

# Arhitekture omrežij za podatkovne centre

Zasnovane s stikali zgrajenimi s standardnimi SoC

©2015 Xenya – Peter Reinhardt  
[peter.reinhardt@xenya.si](mailto:peter.reinhardt@xenya.si)

XENYA

# Novi trendi v Podatkovnih centrih (PC)

- ▶ Virtualizacija aplikacij in storitev
  - Zagotavlja neodvisnost od HW, enstaven backup, optimizacija porabe resursov ....
- ▶ Centralizacija aplikacij in storitev (cloud, private cloud ...)
- ▶ Zmanševanje porabe energije
- ▶ Neodvisnost od proizvajalcev strojne opreme, več virov strojne opreme
- ▶ Enovita skladisčna in podatkovna omrežja
- ▶ Avtomatizirani postopki upravljanja (orkestracija)

# Novi trendi v izvedbi in upravljanju omrežij

- ▶ Dinamično prilagajanje omrežja aplikacijam
  - Dinamično kreiranje VLANov hkrati s kreiranjem/selitvijo VM
- ▶ Orkestracija - Odprte rešitve, neodvisne od strojne opreme, ki omogočajo poenostavitev upravljanja standardnih nalog in integracijo upravljanja strežnikov in omrežja
- ▶ SDN – Funkionalna Delitev Nadzorne in Podatkovne ravni v omrežjih, centralizacija Nadzorne ravni v zunanji SW krmilnik, aplikativni nadzor obnašanja omrežja
  - OpenFlow, OpenAPI
- ▶ Virtualizacija omrežnih komponent – Del funkcij omrežja se seli na strežnike v obliki virtuelnih stikal, usmerjevalnikov, požarnih pregrad, load balancerjev ...., Omrežje dobi dodatne konfiguracijske (aplikativne) podatke iz virtuelnih stikal.

# Novi trendi v izvedbi IP omrežij PC

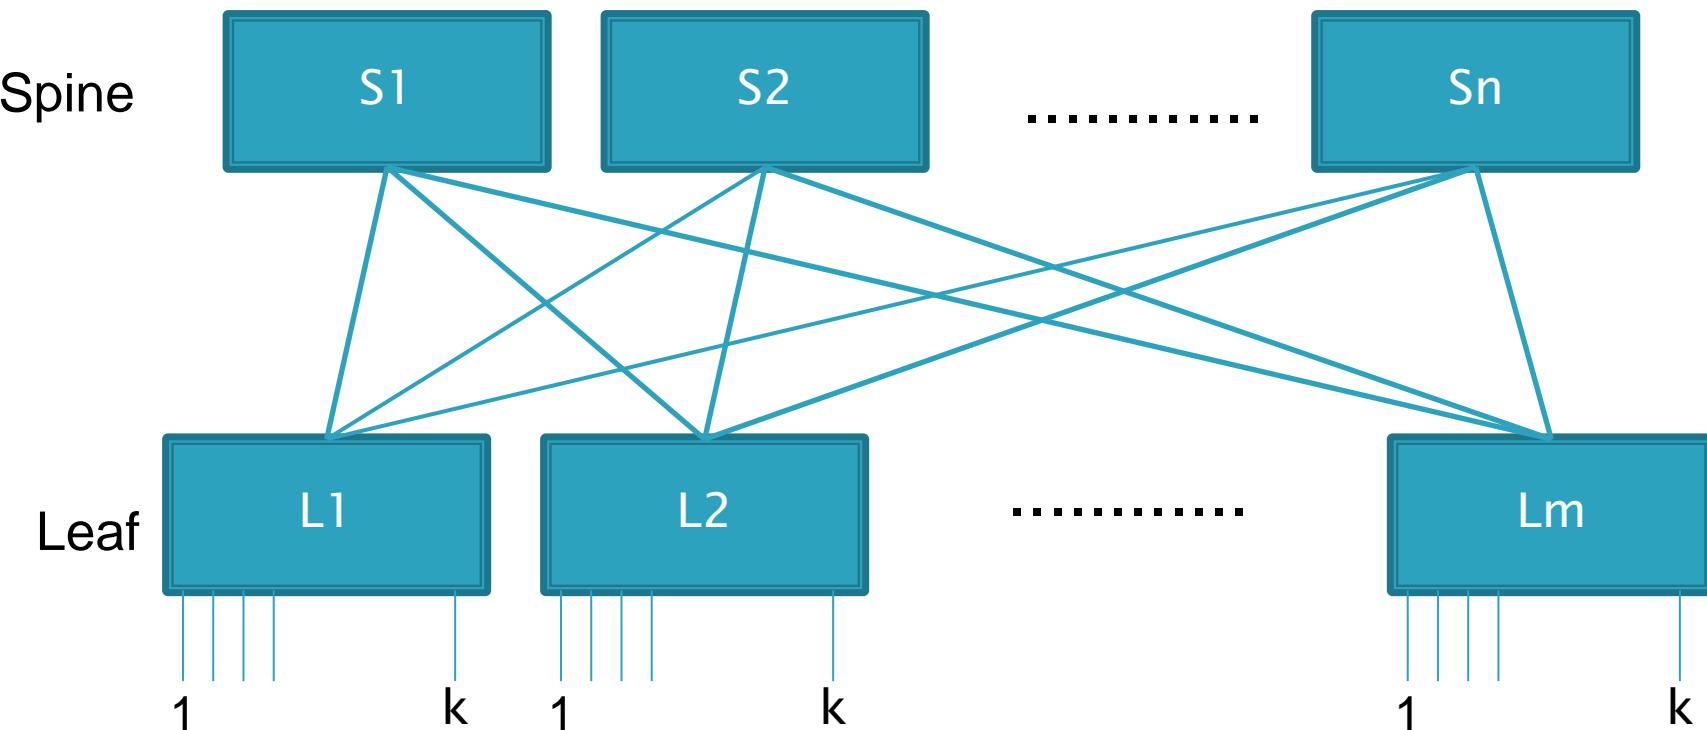
- ▶ Velike hitrosti prenosa in prepustnosti komunikacijskega omrežja
  - Vmesniki proti klijentom 10G, 40G in 25G, vmesniki v hrbtenici 40G in 100G
  - Velika prepustnost za komunikacijo znotraj podatkovnega centra - horizontalna komunikacija (Oversubscription od 1:6 do 1:1)
  - Majhne zakasnitve in ultra majhne zakasnitve, ....
- ▶ Enotna struktura omrežja v celotnem Podatkovnem centru (PC)
  - “Fabric” omrežja – enaka pasovna širina, enake zakasnitve med priključki
  - Podpira enostavno optimizacijo uporabe resursov
- ▶ Zagotavljanje redundance z izborom arhitekture & protokolov v PC, ne z uporabo kompleksnih komponent, ki že same zagotavljajo redundanco
  - Boljše razmerje sposobnosti/cena, Hitrejše prilagajanje novim tehnologijam, nižja poraba energije, nizja cena ...
- ▶ Nove arhitekture - (spine&leaf), virtuelne komponente, SDN ...
- ▶ Overlay protokoli
  - npr. za tuneliranje L2 nad L3 (TRILL, VXLAN, NVGRE...)
- ▶ Novi protokololi za podporo enovitim omrežjem - učinkovito prenašajo klasične mrežne protokole in skladiščne protokole (FCoE) – DCB

# Fizični del omrežja pod. centra

- ▶ Lastnosti Spine/Leaf arhitekture (primerne za več kot 4 stikala)
  - Izpoljuje vse zahtevane komunikacijske lastnosti:
    - visoka prepustnost, vsi priključki imajo isto pasovno širino, iste zakasnitve (Fabric)
  - Enostavno vzdrževanje:
    - Ena ali dva tipa standardnih stikal sestavljajo celo omrežje
  - Redundantna zasnova
    - Omejen vpliv okvare na povezavi/stikalu
  - Razširljivo do zelo velikih omrežij ....
  - Nizka poraba energije
- ▶ Glavni parametri za konstrukcijo:
  - Hitrost priključka
  - Število priključkov
  - Razmerje agregirane pasovne širine vseh priključkov klijentov proti agregirani pasovni širini povezav navzgor – Oversubscription
  - Izjemoma tudi zahtevana Latenca

# Arhitekture Spine/Leaf

## ► Spine / Leaf



Število priključkov:  
Oversubscription:  
Pasovna širina:

$$N_C = m * k$$
$$OSR = K * S_C / n * S_{up}$$
$$S_T = S_{up} * n$$

# Nekaj Primerov izvedenih s 3 tipi stikal

## ▶ LY2R

- 48 x ..... 1x10Gb (SFP+) ali 1x1Gb (SFP) in
- 4 x ..... 1x40Gb ali 4x10Gb (QSFP+)

