Redes de Computadores

Encaminhamento pelo Caminho mais Curto

(1) *Link State Routing*

Departamento de Informática da
FCT/UNL

Objetivos do Capítulo

- O encaminhamento numa rede de computadores tem de resolver o problema de determinar o caminho que um pacote deve seguir desde o computador de origem até ao destino
- Numa rede em que existem vários caminhos possíveis existem muitas alternativas
- Neste capítulo vamos conhecer soluções denominadas Encaminhamento pelo Caminho Mais Curto
- Nesta parte do capítulo vamos conhecer uma solução baseada num algoritmo de teoria dos grafos

Make everything as simple as possible, but not simpler.

– Autor: ***Albert Einstein (1879-1955)***

O Problema Geral do Encaminhamento

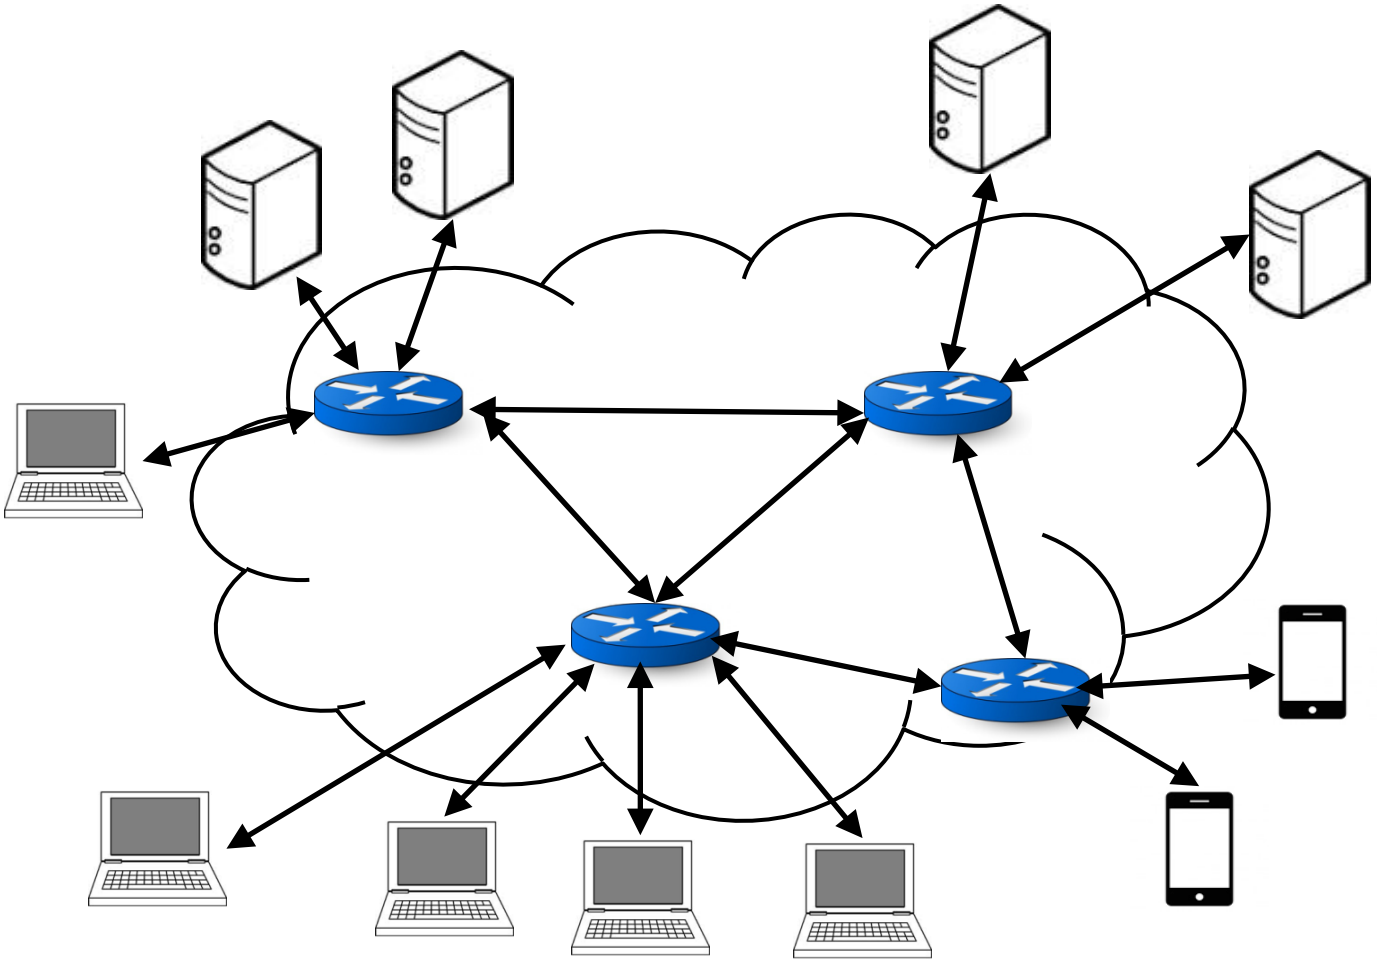

Consiste em escolher um caminho ótimo para os pacotes entre a origem e o destino, que pode ser o mais "direto", mas nem sempre, dependendo da carga da competição pelo mesmo.

Formulação do Problema do Encaminhamento

- Uma rede pode ser modelizada por um grafo, isto é, por um conjunto de nós e um conjunto de arcos, os canais, que interligam os nós
- O problema do encaminhamento é o seguinte: dados quaisquer dois nós X e Y que caminho deve seguir cada pacote com origem em X e destino Y?
- Se existe mais do que um caminho possível, qual deles escolher?
  - Um grafo em que entre quaisquer dois nós X e Y só existe um caminho único é uma árvore
  - No caso geral o grafo tem a configuração de uma malha e disponibiliza caminhos alternativos

O Problema e uma Solução Possível

- O problema do encaminhamento numa rede de comutação de pacotes é um problema fundamental das redes de computadores que envolve facetas de modelização e otimização, algorítmicas, de engenharia para sua concretização, operacionais, e de planeamento e gestão.

