upna
Universidad Pública de Navarra
Nafarroako Unibertsitate Publikoa

Redes de Nueva Generación
Área de Ingeniería Telemática

Layer 3 MPLS VPNs

Layer 3 VPNs

- RFC 4364 “BGP/MPLS IP Virtual Private Networks (VPNs)” (Cisco Systems y Juniper Networks, 2006)
  - *“This document describes a method by which a Service Provider may use an IP backbone to provide IP Virtual Private Networks (VPNs) for its customers.”*
- VPN para el transporte de paquetes IP entre sedes (*sites*)
- El backbone del proveedor de servicio es una red IP MPLS
- RFC 4760 “Multiprotocol Extensions for BGP-4” (Cisco, Sanoa, Juniper, 2007)
- Extensiones a BGP-4 para poder transportar información de otros protocolos de nivel de red: IPv6, IPX, L3VPN, etc
- En este caso, en lugar de transportar rutas IPv4 transportará rutas “VPN-IPv4”

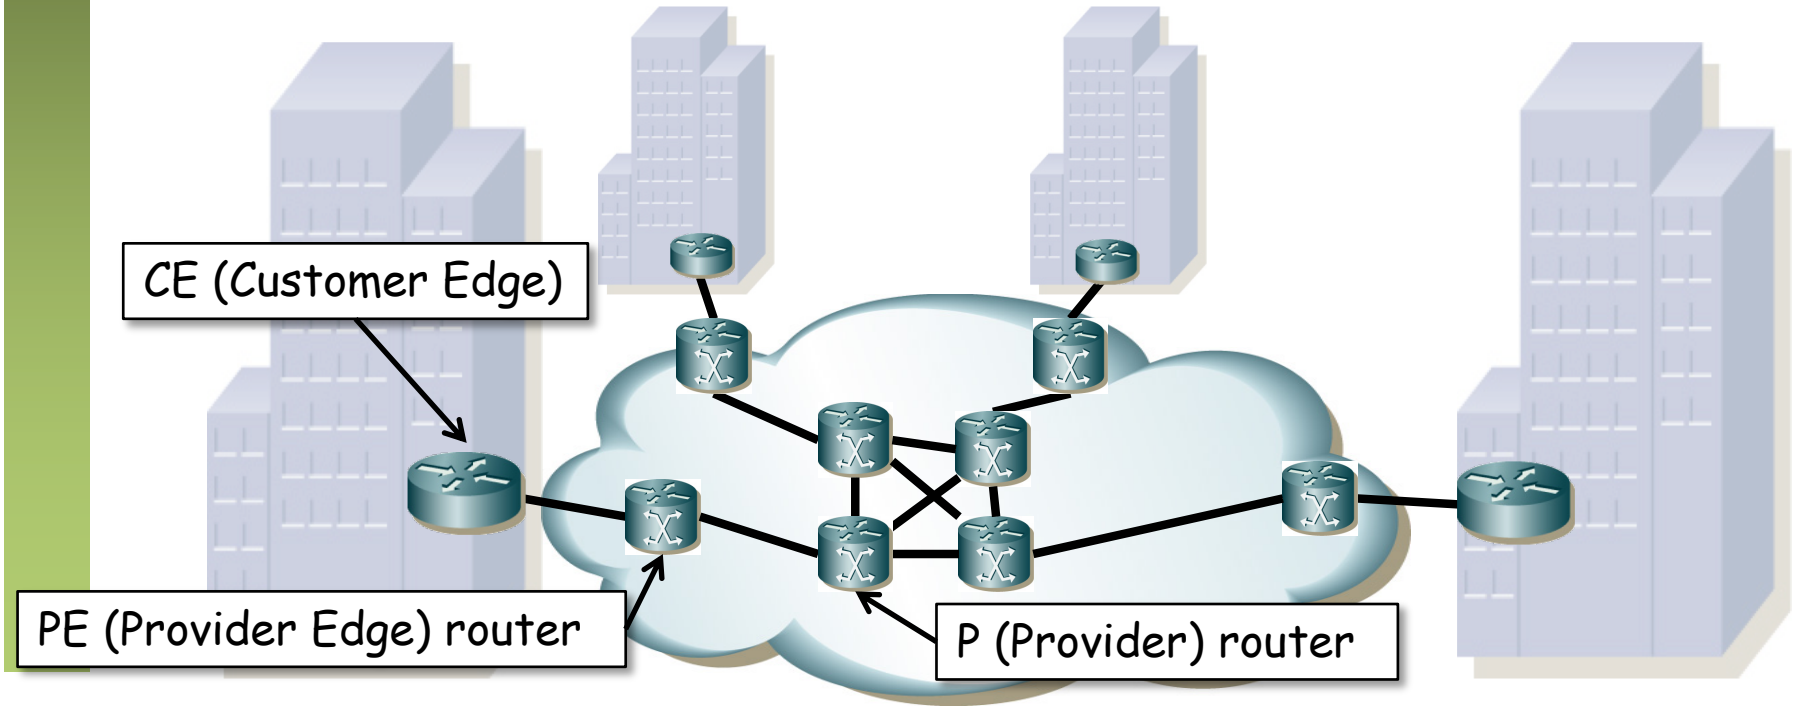

upna
Universidad Pública de Navarra
Nafarroako Unibertsitate Publikoa

Redes de Nueva Generación
Área de Ingeniería Telemática

L3VPN - Routing

L3VPN: Routing

- Los CEs anuncian sus rutas a los PEs (con un IGP o rutas estáticas)
- Los PEs emplean MP-BGP para intercambiarse esas rutas (iBGP)
- El PE la distribuye al CE del mismo cliente (de la misma VPN)
- Los P y PE corren un IGP para tener alcanzabilidad interna
- Los CE son routers convencionales, no necesitan ninguna configuración de VPN ni emplean MPLS
- Los CEs no intercambian información de routing entre ellos, no son adyacentes
- La VPN no actúa como un overlay sino una red IP con otro gestor

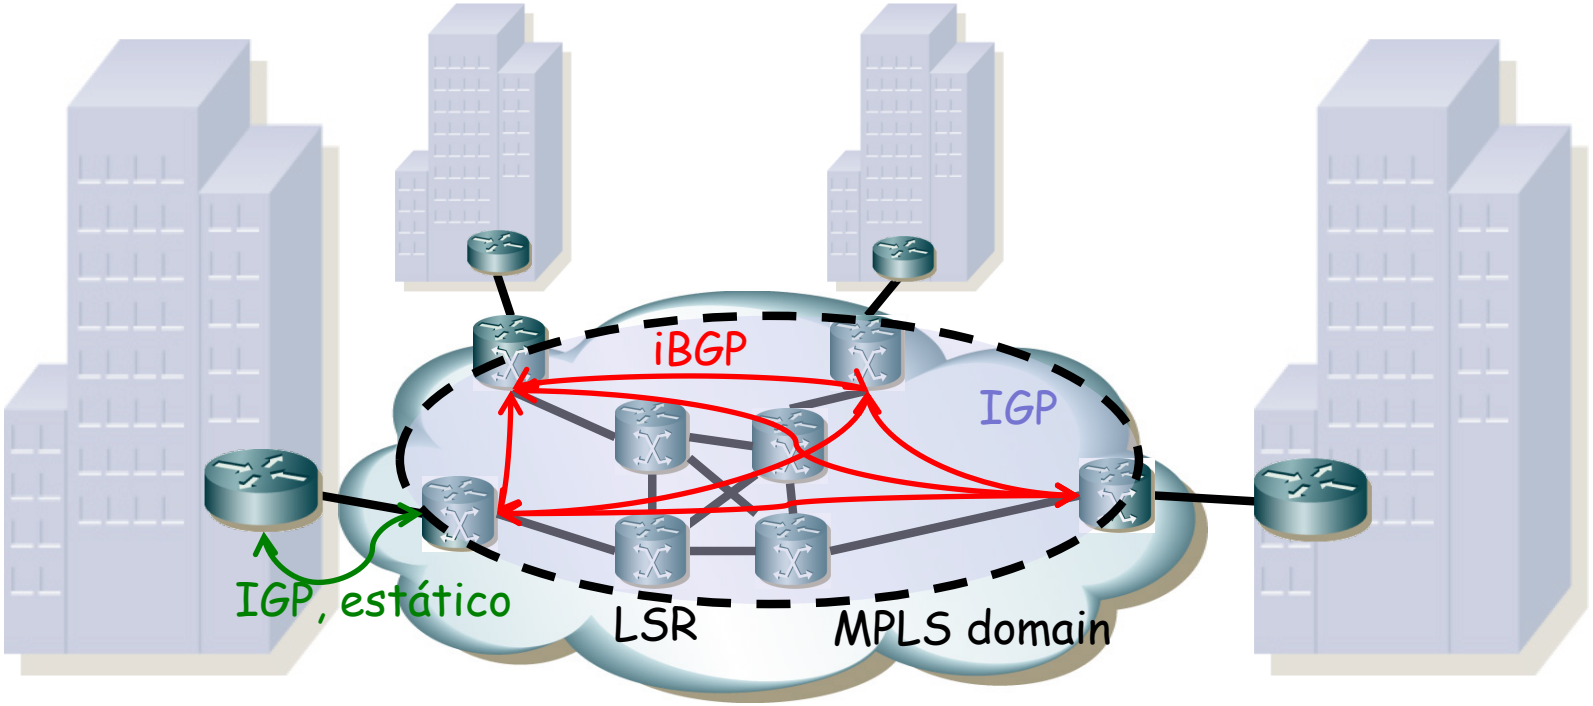

L3VPN: Routing

- Dos VPNs pueden emplear espacios de direcciones IP que se solapen
- Los anuncios VPN-IPv4 (MP-BGP) incluyen un identificador (*Route Distinguisher = RD, 64 bits)* que las diferencia
- Anuncio de la AF (Address Family) VPN-IPv4 es un prefijo de 12 bytes:

  `<Route Distinguisher>:<IP Prefix>`
- Permite también anunciar más de una vez el mismo prefijo IPv4 para el mismo cliente empleando distinto RD (múltiples rutas para el mismo destino)

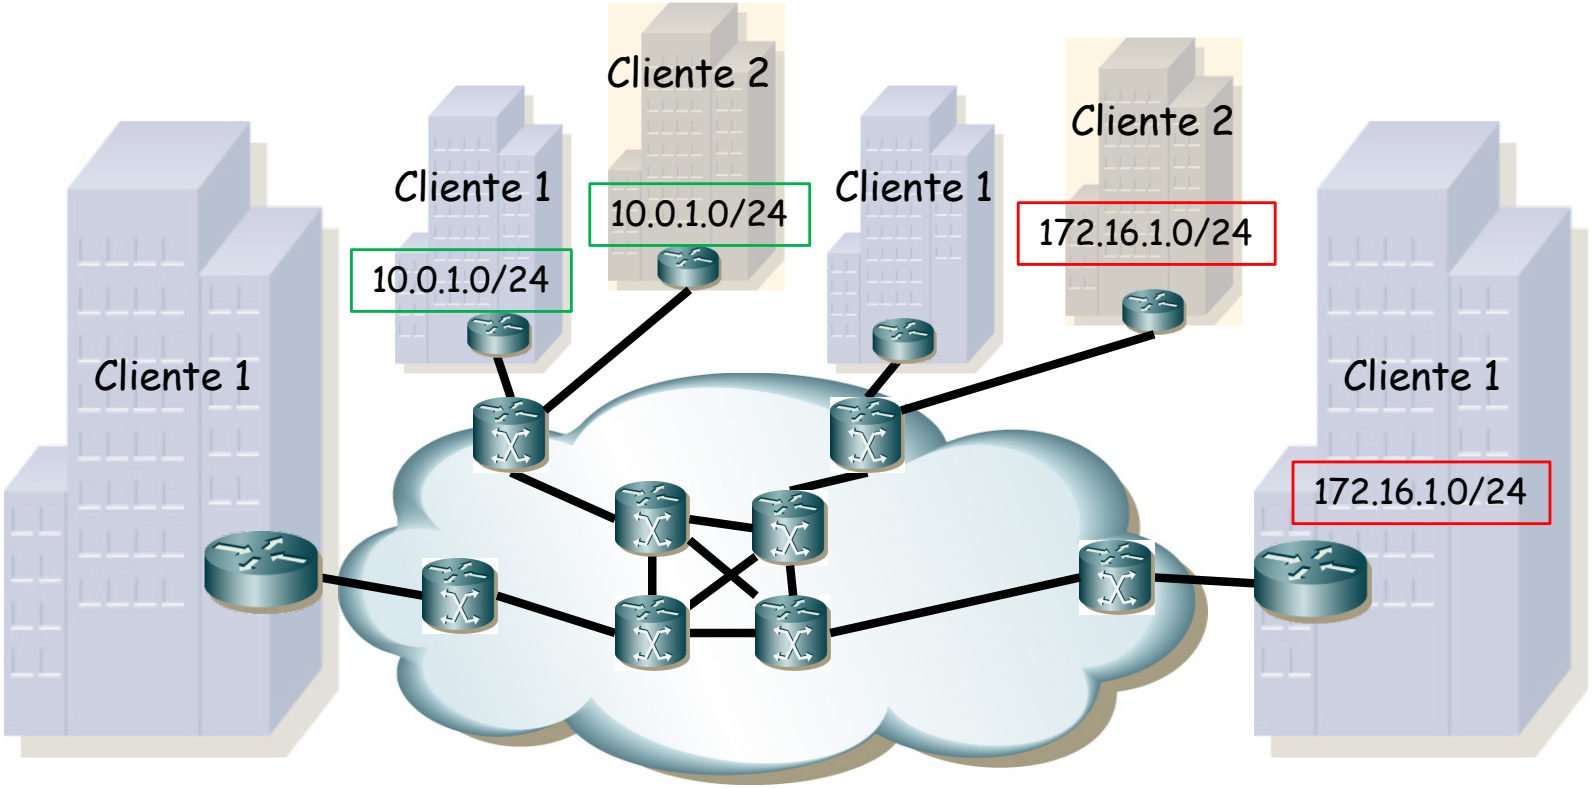

Ejemplo en mensaje BGP

```
▶ Frame 84: 203 bytes on wire (1624 bits), 203 bytes captured (1624 bits)
▶ Ethernet II, Src: Cisco_9d:ff:02 (a0:3d:6f:9d:ff:02), Dst: Cisco_cb:84:02 (a0:e0:af:cb:84:02)
▶ MultiProtocol Label Switching Header, Label: 23, Exp: 0, S: 1, TTL: 255
▶ Internet Protocol Version 4, Src: 10.100.100.6, Dst: 10.100.100.17
▶ Transmission Control Protocol, Src Port: 179, Dst Port: 52361, Seq: 104, Ack: 85, Len: 141
▼ Border Gateway Protocol - UPDATE Message
    Marker: ffffffffffffffffffffffffffffffff
    Length: 112
    Type: UPDATE Message (2)
    Withdrawn Routes Length: 0
    Total Path Attribute Length: 89
  ▼ Path attributes
    ▼ Path Attribute - MP_REACH_NLRI
      ▶ Flags: 0x80, Optional, Non-transitive, Complete
        Type Code: MP_REACH_NLRI (14)
        Length: 48
        Address family identifier (AFI): IPv4 (1)
        Subsequent address family identifier (SAFI): Labeled VPN Unicast (128)
      ▶ Next hop network address (12 bytes)
        Number of Subnetwork points of attachment (SNPA): 0
      ▼ Network layer reachability information (31 bytes)
        ▼ BGP Prefix
            Prefix Length: 112
            Label Stack: 28 (bottom)
            Route Distinguisher: 14:14
            MP Reach NLRI IPv4 prefix: 10.1.6.0
        ▼ BGP Prefix
            Prefix Length: 120
            Label Stack: 27 (bottom)
            Route Distinguisher: 14:14
            MP Reach NLRI IPv4 prefix: 10.100.100.1
```

https://www.networkingwithfish.com/mpls-l3vpn-label-following-fun-with-fish/

L3VPN: Routing

- RD no tiene significado pero un formato habitual es <ASN>:<id>
- Así cada service provider tiene su espacio de valores RD
- Las sesiones iBGP son entre los PE, así que ...
- Los P no ven las rutas de las VPNs (evita problemas de escalabilidad)
- ¿Cómo se enruta si hay direcciones duplicadas y los routers centrales no ven esas rutas?

