

インテル HPC-AI ロードマップ

2024年3月12日

矢澤 克巳
インテル株式会社 HPC事業開発部長





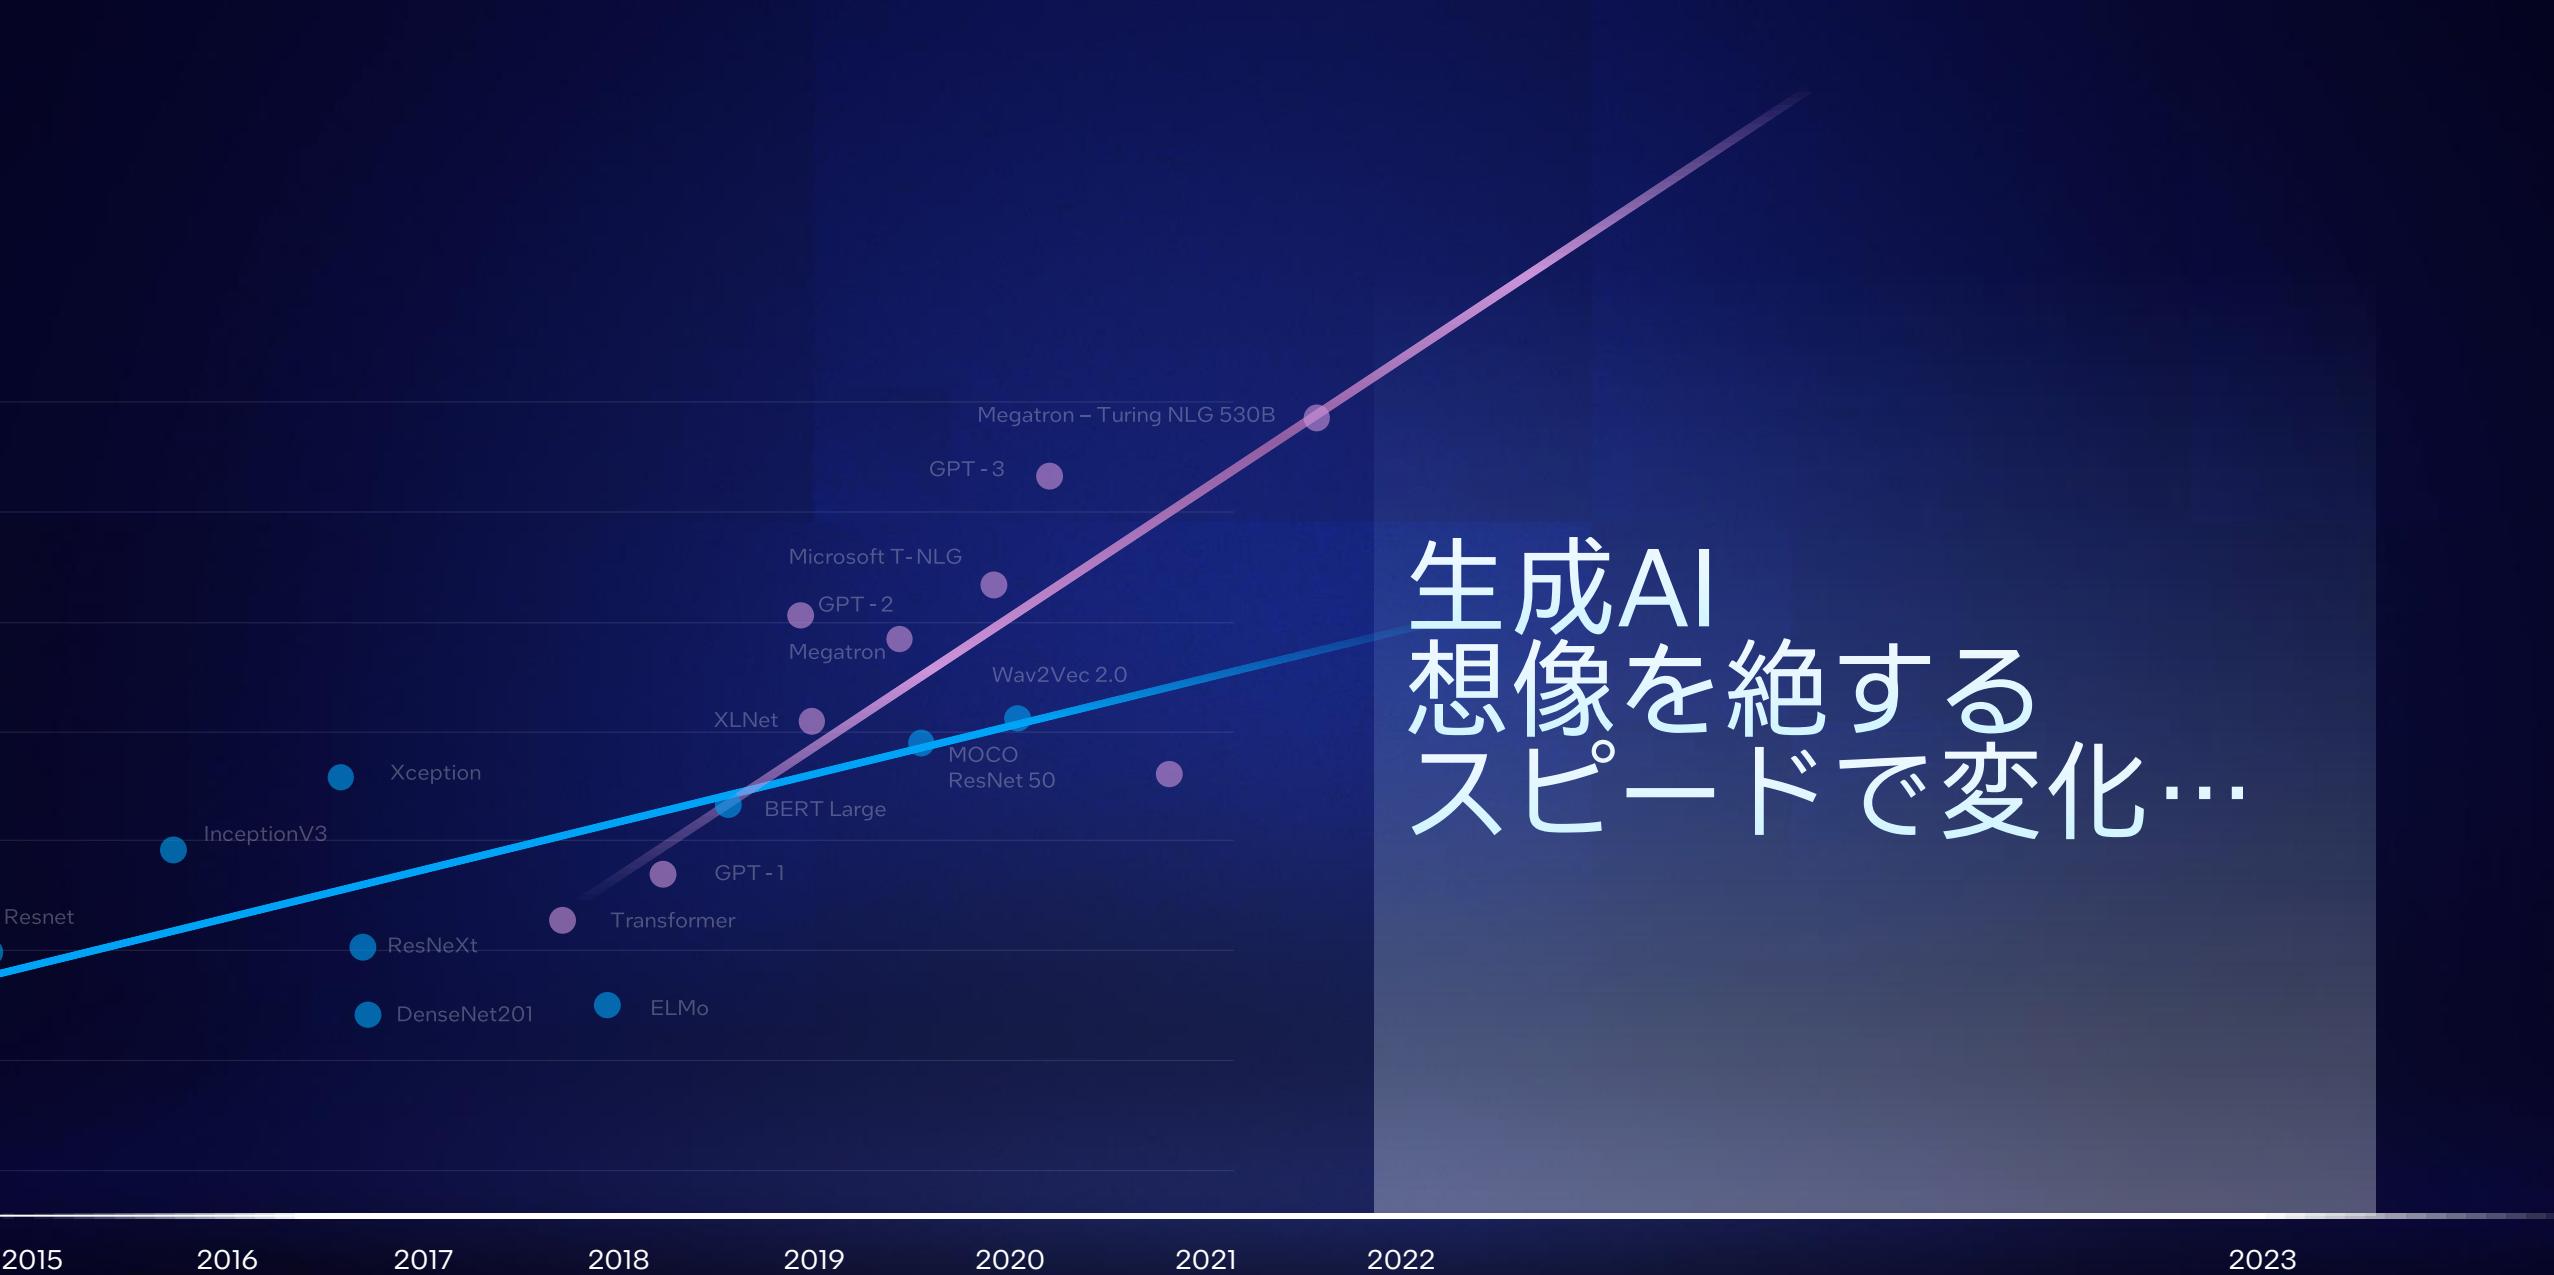
Siliconomy

シリコノミー

シリコンの可能性によって実現する経済成長
現代経済の維持と発展に半導体は不可欠

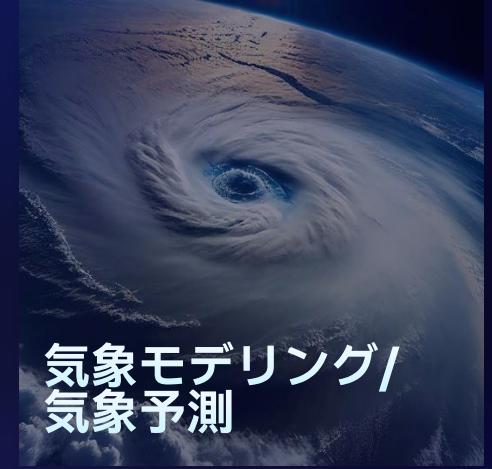
- ・ テクノロジーは現代の生活に広く浸透しており、コンピューティングの需要が拡大している
- ・ 「Superpowers」(コンピューティング、接続性、インフラ、AI、センシングなど)が相互に結合し、新たな可能性を切り拓いている
- ・ これにより、コンピューティング技術が急速に進化し、その基盤としてシリコンが重要な役割を果たしている。

シリコノミーの世界へようこそ



Source: Moore, S. (2022), "Nvidia's Next GPU Shows That Transformers Are Transforming AI", IEEE Spectrum.

科学分野に AIブームが到来...



