

# **MI020 - Internet Nouvelle Génération**

Module de M1 de la Spécialité Réseaux  
(Mention Informatique)  
2<sup>e</sup> semestre 2010 - 2011  
Université Pierre et Marie Curie

## **Support de Cours n°3**

**Contrôle de trafic / QoS  
BGP**

**Bénédicte LE GRAND  
Prométhée SPATHIS**



## Qualité de Service dans les réseaux IP

## Plan

### • Introduction

- Qu'est-ce que la QoS?
- Le besoin de QoS

### • QoS : boîte à outils

- Classification, conditionnement de trafic, files d'attente ...
- Différentes approches pour la QoS
  - QoS garantie vs différenciée

### • Architectures de QoS

- Integrated Services (IntServ) et RSVP
- Differentiated Services (DiffServ)

2

## Qu'est-ce que la QoS ?

## Contexte

- Réseau de paquets avec multiplexage asynchrone
  - Partage de bande passante dynamique
    - Multiplexage statistique, haute utilisation de la bande passante
  - Partage de ressources => contention
  - Contention => file d'attente FIFO
- Problèmes
  - Les flux de paquets sont remis en forme
    - Le délai introduit dans une rafale atteint par tous les flots
    - Pas d'isolation
  - Partage inéquitable quand forte contention
    - Différentes probabilités d'être jeté pour chaque flot
    - Bande passante allouée en fonction du niveau d'occupation de la file
  - Pas de différenciation des flots
    - Plusieurs utilisateurs peuvent demander des services différents
- Objectifs
  - Gérer la contention
  - En mode Best Effort : fair share
  - En service garanti : honorer les garanties de performance
    - Isolation et partage

4

## Qu'est-ce que la QoS ?

- QoS (Qualité de Service) = attribut du service fourni par le réseau
  - Un réseau peut fournir différents modèles de service
  - Le client et l'opérateur réseau négocient un SLA (Service Level Agreement) basé sur des modèles de service rédéfinis
- **QoS ≠ Performance**
  - La performance caractérise le comportement du réseau
  - Le réseau devrait fournir les différents modèles de service et minimiser l'utilisation des ressources du réseau

5

## Qu'est-ce que la QoS ?

- La QoS peut être évaluée selon différents critères:
  - **Bande passante**
  - **Délai** :
    - Délai de bout-en-bout
    - Variation du délai de bout-en-bout
  - **Intégrité des données** :
    - Taux de perte de paquets
    - Taux d'erreur des paquets
    - Taux de déséquencement des paquets
  - **Fiabilité et disponibilité**

6

## Besoin de QoS dans les réseaux IP

## Le besoin de QoS (1)

- Les applications ont besoin de QoS:
  - Les applications de voix, vidéo et multimédia constituent des flots de **trafic temps réel** qui ont des **contraintes de délai**.
  - Les applications commerciales basées sur des **transactions client/serveur** ont des contraintes fortes en terme de **temps de réponse**.
- Historiquement :
  - Applications vidéo et multimédia applications presque inexistantes dans le contexte de réseaux asynchrones
  - La voix avait son réseau optimisé, le PSTN (public switched telephone network), lui fournissait la QoS nécessaire.
  - Les applications commerciales avaient leurs réseaux avec des architectures ad-hoc telles que SNA (System Network Architecture) .

8


## Le besoin de QoS (2)

- Aujourd'hui :
  - La voix est de plus en plus compressée et tend à être transmise dans des paquets de données plutôt que dans des réseaux à commutation de circuits
  - Développement des application vidéo et multimédia (vidéo-conférence, video-on-demand...)
  - Réseaux tout IP
- Les réseaux de données devraient pouvoir réaliser une **intégration de service** en fournissant à chaque application la QoS dont elle a besoin (concept de **Next Generation Network** )

9

## Fournir la QoS

- La QoS a un sens quand le réseau est chargé :
  - Plus la charge du réseau est élevée et plus les mécanismes de QoS sont complexes.



- Le niveau de déploiement de la QoS est directement lié aux aspects économiques :
  - Prix de la bande passante (réseaux d'accès ou de coeur)
  - Prix des équipements (impact de la QoS sur le hardware et le software)
  - services visés (contraintes de QoS contraints des applications, etc.)

10

## Fournir de la QoS pour le trafic IP


- **Solutions possibles**
  - **Sur-dimensionner les ressources du réseau.**
    - Dans ce cas, pas besoin de déployer des mécanismes de gestion de trafic complexes.
  - **Utiliser des fonctions de contrôle de la QoS** et charger le réseau à des niveaux plus élevés
    - Peut être implémenté
      - Au niveau IP
      - En utilisant IP sur ATM, la couche ATM fournissant les capacités de QoS à la couche IP

11

## Pourquoi la QoS est-elle complexe ?

## Le problème de la QoS


- QoS garantie => **allocation de ressources**.
- Optimiser l'utilisation des ressources réseau => **ressources partagées** entre tous les flots de données.
  - L'optimisation des ressources réseau est, en général, nécessaire pour réduire les coûts
- Compromis entre la QoS et l'optimisation des ressources réseau.
  - Ceci est effectué via le **multiplexage statistique** utilisé avec d'autres fonctionnalités afin de réaliser l'optimisation des ressources et la provision de QoS



13

## Multiplexage statistique

- À un niveau microscopique (échelle de temps de la transmission de paquet)
  - Intéressant de par la nature sporadique du trafic transporté




- À l'échelle de temps de la rafale (ex : ABT ATM Block Transfer)
- À l'échelle de temps du flot ( flot / durée de connexion)

14

## Multiplexage statistique (2)


- Illustration du compromis entre utilisation du réseau / QoS



15

## Principes pour la garantie de QoS

- Exemple : téléphone IP 1Mbps, FTP 1Mbps ; partagent un lien à 1.5 Mbps.
  - Les rafales de FTP peuvent congestionner le routeur et causer des pertes audio
  - On veut donner la priorité à l'audio par rapport à FTP




**Principe 1**  
 Marquage de paquets nécessaire pour que les routeurs puissent distinguer des classes différentes; nouvelle politique des routeurs pour traiter les paquets en fonction de leur classe

16

## Principes pour la garantie de QoS (suite)

- Que se passe-t-il si les applications se comportent mal ? (ex: l'audio envoie plus de trafic que le débit déclaré)
  - Policing : contraindre les sources à adhérer aux allocations de bande passante
- Marquage et police en bordure du réseau
  - Similaire à l'UNI d'ATM (User Network Interface)




**Principe 2**  
 Protéger (isoler) les classes les unes par rapport aux autres

17

## Principes pour la garantie de QoS (suite)

- Allocation de bande passante *fixée* (non partageable) à un flot : utilisation *inefficace* de la bande passante si le flot n'utilise pas ce qui lui a été alloué




**Principe 3**  
 Tout en fournissant l'isolation, il faut utiliser les ressources aussi efficacement que possible

18

## Principes pour la garantie de QoS (suite)

- *Fait réel* : on ne peut pas répondre à des demandes de trafic au-delà de la capacité du lien




**Principe 4**  
Admission d'appel : un flot déclare ses besoins, le réseau peut bloquer l'appel (ex : signal occupé) s'il ne peut pas répondre à ces besoins

19

## Résumé des principes de QoS

### QoS for networked applications



Regardons maintenant les mécanismes pour mettre tout ceci en oeuvre...

20

## QoS : mécanismes

- **Protocole de réservation.** Pour indiquer le volume de ressources nécessaire (CPU, mémoire, bande passante) le long du chemin des données.
- **Classification.** Pour identifier le flot auquel appartient le paquet qui arrive
- **Contrôle d'admission.** Pour déterminer, pour chaque nouvelle réservation, si elle peut être acceptée ou non en fonction des ressources disponibles.
- **Fonction de police.** Pour vérifier si le volume de ressources réservé n'est pas dépassé par la source.
- **Fonction de mise en forme.** Pour retarder les flots qui ne suivent pas certaines règles.
- **Algorithmes d'ordonnement.** Pour allouer une capacité de transmission sur une base paquet par paquet afin d'atteindre les objectifs de QoS pour chaque flot.
- **Gestion de files d'attente.** Pour jeter les paquets, en cas de congestion, selon le niveau de priorité des paquets

21

## Plan

### • Introduction

- Qu'est-ce que la QoS?
- Le besoin de QoS

### • QoS : boîte à outils


- Classification, conditionnement de trafic, files d'attente ...
- Différentes approches pour la QoS
  - QoS garantie vs différenciée

### • Architectures de QoS

- Integrated Services (IntServ) et RSVP
- Differentiated Services (DiffServ)

22


## Mécanismes de QoS : vue globale



23

## Classification

- Classification du trafic
  - Besoin de classification :
    - Différents clients sur la même interface (chacun avec un SLA/TCA spécifique)
    - Différentes « classes de service », etc.
  - Types de classification :
    - Basée sur les adresses IP (en-tête de niveau 3)
    - Basée sur les en-têtes de niveau supérieur (N°s de port TCP/UDP etc.)
    - Basée sur des marqueurs spécifiques (DiffServ)



24

## Conditionnement de trafic

Nous aborderons :

- Le policing
- Le contrôle de flot
- Le contrôle de congestion
- L'équité
- Les Token/Leaky buckets
- Les TSpec
- Le contrôle d'accès
- La remise en forme (shaping)
- Les files d'attente
- ...

25

## Policing

**But :** limiter le trafic pour ne pas dépasser les paramètres déclarés


Trois critères fréquemment utilisés :

- **Débit moyen (Long terme) :** combien de paquets peuvent être envoyés par unité de temps (à long terme)
  - Question cruciale : quel est l'intervalle de temps : 100 paquets par seconde ou 6000 paquets par minute ont la même moyenne !
- **Débit crête :** ex : 6000 paquets par minute en moyenne ; 1500 ppm de débit crête
- **Taille de rafale (Max.) :** nombre max. de paquets envoyés en une fois (sans silence intermédiaire)

26

## Policing


- Conditionnement de trafic
  - Nécessite des TCA (Traffic Conditioning Agreements)
  - De tels mécanismes incluent :
    - Des mesures de trafic (débit moyen, débit crête)
    - Packet Dropper (avec des politiques de rejet spécifiques)
    - Traffic Shaper
    - ...
  - Exemple : Contrôle du débit crête avec un token bucket shaper (R,B)



27

## Policing

token bucket, combiné avec WFQ pour imposer une borne supérieure au délai, i.e., *QoS garantie* !



