GTA / UFRJ
GRUPO DE TELEINFORMÁTICA E AUTOMAÇÃO

Roteamento em Redes de Computadores
CPE 825

Parte V
Roteamento Unicast na Internet
Roteamento Inter-Domínio

Luís Henrique M. K. Costa
luish@gta.ufrj.br

Universidade Federal do Rio de Janeiro -PEE/COPPE
P.O. Box 68504 - CEP 21941-972 - Rio de Janeiro - RJ
Brasil - http://www.gta.ufrj.br

Sistemas Autônomos

"conjunto de roteadores e redes sob a mesma administração"

- Não há limites rígidos
  - 1 roteador conectado à Internet
  - Rede corporativa unindo várias redes locais da empresa, através de um *backbone* corporativo
  - Conjunto de clientes servidos por um ISP (*Internet Service Provider*)
- Do ponto de vista do roteamento
  - "todas as partes de um AS devem permanecer conectadas"
  - Todos os roteadores de um AS devem estar conectados
    - Redes que dependem do AS *backbone* para se conectar não constituem um AS
  - Os roteadores de um AS trocam informação para manter conectividade
    - Protocolo de roteamento

Sistemas Autônomos

- Roteadores dentro de um AS
  - *Gateways* internos (*interior gateways*)
  - Conectados através de um IGP (*Interior Gateway Protocol*)
    - Ex. RIP, OSPF, IGRP, IS-IS
- Cada AS é identificado por um número de AS de 32 bits (antes 16 bits)
  - Escrito na forma decimal
  - Atribuído pelas autoridades de numeração da Internet
    - IANA (*Internet Assigned Numbers Authority*)

Troca de Informação de Roteamento

- Divisão da Internet em ASs
  - Administração de um número menor de roteadores por rede
- Mas conectividade global deve ser mantida
  - As entradas de roteamento de cada AS devem cobrir *todos os destinos* da Internet
- Dentro de um AS, rotas conhecidas usando o IGP
- Informação sobre o mundo externo através de *gateways externos*
  - EGP (*Exterior Gateway Protocol*)

O Protocolo EGP

- Responsável pela troca de informação entre *gateways* externos
  - Informação de alcançabilidade ("*reachability*")
  - Conjunto de redes alcançáveis

- Os roteadores A e B utilizam EGP para listar as redes alcançáveis dentro dos AS X e Y
- A pode então anunciar estas redes dentro do AS X usando RIP ou OSPF, por exemplo
  - RIP: DV com entradas correspondentes às redes anunciadas por B
  - OSPF: LS com rotas externas

Funcionamento do EGP

- EGP:
  - Troca de alcançabilidade entre dois *gateways* externos
- Procedimentos
  - Atribuição de vizinho ("*neighbor acquisition*")
    - Determina se dois *gateways* ***concordam*** em ser vizinhos
  - Alcançabilidade de vizinho ("*neighbor reachability*")
    - Monitora o enlace entre dois *gateways* vizinhos
  - Alcançabilidade de rede ("*network reachability*")
    - Organiza a troca de informação de alcançabilidade

Mensagens do EGP

- Transportadas sobre o IP (protocol number = 8)
- Cabeçalho comum

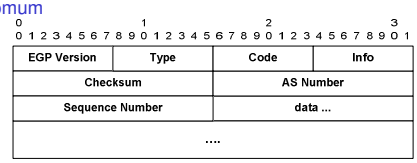

- Version – 2
- AS Number - identificação do Sistema Autônomo
- Sequence number - nº de seqüência
  - Valores diferentes de acordo com o tipo de mensagem
  - Em geral, relacionam perguntas a respostas
- Checksum – idêntico ao IP

Mensagens do EGP

- Type – sub-protocolo
  - 1, 2 – procedimento de alcançabilidade de rede
  - 3 – procedimento de atribuição de vizinho
  - 5 – procedimento de alcançabilidade de vizinho
  - 8 – mensagens de erro
- Code
  - Identificação de um tipo de mensagem dentro de um sub-protocolo
- Info
  - Informação adicional
    - p. ex. motivos de eventos

Mensagens de Erro

- Enviadas a qualquer momento

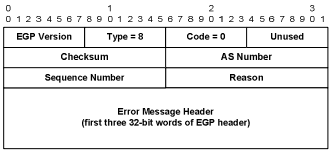

0	Unspecified
1	Bad EGP checksum
2	Bad IP Source address in NR Poll or Response
3	Undefined EGP Type or Code
4	Received poll from non-neighbor
5	Received excess unsolicited NR message
6	Received excess poll
7	Erroneous counts in received NR message
8	No response received to NR poll

- nº de seq. arbitrário escolhido pelo emissor
- Code = 0
- Reason – especifica o erro
- Os primeiros 12 bytes do pacote que gerou o erro são repetidos
  - Tratamento do erro pode se basear neste "cabeçalho"

Procedimento de Atribuição de Vizinho

- Ser vizinho EGP
  - Eventualmente transportar tráfego proveniente do AS vizinho
  - Acordo formal necessário
  - Configuração explícita
- Implementação do EGP
  - Parâmetro: lista de vizinhos potenciais
  - Um roteador só aceita se tornar vizinho de outro roteador em sua lista
- Atribuição
  - *2-way handshake*
    - Roteador envia mensagem "*neighbor acquisition request*"
    - Vizinho envia mensagem "*neighbor acquisition reply*"

Mensagem de Atribuição de Vizinho

Info field

Code	Meaning
0	Neighbor Acquisition Request
1	Neighbor Acquisition Reply
2	Neighbor Acquisition Refusal
3	Neighbor Cease Message
4	Neighbor Cease Acknowledgement

0

0	Unspecified
1	Out of table space
2	Administrative prohibition

0	Unspecified
1	Going down
2	No longer needed

Alcançabilidade de Vizinho

- *Neighbor Reachability* (NR) messages (tipo 5)