## ▶ LY6

- 32x ..... 1x40Gb ali 4x10Gb (QSFP+)

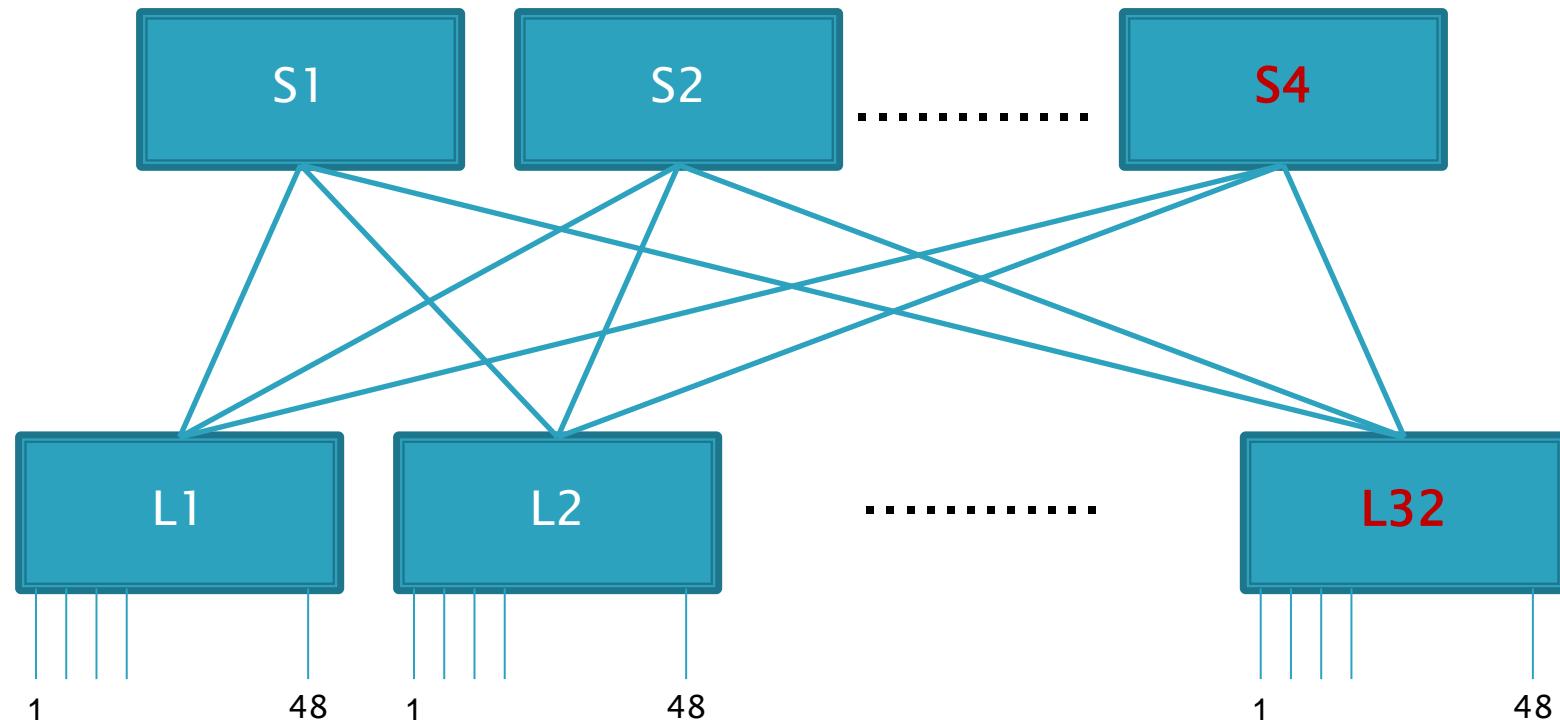
## ▶ IX1

- 32 x ..... 1x100Gb, 2x50Gb, 2x40Gb, 4x25Gb (QSFP28)

# Spine /Leaf – Primer 1

Stikala: Leaf: (LY2R) 48x1/10Gb+ 4x40Gb

Spine: (LY6) 32x40Gb

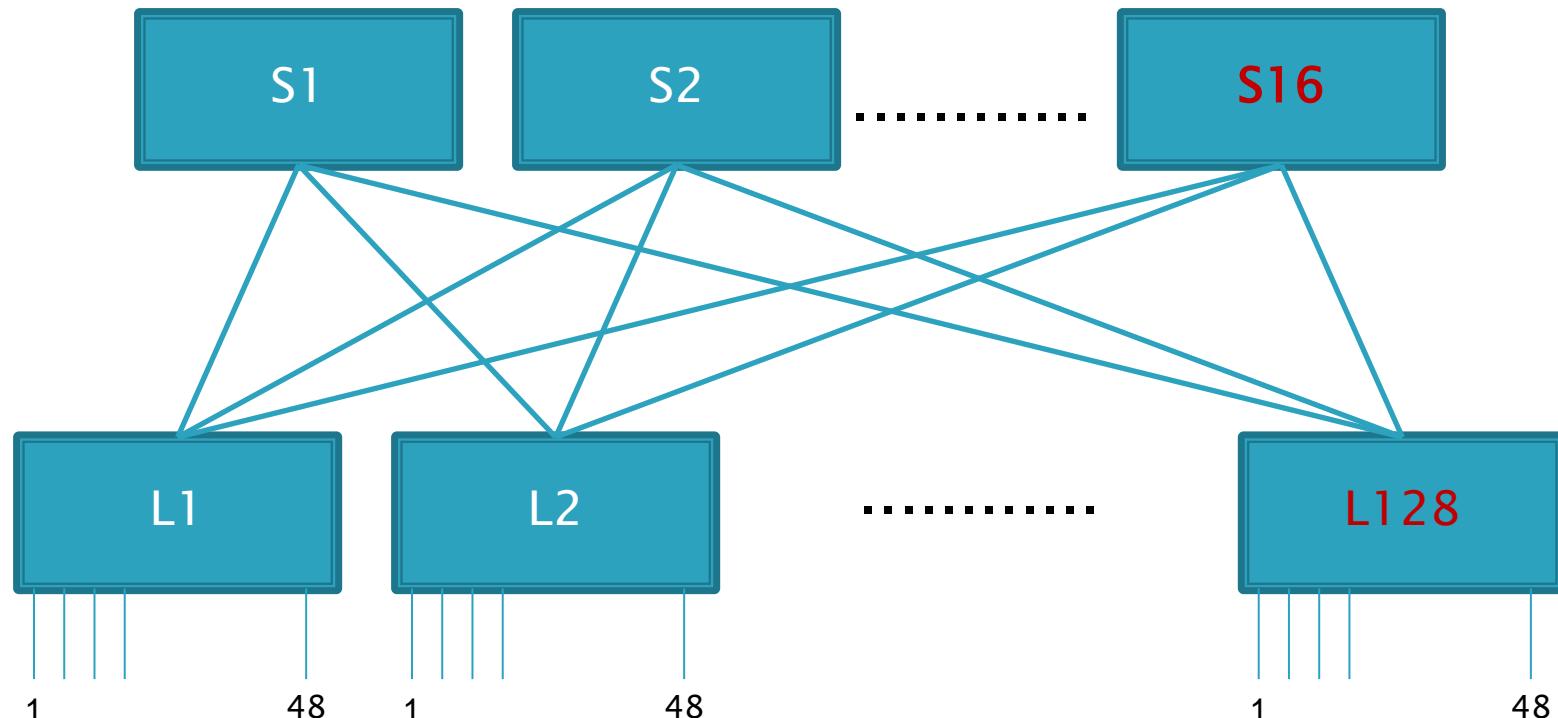


Število priključkov (10Gb)       $N_C = 32 \cdot 48 = 1536$   
Oversubscription                         $OSR = 48 \cdot 10 / 4 \cdot 40 = 3$   
Pasovna širina                         $S_T = 160 \text{Gb}$

# Spine /Leaf – Primer 2

(enaka stikala kot v primeru 1, drugačna vezava )

Stikala: Leaf: (LY2R) 48x10Gb + 4x40Gb uporabljeni kot 16x10Gb (LY1R)  
Spine: (LY6) 32x40Gb kot 32x4x10Gb



