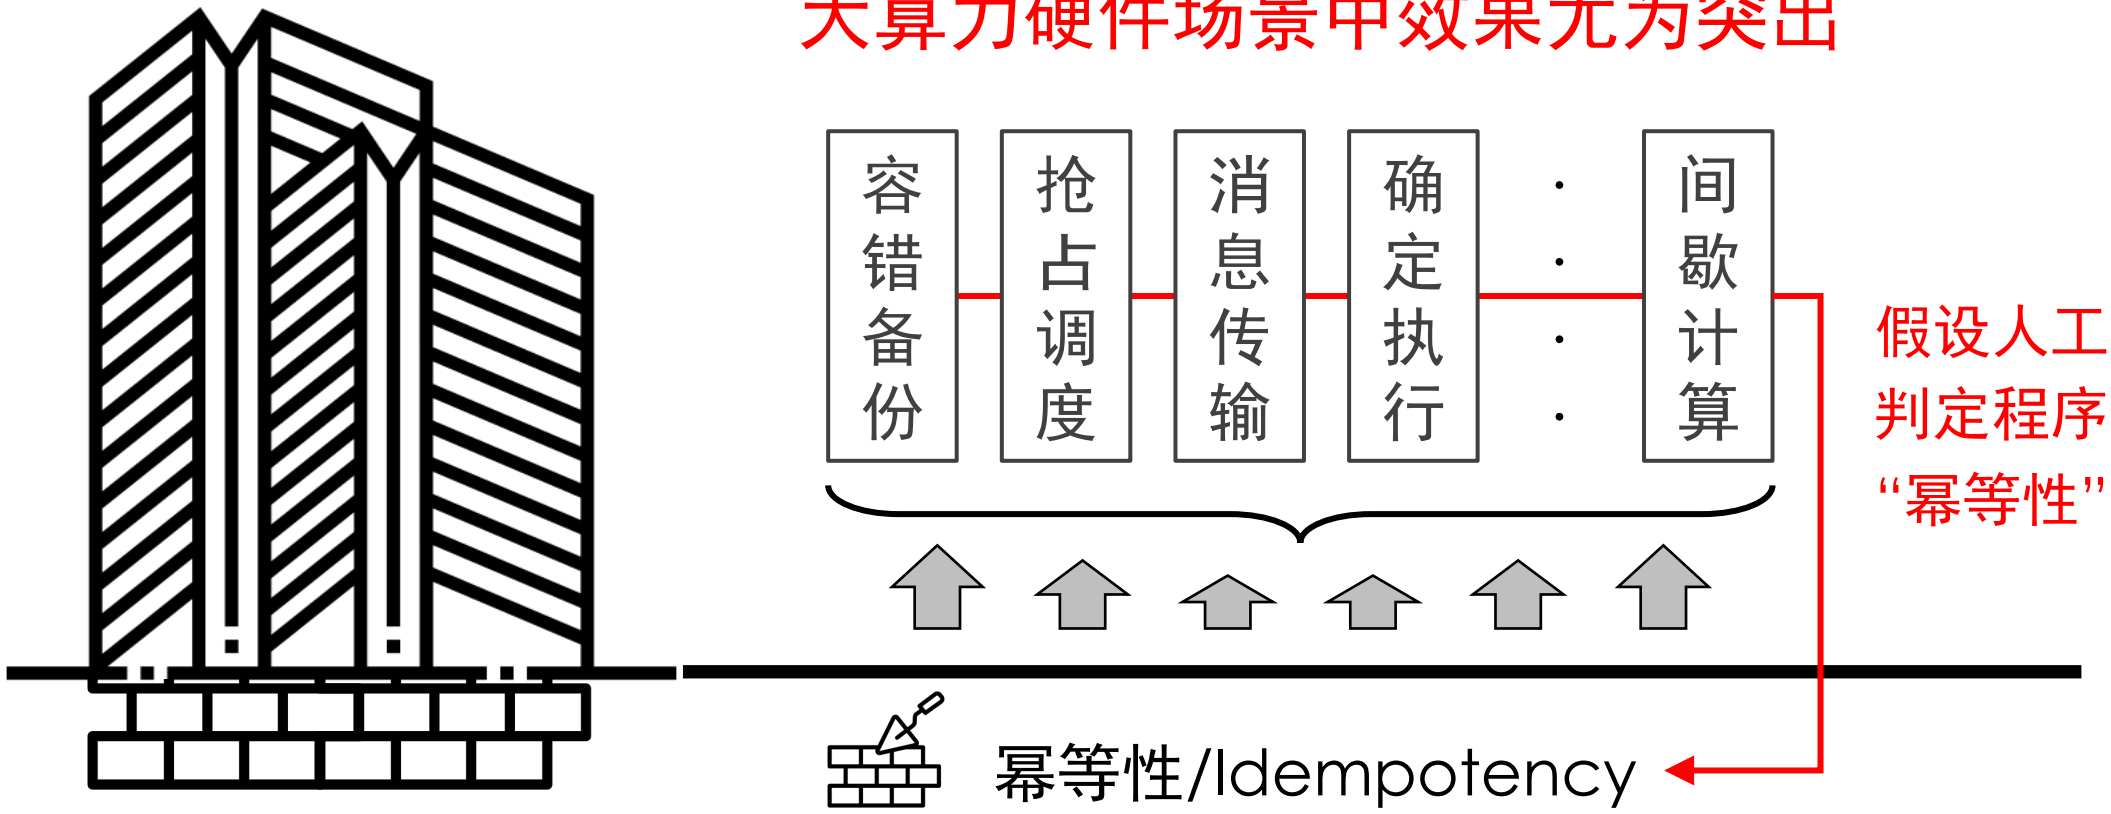

GPU程序“幂等性”——实际情况

幂等/Idempotent

```
__global__ void vectorSet(A)
  idx = bid * bdim + tid
  A[idx] = VALUE
```

非幂等/Non-idempotent

```
__global__ void vectorInc(A)
  idx = bid * bdim + tid
  A[idx] = A[idx] + VALUE
```

```
vectorSet<<<32,64>>>(x) ★ 幂等
vectorSet<<<32,16>>>(y) ★ 幂等
...
```

```
vectorInc<<<32,64>>>(x) ☆ 非幂等
vectorInc<<<32,64>>>(y) ☆ 非幂等
...
```

