ЦЕНТР
ПРИКЛАДНЫХ
ИССЛЕДОВАНИЙ
КОМПЬЮТЕРНЫХ
СЕТЕЙ

Разработка OpenFlow коммутатора.

Вячеслав Васин: vvasin@arccn.ru

Текущая ситуация с сетевым оборудованием:

Отсутствие автоматической реакции на сетевые события в требуемом масштабе

Индивидуальное конфигурирование каждого устройства

Различные интерфейсы управления

Отсутствие гибкости

Ручной процесс конфигурирования

Длительное перестроение под нужды пользователей

Различные механизмы определения политик

Неэффективное использование ресурсов

Жесткая интеграция control & data plane

Различные возможности

Сложное управление

Высокая стоимость

Разрозненные функции

Патентованная операционная система

Закрытая патентованная архитектура

OpenFlow:

- Детальный контроль потоков.
- Гибкость в реализации политик.
- Поддержка производителей оборудования, исследовательских центров, академических кругов делает его в текущее время стандартом de-facto.

- Коммутатор может поддерживать только OpenFlow или быть гибридным.
- Режим работы OpenFlow может быть реактивный или проактивный
- Коммутатор может иметь закрытую архитектуру, но обеспечивать открытый интерфейс для управления своей таблицей коммутации.
- Коммутатор может быть сравнительно простым устройством, а значит более надежным и дешевым

Поиск по заголовку пакета

Switch Port	MAC src	MAC dst	Eth type	VLAN ID	IP Src	IP Dst	IP Prot	TCP sport	TCP dport
-------------	---------	---------	----------	---------	--------	--------	---------	-----------	-----------

Предпосылки:

Ситуация на рынке OpenFlow и гибридных коммутаторов.

Отличия в скорости реализации нового функционала в классическом и OpenFlow коммутаторе.

Отсутствие в России коммутаторов, созданных на российской элементной базе.

Рынок сбыта

- Государственные компании.
- Компании работающие с кредитными историями граждан.
- Коммерческие компании работающие в области медицины, образования, транспорта.
- Системы связанные с обработкой персональных данных.

Каким должен быть коммутатор для небольшой корпоративной сети:

- Подключение рабочих мест на скорости 100Mbps-1Gbps.
- Подключение к уровню ядра на скорости 1Gbps-10Gbps.
- Модульность для сохранения инвестиций и гибкости решений.
- Поддержка политик QoS.
- Поддержка механизмов обеспечения безопасности.
- Поддержка инструментов контроля состояния, загрузки, эффективности использования имеющихся линий связи.
- Поддержка возможности виртуализации сетевой инфраструктуры.
- Возможность передачи широковещательного трафика.
- Возможность организации балансировки нагрузки.
- Быстрая сходимость для достижения минимального времени простоя например за счет перенаправления пакетов на запасные маршруты.
- Динамическое управление сетевой инфраструктурой в зависимости от требований приложений и текущей загрузки.

Архитектура малой корпоративной сети:

- Небольшая корпоративная сеть – до 150 пользователей
- Уровни ядра и распределения объединены.

Архитектура средней корпоративной сети:

Корпоративная сеть – до 500 пользователей

ARCCN OpenFlow Switch:

- ❑ Enterprise-class Multigigabit Ethernet Switch.
- ❑ Модульная платформа на 4 слота.
- ❑ 2 типа модулей (8x1Gbps портов и 1x10Gbps порт).
- ❑ Высокоскоростное взаимодействие между модулями на скорости 10 Gbps
- ❑ Распределенная архитектура.
- ❑ Прототип на базе Xilinx Virtex-7 family FPGA (XC7V485T-2).
- ❑ Оперативная память QDR II SRAM Cypress (CY7C1515KV18)
- ❑ Использование TCAM и/или SRAM для хранения записей Flow Table.
- ❑ 4 Flow Table различной длины (до 16000 записей).
- ❑ 4 входящих и 4 исходящих очереди на каждый порт для реализации политик качества обслуживания.
- ❑ Частичная поддержка спецификации OpenFlow 1.4 (полная поддержка в будущих релизах ПО).
- ❑ 2x1Gbps порта для OOB соединения с OpenFlow контроллером.
- ❑ Высокоскоростной Control Plane процессор Xilinx Zynq-7030 (1GHz, dual-core ARM Cortex-A9 MPCore) для выполнения функции Open Flow агента.
- ❑ Производство будущей коммерческой версии полностью на Российской элементной базе.
- ❑ Rack-mount 19' ; Rack height – 1 rack unit; AC input voltage – 220V.

