QoS: Transporte de Voz

Area de Ingeniería Telemática
http://www.tlm.unavarra.es

Grado en Ingeniería en Tecnologías de Telecomunicación, 3º

upna Universidad Pública de Navarra Nafarroako Unibertsitate Publikoa
Tecnologías Avanzadas de Red
Área de Ingeniería Telemática

Implementación de VoIP

Esquema básico de flujos en VoIP

- Dos tipos de flujos
  - Voz, generalmente directa entre los peers (RTP)
  - Señalización, entre peers o con servidores (SIP, H.323, MGCP...)
- Diferentes requisitos de calidad

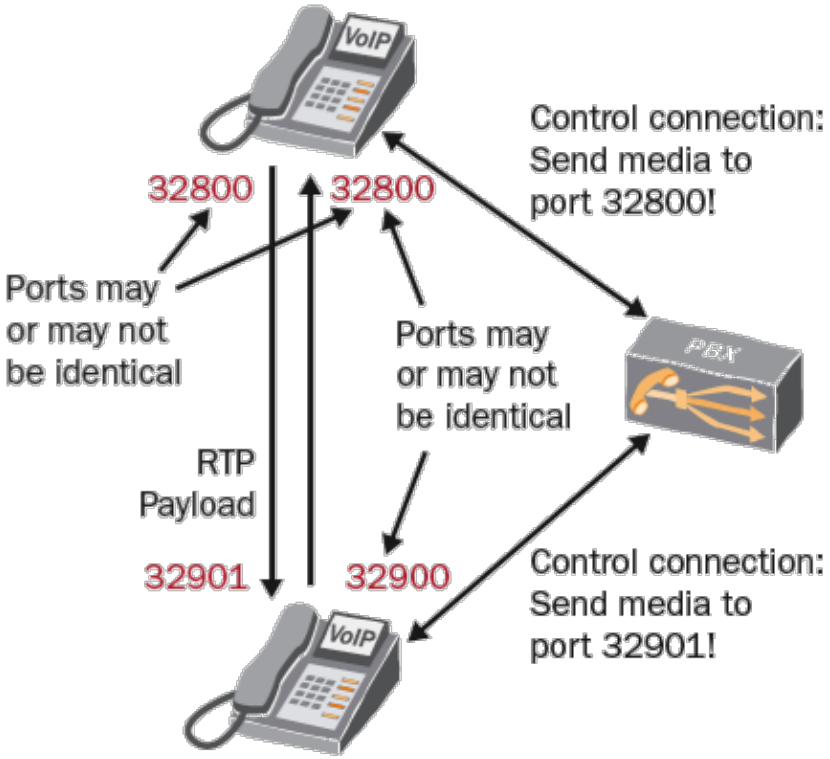

Terminología PSTN-VoIP

(Media) Gateway

- En cualquiera: H.323, SIP, MGCP, Megaco
- Terminación de llamadas entre un medio y otro
- "Traduce" voz y también la señalización
- Generalmente entre la PSTN y la red de datos
- O puede ser entre dos partes de la red con diferentes requisitos
  - *Transcoding* (cambio de codificador)
  - Diferente señalización (entre SIP y H.323)
- *Residential Gateway, Access Gateway, Business Gateway, Trunking Gateway, Signaling Gateway*

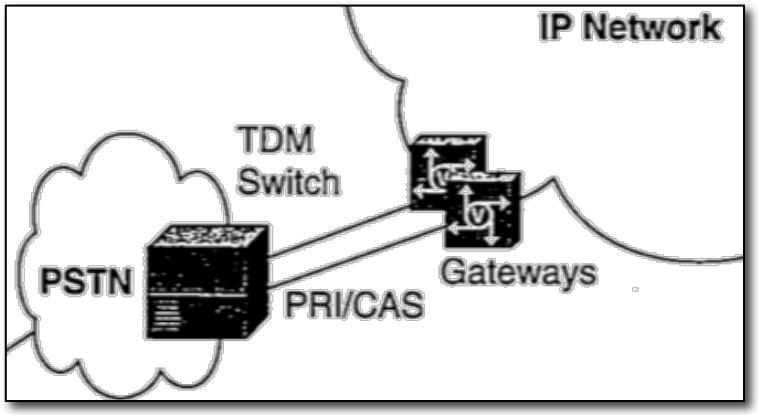

Terminología PSTN-VoIP

Media (Gateway) Controller

- Controla Media Gateways para proveer llamadas extremo a extremo
- Registro de llamadas, autentificación, autorización, encaminamiento, facturación, gestión de recursos …
- Traducción de direcciones (de nº telef., URL, e-mail, etc a dirección IP)
- Cada MGC controla una *zona*
- Media Gateway Controller en Megaco/H.248.1
- A.k.a. Call Agent en MGCP
- a.k.a Gatekeeper en H.323
- Media Server, Telephony Server,
- Call Manager, Virtual Switch,
- Softswitch…

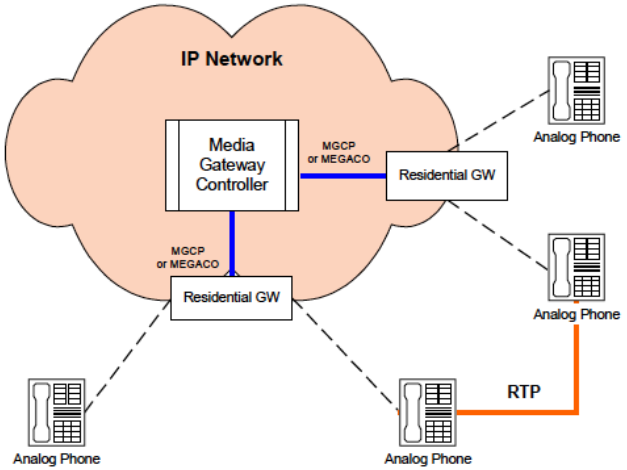

Voz en escenarios privados

Voz entre sedes

Mediante llamadas por la red pública

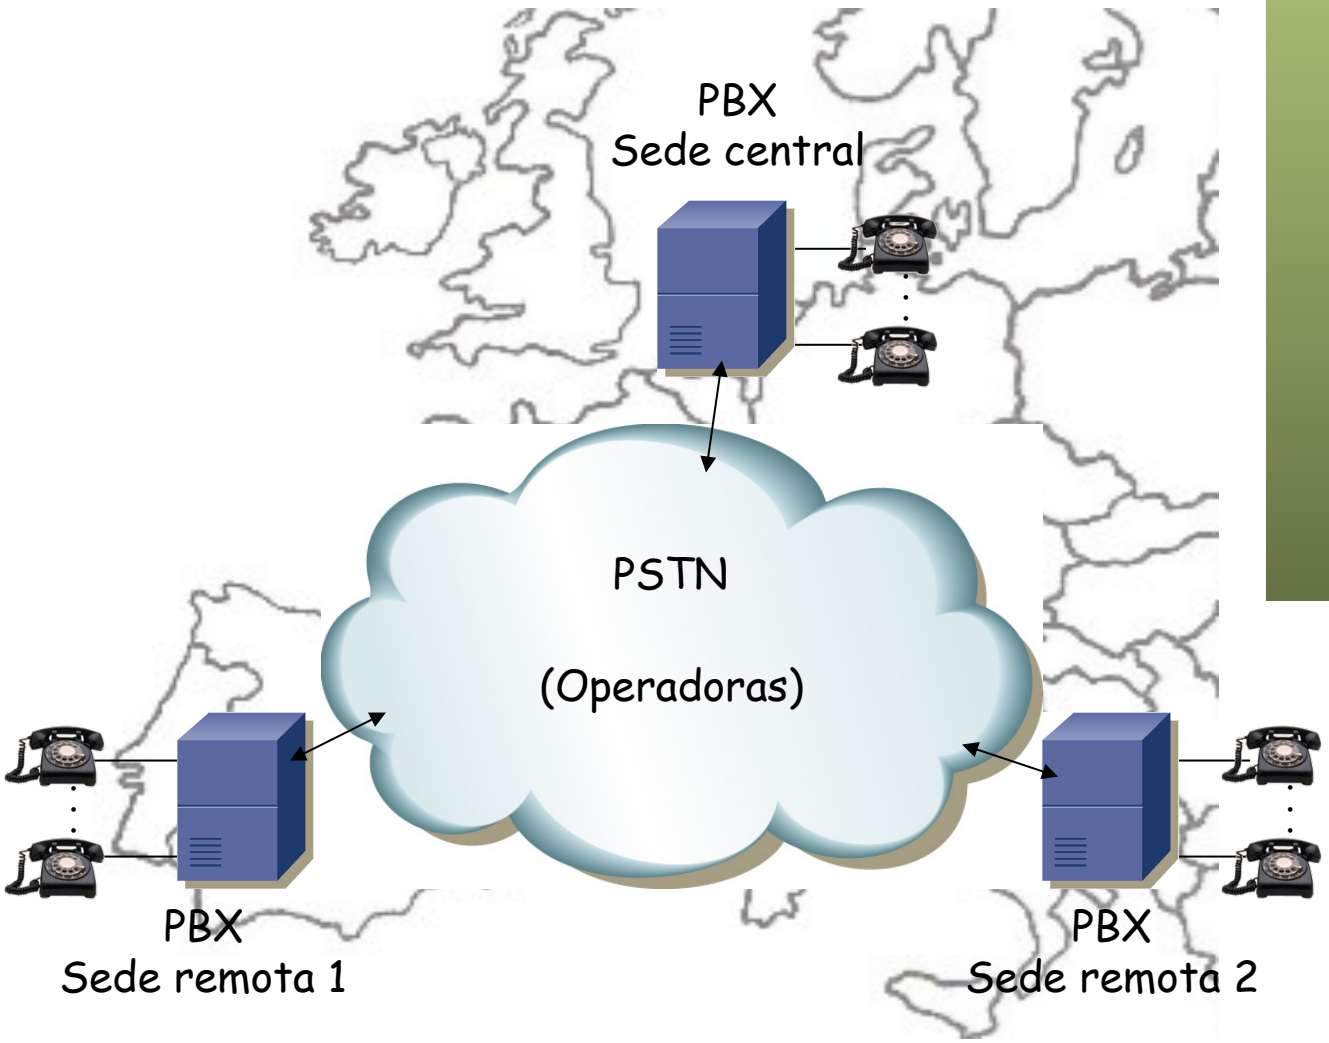

PBX = *Private Branch eXchange*

Voz entre sedes

Enlaces dedicados (malla o hub)