GPU程序/Kernel【静态】 | 【动态】GPU实例/Instance

GPU程序“幂等性”——实际情况

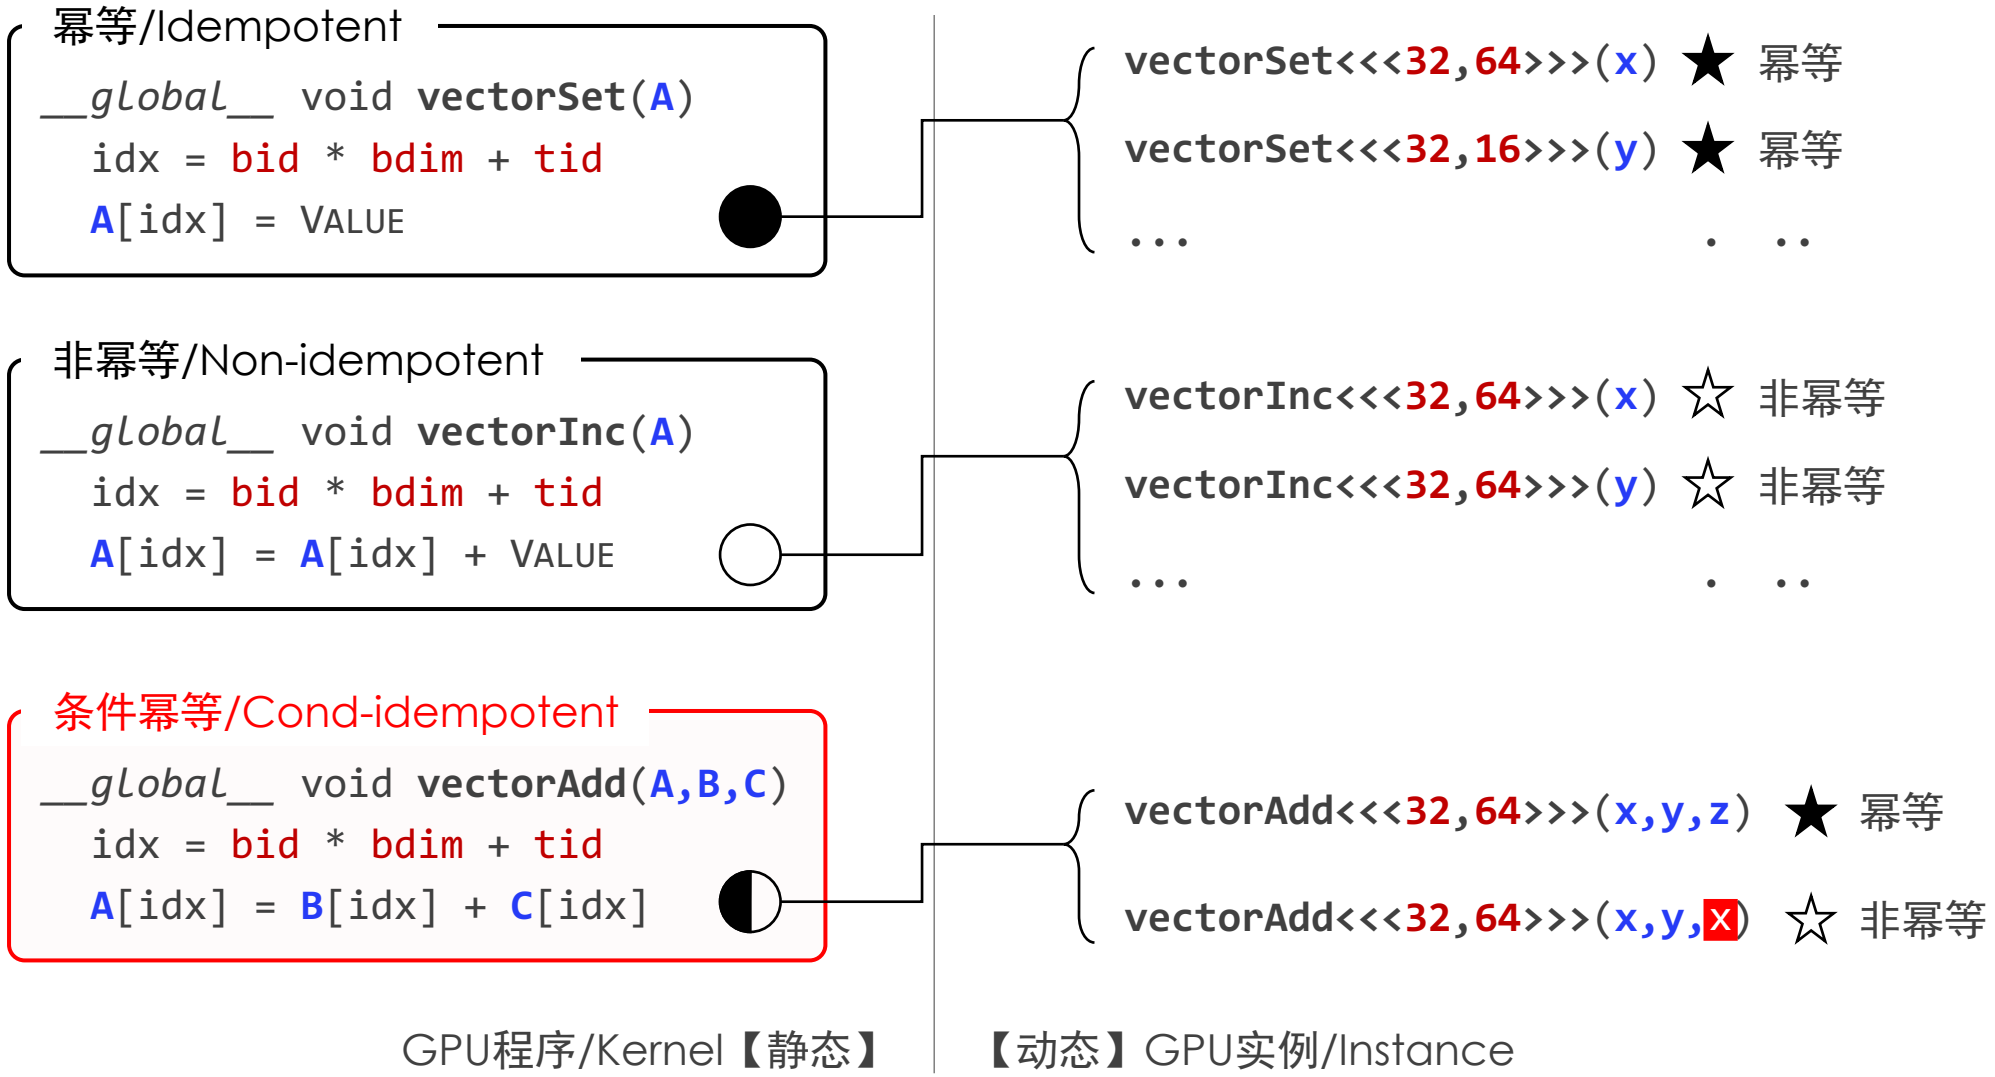

GPU程序“幂等性”——实际情况

幂等/Idempotent

```
__global__ void vectorSet(A)
  idx = bid * bdim + tid
  A[idx] = VALUE
```