- Uma primeira solução de compromisso relativamente comum consiste em usar encaminhamento pelo caminho mais curto. **Esta solução é aceitável quando os caminhos mais curtos estão bem dimensionados para o tráfego existente.**

Modelização de Redes com Grafos

- Os nós do grafo são os equipamentos de comutação de pacotes da rede, os nós de comutação, os arcos são os canais
- Custo de um canal é um valor positivo que permite comparar arcos e caminhos
- A função que a cada canal associa um custo é designada por métrica do encaminhamento
- Os canais dizem-se simétricos se o custo é independente da direção do tráfego, o que é uma situação comum

Modelização de Redes com Grafos

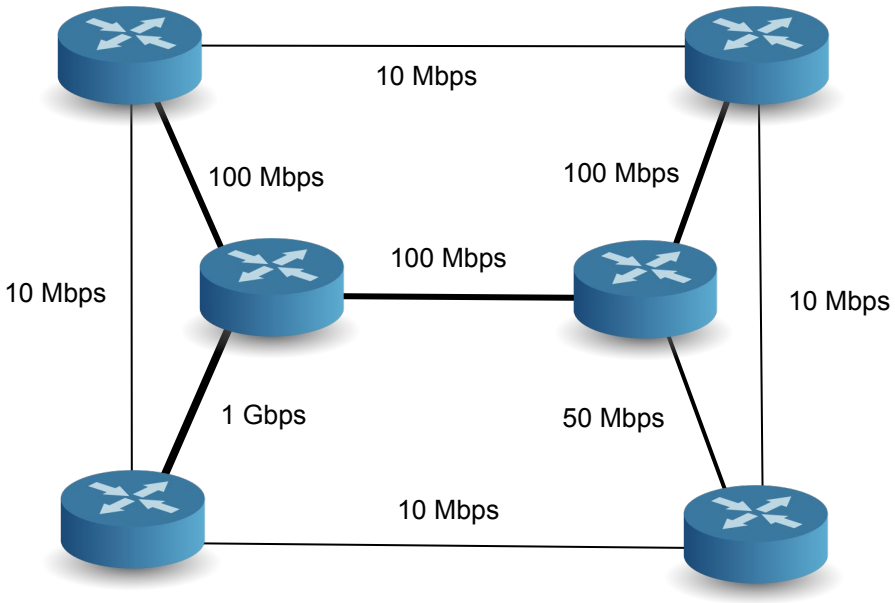

(a) - Rede

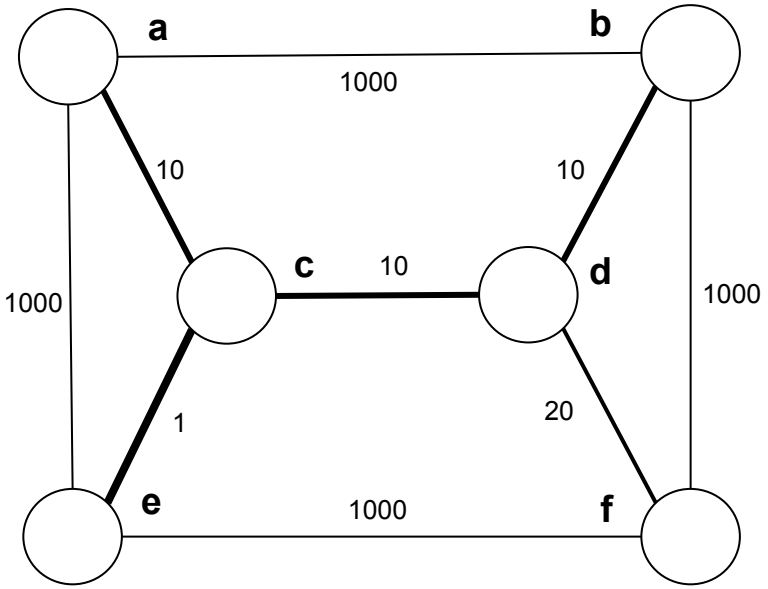

(b) - Rede com os custos dos canais

SPR – *Shortest Path Routing*

- Problema clássico de otimização em teoria dos grafos
- Algoritmo clássico – proposto por Dijkstra
- Dado um nó origem determina o caminho mais curto para todos os outros nós
- A noção de comprimento de um canal é diferente da noção de custo de um canal, no entanto, vamos assumir que são equivalentes, admitindo que o custo de um arco está de alguma forma relacionado com o seu comprimento

Dados G = (N,E,cost) e orig

G é o grafo que modeliza a rede

N é o conjunto dos seus nós

orig o nó inicial, nó a partir do qual se querem conhecer caminhos mais curtos para todos os outros nós

E é o conjunto dos arcos

cost(x,y) é custo do arco que liga diretamente os nós x,y. O custo é sempre positivo.

cost(x,y) = ∞ se não existe um arco entre x e y, senão é igual ao custo desse arco

Variáveis Auxiliares

Estavel ou S de stable é o conjunto de nós para os quais já se conhece um caminho mais curto com origem em **orig**

Inicialmente S = {orig}

No fim S = N

Tentativa ou T de tentative é o conjunto de nós para os quais já se conhece um caminho com origem em **orig** se este existe

Inicialmente T = nós diretamente ligados a **orig**

No fim T = vazio e todos os nós sem caminho para orig são colocados em N à distância infinito

Vetor distance [v] - ∑ dos custos dos arcos do caminho de **orig** a v

Inicialmente, distance [v] = cost(orig,v) se existe um arco que liga orig a v, ou ∞ se não existe

Vetor predecessor [v] – nó que precede v no caminho escolhido de **orig** para v

Algoritmo de Dijkstra

```
while ( S ≠ N) {
        Encontrar p (de pivot) não pertencente a S tal que
                distance(p) é um mínimo (p está em
                Tentativa)
        Juntar p a S // pois não existe nenhum caminho mais curto para w
        Actualizar distance(v) para todos os nós v
        adjacentes a p e que ainda não pertencem
        a S usando:
                distance(v) = min( distance(v),
                distance(p) + cost(p,v) )
//      O novo custo para v é o antigo distance(v) ou o novo
//      via p (o pivot) caso este seja inferior; não existe nenhum
//      outro caminho para v mais curto visto que não existe
//      nenhum outro caminho mais curto para p
}
```

