

Nový networking pro nové IT

Tomáš Kubica, Enterprise Architect + Daniel Prchal

tomas.kubica@hpe.com

Twitter: @tkubica

cloudsvet.cz

netsvet.cz

Úspěšné budou firmy, které využijí třetí platformu: Social, Mobile, Big Data, Cloud



Lean Enterprise, Inspirace výrobou

**Waste
Value stream
Unplanned work**

**Agile
Fluid
DevOps**



Infrastructure as code

PaaS

CI/CD

Kontejner

Dev Ops

Tato zed' musí pryč !

Inovace (ne šetření) jsou klíčem k úspěchu

Zajistěte vašim aplikacím přenositelnost



DevOps



Jen kontejner nestáčí

Dev

Buildpack
A/B testing
Services
Late binding



Ops

Balancing
Autoscaling
HA
Rollback
Green/Blue
DBaaS
MSGaaS



A long, straight asphalt road stretches from the foreground into the distance, leading towards a range of dark, mountainous peaks. The sky above is filled with heavy, white and grey clouds. Overlaid on the road are several large, white, semi-transparent text labels representing different cloud computing components:

- Storage*
- vSphere*
- HyperV*
- KVM*
- Compute*
- Networking*

Zvolte vás přístup ke zrychlení IT



Změňte IT

Bimodal IT
(dvourychlostní)

Innovation
labs

Kam jedou sítě?

Nové sítě pro nové IT

**Nemluvme jen o SDN....
... Mluvme o nové síťařině**



Nemluvme jen o SDN.... ... Mluvme o nové síťarině

Software-defined Networking

Network Virtualization

Network Function Virtualization

Disagregace

Open source

DevOps

Mluvme možná o něčem nepříjemném

- Zapomeňte na SNMP a CLI
- Nesmíte se přihlásit do prvku přes SSH a udělat změnu
- Víc funkcí a protokolů? Naopak – většinu pryč
- Učte se CI/CD nástroje, zejména Ansible, Git, RESTful API, YAML
- Vaše infrastruktura = definice desired state, ne skript
- Vaše politika = intent-based networking, ne VLAN a ACL
- Vaše dokumentace = „kód“ nebo manifest
- Programovat OpenFlow by měli umět 3 lidi na planetě

Nemluvme jen o SDN.... ... Mluvme o nové síťarině

Software-defined Networking

Network Virtualization

Network Function Virtualization

Disagregace

Open source

DevOps

Proč SDN?



Je heparin lék nebo jed?

Záleží na kontextu !

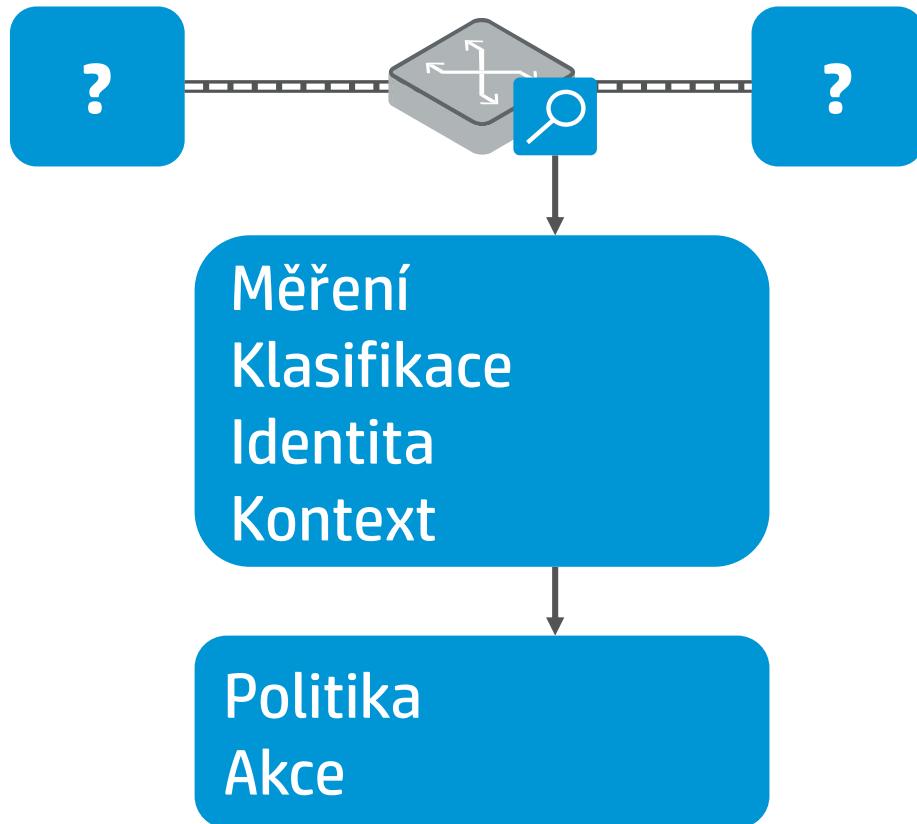


**Chceme
optimalizovat aplikace
díky
skládačkové
infrastruktuře
se znalostí kontextu**

**Tradičně jsme odkázáni
jen na to, co vidíme
procházet sítí...**



Odhadovat – Application ‘Aware’ Network



Drahá infrastruktura s důrazem na hardware

Opožděná integrace nových aplikací

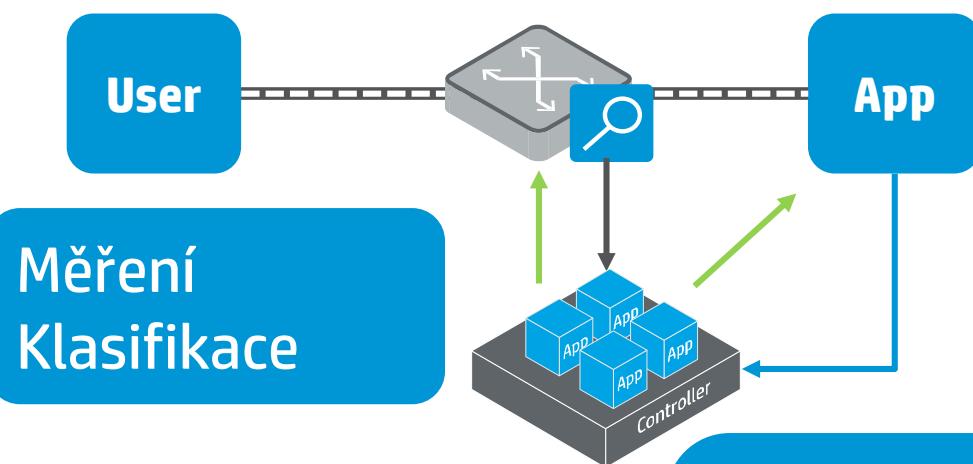
Je obtížné získat data z omezených a šifrovaných zdrojů

Vědět – Context-Driven Network

Otevřená programovatelná architektura

Otevřenosť umožňuje samostatnou až živelnou integraci

Vhled do aplikací, událostí, kontextu i telemetrie



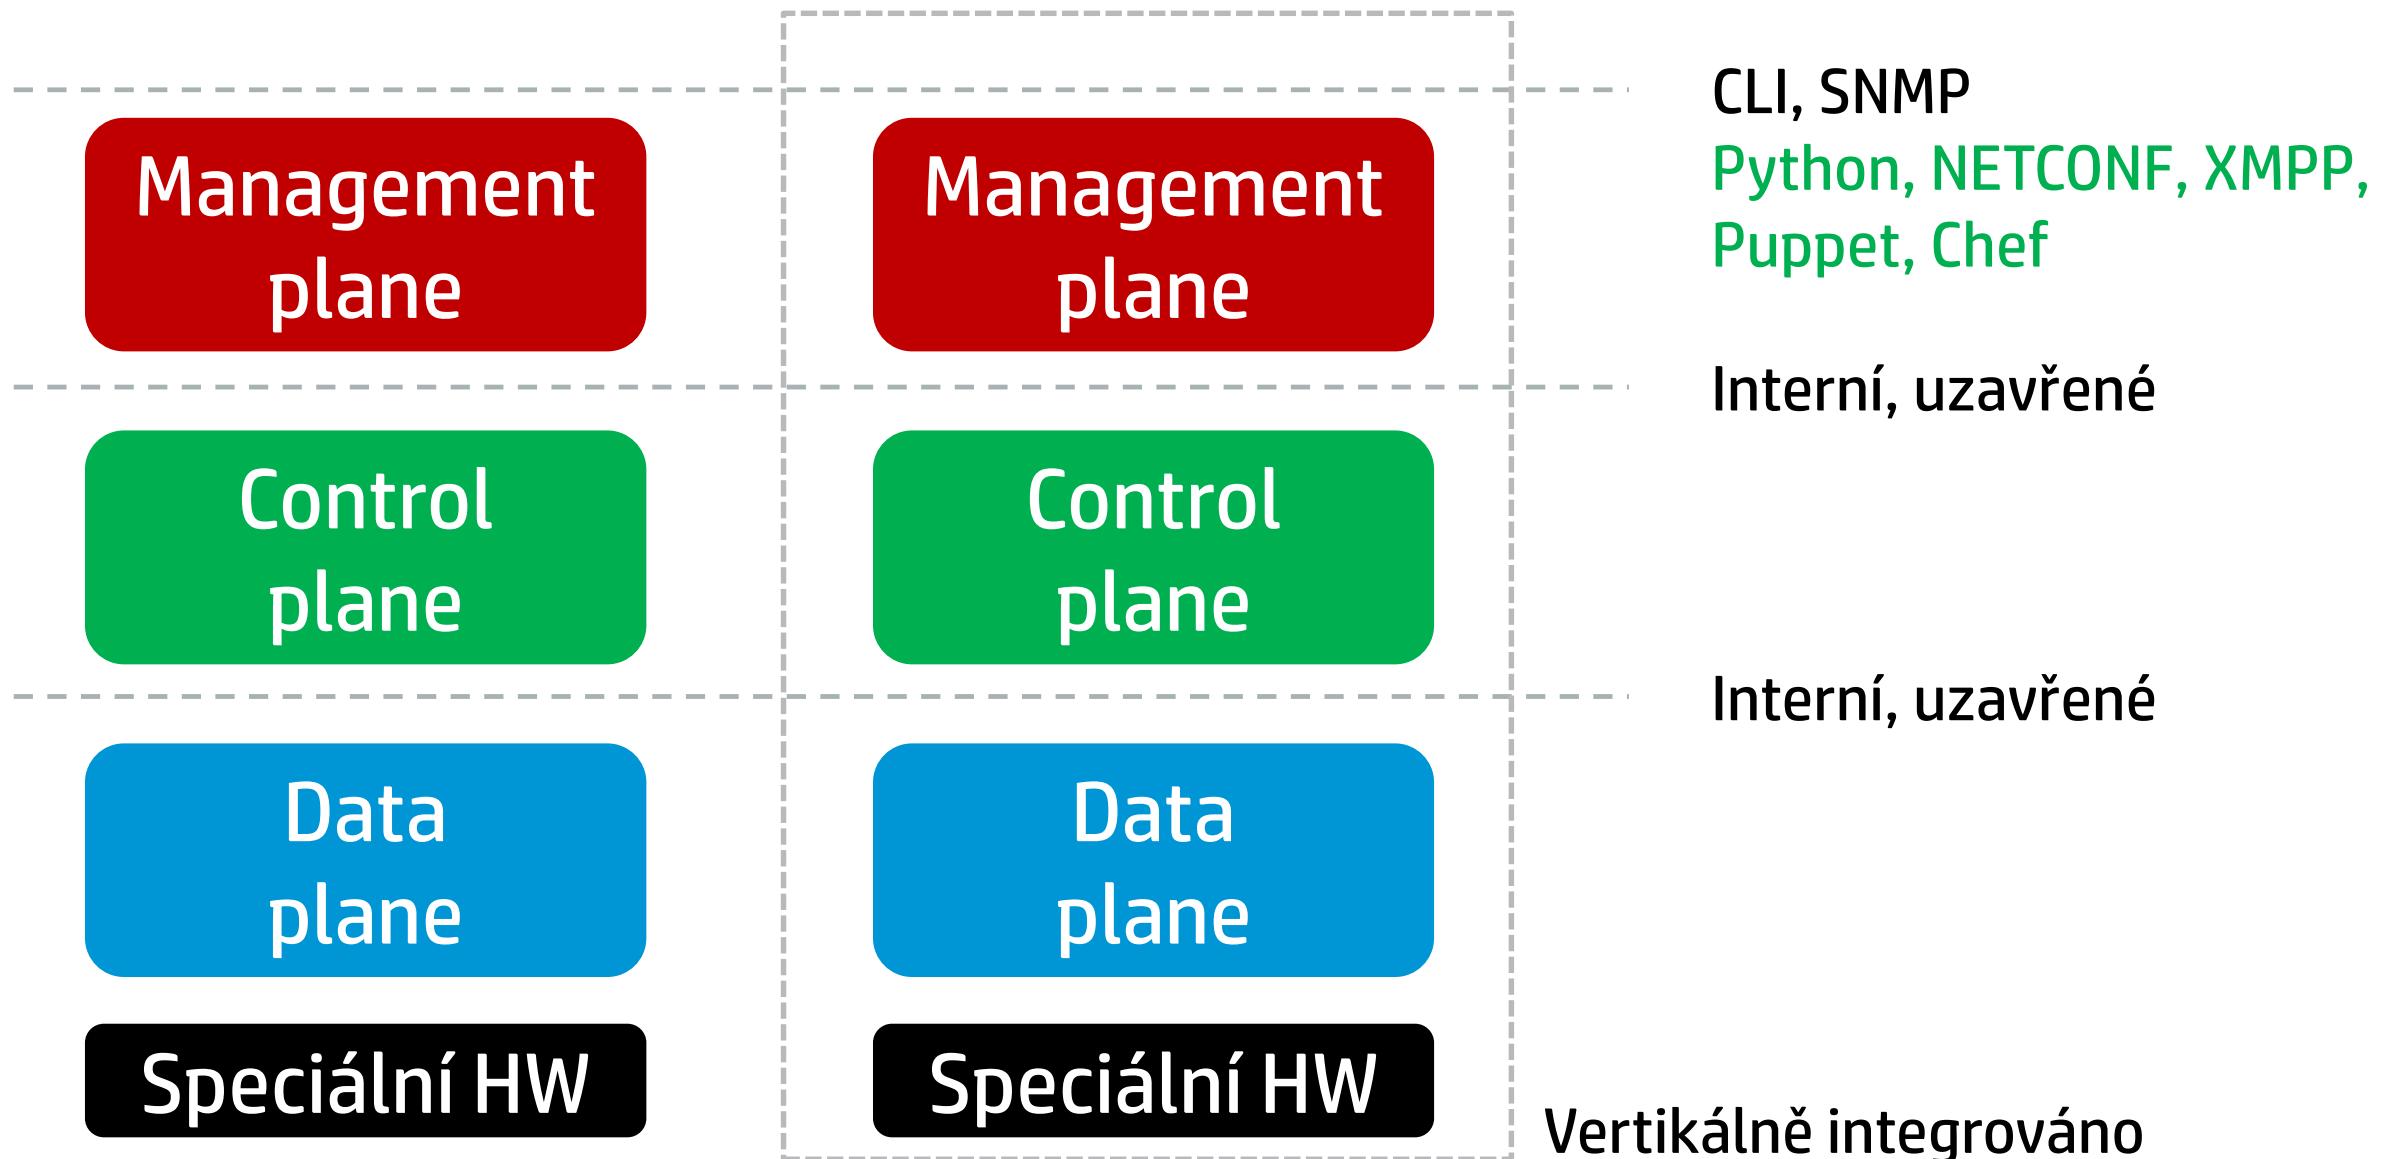
Politika
Koordinovaná akce



SDN

NABÍZÍ ZPŮSOB
JAK ZÍSKAT KONTEXT
A APLIKOVAT POLITIKU

Tradiční síťové prvky



Software-defined Networking

Management plane / SDN aplikace

Northbound API, RESTful,
OSGi/Java, ONF, ODL, VAN

Centralizovaný Control
Plane / SDN kontroler

OpenFlow, NETCONF,
OVSDB, ...

Data
plane

Data
plane

Speciální HW

Speciální HW

Kontrolery

Jaký si mám vybrat kontroller?