28

## Problème

- Transfert de fichier
  - Le flot de paquet représente le fichier
  - Le débit dépend de la capacité du récepteur et la capacité du réseau
- Comment choisir le débit ?
  - Trop faible : temps perdu
  - Trop élevé : risque d'introduire de la congestion
- Vidéo à la demande
  - Débit variable
- Comment réserver des ressources réseau ?
  - Trop : faible utilisation des ressources
  - Trop peu : risque d'introduire de la congestion

29

## Contrôle de flot


- Définition
  - Ensemble de techniques de contrôle de trafic et de congestion pour obtenir un service réseau satisfaisant pour l'utilisateur
- Contrôle
  - Contrôle de trafic
    - Ensemble d'actions de contrôle effectuées par le réseau pour éviter la congestion
    - Actions préventives
  - Contrôle de congestion
    - Ensemble d'actions pour restaurer un fonctionnement normal du réseau en cas de congestion
    - Actions réactives : quand la congestion est proche ou installée
  - Objectifs du contrôle
    - Maintenir la qualité du transfert pour les flots de service garanti
    - Équité entre les flots BE
    - Utilisation optimale des ressources
      - Liens
      - Files d'attente

30

## Congestion

- Définition générale  
Situation où le réseau ne peut pas satisfaire un service pour les applications
- Quand ?

$$\sum Demand(t) > Resource(t)$$





- Causes
  - Fluctuations de trafic imprévisibles
  - Problèmes du réseau

- Solutions
  - Augmenter les ressources
    - BP, Buffers ...
  - Contrôler les demandes

31

## Conséquences de la congestion




- Contention gérée par les files
  - Sérialisation des demandes
  - La file est la première protection face à l'augmentation de  $\lambda$
- Sévère contention  $\lambda \gg \mu$ 
  - Buffers pleins
  - Pertes
- Conséquences
  - Les temps de transfert des paquets augmente
  - Perte de paquets
    - Transfert de données : retransmission des paquets perdus et risque de retransmissions abusives dues aux délais importants
  - "Congestion collapse"
    - Gâchis de ressources réseau
    - Ressources utilisées par un paquet avant qu'il soit détruit sont perdues
    - Augmentation de la charge => diminution du débit

32

## (Mauvaises) solutions possibles

- Augmenter la taille du buffer
  - Augmentation du délai, retransmission activée par le transport
    - Durée de vie finie du paquet
  - Gâchis de ressources, le paquet retransmis est jeté
  - Pire qu'un petit buffer

- Augmenter la bande passante
  - Ajouter un lien à haut débit
    - Augmente le temps de transfert
  - Un réseau possède des liens hétérogènes



- Conséquence
  - La congestion est un problème dynamique qui requiert des solutions dynamiques
    - Contrôler les demandes
    - Gérer les ressources

33

## Critères de performance

- Efficacité
  - Best-effort : équité
    - Partage équitable des ressources
  - QoS : performance garantie
    - Fournir des garanties et les respecter
      - Utiliser des réservations
    - Expression via des paramètres de QoS
      - BP
      - Délai
      - Gigue
      - Perte
- => Il faut isoler les utilisateurs

34

## Équité

- Allocation d'un système partagé
- Enjeu quand certaines demandes ne sont pas satisfaites
- Résulte d'une optimisation

### Métrique

- Fair index<sup>1</sup>
  - Quantifie l'équité dans l'allocation de la BP en excès entre les clients qui partagent un lien

$$f(x_1, x_2, \dots, x_n) = \frac{\left(\sum_{i=1}^n x_i\right)^2}{n \sum_{i=1}^n x_i^2} \leq 1 \text{ toujours,} \\ = 1 \text{ s'il y a équité}$$


où  $x_i$  est le débit en excès du  $i$ ème client

- Portée
  - Globale : niveau réseau => action au niveau rafale
  - Locale : niveau routeur => action au niveau paquet

35

## Équité locale et globale

- Considérons un partage équitable entre les utilisateurs :




- Résultat
  - Localement équitable
  - Globalement inéquitable
- Éviter le congestion collapse
  - Un flot doit avoir une allocation correspondant au goulot d'étranglement
    - Limiter le débit par source
    - Échelle temporelle d'action : RTT
  - sinon
    - Utilisation inefficace des ressources réseau
    - Du point de vue des sources, la performance n'est pas satisfaisante

36

### Partage équitable

- Le partage équitable n'est pas une bonne solution
- Trouver un équilibre entre efficacité et équité




© Andrzej Dutka

37

### Max-min Fair Share

- Satisfaire un maximum de flots
- Principe
  - Satisfaire ceux qui demandent moins
  - Aucun nœud n'obtient plus que ce qu'il demande
  - Ceux qui ne sont pas satisfaits obtiennent un partage équitable




- Définition
  - Personne ne peut obtenir plus aux dépens de quelqu'un qui a déjà moins

© Keshav

38

### Max-min Fairness

- Augmente l'efficacité du réseau
  - $x_1$  a une plus grande allocation sans gêner les autres flots.



© Andrzej Dutka

39

### Goulot d'étranglement

- Définition
  - Un lien est goulot d'étranglement pour une source si et seulement si
    - Le lien est saturé
    - La source s sur ce lien a le débit maximum de toutes les sources sur ce lien
- Théorème
  - Une allocation X est max-min fair ssi chaque source a un goulot d'étranglement

40

### Isolation

- Protection
  - Isoler chaque flot
- L'équité apporte la protection
  - Chaque source a sa propre allocation équitable

41


### Action de contrôle

- Échelle de temps
  - Paquet
  - RTT
  - Session
  - Long terme
- Granularité
  - Flot applicatif
  - Agrégation de flot
- Localisation
  - Source
    - Couche transport ou application
    - Action basée sur une notification
  - Routeur
    - En bordure ou au cœur
    - Police (vérifier que le trafic respecte certaines règles)
    - Priorités : disciplines de files d'attente et de service


42

## Échelle de temps du contrôle

- Modèle de trafic



- Actions



43

## Modes de contrôle

- Boucle ouverte*

- La source décrit son débit désiré
- Le réseau accepte l'appel
- La source respecte le débit
- Actions préventives
- Contrôle de trafic

- Boucle fermée*

- La source adapte le taux de service en fonction d'une notification de feedback
- Latence dans la propagation des notifications => erreurs
- Actions réactives
- Contrôle de congestion

- Hybride*

- La source demande un débit minimum
- Mais elle peut envoyer plus si c'est possible

44

## Boucle ouverte

- Principe

- Performance prévisible si les flots sont contraints
- Flot contraint + réservation = performance garantie

- Pour des application capables de décrire leur comportement futur

- Média continus

- 2 phases

- Établissement d'appel
- Transmission de données

- Établissement d'appel

- Négocier les ressources (entre source et réseau)
  - Décrire le trafic : descripteur de flot
- Le réseau accepte ou refuse : contrôle d'admission
- Contrat de trafic : réservation
  - Si la source se conforme au contrat, le réseau garantit qu'il n'y a pas de congestion

- Transmission de données

- La source envoie du trafic conformément à la description
- Le réseau contrôle la conformité (contrôle d'accès)
  - Régulation : mise en forme
  - Surveillance: Dropping
- Actions du réseau pour fournir la QoS au flot
  - Priorités (ordonnement et files d'attente)

45

## Évaluation

- Contrôle pour les applications critiques

- La QoS peut être fournie
- Pas de congestion
  - Pas de perte dans le réseau
  - Gigue et temps de réponse minimisés
- Difficile à mettre en œuvre en mode sans connexion
- Sous-utilisation des ressources
  - Mauvaise caractérisation de la source
  - Les sources ne sont pas toujours actives

- Difficulté à choisir

- Le descripteur de flux
- Comment admettre / rejeter un flot
- La politique d'ordonnement et de file d'attente

46

## Descripteur de flot

- Définition :

- Ensemble de paramètres qui représentent le comportement de la source
- Description du trafic envoyé

- Principe

- Décrire le « pire » comportement
- Définir une enveloppe

- Utilisation

- Contrôle d'admission : contrat de trafic
- Contrôle d'accès : régulation, surveillance.

47

## Débit crête

- Principe

- Débit maximal auquel les données peuvent être envoyées
- Intervalle temporel minimum entre les paquets

$$D_{\max} = \frac{L}{T} \quad L : \text{taille du paquet}$$

- Mise en forme (shaping)

- Démarrer un temporisateur quand un paquet est envoyé
- Possible d'envoyer un autre paquet quand le tempo expire

- Évaluation

- Limite extrême, sensible aux variations

48


### Débit moyen

- Principe
  - Débit sur une période de temps
    - réduire la sensibilité aux variations
  - Volume de données A envoyé sur une période de temps T
- Descripteurs
  - $D = \frac{A}{T}$
  - Fenêtres
    - Pour chaque fenêtre temporelle consecutive de taille T, pas plus de A bits peuvent être envoyés
  - Dépendent de l'état initial
  - Fenêtre glissante
    - Pour chaque période T, pas plus de A bits peuvent être envoyés
- Trop complexe à un débit élevé

49


### Modèle fluide

- Modèle mathématique
  - Utiliser un modèle parfait
    - Fonction continue
    - Pas de discontinuité introduite par les paquets
  - Étudier le flot isolé des autres flots
    - Lien dédié
- Courbes d'arrivée et de départ



50


### Flot contraint : enveloppe



51

### Leaky Bucket

- Paramètres
  - r: rate (débit)
  - b: taille du buffer
- Algorithme
  - Token = droit d'envoyer 1 bit
  - Le seau se vide à un débit de token contraint (r)
  - Le seau ne doit pas déborder
  - Quand il y a débordement, le flot n'est pas conforme
    - L'action sur les données non-conformes dépend de la politique.



