中国科学院大学计算机学院专业选修课

GPU架构与编程

第一课：课程介绍、GPU简介

赵地
中科院计算所
2025年秋季学期

讲授内容

- 课程介绍
- GPU简介
  - 定义、发展史、总体构架
  - 功能（一）：图形图像处理
  - 功能（二）：通用计算、编程语言
  - 模拟器、生产商

教学目的

- ✓本课程是面向全校（本科生、研究生）开设的一门计算机系统结构方向的专业选修课程。
- ✓本课程旨在通过介绍GPU架构与编程，特别是GPGPU，运行机理、关键技术及科技发展史，帮助学生建立、贯通GPU架构与编程所需的知识体系，培养学生的GPU架构与编程的能力、系统思维能力和正确的历史唯物主义科技观。

适用对象（前置课程）

- ✓课程从基本概念出发，循序渐进、由浅入深讲授GPU架构与编程的相关专业知识，对学生专业知识基础要求不强，适用于选择攻读计算机系统结构方向的研究生。
- ✓建议前置课程：并行计算、C/C++编程；数字电路、计算机组成原理。

课程内容

- ✓周次2：GPU简介、课程简介、课程大作业
- ✓周次3：GPU的架构（GPU架构综述、SIMT核、片上网络NoC、L2、访存系统、等）
- ✓周次4、5、6：CUDA编程（英伟达原版教案）
- ✓周次7、8：PTX编程
- ✓周次9：AMD ROCm简介、OpenCL编程

课程内容

- ✓周次10：国产GPU编程、课程大作业（一）截止
- ✓周次11、12：OpenAI Triton编程
- ✓周次13、14：大模型（英伟达原版教案）
- ✓周次15：课程大作业（二）截止、课程大作业讲解、颁奖典礼、总复习
- ✓周次16：期末考试

上课时间

✓授课：2-16周；

✓每周三晚间（雁栖湖）：连续三节课（10-12 节），地点：教 1-002；

✓每周四晚间（玉泉路）：连续三节课（10-12节），地点：阶一5，同步直播　阶二5。

10	18:30 — 19:20
11	19:20 — 20:10
12	20:10 — 21:00

参考书：GPU的架构

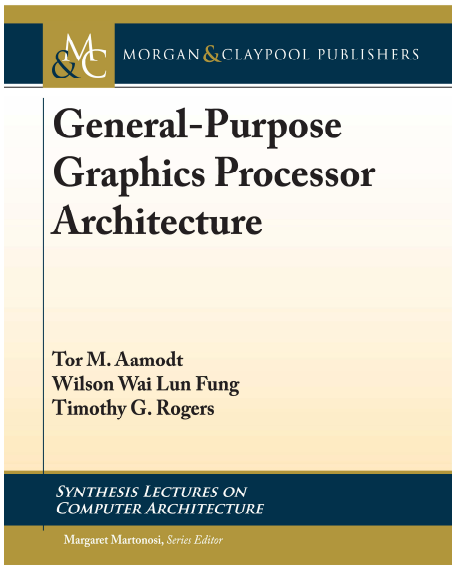

Tor M. Aamodt, Wilson Wai Lun Fung, Timothy G. Rogers, General-Purpose Graphics Processor Architectures, Springer Cham, 2018

参考书：GPU的架构

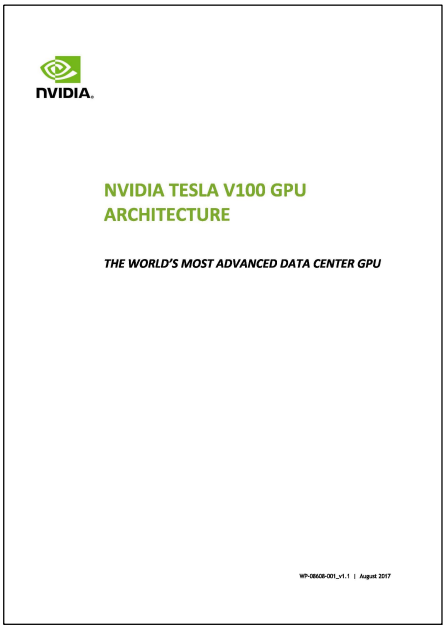

NVIDIA TESLA V100 GPU ARCHITECTURE, 2017

参考书：CUDA编程

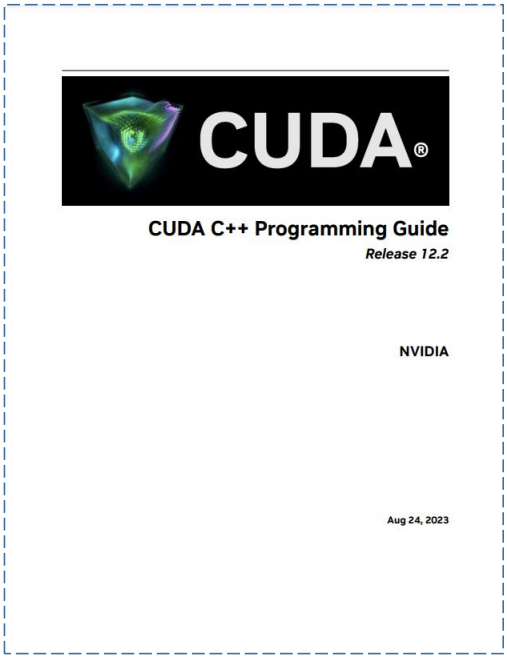

✓https://docs.nvidia.com/cuda/pdf/CUDA_C_Programming_Guide.pdf

参考书：CUDA编程

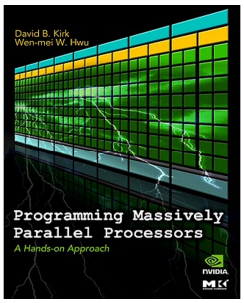

2010

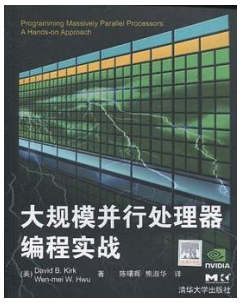

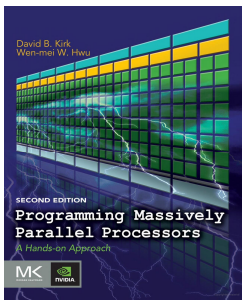

2012

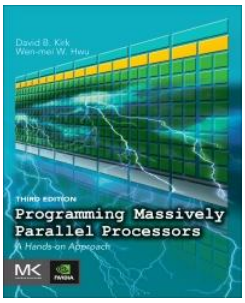

2017

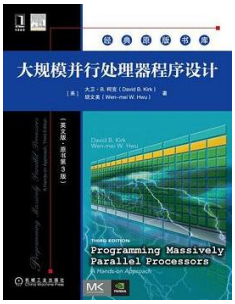

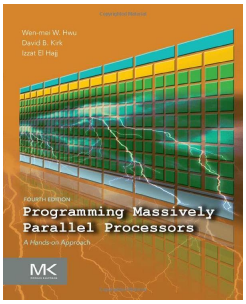

2022

✓教材：Third Edition:
https://www.sciencedirect.com/book/9780128119860/programming-massively-parallel-processors

David B. Kirk, Wen-mei W. Hwu, Programming Massively Parallel Processors: A Hands-on Approach;

Contents

David B. Kirk, Wen-mei W. Hwu, Programming Massively Parallel Processors: A Hands-on Approach;

David B. Kirk, Wen-mei W. Hwu, Programming Massively Parallel Processors: A Hands-on Approach;

