Interligação de Redes / Redes IP

Protocolos – IP / TCP / UDP

FEUP/DEEC
Redes de Computadores
MIEEC – 2010/11
José Ruela

Pilha protocolar TCP/IP

- Acesso à rede (física)
  - » Interface ao meio físico
    - – Carta de rede, *device driver*
- Rede (*internetworking*)
  - » Transferência de pacotes na rede (através de várias redes físicas)
    - – Protocolos de encaminhamento (e.g., RIP, OSPF, BGP)
  - » IP – *Internet Protocol*
  - » ICMP – *Internet Control Message Protocol*
  - » IGMP – *Internet Group Management Protocol*
- Transporte
  - » Multiplexagem de fluxos de dados entre máquinas (*hosts*)
    - – TCP – *Transmission Control Protocol*
    - – UDP – *User Datagram Protocol*
- Aplicação
  - » Serviços de utilizador
    - – Telnet, FTP, SMTP, HTTP, etc.
  - » Modelo tradicional: cliente-servidor

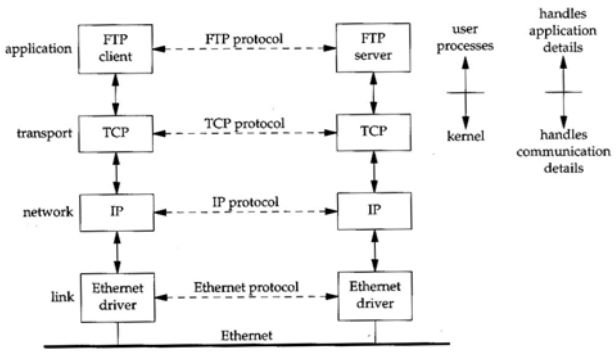

Interligação de redes

- Redes de diferentes organizações e usando diferentes tecnologias de acesso devem poder comunicar

- Internet – rede única, virtual
  - » *End-Systems* – computadores (*hosts*)
  - » *Intermediate-Systems – routers*
  - » Comunicação global
  - » Interligação de redes com *routers*
    - – Um *router* tem uma interface por cada rede física que interliga

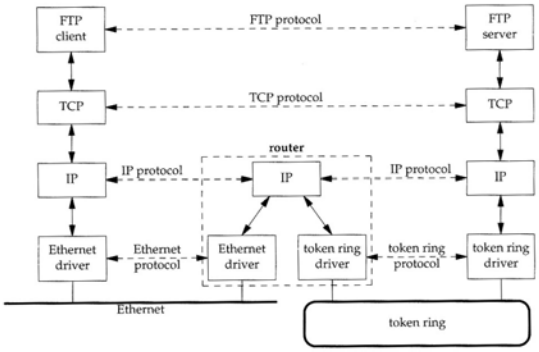

- Comunicação protocolar
  - » Camadas de Aplicação e Transporte
    - – Extremo-a-extremo (entre *hosts*)
  - » Camada de Rede
    - – Entre máquinas adjacentes no nível IP

Arquitectura TCP/IP – protocolos

- TCP
  - » Serviço orientado à conexão
  - » Transporte fiável entre máquinas
- UDP
  - » Serviço sem conexão (*connectionless*)
  - » Transporte não fiável
- IP
  - » Protocolo central da pilha
  - » Encaminha datagramas (*connectionless*)
- ICMP
  - » Auxiliar do IP
  - » Transporta mensagens de controlo (por exemplo, mensagens de erro)
- IGMP
  - » Gere grupos *multicast*
- ARP, RARP
  - » Resolução de endereços IP em endereços físicos (por exemplo, endereços MAC)

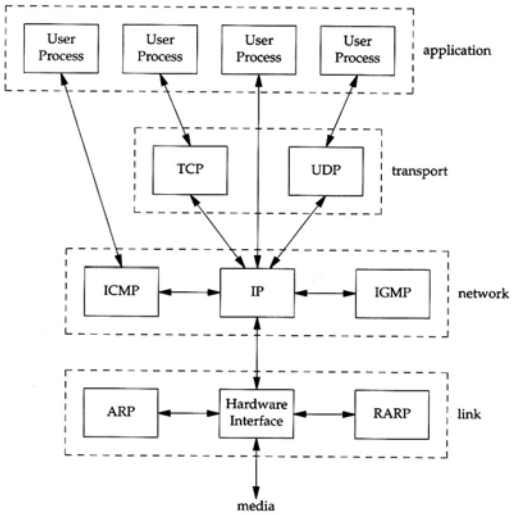

Encapsulamento

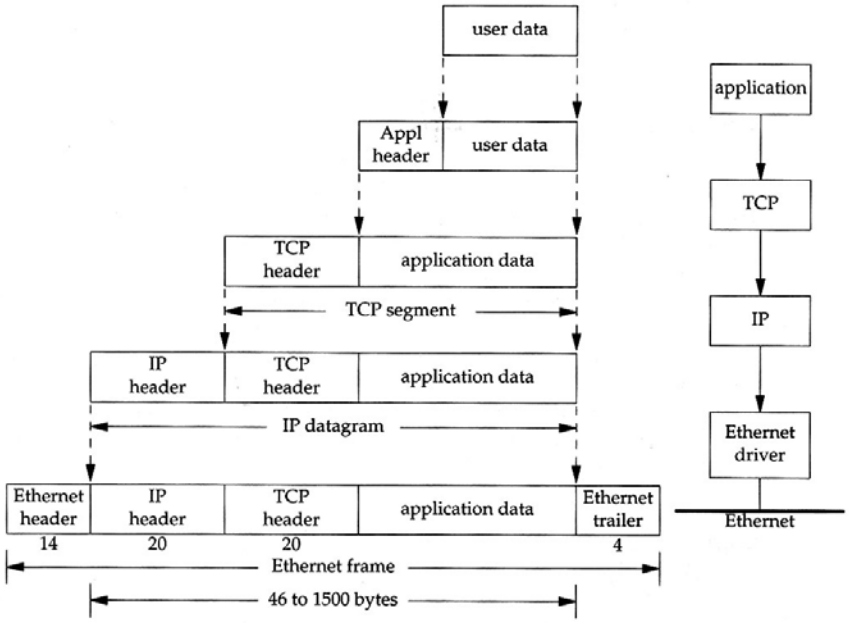

Encapsulamento Ethernet e IEEE 802

Cartas Ethernet
- » Devem permitir
  - Encapsulamento IEEE 802 (RFC 1042)
  - Encapsulamento Ethernet (RFC 894)
- » Se suportarem os 2 tipos
  - O tipo deve ser configurável
  - *Default*: encapsulamento Ethernet

Valores válidos IEEE 802 *length*
- » Diferentes de *type* válidos
  - Ex. 0x0800 = 2048

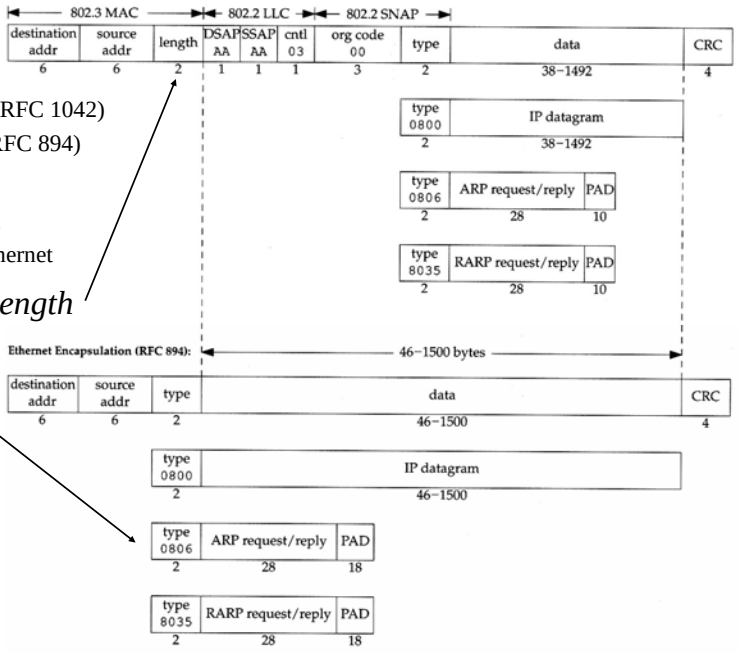

Encapsulamento baseado em LLC

- Encapsulamento de protocolos “encaminháveis” (*routed ISO protocols*)
  - Identificado por DSAP = SSAP = 0xFE
  - O primeiro octeto do campo de Dados é NLPID (*Network Layer Protocol Identifier*), administrado por ISO / ITU
    - NLPID é também usado em encapsulamento não baseado em LLC
  - Valores de NLPID
    - 0x00 *Null Network Layer* / *Inactive Set*
    - 0x08 ITU-T Q.933
    - 0x80 SNAP (*Subnetwork Access Protocol*)
      - Usado em encapsulamento não baseado em LLC quando o protocolo não tem NLPID associado
      - LLC suporta encapsulamento LLC/SNAP
    - 0x81 ISO CLNP
    - 0x82 ISO ES-IS
    - 0x83 ISO IS-IS
    - 0xCC IP
      - IP não é protocolo ISO mas tem NLPID associado
      - IP é normalmente encapsulado com base em LLC/SNAP (LANs, IP sobre ATM, LANE)
- Encapsulamento LLC/SNAP
  - Identificado por DSAP = SSAP = 0xAA

Encapsulamento LLC/SNAP

- O campo SNAP é constituído por cinco octetos
  - OUI *Organizationally Unique Identifier* (3 octetos)
  - PID *Protocol Identifier*, normalmente designado *Ether Type* (2 octetos)
- Tipos de encapsulamento
  - *Routed non ISO PDUs* OUI = 0x000000
  - *Bridged IEEE 802 PDUs* OUI = 0x0080C2

