Capítulo 3: Capa Transporte - IV

ELO322: Redes de Computadores

Agustín J. González

Este material está basado en:

- Material de apoyo al texto *Computer Networking: A Top Down Approach Featuring the Internet 3rd* edition. Jim Kurose, Keith Ross Addison-Wesley, 2004.

Capítulo 3: Continuación

- 3.1 Servicios de la capa transporte
- 3.2 Multiplexing y demultiplexing
- 3.3 Transporte sin conexión: UDP
- 3.4 Principios de transferencia confiable de datos
- 3.5 Transporte orientado a la conexión: TCP
  - Estructura de un segmento
  - Transferencia confiable de datos
  - Control de flujo
  - Administración de conexión
- 3.6 Principios del control de congestión
- 3.7 Control de congestión en TCP

Principios del control de congestión

Congestión:

- Informalmente: “demasiadas fuentes enviando muchos datos muy rápido para que la red lo maneje”
- Es distinto a control de flujo, éste ocurre entre dos aplicaciones.
- Manifestaciones:
  - Pérdidas de paquetes (buffer overflow en routers)
  - Grandes retardos (en las colas en los router)
- Uno de los problemas top-10!

- La capa de red no ofrece garantías de: entrega de paquetes en orden, tasas de transferencia fija, llegada confiable de datos, y retardo acotado desde transmisión hasta recepción. ¿Cuáles de estos requerimientos son posibles de garantizar vía una programación adecuada de la capa de transporte?

- Entrega de paquetes en orden y llegada confiable de datos

Causas/costos de congestión: escenario 1 (buffer ∞, sin re-envío)

- dos transmisores, dos receptores
- un router, buffer tamaño infinito
- sin retransmisión
- λ_{in} datos enviados por la aplicación (bytes/sec)
- λ_{out} datos recibidos por la aplicación (bytes/sec)

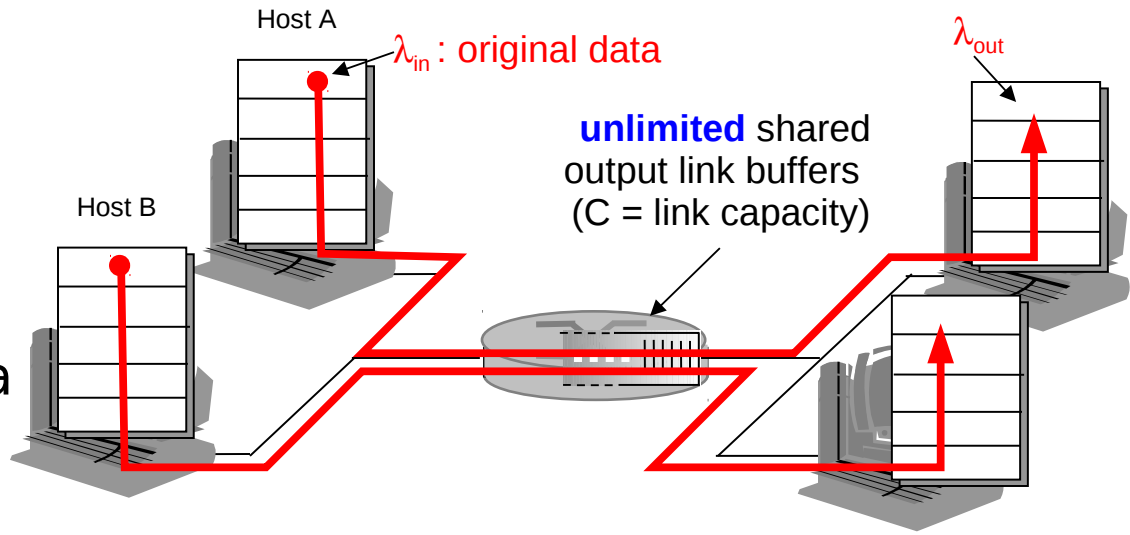

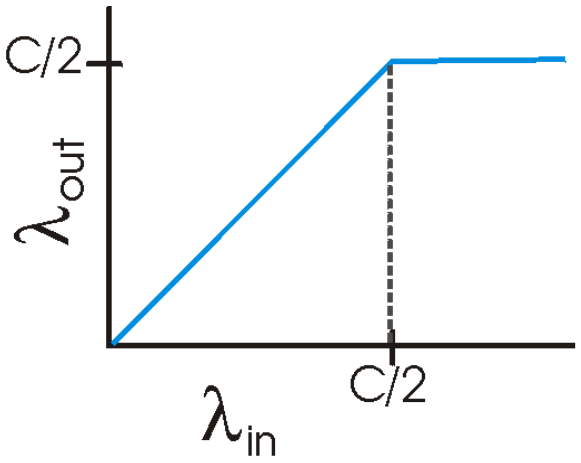

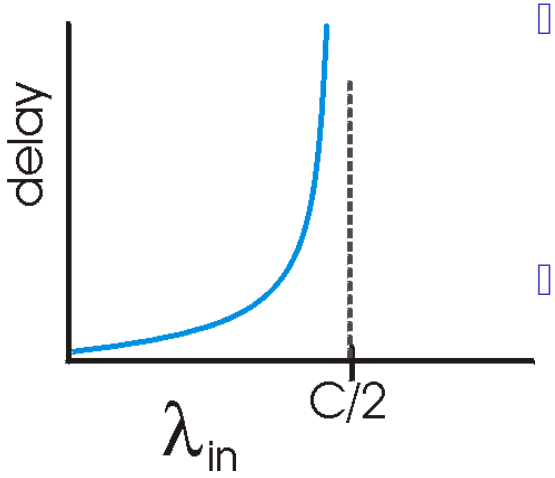

- grandes retardos en estado congestionado (muchos paquetes esperando en cola)
- máximo flujo posible (throughput = C) de datos

Causas de congestión: escenario 2 (buffer no ∞, con re-envío)

- un router, buffer *finito*
- Se pierden paquetes que no tienen espacio en buffer.
- transmisor retransmite paquetes perdidos

