

Tarification des réseaux à différenciation de services

Yezekael Hayel¹, Bruno Tuffin¹

IRISA/INRIA Rennes–Campus Universitaire de Beaulieu, 35042 Rennes Cedex, France
yezekael.hayel@irisa.fr, bruno.tuffin@irisa.fr

Résumé : Apporter de la différenciation de services dans les réseaux de communication tel Internet est une solution permettant de répondre aux exigences de qualité de service des nouvelles applications. Cette différenciation de service doit s’accompagner d’une gestion d’un point de vue économique des classes de service afin de répartir de manière optimale le trafic. Nous étudions dans ce papier l’impact économique des différentes politiques de gestion des classes de service dans une architecture de réseau à différenciation de service telle que *DiffServ*. Nous montrons qu’un fournisseur de service offrant une différenciation sur son réseau augmente son revenu et qu’il peut l’optimiser suivant la politique de gestion des classes utilisée. Nous comparons également différentes politiques d’ordonnancement pour la gestion des classes de service.

Mots-clés : QoS, DiffServ, Tarification, Optimisation

1 Introduction

Le réseau Internet actuel est basé sur la technologie IP et sur une gestion *best-effort* du trafic. L’émergence de nouvelles applications à contraintes temps-réel qui ont des besoins importants en terme de qualité-de-service (QoS), telles la téléphonie sur IP ou la vidéo *à la demande*, ont conduit l’organisme IETF à la création d’un groupe de travail visant à proposer un modèle de réseau qui prend en compte ces considérations de QoS. Dans une architecture à intégration de service, il est possible de garantir les pertes et le délai de bout-en-bout pour chaque flux (ou connection), tout en contrôlant la distribution des ressources pour l’ensemble du trafic. De ce principe a émergé le modèle de réseau à intégration de service *IntServ* (Braden *et al.*, 1994). Le problème majeur de ce type d’architecture est la réservation de ressources de bout-en-bout, ce qui ne résiste pas au passage à l’échelle d’un réseau comme Internet. Pour pallier cet inconvénient, l’architecture de réseau *DiffServ* a vu le jour. Le principe de ce modèle d’architecture de réseau est de considérer plusieurs classes de service ayant chacune un traitement différent au niveau des routeurs. Une classe de service représente une *aggregation* de trafic et ainsi le problème de passage à l’échelle du modèle *IntServ* n’existe plus. Cette nouvelle architecture de réseau se base sur deux techniques : tout d’abord la répartition du trafic en plusieurs classes, puis le traitement des paquets de ces classes suivant une politique d’ordonnancement particulière. La différenciation de service dans *DiffServ* peut se faire suivant plusieurs critères (Medina & Toutain, 2001). Soit en définissant une classe plus prioritaire sur le traditionnel *Best-Effort* et ainsi on construit une classe avec un service *Better-Than-Best-Effort* ou alors, en définissant une nouvelle classe de service offrant une performance dégradée par rapport au *Best-Effort*. La première façon a engendrée deux mécanismes : (1) *Expected Forwarding* (EF) dans lequel un service *premium* est offert à une classe de service dont le système garantie un délai minimum et (2) *Assured Forwarding* (AF) dans lequel nous avons quatre classes de service possédant chacune trois niveaux de priorité. La différenciation de service par dégradation fût proposée afin de définir une classe *Less-Than-Best-Effort* (Bless *et al.*, 2002) avec un traitement moins prioritaire que le traditionnel *Best-Effort*. Ce type de service peut servir à séparer le trafic afin que certains flux n’affectent pas la QoS des autres.

La différenciation de service dans les réseaux a été introduite afin de proposer des notions de QoS pour certaines applications suivant la classe de service utilisée. Dans un modèle de type *DiffServ*, la différenciation est gérée par le réseau. En introduisant un coût d’utilisation des différents services, le choix de la classe de service peut être faite par l’utilisateur (générateur du trafic) suivant la qualité et le prix associés à la classe choisie pour gérer son trafic. Ainsi, le modèle de tarification de l’Internet actuel basé sur une tarification forfaitaire n’est absolument pas adapté à une architecture de réseau à différenciation de service dans laquelle l’utilisateur aurait le choix de sa classe de service. Notre travail porte sur l’étude de modèles de tarification

adaptés à une architecture de réseau de type *DiffServ* et particulièrement sur l'impact économique des algorithmes d'ordonnancement de gestion des différentes classes de service. Nous montrons tout d'abord que la différenciation de service engendre un revenu plus important pour le fournisseur de service, et ensuite qu'il pourra optimiser son revenu en choisissant une politique particulière de gestion des classes de service.