参考书：PTX编程

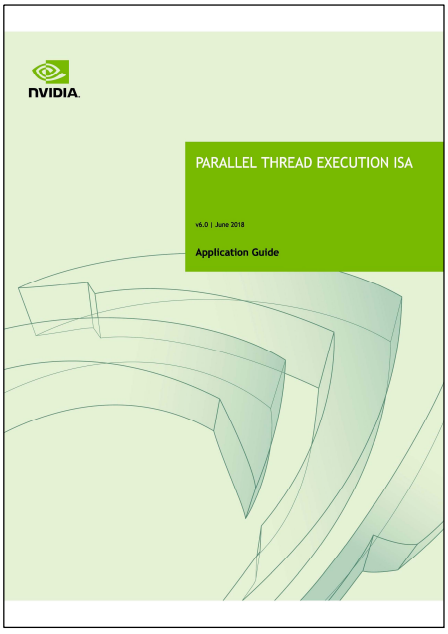

Parallel Thread Execution ISA Version 6.0, 2018

参考书：CANN编程

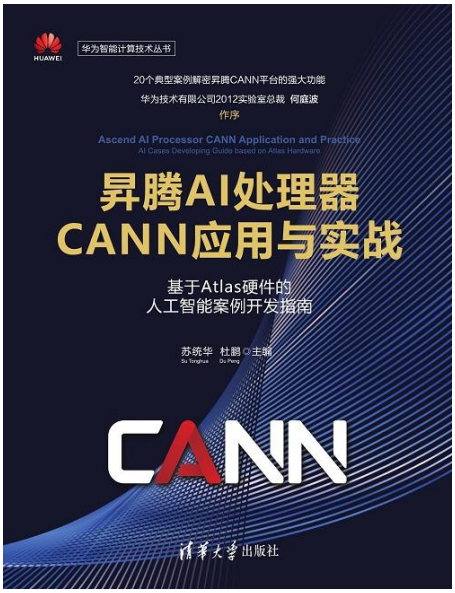

✓https://www.hiascend.com/zh/ascend-c

参考书：Triton编程

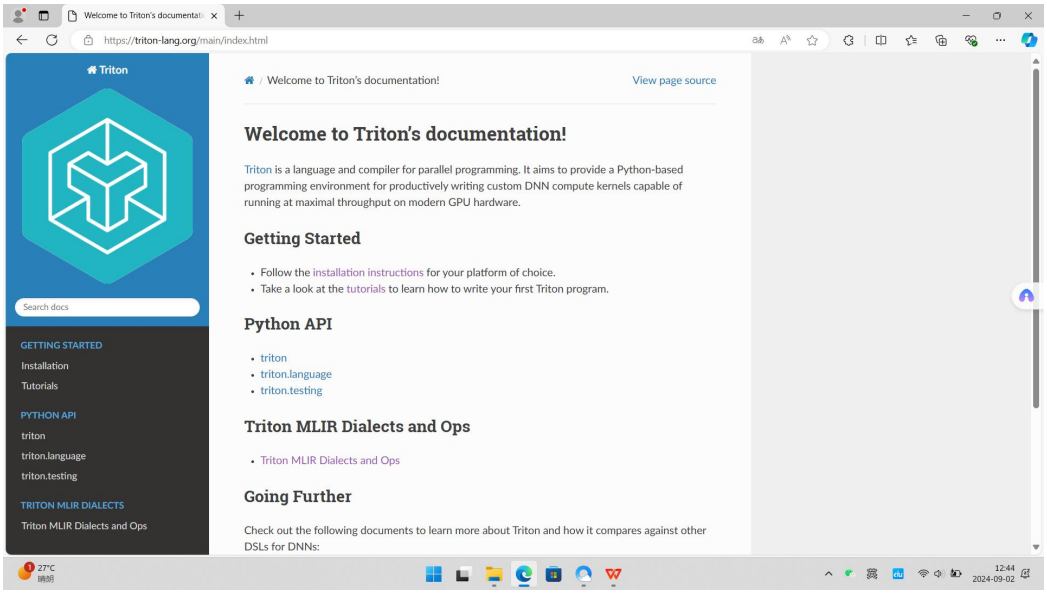

✓https://triton-lang.org/main/index.html

期末考试

✓时间：周次16；
✓考试内容：GPU架构与编程；
✓考试方式：线下、纸质试卷、开卷。

评分标准

✓课程大作业（一）：30%，后续发布加分题
✓课程大作业（二）：30%，后续发布加分题
✓期末考试（开卷）：30%
✓考勤：10%
✓满分：100%

组织形式

- ✓课程大作业（一）：统一评分
- ✓课程大作业（二）：**赛区、赛道**
- ✓期末考试（开卷）：统一评分
- ✓考勤：统一评分

组织形式

- ✓课程大作业（一）：国科大计算中心（八卡英伟达V100）
- ✓课程大作业（二）：各位同学选择一个赛道，每位同学只能选择一个赛道

	摩尔线程	沐曦
玉泉路校区	选择一个	
雁栖湖校区		

赛道一：摩尔线程

✓奖品池：

- ✓AIBOOK算力本，价值9999元，2台
- ✓摩尔线程MTT S80游戏显卡，价值1499元，4块
- ✓摩尔学院礼包（内含笔记本1本、摩尔学院徽章1枚、手机支架1个），6个
- ✓摩尔学院徽章，90个
- ✓每人价值100元的AutoDL算力券。

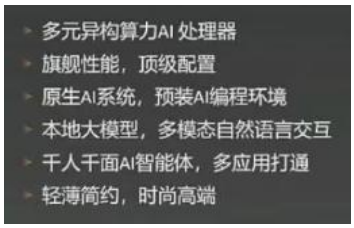

赛道二：沐曦

✓奖品池：

- ✓《沐曦异构并行计算软件栈——MXMACA C/C++程序设计入门教程》 每人1册；
- ✓gitee算力券，每人50元；
- ✓“开源GPU创新生态赛”算力券，每人300元，地址：https://www.gitlink.org.cn/competitions/gitlinkGPU1；
- ✓课程实验环境，免费。

任课教师简介

✓赵地，中科院计算所副研究员；

✓2007年开始学习和研究GPU编程与架构；

✓在GPU领域发表论文多篇；


Efficiently solving tri-diagonal system by chunked cyclic reduction and single-GPU shared memory


Fast filter bank convolution for three-dimensional wavelet transform by shared memory on mobile GPU computing


Mobile GPU Computing Based Filter Bank Convolution for Three-Dimensional Wavelet Transform

Acceleration of sequential Monte Carlo for computationally intensive target distribution by parallel lookup table and GPU computing


GPU Computing based fast discrete wavelet transform for l1-regularized SPIRT reconstruction


基于脉冲神经网络与移动 GPU 计算的图像分类算法研究与实现

Image classification algorithm based on spiking neural network and mobile GPU computing

任课教师简介

✓2015 年度，赵地博士担任美国英伟达公司（NVIDIA）-中科院网络中心GPU研究中心（GPU Research Center）主任、美国英伟达公司（NVIDIA）-中科院网络中心GPU教育中心（GPU Education Center）主任。

任课教师简介

✓2016 年，中国科学院网络信息中心和美国英伟达公司（NVIDIA）联合主办2016大数据智能论坛（BDA2016），赵博士担任大会主席，并获得中国科学院国际合作局 2016年度国际会议资助；推动并成立了CNIC-英伟达“智慧医疗”联合实验室，担任实验室主任。

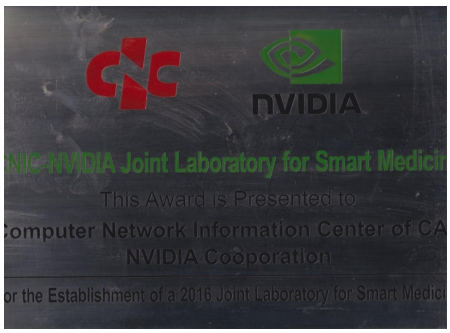

任课教师简介

✓2013 年、2014 年、2016 年、2017 年和 2019年，前往美国硅谷参加英伟达公司举办的 GPU 技术大会（GPU Technology Conference），并与 NVIDIA 创始人兼首席执行官 Jensen Huang（黄仁勋）等顶尖 GPU 专家进行了深入的探讨；