0 1 2 3 4 5 6 7	8 9 0 1 2 3 4 5	6 7 8 9 0 1 2 3	4 5 6 7 8 9 0 1
EGP Version	Type = 5	Code = 0 / 1	Status
Checksum		AS Number	
Sequence Number			

- Code: 0 – Hello, 1 - IHU (*I Heard You*)
  - 1 IHU para cada Hello, com nº de seqüência correspondente
- Info – indicação de status (assimetria possível, status 1)

0	No status given
1	You appear reachable to me
2	You appear unreachable to me due to neighbor reachability protocol
3	You appear unreachable to me due to network reachability information
4	You appear unreachable to me due to problems with my network interface

Alcançabilidade de Vizinho

- Escolha do período de Hellos
  - NR Hello Interval – define o intervalo *mínimo* entre os hellos
    - Se o vizinho envia mais hellos dentro do NR HI, pode-se não responder a todos
    - Como conseqüência, 1 par Hello/IHU com sucesso não significa enlace ok, 1 falha não é suficiente para declarar enlace ruim
  - Além disso, deve-se evitar oscilações (enlace up/down)

- *Dual threshold procedure*
  - Alcançável >> Inalcançável
    - Menos que i IHUs recebidos em resposta a n Hellos
  - Inalcançável >> Alcançável
    - Pelo menos j IHUs recebidos em resposta a m Hellos
  - m > n, j/m > i/n
    - RFC911: i=1 n=4 j=3 m=4

Alcançabilidade de Redes

- Troca de lista de redes alcançáveis por cada vizinho
- Baseada em *polling*
  - A intervalos regulares, o roteador consulta seu vizinho sobre sua lista de redes alcançáveis
  - Intervalo mínimo entre consultas dado pelo parâmetro NR poll interval (da mensagem de atribuição)

0 1 2 3 4 5 6 7	8 9 0 1 2 3 4 5	6 7 8 9 0 1 2 3	4 5 6 7 8 9 0 1
EGP Version	Type = 2	Code = 0	Unused
Checksum		AS Number	
Sequence Number		Unused	
IP Source Network			

Alcançabilidade de Redes

- Mensagens de consulta (*polling*)
  - Tipo = 2, Code = 0, campo info não utilizado
  - nº de seq. a ser repetido nas respostas
  - IP source network – prefixo da rede à qual os dois parceiros estão conectados
- Mensagens de alcançabilidade (*reachability*)
  - Tipo = 1, Code = 0
  - Enviada alguns segundos após recepção da msg. de consulta
    - Repete seu nº de seq.

- Consulta é repetida, com mesmo nº de seq., se não houve resposta
- O respondedor deve repetir a resposta
- Se após n consultas, não houve resposta
  - Não há redes alcançáveis a partir deste vizinho

Mensagens de Alcançabilidade

- As mensagens de alcançabilidade contêm
  - Cabeçalho EGP
  - IP source network – idêntico ao da mensagem de consulta
  - Lista de *gateways* e redes alcançáveis
  - Um segmento Ethernet pode conter vários roteadores, de vários Sistemas Autônomos

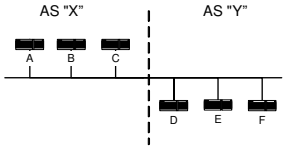

Exemplo

- Se relações de vizinhos independentes
  - 9 conexões EGP, desperdício de recursos
- Uma conexão é suficiente
  - C, um *gateway* externo do AS X, conhece as redes alcançáveis a partir dos outros roteadores, A e B
  - Basta uma conexão EGP entre 1 roteador de cada AS
- No entanto, não basta dar a lista de redes alcançáveis
  - Ou todos os destinos dentro do AS X seriam alcançados através do roteador C
- Portanto, mensagens carregam associações entre *gateways* e redes
- Terminologia: A e B são vizinhos indiretos de C

Mensagem de Alcançabilidade

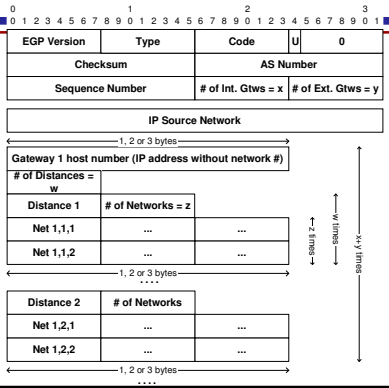

Mensagem de Alcançabilidade

- Número de *gateways* (externos + internos)
  - Modelo hierárquico: só o *core* anuncia *gateways* externos
- Cada lista
  - Parte estação do endereço do roteador na rede de conexão
  - #Distances sub-listas
    - Redes alcançáveis agrupadas por distância
    - Distâncias definidas por convenções
      - EGP só define que 255 significa inalcançável
- Mensagens enviadas em resposta a consultas (*polls*)
  - Mesmo nº de seq., campo info não utilizado
  - Intervalo típico de consultas ~ 2 min.
  - Um roteador pode enviar (no máximo) 1 mensagem de resposta não solicitada
    - U bit = 1 (bit mais significativo do campo info)

GTA/UFRJ

Anúncio de Destinos no EGP

- Anúncio do destino x supõe
  - Existe caminho para o destino x dentro do AS
  - O AS concorda em transportar dados para x usando este caminho
- Implicações
  - Maiores custos em redes pagas por volume de tráfego
  - O tráfego externo compete pelos mesmos recursos que o tráfego interno
- Deve-se tomar cuidado com o que se anuncia...