Dados

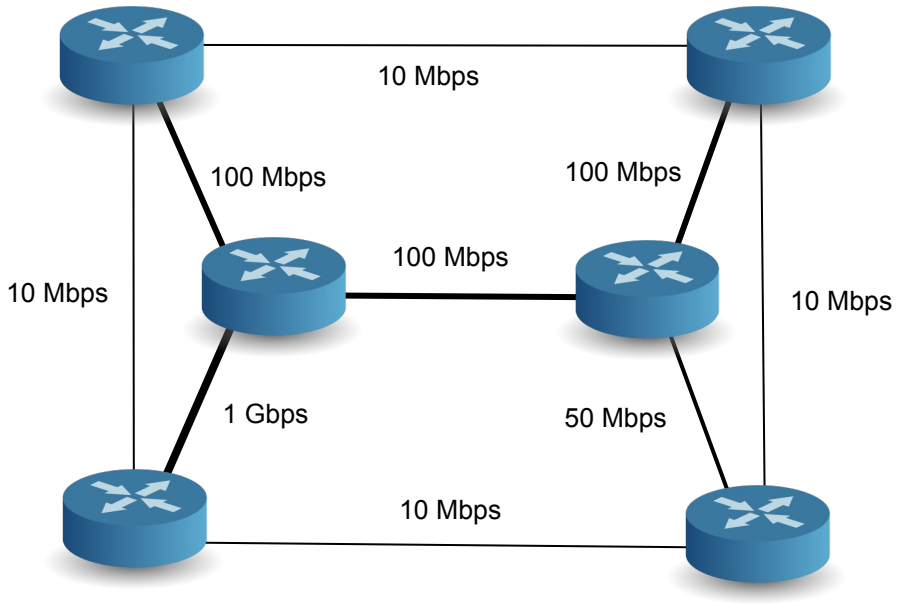

(a) - Rede

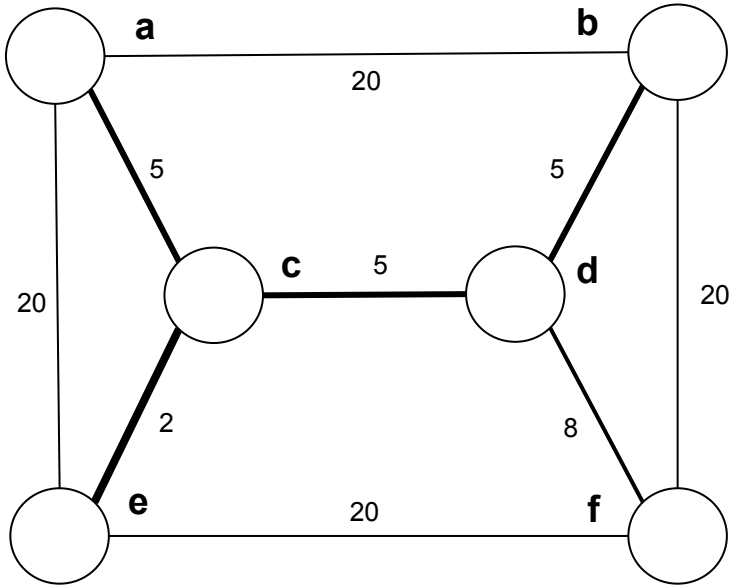

(b) - Modelo

À direita figura o grafo G = (N, E, cost) a **orig** é o nó **a**

Inicialização e Primeira Iteração

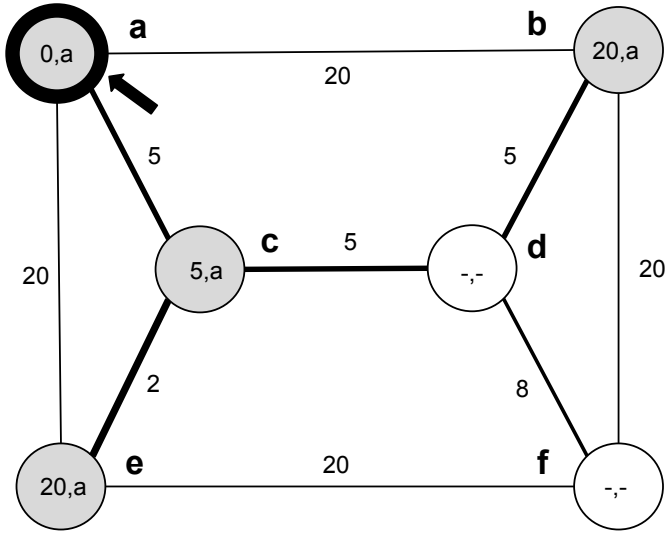

Estável	Tenta-tiva
(a,0,-)	(c,5,a)
	(e,20,a)
	(b,20,a)

(a) - Estado após a inicialização

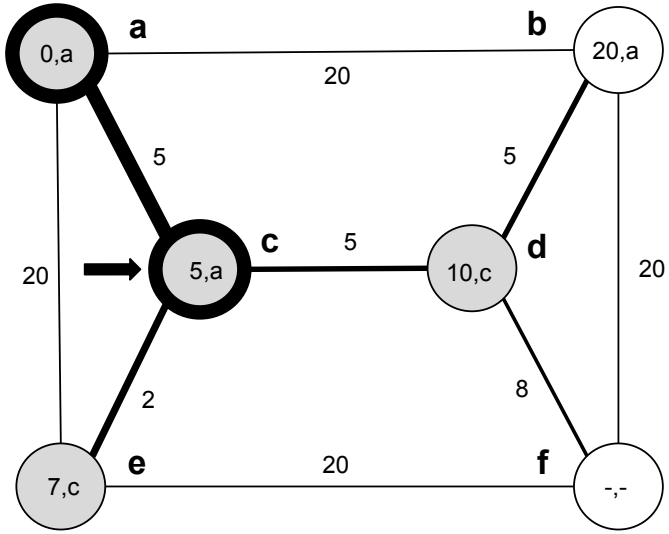

Estável	Tenta-tiva
(a,0,-)	(e,7,c)
(c,5,c)	(d,10,c)
	(b,20,a)

(b) - Estado após a primeira iteração

Após a inicialização, o nó **c** é o primeiro mínimo de Tentativa, o novo pivot, é incluído em Estável, inclui-se em Tentativa o novo nó **d** diretamente ligado ao **pivot** e atualiza-se a distância e o predecessor de **e** visto que se descobriu um melhor caminho para o mesmo via o pivot. Não há alterações em **b** visto que não se descobriu nenhum caminho mais curto.