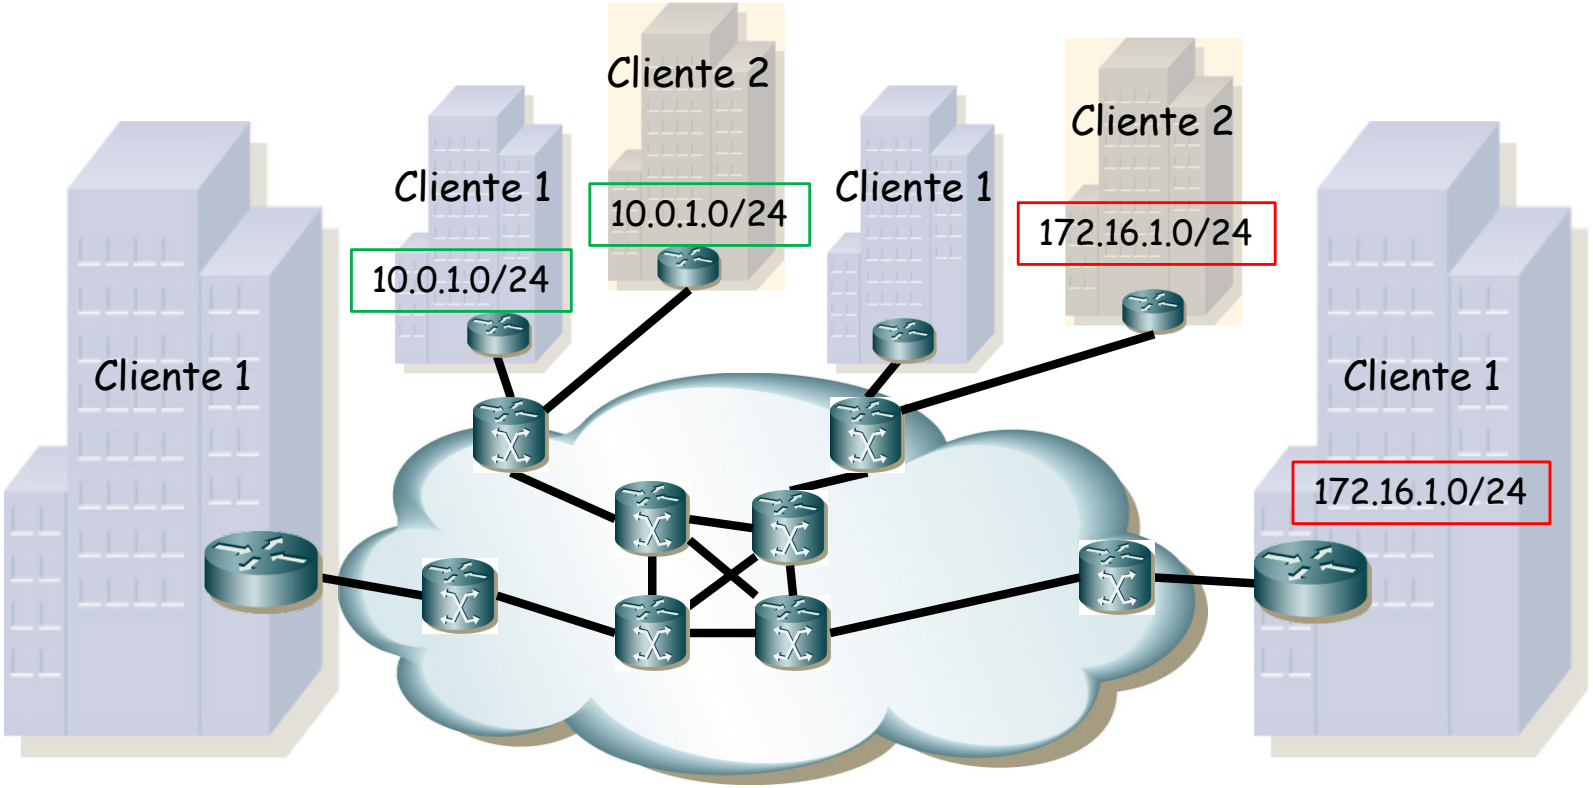

L3VPN - Forwarding

L3VPN: Forwarding

- Cada PE mantiene una tabla de rutas para cada cliente y además una tabla por defecto
- VPN o *VPN/Virtual Routing and Forwarding tables (VRFs)*
- Al recibir un paquete IP de un cliente consulta la VRF correspondiente

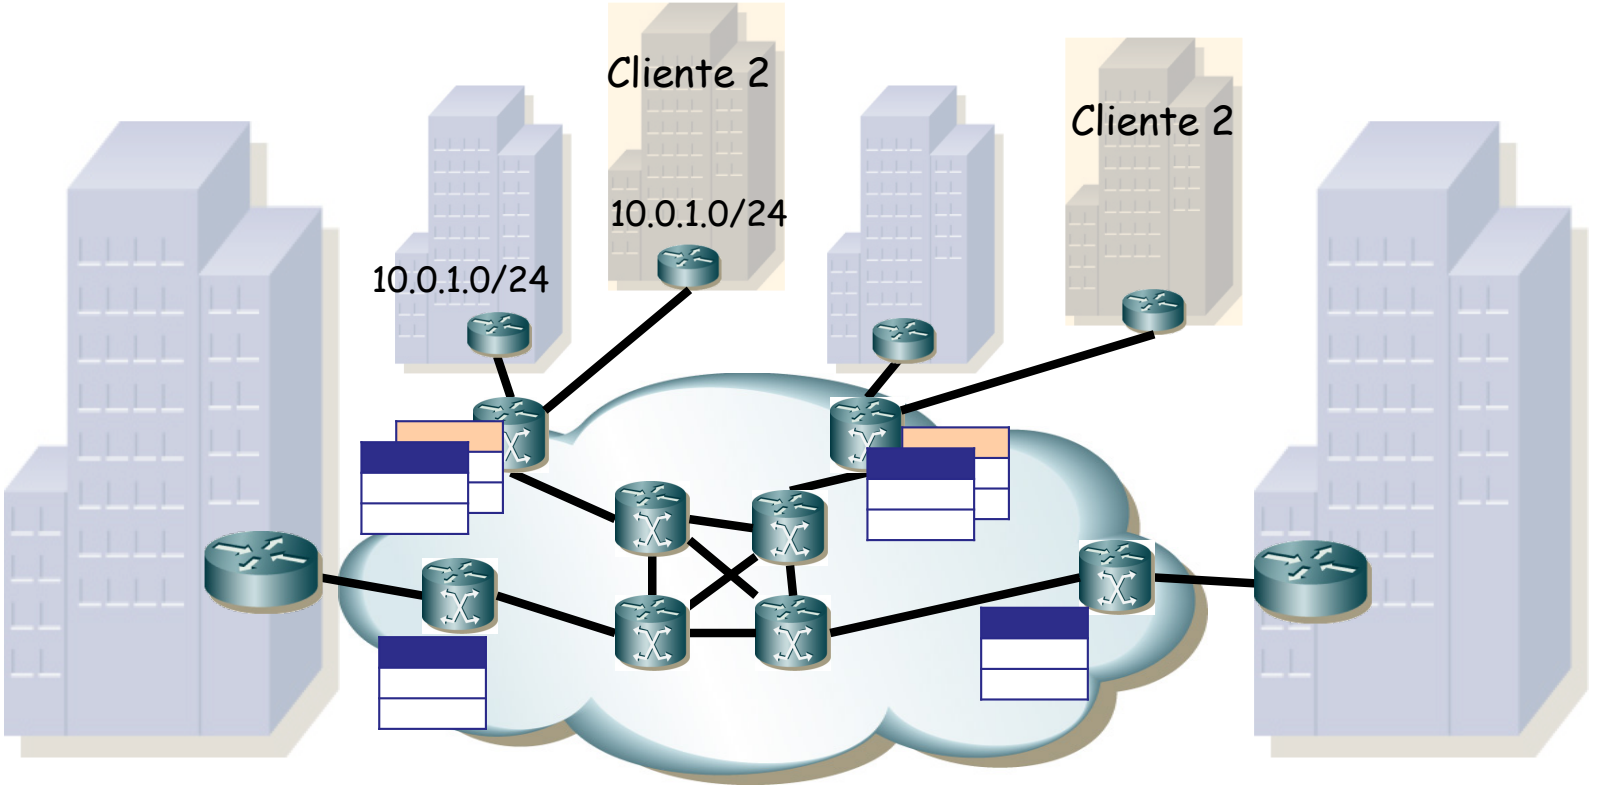

L3VPN: Forwarding

- Los anuncios MP-BGP de la AF VPN-IPv4 incluyen uno o más *"Route Targets"* (RT)
- Una VRF importa las rutas que traen los RT que desee
- El RT se transporta como una *extended community* (RFC 4360)
- Las comunidades son atributos opcionales transitivos (32 ó 64 bits)
- Son una forma de incluir una etiqueta numérica que quien la vea debe saber interpretar
- Incluye una etiqueta MPLS (para el plano de datos)

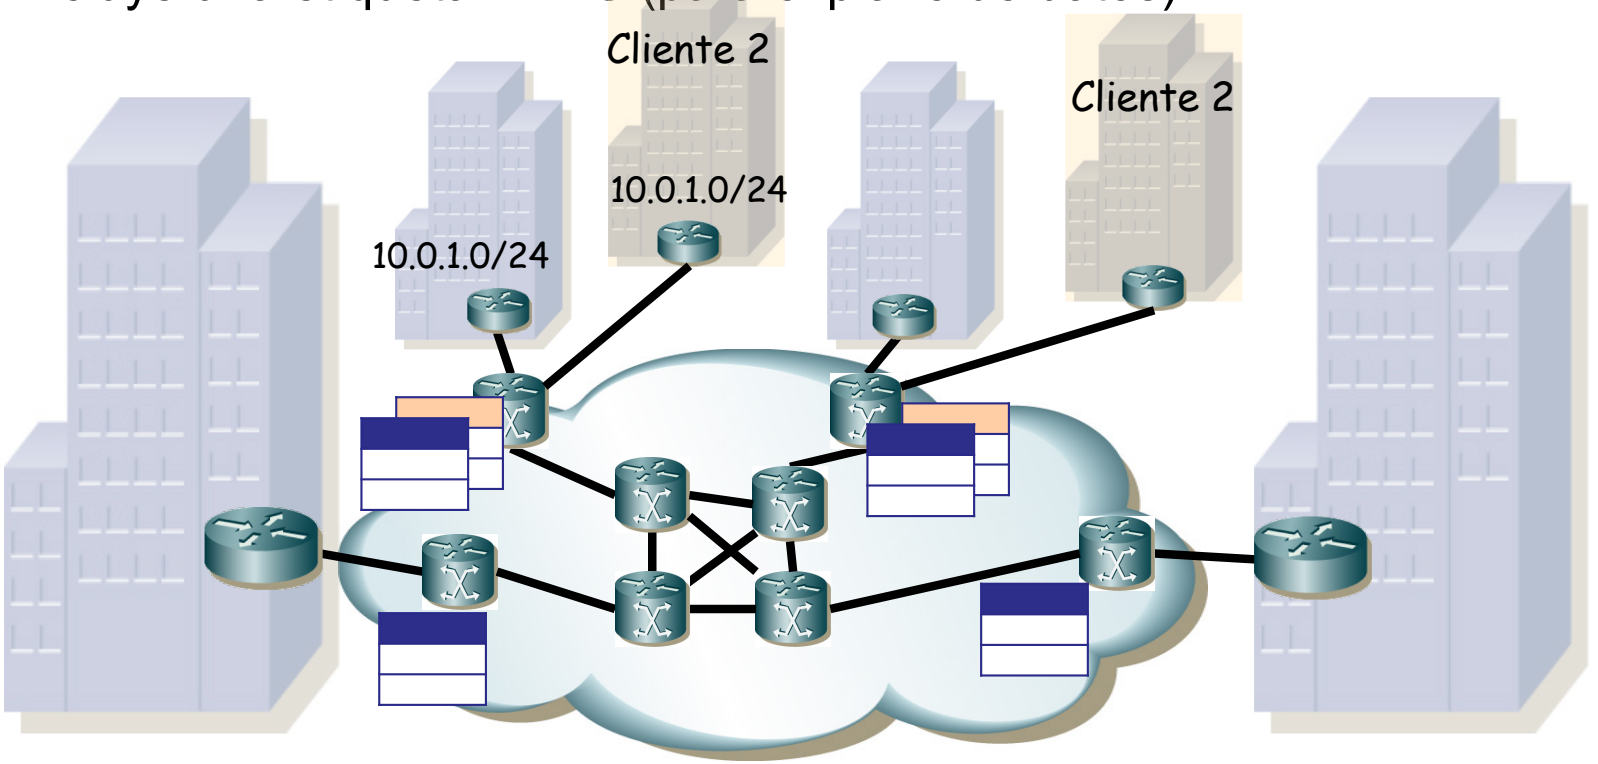

Ejemplo en mensaje BGP

```
▶ Frame 84: 203 bytes on wire (1624 bits), 203 bytes captured (1624 bits)
▶ Ethernet II, Src: Cisco_9d:ff:02 (a0:3d:6f:9d:ff:02), Dst: Cisco_cb:84:02 (a0:e0:af:cb:84:02)
▶ MultiProtocol Label Switching Header, Label: 23, Exp: 0, S: 1, TTL: 255
▶ Internet Protocol Version 4, Src: 10.100.100.6, Dst: 10.100.100.17
▶ Transmission Control Protocol, Src Port: 179, Dst Port: 52361, Seq: 104, Ack: 85, Len: 141
▼ Border Gateway Protocol - UPDATE Message
    Marker: ffffffffffffffffffffffffffffffff
    Length: 112
    Type: UPDATE Message (2)
    Withdrawn Routes Length: 0
    Total Path Attribute Length: 89
  ▼ Path attributes
    ▶ Path Attribute - MP_REACH_NLRI
    ▶ Path Attribute - ORIGIN: INCOMPLETE
    ▶ Path Attribute - AS_PATH: 65000
    ▶ Path Attribute - MULTI_EXIT_DISC: 0
    ▶ Path Attribute - LOCAL_PREF: 100
    ▼ Path Attribute - EXTENDED_COMMUNITIES
      ▶ Flags: 0xc0, Optional, Transitive, Complete
        Type Code: EXTENDED_COMMUNITIES (16)
        Length: 8
      ▼ Carried extended communities: (1 community)
        ▼ Route Target: 14:14 [Transitive 2-Octet AS-Specific]
          ▶ Type: Transitive 2-Octet AS-Specific (0x00)
            Subtype (AS2): Route Target (0x02)
            2-Octet AS: 14
            4-Octet AN: 14
```

L3VPN: Forwarding

- RD:prefijo y RT son plano de control
- El anuncio MP-BGP incluye una etiqueta MPLS
- Esta etiqueta es para el plano de datos

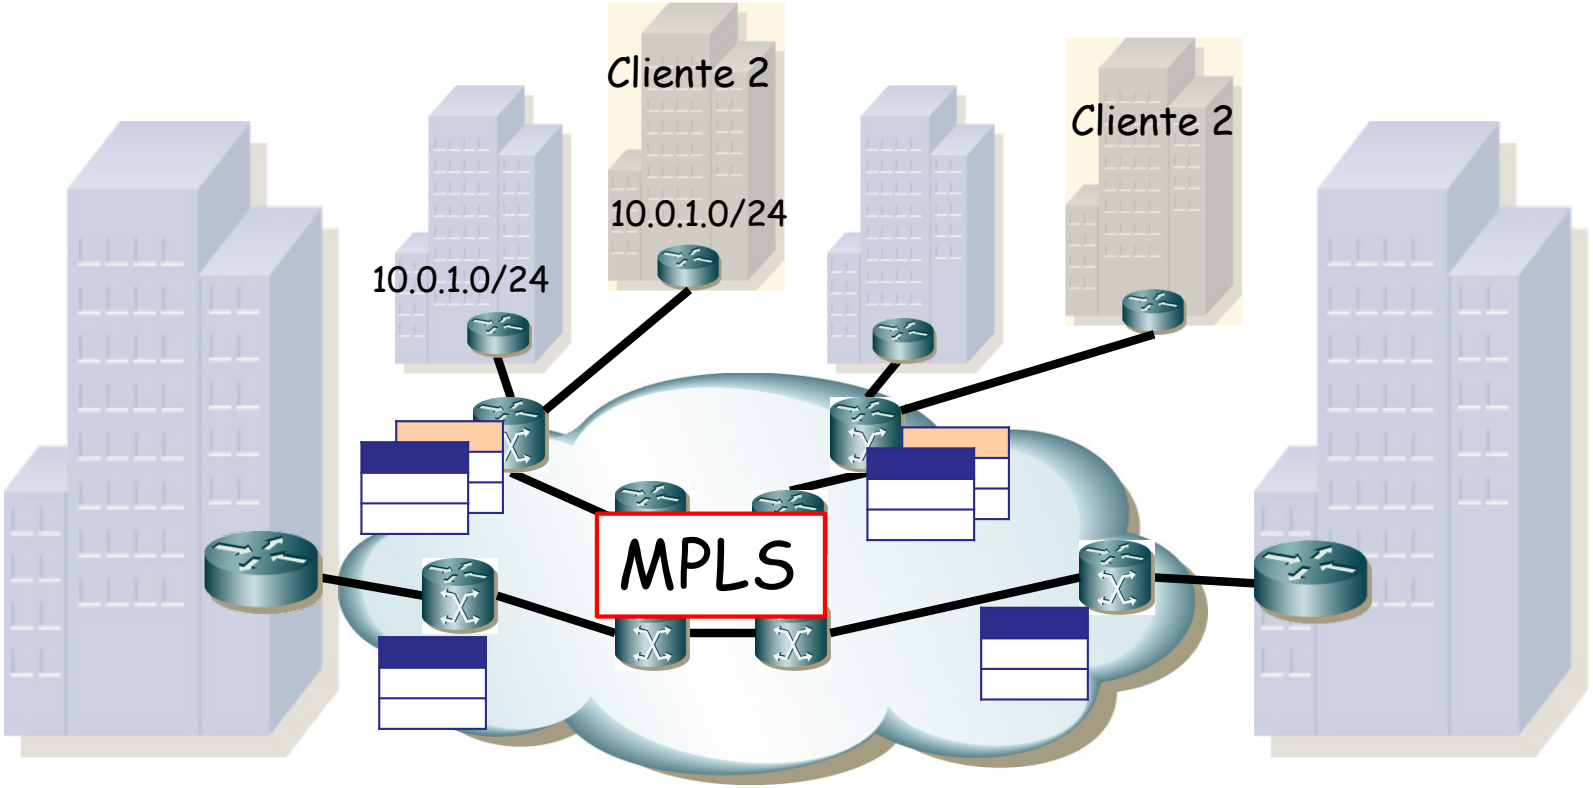

Ejemplo en mensaje BGP

```
▶ Frame 84: 203 bytes on wire (1624 bits), 203 bytes captured (1624 bits)
▶ Ethernet II, Src: Cisco_9d:ff:02 (a0:3d:6f:9d:ff:02), Dst: Cisco_cb:84:02 (a0:e0:af:cb:84:02)
▶ MultiProtocol Label Switching Header, Label: 23, Exp: 0, S: 1, TTL: 255
▶ Internet Protocol Version 4, Src: 10.100.100.6, Dst: 10.100.100.17
▶ Transmission Control Protocol, Src Port: 179, Dst Port: 52361, Seq: 104, Ack: 85, Len: 141
▼ Border Gateway Protocol - UPDATE Message
    Marker: ffffffffffffffffffffffffffffffff
    Length: 112
    Type: UPDATE Message (2)
    Withdrawn Routes Length: 0
    Total Path Attribute Length: 89
  ▼ Path attributes
    ▼ Path Attribute - MP_REACH_NLRI
      ▶ Flags: 0x80, Optional, Non-transitive, Complete
        Type Code: MP_REACH_NLRI (14)
        Length: 48
        Address family identifier (AFI): IPv4 (1)
        Subsequent address family identifier (SAFI): Labeled VPN Unicast (128)
      ▶ Next hop network address (12 bytes)
        Number of Subnetwork points of attachment (SNPA): 0
      ▼ Network layer reachability information (31 bytes)
        ▼ BGP Prefix
            Prefix Length: 112
            Label Stack: 28 (bottom)
            Route Distinguisher: 14:14
            MP Reach NLRI IPv4 prefix: 10.1.6.0
        ▼ BGP Prefix
            Prefix Length: 120
            Label Stack: 27 (bottom)
            Route Distinguisher: 14:14
            MP Reach NLRI IPv4 prefix: 10.100.100.1
```