✓2020年、2021年、2022年、2023年、2024年，在线参加GPU 技术大会（GPU Technology Conference）。

助教

- ✓线下
  - ✓龚昊，计算机学院博士生

课程群

群聊: 2025秋《GPU架构与编程》

该二维码7天内(9月30日前)有效，重新进入将更新

赵地

中国大陆

扫一扫上面的二维码图案，加我为朋友。

往届课程（23秋）：126人获得学分

往届课程（23秋）

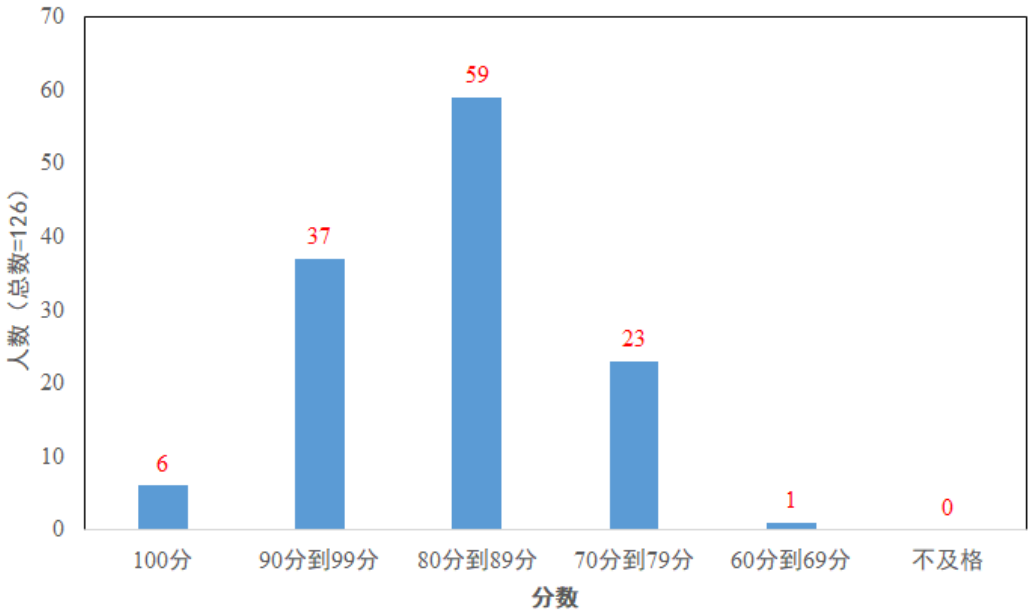

往届课程（23秋颁奖典礼）

往届课程（24秋）：244人获得学分

往届课程（24秋）

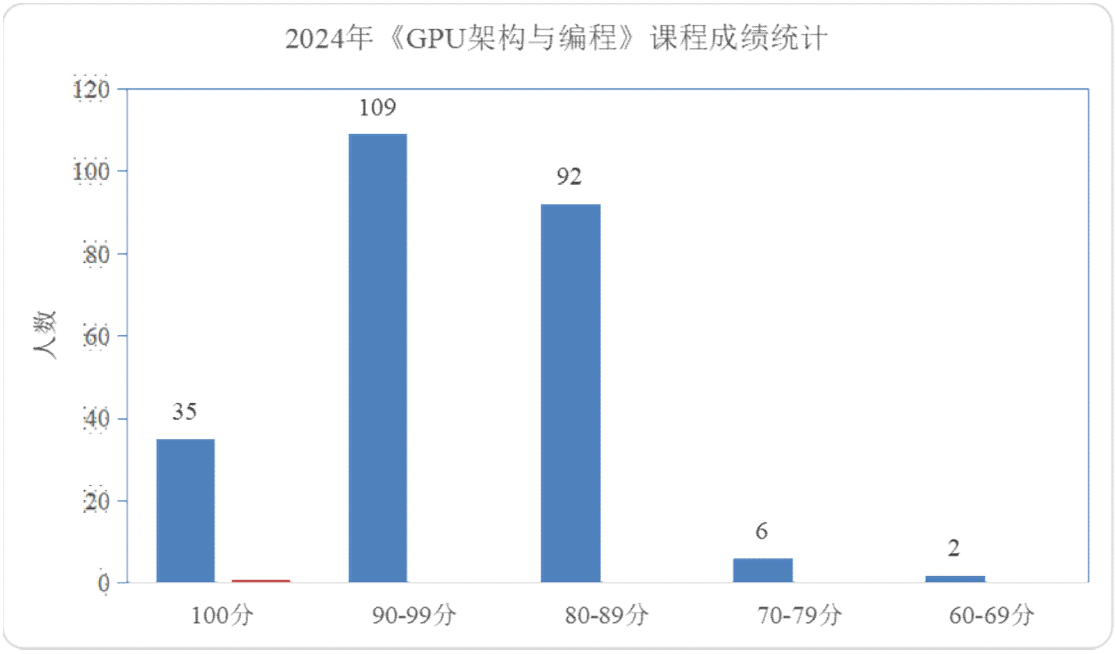

往届课程（24秋颁奖典礼）

摩尔线程董事长张建中先生颁奖

讲授内容

- 课程介绍
- GPU简介
  - 定义、发展史、总体构架
  - 功能（一）：图形图像处理
  - 功能（二）：通用计算、编程语言
  - 模拟器、生产商

GPU和GPGPU

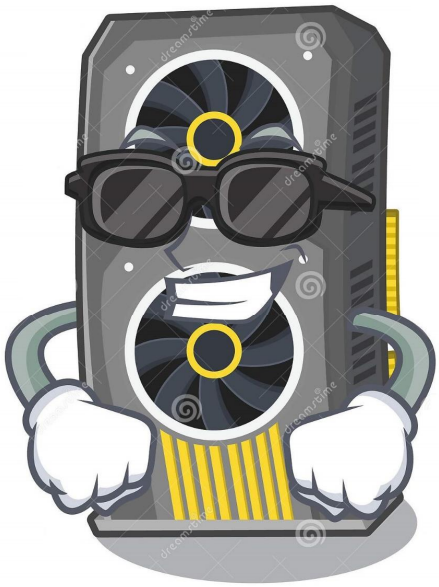

- ✓GPU的全称是 Graphics Processing Unit，是一种用于图形图像处理的处理器；
- ✓因为图形和图像处理方面的特点，对于并行处理大块数据的算法，GPU的并行结构比通用CPU更高效。将GPU用于通用计算，形成了GPGPU。

GPU和GPGPU

AMD’s 2016-2017 Datacenter Roadmap: x86, ARM, and GPGPU, https://www.anandtech.com/show/9234/amds-20162017-datacenter-roadmap-x86-arm-and-gpgpu

英伟达NV1

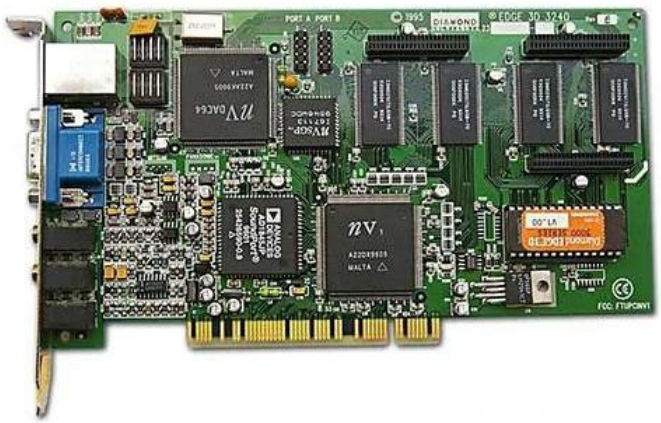

- ✓英伟达成立于1993年初，英伟达的第一代媒体加速器将使PC平台能够提供高性能的2D和3D图形、视频、数字操纵杆界面和高级音频功能，以加速快速增长的多媒体应用程序安装基础。
- ✓英伟达销售NV1 VRAM版本，而SGS提供DRAM版本STG2000。

Jon Peddie, Nvidia’s Quadratic Processor, the NV1

英伟达NV1

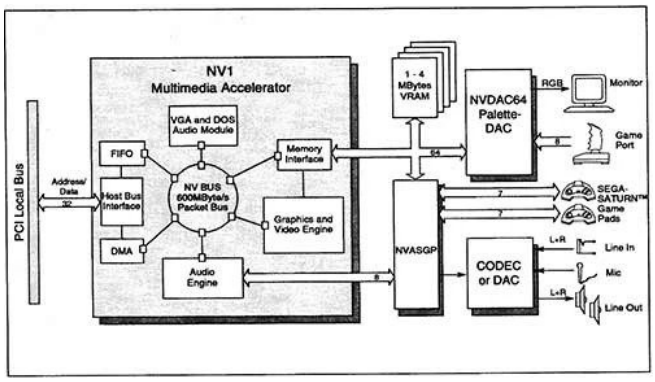

- ✓250万个晶体管，单芯片多媒体加速器；
- ✓支持行业标准：Windows 3.11 下所有 DirectX API 的加速、全动态视频加速（Indeo，MPEG，Cinepak）、等；
- ✓实时纹理映射 3D 图形；
- ✓加速所有 3D 标准：三角形、四边形和曲线。