Segunda e Terceira Iterações

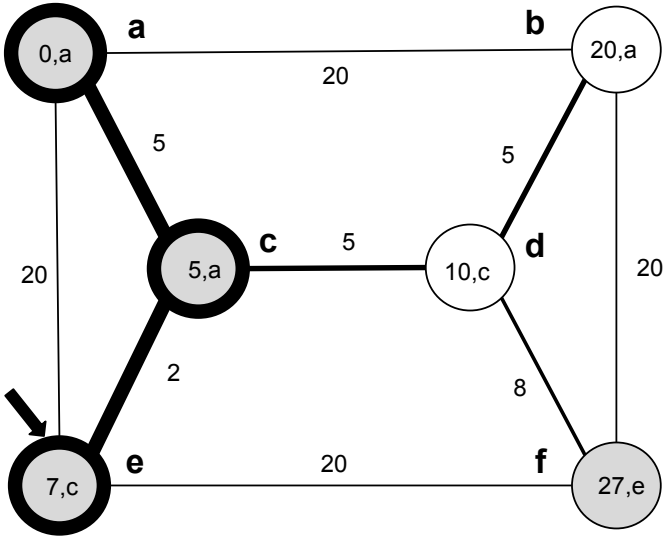

Estável	Tenta-tiva
(a,0,-)	(d,10,c)
(c,5,c)	(b,20,a)
(e,7,c)	(f,27,e)

(a) - Estado após a segunda iteração

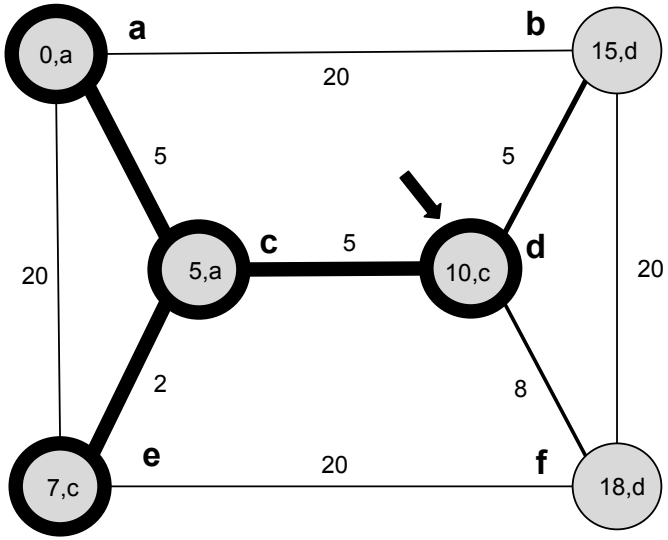

Estável	Tenta-tiva
(a,0,-)	(b,15,d)
(c,5,c)	(f,18,d)
(e,7,c)	
(d,10,c)	

(b) - Estado após a terceira iteração

(2) e é o novo **pivot**, é incluído em Estável, inclui-se em tentativa o novo nó **f** diretamente ligado ao **pivot**, mas não se descobrem melhores caminhos para os outros nós. (3) **d** é o novo pivot que é incluído em Estável, e atualizam-se as distâncias e os caminhos para **b** e **f** via o mesmo visto que são mais curtos.

Quarta e Quinta Iterações

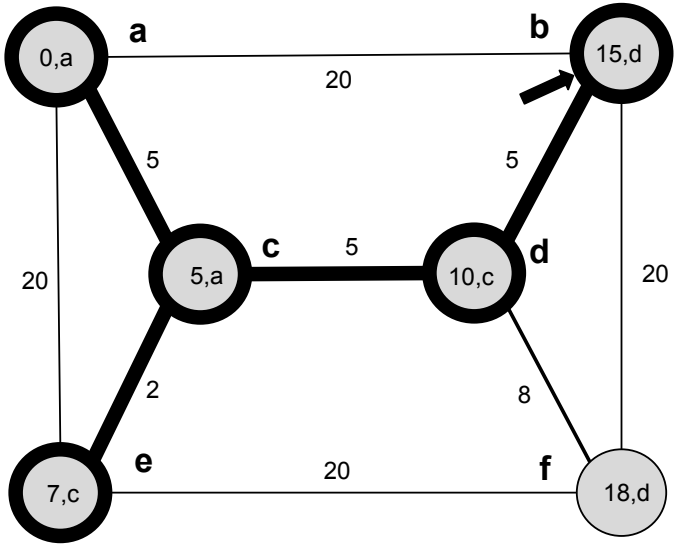

Estável	Tenta-tiva
(a,0,-)	(f,18,d)
(c,5,c)	
(e,7,c)	
(d,10,c)	
(b,15,d)	

(a) - Estado após a quarta iteração

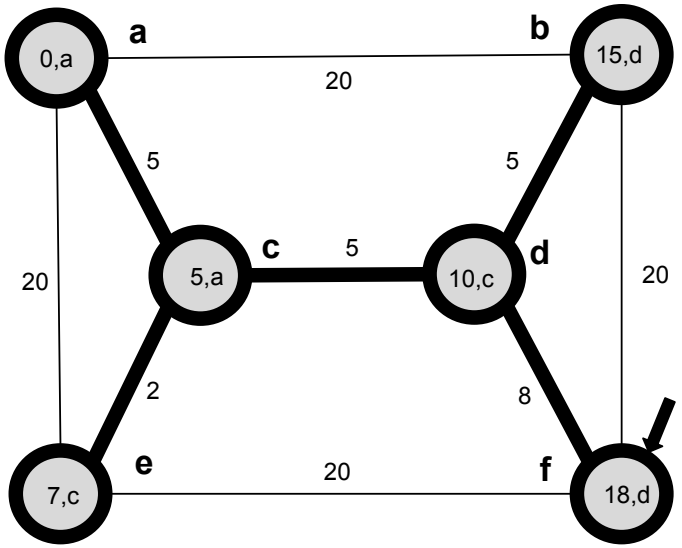

Estável	Tenta-tiva
(a,0,-)	
(c,5,c)	
(e,7,c)	
(d,10,c)	
(b,15,d)	
(f,18,d)	

(b) - Estado após a quinta iteração

(4) **b** é o novo **pivot**, é incluído em Estável, mas não se descobrem mais nós a colocar em Tentativa, nem caminhos mais curtos para os outros nós. (5) **f** é o novo pivot que é incluído em Estável e termina-se visto que Estável é igual ao conjunto de todos os nós N.

No fim conhece-se um árvore de cobertura de G de caminhos mais curtos com origem em a (**orig**).

Complexidade do Algoritmo

- Em cada uma das n iterações é necessário testar todos os nós que ainda não estão em S
- Do que resulta uma complexidade $O(n^2)$
- Conseguem-se implementações mais otimizadas com custo $O(n \log n)$
- De qualquer forma é um algoritmo pesado e que necessita de informação completa sobre a rede

Que Métricas Usar?