24 bits Label
64 bits RD
32 bits dirección de red

Total: 120 bits

Prefix Length: 112
120-112 = 8 bits (es decir /24)

https://www.networkingwithfish.com/mpls-l3vpn-label-following-fun-with-fish/

L3VPN: MPLS

- ¿Para qué esa etiqueta?
- Asociada a la ruta
- Paquetes de la VRF que siguen esa ruta se introducen en LSP con esa etiqueta
- (…)

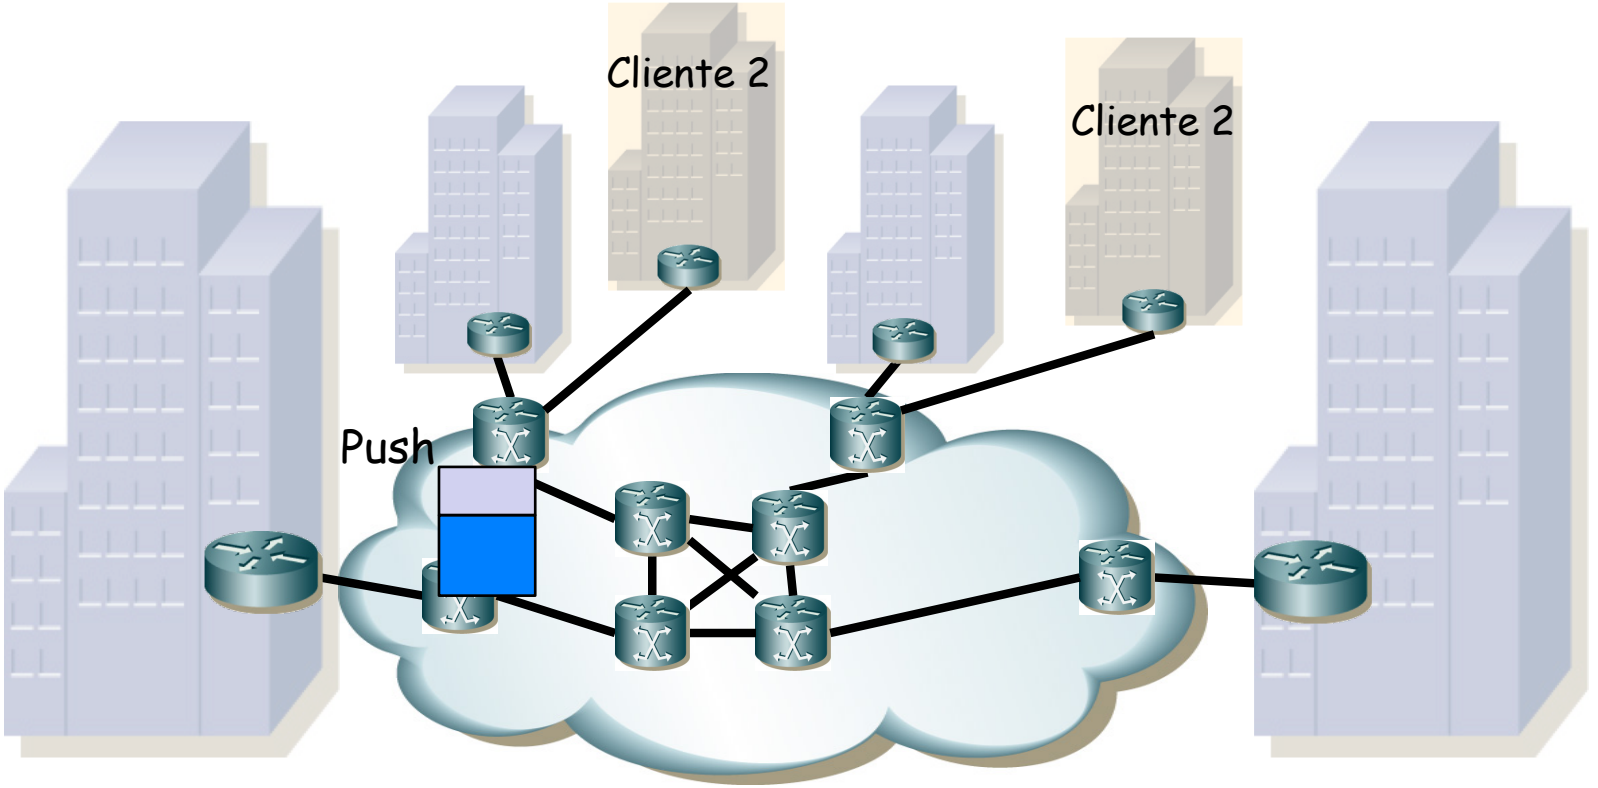

L3VPN: MPLS

- Al salir el paquete en el PE de egreso se sabe a qué VRF pertenece en base a ese LSP en el que venía
- No puede usar la dirección IP destino ya que pueden estar duplicadas
- El paquete MPLS viene con la etiqueta que puso el de ingreso
- Es decir, PE de egreso hizo el anuncio de la ruta con la etiqueta, PE de ingreso la añadió y el paquete llegó con ella
- ¿No cambiaron la etiqueta los LSR del camino?

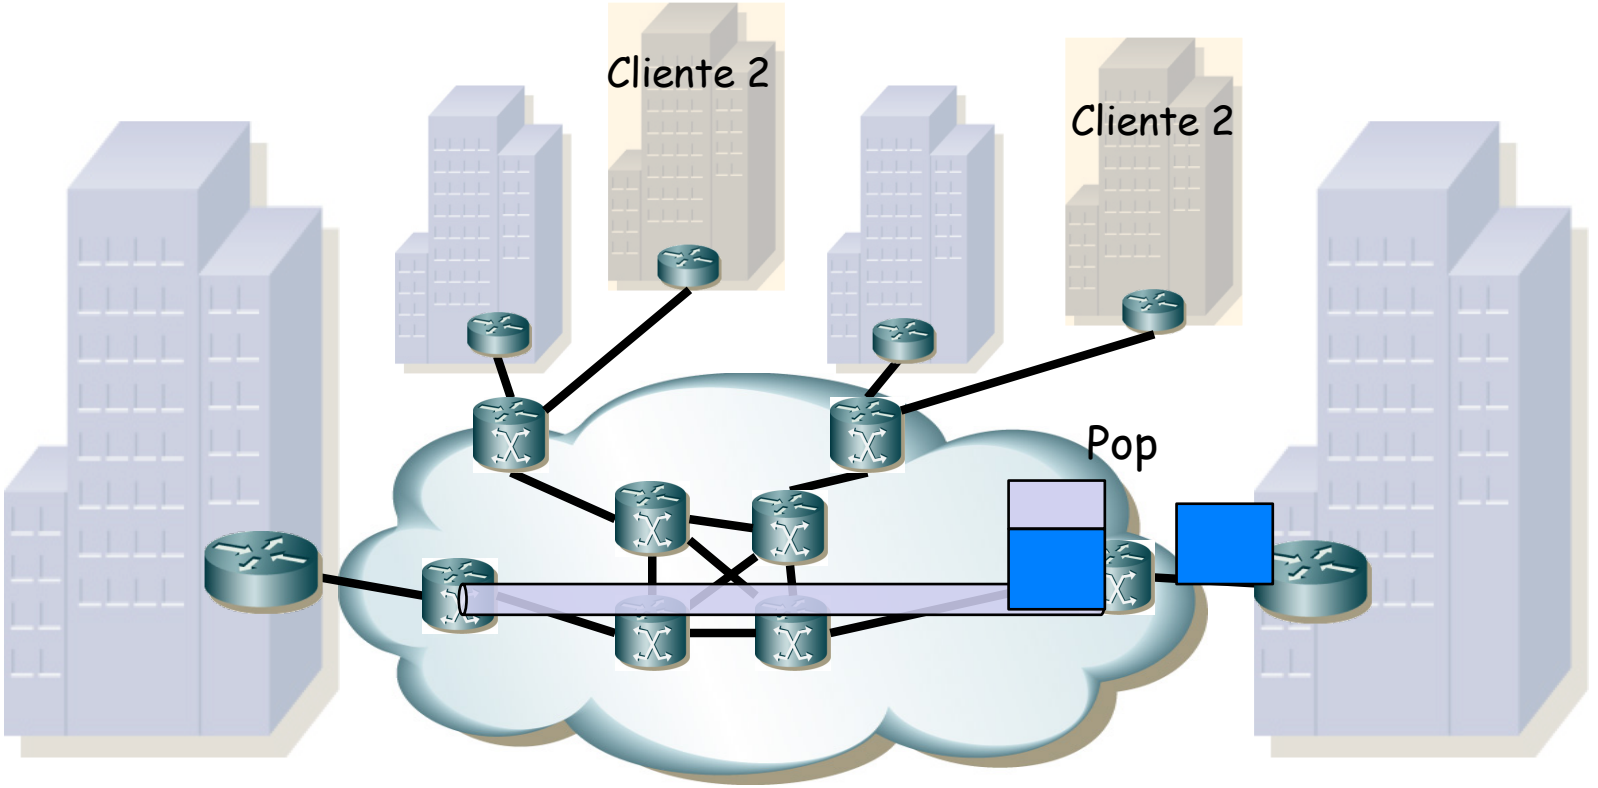

upna
Universidad Pública de Navarra
Nafarroako Unibertsitate Publikoa
Redes de Nueva Generación
Área de Ingeniería Telemática

L3VPN – Forwarding en el Core

L3VPN: MPLS

- ¿Y en los P routers? ¿Reenvían en función de esa etiqueta?
- Tendríamos en ellos una gran cantidad de LSPs, para todas las VPNs
- Mala escalabilidad
- (…)

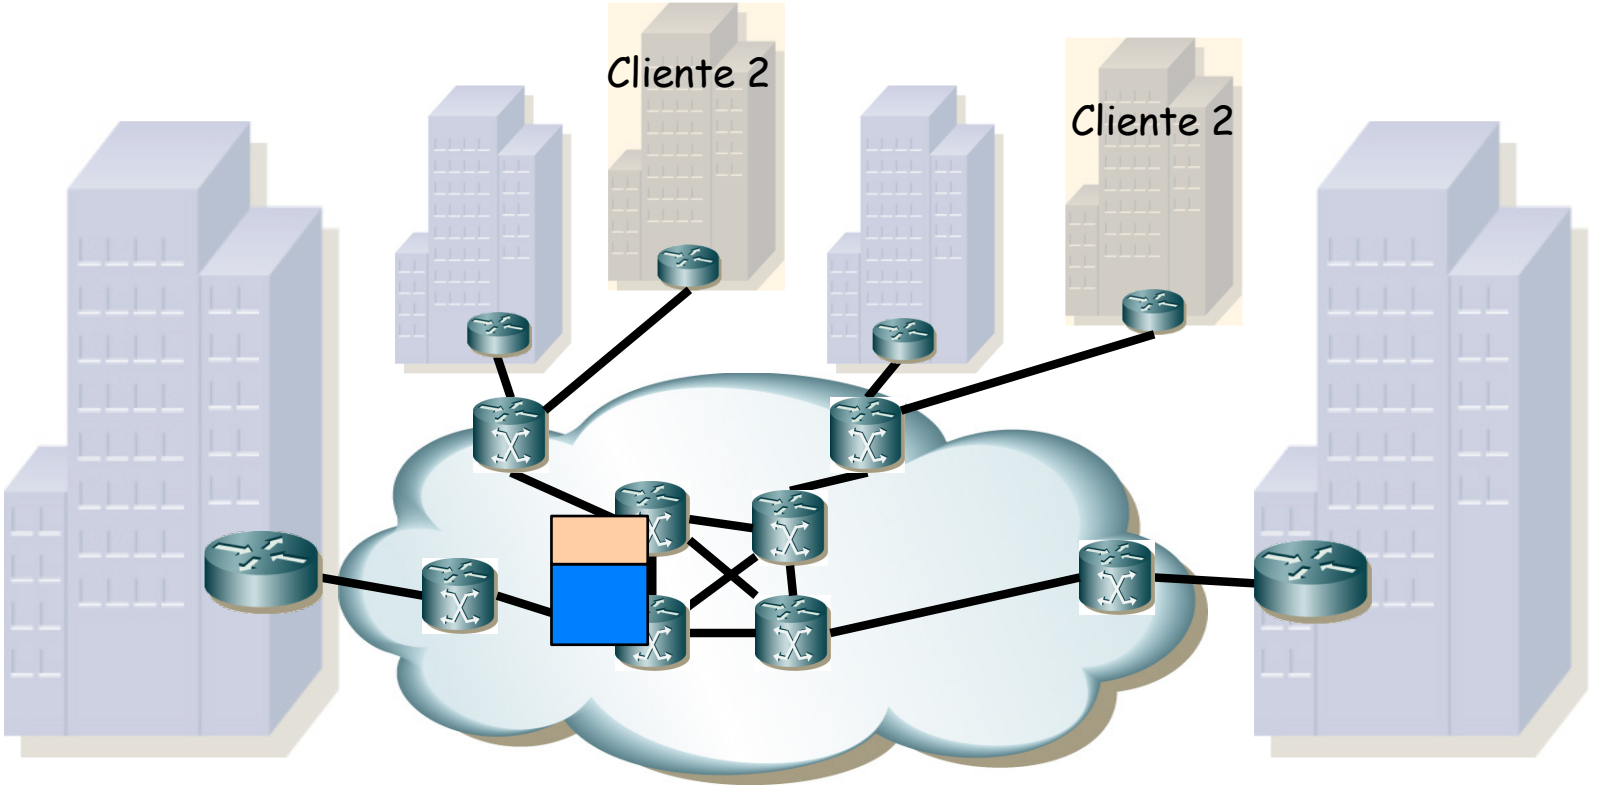

L3VPN: MPLS

- ¿Y en los P routers? ¿Reenvían en función de esa etiqueta?
- Se crean LSPs entre los PEs (“Tunnel LSPs”)
- Los P routers reenvían en función de esa etiqueta externa (...)

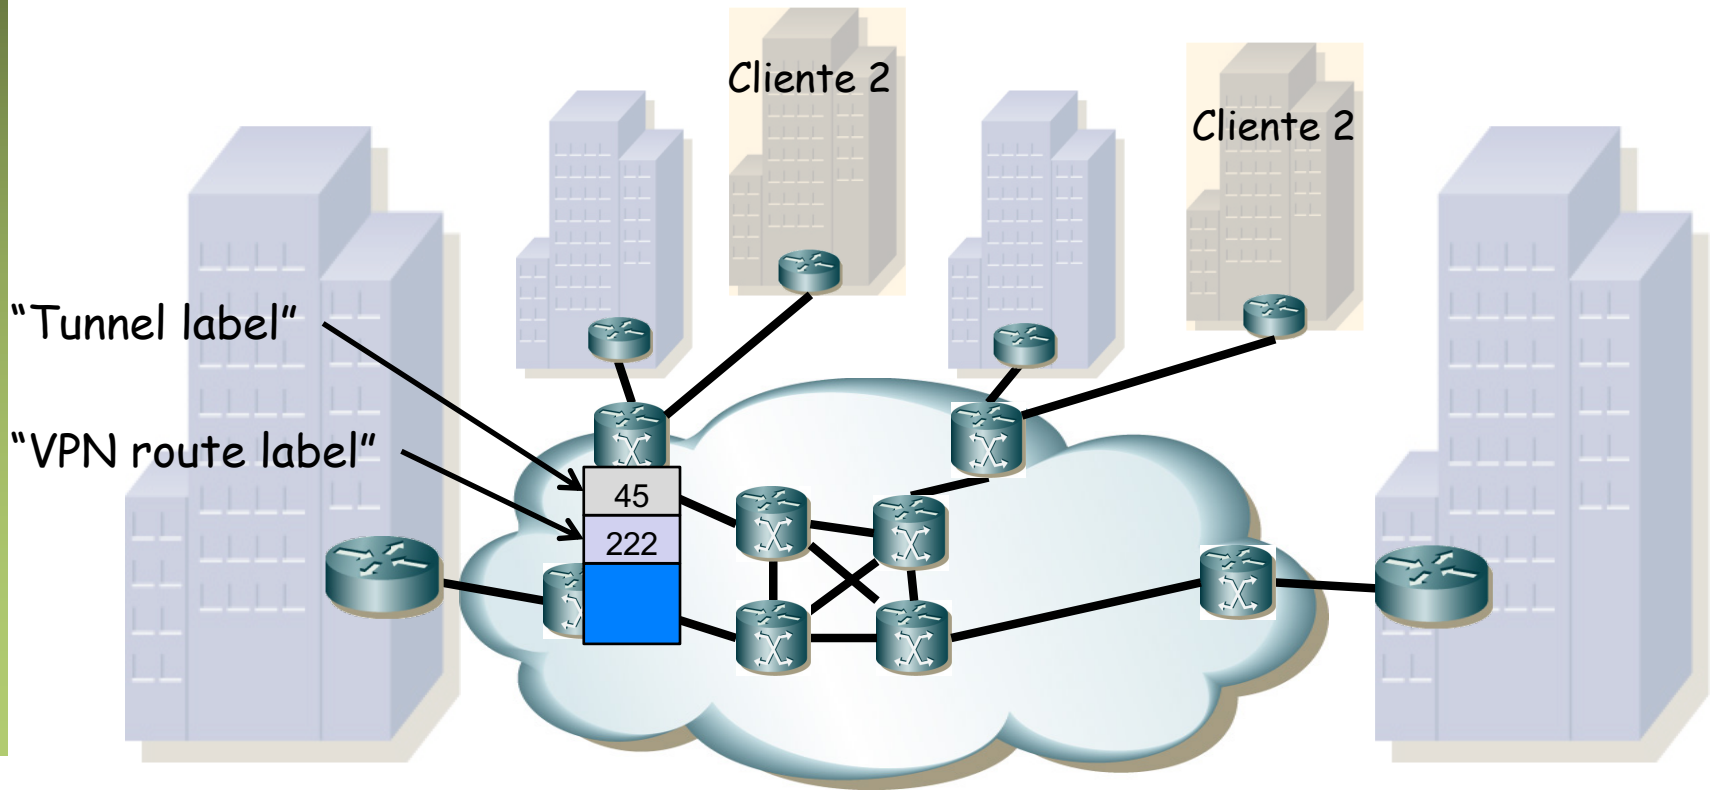

L3VPN: MPLS

- ¿Y en los P routers? ¿Reenvían en función de esa etiqueta?
- Se crean LSPs entre los PEs (“Tunnel LSPs”)
- Los P routers reenvían en función de esa etiqueta externa
- (…)

