

大模型系列 – AI 集群

NV GB200 互联集群架构



nvidia  zomi

© 2018 NVIDIA Corporation. All rights reserved. The NVIDIA logo are trademarks and/or registered trademarks of NVIDIA Corporation in the U.S. and other countries. Other company and product names may be trademarks of the respective companies with which they are associated.



本节内容


1. GH200 to NVL32 & SuperPod
2. GB200 to NVL32 & SuperPod
3. NV 产品演进的小结与思考

01 GH200

NVL32&SuperPod

GH200 Compute Tray

- GH200 Compute Tray 基于 NVIDIA MGX 设计 (IU) , 每个 Compute Tray 上有 2 个 GH200, 也就是 2 个 Grace CPU 和 2 个 H200 GPU



NVSwitch Tray

- 第一代 NVSwitch Tray 包含 2 个第 3 代 NVSwitch 芯片，共 128 个 NVLink Port，通信带宽上限为 6.4TB/s



GH200 NVL32

- 一个机柜有 16 x GH200 Compute Tray 和 9 x NVSwitch Tray, 共 32 x GH200 GPU + 18 x NVSwitch
- 实际 32 x GH200 有 $32 \times 18 = 576$ 个 NVLink, 只需 $576 / 64 = 9$ 个 NVSwitch 可以实现全互联



NVLink Switch x9



NVIDIA GH200 x32

GH200 NVL32

- 一个机柜有 16 x GH200 Compute Tray 和 9 x NVSwitch Tray, 共 32 x GH200 GPU + 18 x NVSwitch
- 实际 32 x GH200 有 $32 \times 18 = 576$ 个 NVLink, 只需 $576 / 64 = 9$ 个 NVSwitch 可以实现全互联

NVIDIA GH200 NVL32
Front View



Power shelves


8x Dual GH200 Compute Trays

9x NVLink Switch Trays

8x Dual GH200 Compute Trays

Power shelves

NVIDIA GH200 NVL32
Rear View



Liquid Cooling Manifold

NVLink Interconnect Cable Cartridges

GH200 SuperPod

- GH200 SuperPod 由 256 个 GH200 GPU 实现全互联，但并不是由 8 个 NVL32 组成的，而是由 32 个 8-Grace Hopper Superchip 组成。




GH200 SuperPod: 32 x 8-Grace Hopper Superchip

- 8 个 Hopper Compute Tray (8U) , 每个包含:
 - 1 个 GH200 GPU
 - 1 个 ConnectX-7 IB 网卡, 400Gb/s
 - 1 个 200 Gb/s 以太网卡
- 3 个 NVSwitch Tray (3U) , 共 6 个 NVSwitch


GH200 SuperPod: NVLink

- 每个 GH200 和每个 NVSwitch 上有 3 个 NVLink 连接，每个 NVSwitch 上使用了 24 个 Port
- 每个 NVSwitch 有 24 个 Port 与 L2 NVSwitch 相连，相当于每个 NVSwitch 使用 48 个 Port




GH200 SuperPod: NVLink

- GH200 SuperPod 由 32 x 8-Grace Hopper Superchip 组成, L1 包含 32 x 3=96 NVSwitch Tray (192 个 NVSwitch), L2 包含 36 个 NVSwitch Tray (64 个 NVSwitch)
- 每个 L1 NVSwitch Tray 有 24 x 2=48 个 Port 与 L2 NVSwitch Tray 相连, 因此需要 $96 \times 48 / (64 \times 2) = 36$ 个 L2 NVSwitch Tray



GH200 SuperPod: NVLink

256 个 GH200 通过两级 IB 交换机互联



02 GB200

NVL72&SuperPod


GB200 NVL72

- 一个 GB200 NVL72 Rack 包含 18 个 GB200 Compute Tray, 即 36 个 Grace CPU + 72 个 GPU, 9 个 NVSwitch Tray
- 显存为 $72 \times 192\text{GB} = 13.8\text{TB}$, CPU 对应 Fast Memory LPDDR5X 为 $480\text{GB} \times 36 = 17\text{TB}$, 共 Fast Memory 为 30TB



GB200 Compute Tray

- 基于 NVIDIA MGX 设计 (大小为 1U) ,
一个 Compute Tray 包含 2 个 GB200: 2 个 Grace CPU、4 个 Blackwell GPU
- 支持 1.7TB Fast Memory, 每个 Blackwell 显存为 $192\text{GB} \times 4 = 768\text{GB}$, 1.7TB 包含每个 GB200 额外 480GB LPDDR5X, 一共 $768\text{GB} + 480\text{GB} \times 2 = 1728\text{GB}$



GB200 NVSwitch Tray

- 一个 Switch Tray 包含两颗 NVLINK Switch 芯片，累计提供 $72 \times 2 = 144$ 个 NVLINK Port
- 单颗 NVSwitch 芯片，上下各 36 个 Port，带宽为 7.2TB/s
- 28.8 Tbps 交换容量，相对于最领先 51.2Tbps 交换芯片小一些