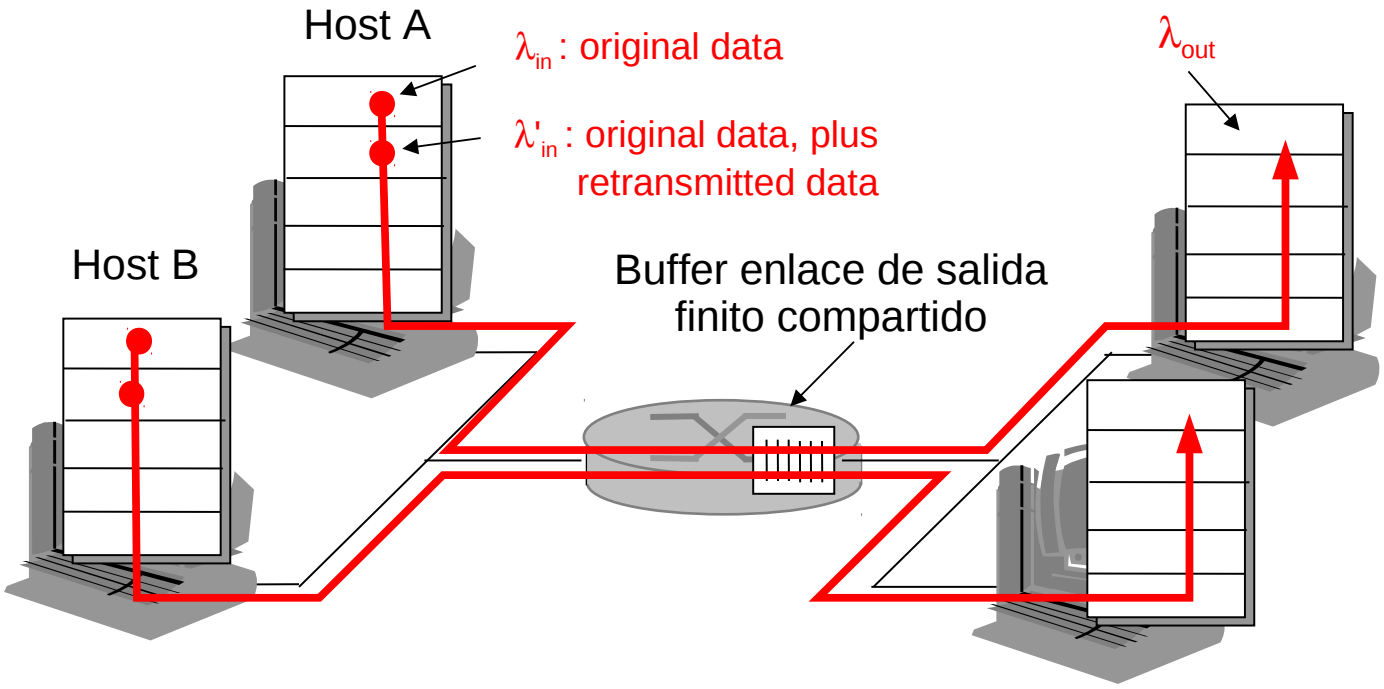

Causas/costos de congestión: escenario 2

- (a) caso perfecto, sin pérdidas ni retransmisiones: $\lambda_{in} = \lambda'_{in}$
- (b) retransmisión sólo en caso de pérdida de segmentos (no por timeout prematuro): $\lambda'_{in} > \lambda_{out}$
- (b) retransmisión de paquetes hace que λ'_{in} sea más grande (que el caso perfecto) para el mismo λ_{out} (No necesariamente R/3 como cota)
- (c) retransmisiones innecesarias (timeout prematuros) : enlaces envían múltiples copias del paquete (e.g. dos re-envíos por paquete)

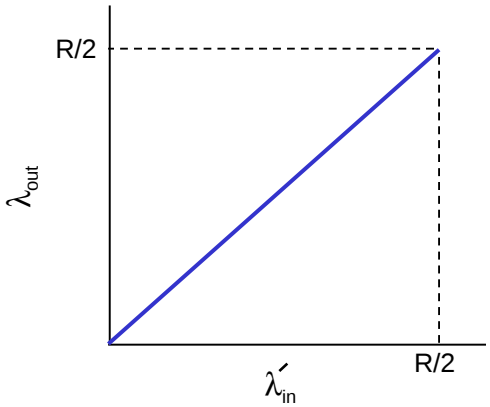

a.

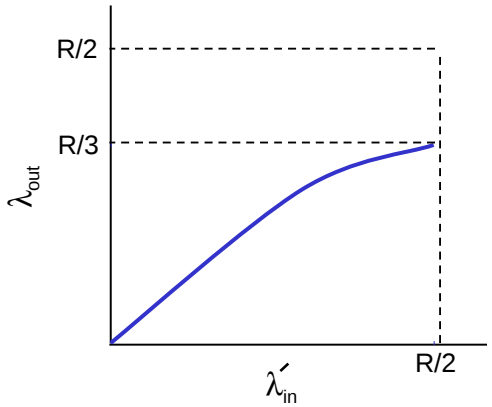

b.

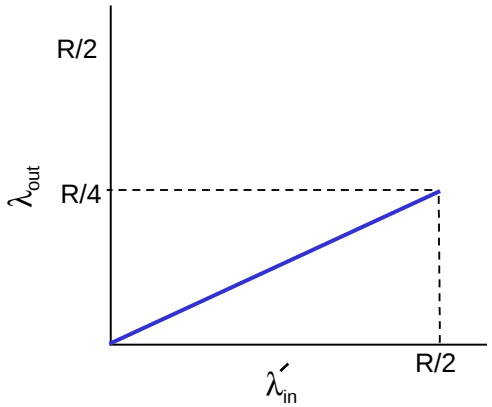

c.

"costos" de congestión:

- más trabajo (retransmisión) para lograr el transporte de datos "goodput"

Causas/costos de congestión: escenario 3

- cuatro transmisores
- rutas con multihops
- timeout/retransmisiones

Q: ¿Qué pasa cuando λ_{in} se incrementa y λ'_{in} crece?