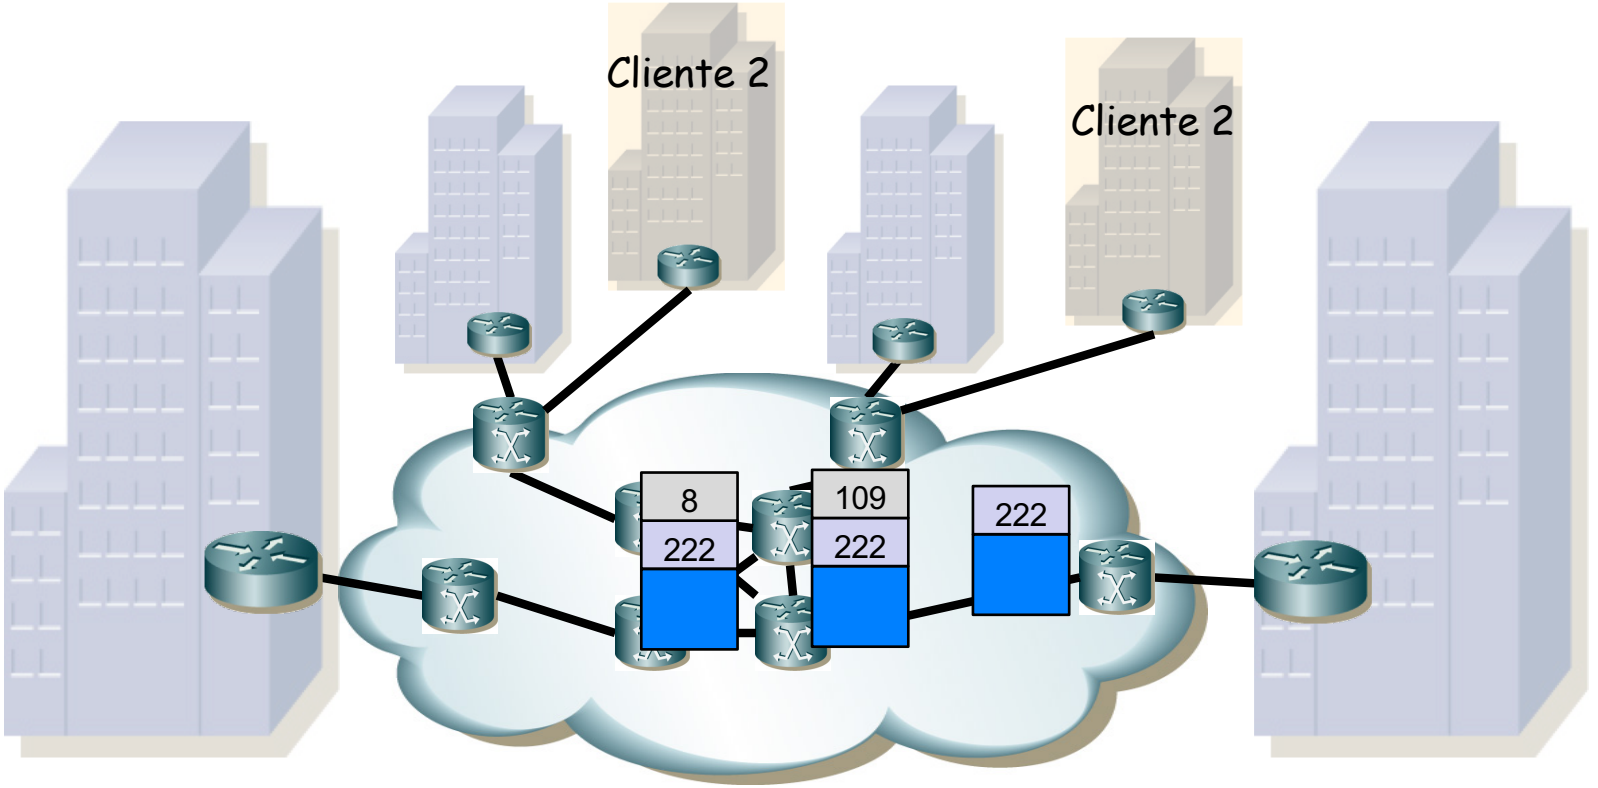

L3VPN: MPLS

- ¿Y en los P routers? ¿Reenvían en función de esa etiqueta?
- Se crean LSPs entre los PEs (“Tunnel LSPs”)
- Los P routers reenvían en función de esa etiqueta externa
- Un full-mesh entre los PEs que compartan VRF
- Podrían ser otro tipo de túneles (GRE o IP en IP, RFC 4797), lo cual elimina el requerimiento de una red de transporte MPLS

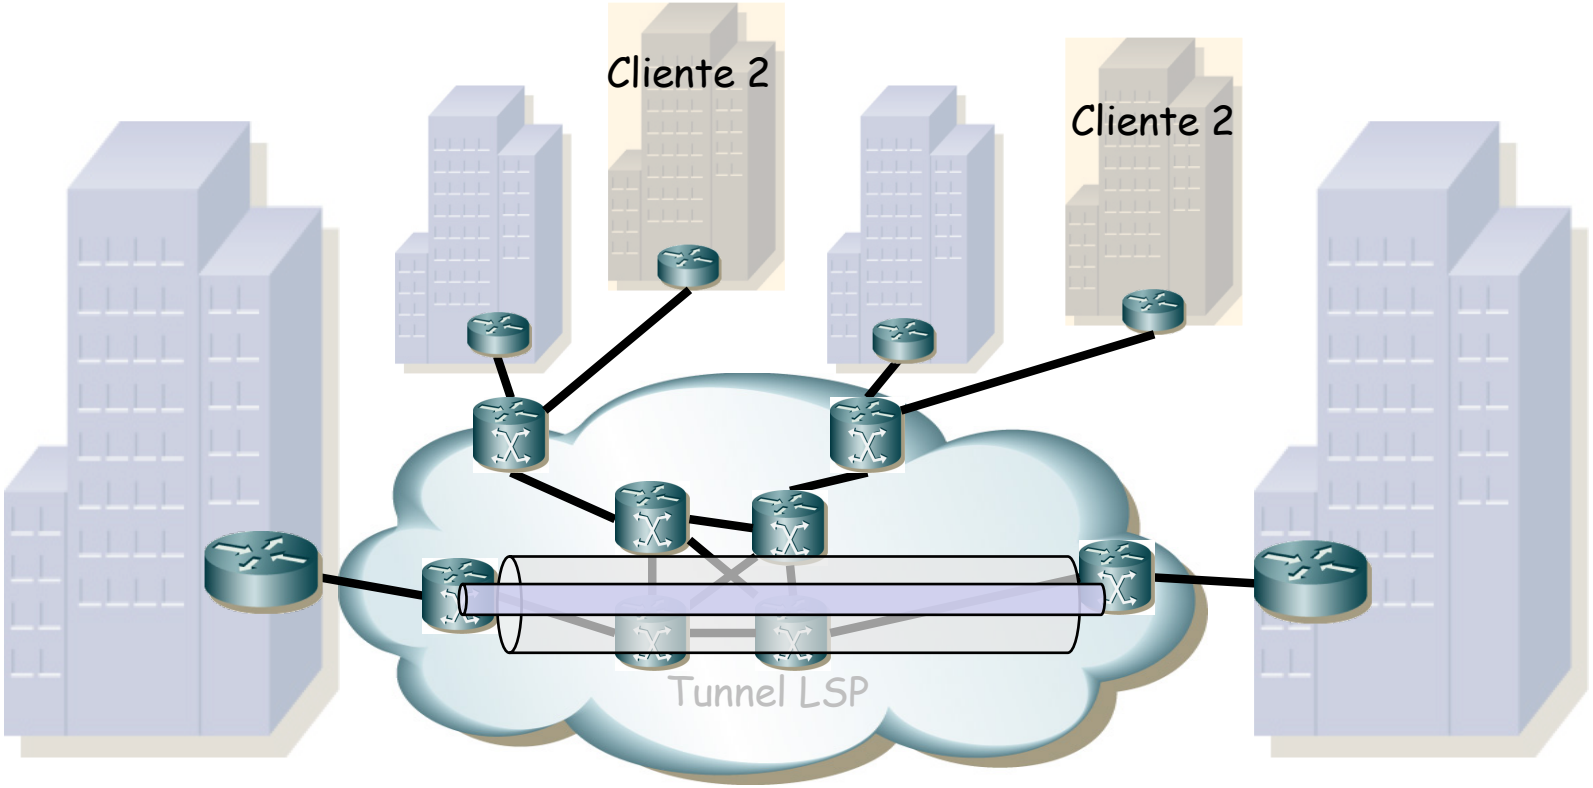

Recapitulando

- Un LSP entre cada pareja de PEs
- Hacen de túnel para los LSPs de cada cliente
- Cada PE una VRF para cada cliente
- Dado el interfaz de entrada del paquete distingue al cliente y su VRF
- La VRF indica la etiqueta MPLS a añadir y el puerto de salida
- Aprendió esa ruta y su etiqueta asociada mediante MP-BGP
- Asoció esa ruta a esa VRF en base al RT
- Distingue esa ruta de otra que tenga la misma dirección IP con el RD

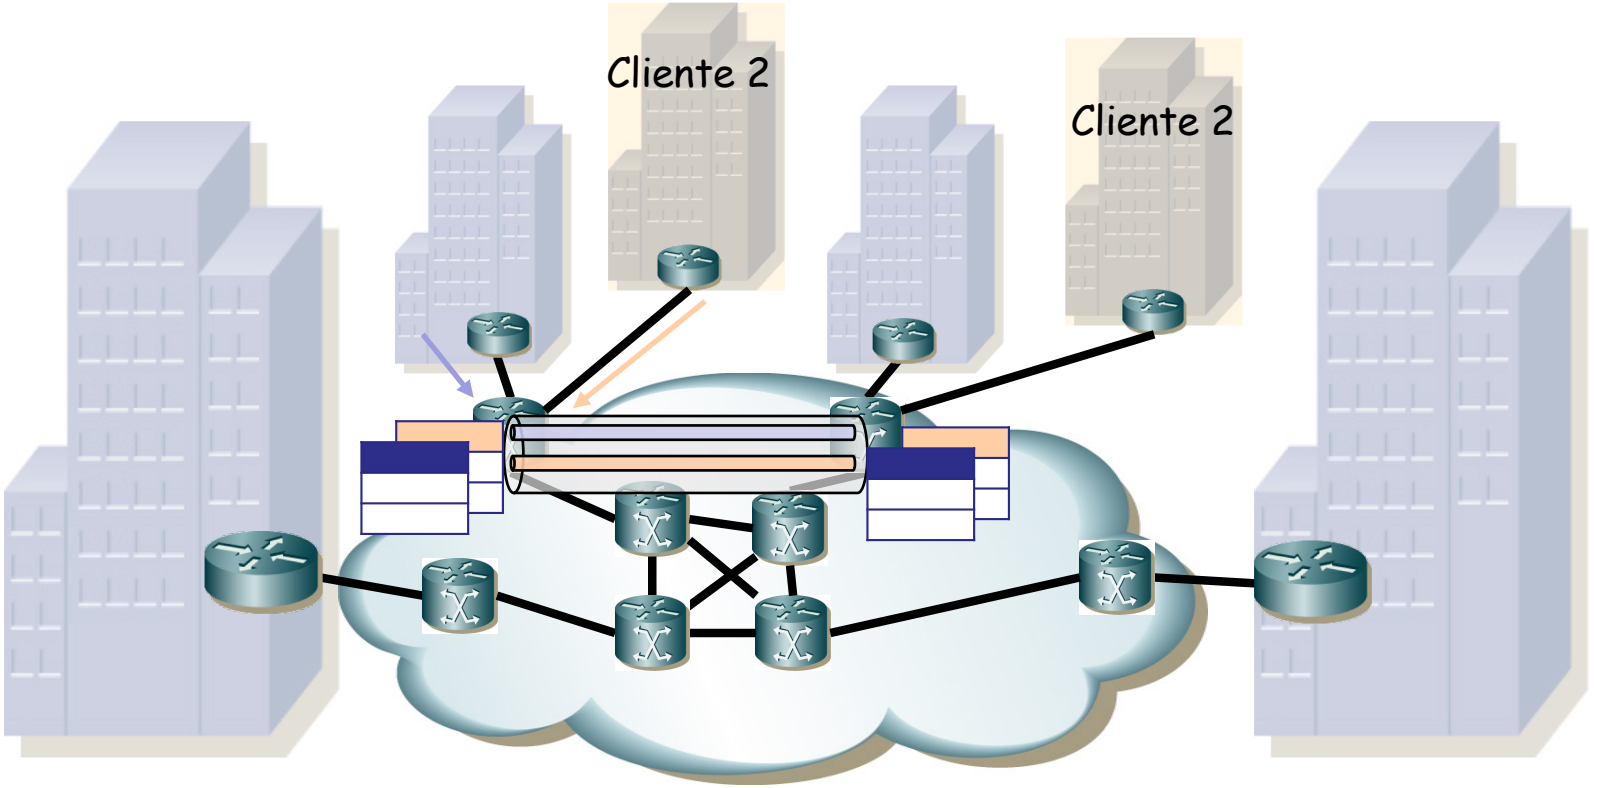

Recapitulando

- Esa etiqueta corresponde al LSP del usuario
- El puerto de salida es el LSP entre los dos PEs
- Se le añade otra etiqueta que identifica al LSP entre esos dos PEs
- Los P routers reenvían en función de esa etiqueta externa
- Los P routers no ”ven” la etiqueta interna y por lo tanto no ven los LSPs de usuarios, solo la malla entre los PEs

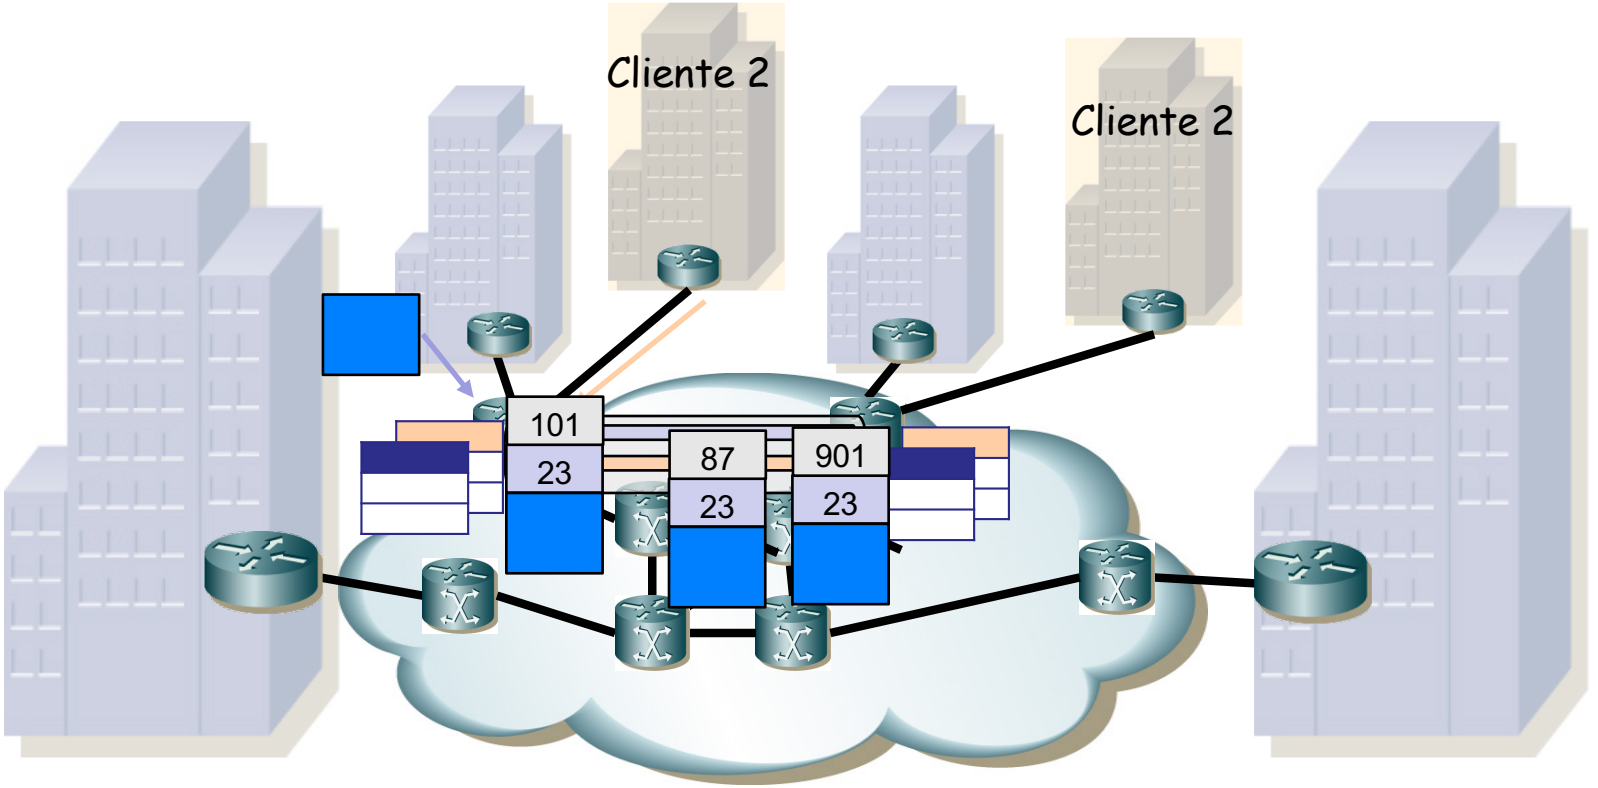

Recapitulando

- En el PE de egreso la etiqueta del LSP permite identificar la VRF y con ella la tabla de rutas