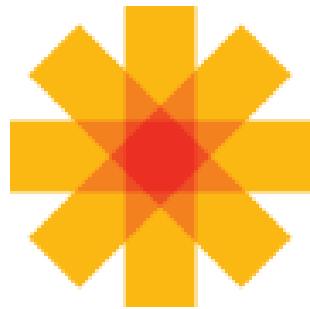


Ryu
Floodlight
POX
NOX
Beacon

Intent-driven SDN



OPEN NETWORKING
FOUNDATION

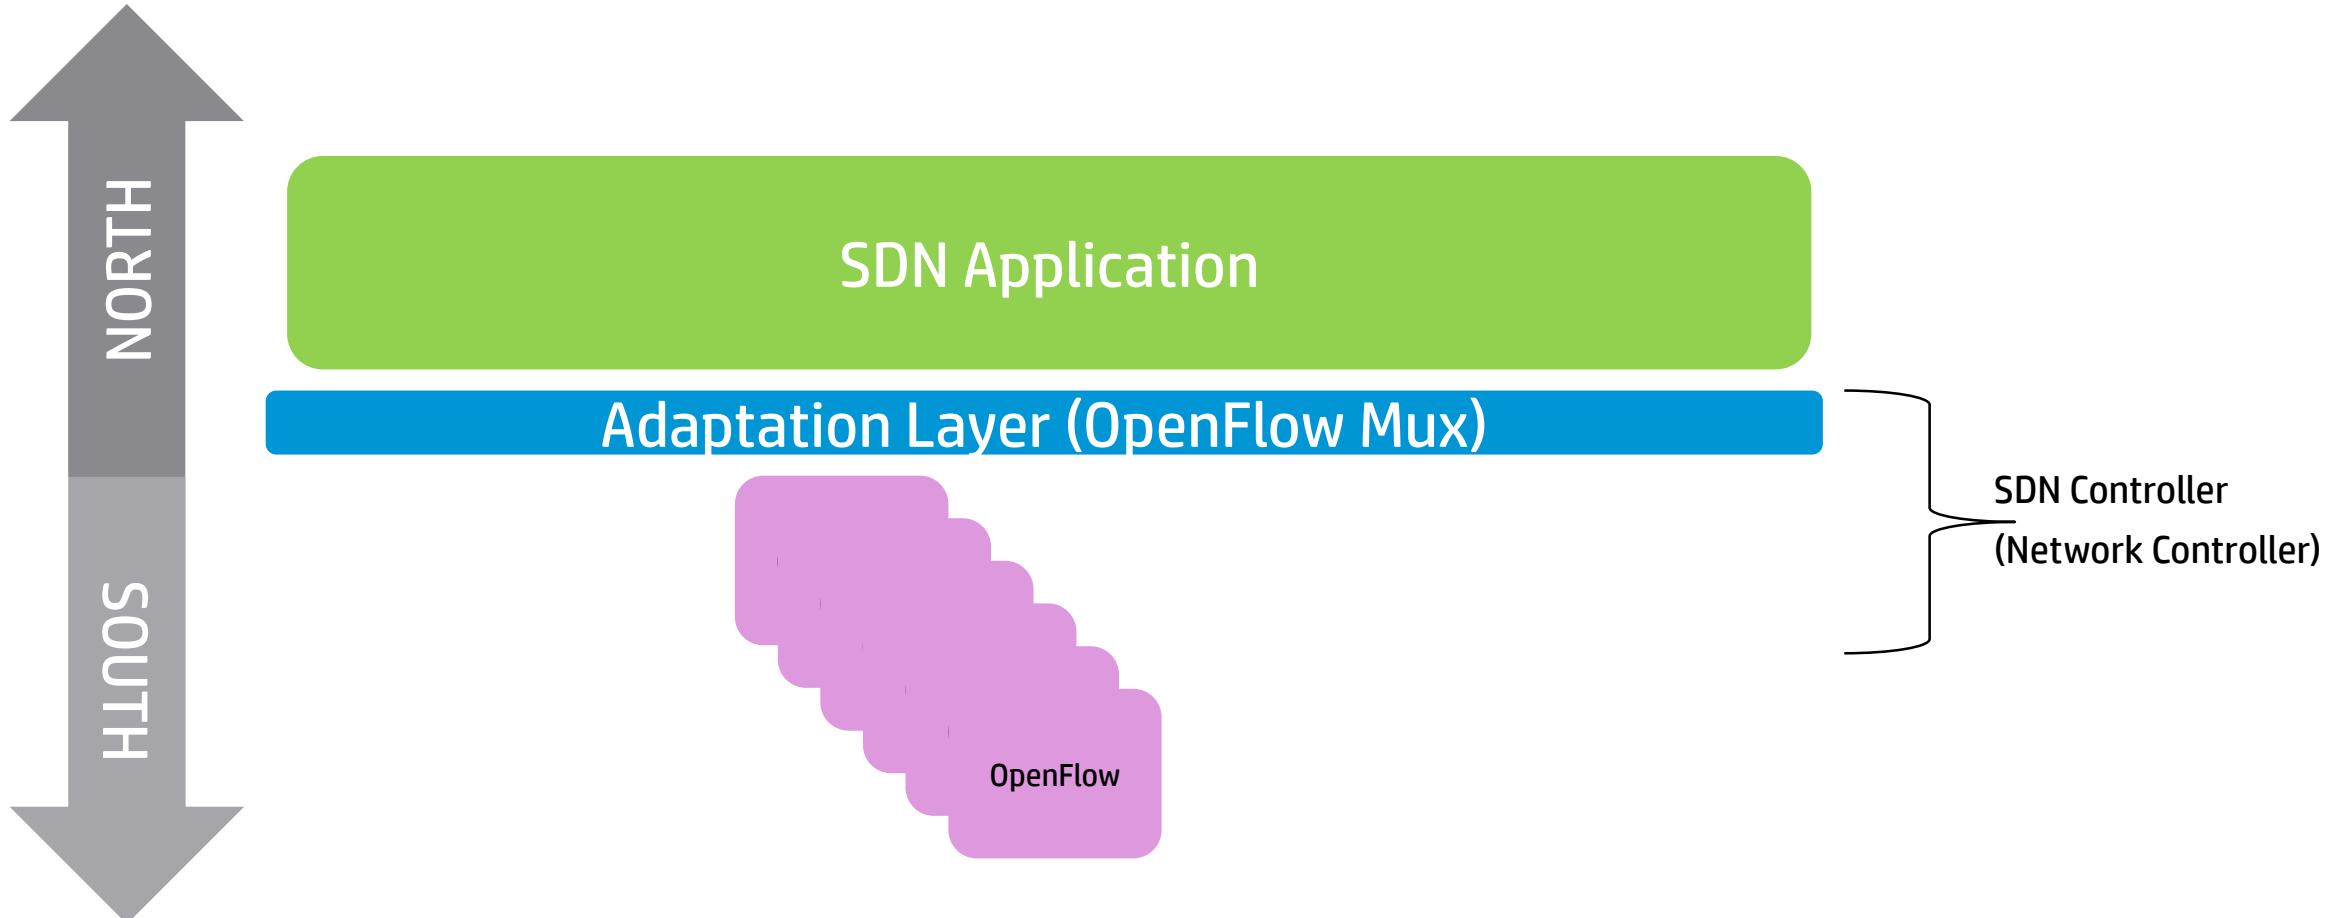


Software-defined Networking: Vyjadřujte záměry, dávejte kontext



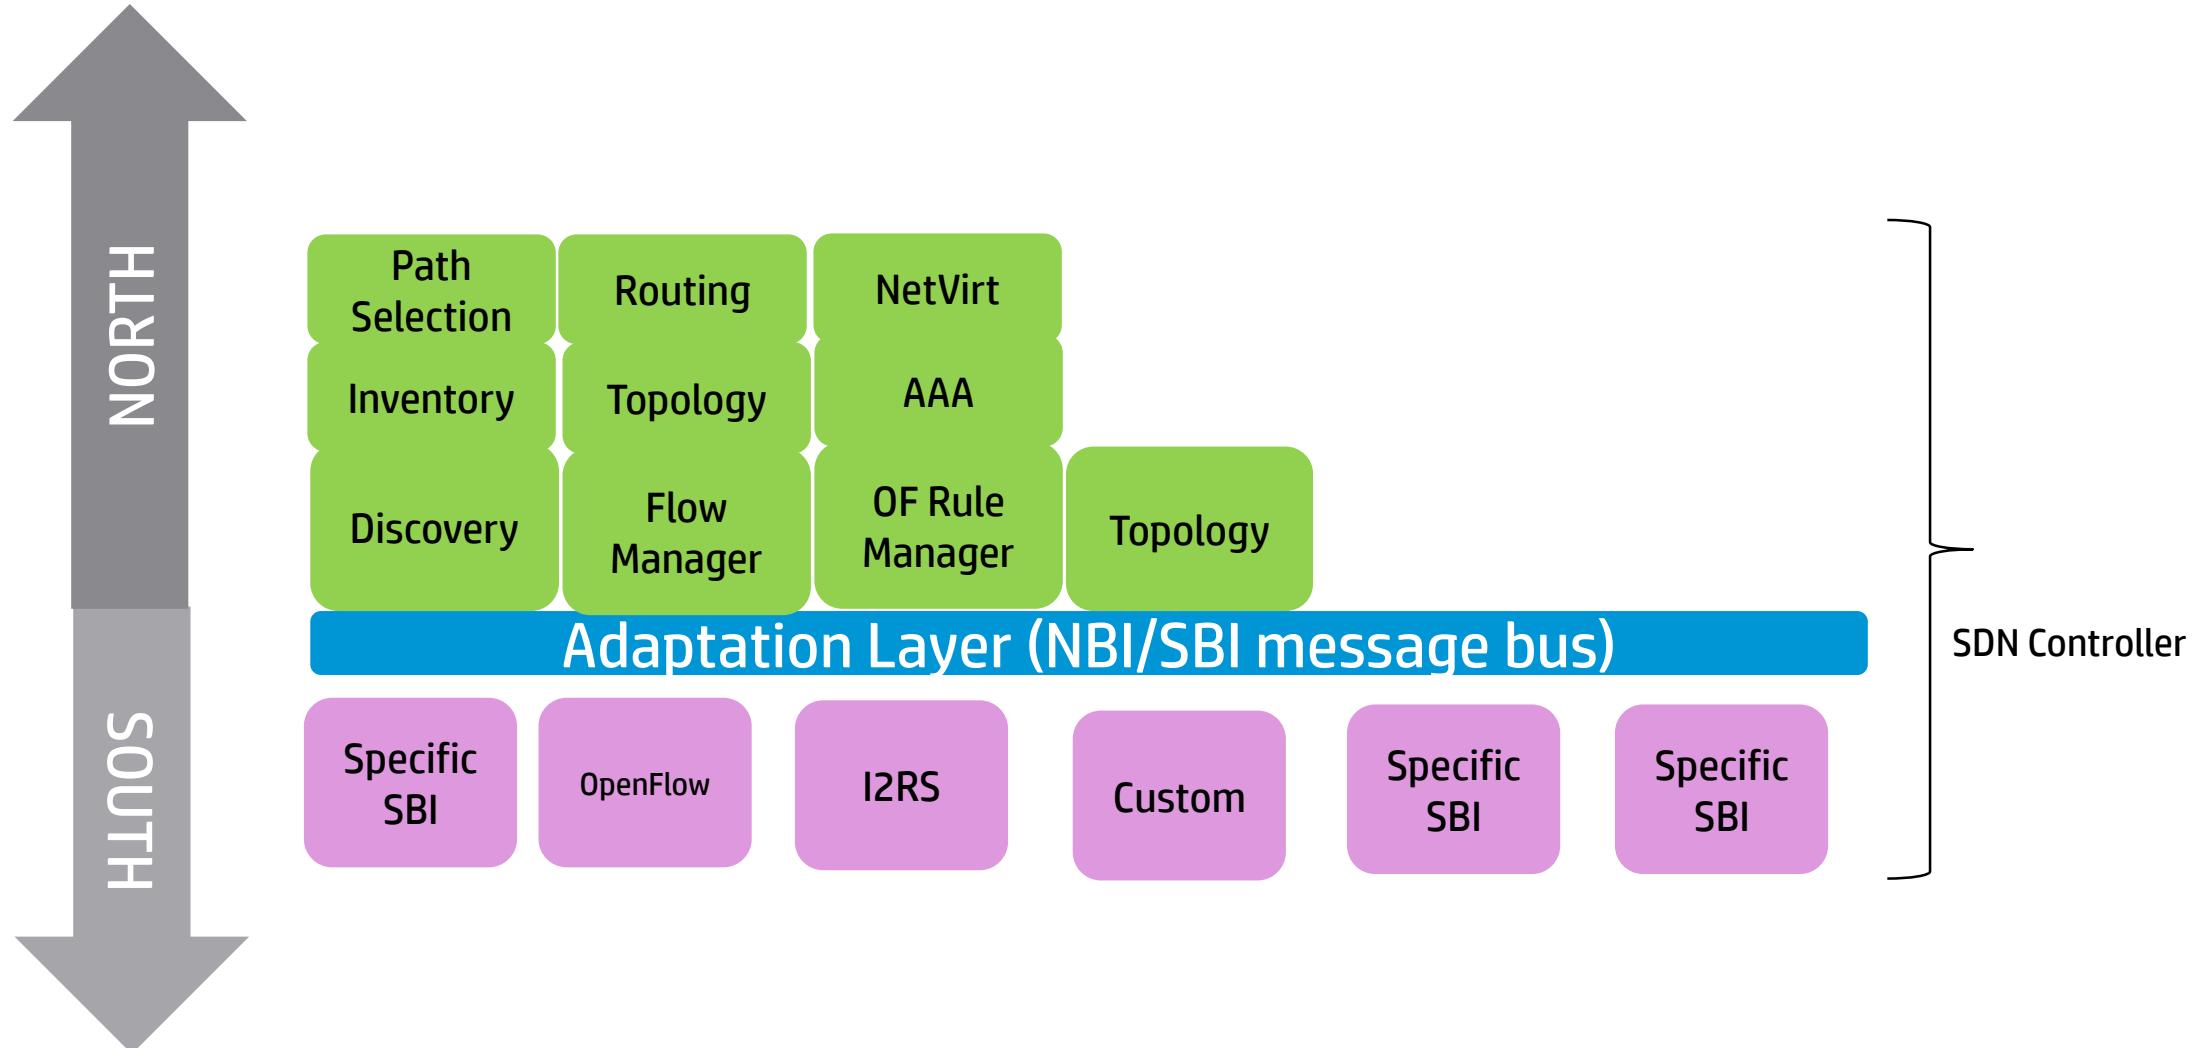
První pokus

OpenFlow == assembler, switch je flow tabulka



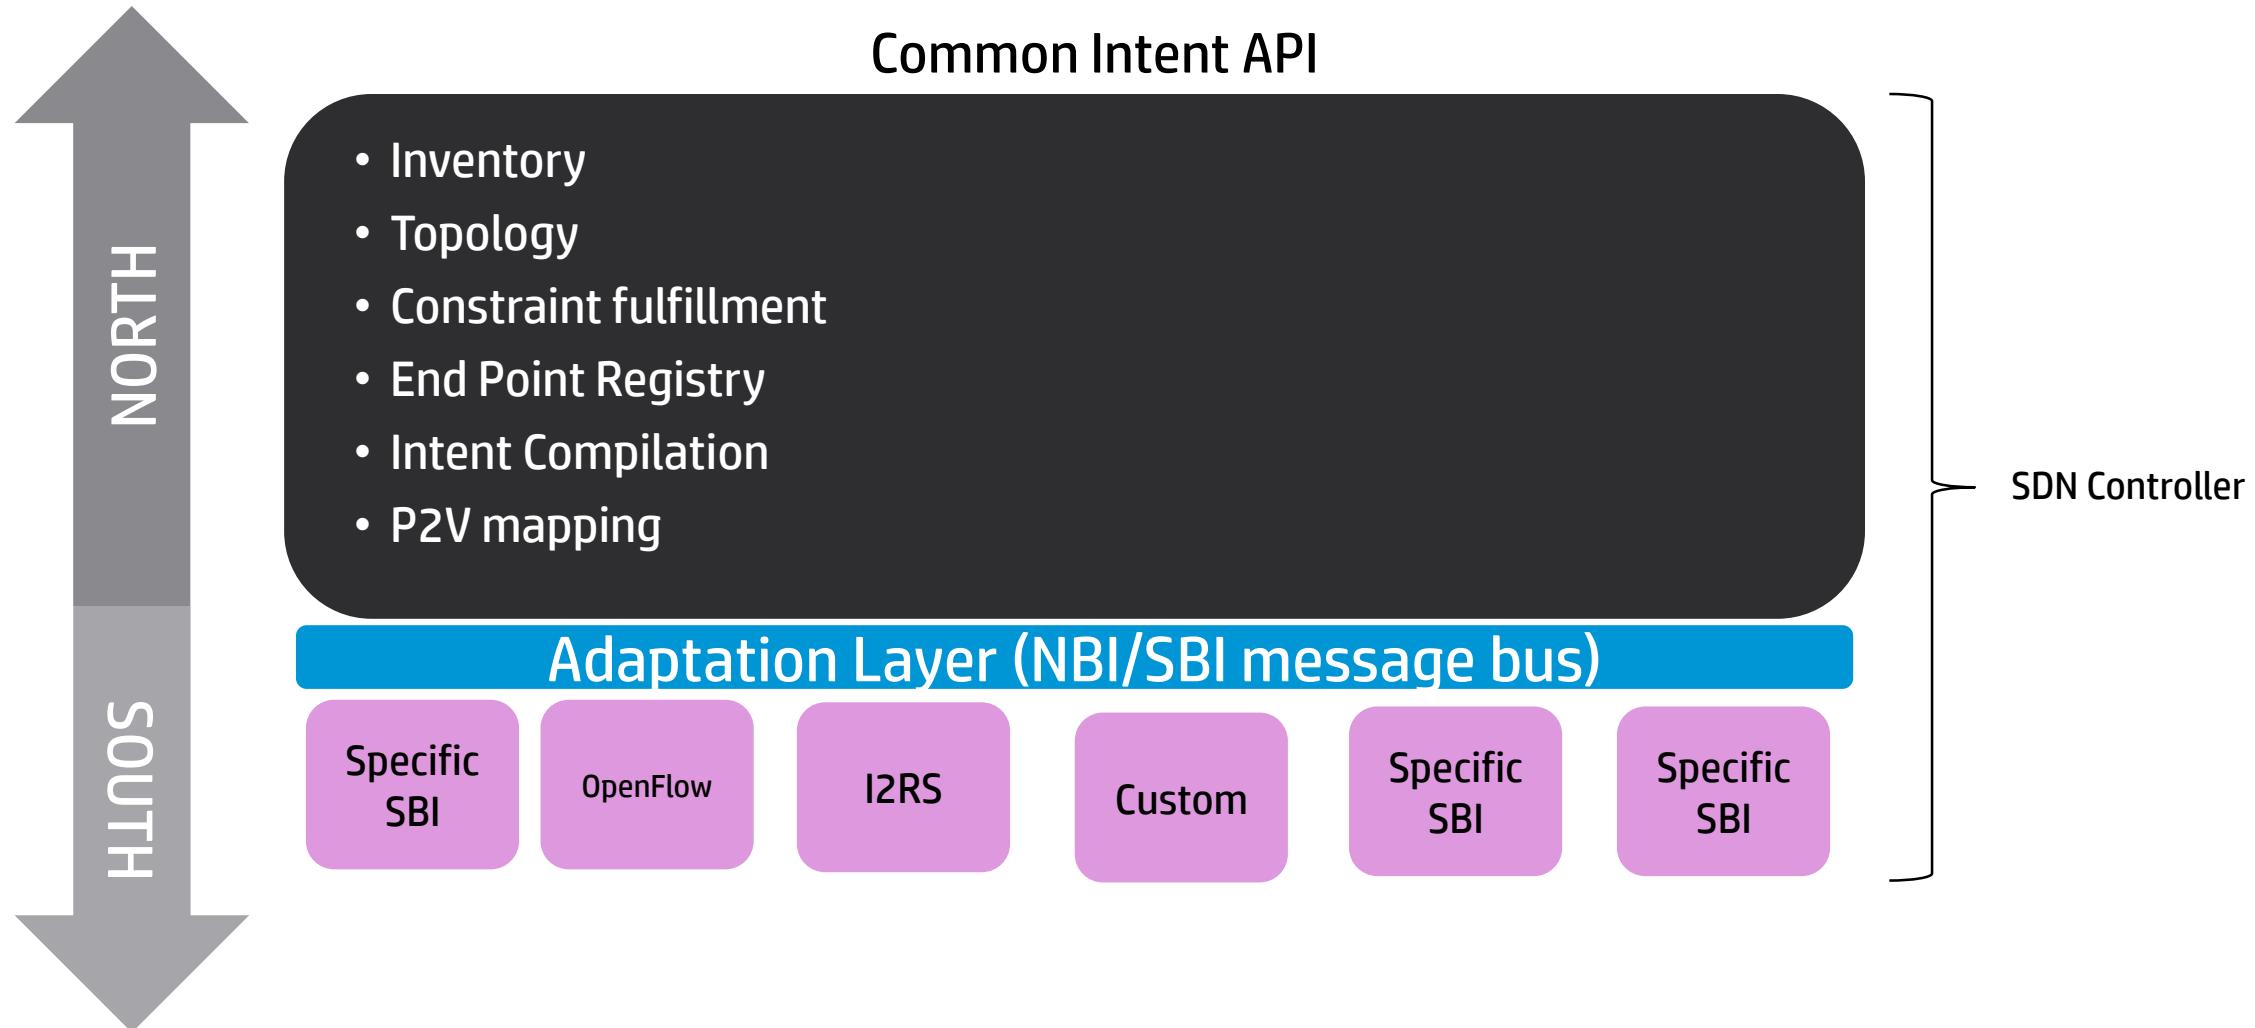
Druhý pokus - SDK

Vývojář může programovat síť, ale příliš pozdě na standardizaci



Doufejme poslední pokus – Intent API driven Black Box

Dovoluje milionům lidí ovládat síť



Intent je

- Co, ne jak
- Univerzální jazyk
- Přenositelný
- Škálovatelný
- Přináší kontext
- Menší prostor pro útok
- Příklady:
 - Martin má v zasedčce přístup na Internet
 - Jana může na HR systémy v pracovní době
 - Tomáš, pokud komunikuje se R&D aplikací, musí přistupovat šifrovanou cestou

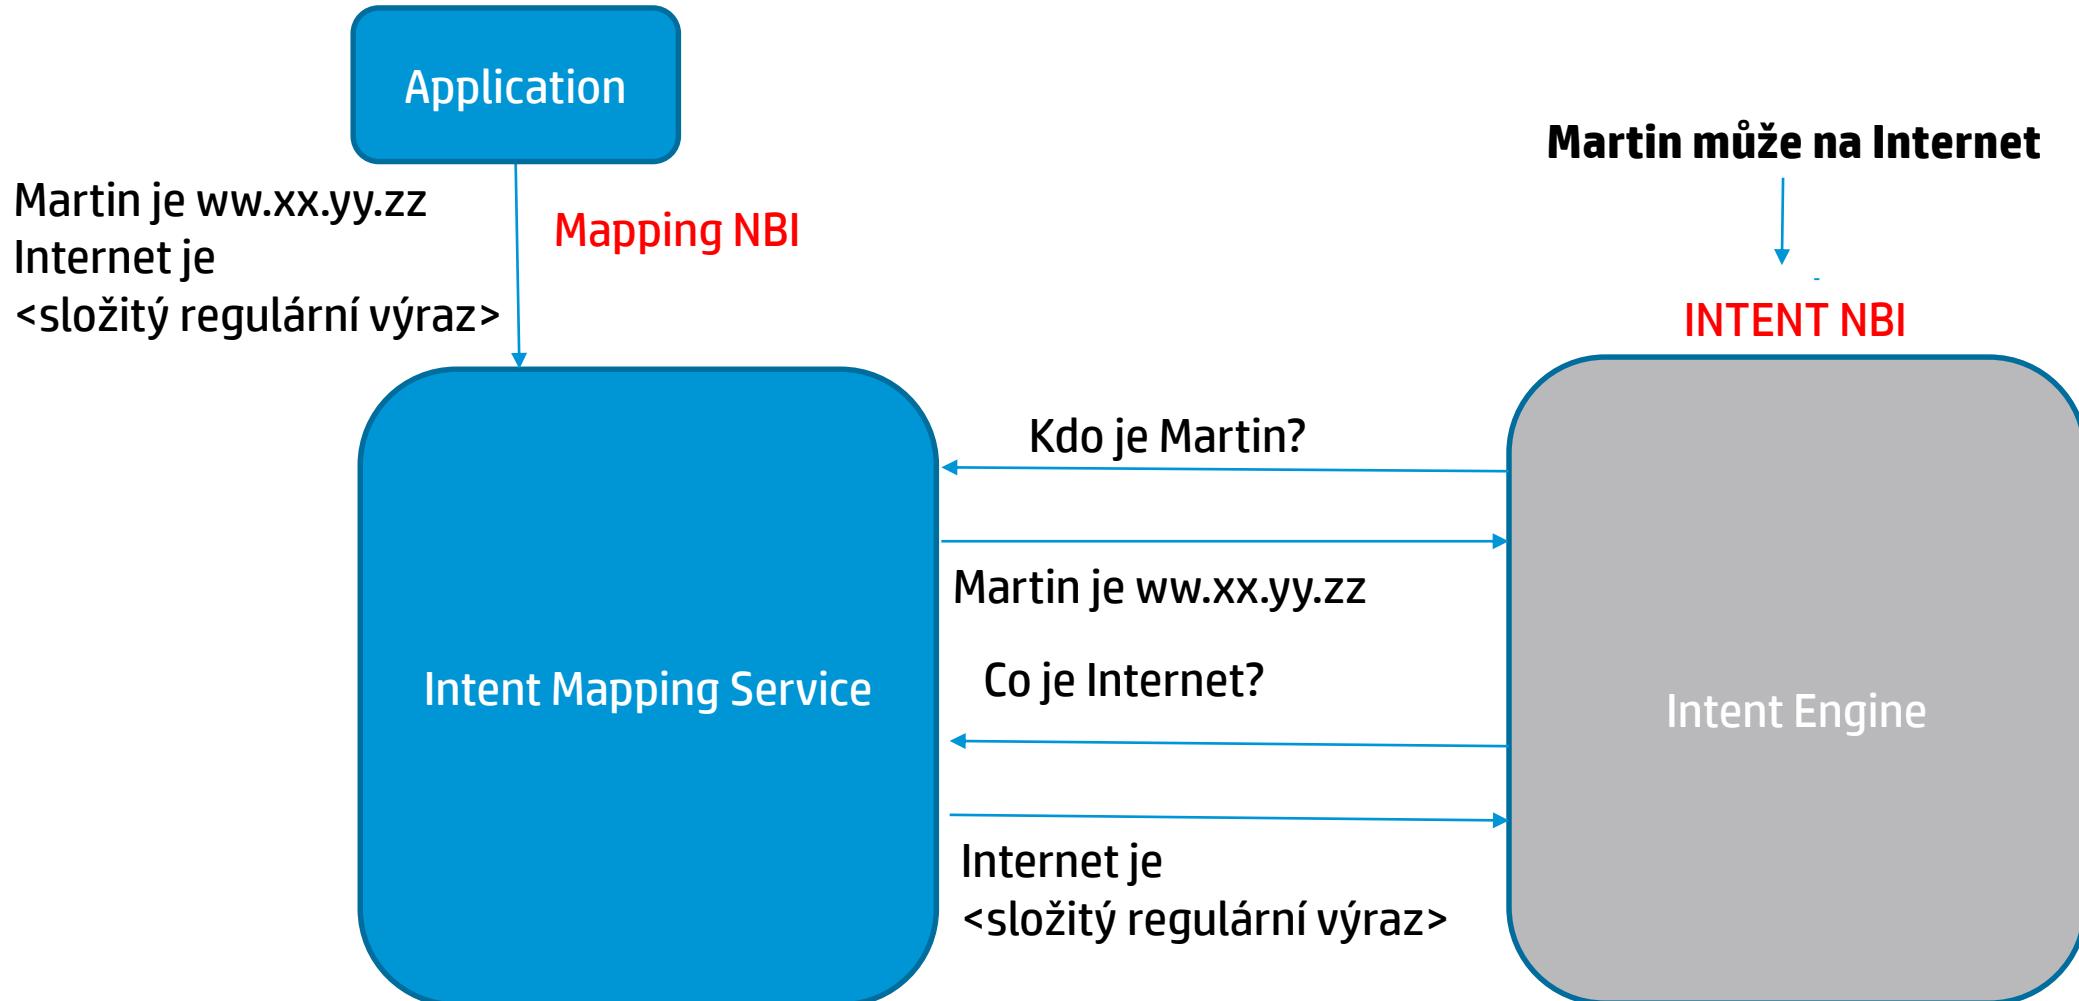
Mapování záměru (nepřenosné)

- Zařízení
- Protokoly
- Výrobci
- Rozhraní
- Adresy
- Lokace
- 5-tuples
- 12-types

Záměr (přenosný)

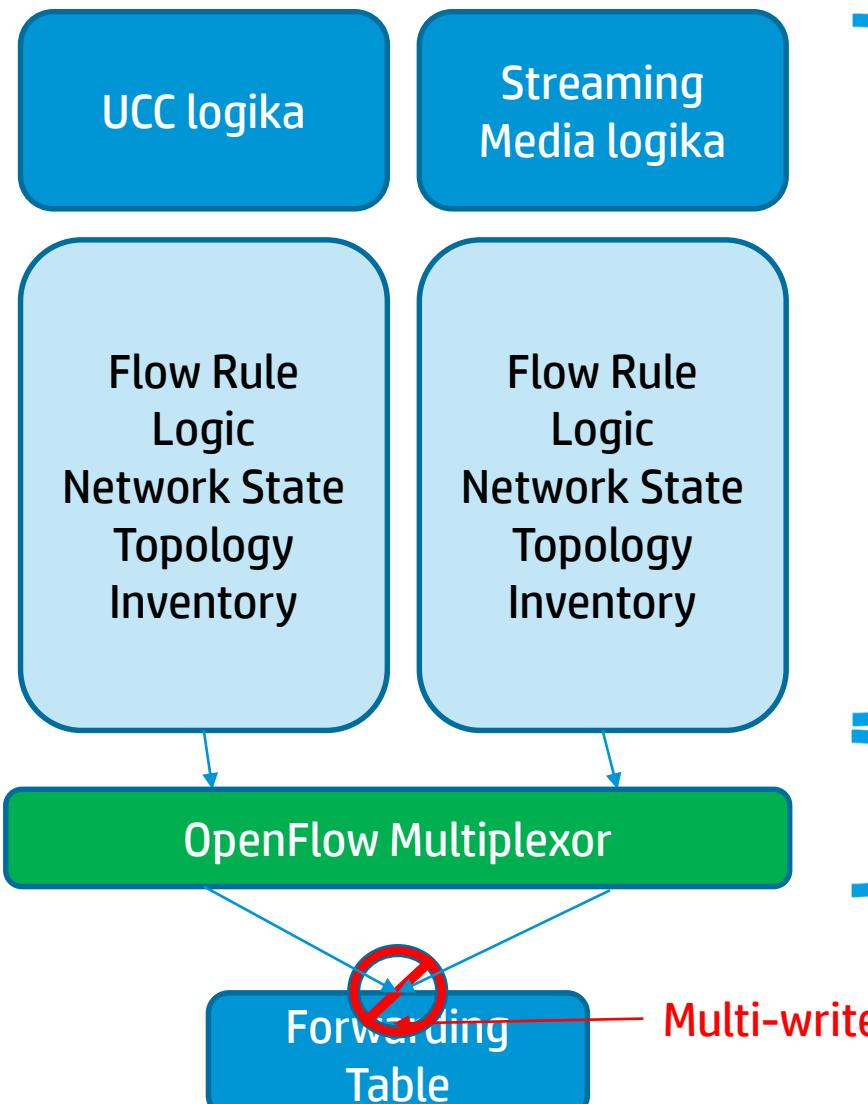
- Vztahy mezi skupinami koncových bodů
- Nálepky/objekty (např. Internet, HR, Franta)
- Záměrová slovesa (např. povol, zakaž, přesměruj)
- Omezení a vlastnosti (QoS, izolace,...)

Martin chce internet



Řešení pro Multi-Writer situaci (jinak prakticky neřešitelné)

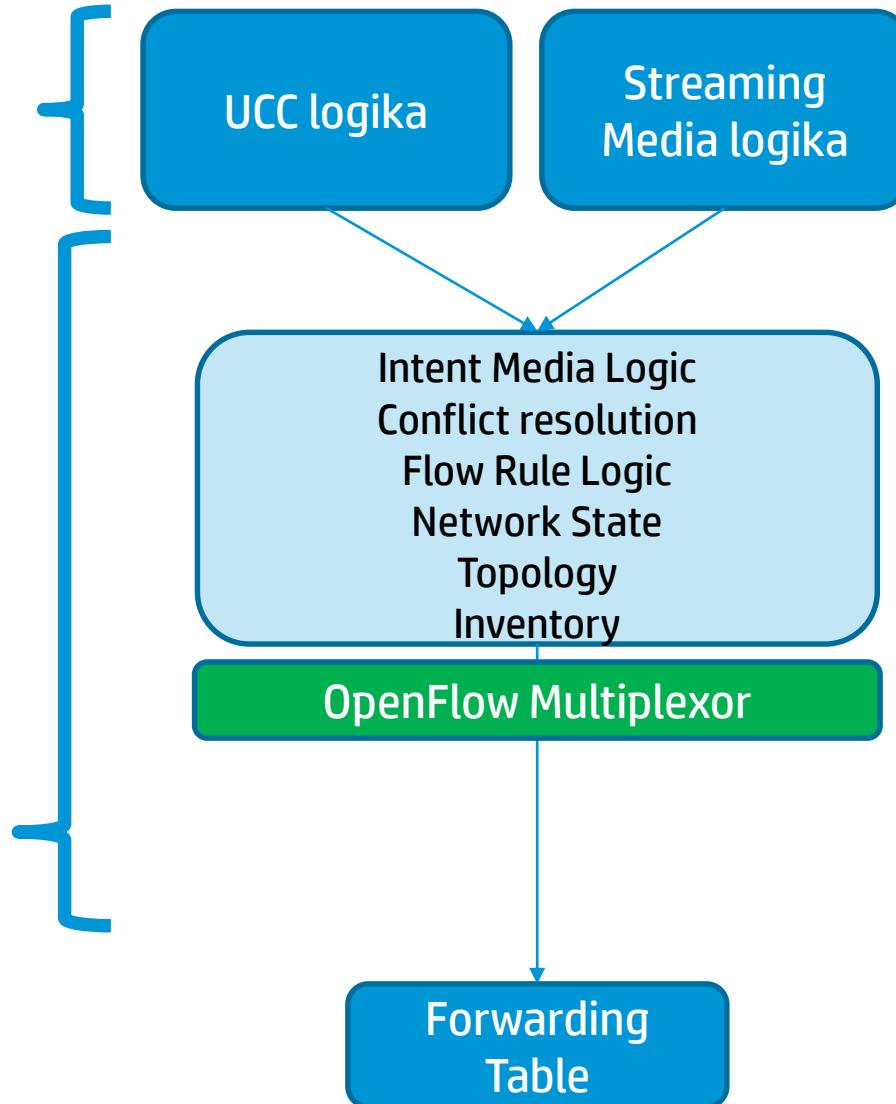
SDN aplikace sahá na OpenFlow



Aplikace

SDN kontroler

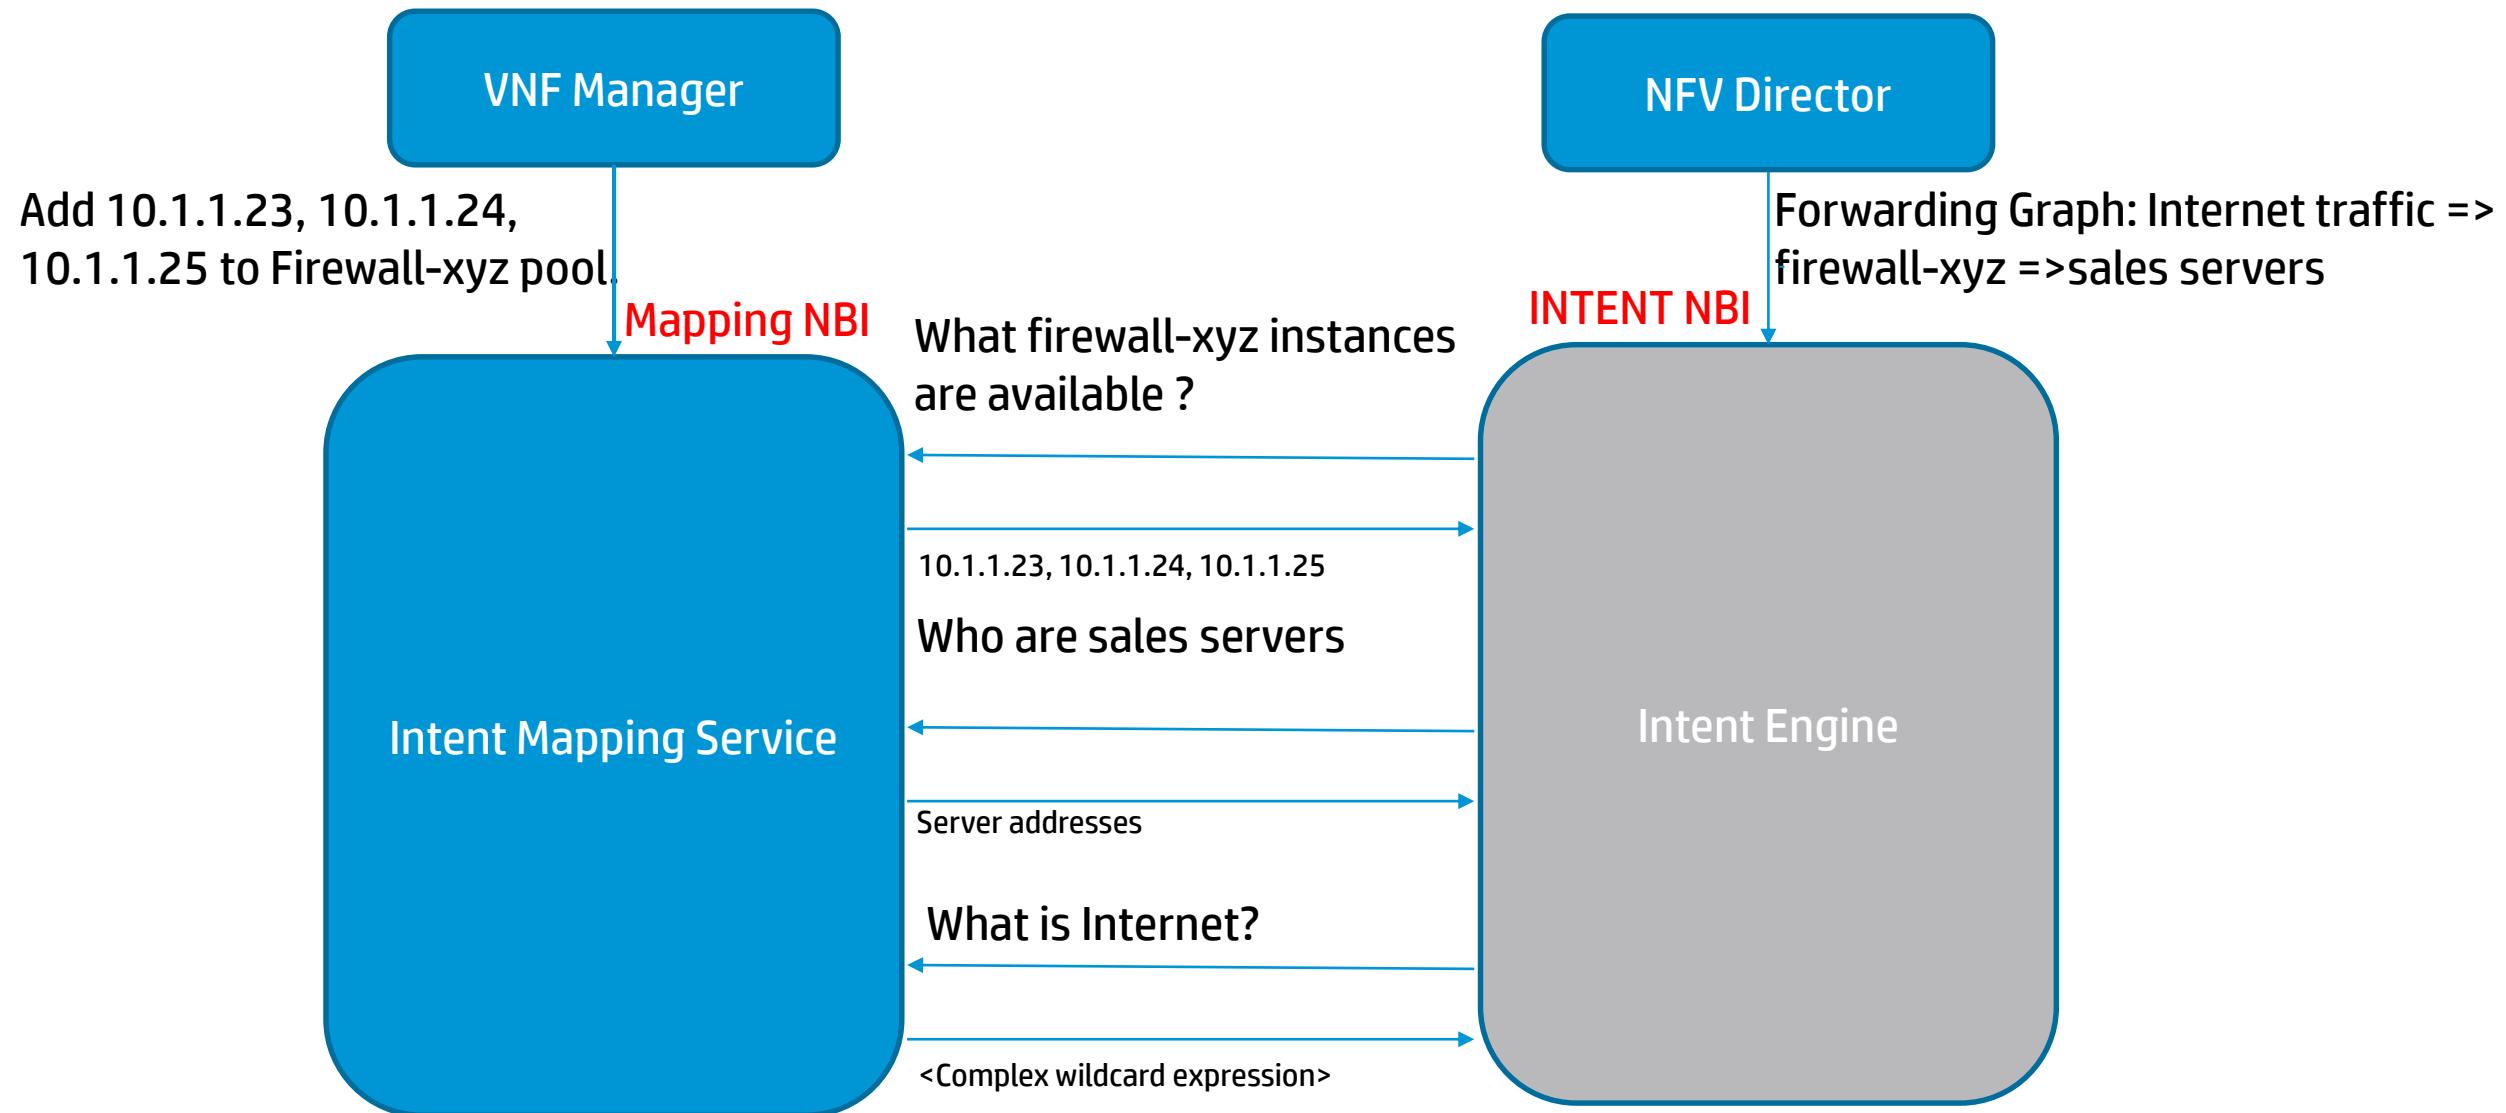
SDN aplikace definuje záměry



Multi-writer konflikt

Pozn.: Ano, použití více tabulek se zkoušelo, ale nedopadlo lépe...a v hardware není možné.