52


### Leaky Bucket

- Utilisation
  - Média continus : descripteur approximant le débit moyen et la sporadicité
  - Média discrets : détermine une enveloppe obtenue après régulation
- Évaluation
  - Limite la taille des rafales
  - Algorithme simple
  - Difficile de choisir b et r
  - Pour les média discrets, consiste en la mise en forme au débit r

53

### Concaténation de Buckets

- Plusieurs seaux peuvent être concaténés pour contrôler plusieurs débits
  - Le débit diminue au fur et à mesure des seaux




© Roch Guérin

54

### Token bucket

- Token Bucket
  - Ajout d'un régulateur au débit crête



MBS = Maximum Burst Size      MBD = Maximum Burst Duration

$$MBS = \sigma \frac{P}{P - \rho} > \sigma \qquad MBD = \frac{MBS}{P} = \frac{\sigma}{P - \rho}$$

55


### Leaky bucket et Token Bucket

- Leaky bucket
  - Contrôle de conformité
    - Débit moyen
  - Mise en forme : couplée avec une file d'attente
  - Surveillance : effacer les paquets non conformes.
- Token Bucket
  - Leaky bucket avec un régulateur de débit crête
  - Pour contrôler
    - Le débit moyen
    - Le débit crête
    - La taille maximum de rafale (Maximum burst size)
  - Utilisé pour le TSpec dans IntServ (présenté plus loin)

56

### Application du TSpec


- Attention
  - Un flot de paquet n'est pas un liquide
  - Paquets transmis au débit du médium
  - Les paquets sont de taille variable
- TSpec (spécification de trafic)
  - Le TSpec( $r, b, p, L$ ) détermine une courbe d'arrivée
$$a(t) = \min(L + pt, b + rt)$$
  - équivalent à la conjonction de 2 leaky buckets



57


### Le Dual leaky Bucket

- Le Token bucket limite les débits à court et long termes



58

### Mode Dropping/Marquage



59

### Contrat de trafic

- Pour définir les caractéristiques d'un flot et les imposer
- La source doit respecter les caractéristiques annoncées
- Le réseau doit maintenir la QoS demandée
- Établi durant la phase de négociation
- Éléments du contrat de trafic
  - Paramètres de QoS de l'utilisateur
    - Service attendu
    - Ensemble de paramètres
      - Négociables : taux de perte, temps de transfert max...
      - Non négociables : taux d'erreur par paquet...
  - Descripteur de flot
    - Caractérise le trafic de la source
    - Comprend : le descripteur de trafic de la source, la définition de conformité

60


## Contrôle d'admission

- Limite le nombre de flots dans le réseau
- Vérifie que le réseau a suffisamment de ressources pour accepter un nouveau flot
- Mise en œuvre
  - Analyser la demande dans le contrat de trafic
  - Réserver des ressources
- **Contrôle d'admission pour CBR :**  $L + \rho_i \leq C$ 
  - Test pour un appel  $i$  et une charge déjà admise  $L$
  - Simple
  - Si cela échoue, la requête est re-routée, retardée ou effacée
- **Contrôle d'admission pour BE**
  - Jamais rejeté
- **Contrôle d'admission pour VBR**
  - Caractéristiques de VBR
    - rafales (les débits crête et moyen sont différents)
    - Politiques de réservation
      - Débit crête : ressources gâchées
      - Débit moyen : paquets jetés pendant les rafales (probablement)
    - Plusieurs types de réservation (débit crête, débit moyen ...)

61

## Contrôle d'admission au débit crête

- **Avantages**
  - Délai et perte nuls
  - Simple
    - calcul
    - L'ordonnement FIFO est OK
- **Inconvénients**
  - Gâche la bande passante




- Le débit crête peut augmenter après être passé par plusieurs ordonnanceurs
  - Introduit de la gigue

62

## Contrôle d'admission : LBAP (Linear Bounded Arrival Process)


- **Principe**
  - Description de la source avec LBAP
  - Utilise un ordonnanceur qui réserve
    - BP > débit moyen
    - Un buffer pour MBS
- **Avantages**
  - Plus efficace pour la BP que l'allocation au débit crête
  - Utilisé pour donner des garanties de délai, perte et BP
    - Dans GS
- **Inconvénients**
  - Un délai court peut nécessiter une réservation supérieure au débit crête
  - Le pire cas peut être très improbable => gâchis de BP
  - Complexe



63

## Contrôle d'admission : garanties statistiques

- **Principe**
  - Repose sur le multiplexage statistique
  - Lorsque le nombre de flots  $N$  augmente, la probabilité qu'ils soient tous actifs diminue



- Pour des valeurs élevées de  $N$ , le débit total est quasiment constant
- Contrôle sur la notion de BP équivalente
- **Avantages :** utilisé pour fournir des garanties statistiques pour le délai
- **Inconvénients**
  - Suppose que les sources sont indépendantes
  - Complexe

64

## Contrôle d'admission : MBAC (Measurement-based Admission Control)

- Pour les flots qui ne peuvent pas être décrits ou varient de manière imprévisible
- **Principe**
  - Mesure la charge réelle
  - Nouveau flot décrit par son débit crête
  - Admission
    - crête + moyen  $\leq$  capacité
  - Le flot est décrit par le débit moyen quand actif
  - Utilisé par CL
- **Inconvénients**
  - Suppose que le futur et le passé sont similaires
  - Durée de la période de mesure ?
  -

65


## Contrôle d'accès

- **Problèmes**
  - La charge peut dépasser la demande si
    - Elle est mal caractérisée
    - On a une mauvaise connaissance du trafic
- **Objectifs**
  - Vérifier que le trafic est conforme à la déclaration
  - Éviter la congestion
- **Principe**
  - Vérification
    - De la part du réseau : que chaque flot est conforme au descripteur
      - En utilisant un leaky bucket
      - Représente un ensemble d'actions (de la part du réseau) pour surveiller et contrôler le trafic
- **Actions**
  - Surveillance : détecter si un paquet est conforme ou non à une spécification
  - Régulation (shaping)
    - Réduire la sporadicité du trafic ou changer les caractéristiques du trafic
  - Marquage
    - Préférence pour jeter les paquets parmi les paquets non-conformes

66

## Shaping


- Définition
  - Modifier le flot temporellement pour s'assurer qu'un flot envoyé sur le réseau ne dépasse pas certaines limites
  - Limites en termes de
    - Débit crête, débit moyen, taille maximum de rafale
- Principe
  - Adapter le flot en fonction d'un contrat / profil établi
  - Si la file est pleine, des paquets sont perdus
    - => les paramètres de trafic doivent être correctement définis pour éviter un dropping excessif
- Objectifs
  - Contraindre le flot à des caractéristiques connues
    - Pour fournir des garanties de QoS
  - Réduire la sporadicité



Interface de sortie


67

## Shaping Mode



68


## Shaping Mode – Taille du Buffer (BF)




69

## Boucle fermée : boucle de contrôle

- Utilisation
  - La source ne peut pas décrire son trafic ou le réseau ne peut pas réserver de ressources
  - Les ressources sont insuffisantes pour la source
    - La source peut envoyer plus que ce qu'elle a
- Objectifs
  - Éviter le congestion collapse (réduction de la quantité de trafic qui parvient à traverser le réseau)
  - Équité (partage équitable de ressources)
  - Contrôler la performance obtenue



- Contrôle réactif
  - La source envoie une notification



70

## Boucle de contrôle

- Principe
  - Évaluer les ressources disponibles
  - Notification de la source
    - Implicite ou explicite
  - Contrôler le débit de la source
    - fenêtre, etc.
- Inconvénients
  - Requiert la coopération de la source de trafic
  - En général, un émetteur doit pouvoir contrôler son débit et le réduire pour réduire la congestion
- Exemple :
  - TCP
    - Notification implicite et fenêtre de congestion
    - Notification implicite et contrôle par fenêtre.
- évaluation
  - Pas efficace pour les applications temps réel
  - Utilisation optimale des liens

71


## Classification des gestions de files d'attente

- Nombre
- Par couleur, par circuit virtuel, par flot ou globale
- Multiple ou unique
- seuil : single ou multiple
- Différents types
  - SAST : Single Accounting, Single threshold
  - SAMT : Single Accounting, Multiple threshold
  - MAST Multiple Accounting, Single threshold
  - MAMT Multiple Accounting, Multiple threshold

72

## Files d'attente

- Gestion des files d'attente
  - Pourquoi ?
    - Des mécanismes préventifs (conditionnement de trafic, ordonnancement) permettent d'éviter l'apparition de congestion, avec un certain niveau de confiance. Cependant, à de courtes échelles temporelles, la congestion pourrait apparaître, auquel cas les files d'attente grossissent. Des procédés curatifs sont alors nécessaires pour protéger les paquets "privilegiés".
  - Une gestion active de files d'attente (Active Queue Management) peut utiliser des priorités de pertes spécifiques (jaunes, vertes, rouge)



73

## Files d'attente

- **Q ? Quand jette-t-on des paquets ?**
  - Quand le buffer est plein (tail drop)
  - Quand l'occupation du buffer augmente trop (RED)
- **Q ? Quels paquets doit-on jeter ?**
  - Le paquet arrivant (tail drop : mais est-ce que ce paquet est responsable de la congestion ?)
  - Un autre paquet parmi le flot de paquets arrivants
    - Ceci pourrait aider les algorithmes de contrôle de congestion
  - Un paquet d'un flot quelconque
  - Le paquet en tête de file
    - Pourrait améliorer les performances de TCP

74

## Files d'attente

- Objectifs
  - Ajouter de la discrimination dans le réseau
  - Résoudre les problèmes de TCP
    - Le contrôle de congestion de bout-en-bout est inéquitable
    - UDP n'est pas équitable avec TCP
    - Le DropTail entraîne une synchronisation des sources TCP
    - Le DropTail pénalise le trafic sporadique
    - Difficile d'identifier la nature de la congestion (temporaire ou non)
- Principe
  - Gérer les buffers des routeurs
  - Actions
    - Jeter des paquets (RED, ...)
    - Notification (ECN)