GB200 NVL72

- 单个 GB200 子系统则包含 $2 \times 18 = 36$ 个 NVLink 5th Port
- 整个系统对外互联上并没有采用 OSFP 光模块接口，而是直接通过后置的铜线背板连接




GB200 NVL72

- GB200 NVL72 外形尺寸，需要大约 120kW/机架。每机架超过 40kW，因此 GB200 需要液冷。
- 通用 CPU 机架支持高达 12kW/机架，而更高密度的 H100 风冷机架通常仅支持大约 40kW/机架。
- 18 个 IU Computer Tray 和 9 个 NVSwitch Tray 组成。每个 Computer Tray 高 1U，包含 2 个 Bianca 板。每个 Bianca 板包含 1 个 Grace CPU 和 2 个 Blackwell GPU。NVSwitch Tray 有两个 28.8Tb/s NVSwitch5。




GB200 NVL36

- GB200 NVL36 * 2, 两个并排互连在一起的机架。每个机架包含 18 个 Grace CPU 和 36 个 Blackwell GPU。
- 在 2 个机架之间, 仍然保持 NVL72 中所有 72 个 GPU 之间的无阻塞全对全。
- 每个计算托盘的高度为 2U, 包含 2 个 Bianca 板。每个 NVSwitch 托盘都有两个 28.8T b/s NVSwitch5 芯片。



GB200 NVL36

- 2025 年第二季度将推出B200 NVL72 和 NV L36x2 规格，将使用 x86 CPU 而不是 Nvidia 内部的 grace CPU。
- 这种规格称为 Miranda。semi 认为每个计算托盘的 CPU 到 GPU 的比例将保持不变，即每个计算托盘 2 个 CPU 和 4 个 GPU。



思考

A: H100 时代大家预测光模块的需求会激增，不过很快 B200 时代大家有改变方向了，预测后面光模块需求急剧下降，因为类似于大型机的交付时代后面选用铜互联。ZOMI 老师怎么看？



思考

A: H100 时代大家预测光模块的需求会激增，不过很快 B200 时代大家有改变方向了，预测后面光模块需求急剧下降，因为类似于大型机的交付时代后面选用铜互联。

Q: 看每一代架构演进：Hopper 使用松耦合连接方式，机柜的散热和部署会相对灵活，而且同时提供 HGX 方式部署；B200 采用大型机交付方式，铜互联有效降低整体功耗和增加超节点内的稳定性。




GB200 NVL72

	GB200 NVL72	GB200 Grace Blackwell Superchip
Configuration	36 Grace CPU : 72 Blackwell GPUs	1 Grace CPU : 2 Blackwell GPU
FP4 Tensor Core ²	1,440 PFLOPS	40 PFLOPS
FP8/FP6 Tensor Core ²	720 PFLOPS	20 PFLOPS
INT8 Tensor Core ²	720 POPS	20 POPS
FP16/BF16 Tensor Core ²	360 PFLOPS	10 PFLOPS
TF32 Tensor Core	180 PFLOPS	5 PFLOPS
FP32	6,480 TFLOPS	180 TFLOPS
FP64	3,240 TFLOPS	90 TFLOPS
FP64 Tensor Core	3,240 TFLOPS	90 TFLOPS
GPU Memory Bandwidth	Up to 13.5 TB HBM3e 576 TB/s	Up to 384 GB HBM3e 16 TB/s
NVLink Bandwidth	130TB/s	3.6TB/s
CPU Core Count	2,592 Arm® Neoverse V2 cores	72 Arm Neoverse V2 cores
CPU Memory Bandwidth	Up to 17 TB LPDDR5X Up to 18.4 TB/s	Up to 480GB LPDDR5X Up to 512 GB/s

GB200 NVL72 互联拓扑

- 每个 B200 有 18 个 NVLINK Port, 9 x Switch Tray 共计 18 颗 NVLINK Switch 芯片, 每个 B200 的 Port 连接一个 NVSwitch 芯片, Switch Tray 上单 NVSwitch 有 72 个 Port, 刚好构成 NVL72, 把 72 x B200 芯片全部连接起来。



思考


1. 在 NVL72 机柜中，所有 NVSwitch 交换机已经没有额外接口互联构成更大规模的两层交换集群。那么 NVL576 (72×8) 是怎么把 8 个 NVL72 链接起来的吗？



GB200 SuperPod


- Q: 通过 Scale-Out RDMA 网络互联，而并不是通过 Scale-Up NVLINK 网络互联
- 由 8 个 NVL72 组成，共 576 个 Blackwell GPU，要实现其全互联，和上一代 256 个 GH200 全互联类似两级 NVSwitch Tray：
 - L1 NVSwitch Tray 一半 Port 连接 576 个 Blackwell GPU，需要 $576 \times 18 / (144 / 2) = 144$ 个 NVSwitch Tray（剩余 144×72 个 Port）。
 - L2 NVSwitch Tray Port 全部与 L1 NVSwitch 剩余 Port 连接，需要 $144 \times 72 / 144 = 72$ 个 NVSwitch Tray。L2 每一个 NVSwitch Tray 都与 L1 所有 NVSwitch Tray 连接。