Jon Peddie, Nvidia’s Quadratic Processor, the NV1

GPU的发展史（英伟达GPU为例）

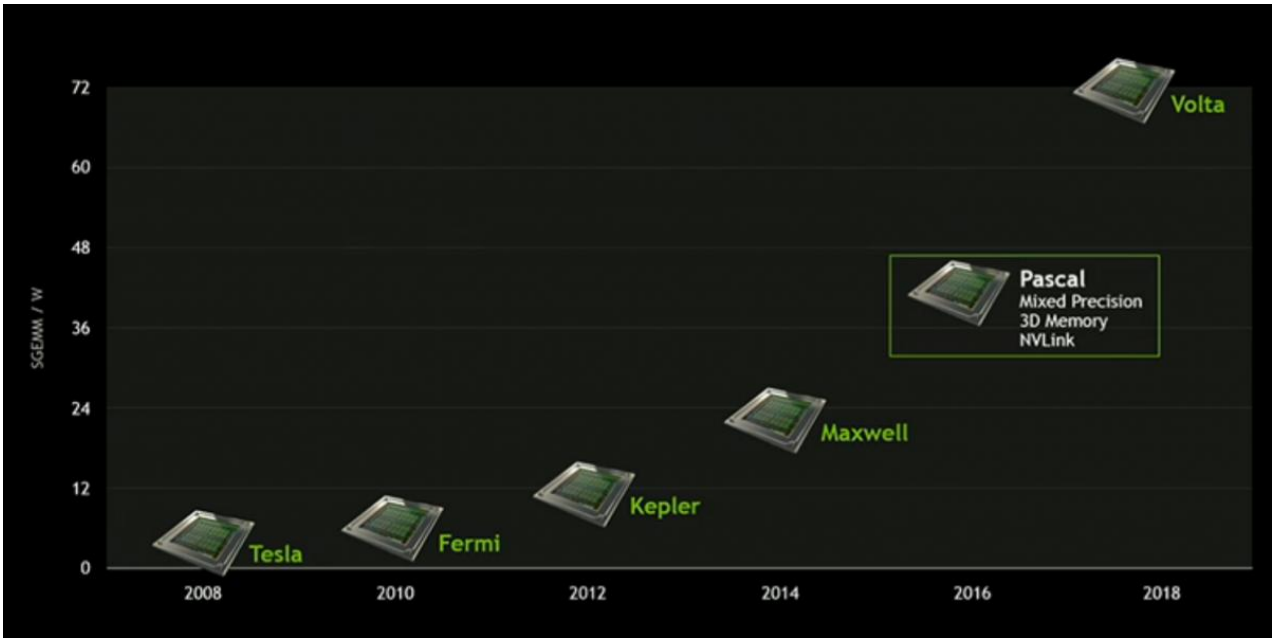

slides from Nvidia

GPU的发展史（英伟达GPU为例）

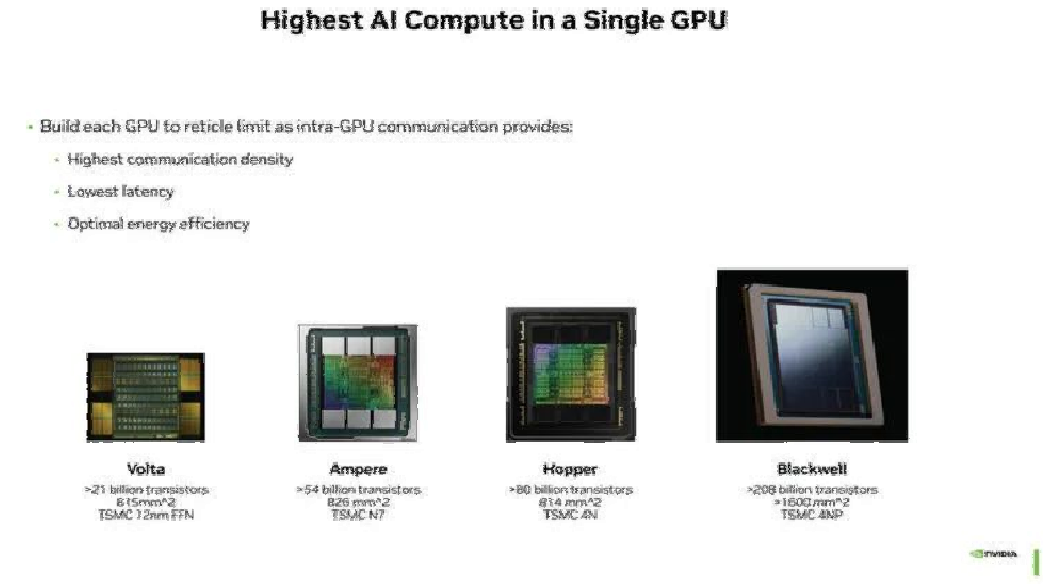

slides from Nvidia

GPU的发展史：英伟达GB200

slides from Nvidia

GPU的发展史：英伟达GB200

5th Generation Tensor Cores — FP Formats Summary

- New FP4 and FP6 precision support
- New micro-scaled formats for FP4, FP6, and FP8
- 4x faster per-clock, per-SM FP4 vs. Hopper FP8
- Blackwell also increases operating frequency and SM count

Format	Hopper SM MACs/clock		Blackwell SM MACs/clock		Blackwell Speedup per clock per SM
	Dense	Sparse	Dense	Sparse	
FP16	2048	4096	4096	8192	2x
BF16	2048	4096	4096	8192	2x
FP8 (+/- scale)	4096	8192	8192	16384	2x
FP6 (+/- scale)	-		8192	16384	New! 2x of Hopper FP8
FP4 (+/- scale)	-		16384	32768	New! 4x of Hopper FP8

slides from Nvidia

GPU的发展史：英伟达GB200

FP4 Inference Accuracy

- Data from Blackwell silicon with quantized FP4
- Excellent MMLU* scores for LLMs
- Same accuracy even for Nemotron-4 340B model
- Achieved with full-stack hardware, software and algorithm co-design

*Massive Multitask Language Understanding

Blackwell FP4 and NVIDIA Quasar Quantization System Measured MMLU Scores

Model	BF16	Quantized FP4
Nemotron-4 15B	64.2	64.5
Nemotron-4 340B	81.1	81.1

Nemotron-4 340B Technical Report

slides from Nvidia

GPU的发展史：英伟达GB200

Over 400 NVIDIA CUDA-X Libraries

Blackwell optimized to deliver maximum performance

- Optimized libraries for each platform
- Targeting diverse application domains
- Built on our decades-long innovation
- Ever-expanding set of algorithms

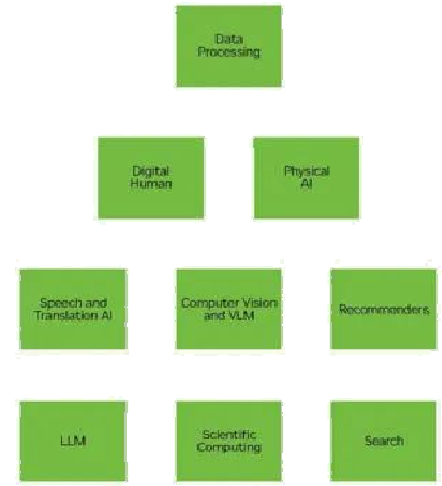

slides from Nvidia

GPU架构（英伟达GPU为例）

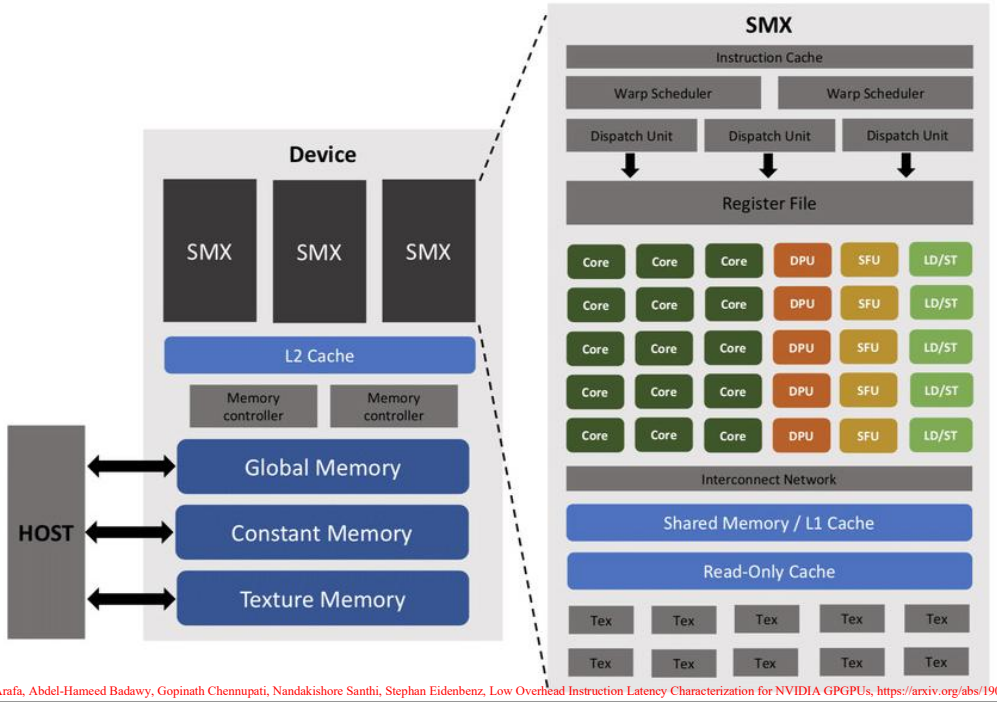

Yehia Arafa, Abdel-Hameed Badawy, Gopinath Chennupati, Nandakishore Santhi, Stephan Eidenbenz, Low Overhead Instruction Latency Characterization for NVIDIA GPGPUs, https://arxiv.org/abs/1905.08778