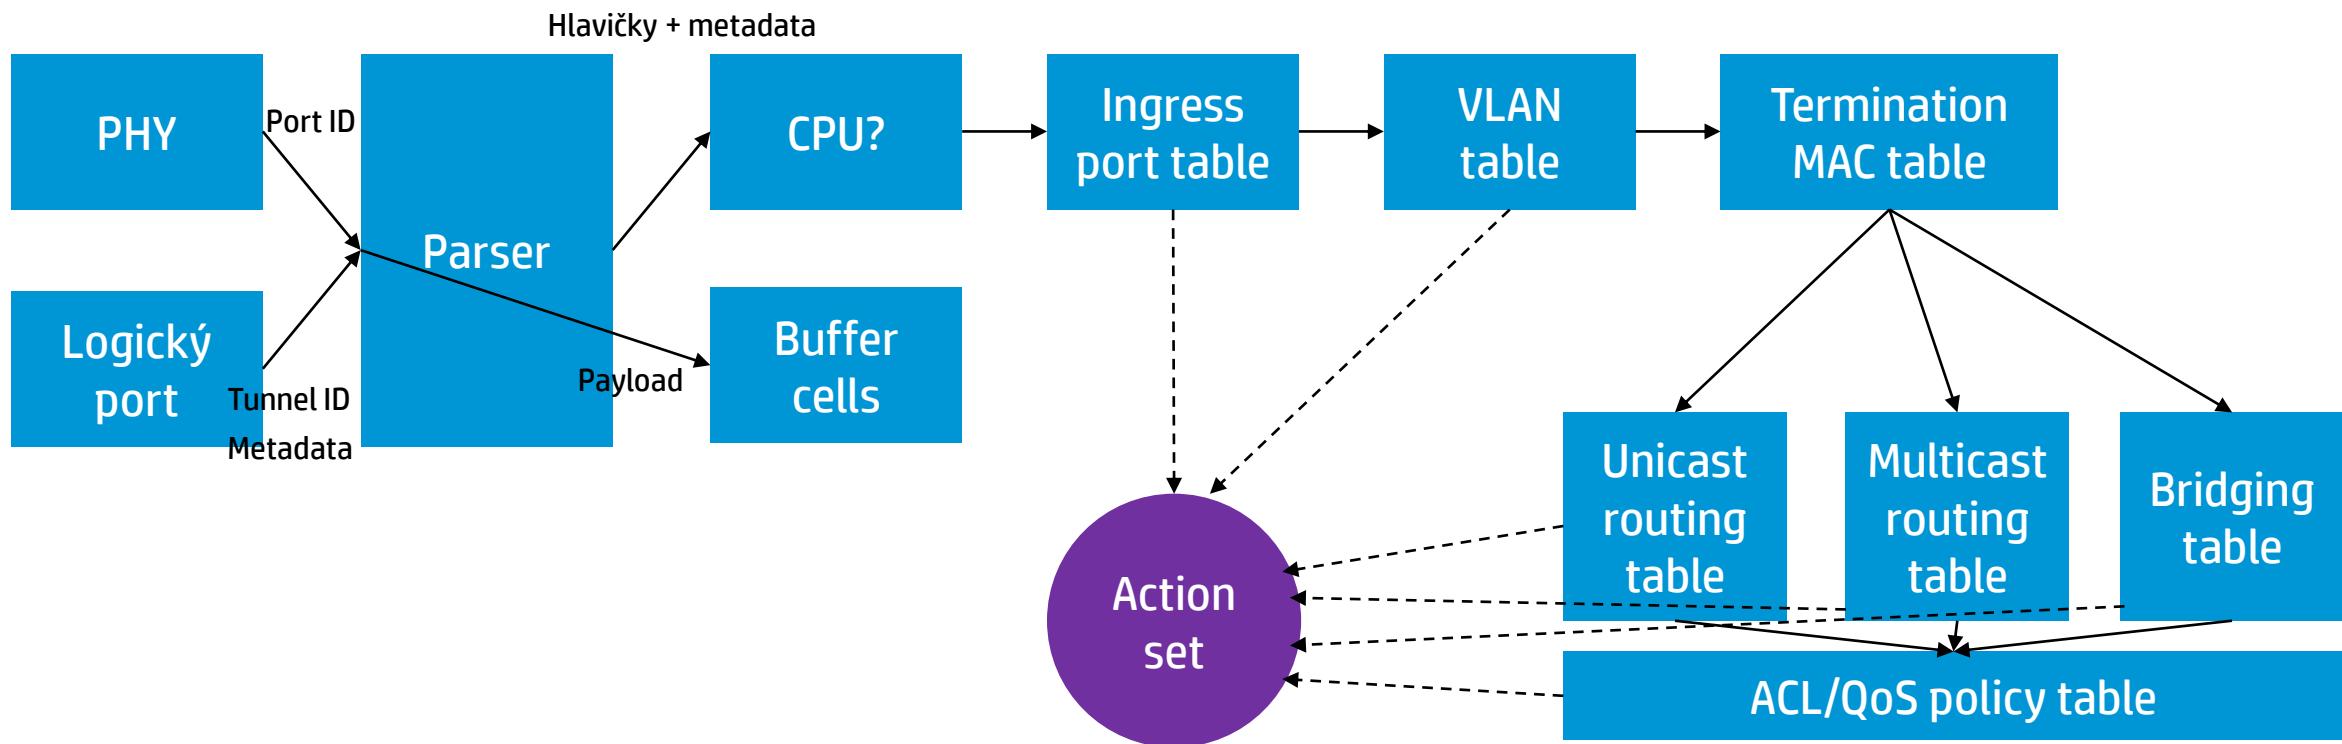
Service chaining (pro NFV) s využitím intent-based SDN



Hardware

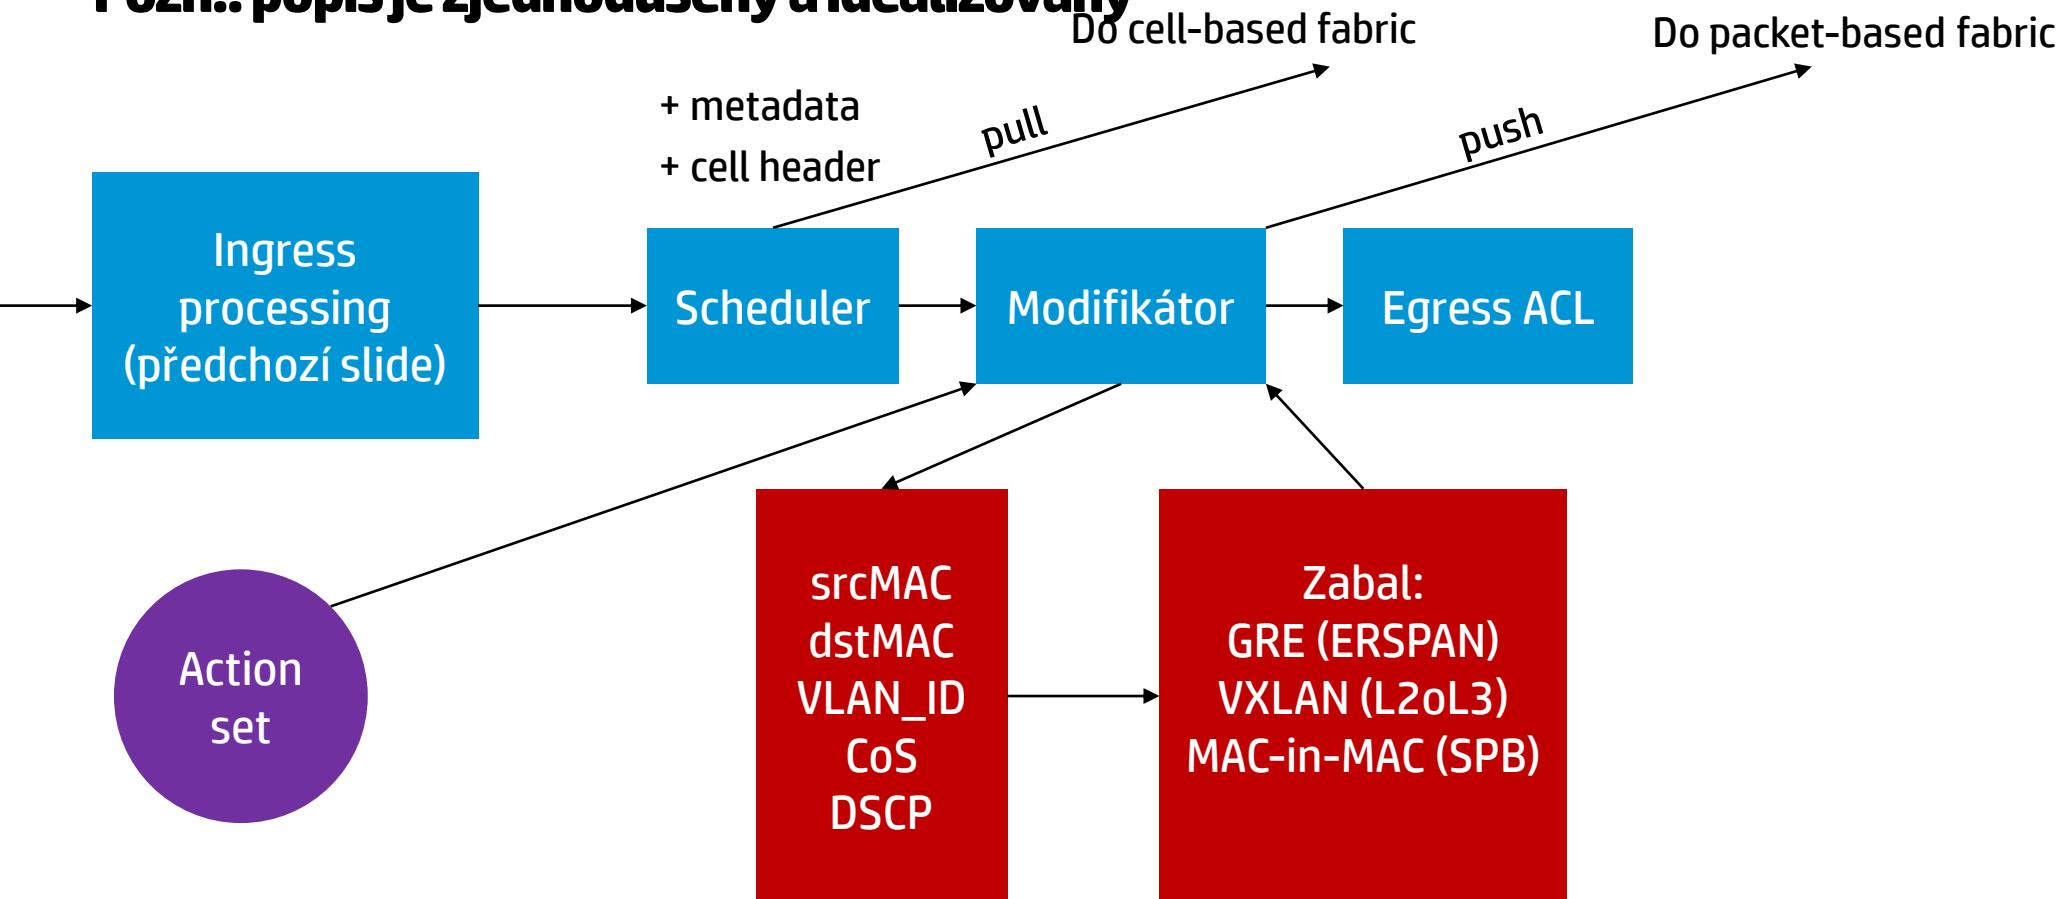
Jak funguje switch ASIC?

Pozn.: popis je zjednodušený a idealizovaný



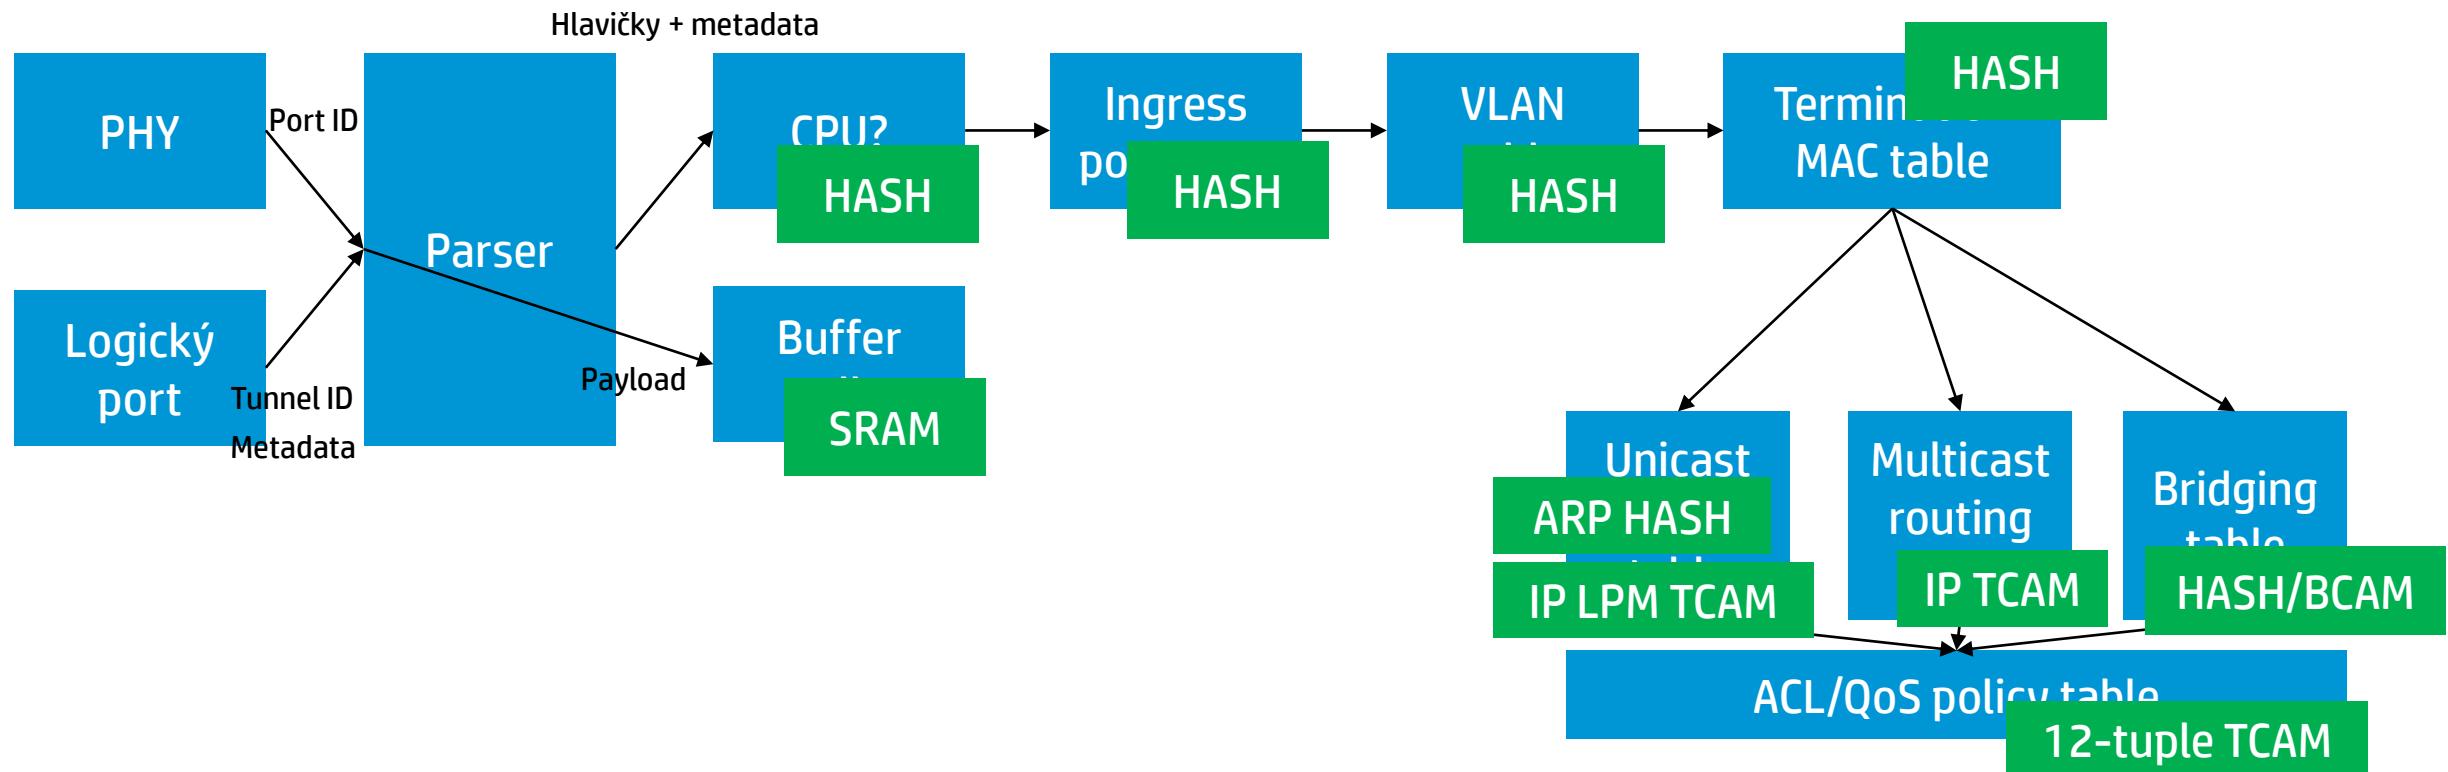
Jak funguje switch ASIC?

Pozn.: popis je zjednodušený a idealizovaný



Jak funguje switch ASIC?

Pozn.: popis je zjednodušený a idealizovaný



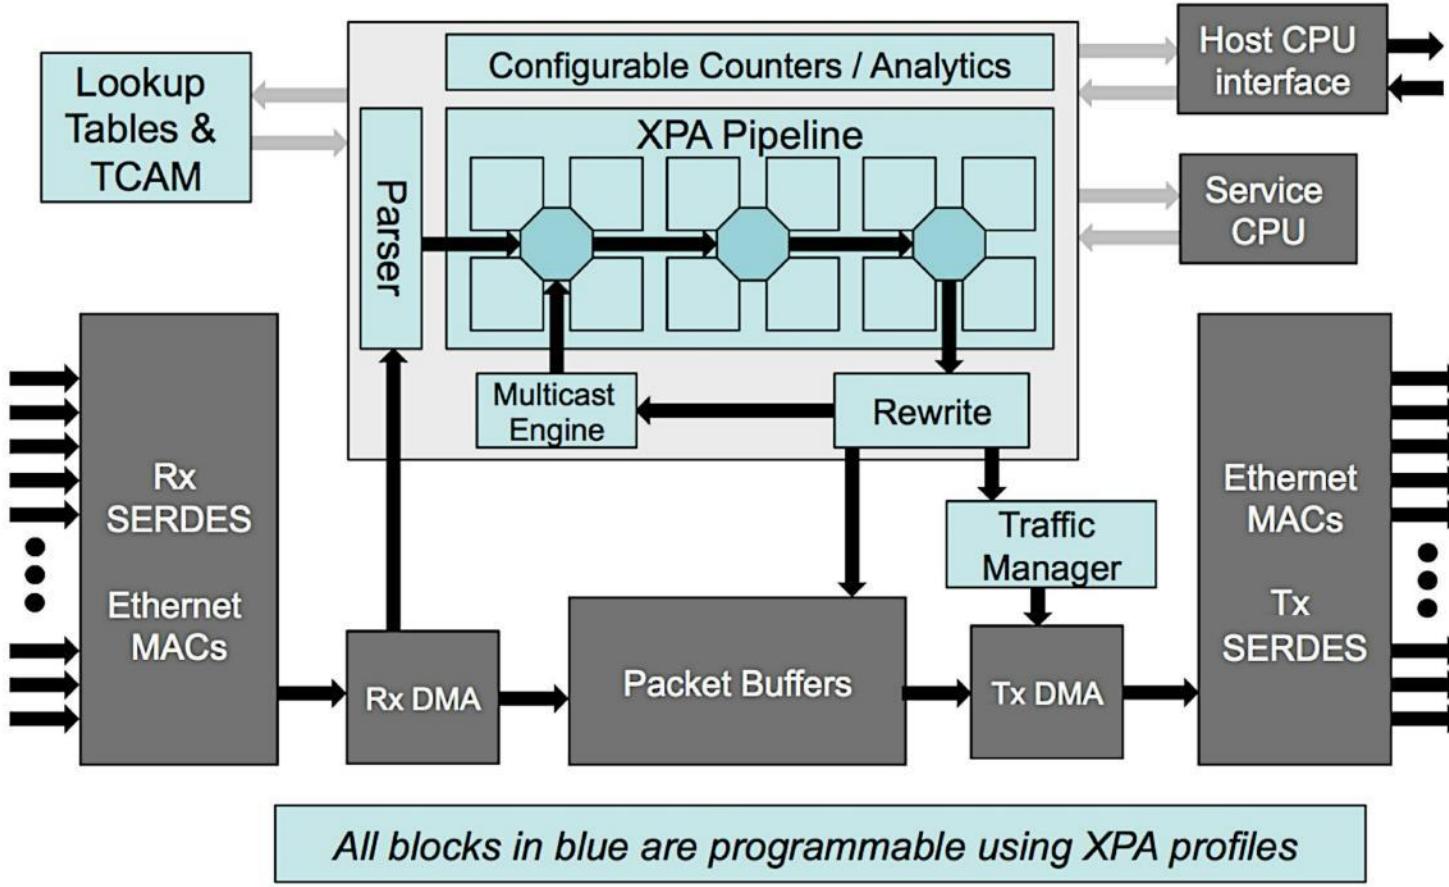
V čem je potíž?

- **Průtokovost, nelze se vracet** (např. problém routingu VXLAN provozu)
- **Všechny datové konstrukty pevně dané** (např. nelze přidat data-plane hlavičku bez změny ASIC jako je VXLAN, 802.1BR, FCoE)
- **Modifikační funkce pevně dané** (měnit můžete jen hlavičky, které se mění při switchingu/routingu)
- **Počet a pořadí tabulek je pevně dané**
- **Malé možnosti realokace kapacit tabulek** (ale čím dál tím lepší viz. **Broadcom Trident II**)

HP ProVision ASIC pro campus

- **Definujete si typ a pořadí tabulek (až 32)**
- **10x microcode engine pro manipulaci s pakety**
- **FPGA pro pattern match (jakékoli bity)**
- **FPGA pro modifikaci odchozího provozu (bity v offsetu určité délky)**
- **Programovatelnost tabulek přímo přes OpenFlow (můžete např. vytvořit tabulku !)**

Cavium XPliant ASIC do DC



XPliant Packet Architecture (XPA) Block Diagram

Co na to Broadcom?