GB200 SuperPod



GB200 SuperPod 互联拓扑

- 为以后扩展到576卡集群，每个交换机都提供36个对外互联的Uplink，累计单个机柜有 $36 * 2 * 9 = 648$ 个上行端口，构成NVL576需要有16个机柜，则累计上行端口数为 $648 * 16 = 10,368$ 个，实际上可以由9个第二层交换平面构成，每个平面内又有36个子平面，由18个Switch Tray构成



思考

- I. 从下一代大模型本身的算力需求来看，超节点已经成为 High Bandwidth Domain，当 Scale-Up 的 NVLink 网络规模增大时，实际 HBD 之间互联 RDMA 带宽带来的性能收益在减小。所以 SuperPod 的需求量到底有多大？到底会不会迎来思科时刻？





03

小结与思考




分析 1：制造工艺对性能提升有限

- 单 die GPU 性能并没有大幅提升，NV 代际间受先进工艺限制约束：
 1. 先进工艺代际升级时间长（2~3 年）；
 2. 代际间单芯片面积性能提升~15%，功耗提升35%；



分析 2：封装能力提升解决工艺提升慢

- 拼封装技术的时代，从传统单 die 主处理芯片，演进到双 die 合封。
 - HBM 实现多 die 和多层合封技术，解决内存墙问题；
 - 多 die 合封实质上是在解决工艺发展受限；



BLACKWELL

THE ENGINE OF THE NEW INDUSTRIAL REVOLUTION

20 petaFLOPS of AI performance


192GB of HBM3e

8TB/s of memory bandwidth

Full stack, CUDA enabled

分析 3：引入 Tray 板卡概念

- Nvidia 不仅使用封装来解决部件性能瓶颈，也运用板卡（Tray）概念。
 - Hopper 板卡支持 1 CPU + 1 GPU；
 - Blackwell 板卡支持 1 CPU + 2 GPU，同制造工艺下算力增加 4 倍+，单 GPU 包括两 die 主芯粒。



Kiến trúc của một GB200 Grace Blackwell Superchip

分析 4：网络带宽提升

- NVLink 交换机端口数和单端口带宽都增加了1倍，为更大规模 NVLink 组网提供支撑。
 - 单柜支持 72 GPU 组网（NVL72）， SuperPod 支持 576 GPU 组网（NVL576）；
 - 中等规模微调大模型， NVL72 + IB 可实现千卡互联更有性价比优势；
 - 大规模训练大模型， NVL576 + IB + Internet 可以组成万卡超级集群；



GB200 NVL72 | 36 GRACE CPUs
72 BLACKWELL GPUs
Fully Connected NVLink Switch Rack

Training	720 PFLOPs
Inference	1,440 PFLOPs
NVL Model Size	27T params
Multi-Node Bandwidth	130 TB/s
Multi-Node All-Reduce	260 TB/s

分析 5：网络带宽提升弥补计算性能

- Serdes当前 224Gbps 继续提升到 336或 448
- 单芯片 NVLink 数量再提升 1 倍，如从现在 18 提升到 36
- 单柜集群实现 72 to 144 GPU 超级互联，计算密度继续提升1倍，带宽提升 4 倍。




GB200 NVL72 — 36 GRACE CPUs
72 BLACKWELL GPUs
Fully Connected NVLink Switch Rack

Training	720 PFLOPs
Inference	1,440 PFLOPs
NVL Model Size	27T params
Multi-Node Bandwidth	130 TB/s
Multi-Node All-Reduce	260 TB/s

分析 6:

- 交换机端口数更多，以支持更大规模集群。交换机端口数量越多越能减少层级数，这不仅可以减少网络跳数，还可以提升单柜的计算密度。
- NV 未来还会享受先进工艺的红利，可以持续发展多年。并且，光通信这一块的能力，还有待进步释放，包括芯片内光互联，芯片直接出光等。



Thank you

把AI系统带入每个开发者、每个家庭、
每个组织，构建万物互联的智能世界

Bring AI System to every person, home and
organization for a fully connected,
intelligent world.

Copyright © 2023 XXX Technologies Co., Ltd.
All Rights Reserved.

The information in this document may contain predictive statements including, without limitation, statements regarding the future financial and operating results, future product portfolio, new technology, etc. There are a number of factors that could cause actual results and developments to differ materially from those expressed or implied in the predictive statements. Therefore, such information is provided for reference purpose only and constitutes neither an offer nor an acceptance. XXX may change the information at any time without notice.



Course [chenzomi12.github.io](https://github.com/chenzomi12)

GitHub github.com/chenzomi12/DeepLearningSystem



Reference 参考&引用

1. <https://www.fibermall.com/blog/nvidia-b100-b200-gh200-nvl72-superpod.htm>
2. <https://www.facebook.com/photo.php?fbid=1048191653980302&id=100063684318606&set=a.747927134006757>