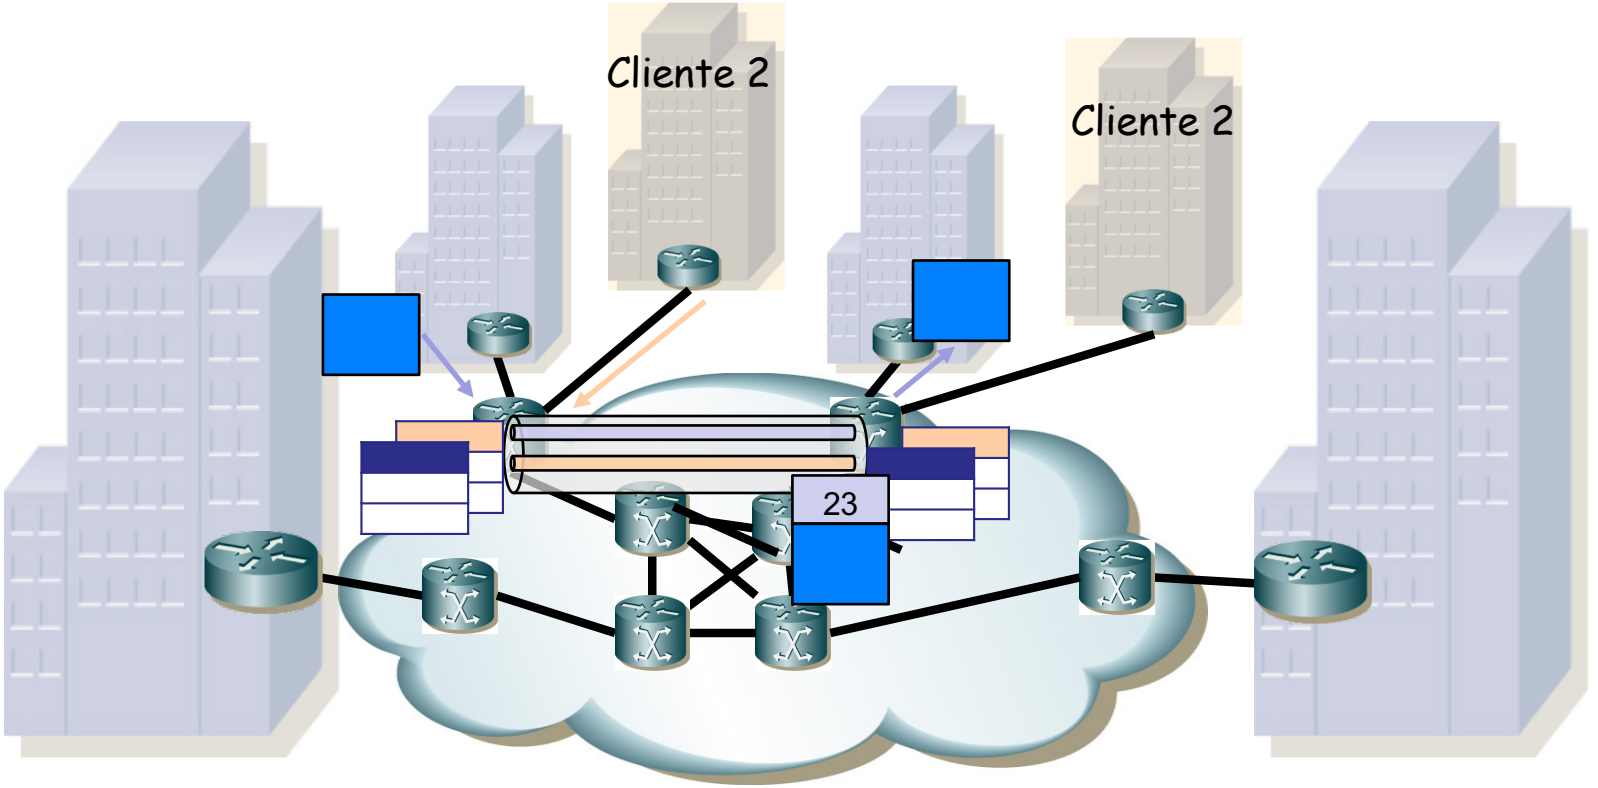

L3VPN con GRE

- Los túneles entre los PE pueden ser túneles GRE o simple IPoIP
- Entonces la red de transporte ya no necesita ser MPLS, es simple IP

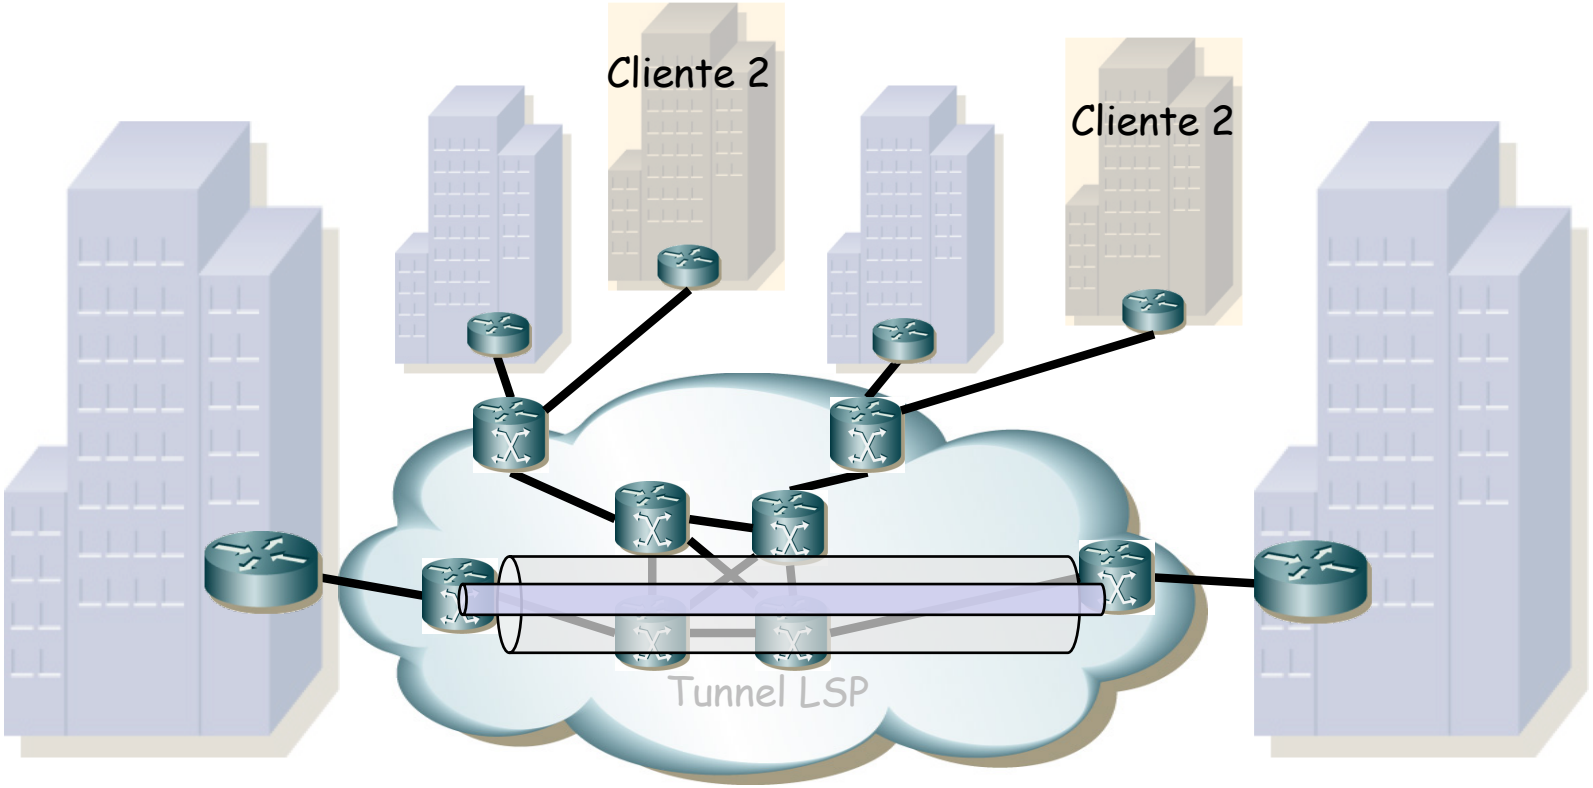

MPLS in GRE in IP

- RFC 4023 “Encapsulating MPLS in IP or Generic Ruting Encapsulation (GRE)” (Motorola, Juniper, Cisco, 2005)
- El “*delivery protocol*” podría ser IP (protocol = 47 = GRE)
- El “*payload packet*” podría ser MPLS (Ethertype 0x8847 para unicast y ese mismo ó 0x8848 para multicast, RFC 5332)
- EoMPLSoGRE = Ethernet over MPLS over GRE
- Al transportarse sobre IP puede emplear IPSec
- RFC 4023 contempla también que MPLS se transporte directamente sobre IP, lo cual es más eficiente (sin GRE, protocolo 137 sobre IP)
- Puede haber motivos para tener GRE (exista el túnel con anterioridad, la implementación del equipo lo requiera en su fastpath, etc)

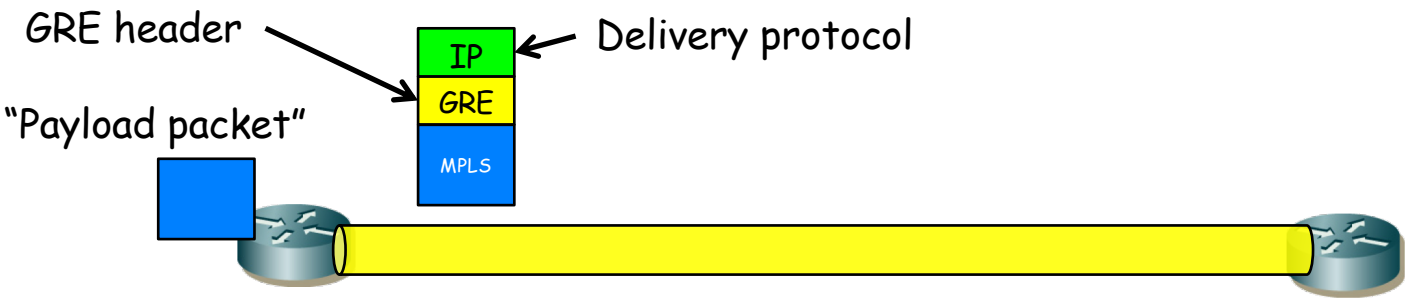

RD y RT

- RD permite anuncios del mismo prefijo que se puedan diferenciar
- Se suele asociar a una VRF
- RT permite importar en una VRF los anuncios con ciertos RTs
- En el anuncio de los prefijos se pone el RT que emplearemos para importar en otras VRFs
- Esto se puede usar para que unos PEs importen (para el mismo cliente) diferentes rutas
- Unos pueden importar por ejemplo los anuncios de un solo RT y otros los de varios

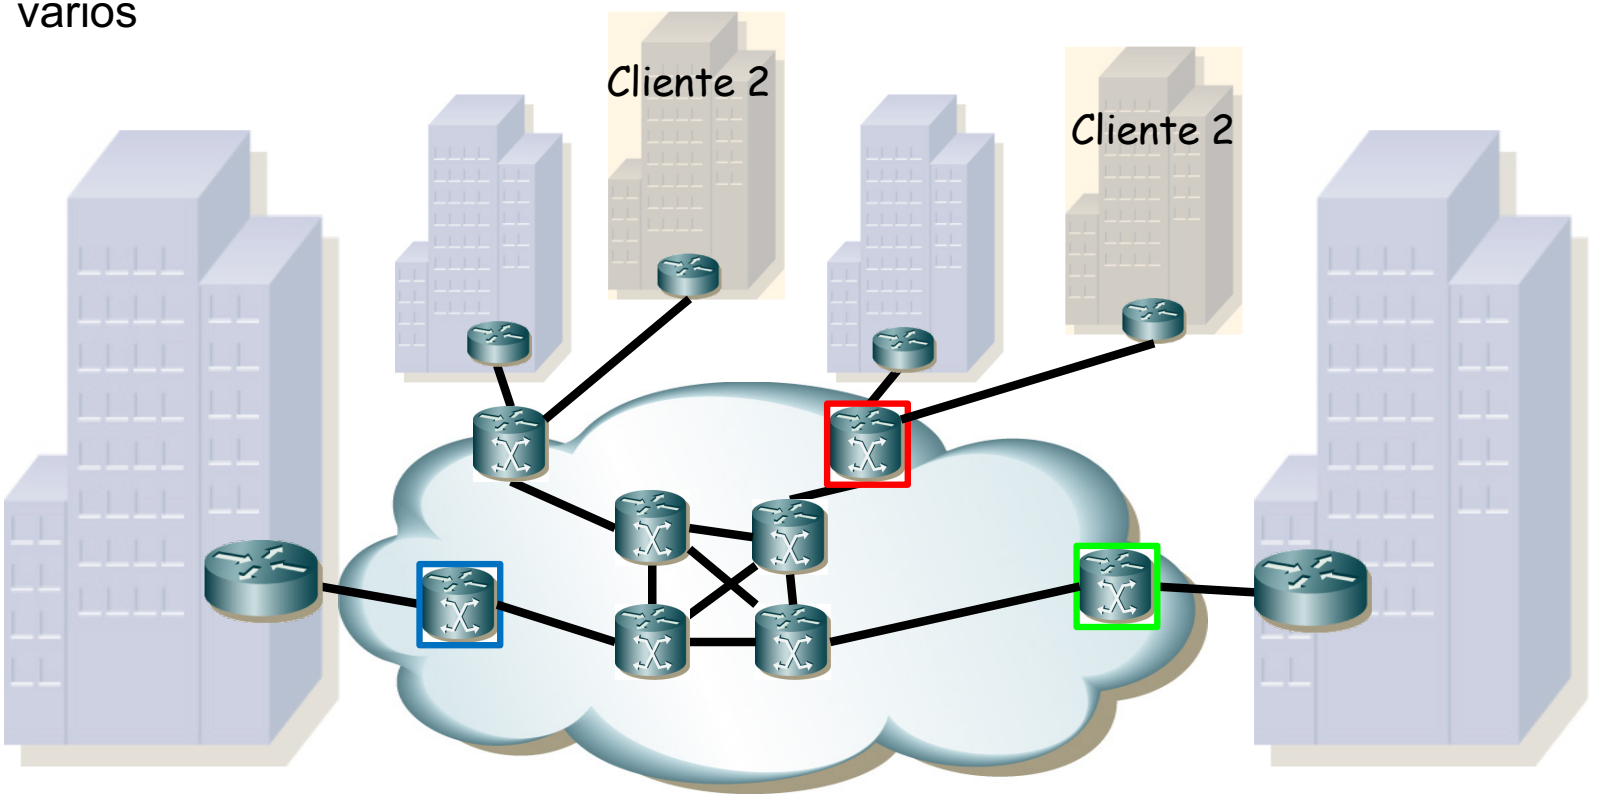

RD y RT

- Por ejemplo para el cliente 1 cada PE podría hacer sus anuncios con un RT diferente
- Podríamos decirle a los PEs amarillo, azul y verde que importen del RT rojo
- Y decirle al PE rojo que importe de los RTs amarillo, azul y verde
- Con eso verde, azul y amarillo puedes comunicarse con rojo pero no entre ellos