75


## Files d'attente : RED (Random Early Detection)

- Idée
  - Agir avant la congestion et réduire le débit de la source
  - Seuil pour commencer à jeter des paquets
- Objectifs
  - Éviter la synchronisation des sources TCP
  - Augmenter la charge sur les liens
  - Ne pas pénaliser les flots sporadiques
  - Éviter de jeter des rafales


76

## RED (Random Early Detection)

- Algorithme :
  - 2 seuils (Min\_Th, Max\_Th) pour la file d'attente
  - Taille moyenne de la file (avg)
  - Effacer (aléatoirement) des paquets de la file



Pour chaque paquet reçu  
 Calculer la taille moyenne de la file avg  
 si  $minh \leq avg \leq maxth$   
 Calculer la proba  $p(avg)$   
 Avec la proba (avg)  
 marquer/jeter le paquet  
 Sinon si  $axth < avg$   
 Jeter le paquet




77

## RED

- Evaluation
  - Adapté à TCP
  - Jeter un paquet => éviter la congestion
  - La probabilité de choisir un flot est proportionnelle au débit du flot
  - Difficile à paramétrer
    - Dépend du trafic : dynamique
- Amélioration : marquage
  - Réduit le nombre de paquets jetés
  - Réduit le temps pour détecter la congestion
  - Limites :
    - Les paquets marqués peuvent être jetés
    - Certaines sources peuvent ne pas prendre le marquage en compte
- RED amélioré
  - Identifier les flots "gourmands"
    - Supprimer l'inéquité UDP
  - Réguler les flots
    - Équité et protection avec des buffers
    - maintenir 1 état par flot

78

### Exemple de réseau pour RED




- Exemple de réseau avec 3 sources TCP
  - Différents temps de propagation des liens
  - Files limitées sur le lien (20 paquets)

© Andrzej Duda

79

### Débit sans / avec RED



© Andrzej Duda

80


### Ordonnancement (Scheduling)

- Nous étudierons :
  - FIFO
  - Round robin
  - Fair queuing
  - Weighted Fair queuing
  - Virtual Colock
  - Generalized Processor Sharing
  - ...

81

### Ordonnancement


- Dans l'Internet
  - Ordonnancement : FIFO
  - Discipline de file d'attente : Drop Tail



82

### Ordonnancement

- **Scheduling** : choisir les prochains paquets à envoyer sur le lien
- **Ordonnanceur**
  - Permet de servir une classe de service avec un débit spécifique ou une priorité spécifique
- **Ordonnancement FIFO (first in first out)** : envoyer par ordre d'arrivée dans la file
- Exemples :
  - Round Robin, Weighted Round Robin (ex : 10% or, 30% argent, 55% Bronze, 5% Controle), Deficit Round Robin
  - Priorité stricte (décrite ci-dessous)
  - Generalized processor sharing, Virtual Clock, Virtual Spacing
  - Weighted Fair Queueing




83

### Ordonnancement : Work Conserving ou non ?

- **Work-conserving**
  - Jamais oisif quand des paquets attendent
  - Loi de conservation
    - Délais constants, l'ordonnancement alloue les délais

$$\sum_{i=1}^N \rho_i d_i = Cst \quad \text{With } \sum \rho_i \leq 1$$

- **Non work-conserving**
  - Peut être oisif même si des paquets attendent
  - Retarde le service quand le paquet est éligible



84

### Ordonnement : FIFO


- Ordonnement par défaut de l'Internet
- Partage de bande passante
  - proportionnel à la charge offerte
- Pas d'isolation
  - Flot adaptatif / non adaptatif
  - Flot temps réel / non temps réel

85

### Ordonnement : ordonnancement par priorité

Transmettre les paquets de la file avec la plus haute priorité

- plusieurs classes, avec différentes priorités
  - La classe peut dépendre du marquage ou d'autres infos contenues dans l'en-tête, par ex. Adresse IP source/dest, numéros de port, etc..



86


### Ordonnement : ordonnancement par priorité

- Avantages
  - Simple
- Inconvénients
  - Les files de faible priorité risquent de ne pas avoir de service
  - Protection unidirectionnelle
    - Trafic urgent non influencé par le BE
  - Pas de garantie de BP ou de délai

87

### Ordonnement : ordonnancement round robin

- Parcourt les files des différentes classes de manière cyclique, en servant 1 paquet de chaque classe (s'il y en a)
- WRR : Weighted Round Robin
- Evaluation
  - Faible complexité, isolation des flots, équité entre les paquets (paquets de taille variée => flots avec des gros paquets ont une plus grosse part), difficile d'allouer de la BP précisément (garantie de délai et de BP ?)



88

### Ordonnement : Fair Queuing

- Émule le round robin par bit pour chaque flot
- Principe
  - Estampille temporelle sur chaque paquet avec le temps de transmission du dernier bit
  - Sert les paquets avec la fin de service la plus proche
- Soit  $R(t)$  le nombre de cycles de service
- Soit l'estampille temporelle de fin de service  $F_i^k$  pour le paquet  $k$  du flot  $i$ 

$$F_i^k = S_i^k + L_i^k$$

$$S_i^k = \max(F_i^{k-1}, A_i^k)$$

Début du service

$$A_i^k = R(d_i^k)$$


Scheduling state

  - Un flow est actif (backlogged) tant que
 
$$F_i^k > R(t)$$
  - La durée d'un cycle est proportionnelle au nombre de flots actifs

89

### Ordonnement : Weighted Fair Queuing

- Round Robin généralisé
- Chaque classe obtient une quantité de service pondérée à chaque cycle



90


### Ordonnement : Virtual Clock

- Émulation TDM
  - Timestamp de fin de service dans TDM
  - Le Timestamp dépend du débit alloué
- Pour chaque flot  $i$ , un débit moyen :  $R_i$

$$VC_i^k = S_i^k + \frac{L_i^k}{R_i} \quad \text{with} \quad S_i^k = \max(VC_i^{k-1}, A_i^k)$$

$$A_i^k = a_i^k$$


- Ordre de service
  - Ordre des timestamps



91

### Ordonnement : Virtual Clock

- Évaluation
  - Garantie de délai : flot régulé
  - Pénalise l'utilisation de rafales
    - Si un flot a envoyé une rafale, il se peut qu'il doive rester oisif pendant une longue période
  - Inéquitable
    - Utilise le temps réel




© Roch Guérin

92

### Ordonnement : GPS (Generalized Processor Sharing)

- Équité Max-Min
- Principe
  - Modèle de service
    - Unité de service infinitésimale (tous les flots servis en même temps)
    - Cas idéal, infaisable



- Service reçu proportionnel au poids du flot

$$\frac{S_i(\tau, t)}{S_j(\tau, t)} = \frac{\phi_i}{\phi_j} \quad \phi \text{ nombre réel positif}$$

Intervalle de temps

93

### Ordonnement : GPS (Generalized Processor Sharing)

- $g_i$ : taux de service pour le flot  $i$  de poids  $\phi_i$ 

$$g_i = \frac{\phi_i C}{\sum_{j=1}^N \phi_j} \quad \text{Si} \quad \sum_{j=1}^N \phi_j \leq 1 \quad \text{Garantie de BP absolue}$$

- Service équitable pour :

$$\phi_i = \frac{1}{N}$$

- Délai maximum
  - Si tous les flots  $i$  sont régulés  $(\sigma_i, \rho_i)$

$$D_i = \frac{\sigma_i}{g_i} \leq \frac{\sigma_i}{\rho_i} \Rightarrow g_i \geq \rho_i$$

- Évaluation
  - Garantie de BP
  - Fair share de la bande passante excédentaire
  - Work conserving
  - Un système réel utilise des paquets
    - Les services de paquets doivent approximer le modèle fluide
    - Le service d'un paquet induit une inéquité

94

### Ordonnement : PGPS-WFQ

- Principe
  - Détermine le temps de fin de service d'un paquet s'il avait été servi avec GPS
  - Émulation de GPS
  - Similaire au fair queuing mais notion de temps virtuel
  - Temps virtuel : temps de service en GPS
    - Plus rapide ou plus lent en fonction du nombre de flots actifs
    - Temps virtuel = temps réel quand tous les flots sont actifs
    - En temps virtuel, le service reçu par chaque flot reste constant
  - $A_i^k = V(a_i^k)$


- Timestamp de fin de service

$$F_i^k = S_i^k + \frac{L_i^k}{\phi_i} \quad \text{with} \quad S_i^k = \max(F_i^{k-1}, A_i^k)$$

95

### Ordonnement : PGPS-WFQ

- Caractéristiques
  - Délai du paquet  $p$  en PGPS comparé à GPS
 
$$F_{PGPS}^p - F_{GPS}^p \leq \frac{L_{\max}}{C}$$
  - Le délai additionnel du au service de paquet est au plus  $L_{\max}$ 
    - Graphique de service



- Pour un flot régulé  $(\sigma_i, \rho_i)$ 
  - Délai de bout en bout
    - Pour  $m$  nœuds

$$D_i = \frac{\sigma_i}{g_i} + \frac{(m-1)L_{\max}}{g_i} + \sum_{j=1}^m \frac{P_{\max}}{C_j}$$

96

## Ordonnement : PGPS-WFQ

- Évaluation
  - Difficile de maintenir le temps virtuel de GPS en mode paquet
    - Mis à jour constamment
  - Calcul complexe de  $V(t)$  quand un nouveau paquet arrive
    - Effet de cascade




- 1 état par flot
- Nombreux algorithmes pour simplifier le calcul de  $V(t)$

97

## Ordonnement : Service à débit contrôlé

- Idée
  - Séparer la bande passante et le délai garanti
- Architecture



- Régulateur
  - Retient les paquets jusqu'à ce qu'ils soient éligibles
- Ordonnanceur
  - Choisit l'ordre des paquets éligibles
    - Indépendamment du débit

98


## Ordonnement : propriétés des contrôleurs de débit

- garanties
  - Débit
  - Délai
  - Contrôle de la gigue
  - sporadicité
- Mais
  - Pas d'utilisation de la bande passante en excès
  - Non-Work conserving

99

## Provisionnement de la QoS

- Le provisionnement de la QoS requiert la définition de :
  - Service Level Agreement (SLA), qui contient en particulier :
    - Les cibles de QoS (délai borné ? Faibles pertes ? Etc.)
    - Le trafic concerné (tout le trafic du client, seulement la VoIP etc...)
  - Traffic Conditioning Agreement (TCA)
    - Conditions d'application du SLA (ou clauses du contrat), qui peuvent imposer en particulier des restrictions sur le volume de trafic qui peut être accepté
- Le contrat de trafic (SLA/TCA) peut alors être implémenté en utilisant :
  - Le contrôle d'admission (basé sur le TCA)
  - La réservation de ressources (basée sur le SLA)
    - Gestion de file d'attente
    - Réservation de bande passante
    - ...



