

Control de Congestión

Contenidos


Disciplina de encolado

Reaccionando ante Congestión

Abolición de Congestión

Problemas

- Control de Congestión: Es el esfuerzo hecho por los nodos de la red para prevenir o responder a sobrecargas de la red que conducen a pérdidas de paquetes.
- Los dos lados de la moneda
 - Pre-asignar recursos (ancho de banda y espacio de buffers en routers y switches) para abolir congestión
 - Controlar la congestión si ocurre (y cuando ocurra)




- Objetivo: asignar los recursos de la red en forma “equitativa”; es decir cuando haya problemas compartir sus efectos entre todos los usuarios, en lugar de causar un gran problema a tan solo unos pocos.

Problemas (cont)

- Control de flujo v/s control de congestión: el primero previene que los transmisores sobrecarguen a receptores lentos. El segundo evita que los transmisores sobrecarguen el interior de la red.
- Dos puntos para su implementacion
 - maquinas en los extremos de la red (protocolo de transporte)
 - routers dentro de la red (disciplina de encolado)
- Modelo de servicio de los niveles inferiores
 - best-effort o mejor esfuerzo (lo asumimos por ahora). Es el servicio de Internet.
 - múltiples *calidades de servicio* QoS (mas adelante). Por ejemplo ancho de banda (para video streaming bajo) y retardo (para Voz sobre IP VoIP).

Marco de trabajo


- Caso no internet (como ATM, X.25) hay servicios orientados a la conexión. Se reserva ancho de banda y espacio al establecer la conexión. => subutilización de recursos.
- Flujos de datos no orientados a la conexión (Caso Internet)
 - secuencia de paquetes enviados entre el par fuente/destino
 - mantenemos estado transiente en el router



- Taxonomía
 - Centrado en router versus centrado en los hosts
 - basados en reservación versus los *basados en realimentación*
 - basados en ventanas versus los basados en tasa de transferencia

Criterios de Evaluación

- La idea es que la red sea *utilizada eficientemente* y al mismo tiempo en forma *equitativa*
- Buen indicador para eficiencia: $\text{Potencia} = \text{throughput} / \text{retardo}$



Criterios de Evaluación



- Equidad: los recursos sean compartidos equitativamente.
- Indicador de equidad de Jain: Dados flujos por un enlace (x_1, x_2, \dots, x_n)

$$f(x_1, x_2, \dots, x_n) = \frac{\left(\sum_{i=1}^n x_i\right)^2}{n \sum_{i=1}^n x_i^2}$$

- $0 \leq f \leq 1$

Disciplinas de Encolado

- Hay que distinguir entre disciplina para sacar paquetes del buffer (programación) y disciplina de descarte de paquetes
- Disciplinas de programación: FIFO y Encolado equitativo
- First-In-First-Out (FIFO)
 - No discrimina entre fuentes de tráfico
 - Problema: no discrimina entre diferentes fuentes de tráfico.
- Fair Queuing (FQ) (encolado equitativo)
 - explícitamente segrega tráfico basado en los flujos (varias colas)
 - asegura que ningún flujo tomará más de su cuota de capacidad
 - variación: weighted fair queuing (WFQ) (encolado equitativo ponderado)
- Problema?:
 - paquetes de distinto tamaño




Algoritmo FQ

- Idealmente queremos round-robin bit a bit.
- Supongamos que un reloj hace tic cada vez que un bit es transmitido
- Sea P_i el largo del paquete i medido en tics
- Sea S_i el tiempo cuando comenzamos a transmitir el paquete i
- Sea F_i el tiempo cuando terminamos de transmitir el i
- $F_i = S_i + P_i$
- Cuando el router comienza a transmitir el paquete i ?
 - Si esto es antes que el router termine de transmitir el paquete $i - 1$ de este flujo, entonces i es transmitido inmediatamente después del ultimo bit de $i - 1$ (F_{i-1})
 - Si no hay paquetes actuales de este flujo, entonces comenzar a transmitir cuando el paquete llegue (digamos tiempo A_i)
- Así: $F_i = \text{MAX} (F_{i-1}, A_i) + P_i$

Algoritmo FQ (cont)

- Para múltiples flujos
 - calcula F_i para cada paquete que llega en cada flujo
 - Tratar todos los F_i 's como marcas de tiempo
 - el próximo paquete a transmitir es el con marca de tiempo mínima
- No es perfecto: no puede retrasar el paquete actual

Ejemplo



Comentarios sobre FQ

- Puede ser combinado con varias políticas de descarte.
- Existen esquemas ponderados. En estos se asigna distinta tasa de salida a cada flujo. Por ejemplo, para acceso internet: red de alumnos 2, profesores 2 y memoristas 1 ($2/5$, $2/5$ y $1/5$ del ancho de banda).
- Se puede considerar también FQ en términos de clases de tráfico (usando campo Type of service de IP, se usan tres bits 0= best effort, 7 mayor prioridad).

