Transmisión de secuencia de bytes confiablemente (Transission Control Protocol, TCP)

Contenidos

- Establecimiento y término de conexión
- Revisión a Ventana Deslizante
- Control de Flujo
- Temporizadores Adaptivos

Contexto

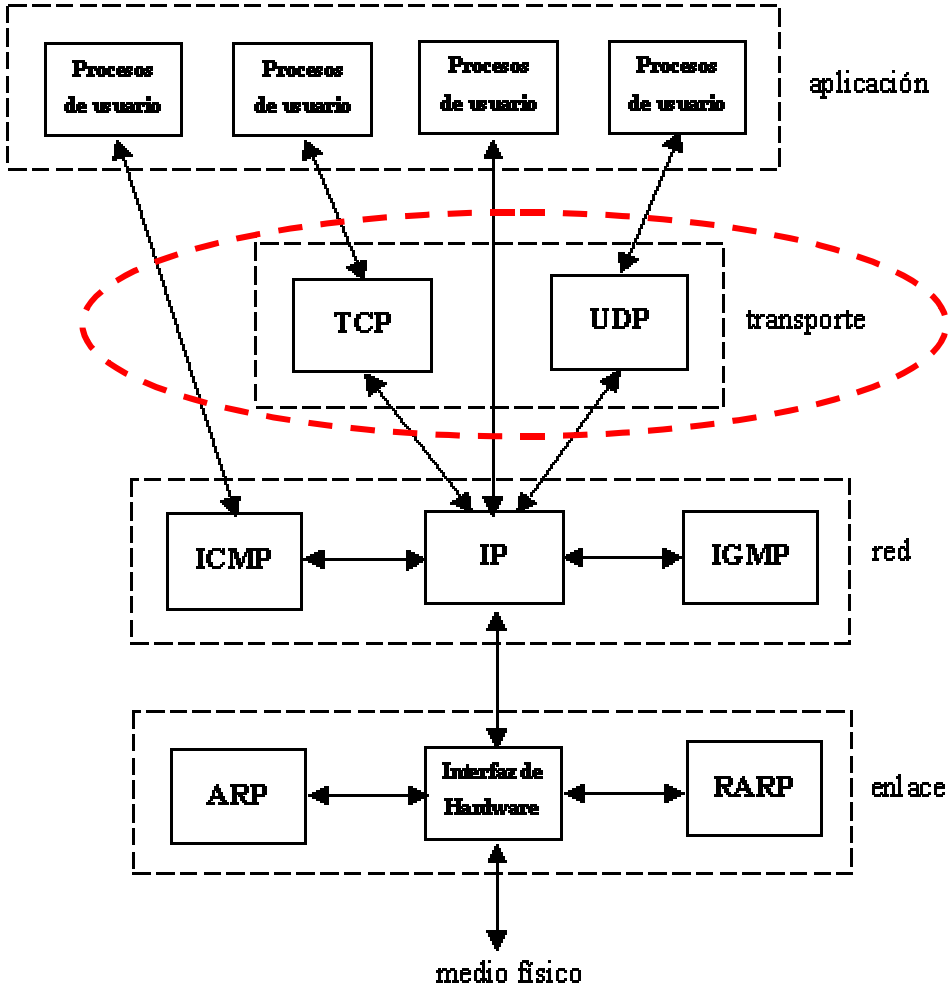
Procesos de usuario
Procesos de usuario
Procesos de usuario
Procesos de usuario
aplicación
TCP
UDP
transporte
ICMP
IP
IGMP
red
ARP
Interfaz de Hardware
RARP
enlace
medio físico

Protocolos End-to-End

- Se apoyan en la capa Red, la cual es de mejor esfuerzo (best-effort)
  - descarta mensajes
  - re-ordena mensajes
  - puede entregar múltiples copias de un mensaje dado
  - limita los mensajes a algún tamaño finito
  - entrega mensajes después de un tiempo arbitrariamente largo
- Servicios comunes ofrecidos/deseados end-to-end
  - garantía de entrega de mensajes
  - entrega de mensajes en el mismo orden que son enviados
  - entrega de a lo más una copia de cada mensaje
  - soporte para mensajes arbitrariamente largos mensajes
  - soporte de sincronización
  - permitir al receptor controlar el flujo de datos del transmisor
  - soportar múltiples procesos de nivel aplicación en cada máquina

Demultiplexor Simple (UDP:User Datagram Protocol)

- Servicio de entrega no confiable y no ordenado de datagramas
- Agrega multiplexión
- No hay control de flujo
- Hay puertos definidos en cada extremo
  - servidor posee un puerto *bien conocido*
  - ver **`/etc/services`** en Unix (o Linux)
- Formato de encabezado