100

## Plan

- Introduction**
  - Qu'est-ce que la QoS?
  - Le besoin de QoS
- QoS : boîte à outils**
  - Classification, conditionnement de trafic, files d'attente ...
  - Différentes approches pour la QoS
    - QoS garantie vs différenciée
- Architectures de QoS**
  - Integrated Services (IntServ) et RSVP
  - Differentiated Services (DiffServ)

101

## QoS différenciée / garantie (1)

- La QoS garantie requiert la réservation de ressources** et les fonctionnalités de contrôle associées.
- Un autre type de QoS existe : **la QoS différenciée**.
  - Les flots sont **agregés** en classes de trafic.
  - Pas de valeurs explicites données aux paramètres de QoS de bout en bout, seulement les **"priorités relatives"** entre les classe de trafic sont gérées dans les noeuds du réseau
  - Un paquet d'une classe de trafic avec une priorité temporelle supérieure devrait être traité "avant" le trafic avec une priorité temporelle inférieure (**ordonnement**)
  - Le choix de rejet devrait dépendre de la priorité de perte de la classe

102


## QoS différenciée / garantie(2)

- La QoS différenciée est **plus simple** à implémenter.
- Pour être supportée, elle a besoin :
  - D'une manière de reconnaître le niveau de priorité de chaque paquet de données et
  - D'algorithmes d'ordonnement et de files d'attente orientés priorité
- Malgré tout, c'est moins efficace que la QoS garantie en cas de congestion des ressources de plus haute priorité
- Le volume de trafic de plus haute priorité doit être contrôlé afin de s'assurer que l'approche Diffserv reste efficace

103

## Services

Différentiation de la QoS des flots



104

## Architecture IntServ

## Services intégrés de l'IETF


- Architecture pour fournir des garanties de QoS dans des réseaux IP pour des sessions applicatives individuelles (flots)
  - Avec une emphase spécifique sur les applications multimédia (voix, vidéo)
- Réserve de ressources : les routeurs maintiennent des états des ressources allouées, des demandes de QoS
- Admettent / refusent de nouvelles requêtes :

**Question :** est-ce qu'un flot nouvellement arrivé peut être admis avec des garanties de performance sans violer les garanties de QoS des flots déjà admis ?

106

## Architecture Intserv/RSVP

- Qui ?
  - 2 groupes de travail à l'IETF
- IntServ (Integration Services)
  - Modèle pour fournir un ensemble de services
    - À une session applicative
    - Utilise la réservation des ressources et les états dans les routeurs
  - Composants pour fournir ces services
  - Démarré en 1994, inspiré des travaux sur les circuits virtuels
- RSVP (Resource Reservation Protocol)
  - Protocole de signalisation (RFC 2205)
  - Informe le réseau des besoins applicatifs
  - Requiert des réservations IP
  - Vu comme LE protocole de réservation d'Intserv



107

## IntServ : caractéristiques principales

- Granularité fine (isolation des flots) : 1 SLA/TCA par flot
  - Flot = source @, dest @, numéros de port
  - Description de flot
    - Spécification de trafic, QoS demandée, règles pour identifier le flot
- Contrôle d'admission
  - Vérifier que la QoS requise peut être produite sans déranger les flots existants
- Classification (classifieur de paquets)
  - En fonction de la QoS requise
- Ordonnement
  - Pour respecter la QoS demandée
- Protocole de signalisation (RSVP)
  - Alloue les ressources nécessaires pour le service.
- Paramètres de QoS de granularité fine disponibles
- Réservations dynamiques : plan de contrôle avec un protocole de signalisation spécifique (RSVP)
- QoS de bout-en-bout (grâce au plan de contrôle)

108

## Mécanismes du routeur

- Contrôle d'admission
  - Décide si un flot peut être accepté
    - Une session peut décrire son flot
      - Classe et niveau de service
      - Descripteur de flot
    - Chaque routeur vérifie que l'admission peut être assurée
      - En fonction de la demande
      - En fonction des ressources disponibles
    - COMMENTAIRE : différent du contrôle d'accès (*policing*)
- Pour les paquets
  - Classification
    - Associe un paquet à la réservation appropriée
  - Discipline de service
    - Ordonnancement
    - Équivalent au contrôle d'accès


109

## Description de flot

- FlowSpec : décrit les caractéristiques du flot
  - Trafic envoyé
  - Service désiré
    - Délai
    - débit
- FilterSpec : identifie la (les) sources (s)
  - IPv4 : adresse Source et numéro de port
  - IPv6 : adresse Source address et identifiant de flot
- Session : identifie la (les) destination(s)
  - Adresse Destination, protocol ID, numéro de port

110

## FlowSpec

- Tspec :  $TSpec = (r, b, p, m, M)$ 
    - r: (débit moyen) mean rate
    - b: sporadicité (burstiness)
    - p: débit max (peak rate)
    - M: taille max de paquet (MTU)
    - m: taille min de paquet
      - Les paquets plus petits que m sont considérés de taille m => pénalise les petits paquets
  - Définit l'enveloppe du trafic envoyé
  - Implémenté sous forme de token bucket:
- 
- Rspec: service requis
    - controlled-load : pas de valeur
    - Garanti : délai maximum

111

## RSVP

- Protocole de signalisation pour la réservation de ressources sur un chemin donné
- Un flot utilise RSVP pour demander une qualité de service (QoS) spécifique de la part du réseau,
  - RSVP transporte la requête à travers le réseau,
    - À chaque noeud, RSVP essaie de faire une réservation de ressources pour le flot
- Protocole Soft State
  - Les terminaux rafraichissent périodiquement le soft state de la réservation
  - En l'absence d'un rafraichissement, l'état RSVP dans les routeurs expirera et sera effacé
- Protocole de signalisation orienté récepteur (paradigme multicast)
  - Flots de données unidirectionnels. Deux réservations indépendantes pour un flot bidirectionnel
- Conçu pour les flots multicast (1 vers plusieurs)
  - RSVP peut être utilisé à la fois pour des flots unicast et multicast
  - RSVP est un protocole de réservation orienté récepteur.
    - Les messages de réservation sont envoyés par les récepteurs et fusionnent alors qu'ils progressent dans l'arbre multicast
- Différents styles de réservation
- Adaptation aux changements de route
- De bout en bout
- Indépendant du service
- **Aucun mécanisme de routage n'est implémenté dans RSVP.**
- Pas de contrôle d'admission, pas d'autorisation, pas de discipline de service (réservation = algorithme local)
- RSVP fonctionne au-dessus d'IP (IPv4 et IPv6). Il peut aussi fonctionner sur UDP


112

## Messages RSVP

- 2 principaux types de messages:
  - PATH (de la source vers les récepteurs)
    - Transporte les caractéristiques du trafic de la source et l'identification du flot
    - Fixe le chemin inverse pour les messages RESV
    - Collecte les informations sur l'état du réseau (BP disponible, délai de propagation)
  - RESV (des récepteurs vers la source)
    - Envoyé sur demande du récepteur

113

## RSVP et IntServ



114

### Le message Path

- Le message *Path* est le message envoyé par une source d'un arbre de distribution multicast aux récepteurs de l'arbre
- Les principales fonctionnalités du message *Path* sont :
  - Transporte la **description du trafic que la source va envoyer**
  - Transporte la **description de la capacité des nœuds le long du chemin**. Chaque nœud supportant RSVP insère ou modifie l'information contenue dans ce champ en fonction de ses possibilités
  - Détermine le **chemin retour** des messages *Resv* messages que les récepteurs enverront à réception du message *Path*. Ce chemin inverse est aussi maintenu dans le soft state des routeurs du chemin
- Transporte aussi l'ADSPEC
  - Mis à jour à chaque routeur et utilisé pour calculer le délai de bout-en-bout
  - Contient le nombre de saut, la BP sur le chemin, un délai fixe, la MTU,  $C_{tot}$ ,  $D_{tot}$

115

### Le message Resv



- Envoyé par les récepteurs d'un arbre de distribution multicast pour effectuer une réservation de ressources dans le réseau
- Suit le chemin inverse** tracé par le message *Path*
- Fusionne aux embranchements** de l'arbre multicast
- Plusieurs **styles de réservation** existent quand il y a plusieurs sources dans l'arbre multicast
  - Wildcard Filter (WF) : plusieurs émetteurs wildcard partagent la même réservation (un seul parle à la fois)
  - Fixed Filter (FF) : réservations distinctes par émetteur (vidéo)
  - Shared Explicit (SE) : liste explicite des émetteurs qui partagent la même réservation
- Les paramètres de réservation **dépendent du service intégré demandé**
- Transporte le **RSPEC**
  - Peut être différent du TSpec

116

### Styles de réservation


- Déterminent les règles de fusion des messages RESV
- Dédiée
  - Une réservation par émetteur (*Fixed Filter*)
  - Fusionne les réservations pour une session
    - Par émetteur
- Partagée
  - Une réservation pour un ensemble d'émetteurs
    - tous (*Wildcard Filter*)
    - Identification explicite (*Shared Explicit*)
  - Réservation conforme à la demande la plus haute de la session

Sender Selector	Reservations	
	Distinct	Shared
Explicit	Fixed Filter (FF) Style	Shared Explicit (SE) Style
Wildcard	(No Style Defined)	Wildcard-Filter (WF) Style




