Università di Genova
Facoltà di Ingegneria

1. Servizi Multimediali e Qualità del Servizio (QdS) su IP

1.1 Introduzione alle QoS su IP

Prof. Raffaele Bolla

dist

Qualità del Servizio (QdS)

- Due possibili QdS:
  - Misurata sul traffico generato dal servizio (traffico utente)
    - » Si valuta sulla base di indici di prestazione
      - A livello di pacchetto o bit
        - ***Troughput*, banda**
        - **Ritardo (medio, massimo, jitter)**
        - Probabilità di perdita
        - Probabilità di errore
      - A livello di connessione o flusso
        - Probabilità di blocco

Spesso considerate insieme come perdita di pacchetto

  - Percepita dall'utente del servizio (P-QdS)
    - » Qualità percepita dall'utente
      - ***Mean Opinion Score*** (MOS)

Qualità del Servizio (QdS)

Nessun recupero d'errore, misurata su i pacchetti correttamente ricevuti.

Qualità del Servizio (QdS)

- Il mantenere la P-QoS almeno ad un livello di accettabilità per ciascun servizio dovrebbe essere il vero obiettivo della rete
- Nella pratica i meccanismi di controllo della rete (quando presenti) operano sulla base di indici di prestazioni relativi alla QoS misurata sul traffico utente.
- L'idea generale è quella di cercare di realizzare una tabella di corrispondenze (*mapping*) fra i due insiemi di indici di prestazione
  - Ad esempio per ottenere una MOS di 4 (buona qualità) su un traffico voce si determina che la probabilità di perdita/errore debba essere inferiore a 10^{-4}, il ritardo massimo minore di 20 ms e il jitter minore di 5 ms.

Reti per servizi multimediali

Caratteristiche fondamentali

- Tipicamente richiedono il rispetto di un qualche vincolo sul ritardo (massimo, *jitter*, medio)
- Ma sono "tolleranti" alla perdita (perdite poco frequenti causano "solo" una leggera perdita di qualità)
- I requisiti, in questo senso, sono esattamente opposti a quelli richiesti dai servizi dati.
- I servizi multimediali sono spesso indicati anche col nome di "***continuous media***"

Classi di applicazioni *continuous media:*

- ***Streaming stored audio and video*** (video diffusivo non in tempo reale)
- ***Streaming live audio and video*** (video diffusivo in tempo reale)
- ***Real-time interactive audio and video*** (video interattivo in tempo reale)

Reti per servizi multimediali

Streaming stored audio and video

- Un *client* richiede un file audio/video ad un server e concatena/parallelizza la ricezione dalla rete con la visualizzazione.
- E' interattivo: l'utente può eseguire delle operazioni di controllo (operando in modo simile ad un video registratore : *pause*, *resume*, *fast forward*, *rewind*, etc.)
- Ritardo: dalla richiesta del *Client* alla partenza della visualizzazione possono passare da 1 a 10 s.

Streaming live audio and video

- Molto simile alle TV e radio attuali ma realizzato tramite internet.
- Non interattivo, solo "guarda e ascolta".

Interactive Real-Time :

- Conferenze audio/video.
- Vincoli sul ritardo più stringenti a causa dell'interazione in tempo reale.
- Video: accettabile < 150 msec
- Audio: buono < 150 msec, accettabile < 400 msec

Il supporto di IP

- TCP/UDP/IP suite fornisce un servizio *best-effort* senza garanzie sul ritardo o sulla variabilità del ritardo.
  - Le applicazioni *streaming* (con un ritardo iniziale di 5-10 sec.) sono oggi relativamente comuni, ma le prestazioni si deteriorano in modo inacettabile quando le linee tendono a congestionarsi.
  - Le applicazioni in tempo reale interattive hanno dei requisiti più stringenti sia sul ritardo che sul *jitter*, requisiti che non si riescono a rispettare in modo affidabile usando il TCP/IP.

