Redes de Computadores 2
EEL 879

Parte III
Roteamento Unicast na Internet
Estado do Enlace

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

Universidade Federal do Rio de Janeiro -PEE/COPPE
P.O. Box 68504 - CEP 21945-970 - Rio de Janeiro - RJ
Brasil - http://www.gta.ufrj.br

Protocolos de Estado do Enlace

- Baseiam-se em um ***mapa distribuído*** da topologia da rede
- O mapa deve ser atualizado a cada mudança na topologia
- Cada no é capaz de calcular a melhor rota entre quaisquer 2 pontos da rede, a partir do mapa local

Base de Dados de Estados do Enlace

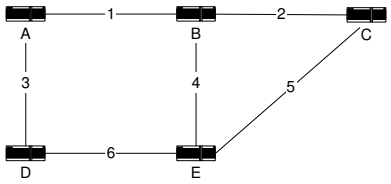

De	Para	Enlace	Dist.
A	B	1	1
A	D	3	1
B	A	1	1
B	C	2	1
B	E	4	1
C	B	2	1
C	E	5	1
D	A	3	1
D	E	6	1
E	B	4	1
E	C	5	1
E	D	6	1

Estados do Enlace

- Cada nó pode calcular o caminho mais curto para todos os outros nós
- Todos os nós possuem a mesma base de dados
  - Não podem ocorrer *loops*

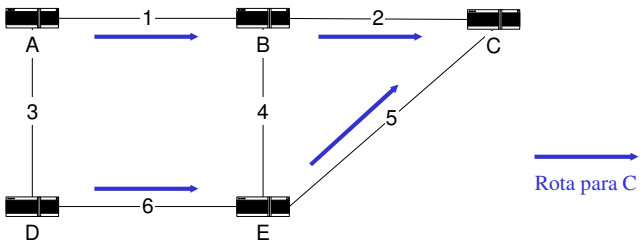

Protocolo de Inundação

- Detecção de falhas deve ser rápida e confiável
  - Protocolo de inundação

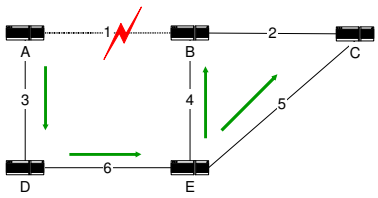

De A, para B, enlace 1, dist. = inf.

Protocolo de Inundação

- Mensagens "antigas" não devem contaminar as bases de dados
  - Mensagens devem ser identificadas (datadas)
    - Estampa de tempo
    - Número de mensagem
- Algoritmo
  1. Recepção da mensagem. Busca do registro na base de dados.
  2. **Se o registro não existia**, adicioná-lo à base. Enviar a mensagem em *broadcast*.
  3. Senão, **se o número na base de dados é menor** que o número recebido na mensagem, substituir o registro pelo novo valor. Enviar a mensagem em *broadcast*.
  4. Senão, **se o número na base de dados é maior**, transmitir o registro da base de dados em uma nova mensagem, na interface de entrada.
  5. Senão, **se os números são iguais**, não fazer nada.

Detecção de uma Falha

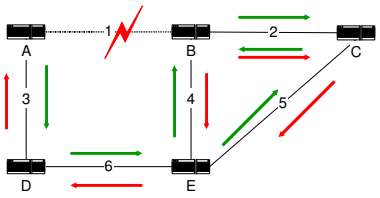

De A, para B, enlace 1, dist. = inf., n = 2

De B, para A, enlace 1, dist. = inf., n = 2

De	Para	Enl.	Dist.	No.
A	B	1	inf.	2
A	D	3	1	1
B	A	1	inf.	2
B	C	2	1	1
B	E	4	1	1
C	B	2	1	1
C	E	5	1	1
D	A	3	1	1
D	E	6	1	1
E	B	4	1	1
E	C	5	1	1
E	D	6	1	1

GTA/UFRJ

Números de Seqüência

- A rede deve funcionar por tempo indeterminado
  - Número de seqüência circular
- Como decidir se X < Y ?
  - Supõe-se que os números de seqüência são incrementados lentamente
    - Devido a mudanças de estado de enlaces, ou estouro de temporizadores (*suficientemente longos*)
  - Se X + dx = Y, onde dx é "pequeno", X < Y
  - Definição de dx deve ser precisa
    - Coerência das bases de dados em todos os nós

GTA/UFRJ

Desconexão da Rede

- Enlace 6 falha

De D, para E, enlace 6, dist. = inf., n = 2 → **De E, para D, enlace 6, dist. = inf., n = 2** →

De	Para	Enl.	Dist.	No.
A	B	1	inf.	2
A	D	3	1	1
B	A	1	inf.	2
B	C	2	1	1
B	E	4	1	1
C	B	2	1	1
C	E	5	1	1
D	A	3	1	1
D	E	6	inf.	2
E	B	4	1	1
E	C	5	1	1
E	D	6	1	1

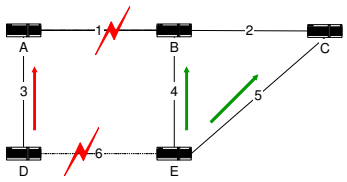

De	Para	Enl.	Dist.	No.
A	B	1	inf.	2
A	D	3	1	1
B	A	1	inf.	2
B	C	2	1	1
B	E	4	1	1
C	B	2	1	1
C	E	5	1	1
D	A	3	1	1
D	E	6	1	1
E	B	4	1	1
E	C	5	1	1
E	D	6	inf.	2

Mapas da topologia diferentes

Não há problema, pois destinos na outra parte da rede estão inalcançáveis

GTA/UFRJ

Mapas evoluem separadamente

- Enlace 2 falha

De B, para C, enlace 2, dist. = inf., n = 2 → **De C, para B, enlace 2, dist. = inf., n = 2** →

De	Para	Enl.	Dist.	No.
A	B	1	inf.	2
A	D	3	1	1
B	A	1	inf.	2
B	C	2	1	1
B	E	4	1	1
C	B	2	1	1
C	E	5	1	1
D	A	3	1	1
D	E	6	inf.	2
E	B	4	1	1
E	C	5	1	1
E	D	6	1	1

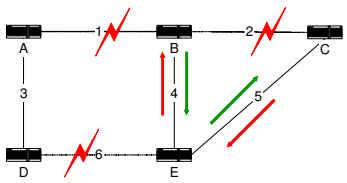

De	Para	Enl.	Dist.	No.
A	B	1	inf.	2
A	D	3	1	1
B	A	1	inf.	2
B	C	2	inf.	2
B	E	4	1	1
C	B	2	inf.	2
C	E	5	1	1
D	A	3	1	1
D	E	6	1	1
E	B	4	1	1
E	C	5	1	1
E	D	6	inf.	2

GTA/UFRJ

Recuperando Adjacências

- Enlace 1 é religado

De A, para B, enlace 1, dist. = 1, n = 3

De	Para	Enl.	Dist.	No.
A	B	1	1	3
A	D	3	1	1
B	A	1	1	3
B	C	2	1	1
B	E	4	1	1
C	B	2	1	1
C	E	5	1	1
D	A	3	1	1
D	E	6	inf.	2
E	B	4	1	1
E	C	5	1	1
E	D	6	1	1