- *Routed non ISO PDUs – PID*
  - 0x0800 IPv4
  - 0x0806 ARP
  - 0x0807 XNS
  - 0x6003 DECnet
  - 0x8035 RARP
  - 0x809B AppleTalk
  - 0x8137 IPX
  - 0x86DD IPv6
  - 0x8847 MPLS
- *Bridged IEEE 802 PDUs – PID*
  - 0x0001/0007 IEEE 802.3
  - 0x0002/0008 IEEE 802.4
  - 0x0003/0009 IEEE 802.5
  - 0x0004/000A FDDI
  - 0x000E BPDUs

Desmultiplexagem

- Cabeçalho TCP/UDP (porta)
  - FTP → 21
  - Telnet → 23
  - HTTP → 80
  - SMTP → 25
- Cabeçalho IP (protocolo)
  - ICMP → 1
  - IGMP → 2
  - TCP → 6
  - UDP → 17
- Cabeçalho Ethernet (tipo)
  - IPv4 → 0x0800
  - ARP → 0x0806
  - RARP → 0x8035
  - IPX → 0x8037
  - IPv6 → 0x86DD
  - MPLS → 0x8847

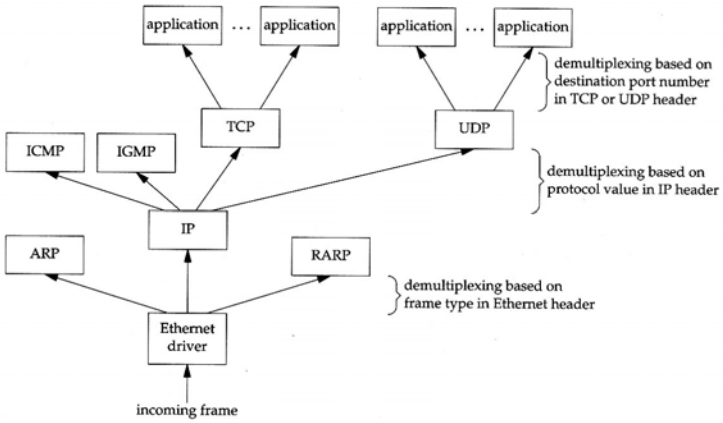

Internet Protocol

- IP
  - » Comutação de datagramas
  - » Serviço não fiável / *best effort*
    - Entrega no destino não garantida (rede pode perder / descartar datagramas)
    - Tempo máximo de entrega não garantido
  - » Datagramas para um mesmo destino podem seguir caminhos diferentes e portanto ser entregues fora de ordem
- Cada *router*
  - » Analisa o endereço de destino presente no cabeçalho de cada datagrama
  - » Comuta o datagrama recebido para uma das suas interfaces
  - » Em situações de erro
    - Elimina datagrama
    - Envia mensagem de erro ICMP para a origem

Cabeçalho IP (IPv4)

IP Header

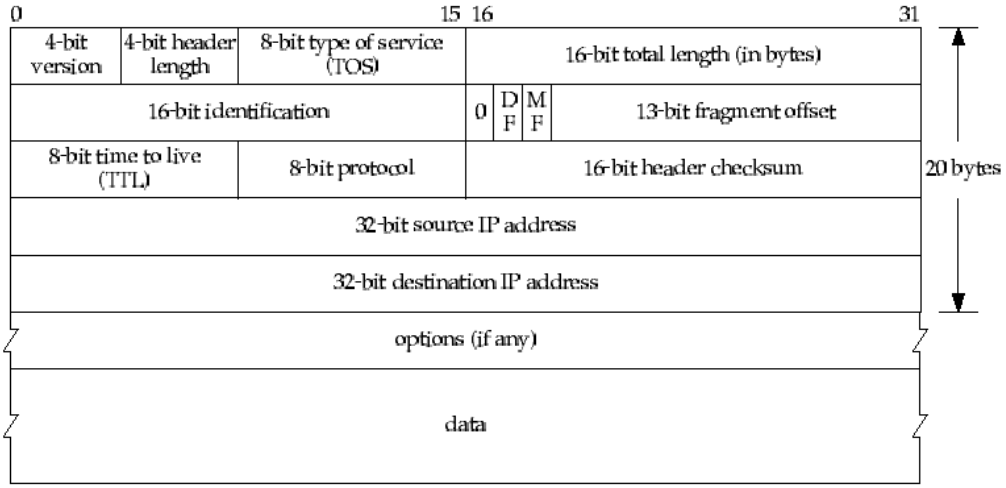

Cabeçalho IP (IPv4)

- Versão – 4 (IPv4)
- Comprimento do cabeçalho
  - Número de palavras (de 32 bits) do cabeçalho
  - Tamanho máximo do cabeçalho – 60 octetos
- TOS (*type of service*)
  - O RFC 791 definiu 3 bits de precedência e 3 bits para exprimir a importância relativa entre *delay* (D), *throughput* (T) e *reliability* (R), tendo o RFC 1349 proposto usar mais um bit relacionado com o custo (C)
  - Actualmente 6 bits são usados em *DiffServ* (DS *codepoint*) e os 2 restantes estão previstos para *Explicit Congestion Notification*
- Comprimento total
  - Comprimento total do datagrama
  - Tamanho máximo do datagrama: 65535 octetos
- Identificação
  - Identifica univocamente um datagrama
  - Incrementado por cada datagrama enviado
- *Flags*
  - DF – *Don't Fragment*
  - MF – *More Fragments*
- *Fragment offset*
  - Indica a posição dum fragmento em relação ao datagrama inicial
- TTL (*time to live*) – tempo de vida
  - Número máximo de *routers* visitáveis por um datagrama
  - Valor inicial fixado pelo *host* (e.g., 16, 32, 64)
  - Decrementado por cada *router* visitado
- Protocolo
  - Usado para desmultiplexagem
- *Checksum*
  - Protecção do cabeçalho (detecção de erros)
- Endereços de origem (32 bits) e destino (32 bits)
  - Endereços IP dos *hosts* de destino e origem
- Opções
  - Registo de rota
  - Registo de tempos
  - Encaminhamento definido pela origem
    - *Loose source routing*
    - *Strict source routing*

MTU – Maximum Transmission Unit

- Cada rede limita o tamanho do campo de dados nas respectivas tramas – este limite designa-se *Maximum Transmission Unit* (MTU)
- Se o tamanho de um datagrama IP for superior ao MTU de uma rede no seu percurso, é necessário fragmentá-lo em datagramas mais pequenos, podendo ser necessário fragmentar novamente para atravessar outra(s) rede(s)
- Se um datagrama atravessar várias redes, o menor MTU condiciona o tamanho dos datagramas IP (fragmentos) entregues no destino

Network	MTU (bytes)
16 Mbits/sec token ring (IBM)	17914
4 Mbits/sec token ring (802.5)	4464
FDDI	4352
Ethernet	1500
IEEE 802.3/802.2	1492
X.25	576
Point-to-Point (low delay)	296

Fragmentação de pacotes IP

- A fragmentação é realizada quando necessário em *routers* (a fragmentação na origem é evitada)
- A reconstrução de datagramas é feita no destino
- Informação usada na fragmentação (cabeçalho IP)
  - » *Identification*
    - – Valor único atribuído a cada datagrama pelo emissor
    - – Copiado em cada fragmento do datagrama original
  - » *Data length*
    - – Comprimento dos dados (do fragmento) em octetos
  - » *Offset*
    - – Posição do fragmento no datagrama (n * 64 bits)
  - » *More Fragments* (MF *flag*)
    - – Indica que o fragmento não é o último
- Problema
  - » Perda de fragmentos
- Solução
  - » Limitar o tempo máximo de reconstrução e o tempo máximo de vida (TTL) de um datagrama

Fragmentação de pacotes IP – exemplo

Rede 1
MTU = 1500

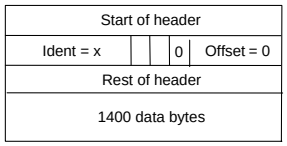

Rede 2
MTU = 532

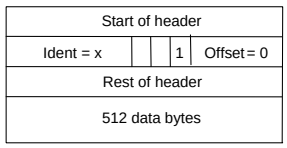

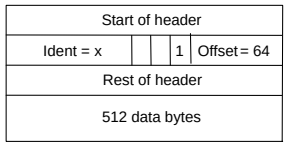

Valor do campo *offset* = *offset* real / 8

Com excepção do último fragmento, o tamanho do campo de dados deve ser múltiplo de 8 octetos

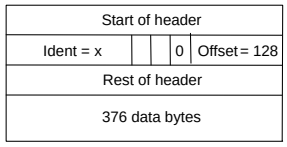

Endereçamento IP

- Um endereço IP identifica uma interface de rede (um endereço por interface) e é estruturado em duas partes
  - » *netid* – identificador da rede
  - » *hostid* – identificador da máquina (*host*, *router*)
- Um endereço IPv4 é constituído por 32 bits
  - » Exemplo: 142.252.13.33 (*dotted decimal notation*)
- Atribuição de endereços
  - » A gestão e coordenação de endereços IP é da responsabilidade do ICANN (*Internet Corporation for Assigned Names and Numbers*)
    - – O ICANN delega partes do espaço de endereçamento a outras autoridades, que por sua vez atribuem endereços a fornecedores de serviços IP (ISP) e outras empresas
  - » A atribuição de *hostid* é da responsabilidade do administrador de cada rede
    - – *All 0s*: representa a subrede identificada por <*netid*>
    - – *All 1s*: endereço de *broadcast* na subrede identificada por <*netid*>
- O esquema de endereçamento inicialmente usado na Internet era baseado em classes (*classful addressing*)
  - » Neste esquema a demarcação dos campos *netid* e *hostid* era feita ao nível de octeto (24, 16 ou 8 bits usados para atribuição de *hostid*)