117

### RSVP et changements de routes




118

### Nuages non-RSVP



119


### IntServ : Vue globale



120

## IntServ : Complexité

- Questions d'implémentation
  - Isolation des flots avec une granularité fine




- Plan de contrôle / management
  - Les routeurs traditionnels manipulent seulement des agrégats de route (mas des micro-flots)
  - Dans IntServ, un protocole de signalisation est requis
  - Architecture de police aussi nécessaire pour le contrôle d'accès
    - Contrôle d'accès local (basé sur les ressources disponibles)
    - Décisions de police centralisées

121

## Le concept de session de service


- Une session est explicitement définie par une **adresse destination** (unicast ou multicast), un **protocole de transport** et un **numéro de port destination**
  - <session> = <DstAddr, PID, DstPort>
  - Problèmes avec les tunnels IP



- Le **session id** permet de corréler les flots de contrôle RSVP d'une session donnée (flots *Path* and *Resv*) et identifie un contexte particulier (incluant les réservations soft et la route inverse) pour cette session à chaque noeud du chemin

122

## Messages RSVP format commun



😊 Facile de définir de nouveaux messages

123

## Messages RSVP Champs de l'en-tête

- **Vers** : actuellement, RSVP version 1
- **Flags** : par défini pour l'instant
- **Msg Type** :
  - 1=Path
  - 2=Resv
  - 3=PathErr
  - 4=ResvErr
  - 5=PathTear
  - 6=ResvTear
  - 7=ResvConf
- **RSVP Checksum** : checksum calculé sur la totalité du message RSVP
- **Send\_TTL** : utilisé pour détecter les noeuds non-RSVP
- **RSVP Length** : longueur totale (en octets) du message RSVP
- Pour les objets
  - **Length** détermine la longueur de l'objet
  - **Class-Num** identifie l'objet
  - **C-Type** identifie les sous-classes de l'objet (ex : applicable à IPv4 ou IPv6)
- Le nombre d'objets et leur type dépend du message RSVP

124

## QoS Intserv : Modèles de service [rfc2211, rfc 2212]


2 classes de service sont disponibles :

### Best Effort

Service IP traditionnel. Utilisé par défaut (ce service ne requiert pas l'utilisation de RSVP)

### Service Controlled load

"une qualité de service se rapprochant de la QoS que le même flot recevrait de l'élément d'un réseau non chargé"



### Guaranteed service:

- Arrivée de trafic dans le pire des cas : source policée par un leaky-bucket
- **Limite** simple (prouvable mathématiquement) sur le délai
- Classe prévue pour fournir un service à perte faible / nulle et un délai limité aux applications sensibles telles que les applications temps réel

125

## Evaluation

- L'architecture Int-serv/RSVP introduit des aspects de QoS dans le domaine IP sans nécessiter de nouvelle technologie (ex : ATM) => c'est un important **facteur de continuité**
- Int-serv/RSVP est basé sur les flots => ceci lui confère une **bonne granularité** mais **n'est pas très scalable**
  - Int-serv/RSVP sera difficile à utiliser chez un gros ISP ou un backbone (il faut de l'agrégation)
  - Cela peut être utilisé dans l'Intranet d'une grosse entreprise où l'on peut avoir de la congestion
- Aujourd'hui, RSVP devient un protocole de signalisation générique pour établir n'importe quel flot pour
  - MPLS, SDH, layer 4

126

## Architecture DiffServ

### Services différenciés de l'IETF

#### Problèmes avec Intserv:

- **Passage à l'échelle** : signalisation, maintien d'états par flot au niveau des routeurs difficile avec un nombre élevé de flots
- **Modèles de Service fluides** : Intserv possède seulement 2 classes. On veut aussi des classes de service « qualitatives »
  - Distinction de services relatifs : platine, or, argent...
- **MAIS**
  - Besoin de rester **pragmatique** étant donné la capacité des routeurs actuels et les problèmes d'échelle de l'Internet

128

### Vue globale de l'approche DiffServ

- Fonctions simples dans le cœur du réseau, fonctions relativement complexes au niveau des routeurs de bordure (ou les hôtes)
- Ne définissent pas de classes de service, fournissent des composants fonctionnels pour construire des classes de service
- **Propriétés principales**
  - **Faible granularité** : pas de manipulation de micro-flots. QoS offerte à des **agrégats de trafic**.
    - Simple classification des flots
    - Nombre d'états limité pour la gestion de la QoS (par rapport à IntServ)
  - **Complexité en bordure du réseau**.
    - **Marquage de trafic** au niveau du nœud entrant.
    - L'implémentation DiffServ ne devrait nécessiter que des mises à jour simples au niveau des routeurs de cœur de réseau
  - **Pas de plan de contrôle**. Pas de protocole de signalisation. La QoS est offerte au moyen d'un dimensionnement de réseau adéquat

129

### Vue globale de l'approche DiffServ

- **Mode hiérarchique pour la gestion des ressources**
  - Intra-domaine
    - Responsabilité des ISP : configuration et dimensionnement des classes
  - Inter-domaine
    - **Contrat de service**
      - Entre 2 domaines DS
      - Entre un client et un domaine DS
    - **Contrat** :
      - Caractérisation du trafic pour le client
      - Garantie de QoS pour le fournisseur
- **Service du réseau**
  - **Police de conditionnement**
    - Modifier le trafic pour qu'il respecte les règles (contrat)
  - **PHB** : comportement d'un routeur
    - Par paquet
    - Service d'un élément de réseau
- **DiffServ ne décrit pas**
  - Les mécanismes pour les PHBs
  - Le nombre de classes
  - Les caractéristiques des classes

130

### La bordure du réseau

- **Bordure**
  - Hôtes supportant DiffServ
  - Premier routeur du domaine DS
- **Classification**
  - Marquage à l'entrée en fonction du SLA
- **Conditionnement**
  - Actions sur le trafic entrant
  - **Contrôle d'accès**
    - Limite la quantité de trafic à l'intérieur d'une classe
    - Évite la congestion

131

### Le cœur du réseau

- **Forwarding**
  - Comportement appliqué à un paquet en fonction du marquage (qui identifie la classe de service)
- **Dimensionnement**
  - Pour fournir de la QoS, la classe doit être provisionnée

132

## Classification

- En bordure
  - Identifier les paquets en fonction du SLA
  - Classification multi-champs
    - Marquage dans le paquet IP




- Au cœur
  - Classification basée sur le marquage
  - Marquage = index d'un comportement

- Identification de classe
  - Champ "octet DS"
    - Au lieu du ToS(IPv4) ou classe (IPv6)
  - Valeur du DS codepoint
    - Identifie le comportement dans un routeur

133

## Conditionnement

- Action décrite dans le contrat
- Actions
  - marqueur
    - Modifie le *codepoint* => le PHB
    - Pour allouer un niveau de priorité différent
  - mètreur
    - Vérifie que le flot est conforme à un profil
  - dropper
    - Détruit un datagramme, modifie les caractéristiques sémantiques d'un flot
  - shaper
    - Modifie les caractéristiques temporelles des flots



134


## Architecture DiffServ (1)

### Routeur de bordure :

- Management du trafic *par flot*
- marque les paquets (champ DS) comme *in-profile* et *out-profile*
- PHB : Per Hop Behavior associé au champ DS du paquet

### Routeur de coeur :


- Management de trafic *par classe*
- buffering et scheduling basés sur le *marquage* en bordure
- Préférence données aux paquets *in-profile*



135

## Marquage de paquet par le routeur de bordure

- Profil : débit pré-négocié A, taille de bucket B
- Marquage de paquet en bordure basé sur un profil *par-flot*




### Utilité possible du marquage :

- Marquage basé sur la classe : paquets de classes différentes marqués différemment
- Marquage intra-classe : partie conforme du flot marquée différemment de la partie non-conforme

136

## Classification et Conditionnement


- Le paquet est marqué dans le champ Type of Service (TOS) en IPv4, et Traffic Class en IPv6
- 6 bits utilisés pour le Differentiated Service Code Point (DSCP) qui déterminent le PHB que le paquet recevra
- 2 bits sont pour l'instant inutilisés



137

## Champ DiffServ en IPv4 / IPv6

- Champ DS



138

## Forwarding (PHB)

- Le PHB résulte en des performances de forwarding différentes observables (mesurables)
- Le PHB ne spécifie pas quels mécanismes utiliser pour assurer le comportement PHB requis
- Exemples:
  - LA classe A obtient x% du lien sortant pendant des intervalles de temps d'une longueur spécifique
  - Les paquets de la classe A partent avant les paquets de classe B

139


## Forwarding (PHB)

- Pas d'état dans les routeurs !!!**
- Services traditionnels
  - « Best-Effort » (BE) PHB.
- Expedited Forwarding:** Le débit de départ d'un paquet d'une classe est égal ou dépasse un débit spécifique
  - « Service Premium » (pour les flots interactifs)
  - PHB avec peu de pertes, délai garanti.
  - Lien logique avec un débit minimum garanti
  - Pas de trafic hors profil
- Assured Forwarding:** 4 classes de trafic avec pour chacune une bande passante minimale garantie
  - Chacune avec 3 partitions de drop preference
  - 4 priorités temporelles (ne pouvant pas être modifiées par le réseau), et 3 priorités spatiales (pouvant être modifiées par le réseau)
  - Assurance ≠ garantie
  - Du trafic opportuniste (hors profil) peut être admis

140


## Architecture de routeur DiffServ (1)

différentiation de service à l'intérieur des interfaces  
La complexité des interfaces dépend du vendeur (pas de standard)



141

## Architecture de routeur DiffServ (2)



142


## Boîte à outils DiffServ

### EF PHB : Définition

- Expedited Forwarding
  - DSCP: 101110
  - Classe unique sans drop precedence disponible
- Définition :
  - Un équipement EF compliant est caractérisé par  $(R, E_p)$  si, pour tous les paquets :

$$d_j \leq f_j + E_p$$


$$f_j = \max \{ a_j, \min \{ d_{j-1}, f_{j-1} \} \} + l_j / R$$



144

### EF PHB : limites de QoS

- Avec la définition précédente, le délai est limité par D avec  $D = B/R + E_p$ 
  - R : débit de service EF sur l'interface de sortie,
  - $E_p$  : terme d'erreur par rapport au traitement idéal,
  - B : profondeur du Token Bucket (de débit R) qui correspond à l'arrivée des paquets (pour l'agrégat EF)




- Limites sur la gigue :  $J = B/R + E_p$  variable avec :  $E_p = E_{p, \text{fixed}} + E_{p, \text{variable}}$ .

