

NVIDIA TESLA V100 GPU 加速器

当今市场上数据中心 GPU 中的精尖之作。

NVIDIA® Tesla® V100 是当今市场上为加速人工智能、高性能计算和图形的数据中心 GPU 中的精尖之作。Tesla V100 采用全新一代 NVIDIA Volta™ 架构,可在单个 GPU 中提供高达 100 个 CPU 的性能,助力数据科学家、研究人员和工程师解决以前无法应对的难题。

规格

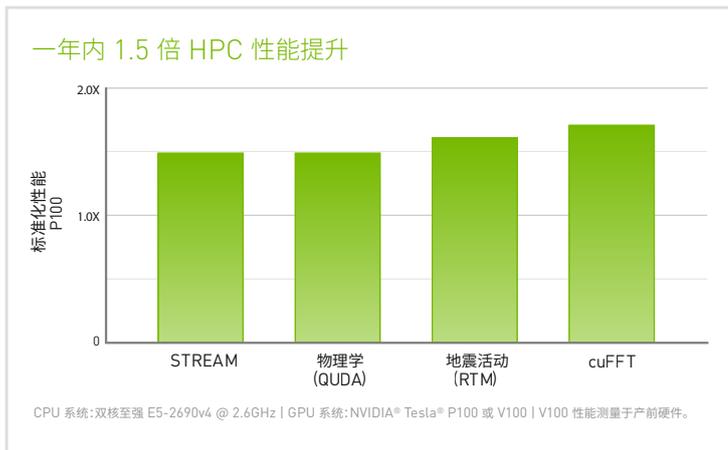
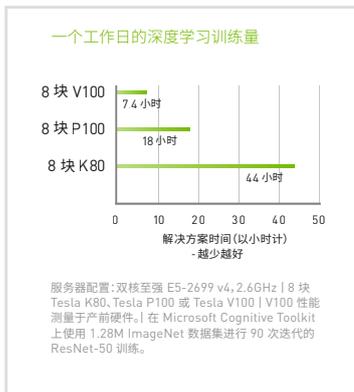
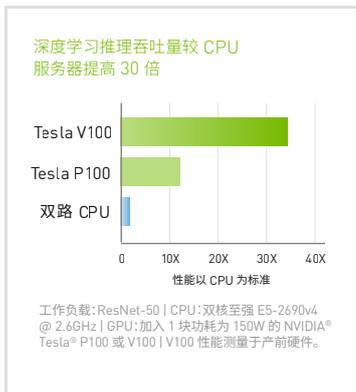


Tesla V100 PCIe




Tesla V100 SXM2

GPU 架构	NVIDIA Volta	
NVIDIA Tensor 核心数量	640	
NVIDIA CUDA® 核心数量	5,120	
双精度浮点运算能力	7 TFLOPS	7.5 TFLOPS
单精度浮点运算能力	14 TFLOPS	15 TFLOPS
Tensor 性能	112 TFLOPS	120 TFLOPS
GPU 内存	16 GB HBM2	
显存带宽	900 GB/秒	
ECC	是	
互联带宽*	32 GB/秒	300 GB/秒
系统接口	PCIe Gen3	NVIDIA NVLink
外形尺寸	PCIe 全高/全长	SXM2
最大功耗	250 W	300 W
散热解决方案	被动式	
计算 API	CUDA, DirectCompute, OpenCL™, OpenACC	

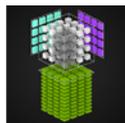


突破性的创新



VOLTA 架构

通过在一个统一架构内搭配使用 CUDA 内核和 Tensor 内核, 配备 Tesla V100 GPU 的单台服务器可以取代数百台通用 CPU 服务器来处理传统的 HPC 和深度学习。



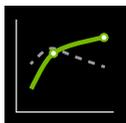
TENSOR 核心

Tesla V100 配有 640 个 Tensor 核心, 可提供 120 亿次级的深度学习性能。与 NVIDIA Pascal™ GPU 相比, 可为深度学习训练提供 12 倍张量浮点运算能力; 为深度学习推理提供 6 倍张量浮点运算能力。




新一代 NVLINK

Tesla V100 中采用的 NVIDIA NVLink 可提供 2 倍于上一代的吞吐量。8 块 Tesla V100 加速器能以高达 300 GB/s 的速度互联, 从而发挥出单个服务器所能提供的最高应用性能。



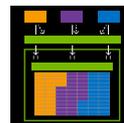
最大节能模式

全新的最大节能模式可允许数据中心在现有的功耗预算内, 使每个机架最高提升 40% 的计算能力。在此模式下, Tesla V100 以最大处理效率运行时, 可提供高达 80% 的性能而只需一半的功耗。



HBM2

Tesla V100 将 900 GB/s 的改良版原始带宽与高达 95% 的 DRAM 利用效率相结合, 在 STREAM 上测量时可提供高于 Pascal GPU 1.5 倍的显存带宽。



可编程性

Tesla V100 的架构设计初衷即是为了简化可编程性。其全新的独立线程调度能力可实现细粒度同步, 并能通过在琐碎的工作之间共享资源进而提升 GPU 的利用率。

Tesla V100 是 Tesla 数据中心计算平台在深度学习、HPC 和图形领域的旗舰产品。Tesla 平台可为 450 余项 HPC 应用程序和各大深度学习框架提供加速。从桌面、服务器到云服务, 均可使用此平台, 不仅能带来巨额性能收益, 还能创造众多成本节约机会。

各深度学习框架



Caffe2



Microsoft

mxnet

PYTORCH

TensorFlow

theano

450+ GPU 加速应用程序



AMBER



ANSYS Fluent



GAUSSIAN



GROMACS



LS-DYNA



NAMD



OpenFOAM



Simulia Abaqus



VASP



WRF

如需详细了解 Tesla V100, 请访问 www.nvidia.cn/v100

© 2017 NVIDIA Corporation. 保留所有权利。NVIDIA、NVIDIA 徽标、Tesla、NVIDIA GPU Boost、CUDA 和 NVIDIA Volta 均为 NVIDIA Corporation 在美国和其他国家/地区的商标和/或注册商标。OpenCL 是 Apple Inc. 的商标, 经 Khronos Group Inc. 许可使用。其他所有商标和版权均为其各自所有者的资产。2017 年 8 月