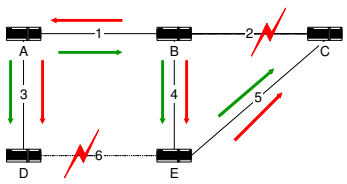

De B, para A, enlace 1, dist. = 1, n = 3

De	Para	Enl.	Dist.	No.
A	B	1	1	3
A	D	3	1	1
B	A	1	1	3
B	C	2	inf.	2
B	E	4	1	1
C	B	2	inf.	2
C	E	5	1	1
D	A	3	1	1
D	E	6	1	1
E	B	4	1	1
E	C	5	1	1
E	D	6	inf.	2

O envio de apenas uma atualização de registro (enlace 1) não é suficiente

Recuperando Adjacências

- Alinhamento dos mapas
  - Identificadores de enlace + Números de versão
  - Para cada registro deve ser armazenada a versão mais recente
    - maior número de versão
- Solução "ingênua"
  - Cada nó envia sua base de dados completa
  - Desperdício de recursos
    - Muitos registros podem ter versões em comum
- OSPF
  - **Pacotes de descrição da base de dados**
    - Contêm apenas os identificadores de enlace e números de versão
    - São enviados numa primeira fase
  - **Na segunda fase, apenas registros interessantes são pedidos ao vizinho**
    - Registros novos ou com número de versão maior

Recuperando Adjacências

Após a o envio dos descritores...

De D, para E, enlace 6, dist. = inf., n = 2

De B, para C, enlace 2, dist. = inf., n = 2
De C, para B, enlace 2, dist. = inf., n = 2
De E, para D, enlace 2, dist. = inf., n = 2

De	Para	Enl.	Dist.	No.
A	B	1	1	3
A	D	3	1	1
B	A	1	1	3
B	C	2	1	1
B	E	4	1	1
C	B	2	1	1
C	E	5	1	1
D	A	3	1	1
D	E	6	inf.	2
E	B	4	1	1
E	C	5	1	1
E	D	6	1	1

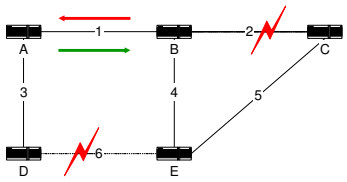

De	Para	Enl.	Dist.	No.
A	B	1	1	3
A	D	3	1	1
B	A	1	1	3
B	C	2	inf.	2
B	E	4	1	1
C	B	2	inf.	2
C	E	5	1	1
D	A	3	1	1
D	E	6	1	1
E	B	4	1	1
E	C	5	1	1
E	D	6	inf.	2

Recuperando Adjacências

Atualizações são propagadas

De D, para E, enlace 6, dist. = inf., n = 2

De B, para C, enlace 2, dist. = inf., n = 2
De C, para B, enlace 2, dist. = inf., n = 2
De E, para D, enlace 2, dist. = inf., n = 2

De	Para	Enl.	Dist.	No.
A	B	1	1	3
A	D	3	1	1
B	A	1	1	3
B	C	2	inf.	2
B	E	4	1	1
C	B	2	inf.	2
C	E	5	1	1
D	A	3	1	1
D	E	6	inf.	2
E	B	4	1	1
E	C	5	1	1
E	D	6	inf.	2

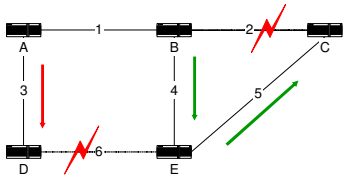

De	Para	Enl.	Dist.	No.
A	B	1	1	3
A	D	3	1	1
B	A	1	1	3
B	C	2	inf.	2
B	E	4	1	1
C	B	2	inf.	2
C	E	5	1	1
D	A	3	1	1
D	E	6	inf.	2
E	B	4	1	1
E	C	5	1	1
E	D	6	inf.	2

Mapas sincronizados

Proteção dos Mapas

- Sincronia das bases de dados
  - Fundamental para roteamento coerente
- Mas acidentes podem ocorrer
  - Falhas na inundação ou sincronização
  - Registros desatualizados
  - Erros de memória
  - Introdução voluntária de informação errônea

Proteção dos Mapas no OSPF

- A inundação inclui reconhecimentos salto-a-salto
- Os pacotes de descrição são transmitidos de maneira segura
- Cada registro de estado do enlace é associado a um temporizador e é retirado se não for devidamente atualizado
- Registros são protegidos por um checksum
- As mensagens podem ser autenticadas
  - Ex. senhas

Problema após falha de um nó

- Nó X desliga e religa após um curto intervalo
- X envia estado do enlace com no. de seq. = 1
- X recebe estados de enlace de nós vizinhos com no. de seq. maior
  - Mas na verdade, menos atuais
- Solução
  - X deve re-enviar os "seus" registros, com no. de seq. igual ao no. de seq. recebido + 1

Algoritmo Shortest Path First

- *Shortest Path First* (SPF) – Dijkstra
  - Cálculo do caminho mais curto entre um nó e todos os outros nós da rede
- Funcionamento
  - Rede
    - conjunto V contendo N nós, conjunto E contendo M enlaces
  - Separa os nós em 2 grupos
    - C – nós para os quais o caminho mais curto é conhecido
    - R – nós restantes
  - O – lista ordenada de caminhos
  - Nó fonte = S

Algoritmo Shortest Path First

1. C = {S}; R = V – {S}; O = {caminhos de 1 salto a partir de S}
   Os caminhos em O possuem custo igual à métrica do seu enlace.
   Ordenar os caminhos em O por ordem crescente de custos.

2. Se R={ }, O = { }, ou se o primeiro caminho de O possui custo inf.,
   marcar todos os nós em R como inalcançáveis. O algoritmo terminou.

3. Primeiro, examine P, o caminho mais curto em O. Remova P de O.
   Seja U o último nó em P. Se U já pertence a C, vá para o passo 2.
   Senão, P é o caminho mais curto de S para U. Mova U de R para C.

4. Construa um novo conjunto de caminhos candidatos através da
   concatenação de P e dos enlaces saindo de U.
   Insira os novos caminhos na lista O, mantendo sua ordenação.
   Vá para o passo 2.

Algoritmo Shortest Path First

- Complexidade
  - O(M.logM)
- Número de passos para convergir menor que Bellman-Ford (O(N.M))

Vantagens do Estado do Enlace

- Convergência rápida e livre de *loops*
- Suporte de métricas precisas, ou múltiplas métricas
- Suporte de múltiplos caminhos
- Representação separada de rotas externas

Convergência Rápida

- DV – Bellman-Ford
  - No. de passos proporcional ao número de nós
    - Igual ao número de saltos do mais longo caminho, no pior caso
- LS
  - Transmissão da atualização através de inundação
  - Cálculo de rotas realizado localmente (Dijkstra)
- LS mais rápido
  - Atualizações disparadas (DV) ~ inundação (LS)
    - No melhor caso, em que 1 DV de atualização é suficiente
    - Intervalo entre atualizações disparadas
      - 1 a 5s no RIP
  - Cálculo de rotas no LS
    - 200ms para rede com ~ 200 nós
  - Falha de enlace > vários destinos são “atingidos”
    - DV: tamanho de mensagem ~ número de destinos
- Livre de *loops*
  - Logo após inundação e cálculo de rotas

Múltiplas Métricas

- Cálculo do caminho mais curto
  - Conhecimento ***completo*** da topologia
  - Métrica podem ser arbitrariamente precisa
  - DV
    - Granularidade fina **+** grande diferença entre a menor e a maior métrica dos enlaces **=** risco de convergência ***muito*** lenta
- Várias métricas
  - Múltiplos estados do enlace
  - Cálculo de múltiplas tabelas de roteamento, uma para cada métrica
  - Indicação de que rota um determinado pacote deve seguir