Classful addressing – classes de endereços

- Classe A
  - » 126 redes: *netid* = 1 a 126
    - – *netid* = *all 0s*: reservado
    - – *netid* = 127: interface de *loopback*
    - – *netid* = 10: endereços privados
- Classe B
  - » *netid* = 128.0 a 191.255
  - » *netid* = 172.16 a 172.31: endereços privados
- Classe C
  - » *netid* = 192.0.0 a 223.255.255
  - » *netid* = 192.168.0 a 192.68.255: endereços privados
- Classe D – endereços *multicast*
- Classe E – gama reservada para uso futuro

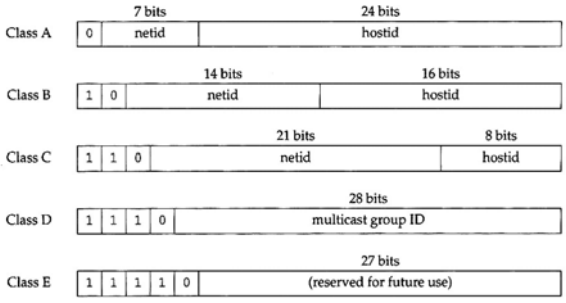

Classe	Valores
A	0.0.0.0 → 127.255.255.255
B	128.0.0.0 → 191.255.255.255
C	192.0.0.0 → 223.255.255.255
D	224.0.0.0 → 239.255.255.255
E	240.0.0.0 → 247.255.255.255

CIDR – Classless Inter-Domain Routing

- O esquema *classful addressing* apresenta limitações graves
  - » A rigidez na atribuição de endereços contribui para o seu desperdício e portanto para um mais rápido esgotamento do espaço disponível
  - » Um problema relacionado era o aumento do número de rotas que tinham de ser mantidas pelos *routers* à medida que crescia o número de redes
- Estes problemas foram resolvidos com duas medidas
  - » Reestruturação da forma de atribuir endereços (CIDR – *Classless Inter-Domain Routing*), de modo a melhorar a eficiência do processo
  - » Agregação hierárquica de rotas, com o objectivo de reduzir o tamanho das tabelas de encaminhamento
- No esquema CIDR, o identificador (prefixo) de uma rede (*netid*) pode ter um número de bits que não é condicionado pela existência de classes, pelo que se torna necessário associar uma máscara ao endereço
  - » O endereço é representado na notação habitual seguida de /*n*, sendo *n* o número de bits do prefixo comum a todas as máquinas da rede
  - » Com este esquema adoptou-se uma atribuição hierárquica de endereços
  - » A utilização de uma máscara é igualmente necessária no processo de constituição de subredes (*subnetting*) dentro de uma organização

Endereços especiais

Endereço	*netid*	*hostid*	*Source / Destination*
Endereço de uma rede	específico	*all 0s*	Não aplicável
Direct broadcast address	específico	*all 1s*	*Destination*
Limited broadcast address	*all 1s*	*all 1s*	*Destination*
Este *host* nesta rede	*all 0s*	*all 0s*	*Source*
Host específico nesta rede	*all 0s*	específico	*Destination*
Loopback address	127	qualquer	*Destination*

» *Direct broadcast address* – identifica todos os *hosts* numa rede específica (*netid*), pelo que os pacotes com este endereço de destino devem ser encaminhados pelos *routers* no percurso

» *Limited broadcast address* – endereço de *broadcast* na rede onde o pacote é gerado; os pacotes com este endereço de destino não são encaminhados para fora desta rede, sendo ignorados pelos *routers* respectivos

Interface de loopback

- Interface de teste, num computador
  - » O datagrama não é passado à carta de rede
  - » *netid* → 127
  - » Endereço IP da interface → por convenção, usa-se normalmente o endereço 127.0.0.1
  - » Nome → *localhost*
- Um datagrama enviado para *localhost* não é visto na rede
- Permite que um cliente e um servidor na mesma máquina comuniquem usando TCP/IP

IP – subredes

- Divisão de uma rede em subredes
  - » A parte correspondente ao endereço de um *host* passa a ter o significado de "identificador de subrede (*subnetid*) + identificador de *host* (*hostid*)"
  - » Exemplo: uma LAN / VLAN associada a uma subrede IP
  - » Todos os computadores de uma subrede têm o mesmo *subnetid* (e o mesmo *netid*)
- Permite construir múltiplas redes numa empresa
  - » Esconde para o exterior as redes da empresa
  - » Do exterior as redes da empresa são vistas como uma rede única (*netid*)
- Os *routers* da empresa fazem encaminhamento interno usando informação de subrede
- Máscara de subrede
  - » Identifica bits que devem ser interpretados como *netid* + *subnetid*

IP – máscaras

	Binary Representation	**Dotted Decimal**
IP address	11000000.11100100.00010001.00111001	192.228.17.57
Subnet mask	11111111.11111111.11111111.11100000	255.255.255.224
Bitwise AND of address and mask (resultant network/subnet number)	11000000.11100100.00010001.00100000	192.228.17.32
Subnet number	11000000.11100100.00010001.001	1
Host number	00000000.00000000.00000000.00011001	25

Default subnet masks

	Binary Representation	**Dotted Decimal**
Class A default mask	11111111.00000000.00000000.00000000	255.0.0.0
Example Class A mask	11111111.11000000.00000000.00000000	255.192.0.0
Class B default mask	11111111.11111111.00000000.00000000	255.255.0.0
Example Class B mask	11111111.11111111.11111000.00000000	255.255.248.0

IP – máscaras

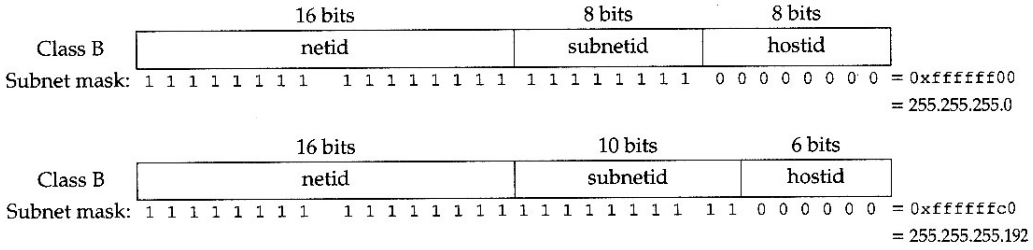

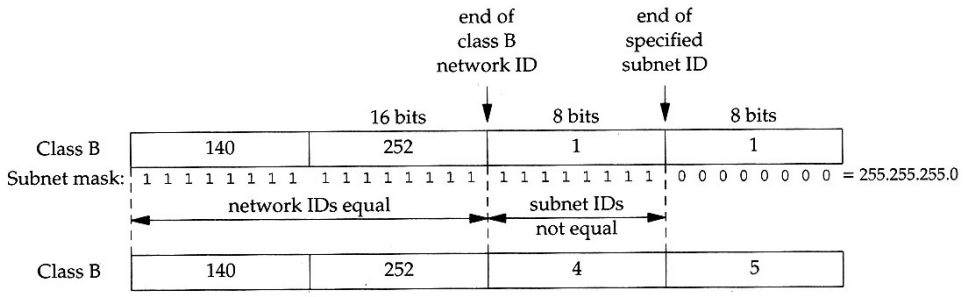

Constituição de subredes

No exemplo supõe-se que a rede 192.228.17.0/24 é dividida em oito subredes constituídas com base numa máscara comum de 27 bits (mas poderiam formar-se subredes com máscaras diferentes)

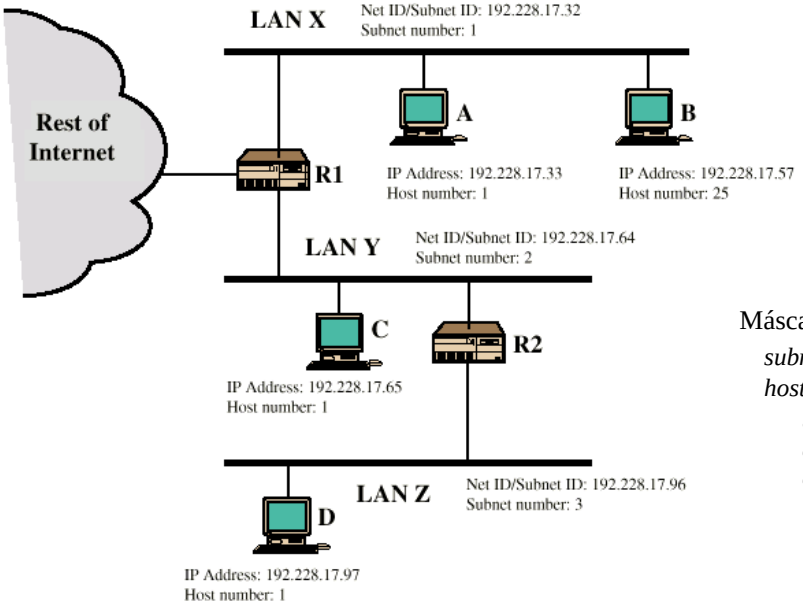

Exemplos de subredes

192.228.17.0/27
192.228.17.32/27
192.228.17.64/27
192.228.17.96/27
…..
192.228.17.224/27

Máscara de subrede – 27 bits

- *subnetid* – 3 bits (8 subredes)
- *hostid* – 5 bits
  - até 30 *hosts* / *routers* por subrede
  - *all 0* – identifica subrede
  - *all 1* – endereço de *broadcast*