●

非幂等/Non-idempotent

```
__global__ void vectorInc(A)
  idx = bid * bdim + tid
  A[idx] = A[idx] + VALUE
```

○

条件幂等/Cond-idempotent

```
__global__ void vectorAdd(A,B,C)
  idx = bid * bdim + tid
  A[idx] = B[idx] + C[idx]
```

◐

GPU程序/Kernel【静态】

“条件幂等”GPU任务真实存在、且是大多数

GPU Apps	Code	#Kernels	●	○	◐	◐/T
Rodinia [9]	Source	40	7	12	21	2
Parboil [57]	Source	25	4	12	9	0
TVM [60]	Source	308	0	0	308	0
PyTorch [49]	Binary	66	3	1	62	2
TensorRT [44]	Binary	58	0	2	56	0
FT [46]	Binary	50	9	7	34	0
All		547	23	34	490	4

基于官方用例

未发现非幂等实例

89.6%

```
vectorAdd<<<32,64>>>(x,y,z)   ★ 幂等
vectorAdd<<<32,64>>>(x,y,x)   ☆ 非幂等
```

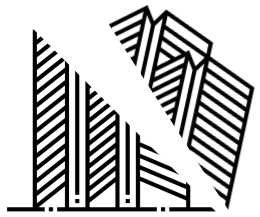

大厦将倾

【动态】GPU实例/Instance

GPU任务“幂等性”——实际情况

条件幂等/Cond-idempotent

```
__global__ void vectorAdd(A,B,C)
  idx = bid * bdim + tid
  A[idx] = B[idx] + C[idx]
```

【静态】GPU程序/Kernel

【动态】GPU实例/Instance

`vectorAdd<<<32,64>>>(x,y,z)` ★ 幂等（大多数）

`vectorAdd<<<32,64>>>(x,y,x)` ☆ 非幂等

“条件幂等”GPU任务的大多数实例是“幂等”

GPU Apps	#Instances	●/★	○/☆	◐/★	◐/☆
Rodinia [9]	4,527	85	78	4,334	30
Parboil [57]	1,033	103	738	192	0
TVM [60]	609	0	0	609	0
PyTorch [49]	1,570	151	1	1,131	287
TensorRT [44]	478	0	8	465	5
FT [46]	10,000	229	988	7,119	1,664
All	18,217	568	1,813	13,850	1,986

87.5%

关键技术：GPU实例的“幂等性”判定

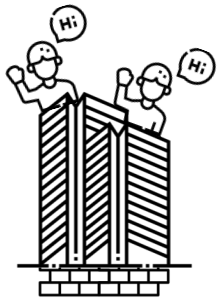

“幂等性”动态判定

问题/挑战

1. 如何安全判定“幂等性”?

现有方法：~~“读后写”~~ → “幂等”

× GPU执行访存高度并行

× 无法确定线程间访存顺序

思路/方法

关键设计：“读-写域”覆盖检查

~~读写覆盖~~ → “幂等” ★

○ 无误判/no false positive

○ 高精度/less false negative

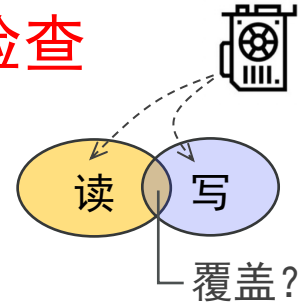

“幂等性”动态判定

问题/挑战

1. 如何安全判定“幂等性”？

现有方法：~~“读后写”~~ → “幂等”

× GPU执行访存高度并行

× 难以确定内存读写顺序

2. 如何在执行前完成判定？

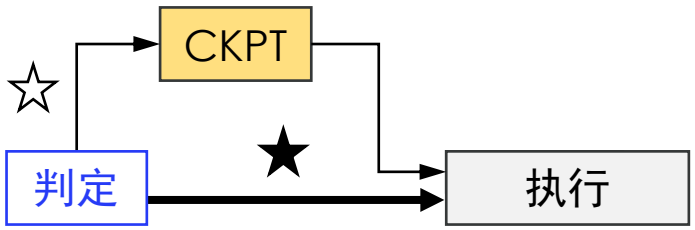

典型基于“幂等性”的系统架构

思路/方法

关键设计：“读-写域”覆盖检查

~~读写覆盖~~ → “幂等” ★

- 无误判/no false positive
- 高精度/less false negative

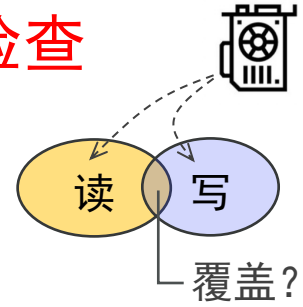

关键洞见：“启动参数”确定“读-写域”

```
vectorAdd<<<32,64>>>(x,y,z)
```

LAs

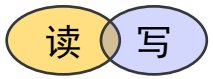

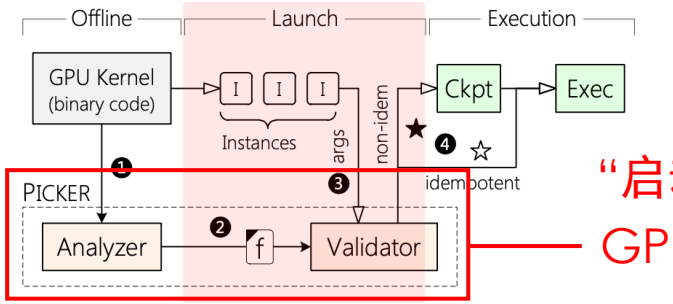

“启动期”