- Para a definição do custo de um canal poder-se-ia usar as suas características essenciais:
  - Débito e tempo de propagação
  - Taxa de erros e dimensão média da fila de espera
- A prática mostrou que se obtém melhor estabilidade na rede usando propriedades constantes (ver a seguir)
- Por exemplo custo = referência / débito do canal

Exemplo: custo = 1 para 10 Gbps (referência)
= 10 para 1 Gbps,
= 100 para 100 Mbps,
= 1000 para 10 Mbps,
= 10.000 para 1 Mbps

Métricas Variáveis e Instabilidade

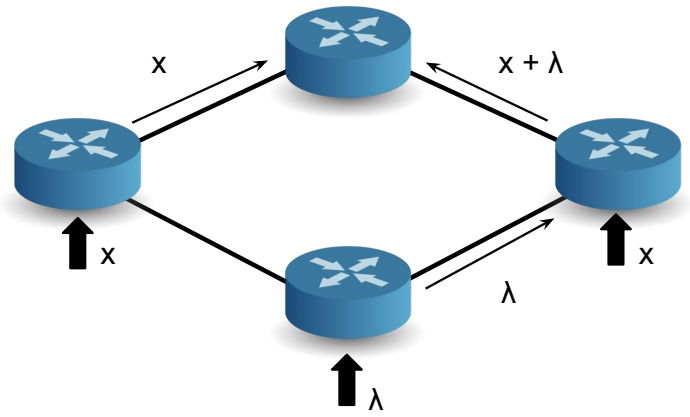

(a)

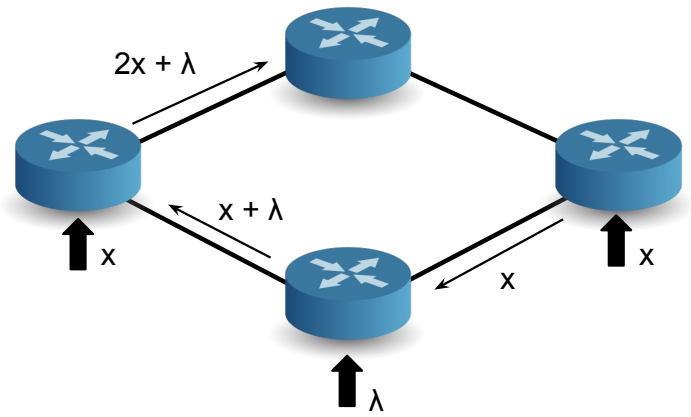

(b)

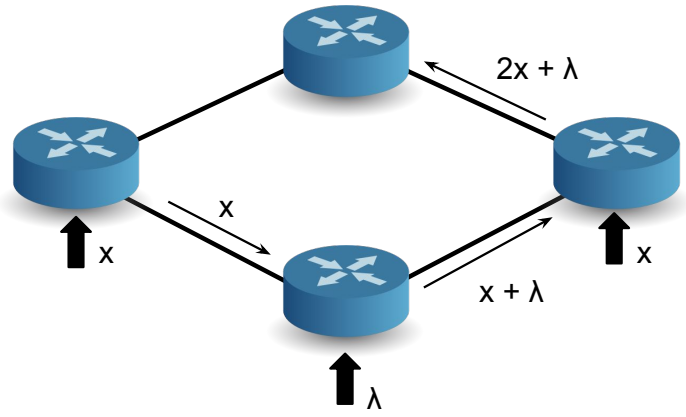

(c)

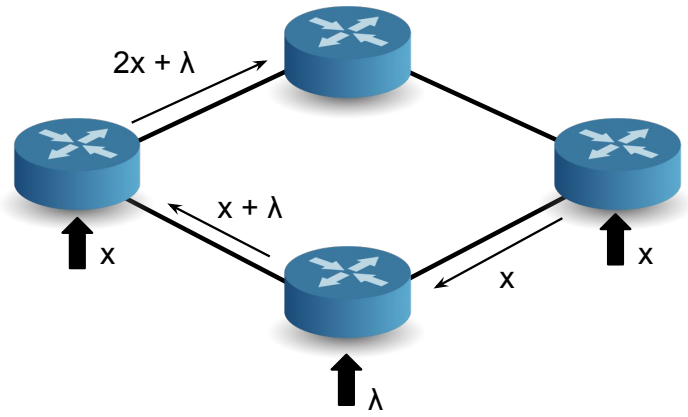

(d)

Conclusões

- Numa rede em malha (onde existem ciclos) é necessário escolher os caminhos seguidos pelos pacotes, pois existe mais do que um caminho para cada destino

- O algoritmo de Dijkstra, um algoritmo clássico de optimização em teoria dos grafos, fornece uma solução que permite determinar um caminho mais curto
  - Baseia-se em estabelecer um modelo da rede como um grafo
  - Determina uma árvore de cobertura de caminhos mais curtos com base na origem
  - Tem uma complexidade aceitável para os computadores modernos
  - Mas exige uma visão completa da rede !

Comutadores Inteligentes ou *Routers*

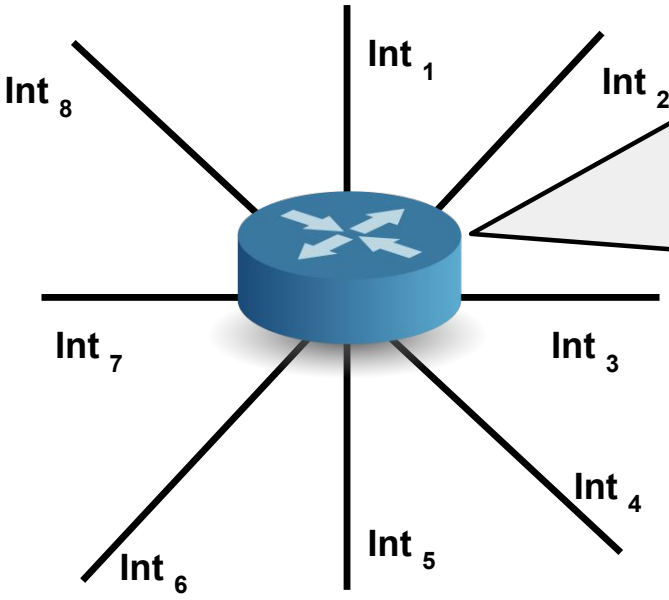

FIB - *Forwarding Information Base*

Destino	Distância	Interface (direção)
a	100	Int 8
.....	.....	.....
e	10	Int 2
f	1000	Int 1

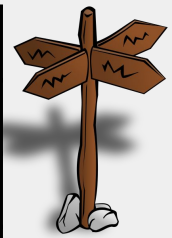

RIB - *Routing Information Base*

Informações sobre o estado da rede

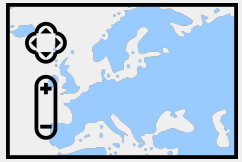

A FIB é como que um conjunto de tabuletas num cruzamento. Geralmente, a RIB assemelha-se mais a um mapa global da estrada que contém uma visão dos caminhos da origem até ao destino.