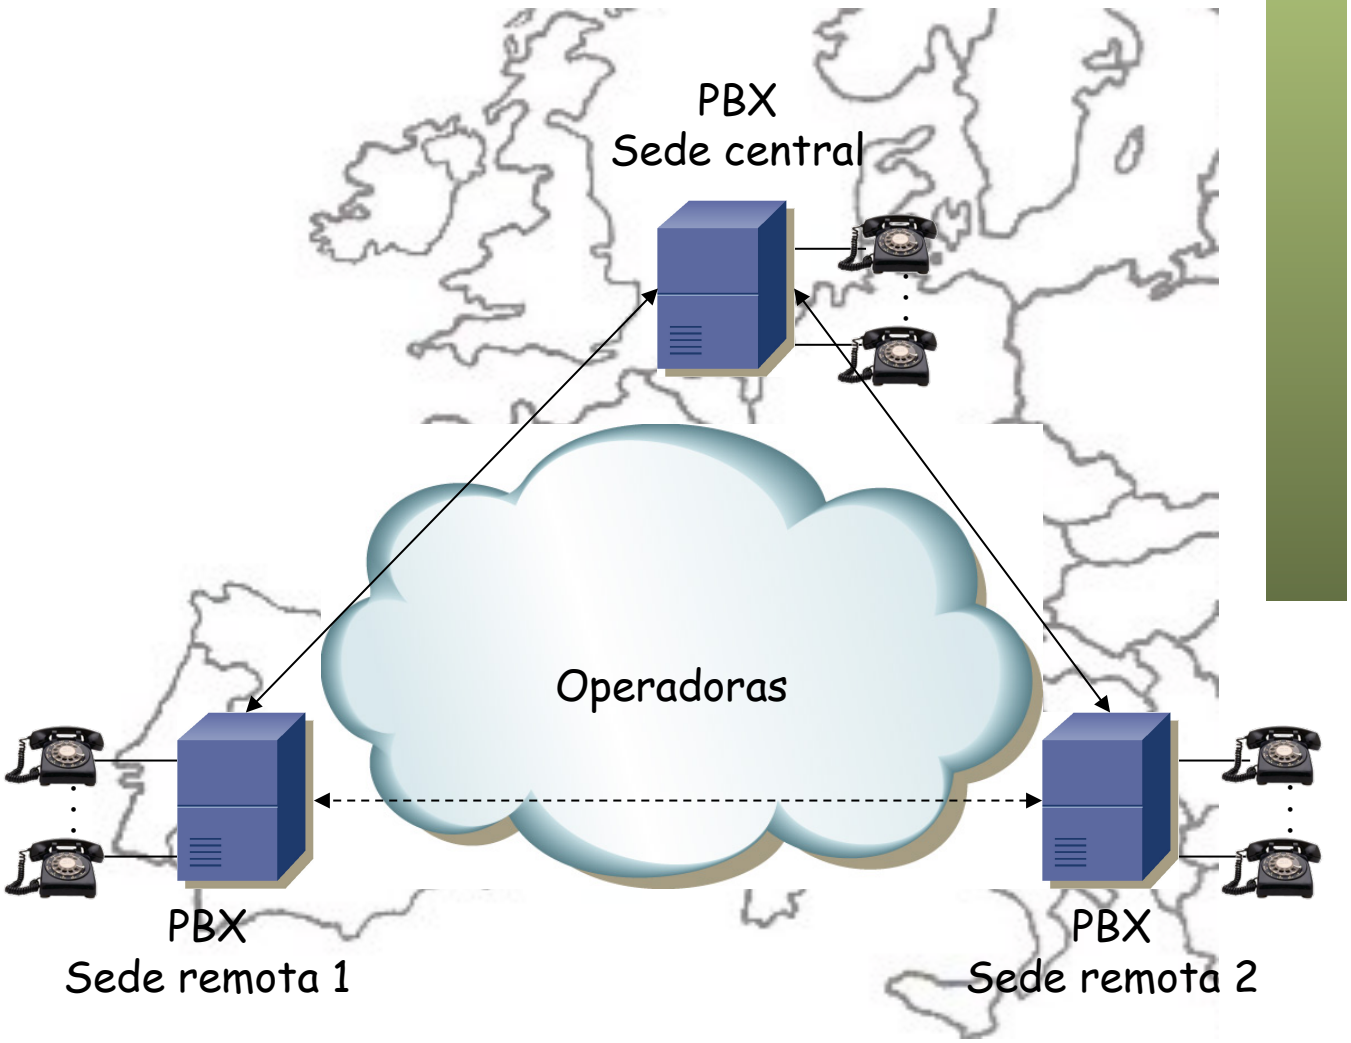

Voz + datos

Probablemente tenga enlaces de datos simultáneamente

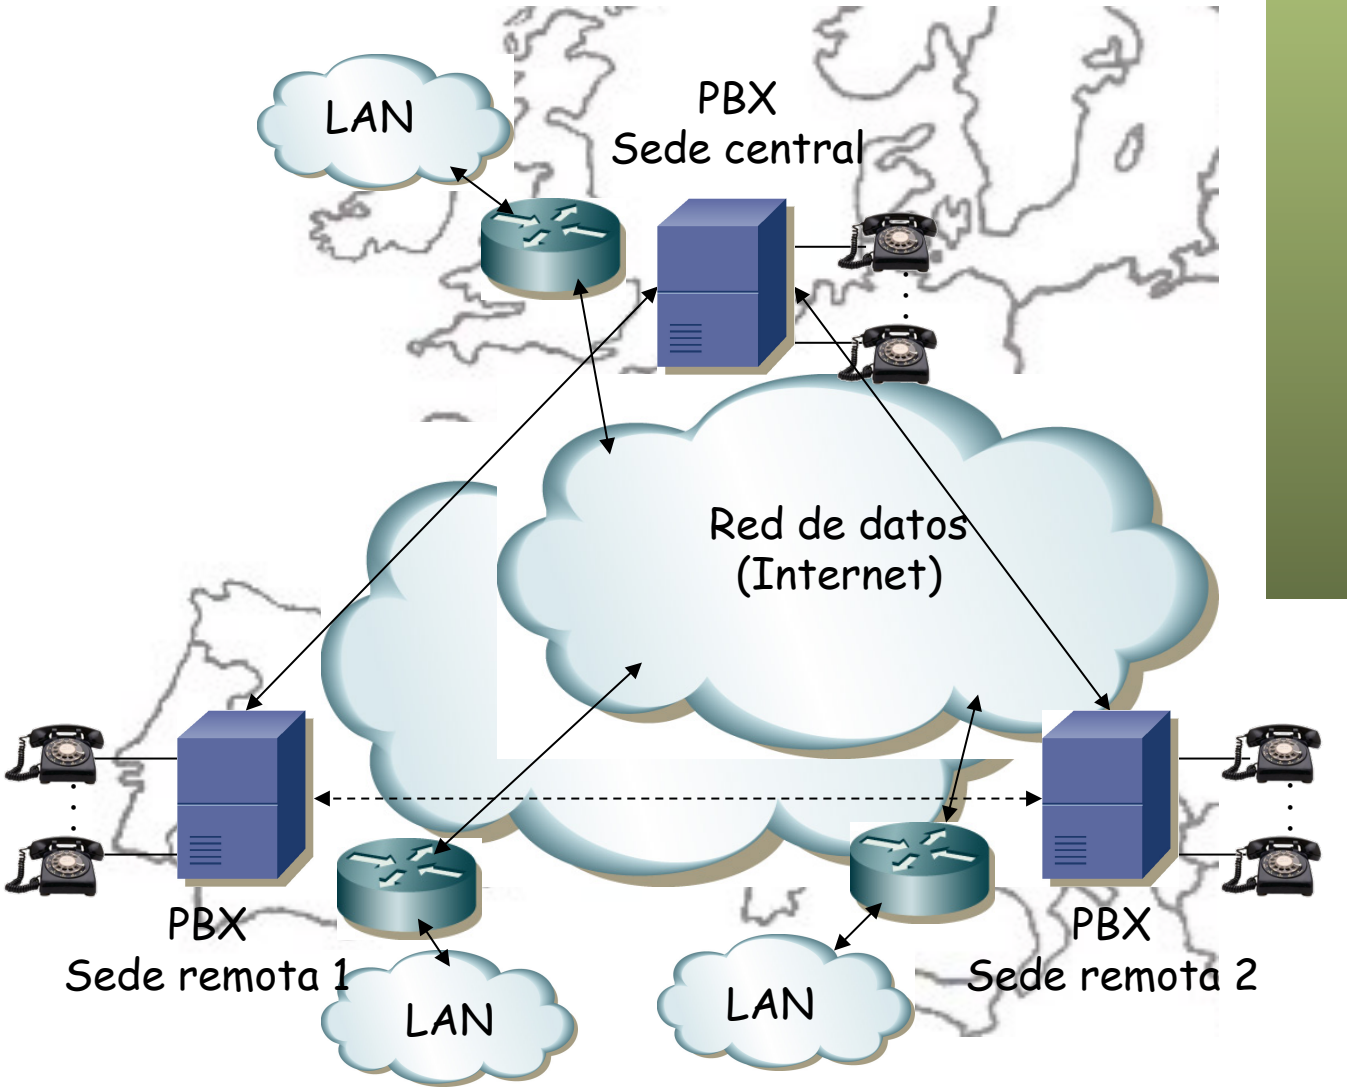

¿Por qué dejar de usar TDM?

- Utilizar la misma infraestructura de datos: reduce CAPEX y OPEX
- Negocio:
  - Añadir más servicios al cliente
  - Telcos añaden datos, ISPs añaden voz
- (...)

¿Por qué dejar de usar TDM?

- Aumentar la cantidad de llamadas que se pueden cursar por un enlace
  - *Voice compression*
    - vs los 64 kbps PCM
    - Cuidado, reduce la calidad
  - *Silence supresion*
    - *VAD = Voice Activity Detection*
    - Habla tiene en torno a un 40-50% de actividad frente al tiempo total
  - *Statistical gain*
- Más sencillo incluir nuevos servicios de valor añadido
- Hacer escalabilidad más sencilla
- Simplificar enrutamiento alternativo

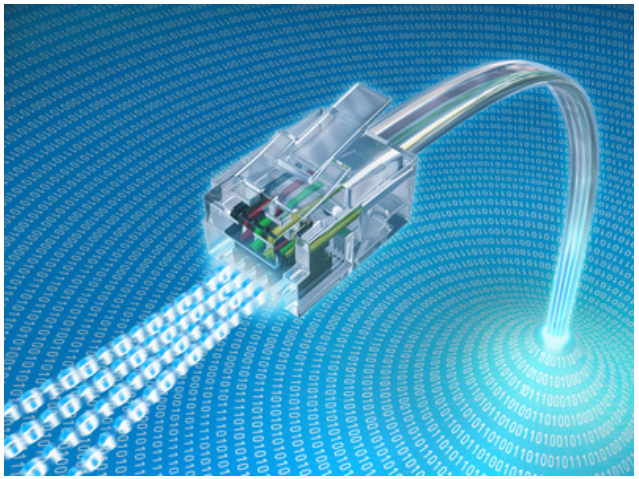

Convergencia

PBXs con interfaces IP (Ethernet)

- Reutiliza servicios de PBX:
  - Call transfer
  - Call conference
  - Paging
  - Bridging
  - Group calling
  - Etc.
- Señalización no preparada para delays en red IP
- Fabricante con experiencia en voz, no en datos