Control de Congestión en TCP

- Idea
 - TCP asume red de “mejor esfuerzo” (routers FIFO o FQ) cada fuente determina por si misma la capacidad de la red.
 - Usa reglamentación implícita
 - ACKs regulan el paso transmisiones. Cuando llega un ACK implica que un paquete salió de la red (*self-clocking*).
- Desafíos
 - determinación de la capacidad disponible en primer lugar
 - ajustes a los cambios en la capacidad disponible

Incremento aditivo/Decremento multiplicativo


- Objetivo: ajustarse a los cambios en la capacidad disponible
- Nueva variable de estado por conexión: **CongestionWindow**
 - limita cuantos datos la fuente tiene en transito (en la red)
$$\text{MaxWin} = \text{MIN}(\text{CongestionWindow}, \text{AdvertisedWindow})$$
$$\text{EffWin} = \text{MaxWin} - (\text{LastByteSent} - \text{LastByteAcked})$$
 - Así TCP no envía lo mas restrictivo entre lo que el destino y la red pueden aceptar
- Como TCP llega a un buen valor para **ContentionWindow** ?
- Idea:
 - aumentar **CongestionWindow** cuando la congestión se reduce
 - reducir **CongestionWindow** cuando la congestión aumenta

Incremento aditivo/Decremento multiplicativo (cont)

- Pregunta: como la fuente determina si la red está o no congestionada?
- Respuesta: a timeout ocurre
 - timeout indica que un paquete se perdió
 - Paquetes son raramente perdidos debido a errores de transmisión (ruido en la líneas etc..)
 - Paquetes perdidos implican congestión

Incremento aditivo/Decremento multiplicativo (cont)

- Algoritmo
 - Incrementar **CongestionWindow** en un paquete por RTT (*incremento lineal*)
 - dividir **CongestionWindow** por dos cada vez que ocurre un timeout (*decremento multiplicativo*)




- En práctica: incrementar un poco por cada ACK
$$\text{Increment} = (\text{MSS} * \text{MSS}) / \text{CongestionWindow}$$
$$\text{CongestionWindow} += \text{Increment}$$

MSS: Maximum Segment Size


Incremento aditivo/Decremento multiplicativo (cont)

- Traza: comportamiento diente de sierra



Partida lenta (Slow Start)


- Objetivo: determinar la capacidad disponible, i.e. llegar a la ventana de congestión mas rápidamente que incrementando de a un paquete.
- Idea:
 - comenzar con `CongestionWindow = 1` paquete
 - duplicar `CongestionWindow` cada RTT (incrementar en 1 paquete por cada ACK)
- Su nombre se debe a que originalmente TCP enviaba toda la ventana avisada.



Partida lenta (cont)

- Crecimiento exponencial, pero más lenta que toda la ventana avisada de una vez
- Cuando es usado...
 - recién iniciada la conexión
 - cuando la conexión se cuelga esperando por un timeout. Al reiniciarse tendría toda la ventana libre para enviar como al partir.


- Traza




- Problema: al comienzo puede llegar a perder hasta la mitad de una **CongestionWindow** en datos (duplica la ventana justo antes que un paquete se pierde en el camino)

Retransmisiones rápidas y Recuperaciones Rápidas

- Problema: granularidad gruesa del timeout de TCP conduce a periodos de no actividad
- Retransmisiones rápidas: usa ACKs duplicados para gatillar retransmisión



Resultados




- Recuperación rápida cuando usamos retransmisiones rápidas
 - saltar la fase de partida lenta
 - ir directamente a la mitad de la ultima **CongestionWindow (ssthresh)** exitosa

Abolición de la Congestión

- Estrategia de TCP
 - Controlar congestión una vez que esta ocurre
 - Repetidamente incrementar la carga en un intento de encontrar el punto al cual la congestión ocurre y luego retroceder
- Estrategia Alternativa
 - predecir cuando la congestión está a punto de ocurrir
 - reducir la tasa antes que empiecen a descartarse paquetes
 - llamamos a esto *abolición* de la congestión en lugar de *control* de congestión
- Dos posibilidades
 - Centradas en router: DECbit y RED Gateways
 - Centradas en host: TCP Vegas