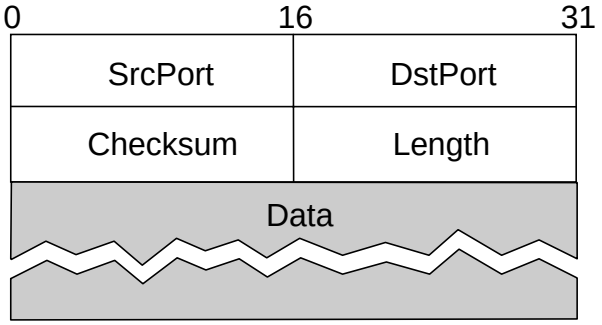

- Chequeo se suma opcional
  - psuedo header(IP) + UDP header + data

Contexto para encabezado UDP

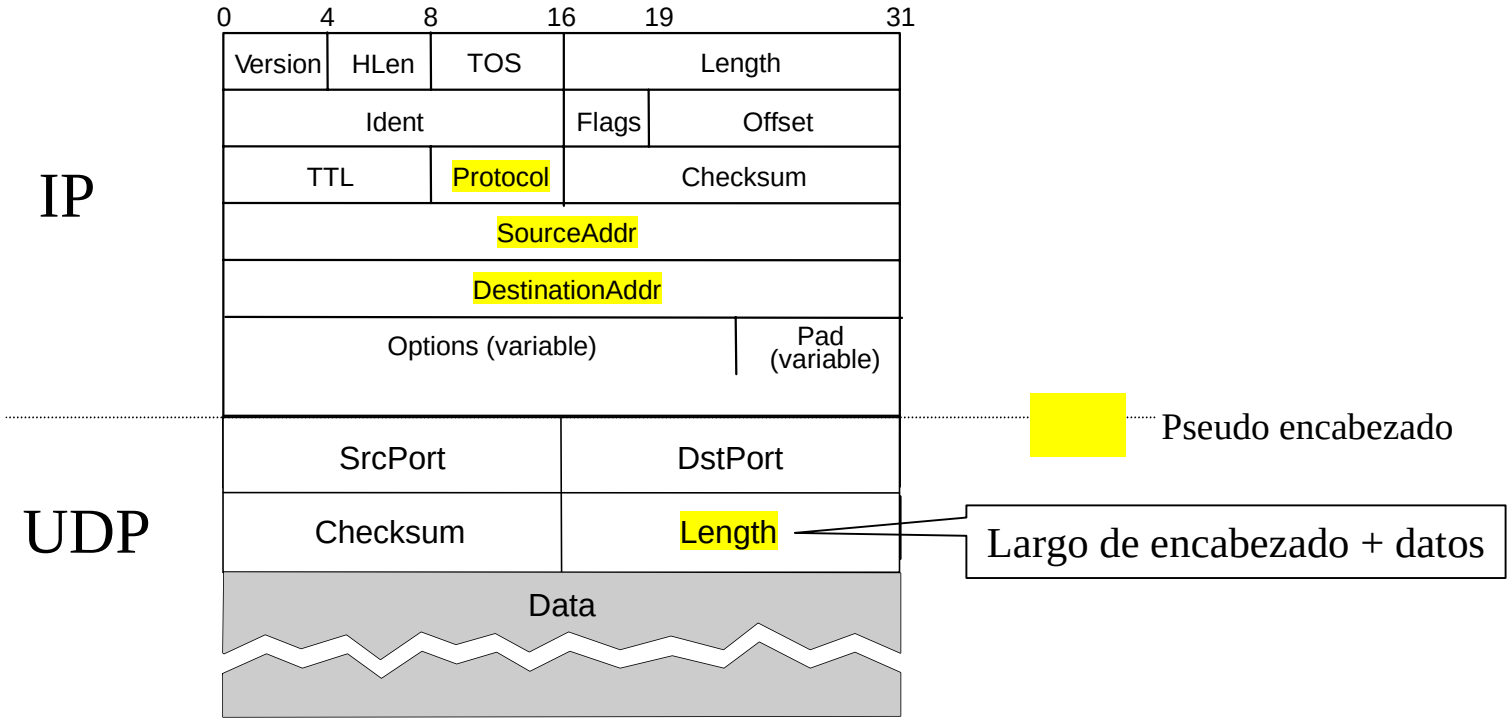

Niveles de Demultiplexión

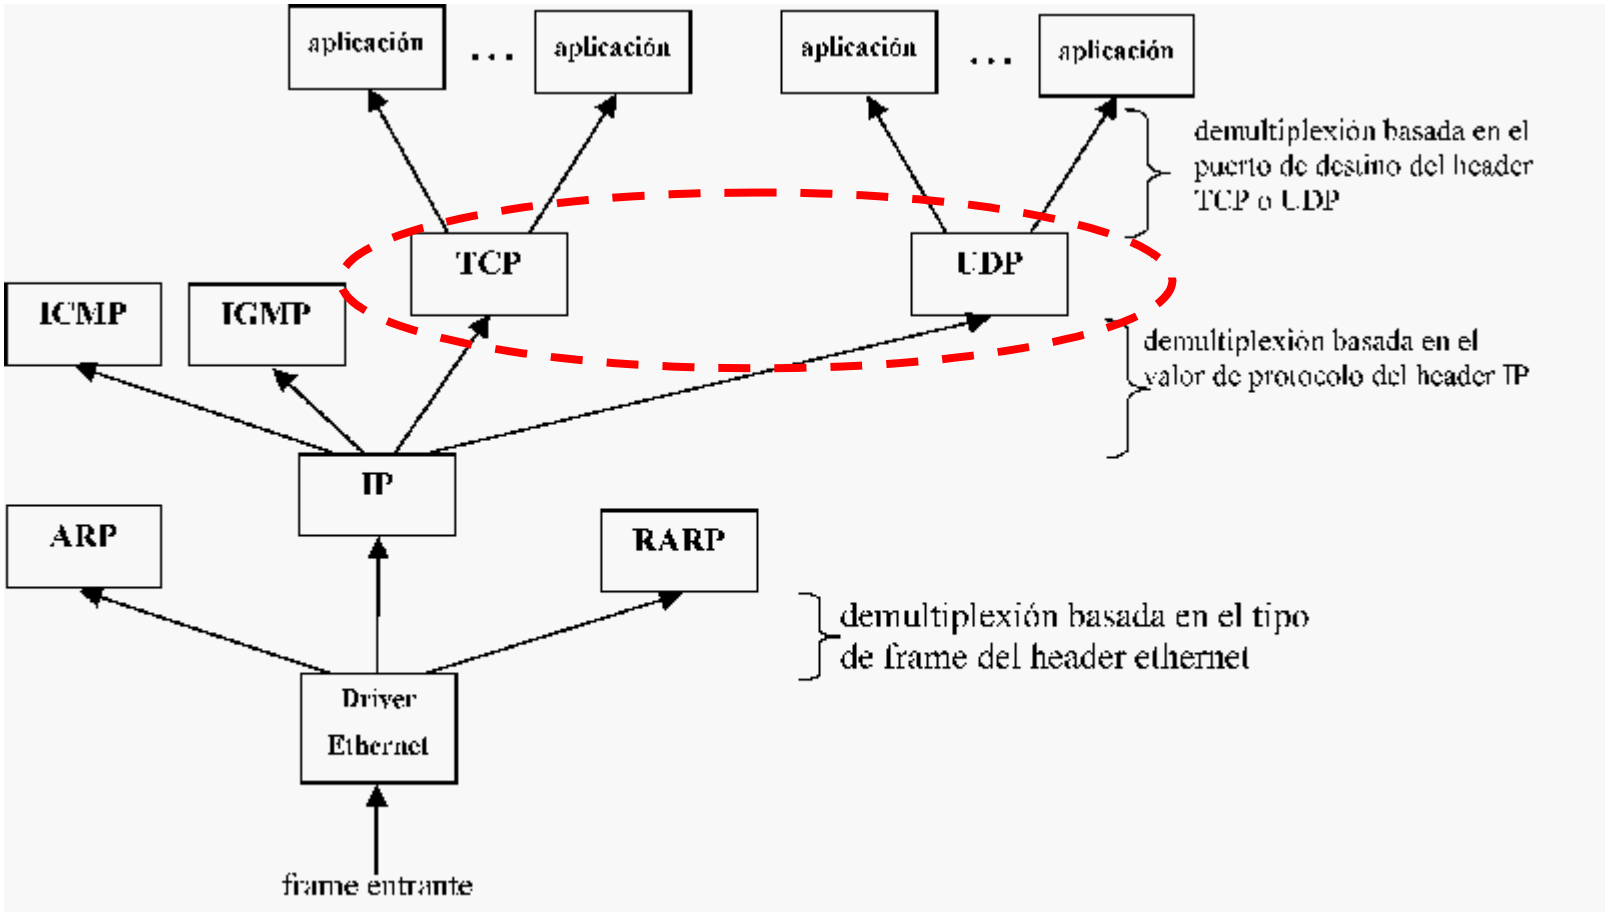

TCP Generalidades

- Orientado a conexión
- flujo de byte
  - app escriben bytes
  - TCP envía *segmentos*
  - app lee bytes
- Full duplex
- Control de flujo: evita que el Tx rebalse al receptor
- Control de congestión: evita que el Tx sobrecargue la red

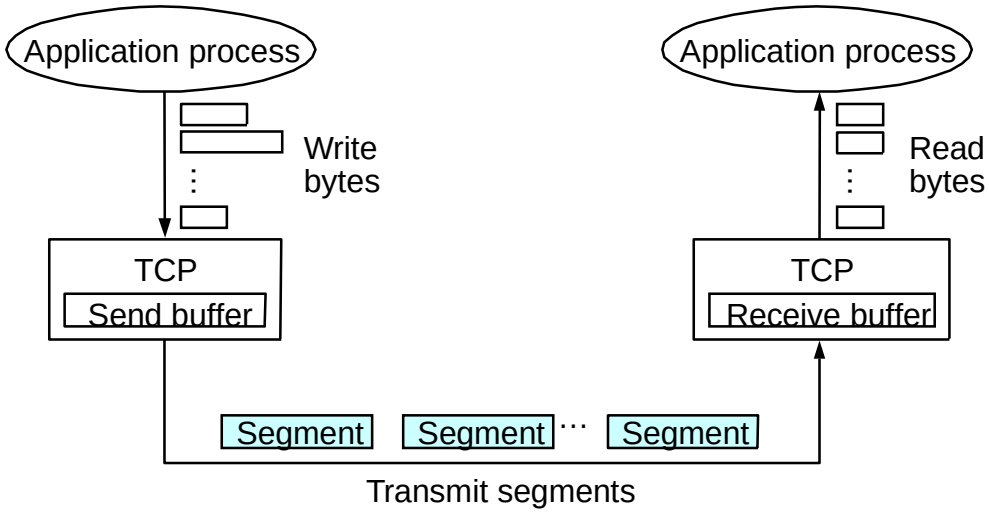

Enlace de Datos Versus Transporte

- Potencialmente conecta muchas máquinas diferentes
  - requiere de establecimiento y término de conexión explícitos
- Potencialmente diferentes RTT
  - requiere mecanismos adaptivos para timeout
- Potencialmente largos retardos en la red
  - requiere estar preparado par el arribo de paquetes muy antiguos
- Potencialmente diferente capacidad en destino
  - requiere acomodar diferentes capacidades de nodos
- Potencialmente diferente capacidad de red
  - requiere estar preparado para congestión en la red