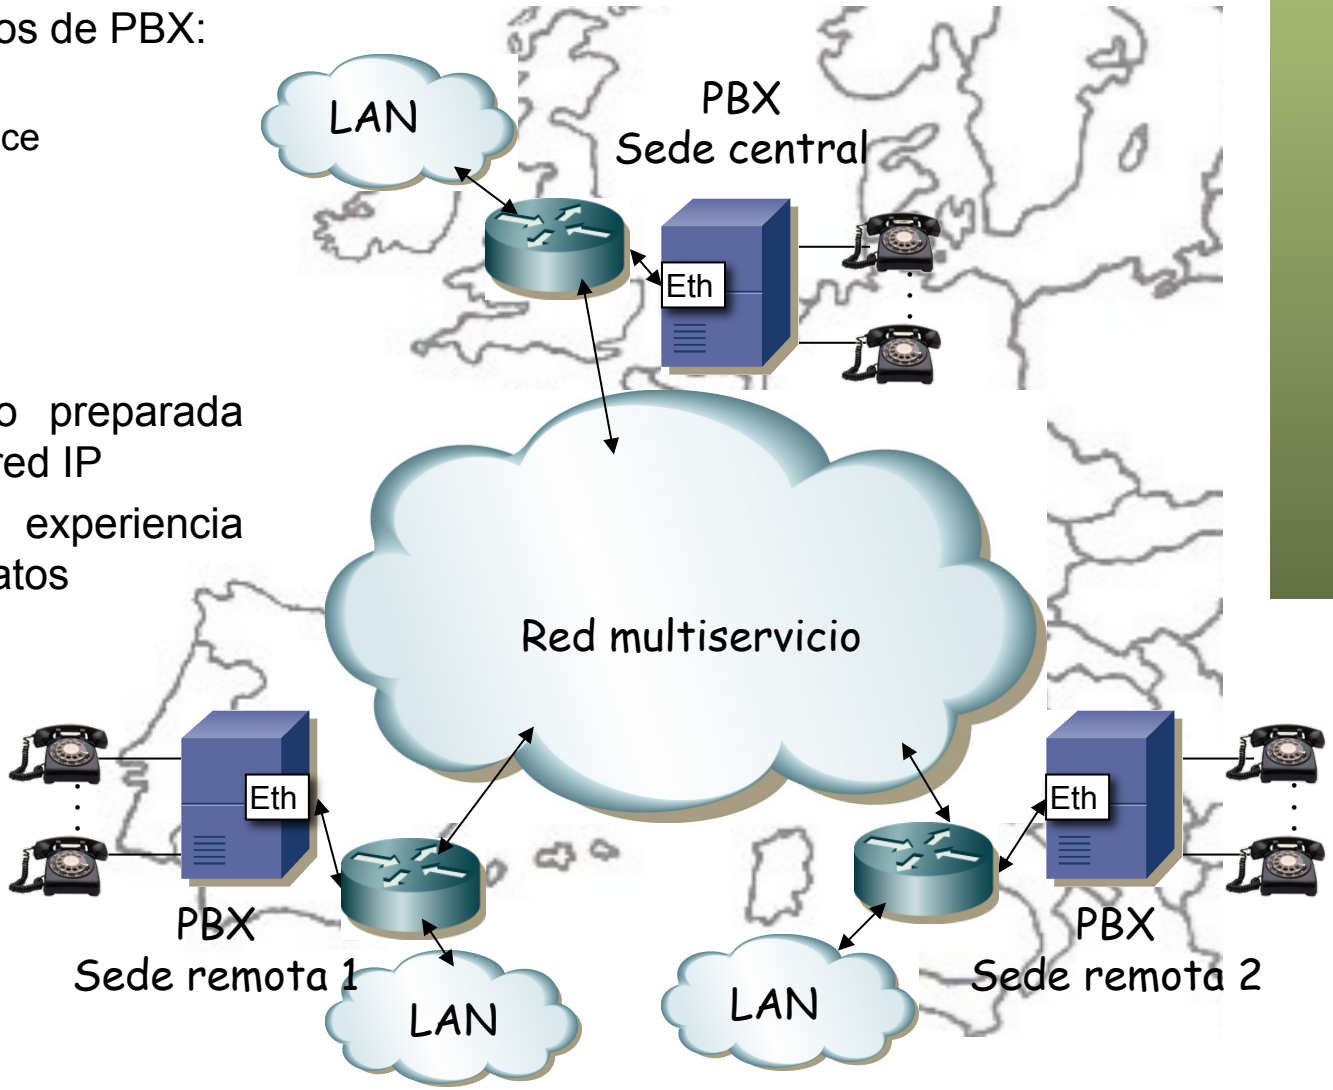

Convergencia

PBXs trunk TDM y conversión en router

- Router actúa como *Media Gateway*
- Puede ser un PC
- En algún lugar (routers o externo) habrá un *Gateway Controller*
- Fabricante con experiencia en datos, no en voz