La mise en œuvre de la différenciation de service se base sur les mécanismes standards de *DiffServ* : (1) le marquage de paquets se fait avec le *DiffServ codepoint* (DSCP) approprié à la classe de service, et (2) un mécanisme de traitement des paquets qui permet de les différencier suivant ce DSCP. Pour ce qui est du marquage, nous considérons qu'il est peut être réalisé volontairement par l'utilisateur (par exemple, avec une sélection de la classe de service avec le plus petit coût) ou par le réseau (par exemple pour ne pas mélanger deux types d'applications avec des contraintes de QoS différentes). Pour ce qui est du mécanisme de traitement des paquets, un mécanisme consiste à utiliser le modèle de deux files d'attente séparées, et le traitement des paquets se fait via un algorithme d'ordonnancement standard. Plusieurs types d'algorithmes ont été proposés (Chown *et al.*, 2003; qbo, ; Bless *et al.*, 2002) : les priorités strictes non-préemptives (PQ) ou le *Weighted Fair Queueing* (WFQ). D'un point de vue théorique, des mécanismes de type WFQ sont considérés comme des approximations par paquets (Parekh & Gallager, 1993) des modèles fluides *Generalized Processor Sharing* (GPS) et *Discriminatory Processor Sharing* (DPS). Comme nous allons le voir dans les parties 3 et 4, chaque mécanisme d'ordonnancement a un impact différent sur les performances de chacune des classes de service.

Nous étudions les implications des trois algorithmes d'ordonnancement PQ, GPS et DPS sur le revenu du fournisseur de service. La mise en place d'une nouvelle tarification de l'Internet à l'usage est étudiée depuis quelques années dans les réseaux comme un moyen de résoudre des problèmes de congestion et de bonne utilisation du réseau sans avoir à changer l'infrastructure. Pour avoir un aperçu de l'utilisation des modèles de tarification pour les réseaux de télécommunications, se référer à (Courcoubetis & Weber, 2003). Nous supposons ici une tarification à l'usage avec un prix unitaire différents suivant la classe de service utilisée. L'algorithme d'ordonnancement basé sur des priorités strictes (PQ) peut être utilisé pour offrir un très faible délai pour la classe la plus prioritaire, ce qui est désirable pour des applications à contraintes temps-réel très sensibles au délai telles la voix sur IP ou VoD. Seulement, cet algorithme simple à mettre en œuvre dans les routeurs, souffre d'un réel inconvénient : si le trafic de classe la plus prioritaire est important alors le taux de service du trafic des autres classes moins prioritaire peut être très faible (on parle alors de risque de *famine* pour les autres classes). Ce phénomène est d'autant plus gênant que l'on considère du trafic élastique sensible au délai utilisant le protocole de transport TCP. L'algorithme d'ordonnancement WFQ correspond à une vision par paquet du modèle fluide GPS qui ne possède pas le problème de *famine* évoqué auparavant. Avec ce modèle, on associe à chacune des classes de service un *poids* positif. Ce *poids* spécifie la capacité minimum garantie pour la classe. En particulier, si une classe n'utilise pas la totalité de sa capacité, alors l'excès de capacité est distribué aux autres classes. Ce modèle est encore parfois appelé modèle de *Tirupati* (Dube *et al.*, 2002). Ainsi le mécanisme d'ordonnancement basé sur GPS peut être vu comme un PS entre classes accompagné d'une politique FIFO à l'intérieure de chacune d'elle. Nous étudions également un autre modèle proche de GPS qui est DPS. Cet algorithme d'ordonnancement associe comme GPS un poids à chacune des classes mais considère par contre une politique PS à l'intérieur de chaque classe, c'est-à-dire que la capacité de service associée à une classe est partagée entre tous les paquets présents dans la classe de service.

Nous considérons le cas d'un fournisseur de service voulant maximiser son profit dans un réseau fournissant deux classes de service. Nous étudions, pour chacun des algorithmes d'ordonnancement, comment déterminer les prix optimum pour chacune des classes, et l'impact d'un système de file d'attente avec ces politiques de gestion des classes sur le revenu. Notre travail se base sur l'article de Mandjes (Mandjes, 2003), dans lequel les prix optimaux et le revenu optimum sont définis dans le cas PQ. Nous utilisons la performance d'une file FIFO (correspondant à un réseau sans différenciation de services) pour comparer les revenus.