インテル データセンター ロードマップ

E-Core
CPU

P-Core
CPU

AI
専用アクセラレータ

HPC & AI
GPU

Visual Cloud
GPU

FPGA

インテル® Xeon®
プロセッサー
コードネーム Sierra Forest

インテル® Xeon®
プロセッサー
コードネーム Clearwater Forest

第四世代 インテル® Xeon®
スケーラブル・プロセッサー

第五世代 インテル® Xeon®
プロセッサー
コードネーム Emerald Rapids

インテル® Xeon®
プロセッサー
コードネーム Granite Rapids

Habana®
Gaudi® 2

Habana®
Gaudi® 3

インテル® Data Center GPU マックス・シリーズ

次世代 GPU
コードネーム Falcon Shores

インテル® Data Center GPU Flex Series

インテル® Data Center GPU Flex Series
コードネーム Melville Sound

15+ new FPGAs on
schedule to PRQ in
2023

Next Gen FPGAs

2023

2025+

Sierra Forest demo

2 processors with 288 cores

```
processor : 567
processor : 568
processor : 569
processor : 570
processor : 571
processor : 572
processor : 573
processor : 574
processor : 575
demo@srubuntu22p4-3405:~$ █
```

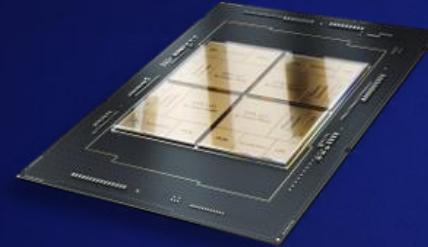


288 cores
Intel® Xeon® with E-core
Launch 2024

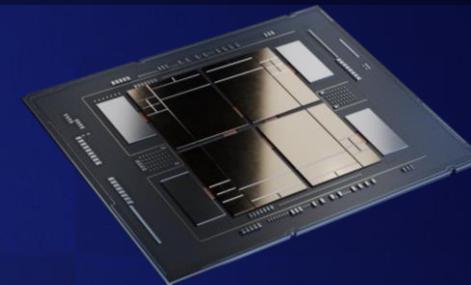
インテル® Xeon® プロセッサー

HPC と AI アクセラレーションに最適化された特徴的な新機能

第4世代インテル® Xeon® スケーラブル・プロセッサー



インテル® Xeon® CPU マックス



ブレークスルー・テクノロジー

DDR5

強化されたメモリバンド幅

PCIe 5

高いスループット

CXL 1.1

次世代 IO

内蔵AI アクセラレーション

インテル® Advanced Matrix Extensions (AMX)

ディープラーニングの推論および学習処理性能を向上

広帯域メモリ

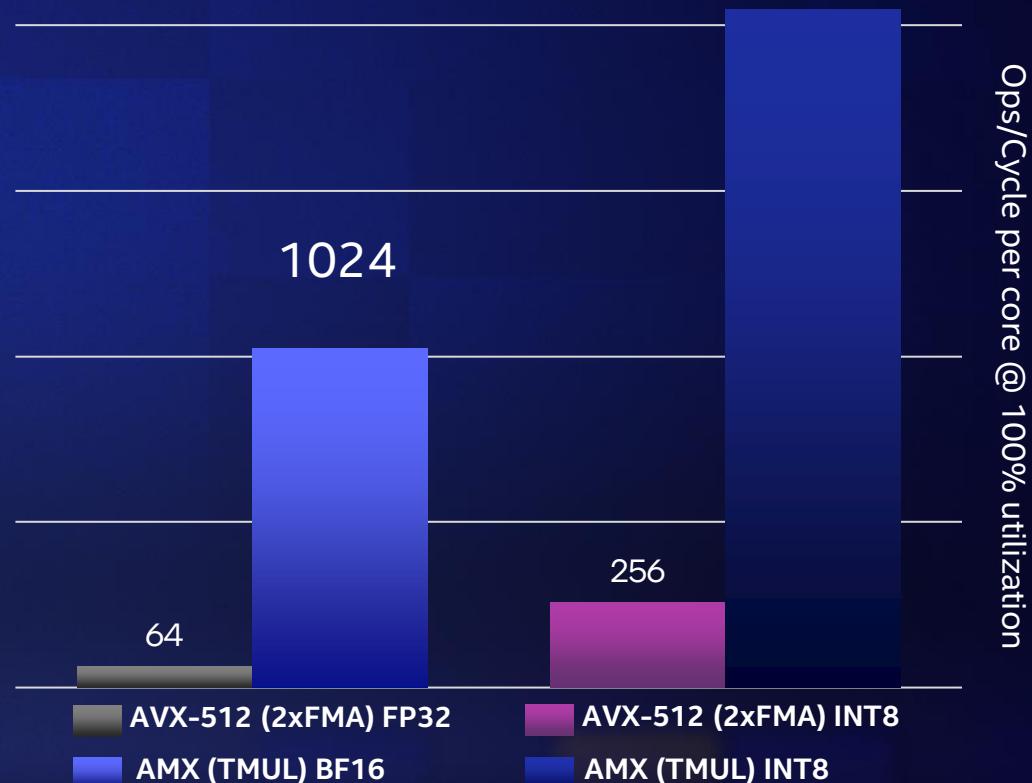
HBM2e

広帯域を必要とするワークロードの性能を飛躍的に向上

インテル® Advanced Matrix Extensions (AMX)

ディープラーニングの推論および学習処理性能を向上

2048



Results have been simulated. For workloads and configurations visit www.intel.com/ArchDay21claims. Results may vary



X86初 HBMを持つ唯一のCPU

最適なメモリ選択肢となりうる

64GB

HBM2e
4 stacks of
16GB

最大

220GF/s

HPCG

最大

2GB

HBM per Core

Memory Modes

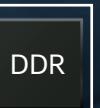
HBM Only

Bootable from HBM
No code change



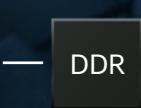
HBM Flat

2 Memory Regions
SW Optimization Needed



HBM Caching

HBM as cache for DDR
No code change

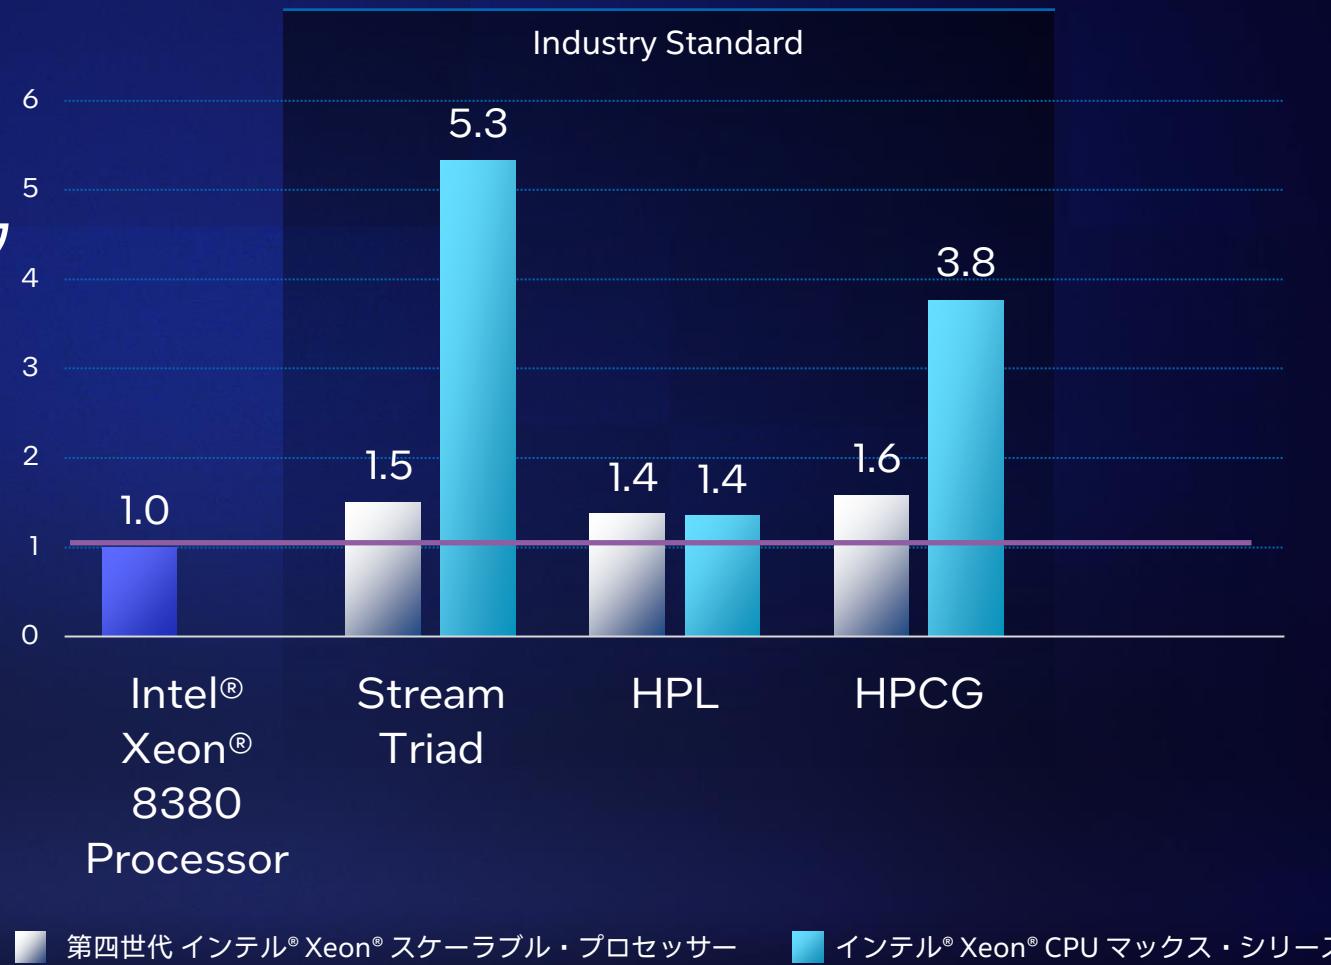




メモリ帯域を要求するベンチマーク
CPU MAXでは最大
5倍の性能

2S インテル® Xeon® CPU マックス・シリーズ vs.
2S 第三世代 インテル® Xeon® 8380 プロセッサー

Relative Perf. Higher is better

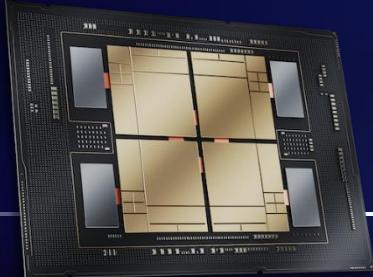


See backup for workloads and configurations. Results may vary.



コア数差を超えた性能

HPCG 性能



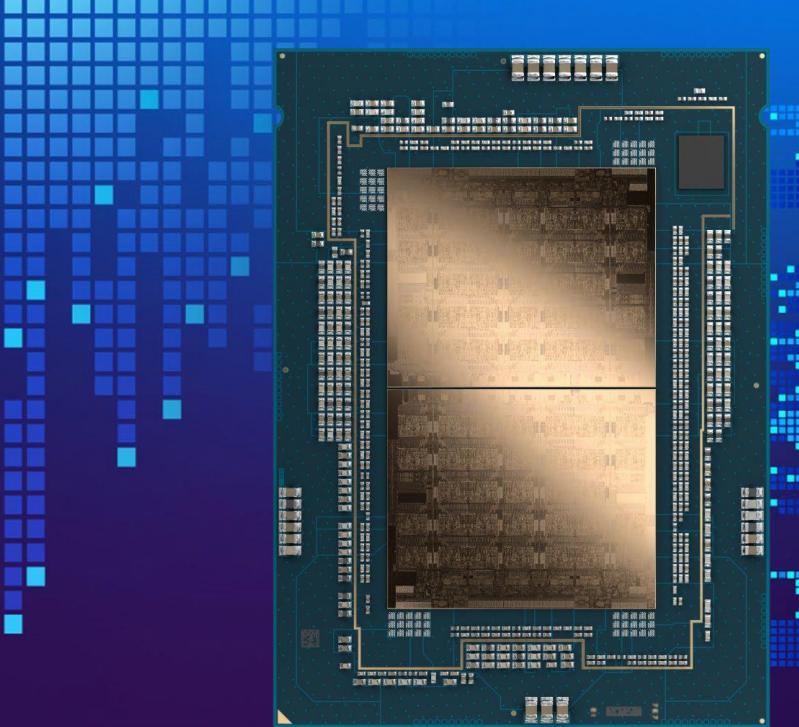
1x

AMD EPYC 9654

インテル® Xeon®
CPU マックス
9480



Visit www.intel.com/performanceindex for workloads and configurations. Results may vary.