GTA/UFRJ

Exemplo

- ASs X e Y conectados ao provedor Z

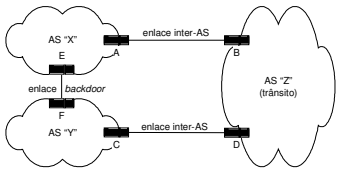

- X e Y pagam Z pelo transporte de seus pacotes
- Suponha que X e Y sejam organizações "próximas"
  - Podem decidir ter uma conexão direta ("*backdoor*")
- Anúncios
  - E deve anunciar para F alcançabilidade das redes dentro de X
  - F deve anunciar para E alcançabilidade das redes dentro de Y

GTA/UFRJ

Exemplo

- Rotas aprendidas são propagadas pelos IGPs
- A é capaz de alcançar redes em X e Y
  - Mas A não deve anunciá-las
  - Não faz sentido A anunciar rotas para Y, o objetivo não é X se tornar uma rede de trânsito...
- Para funcionar, deve-se implementar duas listas
  - Redes que podem ser servidas
    - Arquivo de configuração (lista pode ser por vizinho)
  - Redes que podem ser alcançadas
    - Obtidas do IGP

GTA/UFRJ

Outro Exemplo

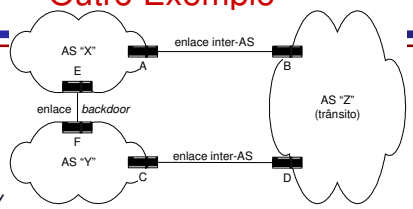

- Rotas em Y
  - Anunciadas por C para D
  - Anunciadas por B para A
  - Anunciadas por F para E (conexão *backdoor*)
- Para que o *backdoor* funcione
  - Distância anunciada por F < distância anunciada por B
  - Para tanto
    - Anuncia-se distâncias maiores por C que por F
    - E ***espera-se*** que Z não anunciará através de B distâncias menores que as aprendidas por D...

GTA/UFRJ

Tabelas de Roteamento

- Para que uma rota externa seja usada pelo IGP
  - Procedimento de atribuição de vizinho realizado com sucesso
  - Vizinho deve estar alcançável
  - Vizinho deve ter anunciado o destino
  - O roteador local deve ter determinado que não existe outra rota melhor para o destino
- Quarta condição
  - Várias rotas podem existir para o destino
  - A de menor distância deve ser escolhida...

GTA/UFRJ

Topologia da Rede

- EGP "parece" com protocolos de vetores de distância
  - Mas não há regras bem especificadas para cálculo de distâncias
  - Convergência lenta
- Distâncias anunciadas pelo EGP
  - Combinam preferências e políticas
- Exemplo do *backbone* NSFnet
  - 128 – rede alcançável
  - 255 – rede inalcançável

Topologia da Rede

- Em geral, um roteador não anuncia distância menor que a aprendida do seu vizinho
  - Apenas um consenso, não existe a *regra* no EGP
- Necessidade de isolamento de mudanças de topologia
  - Mudanças de métricas em um AS não são anunciadas em geral, apenas quando há perda de conectividade
- Infinito = 255
  - Convergência seria lenta em caso de *loop*
- Além disso, *updates* enviados após consultas (a cada 2 min.)
  - 2 min. x 255 > 8 horas...

Topologia da Rede

- Conclusão
  - EGP não foi projetado como protocolo de roteamento em geral, apenas como " anunciador de alcançabilidades"
- Topologia
  - ASs *stub* conectados a um *backbone* (Arpanet)
  - Pode funcionar se a topologia for uma árvore
  - NSFnet
    - Redes regionais
      - Redes universitárias e de pesquisa
  - Podem haver conexões *backdoor*, apenas bilaterais
- Com o aumento da Internet, as limitações do EGP ficaram evidentes...

Border Gateway Protocol (BGP)

- Histórico
  - No início...
    - 8 bits de rede, 24 bits de estações...
      - Mas a Internet logo iria ultrapassar as 256 redes...
    - Divisão em classes A, B e C
      - Redes grandes, médias e pequenas poderiam ser criadas
  - 1991: mais problemas por vir...
    - Penúria de endereços de Classe B
    - Explosão das tabelas de roteamento
  - Remédio: CIDR (*Classless Inter-Domain Routing*)

Penúria de Redes Classe B

- Classe A – 128 redes, 16.777.214 estações
- Classe B – 16.384 redes, 65.534 estações
- Classe C – 2.097.152 redes, 254 estações

- Classe A – muito escassos...
- Classe C – muito pequeno...
- Classe B – melhor escolha na maioria das vezes

- Em 1994, metade dos Classe B já haviam sido alocados...

Explosão das Tabelas de Roteamento

- Problemas observados
  - IGP que enviava tabelas completas, periodicamente
    - Aumento da tabela de roteamento
      - Mensagens fragmentadas
    - Roteadores com buffer de 4 pacotes
      - Realocação do buffer não era rápida o suficiente
  - Tabela de roteamento com próx. salto para todos os destinos
    - Implementada em memória rápida nas próprias interfaces de rede
      - Memória rápida, mas escassa...
      - Na época, havia 2.000 redes, o projeto comportava 10.000 entradas...
  - Sistemas modernos usam solução hierárquica
    - Rotas usadas mais freqüentemente são guardadas em cache
      - Tabela completa na memória principal e calculada pelo processador central
    - No entanto, o problema persiste...
      - BGP: envio diferencial, tamanho da tabela proporcional ao produto do número de destinos pelo número de vizinhos

Endereços Sem Classe (CIDR)

- Muitas organizações possuem mais de 256 estações, mas muito poucas mais de alguns milhares...
  - Em vez de uma Classe B, alocar várias Classes C
- Fornecimento de endereços
  - Existem dois milhões de Classe C
  - Classe B fornecido
    - Se no mínimo 32 redes, com no mínimo 4.092 estações
  - Classe A fornecido em casos raros
    - E apenas pelo IANA, as autoridades regionais não o distribuem
- Distribuição de *n* Classes C
  - Resolve a penúria de Classes B
  - Mas deve ser feita com cuidado, para não piorar a explosão das tabelas
    - Classes C "contíguos" devem ser alocados
      - Criam "super-redes"
      - Agregação por regiões pode ser vislumbrada

Vetores de Caminho

- Inter-domínio
  - Nem sempre o caminho mais curto é o melhor
  - Distâncias representam preferências por determinadas rotas
    - Convergência do Bellman-Ford não pode ser garantida
    - Destinos inalcançáveis poderiam implementar split horizon, mas não há como contar até o infinito para prevenir loops
  - Estados de enlace
    - Tentado no protocolo IDPR (*Inter-Domain Policy Routing*)
    - Problemas
      - Distâncias arbitrárias
        - Para evitar loops, IDPR propunha source routing
      - Inundação da base de dados da topologia
        - Problema mesmo com nível de granularidade do AS
        - OSPF: áreas com até 200 roteadores
        - Internet: 700 ASs em 1994...