Contexto Formato de Segmento

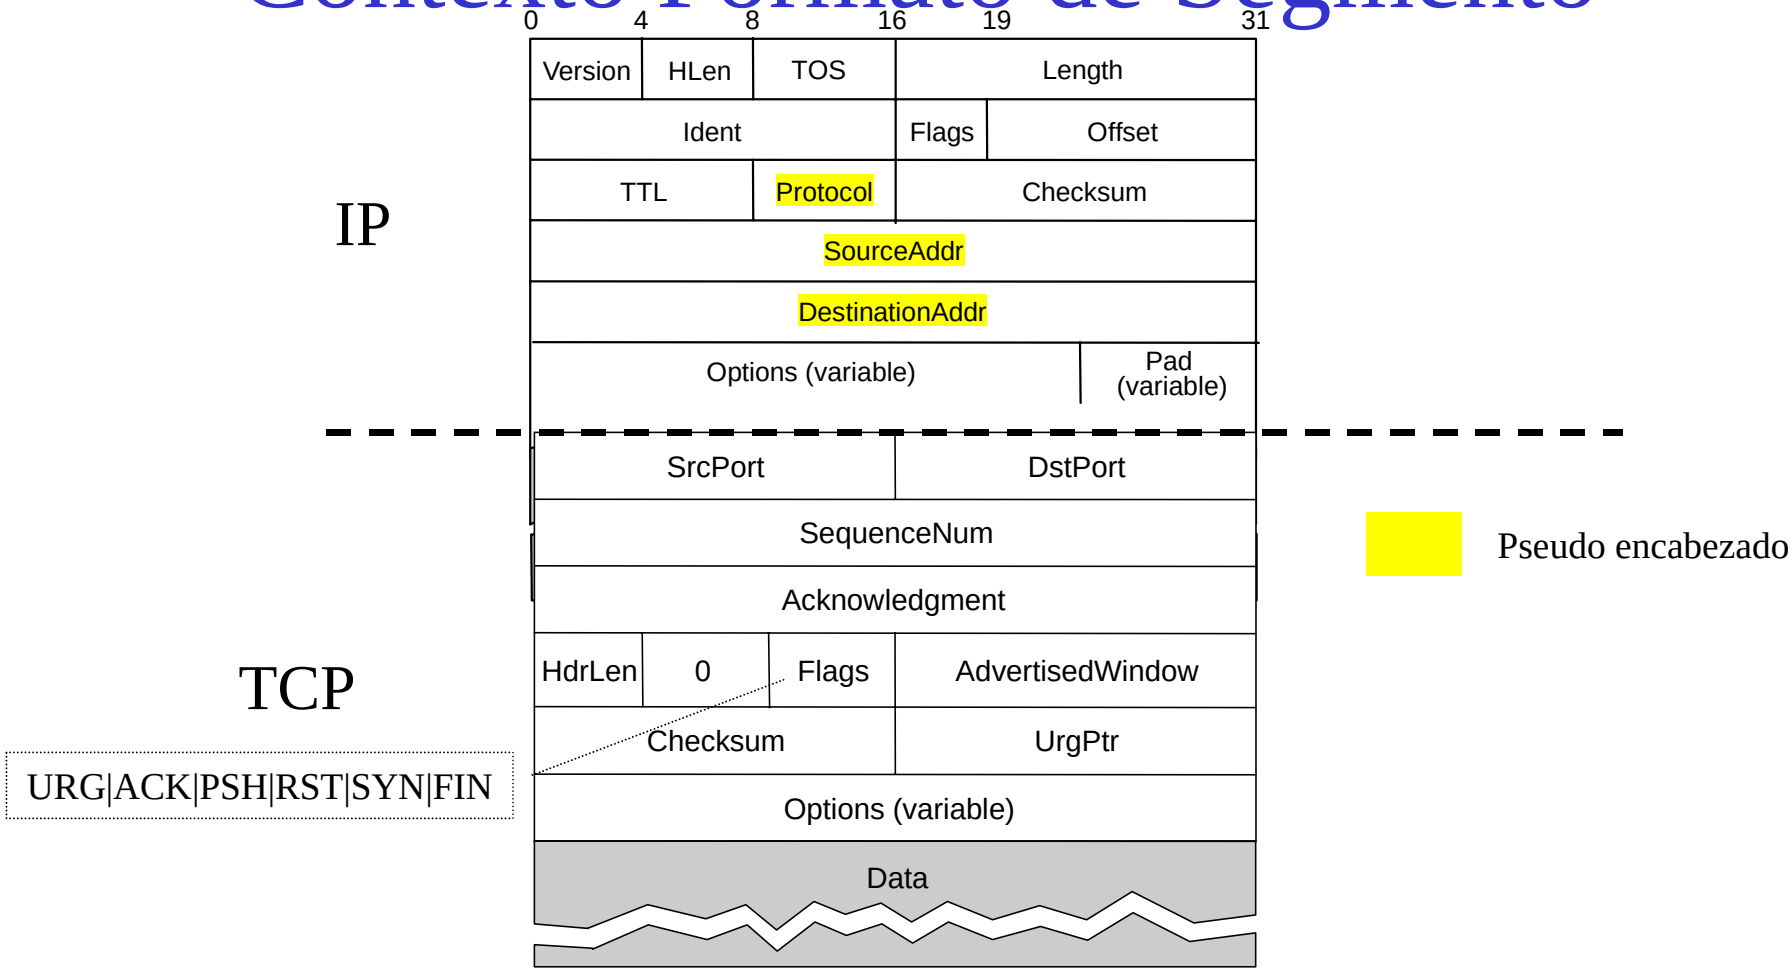

Formato de Segmento

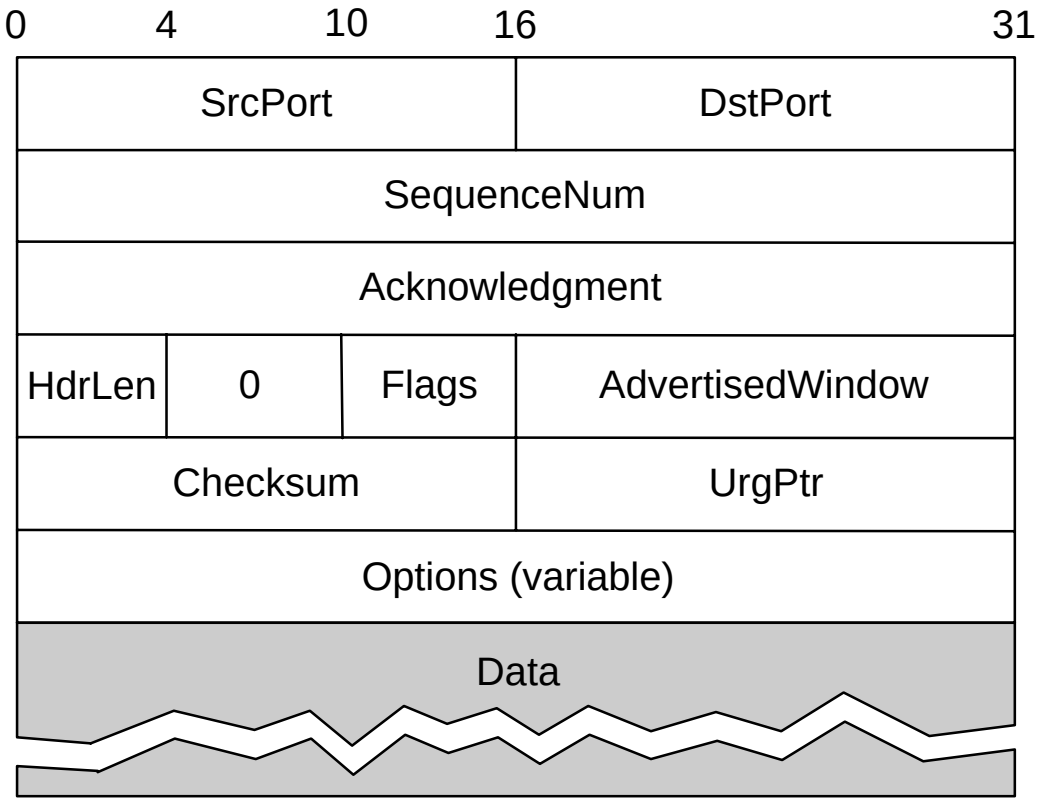

Formato de Segmento (cont)

- Cada conexión es identificada por la 4-tupla:
  - **`(SrcPort, SrcIPAddr, DsrPort, DstIPAddr)`**