Exemplo de subredes

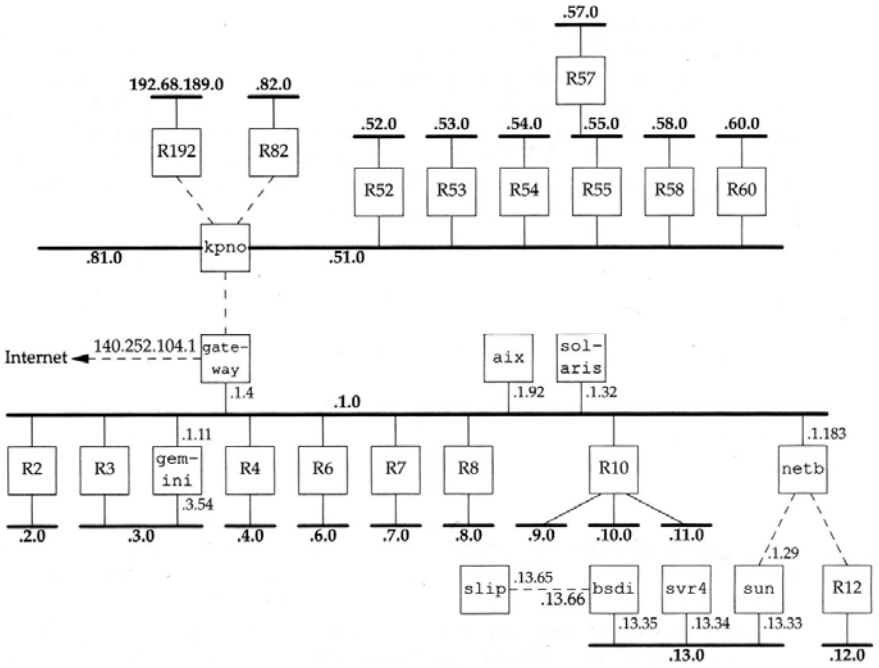

Rede exemplo

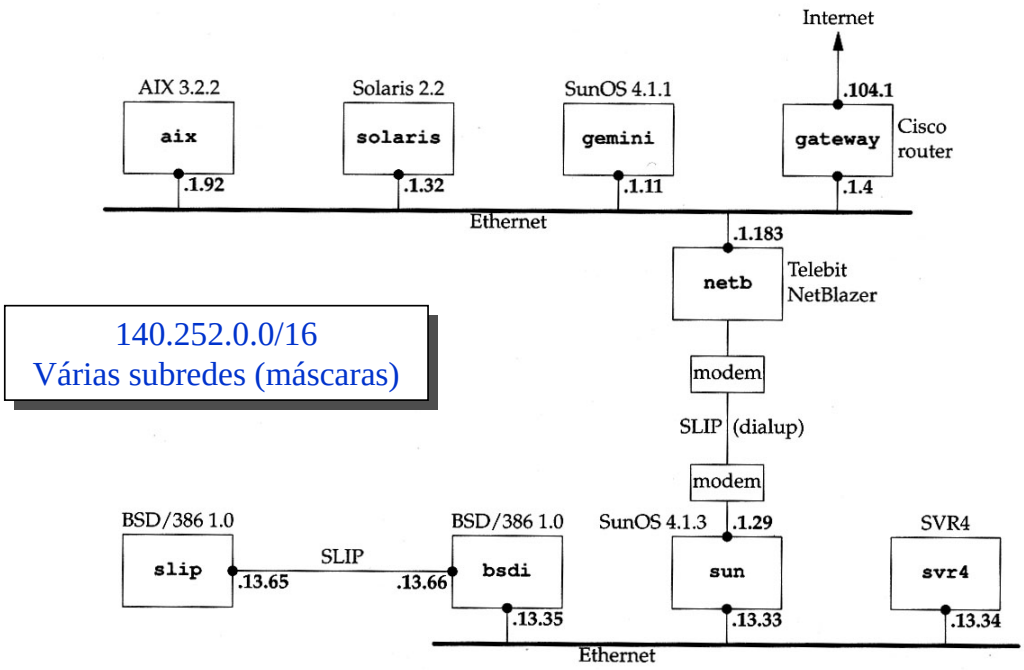

Tabelas de encaminhamento – conteúdo

- Cada sistema IP (*host* ou *router*) deve possuir uma tabela de encaminhamento; a tabela é relativamente simples no caso de um *host*, que pode ser configurado para funcionar, em certos casos, como *router*
  - » No caso de o sistema de destino estar directamente ligado ao *host* de origem (e.g., uma ligação ponto a ponto) ou numa rede partilhada (e.g., uma LAN), os pacotes IP são enviados directamente para o destino
  - » Caso contrário, os pacotes são enviados pelo *host* de origem para um *router* (*next hop router*) na mesma rede – a existência de mais do que um *router* impõe que seja seleccionado um deles, de acordo com o destino dos pacotes
- Cada entrada de uma tabela de encaminhamento contém
  - » Um endereço IP, que pode ser um *host address* (*netid* + *hostid*) ou um *network address* (*netid*, *hostid* = 0) – estes casos são distinguidos por uma *flag* H
  - » A indicação de uma rota, que pode ser indirecta (endereço IP de um *next hop router*) ou directa (endereço IP de uma interface local) – estes casos são distinguidos por uma *flag* G
  - » Interface de rede à qual o datagrama deve ser passado

Tabelas de encaminhamento – pesquisa

- Para encaminhar um pacote, a tabela é pesquisada com o objectivo de encontrar
  - » Uma entrada que seja igual ao endereço de destino do pacote (*netid* + *hostid*)
    - – Ligações ponto a ponto são um exemplo deste caso
  - » Uma entrada que seja igual ao *netid* de destino, no caso de o passo anterior não ter sucesso
    - – Todas as máquinas numa LAN são cobertas por este caso
  - » Uma entrada por omissão (*default*), no caso de não existir qualquer entrada que satisfaça os critérios anteriores
- Se for encontrada uma entrada que satisfaça uma das condições, o pacote é enviado de acordo com o especificado nessa entrada (*flag* G)
  - » Para um *next hop router* – o endereço IP do pacote é o da máquina de destino, mas o endereço de nível 2 (trama) é o do *next hop router* (e.g., um endereço MAC numa LAN)
  - » Para um destino directamente acessível – o endereço IP do pacote e o endereço de nível 2 (trama) são endereços da máquina de destino
- Se não for satisfeita qualquer das condições (o que significa que não existe uma entrada *default*), o pacote não é encaminhável, sendo por isso descartado

Endereçamento hierárquico – agregação de rotas

- O endereçamento hierárquico permite divulgação eficiente de informação de encaminhamento (agregação de rotas), conforme ilustrado
  - » O ISP 1 dispõe de endereços da rede 200.23.16.0/20 (200.23.16.0 a 200.23.31.255) e dividiu esse espaço para atribuição de endereços a 8 organizações (conforme ilustrado)
  - » O ISP2 dispõe de endereços da rede 199.31.0.0/16

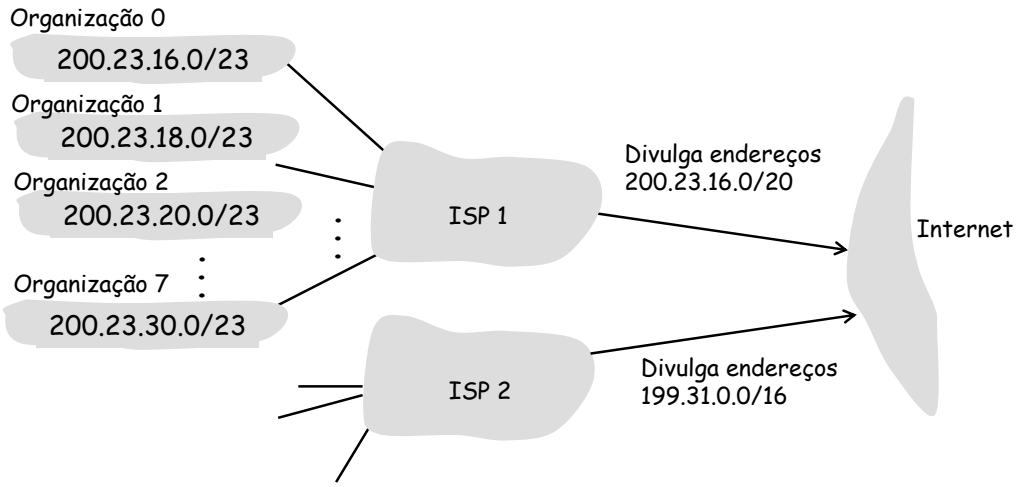

Endereçamento hierárquico – rotas específicas

- Pode ser necessário divulgar rotas específicas, no caso de a agregação de rotas não ser (ou deixar de ser) possível (no exemplo, a Organização 1 alterou o seu ISP, mas manteve os endereços originais)
- Esta situação determina que a selecção de uma entrada na tabela de encaminhamento (comparação do endereço de destino com os endereços presentes na tabela) deve ser feita com base na coincidência com o prefixo mais longo (*longest prefix matching*)

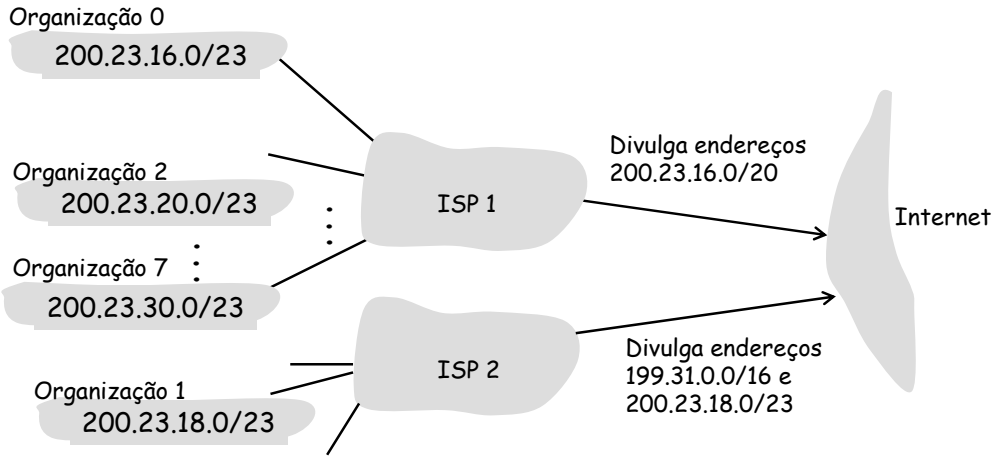

Tabelas de encaminhamento – exemplos

Host 140.252.13.34 (svr4) na rede 140.252.13.32/27

Destination	Gateway	Flags	Refcnt	Use	Interface
140.252.13.65	140.252.13.35	UGH	0	0	emd0
127.0.0.1	127.0.0.1	UH	1	0	lo0
default	140.252.13.33	UG	0	0	emd0
140.252.13.32	140.252.13.34	U	4	25043	emd0

