Protokoły warstwy 2
Przegląd dostępnych opcji

Łukasz Bromirski
lbromirski@cisco.com

PLNOG, Warszawa, marzec 2011

Agenda

- Ethernet
- Spanning Tree
- Praca warstwy drugiej w pierścieniach
- Transport ruchu L2 przez operatora
- Nadzór sieci i diagnostyka
- Nowe standardy
- Q&A

Ethernet

Co się dzieje obecnie i jak to wygląda?

Standardy Carrier Ethernetu

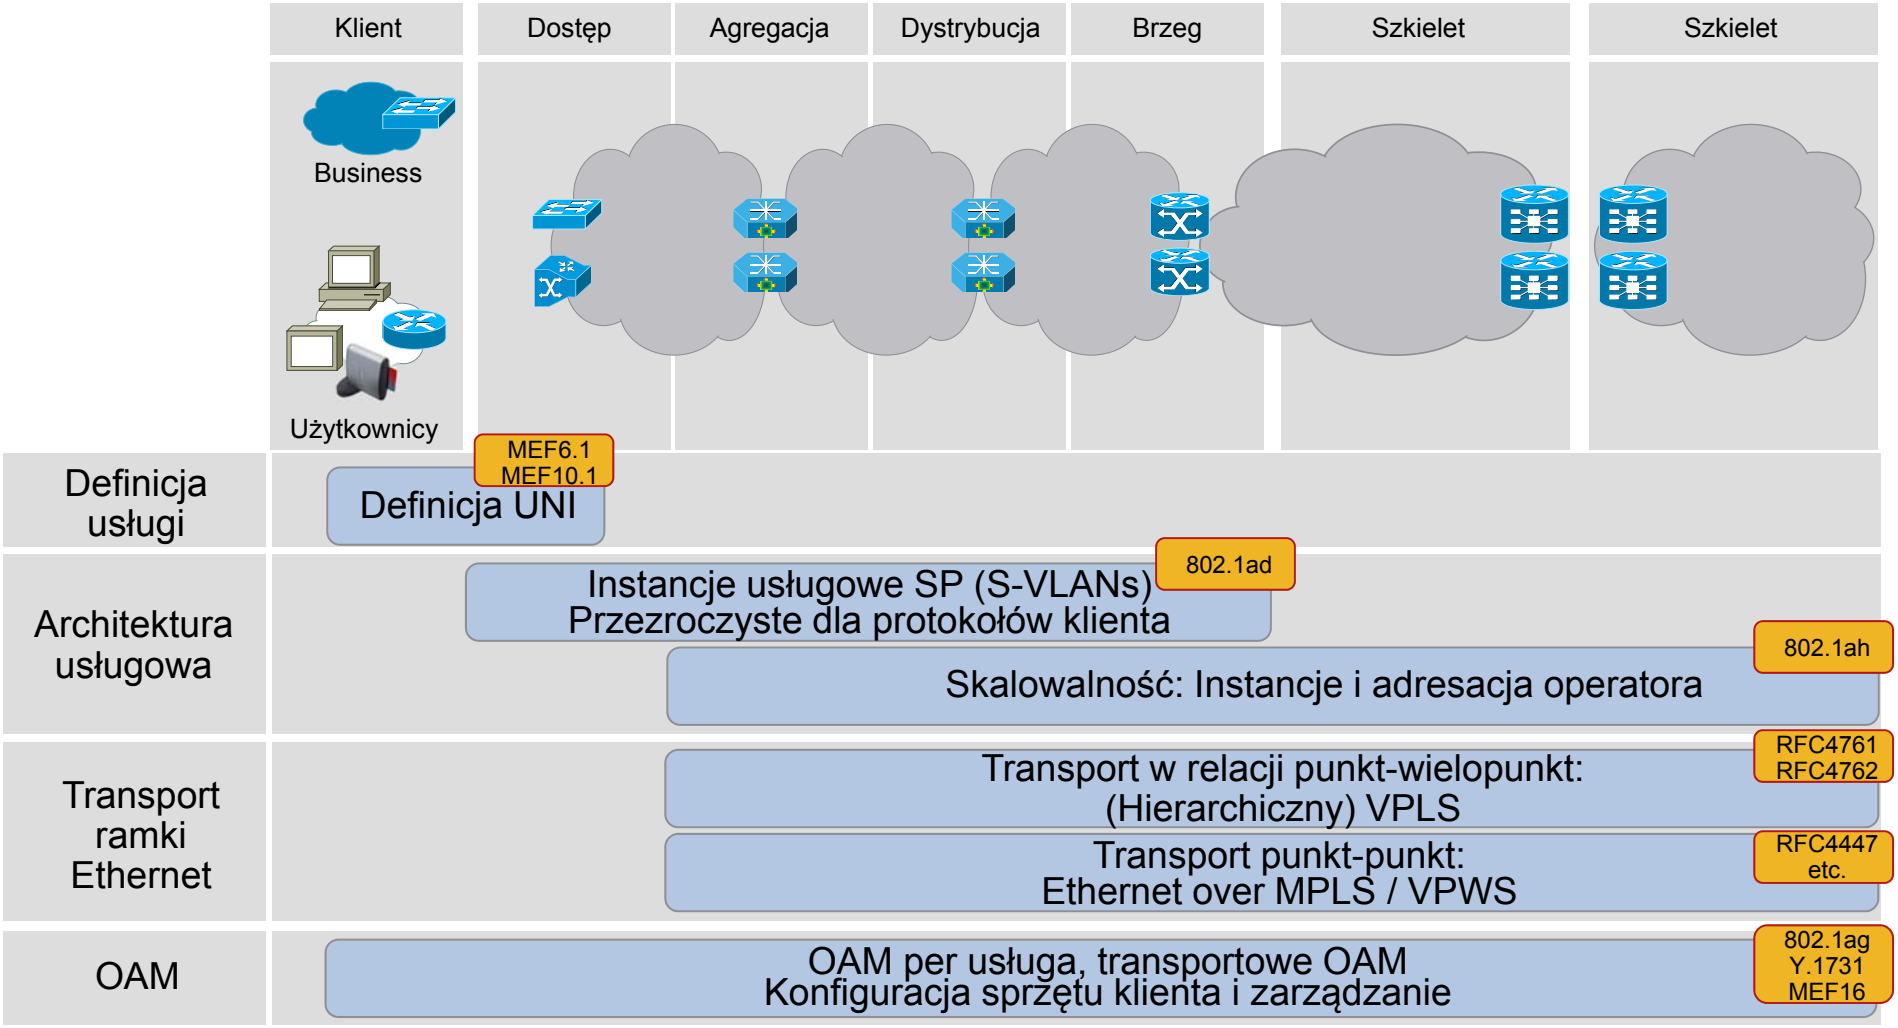

Standardy Carrier Ethernetu - nowe

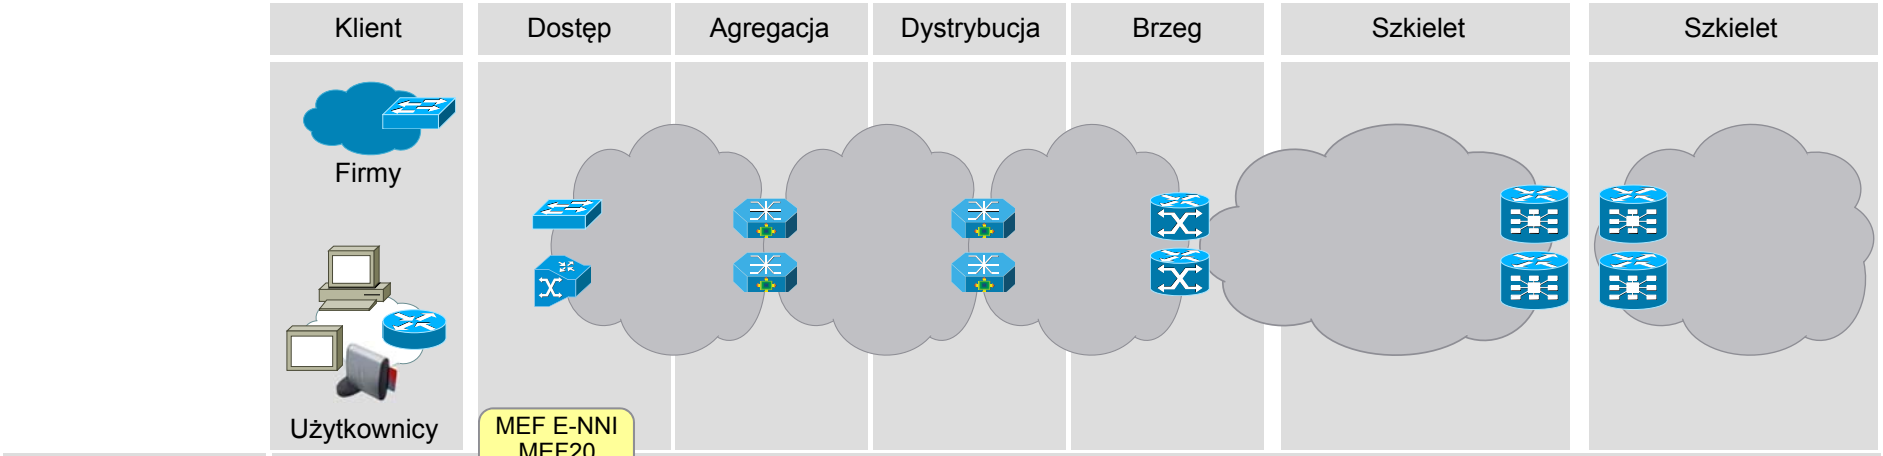

IEEE 802.3ba: 40Gbit/s Ethernet

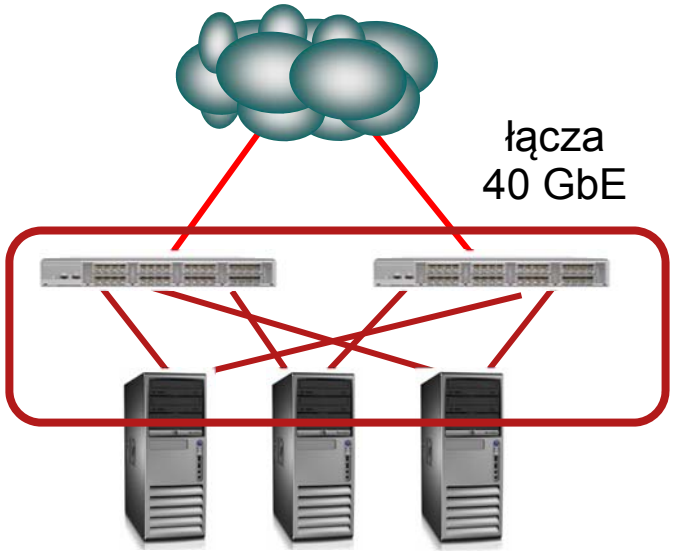

- Wsparcie do pracy wyłącznie w trybie full-dupleks
- Wykorzystuje format ramki Ethernet oraz limity wielkości
- Zachowuje BER na poziomie 10^{-12}
- Transmisja ustandaryzowana dla
  - 1m dla połączeń wewnątrz matrycy
  - 10m na kablu miedzianym
  - 100m światłowód OM3
  - 10km światłowód SM