Dans notre modèle, comme dans (Mandjes, 2003), nous supposons que le délai est le paramètre principal de QoS perçu par les utilisateurs. La valuation de service de chaque utilisateur est donnée par une fonction d'utilité strictement décroissante par rapport au délai moyen. Nous considérons deux classes d'utilisateurs ou applications, qui diffèrent suivant leur sensibilité au délai moyen. Nous supposons également deux classes de service, construites pour transporter ces applications. Chacun des deux types de trafic est supposé *élastique* (Shenker, 1995), dans le sens où les utilités réagissent face au délai et au prix.

Nous supposons que les utilisateurs payent pour ce service suivant leur utilisation, sur la base de leur débit. Le réseau est modélisé par un goulot d'étranglement dans lequel un serveur gère les deux files, une pour

chaque classe de service. Le prix unitaire pour chacun des services doit être différent afin de forcer les utilisateurs à choisir l'une ou l'autre classe, sinon tous les utilisateurs choisiraient la classe avec les meilleures performances pour le même prix que l'autre. Nous supposons que le marquage se fait par les utilisateurs et qu'ils choisissent eux-même leur classe de service en fonction du prix et de la QoS attendue.

Nos contributions sont les suivantes. Tout d'abord, nous étendons le modèle proposé par Mandjes pour une file avec PQ au cas d'un serveur GPS et DPS. À notre connaissance, il n'existe pas de forme close du délai moyen dans une file d'attente avec politique de service GPS (voir (Borst *et al.*, 2002) pour une discussion à ce sujet). Seulement, on peut considérer le fait que la différenciation de services sur Internet est intéressante pour les flux élastiques seulement en période de congestion. Ainsi, nous considérons un réseau sous des hypothèses de *gros trafic*, tout comme dans (Dube *et al.*, 2002). Dans telle configuration, un modèle de serveur GPS réagit approximativement comme un serveur partitionné, c'est-à-dire deux files indépendantes FIFO où chacune possède un taux de service correspondant au débit minimum garanti dans le modèle GPS. Une autre formulation est la suivante : dans un contexte de gros trafic, un modèle GPS associé à une tarification différente pour chaque file peut être vu comme le modèle de réseau de type *Paris Metro Pricing* (PMP) (Odlyzko, 1999), dans lequel la capacité du lien est distribuée d'une façon logique en deux. Ensuite, nous comparons les revenus optimaux avec les différents algorithmes d'ordonnement : PQ, FIFO, GPS (ou du moins dans sa version approchée avec hypothèse de trafic important) et DPS. Nous montrons que : (a) les priorités strictes sont plus efficaces en terme économique que le modèle GPS, DPS ou la simple file FIFO ; (b) les revenus optimaux sont plus faibles avec GPS que la file sans différenciation FIFO ; (c) les revenus optimaux sont plus faibles avec FIFO qu'avec le modèle avec DPS. Les résultats traitant du modèle avec GPS sont publiés dans l'acte de la conférence annuelle IEEE INFOCOM 2004 (Hayel *et al.*, 2004). Quant aux résultats à propos du modèle DPS, ils sont en cours de rédaction.

Le papier s'organise de la manière suivante. La section 2 présente un modèle mathématique d'un nœud *DiffServ* supportant deux classes de service, et utilisant les trois différents algorithmes d'ordonnement : PQ, GPS et DPS. Dans les sections 3 et 4, nous comparons les performances de chacun des algorithmes d'ordonnement en terme de revenu pour le fournisseur de service. Dans la section 5, nous discutons de l'aspect économique et pratique de nos résultats. Finalement, la section 6 conclut le papier.

2 Modèle mathématique

Tout d'abord, nous décrivons le modèle introduit par Mandjes (Mandjes, 2003). Ensuite, nous formalisons l'hypothèse de *gros trafic* que nous supposons pour approcher l'algorithme d'ordonnement GPS par des files FIFO indépendantes, enfin nous optimisons les prix pour le modèle GPS afin de comparer les revenus optimaux.

Nous considérons une population infinie d'utilisateurs potentiels. Deux type de trafic sont considérés et qui diffèrent suivant leur sensibilité au délai ; nous appelons le trafic de type-*v* ("voix") et de type-*d* ("données").