Perchè IP
Reti integrate nei servizi

- Uno degli obiettivi delle reti di telecomunicazioni nell'ultimo decennio è stato l'integrazione dei servizi: creare una rete in grado di supportare ogni tipo di servizio (previsto e prevedibile)
- Un rete integrata permetterebbe una elevata efficienza e renderebbe appetibile l'offerta dinamica di nuovi servizi di tlc ma richiede una tecnologia molto flessibile

Commutazione di pacchetto

Perchè IP
IP e ATM

- Inizialmente gli standard (ITU-T) e la ricerca hanno proposto ATM (Asynchronous Transfer Mode)
  - Commutazione pacchetto veloce
  - Orientato alla connessione
  - Pensato principalmente per servizi *real-time* (video-voce)
  - ATM non si trova molto "a suo agio" con il traffico dati, al contrario di IP che è invece stato pensato solo per i dati.
- Con Internet, il TCP/IP si è imposto sia come tecnologia che come "infrastruttura" di rete, quindi è sembrato "naturale" proporre **Internet** anche come **rete integrata universale**

Linee evolutive di Internet verso il supporto delle comunicazioni multimediali (QdS)

- Ci sono due filosofie su come agire per realizzare servizi con Qos in IP
  - Nessun intervento architetturale, si lascia IP così come è, sovradimensionando la banda trasmissiva;
  - Introduzione di nuove architetture, elementi di rete e protocolli specifici per la QoS:
    - » Architetture InteServ e DiffServ
    - » MPLS

Linee evolutive: nessun intervento

- In questo caso si parte dal presupposto che la banda è, almeno potenzialmente, una risorsa disponibile in abbondanza (Fibre ottiche, WDM)
  - Quindi non si opera nessuna distinzione di classe e nessuna prenotazione di banda.
  - Quando la domanda sale, si fornisce più banda in generale (aumentare le capacità delle linee o il loro numero), quindi agire in sede di pianificazione (*Planning*).
  - Si cerca di localizzare i contenuti sul bordo della rete (*Cache* e *server* nella rete d'accesso degli ISP) .

Linee evolutive: nessun intervento

- L'idea di base è che:
  - Se si riesce a realizzare un "*over-provisioning*" sistematico nella rete allora
    - » nessuna linea o nodo sarà mai in condizione di congestione, anche solo accennata
    - » e quindi tutti i parametri di QoS saranno rispettati per tutti i pacchetti
- Questo modello non appare ad oggi realmente applicabile nella sua forma estrema, ma se si fa riferimento ad una sua versione meno estrema può essere considerato valido.

Linee evolutive: nessun intervento

- Pur senza introdurre elementi nuovi, si possono comunque attuare alcune azioni per mitigare l'effetto negativo del trattamento "*best-effort*":
  - Usare UDP evitando la fase di *slow-start* ed il recupero d'errore del TCP.
  - Usare un buffer ed un ritardo iniziale di visualizzazione a destinazione per compensare il *jitter*.
  - Introdurre dei *timestamp* così da permettere la riproduzione temporale corretta dei dati.
  - Adattare la compressione alla banda disponibile.
  - Inviare pacchetti ridondanti per mitigare le perdite.

Multimedia su *best-effort*: Un esempio di servizio voce su IP

- Una sorgente vocale può essere modellata come un sistema a due stati: *parlo* e *silenzio*.

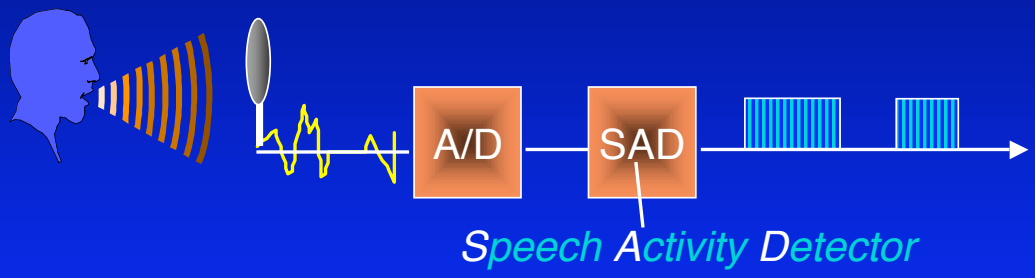

- Durata media del periodo attività (*talkspurt*) = 1.00 s
- Durata media del periodo di silenzio (*gap*) = 1.35 s
- Percentuale di attività ≈ 42 %