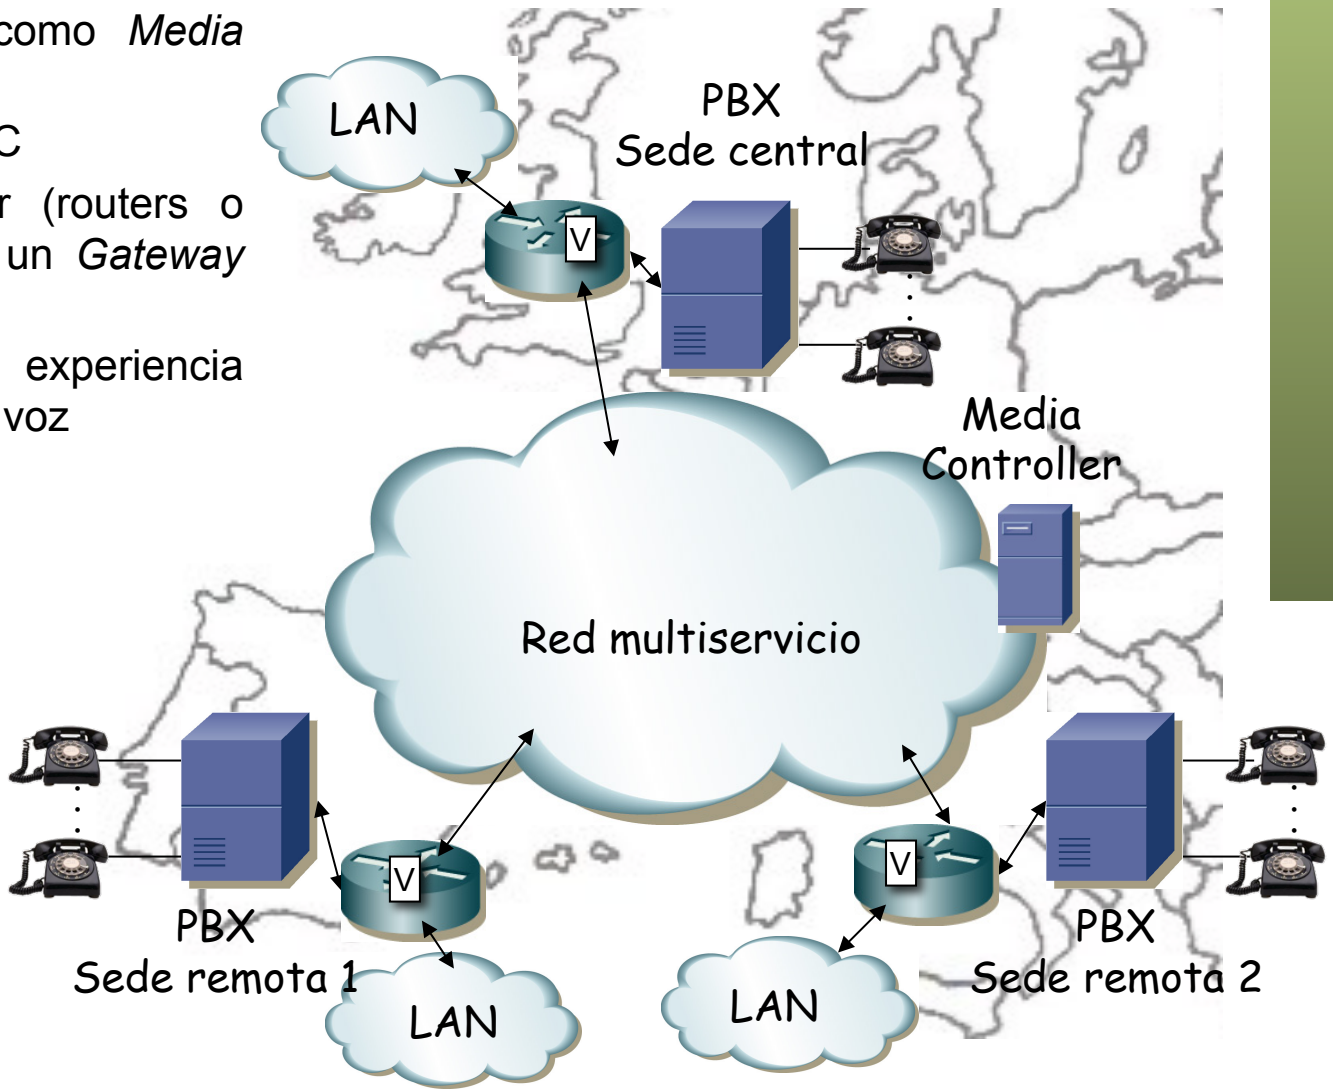

Convergencia

Multi-Point Switched Gateway

- En caso de congestión en la red de datos emplea la PSTN

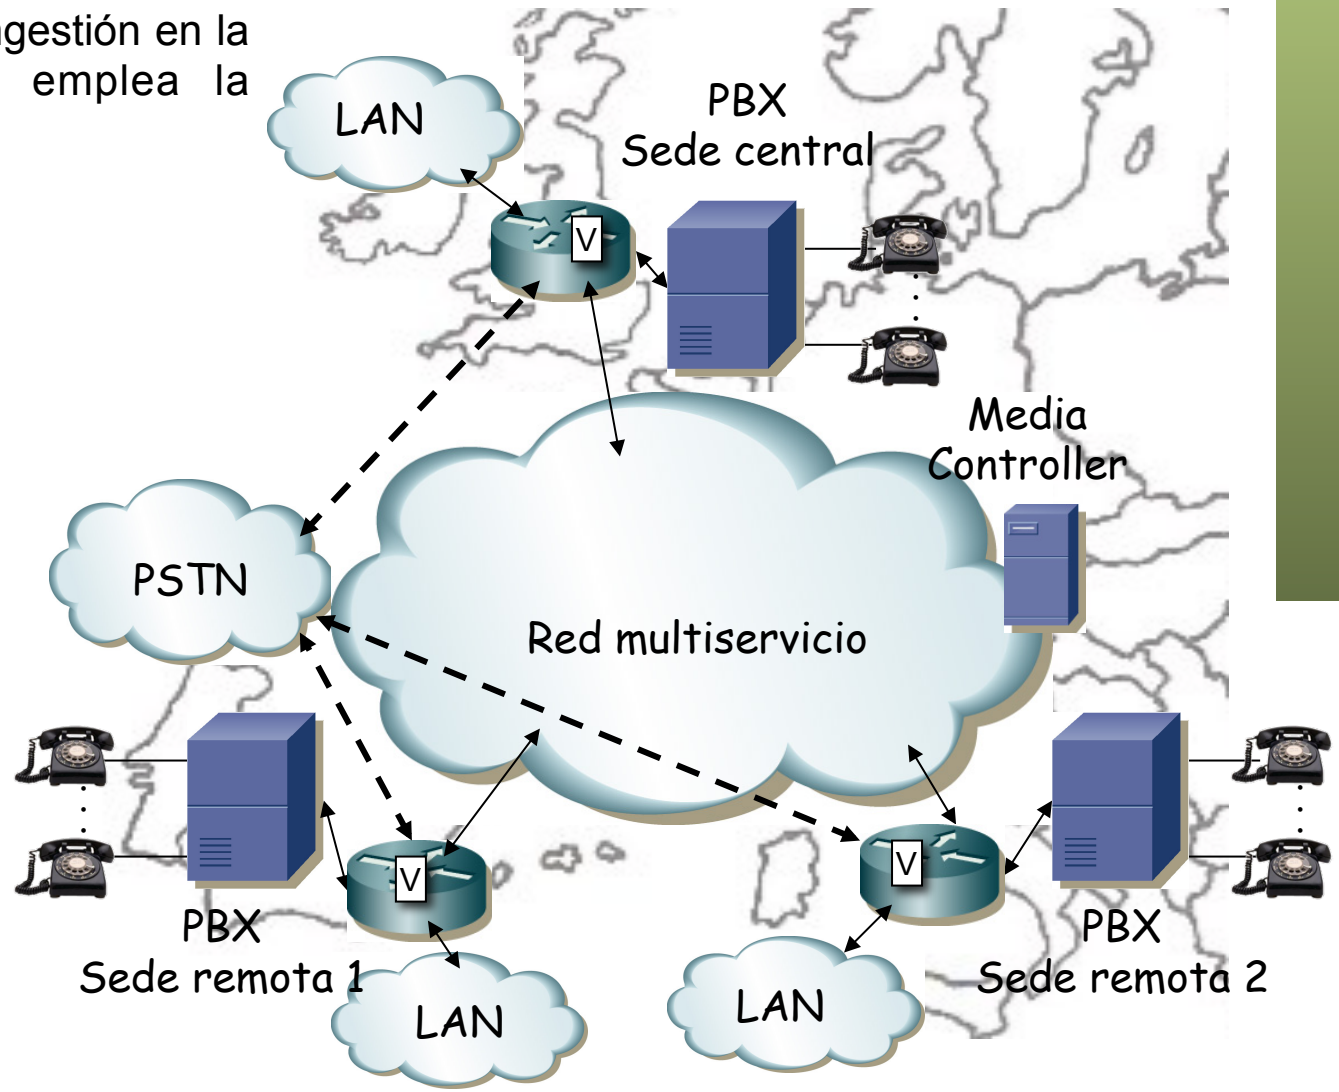

Convergencia

(Remote) Telephony Server

- Gateway que permite a teléfono IP acceder a servicios de PBX / telefonía tradicional

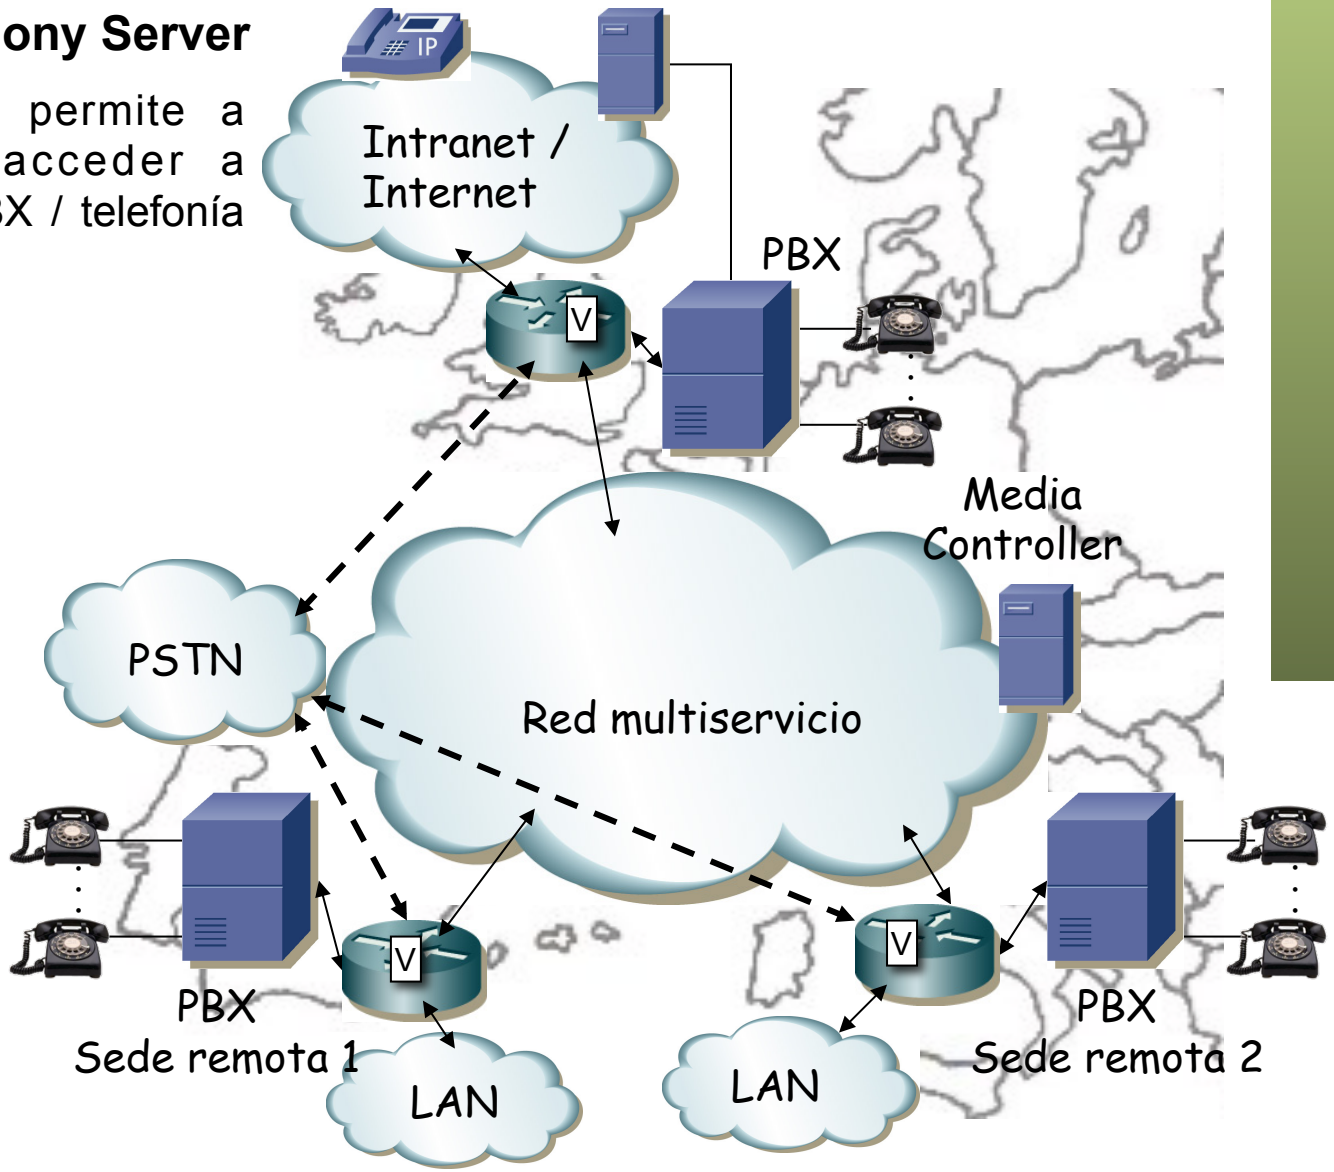

upna Universidad Pública de Navarra Nafarroako Unibertsitate Publikoa
Tecnologías Avanzadas de Red
Área de Ingeniería Telemática

VoIP, QoS y QoE

QoE

- *Quality of Experience*
- Intenta medir la percepción que tiene el usuario
- Para VoIP o vídeo depende de
  - La calidad del codificador
  - El servicio ofrecido por la red
  - La calidad del decodificador
- Pueden ser métricas objetivas o subjetivas
- (...)

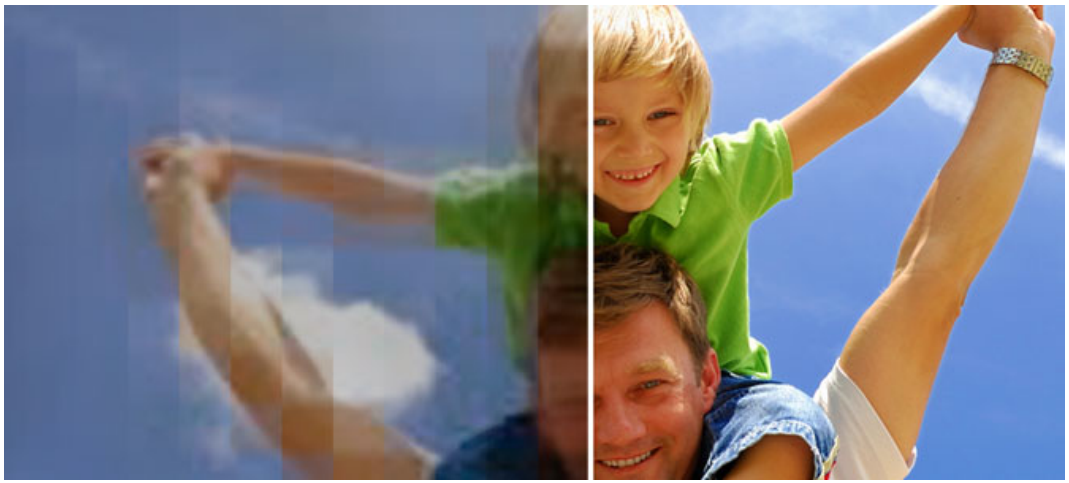

QoE

- Métricas subjetivas para voz:
  - Basadas en la opinión de usuarios
  - Mean Opinion Score (MOS) da una medida numérica 1-5
  - MOS definido en ITU-T P.800
  - POTS tiene un MOS de 4.3 y la telefonía móvil entre 2.9 y 4.1
- (...)

QoE

- Métricas objetivas para voz:
  - Perceptual Evaluation of Speech Quality (PESQ)
    - ITU-T P.862
    - Requiere la señal original y la recibida para predecir el MOS
  - *E model*
    - ITU-T G.107 (factor R)
    - Tiene en cuenta el bitrate, pérdidas, ruido, eco, etc

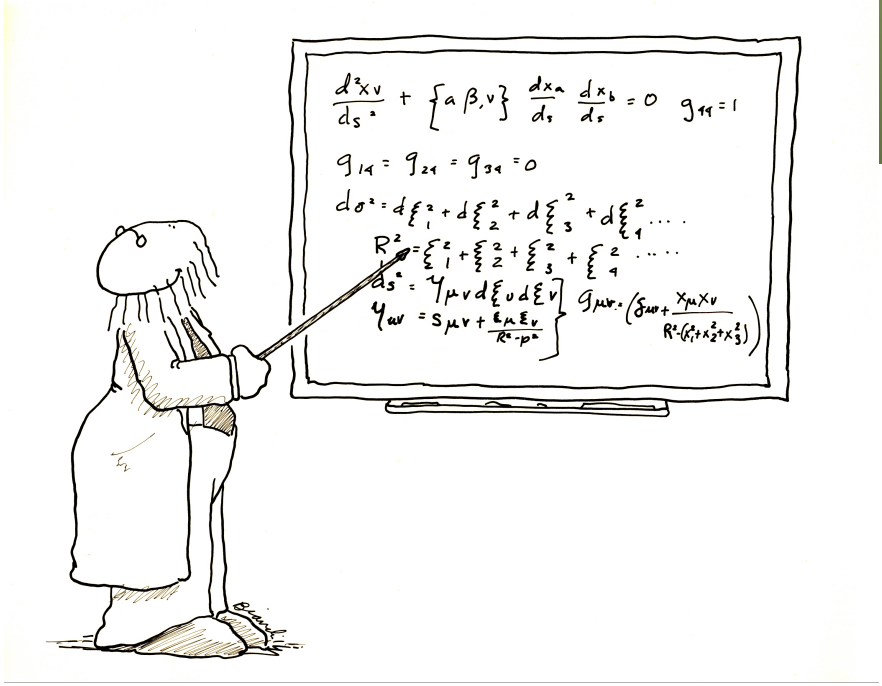

Retardo end-to-end

- ITU-T G.114 “One-way transmission time”
- Por debajo de 150 ms la mayoría de las aplicaciones experimentan interactividad transparente
- La calidad de servicio público exige un máximo de 150 ms
- En entornos privados es razonable un límite de 200-250 ms
- ¿Más de eso? (...)

