

データセンタインフラの「いま」と「これから」

2019/3/28

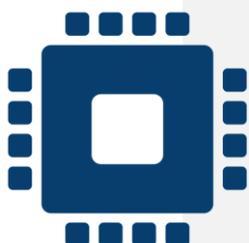
取扱い製品(担当)



Network



- ストレージネットワークに最適な、**低遅延、高機能バッファ搭載**スイッチ
- ハイパースケールネットワーク(Cumulus)
- Smart NIC, 高機能アダプタカード(GPU-Direct, RDMA, OVS, VXLAN)
- LincX ケーブル、モジュール製品



Compute



- FPGAアクセラレータカード
- Deep Learningアクセラレーション
- DataBaseアクセラレーション
- マルチコア、高密度サーバ(Xeon, AMD)
- GPU搭載サーバ
- All NVMe Flashストレージ
- 各種GPU製品
- ML/DLオンプレ統合管理ソフトウェア

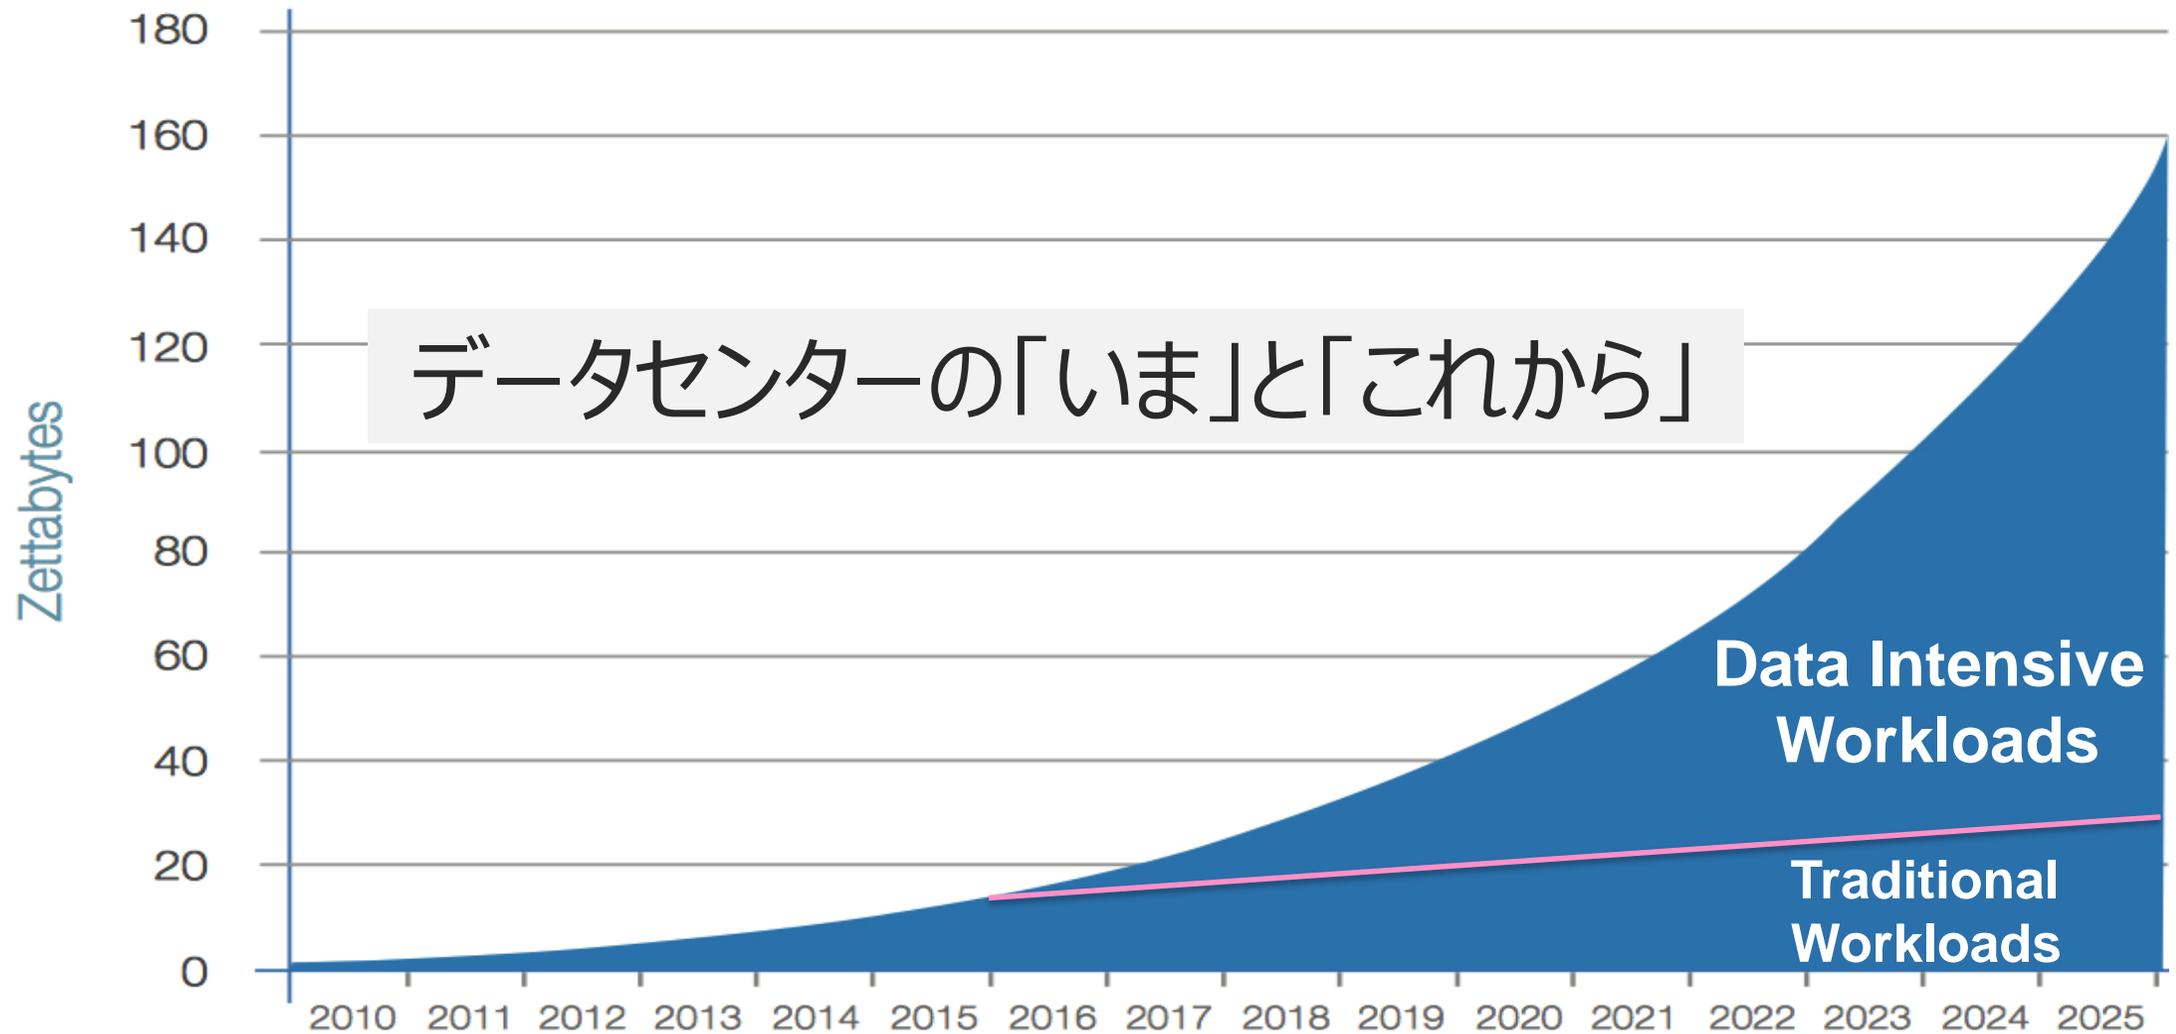


Storage



- NVMe SSD
- 大容量オブジェクトストレージシステム
- JBOD/JBOF
- 次世代NVMeスケールアウトストレージソフトウェアソリューション
- コンポーザブル・インフラストラクチャ統合管理ソフトウェア

本日のお話



データセンターの「いま」と「これから」

Data Intensive Workloads

Traditional Workloads

<https://www.seagate.com/files/www-content/our-story/trends/files/idc-seagate-dataage-whitepaper.pdf>