IEEE 802.3ba: 100Gbit/s Ethernet

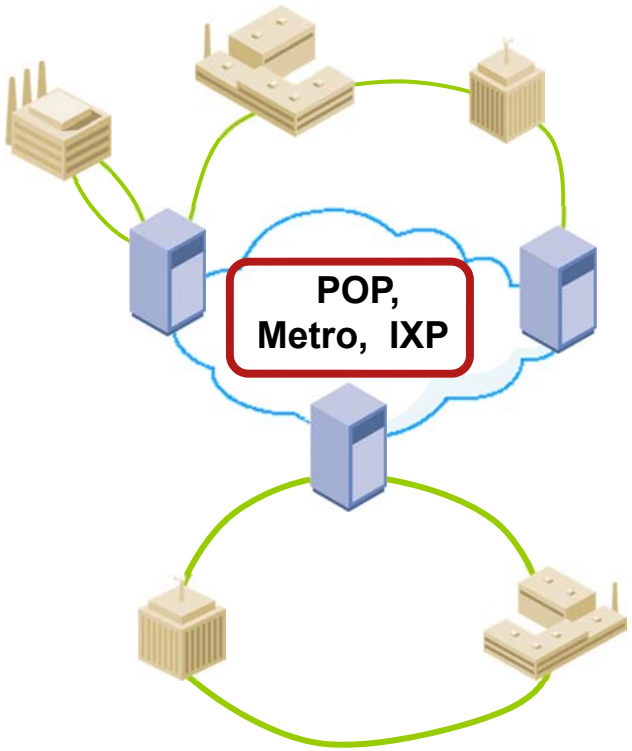

- Wsparcie do pracy wyłącznie w trybie full-dupleks
- Wykorzystuje format ramki Ethernet oraz limity wielkości
- Zachowuje BER na poziomie 10^{-12}
- Transmisja ustandaryzowana dla
  - 10m na kablu miedzianym
  - 10km SM dla sieci Metro
  - 40km SM long-haul
  - Wsparcie dla transmisji w sieci OTN

7

IEEE 802.3ba: 40 i 100 GE

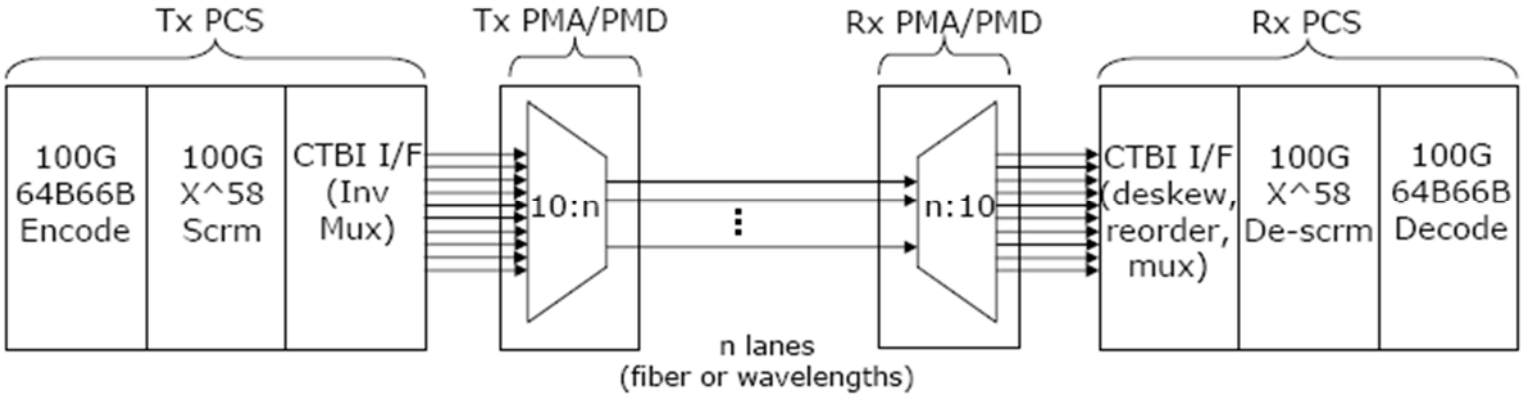

Odległość	40G Ethernet	100G Ethernet
Minimum 1m przez backplane	☑	
Minimum 10m miedź	☑	☑
Minimum 100m OM3 MMF	☑	☑
Minimum 10km SMF		☑
Minimum 40km SMF		☑

8

Demo 100GE Cisco – czerwiec 2008

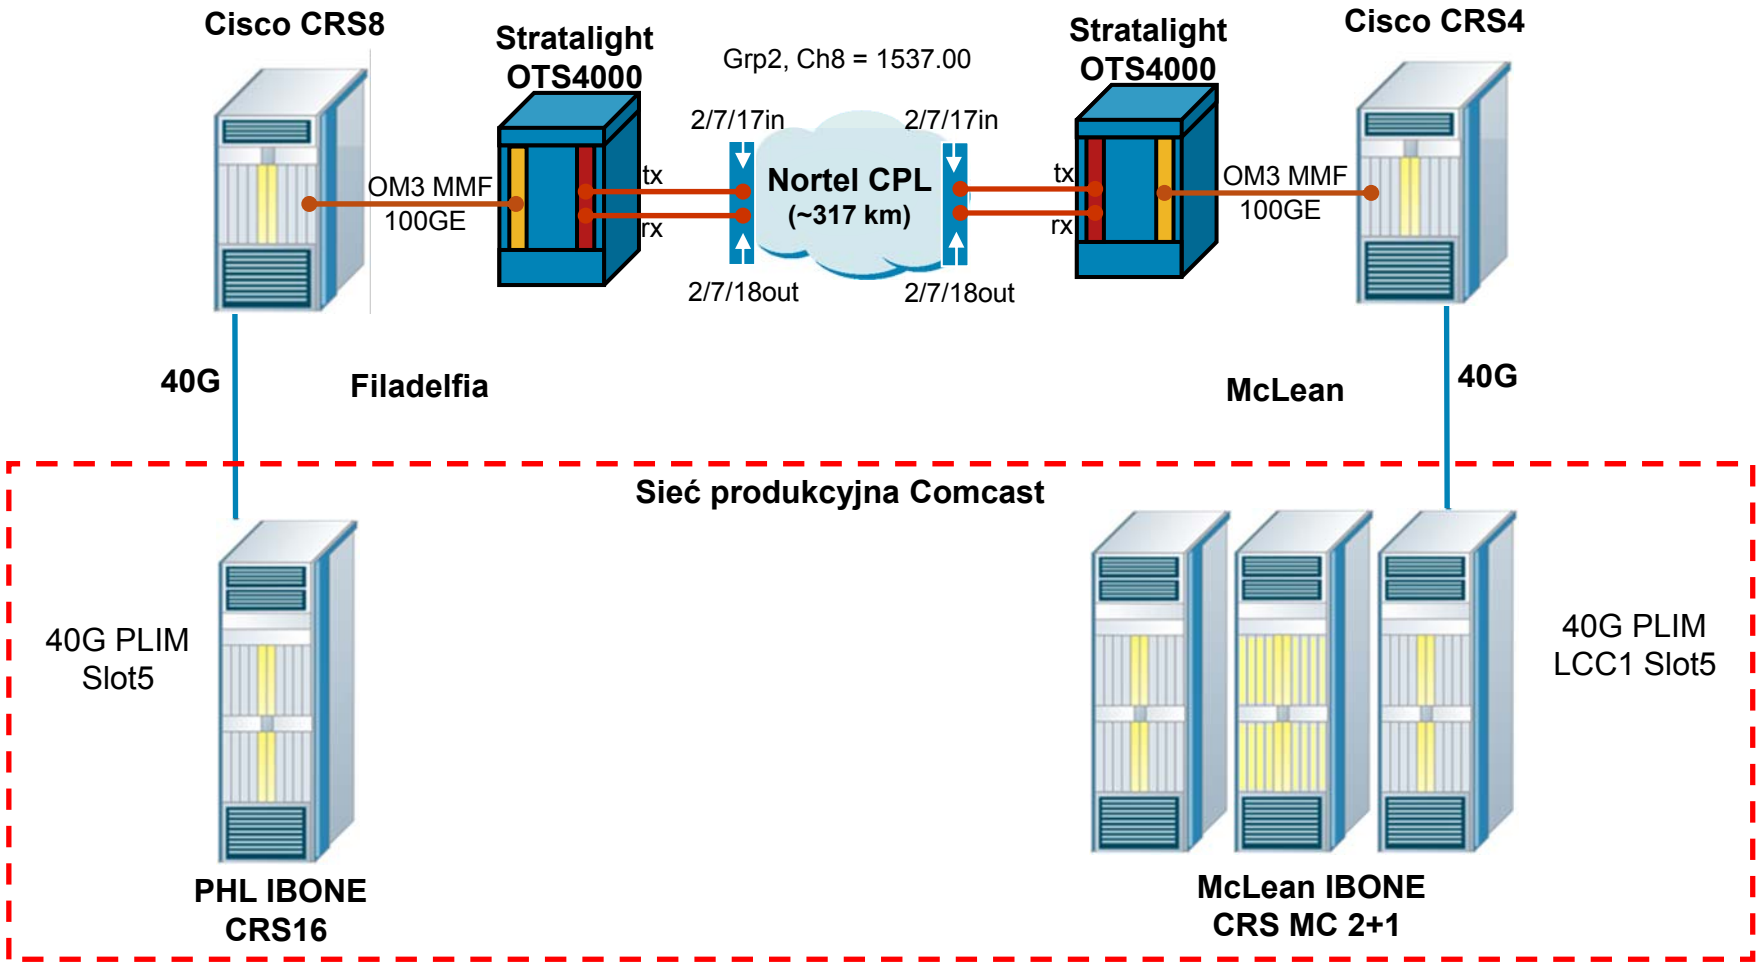

Więcej o teście: http://newsroom.cisco.com/dlls/2008/prod_062608c.html

Spanning Tree

802.1d, 802.1s, 802.1w i inne standardy

Co w 802.1 piszczy?

- 802.1D: MAC Bridges (Spanning Tree Protocol)
- 802.1w: Rapid Spanning Tree Protocol (RSTP)
- 802.1s: Multiple Spanning Tree Protocol (MST)
- 802.1t: 802.1d Maintenance
- 802.1Q: VLAN Tagging (trunking)

Stany portów w STP

- Blocking
- Listening
- Learning
- Forwarding
- Disabled (wyłączony)

