

Hi-Speed Wide-band Storage Networking for IP networkers

Tajima Hirotaka

InternetWeek2019

ver.Nov.13,2019

Agenda

1. Storage Networking 基礎知識
2. 知っておきたい○○ over IP/Ethernet

Agenda

1. Storage Networking 基礎知識
2. 知っておきたい○○ over IP/Ethernet

Storage technology transitions

MEDIA Transitions

HDD
7K, 10K, 15K



NAND FLASH
SLC, MLC, TLC



SCM

DRIVE INTERFACE Transitions

PARALLEL
SCSI & ATA



**FIBRE
CHANNEL**



SAS & SATA



NVMe

HOST INTERFACE Transitions

SCSI




**FIBRE
CHANNEL**



NVMeoF

Storage technology transitions



NVMe of (over Fabrics)

NVMe of **(over Fabrics)**


Conceptualizing NVMe

	HDD + SCSI/SAS	Flash + SCSI/SAS	Flash + NVMe
Media	HDD: varying speed conveyer belts carrying data blocks (faster belts = lower seek time & latency)	Flash: all data blocks available at the same seek time & latency	Flash: all data blocks available at the same seek time & latency
Protocol	SCSI / SAS: pick & place robot w/tracked, single arm executing 1 command at a time, 1 queue	SCSI / SAS: pick & place robot w/single arm executing 1 command at a time, 1 queue	NVMe / PCIe: pick & place robot with 1000s of arms, all processing & executing commands simultaneously, over 64K queues




 Concept attribution:
J Meiz, "The Data Robot Parable"

どこがチンタラ遅いんだ？


NVMe Technical Basics: Driving down latency



NVMe Technical Basics: Driving down latency




NVMe Technical Basics: Driving down latency





Low latency
Higher bandwidth
Higher \$/GB



Lower \$/GB
High Capacity




NVMe Technical Basics: Driving down latency



NVMe Technical Basics: Driving down latency



NVMeってなんだ？



- NVMe は、レジスターインターフェイス～HW、OS、ソフトウェア間の通信の仕組みを標準化したもの。プロトコルと呼んでも良い
 - 従来のレジスターインターフェイスで対応する用語は、AHCI (Advanced Host Controller Interface)
 - NVM Expressも当初は NVMHCI という名前で検討が始まった
- SATA 3
 - 6Gbps (実効 600MB/s)
- SAS 3.0
 - 12Gb/s (実効1200MB/s)
 - 最近のUnityやXtremIO X2などは、SAS 3.0を利用
- PCIe Gen3 で 1レーン 1GB/s
 - PCIe Gen3 x4 だと、4GB/s
 - PCIe Gen3 x8 だと、8GB/s
- SATA はもともとHDD用に作られた。速度的にも進化してきたSSDには力不足

用語的には。 。 。

- **Non-Volatile Memory (NVM):**

不揮発メモリ

- **NVMe = NVM Express:**

不揮発メモリの速達(超訳)

- **NVMe-oF = NVMe over Fabrics:**

NVMeをネットワークで運ぶ

NVMe を理解する

PCI Express SSDの業界標準インターフェイス

不揮発メモリ用に設計・構築された



(SASやSATAがその生い立ちとして保持している) HDDに関する「遺産」を排除

不揮発メモリに最適化

低レイテンシで、オーバーヘッドの小さい、新たなストレージスタック

効率的でスケーラブル

合理化されたプロトコルとコマンドセット、I/Oごとに必要となるクロックサイクルを削減



NVMe を理解する

PCI Express SSDの業界標準インターフェイス

不揮発メモ

(SASやSATAが
する「遺産」を扱

不揮発メモ

低レイテンシで、
ジスタック

効率的です

合理化されたプロ

なるクロックサイクルを削減

Flashを使い倒すには
NVMeが必要



NVMeをワンスライドでいうと

- PCIe経由のSSDアクセスに特化した
- ナウイコマンドセットの
- すごい並列化と深いキューで処理するやつ

NVMe is for local PCIe storage access!

