



200GbE 時代に再考する ハイパーバイザネットワーク設計

Akira KAMIO

whoami

神尾 皓 (Akira KAMIO)

- 株式会社サイバーエージェント
 - CyberAgent group Infrastructure Unit (CIU)
 - Cyccloud Div, Compute Team
- 2020/06 中途入社
 - 入社以来、一貫してIaaS基盤の開発/運用業務に従事
 - QEMU/KVM や高集約コンピュータノードの最適化に興味がある

Contents

1. プライベートクラウドに求められるものの变化
2. ハイパーバイザの選定と性能
3. 仮想ネットワーク方式の選定
4. OVS-DPDK データプレーン設計
5. 実現したハイパーバイザ構成
6. まとめ
7. 今後の展望



本発表の結論

- 新 HV では 100GbE x2 の物理帯域を前提に、HV あたり 170Gbps 級の実運用帯域が必要
- vDPA / SR-IOV も検討したが、互換性・運用要件から OVS-DPDK を採用
- EPYC 9655P + ConnectX-6 Dx + OVS-DPDK により 3c6t で 170Gbps, 4c8t で 200Gbps を確認
- 実運用では VM 収容効率とのバランスから 3c6t / 170Gbps 構成を採用

1

プライベートクラウドに
求められるものの変化



これまでのプライベートクラウド (1)

- ・サイバーエージェントではサービス開発者がインフラを自由に選べる
- ・プライベートクラウドは AWS / Google Cloud / Azure と比較される

プライベートクラウドが選ばれるには明確なメリットが必要

これまでのプライベートクラウド (2)

- ・機能性

- ・パブリッククラウド > プライベートクラウド

- ・性能

- ・パブリッククラウド > プライベートクラウド

- ・運用性

- ・パブリッククラウド > プライベートクラウド

- ・コスト

- ・パブリッククラウド < プライベートクラウド

サービス開発者がコスト以外でプライベートクラウドを選ぶ合理性は低い

プライベートクラウドの式年遷宮

- ・約7年ぶりとなるプライベートクラウドの刷新
- ・目標は「パブリッククラウドと戦えるプライベートクラウド」
 - ・従来の主な優位性はコストであったが、機能面・性能面を強化
- ・IaaS 基盤においては特に **性能面を重点的に刷新**

既存 IaaS の性能と AWS

旧プライベートクラウド (EPYC Rome)

Flavor	Core (thread)	Network Gbps
a1.large	2	1.2
a1.xlarge	4	2.4
a1.2xlarge	8	4.8
a1.3xlarge	12	7.2
a1.4xlarge	16	9.6

AWS 最新世代 (EPYC Turin)

Flavor	Core (thread)	Network Gbps
m8a.medium	1	0.52
m8a.large	2	0.937
m8a.xlarge	4	1.875
m8a.2xlarge	8	3.75
m8a.4xlarge	16	7.5
m8a.8xlarge	32	15
m8a.12xlarge	48	22.5
m8a.16xlarge	64	30
m8a.24xlarge	96	40
m8a.32xlarge	128	50

同一コア数では同等程度のスペックに見えるが
現実には旧プライベートクラウドでは **ホスト全体で 20Gbps 程度** で頭打ち

既存 IaaS の性能と AWS

旧プライベートクラウド
(EPYC Rome)

Flavor	Core (thread)	Network Gbps
a1.large	2	1.2
a1.xlarge	4	2.4
a1.2xlarge	8	4.8
a1.3xlarge	12	7.2
a1.4xlarge	16	9.6

AWS 最新世代
(EPYC Turin)

Flavor	Core (thread)	Network Gbps
m8a.medium	1	0.52
m8a.large	2	0.937
m8a.xlarge	4	1.875
m8a.2xlarge	8	3.75
m8a.4xlarge	16	7.5

15
22.5
30
40
50

これらの VM サービストラフィックに加えて
ストレージ・マイグレーショントラフィックが加わる

=> 高帯域なハイパーバイザネットワークが必要

現実には旧プライベートクラウドでは **ホスト全体で 20Gbps 程度**で頭打ち

2

ハイパーバイザの選定と性能



ハイパーバイザ選定

- CPU
 - なるべくパフォーマンスが高いこと
 - なるべくコアが多いこと
- Memory: 1thread 4GiB or 8GiB
- Storage: NVMe RAID
- Network: 100GbE x2 NIC

