

NVIDIA DGX A100

適用於 AI 基礎架構的通用系統



擴充企業 AI 的挑戰

每家企業都必須利用人工智慧（AI）轉型，才能在充滿挑戰的時代生存並茁壯。然而，企業需要改進傳統方法的 AI 基礎架構平台，其採用緩慢的運算架構，這些架構因分析、訓練和推論工作負載而孤島化。舊方法產生複雜問題、增加成本、限制規模速度且不適用於現代 AI。企業、開發人員、資料科學家和研究人員需要整合所有 AI 工作負載的新平台，以簡化基礎架構並加快 ROI。

適用於所有 AI 工作負載的通用系統

NVIDIA DGX™ A100 是適用於所有 AI 工作負載的通用系統 — 從分析到訓練以至推論。DGX A100 樹立運算密度的新基準，將 5 petaFLOPS 的 AI 效能融入 6U 規格，以單一整合式系統取代傳統的運算基礎架構。DGX A100 還能提供前所未有的效能，利用 NVIDIA A100 Tensor 核心 GPU 的多執行個體 GPU 功能精細分配運算能力，讓管理員能夠分配適合特定工作負載的資源。如此可確保最大、最複雜的工作，以及最小、最簡單的工作都受到支援。利用來自 NGC 的最佳化軟體執行 DGX 軟體堆疊，將密集的運算能力與完整的工作負載彈性結合，使 DGX A100 成為單節點部署，和透過 NVIDIA DeepOps 部署的大規模 Slurm 和 Kubernetes 叢集的理想選擇。

NVIDIA DGXpert 直接支援

NVIDIA DGX A100 不僅只是伺服器，而是完整的軟硬體平台，此平台以從全球最大的 DGX 試驗場 — NVIDIA DGX SATURNV 獲得的知識為基礎，並且以數千名 NVIDIA DGXpert 為後盾。DGXpert 是精通 AI 的專家，提供規範性指導和設計專業知識以加快 AI 轉型。其在過去十年內累積豐富的知識和經驗，協助您將 DGX 投資的價值最大化。DGXpert 可確保關鍵應用程式快速啟用並維持流暢運作，大幅縮短取得洞見的時間。

系統規格

GPU	8x NVIDIA A100 Tensor 核心 GPU
GPU 記憶體	共 320 GB
效能	5 petaFLOPS AI 10 petaOPS INT8
NVIDIA NVSwitches	6
系統電源用途	最大 6.5kW
CPU	雙 AMD Rome 7742， 共 128 核心，2.25 GHz (基礎)、 3.4 GHz (最大提升)
系統記憶體	1TB
網路	8x 單連接埠 Mellanox ConnectX-6 VPI 200Gb/s HDR InfiniBand 1x 雙連接埠 Mellanox ConnectX-6 VPI 10/25/50/100/200Gb/s 乙太網路
儲存裝置	OS: 2x 1.92TB M.2 NVME drives 作業系統：2x 1.92TB M.2 NVME 磁碟機 內部儲存空間：15TB (4x 3.84TB) U.2 NVME 磁碟機
軟體	Ubuntu Linux OS
系統重量	271 lbs (123 kgs)
含包裝系統重量	315 lbs (143kgs)
系統尺寸	高度 10.4 in (264.0 mm) 寬度最大 19.0 in (482.3 mm) 長度最大 35.3 in (897.1 mm)
工作溫度範圍	5°C 至 30°C (41°F 至 86°F)

最快解決時間

NVIDIA DGX A100 搭載八個 NVIDIA A100 Tensor 核心 GPU，為使用者提供無與倫比的加速，並且針對 NVIDIA CUDA-X™ 軟體和端對端 NVIDIA 資料中心解決方案堆疊，全面進行最佳化。NVIDIA A100 GPU 帶來新的精度 TF32，其運作方式與 FP32 相同，同時為 AI 提供比上一代高 20 倍的 FLOPS，而且最棒的是，不必修改任何程式碼即可獲得此加速。使用 NVIDIA 的自動混合精度時，A100 只需使用 FP16 精度時增加一行程式碼，即可進一步將效能提升 2 倍。A100 GPU 還具有領先同級的每秒 1.6 兆位元組數 (TB/s) 記憶體頻寬，比上一代增加超過 70%。此外，A100 GPU 擁有更多晶片內建記憶體，包括比上一代大將近 7 倍的 40MB Level 2 快取，將運算效能最大化。DGX A100 也首次搭載下一代 NVIDIA NVLink™，將 GPU 至 GPU 直接頻寬加倍，達到每秒 600 十億位元組數 (GB/s)，比 PCIe Gen 4 高將近 10 倍，以及新的 NVIDIA NVSwitch，比上一代快 2 倍。此前前所未有的效能提供最快解決時間，讓使用者解決過去無法克服或難以克服的挑戰。

世界上最安全的企業用 AI 系統

NVIDIA DGX A100 為 AI 企業提供最穩健的安全態勢，以多層方法保護所有主要硬體和軟體元件。包含基板管理控制器 (BMC)、CPU 機板、GPU 機板、自我加密磁碟機和安全啟動的 DGX A100 內建安全性，讓 IT 專注於啟用 AI，而不必花時間進行威脅評估和緩解。

以 Mellanox 造就無與倫比的資料中心擴充性

NVIDIA DGX A100 擁有所有 DGX 系統中最快的 I/O 架構，是大型 AI 叢集的基礎構件，例如可擴充 AI 基礎架構的企業藍圖 — NVIDIA DGX SuperPOD™。DGX A100 搭載 8 個單連接埠 Mellanox ConnectX-6 VPI HDR InfiniBand 介面卡（用於叢集化）、以及 1 個雙連接埠 ConnectX-6 VPI 乙太網路介面卡（用於儲存和網路），全部都能達到 200Gb/s。DGX A100 將龐大的 GPU 加速運算效能與最先進的網路軟硬體最佳化結合，可擴充至數百或數千個節點以解決最大的挑戰，例如對話式 AI 和大規模影像分類。

DGX A100 提供 6 倍的訓練效能



以 PyTorch 執行 BERT 預先訓練傳輸量，包括 (2/3) 階段 1 和 (1/3) 階段 2 | 階段 1 區段長度 = 128，階段 2 區段長度 = 512 | V100:DGX-1 搭配 8x V100，使用 FP32 精度 | DGX A100:DGX A100 搭配 8x A100，使用 TF32 精度

DGX A100 提供 172 倍的推論效能



CPU 伺服器：2x Intel Platinum 8280，使用 INT8 | DGX A100:DGX A100 搭配 8x A100，使用 INT8，結構稀疏

DGX A100 提供 13 倍的資料分析效能



3000x CPU 伺服器與4x DGX A100 | 已發布的 Common Crawl 資料集：128B 邊緣，2.6TB 影像

與可靠的資料中心領導者共同打造經驗證的基礎架構解決方案

我們與儲存和網路技術的領導供應商合作，提供結合 NVIDIA DGX POD™ 參考架構優點的各種基礎架構解決方案。我們透過 NVIDIA 合作夥伴網路提供完全整合且可立即部署的解決方案，使 IT 的資料中心 AI 部署變得更簡單、更快速。

欲深入瞭解 NVIDIA DGX A100，請瀏覽 www.nvidia.com/zh-tw/data-center/dgx-a100/