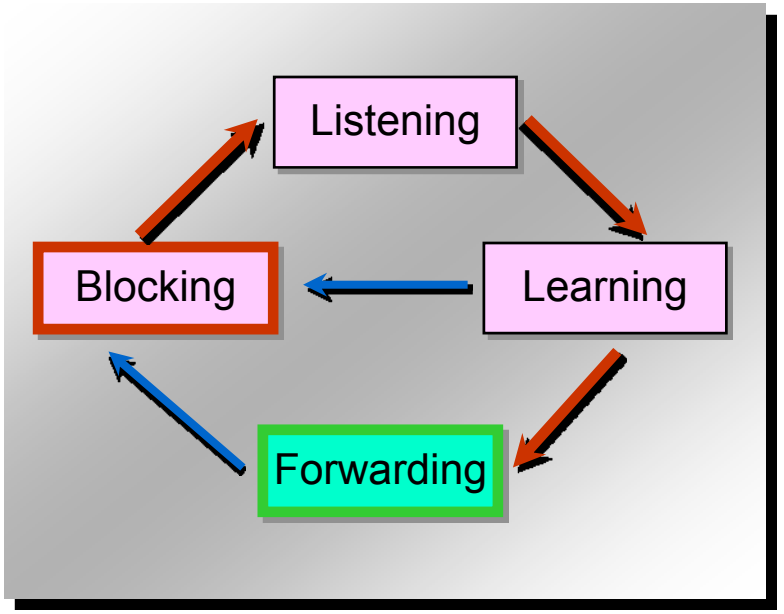

Spanning Tree i liczniki

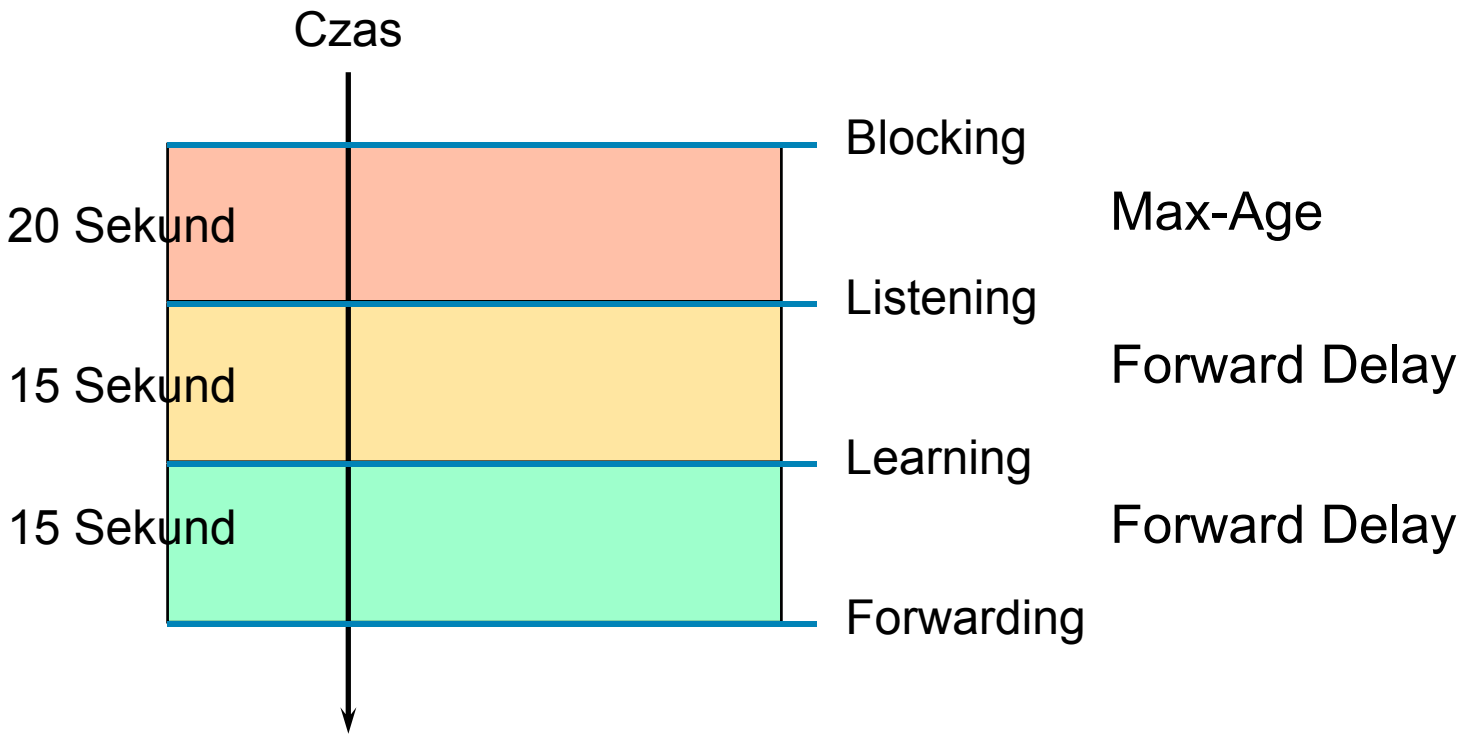

Głównym ograniczeniem konwergencji tradycyjnego STP jest przywiązanie do zależności czasowych

Nowe funkcje w Rapid STP

- Nowe role i stany portów
- Zmodyfikowane BPDU
- Nowa obsługa i zachowanie BPDU
- Nowy mechanizm zmiany topologii
- Szybkie przejście do stanu „forwarding”
- Możliwość migracji – kompatybilność z 802.1D

Role portów w Rapid STP

- RSTP definiuje 4 role portów:

  Root port

  Designated port

  Alternate port

  Backup port

  } blokujące

- Stan portu może być ustalony bez względu na jego rolę: blocking, forwarding, learning (listening = blocking)

Zmodyfikowane BPDU

- Pole „wersja protokołu” ustawione na 2 (było 0)
- Znika TCN BPDU
- Zmiana w polu flag

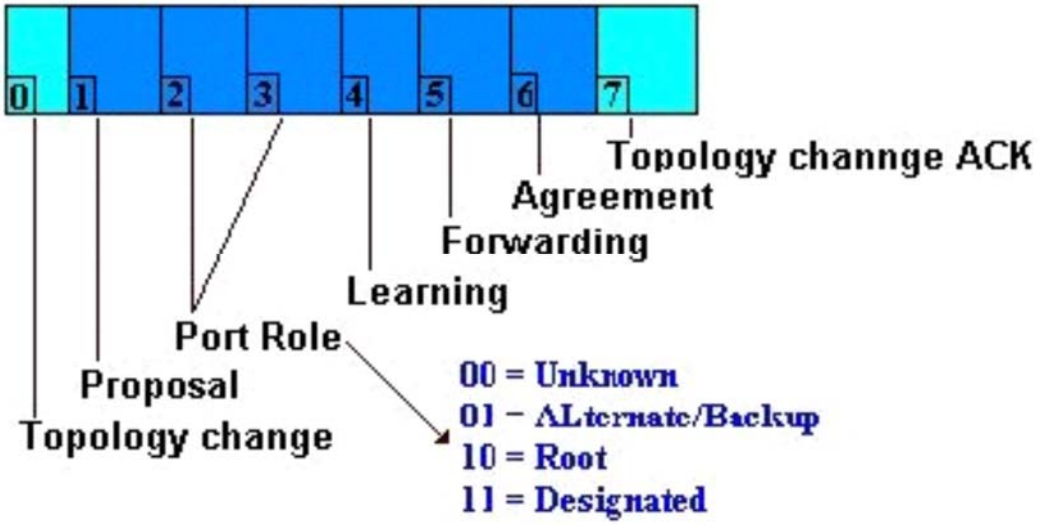

- Mosty 802.1D odrzucają BPDU z RSTP

Nowa obsługa i wykorzystanie BDPU

- BPDU są wysyłane jako ramki „keepalives”

  most wysyła BPDU co czas „hello” (domyślnie 2 sekundy)

  informacja o porcie zostaje unieważniona po upływie 3x czasu bez otrzymania BPDU

Szybkie przejście portu do „forwarding”

- Dotyczy tylko połączeń P2P

  Port domyślnie jest P2P jeśli pracuje w dupleksie oraz nie jest portem brzegowym

- Po otrzymaniu lepszej propozycji, most od razu wykonuje jednocześnie trzy rzeczy:

  Przyjmuje lepszą propozycję

  Blokuje port w stronę dotychczasowej sieci

  Wysyła propozycję nowego root’a w stronę reszty sieci, jednocześnie akceptuje propozycję lepszego root’a i przesuwa porty w stan „forwarding”

Po co MST?

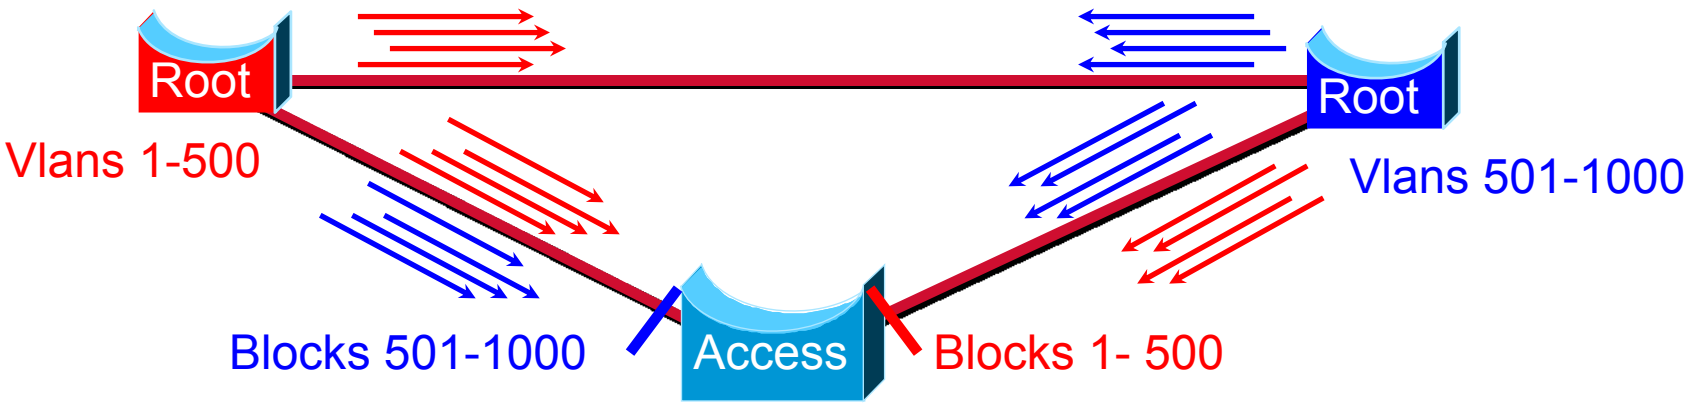

Jeden VLAN to jedna instancja STP

- Możliwość zrealizowania „ręcznego” rozkładania ruchu przez podział VLANów
- CPU obsługuje 1000 instancji mimo tylko dwóch topologii fizycznych

Co daje MST?

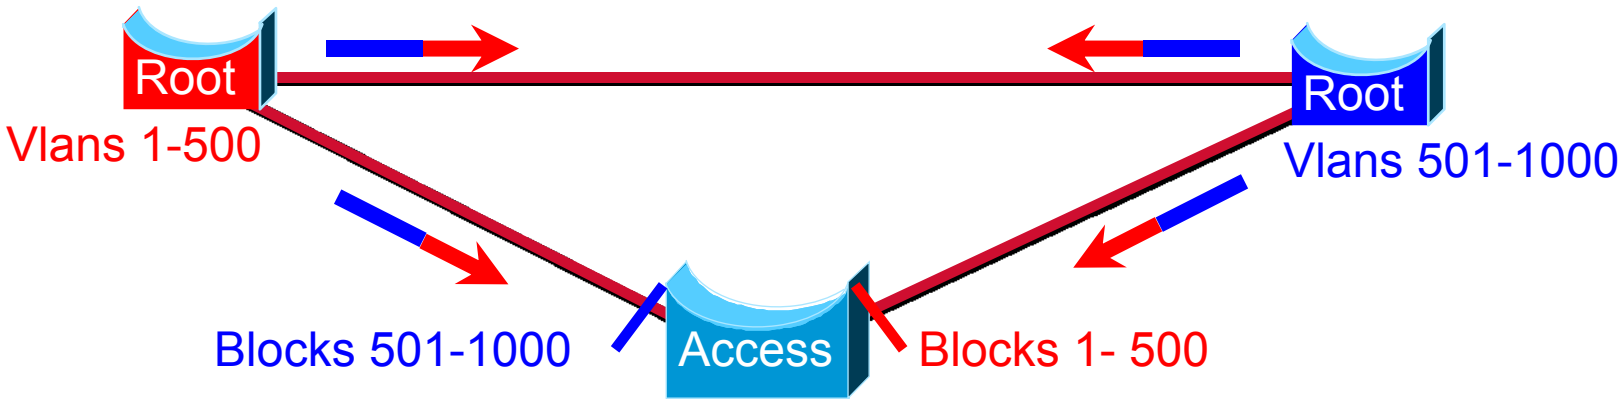

- Wygodne rozkładanie ruchu i oszczędność CPU – tylko dwie różne topologie STP
- Dosyć złożone – we wdrożeniu a potem przy ewentualnym rozwiązywaniu problemów oraz współpracy z innymi protokołami

Praca w topologii pierścienia w warstwie drugiej

REP, EAPS, RRPP, EPSR, MRP, RRP i ERPS

Trendy i problemy w L2

- Duże domeny SPT

  Coraz więcej węzłów w sieci

- Większa ilość klientów

  Zwiększamy ilość VLANów i adresów MAC dla domeny L2

- W oczywisty sposób powoduje to zwiększenie problematyczności rozwiązywania problemów i diagnostyki

- Naturalne aspiracje dla usług „klasy operatorskiej”

  Co z szybką konwergencją?