La fonction de valuation de chaque utilisateurs dépend du délai moyen perçu et du prix par paquet *p* de la façon suivante :

$$U_d(\mathbb{E}D) = \frac{1}{(\mathbb{E}D)^{\alpha_d}} - p, \quad (1)$$

$$U_v(\mathbb{E}D) = \frac{1}{(\mathbb{E}D)^{\alpha_v}} - p, \quad (2)$$

avec $0 < \alpha_d < \alpha_v$ tel que la sensibilité des utilisateurs de type-*v* au délai est plus importante que celle des utilisateurs de type-*d*. Nous supposons que les utilisateurs rejoignent le réseau tant que leur fonction de valuation (utilité) est positive.

Nous considérons ici une file d'attente M/M/1 avec taux de service μ et N utilisateurs indépendants générant des paquets suivant un processus de Poisson de taux λ . Le délai moyen est donc

$$\mathbb{E}D = \frac{1}{\mu - N\lambda},$$

en supposant que $N\lambda < \mu$ (Kleinrock, 1975). Nous notons respectivement λ_d et λ_v le taux d'arrivée des paquets de type-*d* et de type-*v*.

En supposant que le système se compose seulement d'utilisateurs de type- d , le nombre maximum de source joignant le réseau est défini par

$$N_d(p) = \frac{\mu - \alpha\sqrt{p}}{\lambda_d}, \quad (3)$$

si $p \leq \mu^{\alpha_d}$, sinon $N_d(p) = 0$. Il faut remarquer que $N_d(p)$ représente le plus grand nombre d'utilisateurs de type- d associé à une utilité positive. De la même façon, si le système se compose uniquement d'utilisateurs de type- v , nous avons un nombre maximum d'utilisateurs défini par

$$N_v(p) = \frac{\mu - \alpha\sqrt{p}}{\lambda_v}, \quad (4)$$

si $p \leq \mu^{\alpha_v}$, sinon $N_v(p) = 0$.

Dans le cas où il y a une compétition entre les deux type de trafic, nous donnons ci-dessous le résultat principal donné par Mandjes dans (Mandjes, 2003).

Proposition 1 ((Mandjes, 2003))

Supposons une file d'attente M/M/1/FIFO et un prix par paquet p . Si $p < 1$ alors seuls les utilisateurs de type- d ont un intérêt à joindre le système, sinon dans le cas où $p > 1$, seuls les utilisateurs de type- v ont un intérêt à joindre le système.

En effet, supposons qu'il y ait $N_d(p)$ utilisateurs de type- d présents, avec $N_d(p)$ défini par (3). Un utilisateur de type- v rejoindra le système si et seulement si

$$U_v(p) = \left(\mu - \lambda_d \left(\frac{\mu - \alpha\sqrt{p}}{\lambda_d} \right) \right)^{\alpha_v} - p = p^{\alpha_v/\alpha_d} - p > 0.$$

Comme nous avons $\alpha_v > \alpha_d$, les utilisateurs de type- v rejoindront le système si et seulement si $p > 1$. Inversement, si nous avons $N_v(p)$ utilisateurs de type- v présents, un utilisateur de type- d rejoindra le système si et seulement si $p < 1$.

Le résultat important est la comparaison des revenus optimaux en utilisant PQ par rapport à un modèle sans différenciation de service FIFO.

Théorème 1 ((Mandjes, 2003))

Dans un système composé de deux classes de service et de deux trafic de type différents, le revenu optimal en utilisant un algorithme d'ordonnancement de gestion des classes PQ est supérieur ou égal au revenu optimum sans différenciation de service dans le deux cas particuliers de marquage des paquets : le cas des classes dédiées où les paquets sont marqués par le réseau et le cas des classes ouvertes où les paquets sont marqués par l'utilisateur.

Donc ce résultat nous indique tout d'abord que faire de la différenciation de service peut engendrer un gain en terme de revenu en utilisant la politique de service GPS. Dans la suite, nous étudions donc le modèle avec politique de service GPS avec hypothèse de trafic important et comparons le revenu optimal avec celui obtenu avec PQ afin de déterminer la politique optimale

3 Politique de service GPS

Considérons toujours un système modélisé par une file M/M/1 multiclasse et avec une politique de service GPS et I classes. Chacune des classes i possède une proportion γ_i du taux de service total μ , c'est-à-dire que l'on a $\sum_{i=1}^I \gamma_i = 1$. Lorsqu'une file est vide, son taux de service est partagée entre les autres files non-vides (i.e. le server est). En supposant que le trafic est important, la probabilité d'avoir une classe vide est très faible. Donc, dans un contexte de gros trafic, un modèle de file M/M/1 multiclasse avec politique de service GPS se comporte approximativement comme I files M/M/1 logiques indépendantes ayant chacune un taux de service $\gamma_i\mu$. Si l'on considère que chaque classe est tarifée suivant un prix différent, cette séparation logique en I files d'attente correspond au modèle de tarification du *Paris Metro Pricing* (PMP) (Odlyzko, 1999) dont les performances ont été étudiées dans (Tuffin & Ros, 2004), (Gibbens *et al.*, 2000).