Multimedia su *best-effort*: Un esempio di servizio voce su IP

- Nel caso in esempio, supponiamo che quando la sorgente è nello stato ***parlo*** l'applicazione generi dati con tasso pari a 64 Kb/s (8000 campioni/s, ognuno di 8 bit), nello stato *silenzio* ovviamente non genera dati.
- Questa significa che l'applicazione, ogni 20 ms genera un blocco di 160 Bytes.
- Al blocco aggiunge una intestazione ed il tutto viene inserito in un pacchetto UDP ed inviato in rete.
- Il ricevitore riceve questi pacchetti ma non tutti, perché alcuni vanno persi, e con ritardo variabile (eventualmente anche fuori sequenza).
- Il ricevitore deve decidere quando riprodurre un blocco e cosa fare se mancano dei blocchi.

Multimedia su *best-effort*: un esempio di telefonia su IP

- Sono due i problemi principali che vanno risolti
  - Perdite di pacchetti:
    - » Si potrebbe usare TCP, ma la ritrasmissione introduce ritardo e il controllo di flusso limita il tasso.
    - » Anche usando il UDP, in ogni modo, bisognerebbe inserire numeri di sequenza per accorgersi di eventuali perdite.
  - Ritardo
    - » Il ritardo *end to end* deve essere inferiore a 400 ms, altrimenti ne risente l'interatività.
    - » Il *jitter* in questo caso è dato dal fatto che i pacchetti sono trasmessi a 20 ms uno dall'altro ma possono arrivare al ricevitore sia più vicini che più lontani.
    - » Si dovrebbe comunque inserire dei *timestamp* per capire quando un blocco dati debba essere riprodotto.

Multimedia su *best-effort*: Compensazione del *jitter*

- Il *Jitter* viene in genere compensato utilizzando un buffer ed inserendo un ritardo q di riproduzione, ossia:
  - Se un blocco con un *timestamp* t è ricevuto entro t + q, viene riprodotto all'istante t + q
  - Altrimenti viene scartato
- Questa strategia non richiede numeri di sequenza per gestire le perdite (in pratica trasforma in perdita tutto quanto arriva con un ritardo superiore a q).
- Il problema è fissare q
  - q lunghi implicano meno perdite (per *jitter*) ma peggiore interazione;
  - q corti: l'interazione è più efficace ma più perdite.

Multimedia su *best-effort*: Compensazione del *jitter*

- La sorgente genera un pacchetto ogni 20 ms.
- Il primo pacchetto è ricevuto all'istante t.
- Nel primo caso (ritardo q) è riprodotto a partire dall'istante r.
- Nel secondo caso (ritardo q') è riprodotto a partire dall'istante r'.