GPU实例分析工具

“幂等性”动态判定

问题/挑战

3. 如何计算GPU程序读-写域？

× CPU无法执行GPU访存指令

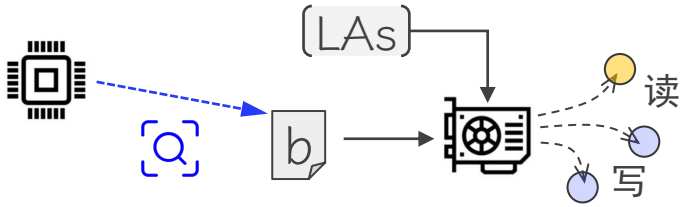

思路/方法

关键设计：基于符号地址的模拟计算

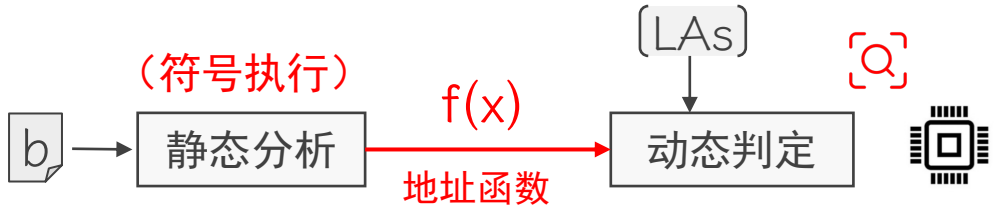

“幂等性”动态判定

问题/挑战

3. 如何计算GPU程序读-写域？

× CPU无法执行GPU访存指令

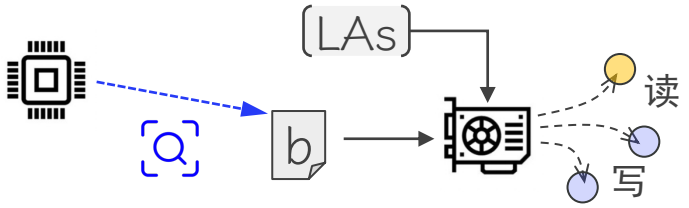

4. 如何快速判定实例“幂等”？

× 访存次数多（GBs）

× 启动时间短（<5μs）

执行时间（3-13ms）

~50ms

判定延迟

思路/方法

关键设计：基于符号地址的模拟计算

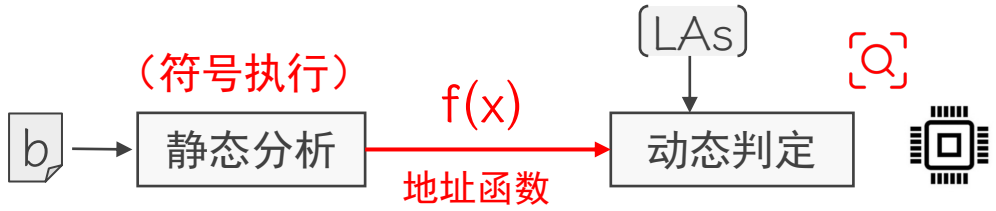

关键观察：访存地址连续性、单调性

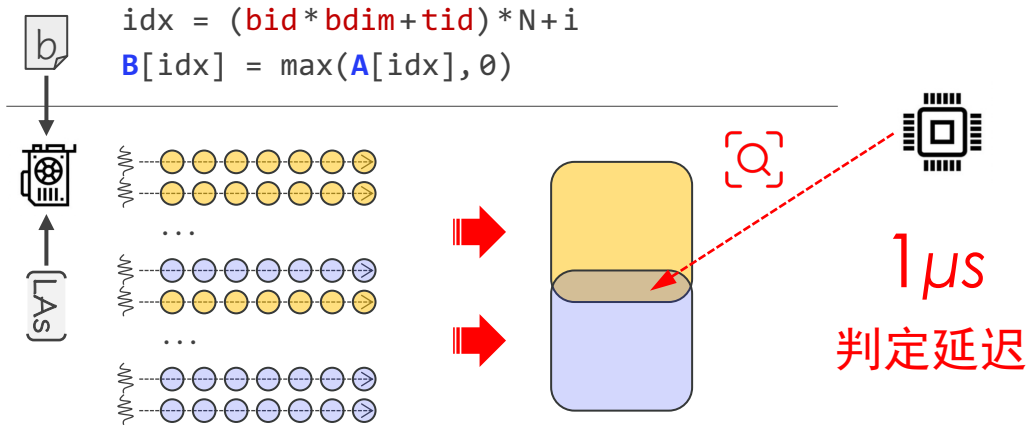

算力硬件的调度与管理——更“深”探索

GPU抢占调度 ☆

（深）

“幂等性”判定问题

“首次实现了GPU实例的幂等性动态判定、且做到了安全、快速、精准”

算力硬件的调度与管理——更“广”探索

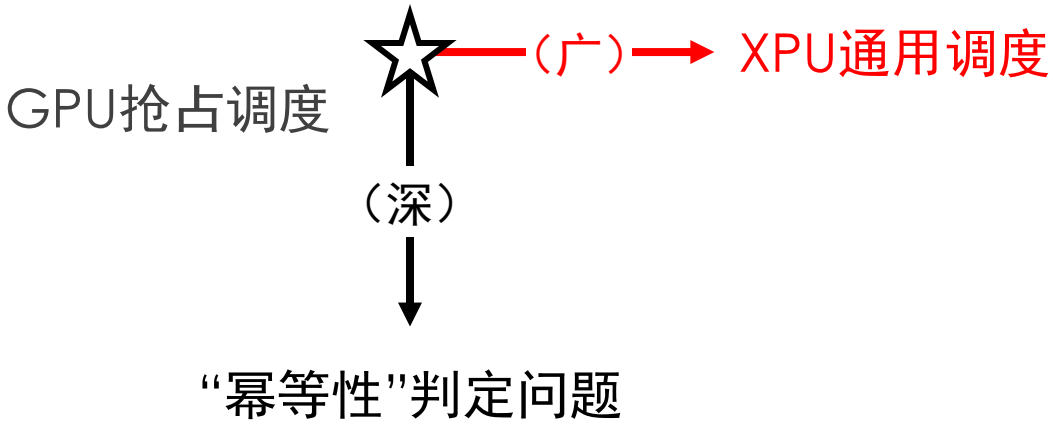

算力硬件（XPU）任务调度

GPU　　TPU　　NPU　　SoC

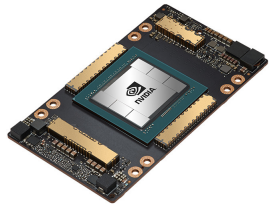
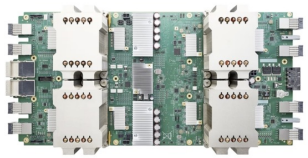
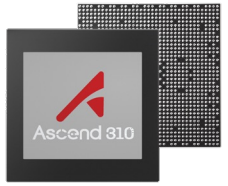