Število priključkov  
Oversubscription  
Pasovna širina

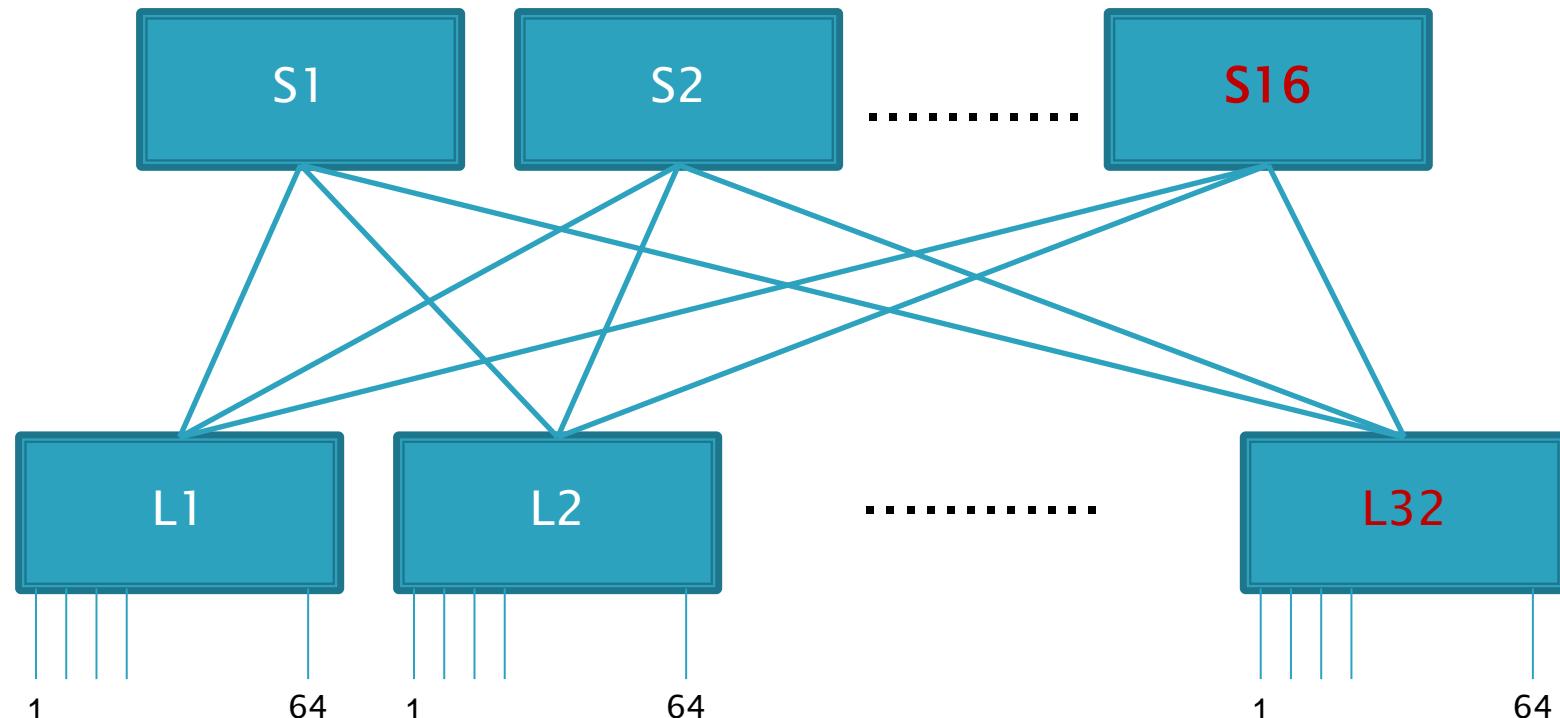
$$N_C = 128 \cdot 48 = 6144$$
$$OSR = 48 \cdot 10 / 16 \cdot 10 = 3$$
$$S_T = 160 \text{Gb}$$

# Spine /Leaf – Primer 3

## No Oversubscription

Stikala: Leaf: (LY6) 32x40Gb uporabljeni kot 16x40Gb + 64x10Gb

Spine: (LY6) 32x40Gb



Število priključkov (10Gb)

Oversubscription

Pasovna širina

$$N_C = 32 \times 64 = 2048$$

$$OSR = 64 \times 10 / 16 \times 40 = 1$$

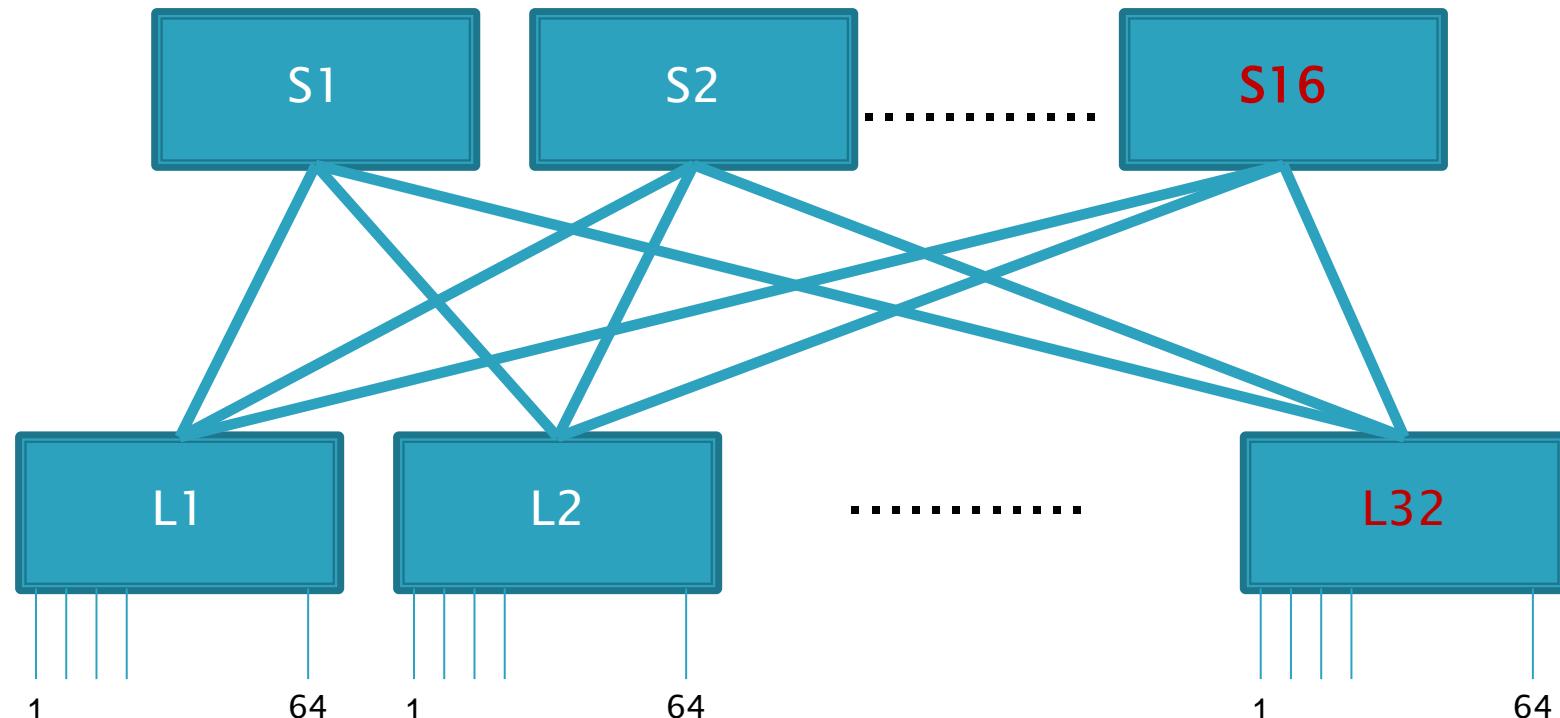
$$S_T = 640 \text{Gb}$$

# Spine /Leaf – Primer 4

## No Oversubscription

Stikala: Leaf: (IX1) 32x100Gb uporabljeni kot 16x100Gb + 64x25Gb

Spine: (IX1) 32x100Gb



Število priključkov (25Gb)