Архитектура устройства

Реализация:

Характеристики платформы NP-4 (EZchip)

- ❖ Модуль управления :
 - ✓ 2x10Гб/с (SFP+)
 - ✓ 2x10/100/1000 Мб/с (SFP)
 - ✓ 1 RS-232 console
- ❖ Сетевые интерфейсные модули (4 шт) :
 - ✓ 2x10Гб/с (SFP+)
 - или
 - ✓ 8x1Гб/с (SFP)
- ❖ Высота 1.5U
- ❖ Монтаж в стойку 19"

- Сетевой процессор производительностью 100 Гб/с, 180 миллионов пакетов в секунду
- Иерархическая система очередизации пакетов. Поддержка WFQ с приоритетной очередью.
- Поддержка WRED, Shaping (CIR, PIR), Per flow metering, marking, policing для миллионов потоков.
- L2-4 switching/routing. Поиск по шаблону вплоть до 80 байт.

Характеристики платформы NP-5 (EZchip)

- ❖ Модуль управления:
 - ✓ 4x10/1Гб/с
 - ✓ 1x1Гб/с
 - ✓ 1 RS-232 console
- ❖ Сетевые интерфейсы:
 - ✓ 44x10Гб/с
или
 - ✓ 11x40Гб/с QSFP+
или
 - ✓ 4x100Гб/с
- ❖ Высота 1.5U
- ❖ Монтаж в стойку 19"

- Сетевой процессор производительностью до 240 Гб/с, 500 миллионов пакетов в секунду
- 5-уровневая иерархическая система очередизации. Поддержка WFQ с приоритетной очередью.
- Поддержка WRED, Shaping (CIR, PIR), Per flow metering, marking, policing для миллионов потоков.
- L2-4 switching/routing. Сбор статистики по потокам, программируемые пороги. 512М счетчиков.

Характеристики платформы NP-5 (EZchip)

NP-5 Sub-system

- ❖ NP-5 – 500MHz (EZchip)
- ❖ Task Optimized Processors (processing/lookup)
- ❖ Unified memory 12GB DDR3 800MHz (Micron)
 - Frame size from 16B to 16KB
 - Up to 16GB frame memory (for 24GB DRAM)
- ❖ Internal TCAM – 2.5Mbit
 - 365M lookups per second
- ❖ External TCAM - 40Mbit, 300MHz (Broadcom)
 - 20B/40B/60B/80B key lookups
- ❖ Integrated Search Engine (table, hash, tree, TCAM)
 - 48 bytes keys for hash
 - 18 bytes keys for trees
 - 80 bytes keys for TCAM
 - Up to 16GB lookup tables headroom

Аппаратные особенности Host CPU NP-4 (NP-5)

Карта расширения, выполняющая функции блока управления

Решаемые задачи:

- взаимодействие с контроллером
- интерфейс администратора
- изменение настроек коммутатора
- мониторинг и управление

Характеристики:

OS: Linux 2.6 GCC ver. 4.2.1;
CPU: Freescale MPC8543 (792 МГц)
Mem: DDR2 667MHz 512 МБ;
HDD: SDD 256 МБ;
EEPROM: 2 КБ.

Интерфейсы:

- мост PCI (66 МГц) – PCI-express;
- Ethernet порт – 10/100/1000 Мб/с.
- RS-232 (для управления)

Тракт обработки данных

Несколько последовательно опрашиваемых таблиц, реализованных с помощью TCAM

Возможность маскирования всех нужных полей

Возможность реализации любой политики приложений клиентов

TCAM - дорогостоящий ресурс.