Dans notre modèle d'étude, nous considérons deux classes de service, i.e. $I = 2$. Soit $0 \leq \gamma \leq 1$ la

proportion de bande-passante allouée à la classe $i = 2$. Ainsi, le taux de service de la classe 1 est $(1 - \gamma)\mu$ et de la classe 2 est $\gamma\mu$.

Tout d'abord nous considérons le cas des classes dédiées dans lequel le trafic est dirigé dans chaque classe de service par le réseau. Ensuite nous verrons le cas des classes ouvertes. Cette étude et les preuves des résultats énoncés ont été publiés dans (Hayel *et al.*, 2004).

3.1 Classes dédiées

Tout d'abord, nous avons besoin des résultats pour le modèle lorsque l'utilisateur n'a pas le choix de sa classe de service. Nous supposons que la première classe de service (file d'attente $i = 1$) est dédiée au trafic de type- v et que la seconde classe de service (file d'attente $i = 2$) est dédiée au trafic de type- d . Le nombre d'utilisateurs de type- d présents est :

$$N_2(p) = N_d(p) = \frac{\gamma\mu - \alpha_d\sqrt{p}}{\lambda_d}, \quad (5)$$

si $p < (\gamma\mu)^{\alpha_d}$ et 0 sinon. De même, le nombre d'utilisateurs de type- v est :

$$N_1(p) = N_v(p) = \frac{(1 - \gamma)\mu - \alpha_v\sqrt{p}}{\lambda_v}, \quad (6)$$

si $p < ((1 - \gamma)\mu)^{\alpha_v}$ et 0 sinon.

Nous supposons que le prix est différent pour chacune des classes de service. Nous notons p_1 le prix pour la première classe dédiée au trafic de type- v et p_2 le prix pour la seconde dédiée au trafic de type- d . Le revenu $\Pi_{GPS}^{(\gamma)}$ est défini comme le produit du débit moyen avec le prix par paquet :

$$\begin{aligned} \Pi_{GPS}^{(\gamma)}(p_1, p_2) &= \lambda_1 N_1 p_1 + \lambda_2 N_2 p_2, \\ &= \lambda_v N_v p_1 + \lambda_d N_d p_2, \\ &= (1 - \gamma)\mu p_1 - p_1^{1+1/\alpha_v} + \gamma\mu p_2 - p_2^{1+1/\alpha_d} \end{aligned} \quad (7)$$

avec $(p_1, p_2) \in D_0 = [0, ((1 - \gamma)\mu)^{\alpha_v}] \times [0, (\gamma\mu)^{\alpha_d}]$. Les prix qui optimisent le revenu pour γ fixé sont donnés par le théorème suivant.

Théorème 2 ((Hayel *et al.*, 2004))

Soit la proportion de bande-passante γ fixée, les prix qui maximisent le revenu $\Pi_{GPS}^{(\gamma)}$ dans un modèle de file d'attente avec la politique de service GPS sous hypothèse de gros trafic sont donnés par :

$$p_1^* = \left(\frac{(1 - \gamma)\mu}{1 + \frac{1}{\alpha_v}} \right)^{\alpha_v} \quad \text{et} \quad p_2^* = \left(\frac{\gamma\mu}{1 + \frac{1}{\alpha_d}} \right)^{\alpha_d}. \quad (8)$$

Nous sommes donc capable maintenant de donner l'expression du revenu optimal (7) en fonction de γ :

$$\Pi_{GPS}^*(\gamma) = (1 - \gamma)^{1+\alpha_v} A(\alpha_v) + \gamma^{1+\alpha_d} A(\alpha_d), \quad (9)$$

avec $A(x) = \mu^{1+x} \left(\frac{x}{1+x} \right)^x \frac{1}{1+x}$.

Une fois que les prix sont optimisés, on s'intéresse à l'optimisation du paramètre de partage de ressource γ entre les classes de service pour maximiser le revenu $\Pi_{GPS}^*(\gamma)$. Le théorème suivant donne cette valeur optimale de γ .