讲授内容

- 课程介绍
- GPU简介
  - 定义、发展史、总体构架
  - 功能（一）：图形图像处理
  - 功能（二）：通用计算、编程语言
  - 模拟器、生产商

GPU图形图像处理

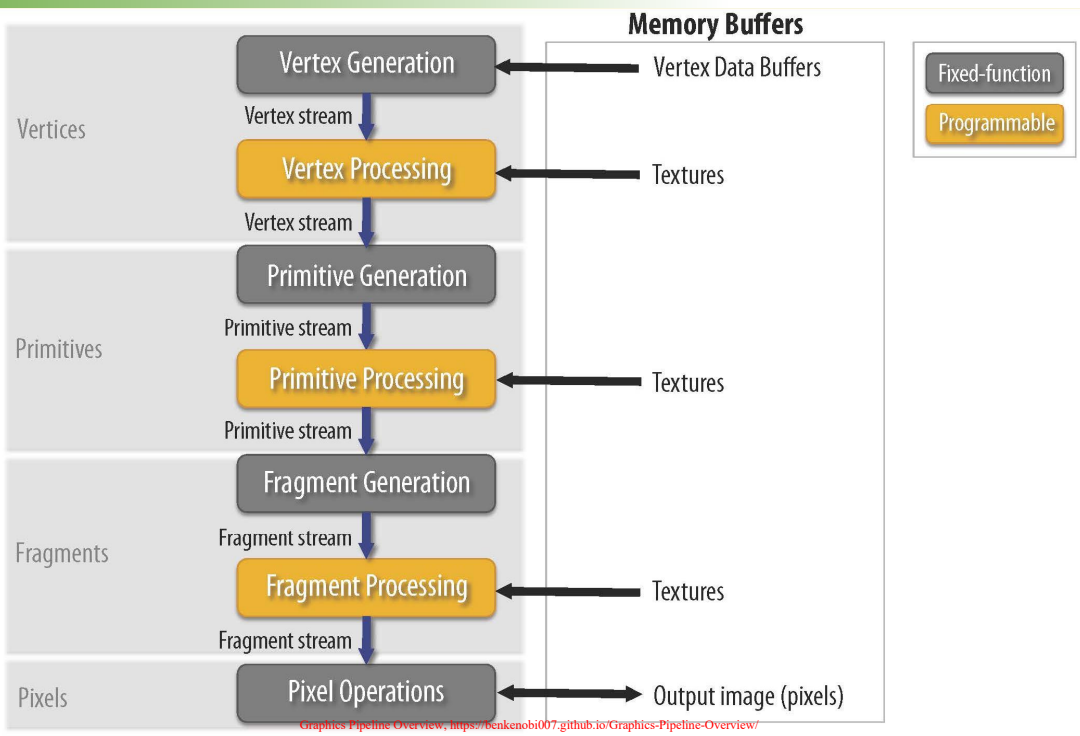

顶点处理（Vertex Processing）

Vertices are transformed into "screen space"

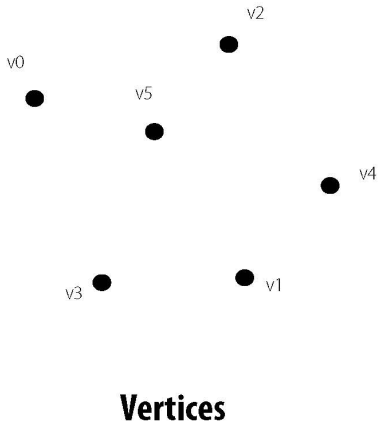

✓每个顶点处理（Vertex Processing）都是独立的。

Graphics Pipeline Overview, https://benkenobi007.github.io/Graphics-Pipeline-Overview/

图元处理（Primitive Processing）

Then organized into primitives that are clipped and culled…

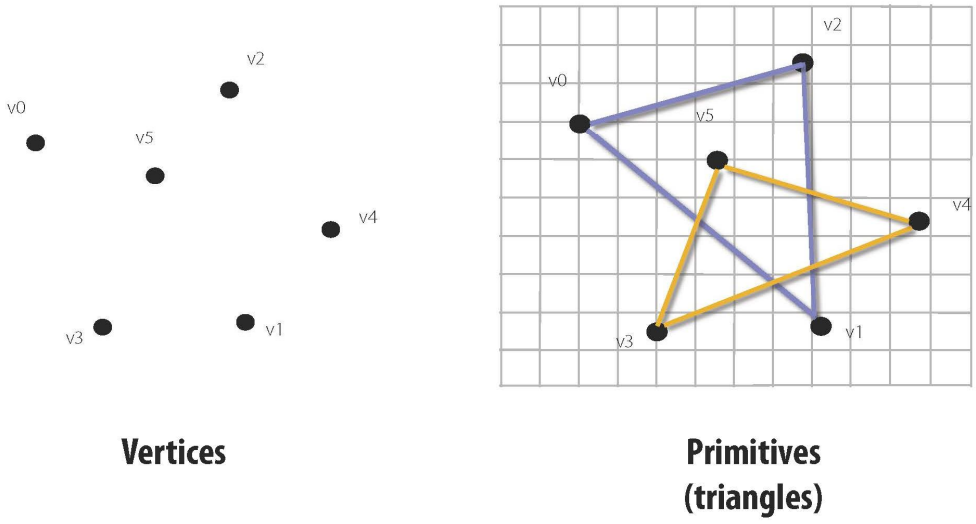

Graphics Pipeline Overview, https://benkenobi007.github.io/Graphics-Pipeline-Overview/

光栅化（Rasterization）

Primitives are rasterized into "pixel fragments"

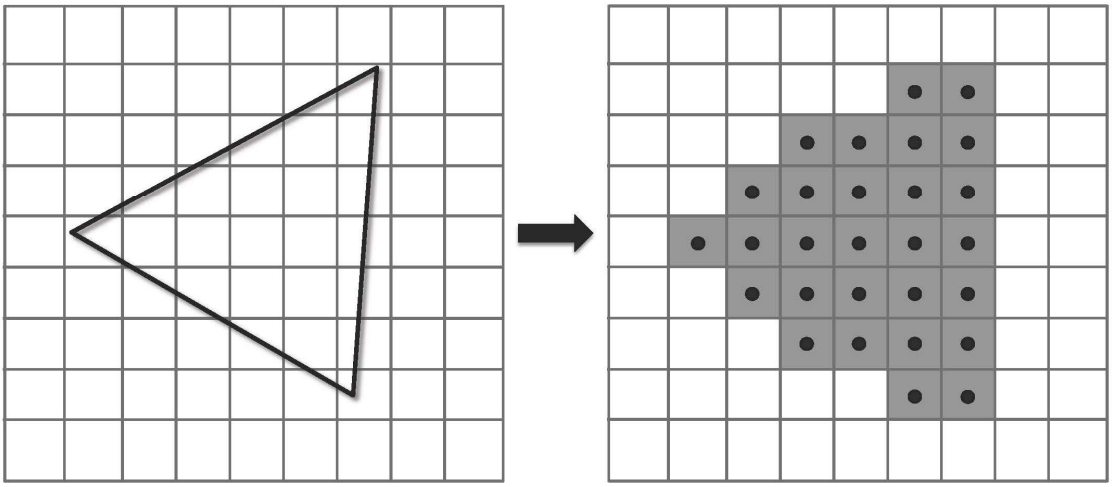

Graphics Pipeline Overview, https://benkenobi007.github.io/Graphics-Pipeline-Overview/

光栅化（Rasterization）

Fragments are shaded to compute a color at each pixel

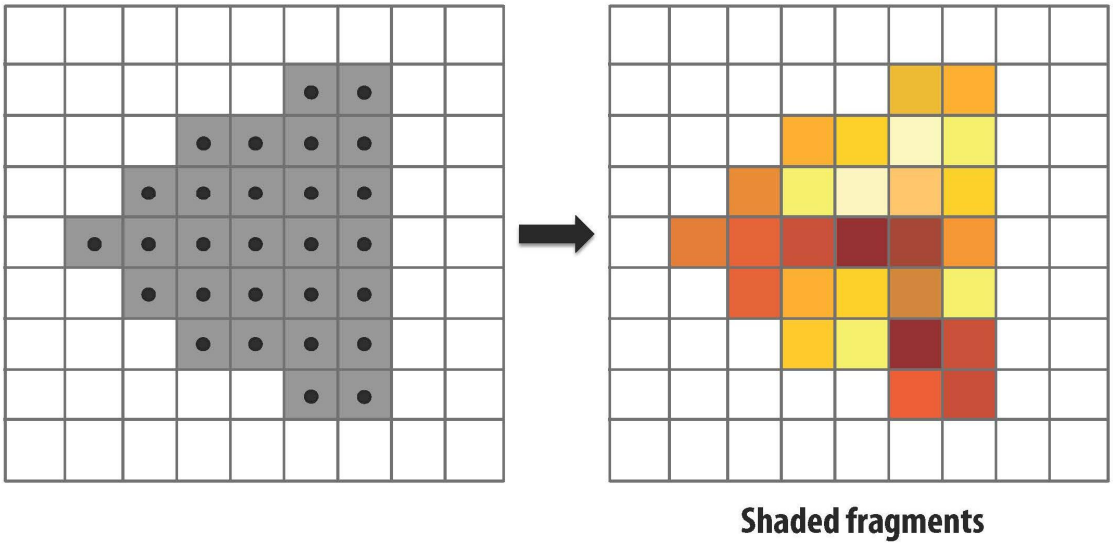

✓每个图元（Primitive）的光栅化（Rasterization）都是独立的。

Graphics Pipeline Overview, https://benkenobi007.github.io/Graphics-Pipeline-Overview/