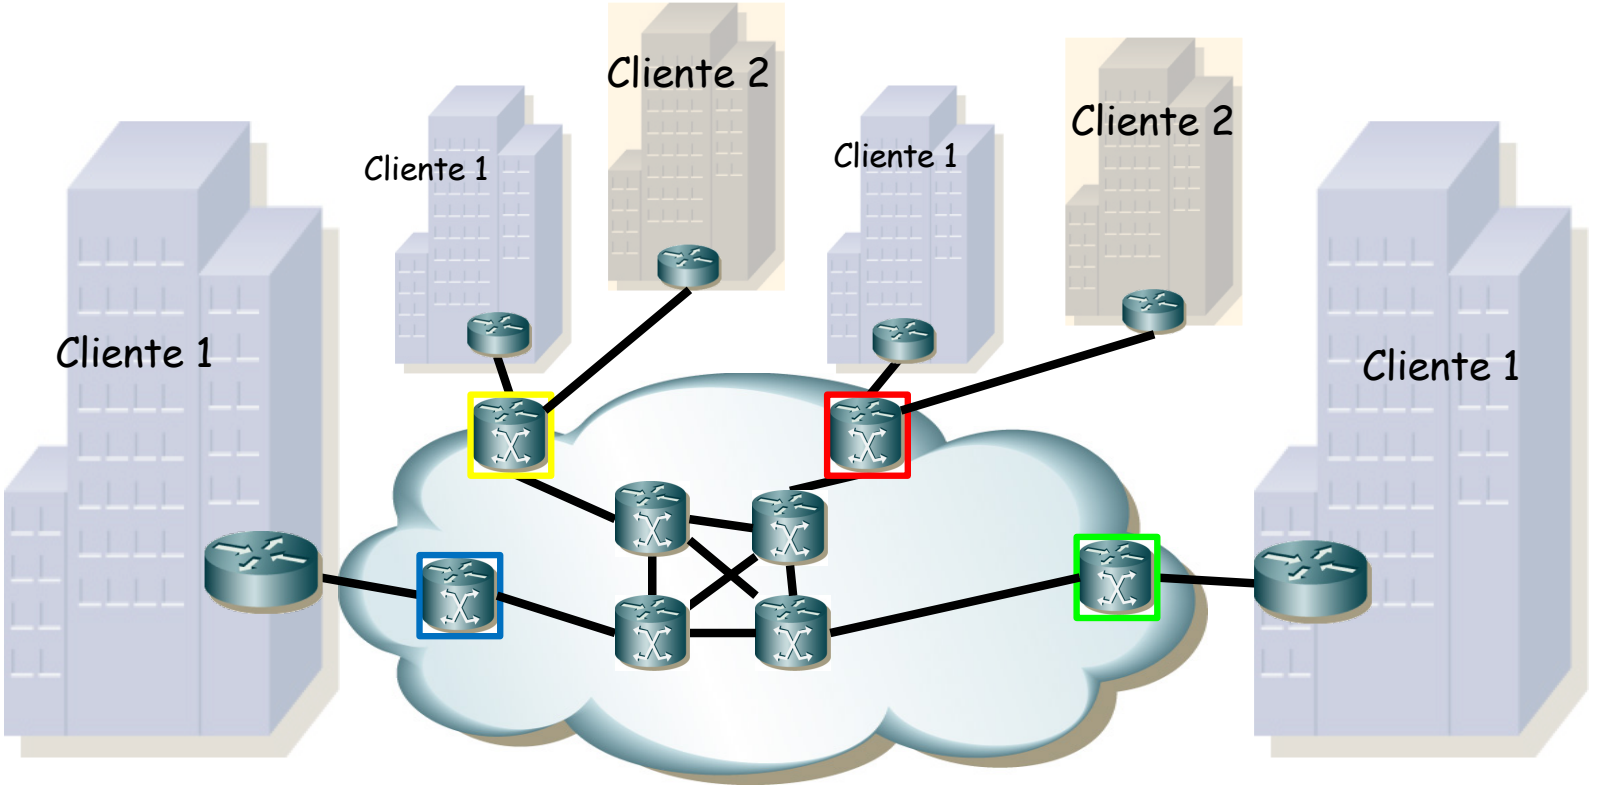

upna
Universidad Pública de Navarra
Nafarroako Unibertsitate Publikoa

Redes de Nueva Generación
Área de Ingeniería Telemática

VPLS

MPLS y VPLS

- *"Virtual Private LAN Service",* una VPN layer 2 (RFC 4664, Acreo y Cisco, 2006)
- Interconecta múltiples *sites* en un solo dominio puenteado
- Todos los extremos se comportan como si estuvieran en una LAN
- *E-LAN Service*
- Transporta Ethernet así que sobre ella el cliente puede usar IP o cualquier otro protocolo
- Los equipos de usuario (Customer Edge) pueden ser switches o routers
- Transporte MPLS u otra solución de túneles (GRE, L2TP, IPsec)

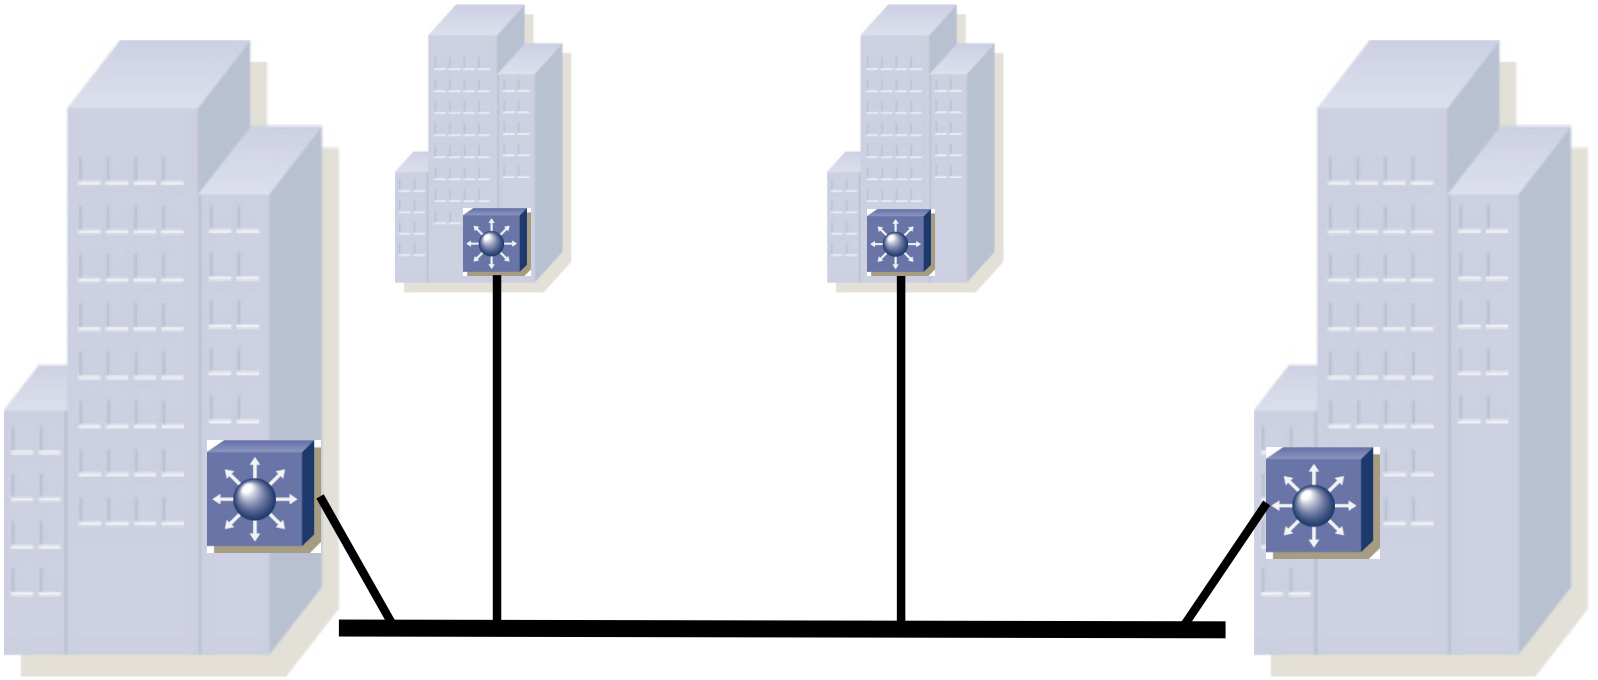

MPLS y VPLS

- El dominio MPLS puede transportar las tramas MPLS sobre IP o sobre otra tecnología
- La red puede dar servicio VPLS a más de un cliente
- El PE hace aprendizaje de direcciones MAC y replicación de tramas de forma independiente para cada cliente
- No interfiere el servicio de un usuario al otro (pueden por ejemplo emplear el mismo direccionamiento IP)
- Los equipos frontera establecen entre ellos los LSPs necesarios para el servicio multiacceso

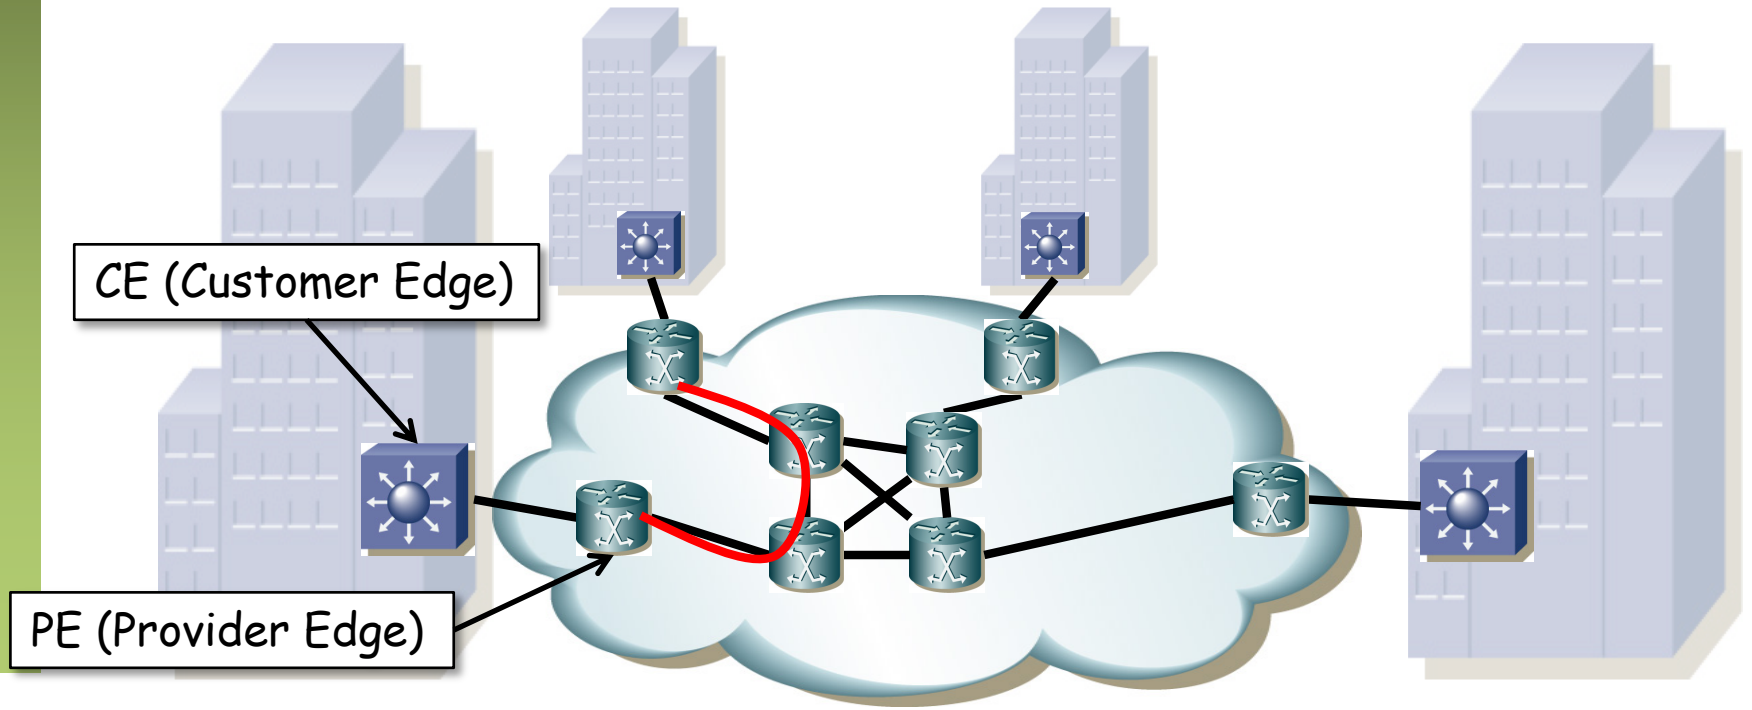

MPLS y VPLS

- Establecen un *full-mesh* entre los nodos frontera
- Para ello disponen de RSVP-TE (o LDP)
- (…)

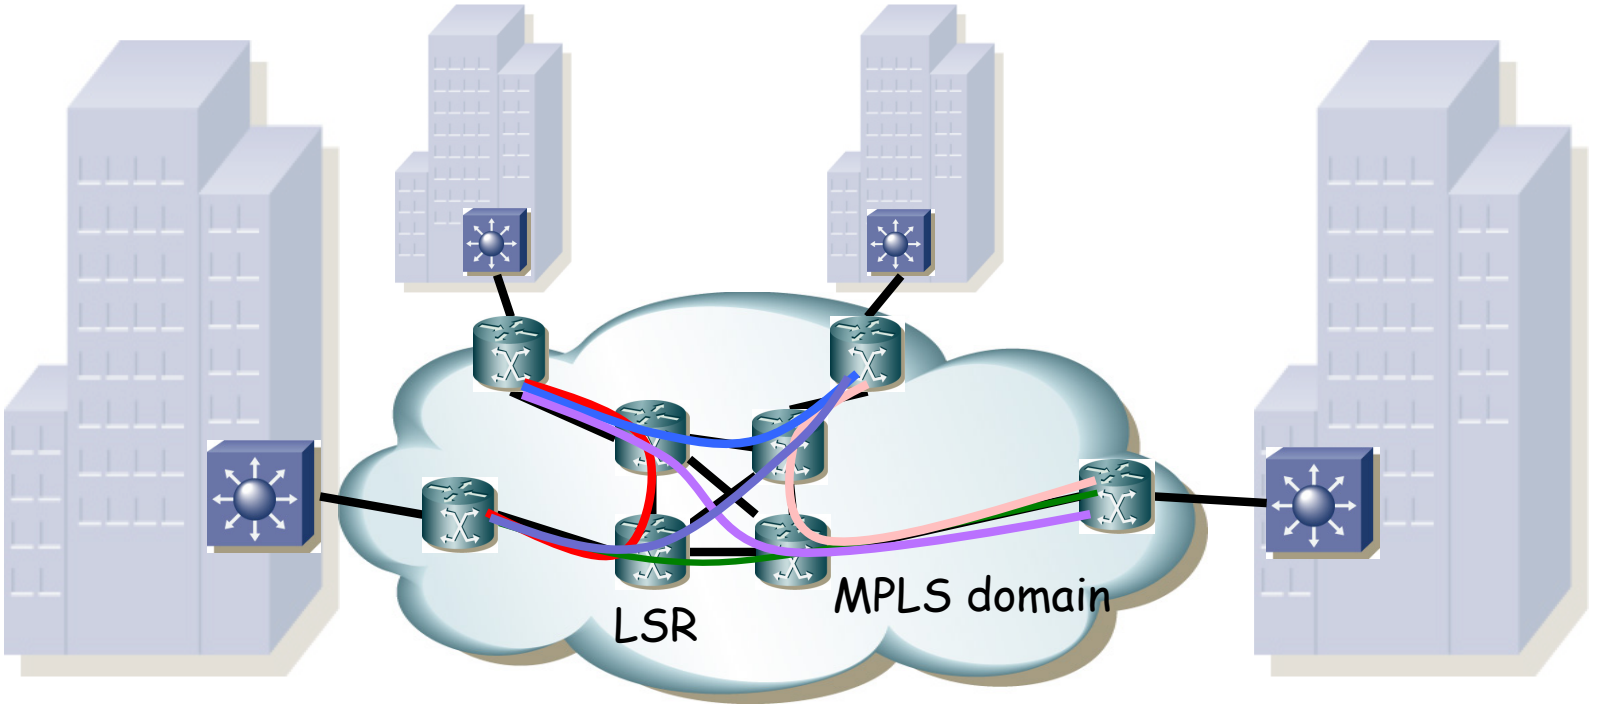

MPLS y VPLS

- Establecen un *full-mesh* entre los nodos frontera
- Para ello disponen de RSVP-TE (o LDP)
- Esos LSPs son globales al servicio VPLS, no particulares para cada cliente
- Es decir, puede haber otras LANs creadas con VPLS, para las sedes de otra empresa, y emplearán los mismos LSPs
- ¿Y para diferenciar a los clientes?

