


NVIDIA H100 Tensor Core コア GPU

比類なきパフォーマンス、拡張性、セキュリティをあらゆるデータセンターに



アクセラレーテッド コンピューティングを桁違いに高速化

NVIDIA H100 Tensor Core GPU コア GPU は、比類のないパフォーマンス、拡張性、セキュリティをあらゆるワークロードに提供します。NVIDIA®NVLink®Switch System との組み合わせで、最大256基のH100 GPUを接続して、エクサスケールのワークロードを高速化します。さらに専用のTransformer Engineで、数兆個のパラメーターを持つ言語モデルにも対応します。H100は、NVIDIA Hopper TMアーキテクチャが実現する画期的な変革を利用して業界最高水準の対話型AIを提供し、大規模言語モデルの処理を前世代の30倍以上の速さで実行します。

エンタープライズ AI への対応は？

NVIDIA H100 Tensor Core GPUには、NVIDIA AI Enterpriseソフトウェアスイートのエンタープライズサポートを含む5年間のソフトウェアサブスクリプションが付属しており、非常に優れた性能によってAI活用を簡素化します。これにより、企業や組織は、AIチャットボット、レコメンデーションエンジン、ビジョンAIなど、H100で高速化するAIワークフローを構築するために必要なAIフレームワークおよびツールが活用できるようになります。**NVIDIA AI Enterprise ソフトウェア サブスクリプション**やこれに関連するNVIDIA H100サポートの詳細については、こちらをご覧ください。

エンタープライズからエクサスケールまで、さまざまな規模のワークロードをセキュアに高速化

NVIDIA H100 GPUは、第4世代のTensor CoreとFP8精度のTransformer Engineを搭載し、大規模言語モデルを使うトレーニングにおいて前世代比で最大9倍高速化、推論の速度を最大30倍と驚異的に高めることで、AI市場におけるNVIDIAのリーダーシップをさらに確かなものにします。ハイパフォーマンスコンピューティング(HPC)のアプリケーションについても、FP64によるFLOPS(1秒間に実行できる浮動小数点演算の回数)を3倍に高め、新しいDPX命令は、動的計画法のアルゴリズムを最大7倍まで高速化します。第2世代のマルチインスタンスGPU(MIG)、組み込みのNVIDIAコンフィデンシャルコンピューティング、NVIDIA NVLink Switch Systemを装備するH100は、エンタープライズからエクサスケールまで、さまざまな規模のデータセンターのあらゆるワークロードを安全に高速化します。

あらゆるワークロードをあらゆる場所で加速する

NVIDIA H100は、NVIDIA データセンタープラットフォームにとって不可欠な存在です。AI、HPC、データ分析のために構築されたこのプラットフォームは、3,000以上のアプリケーションを高速化します。データセンターからエッジまであらゆる場所で利用でき、劇的なパフォーマンス向上とコスト削減の両方を実現します。

規格


| | H100 SXM | H100 PCIe | H100 NVL ¹ |
|-----------------------------|---|--|---|
| FP64 | 34 TFLOPS | 26 TFLOPS | 68 teraFLOPS |
| FP64 Tensor コア | 67 TFLOPS | 51 TFLOPS | 134 teraFLOPS |
| FP32 | 67 TFLOPS | 51 TFLOPS | 134 teraFLOPS |
| TF32 Tensor コア | 989 TFLOPS ² | 756 TFLOPS ² | 1,979 teraFLOPS ² |
| BFLOAT16 Tensor コア | 1,979 TFLOPS ² | 1,513 TFLOPS ² | 3,958 teraFLOPS ² |
| FP16 Tensor コア | 1,979 TFLOPS ² | 1,513 TFLOPS ² | 3,958 teraFLOPS ² |
| FP8 Tensor コア | 3,958 TFLOPS ² | 3,026 TFLOPS ² | 7,916 teraFLOPS ² |
| INT8 Tensor コア | 3,958 TOPS ^{2*} | 3,026 TOPS ² | 7,916 TOPS ² |
| GPU メモリ | 80GB | 80GB | 188GB |
| GPU メモリ帯域幅 | 3.35TB/s | 2TB/s | 7.8TB/s ³ |
| デコーダー | 7 NVDEC 7 JPEG | 7 NVDEC 7 JPEG | 14 NVDEC 14 JPEG |
| 最大熱設計電力 (TDP) | Up to 700W (configurable) | 300-350W (configurable) | 2x 350-400W (configurable) |
| マルチインスタンス GPUs | Up to 7 MIGs @ 10GB each | Up to 7 MIGs @ 10GB each | Up to 14 MIGs @ 12GB each |
| フォームファクター | SXM | PCIe > dual-slot > air-cooled | 2x PCIe > dual-slot > air-cooled |
| 相互接続 | NVLink > 900GB/s PCIe > Gen5: 128GB/s | NVLink > 600GB/s PCIe > Gen5: 128GB/s | NVLink > 600GB/s PCIe > Gen5: 128GB/s |
| サーバーオプション | NVIDIA HGX™ H100 partner and NVIDIA Certified Systems™ with 4 or 8 GPUs NVIDIA DGX™ H100 with 8 GPUs | Partner and NVIDIA Certified Systems with 1-8 GPUs | Partner and NVIDIA Certified Systems with 2-4 pairs |
| NVIDIA AI Enterprise | Add-on | Included | Included |

1 Preliminary specifications. May be subject to change. Specifications shown for 2x H100 NVL PCIe cards paired with NVLink Bridge.