- Ventana deslizante + control de flujo
  - **`acknowledgment, SequenceNum, AdvertisedWinow`**

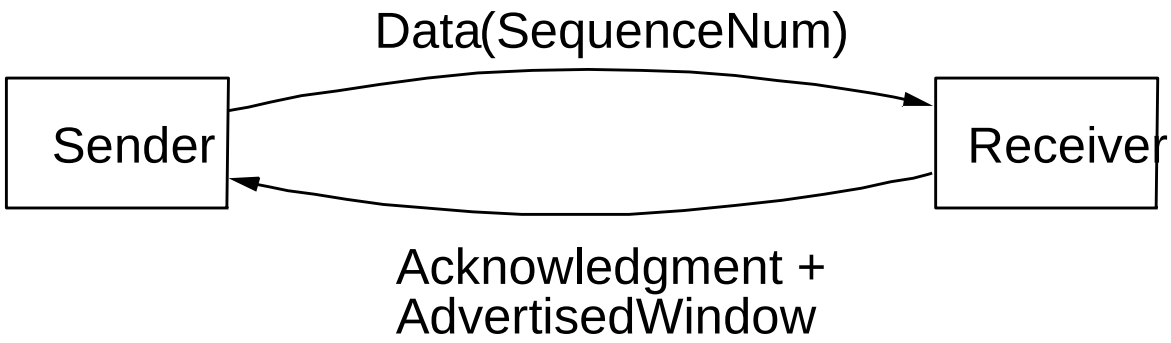

- Flags
  - **`SYN, FIN, RESET, PUSH, URG, ACK`**
- Checksum
  - pseudo header(IP) + TCP header + data