Oversubscription

Pasovna širina

Zakasnitev

$$32 * (4 * 16) = 2048$$

$$\text{OSR} = 64 * 25 / 16 * 100 = 1$$

$$S_T = 1.6 \text{ Tb}$$

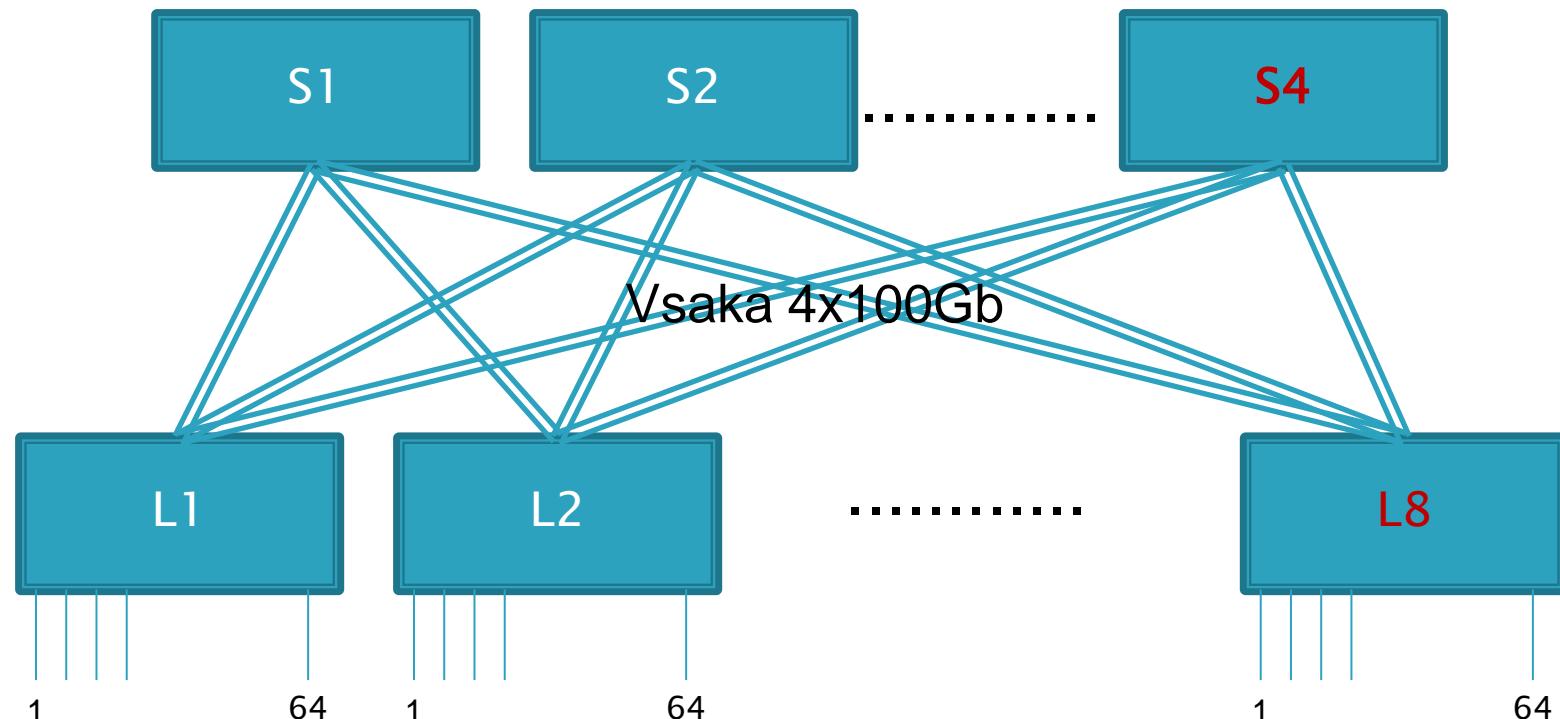
$$< 1.2 \text{ us}$$

# Spine /Leaf – Primer 4a

## No Oversubscription

Stikala: Leaf: (IX1) 32x100Gb uporabljeni kot 16x100Gb + 64x25Gb

Spine: (IX1) 32x100Gb



Število priključkov (25Gb)

Oversubscription

Pasovna širina

Zakasnitev

$$8*(4*16)=512$$

$$\text{OSR}=64*25/16*100=1$$

$$S_T=1.6\text{Tb}$$

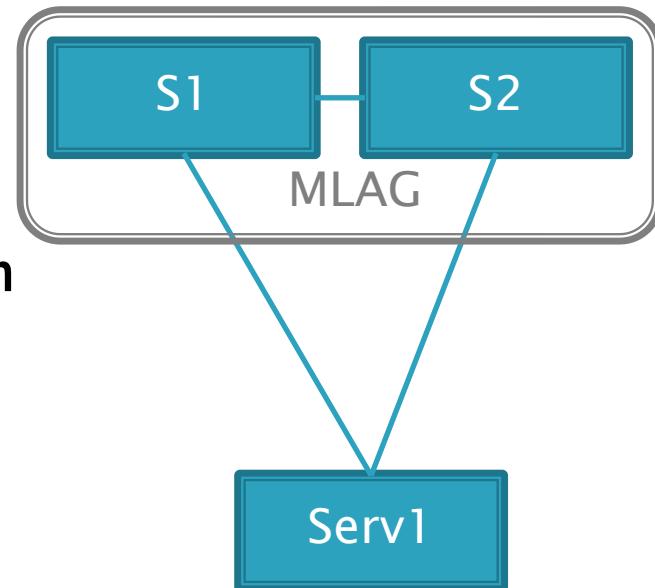
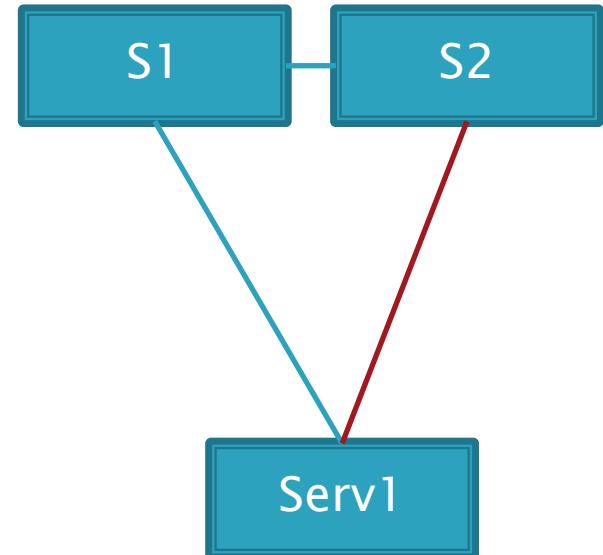
$$<1.2\text{us}$$

# Redundanca omrežja

- ▶ Fizični nivo
  - Redundanca povezav
  - Redundanca Stikal
  - Redundanca napajanja
- ▶ Komunikacijski nivo
  - ECMP, dinamično usmerjanje OSPF, ISIS, BGP
    - Tipično do 64 enakovrednih smeri
  - LAG, MLAG

# Redundanca na L2 nivoju

- ▶ Namesto STP Spanning Tree Protocol-a (STP 802.1D, RSTP 802.1w, MSTP 802.1s)
  - Kompleksna konfiguracija odvisna od HW.
  - Počasna konvergenca (3 do 90s).
  - V močno redundantnih ( $n \times n$ ) topologijah polovica povezav ne prenaša podatkov.
  - Vsaka sprememba topologije načeloma povzroči blokado prenosa v celotni L2 domeni.
- ▶ MLAG – Multiple Chassis LAG (Link AGgregation)
  - Enako kot navadni LAG prenaša podatke **prek vseh povezav**.
  - Hitra konvergenca, še posebno ob podpori LACP
    - **Standardni protokol** na strani klijenta (strežnika)