Host / router 140.252.13.33 (sun) na rede 140.252.13.32/27

Destination	Gateway	Flags	Refcnt	Use	Interface
140.252.13.65	140.252.13.35	UGH	0	171	le0
127.0.0.1	127.0.0.1	UH	1	766	lo0
140.252.1.183	140.252.1.29	UH	0	0	sl0
default	140.252.13.183	UG	1	2955	sl0
140.252.13.32	140.252.13.33	U	8	99551	le0

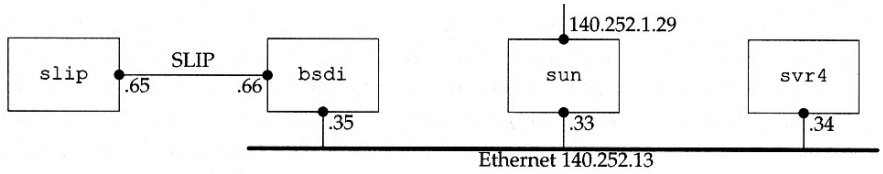

Tabela de encaminhamento – interpretação

Destination	Gateway	Flags	Refcnt	Use	Interface
140.252.13.65	140.252.13.35	UGH	0	0	emd0
127.0.0.1	127.0.0.1	UH	1	0	lo0
default	140.252.13.33	UG	0	0	emd0
140.252.13.32	140.252.13.34	U	4	25043	emd0

Host 140.252.13.34 (svr4) na rede 140.252.13.32/27 (*subnetid* – 3 bits; *hostid* – 5 bits)

Gateways 140.252.13.33 e 140.252.13.35

Flags

U *route Up*

G *route to a Gateway* (*next hop router*)
se omitido: rota directa; o endereço da *Gateway* é o endereço IP da interface local do *host* svr4

H *route to a Host* – o endereço IP de destino na tabela é um *host address* completo
se omitido: *route to a network* – o endereço IP de destino na tabela é um *network address*

Refcnt

Número de utilizações activas da rota (por exemplo ligações TCP estabelecidas)

Use

Número de pacotes enviados pela rota

Interface

Nome da interface local

Rota directa – endereços IP e MAC

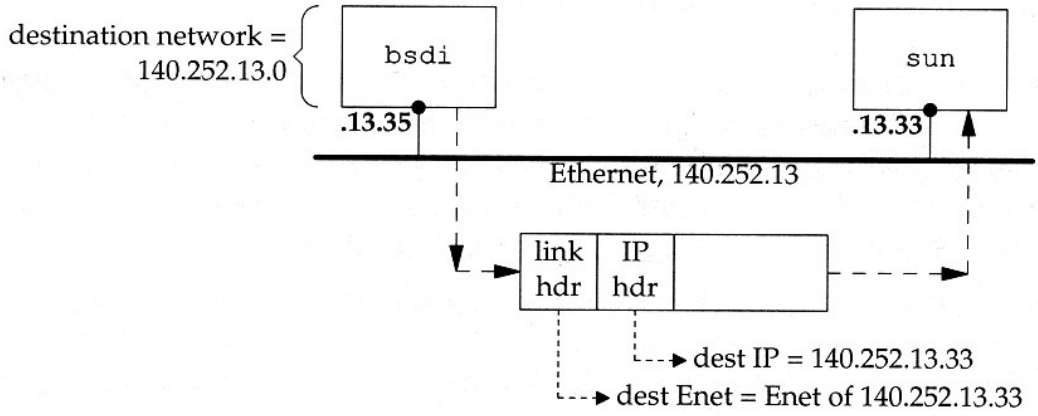

Rota indirecta – endereços IP e MAC

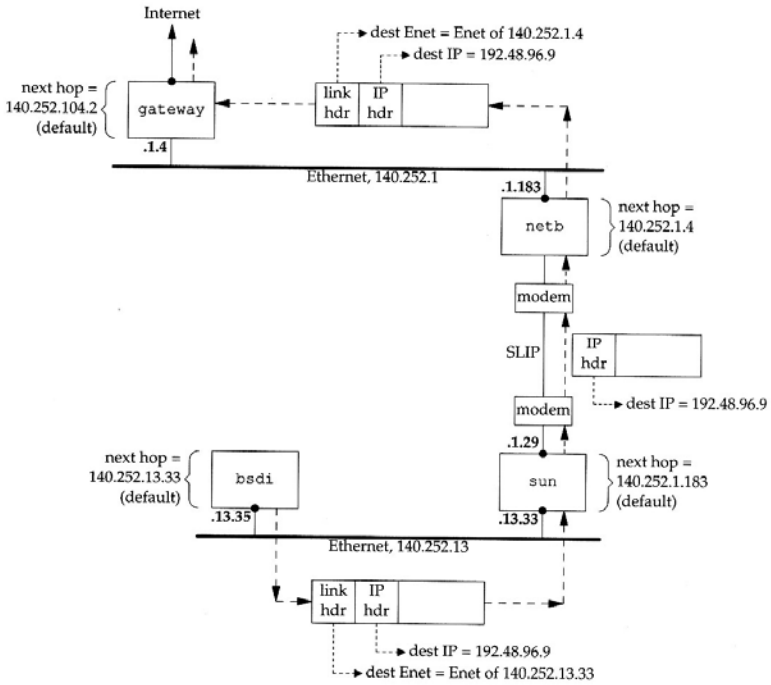

ARP – Address Resolution Protocol

- *Host* TCP/IP → endereço IP
- Carta de rede → endereço físico (*hardware*)
  - » Em LANs – endereço MAC
- ARP
  - » Mapeamento dinâmico
    - – Endereço IP ←→ endereço de *hardware*

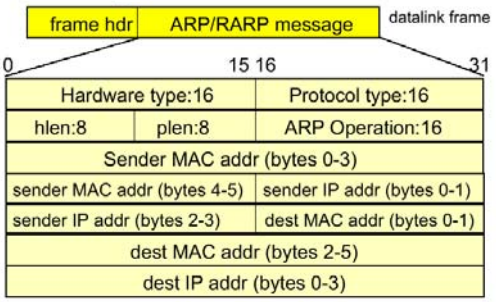

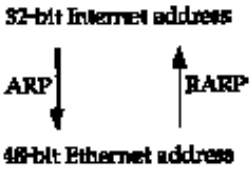

- **hardware type : Ethernet=1 ARCNET=7, localtalk=11**
- **protocol type : IP=0x800**
- **hlen : length of hardware address, Ethernet=6 bytes**
- **plen : length of protocol address, IP=4 bytes**
- **ARP operation : ARP request = 1, ARP reply = 2**
  RARP request = 3, RARP reply = 4