Zatím nemá

- Bit pattern match (tzn. jakýkoli nový protokol)
- Flexibilní engine (jakékoli operace)
- Modifikace offset/pattern (jakýkoli protokol)

Trident I (2010)

- Vysoká hustota

Trident II (2013)

- Vysoká hustota
- Realokovatelné kapacity tabulek
(např. forwarding vs. routing)
- VXLAN enkapsulace

Tamahawk (2015)

- Vysoká hustota
- Flexibilní pořadí operací
- Vysokokapacitní flow countery

Trident II+ (2014)

- VXLAN routing
- Nativní 100G
- Menší spotřeba

Alternativní přístupy

Ani nejmodernější ASIC neumí:

- Match na variable field lenght (aka TLV)
- Zásadní změnu logiky při zachování hardwarového zpracování
- Držení složitějšího state (např. NAT/PAT)
- Vysoko-kapacitní pattern match (TCAM nebo FPGA uvnitř ASIC je velmi malé, drahé a žere)

FPGA

Např. Pre-procesor v routeru (QoS)

- Výkon blížící se ASIC
- Mikrokód určuje logiku
- Programuje se stejně jako design ASIC (nesmírně obtížné)
- Při vyšší kapacitě začně být extrémně drahý

Multi-core CPU

Např. Pobočkový router

- Naprostá flexibilita
- Logiku určuje kód (příjemné API)
- Relativně nižší výkon
- Nutná paralelizace nefunguje pro všechny situace
- Nepředvídatelný výkon/latence

Network Processor

Např. Výkonný router

- Velmi dobrá flexibilita
- Logiku určuje kód (použitelná komplexita)
- Přístup aka GPU (masivní paralelizace) nemusí fungovat pro všechny situace
- Vysoká cena

Nemluvme jen o SDN.... ... Mluvme o nové síťařině

Software-defined Networking

Network Virtualization

Network Function Virtualization

Disagregace

Open source

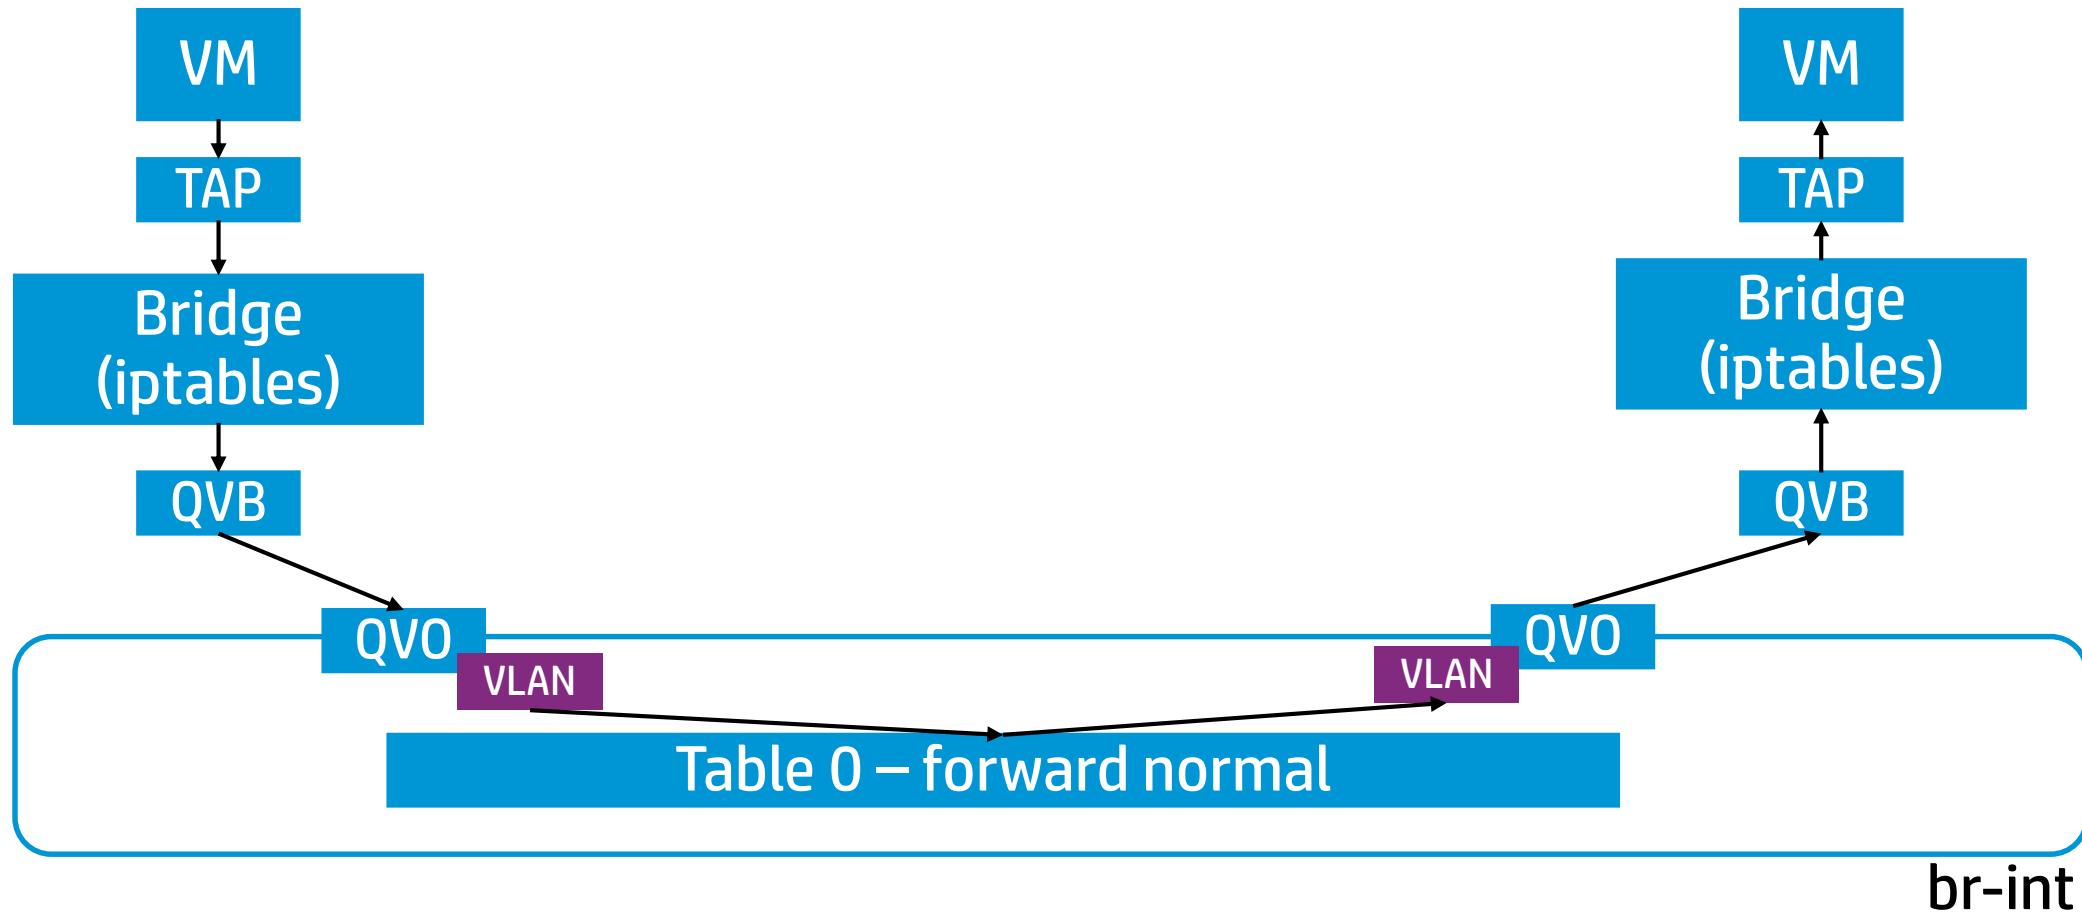
DevOps

**Chcete vědět jak funguje Neutron
implementace s OVS?**

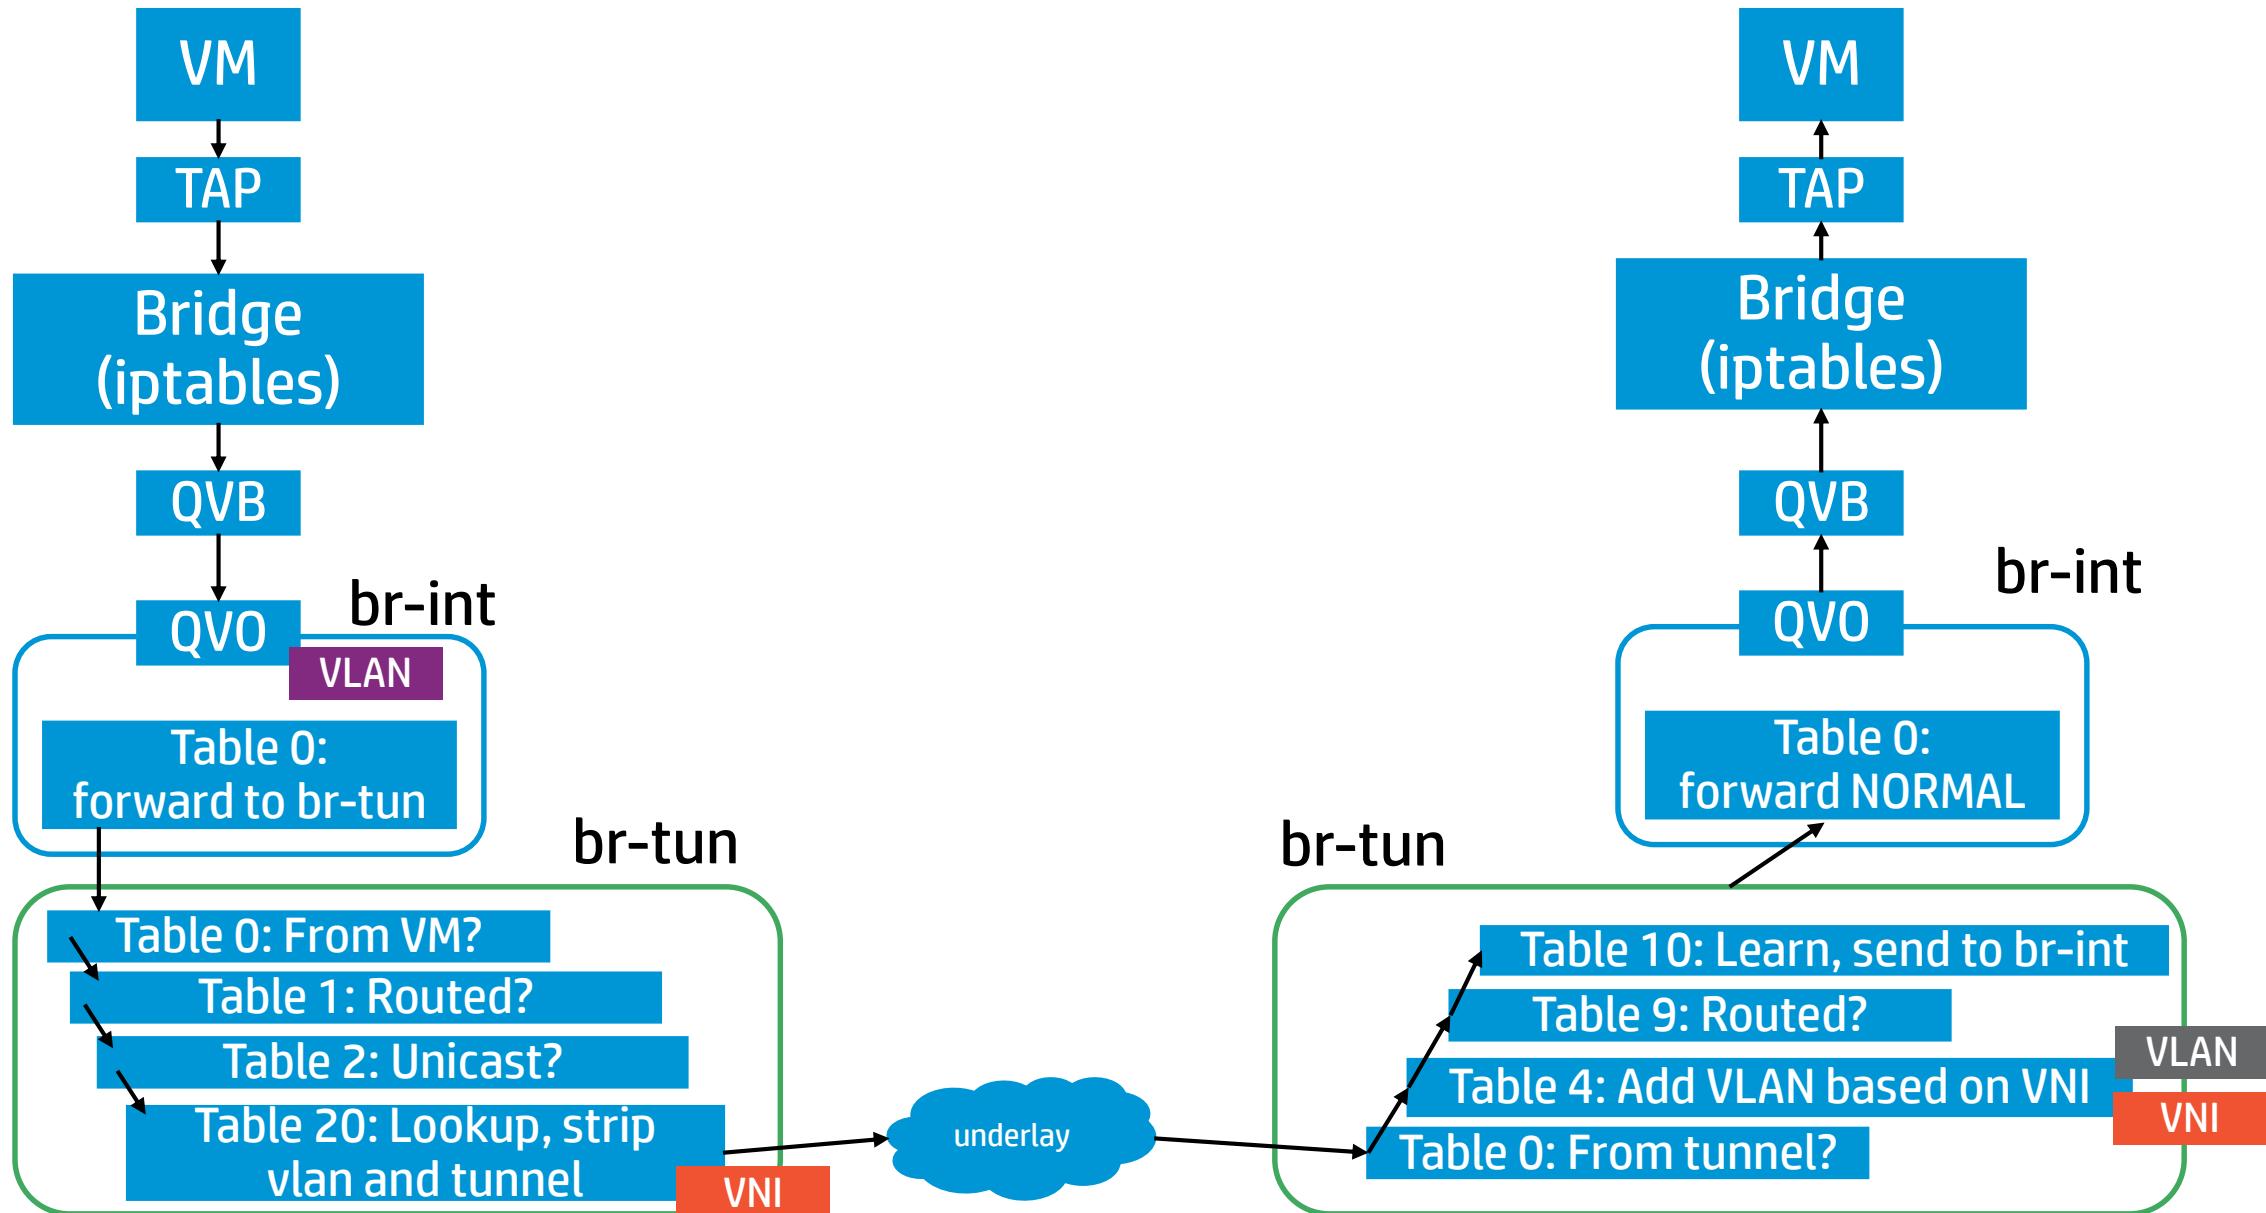
Stáhněte si lab guide 3 na:

http://www.cloudsvet.cz/?page_id=10

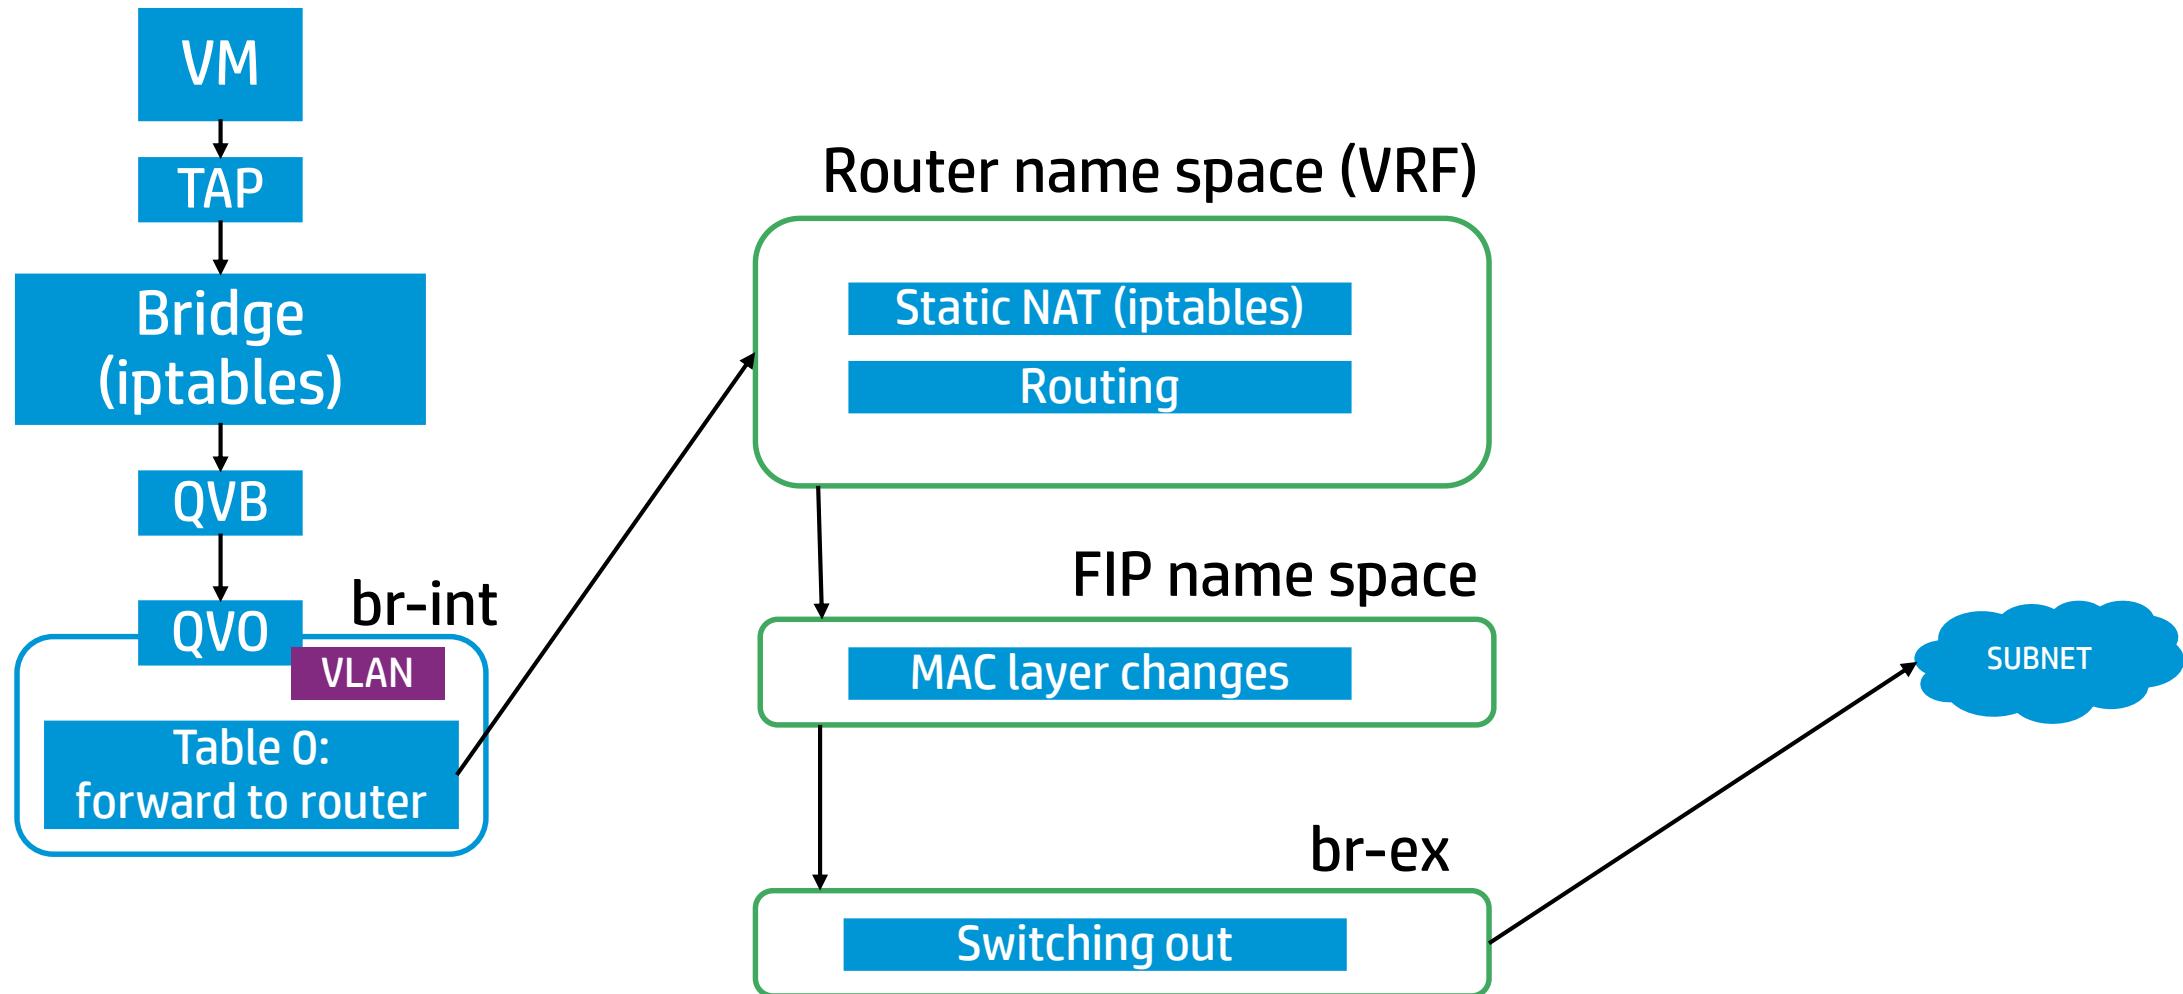
Komunikace mezi VM ve stejné síti na stejném compute node



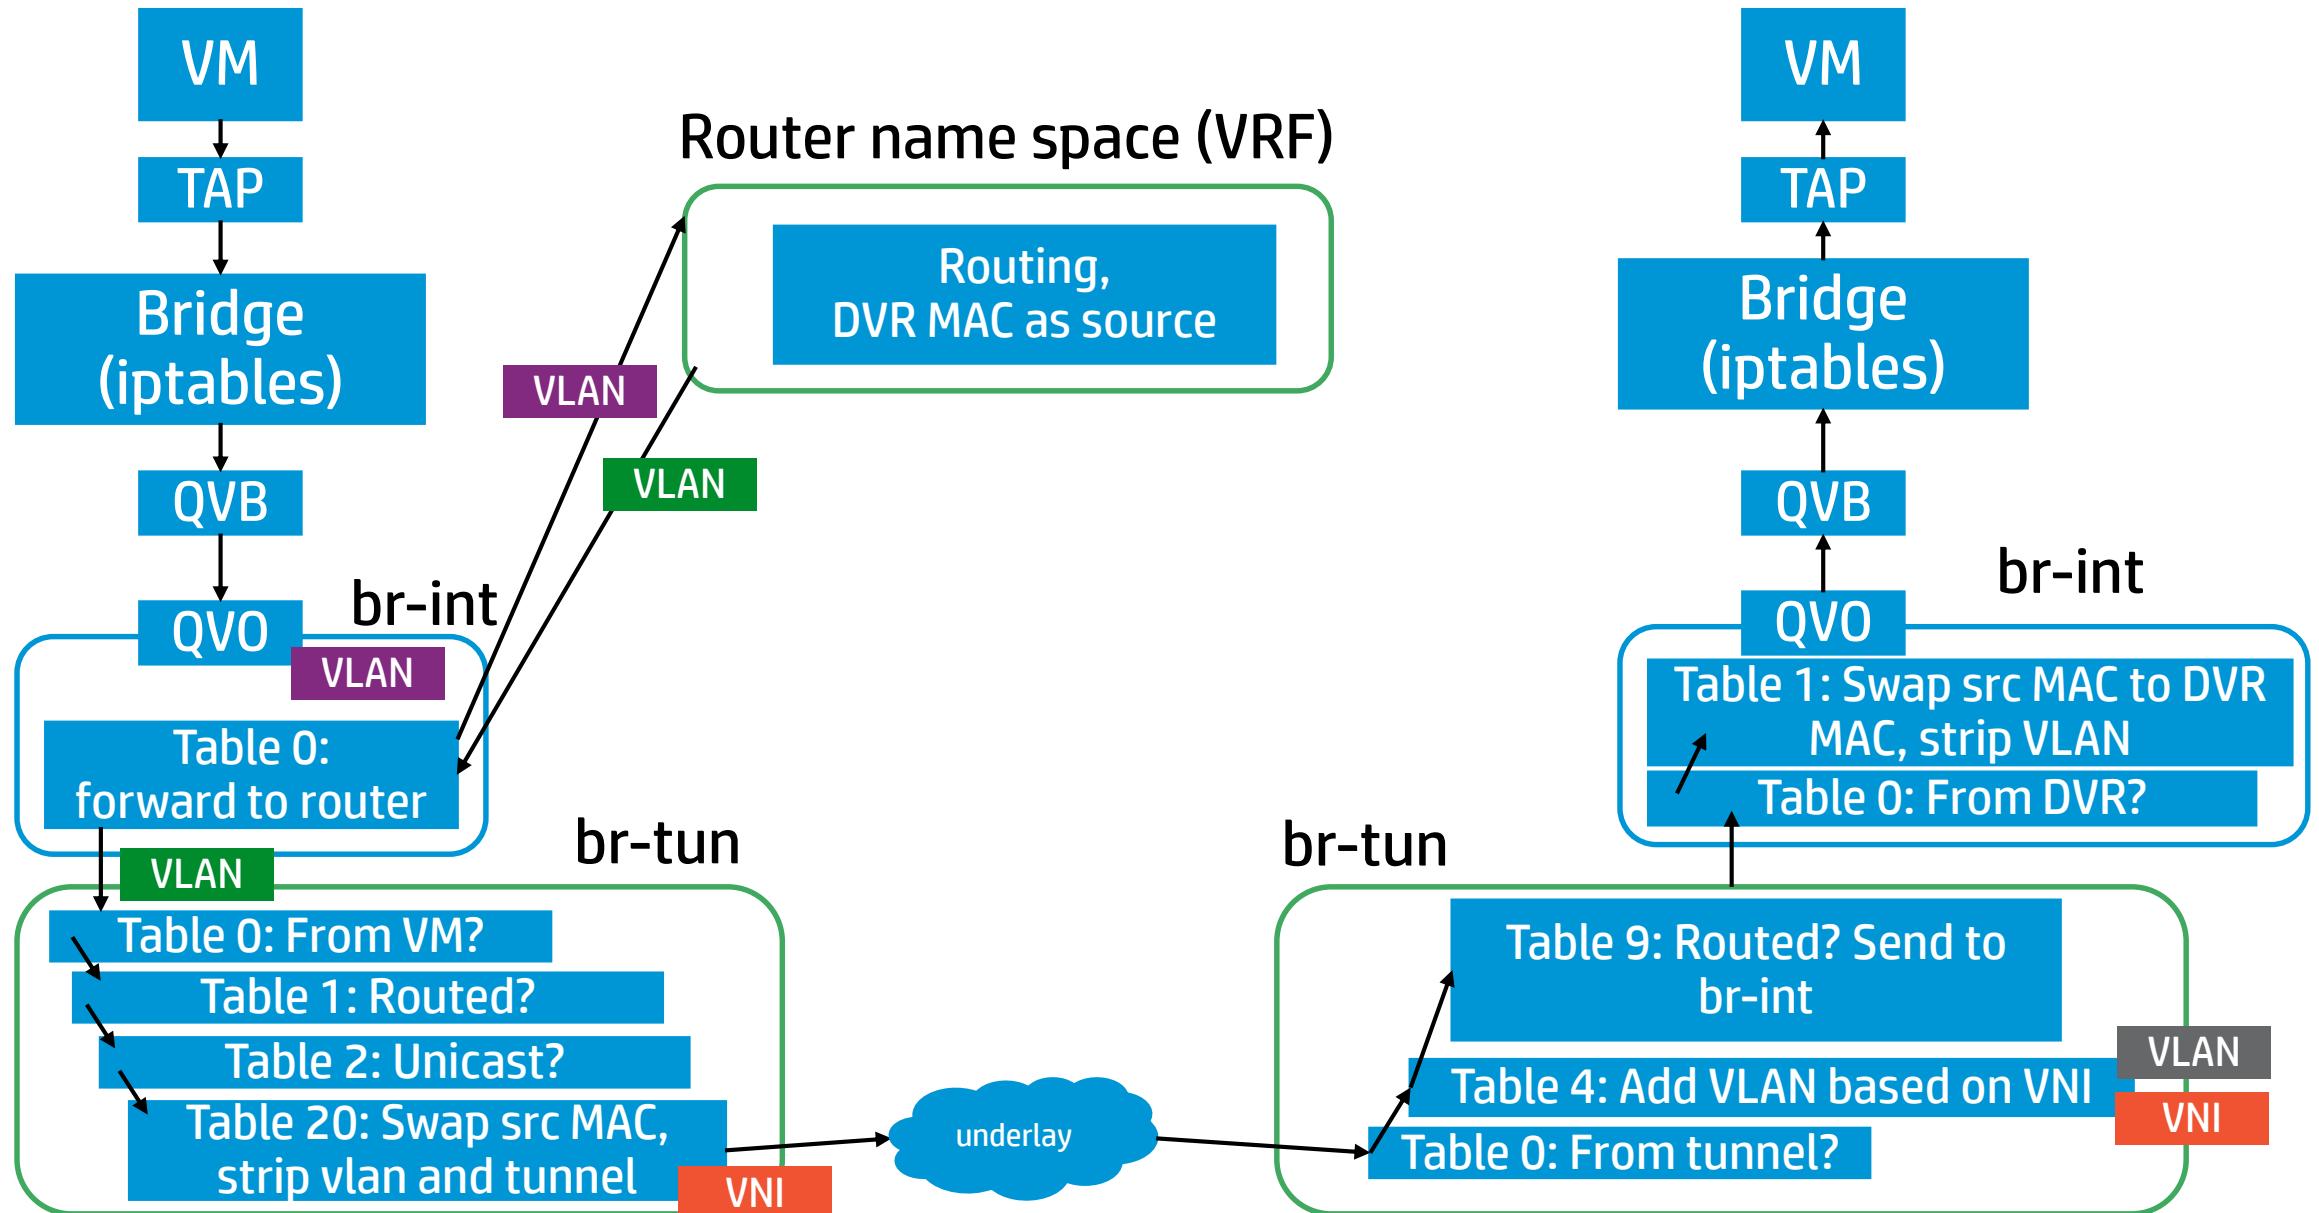
Komunikace mezi VM ve stejné síti na odlišných compute node