Vetores de Caminho

- Vetor de caminho (*path vector* – PV)
  - "DV" que transporta a lista completa das redes (ASs) atravessados
  - *Loop* apenas se um AS é listado duas vezes
- Algoritmo
  - Ao receber anúncio, roteador verifica se seu AS está listado
    - Se sim, o caminho não é utilizado
    - Se não, o próprio número de AS é incluído no PV
  - Domínios não são obrigados a usar as mesmas métricas
    - Decisões autônomas
  - Desvantagem
    - Tamanho das mensagens
    - Memória

Consumo de Memória do PV

- Cresce com o número de redes na Internet (N)
  - Uma entrada por rede
- Para cada uma das redes, o caminho de acesso (lista de ASs)
  - Todas as redes em um AS usam o mesmo caminho
  - Número de caminhos a armazenar proporcional ao número de ASs (A)
  - Tamanho médio de um caminho: distância média entre 2 ASs
    - Depende do tamanho e topologia da Internet
      - Hipótese: diâmetro varia com o logaritmo do tamanho da rede
  - Seja x a memória consumida para armazenar um AS, y a memória consumida por um destino, a memória consumida
    - x . A . Log A + y . N

Agregação de Rotas

- Até BGP-3: destinos são apenas classe A, B ou C
- BGP-4: CIDR
  - Rotas devem incluir endereço e comprimento do prefixo
  - Para diminuir o tamanho das tabelas, agregação de rotas
- Exemplo
  - Provedor T
    - Duas Classes C: 197.8.0/24 e 197.8.1/24
  - ASs X e Y, clientes de T
    - Classes C: 197.8.2/24 e 197.8.3/24
  - Anúncios sem agregação:
    - Caminho1: através de {T}, alcança 197.8.0/23
    - Caminho 2: através de {T, X}, alcança 197.8.2/24
    - Caminho 3: através de {T, Y}, alcança 197.8.3/24
  - Idealmente, anunciar-se-ia Caminho 1: alcança 197.8.0/22
    - Problema: anunciar apenas {T} não evita *loops*, anunciar {T,X,Y} é incorreto...

Agregação de Rotas

- Solução: caminho estruturado em dois componentes
  - Seqüência de ASs (ordenado)
  - Conjunto de ASs (não ordenado)
- Exemplo (cont.)
  - Caminho 1: (Seqüência {T}, Conjunto {X,Y}, alcança 197.8.0/22)
  - Se um vizinho Z anuncia o caminho:
    Caminho n: (Seqüência {Z,T}, Conjunto {X,Y}, alcança 197.8.0/22)
- Os dois conjuntos devem ser usados para prevenir *loops*
- Caminhos podem ser agregados recursivamente
  - A Seqüência de ASs contém a interseção de todas as seqüências
  - O conjunto de ASs contém a união de todos os conjuntos de ASs
  - A lista de redes, todas as redes alcançáveis

Agregação de Rotas

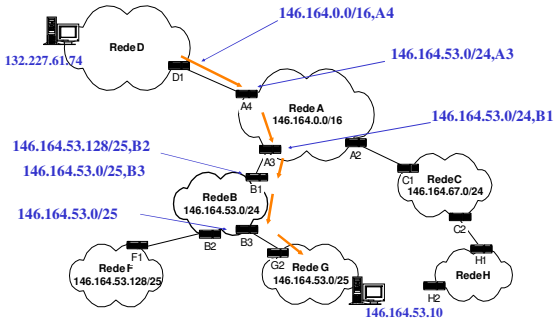

Atributos de Caminhos

- Principais
  - Lista dos ASs atravessados (AS_PATH)
  - Lista das redes alcançáveis (destinos)
- Outros atributos ajudam o processo de decisão...
- BGP-3
- Flags
  - O = 1 atributo opcional ou O = 0 atributo bem conhecido
  - T = 1 atributo transitivo ou T = 0 atributo local
  - P = 1 informação parcial
  - E = 0 comprimento do atributo codificado em 1 octeto ou 2 (E=1)

Atributos de Caminhos

- Tratamento de extensões no BGP-3
  - *Flag* de atributo opcional é verificado
  - Atributos opcionais não-transitivos
    - Informação pertinente à conexão local, apenas
    - Ignorados silenciosamente se não conhecidos
  - Atributos opcionais transitivos
    - Se não conhecidos, enviados, mas com o bit parcial (P) em 1
- BGP-4: 7 atributos

Attribute	Type	Flags	Value
ORIGIN	1	Well known	IGP (0), EGP (1) or other (2)
AS_PATH	2	Well known	Autonomous systems in the path
NEXT_HOP	3	Well known	Address of next router
MULTI_EXIT_DISC	4	Optional, local	32 bit metric
LOCAL_PREF	5	Well known	32 bit metric
ATOMIC_AGGREGATE	6	Well known	Flags certain aggregations
AGGREGATOR	7	Optional, transitive	AS number and router ID

Atributos de Caminho

- Origin
  - Informação de roteamento obtida do IGP; pelo EGP, ou por outro meio (ex. rota estática)
- Next Hop
  - Mesma função que o vizinho indireto no EGP
  - (atributo não transitivo)
- Multi Exit Discriminator (MED)
  - Métrica usada para escolher entre diversos roteadores de saída
    - Entre diversos caminhos que diferem apenas pelos atributos MUITI_EXIT_DISC e NEXT_HOP
    - Estes caminhos não devem ser agregados
    - Permite exportar informação (limitada) da topologia interna para um AS vizinho