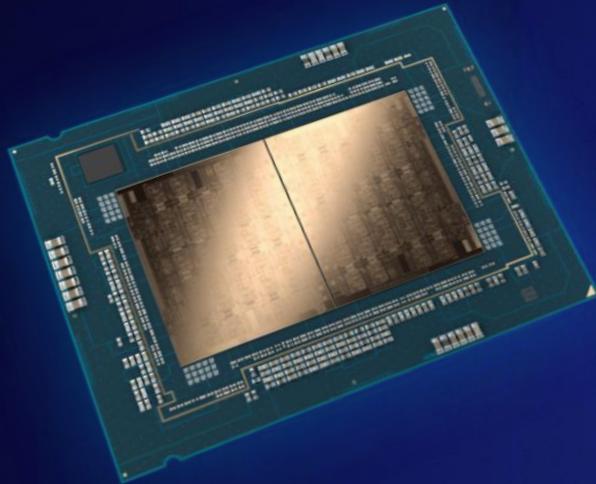


第五世代 インテル® Xeon® プロセッサー

Formerly codenamed Emerald Rapids

2023年12月14日発表

第五世代 インテル® Xeon® プロセッサー



ワークロードに最適化された
電力効率の高いコンピュート

高速メモリ 8x DDR5, 5600 MT/s

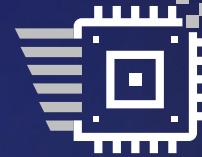
拡張I/O: CXL タイプ1と2, PCIe Gen 5, 80レーン



AI
音声認識

最大
1.4倍

higher throughput
(rec/sec) on
Xeon 8592+
vs
Xeon 8480+ (BF16)



HPC
LAMMPS -
Copper

最大
1.4倍

higher performance
On
Xeon 8592+
vs
Xeon 8480+

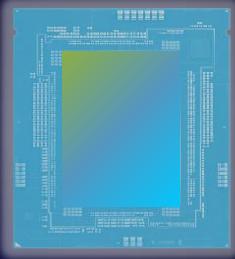


メディア
Transcode
(FFMPEG)

最大
1.2倍

aggregate FPS
on
Xeon 8592+
vs
Xeon 8480+

将来のインテル® Xeon® プロセッサー codenamed Granite Rapids



Extends the Intel® Xeon® processor Advantage

2-3x

より高いAIワークロード性能¹

2.8x

より高いメモリバンド幅¹

2.9X

DeepMD+LAMMPS AI インファレンス²

- より多いコア数, より高い周波数, Intel® Advanced Matrix Extensions (Intel® AMX)
- FP16 を追加
- 12 メモリチャネルおよび MCR サポート (large LLM モデルに有効)
- HPC と AI ワークロードに最適な TCO を実現

1 - Based on architectural projections as of August 21, 2023 vs prior generation platforms. Your results may vary.

2 - See intel.com/performanceindex for workloads and configurations. Your results may vary.

MCR DIMM Memory

Granite Rapids向け2-Rank RDIMMによる
同容量でより高いメモリバンド幅を持つ

最大
8800
MT/s

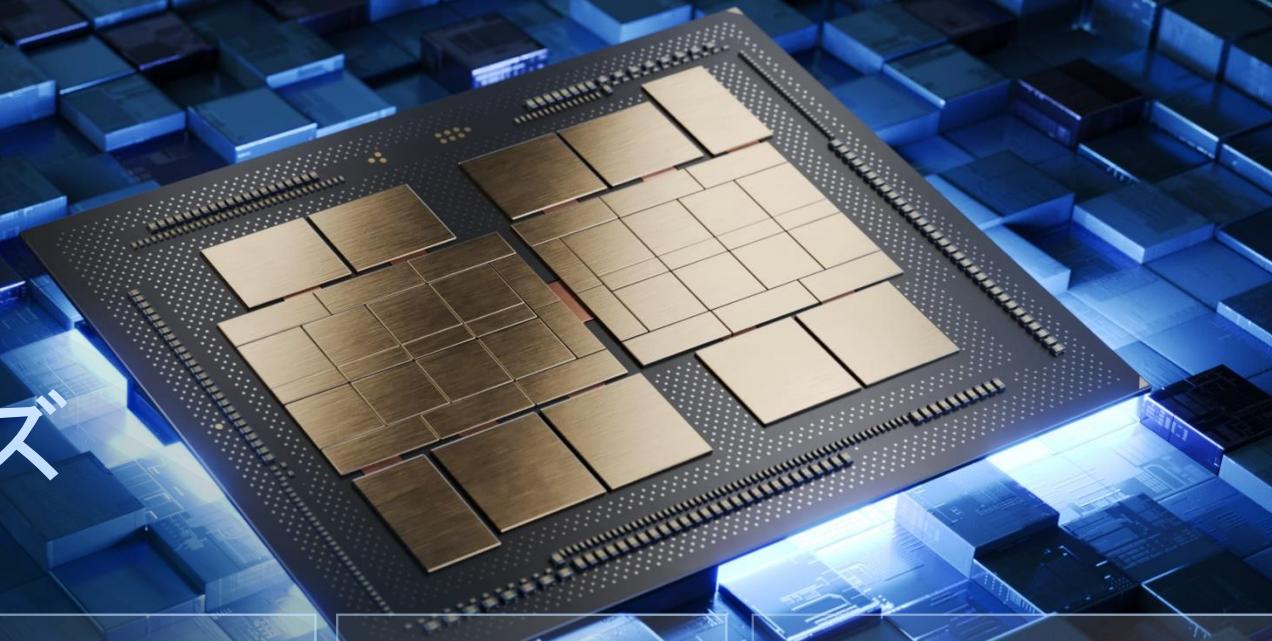
最大
83% peak
B/W increase

2 socket
>1.5 TB/s

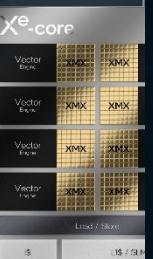




インテル® Data Center GPU マックス・シリーズ



最大
128
X^e HPC
Cores

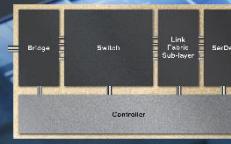


The diagram illustrates the internal structure of an Xe core. It shows four Vector Engines, each consisting of four Xe cores, and four XMX units. Below the core, there is a "Load / Store" unit. At the bottom, a progress bar indicates "15 / 51" with a small arrow icon.

52TF
Peak FP64
Throughput

最大
839TF
Peak BF16
Throughput

128 MB
HBM2e
Memory



The diagram shows the components involved in GPU-to-GPU communications via Xe Links. It includes a "Bridge", "Switch", "Link Layer Sublayer", "Bus Disk", and a "Controller".