ARP Request e ARP Reply

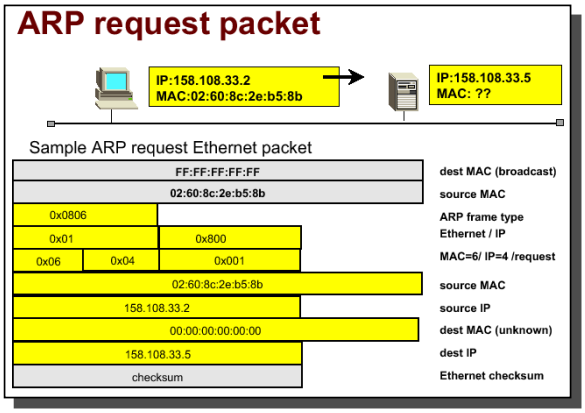

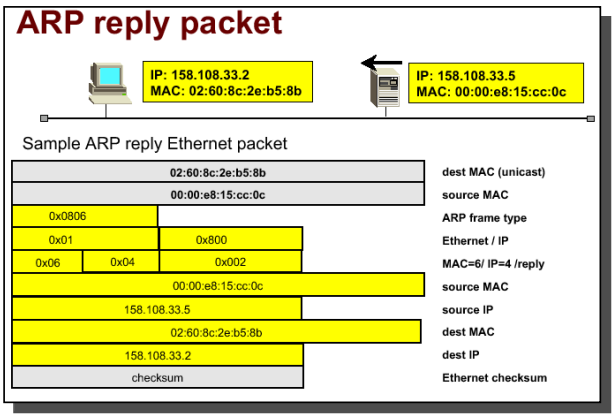

ARP Exemplo

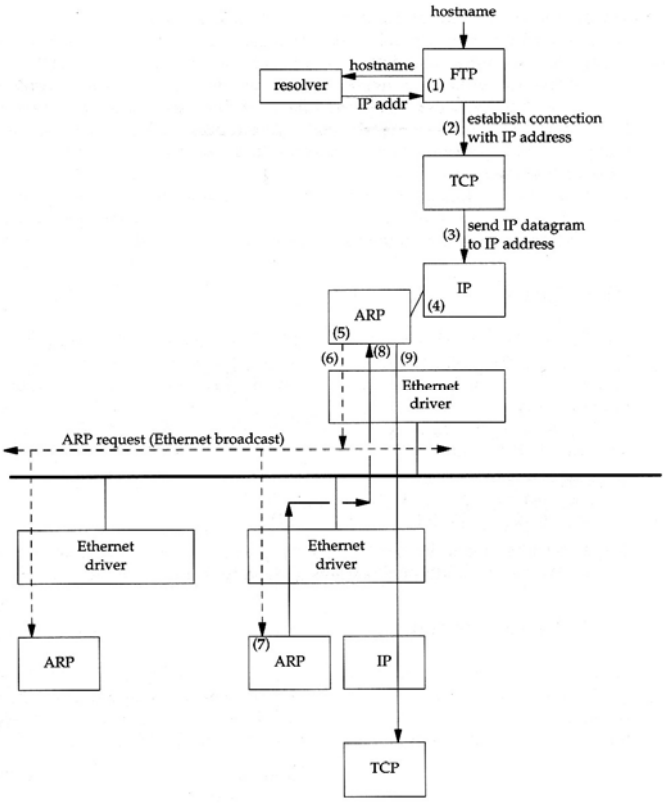

Proxy ARP

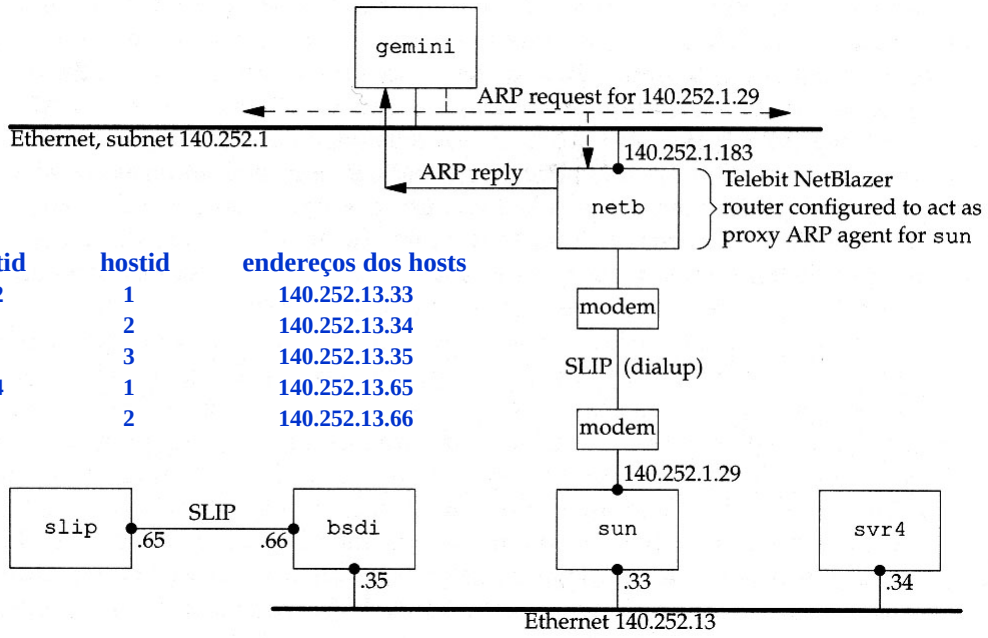

net + subnetid	hostid	endereços dos hosts
140.252.13.32	1	140.252.13.33
	2	140.252.13.34
	3	140.252.13.35
140.252.13.64	1	140.252.13.65
	2	140.252.13.66

ICMP – Internet Control Message Protocol

- O ICMP está descrito no RFC 792
- O ICMP transfere mensagens de controlo
  - » Entre um *host* e um *router* ou entre dois *hosts*
  - » As mensagens ICMP indicam problemas relacionados com o transporte de datagramas
- Mensagens ICMP são encapsuladas em datagramas IP (não fiável)

ICMP – tipos de mensagem

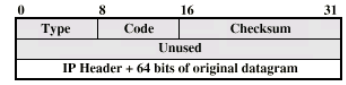

(a) Destination Unreachable; Time Exceeded; Source Quench

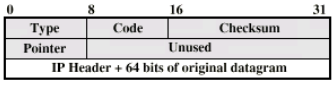

(b) Parameter Problem

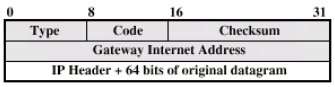

(c) Redirect

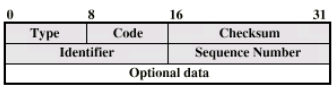

(d) Echo, Echo Reply

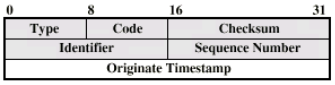

(e) Timestamp

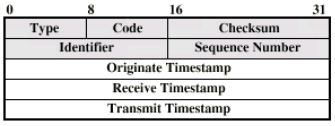

(f) Timestamp Reply

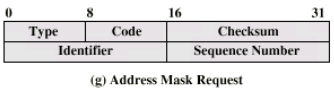

(g) Address Mask Request

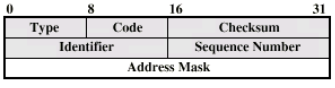

(h) Address Mask Reply

Type	Code	Description
0	0	echo reply (ping)
3	0	dest. network unreachable
3	1	dest host unreachable
3	2	dest protocol unreachable
3	3	dest port unreachable
3	6	dest network unknown
3	7	dest host unknown
4	0	source quench (congestion control - not used)
5		Redirect
8	0	echo request (ping)
9	0	route advertisement
10	0	router discovery
11	0	TTL expired
12	0	bad IP header

Ping

- ICMP *Echo* / *Echo Reply*
- *Echo*
  - » Identificador
    - – Pid do cliente
  - » Sequência
    - – Começa em 0
  - » Dados
    - – Tempo de envio
- *Echo Reply*
  - » Resposta enviada por servidor *ping* (*kernel*)
  - » Ecoa tudo

```
sun% ping gemini

PING gemini: 56 data bytes
64 bytes from gemini (140.252.1.11): icmp_seq=0. time=373. ms
64 bytes from gemini (140.252.1.11): icmp_seq=l. time=360. ms
64 bytes from gemini (140.252.1.11): icmp_seq=2. time=340. ms
64 bytes from gemini (140.252.1.11): icmp_seq=3. time-320. ms
64 bytes from gemini (140.252.1.11): icmp_seq=4. time=330. ms
64 bytes from gemini (140.252.1.11): icmp seq=5. time=310. ms
64 bytes from gemini (140.252.1.11): icmp seq=6. time==290. ms
64 bytes from gemini (140.252.1.11): icmp_seq-7. time=300. ms
64 bytes from gemini (140.252.1.11): icmp_seq=8. time=280. ms
64 bytes from gemini (140.252.1.11): icmp_seq=9. time=290. ms
64 bytes from gemini (140.252.1.11): icmp_seq=10. time=300. ms
64 bytes from gemini (140.252.1.11): icmp_seq=ll. time=280. ms
--gemini PING Statistics--
12 packets transmitted, 12 packets received, 0% packet loss
round-trip (ms) min/avg/max = 280/314/373
```


Traceroute

- Permite determinar rotas entre máquinas
- Usa datagramas IP e mensagens de erro ICMP
  - » *Traceroute* começa por enviar um datagrama para o destino pretendido, com TTL = 1 e porta UDP inexistente

    O primeiro *router*
    - – Decrementa valor de TTL → elimina datagrama (TTL = 0)
    - – Envia mensagem de erro ICMP (*time exceeded*) para origem
    - – *Traceroute* obtém a sua identificação
  - » *Traceroute* envia novo datagrama para o mesmo destino, com TTL = 2 e porta UDP inexistente

    O segundo *router* repete o processo e assim sucessivamente
  - » *Traceroute* continua a enviar datagramas com TTL crescente até se atingir a máquina de destino

    A máquina de destino, após receber o datagrama, envia
    - – Mensagem de erro ICMP – *port unreachable*
    - – *Traceroute* obtém a sua identificação

Traceroute – exemplo

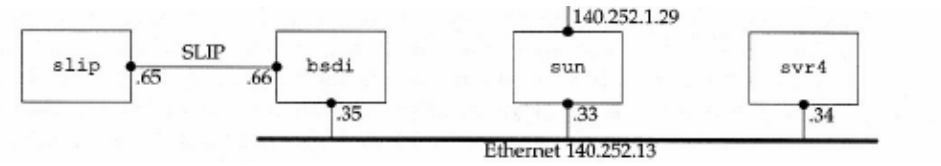


```
svr4% traceroute slip

traceroute to slip (140.252.13.65), 30 hops max. 40 byte packets
1 bsdi (140.252.13.35) 20 ms 10 ms 10 ms
2 slip (140.252.13.65) 120 ms 120 ms 120 ms
```

```
slip% traceroute svr4

traceroute to svr4 (140.252.13.34), 30 hops max, 40 byte packets
1 bsdi (140.252.13.66) 110 ms 110 ms 110 ms
2 svr4 (140.252.13.34) 110 ms 120 ms 110 ms
```


Evolução – IPv4 e IPv6

- Versões
  - » IPv1-v3 → fora de uso
  - » IPv4 → versão de uso generalizado
  - » IPv5 → orientado às ligações (nunca foi implementado)
  - » IPv6 → proposto para substituir o IPv4, devido às limitações deste
- Limitações do IPv4
  - » Endereçamento
    - – Espaço de endereçamento limitado face aos requisitos actuais (número de redes e *hosts*)
    - – Dois níveis de endereçamento (rede, *host*) desperdiça endereços
  - » Não suporta requisitos de novos tipos de serviços (QoS, reserva de recursos)
  - » Necessárias soluções para atenuar estes problemas (e.g., CIDR, NAT)
- Melhorias introduzidas pelo IPv6
  - » Endereçamento
    - – Maior espaço de endereçamento (128 bits), sem classes
    - – *Multicast* – mais versátil e escalável
  - » Melhor suporte de Qualidade de Serviço (QoS)
    - – Suporta o conceito de fluxo de pacotes (campo *flow label* no cabeçalho dos pacotes)
  - » Autoconfiguração (*plug and play*)
  - » Encaminhamento
  - » Segurança (cifragem de dados, autenticação)