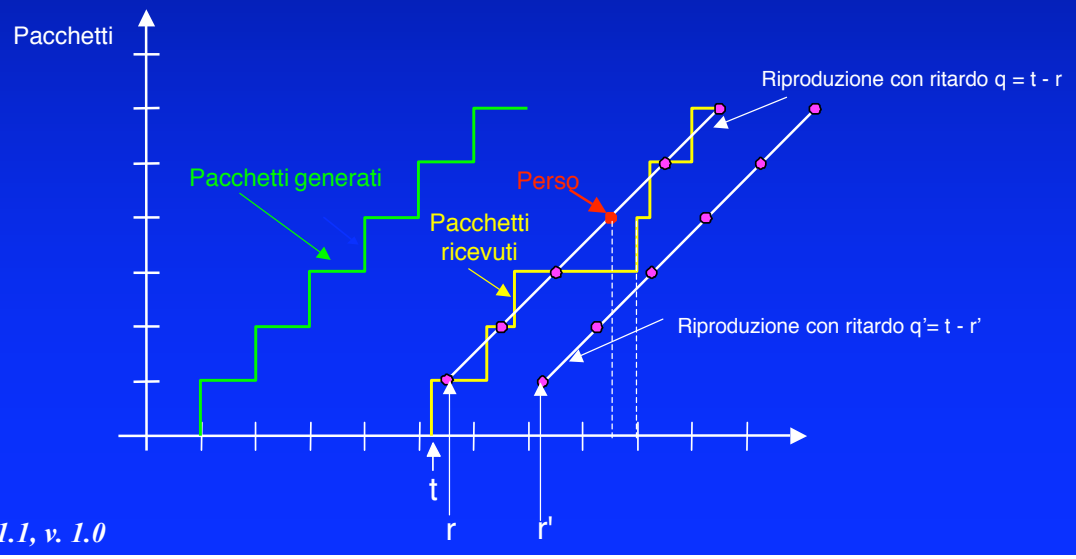

Multimedia su *best-effort*: Compensazione delle perdite

- *Forward Error Correction* (FEC)
  - Siccome la perdita significa il non arrivo del pacchetto, le tecniche FEC devono coinvolgere più di un pacchetto.
  - Possiamo fare due esempi di possibili strategie:
- **Strategia 1**
  - Ogni n blocchi, si costruisce un blocco ridondante ottenuto come XOR degli n precedenti e lo si invia in coda al gruppo
  - Se perdo un blocco solo degli n+1, all'istante di ricezione del blocco n+1 lo posso ricostruire
  - La banda aumenta di un fattore 1/n (ad es. 1/10 se n= 10)
  - Il ritardo fisso iniziale d deve essere tale da permettere la ricezione di almeno n+1 pacchetti (se n = 10, d > 200 msec).
  - Quindi aumentando n aumenta l'efficienza ma aumenta anche il ritardo e la probabilità di avere più di una perdita in una sequenza (situazione in cui questo meccanismo diventa inefficace).

Multimedia su *best-effort*: Compensazione delle perdite

Strategia 2

- Si comprime i dati usando due codifiche a risoluzioni diverse: una bassa (B) ed una alta (A) (ad es. un PCM a 64 Kbit/s e un GSM a 13 Kbit/s).
- Si costruisce il pacchetto n prendendo il blocco n del flusso codificato con A (160 Byte) e il blocco n-1 del flusso codificato con B (32,5 byte)
- Quando un pacchetto viene perso può essere ricostruito (con minore qualità) all'arrivo de pacchetto successivo
- Si può proteggere anche nei confronti di due perdite consecutive aggiungendo anche il blocco n-2 del flusso B.

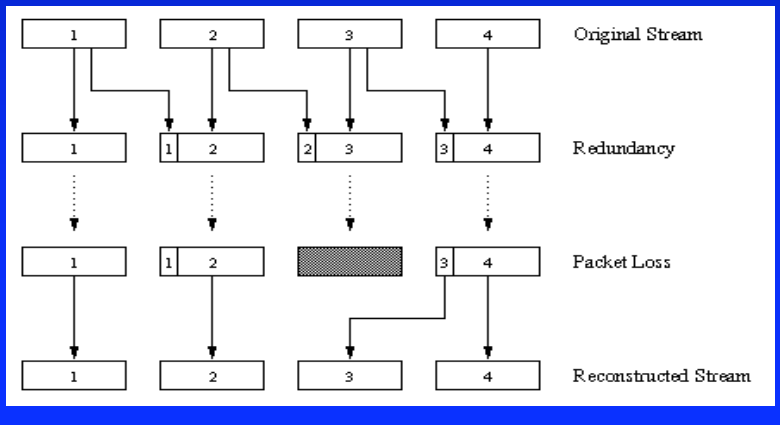

Multimedia su *best-effort*: Compensazione delle perdite

- *Interleaving*
  - I blocchi sono spezzato in unità più piccole (ad esempio in 4 unità da 40 byte).
  - Le unità vengono mescolate in pacchetti successivi che quindi contengono parti di più blocchi.
  - I blocchi originari vengono ricostruiti al ricevitore.
  - Se un pacchetto viene perso la perdita viene distribuita su n blocchi e quindi è più facilmente compensabile.