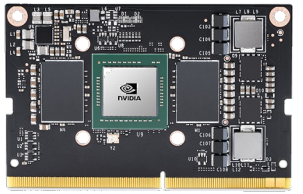

现有算力硬件（XPU: GPU/TPU/NPU/DSA/...）任务调度方法

× 硬件调度：功能有限（First-Come-First-Serve）、仅适合大算力需求

× 软件调度：绑定特定硬件（修改）、实现工作量大、方法迁移困难

我们的工作：面向开源GPU（修改驱动/运行时/应用）、5,500 LoC（C++）

关键技术：XPU通用调度框架

通用调度技术

问题/挑战

1. 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软件栈（部分/全部）闭源

包括：驱动、运行时、应用

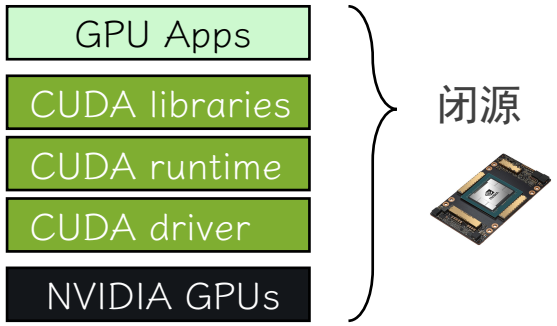

思路/方法

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	Queue
接口：	read/write +OPTs	submit/wait +OPTs
架构：	VFS: EXT3, NFS, ..., RAMFS	VQueue: GPU, NPU, ..., DSA

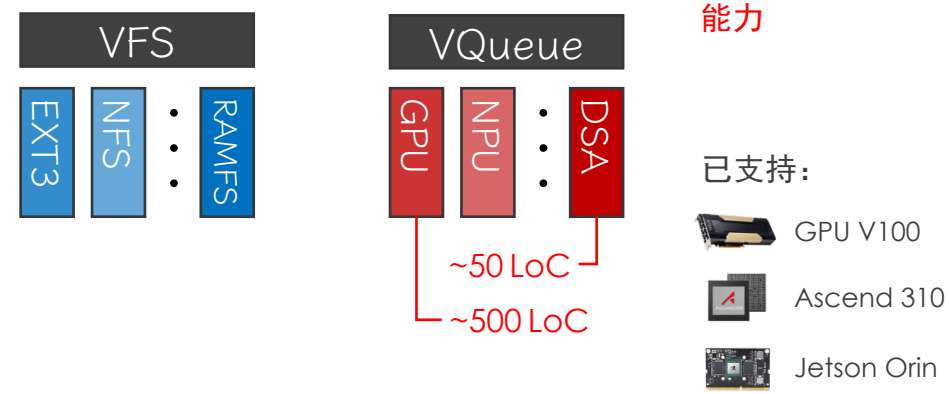

通用调度技术

问题/挑战

2. 如何灵活支持各类调度策略？

× 调度策略多样
- 强实时（real-time）
- 优先级（priority）
- 截止期（deadline）
- 公平（fairness）
- 时间片（slicing）
- . . .

× 硬件能力有差异
- 计算单元重置、内存刷新、. . .

思路/方法

关键思路：通用策略+可选实现

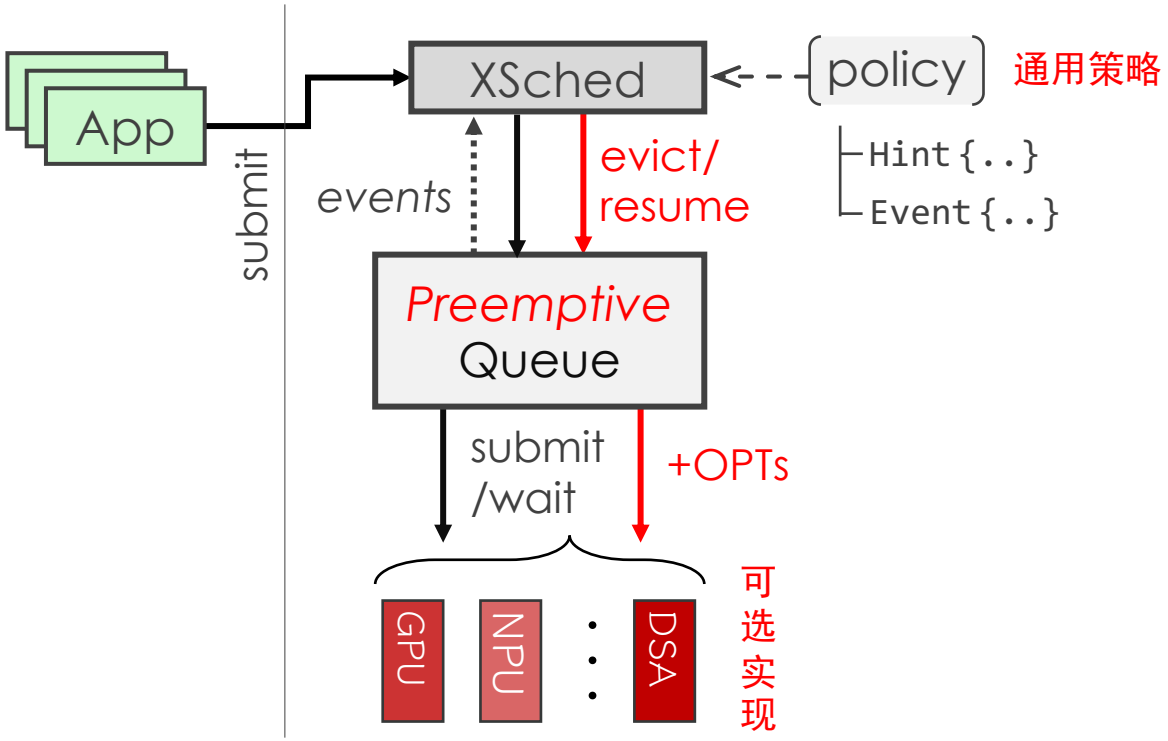

算力硬件的调度与管理——更“广”探索

“支持了GPU/NPU/DSA等
算力硬件和各类调度策略”