Diferença entre RIB e FIB

- Tabela de encaminhamento ou RIB
  - Contém a informação necessária ao funcionamento do protocolo de encaminhamento (*routing*) e permite preencher a FIB
  - Em inglês diz-se *Routing table ou RIB - Routing Information Base*

- Tabela de Comutação ou FIB *(Forwarding Information Base)*
  - Tabela de comutação especial, construída em memória especialmente rápida nos comutadores de alta gama
  - As suas linhas resumem-se a pares (destino, interface, custo)
  - Em inglês diz-se *Forwarding Information Base - FIB*
  - Às vezes a FIB reside diretamente nas placas que recebem os pacotes nos comutadores

Terminologia dos Protocolos de Encaminhamento e dos Comutadores

- *Data plane ou* parte dos dados (faceta relacionada com os pacotes de dados)
  - Trata da problemática da comutação de pacotes entre a interface de entrada e a interface de saída
  - Baseia-se numa tabela de comutação
  - Em inglês diz-se *Forwarding Information Base ou FIB*
  - Esta tabela é consultada para decidir como transmitir cada pacote
- *Control plane ou* parte do controlo (faceta de controlo)
  - Trata da problemática da informação e protocolos necessários ao controlo do equipamento de comutação
  - Nomeadamente tudo o que lhes permite adquirirem a informação necessária para preencherem a *FIB (Forward Information Base)*
  - Utiliza estruturas de dados dependentes do protocolo e algoritmo usado Estas designam-se por *RIB (Routing Information Base)*
  - *Com encaminhamento estático, a RIB é preenchida à mão.*

Encaminhamento com Base no Estado dos Canais

- Admitindo que cada comutador conhece o grafo da rede, isto é, o seu estado completo, o algoritmo de Dijkstra permitiria tomar decisões sobre o encaminhamento dos pacotes
- A técnica conhecida por *Link State Routing* permite que todos os nós da rede conheçam a configuração completa da mesma e possam estar de acordo na escolha dos caminhos que os pacotes devem seguir
- Baseia-se na difusão de anúncios de estado (LSA *Link State Announcements*) entre os comutadores

Link-State Routing

- O algoritmo de Dijkstra pressupõe que cada nó conhece o grafo da rede
- Como à partida só é fácil cada nó conhecer a sua vizinhança — que canais e que vizinhos tem — é necessário encontrar uma forma de cada comutador ficar a conhecer a visão completa da rede
- *Link State Routing* baseia-se na ideia de que se cada nó difundir de forma fiável para todos os outros a sua visão sobre a vizinhança, então todos ficarão com uma visão (consistente e correta) da rede

Como Funciona um Comutador LS

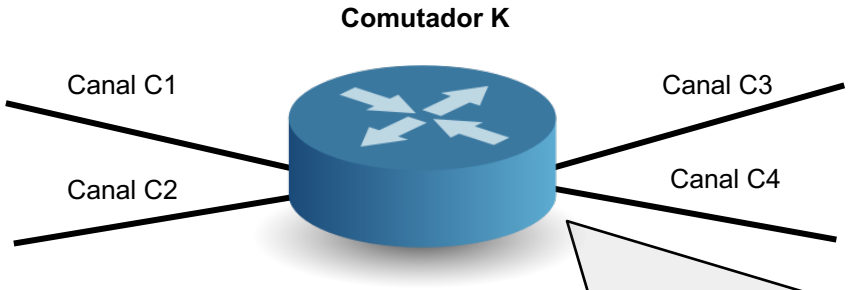

Base de dados de LSA, tabela de vizinhos e tabela de encaminhamento (RIB - routing information base)

Comutador originador	Seq.	TTL (horas)	Tipo e valor do LSA
Comut. A	3	9	...
Comut. A	15	9	...
Comut. B	56	10	...
Comut. C	2	10	...
...	…	...	...
Comut. D	19	9	

Tabela de comutação (FIB - Forwarding Information Base)

Destino	Custo	Canal
A	100	C1
B	50	C2
C	1000	C3
D	10	C2
....	...	...
M	200	C4

RIB de um Comutador LS

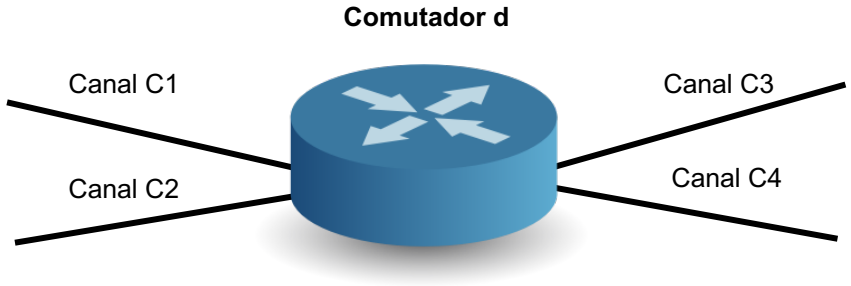

Comutador originador do LSA	Sequência	TTL (horas)	Tipo e valor do LSA
Comutador a	3	9	...
Comutador a	15	9	...
Comutador b	56	10	...
...	...	...	...
Comutador f	19	9	

Neste caso a RIB chama-se Link State Database ou Adjacencies Database e contém os anúncios de adjacência de todos os comutadores. Quando a rede está estável, está tabela é igual em todos os comutadores da rede usando replicação fiável dos anúncios de adjacência ou LSAs (Link State Announcements).