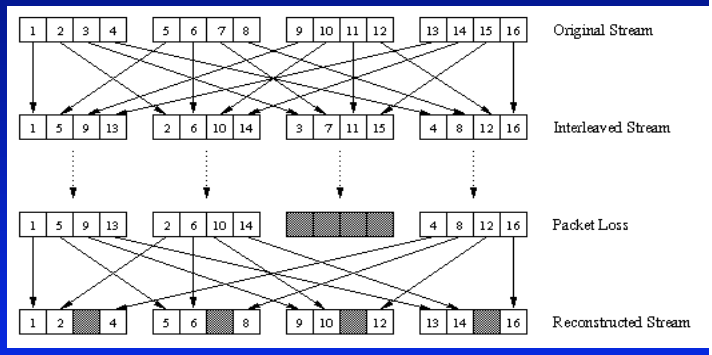

- Ricostruzione pacchetto/unità persa
  - Si usano dei dati che assomiglino ai precedenti (ripetizione o interpolazione)
  - Funziona abbastanza bene per perdite rare e pacchetti/unità piccole (4-40 msec)

QoS

- Per poter fornire supporto a servizi differenti, bisogna poter assicurare una **Qualità** ossia rispettare dei requisiti diversi in termini
  - Perdita massima ↓
  - Ritardo massimo ↓
  - *Jitter* ↓
  - *Throughtput* ↑
- In corrispondenza di flussi di traffico differenti per
  - Tasso di generazione
  - Statistiche di generazione (CBR, VBR,…)

QoS su reti a pacchetto

- Internet o, in generale, l'architettura TCP/IP è nata ed è attualmente strutturata per fornire solo servizi ***best-effort***, ossia con
  - Perdita di pacchetto
  - Ritardi non superiormente limitati
  - Ritardi variabili (*Jitter*)
- Per poter utilizzare Internet come rete universale, bisogna poter assicurare un grado di QoS ad applicazioni o utenti che ne facciano richiesta, e quindi bisogna introdotti dei **nuovi componenti architetturali**.

Scenario di riferimento

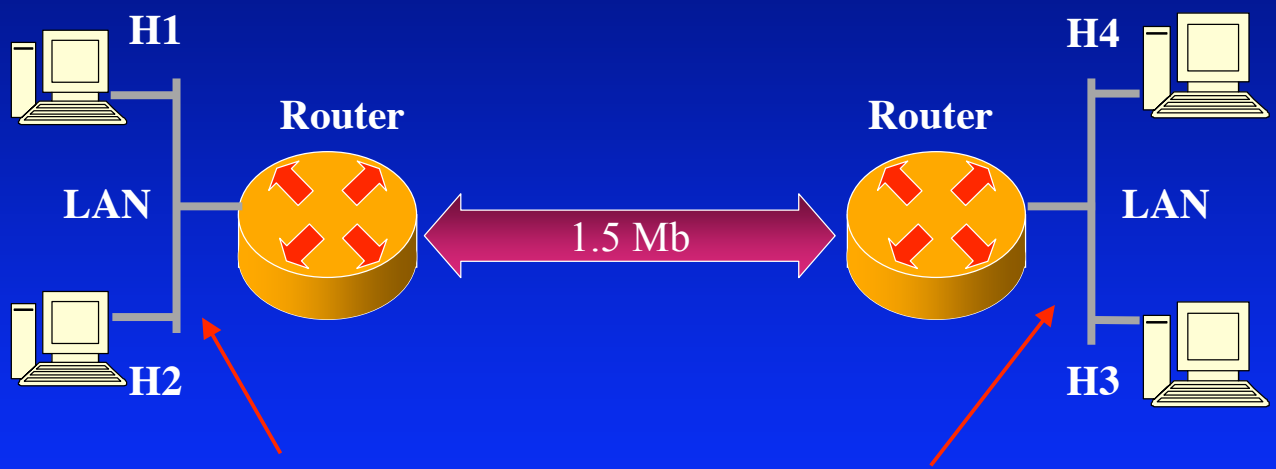

Si supponga che la LAN non sia un elemento critico (nel senso che ha una velocità molto più alta di quella presente fra i due *router*)