Atributos de Caminho

- Local Preference
  - Sincroniza a escolha de rotas de saída pelos roteadores dentro de um AS
  - O atributo é adicionado ao caminho pelo roteador de entrada
  - Usado na escolha entre vários caminhos que levam a um prefixo de rede
- Atomic Aggregate
  - Indica que o roteador realizou a agregação e está *passando* um caminho agregado
    - Não possui conteúdo
- Aggregator
  - Identificador do roteador que agregou rotas
    - Contém o número de AS e IP do roteador
    - Usado para diagnosticar problemas

Parceiros BGP Internos e Externos

- Rotas devem ser passadas para o IGP
- Atributos de caminhos devem ser transmitidos a outros roteadores BGP do AS
  - Transmissão de informação através do IGP não é suficiente

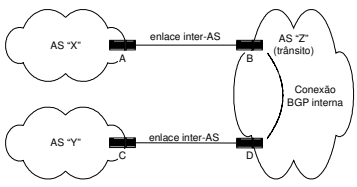

  - Solução: conexão BGP interna

Conexões BGP Internas

- Conexões internas
  - Propagação de rotas externas independente do IGP
  - Roteadores podem eleger a melhor rota de saída, em conjunto
  - Se os roteadores de um AS escolhem nova rota externa, esta deve ser anunciada imediatamente para parceiros externos que usam este AS como trânsito
    - Ou risco de *loops* de ASs...
- Roteadores BGP conectados por malha completa
  - Problemas de **escalabilidade**, se o número de roteadores BGP é grande...

EBGP x IBGP

- External BGP Peers x Internal BGP Peers
  - Diferenciação: pelo número do AS, na abertura da conexão
- Funcionamento
  - Rotas aprendidas de um peer EBGP repassadas a outros ASes através das conexões IBGP
  - Evita-se armazenar todos os prefixos externos nos roteadores internos
  - Porém, no anúncio através do IBGP não se acrescenta o AS
    - Risco de loop > regras específicas

Anúncios EBGP x IBGP

- Regra 1
  - Um roteador BGP pode anunciar prefixos que aprendeu **de um par EBGP a um par IBGP**; também pode anunciar prefixos que aprendeu **de um par IBGP para um par EBGP**
- Regra 2
  - Um roteador BGP não deve anunciar prefixos que aprendeu de **um par IBGP para outro par IBGP**
- Motivos para Regra 2
  - Evitar loops: o número de AS não é acrescentado no anúncio IBGP
  - Rotas internas devem ser anunciadas pelo IGP...

Execução sobre o TCP

- Controle de Erro – TCP
  - O BGP pode ser mais simples (máquina de estados do EGP é bem mais complexa)
  - Por outro lado...
    - EGP – informação gradual (%), decisão de enlace operacional ou não
    - BGP/TCP – enlace operacional ou não (informação "binária")
      - BGP utiliza sondas (*probes*) enviados periodicamente
- Transmissão confiável
  - Atualizações incrementais, menor consumo de banda que no EGP
- Problema: controle de congestionamento do TCP
  - Cada conexão TCP recebe uma parte justa ("*fair share*") da banda
  - Desejável na maioria dos casos
    - Mas ***não*** em se tratando do protocolo de roteamento, que pode eventualmente adaptar-se e remediar o congestionamento

Cabeçalho BGP

- TCP: orientado a byte
  - Delimitadores necessários nas mensagens BGP

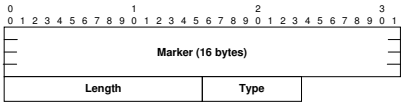

  - Marker – projetado para utilização por mecanismos de segurança
  - A estação lê os 19 bytes correspondentes ao cabeçalho, mais (length – 19) bytes da mensagem BGP
  - Type
    - 1 – Open 2 – Update 3 – Notification 4 – KeepAlive

Exemplo de Problema de Alinhamento

- Suponha uma mensagem de 255 bytes de comprimento

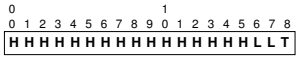

- Recebida desalinhada de 1 byte

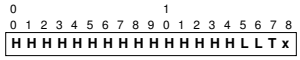

- Comprimento recebido: 65.582(FF02) em vez de 255(00FF)
- Testes de sanidade
  - Comprimento entre 19 e 8192 bytes
  - Type deve estar entre 1 e 4
  - Marker deve ter o valor esperado pelo algoritmo de segurança

Troca Inicial

- Mensagem OPEN

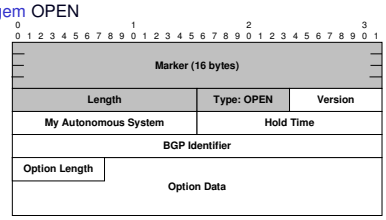

- Version – Versão do BGP
- My Autonomous System – número de AS do roteador emetente
- Hold Time – número de segundos utilizado no KeepAlive
- BGP Identifier – um dos endereços IP do roteador

Troca Inicial

- Opções: TLV
  - 1 byte de tipo + 1 byte de comprimento + N bytes de conteúdo
- Opção Tipo 1
  - Informação de autenticação
  - Determina o conteúdo do marcador (nas mensagens seguintes)
- Conexão com sucesso (envio posterior de mensagens keepalive)
  - Versão e Hold Time devem estar ok
- Insucesso (envio de mensagem de notificação)
  - Diferença de versão
    - pode ser tentada uma versão menor
  - Falha de autenticação
    - existe parametrização, como no EGP
  - Colisão
    - Duas conexões TCP abertas
    - Uma é fechada (decisão pelo identificador BGP)