TCAM имеет высокое энергопотребление.

Несколько разнородных таблиц оптимизированных под выполнение конкретной задачи в сети клиента.

Возможность реализовывать таблицы с миллионами записей

Сложность в адаптации приложений под текущую структуру и архитектуру взаимодействия таблиц

Сложности с потоками требующими проверку маскированных полей

Проект Atrium

Проект Atrium

Проект Atrium

centec
networks

Accton
Making Partnership Work

NoviFlow
switching made smarter

Проблема взаимозаменяемости

Different combinations of Match-Action Tables form Different OF 1.3 pipelines

How can a controller manage these differences?

How can an application work across these differences?

Предлагаемое решение – скрыть от приложений детали реализации

Пример реализации фильтрации.

- Filter → only Permit or Deny options
- On match fields of packet header

Последовательный тракт обработки данных

Тип таблицы	Размерность ключа поиска	Размерность таблицы
Внутренний TCAM	от 160 до 640 бит	2.5 Mbit
Внешний TCAM	от 80 до 640 бит	40 Mbit
Hash	от 8 до 384 бит	до 16 Млн записей
Tree	от 8 до 144 бит	до 4 Млн записей
FastIP	от 8 до 144 бит	до 8 Млн записей

Параллельный тракт обработки данных

Групповые действия

Group ID	Type	Action Bucket(s)
10	All	bucket = 1, actions = OutPort:1 bucket = 2, actions = OutPort:2 bucket = 3, actions = OutPort:3 bucket = 4, actions = OutPort:4
20	Select	bucket = 1, actions = OutPort:1 bucket = 2, actions = OutPort:2
30	Fast Failover	bucket = watch_port:1, actions = OutPort:1 bucket = watch_port:2, actions = OutPort:2
40	Indirect	bucket = 1, actions = OutPort:1

Примеры

При использовании параллельного тракта обработки получаем:

- минимизацию задержки на обработку пакета для задач L2 коммутации
- минимизацию задержки на обработку пакета для задач сетевой трансляции (NAT)
- более эффективное использование ресурсов платформы ввиду большего количества TOPsearch (1024) по сравнению с TOPresolve (96) и TOPmodify(64)
- Возможность снизить требование к количеству записей в TCAM путем организации достаточного количества таблиц разных типов, покрывающих потребности наиболее часто используемых в сети приложений

При использовании последовательного тракта обработки получаем:

- Более эффективный поиск при использовании маскируемых полей, а также за счет просмотра единственной таблицы
- Более эффективное использование ресурсов при решении задач требующих анализа большого количества полей, так как при этом результат достигается за счет просмотра только 1 таблицы
- Более очевидный и понятный алгоритм обработки потоков с помощью последовательности OF таблиц.
- Возможность реализации Apply Action и использование результатов обработки пакета предыдущей таблицей.

Тесты

OFTEST v1.3

- **Basic**
 - echo
 - feature request
 - default drop
 - output exact
 - packet in
 - packet out
- **Matching fields**
 - ipv4
 - arp
 - ethernet
 - vlan
 - mpls
 - in port
- **Group**
 - groups op.
 - buckets (indirect/select/all)
- **Action sets**
 - change fields
 - pop or push Vlan / MPLS
 - instruction set
- **Role request**
 - Permissions for slave / equal / master controllers

Нагрузочное тестирование

- Подтверждается 10G производительность на пакетах от 64 до 1500 байт, в том числе при поиске по нескольким таблицам, в том числе при изменении IP/TCP/UDP (свыше 10 Mpps)
- До 530 Flowmod в секунду для TCAM таблицы (зависит от последовательности приоритетов добавляемых записей)
- Порядка 4000 Flowmod в секунду для Hash таблиц (независимо от количества записей в таблице)
- Порядка 1000 PACKET_IN в секунду.
- Порядка 2500 PACKET_OUT в секунду.