ハイパーバイザ選定

- CPU
 - なるべくパフォーマンスが高いこと
 - なるべくコアが多いこと
- Memory: 1thread 4GiB or 8GiB
- Storage: NVMe RAID
- Network: 100GbE x2 NIC
- NUMA: 1NUMA に収まること

ハイパーバイザ選定

- CPU

- なるべくパフォーマンスが高いこと
- なるべくコアが多いこと

- Memory: 1thread 4GiB or 8GiB

- Storage: NVMe RAID

- Network: 100GbE x2 NIC

- NUMA: 1NUMA に収まること

ハイパーバイザ選定

- CPU

- なるべくパフォーマンスが高いこと
- なるべくコアが多いこと

- Memory: 1thread 4GiB or 8GiB

- Storage: NVMe RAID

- Network: 100GbE x2 NIC

- NUMA: 1NUMA に収まること -> 1 socket

1 socket CPU の候補

- EPYC 9654P

- Genoa, Zen4, 96cores 192threads, 360W

- EPYC 9754

- Bergamo, Zen4c, **128cores 256threads**, 360W

- EPYC 9655P

- Turin, **Zen5**, 96cores 192threads, 360W

1 socket CPU の候補

- EPYC 9654P

- Genoa, Zen4, 96cores 192threads, 360W

- EPYC 9754

圧倒的な CPU パフォーマンス
1.5x vs. Genoa, Bergamo

- Bergamo, Zen4c, **128cores 256threads**, 360W

- EPYC 9655P

- Turin, **Zen5**, 96cores 192threads, 360W

ハイパーバイザ選定

- CPU

- なるべくパフォーマンスが高いこと
- なるべくコアが多いこと

- Memory: 1thread 4GiB or 8GiB

- Storage: NVMe RAID

- Network: 100GbE x2 NIC

- NUMA: 1NUMA に収まること -> 1 socket

NIC の要件

- **100GbE x2 port**
- **複数の仮想ネットワーク方式を検証できること**
 - vDPA / SR-IOV / OVS-DPDK
- **HW offload 経路を持つこと**
 - OVS dataplane offload / switchdev
 - virtio device offload

NIC の候補

- **NVIDIA ConnectX-6 Dx**

100GbE x2 対応 / DPDK / SR-IOV / switchdev / vDPA への展開余地

OpenStack / OVS-DPDK 構成での利用実績が多い

- **Intel E810**

100GbE x2 対応 / Linux / DPDK 実績あり

一方で vDPA / OVS HW offload まで含めた構成検証は要確認

- **NVIDIA BlueField DPU**

NIC 上で OVS / virtio を動かせる可能性

ただしコスト・運用複雑性・ベンダーロックインが大きい

NIC の候補

- **NVIDIA ConnectX-6 Dx**

100GbE x2 対応 / DPDK / SR-IOV / switchdev / vDPA への展開余地

OpenStack / OVS-DPDK 構成での利用実績が多い

- **Intel E810**

100GbE x2 対応 / Linux / DPDK 実績あり

一方で vDPA / OVS HW offload まで含めた構成検証は要確認

- **NVIDIA BlueField DPU**

NIC 上で OVS / virtio を動かせる可能性

ただしコスト・運用複雑性・ベンダーロックインが大きい

NIC の候補

- **NVIDIA ConnectX-6 Dx**

100GbE x2 対応 / DPDK / SR-IOV / switchdev / vDPA への展開余地
OpenStack / OVS-DPDK 構成での利用実績が多い

- **Intel E810**

100GbE x2 対応 / Linux / DPDK 実績あり
一方で vDPA / OVS HW offload まで含めた構成検証は要確認

- **NVIDIA BlueField-3 DPDK**

NIC 上で

**帯域・機能・運用実績・将来性のバランスから
NVIDIA ConnectX-6 Dx を選定**

ただしコスト・運用複雑性・ベンダーロックインが大きい

最終的なハイパーバイザ物理構成

CPU: EPYC 9655P (Zen5, 96cores 192threads)

MEM: 768GiB (1thread 4GiB)

Storage: 3.2TiB NVMe RAID1

NIC: NVIDIA ConnectX-6 Dx 100GbE 2port

最終的なハイパーバイザ物理構成

CPU: EPYC 9655P (Zen5, 96cores 192threads)