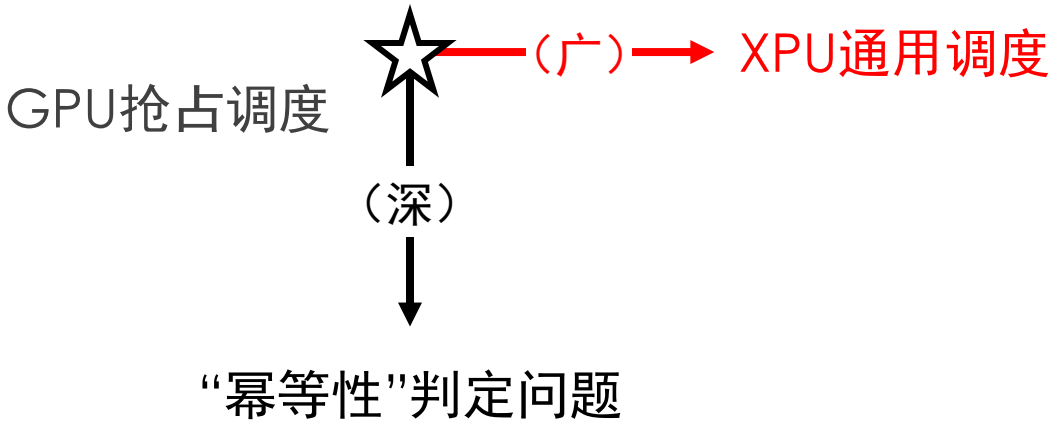

算力硬件的调度与管理——更“远”探索

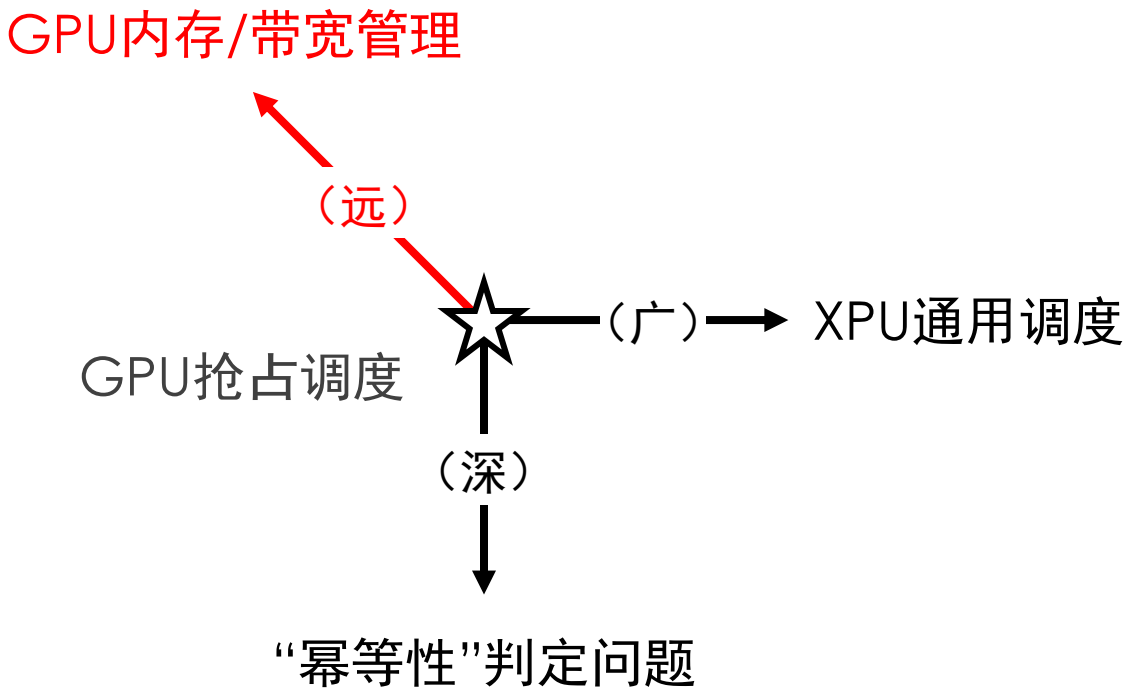

GPU内存/带宽管理

智能应用

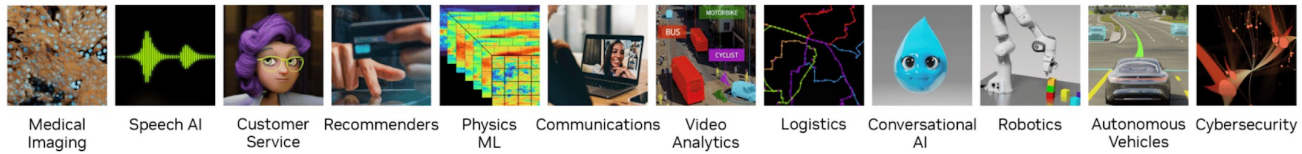

人工智能应用（尤其是DL/LLM）在内存/带宽上同样带来了爆发式需求增长

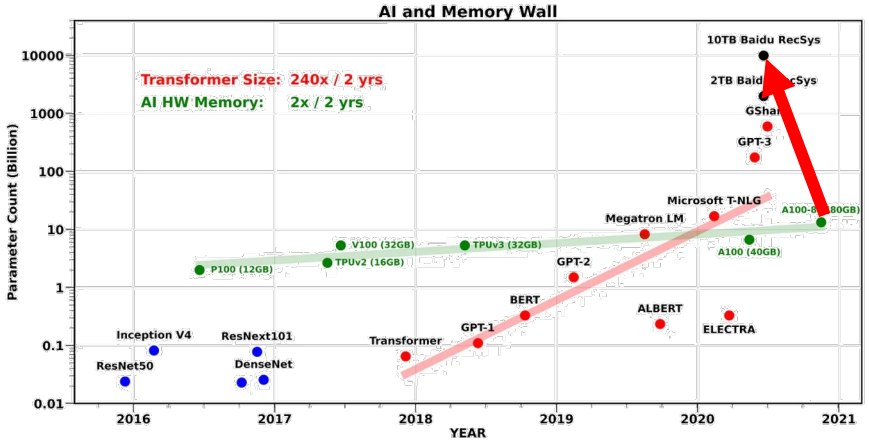

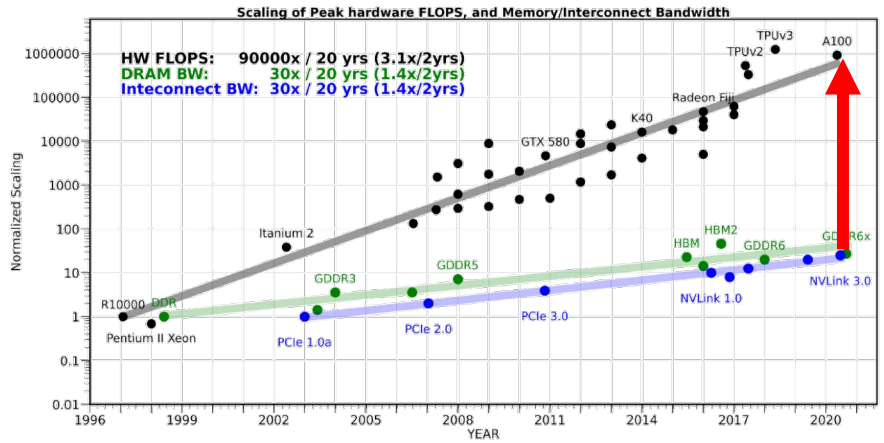

内存需求：240X / 2 Yrs

内存容量：2X / 2 Yrs

算力增长：3.1X / 2 Yrs

带宽增长：1.4X / 2 Yrs（内存）

1.4X / 2 Yrs（互联）

Source: “AI and Memory Wall”, 2021. https://medium.com/riselab/ai-and-memory-wall-2cb4265cb0b8

GPU缓存系统

智能应用

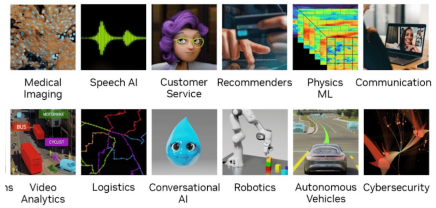