Establecimiento y Término de Conexión

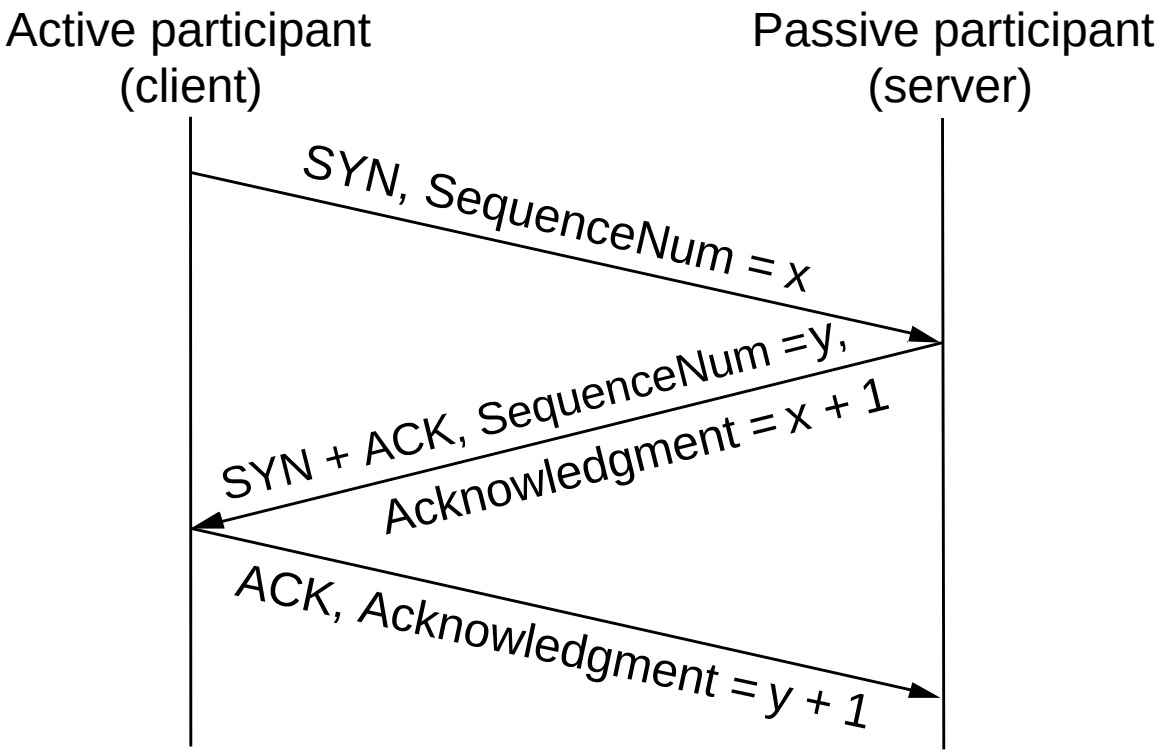

Diagrama de Estado de Transmisión

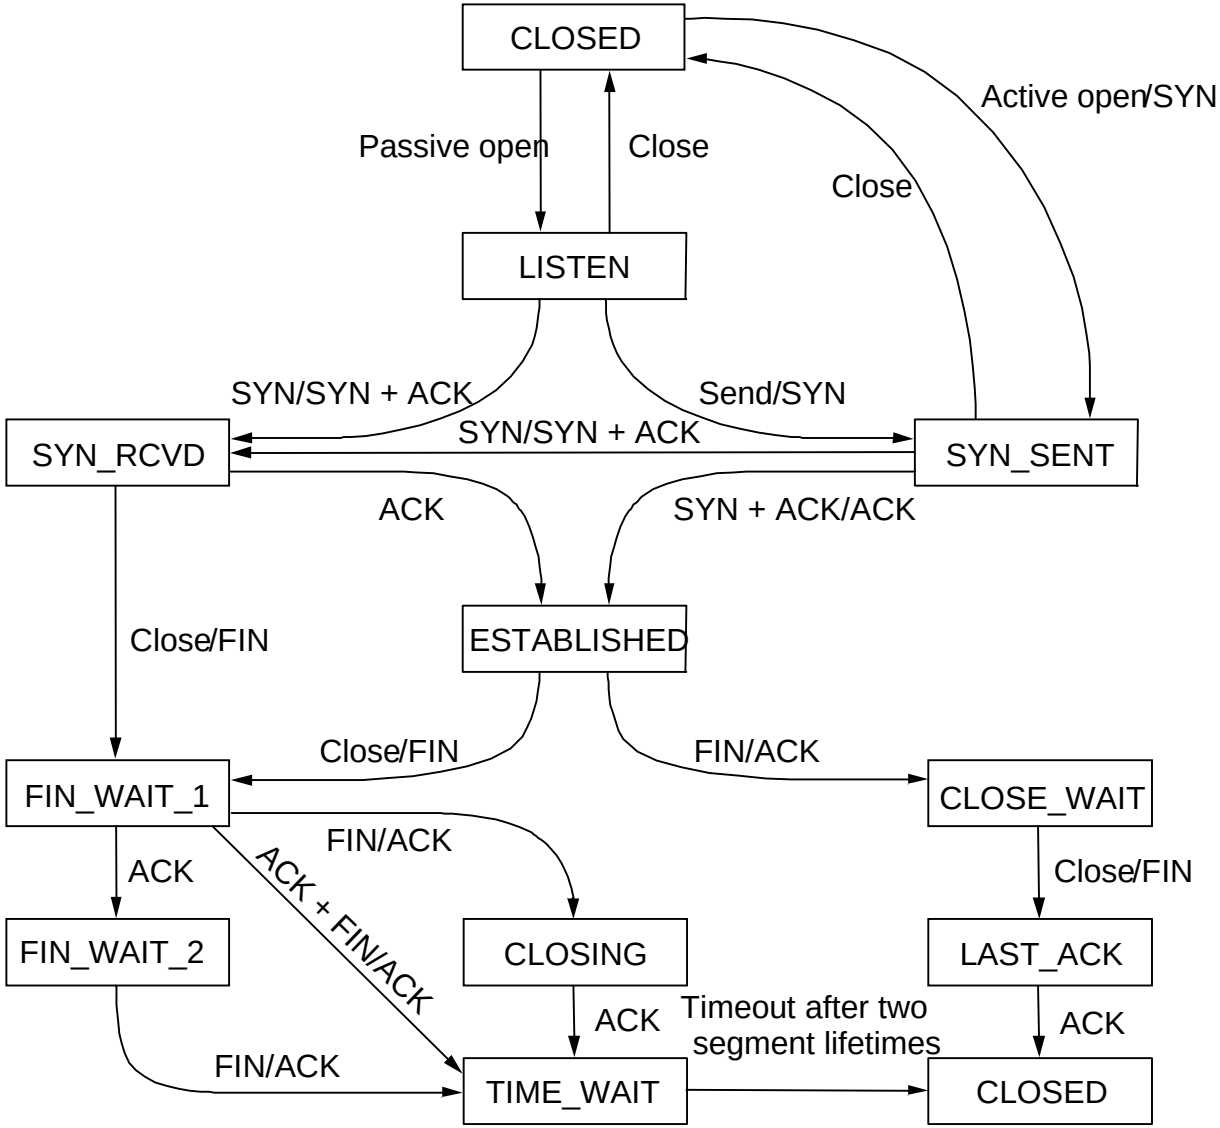

Revisión de Ventana Deslizante

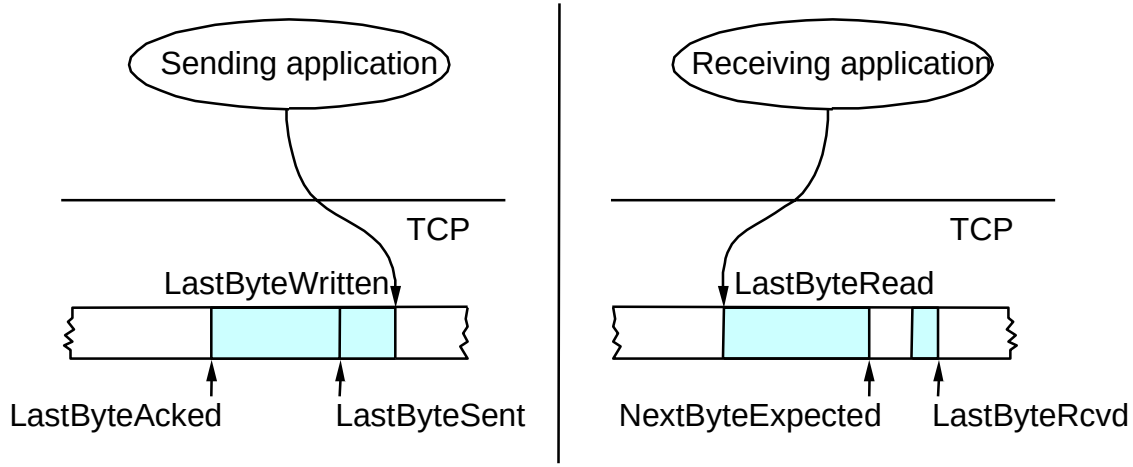

- Lado Transmisor

  `LastByteAcked` < = **`LastByteSent`**

  `LastByteSent` < = **`LastByteWritten`**

  Se tiene en buffer los bytes entre **`LastByteAcked`** y **`LastByteWritten`**

- Lado Receptor

  `LastByteRead` < **`NextByteExpected`**

  `NextByteExpected` < = **`LastByteRcvd +1`**

  Se tiene en buffer los bytes entre **`NextByteRead`** y **`LastByteRcvd`**

LastByteRead+1

Control de Flujo

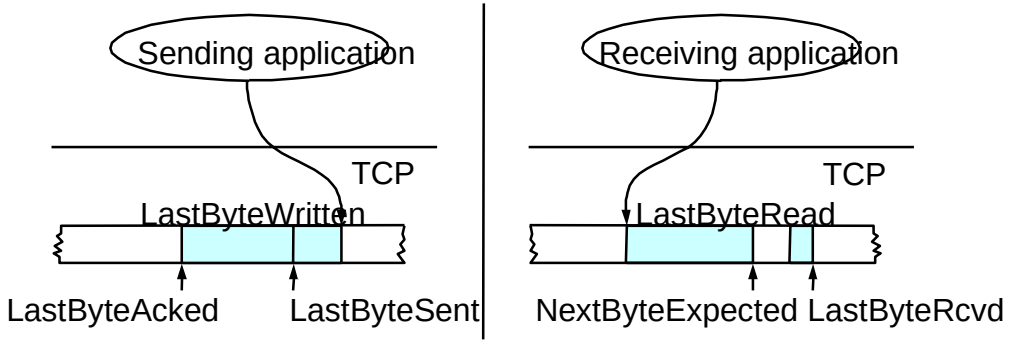

- Tamaño del buffer de envío: **`MaxSendBuffer`**
- Tamaño del buffer de recepción: **`MaxRcvBuffer`**
- Lado receptor
  - **`LastByteRcvd`** - **`LastByteRead`** < = **`MaxRcvBuffer`**
  - **`AdvertisedWindow`** = **`MaxRcvBuffer`** - (**`LastByteRcvd`** - **`NextByteRead`**)
- Lado Transmisor
  - **`LastByteSent`** - **`LastByteAcked`** < = **`AdvertisedWindow`**