Exemplo de Múltiplas Métricas

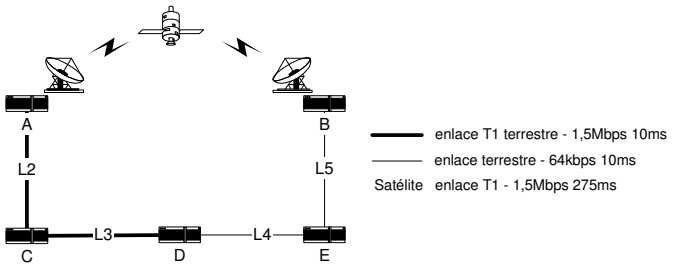

- D > C > A > B
  - Vazão de 1,5Mbps, atraso de 295ms (escolhido pela métrica vazão)
- D > E > B
  - Vazão de 64kbps, atraso de 20ms (escolhido pela métrica atraso)
- Escolha da métrica deve ser coerente
  - Risco de formação de *loops*

Suporte a Múltiplos Caminhos

- Balanceamento de tráfego
  - Diminui o atraso médio dos pacotes
    - A capacidade de transmissão é maior
  - Redução da variação de atraso
    - Correlação entre as chegadas de pacote em um dado caminho é menor
  - Após a falha de um caminho
    - Apenas uma parte do tráfego é re-roteada
      - Todo o tráfego é desviado se apenas uma rota é utilizada
  - Algoritmo SPF pode ser modificado
    - Múltiplos caminhos de mesmo custo
- Mas
  - Pode haver desordem de pacotes

Algoritmo SPF – Múltiplos Caminhos

1. C = {S}; R = V – {S}; O = {caminhos de 1 salto a partir de S}
   Os caminhos em O possuem custo igual à métrica do seu enlace.
   Ordenar os caminhos em O por ordem crescente de custos.

2. Se O = { }, ou se o primeiro caminho de O possui custo inf., marcar todos os nós em R como inalcançáveis. O algoritmo terminou.

3. Primeiro, examine P, o caminho mais curto em O. Remova P de O.
   Seja U o último nó em P. Se U já pertence a C, vá para o passo 4.
   Senão, P é o caminho mais curto de S para U. Mova U de R para C. Continue no passo 5.

4. Se a métrica do caminho P entre S e U é igual à distância previamente calculada entre S e U, foi encontrado um caminho de custo igual para U. Senão, ignorar P. Ir para o passo 2.

5. Construa um novo conjunto de caminhos candidatos através da concatenação de P e dos enlaces saindo de U.
   Insira os novos caminhos na lista O, mantendo sua ordenação. Vá para o passo 2.

Suporte a Múltiplos Caminhos

- OSPF
  - Roteamento por múltiplos caminhos de custo igual ("*equal cost multi-path*")
  - Pode haver desordem de pacotes
    - Potencialmente prejudicial para o TCP
  - Roteadores devem dividir os fluxos TCP entre as rotas
    - Exemplo
    - *Hash code* calculado a partir dos endereços fonte e destino e do número de porta de transporte
    - hash(pacote) > H1, caminho 1
    - hash(pacote) < H1, caminho 2
- De forma mais geral, a carga pode ser usada como métrica
  - Deve-se tomar cuidado com a realimentação de informação

Rotas Externas

- Cenário: Rota de saída da rede é ***única***
  - Anúncio de rota *default* (DV e LS)
- Cenário: ***Múltiplas*** rotas de saída
  - Anúncio de rota *default*
    - DV: caminho mais curto para a saída é o utilizado
  - Anúncio de rotas específicas
    - DV: mais entradas nos vetores de distância
    - LS: estados de enlace especiais
- Comparação
  - LS: *gateway* anuncia a métrica que convier ao enlace de saída
  - DV: métrica limitada pelo valor de infinito
  - Número de rotas externas
    - LS: tamanho da base de dados
    - DV: tamanho dos vetores de distância
  - ***Mas*** custo SPF = O(N.logN), custo Bellman-Ford = $O(N^2)$

O Projeto do OSPF

- OSPF
  - Toda a funcionalidade de protocolos de estado do enlace (LS)
    - Base de dados distribuída
    - Procedimento de inundação
    - Descoberta de adjacências
    - Registros especiais para rotas externas
  - Mais
    - Separação entre estações e roteadores
    - Suporte de redes *broadcast* (Ethernet, Token Ring, FDDI)
    - Suporte de redes não-*broadcast* (X.25, ATM)
    - Divisão de redes muito grandes em áreas (roteamento hierárquico)

Separação de Estações e Roteadores

- Numa rede local, um estado de enlace por estação
  - não escalável
- OSPF
  - Estados de enlace
  - Enlace de roteador (*router link*)
    - Conexão entre roteadores
    - Endereço IP do vizinho
  - Enlace para rede stub (*link to a stub network*)
    - Conexão a uma rede local
    - Número de rede ou de sub-rede

Redes *Broadcast*

- Conectividade total
  - Todas as estações podem se falar diretamente
- Capacidade de difusão (nativa)
  - *broadcast* – todas as estações recebem
  - *multicast* – um grupo de estações recebe
- Problema: adjacências

  - Dados **N** roteadores, **N.(N-1) / 2** adjacências

Redes *Broadcast*

- Cada roteador anuncia
  - N-1 estados de enlace (enlaces para os outros roteadores)
  - 1 estado para as estações na rede (*stub network link*)
- Total = N^2 mensagens
- Redução do número de adjacências
  - Um roteador é escolhido como roteador "designado"
  - Outros roteadores na rede local estabelecem adjacências apenas com este roteador

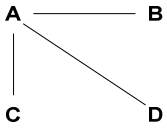

Redes *Broadcast*

- Funcionamento
  - Primeiro passo
    - Eleição do roteador designado
  - Segundo passo
    - Outros roteadores recuperam adjacência com o roteador designado (ou se sincronizam com ele)
  - Se todos se sincronizam com **A**, todos estão sincronizados
    - N adjacências em vez de N.(N-1) / 2
- Além disso, o número de estados do enlace é reduzido
  - Roteador virtual (**X**)

  representa a rede broadcast

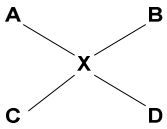

Redes *Broadcast*

- Base de dados
  - 2 enlaces por roteador
    - ***para*** e ***do*** nó virtual, X

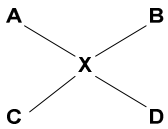

- Anúncios
  - roteador para X – pelo *próprio roteador*
  - X para roteador – *pelo roteador designado*
    - Endereço IP do roteador designado ***na rede broadcast***
    - "Enlaces de rede" (*network links*)
      - Métrica nula para não causar problemas de cálculo de rotas
- Procedimento de inundação

Redes *Broadcast*

- Inundação
  - Envio de LSA (*link state advertisement*)
    - Apenas para o roteador designado
      - "all-designated-routers" – 224.0.0.6
  - Se o LSA é novo, o roteador designado
    - Re-envia em todas suas interfaces
    - E na rede broadcast
      - "all-OSPF-routers" – 224.0.0.5
- Problema
  - Roteador designado – ponto de falha
- Roteador designado de *backup*
  - Roteadores mantêm adjacências com o designado e o backup
  - O backup escuta os anúncios, silenciosamente
    - Falha do roteador designado detectada pelo protocolo *Hello*