976 GB/s
GPU-to-GPU comms
via Xe Links

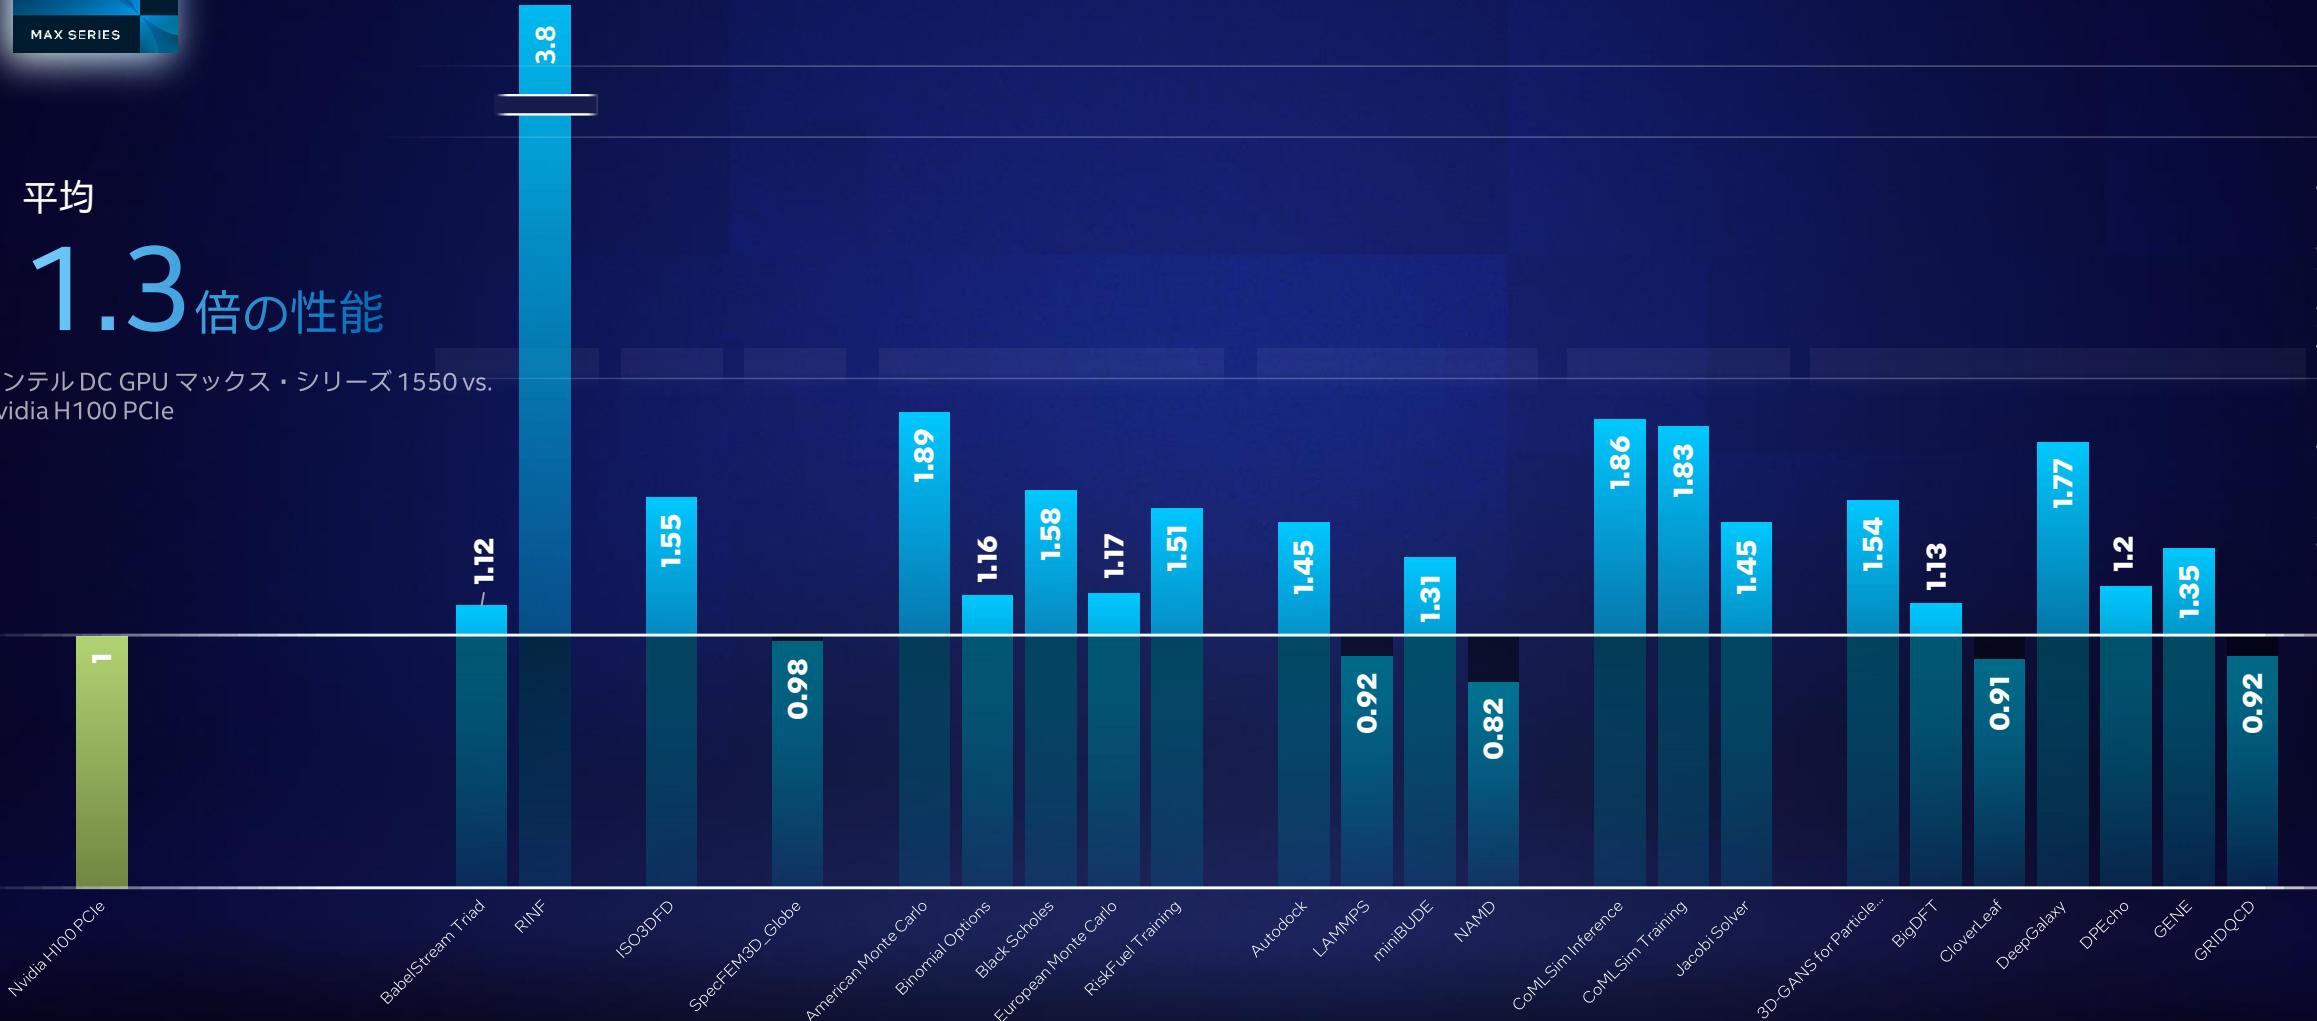


平均

1.3倍の性能

インテルDC GPU マックス・シリーズ 1550 vs.
Nvidia H100 PCIe

標準
ベンチマーク エネル
ギー 地球
システム
モデル 金融 サービス ライフとマテリアル
サイエンス 製造 物理



Visit www.intel.com/performanceindex for workloads and configurations. Results may vary



100+ HPC Apps Running



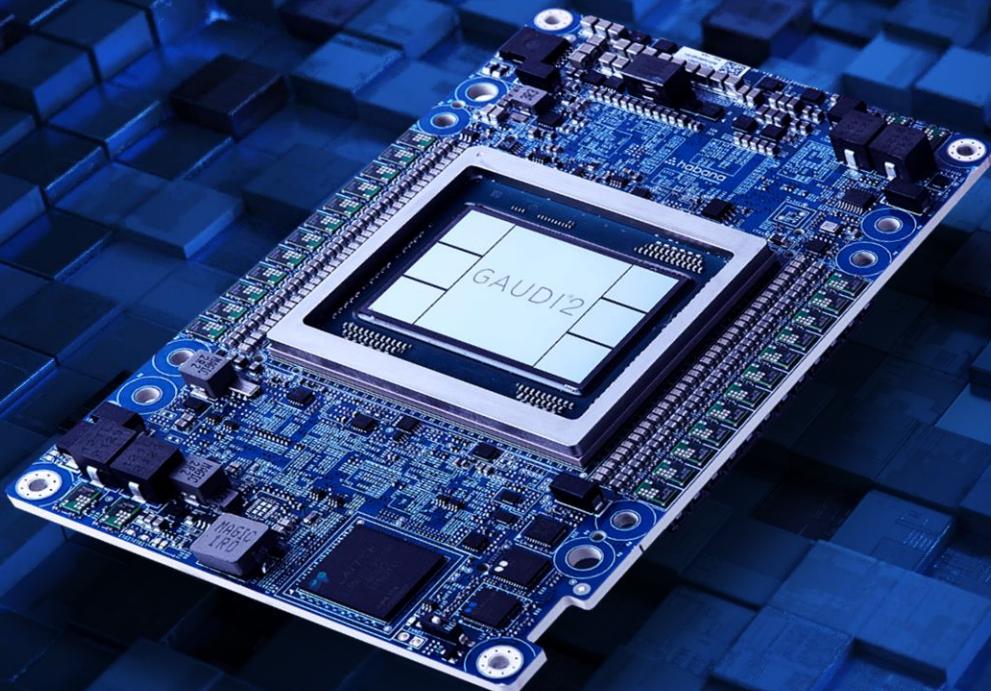
標準ベンチ	D,S,H,I,BF-GEMM	DAOS	Graph500	HPCG	HPL	IO500	MLPerf 2.0
	MLPerf.HPC	OSU	SPEChpc	Stream Triad	MLBench	SPEC ACCEL	SpMV
	RINF	ELPA	Ginkgo	HeFFTe	HYPRE	MFIX (AMReX)	
物理	HACC	DPEcho	GENE	NEKBONE	nekRS	OpenMC	
	XGC	CloverLeaf	Deep Galaxy	Gadget	GRID QCD	MILC	
	QUADA	Chroma	HotQCD	BQCD	CERN 3D GAN		
ライフサイエンス	Autodock-GPU	miniBUDE	AMBER	GROMACS	LAMMPS	NAMD	OpenMM
	Relion	Quantum Espresso	BerkeleyGW	CP2K	NWChem	QMCPACK	DeePMD
製造	ANSYS CoMLSsim	Jacobi Solver	Commercial EDA ISV	Commercial CFD ISV			
	ANSYS ParSeNet (SplineNet)	Commercial Multi-physics ISV	Commercial CFD ISV	Proprietary CFD code			
金融	Binomial Options	Black-Scholes	European Monte Carlo	American Monte Carlo	Riskfuel Risk Calculations	STAC-A2	
地球システム	SPECFEM3D GLOBE	ES3M/MMF	SeisSol				
エネルギー	RTM Stencil Kernel	ISO3DFD					

AI モデルサポート



Computer Vision	ResNet-50 v15	ResNeXt-101	ResNet-101	EfficientNet-B7	SE-ResNeXt50	TSM
Image Classification	Adorvym	CosmoFlow	RegNetY-32Y	ResNeXt-101	Candle Uno	Swin Transformer
画像セグメンテーション	Cosmic Tagger	Mask R-CNN	DenseNet169	FFN	3D-Unet	
	PointNet	DeepCAM	DRN-D-54	ResNeXt3D-101		
物体検知	SSD-ResNet34	SSD-ResNet50	EfficientDet	ShuffleNet	YOLO-v3	YOLO-v4
	Deep Fusion	CascadeRCNN-	MobileNet v3	SSD-MobileNet	MMA	ResNet101-FPN
NLP	BERT-Large	Stable Diffusion	ALBERT	FastFormers	Transformer-LT	Big Bird
言語モデリング	BERT-base	GP-J	BLOOM	DistilBERT	RoBERTa	XLNet
音声認識	RNN-T	LAS - Listen Attend & Smell	Wave2Vec	QuartzNet		
音声合成	FastSpeech2	Tacotron-2 with LPCNet				
リコメンデーション	DLRM	DSSM	ESSM	Wide & Deep	DeepFM	
	DIN	AttRec	DIEN	MMOE		