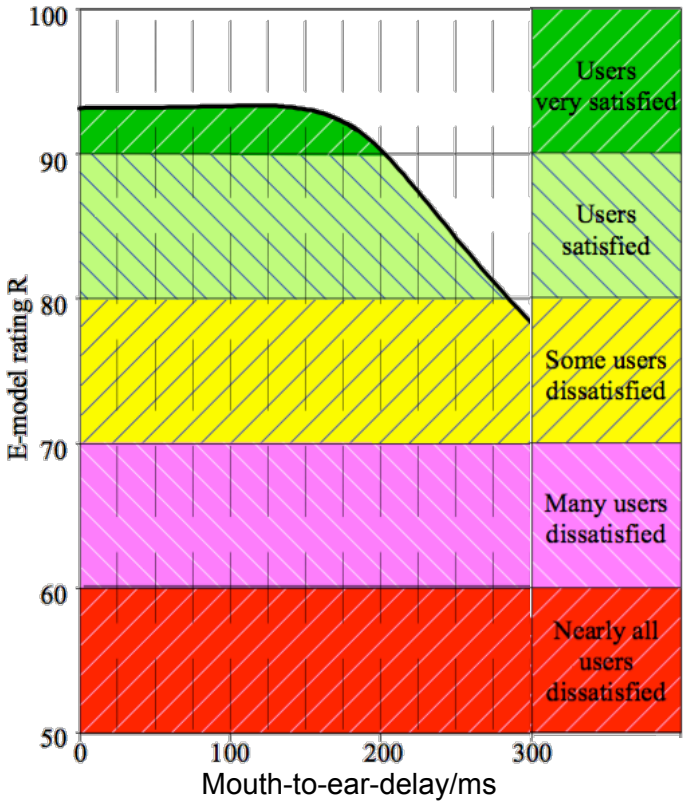

Figure 1/G.114 – Determination of the effects of absolute delay by the E-model

Retardo end-to-end

- Baja el MOS
- >400ms es inaceptable
- ¿Escenarios con alto retardo?

Ear-to-mouth delay (D)	R factor	Objective MOS
D < 150 ms	80–89	5
150 ms < D < 250 ms	70–79	4
250 ms < D < 325 ms	60–69	3
325 ms < D < 425 ms	50–59	2
D > 425 ms	90–100	1

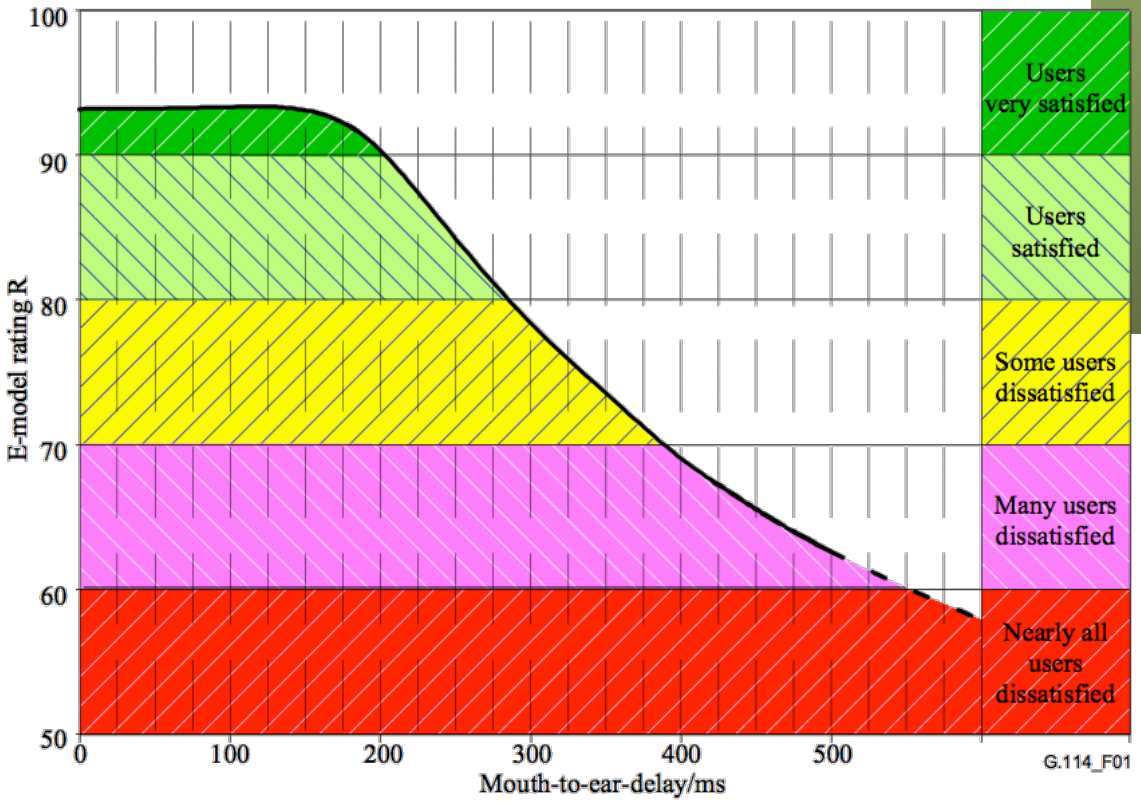

Figure 1/G.114 – Determination of the effects of absolute delay by the E-model

Retardo end-to-end

- Órbita geosíncrona: 36.000km / 300.000 km/s = 120ms
- Hay que subir al satélite y volver a bajar así que 2x120ms = 240ms
- ¡ Sólo de propagación ?

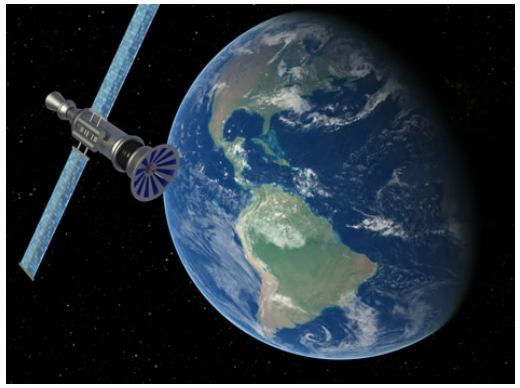

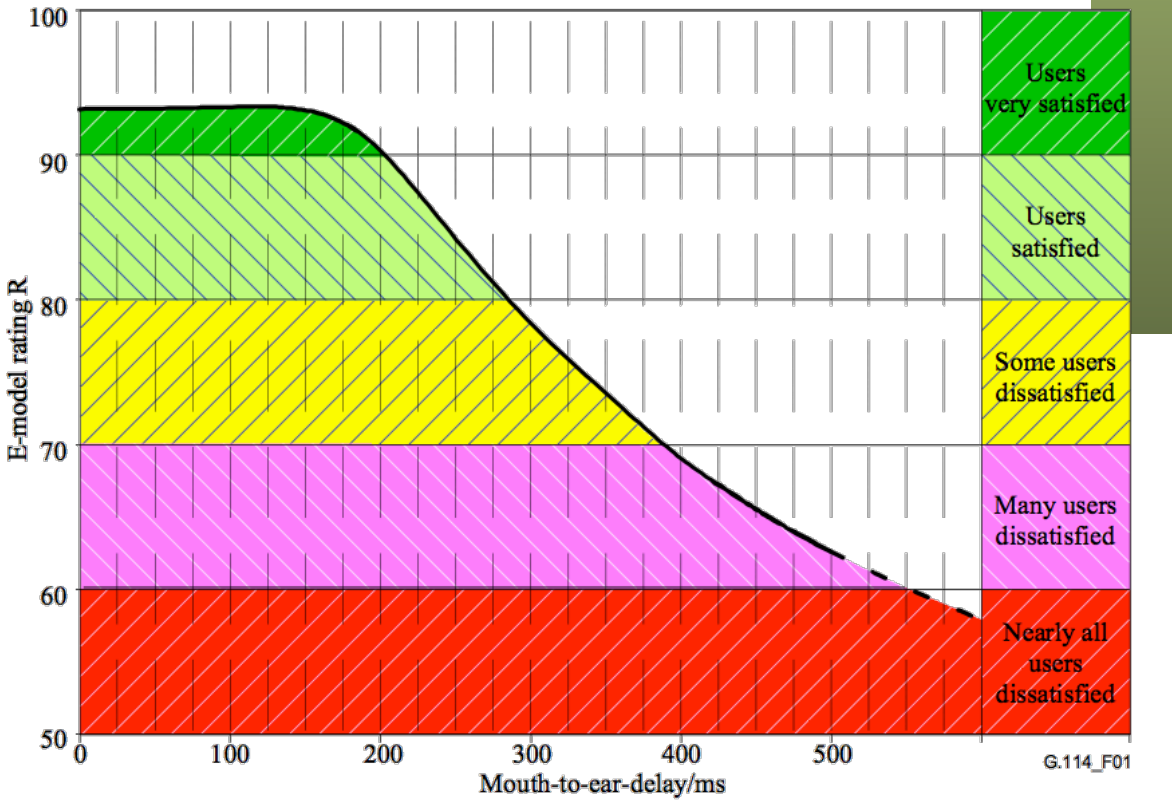

Figure 1/G.114 – Determination of the effects of absolute delay by the E-model

Codificación

Flujo extremo a extremo

- Flujo a través de una WAN

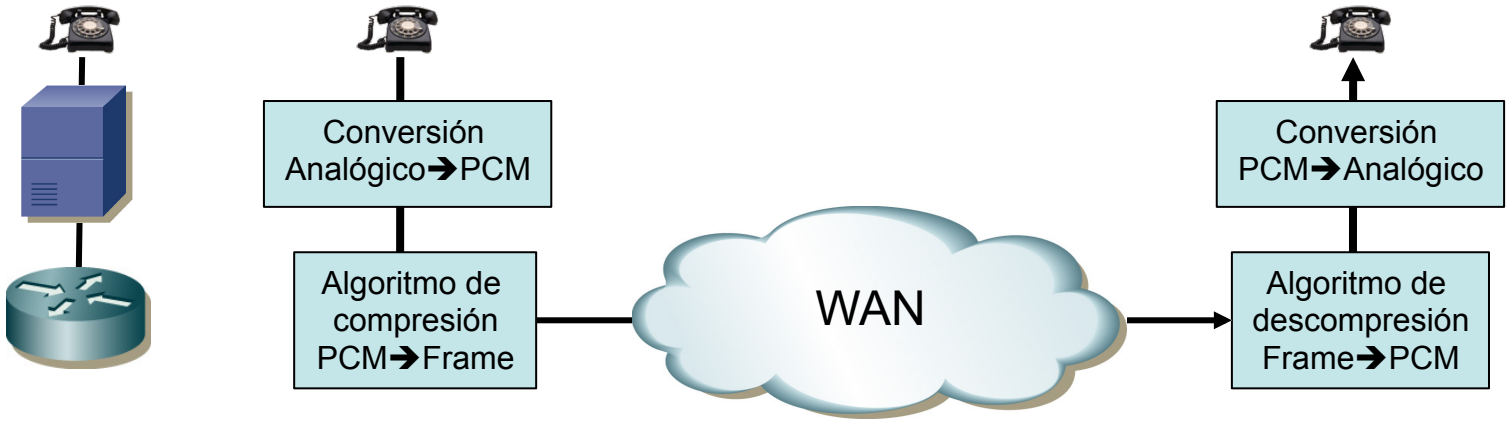

- Una PBX digital puede ser quien hace la digitalización
- Un router entonces suele cubrir la función de compresión y paquetización
- Podría la PBX integrar la funcionalidad del router
- (...)