像素操作（Pixel Operation）

Fragments are blended into the frame buffer at their pixel locations (z-buffer determines visibility)

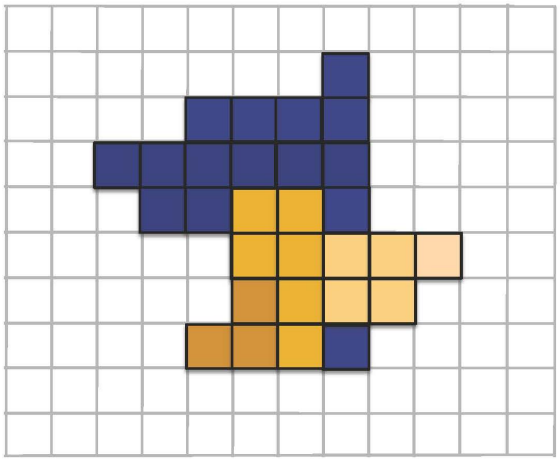

Pixels

Graphics Pipeline Overview, https://benkenobi007.github.io/Graphics-Pipeline-Overview/

流水线实体（Pipeline Entities）

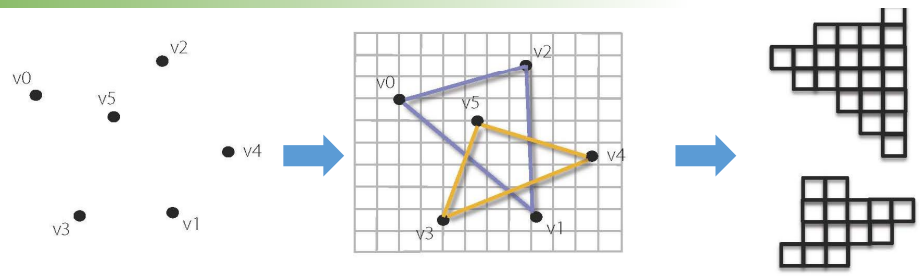

Vertices　　Primitives　　Fragments

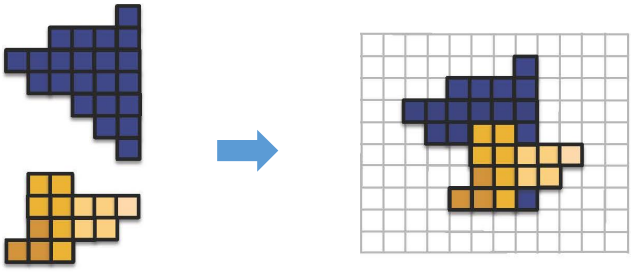

Fragments (shaded)　　Pixels

Graphics Pipeline Overview, https://benkenobi007.github.io/Graphics-Pipeline-Overview/

讲授内容

- 课程介绍
- GPU简介
  - 定义、发展史、总体构架
  - 功能（一）：图形图像处理
  - 功能（二）：通用计算、编程语言
  - 模拟器、生产商

GPU编程语言

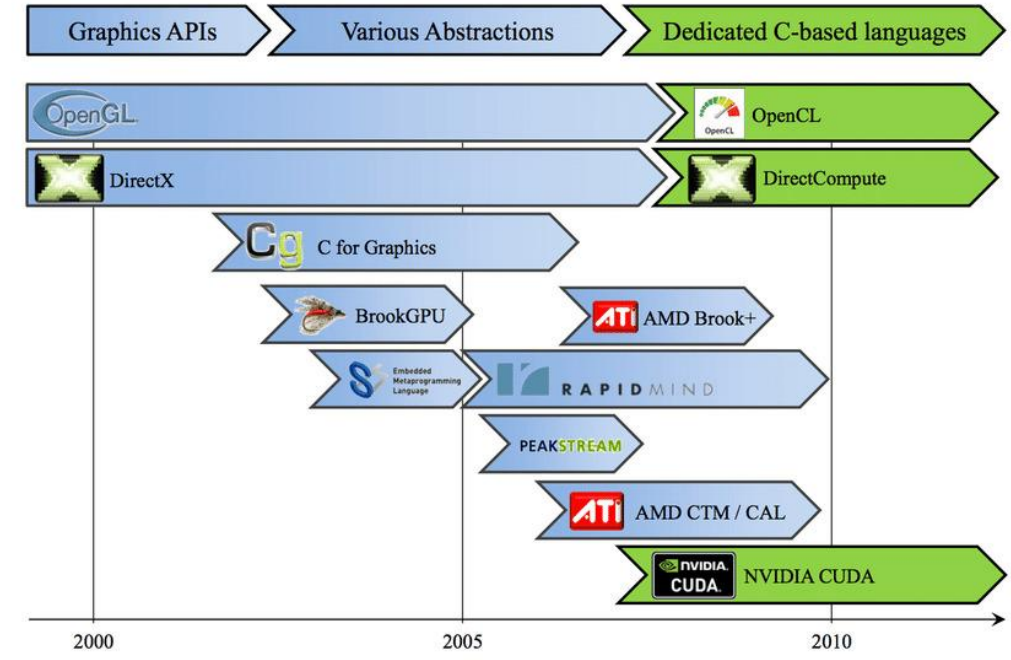

André R. Brodtkorb, Trond R. Hagen, Christian Schulz, Geir Hasle, GPU computing in discrete optimization. Part I: Introduction to the GPU, EURO Journal on Transportation and Logistics, 2013;