AIを制するものが未来を制する

by ソフトバンク孫社長

AIは減衰期に突入

Hype Cycle for Emerging
Technologies, 2018 from Gartner

AI

- Machine Learning
- Deep Learning

Big Data

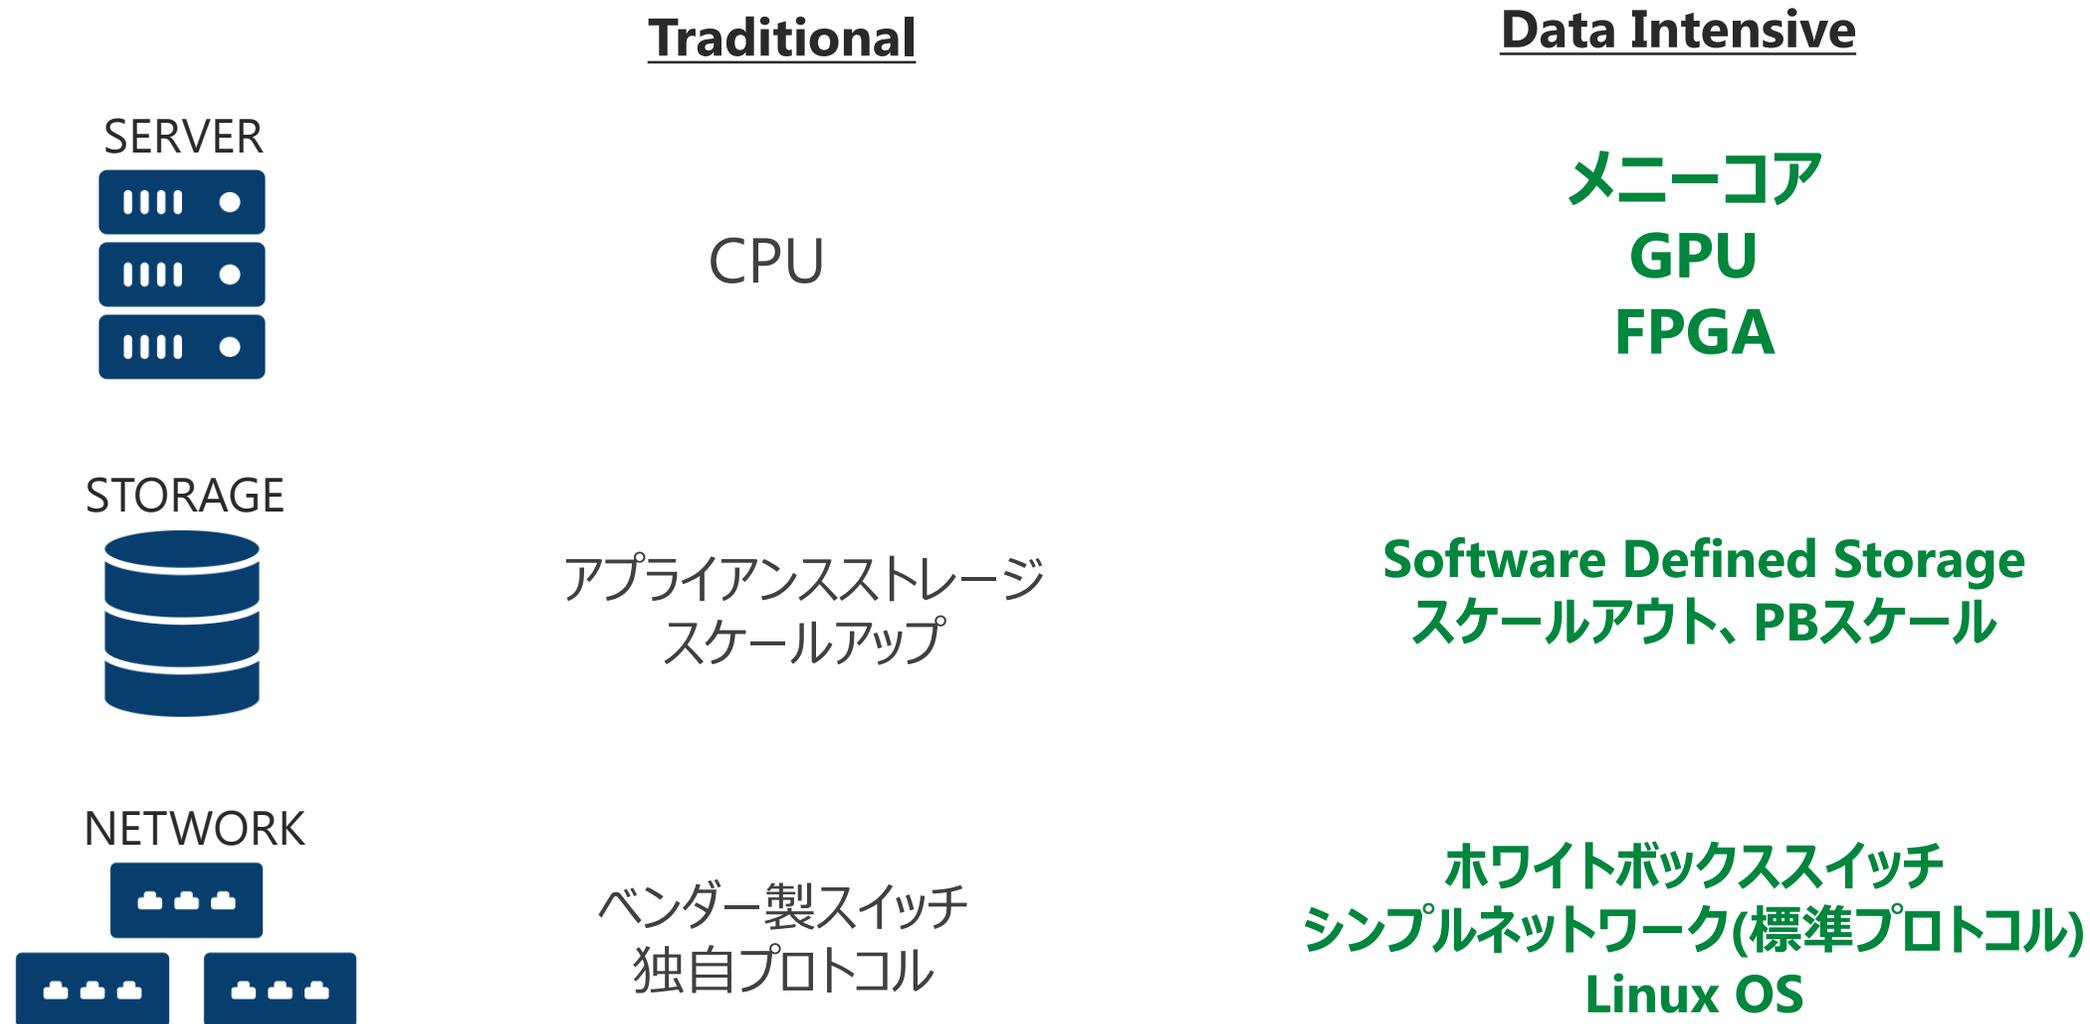
- Real Time Analytic
- Off-line Analytic

IoT

many...

Data Intensiveなアプリケーションはこれまでのインフラで十分か？？

データセンターインフラの構成要素 「いま」と「これから」



データセンターインフラの構成要素 「いま」と「これから」

- ヘテロジニアスな環境
 - CPU, GPU, FPGA, etc
- スケーラビリティのあるストレージシステム
 - SDS
 - コモディティード
 - マルチデバイスへの対応(HDD, SSD, NVMe)
- 新しいワークロードに対応できるネットワークファブリック
 - 標準プロトコル
 - ホワイトボックス > ベンダロックイン
 - エコシステム (Linux)

Traditional

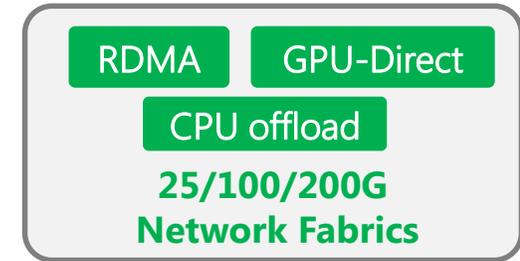
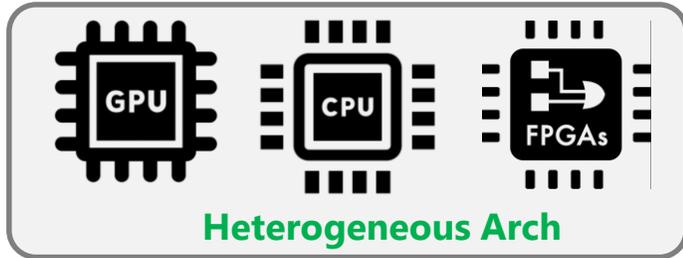
Data Intensive