  - **`EffectiveWindow`** = **`AdvertisedWindow`** - (**`LastByteSent`** - **`LastByteAcked`**)
  - **`LastByteWritten`** - **`LastByteAcked`** < = **`MaxSendBuffer`**
  - Bloquear Tx si (**`LastByteWritten`** - **`LastByteAcked`**) + *y* > **`MaxSenderBuffer`**, *`y bytes que se desean escribir.`*
- Siempre enviar ACK en respuesta a la llegada de segmentos de datos
- Tx persiste enviando 1 byte cuando **`AdvertisedWindow = 0`**

Síndrome de Ventana estúpida (Silly)

- ¿Qué tan agresivamente el Tx explota la apertura de ventana?

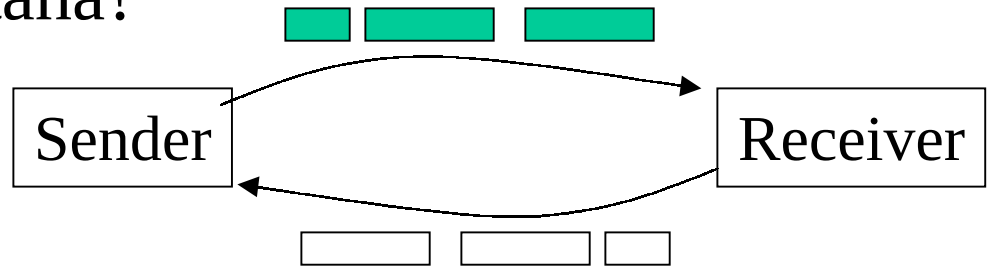

- Soluciones en lado Receptor
  - Retardar los acuses de recibo

Algoritmo de Nagle

- ¿Qué tanto tiempo el Tx retarda la transmisión de datos?
  - Demasiado largo: afecta aplicaciones interactivas
  - Demasiado corto: Utilización de la red es pobre
  - Estrategias: Basadas en timers v/s auto relojes
- Cuando la aplicación genera datos adicionales:
  - Si se llena un segmento (y la ventana está abierta): enviar
  - Sino
    - Si hay datos sin ack en Tx: dejar en buffer hasta llegada de ack
    - sino: enviar datos