GPU架构：编程相关（英伟达GPU为例）

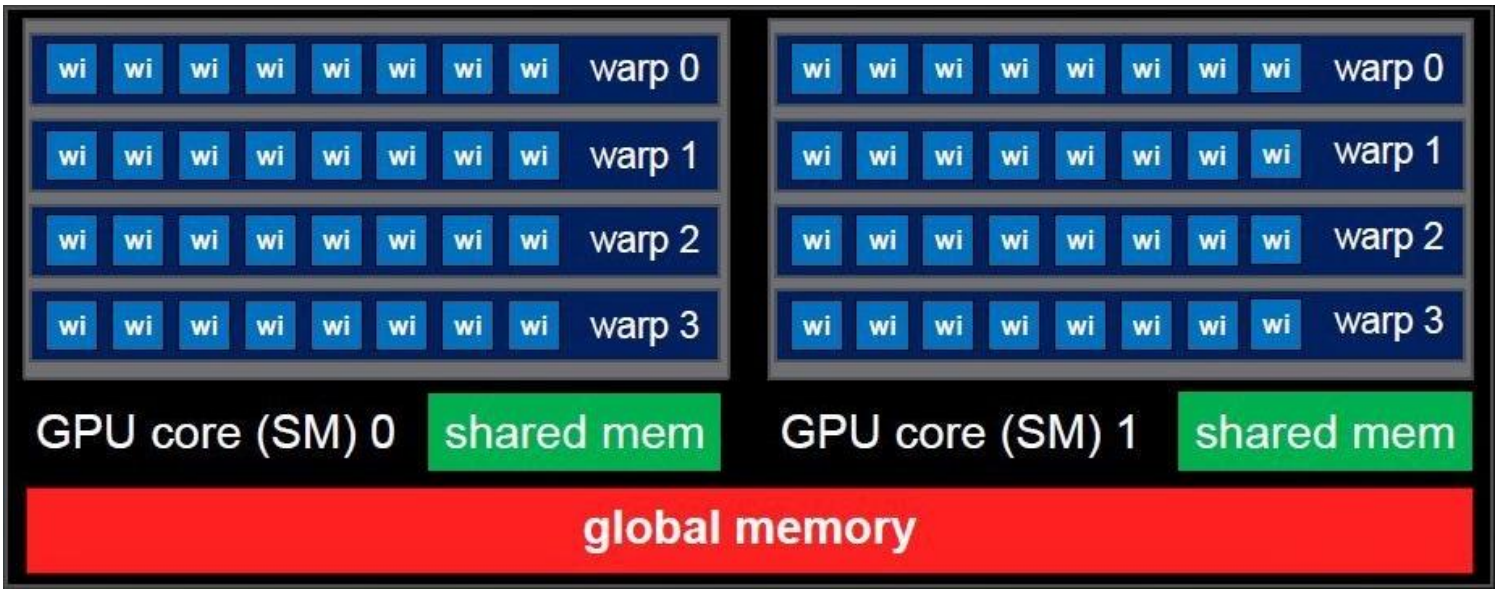

GPU编程语言：CUDA *v.s.* OpenCL

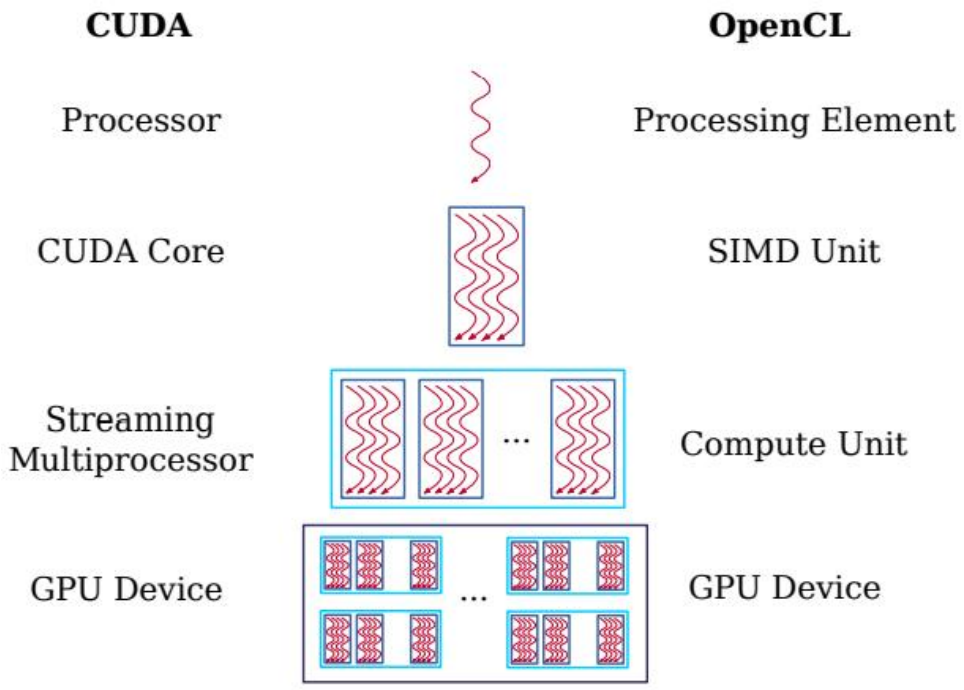

D. vom Bruch, Real-time data processing with GPUs in high energy physics, Journal of Instrumentation, 2020;

CUDA编程模型

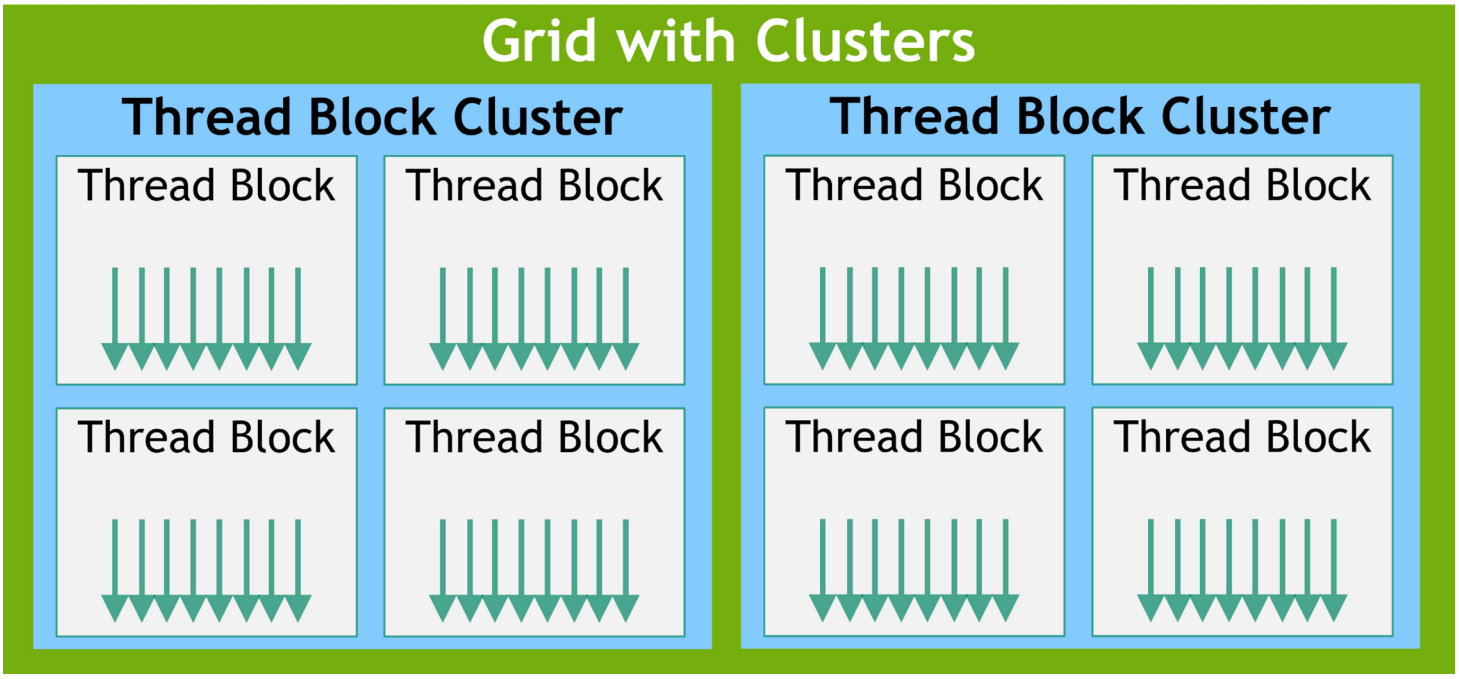

CUDA C++ Programming Guide, Nvidia;

CUDA编程模型

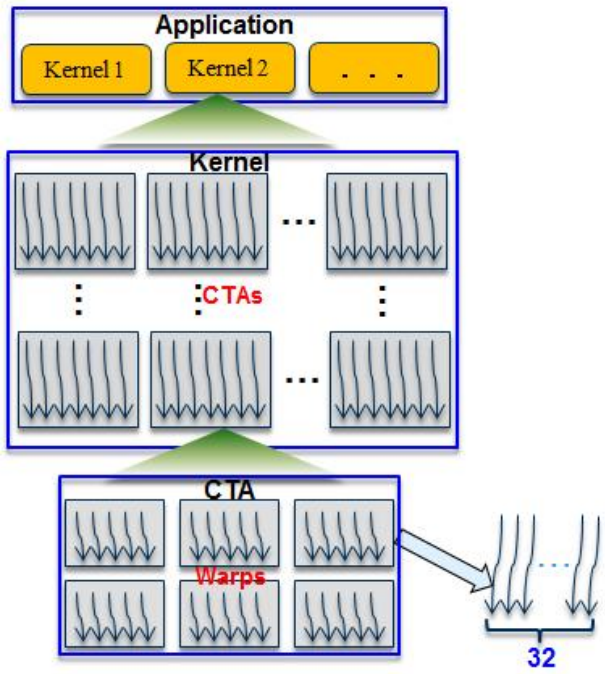

✓请描述thread是如何组织起来执行CUDA程序中kernel的？

Overview of GPGPU Architecture (NVIDIA Fermi Based), https://cinwell.wordpress.com/2013/09/06/overview-of-gpu-architecture-fermi-based/

讲授内容

- 课程介绍
- GPU简介
  - 定义、发展史、总体构架
  - 功能（一）：图形图像处理
  - 功能（二）：通用计算、编程语言
  - 模拟器、生产商

GPU模拟器

GPGPU-Sim

Accel-Sim

NVIDIA NVAS

GPU模拟器

GPU	指令集	模式	图形支持能力	软件栈支持
Ventus（承影）	RISC-V	SIMT	No	N/A
HWACHA	RISC-V	Vector	No	N/A
Simty	RISC-V	SIMT	No	N/A
MIAOW	AMD	SIMT	No	OpenCL
Scratch	AMD	SIMT	No	OpenCL
GPLGPU (kickstarter)	Custom		shaders 2D/3D Texture	
Theia	Custom	SIMT	Shaders Texture Units	OpenCL
FlexiGrip	Custom	SIMT	No	Custom
FGPU	Custom MIPS based ISA	SIMT	No	Custom
NyuziRaster	Custom	SIMT	Fixed-Function Rasterizer	Custom
Vortex	RISC-V	SIMT	Shaders Texture Units	OpenCL/OpenGL