メニーコア
GPU
FPGA

Software Defined Storage
スケールアウト、PBスケール

ホワイトボックススイッチ
シンプルネットワーク(標準プロトコル)
Linux OS

「これから」のテクノロジー要件



ヘテロジニアスな
コンピューティングHW

大容量、低レイテンシー
+ ファブリック接続

広帯域(100/200/400G)、低遅延
+ Application Aware Network

アプリケーション要件を満たすHW
の選択

Ex:
マルチコアプロセッサ
マルチノードプロセッシング
各種オフロード技術

JBOD/JBOF
NVMeスケールアウトストレージ
インメモリ処理
ストレージクラスメモリ
etc

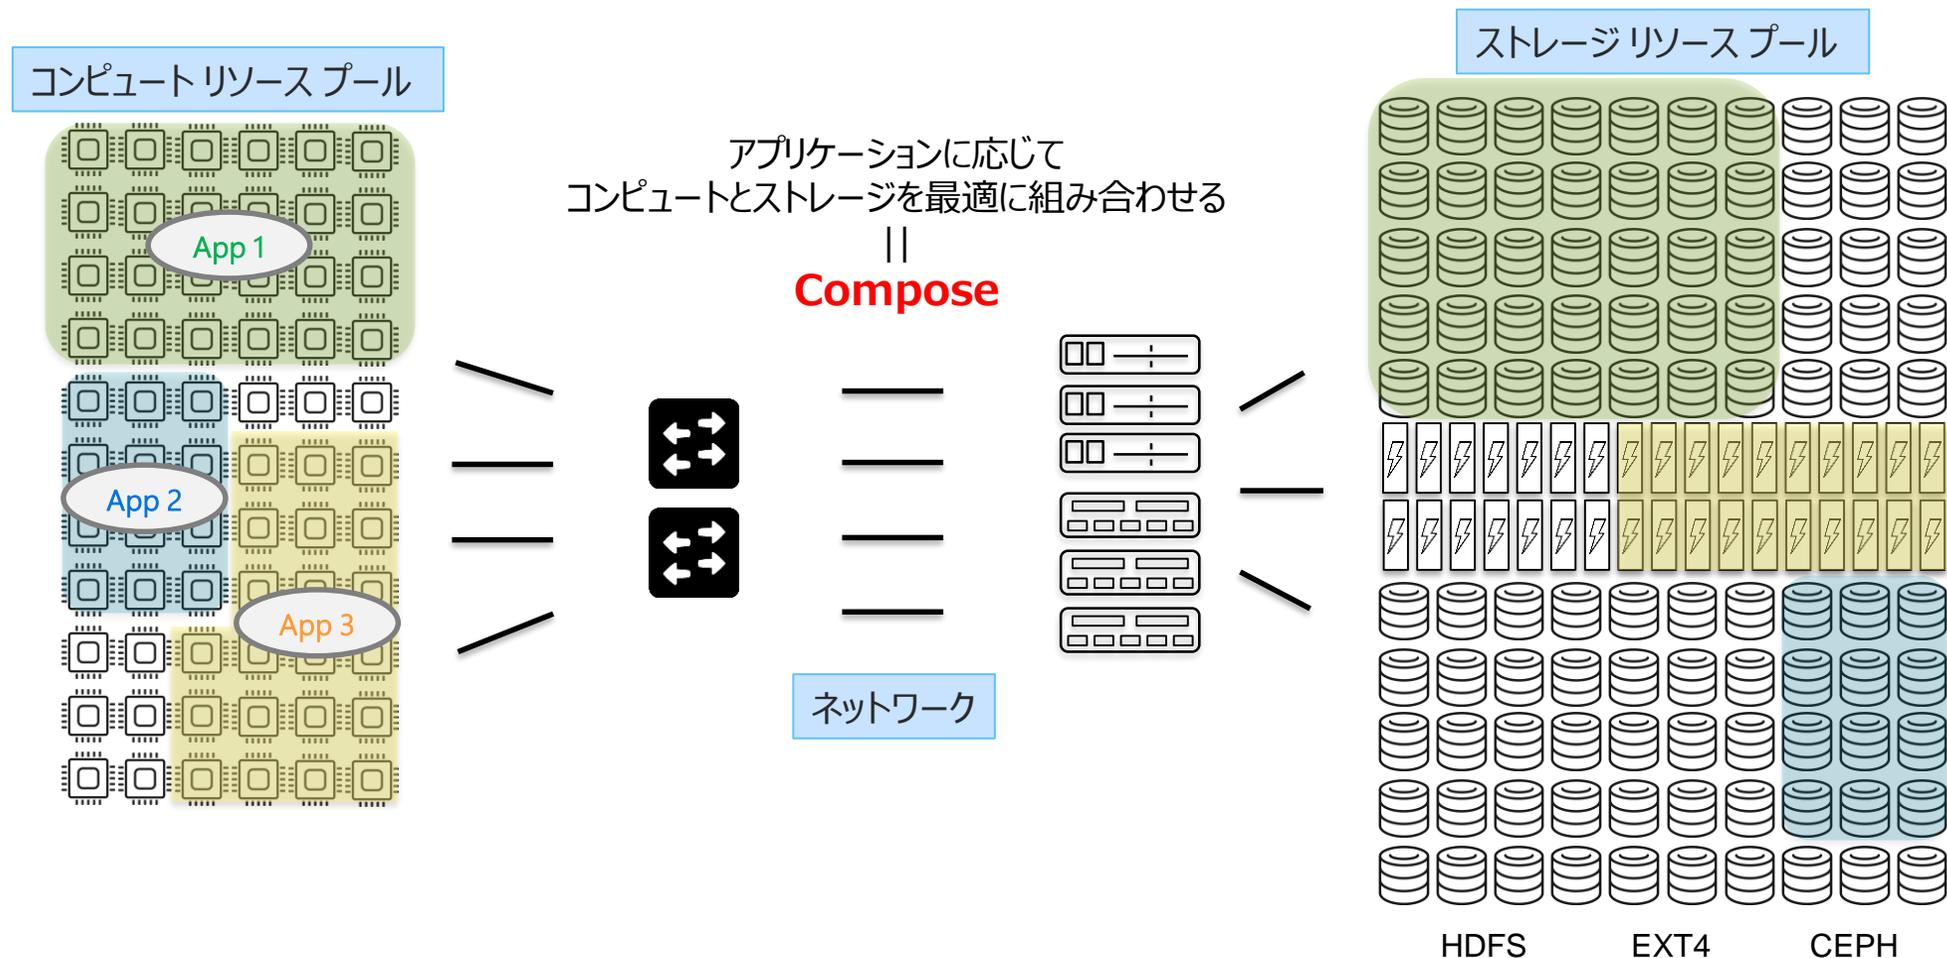
ストレージトラフィック最適化
→RDMA/RoCE、ロスレス
コンピューティングオフロード
→TCP/IP, RDMA, DPDK, OVS offload
スケーラビリティ
→IP CLOS、SDN(VXLAN)、etc