Théorème 3 ((Hayel *et al.*, 2004))

Soit un modèle de file d'attente avec politique de service GPS sous hypothèse de gros trafic. Le revenu maximum est donné par :

$$\Pi_{GPS}^* = \max(A(\alpha_v), A(\alpha_d)),$$

ce qui implique $\gamma = 0$ ou $\gamma = 1$. Ceci est équivalent au fait de ne servir qu'une seule file. De plus, nous avons les cas particuliers suivants :

- Si $\alpha_d > \frac{1}{\mu-1}$, alors $\Pi_{GPS}^* = A(\alpha_v)$.
- Si $\alpha_v < \frac{1}{\mu-1}$, alors $\Pi_{GPS}^* = A(\alpha_d)$.

Pour prouver le théorème, il suffit d'observer que la fonction Π_{GPS}^* est strictement convexe sur l'intervalle $[0, 1]$ et qu'elle atteint son maximum aux bords de cet intervalle. Ce théorème nous dit que le revenu est optimisé en servant une file dans un modèle GPS. Ainsi, lorsque que l'on cherche à optimiser le revenu, seul *une unique classe de service* doit être acceptée dans le réseau.

3.2 Classes ouvertes

Nous supposons maintenant que les utilisateurs ont le choix de leur classe de service sans prendre en compte leur type de trafic. Ainsi, il est possible d'avoir des paquets de type- v et de type- d dans la même classe de service. Nous gardons les notations du cas des classes dédiées avec en particulier, γ la proportion du service total μ allouée à la seconde classe de service.

Le premier résultat porte sur la nature du trafic dans chacune des classes. La proposition suivante montre que seul un unique type de paquets est présent dans chacune des files indépendamment de l'autre file.

Proposition 2 ((Hayel et al., 2004))

Pour chaque classe de service i , nous avons les propriétés suivantes :

- le trafic de type- d est présent dans la classe de service i , $i = 1, 2$, si et seulement si $p_i < 1$.
- le trafic de type- v est présent dans la classe de service i , $i = 1, 2$, si et seulement si $p_i > 1$.

Comme le prix induit différentes configurations du trafic dans le système, le revenu $\Pi_{GPS}^{(\gamma)}$ s'exprime de différentes manières. Pour γ fixé, le domaine d'optimisation des prix se décompose en trois sous-domaines : V_O (seulement du trafic de type- v), D_O (seulement du trafic de type- d) et M_O (les deux types de trafic sont présents). Ces trois sous-domaines pour (p_1, p_2) sont définis de la manière suivantes :

$$\begin{aligned} V_O &= [1, ((1-\gamma)\mu)^{\alpha_v}] \times [1, (\gamma\mu)^{\alpha_v}] \\ D_O &= [0, \min(1, ((1-\gamma)\mu)^{\alpha_d})] \times [0, \min(1, (\gamma\mu)^{\alpha_d})] \\ M_O &= M_O^{(1)} \cup M_O^{(2)} \end{aligned}$$

avec

$$\begin{aligned} M_O^{(1)} &= [1, ((1-\gamma)\mu)^{\alpha_v}] \times [0, \min(1, (\gamma\mu)^{\alpha_d})] \\ M_O^{(2)} &= [0, \min(1, ((1-\gamma)\mu)^{\alpha_v})] \times [1, (\gamma\mu)^{\alpha_d}] \end{aligned}$$

Nous utilisons la notation standard des intervalles avec la convention $[a, b] = \emptyset$ dès que $a > b$. Tout comme dans le cas des classes dédiées, nous déterminons l'expression des prix sur chacun des sous-domaines afin d'optimiser le revenu sur chacun d'eux. Finalement, nous donnons le paramètre optimal γ afin de déterminer le revenu maximum sur chacun des sous-domaines V_O , D_O et M_O .

Proposition 3 ((Hayel et al., 2004))

Sur chacun des sous-domaines de prix V_O , D_O et M_O , le paramètre optimal de poids est $\gamma \in \{0, 1\}$.

Nous avons déterminé les revenus optimum dans les cas de classes dédiées et ouvertes. Nous pouvons donc comparer ces revenus optimaux en considérant l'algorithme d'ordonnement GPS par rapport au revenu maximum obtenu dans (Mandjes, 2003) en considérant le modèle avec des priorités strictes PQ.

3.3 Comparaison des revenus optimum avec GPS et PQ

Dans cette partie, nous comparons les revenus optimaux qui peuvent être obtenus en utilisant les deux type d'algorithmes de gestion des classes, PQ et GPS. Nous comparons chacun des revenus avec celui obtenu dans un modèle sans différenciation des services, i.e. une file FIFO. Nous notons Π_{PQ}^* le revenu optimal obtenu pour un système avec priorités strictes. Nous avons le résultat suivant.