Redes Não-*broadcast*

- Circuitos virtuais (X.25, frame-relay, ATM)
- Conectividade total
  - Todas as estações podem se falar diretamente
- ***Não*** há difusão nativa

- Primeira solução
  - Conjunto de circuitos virtuais configurados estaticamente
    - **N.(N-1) / 2** circuitos
    - Informação de roteamento inundada em todos os circuitos
      - Custo alto, considerando tarificação por volume de tráfego
- Segunda solução
  - Redução do número de circuitos virtuais
    - Pode fazer com que o tráfego passe várias vezes pela rede paga

Redes Não-*broadcast*

- OSPF - Solução semelhante às redes *broadcast*
  - Roteador designado + roteador *backup*
    - Informação de roteamento trocada apenas com estes roteadores
  - Circuitos virtuais podem ser estabelecidos entre qualquer par de roteadores, porém ***sob-demanda***
  - Apenas os circuitos entre "roteador comum" e roteador designado (e *backup*) são utilizados permanentemente
- Diferença: pacotes enviados ponto-a-ponto
  - Anúncio enviado pelo roteador designado
    - Várias mensagens ponto-a-ponto
  - Anúncio enviado por um "roteador comum"
    - Mensagem para o roteador designado + mensagem para o *backup*

Áreas Múltiplas

- Roteamento hierárquico
  - Divisão da rede em diferentes partes conectadas por uma espinha dorsal
  - OSPF: áreas conectadas através da área *backbone*
- Cada área se comporta como uma rede independente
  - Base de dados de estados do enlace
  - Inundação termina nas fronteiras da área
  - Roteadores calculam rotas dentro da área
- Custo proporcional ao tamanho da área, não da rede

Conexão das Áreas Múltiplas

- Roteadores de borda de área (*area-border routers*)
  - Pertencem a várias áreas
    - Tipicamente, área de baixo nível + área *backbone*
  - Mantêm várias bases de dados, uma para cada área à qual pertencem
  - Cada área deve ter pelo menos um roteador de borda de área, conectando-a ao *backbone*
  - Anunciam "enlaces de sumário" (*summary links*)
    - Descrevem rotas internas
- Roteadores de borda (*border routers*)
  - Anunciam "enlaces externos" (*external links*)
    - Descrevem rotas externas

GTA/UFRJ

Exemplo de Áreas Múltiplas

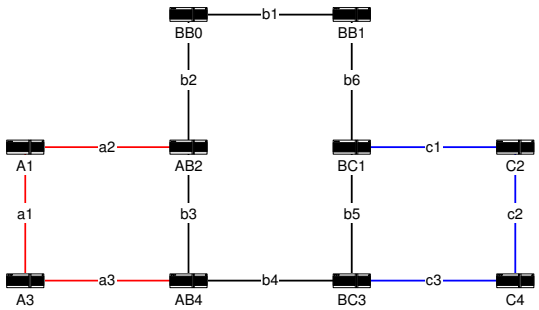

- Área A: roteadores A1, AB2, AB4 e A3; enlaces a1, a2 e a3
- Área C: roteadores C2, C4, BC3 e BC1; enlaces c1, c2 e c3
- Área B: (*backbone*): roteadores de borda BB0 e BB1, roteadores de borda de área AB2, AB4, BC3 e BC1; enlaces b1, b2, b3, b4, b5 e b6

GTA/UFRJ

Exemplo de Áreas Múltiplas

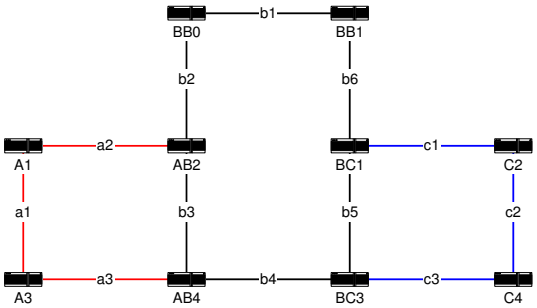

- Base de dados Área A:
  - Estados de enlace para a1, a2 e a3, enviados por A1, AB2, AB4 e A3
  - Registros ***sumário*** emitidos por AB2 e AB4, descrevendo redes e sub-redes da área *backbone* e da **área C**
  - Registros ***externos*** emitidos por BB0 e BB1, e retransmitidos por AB2 e AB4

Registros Sumário

- Registros sumário
  - Representam "enlaces" entre um roteador de borda de área e uma rede na área *backbone*, ou outra área
  - Métrica igual à distância entre o roteador e a rede
  - Propagação semelhante a vetores distância, mas sem riscos de loops, devido à hierarquia estrita
    - Áreas são conectadas apenas através da área *backbone*
  - Exemplo
  - b1: rede Ethernet identificada pelo número de sub-rede nb1

Exemplo de Áreas Múltiplas

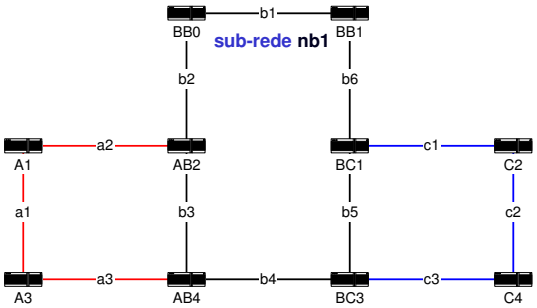

- AB2 anuncia enlace sumário para nb1 com métrica = b1 + b2
- AB4 anuncia enlace sumário para nb1 com métrica = b1 + b2 + b3

GTA/UFRJ

Exemplo de Áreas Múltiplas

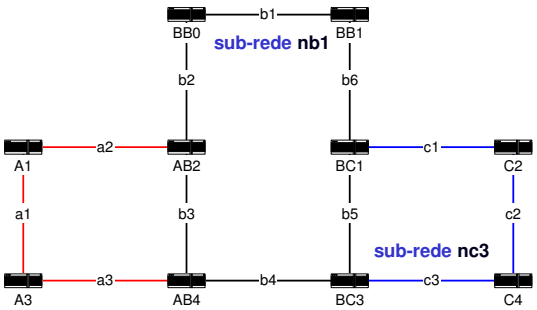

- BC3 anuncia enlace sumário para nc3 com métrica = c3
- BC1 anuncia enlace sumário para nc3 com métrica = c1 + c2 + c3
- AB4 e AB2 calculam o caminho mais curto para nc3 através de BC3
- AB4 anuncia na área A enlace sumário para nc3 com métrica = c3 + b4
- AB2 anuncia na área A enlace sumário para nc3 com m. = c3 + b4 + b3

GTA/UFRJ

Rotas Externas

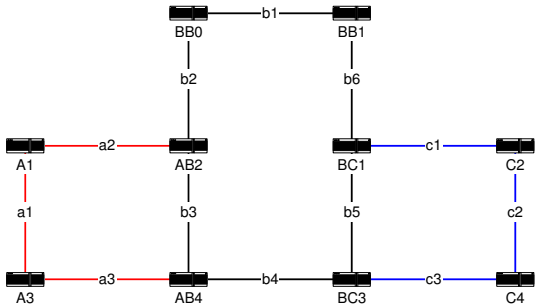

- Registros externos, gerados por BB0 e BB1, são copiados inalterados na base de dados da área A (e C)
- Registros de sumário enviados por AB2 e AB4 dizem como chegar a cada roteador na área de *backbone*
  - Portanto, rotas externas passando por BB0 e BB1 podem ser calculadas precisamente

Área Particionada

- Não há, *a priori*, como diferenciar destinos dentro de uma área
  - Como evitar o envio de pacotes para A3 através de AB2?