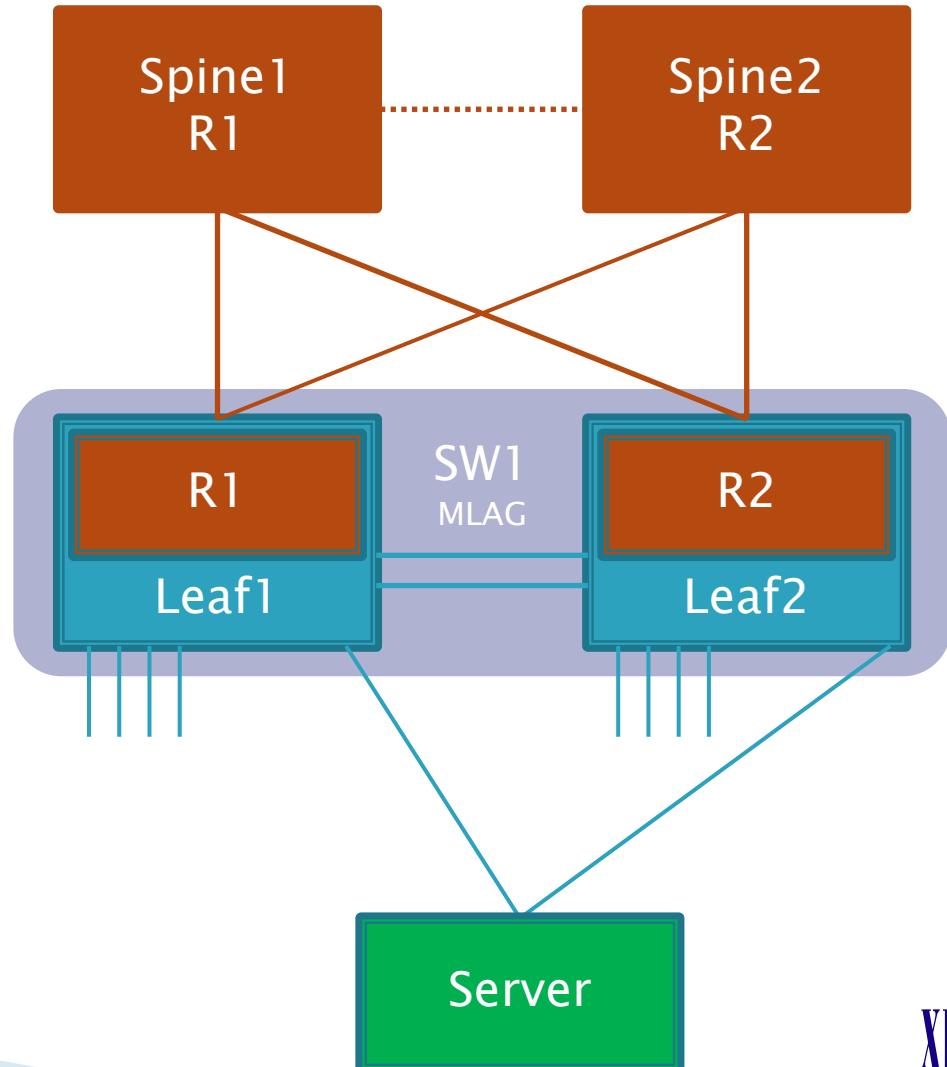


# Kreiranje MLAG

- ▶ Kreiranje agregiranih povezav (port-channel)
- ▶ Dodajanje fizičnih priključkov v agregirane povezave
- ▶ Kreiranje MLAG
  - Nastavitev MLAG domene, mora imeti vrednost različno od ostalih
  - Izbor agregirane povezave, ki povezuje oba stikala v MLAG domeno
  - Opcijsko določitev rezervne poti za nadzorni promet v MLAG domeni
- ▶ Določitev MLAG ID za vsako agregirano povezavo. Ta mora biti enak na povezavah v isti agregirani skupini na obeh napravah v MLAG domeni.

# MLAG in usmerjanje

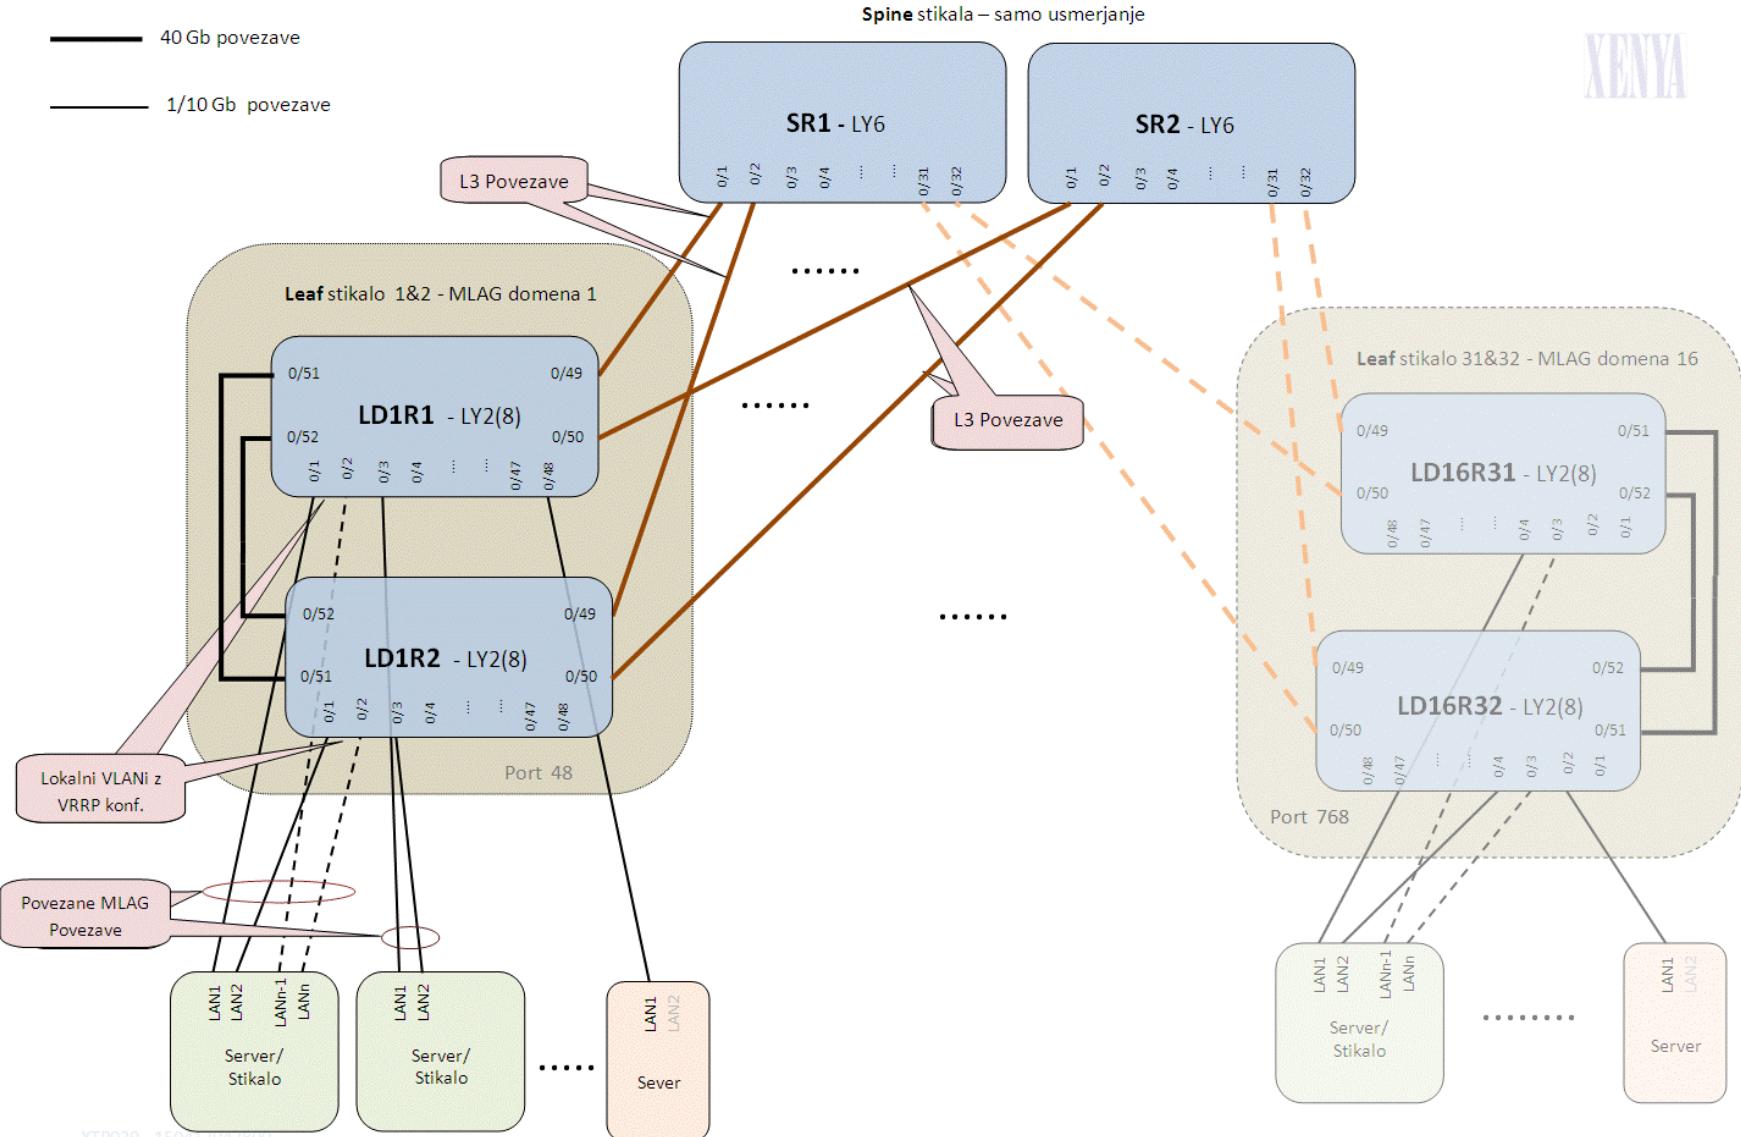
- ▶ Kreiramo MLAG  
Dobimo
  - Eno logično stikalo in
  - Dva usmerjevalnika
  - VRRP
  - mlag peer-gateway