IPv6 – cabeçalhos

- *Version*
  - » 6 (IPv6)
- *Traffic Class*
  - » Classes / prioridades
- *Flow Label*
  - » Suporte de QoS, reserva de recursos
- *Payload length*
  - » Cabeçalhos secundários + dados (não inclui tamanho do cabeçalho principal)
- *Hop Limit*
  - » Idêntico a TTL (IPv4)
- *Next Header*
  - » Identifica o póximo cabeçalho (extensão)
- *Source Address* (SA)
- *Destination Address* (DA)
- *Extension headers* (opcionais)
  - » Número variável (após campos SA e DA)

Cabeçalho principal

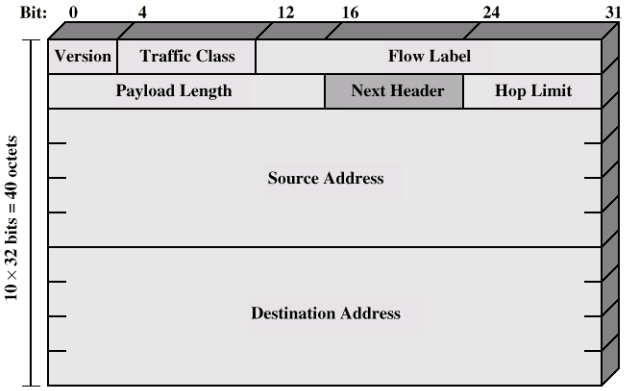

IPv6 – cabeçalhos de extensão

- O cabeçalho IPv6 pode ser seguido de cabeçalhos secundários (de extensão)
  - » *Hop-by-Hop options*
    - – Informação para os *routers* no percurso
  - » *Destination options*
    - – Informação adicional para o nó de destino (não acedida pelos *routers*)
  - » *Routing*
    - – Lista de nós a visitar pelo pacote (semelhante a *Source Routing* do IPv4)
  - » *Fragmentation*
    - – Gestão do processo de fragmentação
  - » *Authentication*
    - – Validação da identidade do emissor
  - » *ESP (Encrypted Security Payload)*
    - – Informação sobre o tipo utilizado de cifragem do conteúdox

Exemplo

- Cada cabeçalho identifica o seguinte

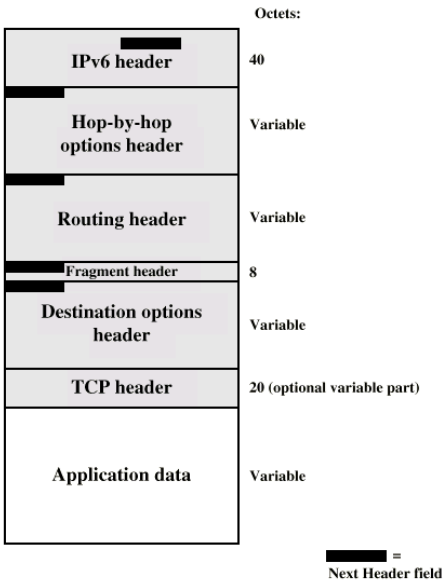

Endereços IPv6

- Endereços com 128 bits, atribuídos a interfaces
  - » Uma interface pode ter múltiplos endereços
- Tipos de endereços
  - » *Link-Local*
    - – Usado para comunicação entre *hosts* na mesma LAN ou ligação (*link*)
    - – O endereço é construído a partir do endereço MAC
    - – Os *routers* não encaminham pacotes com endereços de destino deste tipo
  - » *Global Unicast*
    - – Endereço específico (individual) atribuído a uma interface, com significado global, constituído por um prefixo de rede e um identificador do computador
    - – A estruturação de prefixos permite agregação de redes (reduzindo o número de entradas nas tabelas de encaminhamento)
  - » *Anycast*
    - – Endereço de grupo (associado a um conjunto de interfaces)
    - – O pacote é entregue a qualquer interface do grupo (mas apenas a uma)
  - » *Multicast*
    - – Endereço de grupo (associado a um conjunto de interfaces)
    - – O pacote é entregue a todas as interfaces do grupo

Representação de endereços IPv6

- Os endereços IPv6 (16 octetos) são representados por 32 símbolos hexadecimais, em grupos de 4 símbolos (16 bits) separados por :
  - » Exemplo – 47CD:1234:3200:0000:0000:B792:0428
- Formato comprimido (permite suprimir grupos de 0's)
  - » Exemplo – FF01:0:0:0:0:0:0:43 é representado por FF01::43
    - » No exemplo 0 é uma abreviatura de 0000 e 43 é uma abreviatura de 0043
- Compatibilidade com IPv4
  - » Exemplo – 0:0:0:0:0:0:13.1.68.3 ou ::13.1.68.3
- Endereço de *loopback*
  - » ::1
- O prefixo de rede é descrito como em IPv4 (/)
  - » FEDC:BA98:7600::/40 (prefixo com 40 bits)

UDP – User Datagram Protocol

- Descrito no RFC 768
- Características
  - » Protocolo de transporte, não orientado às conexões (*connectionless*)
  - » Serviço de entrega de pacotes não fiável
  - » Usa serviços IP
  - » Multiplexagem de vários fluxos UDP sobre o mesmo endereço IP

UDP Header

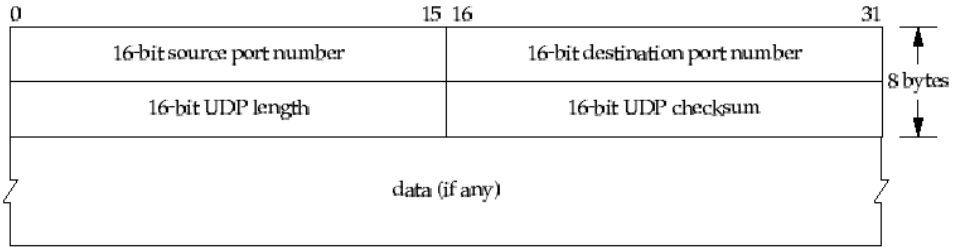

UDP Length – comprimento total do pacote

UDP Checksum – opcional

TCP – Transmission Control Protocol

- Descrito no RFC 793
- Principais características
  - » Os dados da Aplicação são vistos como um *stream* de octetos e organizados em segmentos
  - » Protocolo orientado às conexões
    - – Estabelecimento de conexão TCP – *three way handshake*
    - – As conexões TCP são *full-duplex*
  - » O TCP assegura um serviço extremo-a-extremo fiável, sobre um suporte não fiável (IP)
    - – Confirmação positiva (ACK) de blocos de segmentos contíguos
    - – Recupera de perdas de segmentos por meio de retransmissões, após *time-out*
    - – Entrega ordenada dos dados à aplicação
  - » Controlo de fluxo e de congestionamento
    - – Mecanismo de janela (em octetos)
  - » Multiplexagem de várias conexões TCP sobre o mesmo endereço IP

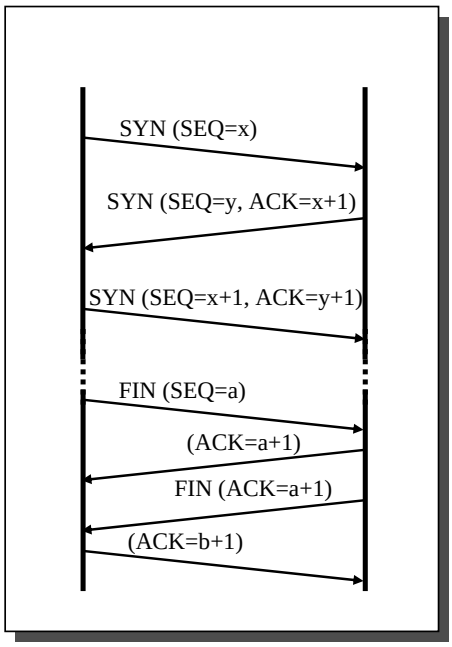

TCP – cabeçalho

Source Port – porta de origem

Destination Port – porta de destino

Sequence Number – identifica, no fluxo do emissor, a sequência de octetos enviada (número do primeiro octeto do segmento)

Acknowledgement Number – corresponde ao número do octeto que se espera receber

HLEN – comprimento do cabeçalho TCP (em palavras de 32 bits)

URG – informa se o campo *Urgent Pointer* deve ser interpretado

ACK – informa se o campo *Ack Nbr* é válido

PSH – permite forçar o envio imediato de dados (sem esperar dados adicionais)

RST – usado para reinicializar uma conexão

SYN – permite estabelecer uma conexão

FIN – permite terminar uma conexão

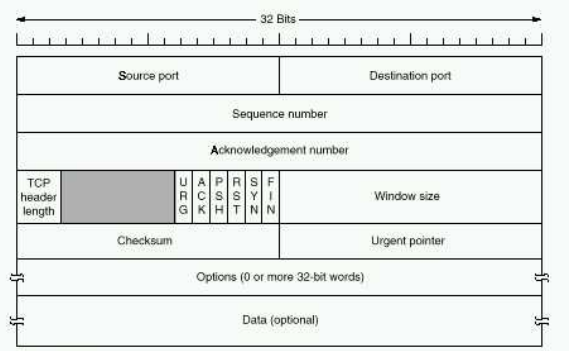

The TCP header.