  STP/rSTP/MSTP nie jest szczególnie „klasy operatorskiej”

Topologia gwiazdy i pierścienia

Różnice

Pierścień	Gwiazda
• Współdzielone pasmo pomiędzy urządzeniami U-PE. • Bardziej skomplikowana inżynieria ruchu. Kolejki wyjściowe współdzielone z innymi U-PE. • Wyższe opóźnienie z powodu większej ilości przeskoków. • Dłuższy czas zbieżności. • Utrudniona kontrola procesu uczenia się adresów MAC.	• Każdy U-PE posiada własne połączenie 1GE do n-PE. • Prostsza inżynieria ruchu. Kolejki wyjściowe dedykowane dla lokalnego urządzenia U-PE. • Mniejsze opóźnienie. • Krótszy czas zbieżności. • Łatwiejsza kontrola adresów MAC.

Podobieństwa

- Wszystkie usługi są dostępne w obydwu topologiach.
- Dostępne te same funkcjonalności bezpieczeństwa, dostępności oraz QoS na urządzeniu N-PE.

Wszyscy potrafimy to robić

- Cisco REP
- Extreme EAPS
- 3COM (Huawei H3C -> HP) RRPP
- Allied Telesyn EPSR
- Brocade MRP / Force10 RRP

- **Standard**: ITU G.8032 ERPS

REP - Topologia pierścienia

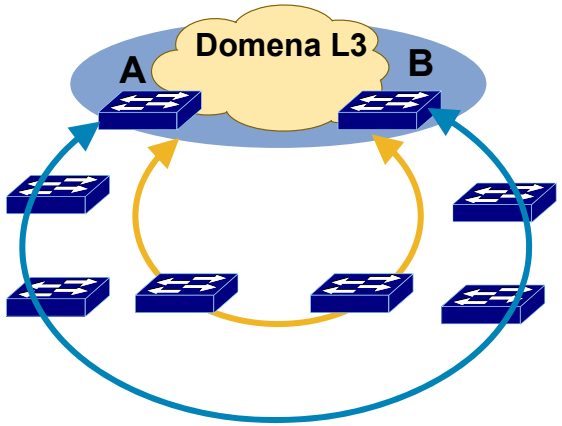

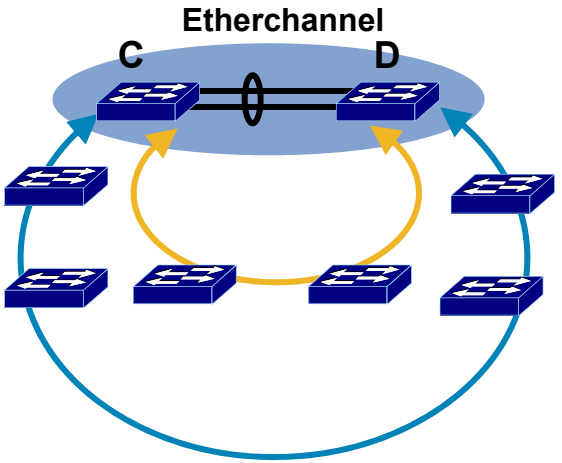

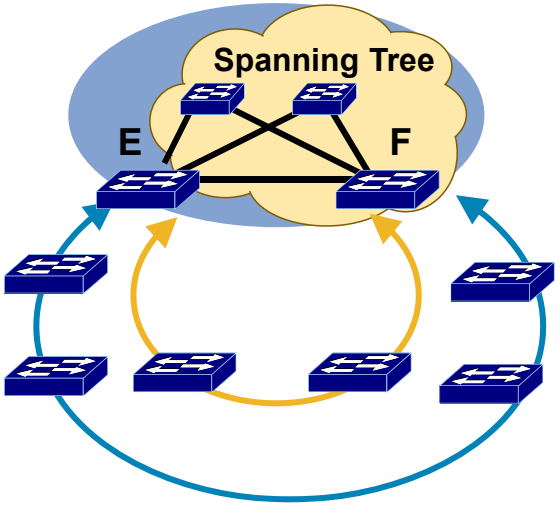

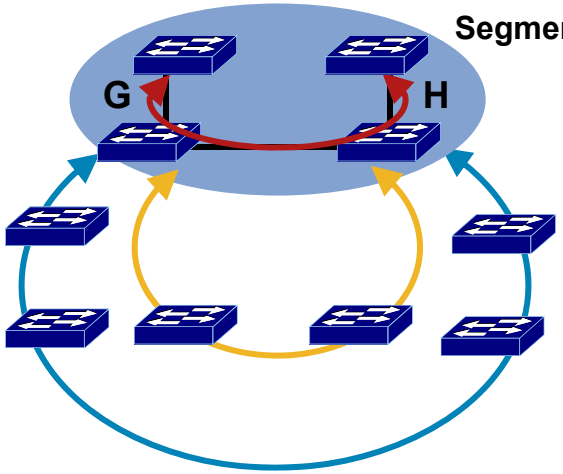

Ethernet dla operatorów

802.1ad, 802.1ah i 802.1Qay

IEEE 802.1ad – Provider Bridges

- Przezroczyste dla VLANów klienta

  IEEE 802.1ad powinny dostarczyć ustandaryzowaną wersję “QinQ”

  Standard ma zawierać pewne rozszerzenia

- Format ramki zgodny z “QinQ”

  Nowy EtherType: 0x88A8

- Techniczne zatwierdzony już dawno – 8 grudzień 2005

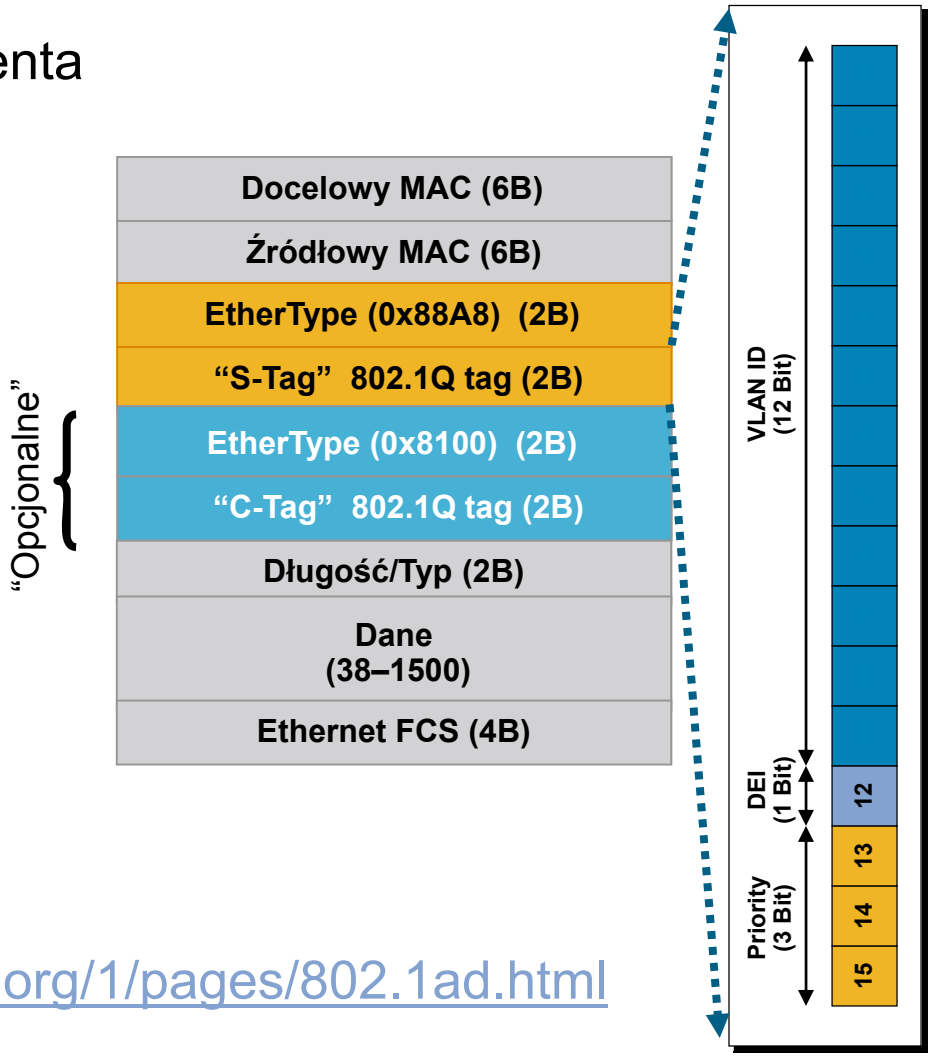

- Więcej na: http://www.ieee802.org/1/pages/802.1ad.html

27

IEEE 802.1ah – Provider Backbone Bridges

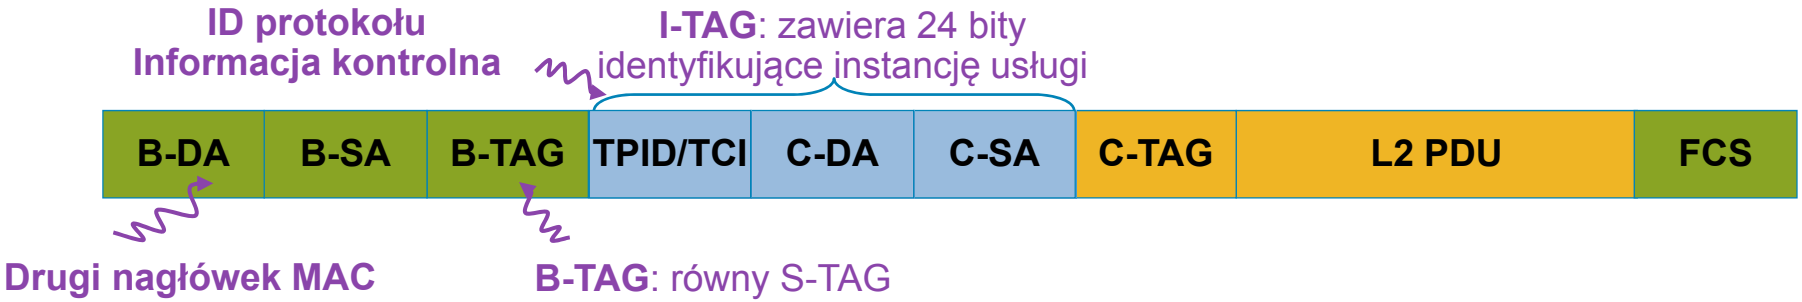

- Skalowalność usługi – 24 bity (I-SID) wskazujące usługę
- Izolacja domen, skalowalność adresów MAC

  Na wejściu do domeny operatora, nagłówek MAC klienta jest wkładany w nagłówek MAC operatora
- Kompatybilny wstecz z 802.1ad

  Zewnętrzny nagłówek jest normalnym nagłówkiem 802.1ad

  802.1ah zakłada wykorzystanie istniejących mechanizmów L2 – takich jak SPT i mechanizmy uczenia się/floodowania

  Inne opcje wdrożenia są również dostępne - 802.1aq, 802.1Qay, ukrywanie topologii z wykorzystaniem VPLS/MPLS oraz redundancja PW
- Standard 802.1ah zaakceptowany 12 czerwca 2008

28

IEEE 802.1Qay – PB + TE

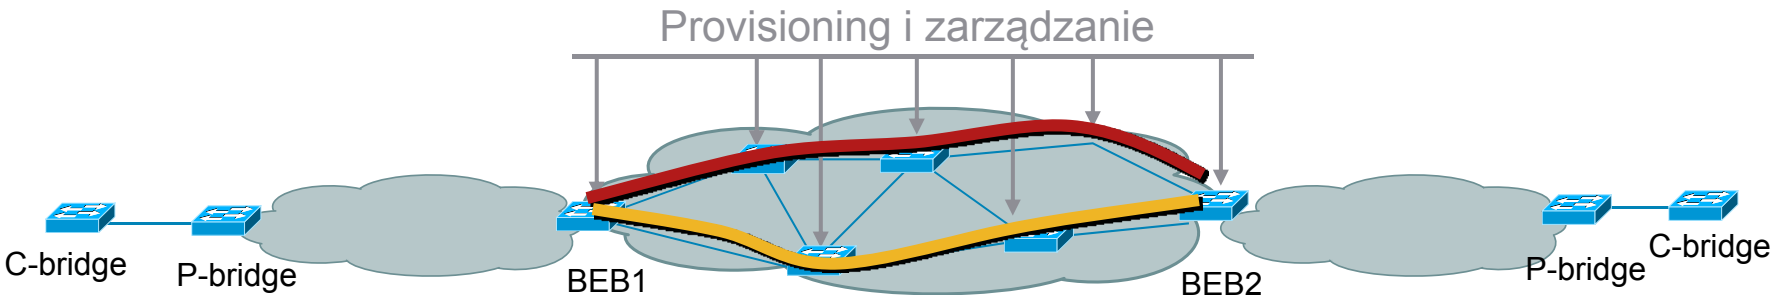

- Standaryzacja mechanizmów inżynierii ruchowej dla sieci składających się z połaczeń punkt-punkt (w stylu PVC ATMowych)
- Bazuje na PBB z ograniczonymi opcjami
  - Wyłączone uczenie (jest w 802.1Q) i flooding
- Statyczny control plane
  - Provisioning odbywa się przez NMS, wykorzystywany jest MIB 802.1
  - Osobne prace nad dynamicznym procesem provisioningu (802.1aq) – poza standardem

OAM

Operations, Administration & Management

Ethernet OAM – co i gdzie?