GAUDI[®]2



7nm

Process
Technology

24

Tensor
Processor Cores

96 GB

On-Board
HBM2

48 MB

SRAM

24

Integrated
Ethernet ports

Availability

Cloud

Intel Developer Cloud

On-Prem

Supermicro Gaudi2 Server

Intel® Gaudi® 2 AI アクセラレータ

MLPerf GPT-3 学習ベンチマーク

- MLPerfの結果を提出した唯一のAIアクセラレーター3社のうちの1社
- FP8により103%GPT-3性能を向上
- 価格性能の優位性

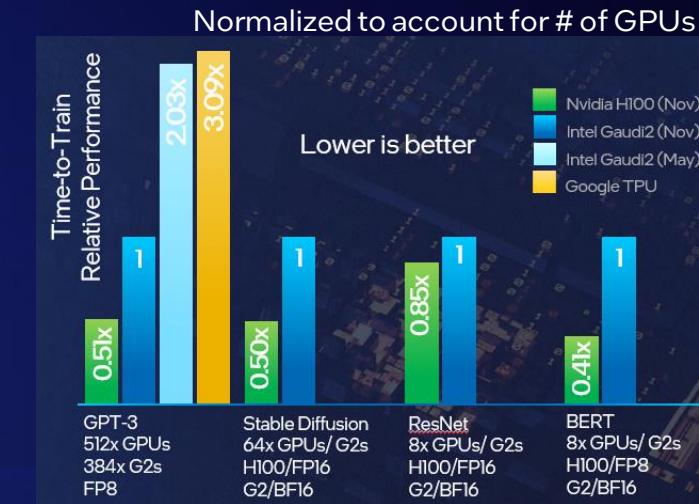


MLPerf GPT-J 推論ベンチマーク

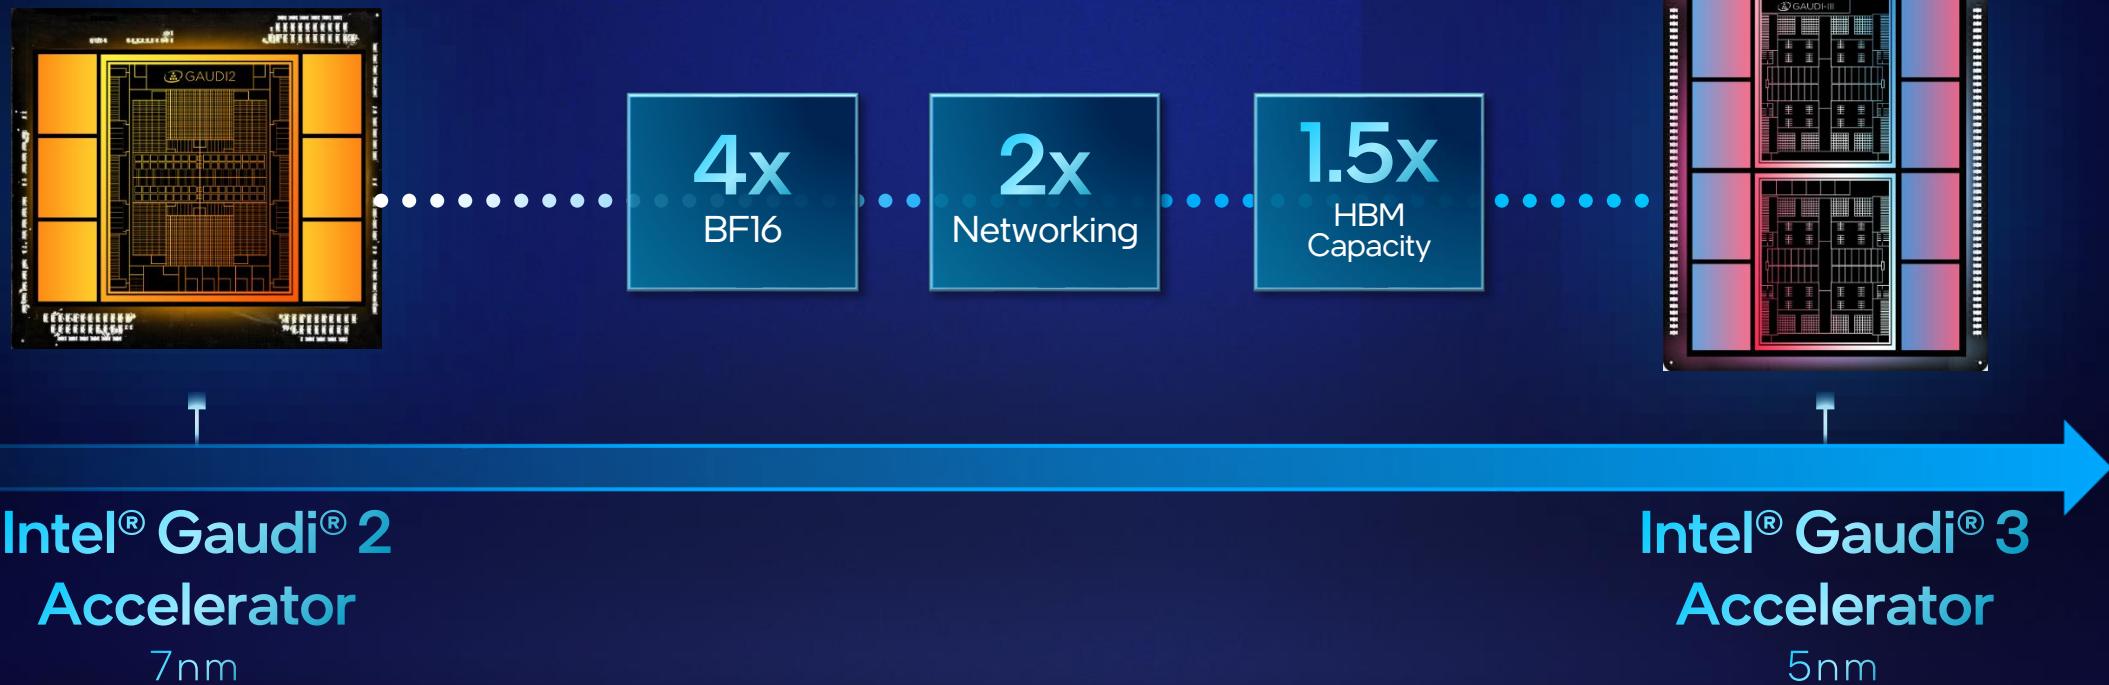
- H100とほぼ同等のパフォーマンス
- A100と比較して2倍の性能



Visit <https://mlcommons.org/en/> for workloads and configurations. Results may vary.