MEM: 768GiB (1thread 4GiB)

Storage: 3.2TiB NVMe RAID1

NIC: NVIDIA ConnectX-6 Dx 100GbE 2port

**物理構成は決まったので 200Gbps 級の帯域を活かせる
ハイパーバイザ面を設計していく**

(再掲) 既存 IaaS の性能と AWS

旧プライベートクラウド (EPYC Rome)

Flavor	Core (thread)	Network Gbps
a1.large	2	1.2
a1.xlarge	4	2.4
a1.2xlarge	8	4.8
a1.3xlarge	12	7.2
a1.4xlarge	16	9.6

AWS 最新世代 (EPYC Turin)

Flavor	Core (thread)	Network Gbps
m8a.medium	1	0.52
m8a.large	2	0.937
m8a.xlarge	4	1.875
m8a.2xlarge	8	3.75
m8a.4xlarge	16	7.5
m8a.8xlarge	32	15
m8a.12xlarge	48	22.5
m8a.16xlarge	64	30
m8a.24xlarge	96	40
m8a.32xlarge	128	50

同一コア数では同等程度のスペックに見えるが
現実には旧プライベートクラウドでは **ホスト全体で 20Gbps 程度** で頭打ち

(再掲) 既存 IaaS の性能と AWS

旧プライベートクラウド (EPYC Rome)

Flavor	Core (thread)	Network Gbps
a1.large	2	1.2
a1.xlarge	4	2.4
a1.2xlarge	8	4.8
a1.3xlarge	12	7.2
a1.4xlarge	16	9.6

AWS 最新世代 (EPYC Turin)

Flavor	Core (thread)	Network Gbps
m8a.medium	1	0.52
m8a.large	2	0.937
m8a.xlarge	4	1.875
m8a.2xlarge	8	3.75
m8a.4xlarge	16	7.5
m8a.8xlarge	32	15
m8a.12xlarge	48	22.5
m8a.16xlarge	64	30
m8a.24xlarge	96	40
m8a.32xlarge	128	50

EPYC 9655P (96c192t) では VM トラフィック 40Gbps x2 = 80Gbps がターゲット

(再掲) 既存 IaaS の性能と AWS

旧プライベートクラウド (EPYC Rome)

Flavor	Core (thread)	Network Gbps
a1.large	2	1.2
a1.xlarge	4	2.4
a1.2xlarge	8	4.8
a1.3xlarge	12	7.2
a1.4xlarge	16	9.6

ストレージ: MAX 50Gbps
マイグレーション: MAX 40Gbps

AWS 最新世代 (EPYC Turin)

Flavor	Core (thread)	Network Gbps
m8a.medium	1	0.52
m8a.large	2	0.937
m8a.xlarge	4	1.875
m8a.2xlarge	8	3.75
m8a.4xlarge	16	7.5
m8a.8xlarge	32	15
m8a.12xlarge	48	22.5
m8a.16xlarge	64	30
m8a.24xlarge	96	40
m8a.32xlarge	128	50

EPYC 9655P (96c192t) では VM トラフィック 40Gbps x2 = 80Gbps がターゲット

(再掲) 既存 IaaS の性能と AWS

旧プライベートクラウド (EPYC Rome)

Flavor	Core (thread)	Network Gbps
a1.large	2	1.2
a1.xlarge	4	2.5
a1.2xlarge	8	5.0
a1.3xlarge	12	7.5
a1.4xlarge	16	10.0

ストレージ: MAX 50Gbps
マイグレーション: MAX 40Gbps

AWS 最新世代 (EPYC Turin)

Flavor	Core (thread)	Network Gbps
m8a.medium	1	0.52
m8a.large	2	0.937
m8a.xlarge	4	1.875
m8a.2xlarge	8	3.75
m8a.4xlarge	16	7.5
m8a.8xlarge	32	15
m8a.12xlarge	48	22.5
m8a.16xlarge	64	30
m8a.24xlarge	96	40
m8a.32xlarge	128	50

80Gbps + 50Gbps + 40Gbps = 170Gbps !