Link-State Routing

- Cada nó (*router*) sabe quais são os seus canais e o respetivo estado
  - O canal está *up* ou *down* ?
  - O custo do canal
- Cada nó (*router*) executa um *broadcast*, através de inundação fiável, do estado do canal (*link state reliable broadcast)*
  - Para que cada nó fique com uma visão completa da rede
- Cada nó executa o algoritmo de Dijkstra
  - Calcula os caminhos óptimos (*shortest paths*)
  - … e reconstrói a sua tabela de encaminhamento
- Protocolos concretos que usam este método
  - Open Shortest Path First (OSPF)
  - Intermediate System – Intermediate System (IS-IS)

Protocolo Hello

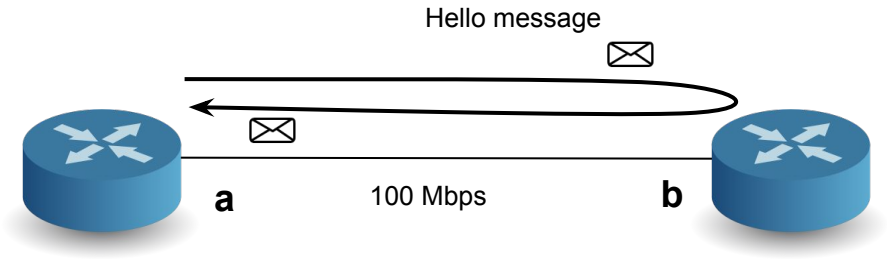

- Sondas periódicas (*beaconing*)
  - Envio periódico de mensagens "hello"
  - Deteção de falhas após um certo número de ausência de resposta
- Alguns canais detetam avarias e lançam alarmes
  - Ausência de portadora por exemplo

Difusão fiável

- Com *Link-State Routing* inicialmente cada nó difunde os canais que conhece e o seu estado
  - Os canais e o seu estado estão na *Link-State Database*
- Sempre que o estado de um canal se altera, é necessário que o nó responsável pelo canal
  - Difunda a alteração a todos os outros nós
  - Como garantir que as notícias chegam a todos ?
- Difusão fiável (*reliable flooding*)
  - Cada nó numera sequencialmente cada mensagem que envia
  - As mensagens são difundidas por inundação (*flooding*)
  - Um nó passa a todos os vizinhos a mensagem que recebe exceto ao vizinho de que a recebeu
  - O número de sequência e a identificação do originador são usadas para detetar os duplicados e as faltas

LSA - Link State Announcement

- Cada comutador emite LSAs
  - No início a dizer quais são os canais que conhece (e.g. canal de a para b operacional e com custo 100)
  - Mas também a dizer os destinos que serve (e.g. os computadores a ele ligados: c1, c2, c3, ...)
  - A seguir sempre que há uma alteração (e.g. canal de a para a down ou com custo ∞) a alteração é difundida
- Cada comutador tem um identificador único
  - Todos os LSAs têm o identificador do emissor original (o originador ou "dono" do LSA)
  - Todos os LSAs têm um número de sequência por ordem crescente colocado pelo seu originador

Link State Database

- O recetor de um LSA
  - Fica a saber que o originador existe (que até pode não ser seu vizinho direto)
  - Fica a saber se já conhece ou não esse LSA pelo seu número de sequência
  - Só lhe interessa guardar a última versão
  - O conjunto dos últimos LSAs recebidos ficam na LSA database
- A LSA database de cada comutador contém a sua visão da rede
  - Funciona como um sistema de emissão de notícias
  - A base de dados de notícias representa o último estado do sistema conhecido
  - A base de dados está replicada em todos os comutadores

Fiabilidade da Difusão

- *Reliable flooding*
  - Assegura que todos os nós recebem as notícias
  - … na sua última versão
- Desafios
  - *Packet loss*
  - Chegadas fora de ordem
- Soluções
  - *Acknowledgments* e retransmissões
  - Números de sequência
  - Time-to-live (TTL) em cada pacote
  - Se houver inconsistência dos números de sequência, os nós sincronizam-se para a versão comum mais avançada

Algoritmo de Difusão Fiável de LSA

- LSA (Orig, s, notícia)
  - Orig é o originador do LSA
  - s é o número de sequência
  - notícia é o valor do LSA

- A envia LSA(Orig, s, notícia) ao seu vizinho B
  - B verifica se conhece Orig e se não conhece, executa database.put(Orig, s, notícia), envia ACK a A e faz flooding do LSA
  - Se conhece vai buscar o número de sequência do último LSA de Orig que conhece (seja i esse número)
  - Se i = s, o LSA é um duplicado, envia ACK a A
  - Se i > s, A está atrasado e B envia-lhe o seu último LSA conhecido sobre Orig
  - Se i < s, B está receber notícias novas, database.put(Orig, s, notícia), envia ACK a A e faz flooding do LSA