2 With sparsity.

3 Aggregate HBM bandwidth.


GPT-3のAI学習を最大9倍高速化



予想されるパフォーマンスは変更される可能性があります。GPT-3 1750億個トレーニングA100クラスター: HDR IBネットワーク, H100クラスター: NDR IB ネットワーク | 3,950 億パラメーターと 1T トークンのデータセットを使ったトレーニング Mixture of Experts (MoE) Transformer Switch-XXL のバリエーション, A100 クラスター: HDR IBnetwork, H100クラスター: NDR IBネットワークとNVLink Switch Systemの組み合わせ

大規模モデルを使うAI 推論を最大30倍高速化

Megatron チャットボット推論 (5300億個のパラメータ)



入力シーケンス長を128、出力シーケンス長を20としたときの Megatron 5,300 億パラメーター モデル チャットボットによる推論 | A100クラスター: HDR IB ネットワーク | H100 クラスター: 16 基 H100 構成の NDR IB ネットワーク | 32 基 A100と16 基 H100 の1秒および 1.5 秒での比較 | 16 基 A100と16基H100の2秒でん比較

NVIDIA Hopper がもたらす画期的なテクノロジー

NVIDIA H100 Tensor コア GPU

NVIDIA のアクセラレーテッドコンピューティングのニーズに合わせてカスタマイズされた最先端の TSMC 4N プロセスで製造されており、800 億のトランジスタを集積した H100 は、これまでに作られた世界で最も先進的なチップです。この飛躍的な進歩により、データセンター規模で AI、HPC、メモリ帯域幅、相互接続、通信が高速化されます。

Transformer Engine

Transformer Engine は、Transformer モデルのトレーニングと推論を高速化するために特別に設計されたソフトウェアと NVIDIA Hopper Tensor コア テクノロジーを組み合わせています。Hopper Tensor コアは、FP8とFP16 が混在する精度を適用することで、Transformer の AI 演算を大幅に高速化できます。

NVLink Switch System

NVLink Switch System は、マルチ GPU の入出力 (IO) を GPU 当たり 900 GB/秒の双方向帯域幅で複数のサーバーにスケールさせます。これは PCIe Gen5 の帯域幅の 7 倍以上です。このシステムは、最大256 基のH100 をサポートし、NVIDIA Ampere アーキテクチャの Infini and HDR の 9 倍の帯域幅を提供します。

NVIDIA コンフィデンシャル コンピューティング

NVIDIA コンフィデンシャル コンピューティングは、Hopper に組み込まれたセキュリティ機能です。これにより、NVIDIA H100 は世界初のコンフィデンシャルコンピューティング機能付きのアクセラレーターとなっています。使用中のデータとアプリケーションの機密性と完全性を保護しながら、H100 GPU による比類のない高速化も獲得できます。

第2世代マルチインスタンスGPU (MIG)

Hopper アーキテクチャの第2世代 MIG は、仮想化環境におけるマルチテナント、マルチユーザー構成をサポートし、7つの安全なテナントに対してサービス品質 (QoS) を最大化するために、GPU を分離した適切なサイズに安全に分割します。

DPX 命令

Hopper のDPX 命令は、動的プログラミングアルゴリズムの処理を CPU と比較して 40 倍、NVIDIA Ampere アーキテクチャ GPU と比較して 7 倍に高速化します。これにより、病気の診断、リアルタイムでの経路の最適化、グラフ分析に必要な時間が大幅に短縮されます。

H100 と NVIDIA AI プラットフォームを導入

NVIDIA AI は、本番環境向け AI の包括的なオープン プラットフォームであり、NVIDIA H100GPU を基盤とします。NVIDIA のアクセラレーテッド コンピューティング インフラストラクチャ、インフラストラクチャの最適化と AI の開発、展開のためのソフトウェア スタック、市場投入を速めるためのアプリケーションワークフローが、このプラットフォームに含まれます。無料のハンズオンラボを利用して、**NVIDIA AI と NVIDIA H100 を NVIDIA LaunchPad** でお試ください。



始めるには？

NVIDIA H100 Tensor コア GPU の詳細については、<https://www.nvidia.com/ja-jp/data-center/h100/>