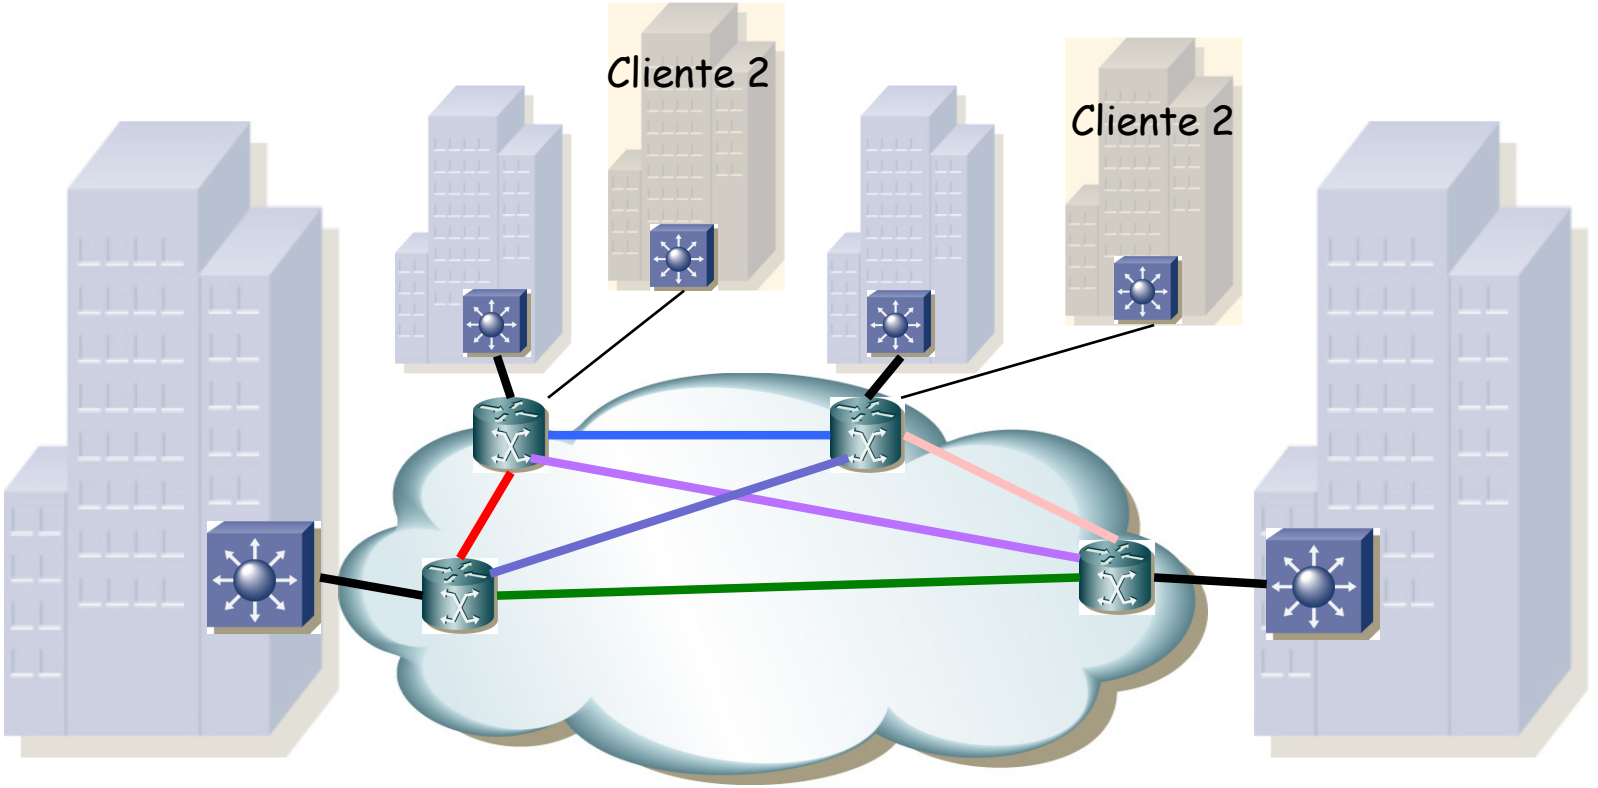

VPLS y PWE

- Por cada instancia VPLS (cada cliente) se establece un full mesh de *pseudo-wires* (PWs) entre los PEs
- RFC 3985 “Pseudo Wire Emulation Edge-to-Edge (PWE3) Architecture” (Cisco Systems, Overture Networks, 2005)
- Un PW emula un circuito, por ejemplo para transportar un E1 o un PVC ATM
- También puede transportar Ethernet, AAL5, SDH, etc

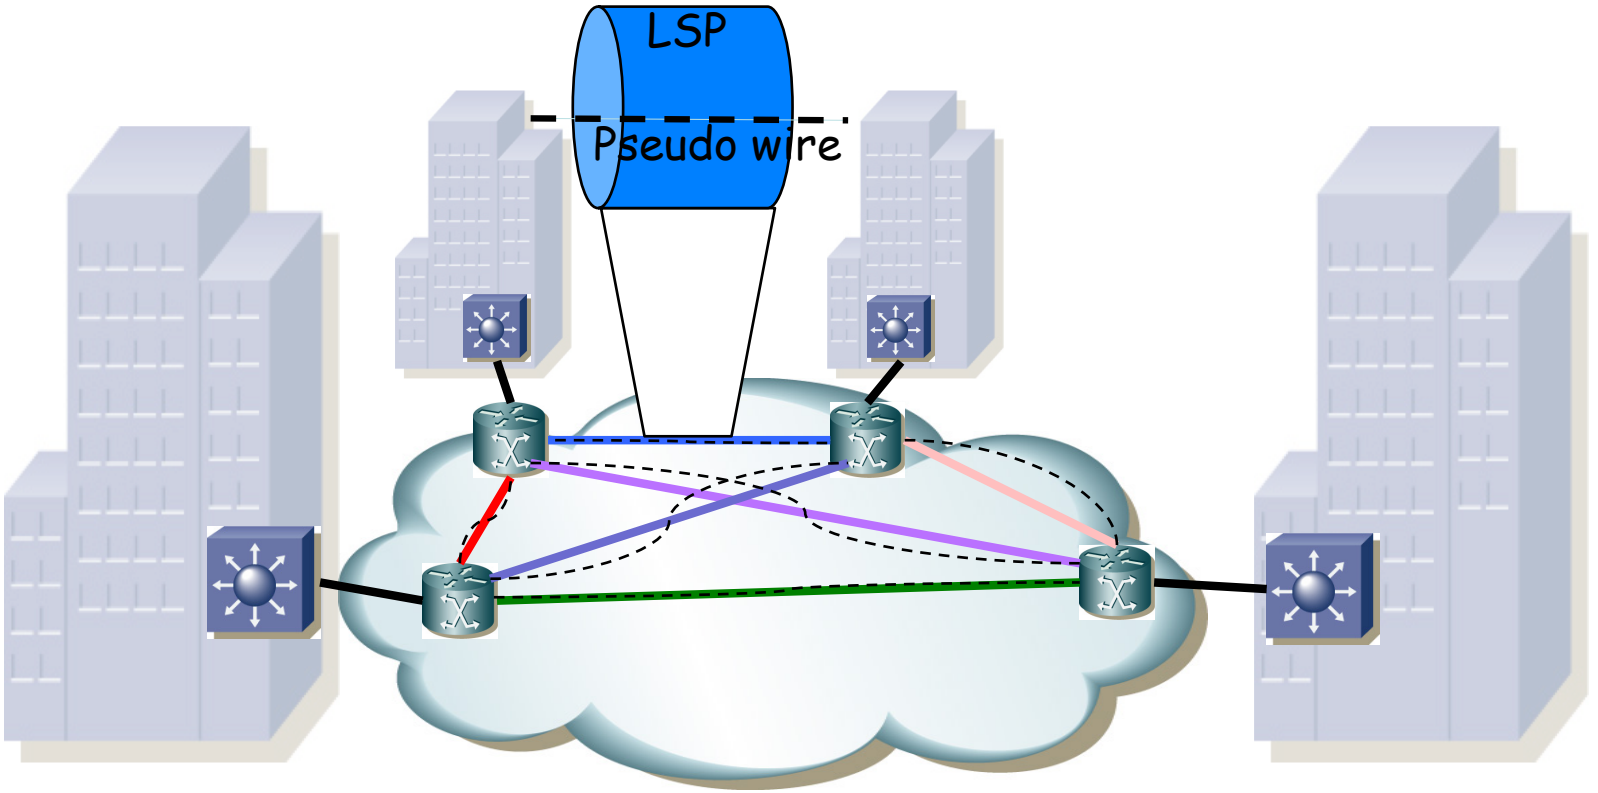

VPLS y PWE

- El full-mesh de PWs hace que los PE puedan enviarse directamente los unos a los otros
- No necesitan hacer reenvío y no hace falta resolver posibles bucles
- Simplemente se implementa una solución que se llama de "*split horizon*":
  - Un PE no debe reenviar tráfico de un PW a otro en el mismo mesh VPLS
- El aprendizaje de direcciones MAC se hace en el plano de datos (con la llegada de tramas Ethernet)

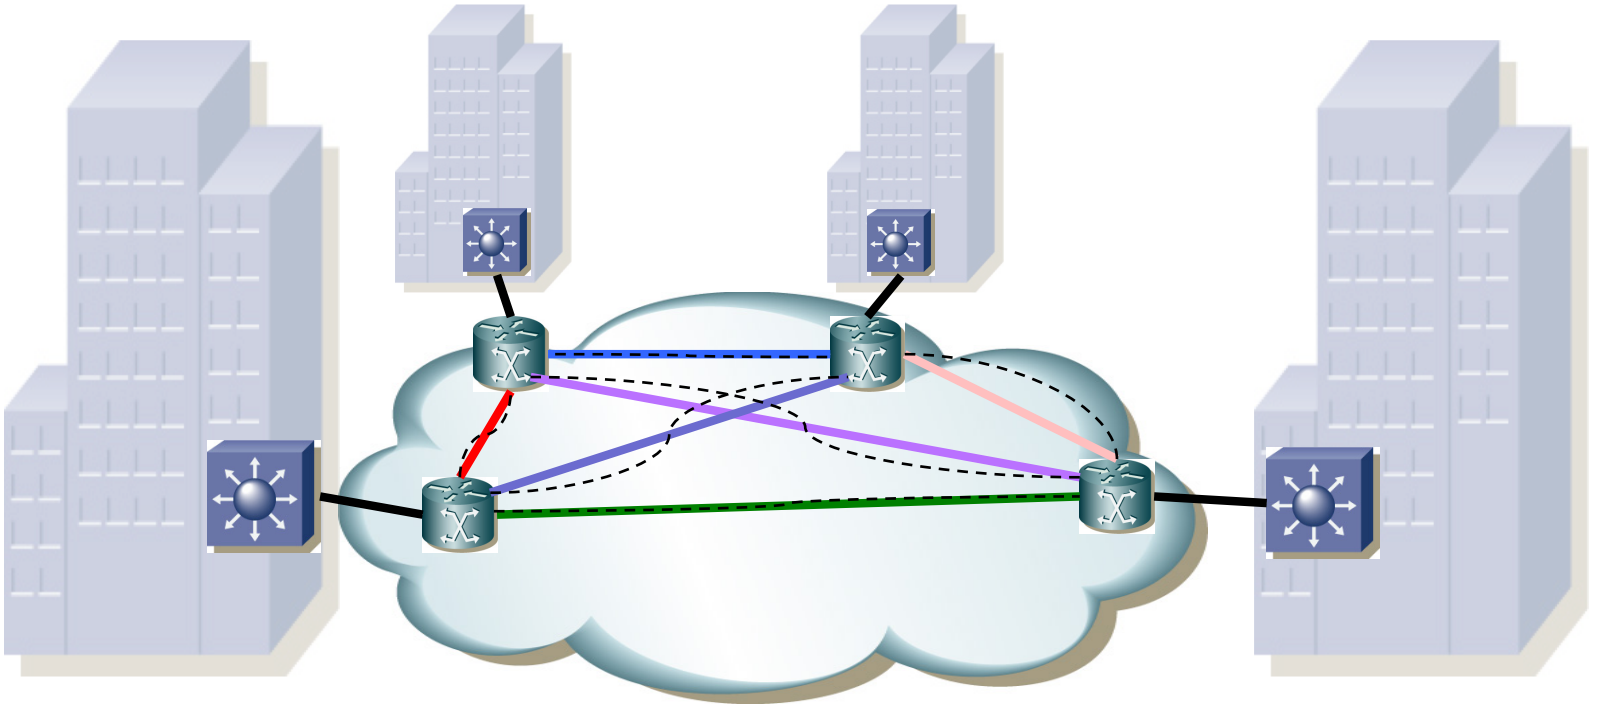

VPLS y PWE

- Sí puede haber ciclos, pero creados por el usuario para obtener redundancia
- En ese caso podrá emplear STP
- Las BPDUs se transportarían normalmente por el mesh VPLS

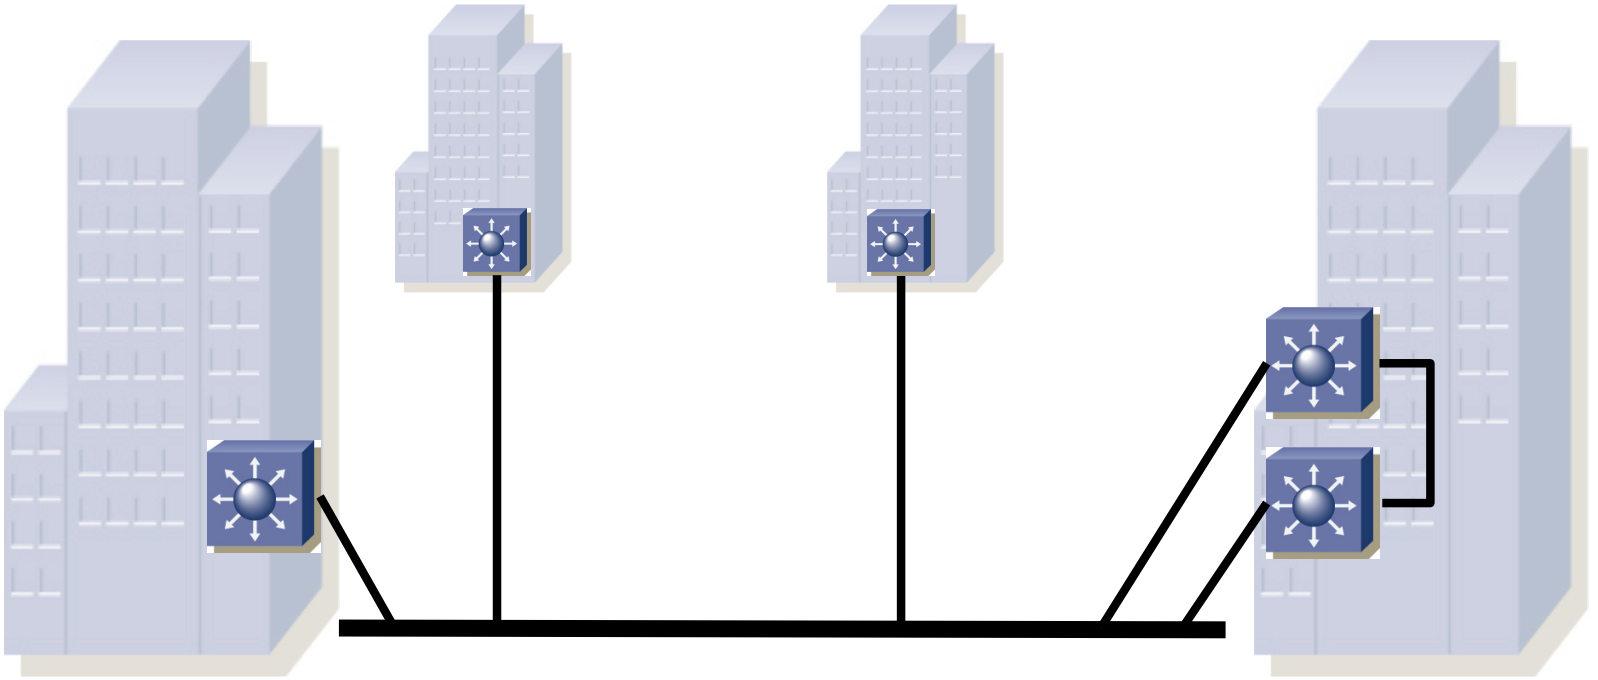

VPLS Control Plane

- Dos alternativas para el establecimiento de los pseudo-wires:
  - RFC 4761 “Virtual Private LAN Service (VPLS) Using BGP or Auto-Discovery and Signaling”
  - RFC 4762 “Virtual Private LAN Service (VPLS) Using Label Distribution Protocol (LDP) Signaling”
- Repito: el aprendizaje de direcciones MAC se hace en el plano de datos, es decir, con la dirección MAC origen de la trama recibida

VPLS - Problemas

Problemas en VPLS

- Se deben establecer Nx(N-1)/2 pseudo-wires
- Problema de escalabilidad (cantidad de tráfico de control)
- Replicación de paquetes que sufren inundación:
  - Se lleva a cabo en el PE de entrada
  - Se dirigen punto-a-punto a cada otro PE del servicio
  - Mayor trabajo en el PE
  - Más uso de capacidad
  - Mayor retardo (si hay que enviar N veces la trama por N PWs que se implementan sobre el mismo LSP irán en serie)
- Si se añade un acceso del cliente, a un PE diferente, se deben crear los PWs, lo cual implica reconfigurar los demás PEs
- Para despliegues pequeños
- Mejoras:
  - H-VPLS (Hierarchical VPLS)
  - Hierarchical BGP VPLS

upna
Universidad Pública de Navarra
Nafarroako Unibertsitate Publikoa

Redes de Nueva Generación
Área de Ingeniería Telemática

EVPN

Limitaciones de VPLS

- Solo soporta *Single-Active Redundancy Mode* (no *all-active*)
- Ejemplo:
  - CE un LAG hacia dos PEs
  - Reparte tráfico entre ellos
  - Al llegar a otro PE llega la misma dirección MAC origen por dos PWs, saltando la MAC aprendida de uno a otro (...)
- Active-Active solo mediante soluciones propietarias (vPC, VSS, etc)

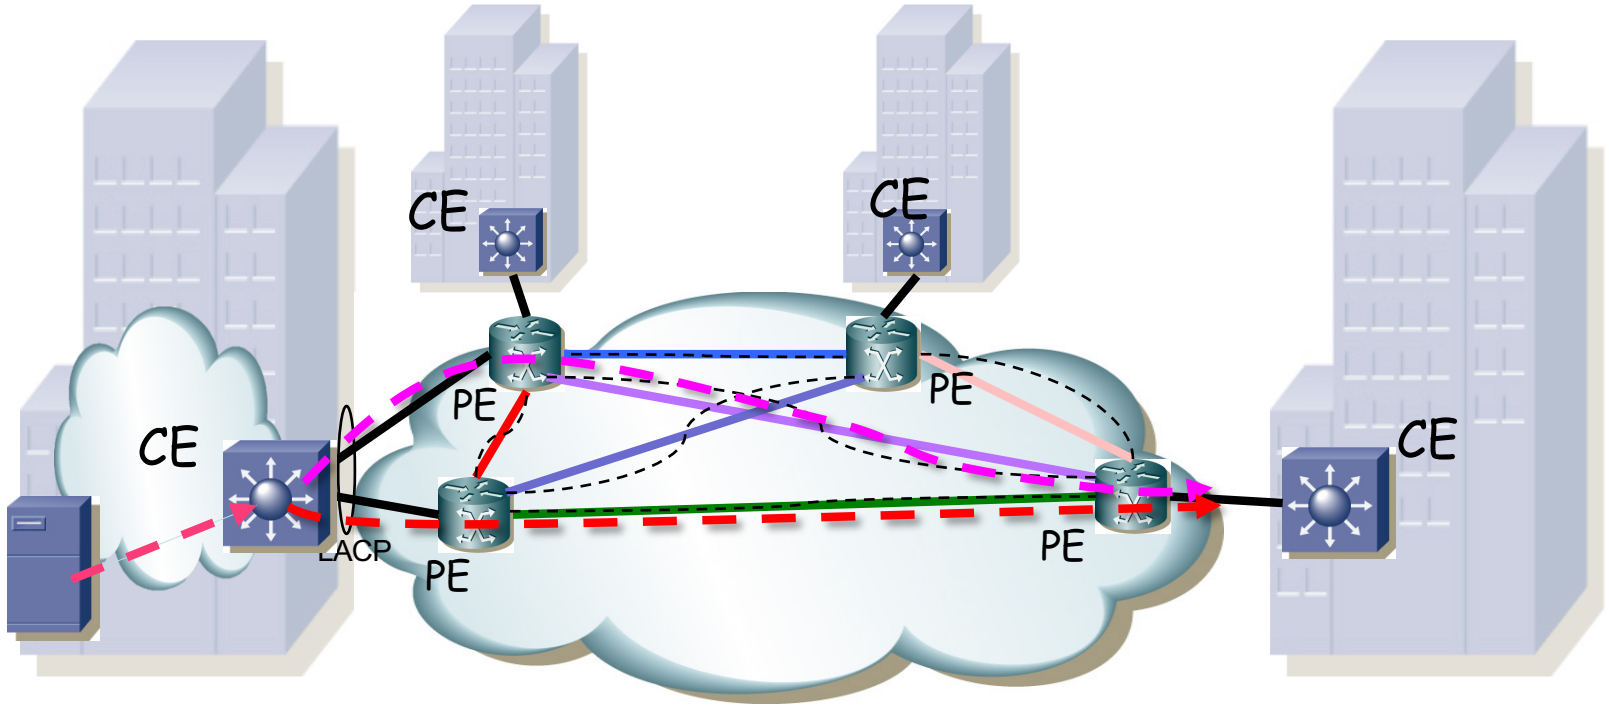

Limitaciones de VPLS

- Solo soporta *Single-Active Redundancy Mode* (no *all-active*)
- Ejemplo:
  - Dos CEs con LAGs (redundancia en el CE)
  - BUM es enviado por PE a todos los demás PEs y puede volver por el otro CE (...)

