Redes de Computadores

O Protocolo TCP

Departamento de Informática da
FCT/UNL

Objetivos do Capitulo

- O protocolo IP na Internet não garante a entrega de todos os pacotes, e também não garante que sejam entregues na ordem de emissão
- Ao nível transporte é necessário compensar essas deficiências providenciando um serviço de comunicações fiáveis
- É esse o papel do protocolo TCP cujas propriedades e funcionamento base serão estudadas nesta lição
- O protocolo TCP é um dos mais importantes da Internet

There's an old maxim that says, "Things that work persist," which is why there's still Cobol floating around.

Vinton G. Cerf

(one of the inventors of TCP
and also known as the
"father of the Internet")

TCP - Transmission Control Protocol

- Serviço de comunicação entre dois computadores
  - Canal lógico dedicado entre duas aplicações
  - Sequência ordenada e fiável de bytes
  - Transmite simultaneamente nos dois sentidos
- Totalmente implementado pelos computadores, nos sistema de operação (End-to-End)
  - Retransmissão dos pacotes perdidos
  - Colocação dos dados por ordem e supressão dos duplicados
  - Controlo de fluxos para evitar "afogar" o recetor
  - Controlo de saturação para adaptar a velocidade de transmissão à capacidade da rede

TCP é um Protocolo End-to-End

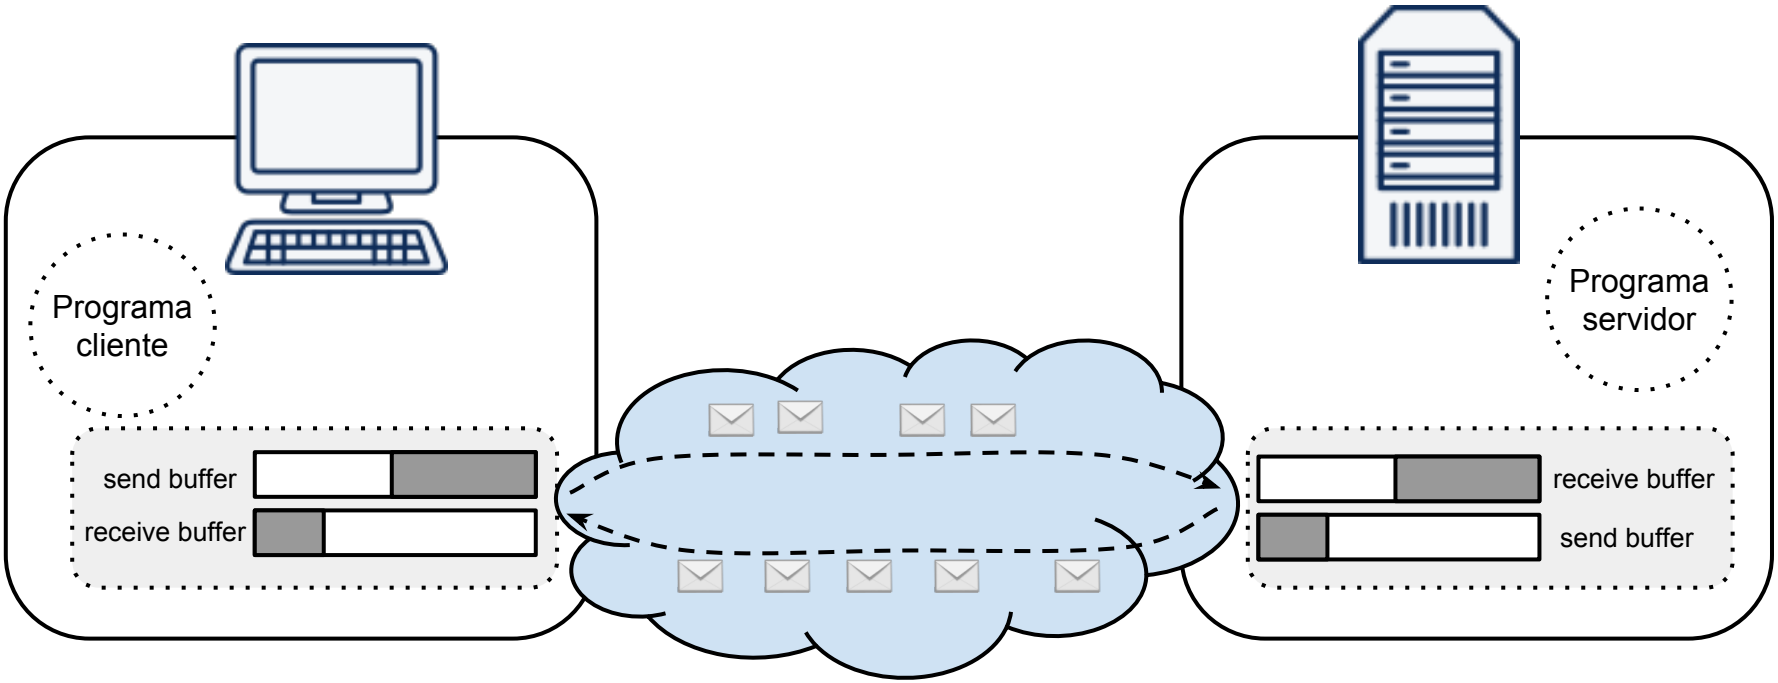

Semântica de uma Conexão TCP

- Conexão bi-direccional
- Transmite sequências de bytes de dimensão arbitrária, isto é, não tem noção de mensagem (mas a aplicação pode)
- Transmissão fiável dos dados
- Vistos pela aplicação, as *sockets* TCP são semelhantes a ficheiros ou *pipes*, mas a funcionalidade é distribuída a quaisquer dois computadores
- Abertura assimétricas das conexões: geralmente o servidor prepara-se para aceitar conexões, os clientes estabelecem as conexões
- Conexões TCP estabelecidas entre (endereço IP, porta) e (endereço IP, porta)

Conexão TCP = (IP_1,$Porta_1$, IP_2, $Porta_2$)