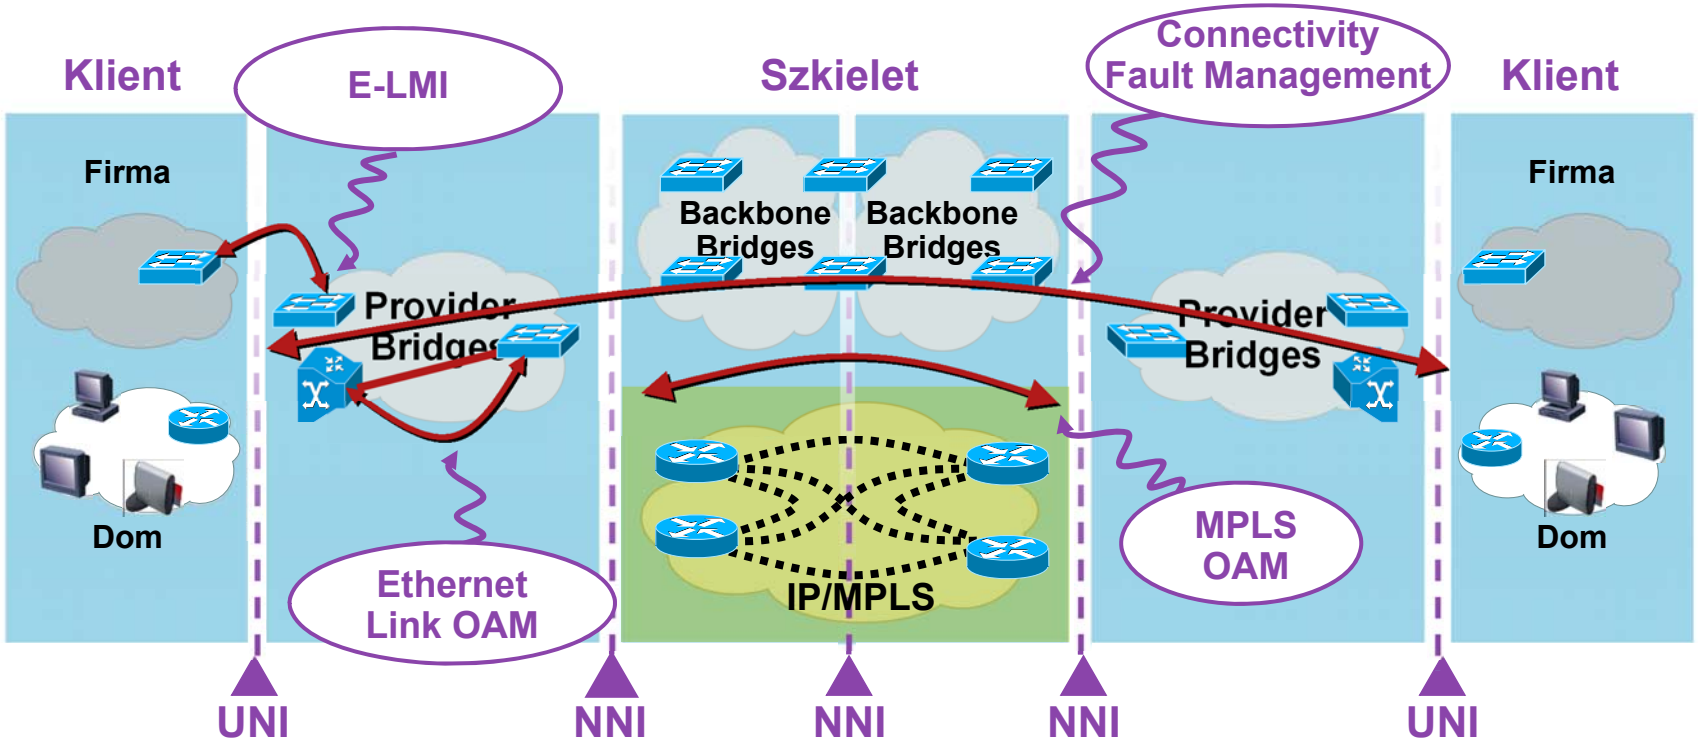

- E-LMI—User to Network Interface (UNI)
- Link OAM—dowolne łącze punkt-punkt 802.3
- CFM—End-to-End UNI do UNI
- MPLS OAM—w chmurze MPLS

Link OAM (IEEE 802.3ah, klauzula 57)

- Mechanizm dla „monitoringu pracy łącza” czyli między innymi do:
  - Monitoringu samego łącza
  - Wskaźnika zdalnej awarii
  - Kontroli zdalnej pętli lokalnej
- Dodaje opcjonalną podwarstwę OAM
- Pracuje na łączach punkt-punkt 802.3
- Używa ramek OAMPDU nie przekazywanych dalej przez klientów MAC wysyłanych relatywnie wolno
  - do 10 ramek na sekundę

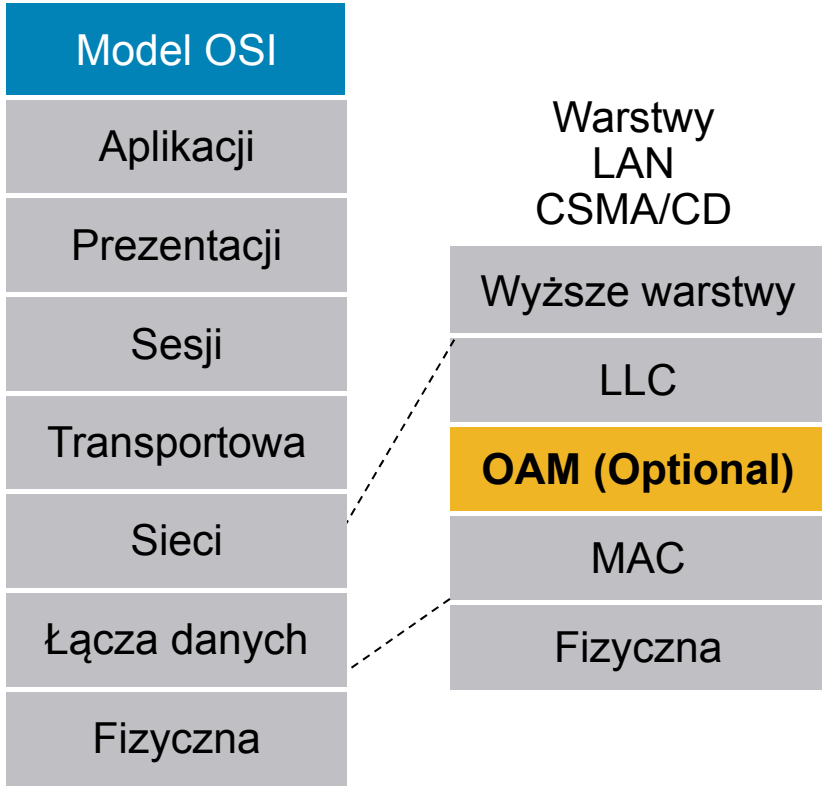

Connectivity Fault Management

- Rodzina protokołów zapewniająca możliwość wykrywania, weryfikacji, izolacji i raportowania problemów w transporcie ruchu na całej trasie od źródła do celu
- Tradycyjne ramki Ethernet, z ustawionym polem EtherType na 0x8902 i docelowym adresem MAC multicast
- Ustandaryzowany przez IEEE pod koniec 2007

CFM – Maintenance Domain (MD)

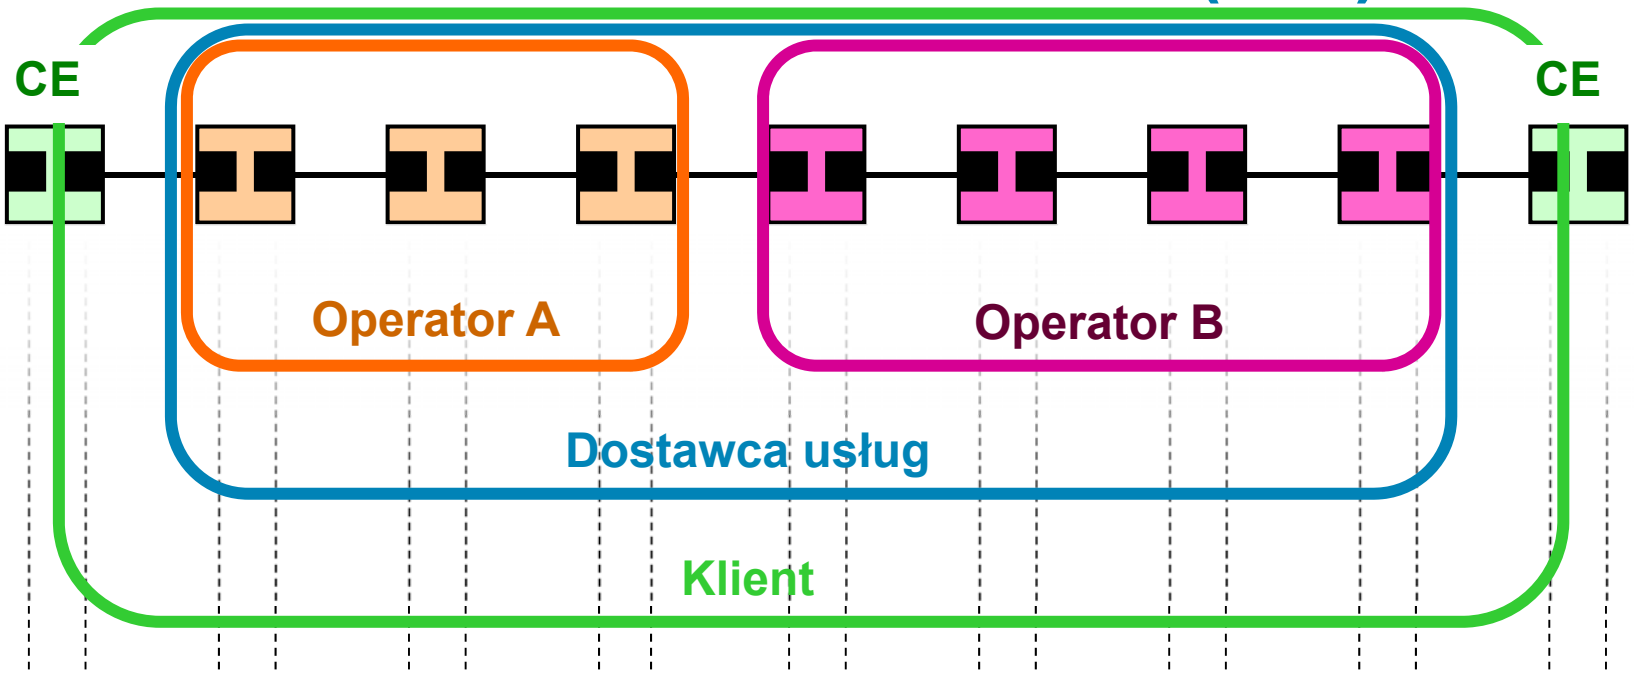

- Definiowana przez granice operacyjne/kontraktu
- MD mogą być zagnieżdżone lub się stykać, ale nie mogą się przenikać
  - do 8 poziomów zagnieżdżenia (0...7) – czym wyższy poziom tym większy zasięg
- Nazwa MD: pusta, adres MAC, DNS lub ciąg znaków