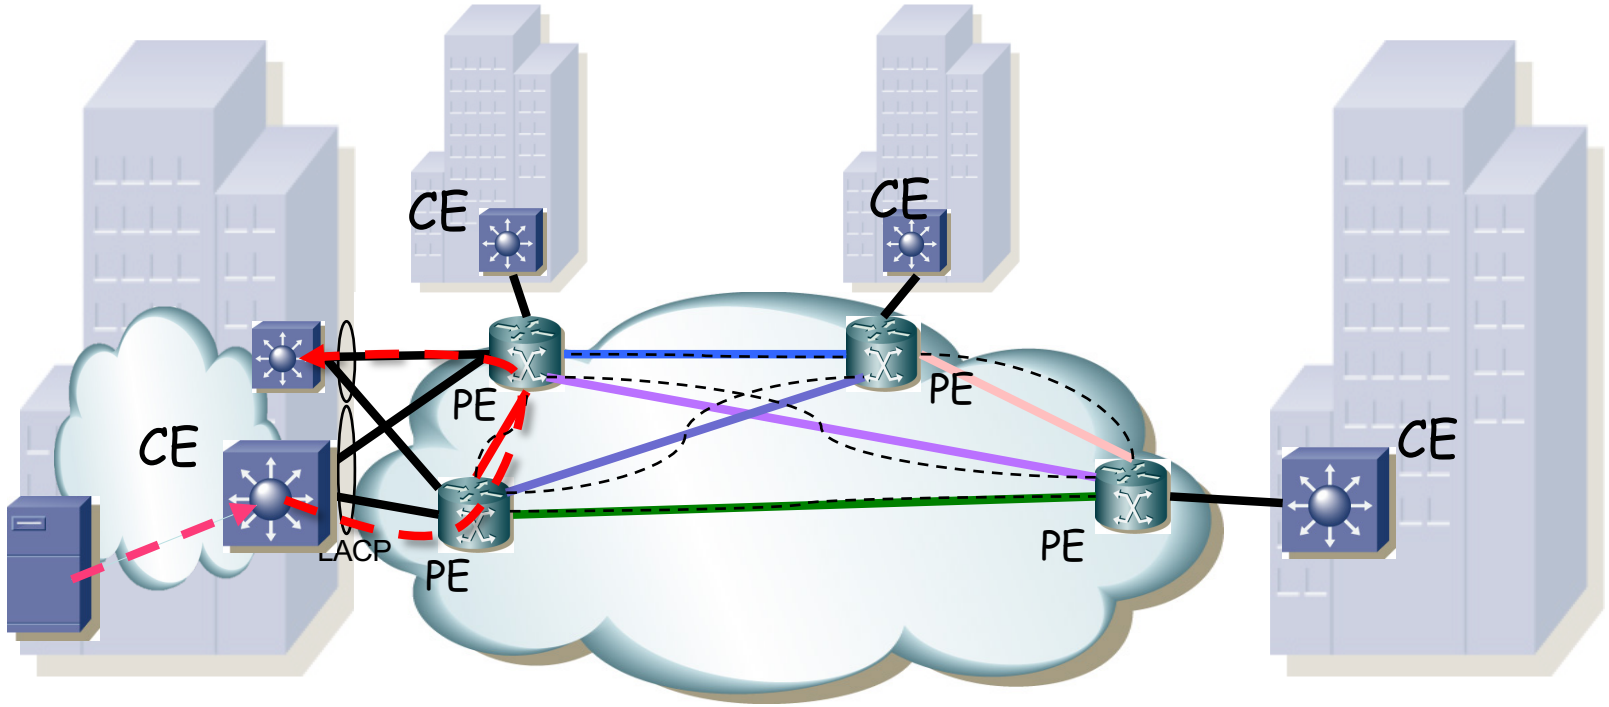

Limitaciones de VPLS

- Solo soporta *Single-Active Redundancy Mode* (no *all-active*)
- Ejemplo:
  - No hay load balancing en el sentido de respuesta si el hash lleva a emplear uno solo de los PEs (...)
  - El otro extremo solo aprende la dirección MAC por un PW
  - En cualquier caso no la puede aprender por dos PWs (...)

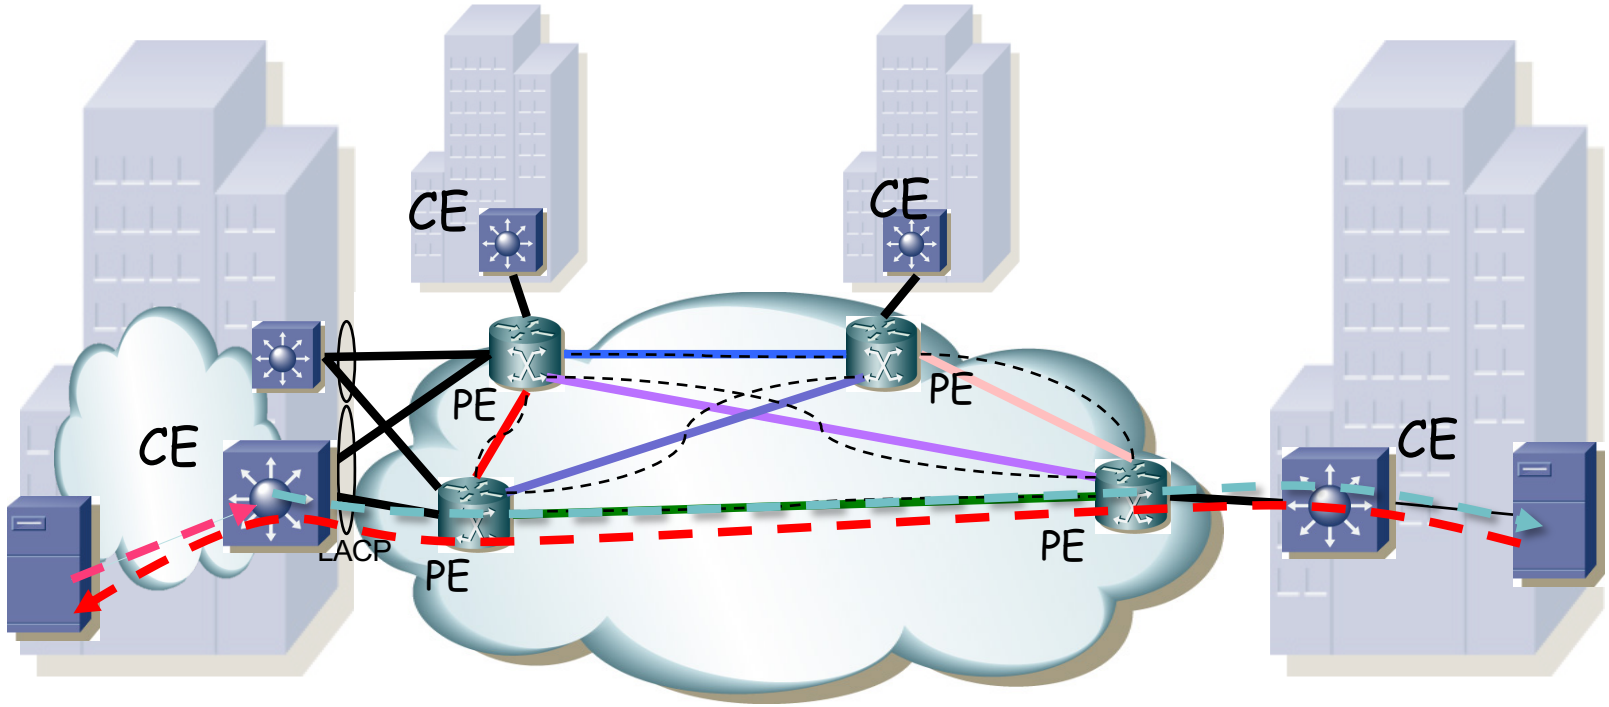

EVPN

- RFC 7209 “Requirements for Ethernet VPN (EVPN)”, Cisco, Arktan, AT&T, Verizon, Alcatel-Lucent, Bloomberg (2014)
- RFC 7432 “BGP MPLS-Based Ethernet VPN”, Cisco, Arktan, Verizon, Bloomberg, AT&T, Juniper, Alcatel-Lucent (2015)
- Ofrece una VPN capa 2, como VPLS
- Los PEs puede estar conectados mediante LSPs o túneles (IP/GRE)
- Emplea un plano de control **BGP** como una L3VPN
- Aprendizaje de direcciones MAC en el plano de control en lugar de en el plano de datos
- Es decir, BGP distribuye Ethernet MACs (opcional el par MAC-IP)
- PEs anuncian direcciones MAC aprendidas del CE, junto con una etiqueta MPLS, al resto de PEs mediante MP-BGP
- Queda abierto cómo aprende el PE del CE (puede ser plano de datos)
- Igual que las L3VPNs emplea *route distinguishers* y *route targets*
- Su uso principal es en DCI

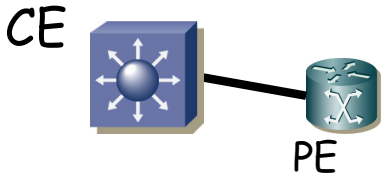

OTV

OTV

- *Overlay Transport Virtualization*
- Solución propietaria de Cisco
- Conectividad Ethernet a través de una red IP
- No hace aprendizaje de direcciones MAC en el plano de datos
- Emplea IS-IS para intercambiar esa información

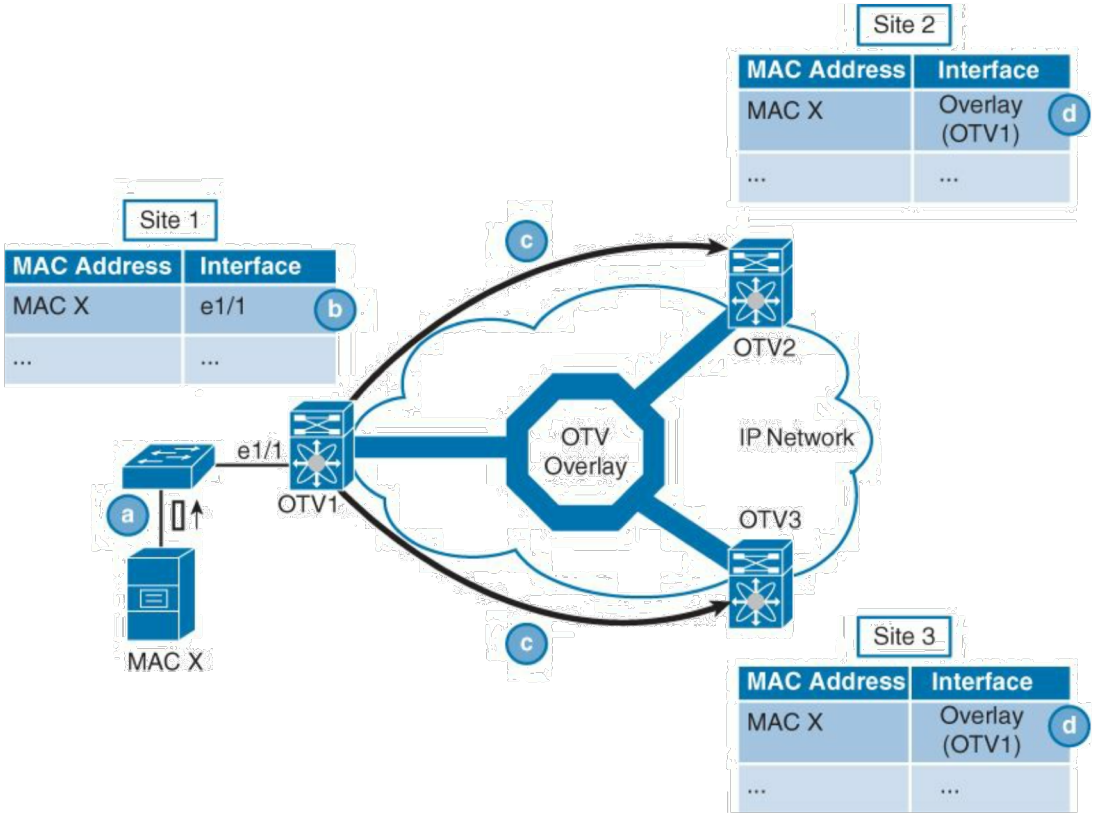

G.A.A.Santana,"Data Center Virtualization Fundamentals", Cisco Press

OTV

- Genera paquetes con DF=1 conteniendo una sola trama Ethernet
- La MTU en la red IP debe poder transportar ese paquete IP
- No transporta BPDUs así que aísla los dominios STP

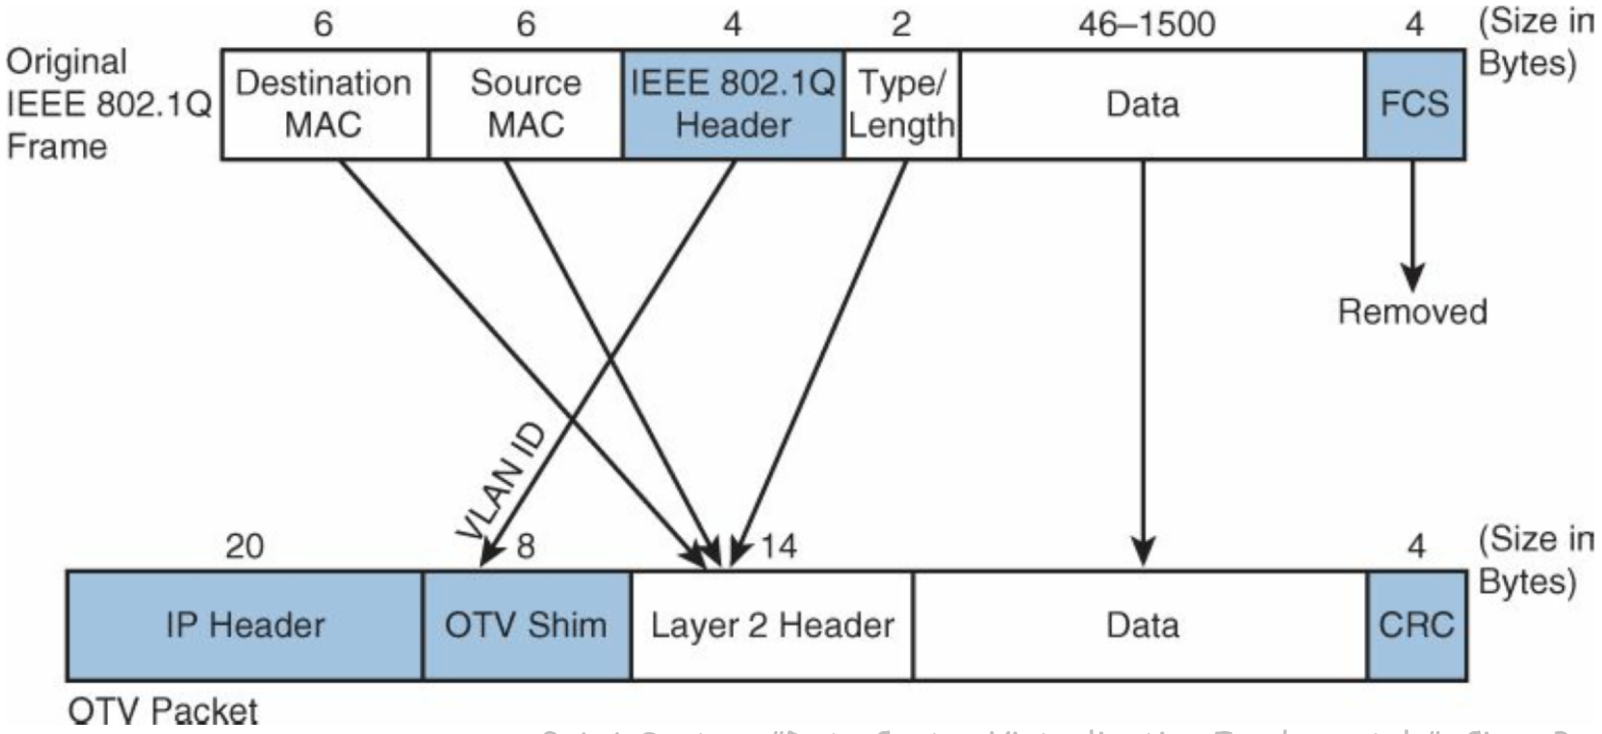

G.A.A.Santana,"Data Center Virtualization Fundamentals", Cisco Press