典型GPU存储架构

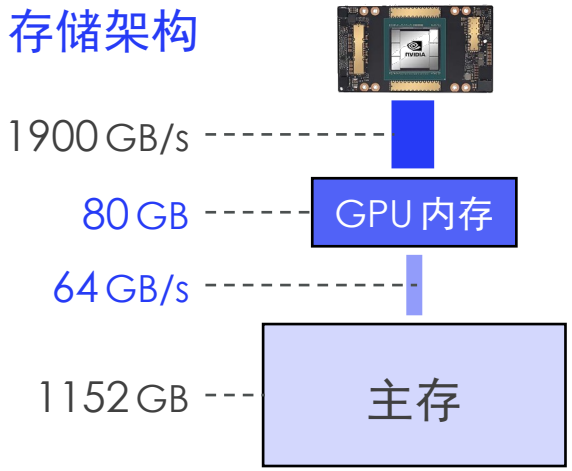

GPU缓存系统[1]

智能应用的数据访问普遍具有偏态分布特征

神经网络、推荐系统的嵌入（Embeddings）

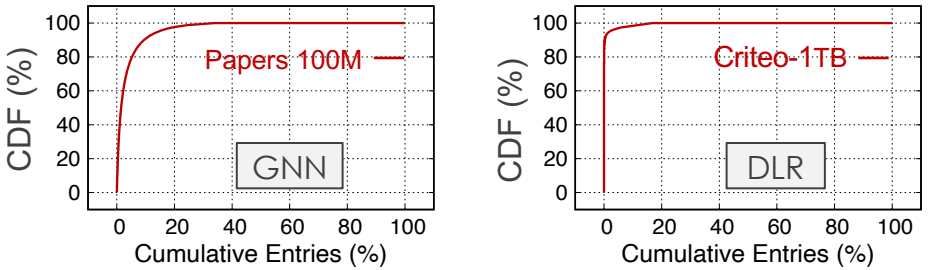

Source: UGache. SOSP 2023

LLM神经元激活（Neuron Activation）

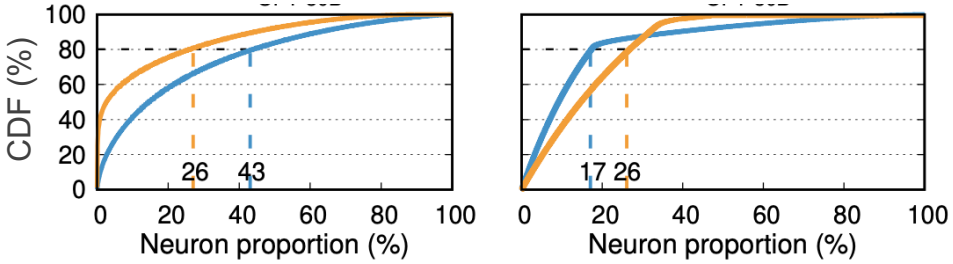

Source: PowerInfer, arXiv 2023

[1] GNNLab: A Factored System for Sample-based GNN Training over GPUs. EuroSys 2022

GPU缓存系统

智能应用

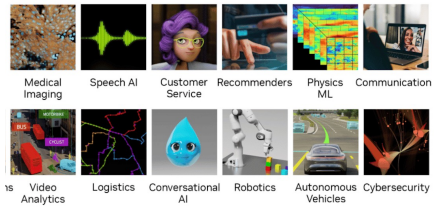

典型GPU存储架构

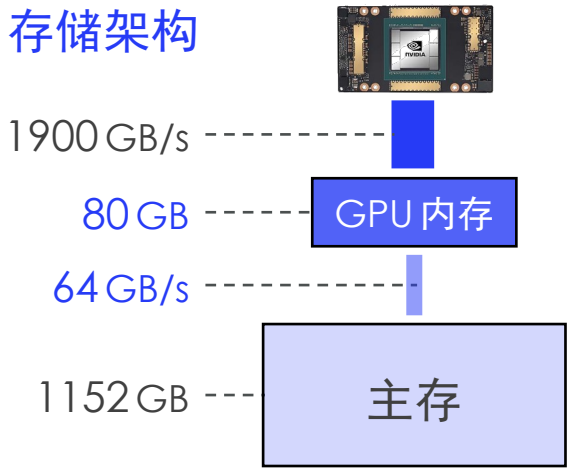

多卡GPU
+
高速互联

?