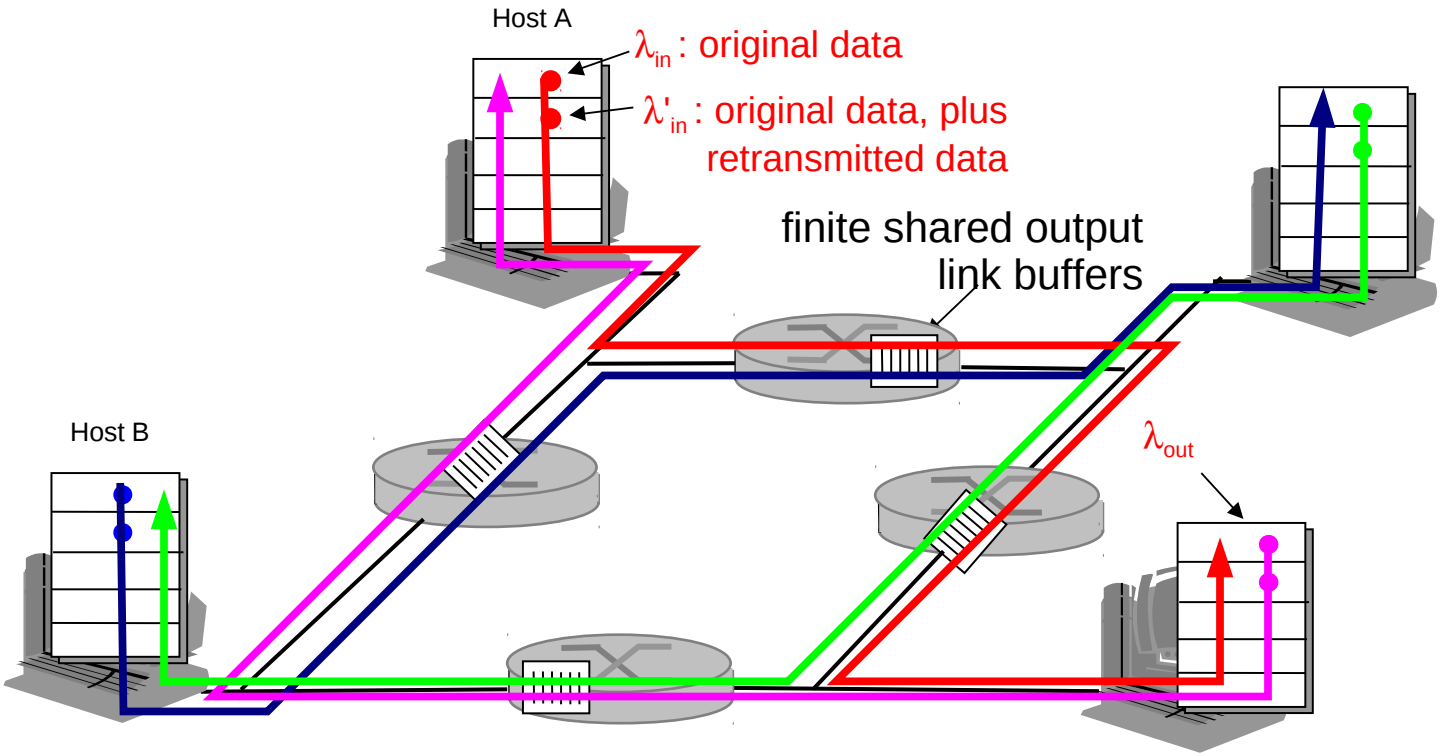

Causas/costos de congestión: escenario 3

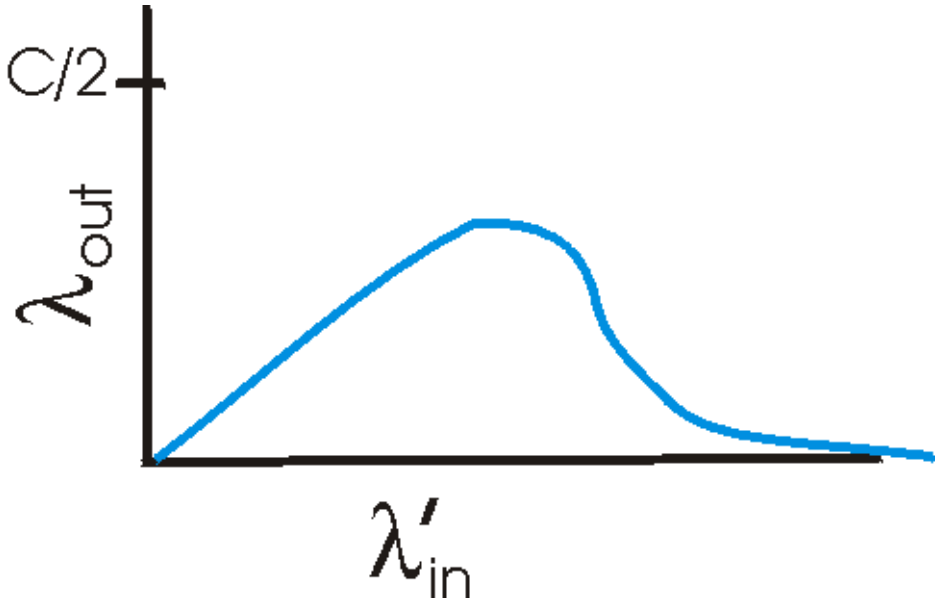

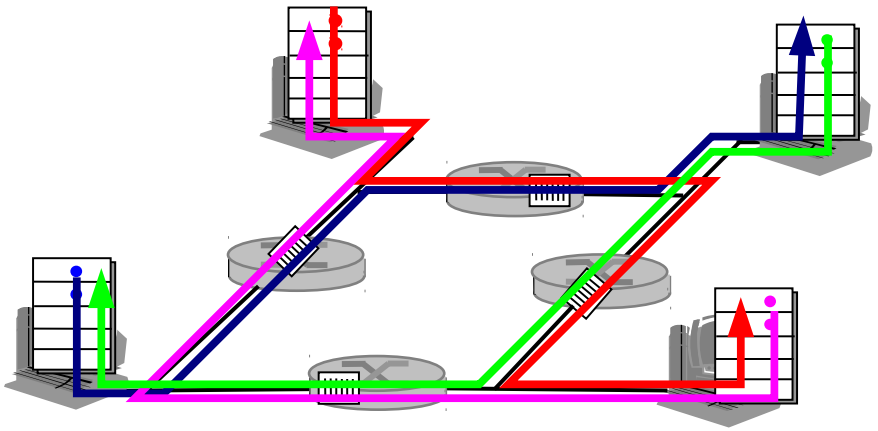

Otro “costo” de congestión:

- cuando se descartan paquetes, cualquier capacidad (de router) usada anteriormente pasa a ser un recurso desperdiciado!