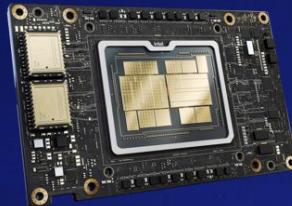


Intel® Gaudi® 3 AI アクセラレータ 2024年予定



アクセラレータとGPU ロードマップ

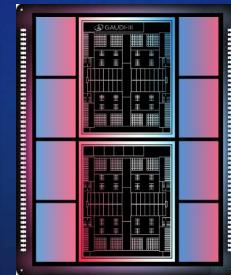
HPC/AI



AI

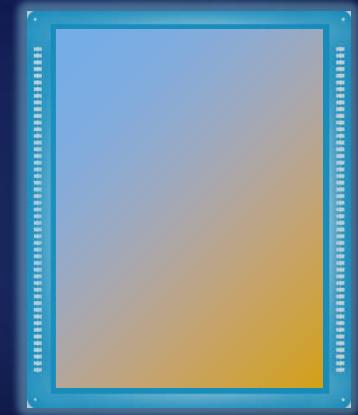


Intel® Data Center
GPU Max Series



Intel® Gaudi® 2 Accelerator

Intel® Gaudi® 3 Accelerator



Next Generation GPU
Codenamed
Falcon Shores



Falcon Shores

GPU

AI & HPC向け
次世代 GPU

Habana と Xe IPを統合

タイルベースのモジュラー・アーキテクチャー

HBM 3とI/Oは拡張できるように設計

標準イーサネット・スイッチング

柔軟なCPUとGPU比率

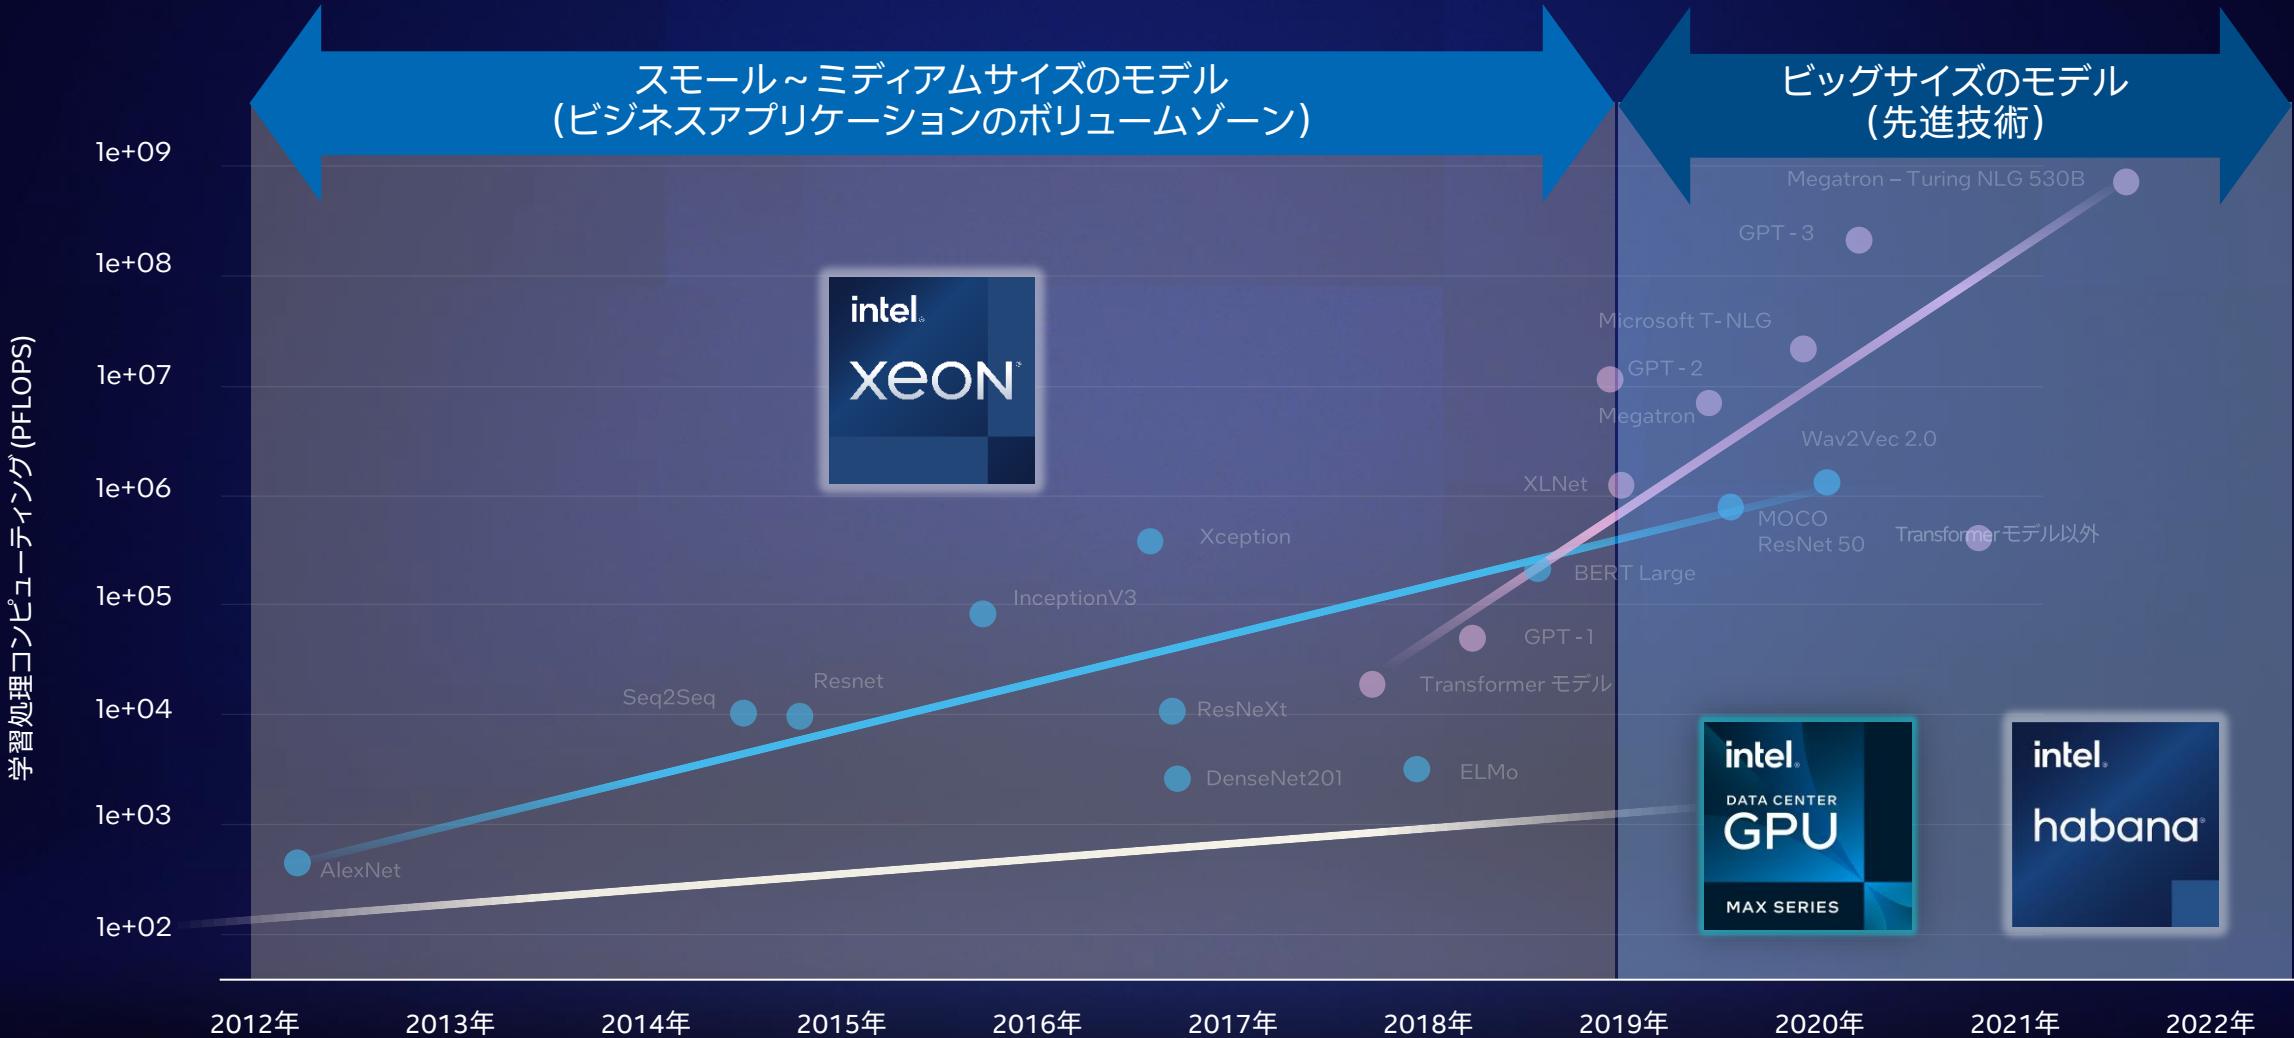
単一のGPUプログラミング・インターフェース

CXLプログラミングモデル

Gaudi3 順調に開発が進んでいます



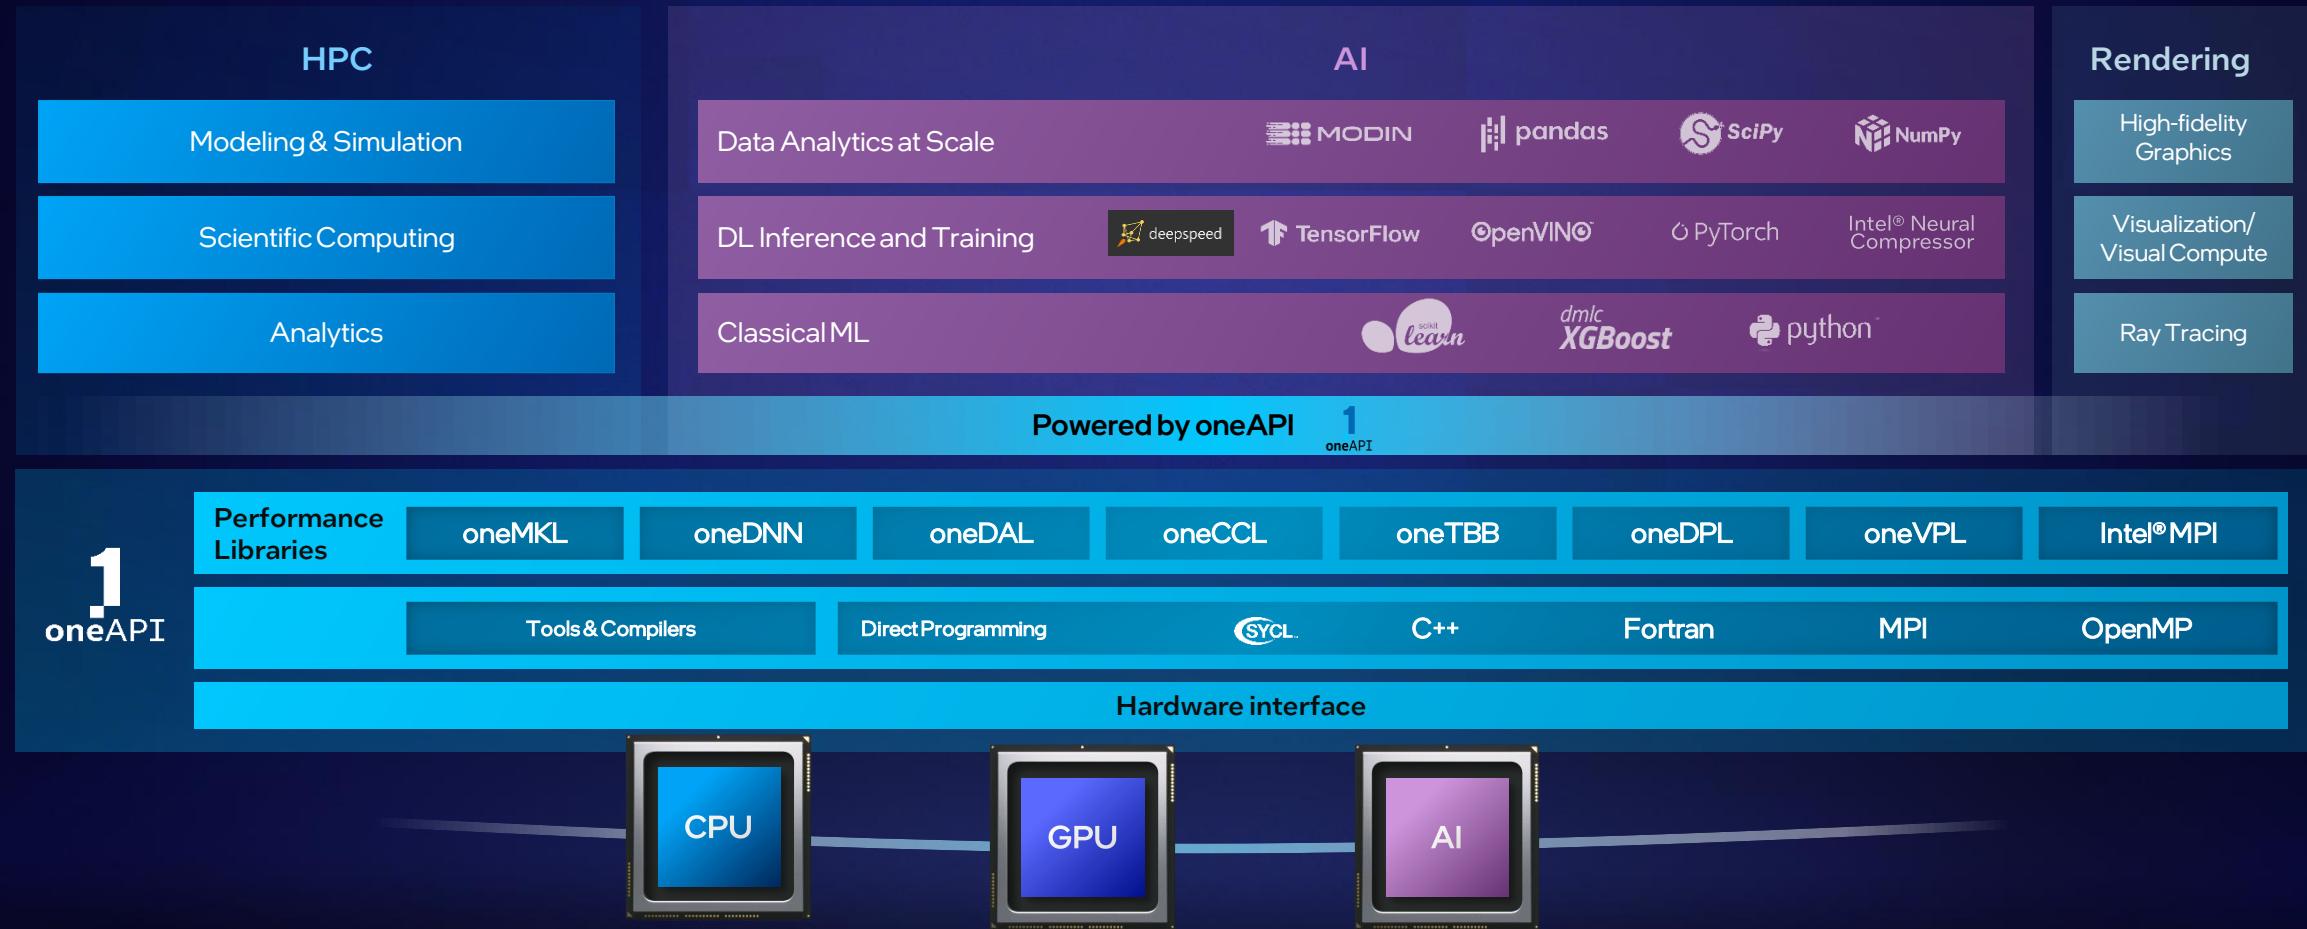
どういったモデルに適している?



出典: Moore, S. (2022年)、「Nvidia's Next GPU Shows That Transformers Are Transforming AI」、IEEE Spectrum

柔軟で包括的なオープンソフトウェアスタック

インテルハードウェアの価値、アプリケーションのパフォーマンス、開発の生産性を最大化



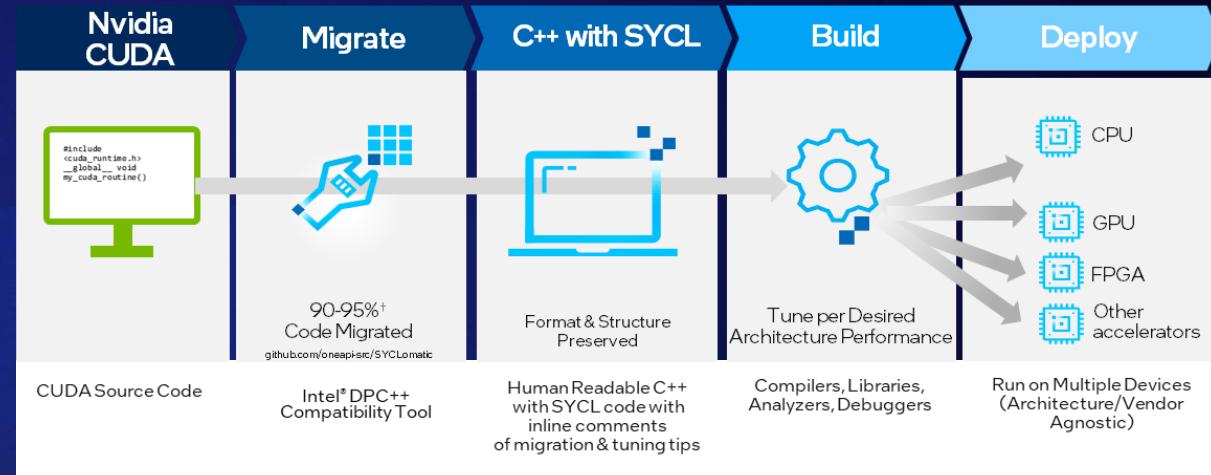
CUDA から C++/SYCLへの移行

アーキテクチャごとに異なるコードを書いたり保守したりする必要はない



[CUDA to SYCL
Migration Portal](#)

- 好みのアクセラレータを選択し、性能と移植性を備えたコードを再利用
- 単一のC++ with SYCLコードベースで、複数のベンダーの複数のアーキテクチャーのアクセラレータ上で実行可能
- インテル® DPC++ Compatibility Toolとオープンソース SYCLomaticは、典型的なCUDAアプリケーションの約90～95%*を自動的にSYCLに移行
- CUDA から SYCL への移行ポータルでは、チュートリアル、ベストプラクティス、コードサンプル、アプリケーションカタログ、コミュニティーサポートを参照可能



Migration Success Examples:



*Intel estimates as of March 2023. Based on measurements on a set of 85 HPC benchmarks and samples, with examples like Rodinia, SHOC, PENNANT. Results may vary.

*Other names and brands may be claimed as the property of others. SYCL is a trademark of the Khronos Group Inc.



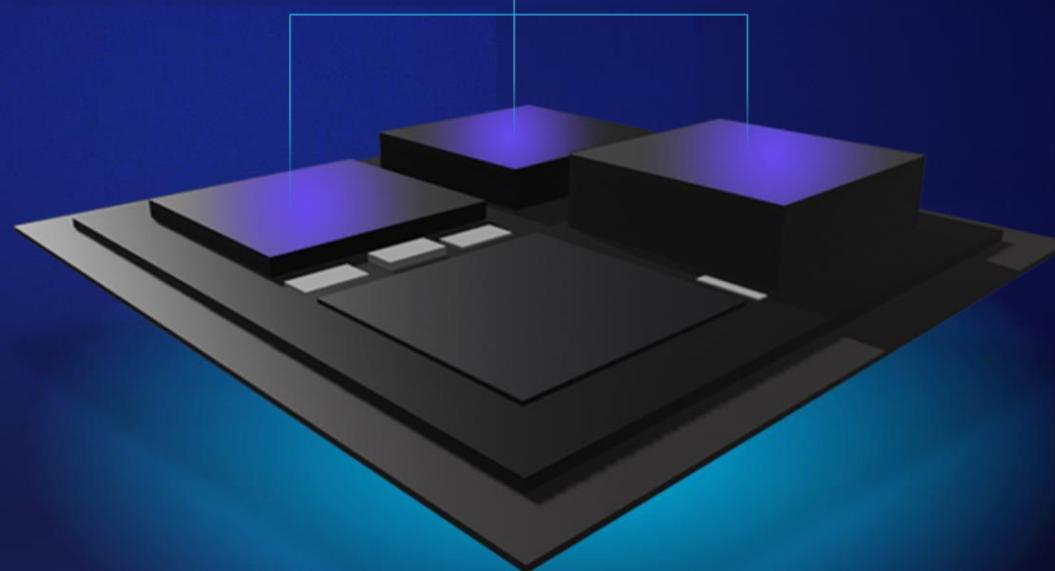
oneAPI for NVIDIA® and AMD



Intel® oneAPI
Toolkit



Intel® oneAPI
Plugins



Intel® Developer Cloud

最新のインテル製ハードウェアとソフトウェアでマルチアーキテクチャーアプリケーションとテスト環境を構築

開発者向け

最新のインテル製CPUとGPUと、インテルに最適化されたAIソフトウェアへのアクセスし開発者に提供する

企業向け

インテル製品とテクノロジーの導入と展開を加速し、新しいソフトウェアとサービスを創出する

パートナー向け

パフォーマンスとコストを最適化したインテルAIコンピュート・サービスを顧客に提供する

無償利用のクラウドクレジットあり

intel®
Developer Cloud

Available software tools and optimizations



AI Tools



Available platforms



intel.
GAUDI

Visit [Intel® Developer Cloud](https://cloud.intel.com) at cloud.intel.com

シリコノミーの一翼を担う インテル HPC-AI



AIとHPCアプリケーション性能をリード

強化された統一ソフトウェア層

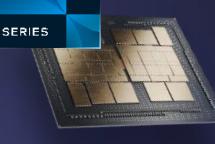
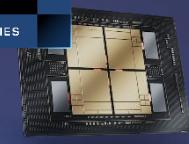
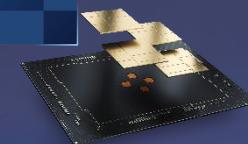
Scale