EPYC 9655P (96c192t) では VM トラフィック 40Gbps x2 = 80Gbps がターゲット

(再掲) 既存 IaaS の性能と AWS

旧プライベートクラウド (EPYC Rome)

Flavor	Core (thread)	Network Gbps
a1.large	2	1.2
a1.xlarge	4	2.5
a1.2xlarge	8	5.0
a1.3xlarge	12	7.5
a1.4xlarge	16	10.0

ストレージ: MAX 50Gbps
マイグレーション: MAX 40Gbps

AWS 最新世代 (EPYC Turin)

Flavor	Core (thread)	Network Gbps
m8a.medium	1	0.52
m8a.xlarge	4	0.937
m8a.2xlarge	8	1.875
m8a.4xlarge	16	3.75
m8a.8xlarge	32	7.5
m8a.12xlarge	48	15
m8a.16xlarge	64	22.5
m8a.24xlarge	96	30
m8a.32xlarge	128	40

80Gbps + 50Gbps + 40Gbps = 170Gbps !

=> ハイパーバイザあたり 170Gbps の帯域が必要

3

仮想ネットワーク方式の選定



仮想ネットワーク方式候補

- **OpenvSwitch**
- **OpenvSwitch + DPDK + vhost-user**
- **OpenvSwitch + SR-IOV**
- **OpenvSwitch + vDPA Kernel Framework**

OpenvSwitch

- **特徴**

- オープンソースの OpenFlow 実装の仮想スイッチ
- linuxbridge と異なり user 空間で動作する

- **性能**

- ～20Gbps

- **Pros.**

- 手軽に構築できる

- **Cons.**

- メモリコピーが多く発生する
- softirq が多い -> CPU 使用率が上がりやすい
- user 空間で実行されるプロセスのため、タスクスケジューリングの影響を受けやすい
- **レイテンシが安定しない**

OpenvSwitch

- 特徴

- オープンソースの OpenFlow 実装の仮想
- linuxbridge と異なり user 空間で動作する

- 性能


- ~20Gbps

- Pros.

- 手軽に構築できる

- Cons.

- メモリコピーが多く発生する
- softirq が多い -> CPU 使用率が上がりや
- user 空間で実行されるプロセスのため、
- レイテンシが安定しない



OpenvSwitch + DPDK + vhost-user

- **特徴**

- OpenvSwitch と DPDK (Data Plane Development Kit) を組み合わせたもの
- NFV で用いられることも多い
- ポーリングプロセスを user 空間で動作させ、パケットを処理
- vhost-user を用いることで shared memory を介してパケットをやり取りできる

- **性能**

- ～50Gbps

- **Pros.**

- OpenvSwitch をそのまま使うよりも圧倒的に**低レイテンシ**
- OpenvSwitch の機能をそのまま利用できる

- **Cons.**

- ポーリングプロセスのために CPU コアを割り当てる必要がある(余分にリソースが必要)

OpenvSwitch + DPDK + vhost-user

user 空間にあるプロセスで NIC をポーリングして kernel 空間をバイパスする

- ポーリングプロセスを user 空間で動作させる
- vhost-user を用いることで shared memory

• 性能


- ~50Gbps

• Pros.

- OpenvSwitch をそのまま使うよりも圧倒的に高速
- OpenvSwitch の機能をそのまま利用でき

• Cons.

- ポーリングプロセスの OvS - vNIC 間は shared memory



OpenvSwitch + SR-IOV

- **特徴**

- OpenvSwitch を NIC 等のハードウェアでオフロードする
- OpenvSwitch のプロセスは OpenFlow コントローラとしての役割にほぼ専念する

- **性能**

- ～200Gbps (wire-rate)

- **Pros.**

- 100Gbps x2 でワイヤーレートを目指せる程度に高速
- OpenvSwitch の機能をそのまま利用できる

- **Cons.**

- ライブマイグレーションができない
- 使い方によってはベンダーロックインする
- VF (SR-IOV で分割したデバイス) の利用にドライバが必要 (古い OS だと疎通しない)

OpenvSwitch + SR-IOV

- **特徴**

- OpenvSwitch を NIC 等のハードウェアで実現
- OpenvSwitch のプロセスは OpenFlow コントローラ

- **性能**


- ~200Gbps (wire-rate)

- **Pros.**

- 100Gbps x2 でワイヤーレートを目指せる
- OpenvSwitch の機能をそのまま利用できる

- **Cons.**

- ライブマイグレーションができない
- 使い方によってはベンダーロックインする
- VF (SR-IOV で分割したデバイス) の利用は



OpenvSwitch + vDPA Kernel Framework

- **特徴**

- OpenvSwitch を NIC 等のハードウェアでオフロードする
- VM へ VF を渡さず host kernel で終端、virtio デバイスを渡す

- **性能**

- ～200Gbps ?