Mensagens de Atualização

- Mensagens UPDATE

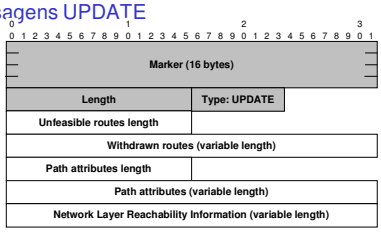

- Lista de rotas inalcançáveis
- Informação sobre um caminho específico

Mensagens de Atualização

- Lista de rotas inalcançáveis
  - Rotas anunciadas anteriormente, agora inalcançáveis
  - Podem ser reunidas rotas de caminhos diferentes
- Informação sobre um caminho
  - Atributos referentes a este caminho
    - Formato TLV
  - Redes alcançáveis por este caminho
- As mensagens não são alinhadas em 32 bits...
  - Listas de prefixos de roteamento nos dois campos
    - 1 byte de comprimento do prefixo em bits
    - Endereço com o comprimento necessário

Mensagens de Atualização

- Uma mensagem para cada caminho
  - Todos os caminhos são enviados após a troca inicial
  - Não são repetidos periodicamente, são enviadas mensagens de atualização apenas para os caminhos que mudarem
- Funcionamento semelhante ao DV
  - Ao receber atualização, se caminho "mais curto", modificação de rota e envio aos vizinhos
  - Se malha completa entre os parceiros BGP internos
    - Atualização recebida em uma conexão interna não precisa ser enviada aos parceiros internos
- Testes de sanidade
  - Verificação de *loops* (*path-vector*)
  - *Hold-down* antes de começar a utilizar o caminho

Procedimento KeepAlive

- Mensagens KeepAlive

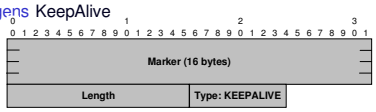

- Enviadas periodicamente, se necessário
  - A conexão TCP sinaliza problemas *quando* há tentativa de envio de dados
  - Testam o enlace em uma direção
- Na direção contrária
  - O parceiro deve enviar uma mensagem no mínimo a cada Hold-Time s
  - Na verdade, envio de 3 mensagens, em média, por Hold-Time
    - O atraso de transmissão sobre o TCP não é constante
    - Tipicamente, uma mensagem a cada 2 minutos
- Hold-Time pode ser zero – não há envio de mensagens keepalive
  - Útil se enlaces pagos por demanda
  - Outro mecanismo deve ser utilizado pra detectar se enlace operacional

Notificação de Erros

- Mensagem de erro
  - Recepção de mensagem incorreta
  - Ausência de recepção de mensagens
- Conexão TCP fechada após o envio da notificação

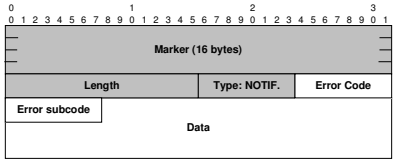

- Erros identificados por código e sub-código
  - A notificação "*cease*" não é um erro, mas indicação de término da conexão

Códigos de Erro

Code	Subcode	Symbolic Name
1		Message Header Error
	1	Connection Not Synchronized
	2	Bad Message Length
	3	Bad Message Type
2		OPEN Message Error
	1	Unsupported Version Number
	2	Bad Peer AS
	3	Bad BGP Identifier
	4	Unsupported Optional Parameter
	5	Authentication Failure
	6	Unacceptable Hold Time
3		UPDATE Message Error
	1	Malformed Attribute List
	2	Unrecognized Well-Known Attribute
	3	Missing Well-Known Attribute
	4	Attribute Flags Error
	5	Attribute Length Error
	6	Invalid ORIGIN Attribute
	7	AS Routing Loop
	8	Invalid NEXT_HOP Attribute
	9	Optional Attribute Error
	10	Invalid Network Field
	11	Malformed AS_PATH
4		Hold Timer Expired
5		Finite State Machine Error
6		Cease

Riscos de Ataques à Conexão TCP

- Ataques e conseqüências pro BGP
  - SYN flooding
    - Derrubar o servidor com um grande número de conexões semi-abertas
    - Desconexão de uma rede inteira
  - RST
    - Quebra da conexão através do envio de um pacote RESET
    - Desconexão de conjuntos de redes (que deixam de ser anunciadas)
  - DATA insertion
    - Inserção de um pacote forjado na conexão
    - Criação de erros
  - Hijacking
    - Um terceiro se passa por uma das estações
    - Inserção de rotas falsas, criação de *loops*, buracos negros, captura do tráfego enviado a uma rede

Proteção da Conexão TCP

- TCP MD5 Signature Option
  - Similar ao mecanismo do RIP e OSPF, mas implementada no TCP
  - Opção TCP

IP Header (20 bytes)
TCP "fixed" header (20 bytes)
TCP Options, including MD5 checksum
TCP Payload (BGP)

  - Foi implementada na Internet
    - Embora seja julgada de proteção fraca por experts de segurança
  - Alternativa
    - TCP + IPSEC

Sincronização com o IGP

- Rotas devem ser mantidas coerentes
- No plano BGP
  - Roteadores de borda aprendem rotas de roteadores em ASs vizinhos
  - Selecionam caminhos através do processo de decisão do BGP
  - Sincronizam-se através de conexões BGP internas
- No plano IGP
  - Roteadores de borda anunciam rotas externas
  - Aprendem a conectividade local

Políticas de Interconexão

- Redes comercias não transportam tráfego para "qualquer um"
  - O acordo básico é entre o provedor e o cliente
    - acesso à Internet através de uma rota *default*
  - Pequenos provedores compram serviços de trânsito de provedores maiores (provedores de *backbone*)
  - Grandes provedores podem se interconectar (*peering*)
    - ***Limited peering*** – conexão aos endereços diretamente administrados pelo parceiro
    - ***Full peering*** – interconexão transitiva (o AS pode ser usado como trânsito)
  - Provedores podem negociar acordos de backup
    - Manter conectividade em caso de falha parcial

Políticas de Interconexão

- Acordos são especificados em contratos, que roteadores de borda devem forçar
  - Acordo com um cliente
    - Só são aceitos caminhos que levam ao cliente, só é exportada uma rota default
  - Serviços de trânsito
    - Anúncio de caminhos para os destinos listados no contrato
  - *Limited peering*
    - Anúncio de rotas apenas para o AS local e clientes
    - O roteador de borda pode ser programado para só aceitar estas rotas
  - *Full peering*
    - Remoção de todas as restrições
  - Backup
    - Preferência baixa associada às rotas importadas