Open

Trusted

Choice

すべてのHPCとAIニーズに対応する製品群



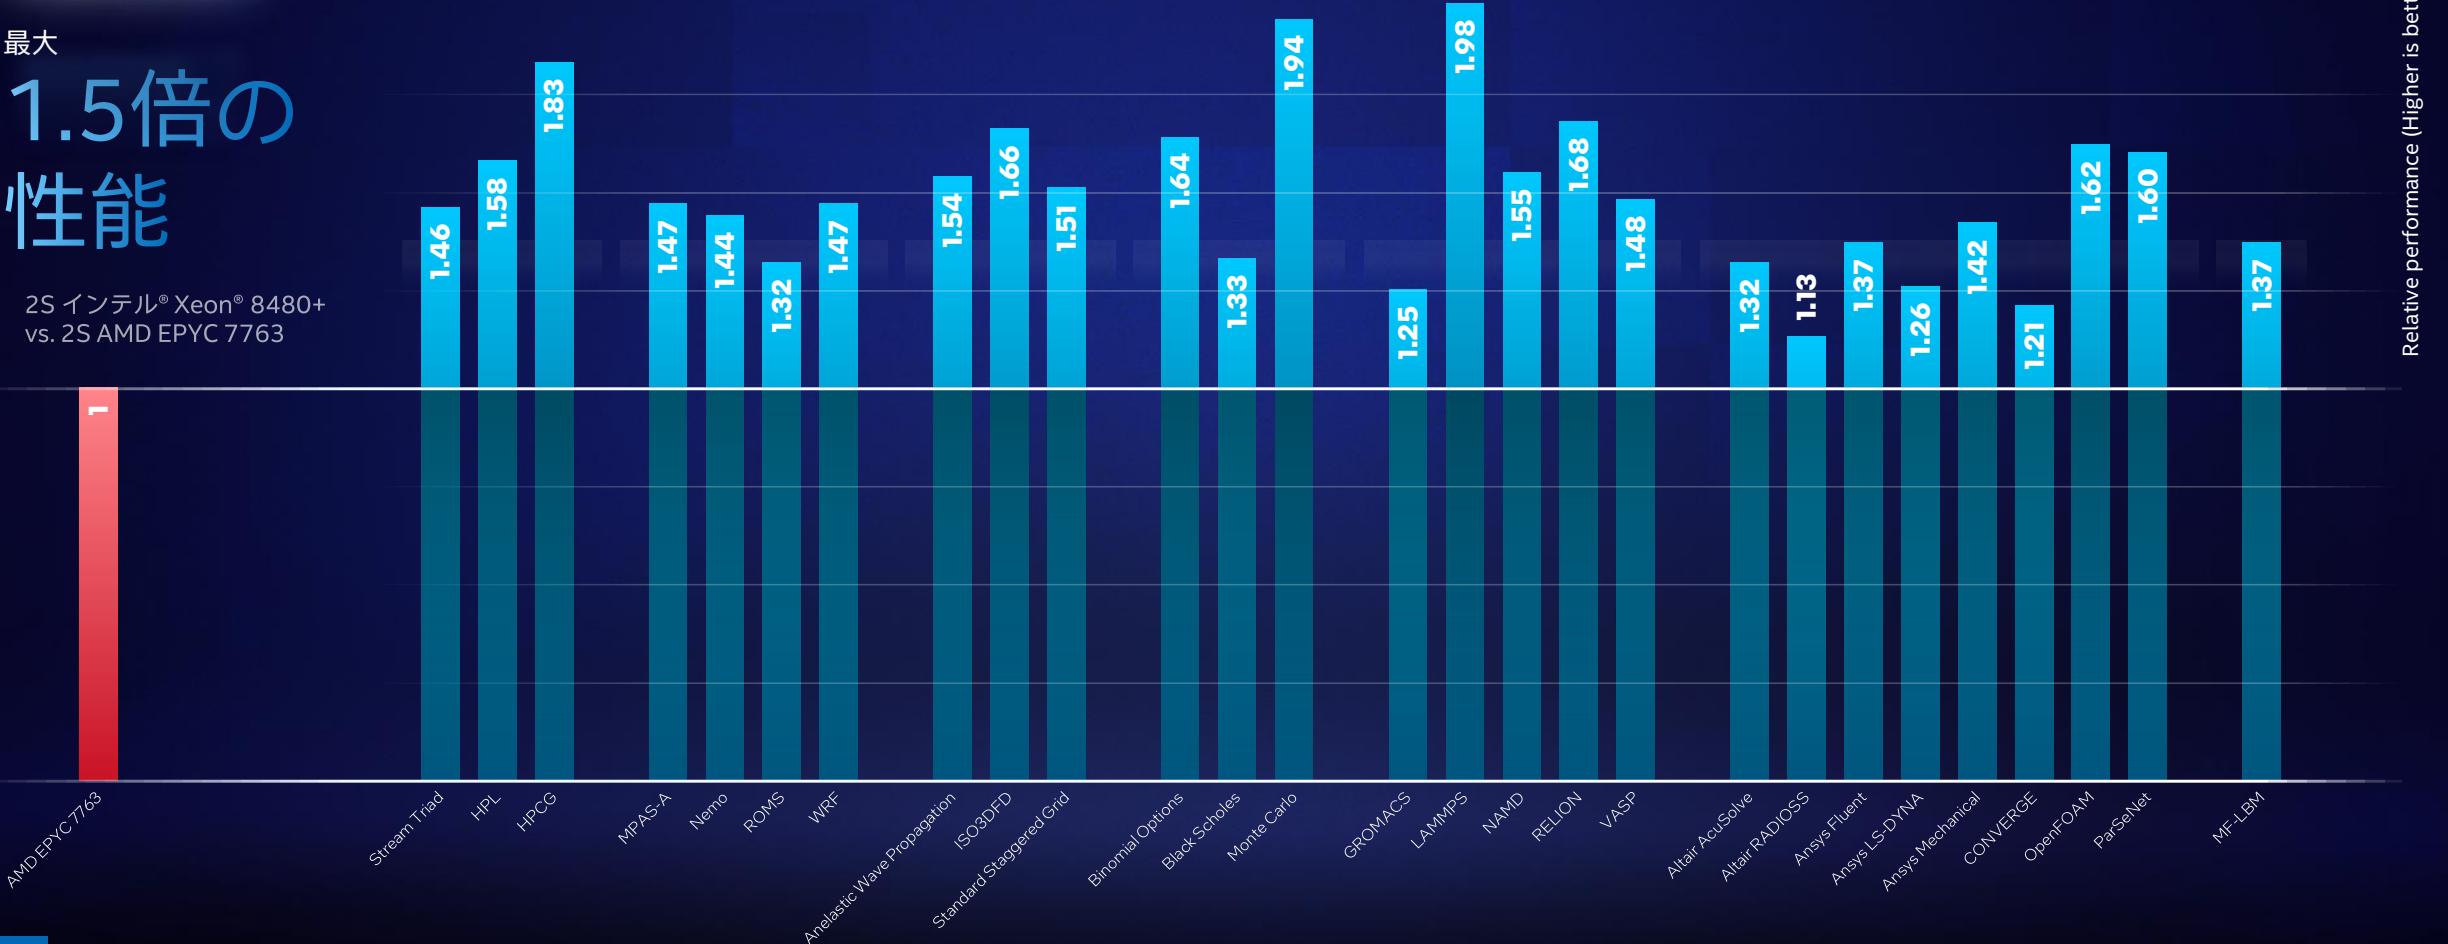
*Conceptual Representation

ご参考



最大
1.5倍の
性能

2S インテル® Xeon® 8480+
vs. 2S AMD EPYC 7763



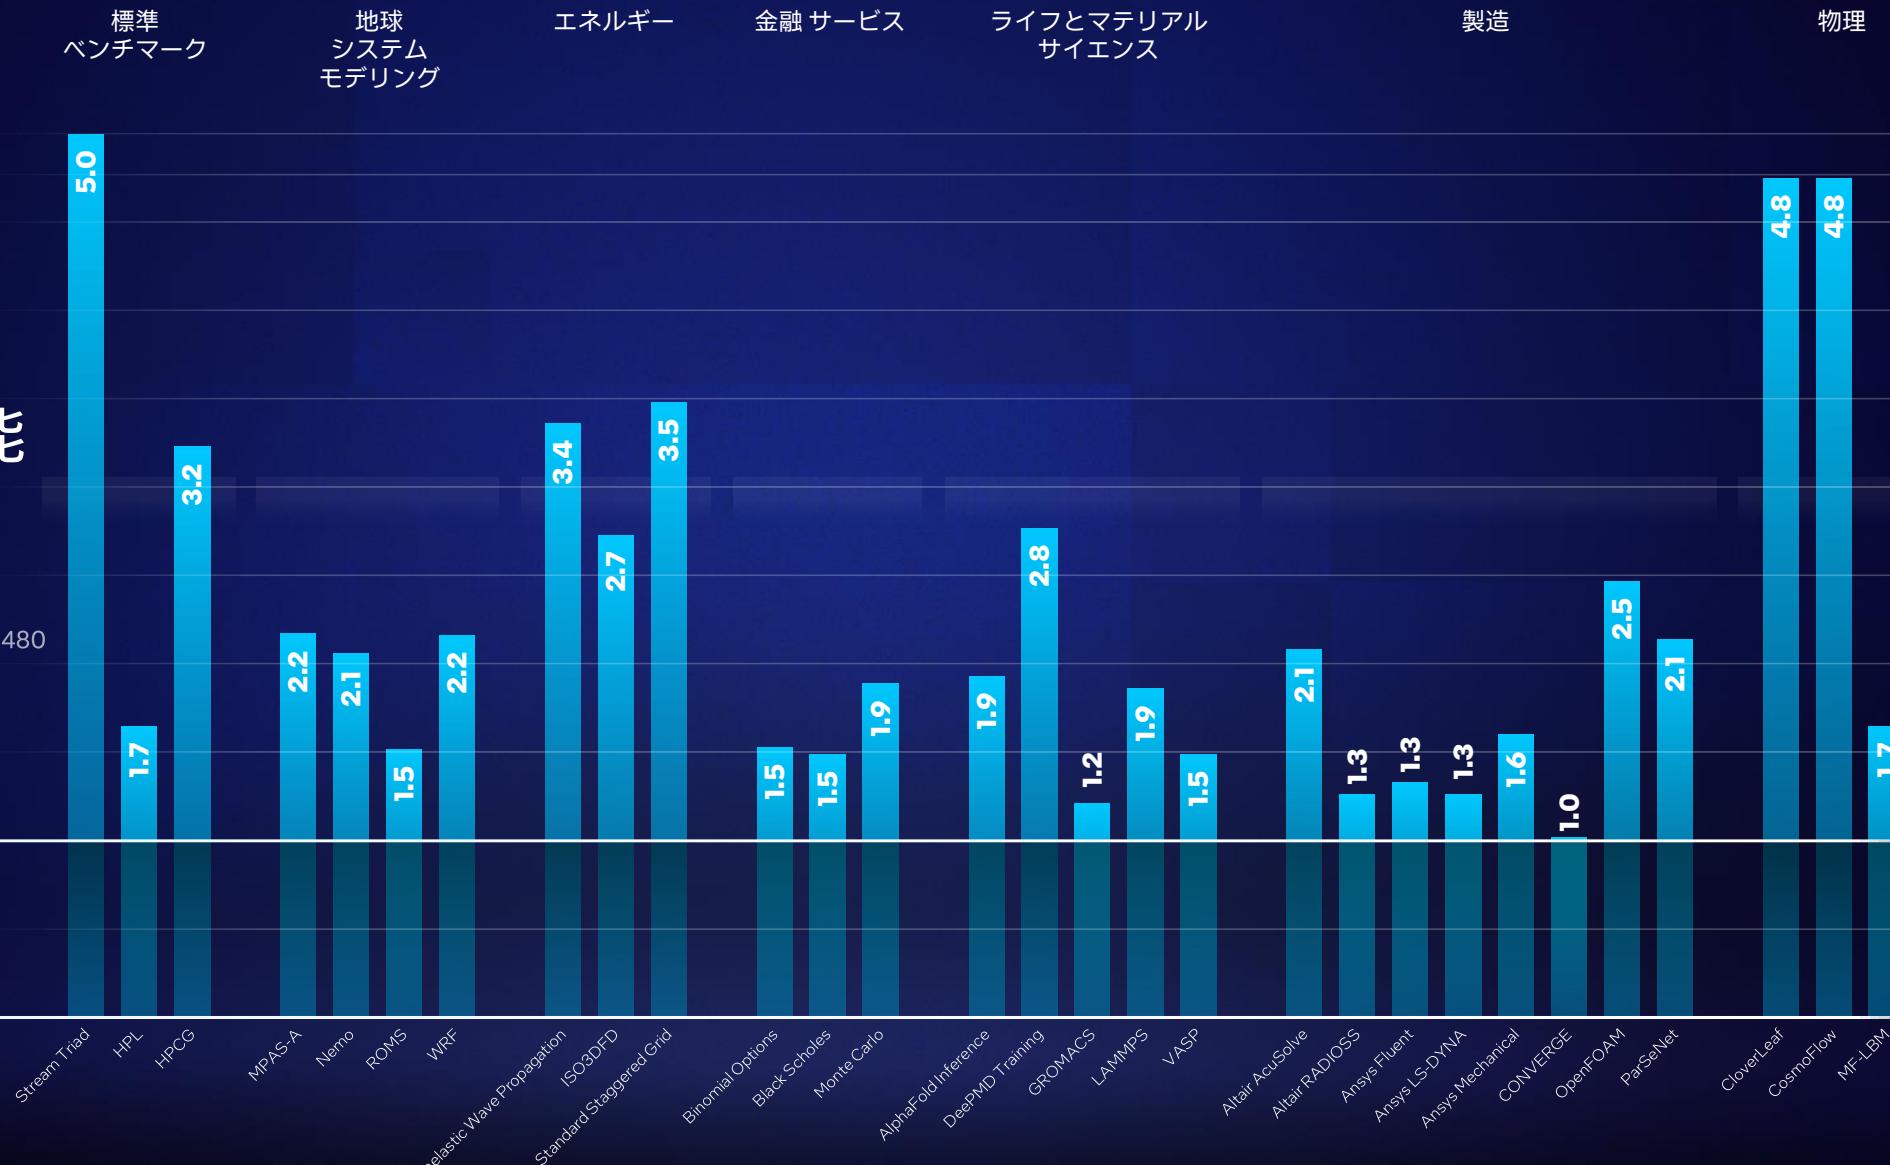
Visit www.intel.com/performanceindex for workloads and configurations. Results may vary.