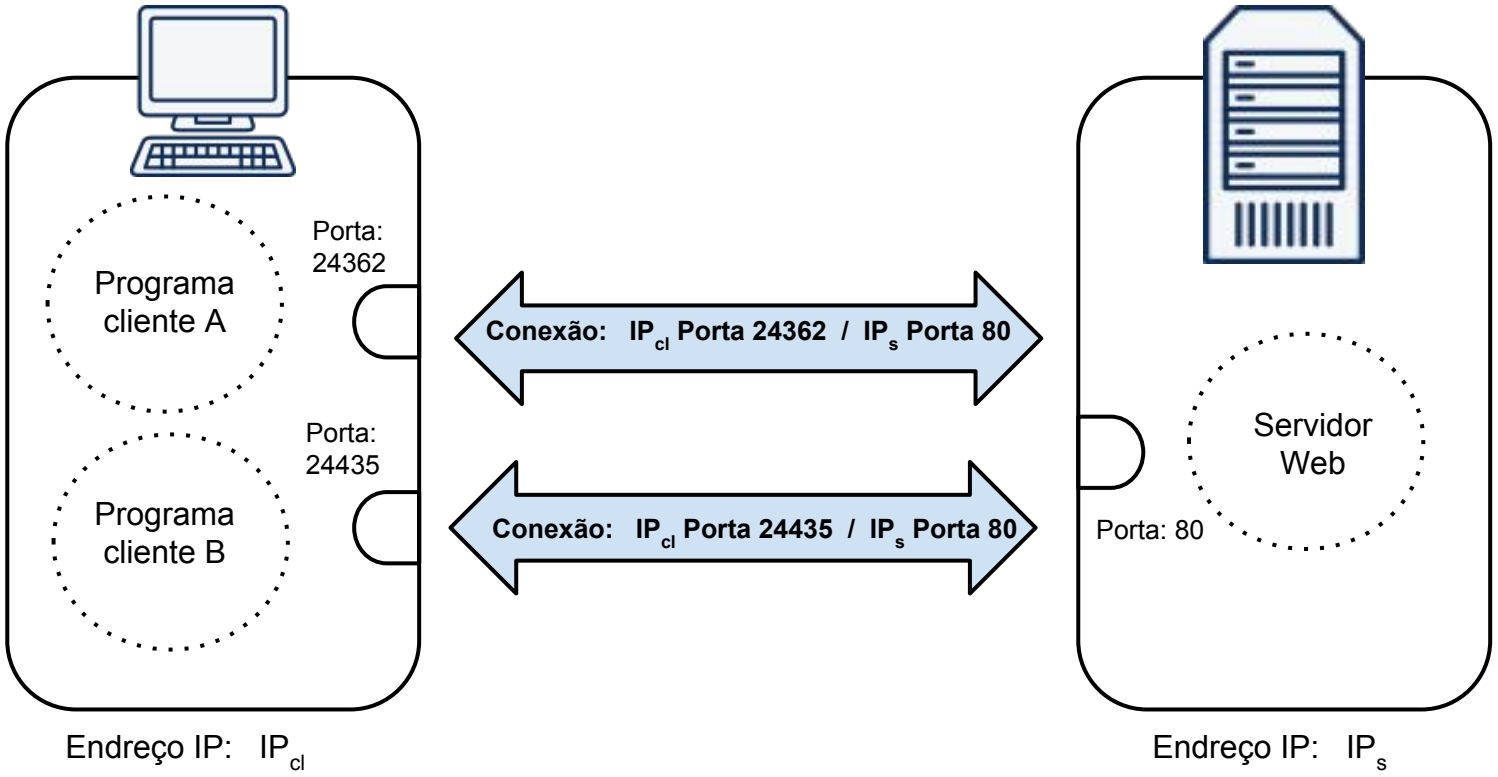

Segmento TCP

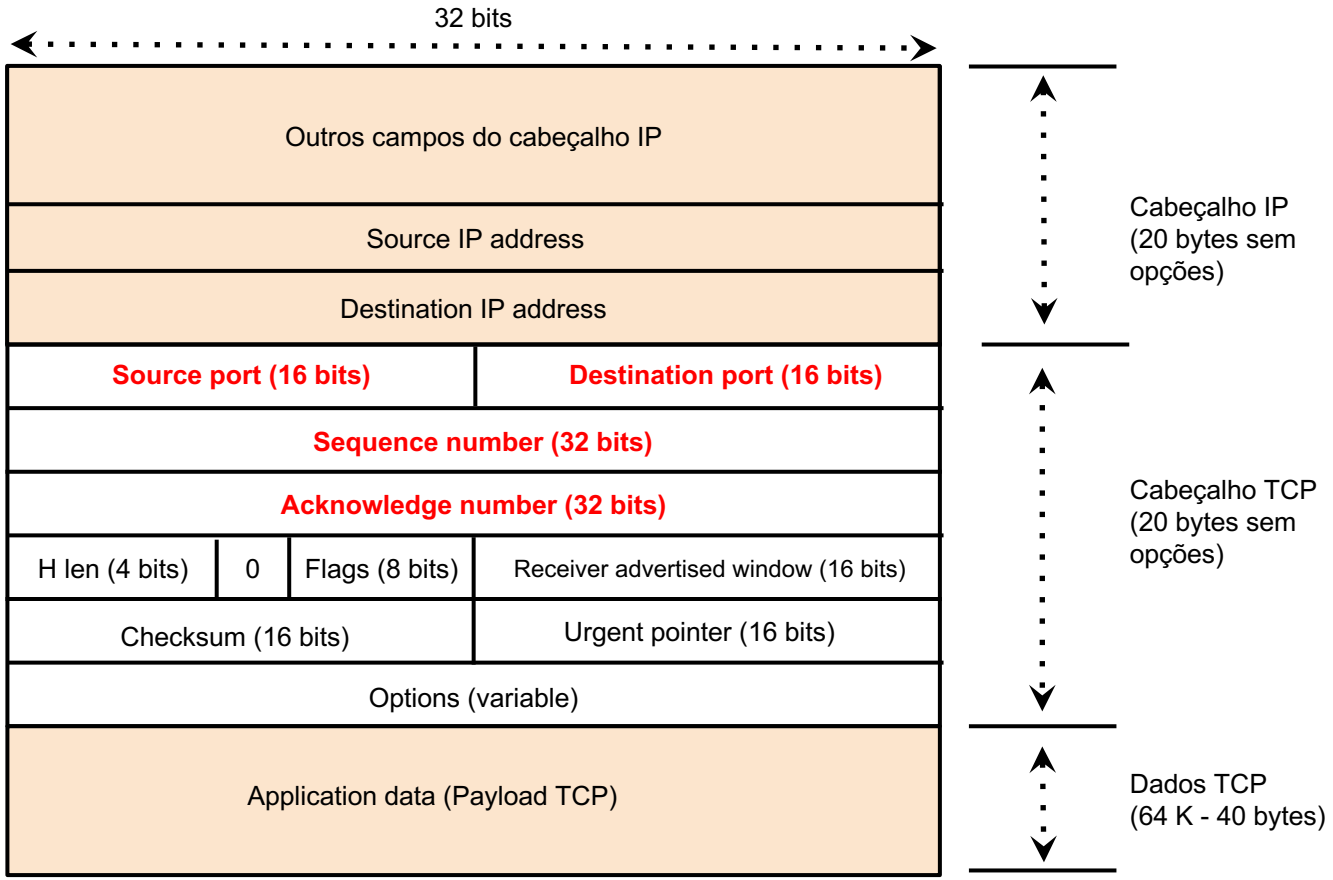

Dimensão dos segmentos TCP

- Um segmento pode ter uma dimensão arbitrária de 0 a MSS (MSS - Maximum Segment Size) bytes
- A dimensão máxima dos segmentos de uma conexão é negociada entre os dois extremos de forma a tentar que os segmentos caibam dentro de um pacote IP (sem fragmentação). Alguns valores típicos são 1460 bytes, 512, ...
- Geralmente cada extremo indica inicialmente aquele que julga ser o MSS mais adequado. Será selecionada a dimensão mais baixa das duas propostas
- Tal não garante que o MSS não provoca segmentação dado não se saber o MTU (Maximum Transfer Unit) de todos os canais intermédios
- Existe um protocolo que permite a ambas as partes determinarem o MSS mais adequado com base no uso de ICMP

Maximum Segment Size (MSS)