Window Size – número de octetos que o par (*peer*) da comunicação pode enviar sem confirmação (controlo de fluxo)

Checksum – abrange o cabeçalho, os dados e o pseudo-cabeçalho

Controlo de fluxo e de congestionamento

- Quando dois sistemas (*hosts*) comunicam através duma rede, o receptor deve poder regular o débito do emissor – este controlo é realizado extremo-a-extremo, tipicamente na camada de Transporte, sendo o TCP um exemplo de referência
- Por outro lado, o débito de um fluxo TCP que a rede é capaz de sustentar depende da capacidade das ligações ao longo do percurso (e respectiva carga) e dos recursos de transmissão que é possível atribuir ao fluxo (em competição com outros fluxos)
- O controlo de fluxo pelo receptor torna-se efectivo quando a rede pode suportar o débito da fonte, devendo este convergir para o valor do débito permitido pelo receptor
  - » O controlo de fluxo extremo-a-extremo é influenciado pelo comportamento dinâmico da rede – o atraso de ida e volta (*round trip time*) e o débito dos fluxos dependem de variações quer do tráfego submetido à rede quer do estado da rede
- Se o estrangulamento se dever à rede e não ao receptor (devido à capacidade limitada de algumas ligações ou da sobrecarga de nós), o débito é na prática limitado pela rede
  - » Caso os emissores não sejam capazes de adaptar o débito às condições da rede, ocorrerá perda de pacotes quando se exceda a capacidade dos *buffers* nalgum nó
  - » Em caso de congestionamento são necessárias medidas adicionais e os emissores devem reduzir o débito com base em informação implícita ou explícita do estado da rede
- Os mecanismos de controlo de fluxo devem regular os débitos de fontes de tráfego de modo que convirjam para os débitos de serviço suportados pelos receptores e pela rede

TCP – janelas de controlo

- O TCP realiza controlo de congestionamento extremo-a-extremo, por meio duma janela dinâmica que é actualizada com base na janela do receptor e em informação implícita do estado da rede
- Em primeiro lugar o emissor deve respeitar a janela anunciada pelo receptor
  - » Para um dado número de pacotes em trânsito, cada ACK recebido indica que um pacote deixou a rede e um novo pacote pode ser enviado (rotação da janela)
  - » Uma vez que o ritmo a que os ACKs são recebidos (e, por isso, novos pacotes podem ser enviados) é determinado pelo estado da rede, o TCP é *self-clocking*
- Contudo, a dinâmica da rede é complexa – o número de sessões activas e a capacidade disponível variam no tempo e a rede pode ficar congestionada
- O TCP deixa que cada fonte determine de forma independente a capacidade que pode usar e adapte o seu débito ao estado da rede, por meio duma janela de congestionamento dinâmica (*congestion window*) actualizada com base na percepção do nível de congestionamento actual da rede
- A janela de congestionamento (*cwnd*) representa controlo de fluxo realizado pelo emissor, enquanto o receptor impõe controlo de fluxo por meio da janela que anuncia (*rwnd*) – a janela de transmissão é o menor dos dois valores

current sender window = min (cwnd, rwnd)

TCP – auto sincronização (self-clocking)

- P_b representa o menor espaçamento entre pacotes de dados na ligação mais lenta (*bottleneck*), pelo que, no receptor, $P_r = P_b$
- Assumindo o mesmo tempo de processamento para todos os pacotes, o espaçamento entre ACKs gerados pelo receptor é $A_r = P_r = P_b$ e, considerando condições idênticas no percurso inverso (e que ACKs ocupam menos largura de banda que pacotes de dados), então $A_s = A_b = A_r = P_b$
- Se, após um *burst* inicial, só forem enviados novos pacotes de dados após recepção de ACKs, o espaçamento de pacotes no emissor coincide com o tempo entre pacotes na ligação mais lenta

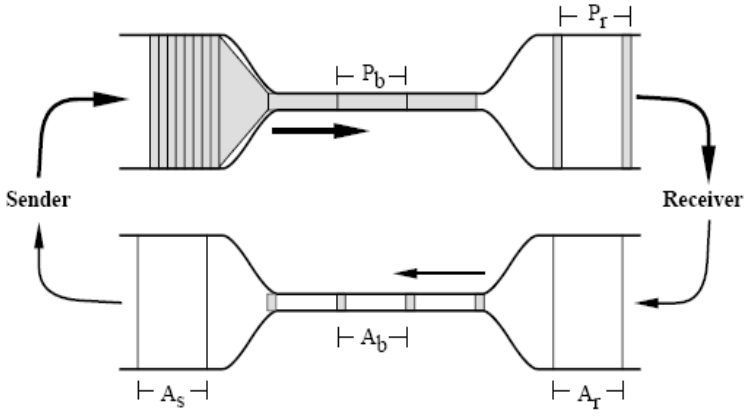

Extraído de Van Jacobson, "Congestion Avoidance and Control", Proc. SIGCOMM'88, August 1988

TCP – algoritmos de controlo

- O TCP implementa quatro algoritmos, habitualmente combinados em dois grupos – *slow start* e *congestion avoidance* por um lado, e *fast retransmit* e *fast recovery* por outro

- O emissor TCP mantém a informação seguinte (por conexão)
  - O estado de duas janelas (*cwnd* e *rwnd*) – o mínimo destes valores é a sua janela actual (*sender window*)
  - O valor de um limiar designado *slow start threshold* (*ssthresh*), que permite decidir se deve ser usado *slow start* (janela abaixo do limiar) ou *congestion avoidance* (janela acima do limiar)
  - Uma variável *FlightSize*, que indica a quantidade de dados enviados mas não confirmados (o seu valor é limitado pelo tamanho actual da janela)

- Na descrição dos algoritmos e actualização das variáveis considera-se também o tamanho máximo dos segmentos que o emissor pode transmitir – *Sender Maximum Segment Size* (SMSS)

TCP – slow start e congestion avoidance

- O TCP assume que a perda de um segmento se deve a congestionamento da rede e o emissor usa dois indicadores para o efeito – *time-out* e recepção de ACKs duplicados, que desencadeiam acções de recuperação diferentes
- Após o estabelecimento de uma conexão ou ocorrência de *time-out*, o valor de *cwnd* é fixado em um segmento (SMSS) e o emissor entra no modo *slow start*
- No modo *slow start*, *cwnd* é incrementado no máximo de SMSS *bytes* por cada ACK recebido – isto significa que o valor de *cwnd* duplica por cada *round trip time* (*exponential increase*)
- Quando *cwnd* atingir o valor actual de *ssthresh*, o emissor comuta para o modo *congestion avoidance* e *cwnd* é incrementado de um segmento (SMSS) por cada *round trip time* (*linear increase*)
  - » Para o efeito, *cwnd* pode ser actualizado por cada novo ACK recebido (não duplicado) usando a fórmula

$$cwnd = cwnd + SMSS * SMSS / cwnd$$

- *Congestion avoidance* continua até ser detectado congestionamento
  - » Ao aumentar *cwnd*, o TCP está a "testar" a rede (*probing*) até que comecem a ocorrer perdas, altura em que a janela de congestionamento deve ser reduzida

Evolução da janela de congestionamento

- *Slow start* – aumento exponencial

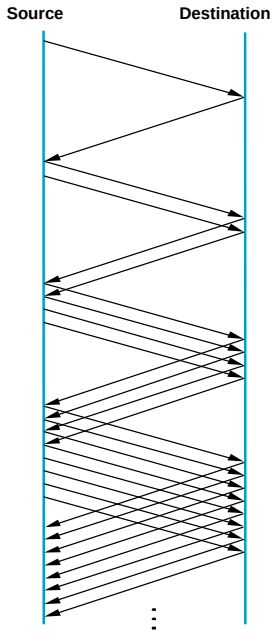

- *Congestion avoidance* – aumento linear

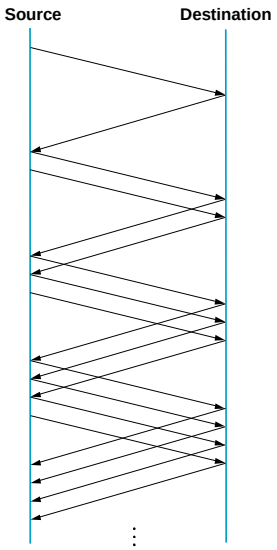

TCP – recuperação após congestionamento

- A ocorrência de *time-out* e a recepção de ACKs duplicados são usados como indicação de perda de pacotes e, portanto, para desencadear acções de recuperação
  - » O receptor TCP deve enviar um ACK (duplicado) quando receber um pacote fora de ordem
- Se ocorrer um *time-out* são feitas as actualizações seguintes (*multiplicative decrease*)
  - » O valor de *ssthresh* é alterado como estabelecido no RFC 2581 (actualizado pelo RFC 5681)

$$ssthresh = max\ (FlightSize\ /\ 2,\ 2 * SMSS)$$

  - » O valor de *cwnd* é reduzido a um segmento (SMSS)
  - » O emissor é colocado no estado *slow start*
- A recepção de três ACKs duplicados (sem que ocorra *time-out*) é uma indicação forte da ocorrência de perda de um pacote mas também que o receptor continuou a receber novos pacotes – neste caso realiza-se *fast retransmit* e *fast recovery* (e não *slow start*)
  - » Após recepção do terceiro ACK duplicado, *ssthresh* é actualizado com o valor acima referido
  - » O segmento perdido é retransmitido e actualiza-se *cwnd* = *ssthresh* + 3 * SMSS (a janela de congestionamento é aumentada artificialmente com os três segmentos que deixaram a rede)
  - » Por cada novo ACK duplicado recebido, *cwnd* é aumentado de um valor igual a SMSS (corresponde ao novo segmento que deixou a rede) e é transmitido um novo segmento, se tal for permitido pelo valor actualizado da janela – *min* (*cwnd*, *rwnd*)
  - » Após recepção de um ACK que efectivamente confirma dados, *cwnd* assume um valor igual ao *ssthresh* actualizado no início da recuperação (reduzindo o aumento artificial da janela)

TCP – slow start e congestion avoidance