# Arhitektura 1

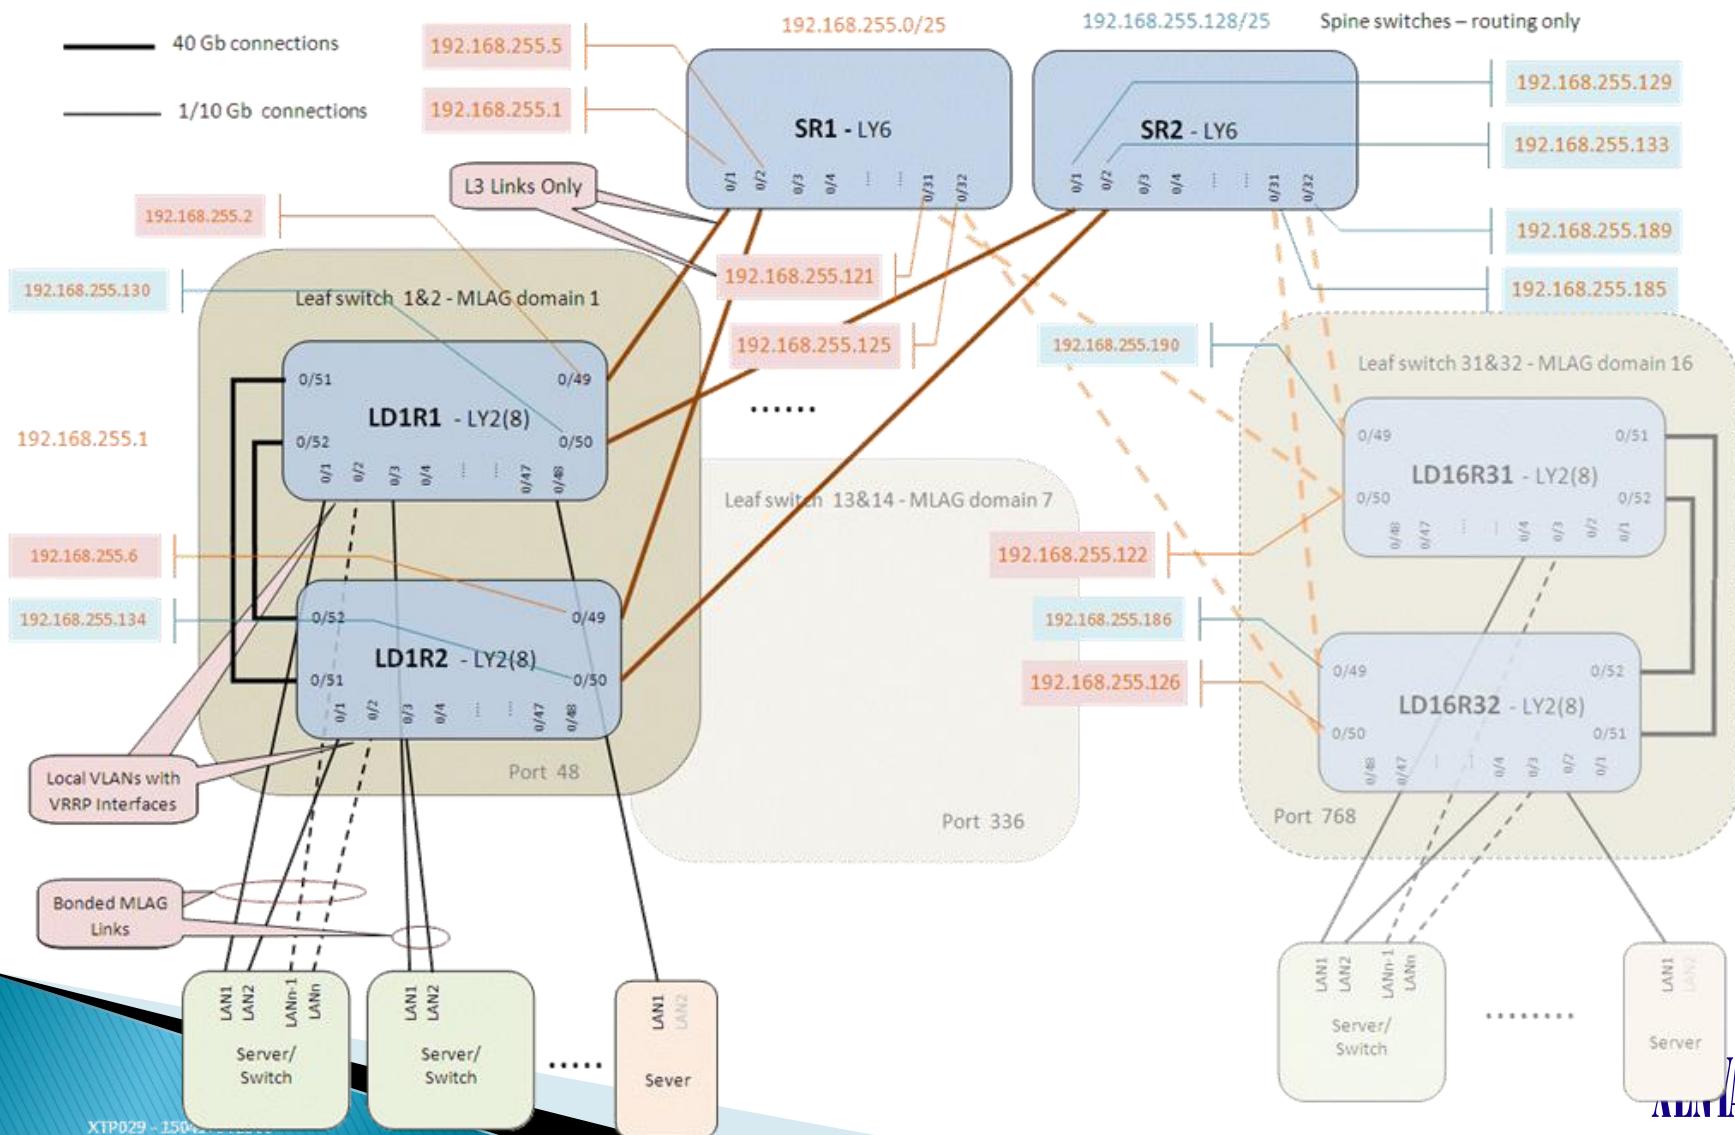
- ▶ “Fabric” topologija samo za L3 promet
- ▶ Redundanca in razporejanje prometa na hrbteničnem nivoju zagotovljene z ECMP usmerjanjem
- ▶ Na vsalem Leaf stikaluh ločeno podomrežje za klijente
- ▶ Na L2 strani (proti uporabnikom) redundanco izvedemo z MLAG vezavo
- ▶ Kombinacija MLAG in usmerjanja zahteva uporabo VRRP na vmesnikih proti klijentom na Leaf stikalih
- ▶ Se lahko razširi do zelo velikega števila priključkov klijentov