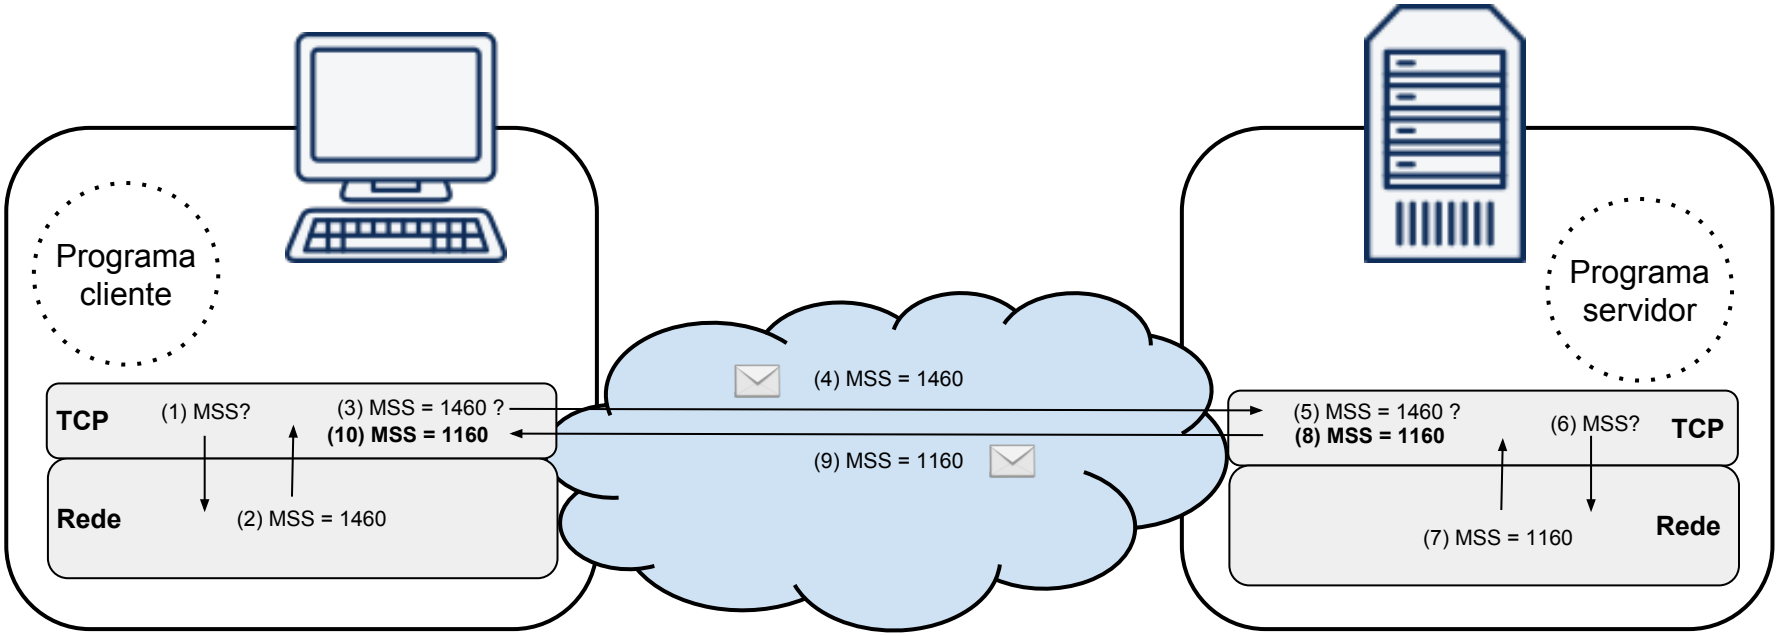

Uma Conexão TCP Transporta Sequências de Bytes

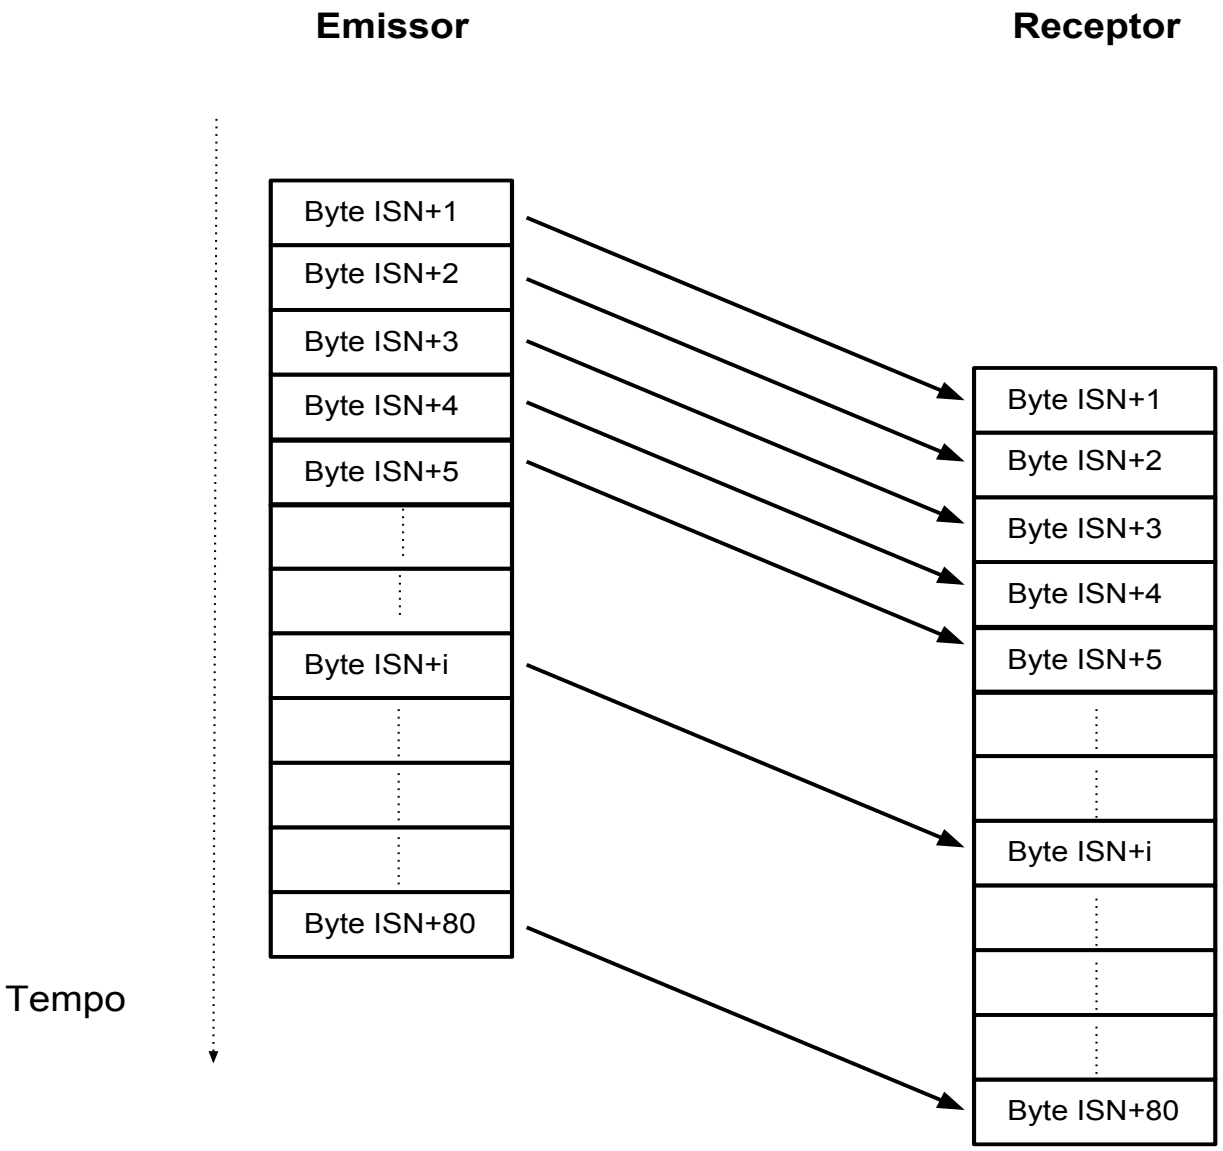

Segmentos e Números de Sequência

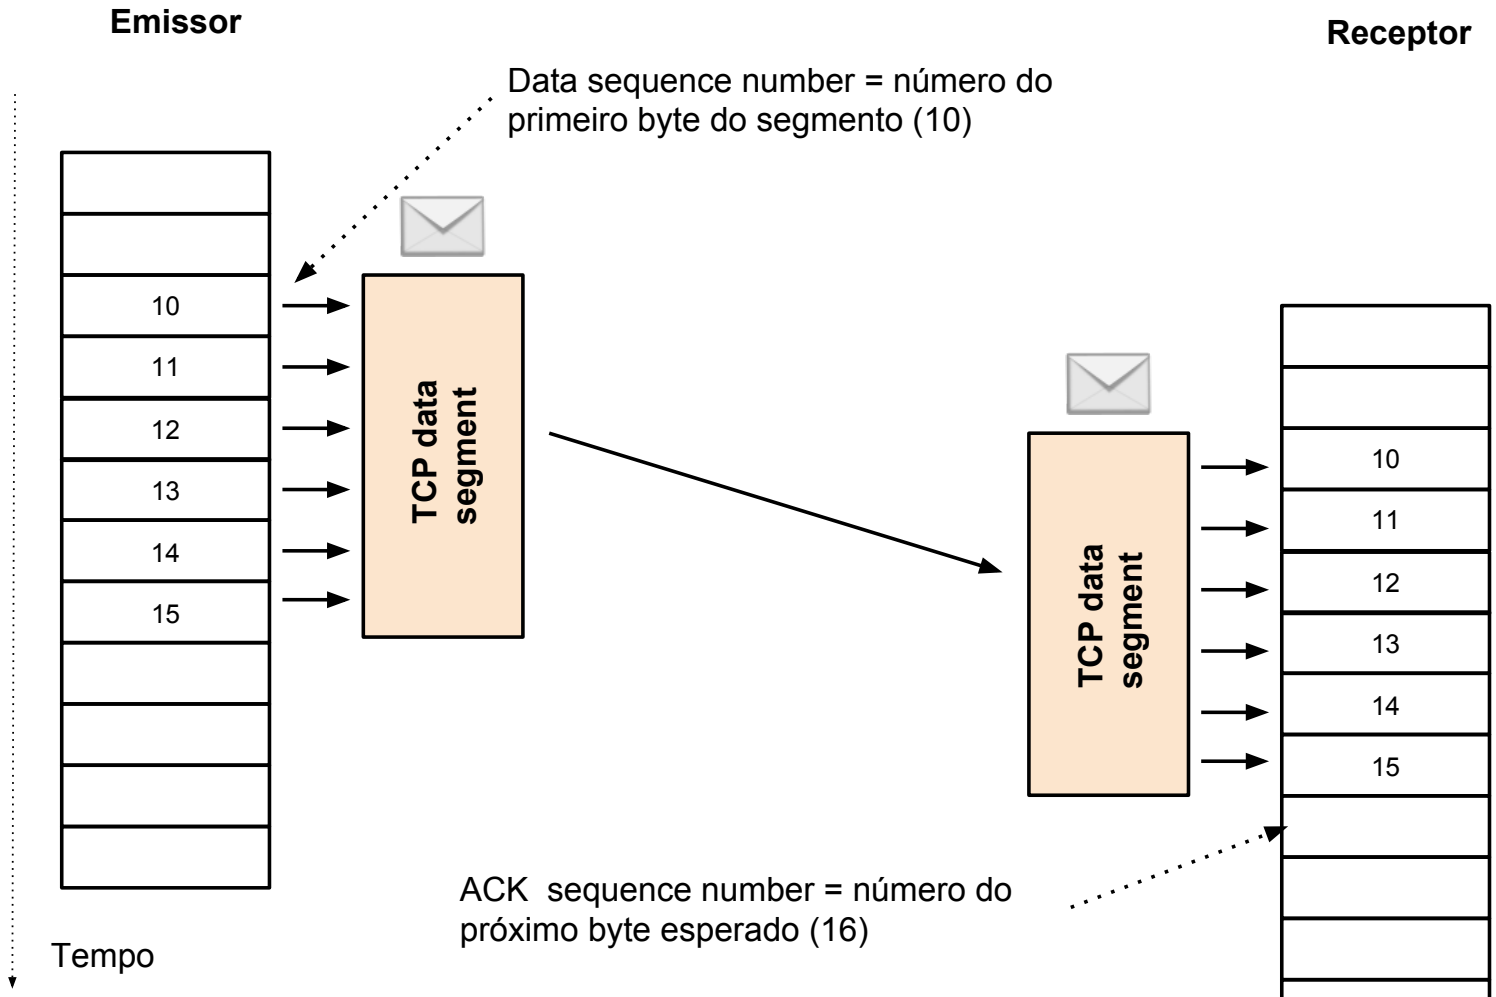

Initial Sequence Number (ISN)

- É o número de sequência do 1.º byte
  - Porque não sempre 0 ou 1?
  - Como garantir que não há confusão entre segmentos de conexões sucessivas ?
- As conexões distinguem-se pelos números dos endereços IP e das portas
  - Mas ambos podem ser reutilizados e poderiam no limite introduzir confusão
  - Utilizar um valor fixo também ajudaria um atacante
- O TCP muda o ISN de cada nova conexão
  - Para isso é usado um gerador de números aleatórios

Sockets e *Buffers*

- A extremidade de cada socket TCP tem dois *buffers* associados
  - O *buffer* (parecido com a janela) de emissão
  - O *buffer* (parecido com a janela) de recepção
- O *buffer* de emissão pode ter muitos bytes ainda não enviados para permitir à aplicação progredir momentaneamente, mais depressa que o TCP
- O *buffer* de recepção pode ter muitos bytes já ACKed, mas que ainda não foram consumidos pela aplicação responsável pelo consumo dos dados

Buffer ≠ Janela do Emissor

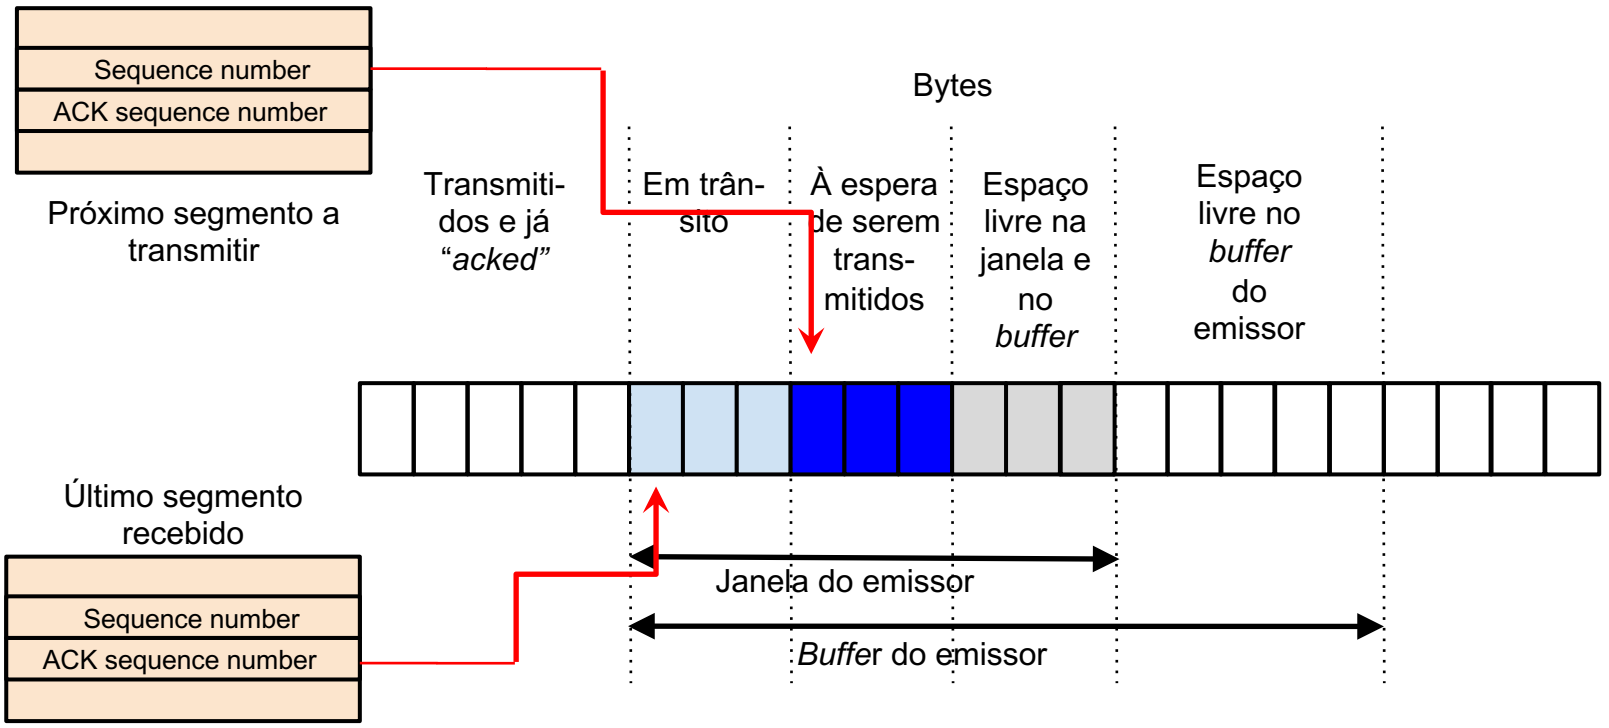

Gestão Inteligente do Envio de Segmentos

- Um novo segmento é transmitido:

  -Quando existem MSS bytes disponíveis para transmitir e a janela tem espaço (MSS - Max Segment Size)

  -Existem menos de MSS bytes disponíveis mas passou demasiado tempo (geralmente 200 ms) e há espaço na janela

  -Empurrados ("pushed") pela aplicação e há espaço na janela (chamada flush() ou opção SI_NODELAY)

ACKs e Retransmissões

- Por defeito todos os ACKs são cumulativos e o funcionamento do protocolo é do tipo GBN (Go-Back-N)
- Logo, em caso de alarme são retransmitidos todos os dados ainda não ACKed desde o mais velho segmento, que desencadeou o *timeout* (GBN)
- O receptor pode guardar dados fora de ordem, isto é, o *buffer* de recepção pode ter buracos. A norma não obriga mas é a opção adoptada atualmente
- Os ACKs viajam nos segmentos enviados com os dados transmitidos no sentido contrário (*piggybacking*)
- Pode funcionar num modo semelhante ao SR em opção, enviando ACKs cumulativos e seletivos em simultâneo

Buffer do Receptor

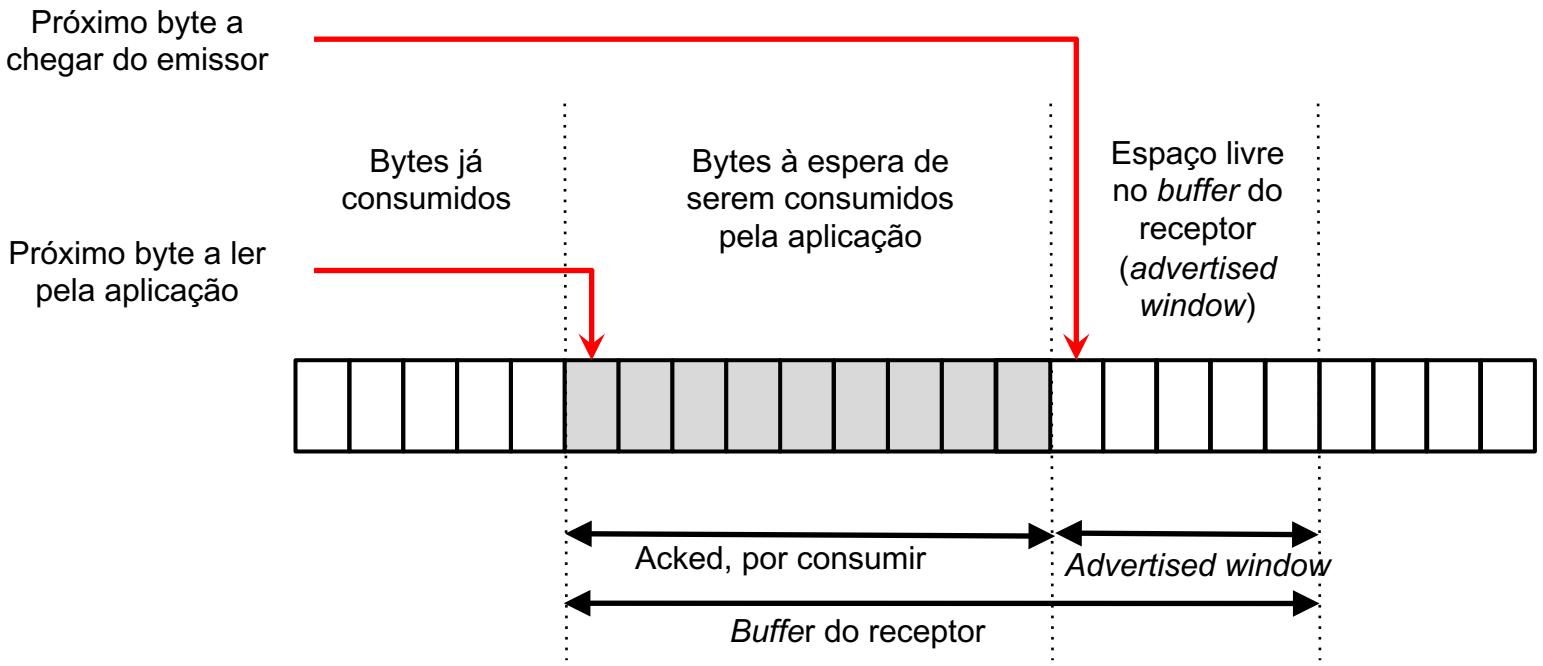

Gestão inteligente de ACKS cumulativos

Evento	Ação do receptor
Segmentos recebidos ordenados com números de sequência esperados, todos os segmentos anteriores já ACKed	*Delayed ACK*: esperar até 500ms por outro segmento na ordem. Se este não chegar enviar ACK
Segmentos recebidos na ordem esperada, todos os segmentos anteriores já ACKed menos 1	Enviar imediatamente um ACK cumulativo
Segmento fora de ordem (gerando um buraco na janela de recepção)	Enviar ACK duplicado, indicando o nº de sequência do próximo byte esperado (o 1º do 1º buraco)
Chegada de um segmento que preenche parcial ou totalmente um buraco	Envio imediato de um ACK cumulativo

Fast Retransmit

- Se os valores de *timeout* são altos quando comparados com o RTT (ver a seguir) a recuperação das falhas pode revelar-se muito lenta
- Como vimos o TCP ao receber segmentos que geram "buracos" no receptor (porque um segmento anterior se perdeu ou está atrasado e fora de ordem) envia por defeito ACKs cumulativos, correspondentes aos dados recebidos corretamente até momento
- Esses ACKs cumulativos têm necessariamente o mesmo número de sequência
- Quando o emissor recebe 3 ACKs seguidos com o mesmo número de sequência, comporta-se como se o *timeout* tivesse disparado e reemite imediatamente (GBN), ou seja, 3 ACKs repetidos idênticos são equivalentes a um NACK (Negative ACK)

Fast Retransmit (sem SR)

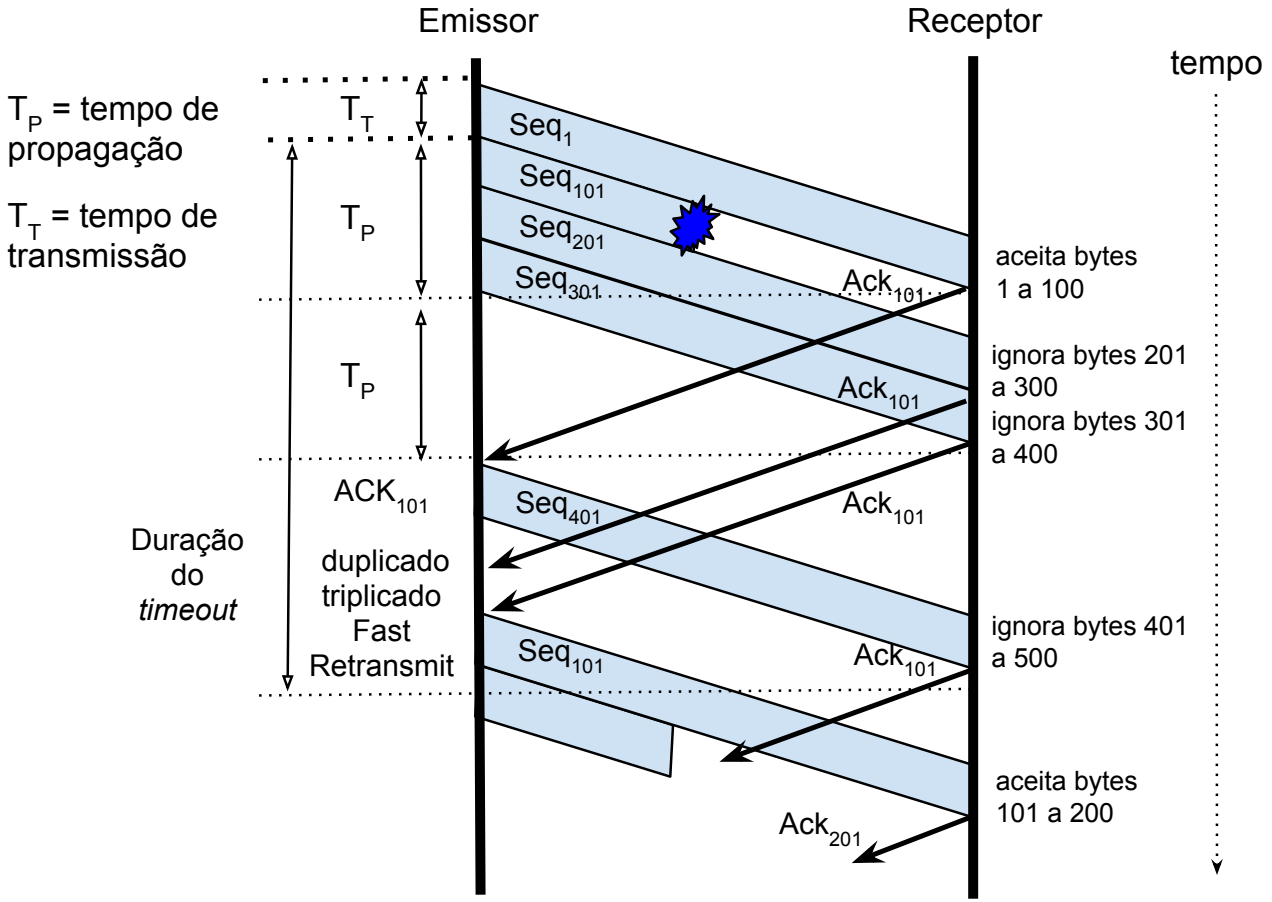

Fast Retransmit é Eficaz?