GPU
缓存系统[1]

智能应用的数据访问普遍具有偏态分布特征

神经网络、推荐系统的嵌入（Embeddings）

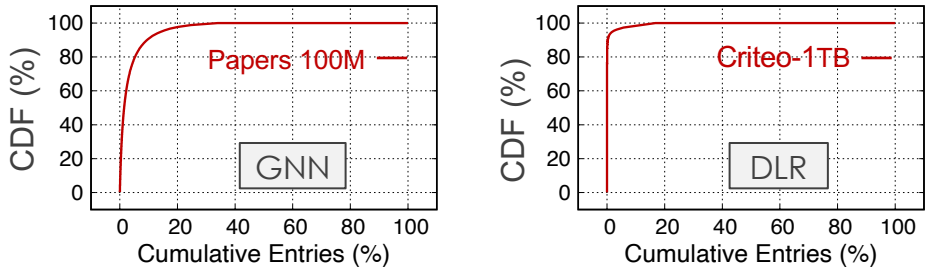

Source: UGache. SOSP 2023

LLM神经元激活（Neuron Activation）

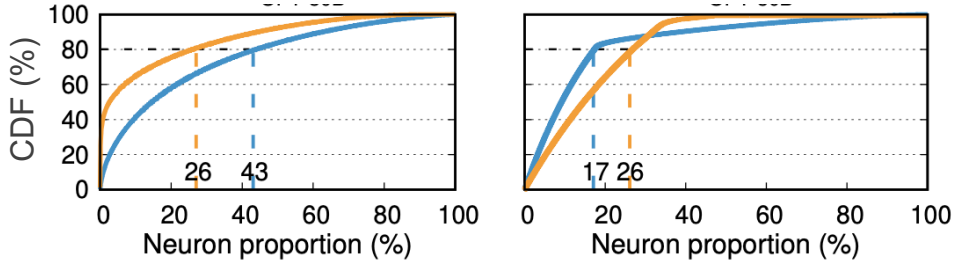

Source: PowerInfer, arXiv 2023

关键技术：多卡GPU统一缓存方法

[1] GNNLab: A Factored System for Sample-based GNN Training over GPUs. EuroSys 2022

多卡GPU缓存系统

问题/挑战

1. 如何统一、高效的缓存数据？

× 多卡GPU系统：互联架构多样

- 互联硬件：PCIe / NVLink / NVSwitch . .
- 访存性能：Local / Remote / Host . .

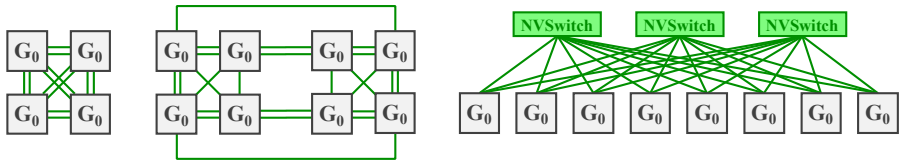

× 统一缓存抽象：放置策略复杂

- 缓存什么数据、在哪里、. . . ？

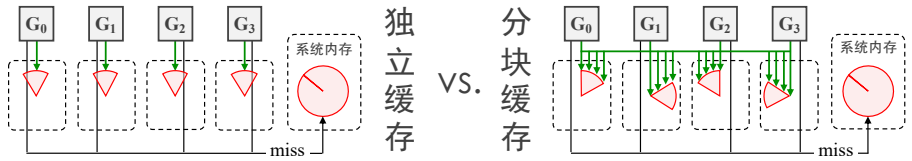

思路/方法

关键思路：对缓存数据问题统一建模

多GPU缓存问题 ➡ 混合整数线性规划/MILP

GPU数量、空间、带宽

数据规模、访问频率

MILP(. .) → 整体访存延迟最低

=

$O(EG^2)$ >1d（求解时间）

#Data（亿级）

#GPU（<16）

近似计算

（粗-细混合分块）

<10s ⟷ <2%

求解时间 精度损失

算力硬件的调度与管理——更“远”探索

“构建了面向多卡GPU架构的统一缓存系统、大大提升了缓存空间与访存效率[1]”

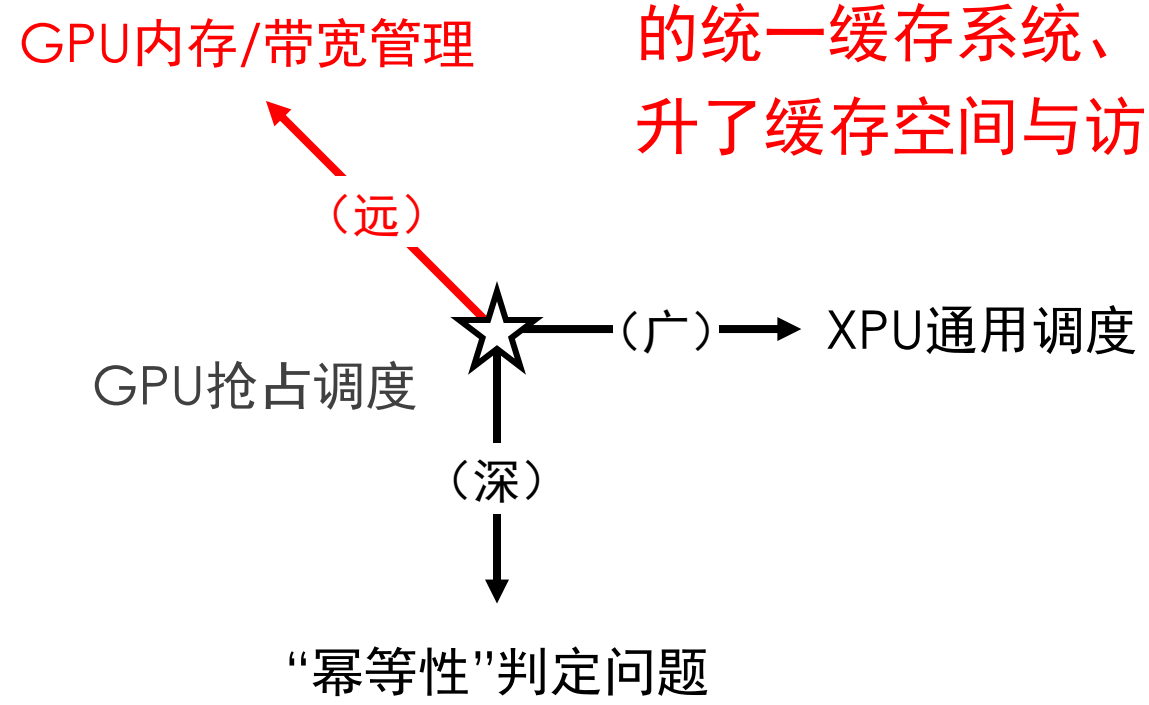

[1] UGache: A Unified GPU Cache for Embedding-based Deep Learning. SOSP 2023

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——**算力硬件调度与管理**

感谢！

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