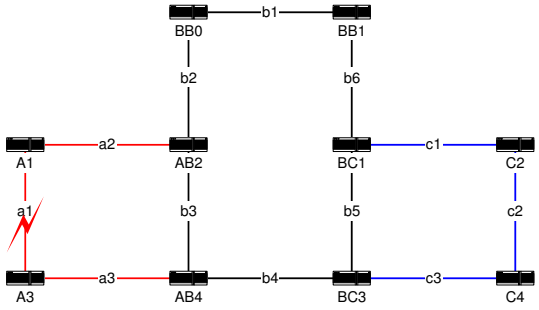

- Roteadores de borda de área enviam registros sumário apenas para redes e sub-redes ***alcançáveis***, em vez de para todas as redes e sub-redes da área
- Entradas na área *backbone* são tão precisas *quanto necessário*

Área *Backbone* Particionada

- Não há conectividade através de enlaces do *backbone*, apenas
  - Poderia ser restaurada através da área C

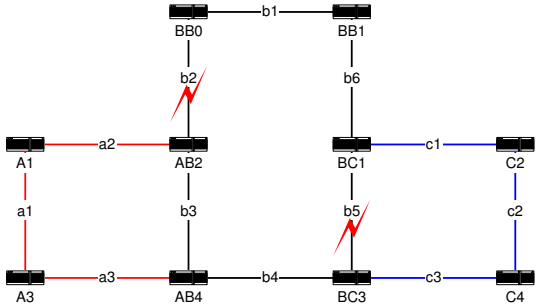

- Solução: enlace virtual entre BC1 e BC3
  - Atualizações da base de dados do *backbone* trocados através da rede **C**
  - Descrição do enlace virtual na base de dados
    - Métrica: c1 + c2 + c3

Áreas Stub

- Geralmente, os registros mais numerosos na base de dados de estados de enlace correspondem às rotas externas
  - ~60.000 em 1999
- Algumas *pequenas* áreas são conectadas por apenas um roteador de borda de área ao *backbone*
- OSPFv2
  - Área *stub* (*stub area*)
    - Todas as rotas externas são resumidas por uma rota *default*
  - A área pode ter mais de um roteador de borda de área, ***mas***
    - Não há como escolher o roteador de saída de acordo com o destino
    - Não há como configurar enlaces virtuais passando por uma área *stub*

Base de Dados de Estados do Enlace

- Composta de *registros de estado do enlace*
  - *Link State (LS) records*

- Tipos de LS
  - Enlace de roteador (tipo 1)
  - Enlace de rede (tipo 2)
  - Enlace sumário (de rede IP) (tipo 3)
  - Enlace sumário (para um roteador de borda) (tipo 4)
  - Enlace externo (tipo 5)

Cabeçalho de Estado do Enlace

- Comum a todos tipos de registro de estado do enlace

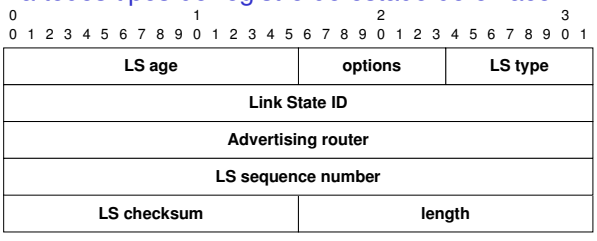

- Advertising router – um dos endereços IP do roteador (identificador OSPF)
- Age – tempo em segundos desde o primeiro anúncio deste LS
- Option
  - E – enlace externo (utilizado pelo prot. Hello)
  - T – indica se o roteador suporta roteamento por TOS

Cabeçalho de Estado do Enlace

- Link State ID – identificação do enlace
  - geralmente, endereço IP (depende do tipo de enlace)
  - (link state ID, advertising router, LS type) devem identificar unicamente o registro
- Checksum – calculado como no cabeçalho IP
  - Sobre cabeçalho + conteúdo
- Length – comprimento total do registro
- LS sequence number
  - N = 2^{31} (usados negativos)
  - Números variam entre 1 - N e N - 2; - N e N -1 não utilizados

Cabeçalho de Estado do Enlace

- Roteador é ligado
  - Começa de 1 – N e incrementa o número
  - Em N - 2, próximo número = 0 (N – 1 não usado)
  - Números agora em seqüência cíclica na parte positiva
- Comparação
  - Um número negativo – comparação direta
  - Ambos positivo ou nulo – comparação cíclica
    - **a** e **b**, com **a** menor que **b**
    - Se **(b - a) < (N - 1) / 2**
      - **b** mais recente que **a**
      - Senão, **a** mais recente que **b**
  - Problema se um roteador re-inicia várias vezes em seqüência

Enlace de Roteador

- O "registro de estado de enlace de roteador" lista todos os enlaces que saem do roteador

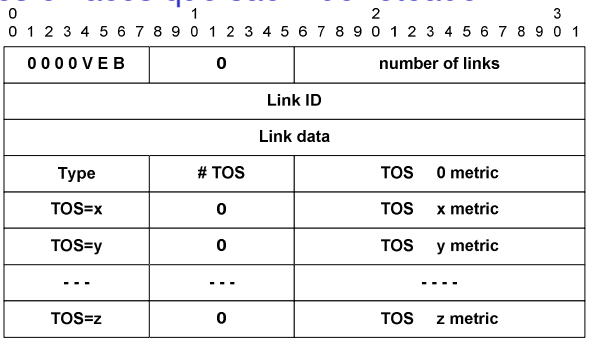

0 0 0 0 V E B	0	number of links
Link ID		
Link data		
Type	# TOS	TOS 0 metric
TOS=x	0	TOS x metric
TOS=y	0	TOS y metric
- - -	- - -	- - - -
TOS=z	0	TOS z metric

- Link ID – identificador OSPF do roteador
- E = 1 – roteador de borda de área
- B = 1 – roteador de borda
- V = 1 – roteador é ponta de enlace virtual passando pela área

Enlace de Roteador

- Type (tipo do enlace)
  - = 1 – enlace ponto-a-ponto
    - Link ID = identificador OSPF
    - Link data = endereço IP desta interface do roteador
  - = 2 – conexão a uma rede de trânsito
    - Link ID = endereço IP da interface do roteador designado
    - Link data = endereço IP desta interface do roteador
  - = 3 – conexão a uma rede stub
    - Link ID = número da rede ou sub-rede IP
    - Link data = máscara de rede ou sub-rede correspondente
- #TOS – número de tipos de serviço anunciados
  - TOS 0 obrigatório
  - TOS = x – número do tipo de serviço

Enlace de Rede

- Enviados por *roteadores designados* para redes de trânsito
- Link state ID = endereço IP da interface nesta rede

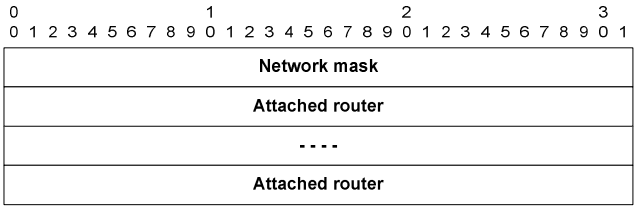

- Máscara de rede ou sub-rede IP
- Identificador OSPF de todos os roteadores conectados à rede (que possuem adjacência com o roteador designado)