- A eficácia é máxima se
  - Com muitos pacotes transmitidos para a frente, isto é, com uma janela grande
  - Os *timeouts* >> RTT
  - Com transferências longas
- Implicações para o tráfego Web
  - Se as conexões para sites Web transmitirem relativamente poucos dados (e.g., 10 pacotes ≈ 15 Kbytes) não há oportunidade para serem enviados muitos pacotes emitidos de avanço
  - Logo, é de todo o interesse privilegiar conexões "longas"

Duração dos Alarmes

- Tem que ser maior que o RTT (e.g. RTT + delta)
  - Se demasiado longo, a recuperação dos erros é lenta
  - Se demasiado curto desperdiça a capacidade da rede
- Mas o RTT é variável, logo é necessário estimar o valor do RTT médio
- Mas adaptando-se às variações do RTT, isto é
- Cada vez que se estima o RTT, calcula-se o valor da variável estimatedRTT fazendo uma média pesada com o valor passado

$$estimatedRTT = estimatedRTT\ (1-\alpha) + \alpha\ .\ sampledRTT$$

Com $\alpha = 0{,}125$

$$estimatedRTT = estimateddRTT\ .\ (1-0{,}125) + 0{,}125\ .\ sampledRTT$$

Que Valor Usar?

- O valor de estimatedRTT é demasiado curto quando as variações momentâneas são significativas, logo temos de introduzir uma margem de segurança, multiplicando-o por um factor
- Esse factor deve ser proporcional ao desvio das amostras obtidas face ao estimado, isto é, quanto maior a variação, maior a margem de segurança

devRTT = (1-β) . devRTT + β . |sampledRTT-estimatedRTT|,

com β=0,25:

devRTT = (1-0,25) . devRTT + 0,25 . | sampledRTT-estimatedRTT |

timeoutValue = estimatedRTT + 4 . devRTT (RFC 2988)

Controlo de Fluxo

- Se a aplicação não consumir os dados recebidos a um ritmo maior ou igual ao que eles chegam, o *buffer* do receptor vai enchendo
- Até não haver espaço e os novos segmentos que chegam são desperdiçados
- O emissor notará isso mais tarde (pelos *ACKs* ou pelo *timeout*)
- Mas de que serve continuar a emitir se a aplicação não lê os dados? (e.g. o utilizador está a analisar os dados recebidos)

Buffer do Receptor

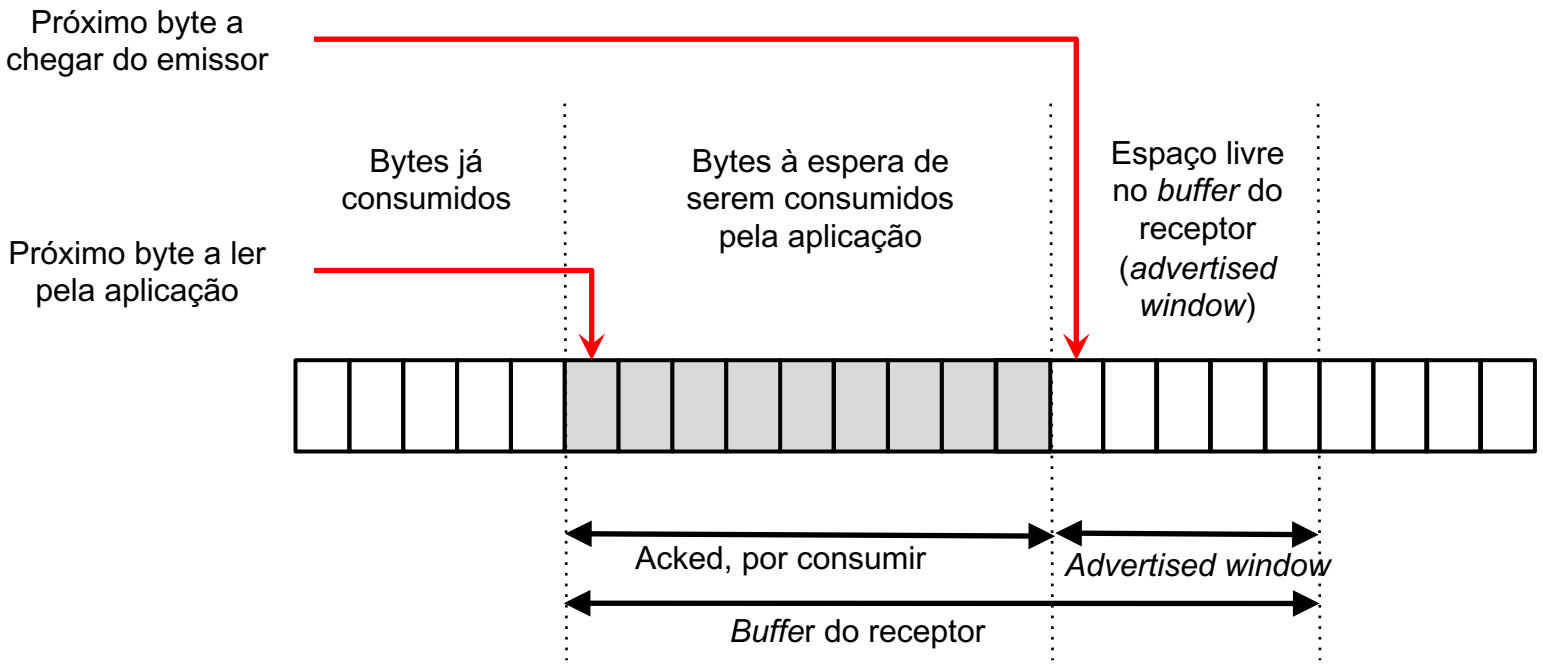

Advertised Window

- Sempre que um segmento é emitido num sentido da conexão, o receptor avisa o outro lado, o emissor, de quanto espaço tem livre no *buffer* de recepção (*Receiver Advertised Window*)
- O emissor refreia então o seu ritmo de emissão de tal forma que

LastByteSent – LastByteAck ≤ Last Receiver Advertised Window

- Dada a dimensão do campo, é interessante analisar o valor máximo da janela

Segmento TCP

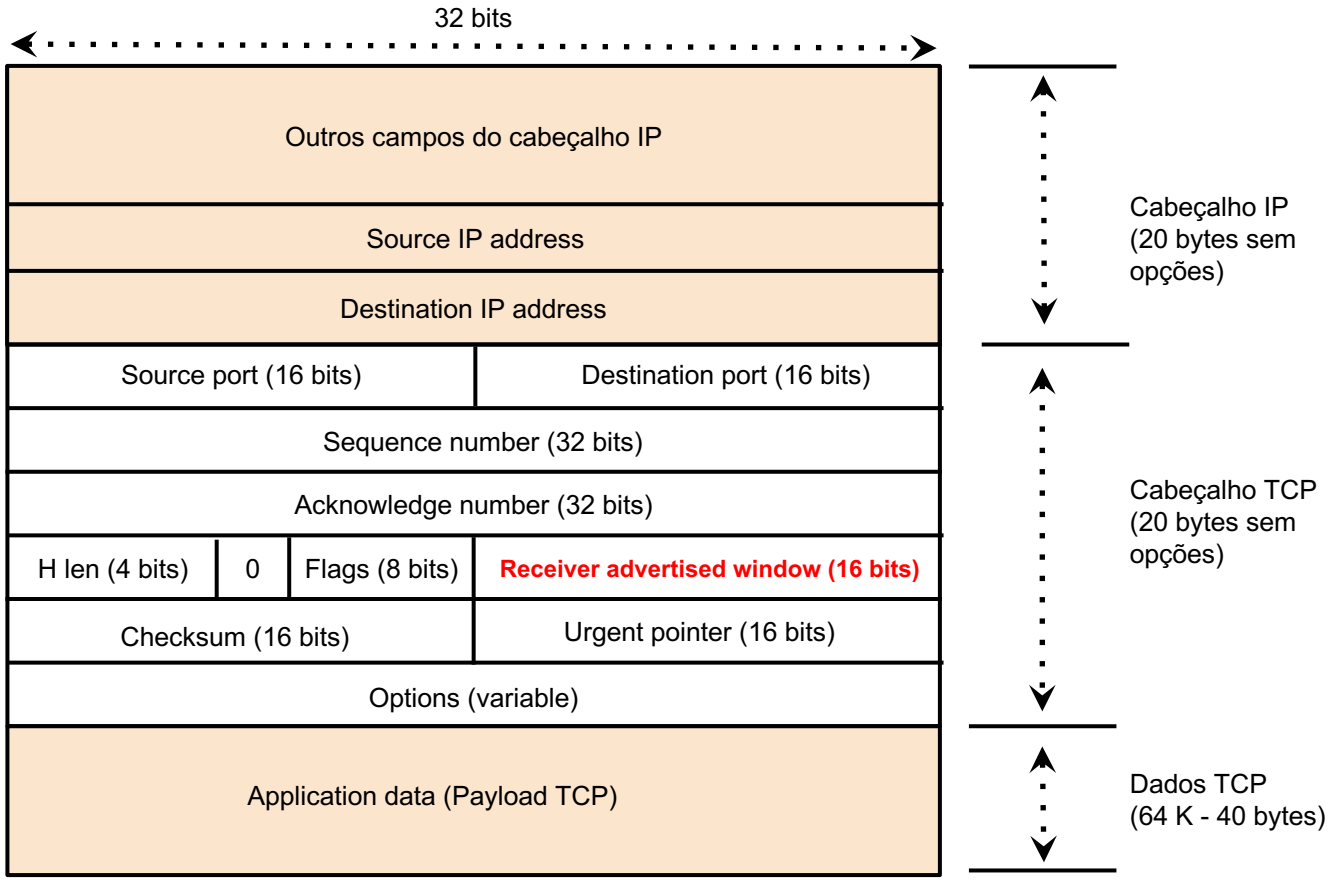

Dimensão Mínima da Janela com RTT = 100 ms

Débito extremo a extremo	Dimensão mínima da janela
100 K bps	≈ 1250 bytes
1 M bps	≈ 12,5 K bytes
10 M bps	≈ 125 K bytes
100 M bps	≈ 1,25 M bytes
1000 M bps	≈ 12,5 M bytes