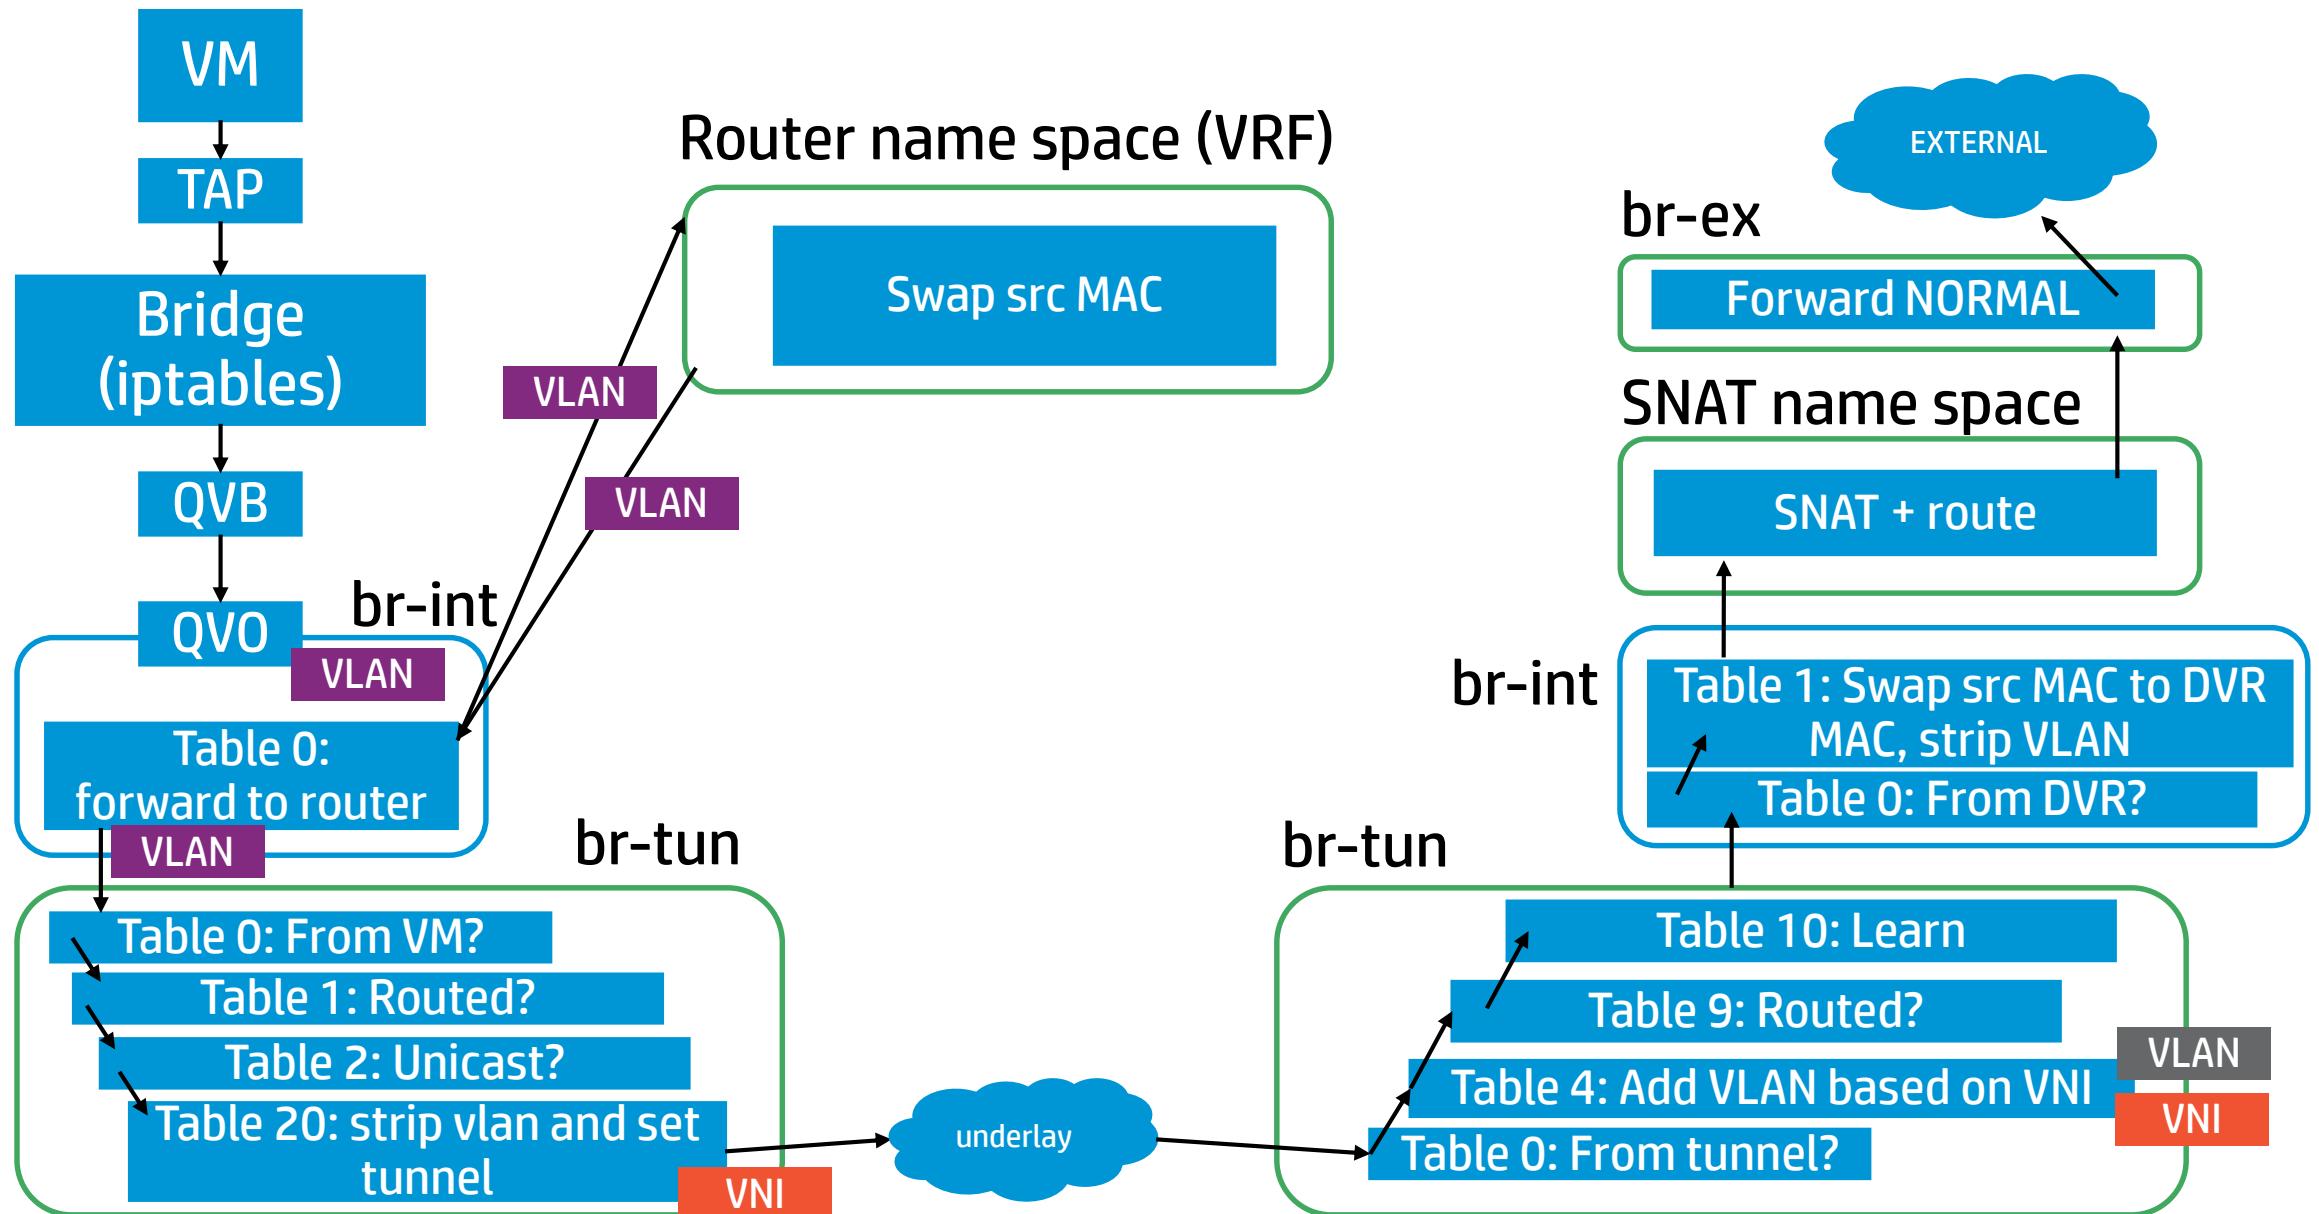
Komunikace z VM do světa s Floating IP



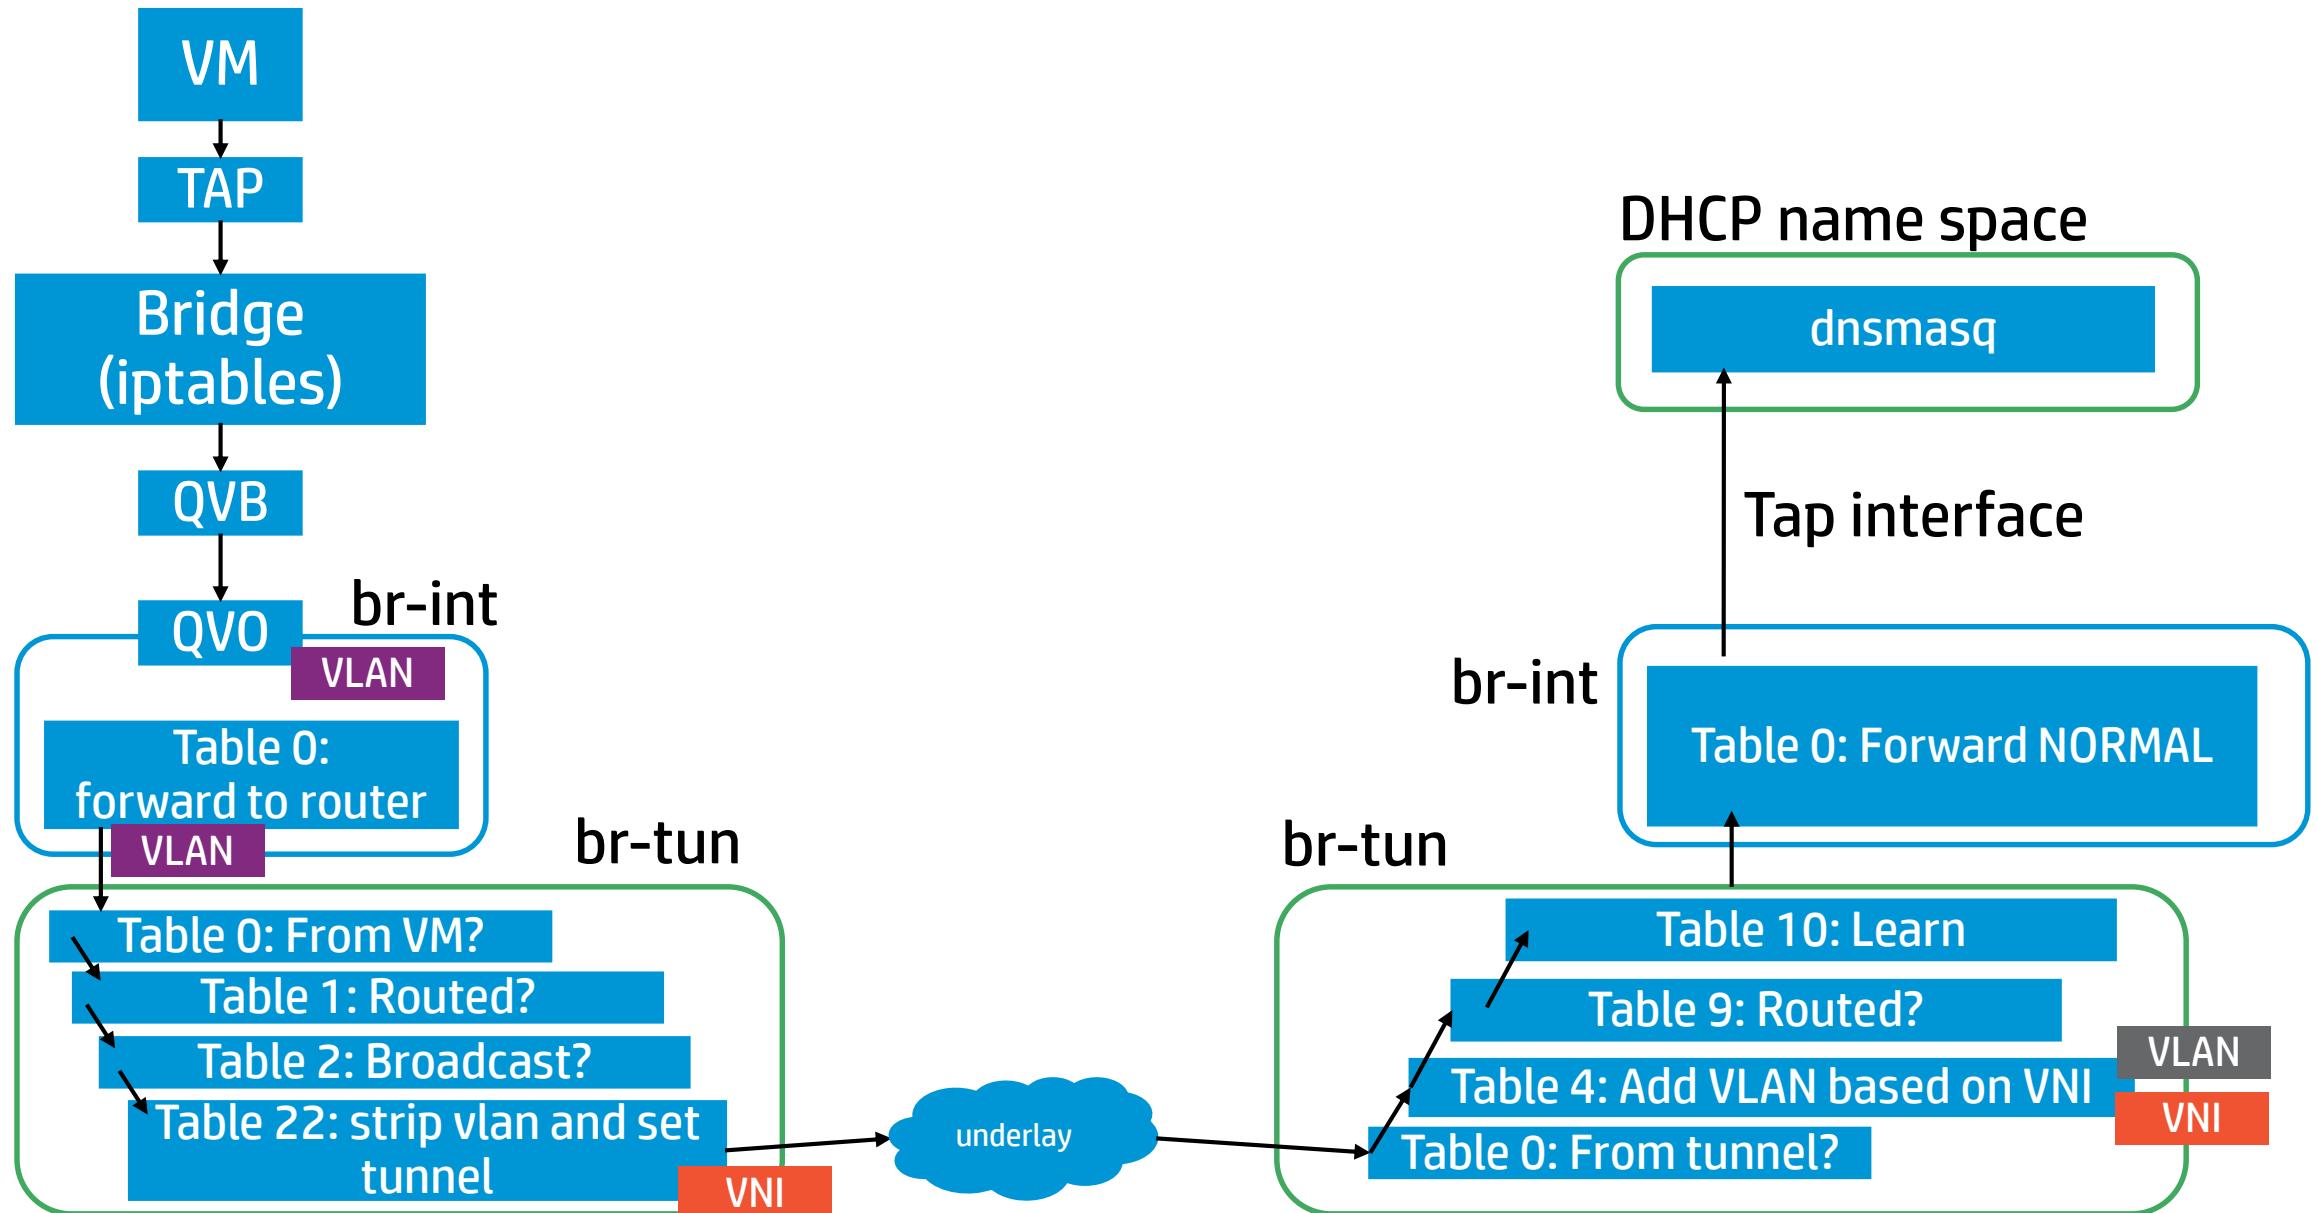
Routing mezi subnety v rámci tenant na různých compute node



Komunikace do externí sítě s použitím source NAT



DHCP



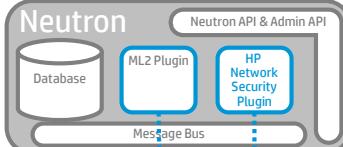
Jaká je potíž s virtualizací sítě?

- **Moc zaměření na netvirt, málo na rámec (= nerozšiřitelnost aka NSX nebo OVN)**
- **Rozmělnění vývoje díky bezkontrolerovým a vícekontrolerovým řešením (viz dále)**
- **Málo koordinace Neutron a non-Neutron řešení (např. SDN pro overlay + SDN pro underlay)**

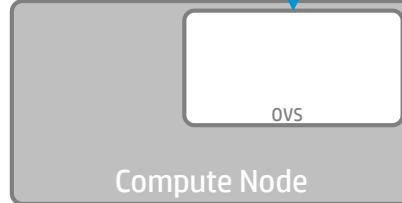
Soupeřící modely

Bez kontroleru

Cloud Orchestration



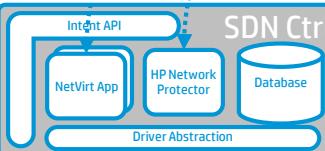
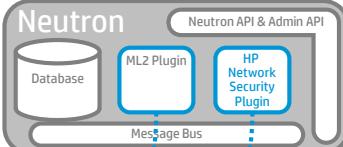
pSwitch



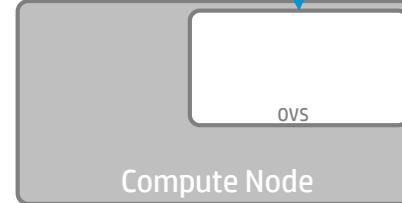
Compute Node

Jeden kontroler

Cloud Orchestration



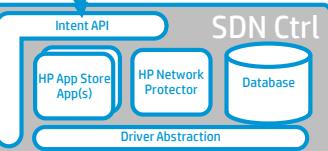
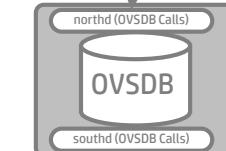
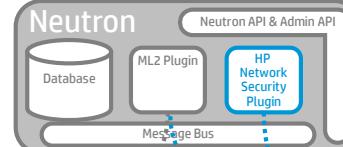
pSwitch