Enlace de Sumário

- Enlaces de sumário *para redes IP (tipo 3)* e para *roteadores de borda (tipo 4)* são enviados por ***roteadores de borda de área***
- Um anúncio separado para cada destino
- Link State ID
  - Número de rede ou sub-rede IP (tipo 3)
  - Endereço IP do roteador (tipo 4)
- Máscara
  - da rede ou sub-rede (tipo 3)
  - 0xFFFFFFFF se roteador de borda (tipo 4)
- Métricas
  - Similar ao "enlace de roteador"
  - Número de TOS não é necessário (deduzido do tamanho)

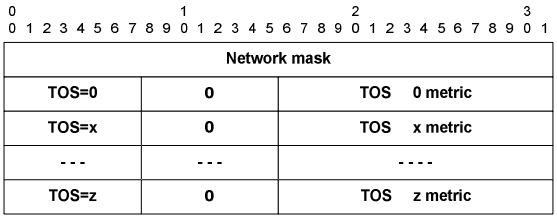

Enlace Externo

- Enlaces Externos são anunciados por ***roteadores de borda***
- Link State ID
  - Número de rede ou sub-rede IP do destino

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		
Network mask		
E,TOS=0	0	TOS 0 metric
External route tag (0)		
E,TOS=x	0	TOS x metric
External route tag (x)		
---	---	----
TOS=z	0	TOS z metric
External route tag (z)		

- Campos TOS
  - E=1 – a métrica anunciada para este TOS não é compatível com a métrica usada internamente
  - E=0 – ok, comparação entre métrica interna e externa é válida
- External route tag
  - Utilizada pelos roteadores de borda, não é examinada pelo OSPF

GTA/UFRJ

Cálculo de Rotas e TOS

Código OSPF	Valor de TOS (RFC 1349)
0	0000 serviço normal
2	0001 minimizar custo financeiro
4	0010 maximizar confiabilidade
8	0100 maximizar vazão
16	1000 minimizar atraso

- Pacote roteado segundo as rotas para o TOS correspondente, mas
  - Roteadores não são obrigados a anunciar métricas para todo TOS
    - Se TOS≠0, sem métrica, é tomada a métrica do TOS 0
  - Roteadores que não suportam TOS o informam no cabeçalho do LS
    - Rotas calculadas para TOS ≠ 0 ***sem*** estes roteadores
    - Se destino inalcançável, rota para TOS 0 é usada
- Métricas
  - Número inteiro
  - Quanto menor melhor

GTA/UFRJ

Cálculo de Rotas e TOS

- Banda passante
  - 10^8 / capacidade(bps) – número de segundos para transmitir 10^8 bits
  - Métrica = 1 para 100Mbps ou mais [RFC1850 – OSPF MIB]
  - 1 também é o valor *default* desta métrica
- Atraso, confiabilidade e custo não definidos
  - Administrador pode configurá-los
  - Regra geral: usar a métrica *default*, aumentar a métrica para enlaces "especiais"
    - Atraso: enlaces de satélite, alto tempo de propagação
    - Custo: enlaces pagos por volume de tráfego
    - Confiabilidade: enlaces de rádio

Cálculo de Rotas: Outras Métricas

- Seja caminho C contendo os enlaces l_1, l_2, e l_3
- Probabilidade de perda
  - $p(C) = 1 - ((1 - p(l_1)) * (1 - p(l_2)) * (1 - p(l_3)))$
- Probabilidade de sucesso
  - $s(C) = s(l_1) * s(l_2) * s(l_3)$
  - $\log(s(C)) = \log(s(l_1)) + \log(s(l_2)) + \log(s(l_3))$
  - Obs.: $0 \leq s(l) \leq 1 \rightarrow -\infty \leq log(s(l)) \leq 0$
  - $|\log(s(C))| = |\log(s(l_1))| + |\log(s(l_2))| + |\log(s(l_3))|$
  - (Pode-se utilizar Dijkstra)

Os Protocolos dentro do OSPF

- OSPF
  - Executado sobre o IP
    - Tipo de protocolo = 89
  - Sub-protocolos
    - **Protocolo Hello**
      - Alcançabilidade de vizinhos
      - Eleição do roteador designado
    - **Protocolo de Troca (*Exchange*)**
      - Sincronização inicial da base de dados de estados do enlace
    - **Protocolo de Inundação (*Flooding*)**
      - Atualização da base de dados de estados do enlace
      - Sincronização da idade dos registros

Cabeçalho Comum dos Pacotes OSPF

- Version # - 2
- Type – tipo de pacote OSPF
- Length – comprimento
- Router ID
  - identificador OSPF (endereço IP)

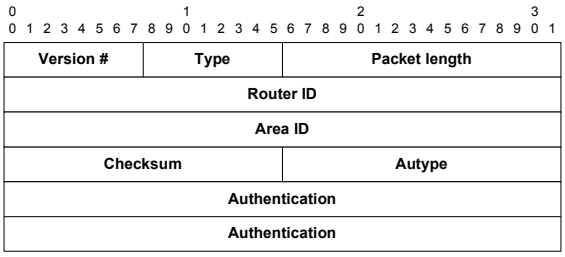

- Area ID
  - 0 – área backbone
  - Utiliza-se na prática o número de rede como Area ID
- Checksum
  - Como no IP, sobre todo o pacote *menos* os 8 bytes de autenticação
- Autype
  - 0 – sem autenticação
  - 1 – autenticação simples
  - 2 – autenticação criptográfica

Autenticação Criptográfica

- Campo de autenticação redefinido

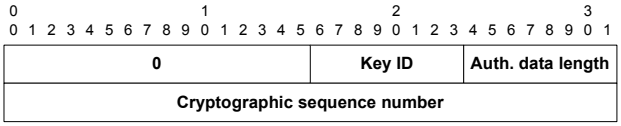

- Key-ID
  - identifica a senha secreta (chave) e algoritmo (MD5)
- Auth Data Len
  - comprimento dados de autenticação
- MD5 digest (16 bytes)
  - calculado sobre o pacote OSPF, chave secreta, campos de enchimento e comprimento
  - concatenado no fim do pacote (trailer)
    - tamanho não conta no tamanho do pacote

Autenticação Criptográfica

- Na recepção, verificação através da utilização da mesma chave secreta
- Número de seqüência (Cryptographic sequence number)
  - Proteção contra *replay attacks*
  - Roteador rejeita mensagem com número de seqüência não superior ao recebido anteriormente para mesmo KeyID
- A cada chave são associadas 4 constantes de tempo, em que o roteador
  - começa a receber mensagens com esta chave
  - começa a enviar mensagens com esta chave
  - pára de enviar mensagens com esta chave
  - pára de aceitar mensagens com esta chave

O Protocolo Hello

- Objetivos
  - Checar que enlaces estão operacionais
  - Eleger os roteadores designado e designado de backup, em redes *broadcast* e *não-broadcast*