NPS Smart NFV TOR/Appliance

Management:

2 x RJ45, 1 x USB

22 x QSFP+ Ports

- ❖ Высота 1U
- ❖ Монтаж в стойку 19"
- ❖ Сетевые интерфейсы:
 - ✓ 88 x 10GBASE-SR/LR/CR с помощью кабеля
 - ✓ 22 x 40GBASE-SR4/LR4/CR4 QSFP+
 - ✓ 8 x 100GBASE-SR10/LR10 с помощью кабеля
- ❖ Модуль управления:
 - ✓ 1 x 10/100/1000 Mbps
 - ✓ 1 RS-232 console RJ-45
- ❖ Индикаторы:
 - ✓ Системные: Блок питания - 1, Блок питания - 2, Охлаждение, Статус
 - ✓ Сетевые: Наличие линка, активность линка

NPS Smart NFV Appliance

- ❖ Блок питания:
 - ✓ Вольтаж AC: 100-240V AC, 50-60Hz
 - ✓ Вольтаж DC: 40-72V DC
 - ✓ 1+1 (резервирование)
- ❖ Блок вентиляторов
 - ✓ 4+1 (резервирование)
- ❖ Вентиляция
 - ✓ Спереди назад
 - ✓ Сзади вперед
- ❖ Горячая замена
 - ✓ Блоков питания
 - ✓ Блоков вентиляции

Блок управления устройством:

- ❖ COM (Computer On Module)
 - ✓ Процессор Intel Core i7 4700EQ
 - ✓ Память 8GB DDR3L
 - ✓ Диск 32GB SSD
- ❖ Высокоскоростное взаимодействие между NPS и блоком управления:
 - ✓ 64 Gbps PCIe
- ❖ Конфигурирование с передней панели:
 - ✓ RS232 serial console RJ-45 порт
 - ✓ Ethernet 10/100/1000 Mbps RJ-45 порт
 - ✓ USB Type 3

Ключевые характеристики NPS-400

- ❖ Сетевой процессор обрабатывающий до 400 Gbps.
- ❖ Обработка пакетов на скорости до 600 Mpps
- ❖ Обработка транзитного трафика до 7 уровня включительно.
- ❖ Возможность перепрограммирования поведения процессора, что обеспечит быстрое внедрение новых технологий и сохранения вложенных средств за счет использования имеющегося оборудования.
- ❖ Обеспечение политик качества обслуживания.
- ❖ Пятиуровневая иерархическая система обработки очередей, обеспечивающая до 1 миллиона очередей для детальной идентификации пользователей и их приложений.
- ❖ Поддержка IPsec и DPI на скорости до 200 Gbps (server offload)
- ❖ Интегрированный TCAM с расширением за счет DRAM для хранения записей.
- ❖ Высокоскоростной алгоритм поиска по большому количеству записей в таблицах (Flow Table, ACL)
- ❖ Поддержка до 24GB DDR4
- ❖ До 512 миллионов разнообразных счетчиков.
- ❖ До 6.4 миллиардов операций в секунду по сбору статистики.

Возможные области применения NPS-400

- ❖ Коммутатор поддерживающий OpenFlow v1.4.
- ❖ Построение наложенных сетей с использованием QinQ, VxLAN, NVGRE.
- ❖ IEEE Edge Virtual Bridging, VN-TAG и Virtual Ethernet Port Aggregator (VEPA).
- ❖ Классификация и маршрутизация по потокам.
- ❖ Высокоскоростное выполнение фильтрации (ACL offload).
- ❖ Балансировка HTTP трафика в зависимости от контента.
- ❖ Высокоскоростная терминация IPsec (IPsec gateway).
- ❖ Терминация SSL (SSL gateway).
- ❖ DPI на скорости до 800Gbps с распознаванием более 1500 сигнатур. Создание собственных сигнатур с использованием множества технологий.
- ❖ Lawful Intercept – идентификация и перехват интересующих потоков трафика, сбор передаваемой информации и запись ее в файл.
- ❖ Open vSwitch data path acceleration.

Благодарю
за
Внимание!