- **Pros.**

- OpenvSwitch HW Offload をより汎用的に利用できる
- virtio driver さえあれば HW Offload のメリットを享受できる

- **Cons.**

- ドキュメントが揃っていない

OpenvSwitch + vDPA Kernel Framework

- 特徴

- OpenvSwitch を NIC 等のハードウェアで
- VM へ VF を渡さず host kernel で終端、vi

- 性能

- ~200Gbps ?


- Pros.

- OpenvSwitch HW Offload をより汎用的に
- virtio driver さえあれば HW Offload のメ

- Cons.

- ドキュメントが揃っていない

VF を vDPA Framework で終端
virtio device として qemu に見せる



構成まとめ

	OpenvSwitch	OvS + DPDK	OvS + SR-IOV	OvS + vDPA Framework
Latency	High	Low	Low	Low
Speed	20Gbps	50Gbps	200Gbps (wire-rate)	200Gbps (wire-rate)
Live Migration	Yes	Yes	No	Yes
virtio support	Yes	Yes	No	Yes
vendor lock	No	No	Yes	No
Manageability	Mid	Mid	Low	?
CPU usage	Mid	High (using dedicated core)	Low	Low

構成まとめ

	OpenvSwitch	OvS + DPDK	OvS + SR-IOV	OvS + vDPA Framework
Latency	High	Low	Low	Low
Speed	20Gbps	50Gbps	200Gbps (wire-rate)	200Gbps (wire-rate)
Live Migration	Yes	Yes	No	Yes
virtio support	Yes	Yes	No	Yes
vendor lock	No	No	Yes	No
Manageability	Mid	Mid	Low	?
CPU usage	Mid	High (using dedicated core)	Low	Low

OpenvSwitch + vDPA Kernel Framework が良さそう ... !

仮想ネットワーク方式候補

- **OpenvSwitch**
- **OpenvSwitch + DPDK + vhost-user**
- **OpenvSwitch + SR-IOV**
- **OpenvSwitch + vDPA Kernel Framework**

仮想ネットワーク方式候補

- ~~OpenvSwitch~~ <- プロダクション向け構成ではないため除外
- OpenvSwitch + DPDK + vhost-user
- OpenvSwitch + SR-IOV
- OpenvSwitch + vDPA Kernel Framework

OpenvSwitch + DPDK + vhost-user

- ・チューニング次第で高帯域を狙える
- ・CPU コアを余分に使ってしまうのは嬉しい ...

OpenvSwitch + SR-IOV

- ・とても高速なのはわかっているので採用したい ... !
- ・**ゲスト OS の互換性を考えると採用できない**
 - ・すべてのゲストが Mellanox NIC VF と喋れるとは限らない
- ・ライブマイグレーションができない

OpenvSwitch + vDPA Kernel Framework

- とても高速ないい感じ NW が構成できそう ... !
- 実際に構築しようとしたところ ...
 - NVIDIA NIC のドライバ周りで
MLNX_OFED -> DOCA への過渡期で **構築不可**
 - mlx5_vdpa driver が dummy driver になっていたり ...

構築時点のドライバ／運用要件では採用困難

仮想ネットワーク方式候補

- ~~OpenvSwitch~~
- OpenvSwitch + DPDK + vhost-user
- OpenvSwitch + SR-IOV
- OpenvSwitch + vDPA Kernel Framework

仮想ネットワーク方式候補

- ~~OpenvSwitch~~
- OpenvSwitch + DPDK + vhost-user -> CPU コア使う
- OpenvSwitch + SR-IOV -> 互換性なし
- OpenvSwitch + vDPA Kernel Framework -> 構築不可

仮想ネットワーク方式候補

- ~~OpenvSwitch~~
- OpenvSwitch + DPDK + vhost-user -> CPU コア使う
- OpenvSwitch + SR-IOV -> 互換性なし
- OpenvSwitch + vDPA Kernel Framework -> 構築不可



ほな、消去法で OpenvSwitch + DPDK かな...