Estrategias para control de congestión

Los podemos clasificar en dos grupos amplios:

Control de congestión extremo a extremo:

- No hay información de realimentación explícita de la red
- La congestión es inferida desde las pérdidas y retardos observados por terminales en los extremos
- **Es la estrategia usada por TCP**

Control de congestión asistido por la red:

- routers proveen realimentación a sistemas extremos
  - Un Bit único indicando congestión (e.g. SNA, DECbit, TCP/IP ECN, ATM)
  - Explícitamente se informa al Tx la tasa que el router puede soportar

Caso de estudio: Control de congestión en ATM ABR (tecnología de red capa 3 y menores)

ABR: Available Bit Rate:

- Es un servicio “elástico” o flexible
- Si camino del Tx tiene poca carga,
  - Tx debería usar ancho de banda disponible
- Si camino de Tx a Rx está congestionado,
  - Tx reduce a un mínimo la tasa garantizada

Celdas RM (Resource Management):

- Enviadas a intervalos por Tx entre celdas de datos
- bits en celda RM son modificados por switches
  - Bit NI: no incrementar tasa (= congestión moderada)
  - Bit CI: Congestion Indication
- Celdas RM son retornadas al Tx por el Rx con bits intactos

ATM: Asynchronous Transfer Mode

Caso de estudio: Control de congestión en ATM ABR

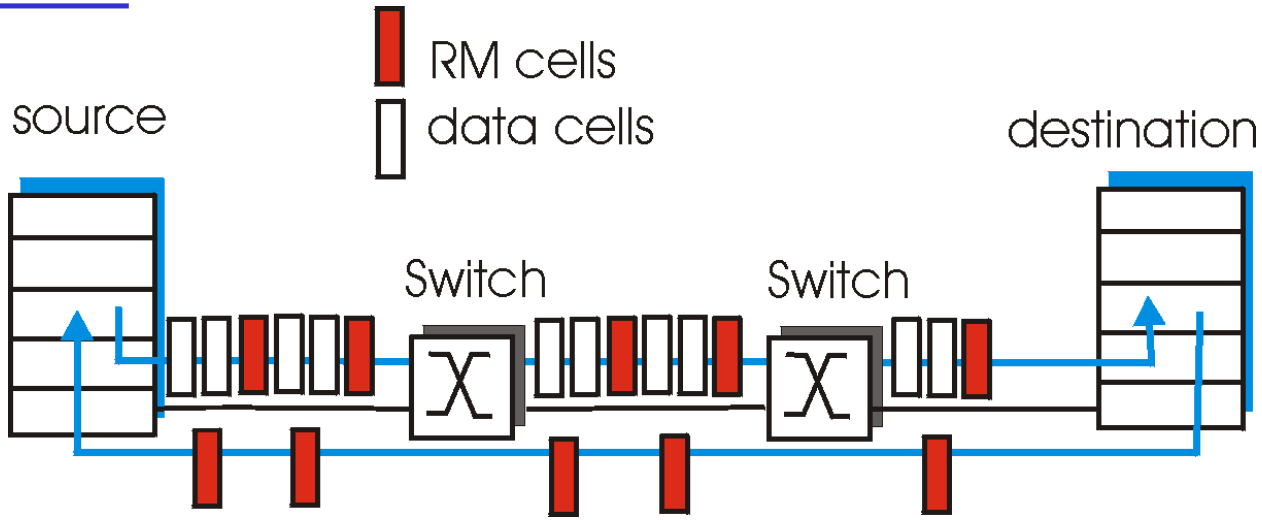

- En celda RM hay campo ER (explicit rate) de dos bytes:
  - Un Switch congestionado puede bajar valor de ER en la celda
  - Tasa de envío del Tx se ajusta a la tasa mínima soportable en el camino entre fuente y destino (la del switch más crítico)
- En celda de datos hay Bit EFCI (explicit forward congestion indicator): éste es fijado en 1 por switch congestionado
  - Si celda de datos precedente a celda RM tiene el EFCI marcado, el destino marca bit CI en celda RM retornada.

TCP corriendo sobre IP espera hasta recibir tres paquetes ACK duplicados para iniciar una retransmisión rápida. ¿Por qué piensa usted que los diseñadores de TCP no escogieron iniciar la retransmisión rápida tan pronto llega el primer ACK duplicado? ¿Se justifica la espera por tres ACKs duplicados en la implementación de un protocolo confiable en una red ATM? Explique.

?

La retransmisión no se efectúa ante la llegada del primer duplicado pues es posible que el primer paquete haya tomado una ruta más larga y llegue con posterioridad al segundo. En este caso, un cambio de orden de llegada genera acuses de recibo duplicados pero no constituye pérdida de paquete.

No se justifica esperar tres ACKs en ATM pues ésta establece una conexión entre fuente y destino luego todos los paquetes deben usar la misma ruta y con ello el orden de salida y llegada se mantiene cuando no hay pérdidas.

Capítulo 3: Continuación

- 3.1 Servicios de la capa transporte
- 3.2 Multiplexing y demultiplexing
- 3.3 Transporte sin conexión: UDP
- 3.4 Principios de transferencia confiable de datos
- 3.5 Transporte orientado a la conexión: TCP
  - Estructura de un segmento
  - Transferencia confiable de datos
  - Control de flujo
  - Administración de conexión
- 3.6 Principios del control de congestión
- 3.7 Control de congestión en TCP

Control de Congestión en TCP

- Usa control extremo a extremo (sin asistencia de la red)
- Tx limita su ventana de transmisión:

$$LastByteSent - LastByteAcked \leq min\{CongWin, RcvWindow\}$$

- Si Rx tiene espacio, se tiene:

$$\text{tasa}_{Aprox} = \frac{CongWin}{RTT} \text{ [Bytes/sec]}$$

- **CongWin** es dinámica y función de la congestión percibida de la red
- **RcvWindow** es el número de bytes que el Rx puede recibir en su buffer, la suponemos grande y no limita la tasa de envío.

