

プライベートスーパーコンピュータの 悩みと楽しみ

2023/08/30

株式会社Preferred Networks

計算基盤担当VP 土井裕介

自己紹介


- 2000-2016 株式会社東芝
 - 分散KVS、RFID、データ表現、無線IoT等
- 2016-現在 株式会社Preferred Networks
 - Computer Networks x Deep Learning
 - → 社内IT整備 (チーム立ち上げて脱退)
 - → クラスタ整備 (チーム立ち上げ)
 - → 計算基盤担当 (2019/9より)

現在の担当領域: クラスタMiddleware (kubernetes等) クラスタ調達設計 (物理基盤含)、独自開発アクセラレータ (MN-Core)


計算基盤いろいろやっています




DC and Cluster





Measurement and Operation



Thermal




Cluster Design and Services



Board temp. distribution

ASIC Design



Interconnect

Preferred Networks 会社概要


現実世界を計算可能にする

自分たちの手で革新的かつ本質的な技術を開発し、未知なる領域にチャレンジしていく。

私たちはソフトウェアとハードウェアを高度に融合し、自動車やロボットなどのデバイスをより賢く進化させます。常に変化する環境や状況に柔軟に対処できる賢いデバイスができれば、物理世界をリアルタイムにセンシングし、現実世界そのものが計算可能になります。

技術を使って、自分たちが見たことが無い、まだ知らない世界を知りたい。すでにわかっている領域で勝負するのではなく、技術の力で想像を超えた世界に挑戦していきます。

会社情報



設立	2014年3月26日
経営陣	代表取締役 最高経営責任者 西川 徹 代表取締役 最高研究責任者 岡野原 大輔
所在地	本社 東京都千代田区大手町1-6-1大手町ビル 米国子会社 Preferred Networks America, Inc. 330 Primrose Rd., Suite 300, Burlingame, CA 94010
従業員数	約300名

グループ企業の提供サービス: Matlantis (PFCC)

MATLANTIS | MATLANTIS (マ) × +

← → ↺

matlantis.com/ja/

Guest

MATLANTIS

ProductCasesCompanyNewsログインJAENお問い合わせ

Features

Matlantisの3つの特長

Matlantisは、深層学習を活用した原子シミュレーションによって、
材料特性の原子レベルでの現象解明や、コンピュータを利用した新材料開発を実現するためのサービスです。


汎用性 / Versatile01



幅広い元素・構造に対応

未知の材料を含む、分子や結晶などの任意の原子の組み合わせにおいてシミュレーションが可能です。現在は72の元素をサポートしており、今後さらに拡大予定です。


高速 / High Speed02



従来手法の10,000倍以上高速

DFT (Density Functional Theory : 密度汎関数法) では、高性能なコンピュータを用いて数時間～数か月かかった原子レベルの物理シミュレーションを、数秒単位で行うことができます。


使いやすさ / Easy to Use03




ブラウザを立ち上げればシミュレーションを開始できます

学習済み深層学習モデル・物性計算ライブラリ・高性能な計算環境をパッケージにすることで、ハードウェアの準備や環境構築をすることなく、シミュレーションによる材料探索が可能です。また、従来の機械学習ポテンシャルとは異なり、ユーザーによるデータ収集や学習が不要です。

グループ企業の提供サービス: Kachaka (Preferred Robotics)




豊富な計算資源と高度な技術を基盤に複数の事業を創出



自社計算基盤の紹介

自社計算基盤：MN-2, MN-3



深層学習をはじめとするPreferred Networks(PFN)の中核技術は膨大な計算を要求します

Networks(PFN)の中核技術は

PFNでは、多量の計算を効率的に実行するために独自の計算機クラスターを複数運用しており、現在はMN-2、MN-3が稼働しています

MN-3は、PFNが自社開発した深層学習用プロセッサMN-Coreを初めて用いた計算機クラスターです

- MN-2：1500GPU規模クラスター
- MN-3：160 MN-Core規模クラスター（写真）

MN-3のサーバ1台あたりのスペック（MN-3は、以下サーバが48台で構成）

MN-Core	MN-Core Board x 4
CPU	Intel Xeon 8260M 2way（48物理core）
Memory	384GB DDR4
Storage Class Memory	3TB Intel Optane DC Persistent Memory
Network	MN-Core DirectConnect（112Gbps）x 2
	Mellanox ConnectX-6（100GbE）x 2
	On board（10GbE）x 2