仮想ネットワーク方式候補

- ~~OpenvSwitch~~
- OpenvSwitch + DPDK + vhost-user -> CPU コア使う
- OpenvSwitch + SR-IOV -> 互換性なし
- Op **OVS-DPDK 構成で 200Gbps を目指すことに** **可**



ほな、消去法で OpenvSwitch + DPDK かな...

4

OVS-DPDK データプレーン設計



(再掲) OpenvSwitch + DPDK + vhost-user

- **特徴**

- OpenvSwitch と DPDK (Data Plane Development Kit) を組み合わせたもの
- NFV で用いられることも多い
- ポーリングプロセスを user 空間で動作させ、パケットを処理
- vhost-user を用いることで shared memory を介してパケットをやり取りできる

- **性能**

- ～50Gbps

- **Pros.**

- OpenvSwitch をそのまま使うよりも圧倒的に**低レイテンシ**
- OpenvSwitch の機能をそのまま利用できる

- **Cons.**

- ポーリングプロセスのために CPU コアを割り当てる必要がある(余分にリソースが必要)

(再掲) OpenvSwitch + DPDK + vhost-user

- **特徴**

- OpenvSwitch と DPDK (Data Plane Development Kit) を組み合わせたもの
- NFV で用いられることも多い
- ポーリングプロセスを user 空間で動作させ、パケットを処理
- vhost-user を用いることで shared memory を介してパケットをやり取りできる

- **性能**

- ～50Gbps

- **Pros.**

- OpenvSwitch をそのまま使うよりも圧倒的に**低レイテンシ**
- OpenvSwitch の機能をそのまま利用できる

- **Cons.**

- ポーリングプロセスのために CPU コアを割り当てる必要がある(余分にリソースが必要)

DPDKのパフォーマンス特性

- ・DPDK は CPU コアを割り当てるほどパフォーマンスが上がる
 - ・ただし NIC の queue 数や NUMA 配置などにも依存する
- ・性能を引き出すには CPU コア配置が重要
 - ・同一 NUMA node、同一 L3 cache を共有するコアを利用
 - ・配置が不適切だと、メモリアクセスやキャッシュ効率が悪化し性能が頭打ちになる

DPDKのパフォーマンス特性

- ・ **DPDK は CPU コアを割り当てるほどパフォーマンスが上がる**
 - ・ **ただし NIC の queue 数や NUMA 配置などにも依存する**
- ・ **性能を引き出すには CPU コア配置が重要**
 - ・ **同一 NUMA node、同一 L3 cache を共有するコアを利用**
 - ・ **配置が不適切だと、メモリアクセスやキャッシュ効率が悪化し性能が頭打ちになる**

DPDKのパフォーマンス特性

- DPDK


- ただし

- 性能を


- 同一

- 配置が

OVS: *hw-offload* Core Scaling Experiment Results



PHY-PHY TEST



PHY-VM-PHY TEST

DPDKのパフォーマンス特性


- ・DPDK は CPU コアを割り当てるほどパフォーマンスが上がる
 - ・ただし NIC の queue 数や NUMA 配置などにも依存する
- ・性能を引き出すには CPU コア配置が重要
 - ・同一 NUMA node、同一 L3 cache を共有するコアを利用
 - ・配置が不適切だと、メモリアクセスやキャッシュ効率が悪化し性能が頭打ちになる

DPDKのパフォーマンス特性

- ・ DPDK は CPU コアを割り当てるほどパフォーマンスが上がる
 - ・ ただし NIC の queue 数や NUMA 配置などにも依存する
- ・ 性能を引き出すには CPU コア配置が重要
 - ・ 同一 NUMA node、同一 L3 cache を共有するコアを利用
 - ・ 配置が不適切だと、メモリアクセスやキャッシュ効率が悪化し性能が頭打ちになる

DPDKのパフォーマンス特性

- ・DPDKはCPUコアを割り当てるほどパフォーマンスが上がる
 - ・ただしNICのqueue数やNUMA配置などにも影響を受ける
- ・性能を引き出すにはCPUコア配置が重要
 - ・同一NUMA node、同一L3 cacheを共有するコアをDPDKプロセスに割り当てる
 - ・配置が不適切だと、メモリアクセスやキャッシュヒット率が低下する