¿Cómo el Tx percibe la congestión?

- Evento de pérdida = timeout ó 3 acks duplicados
- Tx TCP reduce tasa (**CongWin**) después de un evento de pérdida

Hay tres mecanismos:

- AIMD (Additive-Increase, Multiplicative-Decrease)
- "Partida lenta"
- Conservativo después de evento de timeout

TCP AIMD (Additive-Increase, Multiplicative-Decrease)

- Decrecimiento multiplicativo: reducir **CongWin** a la mitad luego de pérdida

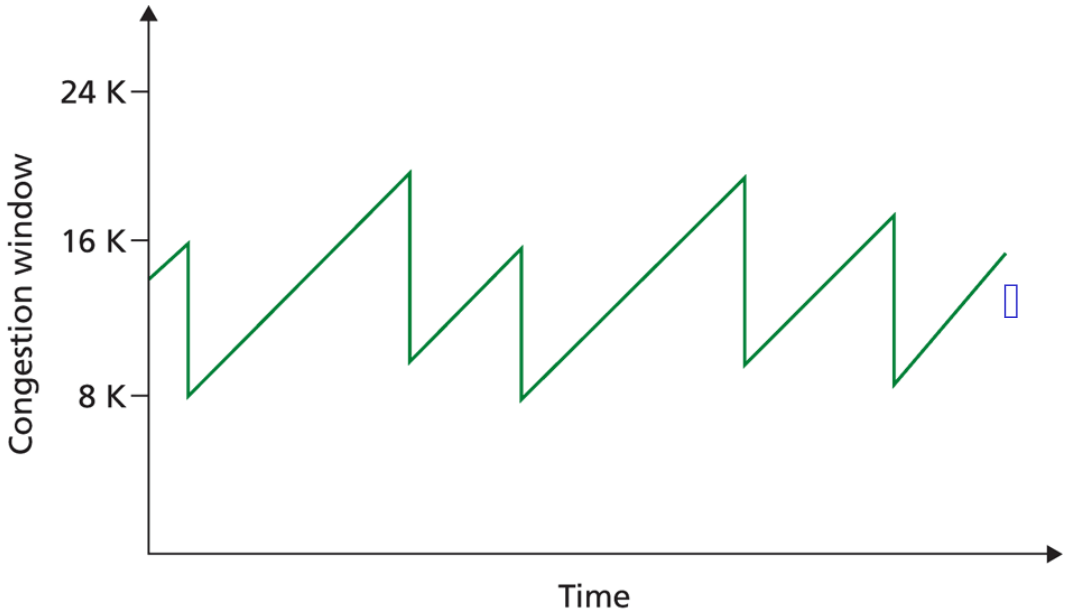

- Aumento aditivo: aumenta **CongWin** en 1 MSS cada RTT en ausencia de pérdida. En algunas implementaciones **CongWin** incrementa en MSSx(MSS/CongWin) por cada ACK recibido.
- MSS (Maximum Segment Size) es la máxima cantidad de datos que se envía en cada segmento sin fragmentarse.

Figure 3.50 ♦ Additive-increase, multiplicative-decrease congestion control

Indique qué protocolo usa el tamaño de segmento máximo (MSS, Maximum Segment Size). ¿A qué corresponde?

?

- El MSS es usado por TCP. Corresponde al MTU (Maximum Transmission Unit) más pequeño en la ruta de la fuente al destino. Usando segmentos de tamaño MSS, TCP asegura que sus paquetes no serán fragmentados.

Aumento aditivo

- La idea es aumentar un MSS luego de un RTT.
- Podemos aproximarnos aumentando la CongWin cada vez que se recibe un ACK de manera que al completar 1 RTT hayamos sumado un MSS.

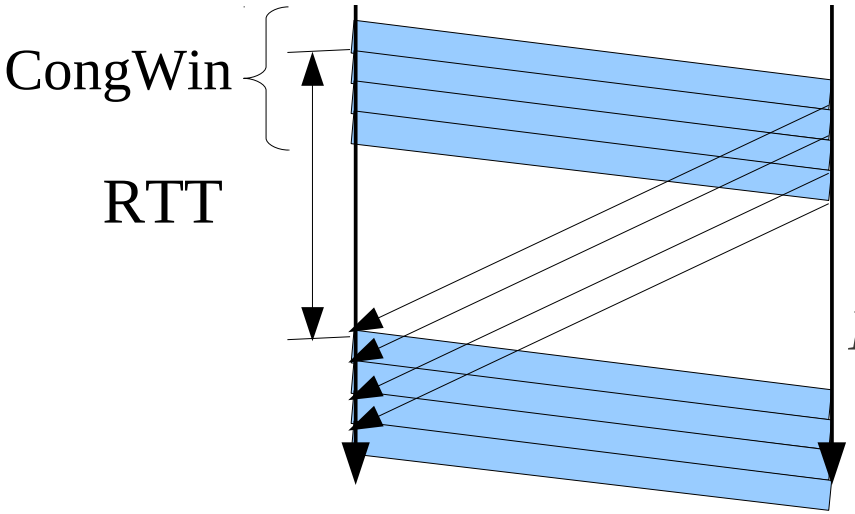

- Se envía como máximo CongWin bytes y esperamos por el acuse de recibo.

$$NumSegmentos = NumAkcs = \frac{CongWin}{MSS}$$

$$Incr. = \frac{MSS}{NumAkcs} = \frac{MSS}{\frac{CongWin}{MSS}} = \frac{MSS * MSS}{CongWin}$$

- Incr. : Incremento por cada ACK

Si hay ACK retardados, el incremento debe ser mayor

Partida lenta en TCP (slow start)

- Cuando la conexión comienza, **`CongWin`** = 1 MSS
  - Ejemplo: MSS = 500 bytes & RTT = 200 msec
  - Tasa inicial = 20 kbps
- Ancho de banda disponible puede ser >> MSS/RTT
  - Es deseable aumentar tasa rápidamente hasta una tasa respetable
- Cuando la conexión comienza, aumentar tasa exponencialmente rápido hasta tener primer evento de pérdida
- Se le llama Slow Start porque parte desde tasa muy abaja.