Théorème 4 ((Hayel et al., 2004))

Dans un contexte de classes ouvertes et dédiées, les revenus maximum vérifient :

$$\Pi_{GPS}^* \leq \Pi_{PQ}^*.$$

Ceci utilise le fait que $\Pi_{PQ}^* \geq \Pi_{FIFO}^*$ et que nous avons $\Pi_{FIFO}^* = \Pi_{GPS}^*$. Ainsi, le revenu maximum obtenu dans un système avec priorités strictes est toujours supérieur ou égal au revenu obtenu dans un système avec un algorithme d'ordonnancement de type GPS. De plus, le revenu maximum obtenu dans un modèle sans différenciation de service donne le même revenu optimal que dans un modèle avec GPS.

4 Politique de service DPS dans le cas de classes dédiées

L'algorithme d'ordonnancement DPS est une variation de l'algorithme GPS. Il a été introduit dans (Kleinrock, 1967). Comme pour GPS, le trafic est partitionné en classes et chacune d'elles est associée à un poids donnant la proportion de service (si aucune classe n'est vide). Cependant, la capacité du serveur attribuée à une file est partagée équitablement entre tous les paquets présents dans la file. Ceci revient à considérer une politique *processor sharing* (PS) à l'intérieur de chaque file alors que pour GPS, la politique est FIFO dans la file. Donc, DPS peut être vu comme une généralisation au cas multiclasse de la politique de service *processor sharing* (PS) avec laquelle chacun des flux reçoit le même taux de service. Ainsi, il n'y a pas de temps d'attente dans un système avec politique de service DPS, dès l'arrivée d'un paquet il commence à être servi. Donc, le délai moyen perçu dans le système est égal seulement au temps moyen de service. Dans l'article (Fayolle et al., 1980), les auteurs obtiennent une forme close du temps moyen de service dans un système modélisé par une file M/M/1 avec politique de service DPS. Nous considérons notre modèle avec deux classes de service, et le cas des classes dédiées avec le trafic de type- v dans la première classe avec comme poids $1 - \gamma$ et le trafic de type- d dans la seconde avec comme poids γ . Nous obtenons les temps moyen de service suivant :

$$\mathbb{E}D_v = \frac{1}{\mu - \lambda_v N_v - \lambda_d N_d} \left(1 + \frac{\lambda_d N_d (2\gamma - 1)}{\mu - (1 - \gamma)\lambda_v N_v - \gamma\lambda_d N_d} \right), \quad (10)$$

et

$$\mathbb{E}D_d = \frac{1}{\mu - \lambda_v N_v - \lambda_d N_d} \left(1 - \frac{\lambda_v N_v (2\gamma - 1)}{\mu - (1 - \gamma)\lambda_v N_v - \gamma\lambda_d N_d} \right). \quad (11)$$

4.1 Équilibre du système

Cette politique de gestion des paquets ne réagit pas comme GPS car un paquet arrivant dans la classe 2 n'influe pas seulement sur le temps moyen de service des paquets de sa classe mais aussi sur le temps moyen de service des paquets de l'autre classe de service et requiert donc une analyse plus fine des relations entre classes. Dans GPS ceci n'était pas le cas et ainsi chacune des classes choisissait son nombre d'utilisateurs indépendamment du nombre d'utilisateurs de l'autre classe.

Avec la politique DPS, nous avons un jeu non-coopératif entre les classes pour déterminer le nombre de sources à l'équilibre. Les utilisateurs rentrent dans le système tant que leur utilité est positive, i.e. pour chaque type de trafic, le nombre de sources augmente de manière continue. Supposons pour simplifier qu'à l'instant initial $N_v = N_d = 0$, $U_v(N_d, N_d) > 0$ et $U_d(N_d, N_v) > 0$. Notons les courbes suivantes $A_v^0 = \{(N_v, N_d)/U_v(N_v, N_d) = 0\}$ et $A_d^0 = \{(N_v, N_d)/U_d(N_v, N_d) = 0\}$. Chaque type de trafic augmente son nombre de sources jusqu'à ce que l'une des utilités soit égale à 0, c'est-à-dire que le couple (N_v, N_d) a atteint soit la courbe A_v^0 , soit la courbe A_d^0 . En fonction de la courbe qui est atteinte en premier, nous avons différents comportements du système :