DPDKのパフォーマンス特性

- ・DPDKはCPUコアを割り当てるほどパフォーマンスが上がる
 - ・ただしNICのqueue数やNUMA配置などにも影響を受ける
- ・性能を引き出すにはCPUコア配置が重要
 - ・同一NUMA node、同一L3 cacheを共有するコアをDPDKに割り当てる
 - ・配置が不適切だと、メモリアクセスやキャッシュヒット率が低下する



DPDKのパフォーマンス特性

- ・DPDK は CPU コアを割り当てるほどパフォーマンスは上がる
- ・ただし NIC の queue 数や NUMA 配置などにもよる
- ・性能を引き出すには CPU コア配置が重要
- ・同一 NUMA node、同一 L3 cache を共有するコアを1グループとする
- ・配置が不適切だと、メモリアクセスやキャッシュヒット率が低下する



EPYC Turin は L3 cache を 8cores 16threads で共有
ここから PMD CPU コアをアサインすれば良い

PMD アサインする CPU のバランス

- ・ PMD に CPU コアを割り当てるほど、仮想スイッチ性能は向上する
 - ・一方で、PMD 用に確保した CPU コアは VM に割り当てられない
- ・そのため、PMD コア数は性能と収容効率のトレードオフになる
 - ・少ない PMD コア数で 200Gbps 級の帯域を実現したい

PMD アサインする CPU のバランス

- ・PMD に CPU コアを割り当てるほど、仮想スイッチ性能は向上する
 - ・一方で、PMD 用に確保した CPU コアは VM に割り当てられない
- ・そのため、PMD コア数は性能と収容効率のトレードオフになる
 - ・少ない PMD コア数で 200Gbps 級の帯域を実現したい

2cores 4threads で 200Gbps の実現を目標に


5

実現したハイパーバイザ構成




実現した OpenvSwitch 構成 (1)

- PMD 3cores 6threads
- dpdkvhostuser**client**
- qemu をホストとして接続




実現した OpenvSwitch 構成 (1)


- PMD 3cores 6threads
- dpdkvhostuser**client**
- qemu をホストとして接続



実現した OpenvSwitch 構成 (2)



ホスト側データパス構成



- ConnectX-6 Dx の SR-IOV VF LAG の機能を利用
 - switchdev のレイヤでポート冗長される

OVS-DPDK チューニング

- **そのままの DPDK 構成では 70Gbps 程度で頭打ったためチューニングを行った**
 - **PMD rxq pinning (bond0 のみ / 100GbE x2 の受信処理を安定化)**
 - **pmd-rxq-assign: group (PMD 処理負荷を最適化しやすい)**
 - **TCP congestion control: BBR**
 - **NIC ring buffer 拡張**
 - **...**


OVS-DPDK チューニング

- そのままの DPDK 構成では 70Gbps 程度で頭打ったためチューニングを行った
 - PMD rxq pinning (bond0 のみ / 100GbE x2 の受信処理を安定化)
 - pmd-rxq-assign: group (PMD 処理負荷を最適化しやすい)
 - TCP congestion control: BBR
 - NIC ring buffer 拡張
 - ...

素の DPDK 構成: 70Gbps
↓ tuning
200Gbps を使い切る構成を達成


性能測定

- ・ホスト側通信と VM 間通信で iperf を同時実行
- ・それぞれのスループットを合算し
HV が処理可能な総帯域として評価
- ・物理 NIC / bond / switchdev / OvS
VM 通信を含む実運用に近い経路で測定



性能測定結果

- 目標: 2cores4threads で 200Gbps -> 実現できず
 - PMD に割く CPU を最小化、VM に最大限 CPU を残す
- 3cores6threads で 170Gbps
 - 200Gbps は達成可能だが、VM 収容効率とのバランスを重視
- 4cores8threads で 200Gbps を達成
 - OVS-DPDK 構成で物理帯域を使い切れることを確認



(再掲) 既存 IaaS の性能と AWS

旧プライベートクラウド (EPYC Rome)

Flavor	Core (thread)	Network Gbps
a1.large	2	1.2
a1.xlarge	4	2.5
a1.2xlarge	8	5.0
a1.3xlarge	12	7.5
a1.4xlarge	16	10.0

ストレージ: MAX 50Gbps
マイグレーション: MAX 40Gbps

AWS 最新世代 (EPYC Turin)


Flavor	Core (thread)	Network Gbps
m8a.medium	1	0.52
m8a.xlarge	4	0.937
m8a.2xlarge	8	1.875
m8a.4xlarge	16	3.75
m8a.8xlarge	32	7.5
m8a.12xlarge	48	15
m8a.16xlarge	64	22.5
m8a.24xlarge	96	30
m8a.32xlarge	128	40

80Gbps + 50Gbps + 40Gbps = 170Gbps !