コンポーザブル インフラストラクチャ

コンポーザブル インフラストラクチャとは？

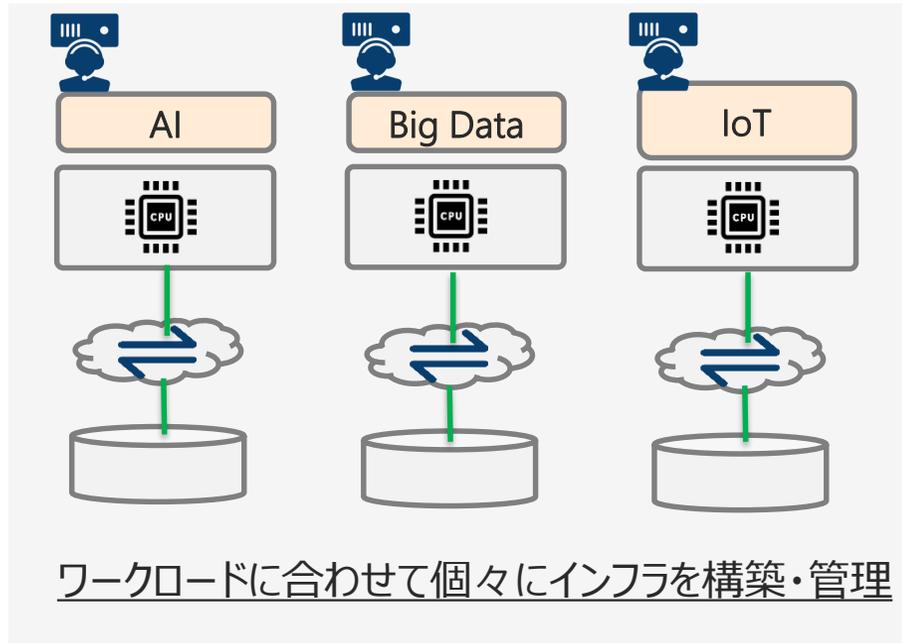
Composable Infrastructure

分離されたコンピューティング、ストレージ、およびネットワークファブリックのプールを使用して、サーバを柔軟に構成する次世代サーバ・インフラストラクチャ



データセンターデザイン 「いま」と「これから」

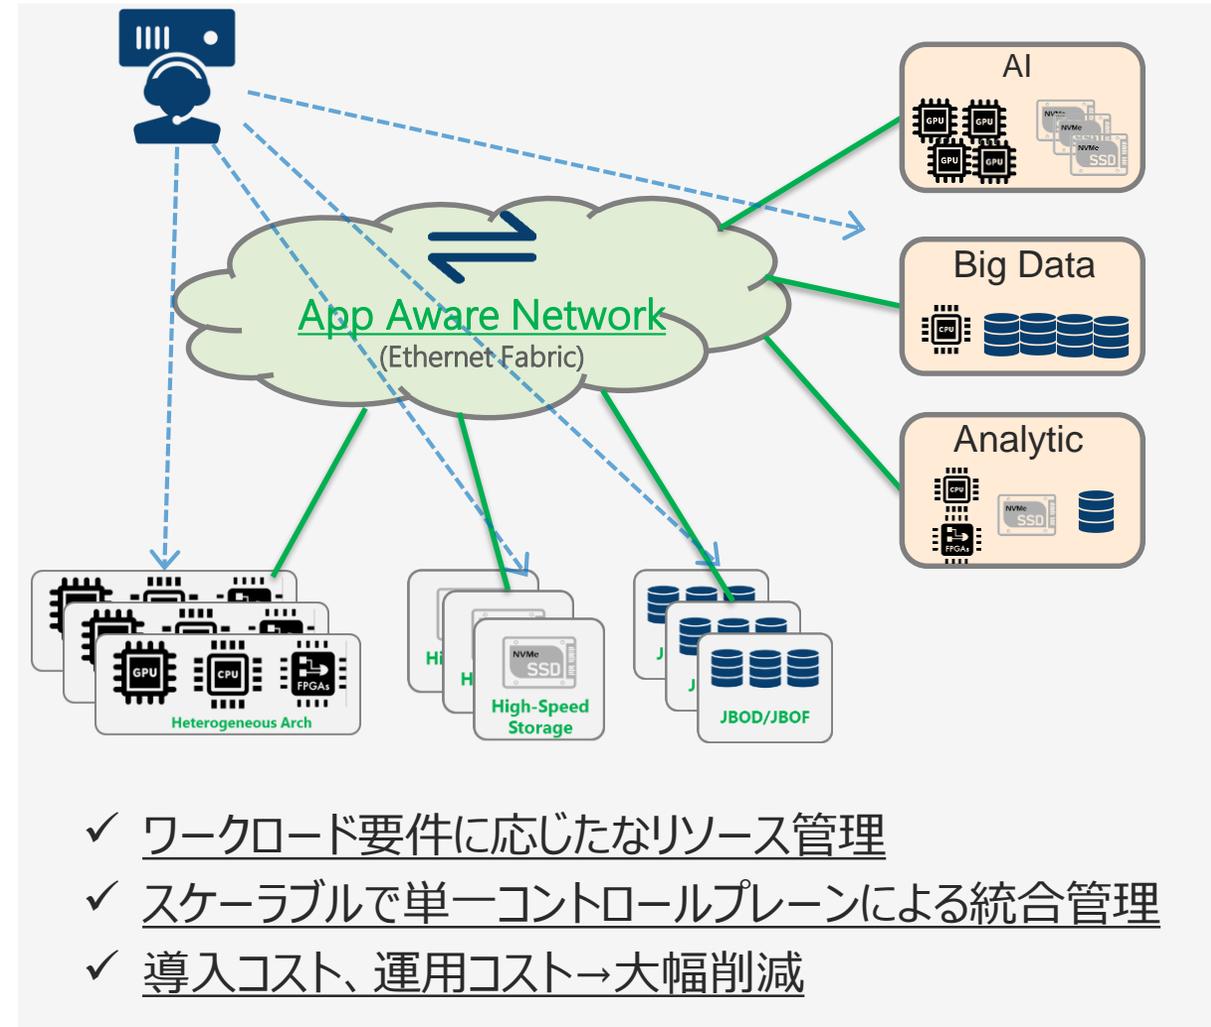
Now



- × スケーラビリティ
- × 管理が複雑
- × 汎用性
- × 運用コスト

Future

Composable + API



「これから」を実現するソリューション紹介

ヘテロジニアスな
コンピューティングHW

大容量、低レイテンシー
+ ファブリック接続



広帯域(100/200/400G)、低遅延
+ Application Aware Network

+

コンポーザブル インフラストラクチャ

すべてを繋ぐ、MellanoxのEnd-to-Endポートフォリオ

Software



NEO™
MELLANOX ONYX
Software Development Kit

Switch



Spectrum™ Spectrum-2™

広帯域、低レイテンシーなデータセンタースイッチ
～400GE見据えたロードマップ
オープンプラットフォーム



Adapter



ConnectX™

10GE～200GE対応
各種アクセラレーション対応
(RoCE, OVS offload, GPU Direct, etc)