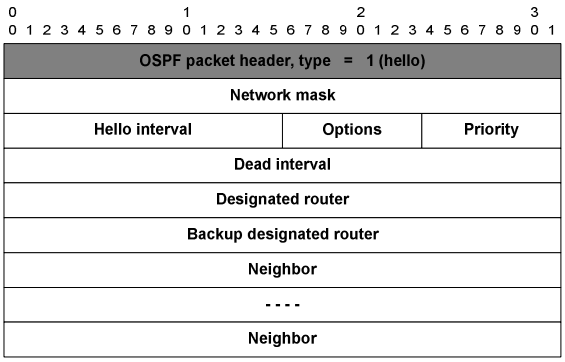

O Protocolo Hello

- Network mask
  - Se não houver, máscara correspondente à rede (A, B ou C)
- Hello interval
  - Intervalo entre as mensagens, em segundos
- Designated router
  - Endereço do roteador designado, ou zero se não definido
- Backup designated router
  - Endereço do roteador *backup* designado, ou zero se não definido
- Neighbor (n vezes)
  - Lista dos vizinhos dos quais foi ouvido um *hello*, nos últimos *dead interval* segundos
- Intervalos hello e dead
  - Parâmetros do enlace, configurados pelo administrador

Conectividade

- Options
  - T = 1 – roteador é capaz de roteamento por TOS
  - E = 1 – roteador é capaz de enviar e receber rotas externas
    (E = 0 – roteador conectado à área *stub*)
- Enlace operacional se
  - Dados podem fluir nas duas direções
  - Roteadores de acordo com valor do bit E
- Conectividade bi-direcional
  - Roteador presente na lista de vizinhos anunciada pelo roteador remoto
  - Se não, conectividade uni-direcional (por enquanto)
    - O enlace não deve ser utilizado para o roteamento
- Dead interval
  - Não é a única forma de reconhecer morte do vizinho
  - Notificação da camada inferior pode ser utilizada

Eleição do Roteador Designado

- Procedimento usa campo priority do pacote Hello
  - Prioridade de cada roteador vai de 0 a 255
  - Roteador com maior prioridade é selecionado, ***mas***
    - Quando roteador designado cai, outro roteador é selecionado
    - Quando o primeiro é re-ligado, não retoma o papel de designado imediatamente
      - Limita-se a freqüência de mudança do roteador designado
  - Prioridade = 0 - roteador ***não*** é selecionado como designado
- Quando roteador é ligado
  - Estado de espera (durante *dead interval*)
    - Envio de pacotes *hello*; designado = 0, backup = 0
    - Não se candidata
  - Ouve pacotes *hello*
    - Para cada vizinho, armazenar
      - Prioridade
      - Estado da conectividade
      - Se é candidato a designado ou backup

Eleição do Roteador Designado

- Eleição
  1. Se um ou vários vizinhos se propuseram como roteador de backup, o de maior prioridade é selecionado roteador de backup (roteadores que se propuseram designado não são elegíveis backup)
  2. Se nenhum vizinho se propôs como backup, o vizinho com a maior prioridade é selecionado
  3. Se um ou vários vizinhos se propuseram como roteador designado, o de maior prioridade é selecionado roteador designado.
  4. Se nenhum vizinho se propôs como roteador designado, o roteador de backup se torna o designado
- Algoritmo executado permanentemente
  - Passo 2 é executado apenas ao fim do período de espera
  - Após mudança de vizinho, eleição e construção de adjacências
- Endereços de envio
  - *Configurados* em redes não-broadcast

O Protocolo de Troca (*Exchange*)

- Objetivo
  - Sincronização inicial da base de dados
    - Após estabelecimento de conectividade
      - Com vizinho no enlace ponto-a-ponto
      - Com roteador designado senão
  - Após a sincronização inicial, protocolo de inundação
- Protocolo Assimétrico
  - Passo 1: escolha do mestre e escravo
  - Passo 2: troca da descrição das bases de dados
  - Passo 3: listagem dos registros a serem pedidos
- Utiliza pacotes de descrição da base de dados OSPF

Funcionamento do Protocolo de Troca

- Funcionamento
  - Roteador que inicia o procedimento
    - Envia pacote com I=1, M=1, MS=1
    - Núm. de Seq. DD = número inédito no outro roteador
  - Vizinho concorda em ser escravo
    - Envio de pacote I=1, M=1, MS=0
- Problemas
  - Perdas
    - Reconhecida por *timeout*, resolvidas pelo re-envio do pacote
  - Colisões
    - Roteador recebe pedido de *mestre*, enquanto estava esperando resposta ao ***próprio*** pedido de *mestre*
    - O *mestre* é o roteador de maior endereço IP

Funcionamento do Protocolo de Troca

- Descrição da base de dados é transmitida pelo *mestre*
  - I=0, MS=1, M=1 para todos os pacotes, exceto o último que possui M=0
  - Cada pacote provoca o envio de um reconhecimento
    - Mesmo núm. de seq. DD, MS=0
    - Descrição do registro na base de dados do escravo
- Proteção contra perdas de reconhecimentos
  - Se o mestre não recebe ***ack*** em **x** segundos, re-envio da descrição
  - Escravo deve re-enviar ***ack*** para mesmo núm. de seq. DD
- Critério de parada
  - Quando mestre terminou, pacote com M=0
  - Se escravo ainda possui registros a transmitir
    - ***Ack*** enviado com M=1
    - Mestre envia pacotes com descrição vazia até ack enviado com M=0

Funcionamento do Protocolo de Troca

- Processamento das descrições de pacotes
  1. Checar registro com mesmo (tipo, advertising router, LS ID)
  2. Registro com núm. de seq. maior ou igual
     - Se 1 ou 2 falso, registro vai para a lista dos registros ***a pedir***
- Ao fim da troca de descrições, envio de pedidos

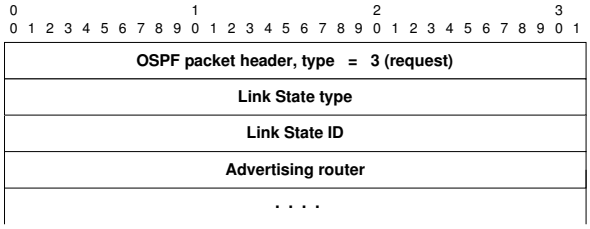

- Pacotes contém listas de identificadores de registros LS
- Quando registro recebido, é retirado da lista ***a pedir***

Problemas no Protocolo de Troca

- Conectividade bi-direcional deixa de existir
- Pacotes de descrição fora de seqüência ou com bits I ou M inconsistentes
- Pedido de um registro que não existe na base de dados
- Em todos os casos, o procedimento de troca é re-iniciado, desde a escolha do mestre e escravo

Protocolo de Inundação

- Atualizações de Estado do Enlace

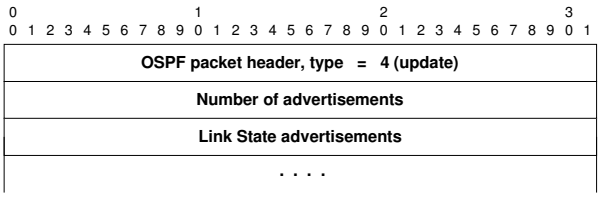

- Cabeçalho OSPF + núm. de anúncios + anúncios LS
- Recepção
  - Se “nova” atualização, re-envio nas outras interfaces de saída
  - Em todo caso, envio de pacote de reconhecimento

Protocolo de Inundação

- Reconhecimento

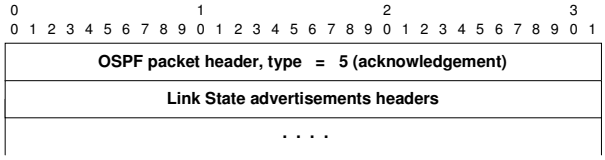

- Pode reconhecer vários LSs, portanto
  - Envio não é imediato
  - Nem tão longo, que cause retransmissão
- Redes broadcast
  - LSs de vários vizinhos podem ser reconhecidos no mesmo pacote
  - Reconhecimento enviado a “all-OSPF-routers”
- Anúncios duplicados devem ser reconhecidos imediatamente
- Com roteador designado
  - Reconhecimento desnecessário, re-envio do update cumpre esta tarefa