=> ハイパーバイザあたり 170Gbps の帯域が必要

性能測定結果

- 目標: 2cores4threads で 200Gbps -> 実現できず
 - PMD に割く CPU を最小化、VM に最大限 CPU を残す
- 3cores6threads で 170Gbps
 - 200Gbps は達成可能だが、VM 収容効率とのバランスを重視
- 4cores8threads で 200Gbps を達成
 - OVS-DPDK 構成で物理帯域を使い切れることを確認




性能測定結果

- 目標: 2cores4threads で 200Gbps -> 実現できず
- PMD に割く CPU を最小化、VM に最大限 CPU を残す

- 3cores4threads で 200Gbps を達成
 - 2cores4threads で 200Gbps を達成
- EPYC Turin の CPU パフォーマンスの高さにより
少ないコアでの高帯域構成を実現

- 4cores8threads で 200Gbps を達成
- OVS-DPDK 構成で物理帯域を使い切れることを確認




性能測定結果

- 目標: 2cores4threads で 200Gbps -> 実現できず
- PMD に割く CPU を最小化、VM に最大限 CPU を残す

- 3cores4threads で 200Gbps を実現
 - 2cores4threads で 200Gbps を実現
- EPYC Turin の CPU パフォーマンス
少ないコアでの高帯域


他の CPU だとどうだった？

- 4cores8threads で 200Gbps を実現
- OVS-DPDK 構成で物理帯域が切れることを確認



他の CPU での DPDK 性能 (1)

- DPDK PMD 処理性能は CPU の single-thread 性能・整数演算性能の影響を大きく受ける
 - > Dhrystone スコアを PMD 必要コア数の概算指標として利用



他の CPU での DPDK 性能 (2)

- 既存のプライベートクラウド CPU

- Intel Xeon Gold 6138 : 8cores 16threads
- AMD EPYC 7352 : 7cores 14threads

- 採用検討 CPU

- AMD EPYC 9654P : 5cores 10threads
- AMD EPYC 9754 : 6cores 12threads

- 採用 CPU

- AMD EPYC 9655P : 3cores 6threads

他の CPU での DPDK 性能 (2)

- 既存のプライベートクラウド CPU

- Intel Xeon Gold 6138 : 8cores 16threads
- AMD EPYC 7352 : 7cores 14threads

- 採用検討 CPU

- AMD EPYC 9654P : 5cores 10threads
- AMD EPYC 9754 : 6cores 12threads

- 採用 CPU

- AMD EPYC 9655P : 3cores 6threads

EPYC Turin の CPU パフォーマンスの高さが際立つ

6

まとめ



まとめ

- ・パブリッククラウドと戦うためには、プライベートクラウドにおいても高帯域なハイパーバイザネットワークが必要
- ・OVS-DPDK にて 200Gbps ready なハイパーバイザ基盤を実現
 - ・実運用設計は 170Gbps
- ・EPYC Turin により、少ない PMD コアでも 170Gbps 級の実運用性能を実現

7

今後の展望



次期 HV ネットワークに向けて

- NVIDIA NIC の推奨・サポート範囲が DPU / vDPA / SR-IOV よりに変化している
 - 最新の NVIDIA の Software Framework では DPDK が削除される等
- DPU: BlueField 3 で NIC 上で OVS / virtio を動かす
 - Pros: HV から仮想ネットワーク処理を分離できる
 - Cons: ベンダーロックインやコスト
- vDPA: ConnectX NIC で vDPA 構成
 - Pros: 比較的安価に低遅延・大容量な仮想ネットワークを実現できる
 - Cons: OpenStack へのインテグレーションコスト

EOP

參考資料

- Partial Offload Optimization and Performance on Intel Ethernet 700 Series NICs Using rte_flow

https://www.openvswitch.org/support/ovscon2019/day1/1305-OVS_Conference_OVS-DPDK_Partial_Offload.pdf