Flujo extremo a extremo

- Flujo a través de una WAN

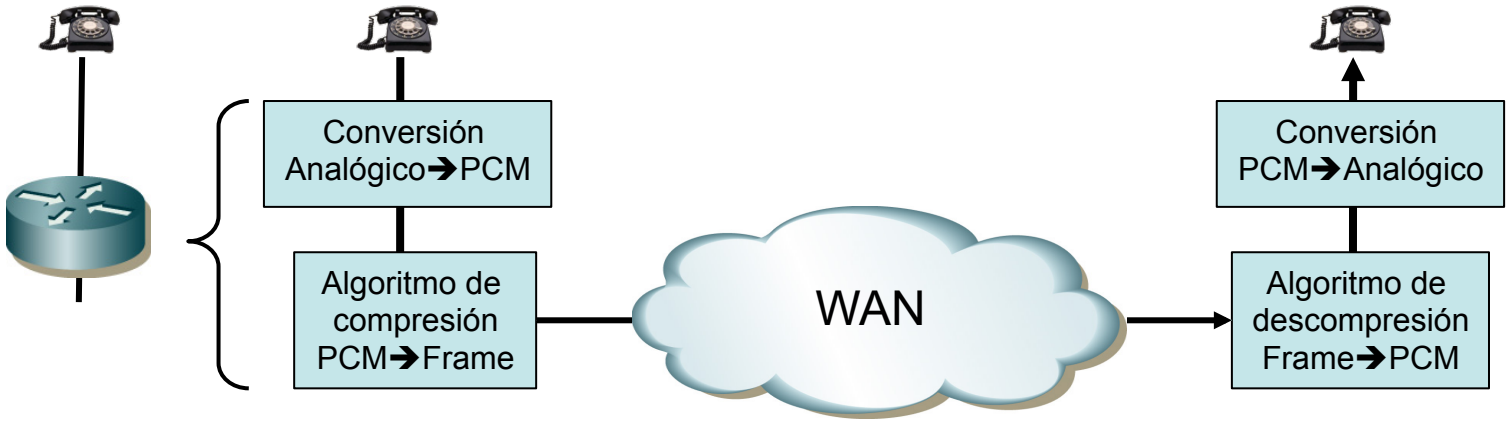

- O puede el router implementar ambas posibilidades

Codecs

- El codec es crítico en el efecto que el SLA tenga sobre la calidad
- Varían en complejidad, BW requerido y calidad de sonido ofrecida
- Los más complejos ofrecen mayor calidad percibida y menor bitrate pero con mayores tiempos de procesado

Ejemplos:

- G.711 basado en PCM (Pulse Code Modulation), simplemente muestreando a intervalos regulares
- G.726, ADPCM (Adaptive Differential PCM), usa predicción de la siguiente muestra y cuantiza eso
- G.723 y G.729 trabajan con bloques de muestras (*frame-based*) para las que aplican técnicas de compresión (ACELP = Algebraic Code Excited Linear Prediction)

Retardos constantes

Componentes del retardo

- **Retardo de paquetización**
  - El tiempo necesario para acumular las muestras
  - Depende del tamaño en muestras que se busque
  - En general no se excede de 30 ms de muestras (240 bytes PCM)
  - A menor tamaño mayor tasa de llegadas de paquetes de voz
- **(...)**

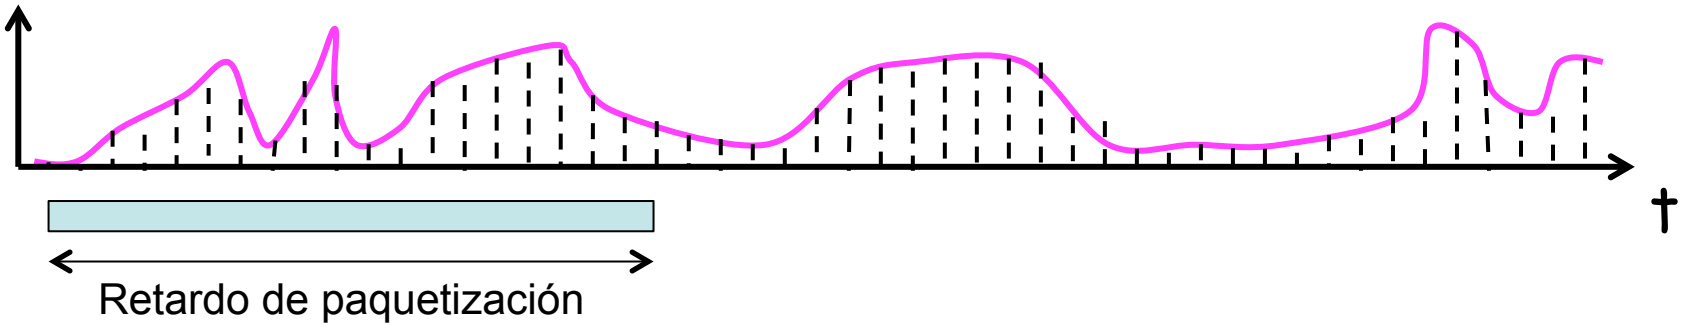

Componentes del retardo

- **Retardo de procesado del codificador**
  - Tiempo que lleva al DSP comprimir las muestras
  - También afecta en descompresión (menor, se suelen juntar al calcular)
  - Depende del coder y de su implementación (fabricante, en torno a 2-20ms)
- ***(...)***

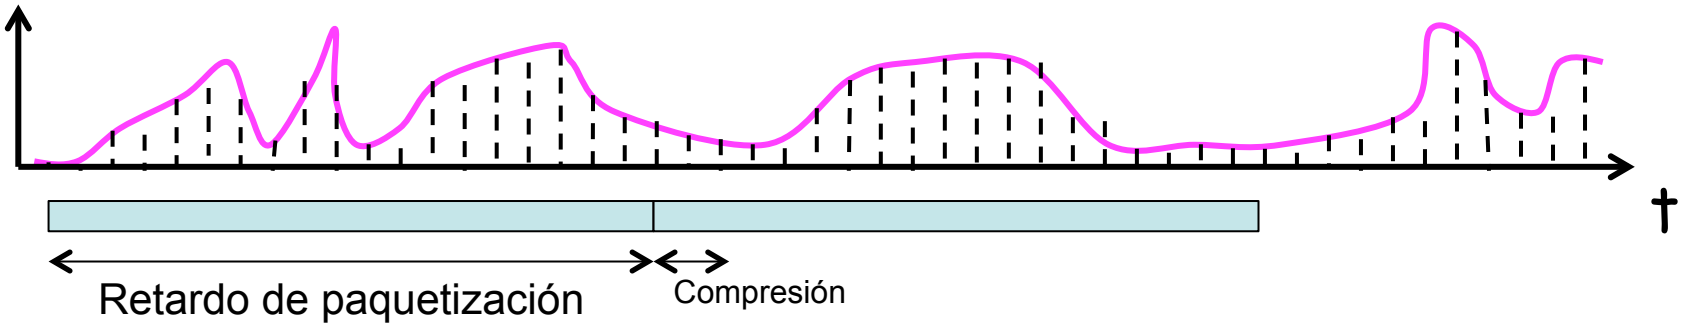

Componentes del retardo

- ***Algorithmic Delay (look ahead)***
  - Los algoritmos de compresión suelen necesitar conocer muestras siguientes a las del bloque a comprimir
  - Eso implica que hay que esperar a que se generen
  - Para G.726 es de 0 ms, para G.729 de 5 ms, para G.723.1 de 7.5 ms

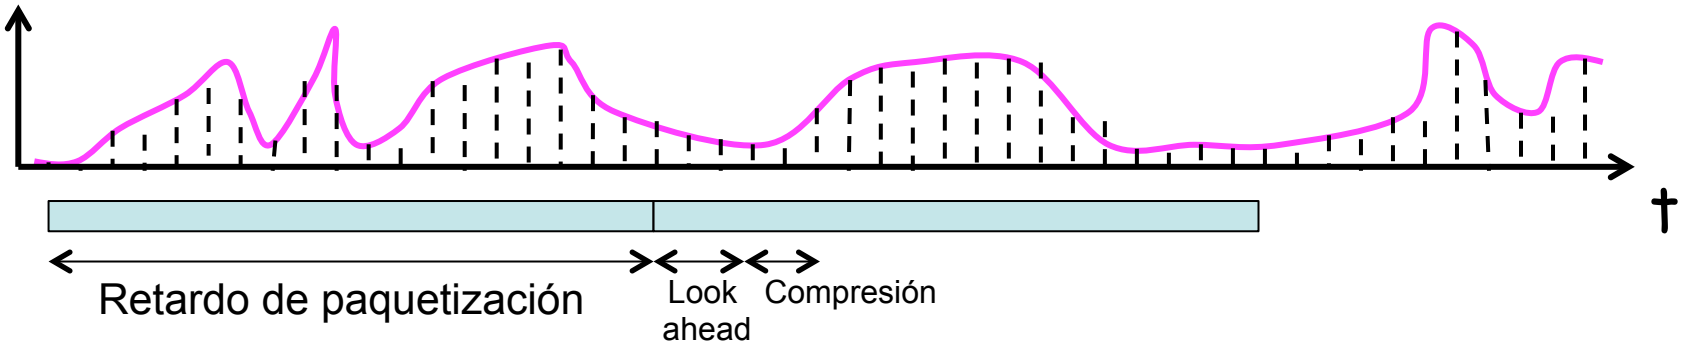

Retardos constantes

Retardo de serialización

- Tiempo de transmisión
- Solo se mejora aumentando la velocidad de transmisión
- Despreciable por encima de 100Mbps

(...)

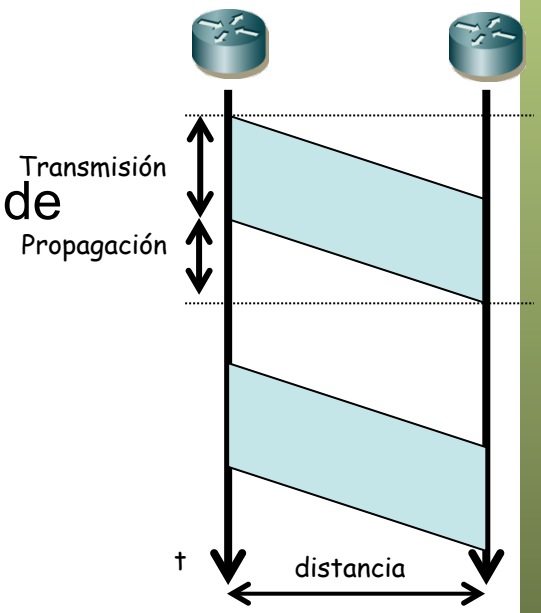

Retardos constantes

Retardo de propagación

- Coaxial terrestre, radio: 4μs cada Km (250.000Km/s)
- Fibra: 5μs cada Km (200.000Km/s)
- Coaxial submarino: 6μs/Km
- Siendo D la distancia en línea recta geográfica (a vuelo de pájaro)
- Los enlaces no siguen una línea recta
- ITU-T G.826 hace una estimación (R)

(...)