Partida Lenta en TCP (más)

- Cuando la conexión comienza, aumentar tasa exponencialmente hasta primera pérdida:
  - Duplicar **`CongWin`** cada RTT
  - Es hecho incrementando **`CongWin`** en 1 MSS por cada ACK recibido
- Resumen: tasa inicial es lenta pero se acelera exponencialmente rápido

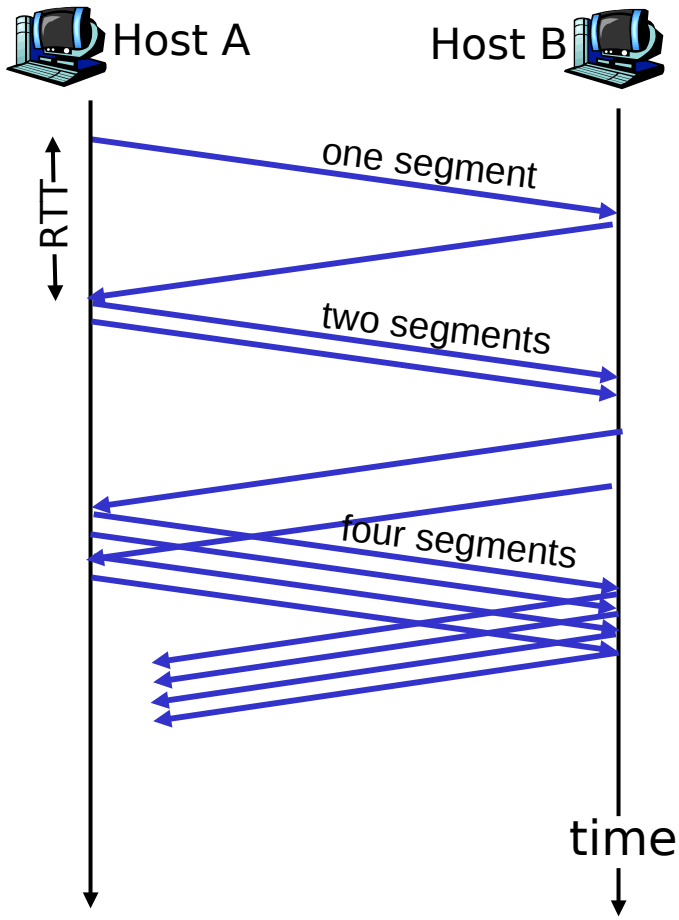

Reacción ante eventos de timeout

Q: ¿Cuándo debería cambiar el aumento de exponencial a lineal?

A: Un buen criterio es: Cuando **`CongWin`** llega a 1/2 de su valor antes del timeout.

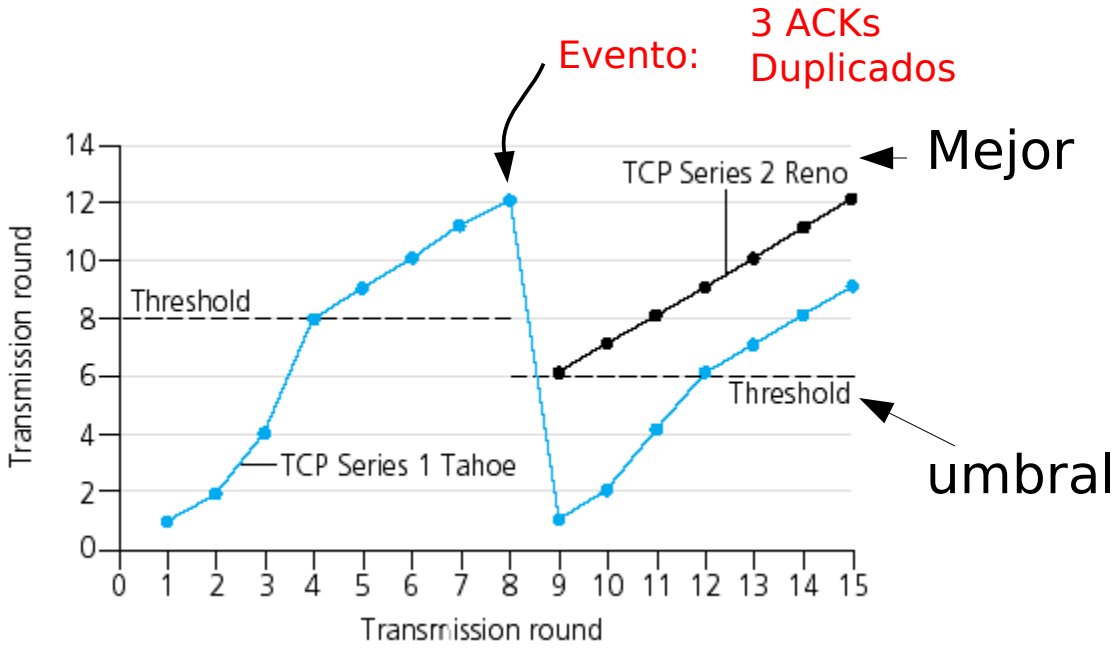

Implementación:

- Umbral variable (variable threshold)
- Ante evento de pérdidas, el umbral es fijado en 1/2 de CongWin justo antes de la pérdida

Tahoe: primera versión de control de congestión en TCP. No distinguía entre timeout o ACK duplicados.

Reno: versión siguiente en TCP. Sí distingue timeout de ACK duplicados. Es como TCP opera hoy.

