

ntt.com



# 100G高速PCルーター開発

～国産ソフトウェアルーターへの挑戦～

2016年 11月 28日  
NTTコミュニケーションズ株式会社  
技術開発部 小原 泰弘

Transform your business, transcend expectations with our technologically advanced solutions.

- コアルータ1つ1億円弱。
- PCルータはどこまでいけるのか。
- 1つ置き換えることができれば、数千万のコストダウン。
- NFVに向けて。
  
- Poptrie (SIGCOMM'15)
- DPDK, RCU.
- 520K BGP full route で 128B frame で 145Gbps (~122Mpps) を達成。
  
- Kamuee0 実装、デモ、評価グラフ
- Poptrie 説明

- NTTコミュニケーションズでソフトウェアルーターを自作してしまおう！という研究プロジェクト
- PCとは：
  - インテルx86アーキテクチャを踏襲したサーバー
- PCルーターとは：
  - PCサーバーでソフトウェアルーターを動作させたもの
- 100G高速とは：
  - 市販の100Gイーサネットサーバーアダプターをターゲット
  - ショートパケット**でも**ワイヤーレート性能を達成する
  - 経路ルックアップ有り**でも**ワイヤーレート性能を達成する
- 安価な市販部品で高速な専用機械を自作する
- 専用ハードウェアを用いないため安価
- メインはソフトウェア技術

- コアバックボーンルーター（専用機）は高価（数千万円）
  - コアバックボーンの経路は最大約65万（2016/10時点）
  - 64B パケットで 100GbE における最大性能は 148.8 Mpps：つまり 1億4880万パケット毎秒
- 経路ルックアップ専用の部品：TCAM
  - 熱とスケール（集積度）の問題
- CPUの高速化、高並列化（3GHz、10コア等）
- ソフトウェアの進化
  - パケット転送：DPDK, NetMap
- NFVの出現
  - 仮想化環境におけるハイパーバイザー（PC）上でのスイッチ、ルーター
- ソフトウェアルーターの重要性

- TCAMを代替できるアルゴリズム (ソフトウェア)
- 経路ルックアップアルゴリズム Poptrie の開発と提案
  - 東京大学 浅井大史 助教による発明、共同研究
  - ACM SIGCOMM '15 での論文採録
    - ✓ H. Asai, Y. Ohara, "Poptrie: A Compressed Trie with Population Count for Fast and Scalable Software IP Routing Table Lookup", ACM SIGCOMM '15, p.57-70.
- 特許取得
  - 特許第5960863号 (特願2015-048657) H.28 7/1 登録
- 実装: Kamuee0
  - DPDKを利用したソフトウェアルーター実装
  - プロプラエタリ (NTTコム固有の技術)
- 40GbE x 4、51万経路で 128Bytes 145Gbps 程度を達成

## ■ 性能問題

- スループット性能の問題
  - ✓ 128Bytes 未満のスループット性能が低い
- パケットロス問題
  - ✓ 128Bytes 以上でも（低負荷時でも）パケットロスが多い
- FPGAサーバーアダプターの開発？

## ■ 機能問題

- ルーティングプロトコルエンジンの統合
- 統計カウンター実装
- NFVサポート（SR-IOV等）

## ■ CAPEX（初期投資）低下、でもOPEXは？




- NTTコミュニケーションズのバックボーンサービスの品質向上
  - 100GbE x 4 レベルの物理ルーターの低コスト化
  - 後方支援：余裕が出ればリソースを他に投入できる（玉突き効果）
- 顧客さまSI案件での高速で安価な物理ルーターの導入
- 共同の研究開発（FW、CGN、ロードバランサー、DPI、…）
- クラウドやNFVサービスでの、安価で高速な仮想ルーターの選択肢

## ■ a paper appeared in AINTEC 2015

- Y. Ohara et. al. "Revealing the Necessary Conditions to Achieve an 80Gbps High-Speed PC Router" AINTEC 2015


## ■ Comparisons of different configurations

## ■ Comparisons of Poptrie v.s. LPM (DPDK's DIR-24-8) with/without SSE optimizations




# Performance of Kamuee Zero

- a paper appeared in IC 2016
  - Y. Ohara, Y. Yamagishi, "Kamuee Zero: the Design and Implementation of Route Table for High-Performance Software Router" IC 2016
- Achieved **145**Gbps on 40GbE I/F x4, BGP Full Route, 128B




# Kamuee0's internal structure




# At ComForum 2016 (10/6,7, Tokyo)







# 40G x4 version






# Benchmark (145Gbps on 128B 40Gx4 510K routes.)







# 100G x4 version



# Q1 - Q6 (bps)




# Q1 - Q6 (fps) (80g -> 2 ports)




# Back / Straight / Cross, and WrongNuma


## WRONGNUMA



# Single Queue, traffic paths (bps)



# 開発の歩みと期待



開発を加速するために、  
要望・コメント等を  
いただけると幸いです。


- Tap デバイスを使って Quagga と連結する
  - Netlink に対応
  - 実験網で試用
  - 商用網で運用
- 
- NFV(VRF, SR-IOV, SPP等)に対応
  - NTTグループ内SDN案件に貢献 (したい)