Controle da Idade dos Registros

- Remoção de LSs desatualizados deve ser sincronizada
- Mecanismo de envelhecimento (*aging*)
  - Idade = 0 no envio do registro
  - Idade++ a cada re-envio
  - Idade++ a cada segundo, daí por diante
  - Se Idade = IdadeMax (1 hora)
    - Registro não utilizado para cálculo de rotas
    - Remoção condicionada ao aviso aos vizinhos

Controle da Idade dos Registros

- Recepção de anúncio duplicado
  - Se idade recebida = IdadeMax
    - Aceito (e será eventualmente apagado) e Re-enviado
  - Se pequena diferença (maioria dos casos)
    - Ignorado e Não re-enviado
      - (conseqüência do envio por diferentes caminhos)
  - Grande diferença (> 15min., casos raros)
    - Registro mais recente é guardado
    - Pode acontecer com um roteador que rebootou e utilizou o mesmo número de seqüência
- Registros têm a idade re-iniciada periodicamente (ao serem re-enviados)
  - ~30 min., pelo menos

Balanceamento de Carga

- Estado de Enlace Opaco (*opaque LS record* [RFC2370])
  - pode ser enviado a todos os nós, mesmo os que não o entendem

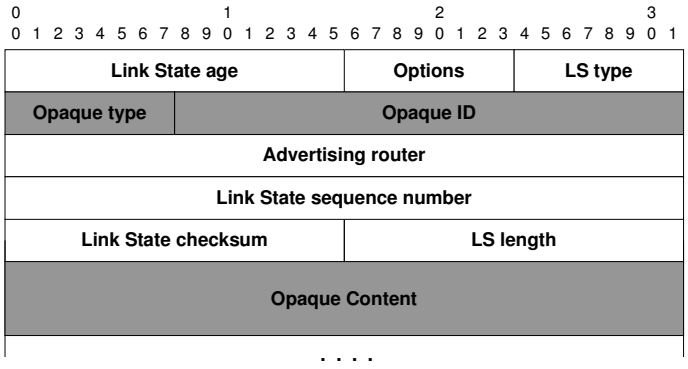

LSA Opaco

- LS Type
  - 9 – inunda apenas um enlace
  - 10 – inunda apenas a área OSPF
  - 11 – inunda toda a rede OSPF
- 32-bit Link State ID
  - Opaque Type
    - 0 – 127 – tipos globais, definidos pelo IANA
    - 128 – 255 – Uso Experimental
  - Opaque ID
    - Identificador escolhido pelo roteador anunciante

Optimized Multi Path

- Proposta de Curtis Villamizar
- Objetivo
  - Direcionar mais tráfego para o enlace menos carregado
- Utiliza LSA opaco de tipo 10 (LS Type = 10)
  - inunda a área OSPF
- Cada “LSA de carga do enlace” é paralelo a um estado do enlace comum (LS Type = 1..5)
  - Utiliza-se também “LSA de carga do ***caminho***”

LSA Opaco de Carga do Enlace

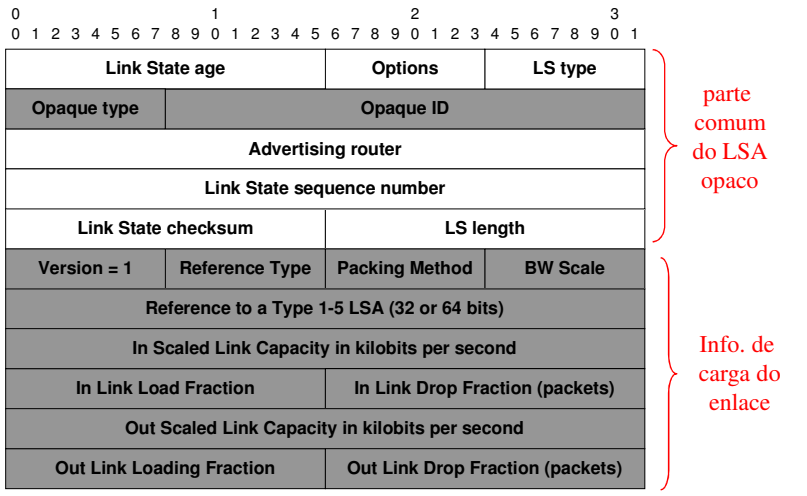

LSA Opaco de Carga do Enlace

- Opaque Type
  - Carga do enlace (Link load)
  - Carga do Caminho (Path load)
- Reference Type
  - Tipo do LS original (1 a 5)
- Reference to a Type 1-5 LSA
  - Identificador do LS original (Link State ID)

Parâmetros do OMP

- Parâmetros para cada enlace, em cada direção

1. Capacidade escalada (32 bits)
   - Capacidade do enlace em kbps (4 Terabits/s no máximo)
   - BW Scale - fator multiplicador da capacidade
     - C = capacidade * $2^{BWScale}$
2. Fração de Carga (16 bits)
   - Carga observada no enlace
   - Packing method – mecanismo de codificação
     - Atualmente = (tráfego observado / capacidade do enlace)
3. Fração de perdas do enlace (16 bits)
   - Taxa de perdas de pacotes do enlace

Algoritmo OMP

1. Algoritmo SPF – cálculo dos caminhos para os destinos a partir dos vizinhos do roteador.
2. Calcular um conjunto de caminhos candidatos a partir dos enlaces locais e dos caminhos a partir dos vizinhos.
3. Guardar os *caminhos de custo mínimo*, ou *dentro de margem de custo aceitável*.

   Para evitar loops, caminhos não minimais são guardados apenas se não contêm enlaces virtuais, e se o roteador vizinho está mais próximo do destino que o roteador de origem.

Algoritmo OMP

- Conjunto inicial de caminhos
  - Tráfego distribuído de acordo com técnica *hash* sobre o cabeçalho dos pacotes
- Roteadores monitoram o tráfego e enviam informação quando a carga varia
- Intervalo de inundação
  - ~20 min. em baixa carga
  - 30~60s em situações de carga alta e variável
- Balanceamento reavaliado
  - nova informação de tráfego foi recebida
  - a cada 30s em alta carga, ou 5 min. em baixa carga
- A idéia é convergir, lentamente, para o melhor balanceamento de carga

Algoritmo OMP

- Após mudança de topologia
  - Cálculo de novo conjunto de caminhos inicial

1. Se houve caminho removido, a carga é dividida entre os caminhos restantes
2. Novos caminhos não recebem carga.
   Sua parcela de carga aumenta gradualmente após cada intervalo de cálculo de carga. (Novos caminhos são "suspeitos": podem conter enlaces instáveis.)
3. Se todos os caminhos foram substituídos por novos caminhos, distribuir a carga entre estes.

OSPF x RIP

- RIP
  - Vetores de distância
  - 2 mensagens de controle
  - DVs enviados a cada 30s
  - Tabela de roteamento
- OSPF
  - Estados do enlace
  - 5 mensagens de controle e 3 "sub-protocolos"
  - LSAs com reconhecimentos
  - Tabela de roteamento + tabela de estados do enlace
- OSPF é mais complexo, porém mais eficiente que o RIP
  - "O OSPF calcula melhores rotas com menos mensagens"