Processo de Decisão

- Três fases
  - Análise dos caminhos recebidos de roteadores externos
  - Seleção do caminho mais apropriado para cada destino
  - Anúncio do caminho aos vizinhos

Análise do Caminho Recebido

- Remoção de caminhos inaceitáveis
  - Que incluem o AS local no caminho de ASs
  - Não conformes à política do AS
  - Que não foram qualificados como estáveis
- Métricas
  - Número de ASs no caminho (simples *demais*)
  - Pesos podem ser associados a alguns ASs
  - Caminhos agregados são um problema
    - Número de ASs na seqüência de ASs é uma sub-estimativa
    - Número de ASs no conjunto de ASs é uma super-estimativa
- A métrica pode então ser combinada com preferências locais
  - Ex. local preference, banda do enlace com o vizinho, custo

Seleção de Caminhos

1. Remoção de caminhos cujo próximo salto está inalcançável
2. Separar os caminhos com o maior LOCAL_PREFERENCE
3. Se existem múltiplos caminhos, escolher o de menor valor MULTI_EXIT_DISC
4. Se ainda existem múltiplos caminhos, selecionar o caminho anunciado pelo parceiro BGP *externo* de maior identificador
5. Se ainda existem múltiplos caminhos, selecionar o caminho anunciado pelo parceiro BGP *interno* de maior identificador

- Anúncio da rota aos vizinhos...

CIDR e IGP

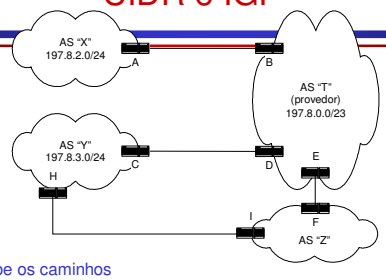

- Z recebe os caminhos
  - Path(T): (Sequence{T}, Set{X,Y}), alcança 197.8.0.0/22
  - Path(Y): (Sequence{Y}), alcança 197.8.3.0/24
- Quando uma máquina em Z quer enviar a uma máquina em Y
  - O segundo caminho ganha ("mais específico")
  - É mais "seguro" utilizar o caminho mais específico

CIDR e IGP

- Mas o caminho mais específico não é necessariamente mais curto

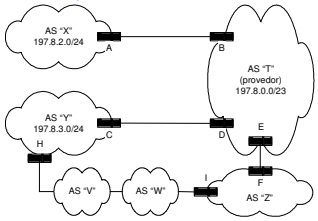

  - Path(T): (Sequence{T}, Set{X,Y}), alcança 197.8.0.0/22
  - Path(W): (Sequence{W,V,Y}), alcança 197.8.3.0/24
  - Pode-se configurar o BGP para não escolher o mais específico
    - A ser feito com cuidado...

CIDR e IGP

- Passagem de prefixos para o IGP
  - Todos os prefixos podem ser passados, se o IGP os "entende"
  - Se não, os prefixos devem ser quebrados
- Anúncios equivalentes no primeiro exemplo
  - Path(T): (Sequence{T}, Set{X,Y}), alcança 197.8.0.0/23, 197.8.2.0/24
  - Path(Y): (Sequence{Y}), alcança 197.8.3.0/24
- Os anúncios podem ser exportados agregados ou não
  - Path(Z): (Sequence{Z}, Set{X,Y,T}), alcança 197.8.0.0/22

Exportando Rotas para ASs Vizinhos

- Caminho exportado
  - Caminho recebido + Número do AS local
  - (AS local adicionado ao AS_SEQUENCE)
  - LOCAL_PREFERENCE é removido
  - MULTI_EXIT_DISC pode ser configurado
  - Se caminhos foram agregados no AS
    - Atributo AGGREGATOR
    - Atributo ATOMIC_AGGREGATE
      - Se caminhos mais específicos foram fundidos em menos específicos

Escalabilidade Interna

- Problema
  - Malha completa de conexões BGP internas
  - Dados N roteadores, cada roteador deve gerir N-1 conexões BGP internas (TCP)
- Soluções possíveis
  - BGP Route Reflectors
  - BGP Confederations

Refletores de Rotas BGP

- Roteadores Route Reflector (RR)
  - Funcionam como “concentradores”
- Roteadores clientes
  - Se conectam apenas a um route reflector
  - Se comportam como se estivessem conectados à malha completa
- Route reflectors se conectam entre si em malha completa