GPU模拟器

表 2　异构模拟器对比

Simulator	Published Year	Developer and Link	Forward Mode	Citation Count	Language	Target Architecture	Operating System	Last Update Date
GPGPU-Sim[37]	2009	University of British Columbia https://github.com/gpgpu-sim/gpgpu-sim_simulations	Functional/ Cycle Accurate	1232	C++	GPGPU	×	2018-11
Qsilver[58]	2004	The University of Virginia Link not found	Cycle Accurate	96		GPU	×	
gem5-APU[59]	2015	AMD https://gem5.googlesource.com/amd/gem5	Cycle Accurate		C++ Python	APU	√	2018-11
GPU Ocelot[60]	2009	Georgia Institute of Technology http://code.google.com/p/gpuocelot/	Functional	25	C++	GPU	×	2013-04
FusionSim[61]	2013	University of Toronto https://sites.google.com/site/fusionsimulator/	Cycle Accurate	16	C++	CPU-GPU	×	2012-06
MV5[62]	2011	Argonne National Laboratory https://sites.google.com/site/mv5sim	Cycle Accurate	11	C++ Python	GPU-like SIMD/SIMT	×	2011-02
GpuTejas[63]	2014	Indian Institute of Technology http://www.cse.iitd.ac.in/tejas/gputejas/index.html	Cycle Accurate	5	Java	GPU	×	2019-05
gem5-gpu[64]	2014	University of Wisconsin-Madison https://gem5-gpu.cs.wisc.edu/wiki/	Functional/ Cycle Accurate	126	C++ Python	CPU-GPU	√	2017-01
HSAemu[65]	2014	National Tsing Hua University https://github.com/SSLAB-HSA/HSAemu	Functional/ Cycle Accurate	10	C	Heterogeneous System	√	2013-11
FATSEA[66]	2010	University of Murcia (Spain) Link not found	Cycle Accurate	1	C++	GPU	×	
Barra[67]	2009	Univ.de Perpignan https://gforge.inria.fr/scm/?group_id=5827	Functional	100	C++	GPGPU	×	2015-08
ATTILA[68]	2006	Norwegian University of Science and Technology https://github.com/attila-gpu/attila-sim	Cycle Accurate	112	C++	GPU	×	2015-04
Multi2Sim[69]	2012	Northeastern University https://github.com/Multi2Sim/multi2sim	Cycle Accurate	351	C++	CPU-GPU	×	2018-04
MacSim[50]	2012	Georgia Tech https://github.com/gtharch/macsim	Cycle Accurate	39	C++	CPU-GPU	×	2018-11
MGSim[70]	2013	Northeastern University https://github.com/svp-dev/mgsim	Cycle Accurate	19	C++	CPU-GPU	×	2017-04

Note: √ means support operating system; × means don't support operating system.

GPU的生产商：

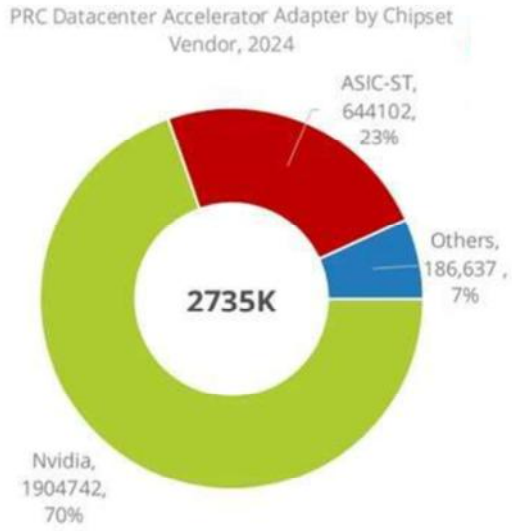

2024年中国市场各品牌GPU市场份额

slides from IDG

国产GPU的生产商

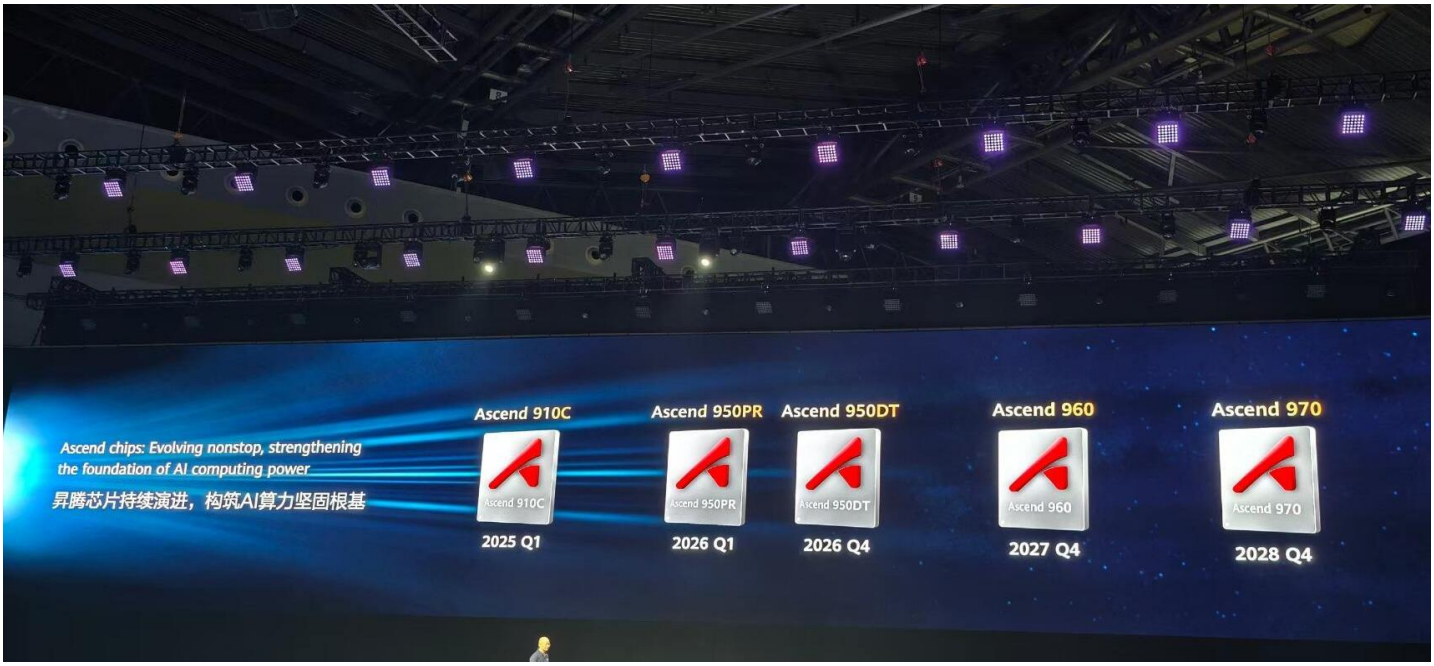

华为昇腾AI芯片路线图公布 https://wallstreetcn.com/articles/3755816?keyword=ai

国产GPU的生产商

企业名称	成立时间	核心技术	主要产品	应用领域
景嘉微	2006 年 4 月	支持国产 CPU 和国产操作系统的自主知识产权 GPU	JM5400、JM7201 、JM92 系列	军用工业、人工智能、云计算、金融、教育等领域
芯瞳半导体	2019 年 12 月	统一渲染 GPU 架构，具有高度可扩展的互联结构和计算阵列	GenBu01 GPU	信创、能源、交通、金融、人工智能等领域
壁仞科技	2019 年 9 月	自主原创的 GPU 芯片架构	BR100 GPU	人工智能、云计算、图形渲染、大数据等领域
摩尔线程	2020 年 10 月	3D 图形计算和高性能并行计算技术	MTT S60、MTT S2000、MTT S10	物理仿真、AI 计算、游戏娱乐、自动驾驶等领域
沐曦集成电路	2020 年 9 月	自主研发高性能 GPU 芯片架构及兼容国际主流生态的完整软件栈	MXN、MXC、MXG	深度学习、数据分析、物理仿真、云游戏和元宇宙等领域
瀚博半导体	2018 年 12 月	云端推理 DSA 架构、视频处理技术	SV100 系列云端推理芯片、VA1 通用 AI 推理加速卡	深度学习、AI 推理、云计算等领域
登临科技	2017 年 11 月	软件定义的异构人工智能计算平台	Goldwasser	自动驾驶、智慧城市、生物医疗、AI 计算等领域
天数智芯	2015 年 12 月	通用 GPU 云端芯片及超级算力系统提供商	7 纳米 GPGPU 高端自研云端训练芯片	自动驾驶、智慧医疗、智慧金融、智慧教育等领域
芯动科技	2007 年 10 月	一站式高速混合电路 IP 及芯片定制解决方案	风华 1 号	元宇宙、云游戏、云桌面、AI 计算等领域
龙芯中科	2010 年 4 月	自研的统一渲染架构	7A2000 桥片的 GPU 模块	金融、政务办公、网安、教育、通信、医疗等领域

现状与未来：国产GPU能否超越英伟达AMD？https://www.163.com/dy/article/HGL8JE7K05312NX9.html