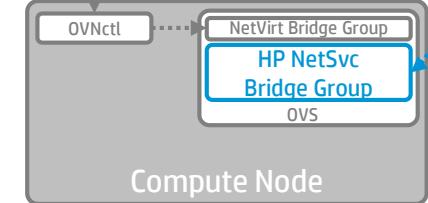
Compute Node

Víc kontrolerů

Cloud Orchestration



pSwitch



Compute Node

Nemluvme jen o SDN.... ... Mluvme o nové síťarině

Software-defined Networking

Network Virtualization

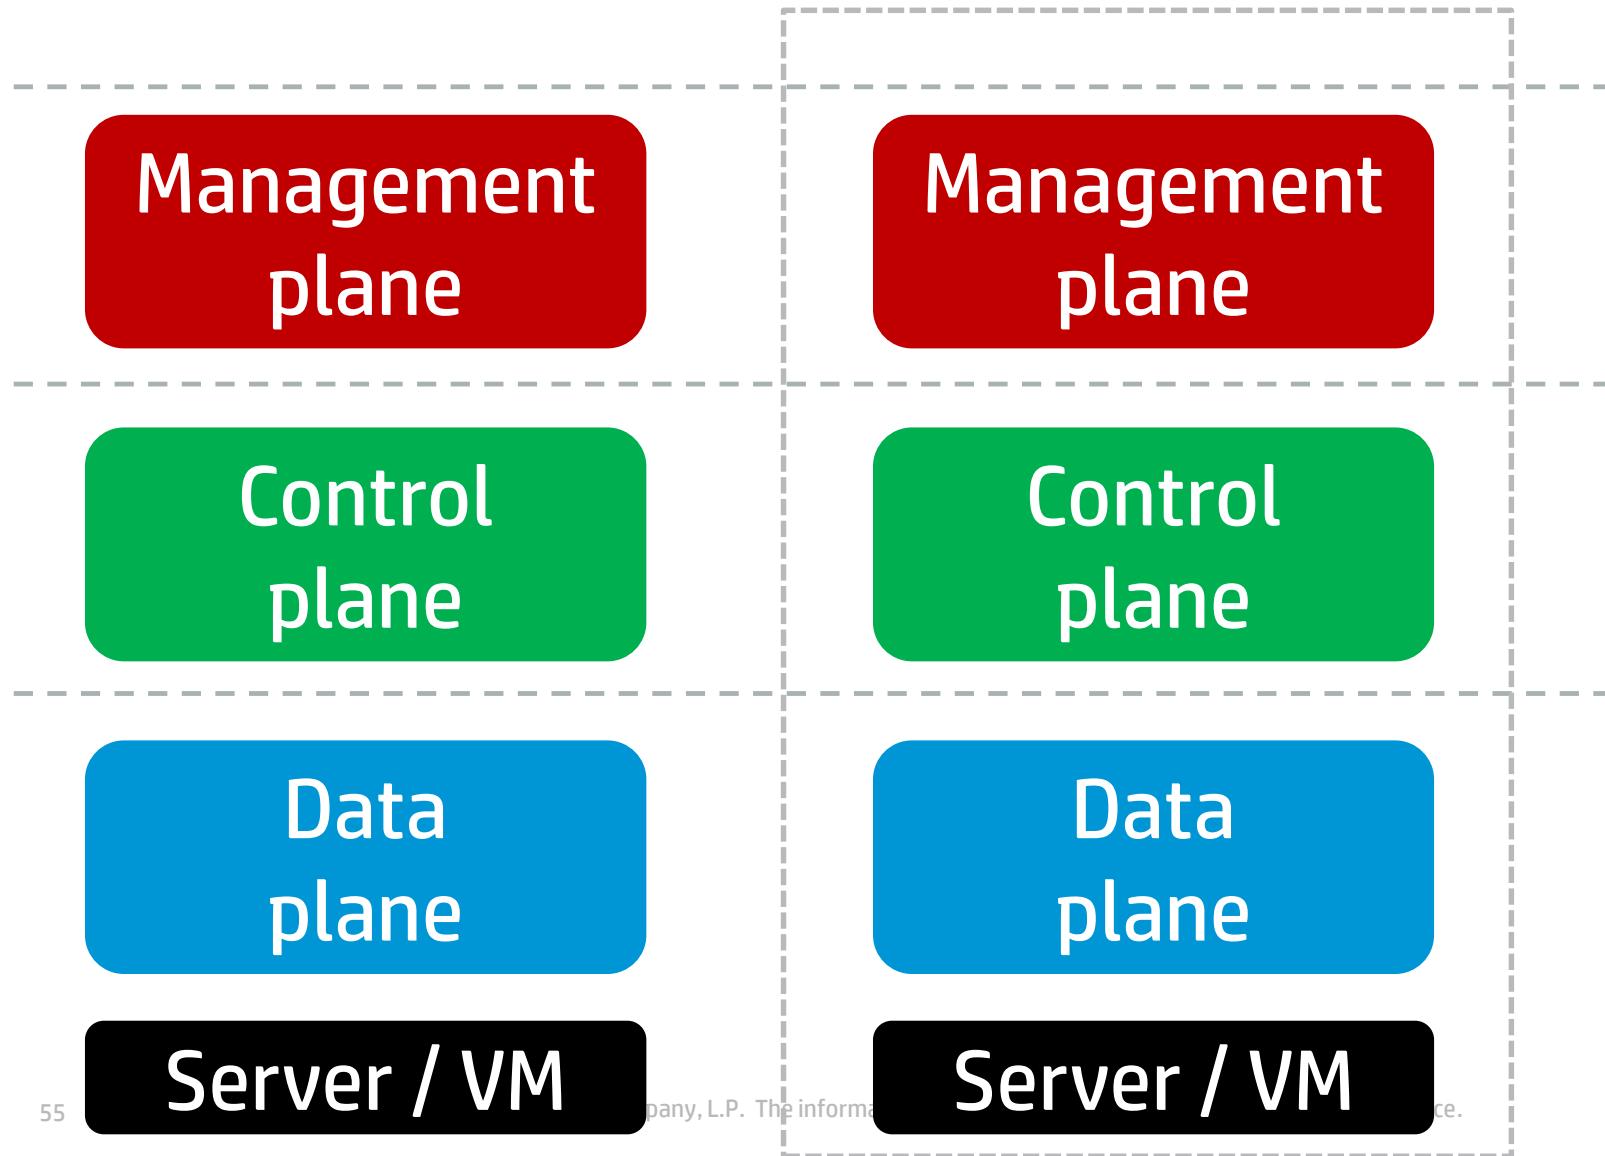
Network Function Virtualization

Disagregace

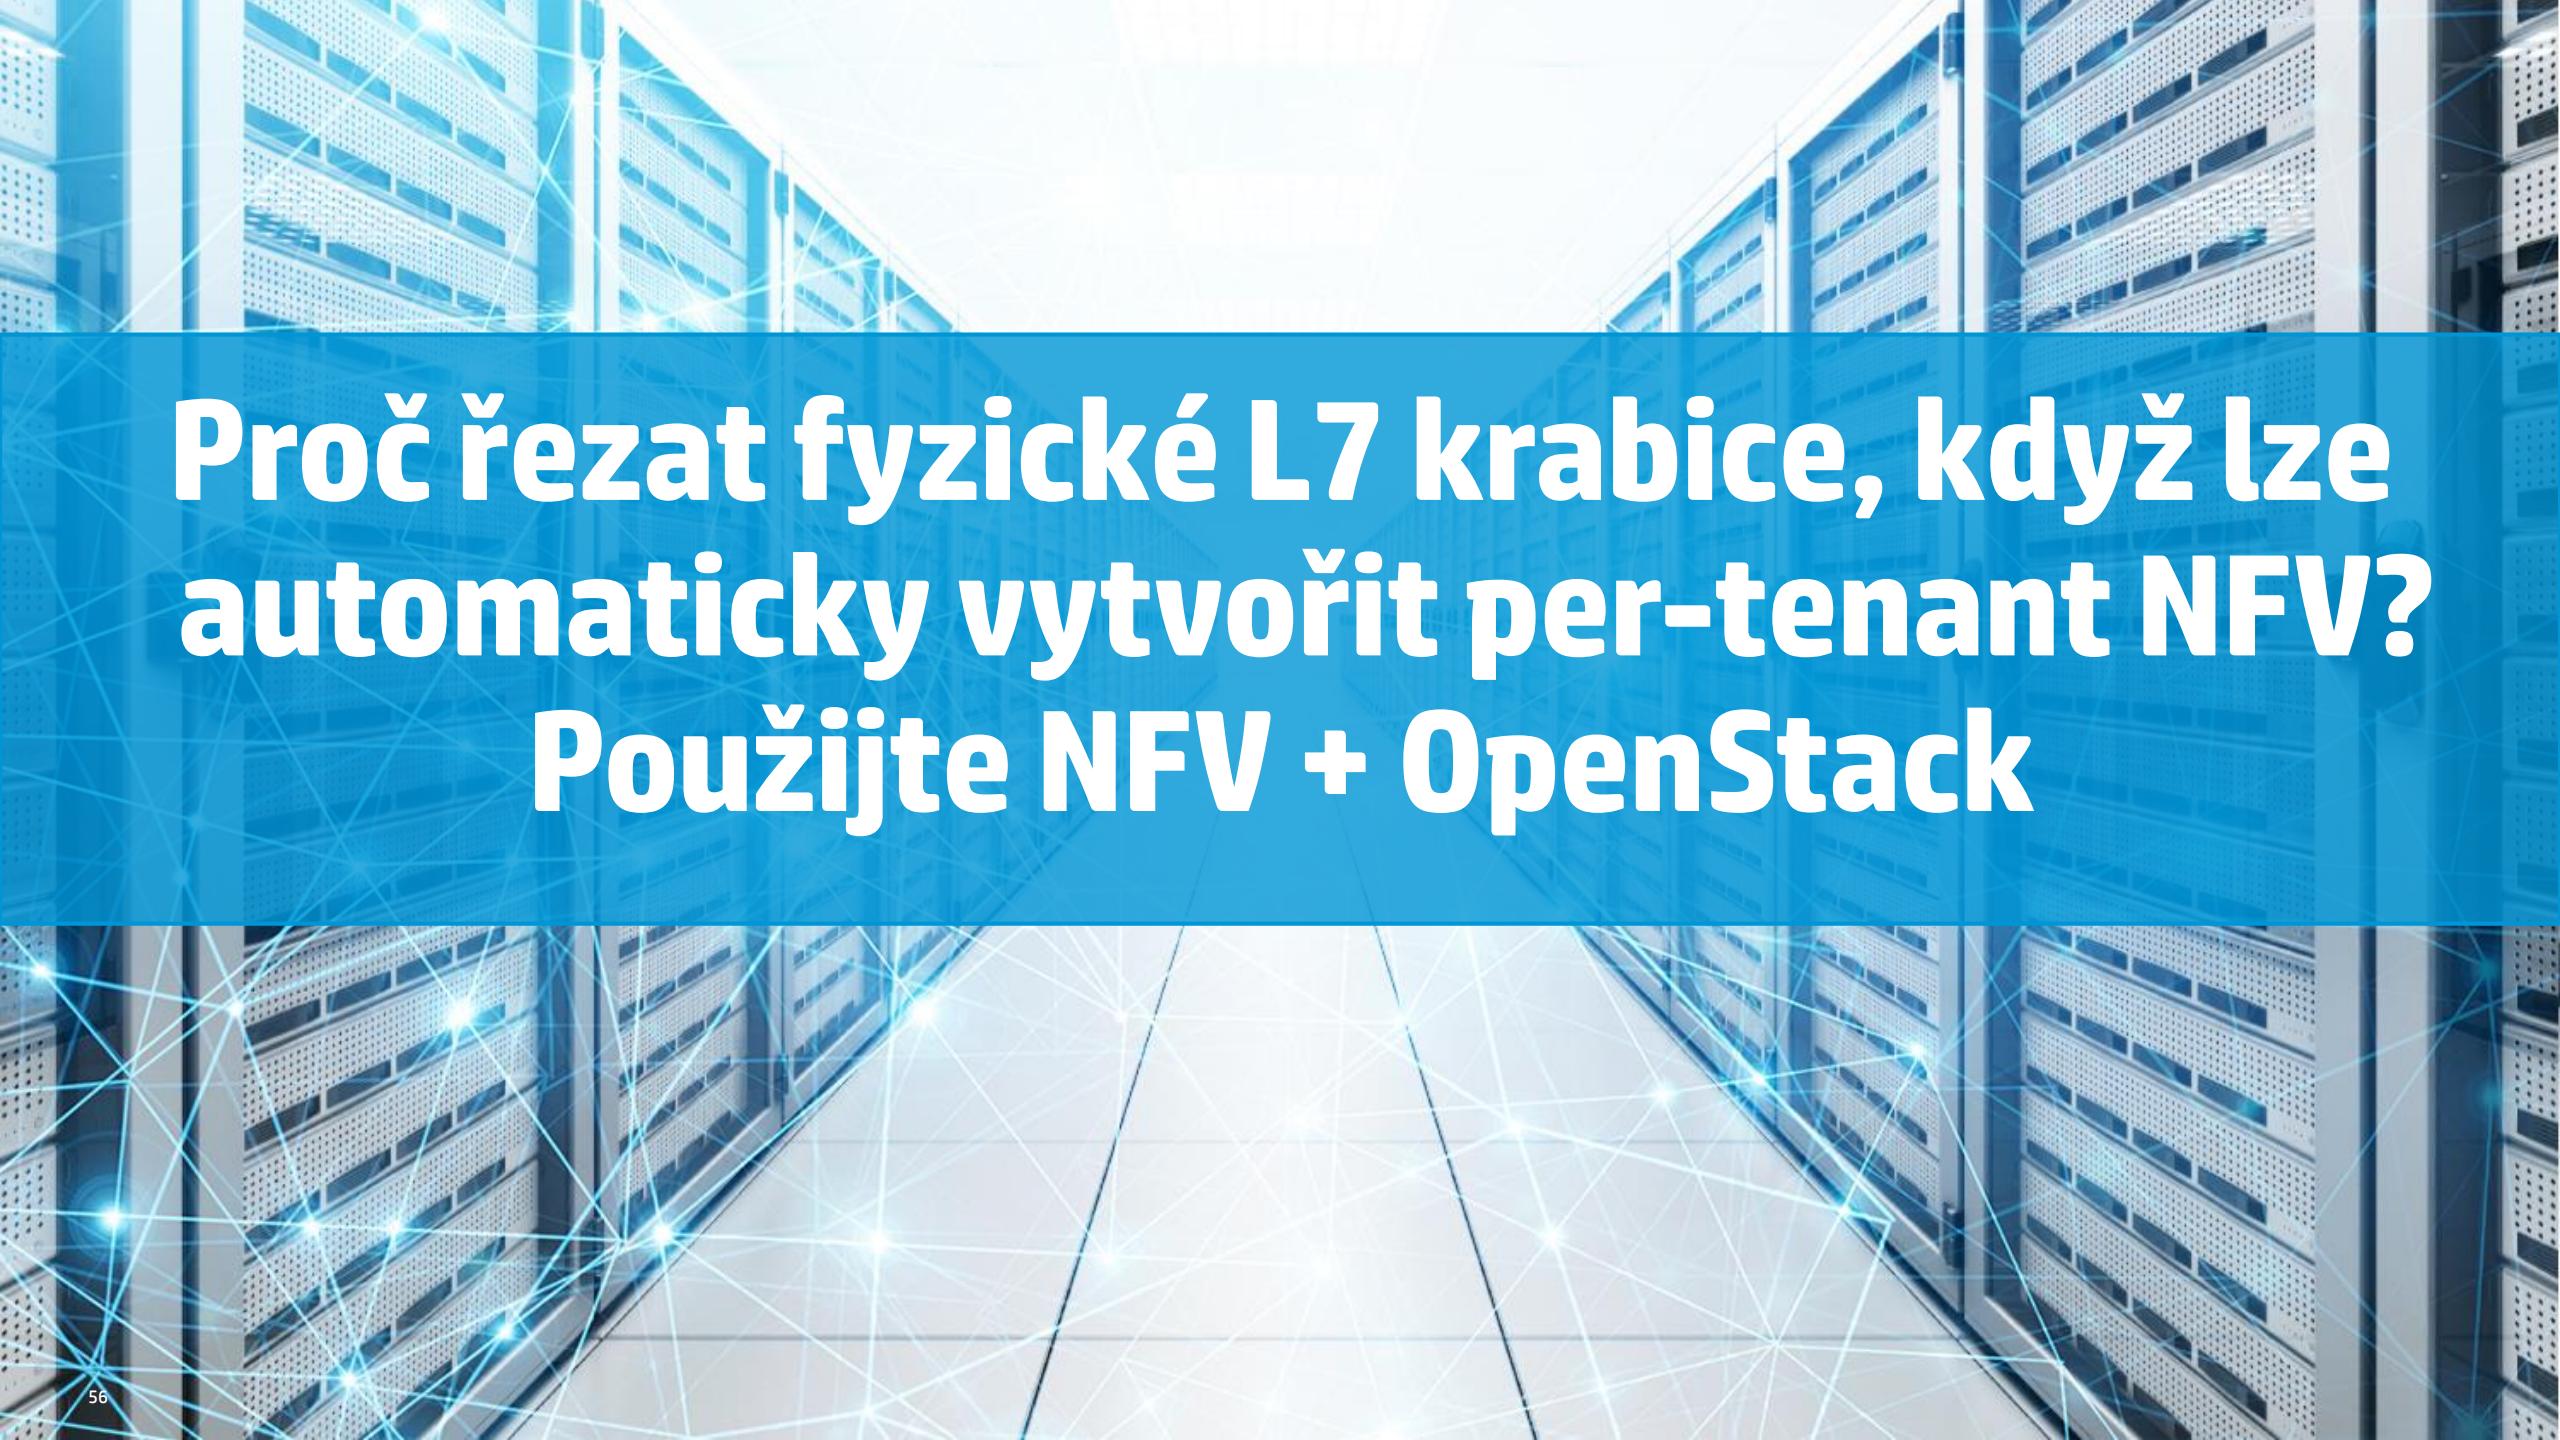
Open source

DevOps

Virtualizace síťových funkcí (NFV)



Přesun síťových funkcí ze specializovaného hardware do obyčejného serveru nebo VM



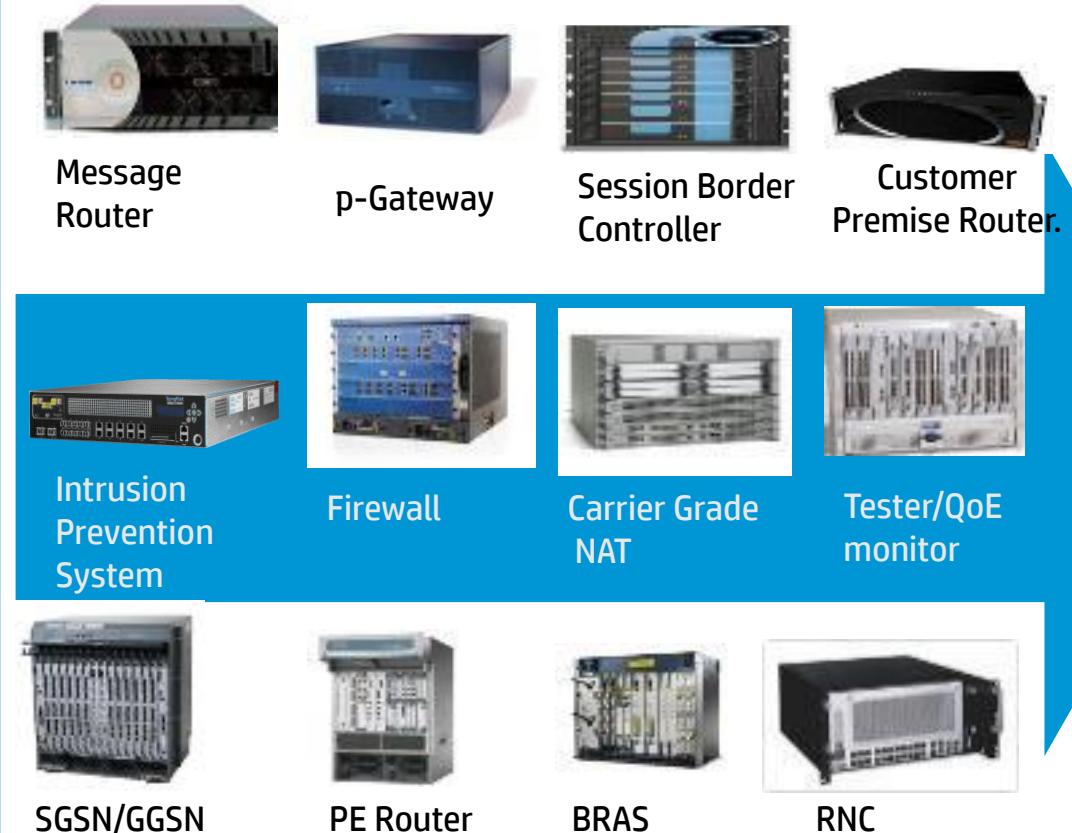
**Proč řezat fyzické L7 krabice, když lze
automaticky vytvořit per-tenant NFV?
Použijte NFV + OpenStack**



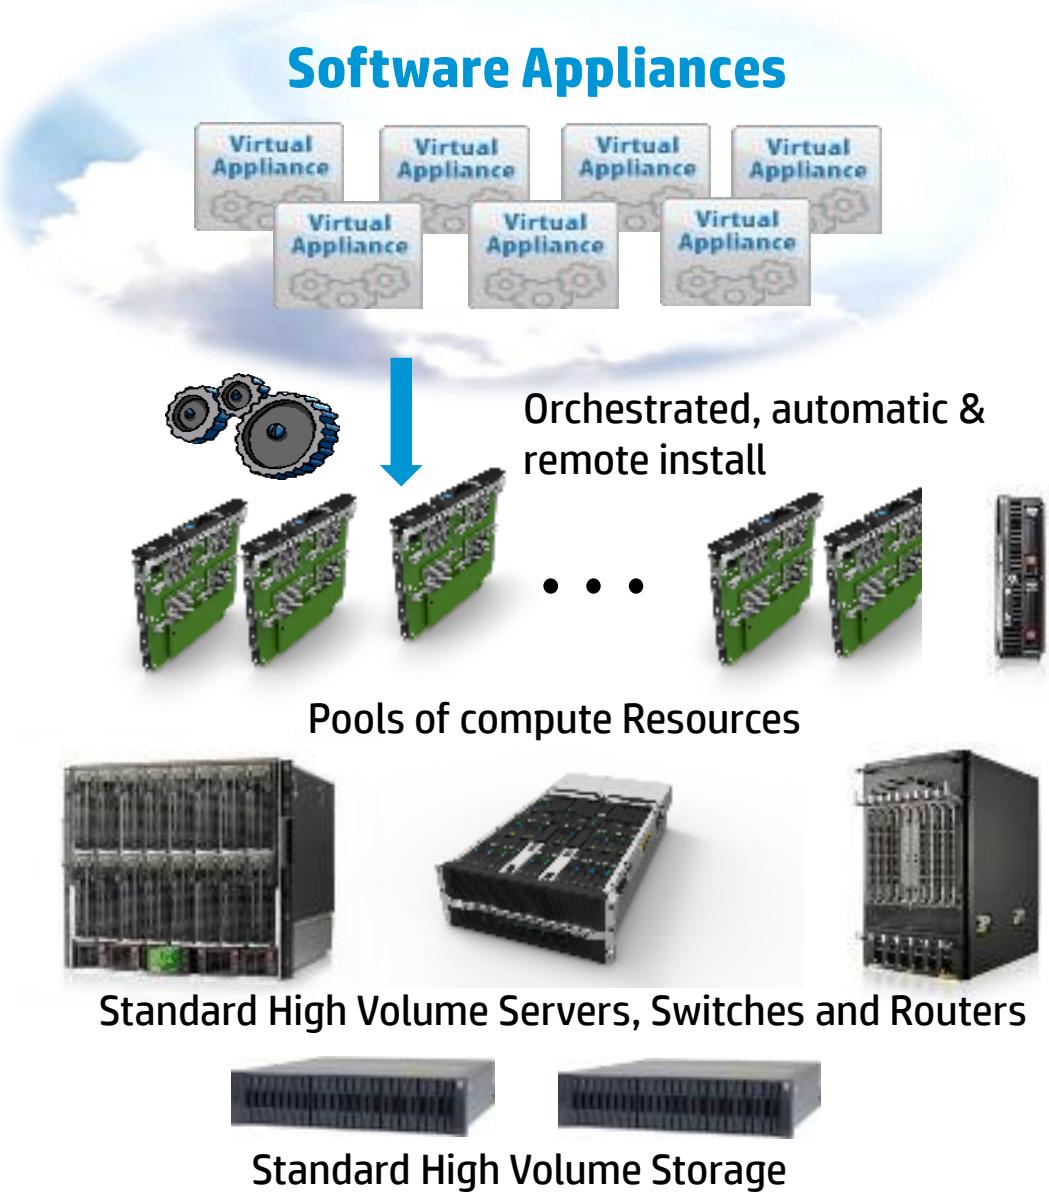
**Jak poslat provoz uživatele do různých L7
služeb ve správném pořadí aniž byste
potřebovali vědět, kde služba běží?
Použijte NFV + SDN**

Jak vznikl požadavek na NFV?