This offering is not approved or endorsed by OpenCFD Limited, producer and distributor of the OpenFOAM software via www.openfoam.com, and owner of the OPENFOAM® and OpenCFD® trademark.



CPU MAXでは平均
2倍の性能

2S インテル® Xeon® CPU マックス9480
vs. 2S AMD EPYC 7773X



See backup for workloads and configurations. Results may vary.

This offering is not approved or endorsed by OpenCFD Limited, producer and distributor of the OpenFOAM software via www.openfoam.com, and owner of the OPENFOAM® and OpenCFD® trademark. MLPerf™ HPC-AI v0.7 Training ベンチマーク Performance. Result not verified by MLCommons Association. Unverified results have not been through an MLPerf™ review and may use measurement methodologies and/or workload implementations that are inconsistent with the MLPerf™ specification for verified results. The MLPerf™ name and logo are trademarks of MLCommons Association in the United States and other countries. All rights reserved. Unauthorized use strictly prohibited. See www.mlcommons.org for more information.



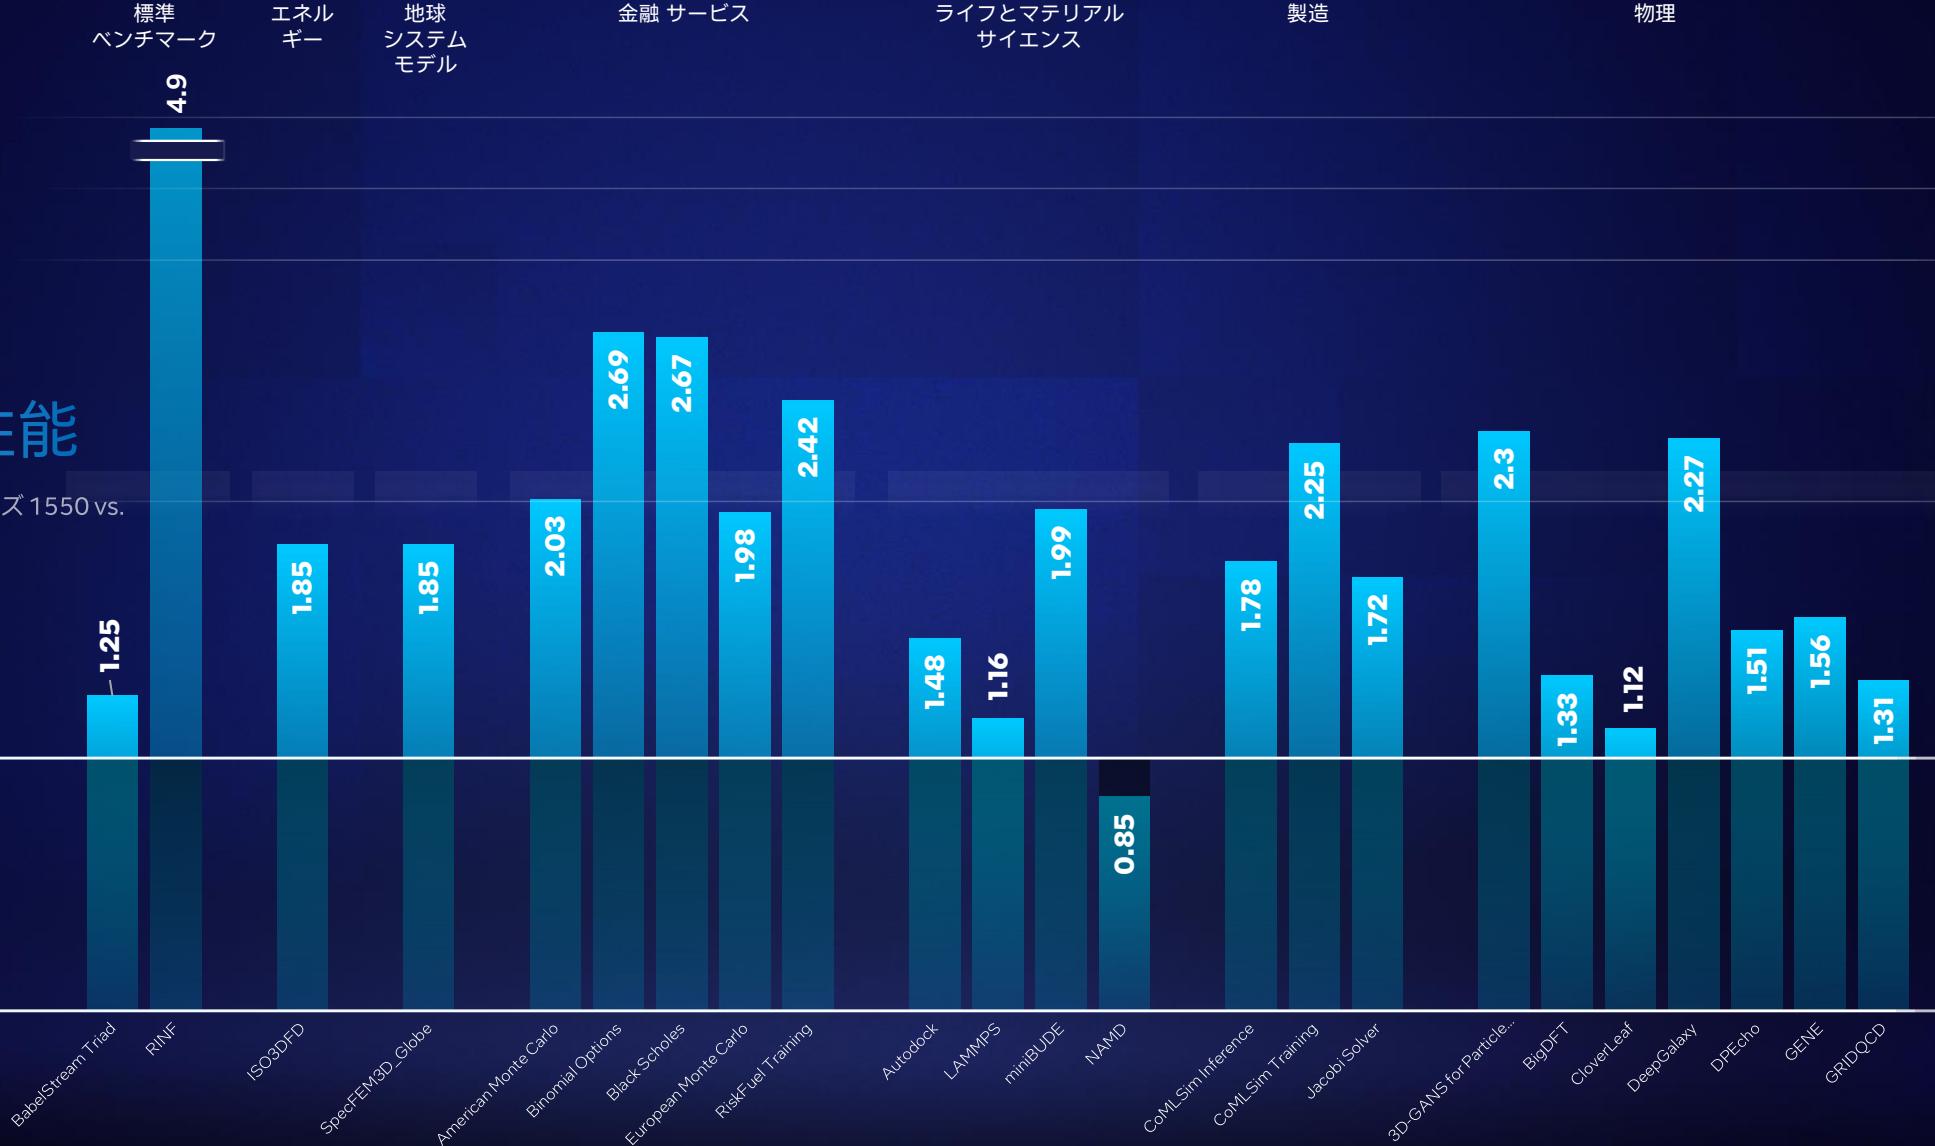
平均

1.7倍の性能

インテル DC GPU マックス・シリーズ 1550 vs.
Nvidia A100 80G PCIe



Nvidia A100 80G PCIe



Relative performance (Higher is better)

See backup for workloads and configurations. Results may vary.

The Intel logo is displayed in white against a dark blue background. The word "intel" is written in a lowercase, sans-serif font. A small, solid cyan square is positioned above the letter "i". A registered trademark symbol (®) is located at the bottom right of the "l".

intel®

Notices and Disclaimers

Statements in this document that refer to future plans or expectations are forward-looking statements. These statements are based on current expectations and involve many risks and uncertainties that could cause actual results to differ materially from those expressed or implied in such statements. For more information on the factors that could cause actual results to differ materially, see our most recent earnings release and SEC filings at www.intc.com.

All product plans and roadmaps are subject to change without notice.

Performance varies by use, configuration and other factors. Learn more on the [Performance Index site](#). Intel technologies may require enabled hardware, software or service activation.

Performance results are based on testing as of dates shown in configurations and may not reflect all publicly available updates. See backup for configuration details. No product or component can be absolutely secure.

Your costs and results may vary.

Intel does not control or audit third-party data. You should consult other sources to evaluate accuracy.

Code names are used by Intel to identify products, technologies, or Service that are in development and not publicly available. These are not "commercial" names and not intended to function as trademarks.

© Intel Corporation. Intel, the Intel logo, and other Intel marks are trademarks of Intel Corporation or its subsidiaries. Other names and brands may be claimed as the property of others.