Reacción ante eventos de timeout (cont)

- Después de 3 ACKs duplicados:
  - **CongWin** baja a la mitad
  - Luego la ventana crece linealmente
- Después de un timeout:
  - **CongWin** es fijada en 1 MSS;
  - Luego la ventana crece exponencialmente hasta un umbral, luego crece linealmente

Filosofía:

- 3 ACKs duplicados indican que la red es capaz de transportar algunos segmentos (sólo llegan fuera de orden en el Rx). Se perdió uno pero llegaron los otros y por eso tenemos ACKs duplicados
- timeout antes de 3 duplicados es “más alarmante” (no llegaron!)

En ausencia de errores y cuando el buffer de recepción es muy grande, la tasa promedio de transferencia de TCP durante un RTT se puede aproximar por (Tamaño de Ventana de congestión)/RTT. Muestre un diagrama que explique la deducción de esta expresión. ¿Es esta expresión válida para todo valor de “Ventana de Congestión”? Explique.

?

- Luego de enviar la ventana W, el Tx debe esperar la llegada del acuse de recibo más antiguo para retomar la transmisión.
- No es válida siempre, pues conforme la ventana de congestión aumenta, aumenta la utilización del canal y cuando ésta alcanza 100% no es posible seguir aumentando la tasa pues la tasa de transmisión del enlace pone una cota máxima.

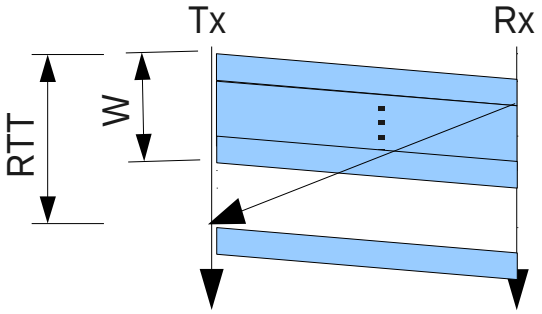

Resumen: Control de Congestión en TCP

- Cuando **CongWin** está bajo el **Threshold (umbral)**, Tx está en fase slow-start, la ventana de transmisión crece exponencialmente (un MSS por cada ACK).
- Cuando **CongWin** está sobre **Threshold**, Tx está en fase abolición de congestión, la ventana crece linealmente (aprox. un MSS por cada RTT).
- Al tercer ACK duplicados, **Threshold** pasa a **CongWin/2** y **CongWin** pasa a **Threshold**.
- Cuando ocurre un timeout, **Threshold** pasa a **CongWin/2** y **CongWin** se lleva a 1 MSS.

Control de congestión del Tx TCP

State	Event	TCP Sender Action	Commentary
Slow Start (SS)	ACK receipt for previously unacked data	CongWin = CongWin + MSS, If (CongWin > Threshold) set state to “Congestion Avoidance”	Resulta en una duplicación de CongWin cada RTT.
Congestion Avoidance (CA)	ACK receipt for previously unacked data	CongWin = CongWin+MSS * (MSS/CongWin)	Aumento aditivo, resulta en aumento de CongWin en apox. 1 MSS cada RTT
SS or CA	Loss event detected by triple duplicate ACK	Threshold = CongWin/2, CongWin = Threshold, Set state to “Congestion Avoidance”	Recuperación rápida, implementando reducción multiplicativa. CongWin no caerá a 1 MSS.
SS or CA	Timeout	Threshold = CongWin/2, CongWin = 1 MSS, Set state to “Slow Start”	Ingresa a Partida Lenta (slow start)
SS or CA	Duplicate ACK	Increment duplicate ACK count for segment being acked	CongWin y Threshold no cambian

Throughput Simplificado de TCP (tasa de transferencia de datos lograda)

- ¿Cuál es el throughput promedio de TCP como una función del tamaño de ventana **CongWin** y RTT?
  - Ignoremos slow start ya que al ser exponencial es una fase muy corta
- TCP pide ancho de banda adicional al incrementar W en 1 MSS por cada RTT hasta una pérdida
- Sea W el tamaño de la ventana (en bytes) cuando ocurre una pérdida.
- Cuando la ventana es W, el throughput es W/RTT
- Justo después de la pérdida, la ventana cae a W/2, y el throughput a W/2RTT.
- Throughput promedio entre W/2RTT y W/RTT es 0.75 W/RTT
- Esto debido a que el throughput crece linealmente entre ambos valores.

Futuro de TCP

- Ejemplo: segmentos de 1500 bytes, RTT de 100ms, queremos throughput de 10 Gbps
- Requiere tamaño de ventana **`CongWin`** W = 83.333 (segmentos en tránsito)
- Throughput en términos de tasa de pérdida (L) es:

$$Avg.Throughput = \frac{1{,}22 * MSS}{RTT\sqrt{L}}$$

  L=(bytes perdidos)/(Número total enviados)
- Para el throughput deseado con el algoritmo de control de congestión actual se toleran probabilidades de pérdida de sólo L = $2 \cdot 10^{-10}$ *Wow (1 cada 5 mil millones de segmentos)*
- Se requieren nuevas versiones de TCP para enlaces de alta velocidad (interesados ver RFC 3649)

¿Por qué la ventana de congestión de TCP sólo se reduce a la mitad cuando la pérdida es detectada por 3 ACKs duplicados, mientras que se reduce a 1 MSS cuando la pérdida es detectada por timeout?

?

Porque la llegada de 3 ACKs duplicados es una indicación que paquetes posteriores al perdido sí llegaron, luego esta situación de congestión es menos crítica que cuando hay timeout sin 3 ACKs duplicados.