CFM – Maintenance Association (MA)

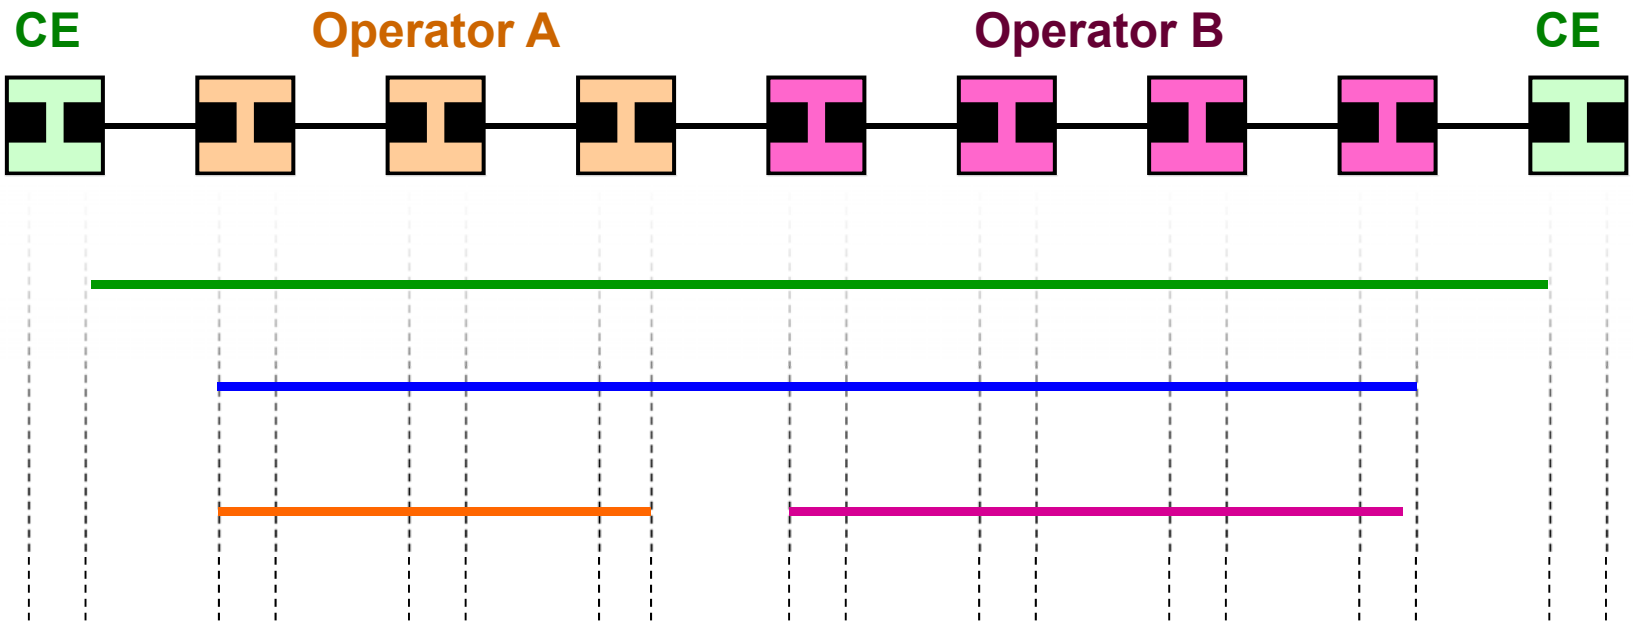

- Monitoruje łączność w danej instancji usługi w danym MD (np. 1 usługa przechodząca przez cztery MD = 4 MA)
- Definiowana przez zestaw Maintenance End Points (MEP) na brzegu domeny
- Identyfikowana przez MAID == „Krótka nazwa MA” + nazwa MD
- Krótka nazwa MA: ID VLANu, VPN, liczba dodatnia lub ciąg znaków

CFM – Maintenance Point (MP) - MEP

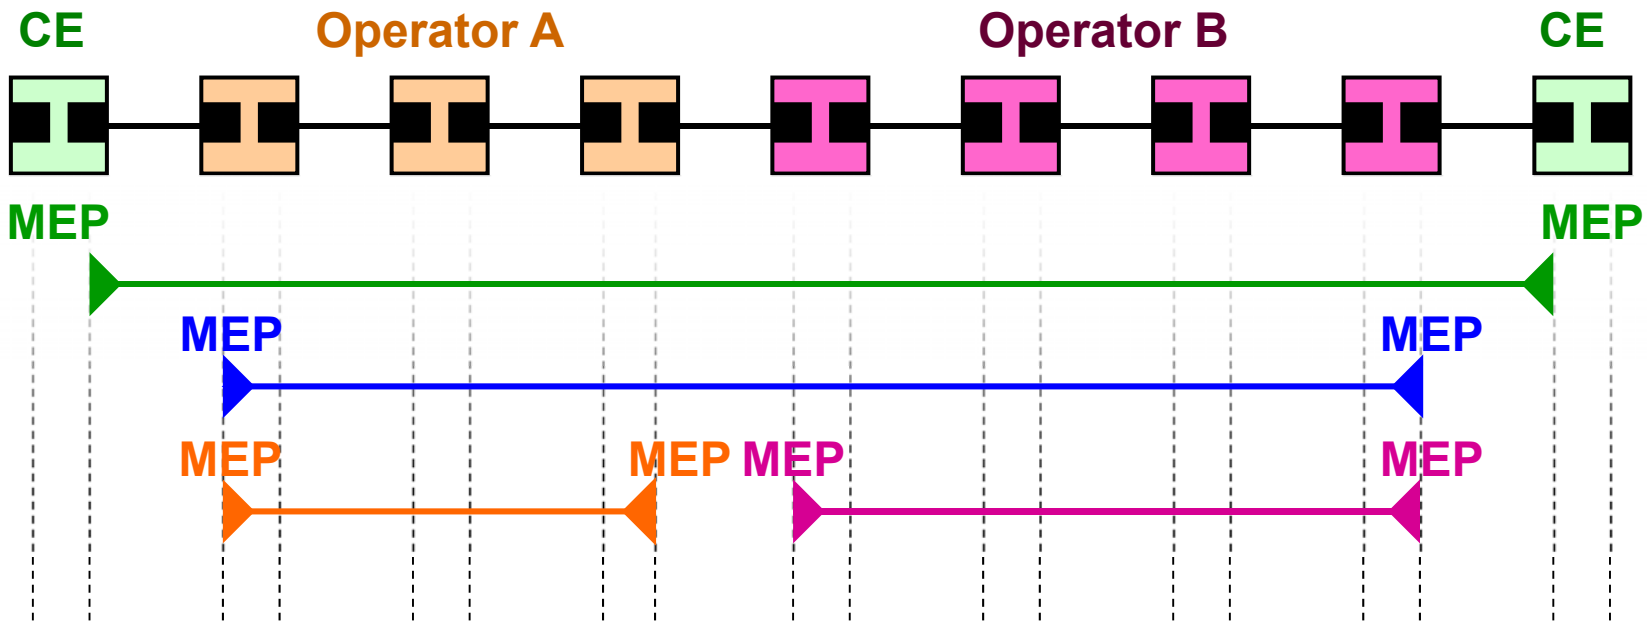

- **Maintenance Association End Point (MEP)**
- Definiuje granice MD
- Obsługuje automatyczne wykrycie problemów z połączeniem pomiędzy dowolną parą MEPów w MA
- Kojarzone per MA i identyfikowane przez MEPID (1-8191)
- Może inicjować i odpowiadać na PDU CFM'owe

CFM – Maintenance Point (MP) - MIP

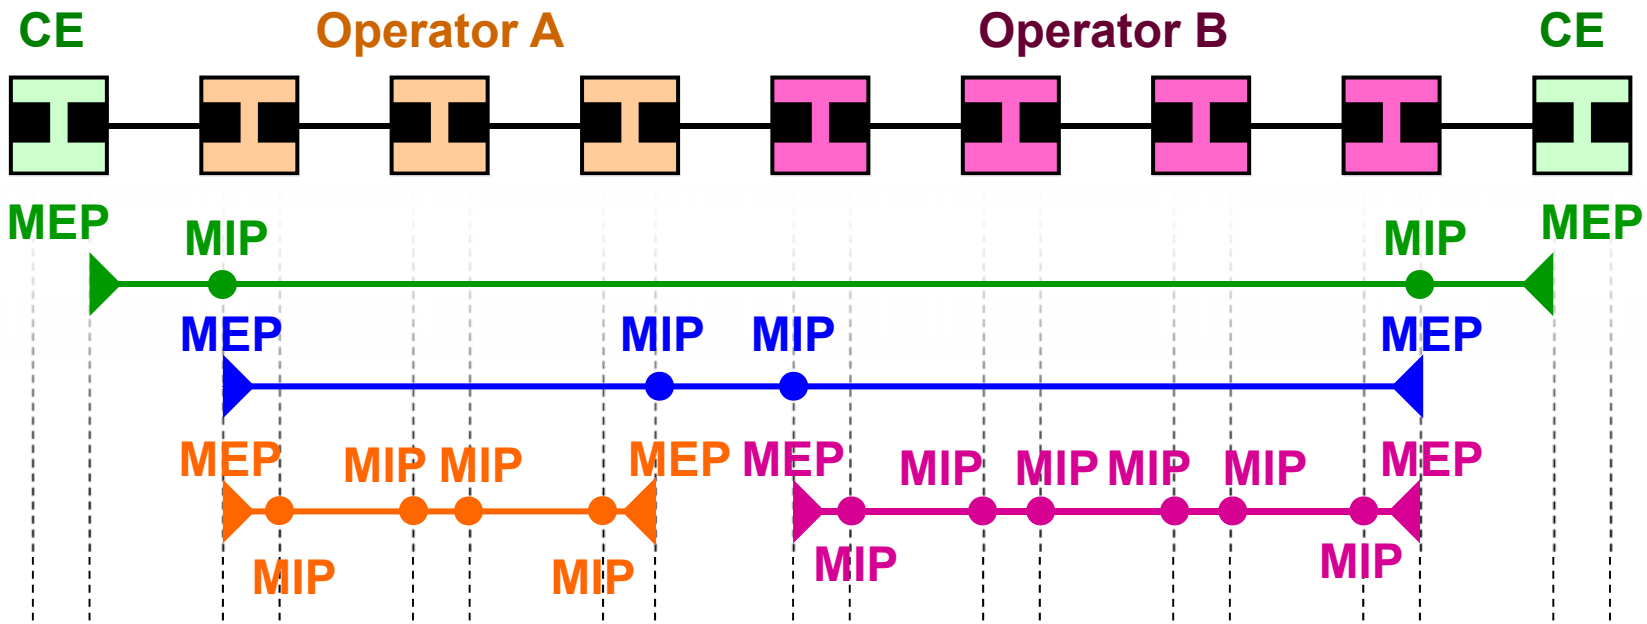

- **Maintenance Domain Intermediate Point (MIP)**
- Obsługuje wykrywanie ścieżek pomiędzy MEP i lokalizację awarii na tych ścieżkach
- Może być kojarzony per MD i VLAN / EVC (ręcznie lub automatycznie)
- Może dodawać, sprawdzać i odpowiadać na PDU CFM'owe