GTA/UFRJ

Malha Completa IBGP

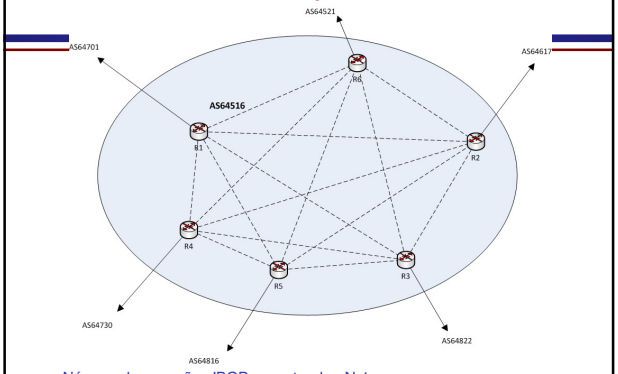

- Número de conexões IBGP por roteador: N-1

GTA/UFRJ

Exemplo: 1 Route Reflector

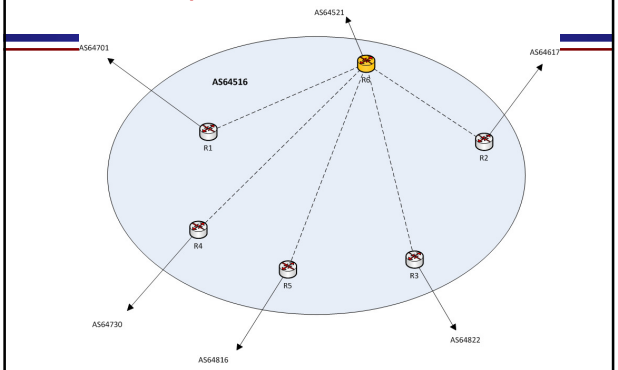

- 1 RR: número de conexões de R6 não diminui

GTA/UFRJ

Exemplo: 2 RRs

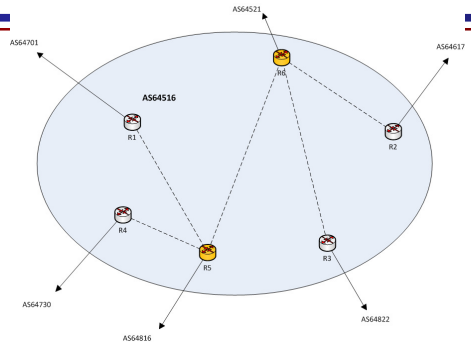

- Diminui o número de conexões para N/2

GTA/UFRJ

Exemplo: 3 RRs

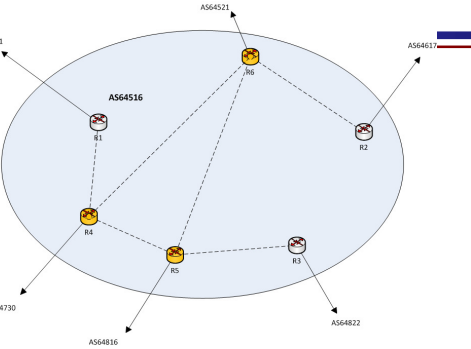

- Aparece a malha entre RRs

GTA/UFRJ

Regras de Anúncios usando Refletores de Rotas BGP

- Anúncio recebido por um RR, de outro RR
  - Repassado aos seus clientes
- Anúncio recebido por um RR, de um cliente
  - Repassado aos outros RRs
- Anúncio recebido por um RR, de um parceiro EBGP
  - Repassado aos outros RRs e a seus clientes

GTA/UFRJ

Refletores de Rotas BGP: prevenção de loops

- ORIGINATOR_ID
  - Adicionado apenas pelo RR de origem
  - Quando recebe anúncio do cliente, acrescenta ORIGINATOR_ID
  - Se o RR recebe um anúncio com seu próprio ORIGINATOR_ID, deve ignorá-lo
- CLUSTER_LIST
  - Sequência de CLUSTER-IDs que indicam o caminho de clusters que um anúncio atravessou (semelhante ao path vector)
  - Quando um RR reflete um anúncio, ele deve acrescentar o seu CLUSTER_ID à lista

Exemplo de RRs com 3 clusters

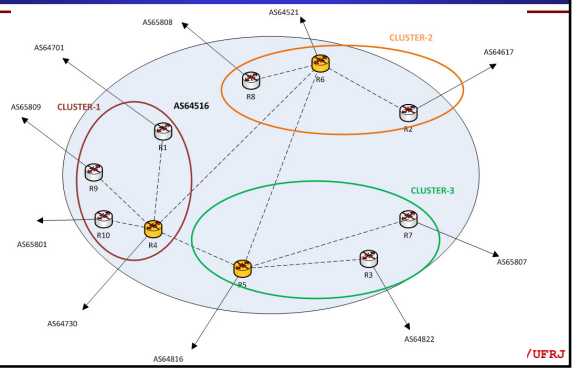

Confederações BGP

- Ideia básica: hierarquia
  - ASes são divididos em sub-ASes
  - Malha completa somente dentro de cada sub-AS
  - Conexões "IBGP externas" interconectam os sub-ASes

Exemplo de Confederações BGP

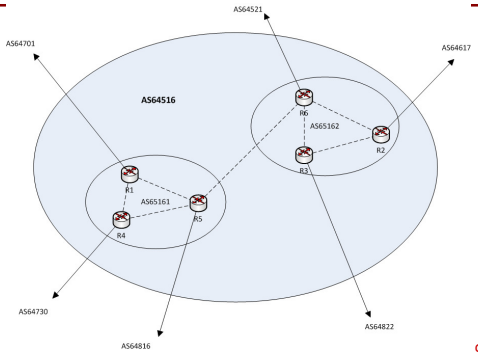

GTA/UFRJ

BGP: Observações Finais

- BGP
  - Topologia genérica, em malha, em vez da árvore imposta pelo EGP
- CIDR
  - Evitou o colapso da Internet pela penúria de endereços Classe B
- BGP
  - Evitou o colapso da Internet pela explosão das tabelas de roteamento
- No entanto, o BGP precisa de muita configuração manual...

GTA/UFRJ

AS´s Únicos

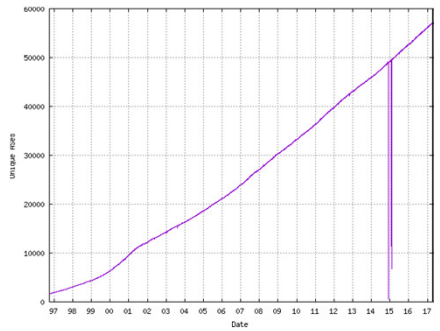

Fonte: http://www.cidr-report.org/

GTA/UFRJ

Entradas BGP Ativas

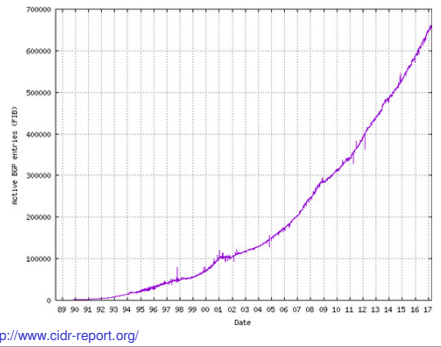

Fonte: http://www.cidr-report.org/

GTA/UFRJ