ConnectX™ 5
ConnectX™ 6



Interconnect



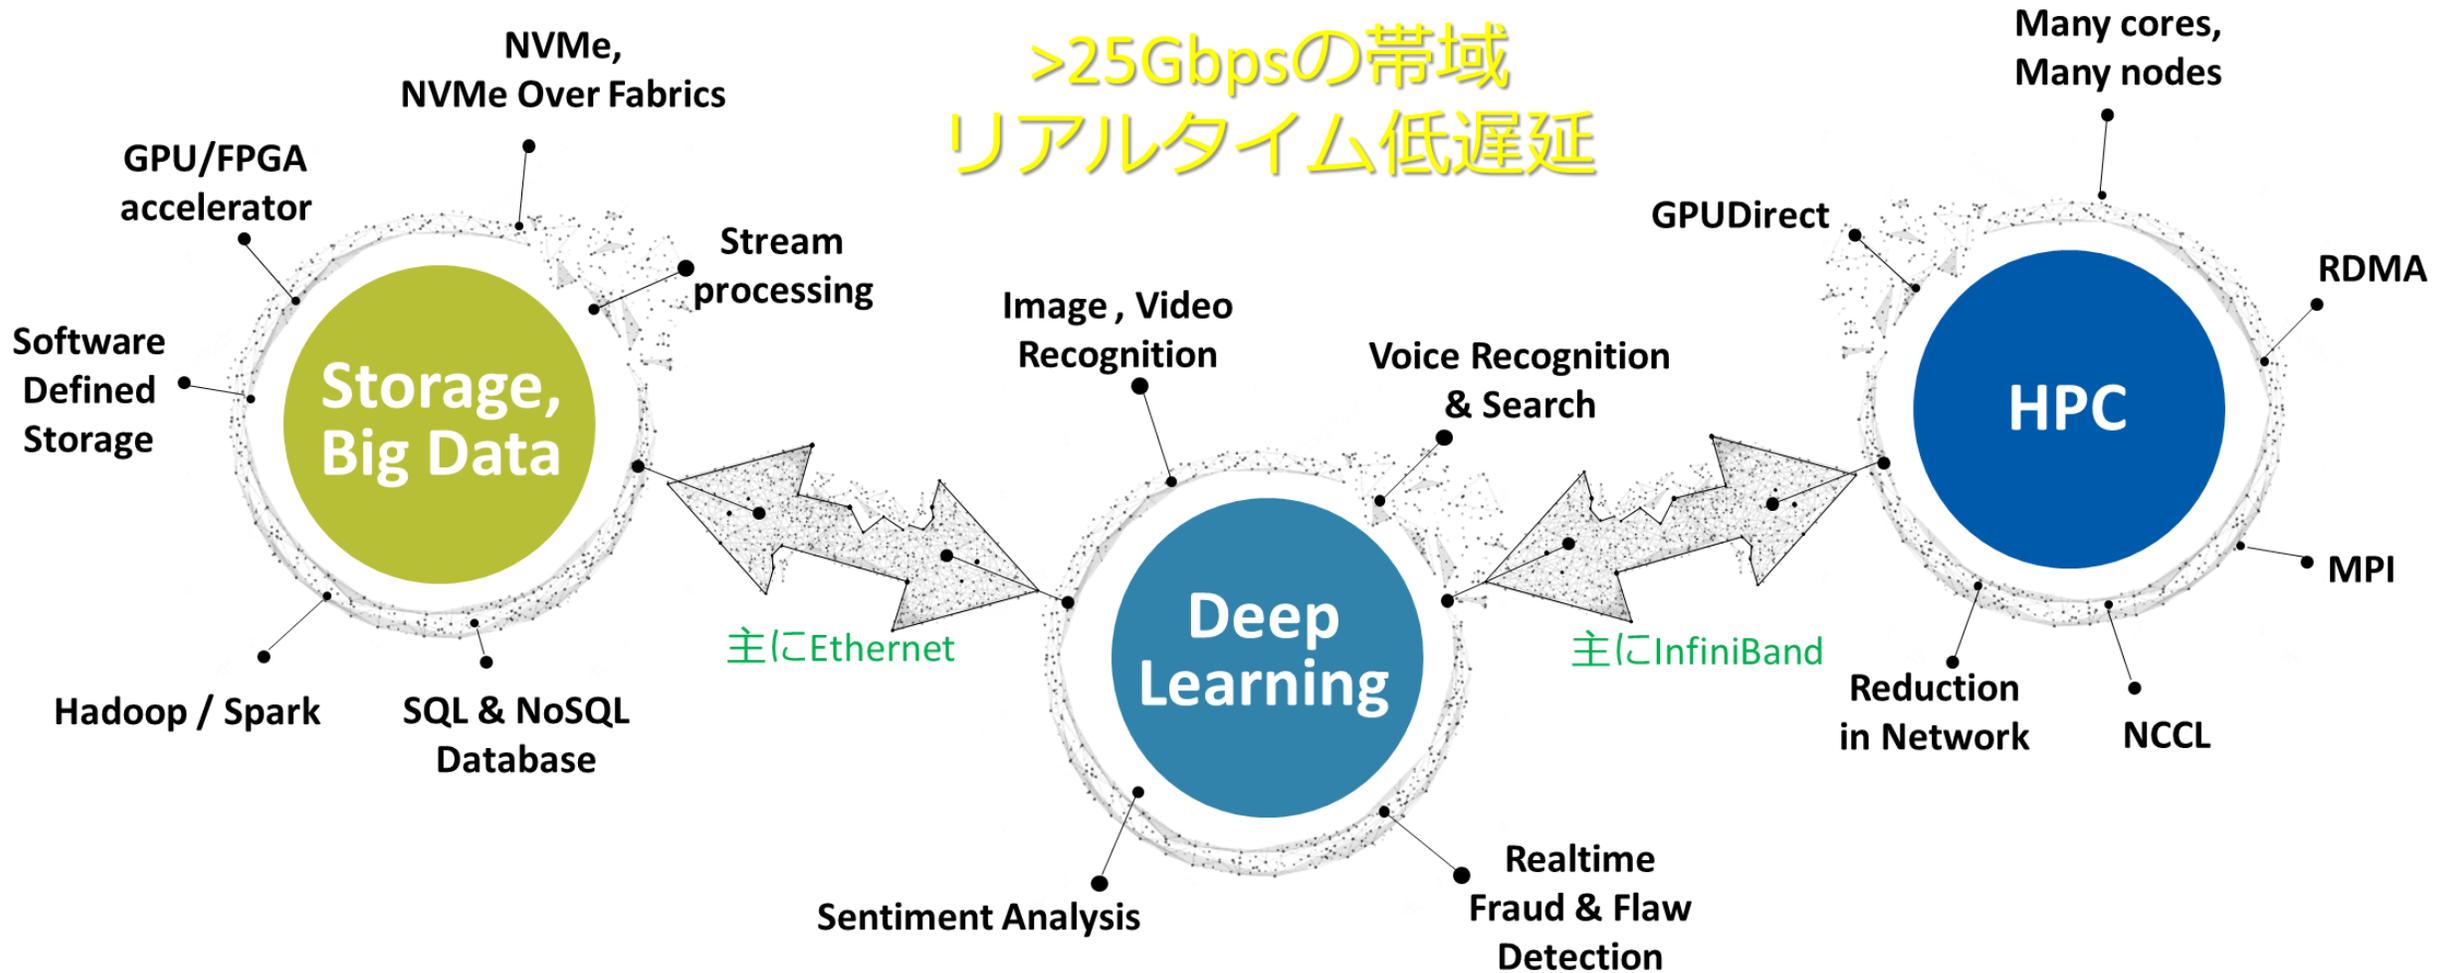
LinkX™

各種トランシーバ
Active Optical and Copper Cables
10 / 25 / 40 / 50 / 56 / 100GbE



VCSELs and Copper

Mellanox が成長している分野



多くのアプリケーションに高性能 Interconnect 技術が要求されている

オープンプラットフォーム & 予測可能なイーサネットファブリック

Application

多様なLinux用OSS/商用ツールを自由に活用

NOS

CumulusVX
ネットワークシミュレーション仮想アプライアンス

Cumulus NetQ
ファブリック全体の検証ツール、障害を防ぎ、対応を高速化

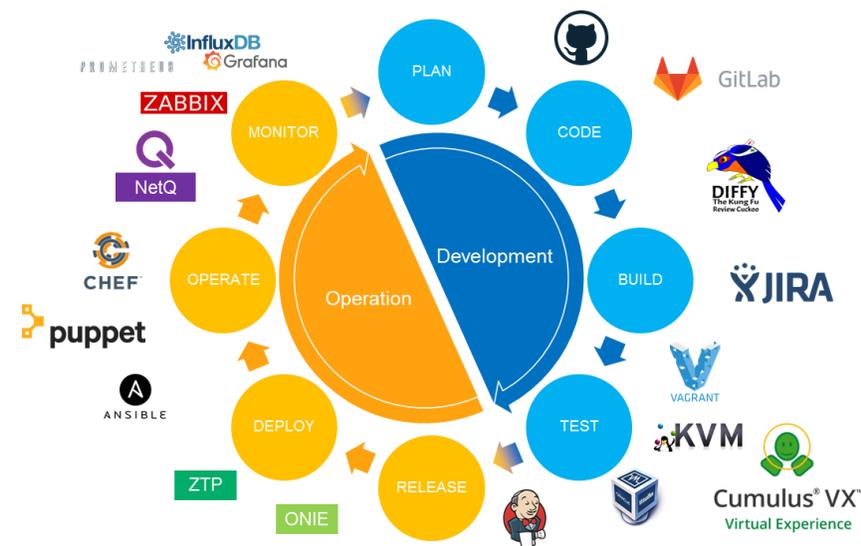
Cumulus RoH
コンテナ・マイクロサービスに最適なホスト用ソフトウェアパッケージ