ここまではローカル接続のストレージのはなし。

(なんでNVMeが必要なのかの説明)


一方、リモートストレージ接続の観点でみると、、、

Agenda


1. Storage Networking 基礎知識
2. 知っておきたい○○ over IP/Ethernet

ボトルネックはどこだ？

CLIENTS /
HOSTS



FRONT-END
CONNECT



STORAGE
CONTROLLER




BACK-END
CONNECT



PHYSICAL
STORAGE

7200 RPM



ボトルネックはどこだ? → ちょっと前までディスクだった


CLIENTS /
HOSTS

FRONT-END
CONNECT

STORAGE
CONTROLLER

BACK-END
CONNECT

回転ディ
スク
STORAGE



ボトルネックはどこだ? →クライアント側になった

CLIENTS /
HOSTS

FRONT-END
CONNECT


STORAGE
CONTROLLER

BACK-END
CONNECT

Flash
STORAGE



Response Time
(ms)



より広帯域が求められる時代に


CLIENTS /
HOSTS

FRONT-END
CONNECT

STORAGE
CONTROLLER

BACK-END
CONNECT

PHYSICAL
STORAGE



より広帯域が求められる時代に


CLIENTS /
HOSTS

FRONT-END
CONNECT

STORAGE
CONTROLLER

BACK-END
CONNECT

PHYSICAL
STORAGE




Spindle時代: Media+Drive I/F速度 >> NW(~1G)

Flash時代 : Media+SATA/SAS ≈ NW(10G)

**SCM+NVM時代: Media+NVM << NW?
(100G)**

Networkの選択肢がより多彩な時代に

NVMe over Fabrics




- NVMe over Fabrics
 - NVMeブロックストレージ・プロトコルを、ストレージネットワーク・ファブリックに拡張する
 - 2016年6月に仕様 1.0 が公開
 - NVMeデバイスを大量に扱う、（データセンター内で）離れた場所のNVMeデバイスにアクセスする、、、等
- 2019年1月に、あらたにNVMe over TCP(NVMe/TCP) が批准された
 - TP 8000 として
 - NVMe-oF 1.1 の仕様ドキュメントに統合予定
 - Later 2019 ?

http://www.nvmexpress.org/wp-content/uploads/NVMe_Over_Fabrics.pdf

<https://nvmexpress.org/answering-your-questions-nvme-tcp-what-you-need-to-know-about-the-specification-webcast-qa/>

Typical NVMe-oF™ Deployment

JBOF / EBOF / FBOF



「ファブリック (Fabrics)」ってなに？

- **Fibre Channel**
 - 昔も今も広く使われてる。
- **InfiniBand (RDMA)**
 - 広帯域、低遅延をいかして、組み込み用途、特にHPC
 - ストレージ内部だけでなくサーバとの接続にも
- **IP/Ethernet RDMA: RoCEv2 , iWARP**
 - RoCEv2: 発音ロッキー、UDP/IPベース、**ロスレス** Converged Ethernet推奨
 - V1はL2、v2と互換性なし
 - iWARP: TCP/IPベース、実質的にHW実装が必要、普及してない
 - NICインプリが推奨
- **IP/Ethernet non-RDMA: TCP/IP**
 - ソフトウェアベース、NICのTCPオフロードで高速化



New!

「ファブリック (Fabrics)」ってなに？

- **Fibre Channel**

- 昔も今も広く使われてる。

- **InfiniBand (RDMA)**

- 広帯域、低遅延をいかして、組み込み用途、特にHPC
- ストレージ内部だけでなくサーバとの接続にも

- **IP/Ethernet RDMA: RoCEv2 , iWARP**

- RoCEv2: 発音ロッキー、UDP/IPベース、**ロスレス** Converged Ethernet推奨
 - V1はL2、v2と互換性なし
- iWARP: TCP/IPベース、実質的にHW実装が必要、普及してない
- NICインプリが推奨

- **IP/Ethernet non-RDMA: TCP/IP**

- ソフトウェアベース、NICのTCPオフロードで高速化




New!

RDMAについて補足

RDMAのまえにDMA

- DMA(Direct Memory Access)方式とは、CPUを介さずに「直接」メモリにアクセスすることをいう
- CPUの代わりにしてくれるのが「DMAコントローラ」というデバイスで、略してDMAC（でいーまっく）とも呼ばれたりする
- DMACは、チップセット（サウスブリッジに含まれています）