Estabelecimento da Conexão

- É baseado num protocolo especial designado por *three-way handshake*
- Durante o mesmo as partes comunicam o ISN (*Initial Sequence Number*) e negoceiam o MSS (*Maximum Segment Size*) e outras opções
- Outras opções típicas:
  - Factor de escala do campo *Receiver Window* para comportar janelas muito grandes (*window scaling factor*)
  - Uso opcional de *SACKs* (Selective ACKs)
  - *Probing e Timestamps* (RFC 1323)

Segmento TCP

Flags:

SYN
FIN
RST
PSH
URG
ACK

Options:

MSS
SACK
W. SCALE
T. STAMP

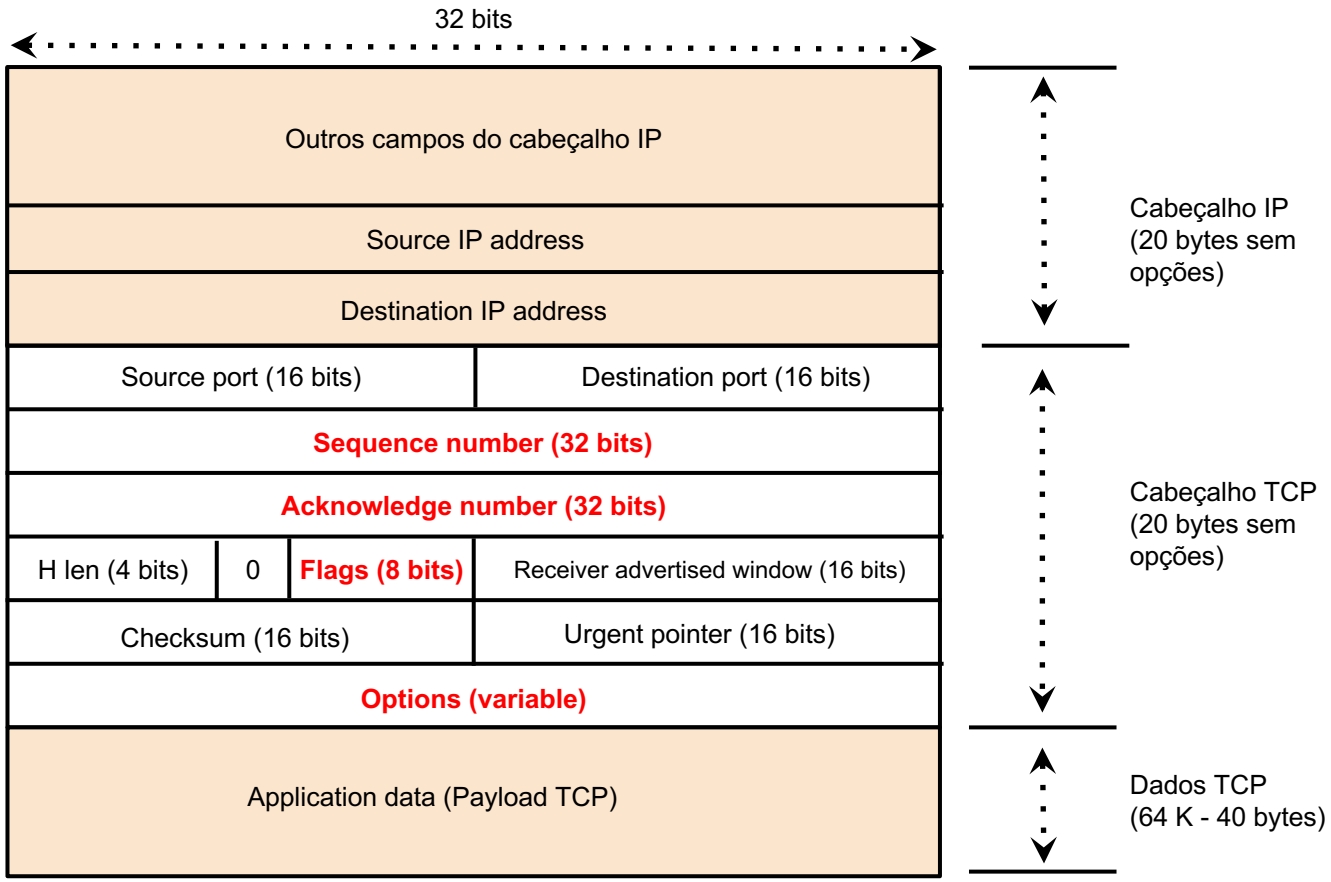

Estabelecimento da Conexão

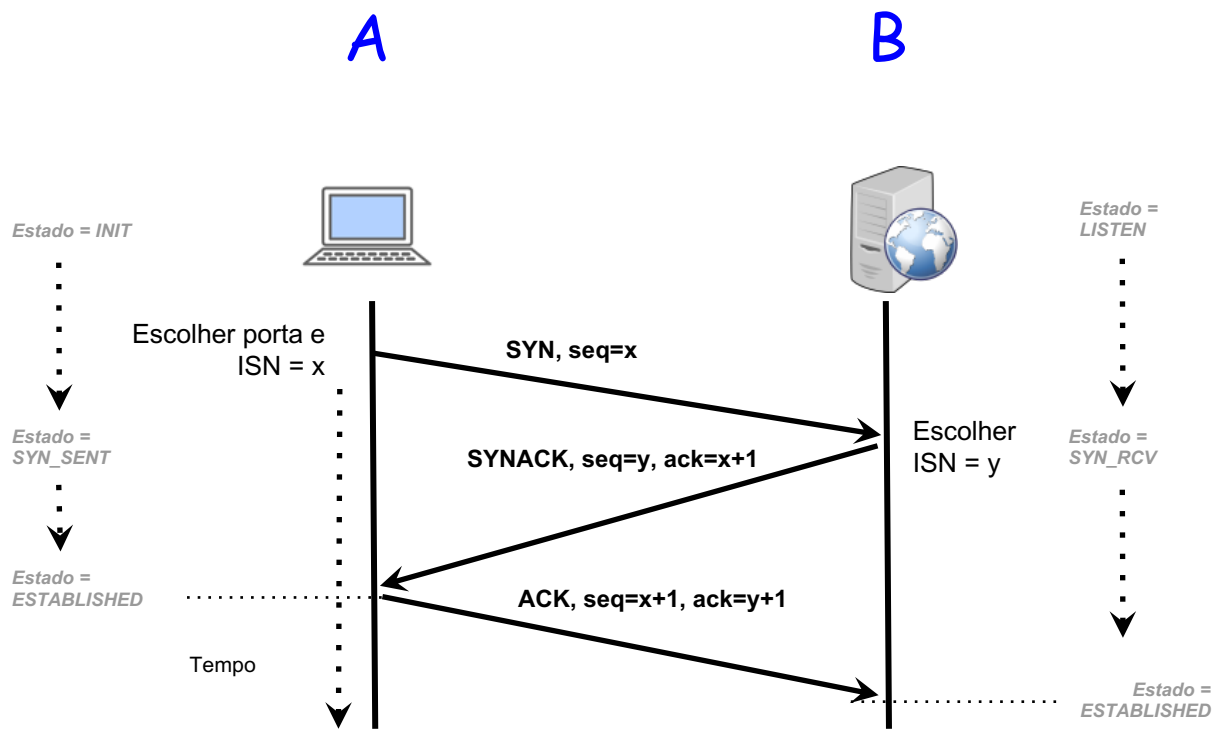

Como Funciona

- A envia um segmento SYN com as suas propostas
- B responde com um segmento SYN+ACK com as suas alternativas
- A envia um ACK a fechar a negociação
- Se A não recebe o segmento SYN+ACK retransmite o segmento SYN