# Spine/Leaf Arhitektura A1 Praktična izvedba

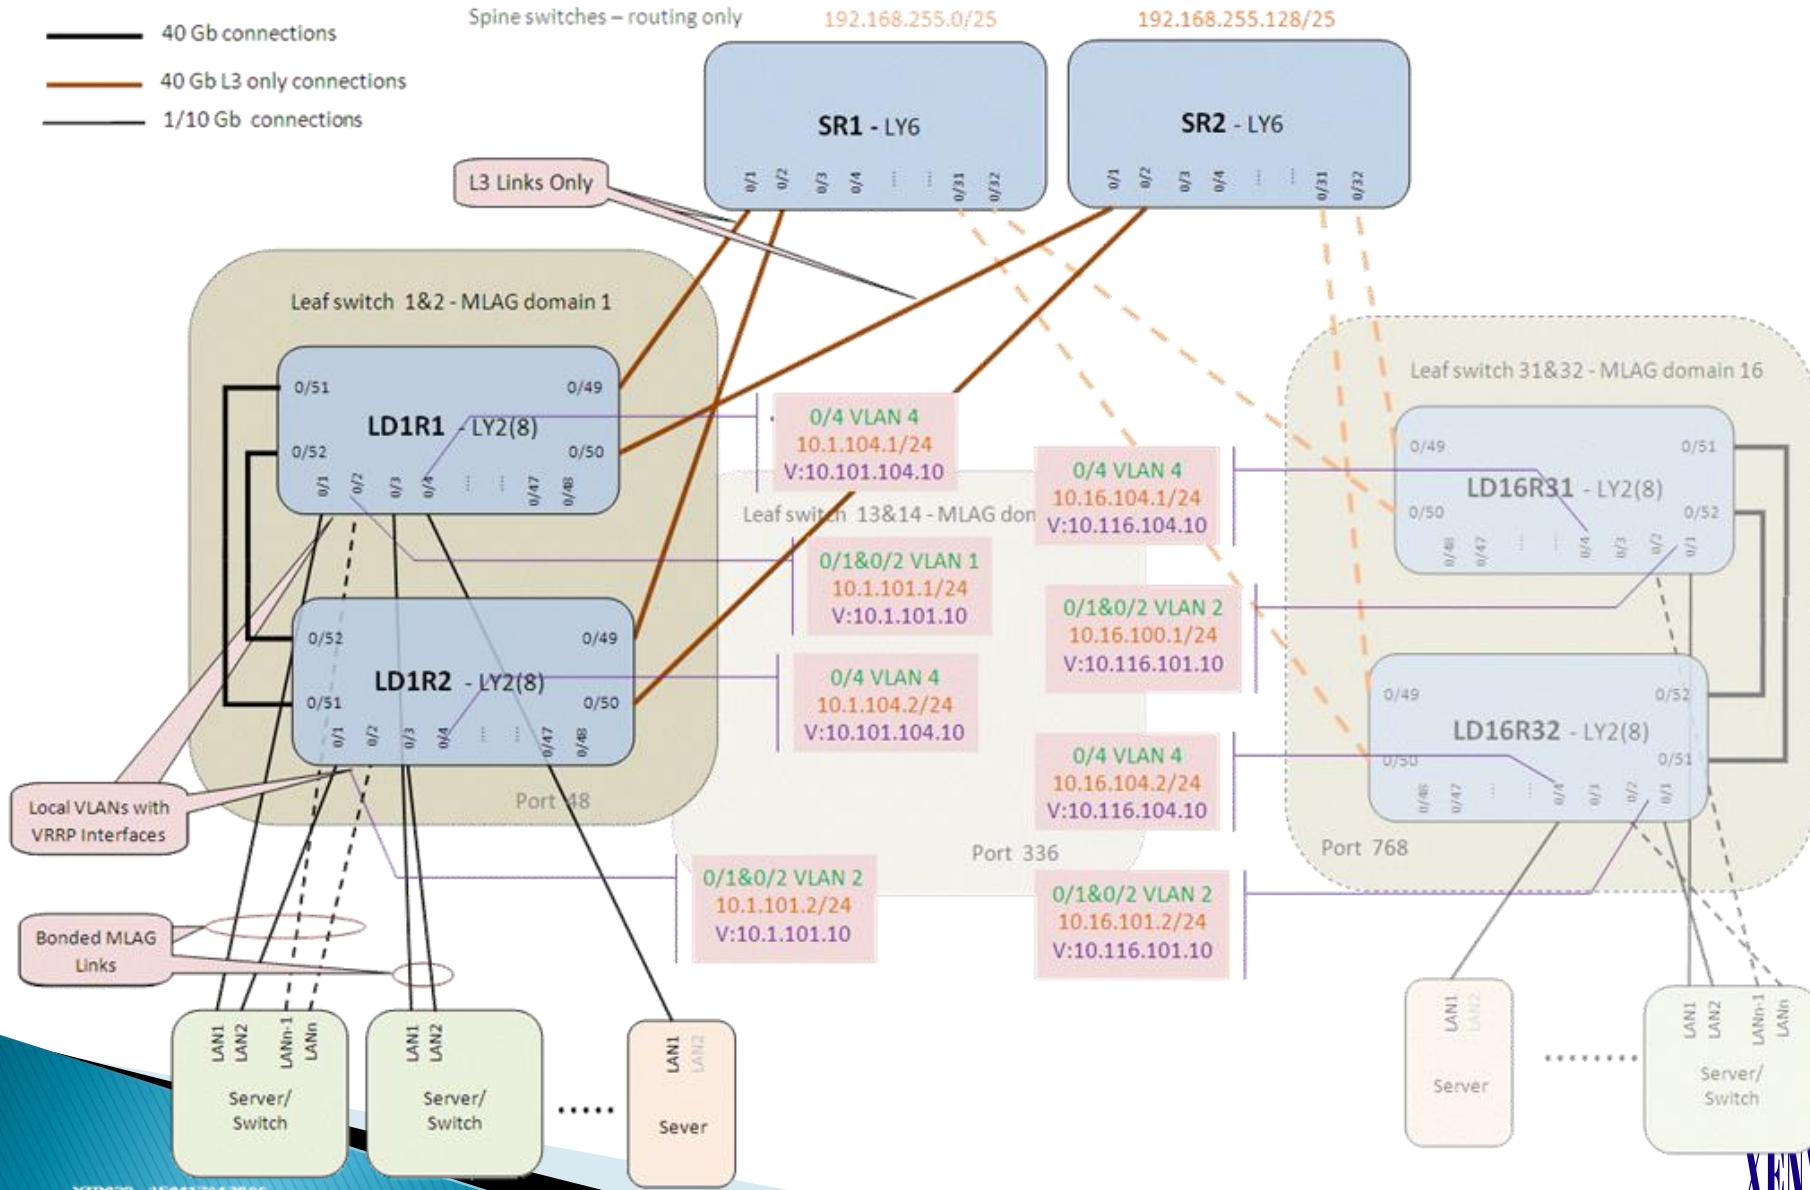


Arhitektura A1 – Primer klasične Spine/Leaf arhitekture z L3 ECMP usmerjanjem in MLAG redundanco na L2 povezavah do strežnikov