LinuxベースNOS

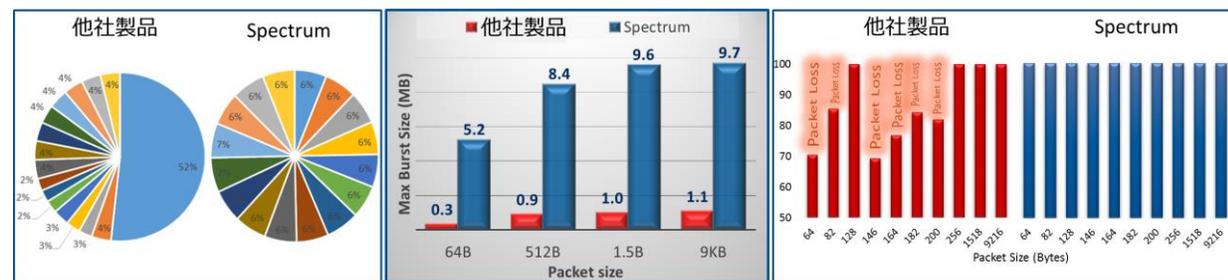
HW

低遅延、高性能バッファリングのスイッチング性能を提供

OPEXの最適化、効率化



スケーラブルで高性能なアンダーレイ基盤



スマートバッファリング

低レイテンシー

ヘテロジニアスな
コンピューティングHW



**大容量、低レイテンシー
+ ファブリック接続**

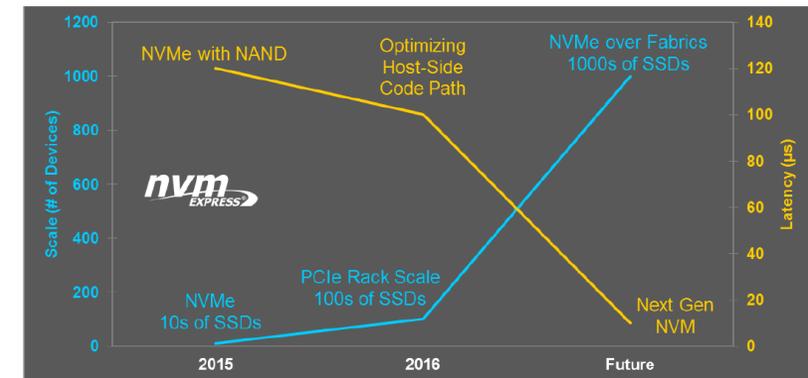
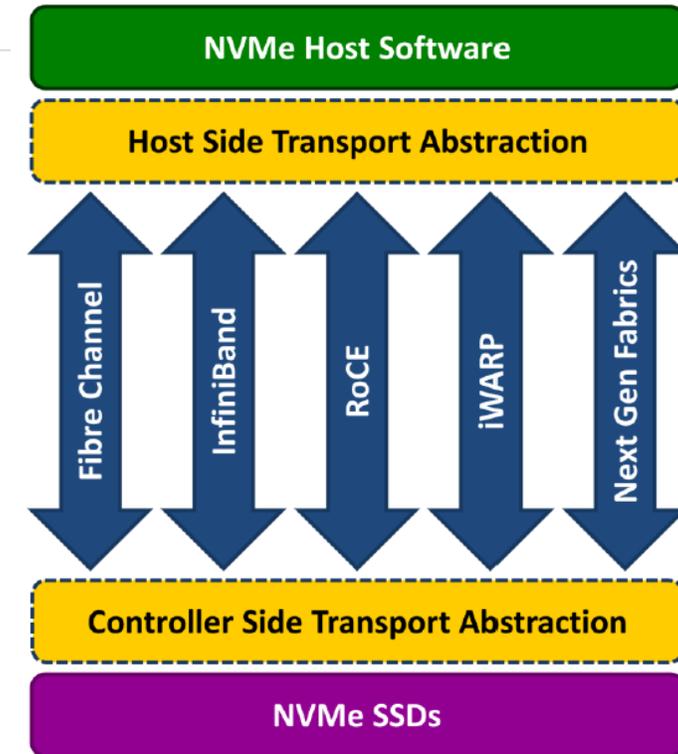
広帯域(100/200/400G)、低遅延
+ Application Aware Network



コンポーザブル インフラストラクチャ

キーワードはNVMe over Fabrics

- NVMeをローカル利用する課題
 - PCIスロット以上には拡張できない
 - ノード単位の容量制限以上をアプリケーション利用できない
- NVMe over Fabricとは
 - NVMeストレージを複数ノードで共有する仕組み
 - マルチプロトコルサポート
 - データプレーン、マネジメントプレーン機能提供
 - NVMe over Fabrics標準規格化
 - NVMe over Fabrics 1st Version 1.0 (2016/June)
 - NVMe over Fabrics Latest Version 1.0a (2018/July)
- NVMe over Fabricが目指すところ
 - 低レイテンシー性能(over Fabric)
 - ファブリックスケール



補足) NVMe ドライブの実力

- NVMe ドライブ性能の例

- HGST社 SN200

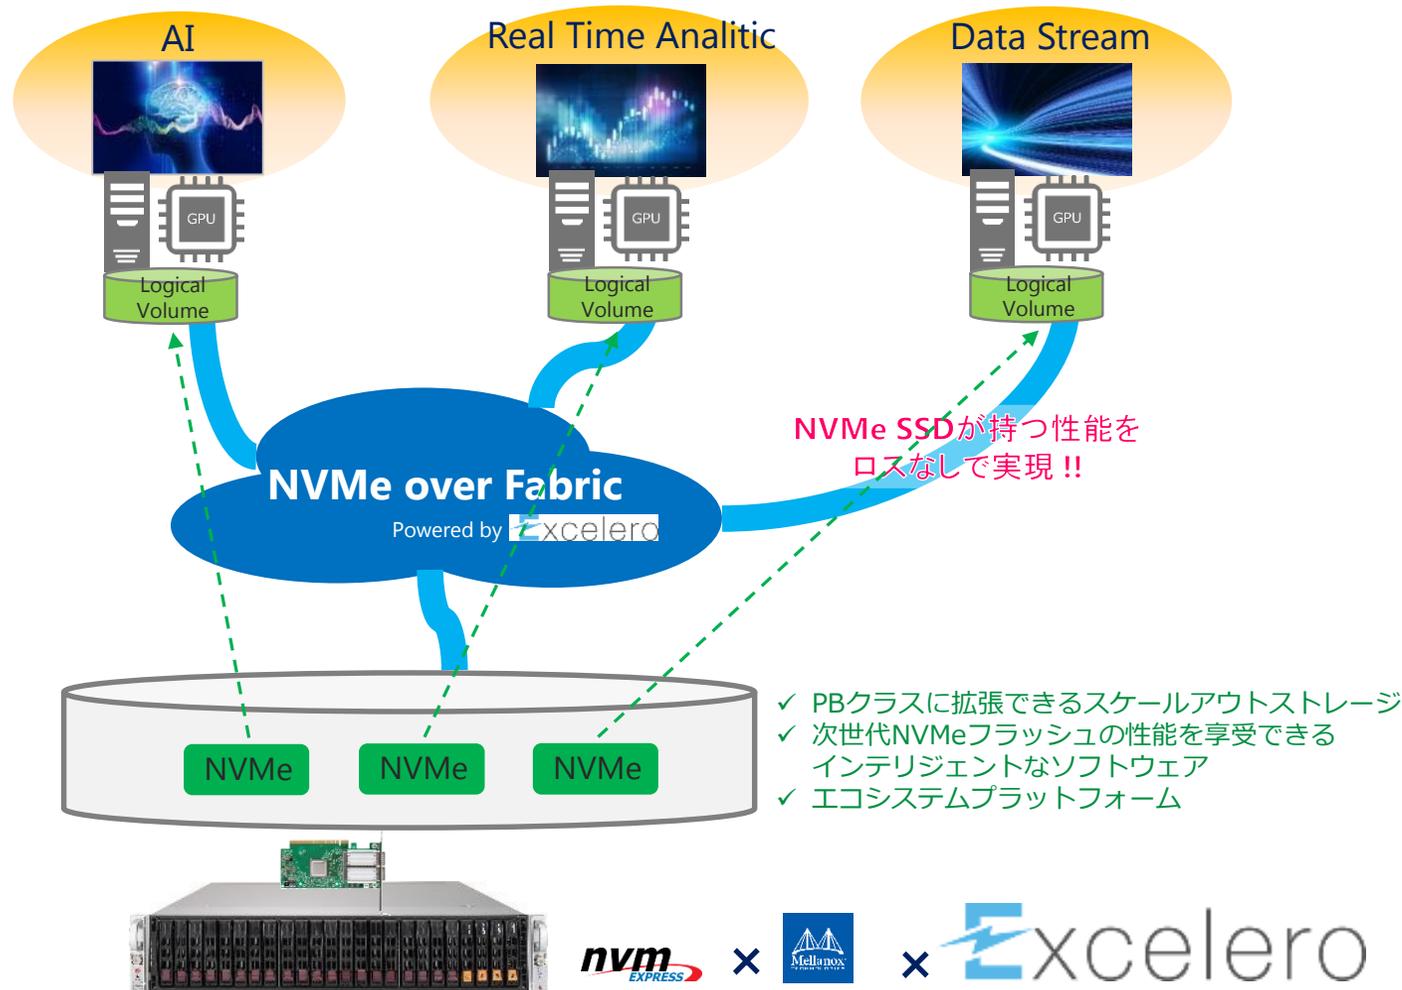
- 7.6TB
- 3,350MB/s (=26.8Gbps)
- 835K IOPS

<https://www.hgst.com/products/solid-state-solutions/ultrastar-sn200-series>



- 4台搭載すれば 100Gbps を超え、軽く 3M IOPS を超える性能を叩き出す

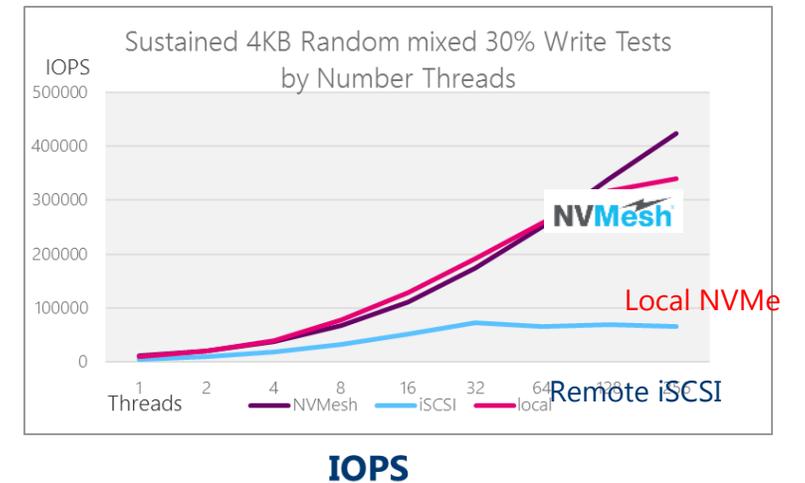
Exceleroで実現するNVMeスケールアウトストレージ



NVMe SSDが持つ性能をロスなしで実現!!