PIO転送



DMA転送

Programmed I/O ↔ DMA


利用例

- HDD, USBメモリ、グラフィックス他多数

RDMA

- コンピューティングにおいて、**Remote Direct Memory Access(RDMA, リモートDMA)**とは、あるコンピュータの主記憶から、異なる（リモートの）コンピュータの主記憶への DMA 転送を行うことである。RDMAでは両コンピュータのオペレーティングシステムに入ることなく転送が行われる。これにより高スループット、低レイテンシの通信を行うことができるため、特に大規模並列のコンピュータ・クラスターにおいて有用である。
- 対象のアプリケーションメモリとオペレーティングシステム中のデータバッファの間でのデータの転送をなくし、CPUやキャッシュを用いることなく、あるいはコンテキストスイッチを行うこともなく、他の処理と並列にデータを転送できる。RDMAリードまたはライト要求を行うアプリケーションでは、アプリケーションメモリのデータは直接ネットワークに配送されるため、レイテンシが削減され高速なデータ転送が可能となる。

異なるコンピュータのメモリ空間同士で（リモートで）、DMA転送を行うということ



「ファブリック(Fabrics)」ってなに？


- Fibre Channel
- InfiniBand
- RoCE
 - RDMA over Converged Ethernet
 - RoCEv1 Link Layer Protocol
 - RoCEv2 internet Layer Protocol
 - v1とv2では、プロトコルヘッダも異なる
 - 従来のEthernetも利用可能ではあるが、標準として採用されていない
- iWARP
 - Internet Wide Area RDMA Protocol
 - TOEのようなHWでの実装でないといけない
 - RDMAコンソーシアムによって策定されている
- TCP

8G/16Gが主流

32Gも徐々に

DC内

実はメタル線も可



rd)
奨

「ファブリック (Fabrics)」ってなに？

- Fibre Channel
- InfiniBand
- RoCE
 - RDMA over Converged Ethernet (RoCE)
 - RoCEv1 Link Layer Protocol
 - RoCEv2 internet Layer Protocol
 - v1とv2では、プロトコルヘッダも異なる
 - 従来のEthernetも利用可能ではあるが、遅延を低減させることを目的とする
- iWARP
 - Internet Wide Area RDMA Protocol
 - TOEのようなHWでの実装でない
 - RDMAコンソーシアムによって策定された標準規格
- TCP

HPC以外にストレージ接続も

10~40Gbpsが主流

低遅延(10GbEの1/10)

DC内



「ファブリック (Fabrics)」ってなに？

- Fibre Channel
- InfiniBand
- **RoCE**
 - RDMA over Converged Ethernet, or RoCE (発音 : "rocky")
 - RoCEv1 Link Layer Protocol
 - RoCEv2 internet Layer Protocols(ルーティングできる)
 - v1とv2では、プロトコルヘッダも異なり互換性がない(RNICは下位互換あり?) (RNIC ::= RDMA network interface card)
 - 従来のEthernetも利用可能ではあるが、ロスレスの Converged Ethernet を必須(**shall**)とする
- **iWARP**
 - Internet Wide Area RDMA Protocol (iWARP) とは、RDMA over TCPを実現する通信プロトコル群の総称である
 - TOEのようなHWでの実装でないと、速度的に問題あり
 - RDMAコンソーシアムによって策定された標準が Internet Engineering Task Force (IETF) によって改版された
- TCP

「ファブリック (Fabrics)」ってなに？

- Fibre Channel
- InfiniBand
- RoCE
 - RDMA over Converged Ethernet, or RoCE (発音 : "rocky")
 - RoCEv1 Link Layer Protocol
 - RoCEv2 internet Layer Protocols(ルーティングできる)
 - v1とv2では、プロトコルヘッダも異なり互換性がない(RNICは下位互換あり?) (RNIC ::= RDMA network interface card)
 - 従来のEthernetも利用可能ではあるが、ロスレスの Converged Ethernet が必須(Shall)とする
- **iWARP**
 - Internet Wide Area RDMA Protocol (iWARP) とは、RDMA over TCPを実現する通信プロトコル群の総称である
 - TOEのようなHWでの実装でないと、速度的に問題あり
 - RDMAコンソーシアムによって策定された標準が Internet Engineering Task Force (IETF) によって改版された
- TCP

余談:shall

7.1 Transport Requirements

- The NVMe Transport **shall provide reliable delivery of capsules between a host and NVM subsystem (and allocated controller) over each connection**. The NVMe Transport may deliver command capsules in any order on each queue except for I/O commands that are part of fused operations (refer to section 4.10 of the NVMe Base specification).