Disseminação Fiável e Partições

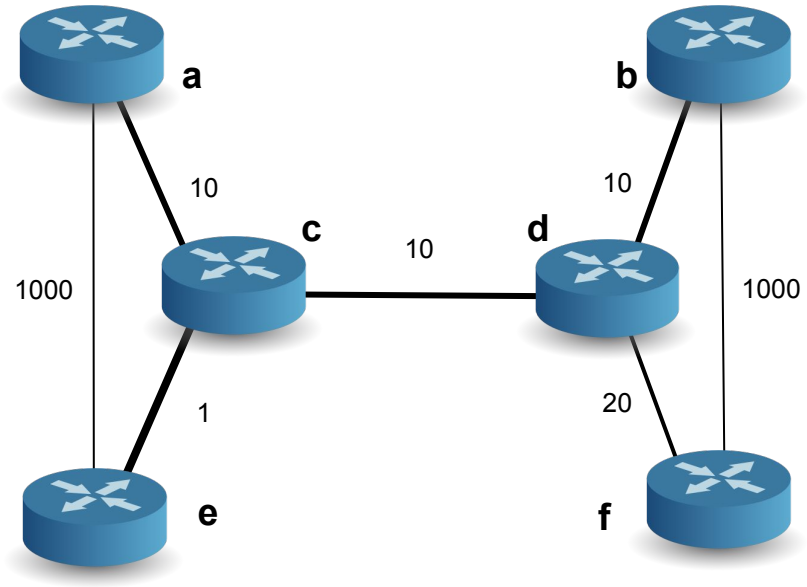

(a) - Rede sem partições

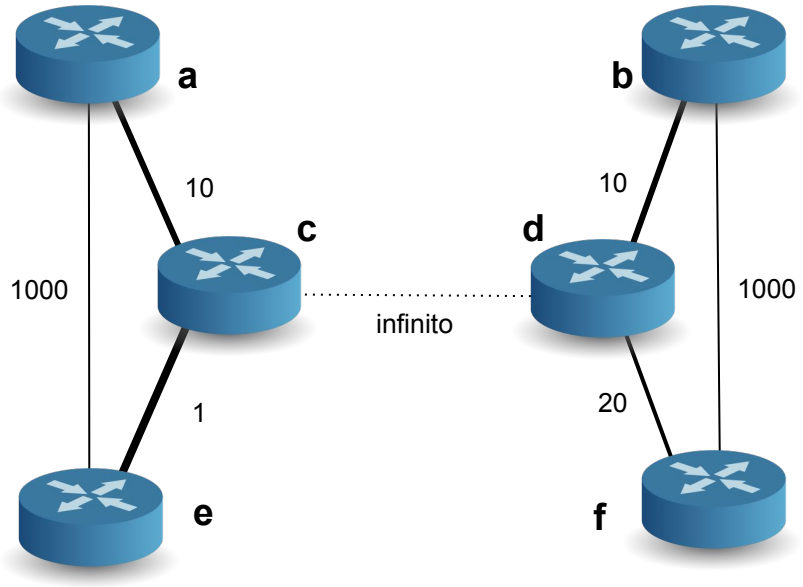

(b) - Rede particionada em duas partições

Quando se dá uma partição, os comutadores de cada lado, logo que recebem o anúncio de que o canal que liga c a d foi abaixo, passam a considerar os comutadores da outra partição à distância infinita. Ambas as partições passam a evoluir independentemente. Quando o canal volta a estar operacional, é necessário ressincronizar as duas partições imediatamente.

Alterações do Estado da Rede

- Na sequência de uma alteração de estado, os nós ficam com visões distintas do estado da rede
  - Têm tabelas de encaminhamento inconsistentes e os pacotes podem entrar em ciclo
  - O TTL dos pacotes garante que estes não ficam eternamente no interior da rede
  - Mas durante essa instabilidade perdem-se pacotes e desperdiça-se capacidade da rede
- Diz-se que a rede converge quando todos os nós refletem a mesma visão da rede e têm tabelas de encaminhamento coerentes

Noção de Convergência da Rede

- O tempo que demora a que todos os nós tenham a mesma visão da rede e tabelas de encaminhamento coerentes
  - Depende do tempo de deteção das alterações
  - do tempo de propagação das mensagens
  - do tempo de execução do algoritmo de Dijkstra
  - e do tempo necessário para alterar as novas tabelas de encaminhamento
  - em nós de grande capacidade e redes realistas é hoje em dia inferior a 1 segundo

Avarias, Ciclos e Convergência

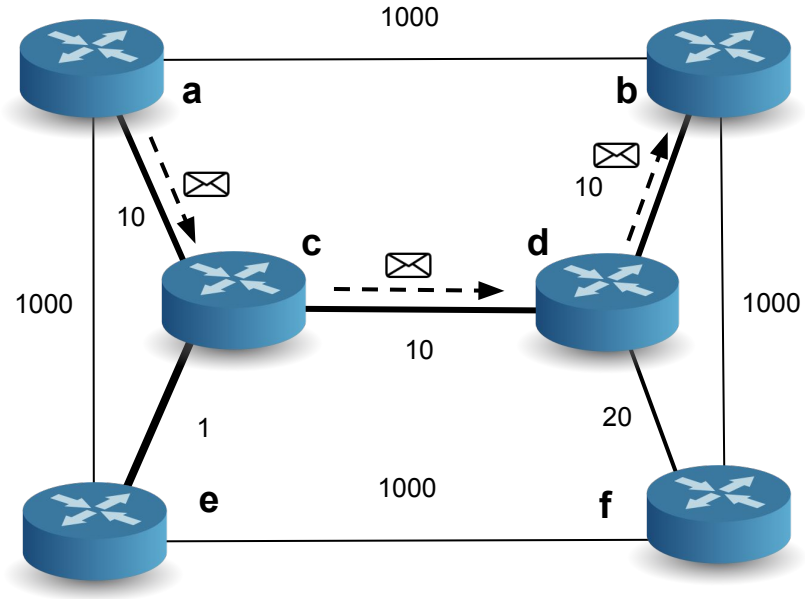

(a) - Rede sem avarias

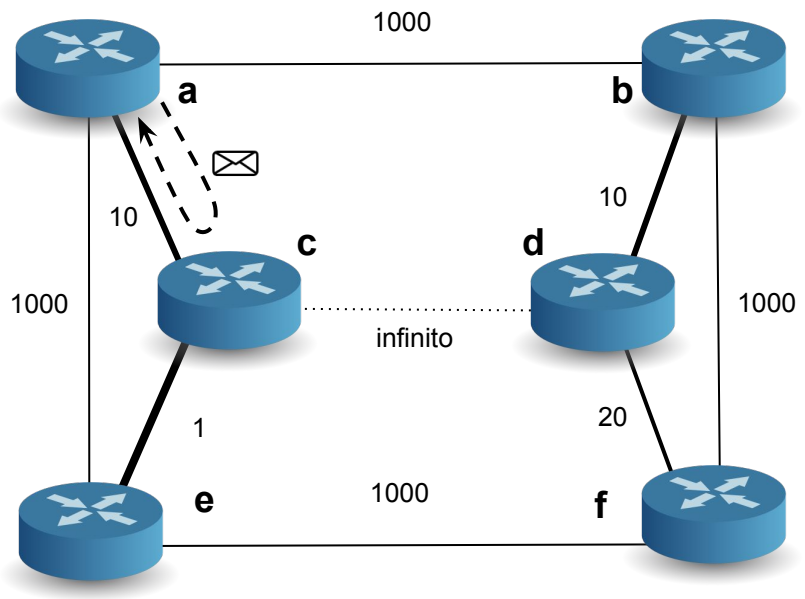

(b) - Rede após a avaria

Inicialmente a envia pacotes para b via c. Após a avaria do canal c para d, o nó c passa a enviar os pacotes para b via a. Enquanto a não souber da avaria continua a enviar os pacotes para b via c e esses pacotes entram em ciclo, perdem-se e desperdiçam a capacidade do canal de c para a. Quando a rede converge, a vai para b pelo canal direto.

Conclusões

- O algoritmo de Dijkstra permite calcular os caminhos mais curtos a partir de um qualquer nó do grafo da rede
- Mas requer que cada comutador conheça toda a rede
- *Link-State Routing* baseia-se na utilização de difusão fiável para propagar para todos os comutadores a visão completa do estado da rede
- É um algoritmo distribuído que introduz inconsistências durante a convergência, mas esta pode ser relativamente rápida