Equidad en TCP

- Objetivo de la Equidad (fairness): Si K sesiones TCP comparten un mismo enlace de ancho de banda R, cada una debería tener una tasa promedio de R/K

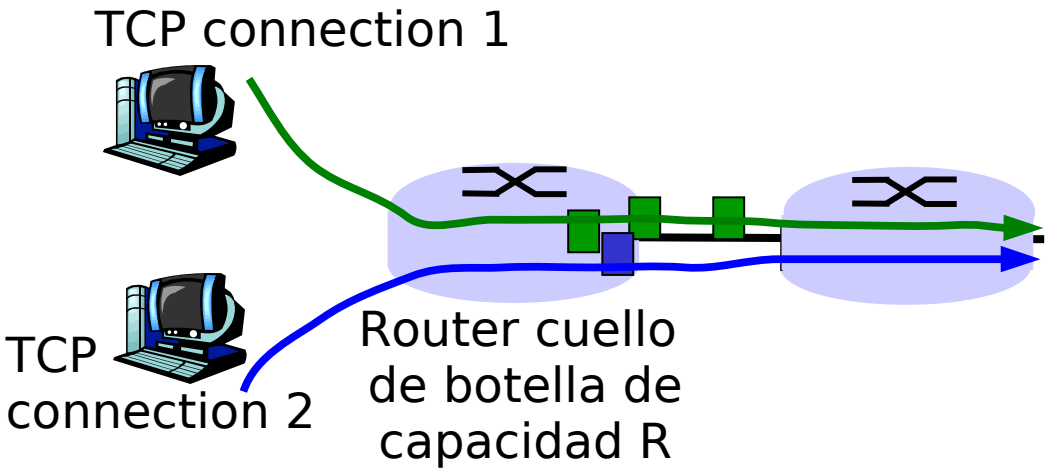

¿Por qué TCP es justa?

Supongamos dos sesiones compitiendo:

- Aumento aditivo da pendiente de 1, como aumento de throughout
- Reducción multiplicativa reduce throughput proporcionalmente

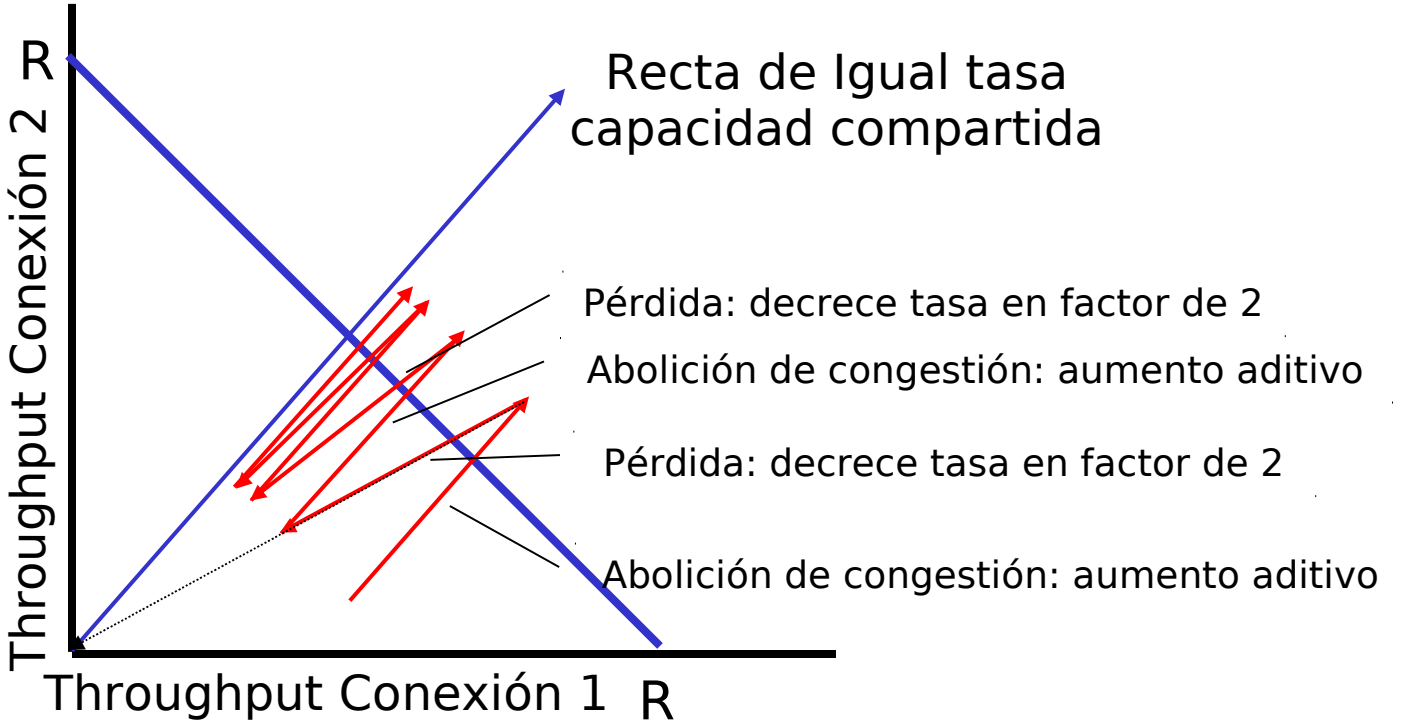

Equidad (más)

Equidad y UDP

- Aplicaciones Multimedia no usan TCP
  - No quieren tasa limitada por control de congestión
- En su lugar usan UDP:
  - Envían audio/vídeo a tasa constante y toleran pérdidas de paquetes
- Área de investigación: Hacerlas amistosas con TCP (TCP friendly)

Equidad y conexiones TCP paralelas

- Nada previene a las aplicaciones de abrir conexiones paralelas entre dos hosts.
- Navegadores WEB hacen esto
- Ejemplo: Sea un enlace de tasa R soportando 9 conexiones;
  - Una aplicación nueva pide 1 conexión TCP, obtendrá R/10
  - Si la aplicación nueva pide 11 conexiones TCP, ésta obtendrá 11R/20 , más de R/2!

En una subred hay 6 usuarios viendo vídeos de Youtube.com vía conexiones TCP. ¿Si éstos fueran los únicos usuarios, qué fracción de la capacidad de un enlace congestionado le debería corresponder a cada uno?

?

1/6.

Nota: Se supone que ese es el único tráfico en el enlace congestionado; en otro caso será la misma fracción del tráfico para cada conexión.

Capítulo 3: Resumen

- Principios detrás de los servicios de capa transporte:
  - multiplexing, demultiplexing
  - Transferencia confiable de datos
  - Control de flujo
  - Control de congestión
- Uso e implementación en Internet
  - UDP
  - TCP

A continuación

- Dejaremos la “periferia” o “edge” de la red (capas aplicación y transporte)
- Nos internaremos en el centro de la red “network core”