Protección contra reapariciones de igual número de secuencia

- **`SequenceNum de 32 bits`**

Bandwidth	Tiempo hasta tener problema
T1 (1.5 Mbps)	6.4 hours
Ethernet (10 Mbps)	57 minutes
T3 (45 Mbps)	13 minutes
FDDI (100 Mbps)	6 minutes
STS-3 (155 Mbps)	4 minutes
STS-12 (622 Mbps)	55 seconds
STS-24 (1.2 Gbps)	28 seconds

Mantención de la tubería llena

- **`AdvertisedWindow de 16 bits`**

Bandwidth	Delay x Bandwidth Product
T1 (1.5 Mbps)	18KB
Ethernet (10 Mbps)	122KB
T3 (45 Mbps)	549KB
FDDI (100 Mbps)	1.2MB
STS-3 (155 Mbps)	1.8MB
STS-12 (622 Mbps)	7.4MB
STS-24 (1.2 Gbps)	14.8MB

64 KB

Asumiendo RTT de 100 ms

Extensiones de TCP

- Son implementadas como opciones del encabezado
- Almacenar marcas de tiempo en segmentos de salida
- Extender espacio de secuencia con marca de tiempo de 32-bit (PAWS)
- Desplazar (escalar) ventana avisada. La idea es medir la ventana en unidades de 2, 4, 8 bytes.

Retransmisión Adaptiva (Algoritmo Original)

- Mide **`SampleRTT`** para cada par segmento/ ACK
- Calcula el promedio ponderado de RTT
  - **`EstimatedRTT`** = α x **`EstimatedRTT`** + β x **`SampleRTT`**
  - donde α **`+`** β **`= 1`**
  - $0.8 <= \alpha <= 0.9$
  - $0.1 <= \beta <= 0.2$
- Fijar timeout basado en **`EstimatedRTT`**
  - **`TimeOut`** = **`2`** x **`EstimatedRTT`**

Algoritmo de Karn/Partridge

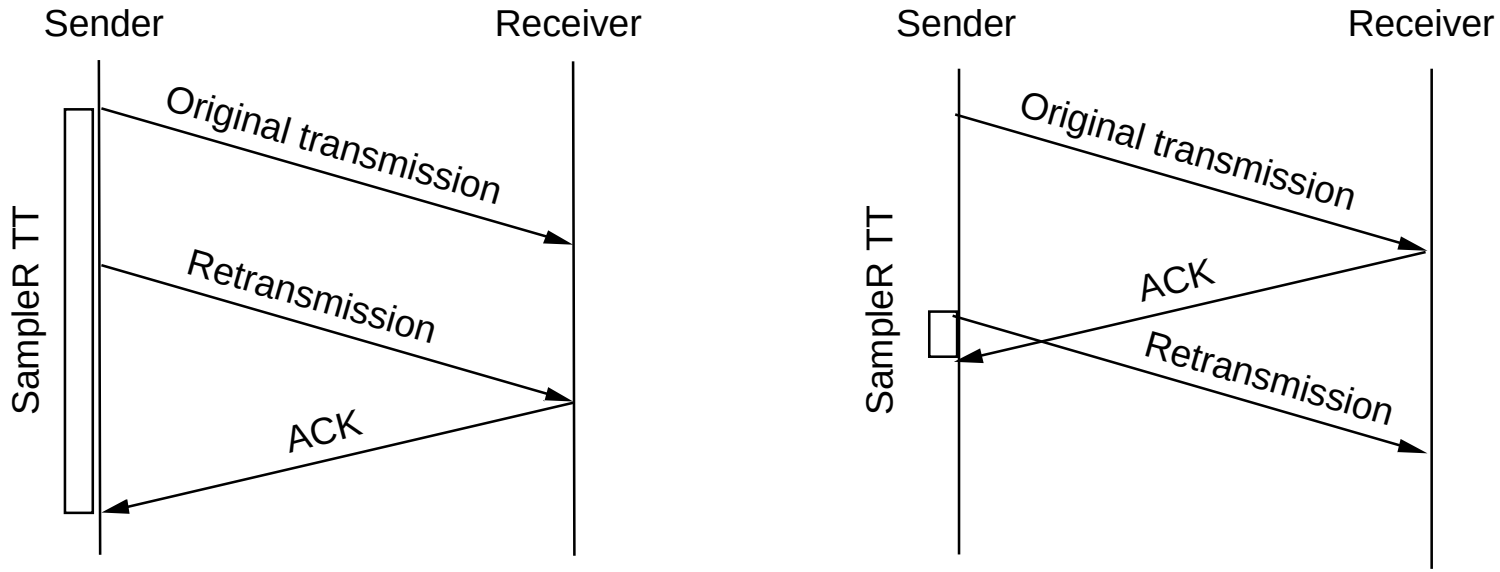

- No considerar RTT cuando se retransmite
- Duplicar timeout luego de cada retransmisión

Algoritmo de Jacobson/ Karels

- Nueva forma de calcular el promedio de RTT
- **`Diff`** = **`sampleRTT`** - **`EstRTT`**
- **`EstRTT = EstRTT + ( δ x Diff)`**
- **`Dev = Dev + δ ( |Diff| - Dev)`**
  - donde δ es un factor entre 0 y 1 (Por ejemplo 1/8)
- Considerar varianza cuando fijamos el timeout
- **`TimeOut`** = μ x **`EstRTT`** + ϕ x **`Dev`**
  - donde $\mu = 1$ y $\phi = 4$
- Notas
  - Los algoritmos son tan buenos/malos como la granularidad del reloj (500ms en Unix)
  - Un preciso mecanismo de timeout es importante para controlar la congestión (más adelante)
  - Además de controlar congestión, la idea es no retransmitir cuando no es necesario.