Protokoły CFM

- CFM definiuje obecnie trzy protokoły
- Continuity Check Protocol

  Wykrywanie i Notyfikacja o awarii
- Loopback Protocol

  Weryfikacja awarii
- Linktrace Protocol

  Izolacja awarii

CFM – protokół Continuity Check

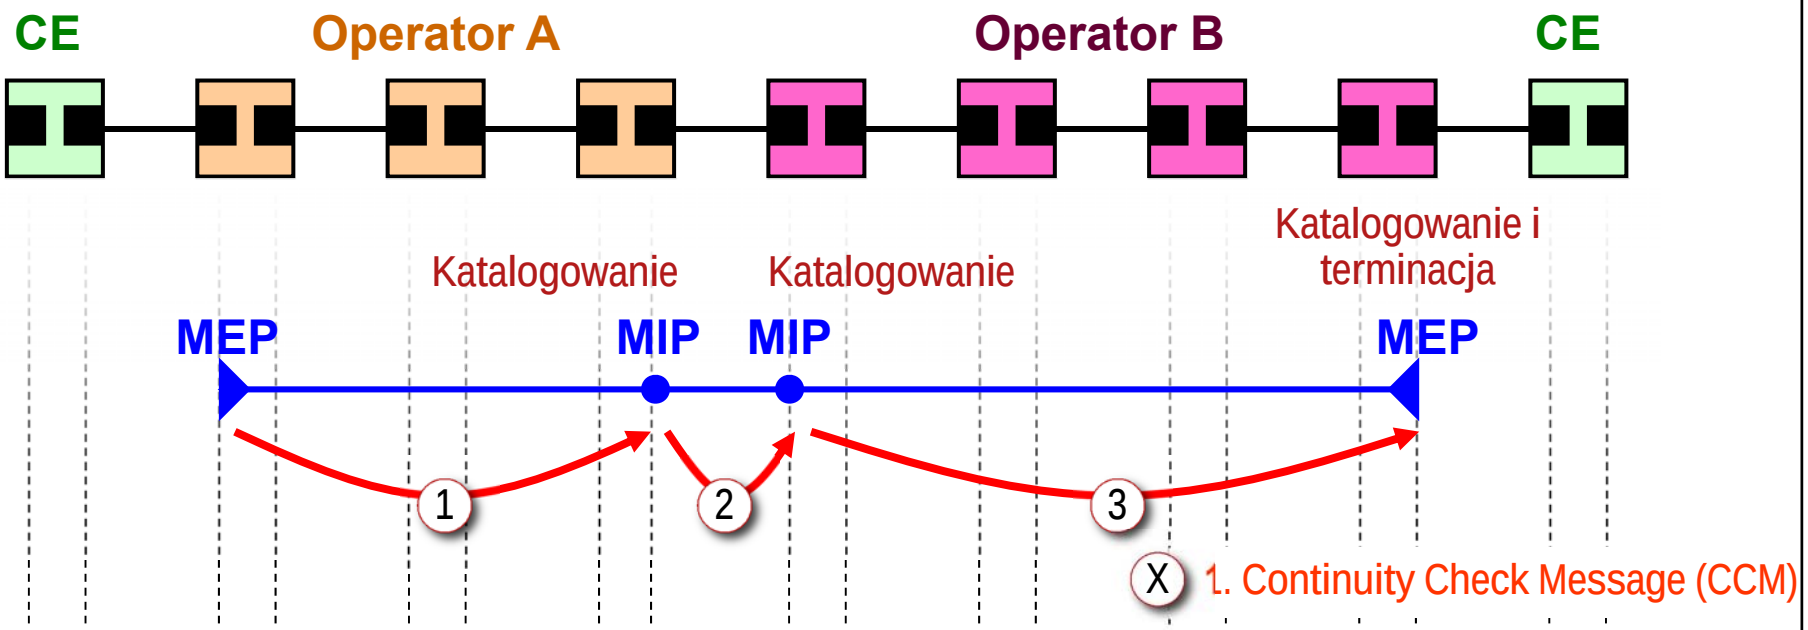

- Wykrywanie i informowanie o awariach
- Skojarzenie per-MA – multicastowa wiadomość „keepalive”
  - Wysyłana przez MEP co konfigurowalny interwał czasowy (3.3ms, 10ms, 100ms, 1s, 10s, 1m, 10m)
  - Jednokierunkowa
  - Przenosi status portu na którym skonfigurowano MEP
- Katalogowane przez MIP na tym samym poziomie MD, terminowane przez zdalny MEP w tym samym MA

CFM – protokół Loopback

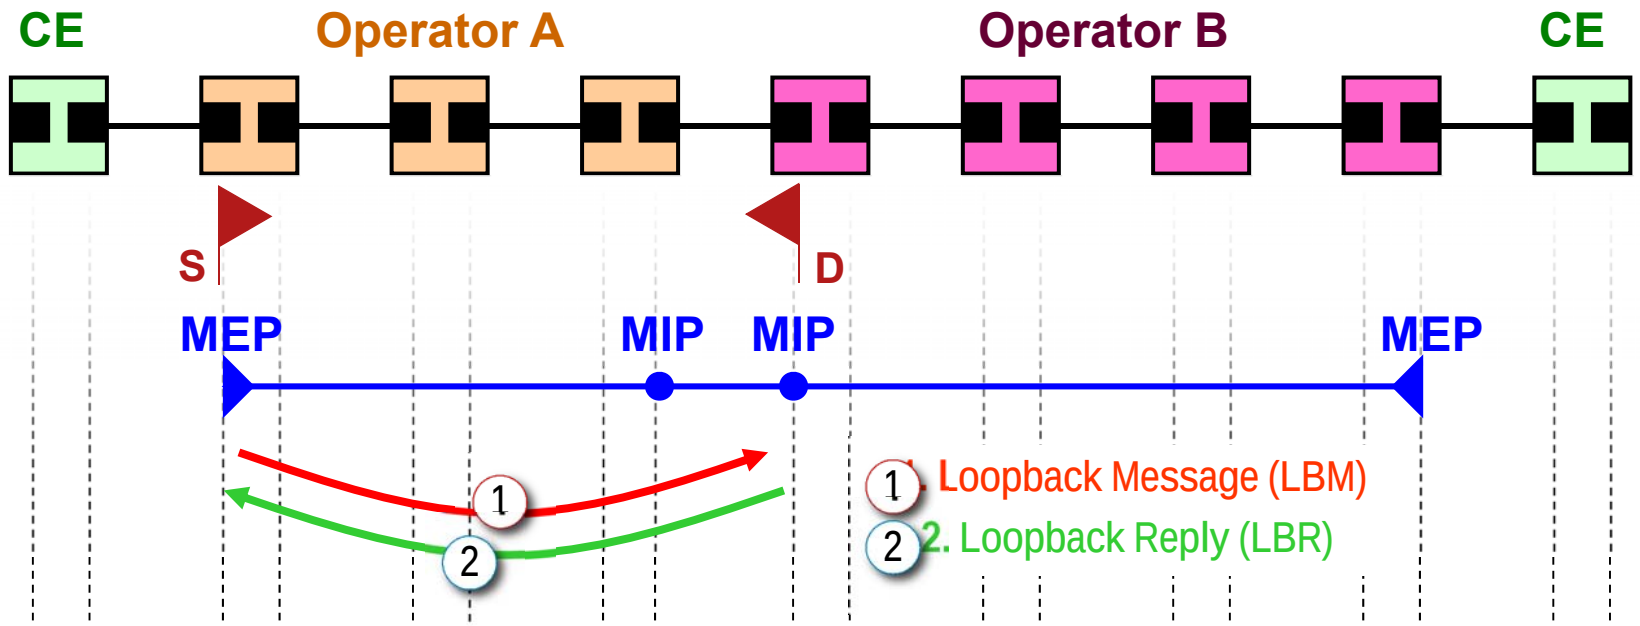

- Używane do weryfikacji awarii
- MEP może transmitować unicastowe LBM do MEP lub MIP w tym samym MA
- MP otrzymujący komunikat odpowiada unicastowym LBR do źródłowego MEPa

CFM – protokół Linktrace

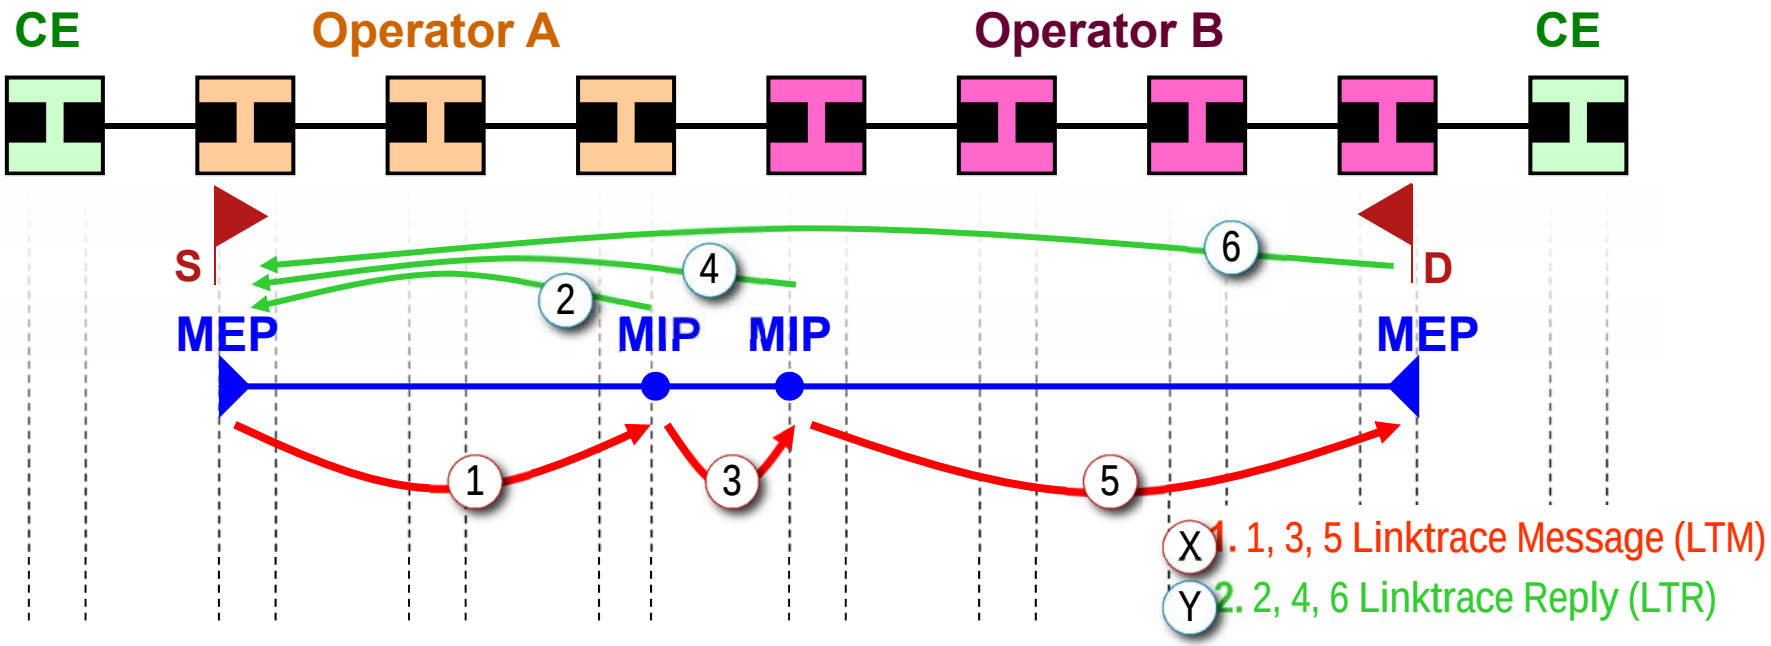

- Odkrywanie ścieżek i izolacja awarii
- MEP wysyła wiadomość multicastową (LTM) w celu wykrycia MP i ścieżki do MIP lub MEP w tym samym MA
- Każdy MIP na trasie pakietu i terminujący MP zwracają unicastowo wiadomość LTR do źródłowego MEPa

ITU Y.1731 – rozszerzenia do 802.1ag

- ETH-LB: Ethernet Loopback—unicast i multicast
- ETH-AIS: Alarm Indication Signal
- ETH-Test: Test Signal