PFNのオンプレKubernetesクラスタ



拠点名: MN-J



MN-2a

128 nodes
(1024 GPUs)



36 CPU Cores



DDR4 384GB



V100 (16 / 32 G)
SXM2 x 8



100GbE x 4
RoCEv2
with SR-IOV

MN-3

48 nodes
(192 MN-Cores)



48 CPU Cores



DDR4 384GB



MN-Core x 4



100GbE x 2
MN-Core
DirectConnect

MN-2b (A100)

42 nodes
(168 GPUs)



128 CPU Cores



DDR4 1024 GB



A100 (80G)
SXM4 x 4



100GbE x 2
RoCEv2
with SR-IOV

MN-2b (A30)

42 nodes
(252 GPUs)



80 CPU Cores



DDR4 512 GB



A30 (24G)
PCIe x 6




100GbE x 2
RoCEv2
with SR-IOV

PFNのオンプレストレージクラスタ

拡大中!

トータル 約 10 PB (論理容量)



何故「プライベート」 (2016)

なぜわざわざ自前の計算機を用意するのか？

- クラウドでいいじゃないか → 当時のクラウドGPUは...
- ABCIつかえば → 当時はなかった
(今はお世話になりまくりです!)

なぜか? ⇒ それが必要だったから

- 計算機が足りない
- 計算機間の通信路が足りない
- ドライバとかいろいろいじくりまわしたい

プライベート「スーパーコンピュータ」

- 作っているモノは、いくつかの意味でスパコンに近い
 - GPUどっさり
 - “Interconnect” の存在

トポロジのマッチング

分散計算のオーバーレイネットワークと
物理的なネットワークが存在


leafの中ではfull bisectionで2リンク分の
速度が(理論上)出る→ tree allreduce
leafをまたぐとleaf-spineの帯域で律速
→ ring allreduce

問題: topologyとマッチしていないと?


例1: ring(ノード1, 16, 2, 17, ...)

例2: ノード1のGPU1→ノード2のGPU5
(各NICから1portの場合)


例: leaf-spine 2:4:32




例: 古典的GPUサーバ CPU:GPU = 2:8



実例




インターフェイスごとのトラフィック (100GbE)



PFC count

プライベート「スーパーコンピュータ」

- 作っているモノは、いくつかの意味でスパコンに近い
 - GPUどっさり
 - “Interconnect” の存在
 - 「謎の半導体」





何故「プライベート」
⇒ MN-Coreをモノにするために


MN-Core：自社開発の機械学習チップ

「自社の計算需要に最適なチップを内製」
(神戸大学と共同研究)

- ・ 計算機の性能が深層学習の性能の最も重要な差異化要因
- ・ チップ内階層構造と機械学習に最適化されたネットワーク（放送、縮約、その他）
- ・ ソフトウェア最適化を優先したアーキテクチャ
 - ソフトウェア側でハードウェアの動作を詳細に制御できる構造



ハードウェアの演算器数を最大化




汎用プロセッサ

MN-Core




CGによる物体認識の学習



地震波による地層解析



テキスト条件付き画像生成
例: “Christmas tree in a datacenter”




分子動力学

MN-Core コンパイラスタック (内製)



ONNX

ONNX model



L3IR

DNN op level,
SIMD parallelism
strategy,

MNGraph

Global
Layout
Planner

Re-computati
on Scheduler

L2IR

ndarray op level,
optimized DNN op
impl,

PEVector

MNTensor

Reshape
Impl.

Generic Conv
Impl.


L1IR

MN-core op level,
memory allocation,
scheduling,
optimization,

Scheduling
Graph

Layer Impl.

Instruction
Merger



「今」と「これから」


物理基盤構築運用のためのもろもろ

技術


サーバ

ネットワーク

ファシリティ



計算機新技術検討、 機器選定・筐体設計



NW新技術検討、 論理・物理設計



電力/冷却設備検討、
DC/設備設計


など

計画


長期計画

年次計画

設備企画



ロードマップ作成



予算計画、
設備計画



基盤設計、
工事計画

など

管理

調達

設備工事

保守運用



資材/機材調達、
ロジ/Kitting手配



施工管理、
子一ム間連携




保守手配・部材管理


など

「これから」の悩みと愉しみ

MN-Core™ 2 ベースのクラスタの立ち上げ + さらに先へ
上から下まで全部やってて(大変|嬉しい)



↑関連blog (本日公開)



カジュアル面談お申し込みはこちら↑