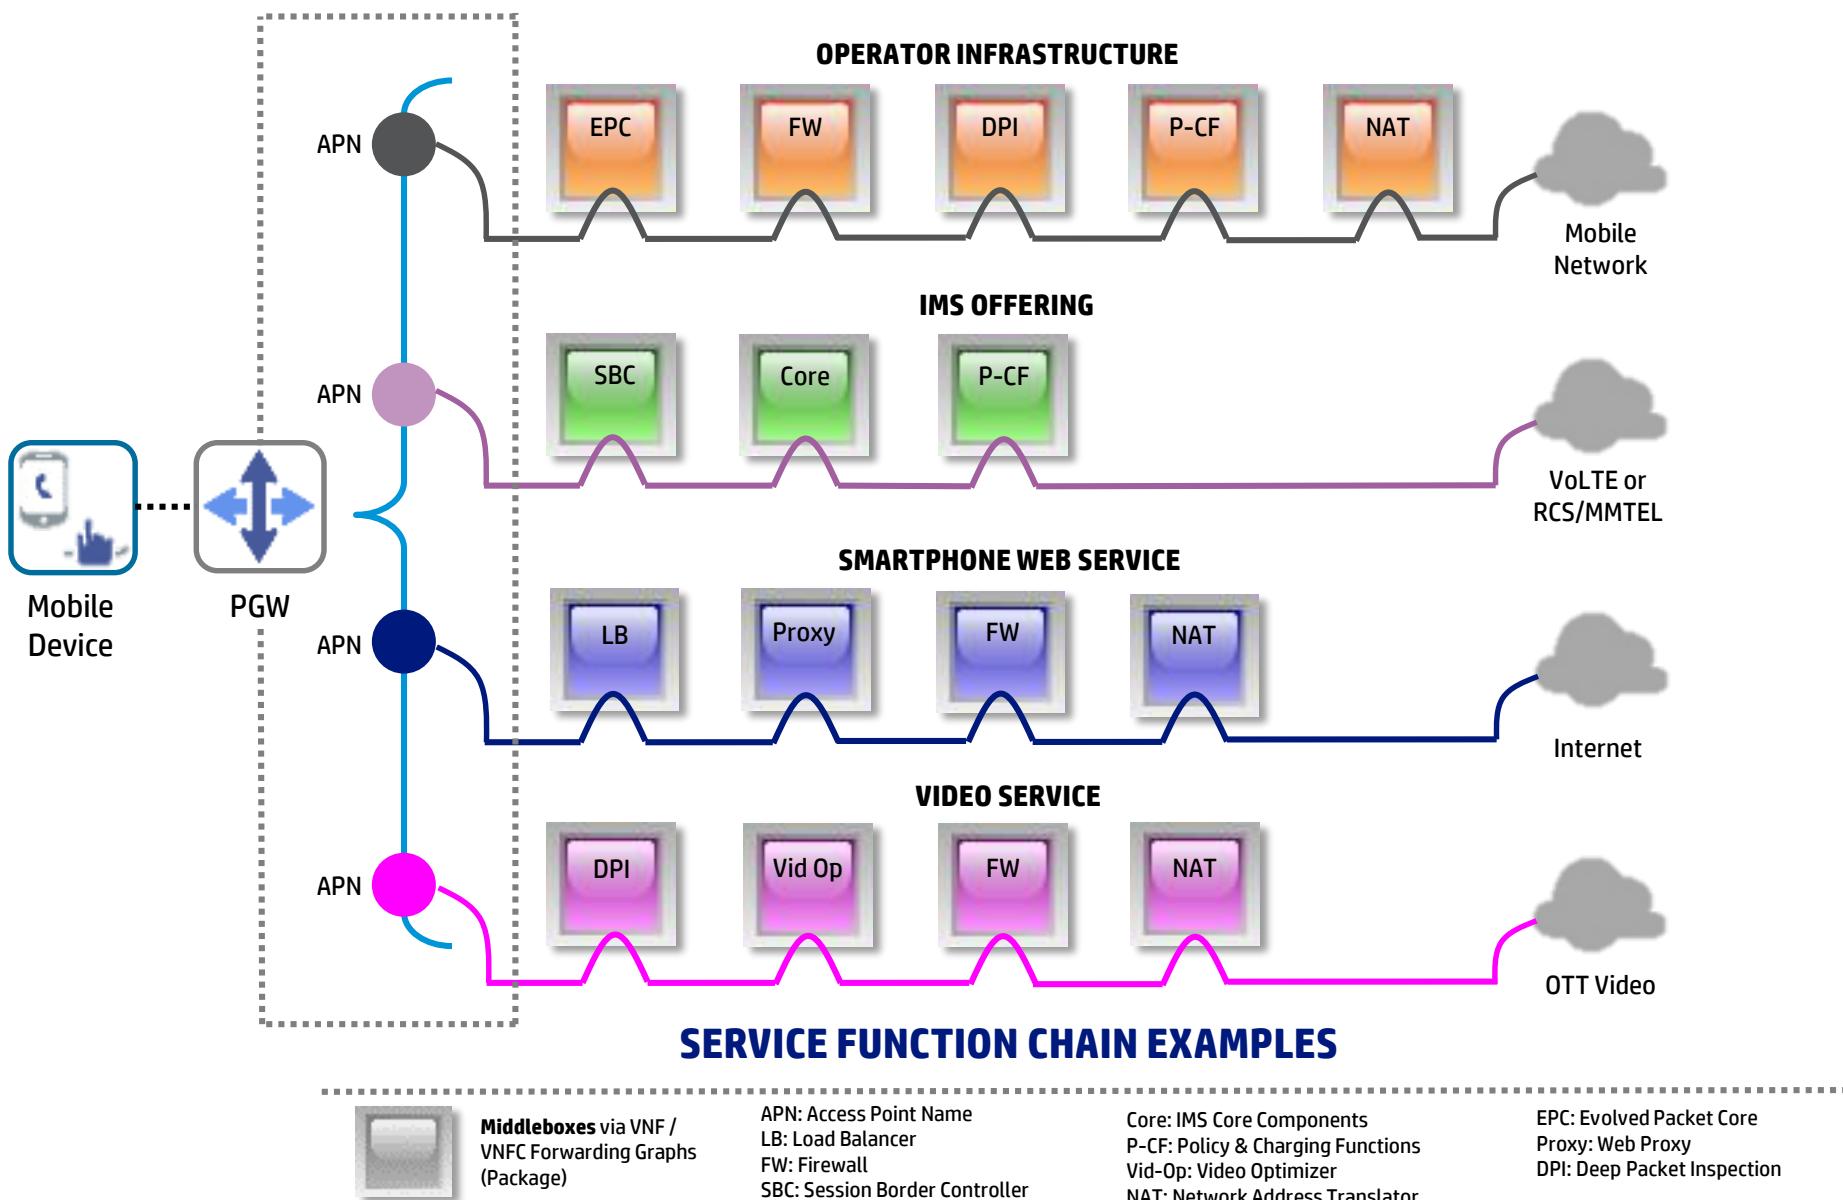
Proprietary Network Appliances



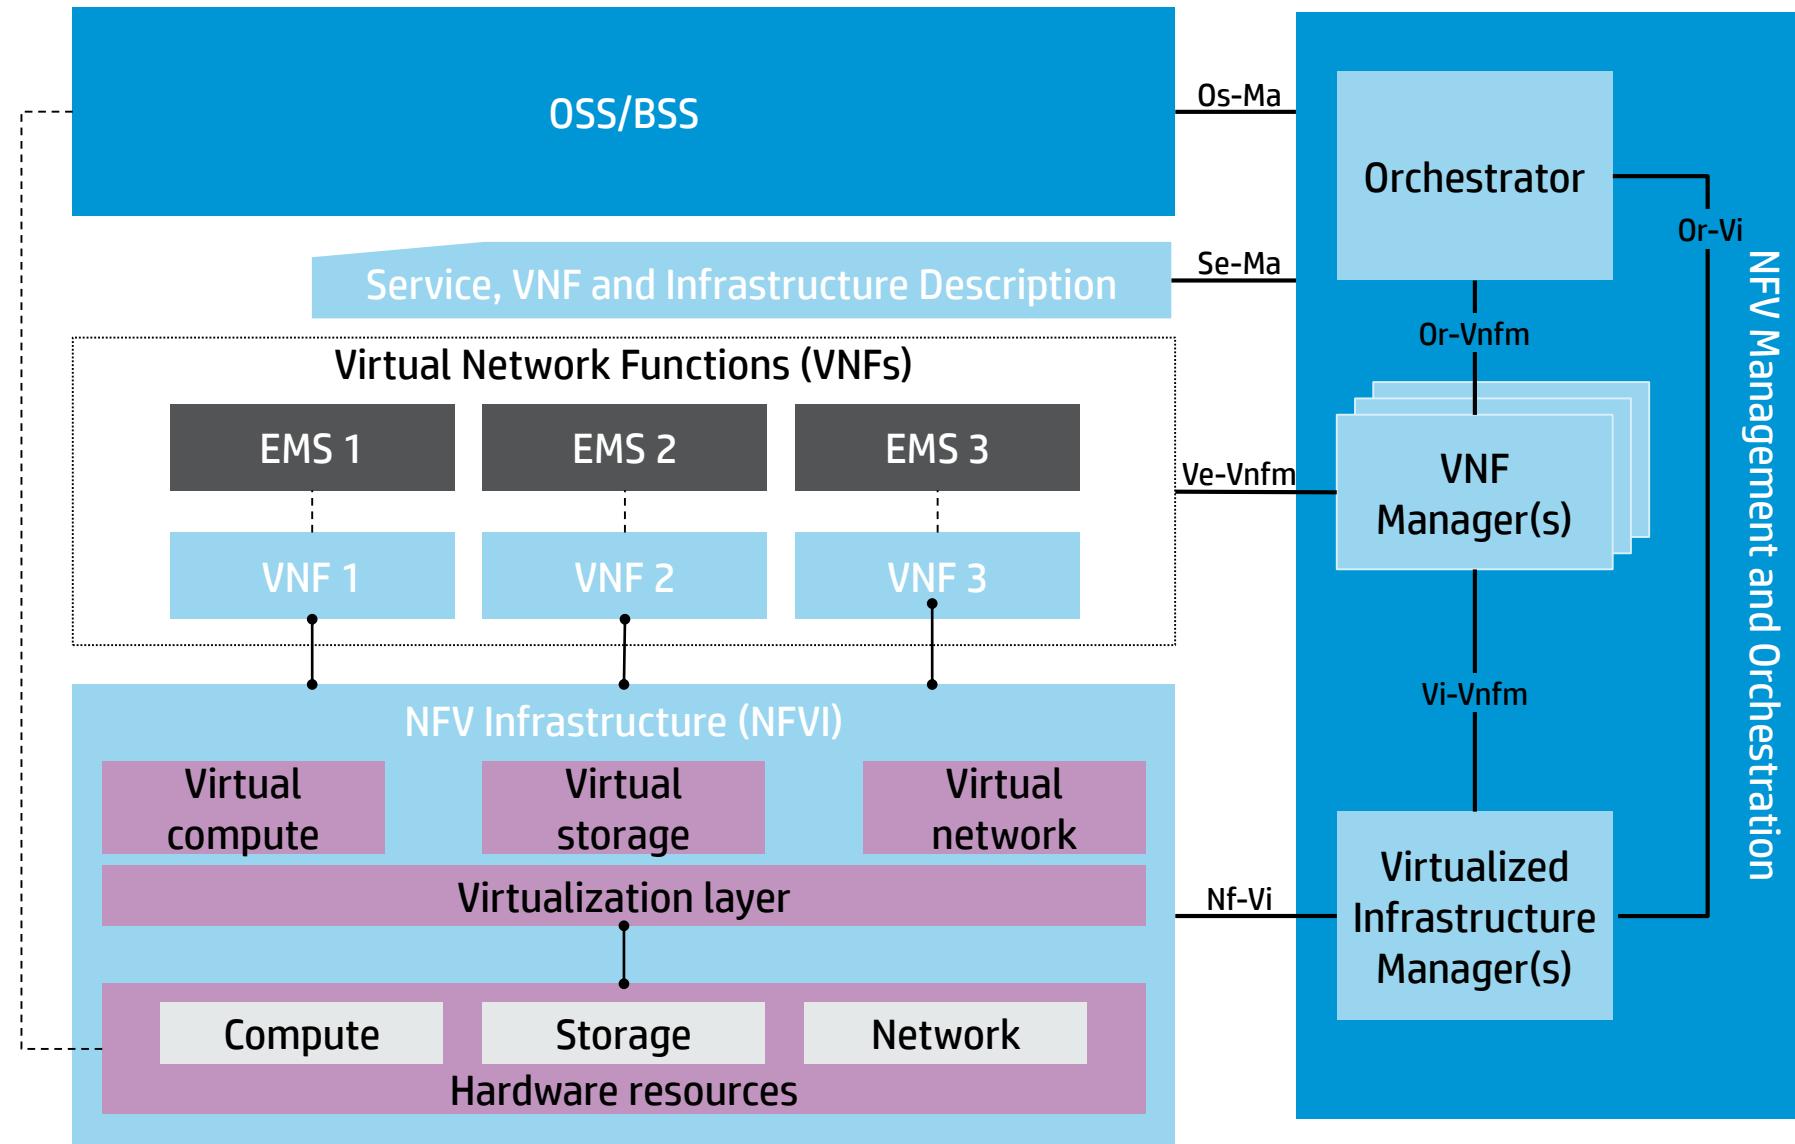
Software Appliances



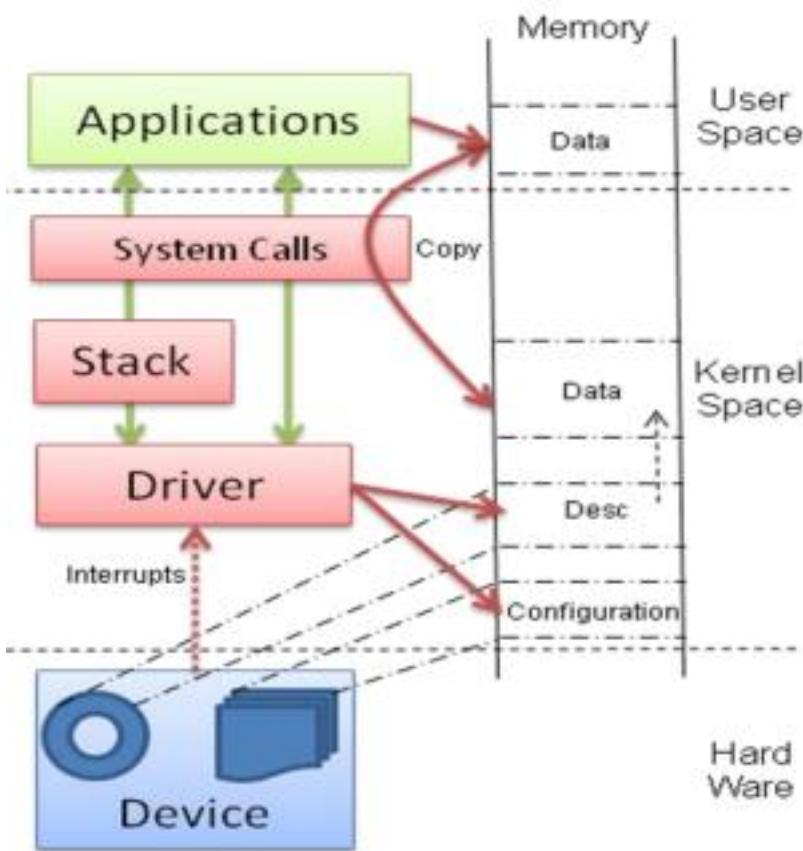
Praktické použití service chaining



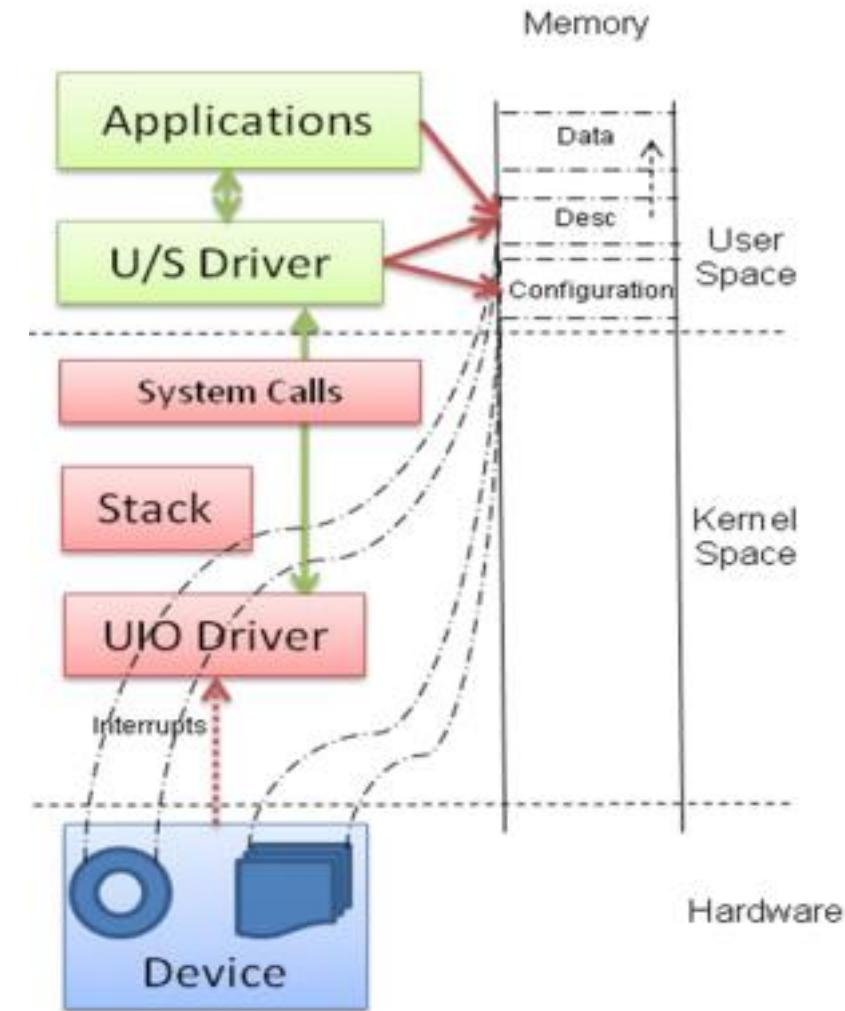
NFV architektura u operátoru



Přechody mezi kernel space a user space bolí

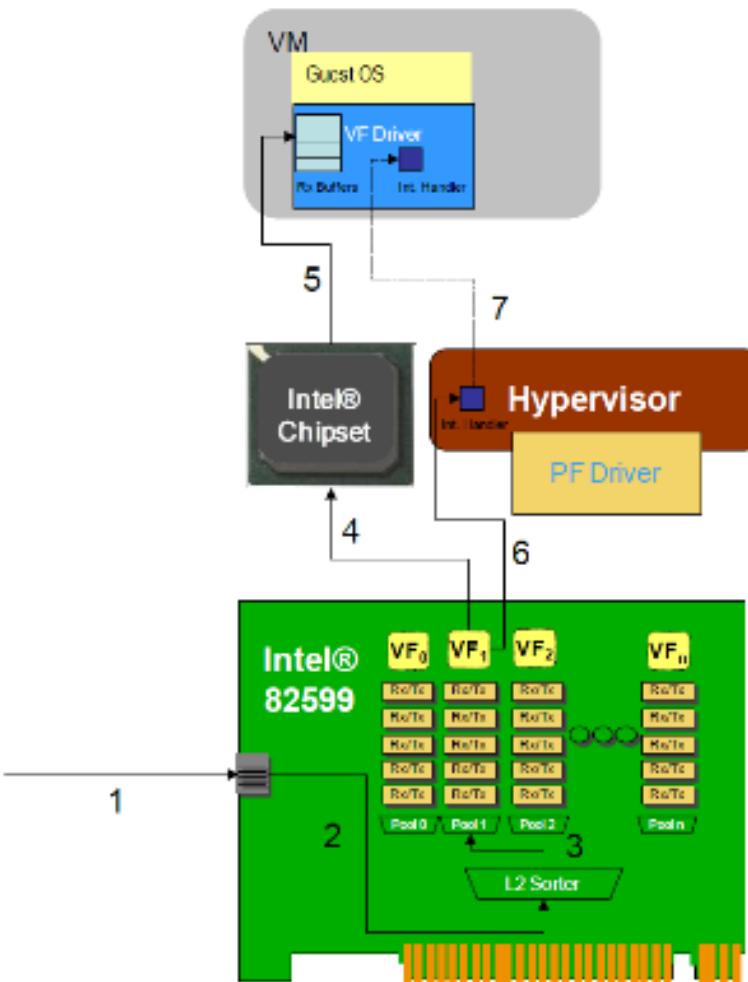


Kernel space network driver



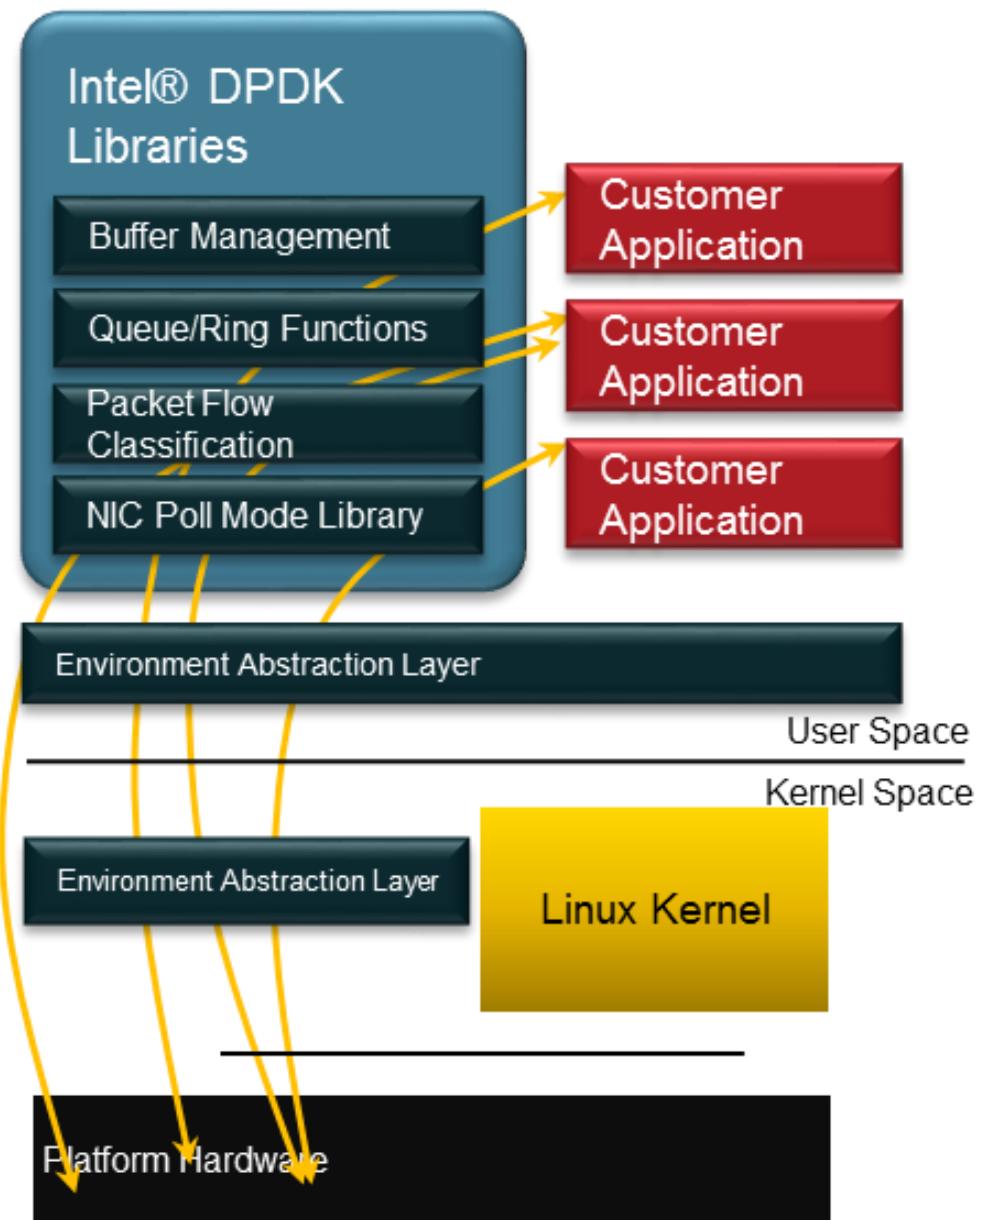
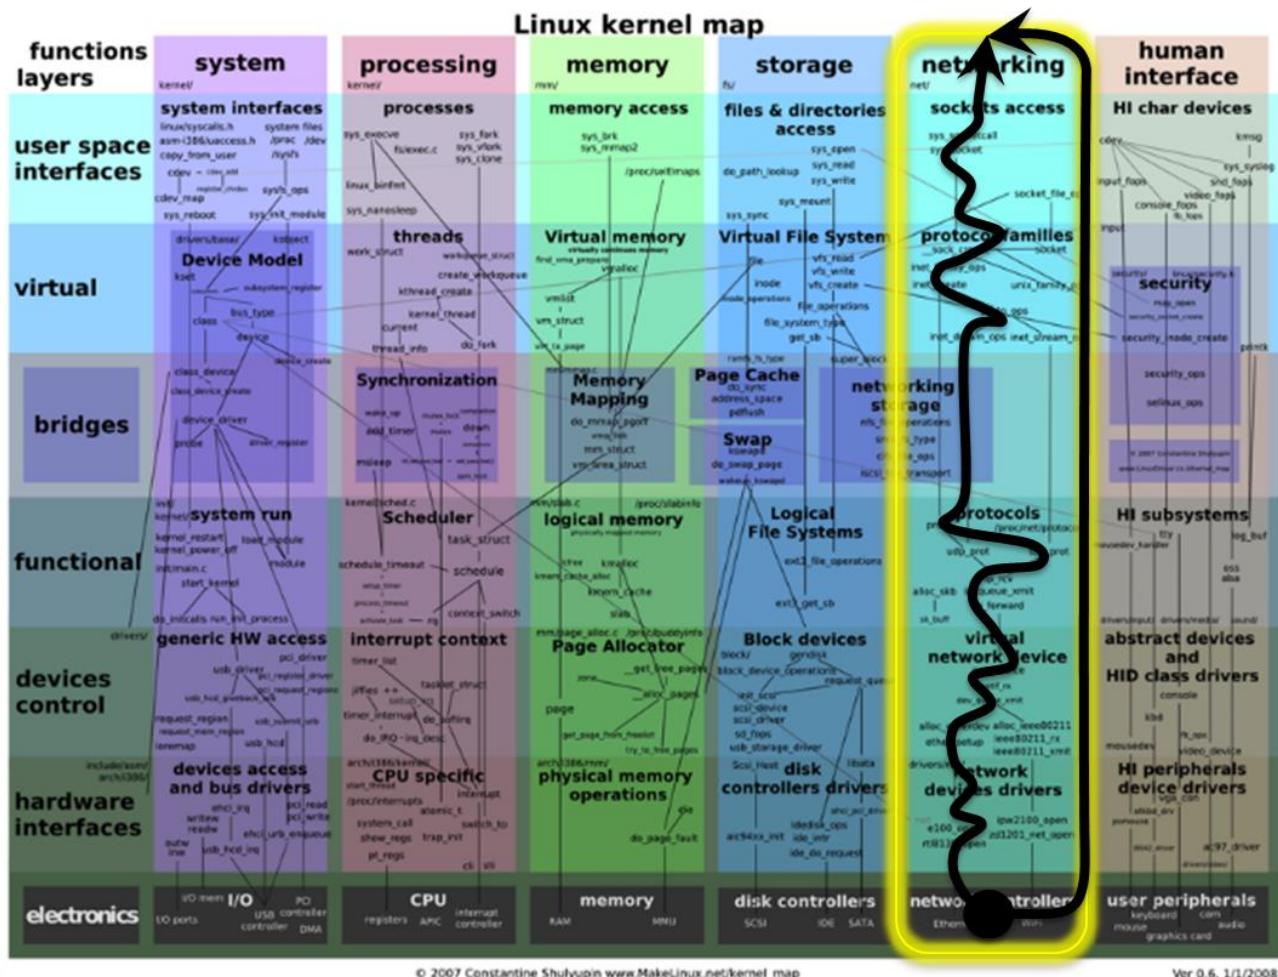
User space network driver

Hardwareová akcelerace – SR-IOV



- **Step 1 & 2:** Packet Arrives, sent to the L2 Sorter/Switch.
- **Step 3:** Packet is sorted based upon destination MAC address; in this case, it matches Pool/VF 1.
- **Step 4:** NIC initiates DMA action to move packet to VM
- **Step 5:** DMA action hits the Intel Chipset, where VT-d (configured by the Hypervisor) performs the required Address Translation, for the DMA operation; resulting in the packet being DMA'd into the VM's VF Driver buffers.
- **Step 6:** NIC posts MSI-X interrupt indicating a Rx transaction has been completed. This interrupt is received by the Hypervisor.
- **Step 7:** The Hypervisor injects a virtual interrupt to the VM indicating a Rx transaction has been completed, the VM's VF Driver then processes the packet.

Intel DPDK



Víte, že se s paketem v Linux jádře dějí docela věci?

Nemluvme jen o SDN.... ... Mluvme o nové síťarině

Software-defined Networking

Network Virtualization

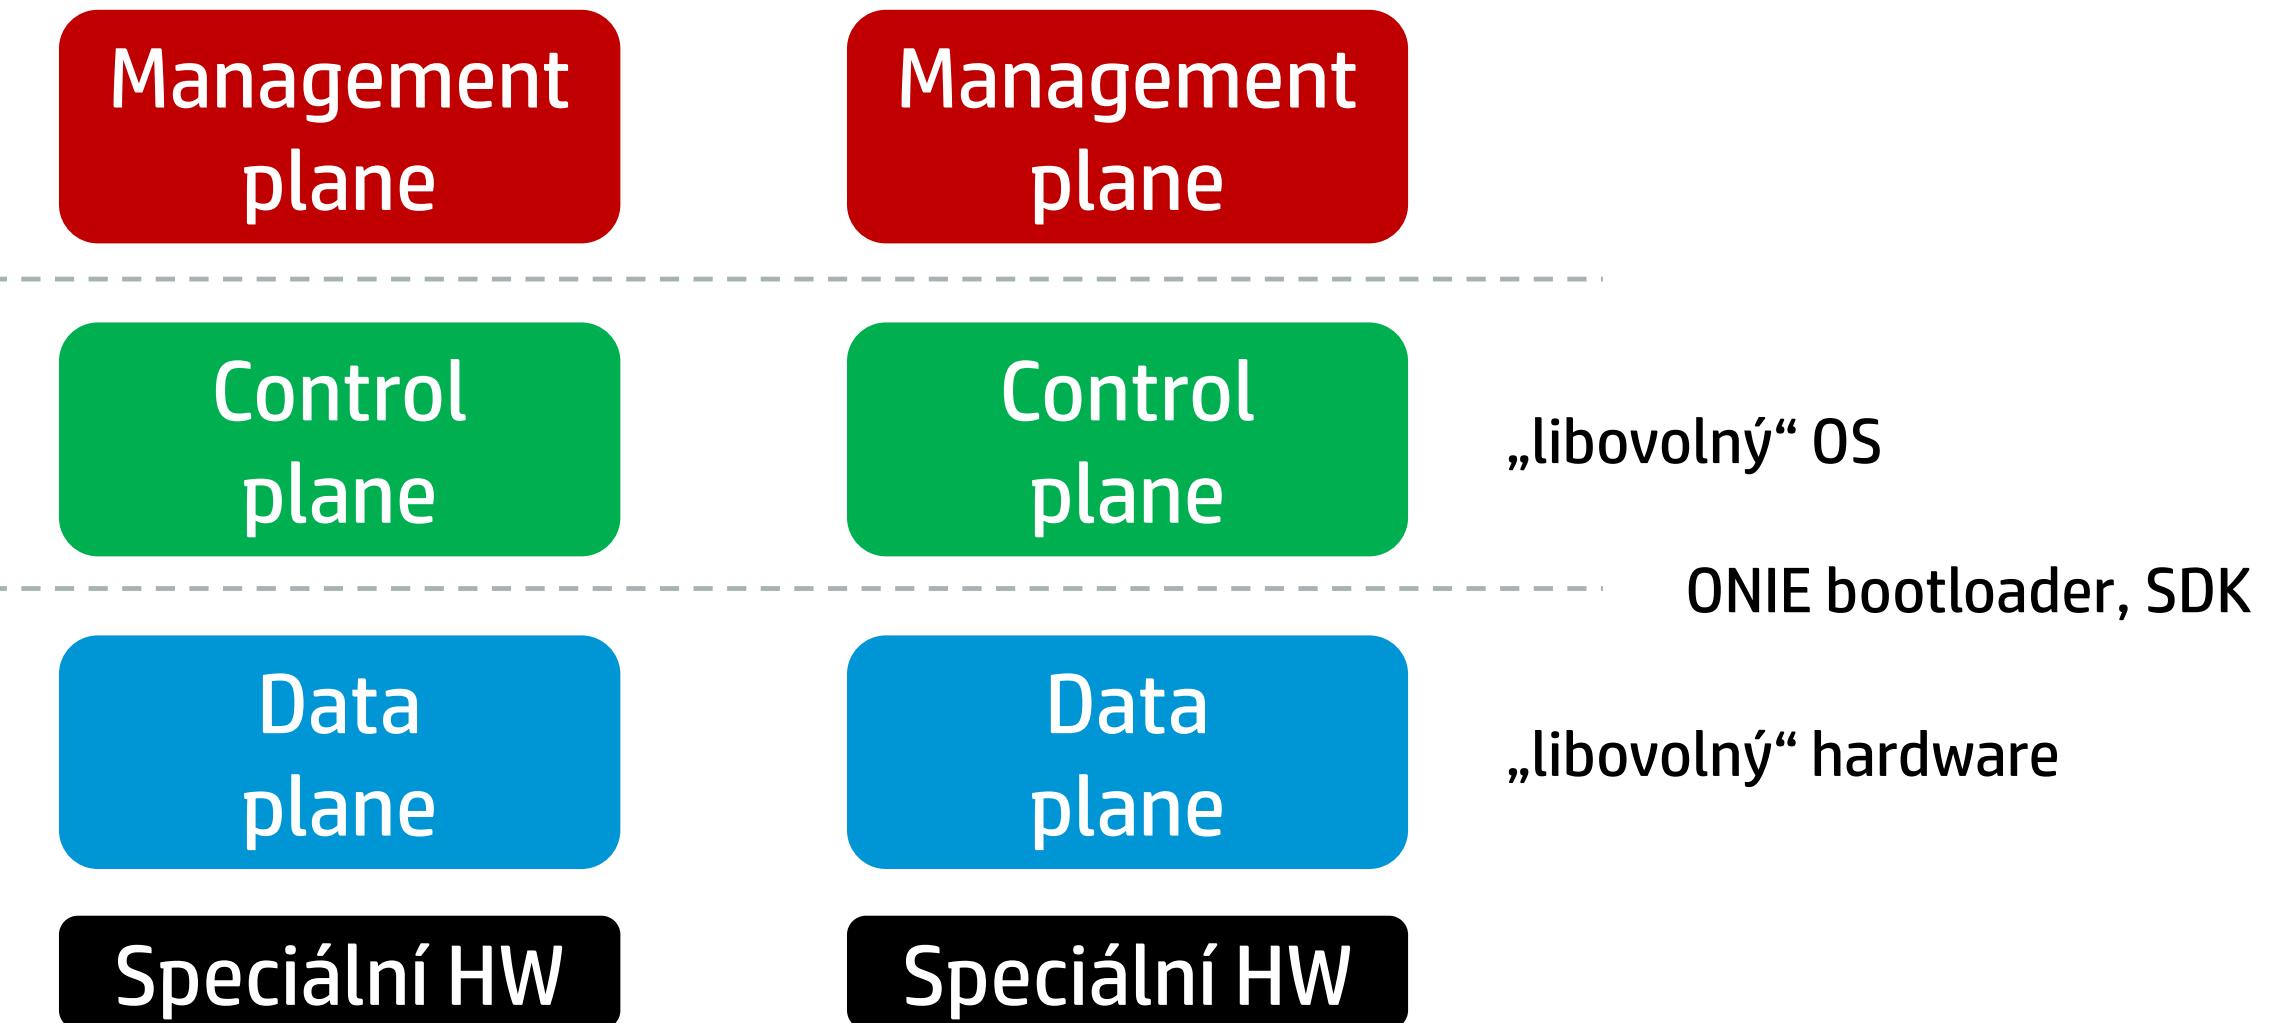
Network Function Virtualization

Disagregace

Open source

DevOps

Disagregované prvky (brite-box / white-box)



Nástroje a správa vendora

L2/L3 síťové protokoly

Operační systém vendora

Značkový integrovany box

ASIC nebo merchant silicon

Integrované sítě



Otevřená správa

Protokoly,
orchestrace



Volitelně SDN



Výběr OS, Linux, ...

Standardní rozhraní ([ONIE](#) Boot Loader)



Značkový nebo ODM box



Broadcom, Intel, ...

Disagregované sítě

Co trh nabízí?



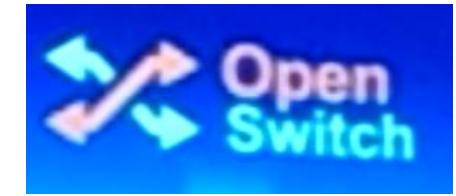
JUNIPER
NETWORKS



Brite-box



JUNIPER
NETWORKS



PICOS

OS



DNI



Accton



Quanta

White-box (ODM)



ASIC



Web-scale / hyper-scale sítě jsou jiné



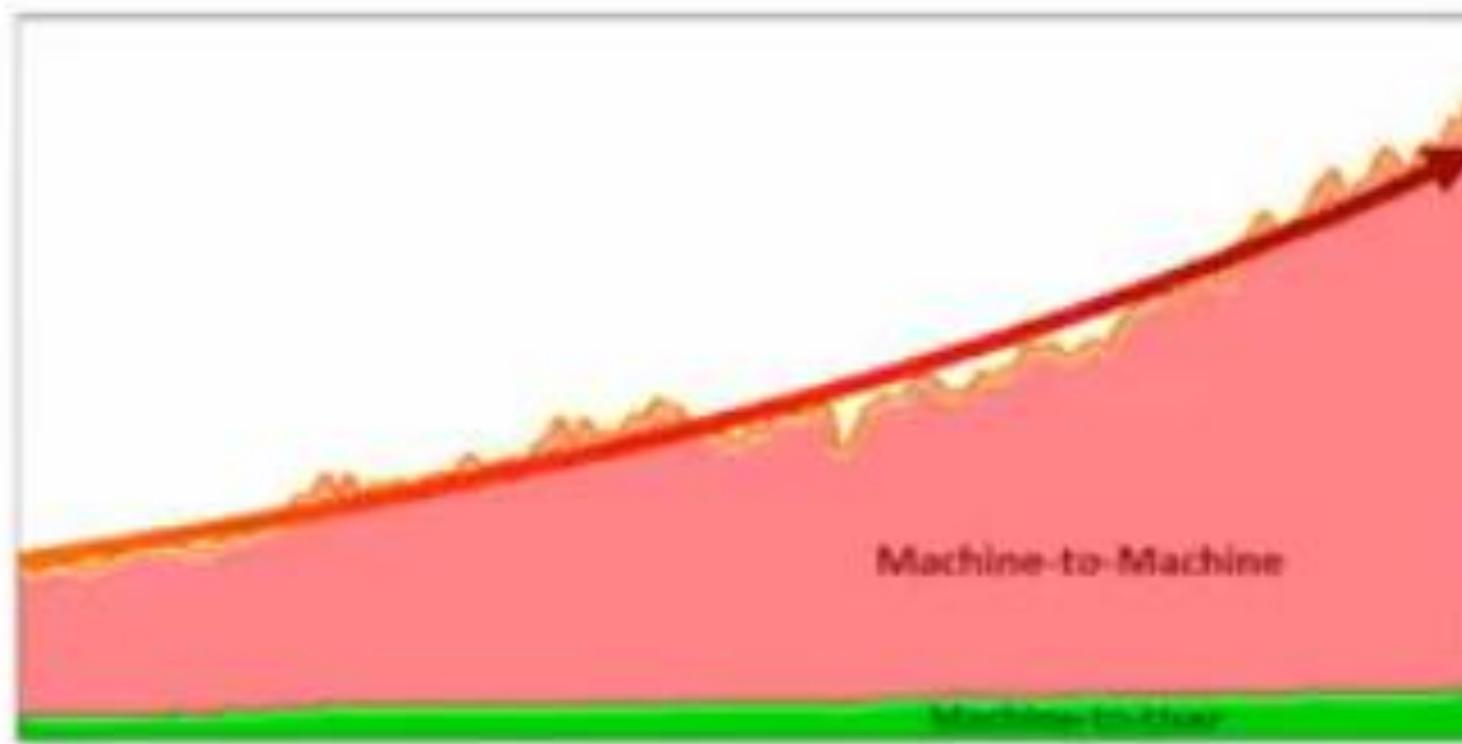
Source: Google and CBS.