145

### EF PHB : Implémentation

- Implémentation
  - Conditionnement de trafic :
    - Peak Rate Metering : un token bucket est l'outil de conditionnement de trafic le plus approprié par définition de EF.
    - Comme aucune drop precedence n'est disponible, le trafic hors profil doit être soit jeté soit « déclassé » (best-effort ou bulk traffic)
  - PHB
    - Pas de management de file d'attente spécifique requis
    - L'EF est par essence basé sur l'ordonnancement



146

### AF PHB : Définition


- Assured Forwarding PHB Group
  - 4 classes de services, avec  $\text{Class 1} \geq \text{Class 2} \geq \text{Class 3} \geq \text{Class 4}$
  - 3 Drop precedence disponibles

	Class 1	Class 2	Class 3	Class 4
Low (Yellow)	001010	010010	011010	100010
Medium (Orange)	001100	010100	011100	100100
High (Red)	001110	010110	011110	100110

147

### AF PHB : Implémentation


- Conditionnement de trafic
  - Possibilité de contrôler la quantité de trafic qui entre dans le réseau dans une classe spécifique avec une drop precedence spécifique.
  - Exemples :
    - srTCM (Single Rate Two Color Marker)
    - trTCM (Two Rate Three Color Marker)
    - tswTCM (Time Sliding Window Three Color Marker), ...



148

### AF PHB : Implémentation

- Gestion de file d'attente :
  - « Active Queue Management » obligatoire.
    - Ex: RIO (RED In Profile/Out Profile)



149

### Evaluation (1)

- L'architecture Diff-serv est relativement **immédiate** avec un certain nombre de composants (PHBs) permettant de construire une large variété de services différenciés
- Une certaine **complexité** demeure concernatn
  - L'implémentation des **traffic conditioners** au niveau des nœuds de bordure
  - Le choix et la configuration des algorithmes d'**ordonnancement** à l'intérieur des nœuds
- L'approche DiffServ pour la provision de QoS pour le trafic IP est une méthode concurrente à d'autres approches telles que
  - Int-serv/RSVP
  - MPLS
  - Marquage par priorité relative (champ IP Precedence)

150

## Evaluation (2)

- Diff-serv est
  - **Plus scalable** que Int-serv/RSVP mais moins granulaire
  - **Plus simple** à implémenter que MPLS étant donné que Diff-serv est encore basé sur le routage tandis que MPLS est basé sur les étiquettes (càd que DiffServ a moins de contraintes sur le hardware des nœuds du réseau)
  - une **extension** aux traditionnelles approches de priorité / marquage de service déjà utilisées dans certaines parties de l'Internet
- Diff-serv peut aussi être **complémentaire** à d'autres architectures :
  - Diff-serv peut être utilisé pour agréger des flots Int-serv/RSVP flows au cœur du réseau
  - Diff-serv peut utiliser MPLS comme une technologie intra-domaine alternative où un BA peut être mappé à un chemin commuté par étiquette spécifique à travers le réseau

151

## Résumé : améliorer la QoS dans les réseaux IP

**Jusqu'ici** : "faire le mieux du best effort"

**Futur** : Internet de nouvelle génération avec des garanties de QoS

- **RSVP** : signalisation pour les réservations de ressources
- **Differentiated Services** : garanties différentielles
- **Integrated Services** : garanties fermes

152

## Routage inter-domaine

## Plan

### ■ Introduction

- Routage intra-domaine
- Routage inter-domaine
  - BGP

## « Philosophie » Internet


- Intelligence aux extrémités du réseau
- Forwarding des paquets le plus rapide possible
- Pas d'état par paquet / par flot dans le réseau
- Pas de contrôle d'accès

Tenter de concevoir et de faire évoluer le réseau en suivant ces principes

## Qu'est-ce que l'Internet ?

- Suite de protocoles IP, ainsi que les mécanismes et applications liés (standardisés par l'IETF)
- Réseau d'interconnexion international constitué d'ISPs, de réseaux d'entreprise et de campus, etc.

## Le sablier Internet (Deering@IETF)



## Internet – Interconnexion de réseaux


- Protocole Internet
  - Transmet un paquet unique d'un hôte vers un autre
  - Le paquet inclut l'adresse IP de l'émetteur et du récepteur
  - Les paquets peuvent être perdus, retardés ou déséquilibrés
  - Les hôtes gèrent la retransmission et le reséquenement des paquets
- Adresse IP
  - Adresses IP sur 32 bits divisées en octets (12.34.158.5)
  - Allouées aux institutions sous la forme de blocs continus ou préfixes
  - 12.34.158.0/24 est un préfixe sur 24 bits avec 2<sup>8</sup> adresses IP
  - Le routage des paquets IP est basé sur les préfixes

## Caracteristiques de l'Internet

- L'Internet est
  - Décentralisé (confédération souple de pairs)
  - Auto-configuré (pas de registre de topologie global)
  - Sans état (informations limitées dans les routeurs)
  - Sans connexion (pas de connexions fixées entre les hôtes)
- Ces attributs contribuent
  - Au succès de l'Internet
  - À sa croissance rapide
  - ... et à la difficulté à le contrôler !

## Il était une fois...


- Voilà ce qu'était Internet !




## Architecture de l'Internet

- Divisé en Systèmes Autonomes (AS)
  - Régions correspondant à des contrôles administratifs distincts (~6000-7000)
  - Ensemble de routeurs et de liens gérés par une seule institution
  - Fournisseur de service, entreprise, université, ...
- Hiérarchie de Systèmes Autonomes
  - Fournisseur de tier-A, de grande taille, backbone à l'échelle nationale
  - Fournisseur de taille moyenne avec un backbone plus petit
  - Petit réseau géré par une unique université ou entreprise
- Interaction entre Systèmes Autonomes
  - Topologie interne non partagée entre AS
  - ... mais les AS voisins interagissent pour coordonner le routage

## L'Internet



## Connectivité des ISPs



## Routage à travers l'Internet

- Intra-domaine
  - Un AS détermine le chemin d'un paquet à l'intérieur de son domaine
  - Utilisation d'un protocole (à état des liens)
  - Performances : question essentielle
- Inter-domaine
  - Les AS échangent des informations d'atteignabilité
  - Basé sur des politiques
  - Pas nécessairement le plus court chemin

## Routage à travers l'Internet

- Protocoles
  - Interior Gateway Protocols (IS-IS, OSPF, RIP, IGRP)
  - Exterior Gateway Protocols (BGP)
- Fonctionnement
  - IGP : trouve le "meilleur" chemin à travers un AS
  - BGP : Définit des règles de relations entre AS


## Routage inter-domaine (entre différents AS)

- Les AS s'échangent des informations d'atteignabilité
- Politiques locales pour la sélection de chemin (lequel utiliser ?)
- Politiques locales pour la propagation de route (Qui informer ?)
- Politiques configurées par l'opérateur du réseau de l'AS




## Routage intra-domaine (à l'intérieur d'un AS)

- Les routeurs échangent des informations pour apprendre la topologie
- Les routeurs déterminent le "prochain saut" pour atteindre les autres routeurs
- Sélection de chemin en fonction du poids des liens (plus court chemin)
- Poids des liens configurés par l'opérateur du réseau d'AS
- ... pour gérer le flux de trafic



## Systèmes Autonomes (AS)


Chemin : 6, 5, 4, 3, 2, 1



## Tiers

- Les ISPs de Tier 1 sont ceux qui ne louent pas de fibre et n'achètent pas de transit auprès d'autres ISPs
  - FT, DT, BT ne sont pas des Tiers 1
  - Le "Peering" ne s'applique qu'à des ISPs de même niveau
- Classification de la topologie Internet à partir des traversées d'AS : les tiers 1 sont en haut de l'arbre
  - Les Tier 1s ont un chemin plus court vers le reste de l'Internet

## Atteignabilité Internet de Sprint




## Backbones de Tier-1 actuels

- Technologies
  - IP over SONET (POS)
  - IP over ATM
  - IP over MPLS
- Topologies
  - Nombreux petits PoPs
  - Relativement peu de gros PoPs


## Topologies

- UUNet : MPLS/IP/ATM avec des petits PoPs
- AT&T : IP over Sonet avec beaucoup de petits PoP. Bientôt MPLS.
- Sprint : IP over Sonet avec des PoPs plus gros et moins nombreux


## UUNet en Amérique du Nord



## Backbone IP d'AT&T



## Backbone IP de Sprint




## Clients, Fournisseurs, Pairs

- Public peers : NAP publics, pas de transit, disparaissent petit à petit (aux US).
- Peers : "pairs" (AT&T, UUNET, etc.) : pas de transit, peering gratuit s'ils sont assez gros, prix en fonction du volume sinon.
- Clients (tier 2, CDN, etc.) : transit, prix en fonction du lien.


## AS de Transit / Non transit

- **AS de transit** : transporte du trafic de transit
- Annonce ses propres routes ET les routes apprises par d'autres AS



## AS de Transit / Non transit

- **AS Non-transit** : ne transporte pas de trafic de transit
- annonce ses propres routes et les routes provenant du transit (clients)
- ne propage pas les routes apprises des fournisseurs et des non transit (pairs)



## Routing inter-domaine

## Historique

- Popularité
  - Au départ, BGP était assez peu connu, et utilisé par un petit nombre de gros IPSs
  - En 1995 (début de la popularité du Web), le nombre d'organisations utilisant BGP a énormément augmenté.
- 2 raisons pour la croissance de son usage et de son intérêt :
  - Croissance significative du nombre d'ISPs;
  - Naissance d'organisations dont le succès dépend de la connectivité
- CIDR (Classless Inter-Domain Routing) introduit en 1995


## CIDR : Classless Inter-Domain Routing

- Format d'adresse <adresse IP /préfixe P>. Le préfixe concerne les P premiers bits de l'adresse IP.
- Idée : *utiliser l'agrégation* – fournir du routage pour un grand nombre de clients en annonçant un préfixe commun.
  - Ceci est possible parce que l'adressage est de nature hiérarchique
- Résumer l'information de routage réduit la taille des tables de routage, mais permet de maintenir la connectivité.
- L'agrégation est essentielle pour le passage à l'échelle et la "survie" de l'Internet


## CIDR : matching du plus grand préfixe

- Puisque des préfixes de longueur arbitraires sont autorisés, il peut y avoir des préfixes recouvrants.
- Exemple : un routeur entend 124.39.0.0/16 d'un voisin et 124.39.11.0/24 d'un autre voisin
- Le routeur transmet le paquet en fonction de l'information de forwarding la plus précise, appelée **longest prefix match**
  - Un paquet avec l'adresse de destination 124.39.11.32 sera transmis en utilisant l'entrée /24 de la table.
  - Un paquet avec l'adresse de destination 124.39.22.45 sera transmis en utilisant l'entrée /16.