Evolução do Estado da Conexão

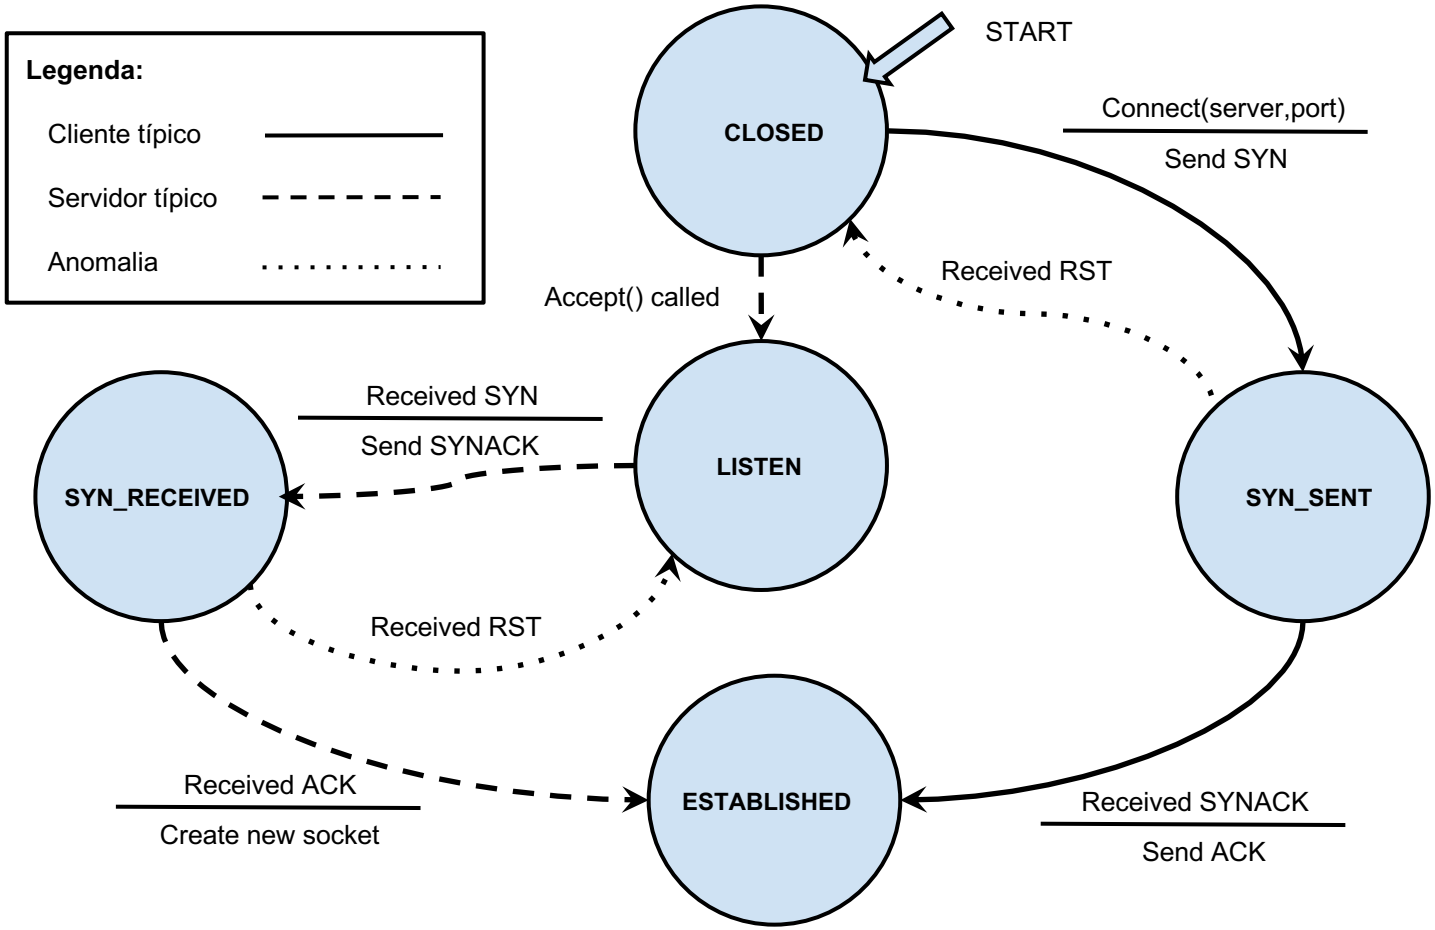

E Se o SYN Se Perde?

- O segmento SYN inicial pode perder-se
  - Na rede houve um problema ou
  - O servidor não aceita mais conexões (parâmetro *LISTEN for # new connections*, também acessível nos *sockets* Java)
- Nenhum SYN+ACK chegará ao cliente
  - O cliente espera um certo limite de tempo (*timeout*)
  - E reemite ou desiste (após algumas tentativas)
- Que valor usar para o *timeout* ?
  - Tipicamente alguns segundos, por exemplo 3 segundos, porque nada se sabe do RTT no início
  - Caso o SYN se perca, a abertura seria muito demorada pelo que modernamente se baixou o valor para 1 segundo

E Se o SYN+ACK Se Perde?

- O cliente acabará por voltar a emitir e tudo recomeça pois o servidor reconhecerá a conexão repetida
  - A conexão acabará por se estabelecer
- Mas que acontece se o cliente for batoteiro e não responder ao SYN+ACK com o ACK final (ataque *SYN flood*)
  - O servidor terá de esperar um certo tempo (*timeout*, com por exemplo o valor de 10 segundos) e depois desistir daquela conexão dita "meia aberta"
- Qual o valor do *timeout*?
  - O servidor espera um tempo fixo pois não conhece o RTT
  - O tempo que espera perante um ataque *SYN flood* determina o espaço desperdiçado na tabela de conexões abertas e *buffers*, etc.

Contra Medidas Para o SYN flood

- Usar SYN cookies, isto é, números de sequência iniciais (ISNs) especiais do lado do servidor
  - O servidor responde com ISN (especial), ver abaixo
  - Mas o servidor memoriza muito pouca informação sobre a conexão aberta (e.g. *client IP, client Port, server IP, server Port, ISN*), ou mesmo apenas o ISN
  - Um cliente correto responde com um ACK=ISN+1
  - O servidor analisa esse valor e constrói então o estado total da conexão pois tem a certeza que o cliente não é falso. Só nessa altura constrói todas as outras estruturas de dados sobre a conexão

ISN = Hash (client IP, client Port, server IP, server Port, segredo)

Perda do SYN ou SYN+ACK e Browsers Web

- O utilizador dá um URL ao browser e carrega em *enter*
  - O browser abre uma conexão TCP para o servidor
- O utilizador espera alguns segundos, mas vários segundos é muito tempo
- Impacienta-se e carrega em *reload*
- O browser abre uma nova conexão
  - o que se traduz em enviar um novo SYN e no abandono da antiga conexão
  - Isto é, o utilizador limita na prática um *timeout* muito alto
  - A antiga conexão não aberta acabará por desaparecer
  - Que repercussões haverá sobre o problema da confusão entre a nova e a antiga conexão ? Nenhuma se as portas não forem reutilizadas ou o ISN avançar adequadamente

Fecho da Conexão

- Fechar uma conexão não é fácil se exigirmos o acordo de ambas as partes
- "Eu quero fechar" porque já não tenho nada para enviar
- Mas a outra parte tem também de estar de acordo e não ter também nada mais para enviar
- Chegar a este acordo numa situação em que se podem perder pacotes é complicado
- Solução do TCP: fechar cada uma das partes de forma independente

Fecho da Conexão

- O processo numa extremidade já não tem mais nada para escrever e fecha a conexão *(close())*
  - O TCP assegura que os dados já escritos chegam ao outro lado e depois desencadeia o envio do segmento FIN
- O outro lado está a ler dados
  - Quando o TCP não tiver mais dados para fornecer
  - O leitor recebe *end-of-file (read() returns -1)*
- Por outro lado, cada lado da conexão pode fechar de forma independente a conexão
  - Invocando *shutdown()* ao invés de *close()*
- Por isso se diz que o TCP implementa um "*graceful tear-down*" das conexões