Source: Facebook

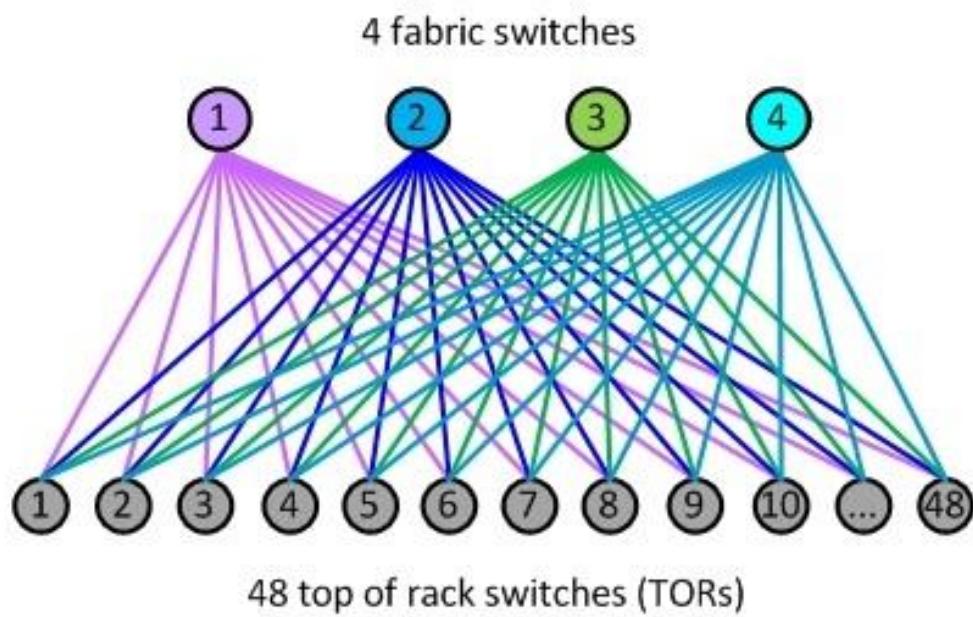
- Mnohem jednodušší sítě (CLOS, L3)
- Jednotný hardware (výnosy z rozsahu)
- Velmi modulární architektura pro rychlý růst
- Omezený set aplikací, vyladění sítě namíru
- Velmi časté změny, DevOps
- Extrémně školení a zdatní lidé

Naprostá většina provozu zůstává uvnitř DC

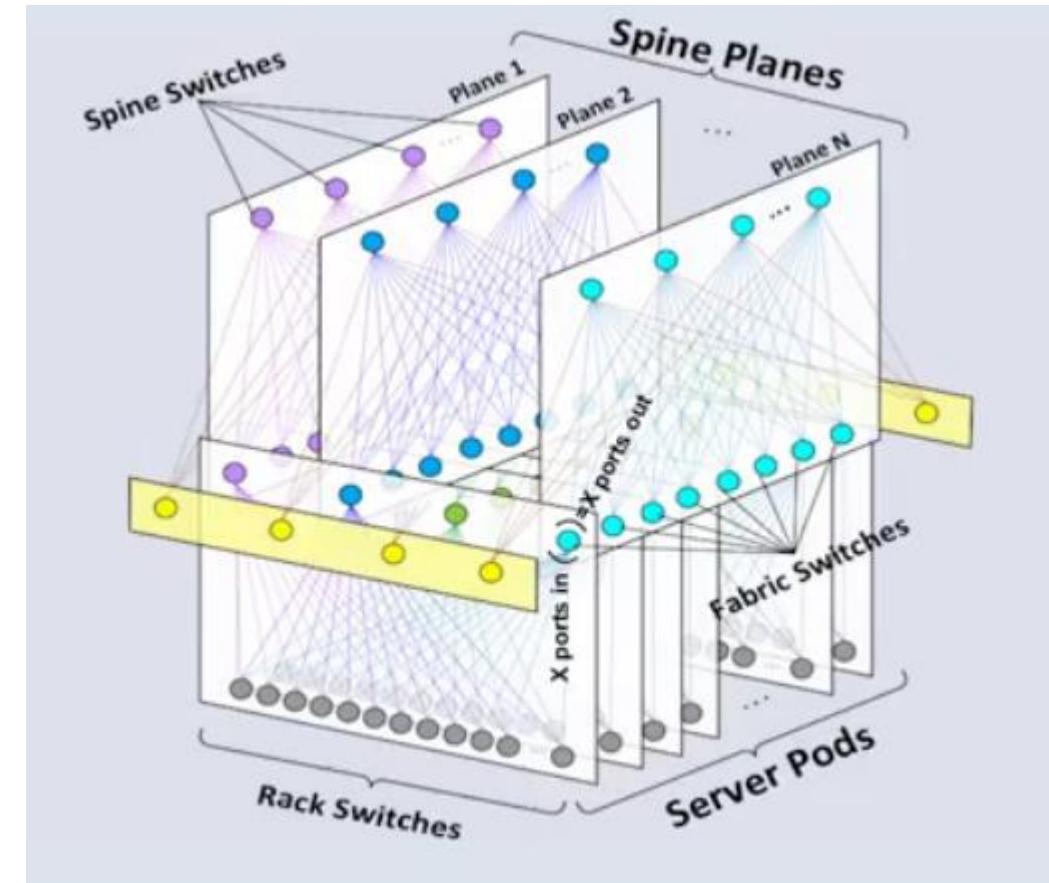


Příklad: Facebook

Facebook

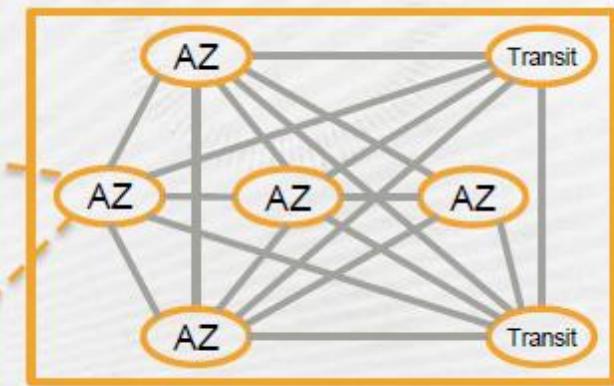
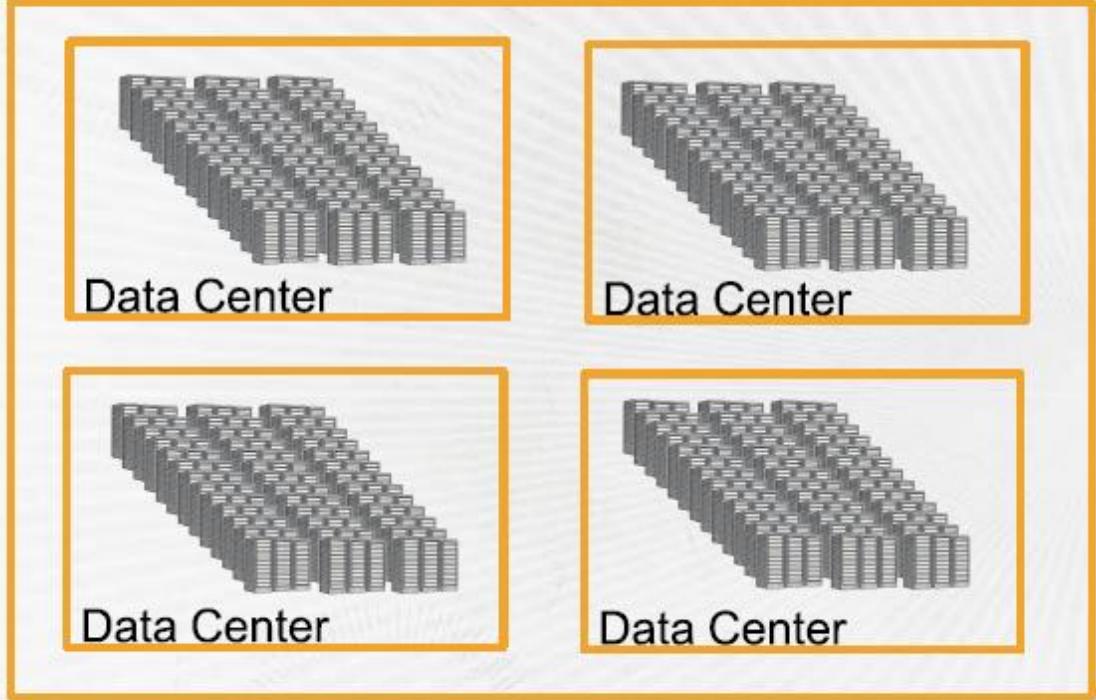


Source: Facebook.



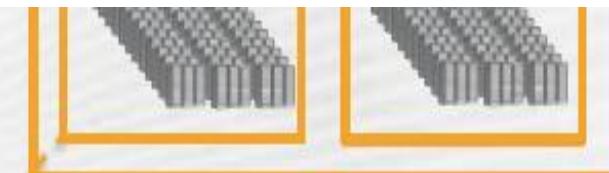
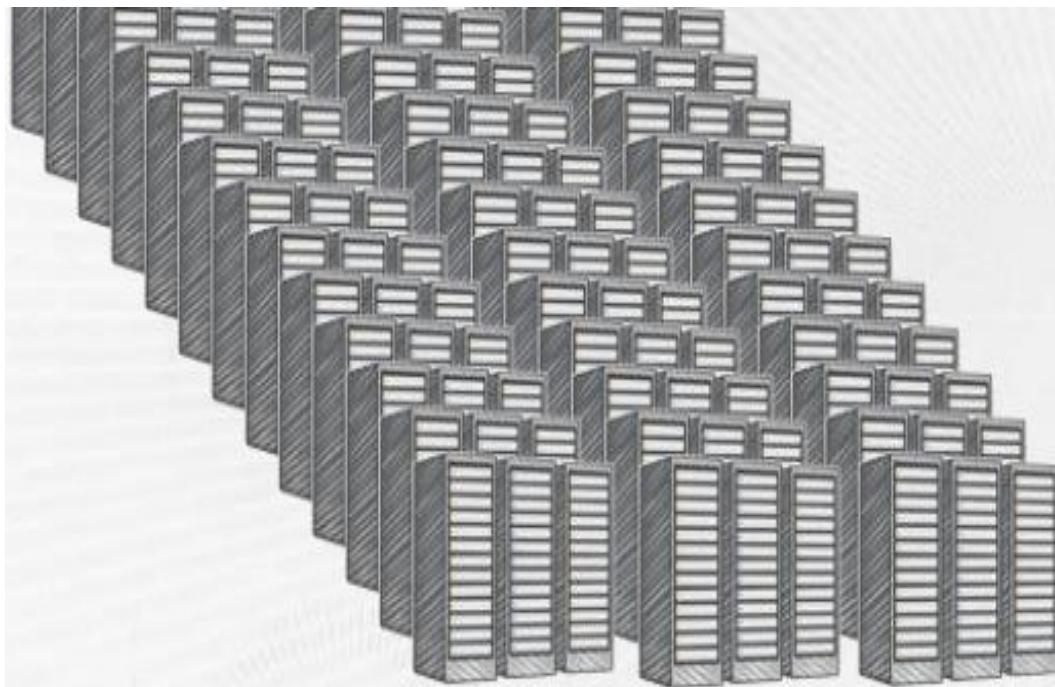
Stovky tisíc 10G portů, non-blocking rack-to-rack

Datové centrum Amazon AWS



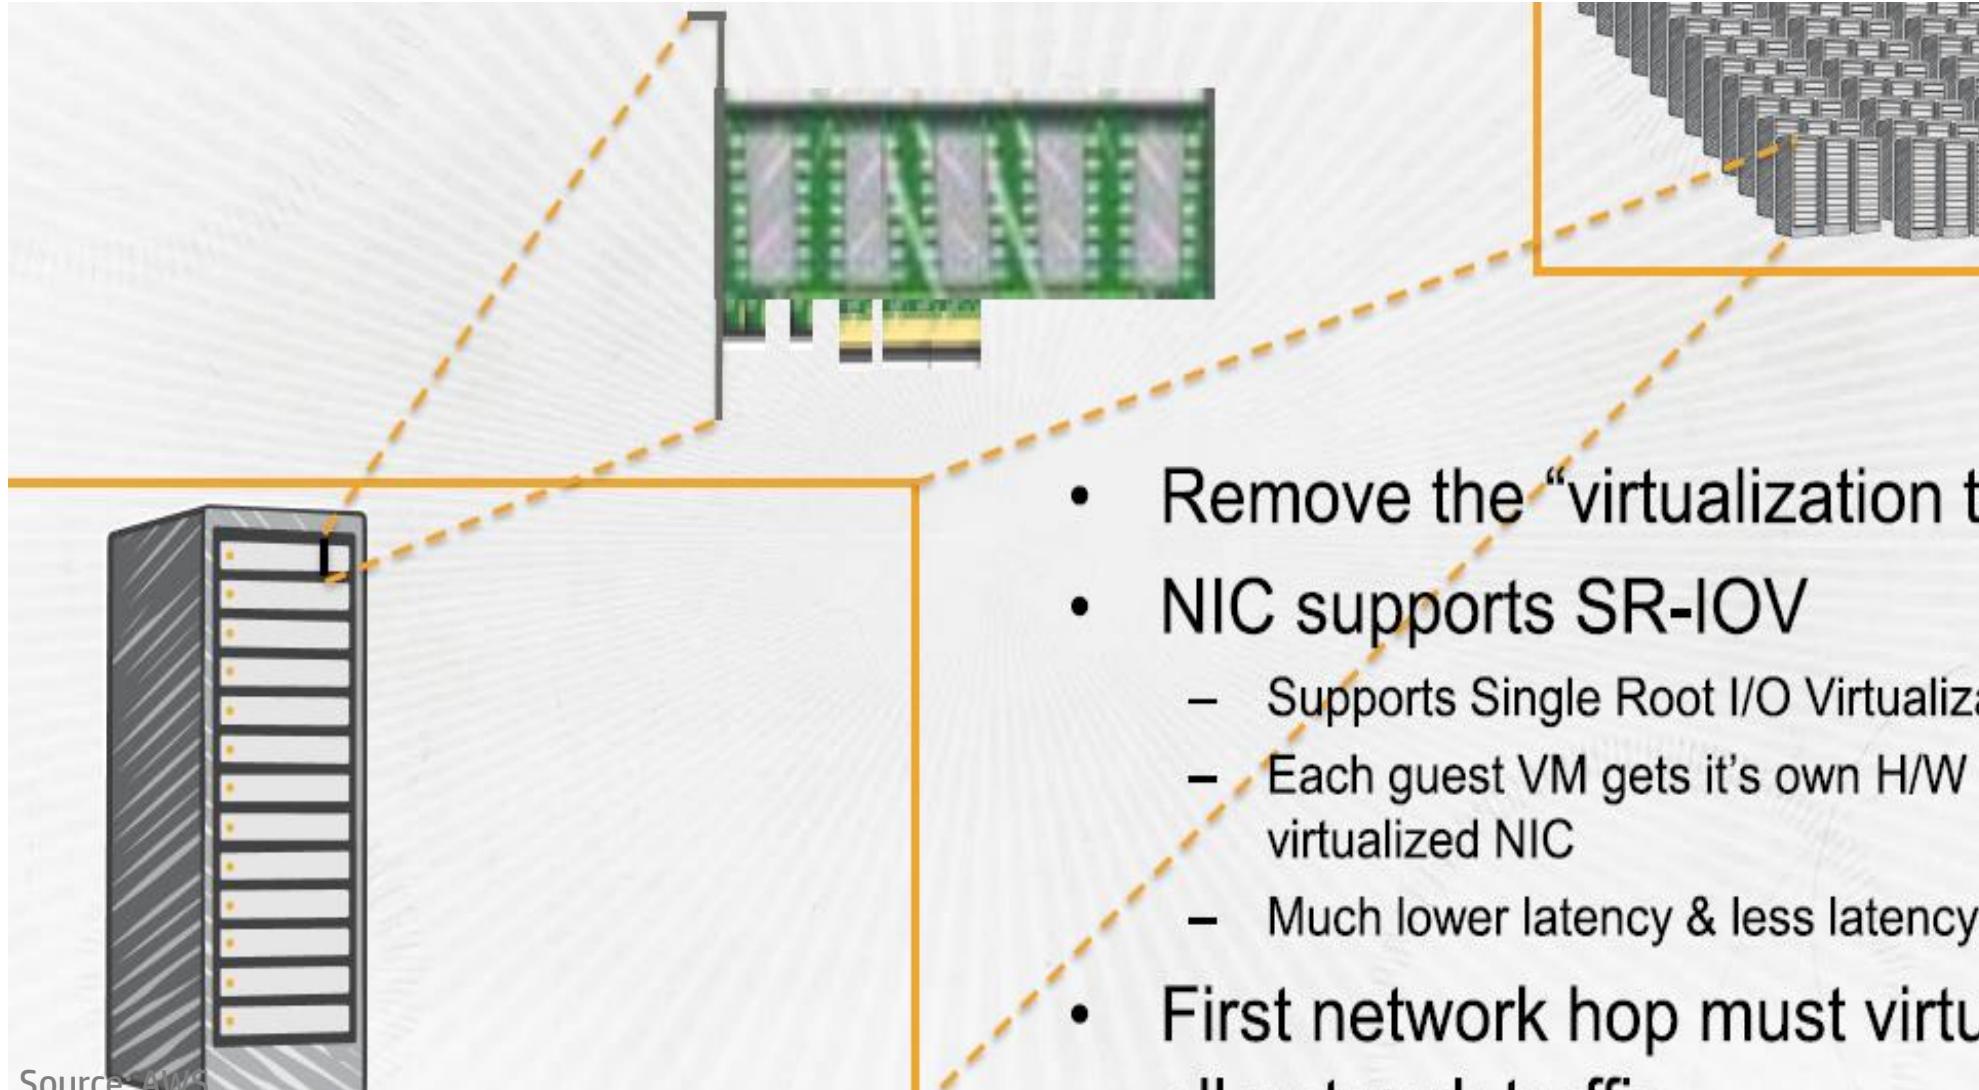
- 1 of 28 AZs world-wide
- All regions have 2 or more AZs
- Each AZ is 1 or more DC
 - No data center is in two AZs
 - Some AZs have as many as 6 DCs
- DCs in AZ less than $\frac{1}{4}$ ms apart
 - Don't need inter-AZ independence
 - Do require low latency & full B/W

Datové centrum Amazon AWS



- Single DC typically over 50,000 servers & often over 80,000
 - Larger DCs undesirable (blast radius)
- Up to 102Tbps provisioned to a single DC
- AWS custom network equipment:
 - Multi-ODM sourced

Datové centrum Amazon AWS



Nemluvme jen o SDN.... ... Mluvme o nové síťarině

Software-defined Networking

Network Virtualization

Network Function Virtualization

Disagregace

Open source

DevOps

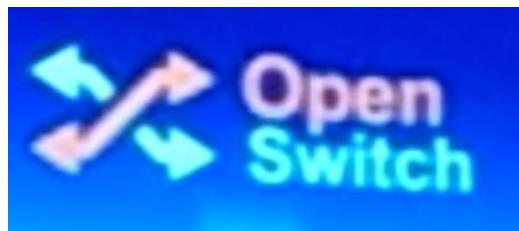


Hewlett Packard Enterprise

■ QOSMOS



Accton



Open Switch
První open source OS

Nemluvme jen o SDN.... ... Mluvme o nové síťarině

Software-defined Networking

Network Virtualization

Network Function Virtualization

Disagregace

Open source

DevOps

CI/CD a Infrastructure as code

Co to znamená pro síť?

Síť uvádíte do požadovaného stavu jeho popisem

Např. YAML playbook v Ansible

Dokumentací sítě je Infrastructure as code

Místo obrázku manifest/YAML, který lze spustit a stav vynutit

Manifest je ve version control systému

Všechno musí být například v Git nebo SVN

Nejsou přípustné jiné ruční změny konfigurace

Change se implementuje změnou manifestu, ne přímo přes SSH

CI/CD a Infrastructure as code

Proč?

Daleko méně chyb a nekonzistencí

Je dokázáno, že člověk ve stejné roli udělá daleko víc chyb

Skutečný stav vždy odpovídá záměru a dokumentaci

Dokumentace není na čtení, není špatně pochopena nebo neprovedena, je živá

Bezpečák je naprosto nadšený

Všechny změny jsou evidované včetně osob a na jednom místě

Vždy to dopadne stejně (Dobře? Špatně? Opakovatelně.)

Pokud se desired state rozhodí (výměna odumřelého boxu), snadno ho vrátíte zpět bez chyb

CI/CD a Infrastructure as code

Co je co a co je vhodné pro networking?

Configuration Management

Ansible
Salt
Chef
Puppet

Version Control

Git
SVN

Interface

prvků
RESTful
NETCONF
OpenFlow
SNMP
CLI

Review Control

Gerrit

NetVirt

OpenStack Heat
Docker SocketPlane
Docket libnetwork
DCN/Nuage
NSX
Contrail

CI/CD automation

Jenkins

Ukažme si Ansible v praxi na „nejmenovaném“ prvku

Pozn.: potřebujete od výrobce moduly, tedy jakési
drivery a příkazy

Soubor s proměnnými, abych měl důležité informace na jednom místě

```
vlans:
  - id: 10
    name: Finance
    leftip: 10.10.0.1
    rightip: 10.10.0.2
    mask: 255.255.255.0
    vip: 10.10.0.254

  - id: 20
    name: HR
    leftip: 10.20.0.1
    rightip: 10.20.0.2
    mask: 255.255.255.0
    vip: 10.20.0.254

  - id: 30
    name: Printers
    leftip: 10.30.0.1
    rightip: 10.30.0.2
    mask: 255.255.255.0
    vip: 10.30.0.254

  - id: 40
    name: Guests
    leftip: 10.40.0.1
    rightip: 10.40.0.2
    mask: 255.255.255.0
    vip: 10.40.0.254
```

```
[all:vars]
username=admin
password=admin

[core]
10.0.0.11
10.0.0.12

[leftcore]
10.0.0.11

[rightcore]
10.0.0.12

[leftcore:vars]
vrrp_priority=250
ISL_port=GigabitEthernet2/0

[rightcore:vars]
vrrp_priority=100
ISL_port=GigabitEthernet2/0
```

Hosts file, tedy seznam prvků v síti, jejich role, login

Můj playbook

```
- name: Configure basics on all devices
hosts: all
gather_facts: no
connection: local
vars_files:
  - vlans.yml

tasks:
  - xxx_facts: username={{ username }} password={{ password }}
    hostname={{ inventory_hostname }}

  - name: Turn on LLDP
    xxx_command:
      command:
        - lldp global enable
      type: config
      username: "{{ username }}"
      password: "{{ password }}"
      hostname: "{{ inventory_hostname }}"

  - name: ensure VLANs exist
    xxx_vlan:
      vlanid: "{{ item.id }}"
      state: present
      name: "{{ item.name }}"
      username: "{{ username }}"
      password: "{{ password }}"
      hostname: "{{ inventory_hostname }}"
    with_items:
      "{{ vlans }}"

- name: Configure core devices
hosts: core
gather_facts: no
connection: local
vars_files:
  - vlans.yml

tasks:
  - name: ensure L3 VLAN interfaces exist
    xxx_interface:
      state: present
      name: Vlan-interface{{ item.id }}
      username: "{{ username }}"
      password: "{{ password }}"
      hostname: "{{ inventory_hostname }}"
    with_items:
      "{{ vlans }}"

  - name: Configure inter-switch link port type
    xxx_interface:
      name: "{{ ISL_port }}"
      type: bridged
      username: "{{ username }}"
      password: "{{ password }}"
      hostname: "{{ inventory_hostname }}"

  - name: Enable all VLANs on ISL
    xxx_switchport:
      name: "{{ ISL_port }}"
      link_type: trunk
      permitted_vlans: "1-1000"
      username: "{{ username }}"
      password: "{{ password }}"
      hostname: "{{ inventory_hostname }}"
```

Můj playbook

```
- name: Configure LEFT core device
  hosts: leftcore
  gather_facts: no
  connection: local
  vars_files:
    - vlans.yml

  tasks:

    - name: ensure IP information is configured
      xxx_ipinterface:
        state: present
        name: Vlan-interface{{ item.id }}
        addr: "{{ item.leftip }}"
        mask: "{{ item.mask }}"
        username: "{{ username }}"
        password: "{{ password }}"
        hostname: "{{ inventory_hostname }}"
      with_items:
        - "{{ vlans }}"

    - name: configure VRRP instances
      xxx_vrrp:
        vrid: "{{ item.id }}"
        vip: "{{ item.vip }}"
        priority: "{{ vrrp_priority }}"
        interface: Vlan-interface{{ item.id }}
        username: "{{ username }}"
        password: "{{ password }}"
        hostname: "{{ inventory_hostname }}"
      with_items:
        - "{{ vlans }}"

- name: Configure RIGHT core device
  hosts: rightcore
  gather_facts: no
  connection: local
  vars_files:
    - vlans.yml

  tasks:

    - name: ensure IP information is configured
      xxx_ipinterface:
        state: present
        name: Vlan-interface{{ item.id }}
        addr: "{{ item.rightip }}"
        mask: "{{ item.mask }}"
        username: "{{ username }}"
        password: "{{ password }}"
        hostname: "{{ inventory_hostname }}"
      with_items:
        - "{{ vlans }}"

    - name: configure VRRP instances
      xxx_vrrp:
        vrid: "{{ item.id }}"
        vip: "{{ item.vip }}"
        priority: "{{ vrrp_priority }}"
        interface: Vlan-interface{{ item.id }}
        username: "{{ username }}"
        password: "{{ password }}"
        hostname: "{{ inventory_hostname }}"
      with_items:
        - "{{ vlans }}"
```

Můj playbook

```
- name: Save configurate on all devices
hosts: all
gather_facts: no
connection: local
vars_files:
  - vlans.yml

tasks:

  - name: save configuration to flash
    xxx_save:
      username: "{{ username }}"
      password: "{{ password }}"
      hostname: "{{ inventory_hostname }}"
```

```
root@ubuntu:~/ansible-demo# ansible-playbook -i hosts tomas.yml
```

Nemluvme jen o SDN.... ... Mluvme o nové síťařině

Software-defined Networking
Network Virtualization
Network Function Virtualization
Disagregace
Open source
DevOps



Nemluvme jen o SDN.... ... Mluvme o tom, jak na to

- Na nic nečekejte, „Uber“ pro váš trh může přijít kdykoli
- Založte innovation labs nebo bimodal IT
- Kontinuita a stávající předpoklady jsou důležité pro provoz, ale svazující pro design a rozvoj váš i vaší sítě
- A především: čtěte cloudsvet.cz ☺

Tomáš Kubica a Daniel Prchal
Hewlett-Packard Enterprise