- ロングストマッチを実行するIP経路ルックアップのためのデータ構造・アルゴリズム
  - ビットマップと popcnt 命令を使った多進木(64分木)トライ (trie)
- メモリ使用量がとても少ない
  - ティア1 ISPのバックボーンルータの経路 (BGPフルルート+IGP経路, 53万経路) が2.4MBに圧縮できる
  - CPUキャッシュに載る
- 超高速なルックアップ速度
  - CPU1コアで200Mlps (ルックアップ/秒) (100GbE 最小パケットで 148.8 Mlps必要)
  - コア数でほぼリニアにスケール: 4コアで 900Mlps 達成
- 経路アップデート (追加・削除) は複雑だが高速
  - 全経路表の再構築で 40ms 程度
  - 差分の追加・削除は 1 経路あたり平均で 2~5  $\mu$ s


- ACM SIGCOMM 2015 に採録
  - <http://dl.acm.org/citation.cfm?id=2787474>
  - 約40種類の経路表でテスト済み
  - SAIL, DXR, TreeBitMap と比較
- 強力、強固なアルゴリズム
  - ほぼすべてのケースで他のアルゴリズムを凌ぐ
  - 悪い状況のときほど優位 (プリフィックス数、長いプリフィックスの混在)
- 発明者
  - 東京大学 浅井 大史 助教
- 特許出願済み
  - 特願2015-048657

# Poptrie (basic): $2^k$ -ary Multiway Trie


Radix Tree



Key IP address



$2^k$ -ary Multiway Trie (k=2)




Push the next hop information in the internal nodes to leaf nodes


# Poptrie (basic): Pointer Compression with Population Count

† in little endian

## Pointer compression with bit-vector and array



## Array compression with population count



Index: # of 1's bits in the least significant N+1 bits of vector (-1)

Index: # of 0's bits in the least significant N+1 bits of vector (-1)

N: Value of the chunk

Counting # of 1s: Use x86's *popcnt* instruction

# Comparison with Other Algorithms (for random traffic pattern)


Algorithm	Memory [MiB]	Rate [Mlps]
Radix	30.48	8.82
Tree BitMap	2.62	56.24
Tree BitMap (64-ary)	3.10	61.61
SAIL	44.24	158.22
D16R	1.16	116.63
D18R	1.91	179.92
Poptrie <sub>16</sub>	2.75	198.28
Poptrie <sub>18</sub>	2.40	240.52

Routing table: Backbone core router of tier-1 ISP (Jan. 9, 2015), Traffic pattern: Random

Poptrie<sub>18</sub> runs 1.34–27.3x faster than the other algorithms

- H. Asai, Y. Ohara, "Poptrie: A Compressed Trie with Population Count for Fast and Scalable Software IP Routing Table Lookup", ACM SIGCOMM '15, p. 57-70.
- Y. Ohara, Y. Yamagishi, S. Sakai, A. DattaBanik, S. Miyakawa, "Revealing the Necessary Conditions to Achieve an 80Gbps High-Speed PC Router", AINTEC '15, p. 25-31.
- Y. Ohara, Y. Yamagishi, "Kamuee Zero: the Design and Implementation of Route Table for High-Performance Software Router", IC 2016.


- 共通 : 20G/40G(50%) 518,231経路 BGP停止 600sec(10分)
- 1 I/F入力
  - port1: 101.53億パケット中 31 ロス (3.05E-09/0.0000000031)
  - port2: 101.54億パケット中 21 ロス (2.07E-09/0.0000000021)
  - port3: 101.47億パケット中 300,879 (2.97E-05/0.0000296530)
  - port4: 101.48億パケット中 13 ロス (1.28E-09/0.0000000013)
- 2 I/F入力
  - port1&2: 203.10億P中 1225 ロス (6.03E-08/0.00000000603)
  - port1&3: 203.04億P中 299,312 (1.47E-05/0.0000147419)
  - port1&4: 203.03億P中 22 ロス (1.08E-09/0.0000000011)
  - port2&4: 203.06億P中 28 ロス (1.38E-09/0.0000000014)




デモ

終わり


# Single Queue, traffic paths (fps)




# Peak (160G -> 4 ports) (bps)




# Peak (160G -> 4 ports) (fps)




# Average Latency




# Maximum Latency




# Average Jitter




# Max Jitter




# 80G QX Average Latency




# 80G QX Maximum Latency




# 80G QX Average Jitter




# 80G QX Maximum Jitter




# 20M – 1Gbps Dropped (against Load)




# Million Frames Dropped (against #packets)




# 80G RCU BPS




# 80G RCU FPS




# FIB Update Time




# Overall Throughput



# Overall Latency



# Overall Jitter



- Kamuee0 Implementation.
  - Integration of Poptrie, RCU, CLI into DPDK I3fwd.
- Achieved 145Gbps in 128B 510K routes (approx. >120Mpps)