Scenario 1

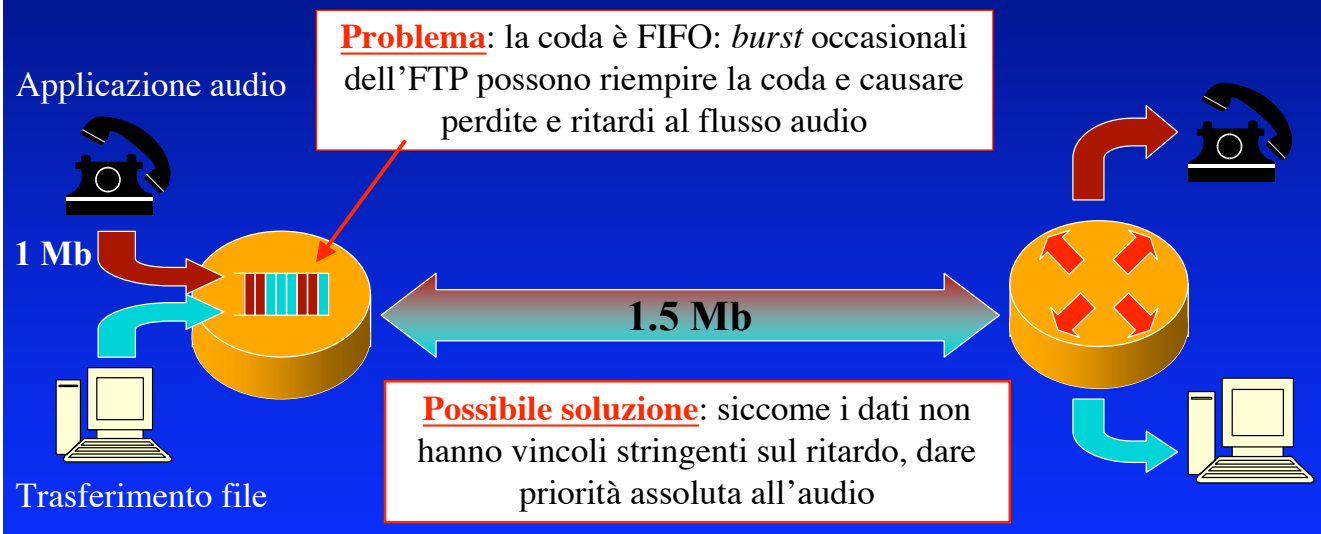

Per poter servire differentemente i due traffici i *router* devono poter distinguere i pacchetti di classi diverse, ossia è necessario un "***packet marking***" per classe di traffico

Scenario 1

- Se l'utente del trasferimento file ha pagato molto per avere un servizio di "prima classe", mentre l'utente audio ha pagato poco per avere un servizio a basso prezzo, non è detto che la priorità dell'audio debba essere assoluta.
- Ci sono tre considerazioni da fare:
  - Il *Marking* esplicito serve solo a distinguere i pacchetti ma non determina necessariamente il tipo di servizio che riceverà un pacchetto.
  - Il modo con cui il *router* classifica (*classification*) i pacchetti può basarsi su diversi criteri (sorgente, destinazione, stato della linea) di cui l'identificazione esplicita è solo uno degli elementi
  - Il modo in cui i diversi pacchetti vengono classificati e poi trattati dipende dalla "politica" di servizio.

Non basta fare il marking per assicurare una QoS

Occorrono anche altri meccanismi

Scenario 2

L'applicazione audio (volontariamente o per errore) comincia a generare più di 1 Mbps; se arriva a generare ≥ 1.5 Mbps, l'FTP non passa più