- ✓ PBクラスに拡張できるスケールアウトストレージ
- ✓ 次世代NVMeフラッシュの性能を享受できるインテリジェントなソフトウェア
- ✓ エコシステムプラットフォーム

- ✓ リモート性能 = ローカル性能
- ✓ PBスケール
- ✓ エコシステムプラットフォーム



NVMeローカル性能に比べ性能低下ゼロ



ヘテロジニアスな
コンピューティングHW

大容量、低レイテンシー
+ ファブリック接続

広帯域(100/200/400G)、低遅延
+ Application Aware Network

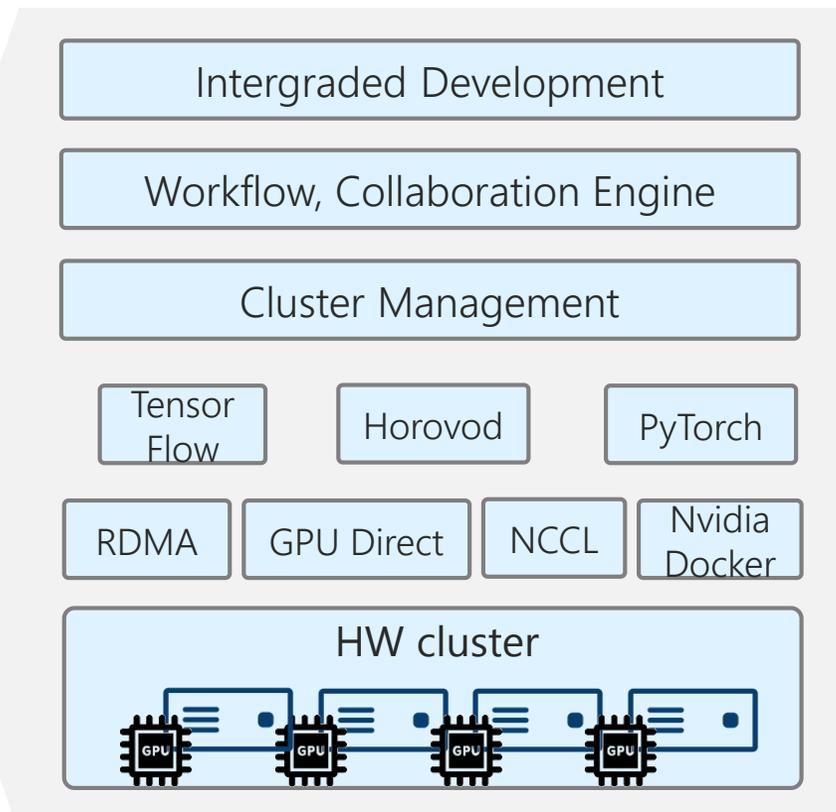
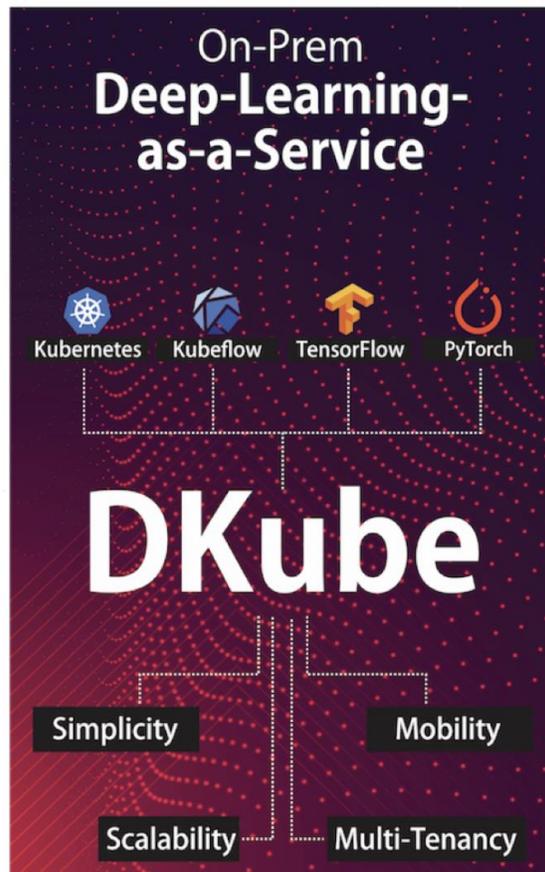


コンポーザブル インフラストラクチャ

ヘテロジニアスなオンプレ環境の統合管理オーケストレータ

オンプレ基盤でDL-as-a-Serviceを実現するためのオーケストレーションソフトウェア

OC One Convergence



- プロジェクト管理
- セグメンテ分離、パーティショニング
- リソース、ワークフローのモニタリング

- GPU, マルチノード接続のクラスタ管理

- オープンソースフレームワークのインテグレーション

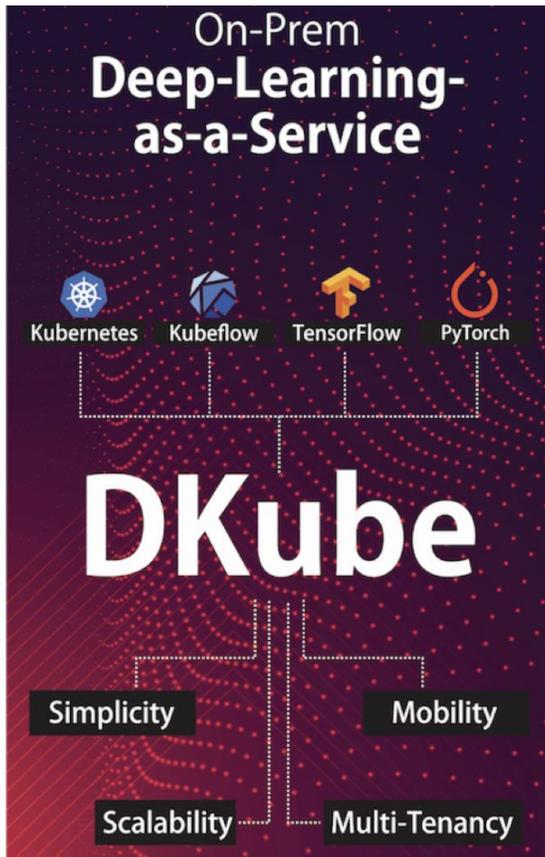
- ドライバ、ミドルウェアのインストールとメンテナンス

- HWクラスタの抽象化(GPU)

Dkubeはハード構成からアプリケーション構築までワンストップで提供

OC One Convergence

On-Prem Deep-Learning-as-a-Service



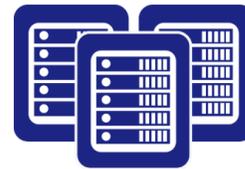
DKube

Kubernetes Kubeflow TensorFlow PyTorch

Simplicity Mobility Scalability Multi-Tenancy

+

オンプレミス



| | | |
|-----------------------------|--------------------------------------|--|
| kubernetes Orchestration | Grafana ZABBIX Monitoring | ANSIBLE puppet Automation |
| PYTORCH TensorFlow | Microsoft CNTK | K Keras Caffe2 Chainer |
| OpenCL CUDA MPI | NVMeof | NIC Driver DPDK |
| GPU CPU FPGA+ | NVMe SSD High-Speed Storage | RDMA GPU-Direct CPU offload 25/100/200G Network Fabrics |