# Spine/Leaf Arhitektura A1 Naslovi Uplink Povezav



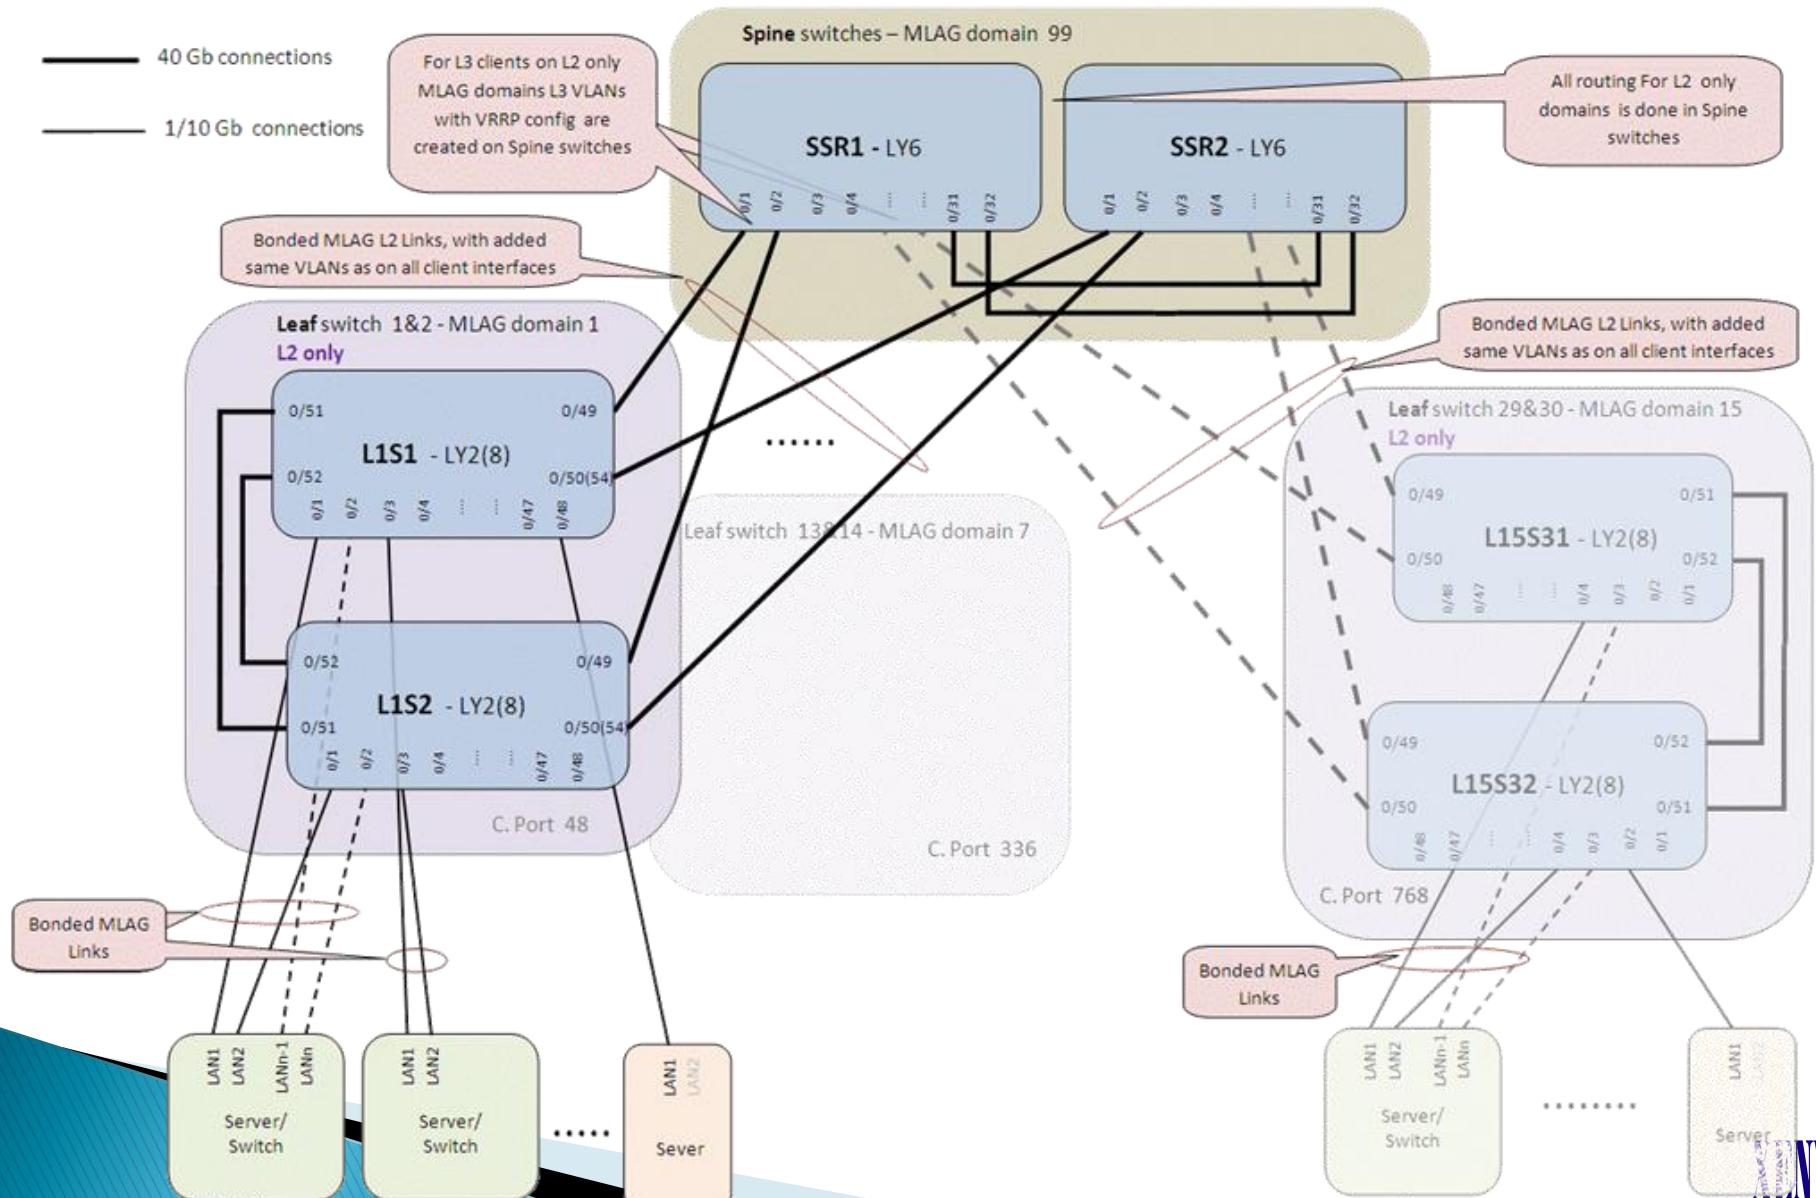
# Spine/Leaf Arhitektura A1 klijentni VLANi in naslovi



# Arhitektura 2

- ▶ Hrbtenični nivo podpira tudi L2 promet
- ▶ L2 in L3 promet
- ▶ Usmerjanje samo v Spine Mlag-u
  - Vsi vmesniki klijentov definirani na Spine stikalih
  - Leaf stikala samo premoščajo
- ▶ Velikost omejena z eno Spine MLAG domeno
- ▶ Nujni ukrepi za omejevanje posledic zank na L2 nivoju
  - Port guard, Storm control, MAC moving ...., opcionalno DHCP relaying, DAI, IP Source Guard...

# Spine/Leaf Arhitektura A2 L2/L3 izvedba



# Nadgradnja omrežij za podatovne centre

- ▶ **Datacenter Bridgeing Protokoli** – Omogočajo implementacijo enovitega omrežja, kjer se lahko prenaša tudi skladiščne podatke brez izgub paketov
- ▶ Protokoli za dinamično segmentacijo na stikalih (kreiranje VLANov)
  - Razširitve L2 arhitekture (zgrajene tudi s Trident+ SoC)
    - **VMTracer** – sprejema informacije o aktivnih VLANih direktno iz virtuelnih stikal. Enostavna konfiguracija, podprta na quanta & arista stikalih.
  - Razširitve standardne L3 arhitekture zgrajene s sikali na osnovi Trident II SoC
    - Overlaying protokoli
      - **VXLAN**, **NVGRE**, ...

# Dodatni protokoli

- ▶ Z DCB protokoli lahko zagotavljamo ločeno obravnavo različnih kategorij prometa (ethernet, storage):
  - Priority-based Flow Control (PFC): [IEEE 802.1Qbb](#)
  - Enhanced Transmission Selection (ETS) v [IEEE 802.1Qaz](#)
  - Congestion Notification (CN) 802.1Qau
  - Data Center Bridging eXchange (DCBX) v [IEEE 802.1Qaz](#)
- ▶ Fibre Channel over Ethernet(FCoE): [T11 FCoE](#)
- ▶ Overlay protokoli:
  - **VXLAN – L2 tuneliranje prek L3 z GRE protokolom**
  - NVGRE – alternativna izvedba L2 tuneliranja prek L3

# Alternativne izvedbe

- ▶ **Cumulus Linux** - Linux distribucija za stikala na osnovi Debian Linuxa instalirana na stikalo (bare metal, white box):
  - Priključki stikala predstavljeni kot mrežni vmesniki: swp1,....., swpn
  - Krmiljenje prek standardnih ukazov za krmiljenje omrežja na linuxu:
    - etc/network/interfaces datoteka: iface,ifup, ifdown; brctl...
  - Orkestracija integrirana v stikalo – upravljanje mreže enako kot upravljanje strežnikov
    - Puppet, Chef, Ansible ...
  - VMWare podpora – NSX krmilnik direktno krmili tudi fizična stikala enako kot virtuelna
    - Registrira L2 storitev fizičnih stikal v VMWare NSX Controller-ju (prek NSX Service Node komponente instalirane na stiku)
    - Tudi overlaying protokol VXLAN in konverzija v VLANe na stiku (VTEP) je tako krmiljena direktno prek hypervisorja.
- ▶ FW tretjih ponudnikov – dobavljen kot samostojen produkt
  - Juniper JUNOS,.....
- ▶ Zunanji SDN krmilnik
  - Stikala tudi s std, FW podpirajo OpenFlow 1.0 do 1.3, OpenAPI ....
- ▶ Open source FW rešitve

# Zaključek

- ▶ Standardne komponente & Nove arhitekture & Novi protokoli
  - Modularne, Redundantne, Skalabilne rešiteve
  - Z nizko porabo energije
  - Razpršene – z možnostjo rasti omrežja po rasti potreb
- ▶ Cenovno ugodne rešitve
- ▶ Rešitve z uporabo overlay protokolov še bolj fleksibilne od prikazanih.
- ▶ Podpirajo bodoče širitev v dinamična omrežja, SDN ...