信頼性のあるトランスポートが必須

RFC2111

1. 「しなければならない (MUST)」

この語句、もしくは「要求されている (REQUIRED)」および「**することになる (SHALL)**」は、その規定が当該仕様の**絶対的な 要請事項**であることを意味します。

もっと余談: 「Shall we dance?」 「I shall return」

NVMe over Ethernet – longer term options

RoCE (RDMA over Converged Ethernet) – ベストなオペレーションには、ロスレスネットワーク（特別なハードウェア）の用意が必要。（Mellanox and Emulexがサポート）


iWARP (Internet Wide-Area RDMA Protocol) – 複雑なハード/ソフトのスタックでよりCPUリソースの消費と、現時点では10Gbのみ。（Chelsio and Intelがサポート）

NVMe over TCP – 標準のスイッチとシンプルなTCPスタックを利用。プロポーザルが内部で批准されたばかり。NVMe oFの V1.1 に盛り込まれる予定

2種類の NVMe over Fabrics

Over Fibre Channel


Figure 36: Fibre Channel Transport Protocol Layers



NVMe
over
TCPも
こちら
と同様

Over RDMA


Figure 38: RDMA Transport Protocol Layers



2種類の NVMe over Fabrics

Over Fibre Channel


Figure 36: Fibre Channel Transport Protocol Layers



NVMe
over
TCPも
こちら
と同様


Over RDMA

Figure 38: RDMA Transport Protocol Layers



2種類のNVMe over Fabrics + (ローカルの) NVMe

Figure 1: Taxonomy of Transports




ローカル

Fibre Channel
TCP

InfiniBand
RoCE
iWARP

2種類のNVMe over Fabrics + (ローカルの) NVMe

Figure 1: Taxonomy of Transports



ローカル

Fibre Channel
TCP

InfiniBand
RoCE
iWARP


**Fabricsに求められるのは「ロスレス」
ネットワーク**

Fabricsに求められる「ロスレス」ネットワーク

- NVMe over Fabricsには「ロスレス」なネットワークが必要
 - データの順序の乱れやデータの欠損は許されない
- ロスレスを実現するネットワーク技術
 - FC / Infiniband = PCI Expressと同等
 - CEE: Converged Enhanced Ethernet (Ethernetの拡張)
 - TCP/IP (再送ベース)

RoCEでロスレスを実現するPFC


- CEEのPFC:Priority-based Flow Control



PFC無しだと再送多発

Do I Really Need DCB (Lossless Net) with RoCE?

BW vs. IO Size



Source: Western Digital Performance Tests

Western Digital

Flash Memory Summit 2019, Santa Clara, CA
© 2019 Western Digital Corporation or its affiliates. All rights reserved.

11/26/2019 9

<https://www.flashmemorysummit.com/Proceedings2019/08-08-Thursday/>

それでも **Ethernet** はむずい。。。。

- Parking lot problem
- Victim Flow problem

Parking lot problem


*すべて40Gbpsリンク

*BGP ECMP

{H1, H2, H3, H4} → (各10Gbps) → R

↓↓↓

T4→R は40Gが出る、はずだが。。。。





Parking lot problem(cont.)

*すべて40Gbpsリンク

*BGP ECMP

そうならない。

Rに近い H4 → T4 が優先される。



Parking lot problem(cont.)




*すべて40Gbpsリンク

*BGP ECMP

P2リンクは1フロー

{P3,P4}リンクは複数フロー(ECMP)

→P2リンクはPauseの影響が少ない



Victim Flow problem


*すべて40Gbpsリンク

*BGP ECMP

{H11, H12, H13, H14} → (各10Gbps) → R

↓↓↓

VS → VRは20Gが出る、はずだが。。。。




Victim Flow problem

*すべて40Gbpsリンク

*BGP ECMP

VS→VR は10Gしかでない




Victim Flow problem

*すべて40Gbpsリンク


*BGP ECMP

さらに、H31→R, H32→R が通信すると

VS→VR はより減少する



T3配下の送信ノード数



まとめ

- 今どきのストレージメディア(Flash, SCM)の性能を引き出すにはNVMeが必須
- 高速ストレージメディアを高速ネットワークで運ぶ複数の選択肢あり
- ローカルNVMeをネットワークで運ぶのがNVMe over Fabrics (NVMeoF)
- FabricsにはFC以外にInfiniband, Ethernet など選択肢がある
- 超高速Ethernetはとても魅力的だが、用途を踏まえた十分な検討とPoCを
- (ぼそっ)FCは安パイ、RoCEはハードのケアが、TCPは今後注目