オンプレ + Cloud Agility



- ✓ オンプレの複雑さを解決
- ✓ クラウドのアドバンテージを享受

ヘテロジニアスな
コンピューティングHW

大容量、低レイテンシー
+ ファブリック接続

広帯域(100/200/400G)、低遅延
+ Application Aware Network

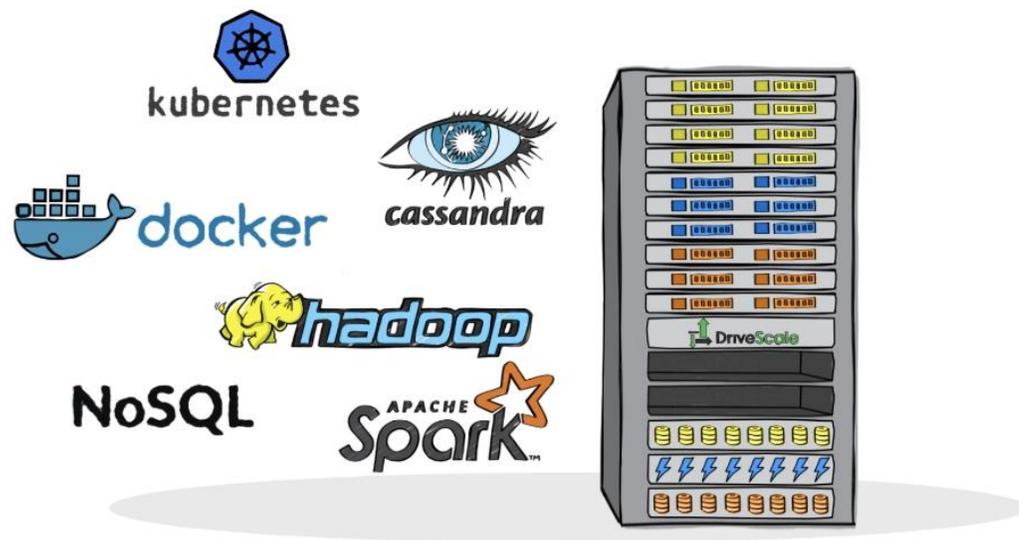
+

コンポーザブル インフラストラクチャ

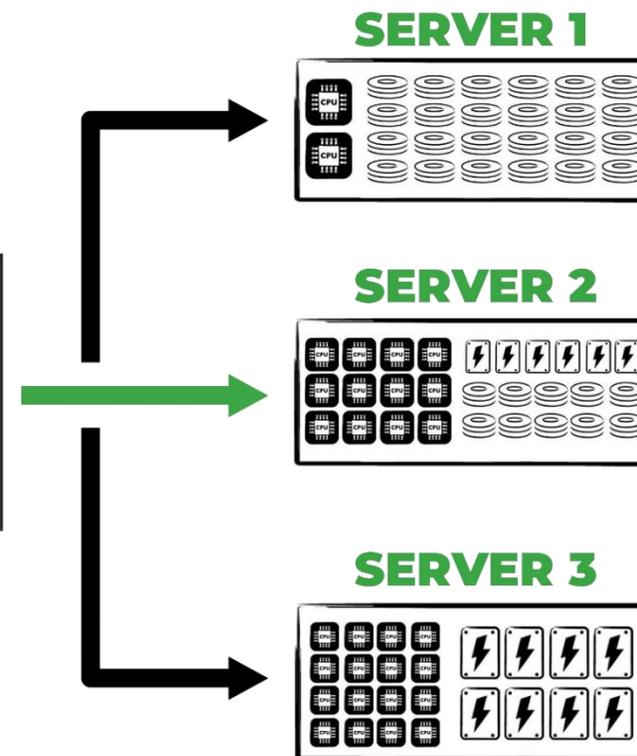


SCIを実現するソフトウェア DriveScale

Software-Defined Composable Infrastructure



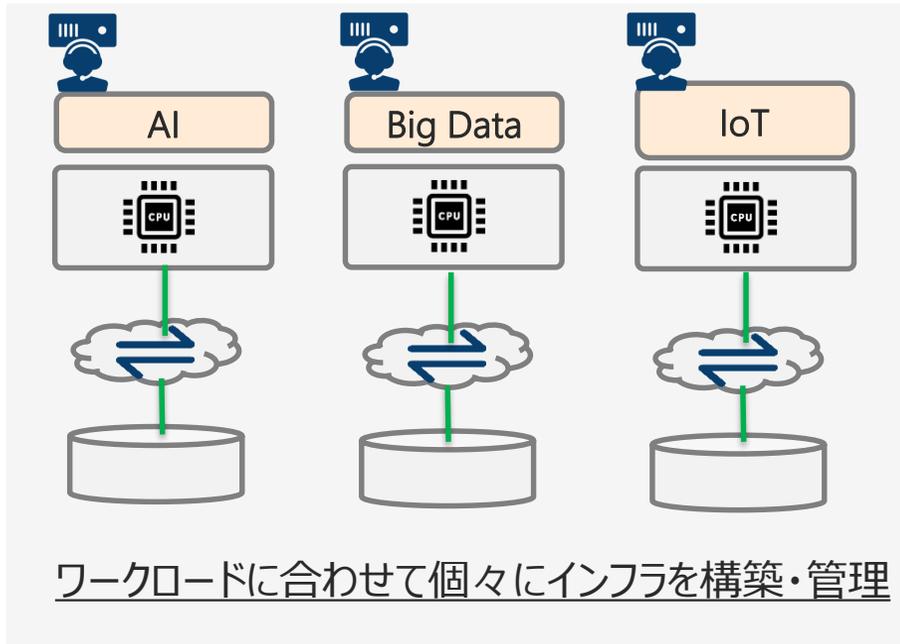
 DriveScale



- Software Composable Infrastructure (SCI) を実現するソフトウェア
- ComputeとStorageのリソースを分離して管理可能
 - スケーラブルで柔軟なインフラの実現
- Web GUI、オープンAPIによる統合管理、監視が可能

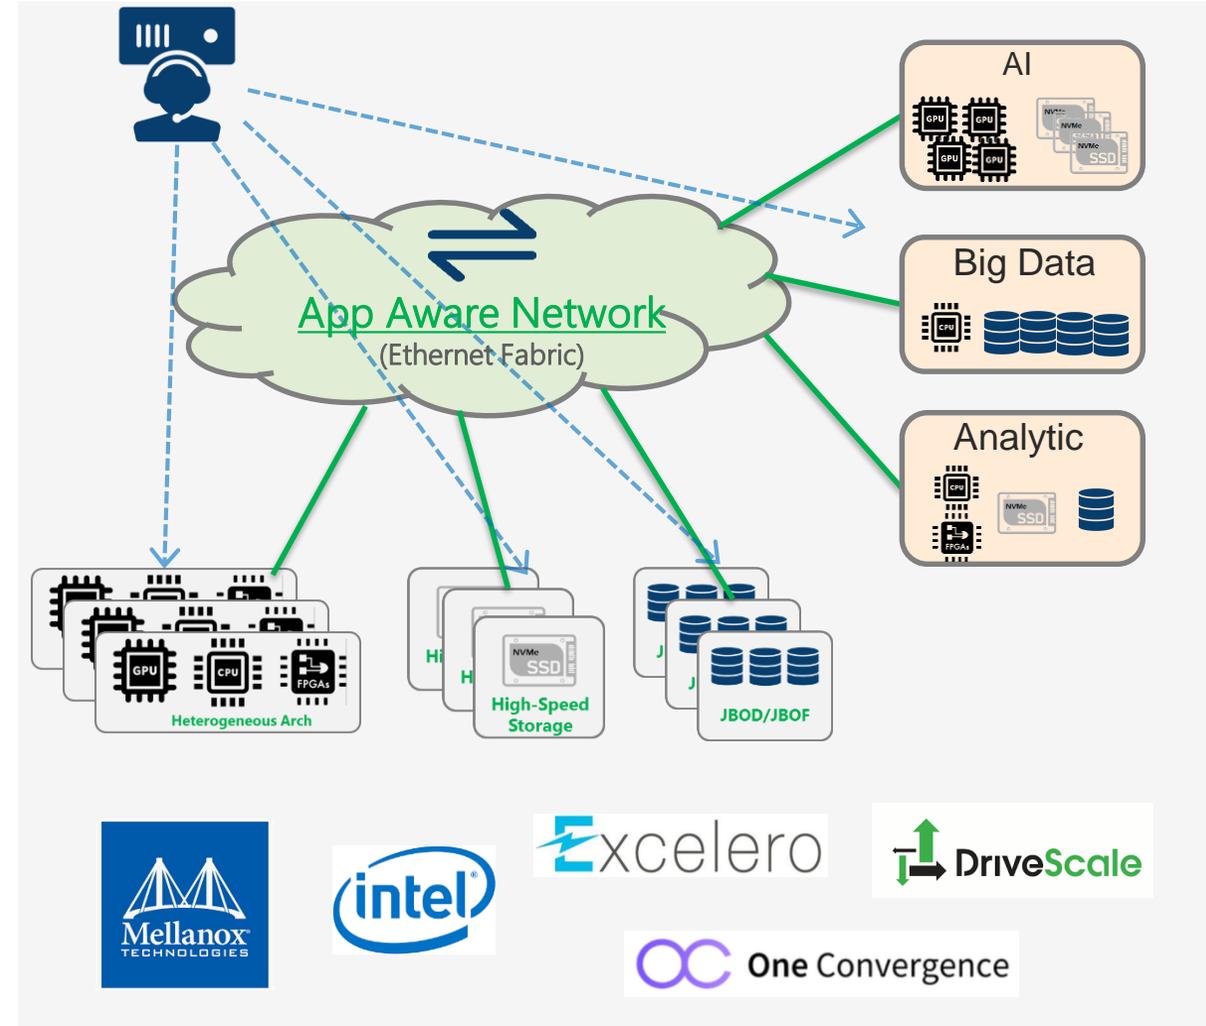
まとめ

Now



Future

Composable + API



オープンでエコシステムなインフラのことなら

マクニカがHW/SW含め、ワンストップで

ご提案、技術サポートをご提供



4/24(水) @同セミナー会場
Cumulus x Mellanox セミナー開催