  Test przepustowości, rekolejkowania ramek, błędów bitowych itp

  Dwu lub jednokierunkowy
- ETH-USR: Ethernet Maintenance Channel

  Zdalne zarządzanie

  Przykład zastosowania: sprawdzenie VC ATMowego na DSLAMie ethernetowym na użytek ethernetowego BNG
- ETH-APS: Ethernet Automated Protection Switching

  G.8031 (wykorzystuje ETH-AIS) ; G.8032

Nowości w L2

TRILL i 802.1aq

„W poszukiwaniu nowego protokołu L2”

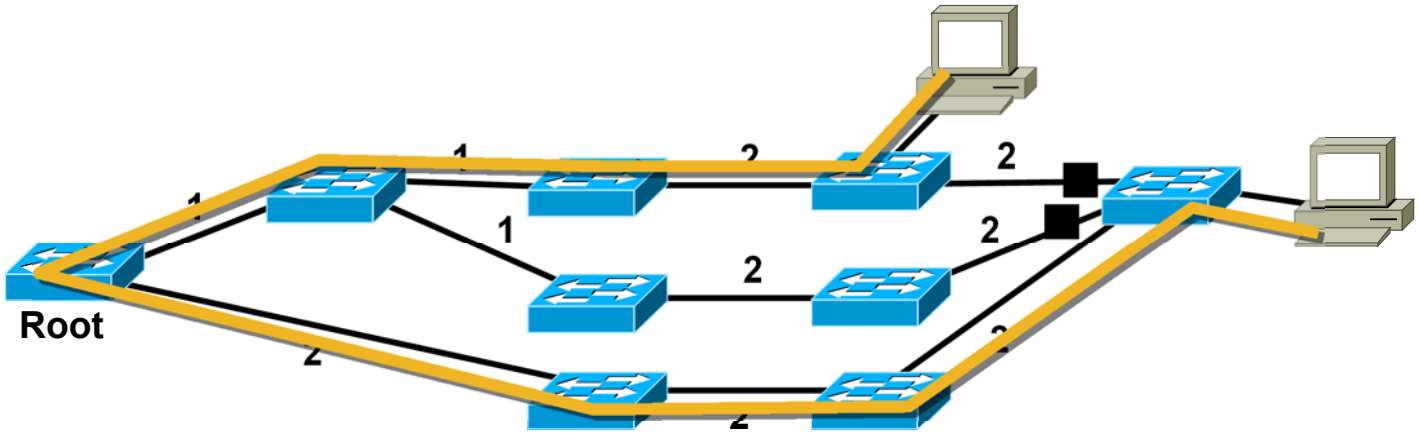

- Obecne Spanning Tree
  - Potencjalnie nieoptymalne ścieżki przekazywania ruchu
  - Nie można wykorzystać ścieżek równoległych
  - Problemy życia codziennego w sieciach
- Propozycje
  - IETF TRILL
  - Shortest Path Bridging 802.1aq
  - Oba wykorzystują rozszerzenia IS-IS → grupa robocza ISIS w IETF zdefiniuje jeden zestaw rozszerzeń dla obu protokołów

44

TRILL – podejście IETF

- TRILL (TRansparent Interconnect of Lots of Links)
  - nazywane również Routing Bridges lub po prostu Rbridges
  - http://www.ietf.org/html.charters/trill-charter.html
- Główne obszary adresowane przez TRILL:
  - Wybór najkrótszej ścieżki
  - Zapewnienie tras równoległych
  - „Plug'n'Play"
- RBridges pracują „na" sieci 802.1 – model warstwowy
  - Sieć 802.1 może być wykorzystywana przez hosty by dostać się do RBrdige
  - RBridge może wykorzystać sieć 802.1 do przenoszenia ruchu pomiędzy sobą
  - RBridges nie uczestniczą w procesie xSTP i odrzucają BPDU gdy je otrzymają

45

TRILL – jak to działa?

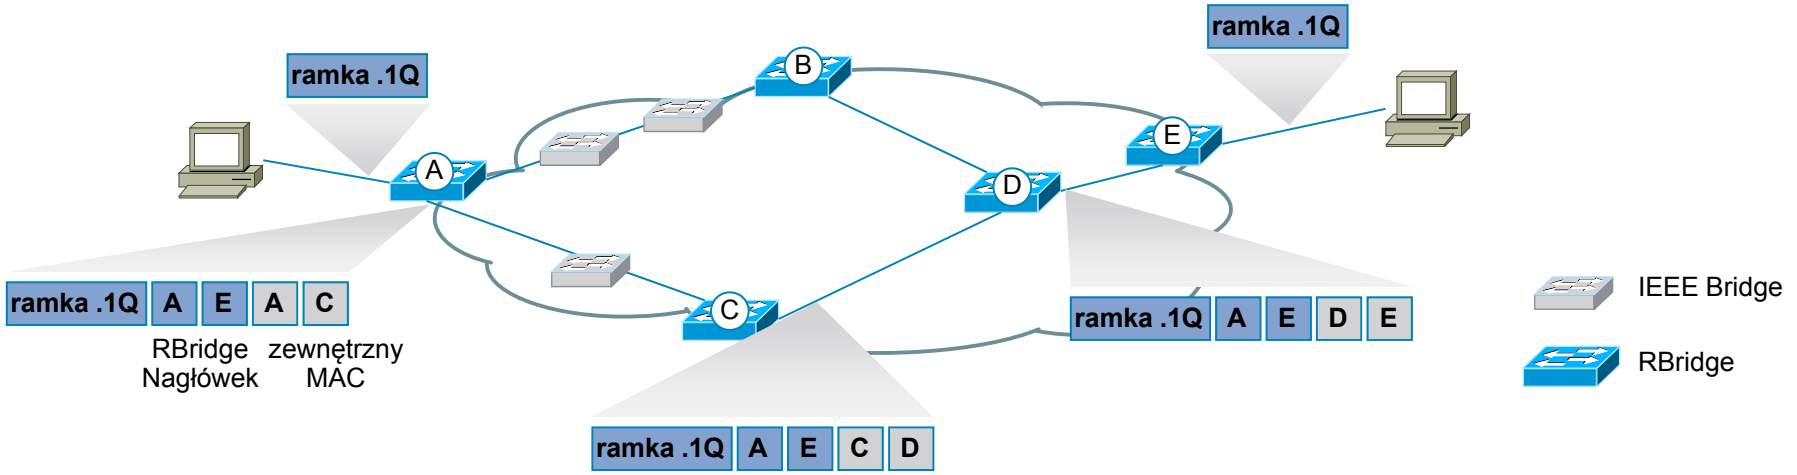

- Ramka otrzymuje adres Rbridge wyjściowego, a następnie dodatkowy adres Rbridge next-hop

  Trochę jak „MAC-in-MAC” – ale pola różnią się od 802.1ah

- RBridges uczą się adresów MAC obecnych na portach brzegowych i **mogą** rozgłaszać je przez IS-IS do innych RBridge’y

  Wybór między uczeniem się zdalnych mapować w data lub control plane

- Nieznane ramki unicastowe są rozlewane zgodnie z drzewem którego korzeń znajduje się na wejściowym RBridge

46

TRILL—Ethernet Data Encapsulation

Outer Ethernet Header (link specific):

Outer Destination MAC Address (RB2)	
Outer Destination MAC Address	Outer Source MAC Address
Outer Source MAC Address (RB1)	
Ethertype = IEEE 802.1Q	Outer.VLAN Tag Information

- **Outer-VLAN Tag Information:** This is used only if two RBridges communicate across a standard 802.1Q network

TRILL Header:

Ethertype = TRILL	V	R	M	Op-Length	Hop Count
Egress (RB2) Nickname	Ingress (RB1) Nickname				

- **V:** Version
- **M:** Multi-destination; indicates if the frame is to be delivered to a single or multiple end stations
- **Opt-Length:** >0 if an Option field is present
- **Hop Limit:** Similar to TTL
- **RBridge Nickname:** Not the MAC address of the Rbridge, but the a TRILL ID for the RBridge (Egress Nickname used differently if M = 1)

Inner Ethernet Header:

Inner Destination MAC Address	
Inner Destination MAC Address	Inner Source MAC Address
Inner Source MAC Address	
Ethertype = IEEE 802.1Q	Inner.VLAN Tag Information

Source: draft-letf-trill-rbridge-protocol

47

802.1aq – najkrótsza ścieżka per bridge

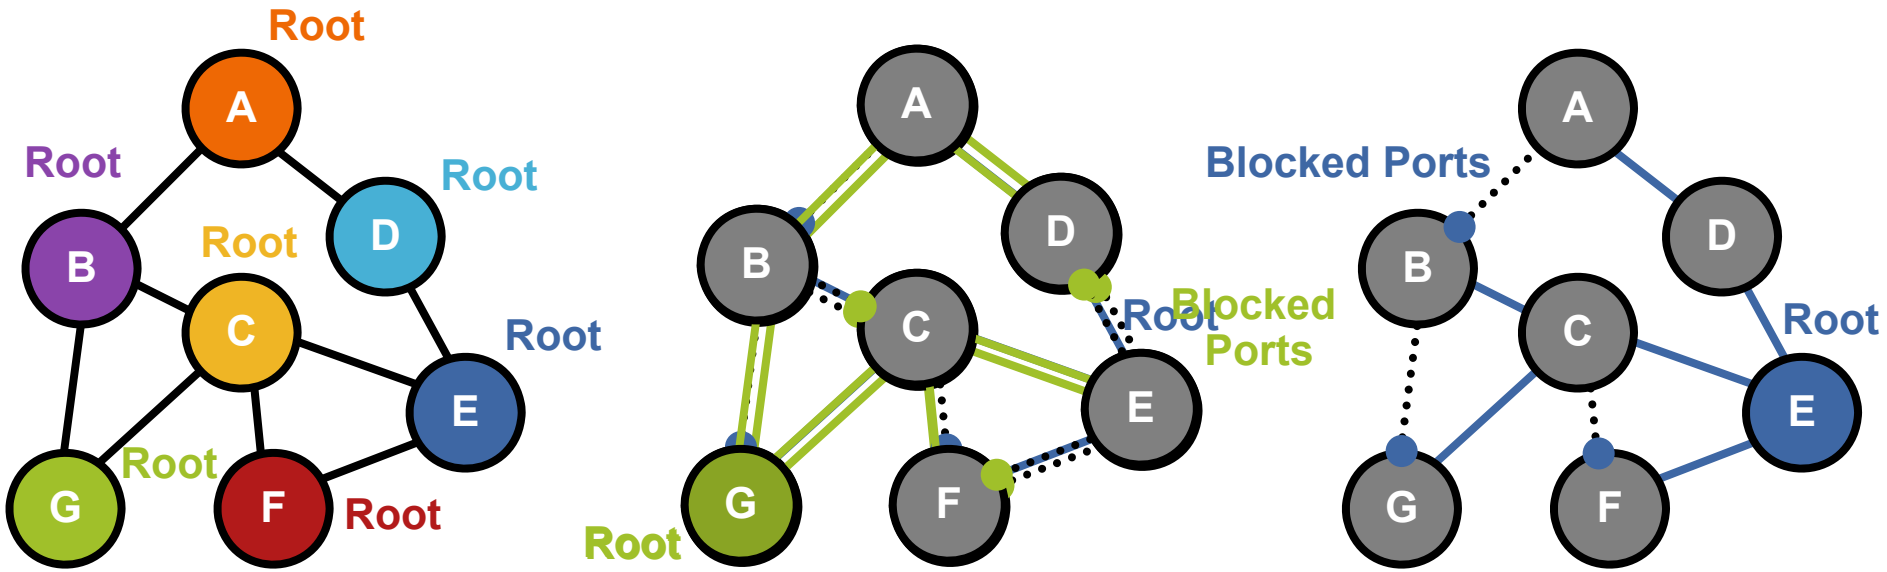

- Każdy most jest korzeniem osobnej instancji najkrótszej ścieżki
- Most G jest korzeniem dla drzewa zielonego
- Most E jest korzeniem dla drzewa błękitnego
- Oba drzewa pracują aktywnie **i** symetrycznie

  Potrzebne w Ethernecie do jednolitej obsługi multicastu i unicastu

48

Q&A