DECbit

- Agrega un bit de congestión a cada encabezado de paquete
- Router
 - monitorea largo promedio de cola sobre último ciclo ocupado/libre y el ciclo ocupado actual



- pone en uno el bit de congestión si largo promedio de cola > 1
- intenta balancear throughput contra retardo ($< 1 \Rightarrow$ poco retardo, router idle. $> 1 \Rightarrow$ cola permanente y mayor throughput)

Hosts extremos

- Destino envía eco del bit hacia la fuente
- Fuente registra cuantos paquetes resultaron con el bit marcado
- Si menos que 50% de la última ventana tenía bit marcado
 - incrementa `CongestionWindow` en un paquete
- Si 50% o más de la última ventana tenía bit marcado
 - decrementa `CongestionWindow` a 0.875 del su valor

Detección aleatoria temprana (Random Early Detection, RED)

- Notificación es implícita
 - solo descarta el paquete (en TCP habrá timeout)
 - podría hacerse explícita marcando el paquete
- Descarte aleatorio temprano
 - en lugar de esperar por que se llene la cola, descarta cada paquete de entrada con alguna *probabilidad de descarte* cada vez que la cola excede algún *nivel de descarte*



Detalles de RED

- Calcula largo de cola promedio

$$\text{AvgLen} = (1 - \text{Weight}) * \text{AvgLen} + \text{Weight} * \text{SampleLen}$$

$0 < \text{Weight} < 1$ (usualmente 0.002)

SampleLen es el largo de la cola cada vez que un paquete llega



Detalles RED (cont)

- Dos umbrales de largo de cola

```
if AvgLen <= MinThreshold then
```

```
    encole el paquete
```

```
if MinThreshold < AvgLen < MaxThreshold then
```

```
    calcule probabilidad P
```

```
    descarte paquete entrante con probabilidad P
```

```
if ManThreshold <= AvgLen then
```

```
    descartar paquete entrante
```


Detalles RED (cont)

- Computo de probabilidad P

$$\text{TempP} = \text{MaxP} * (\text{AvgLen} - \text{MinThreshold}) / (\text{MaxThreshold} - \text{MinThreshold})$$

$$P = \text{TempP} / (1 - \text{count} * \text{TempP})$$

- Count cuenta el número de paquetes encolados mientras el AvgLen está entre los dos umbrales
- Curva de probabilidad de descarte




Sintonía en RED

- Probabilidad de descartar un flujo particular de paquetes es aproximadamente proporcional a parte del ancho de banda que el flujo está obteniendo
- **MaxP** es típicamente fijada en 0.02, es decir cuando el tamaño promedio de la cola es la mitad entre los dos umbrales, el gateway descarta +o- uno de cada 50 paquetes.
- Si el tráfico es rafagoso, entonces **MinThreshold** debería ser suficientemente grande para permitir que la utilización del enlace sea mantenida a un nivel aceptablemente alto
- Diferencia entre los dos umbrales debería ser más grande que el incremento típico en el largo de cola promedio calculado en un RTT; fijar **MaxThreshold** a dos veces **MinThreshold** es razonable para el tráfico de hoy en Internet


TCP Vegas

- Idea: la fuente observa signos de aumentos de colas y congestión; e.g.,


- Crecimiento de RTT
- tasa de envío se aplana



Throughput observado



Espacio de Buffer



Algoritmo


- Sea **BaseRTT** el mínimo de todos los RTTs medidos (comúnmente el RTT de los primeros paquetes)
- Si no hay overflow de la conexión, entonces
$$\text{ExpectRate} = \text{CongestionWindow} / \text{BaseRTT}$$
- La fuente calcula la tasa de envío (**ActualRate**) por cada RTT
- La fuente compara **ActualRate** con **ExpectRate**

```
Diff = ExpectedRate - ActualRate /* >= 0 */
if Diff <  $\alpha$  /* 1 paquete */
    incrementar CongestionWindow linealmente
else if Diff >  $\beta$  /* 3 paquete*/
    decrementar CongestionWindow linealmente
else
    dejar CongestionWindow sin cambio
```


Algoritmo (cont)

- Parametros
 - $\alpha = 1$ paquete
 - $\beta = 3$ paquetes

Congestion Window



Throughput esperado (rojo) y medido (negro) (sombra: región entre β y α)



- Retransmisión aún más rápida
 - mantener marcas de tiempo de granularidad fina para cada paquete
 - chequear timeout del primer ACK duplicado (no el tercero)