Fecho da conexão

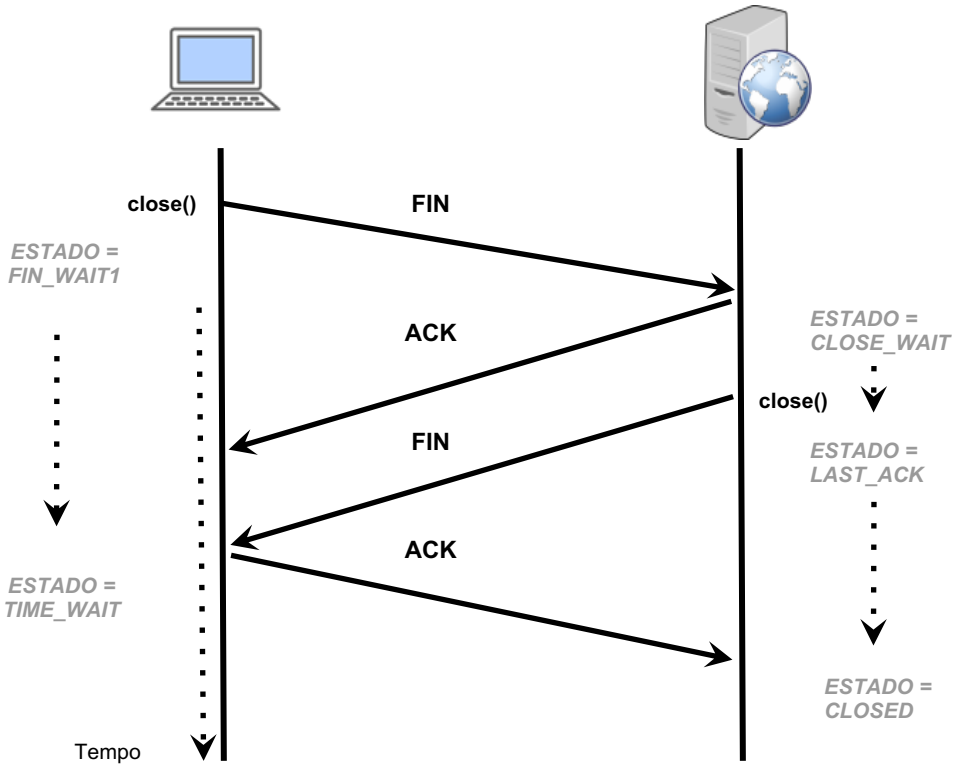

Máquina de Estados

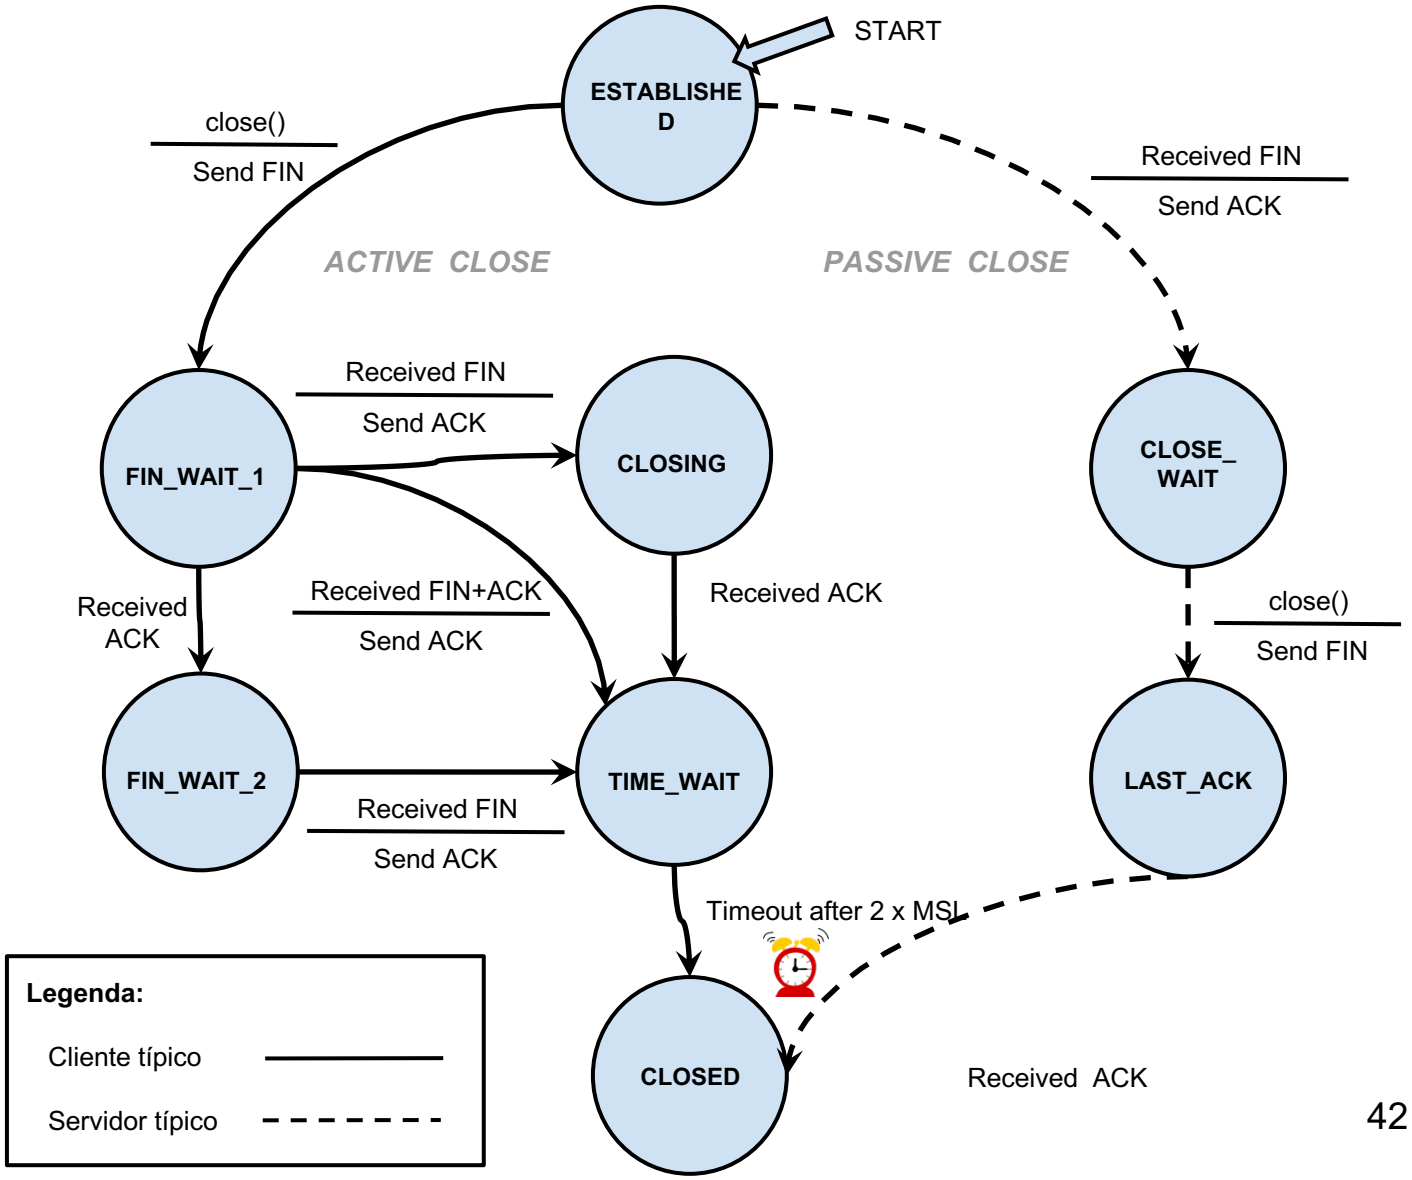

Débito Extremo a Extremo Teórico

Débito = Dimensão Média da Janela / RTT

$$V = W_{avr} / RTT$$

TCP Header

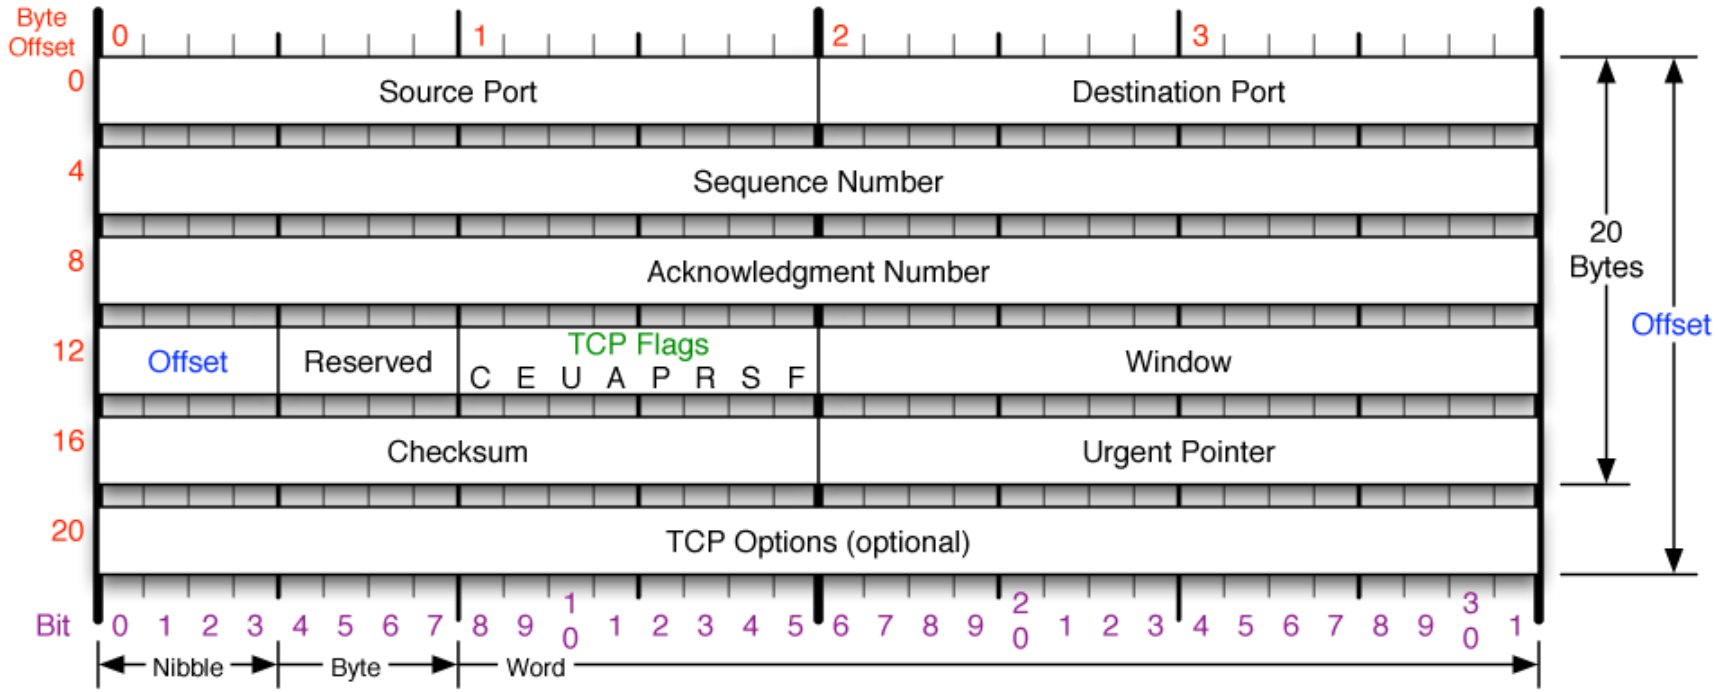

TCP Flags

C E U A P R S F

Congestion Window
C 0x80 Reduced (CWR)
E 0x40 ECN Echo (ECE)
U 0x20 Urgent
A 0x10 Ack
P 0x08 Push
R 0x04 Reset
S 0x02 Syn
F 0x01 Fin

Congestion Notification

ECN (Explicit Congestion Notification). See RFC 3168 for full details, valid states below.

Packet State	DSB	ECN bits
Syn	0 0	1 1
Syn-Ack	0 0	0 1
Ack	0 1	0 0
No Congestion	0 1	0 0
No Congestion	1 0	0 0
Congestion	1 1	0 0
Reciever Response	1 1	0 1
Sender Response	1 1	1 1

TCP Options

0 End of Options List
1 No Operation (NOP, Pad)
2 Maximum segment size
3 Window Scale
4 Selective ACK ok
8 Timestamp

Checksum

Checksum of entire TCP segment and pseudo header (parts of IP header)

Offset

Number of 32-bit words in TCP header, minimum value of 5. Multiply by 4 to get byte count.

RFC 793

Please refer to RFC 793 for the complete Transmission Control Protocol (TCP) Specification.

Copyright 2004 - Matt Baxter - mjb@fatpipe.org

TCP = Turing Award

- O TCP foi desenvolvido a partir da experiência anterior e publicado no ano de 1974 pela primeira vez
- Vinton Cerf and Robert Khan, "A Protocol for Network Interconnection," IEEE Transactions on Networking, Vol. 22 No. 5, May 1974, pp 637-648
- Os seus autores iniciais receberam um ACM Turing Award em 2004 relacionado em geral com as contribuições que deram (IP + TCP = TCP/IP)

Conclusões

- A Internet tem características especiais
  - Pode perder pacotes
  - Pode fazê-los chegar fora de ordem
  - Pode fazê-los chegar muito atrasados face aos outros
  - Apresenta tempo de trânsito extremo a extremo muito variáveis

- Um protocolo de transferência fiável de dados como o TCP tem de lidar com todas essas características
  - O TCP foi sendo desenvolvido a partir da experiência adquirida, inicialmente durante a década de 1970
  - Tem sido melhorado incrementalmente desde então de forma contínua, mesmo ainda recentemente
  - É o principal protocolo de transporte usado na Internet e é muito sofisticado
  - O êxito da Internet está-lhe profundamente ligado