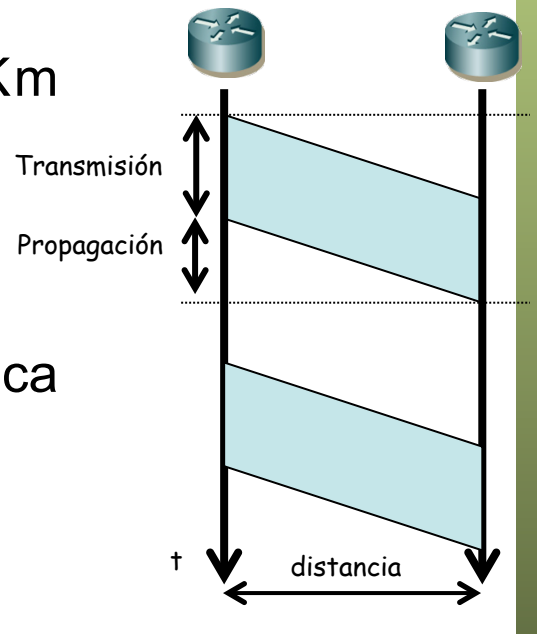

D	R
D < 1000 km	1.5 x D
1000 km ≤ D ≤ 1200 km	1500 km
D > 1200 km	1.25 x D

G.826 "End-to-end error performance parameters and objectives for international, constant bit-rate digital paths and connections
G.114 "One-way transmission time"

Retardos constantes

Tiempo de procesado/conmutación

- En función del hardware
- Típicamente 10-20µs
- Router software 2-3ms

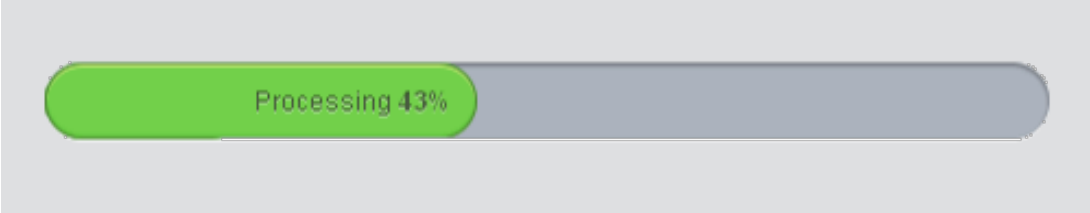

Retardos constantes

- Ejemplo comparativo
  - Retardo de serialización, de propagación y de conmutación
  - Paquete de 1500 bytes
  - Unos 200Km de fibra : 1ms de propagación

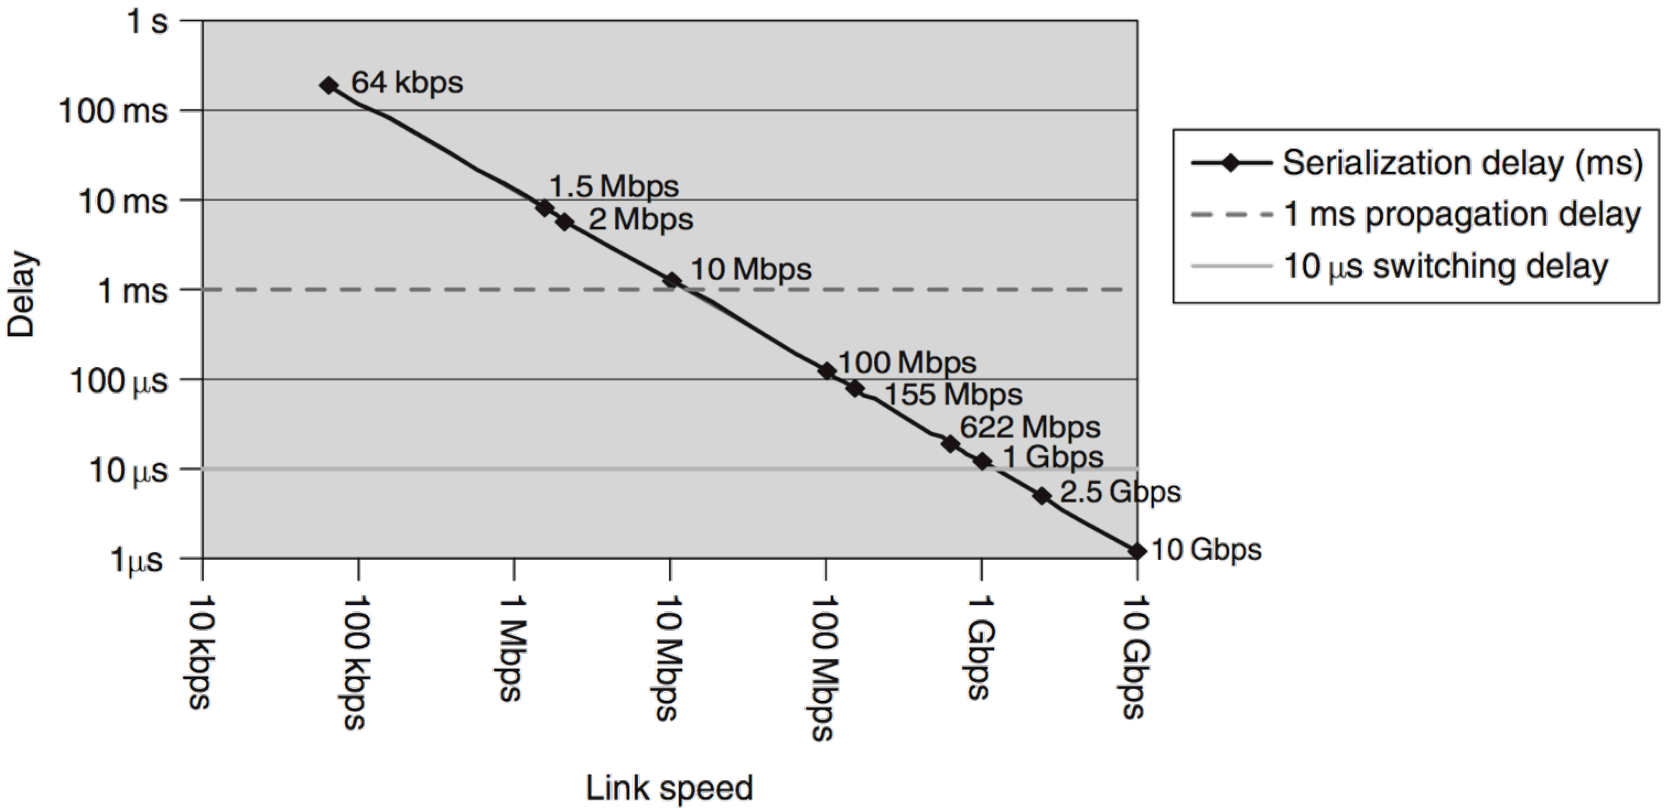

Retardos variables

De-jitter delay

- "*De-jitter buffer*" o "*play-out buffer*"
- Introducen un *play out delay*
- Variación en el retardo ➔ retardo constante en el receptor
- Obliga a la red a tener menor retardo
- Si el buffer es demasiado pequeño obliga a la red a garantizar un jitter bajo

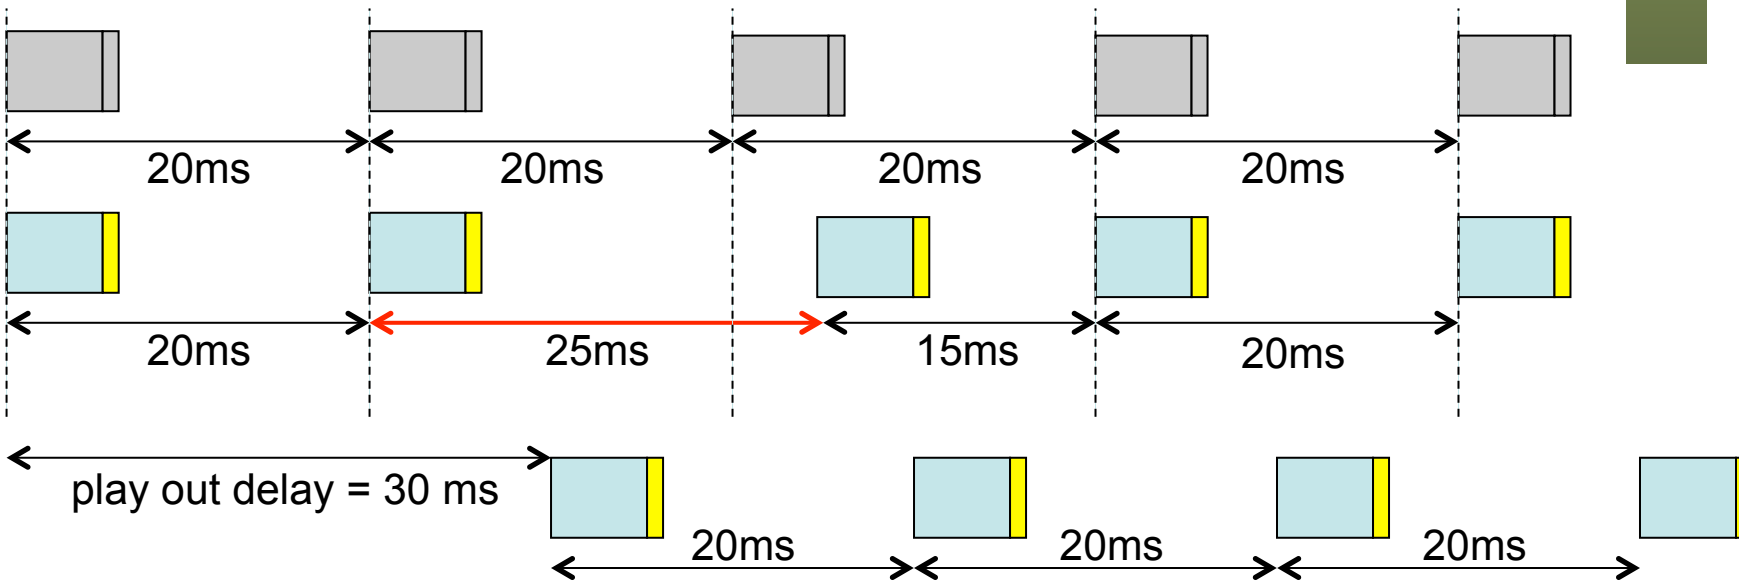

De-jitter delay

- Ejemplo de buffer muy grande:

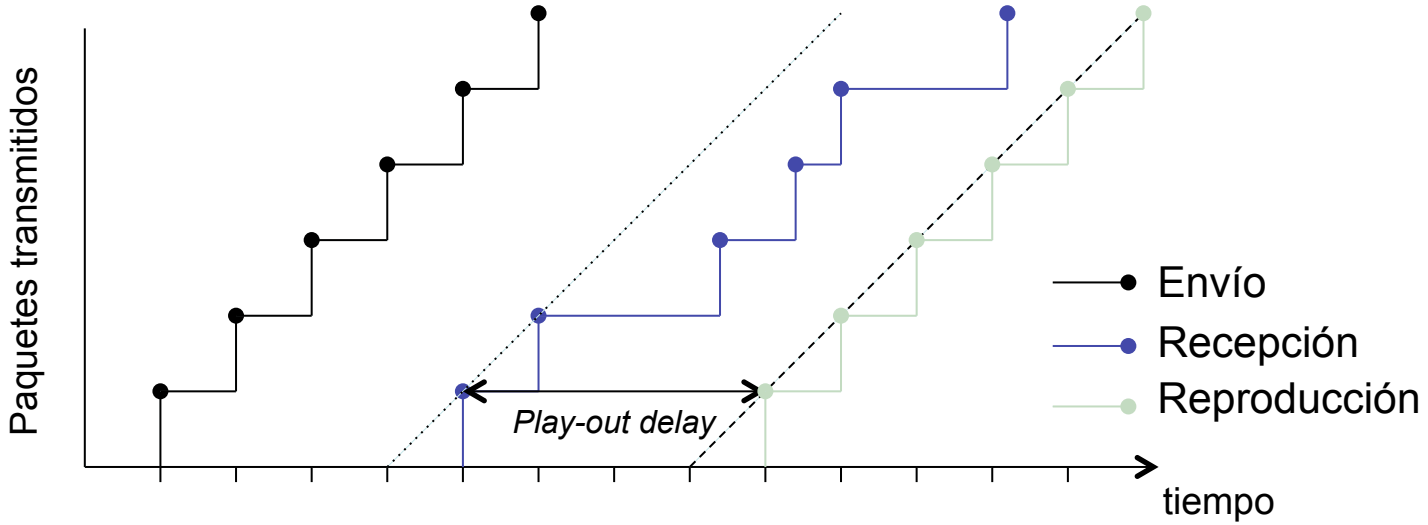

- Ejemplo de buffer demasiado **pequeño**:

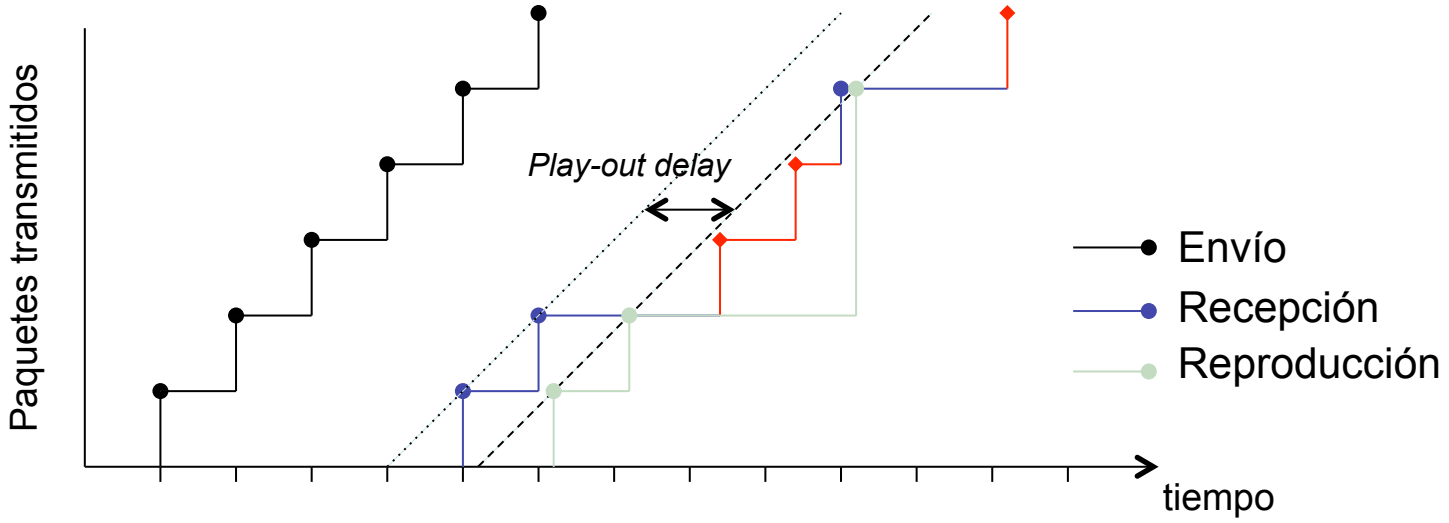

De-jitter delay

- Ejemplo de buffer **óptimo**:

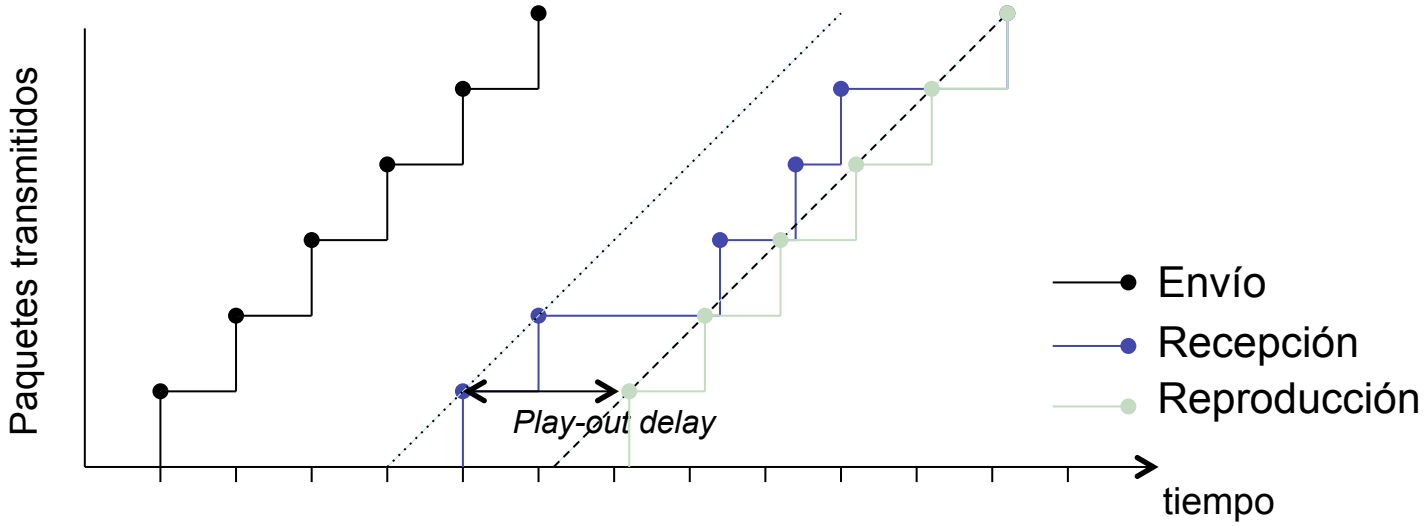

De-jitter delay

- Valor óptimo: el del retardo variable extremo a extremo
- Valores de *play out delay* en torno a los 40 ms
- Se emplea buffer adaptativo (con un valor máximo)
- Si se vacía el buffer entonces la próxima llegada se retiene durante el *play out delay* para reiniciar buffer
- Si se produce un underflow lo intenta "cubrir" (*packet loss concealment*) y aumentan el *play-out delay*
- Si pueden reducir el buffer lo hace de forma lenta

Retardos variables

Retardo en cola (scheduling delay)

- Tiempo entre que el paquete se dirige al interfaz de salida y que empieza a transmitirse
- Depende de la carga
- Depende del planificador

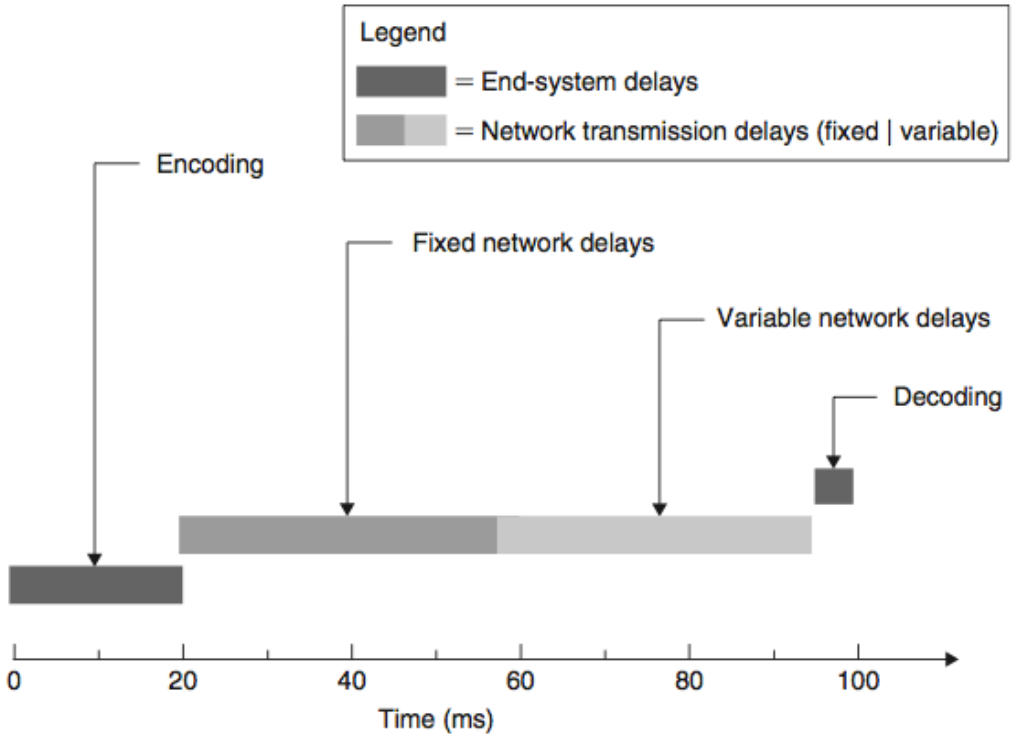

Otros retardos

- La llamada puede pasar por recodificadores, con lo que implica un nuevo tiempo de codificación
  - Sedes remotas podrían conmutar llamadas en sede central
  - Conmutación en PBX digital
  - Requiere convertir a PCM para pasar a la PBX (de-jitter, decodec)
  - Requiere volver a comprimir para enviar a la segunda sede
  - Mayores retardos de procesado
  - Más de dos compresiones CS-ACELP degrada la calidad de voz
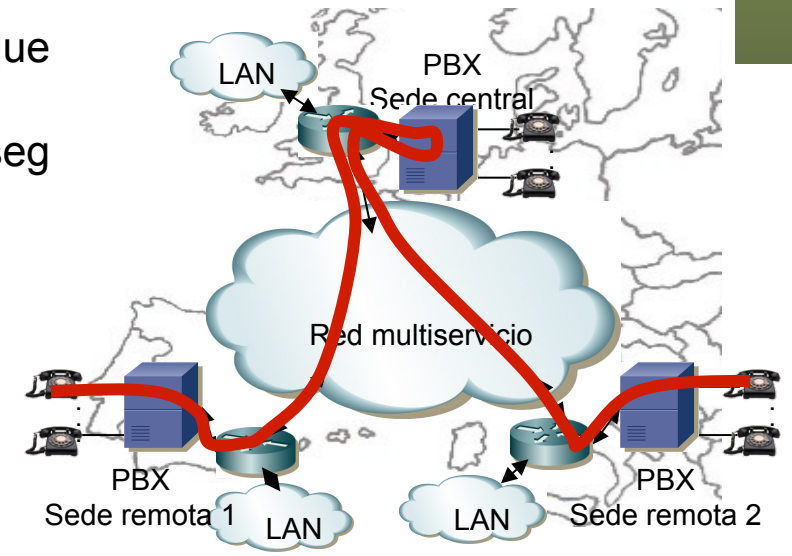
- PDD = Post Dial Delay
  - Entre marcar el último número y que suene el otro teléfono
  - 1-2 seg para llamadas nacionales, 4+ seg para internacionales