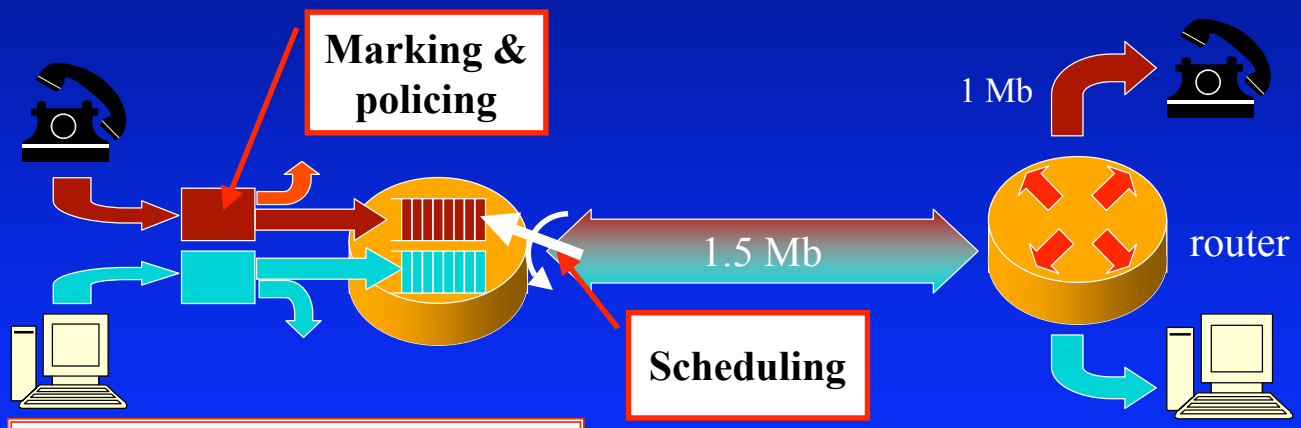

Bisogna poter fornire un **certo grado di indipendenza fra i flussi**, per evitare che flussi "sbagliati" influenzino negativamente le prestazioni degli altri

Si osservi però che l'isolamento fra flussi deve essere ottenuto mantenendo il **massimo grado di efficienza** nell'uso delle risorse (banda e buffer)

Scenario 3

Se si attivano due applicazioni audio da 1 Mbps, qualunque *classification* o *policing* o partizione (*scheduling*) non permette di mantenere la QoS

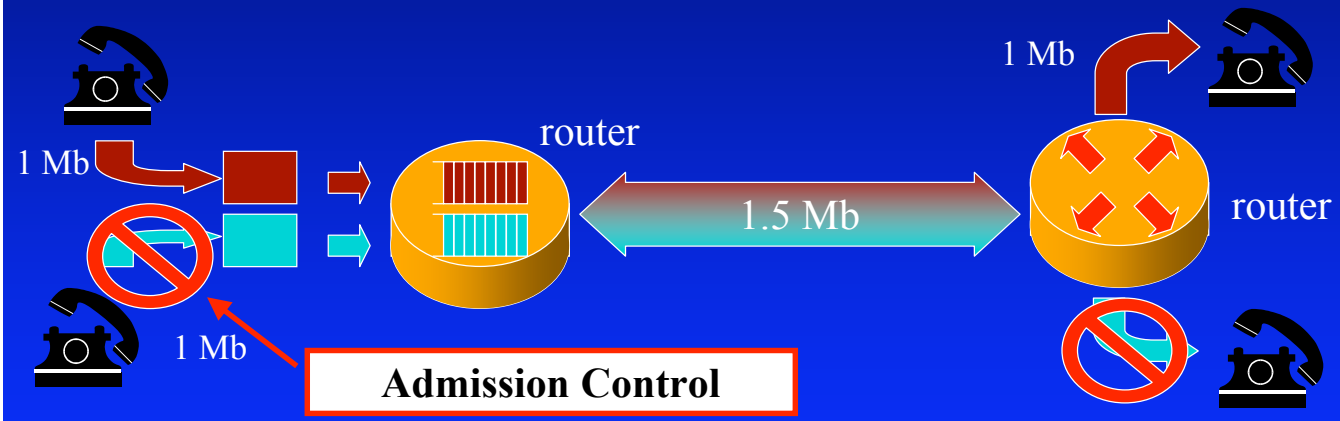

Bisogna che le applicazioni dichiarino i propri flussi e la richiesta di QoS e che subiscano un "**Controllo di Accesso**"

Elementi

- In sostanza gli elementi che devono essere considerati per fornire una QoS su IP sono:
  - **Classificazione dei pacchetti (*Packet Classification*)**
  - **Isolamento dei flussi: *Scheduling* e *Policing***
  - **Efficace utilizzazione delle risorse (Allocazione dinamica delle risorse)**
  - **Controllo di ammissione (*Call Admission*)**