## Objectif : partage d'information de connectivité




## Protocoles de routage



## Sessions BGP


- Un routeur peut participer à plusieurs sessions BGP.
- Initialement* ... un noeud annonce TOUTES les routes qu'il veut faire connaître à ses voisins (il peut y en avoir >50K)
- Pendant* ... seulement informer les voisins des changements



## 4 messages de base

- Open** : établit une session BGP (utilise le N° de port TCP 179)
- Notification** : Rapporte les conditions non usuelles
- Update** : Informe un voisin de nouvelles routes devenues actives  
Informe un voisin de nouvelles routes devenues inactives
- Keepalive** : Informe un voisin que la connexion est toujours valide

## Processus de routage




## Configuration et politique

- Un noeud BGP n'a pas à accepter toutes les routes apprises de ses voisins. Il peut sélectivement accepter et rejeter des messages.
- Un noeud BGP sait quelles routes partager avec ses voisins. Il peut n'annoncer qu'une portion de sa table de routage à un voisin
- Quoi accepter* de ses voisins et *quoi partager* avec ses voisins est déterminé par la **politique de routage**, spécifiée dans le fichier de configuration des routeurs.

## Filtrage en amont - Input Policy Engine

- Le filtrage en entrée contrôle le trafic en sortie
  - Les filtres routent les mises à jour reçues des autres pairs
  - Filtrage basé sur les préfixes IP, l'AS-PATH, la communauté
  - Refuser un préfixe signifie que BGP ne veut pas atteindre ce préfixe via le pair qui a envoyé l'annonce
  - Accepter un préfixe signifie que le trafic vers ce préfixe peut être transmis au pair qui a envoyé l'annonce
- Manipulation d'attributs
  - Positionnement d'attributs pour les routes acceptées
  - Exemple : spécifier LOCAL\_PREF pour établir des priorités entre plusieurs pairs qui peuvent atteindre une destination donnée

## Processus de routage




## Processus de décision BGP

1. Choisir la route avec le plus haut LOCAL-PREF
2. S'il y a plus d'1 route, sélectionner la route ayant l'AS-PATH le plus court
3. S'il y a plus d'1 route, sélectionner selon le type ORIGIN le plus petit, avec  $IGP < EGP < INCOMPLETE$
4. S'il y a plus d'1 route, sélectionner la route ayant le MED le plus petit
5. Sélectionner le chemin de coût minimum vers le NEXT HOP en utilisant des métriques IGP
6. S'il y a plusieurs chemins internes, utiliser l'ID du routeur BGP pour trancher.

## ATTRIBUTS BGP

### LOCAL PREF

- Utilisé pour indiquer des préférences parmi plusieurs chemins pour un même préfixe n'importe où dans l'Internet.
- Valeurs supérieures préférées
- Échangé uniquement entre pairs IBGP. Local aux AS.
- Souvent utilisé pour sélectionner un point de sortie spécifique pour une destination particulière



## ATTRIBUTS BGP

- AS-PATH :
  - Liste d'AS à travers lesquels l'annonce pour un préfixe est passée
  - Chaque AS ajoute son N° d'AS à l'attribut AS-PATH lors de la transmission d'une annonce
  - Utile pour détecter et prévenir les boucles

Prefix	Next hop	AS Path
128.73.4.21/21	232.14.63.4	1239 701 3985 631


- ORIGIN :
  - Qui est à l'origine de l'annonce ? Où un préfixe a-t-il été injecté dans BGP?
  - IGP, EGP ou Incomplete (souvent utilisé pour les routes statiques)

## ATTRIBUTS BGP

### MED

#### Multi-Exit Discriminator


- Quand des AS sont interconnectés par 2 liens (ou plus)
- L'AS annonçant le préfixe fixe MED
- Permet à l'AS2 d'indiquer sa préférence
- L'AS recevant le préfixe utilise MED pour sélectionner le lien



## ATTRIBUTS BGP

### NETX HOP

- Pour une session EBGP, NEXT HOP = adresse IP du voisin qui a annoncé la route.
- Pour les sessions IBGP sessions, si la route à une origine interne à l'AS, NEXT HOP = adresse IP du voisin qui a annoncé la route
- Pour les routes don't l'origine est externe à l'AS, le NEXT HOP du noeud EBGP qui a appris la route est porté sans modification dans IBGP.



BGP Table at Router C:

Destination	Next Hop
140.20.1.0/24	2.2.2.2
209.15.1.0/24	1.1.1.1


IP Routing Table at Router C:

Destination	Next Hop
140.20.1.0/24	2.2.2.2
2.2.2.0/24	3.3.3.3
3.3.3.0/24	Connected
209.15.1.0/24	1.1.1.1
1.1.1.0/24	3.3.3.3

## Processus de décision BGP

1. Choisir la route avec le plus haut LOCAL-PREF
2. S'il y a plus d'1 route, sélectionner la route ayant l'AS-PATH le plus court
3. S'il y a plus d'1 route, sélectionner selon le type ORIGIN le plus petit, avec  $IGP < EGP < INCOMPLETE$
4. S'il y a plus d'1 route, sélectionner la route ayant le MED le plus petit
5. Sélectionner le chemin de coût minimum vers le NEXT HOP en utilisant des métriques IGP
6. S'il y a plusieurs chemins internes, utiliser l'ID du routeur BGP pour trancher.

## Processus de routage



## Filtrage en aval -Output Policy Engine

- Le filtrage de sortie contrôle le trafic entrant
  - **Transmettre une route** signifie que les autres peuvent choisir d'atteindre un préfixe en passant par nous
  - **Ne pas transmettre une route** signifie que les autres doivent utiliser un autre route pour atteindre le préfixe
  - Cela peut dépendre sur le fait qu'il s'agit d'un pair E-BGP ou I-BGP
  - Exemple : si ORIGIN=EGP et que vous êtes un AS non-transit et que le pair BGP n'est pas client, alors pas de transmission
- Manipulation d'attributs
  - Fixe les attributs tels que AS\_PATH et MED


## Annonce d'un préfixe

- Lorsqu'un routeur annonce un préfixe à l'un de ses voisins BGP :
  - L'information est valide jusqu'à ce qu'un routeur annonce explicitement qu'elle n'est plus valide
  - BGP ne nécessite pas le rafraîchissement de l'information
  - Si le noeud A annonce un chemin pour un préfixe au noeud B, alors B peut être sûr que A lui-même utilise ce chemin pour atteindre la destination.


## Quelques pratiques de routage intéressantes

- Routage Hot Potato
- Multi-homing
- Filtrage et dampening de route
- Agrégation de route


### Routage Hot potato




### Routage Hot potato




### Routage Hot potato



### Multihoming vers un même fournisseur




### Multihoming vers plusieurs fournisseurs




### Motivations pour le multihoming

- Partage de charge
- fiabilité
- Indépendance vis-à-vis des fournisseurs


## Croissance des tables BGP (1989-2001)



## Croissance du nombre d'AS



## Taille des tables BGP



## Tendances de BGP

- chaque AS annonce de plus petits intervalles d'adresses
- /24 est le préfixe qui croît le plus dans la table (dans l'absolu).
- /24 - /31 est l'aire qui connaît la plus grande croissance relative (essentiellement à cause du NAT)

## Pratiques communes : filtrage

- Mécanisme par lequel on accepte/rejette une mise à jour de routage entrant/sortant
- Le filtrage peut s'effectuer selon
  - Le numéro de réseau (en utilisant des listes de préfixes)
  - L'AS-PATH (en utilisant des listes d'accès)

## Pratiques communes : agrégation

- Lorsqu'un préfixe est contenu dans un autre, annoncer seulement le plus grand
- Exemple : un ISP a le bloc d'adresses 128.0.0.0/8 et son client a 128.32.0.0/16. L'ISP annonce seulement le bloc /8.
- Aide à contrôler la taille de la table de routage

## Pratiques communes : agrégation

- Éviter les trous noirs : si un ISP annonce un bloc d'adresses mais ne contient pas tous les sous-blocs, alors ces sous-blocs manquants ne seront pas joignables.
- Limites de l'agrégation
  - multihoming
  - Un même AS peut avoir des blocs d'adresses non continus
  - Réticence à renuméroter l'espace d'adressage

## Pratiques communes : Dampening

- Utilisé pour contrôler l'instabilité de la route
- Repérer le nombre de fois qu'une route a changé sur une période de temps
  - Les routes qui varient beaucoup sur une courte période de temps sont supprimées (non annoncées)
  - Une fois que les routes arrêtent de changer pendant suffisamment longtemps, elles sont rétablies (ré-annoncées)

## Causes de l'asymétrie du routage

- Moins de 10% du routage est symétrique
  - Routage Hot potato
  - Pratiques BGP
  - Multi-homing
  - Équilibrage de charge

## Résumé

- L'Internet est stable
  - Grande disponibilité et atteignabilité
  - Grande performance
- Mais il est fragile
  - Explosion BGP
  - Peu de contrôle sur ce qui se passe à l'intérieur
  - Résoudre les problèmes manuellement devient difficile
  - Chaque ISP est différent

## Références

- Données fournies par :
  - Christophe Diot
  - Jeniffer Rexford
  - Matthias Grossglauser
  - Kavé Salamatian