- Si on a atteint A_v^0 (voir figure 1 la courbe en pointillé 1), c'est-à-dire que le couple (N_v, N_d) vérifie $U_v(N_v, N_d) = 0$ et $U_d(N_v, N_d) > 0$. Comme $U_d(N_v, N_d) > 0$, le nombre de sources de type d augmente et ainsi $U_v(N_v, N_d)$ devient négative, ce qui fait diminuer le nombre de sources de type v .
- De la même façon, si on a atteint A_d^0 (voir figure 1 la courbe en pointillé 2), c'est-à-dire que le couple (N_v, N_d) vérifie $U_d(N_v, N_d) = 0$ et $U_v(N_v, N_d) > 0$. Comme $U_v(N_v, N_d) > 0$, le nombre de source de type v augmente et ainsi $U_d(N_v, N_d)$ devient négative, ce qui fait diminuer le nombre de sources de type d .

Il existe donc 3 possibles équilibres.

– Soit le système :

$$U_v(N_v, N_d) = U_d(N_v, N_d) = 0,$$

admet une solution unique (N_v^*, N_d^*) avec :

$$N_v^* = \frac{1}{\lambda_v} \left(-\frac{\mu q_1}{\gamma q_2 - (1-\gamma)q_1} + \frac{q_1 q_2}{\gamma q_1 - (1-\gamma)q_2} \right)$$

et

$$N_d^* = \frac{1}{\lambda_d} \left(\frac{\mu q_2}{\gamma q_2 - (1-\gamma)q_1} - \frac{q_1 q_2}{\gamma q_1 - (1-\gamma)q_2} \right).$$

Dans ce cas, les courbes A_v^0 et A_d^0 se croisent et ceci se produit lorsque les prix vérifient une certaine condition par rapport aux paramètres γ et μ , nous avons que la solution du système est positive (voir exemple de la figure 1). Dans ce cas, le couple (N_v, N_d) tel que $U_v(N_v, N_d) = 0$ et $U_d(N_v, N_d) > 0$ vérifie $N_v > N_v^*$ et $N_d < N_d^*$. Donc comme N_d augmente et N_v diminue, nous allons atteindre l'équilibre $(N_v, N_d) = (N_v^*, N_d^*)$.

– Soit on atteint la courbe A_v^0 en première et ensuite N_d augment et N_v diminue jusqu'à atteindre l'équilibre $(N_v, N_d) = (0, \frac{\mu - q_2}{\lambda_d})$.

– Soit on atteint la courbe A_d^0 en première et ensuite N_v augment et N_d diminue jusqu'à atteindre l'équilibre $(N_v, N_d) = (\frac{\mu - q_1}{\lambda_v}, 0)$.

Nous avons le théorème suivant qui permet de déterminer l'équilibre du système.

Théorème 5

Soient $q_1 = \alpha_v \sqrt{p_1}$ et $q_2 = \alpha_d \sqrt{p_2}$. Nous supposons que le taux de service global μ et le poids de la seconde file γ sont fixés. Nous posons $0 < q_1 < \mu$ fixé alors :

- Si $0 < q_2 < q_2^-$ alors l'équilibre est $(N_v, N_d) = (\frac{\mu - q_1}{\lambda_v}, 0)$,
- si $q_2^- < q_2 < q_2^+$ alors l'équilibre est $(N_v, N_d) = (N_v^*, N_d^*)$,
- si $q_2^+ < q_2 < \mu$ alors l'équilibre est $(N_v, N_d) = (0, \frac{\mu - q_2}{\lambda_d})$,

avec $q_2^- = \sqrt{\mu q_1 + (\frac{\mu - q_1}{2} \frac{1-\gamma}{\gamma})^2} - \frac{\mu - q_1}{2} \frac{1-\gamma}{\gamma}$ et $q_2^+ = \frac{\mu \gamma q_1 + (1-\gamma)q_1^2}{\gamma q_1 + \mu(1-\gamma)}$.




FIG. 1 – Dynamique du système lorsque l'équilibre non trivial est atteint. Supposons que l'utilité du trafic de type voix s'annule avant le trafic de type données (chemin 1), alors le système remonte à l'équilibre non-trivial le long de A_v^0 . Dans l'autre cas de figure lorsque l'utilité du trafic de type données s'annule avant le trafic de type voix (chemin 2), le système tend vers l'équilibre non-trivial le long de A_d^0 .

Ce théorème nous permet donc de déterminer la fonction de revenu $\Pi_{DPS}^{(\gamma)}(q_1, q_2)$ que l'on souhaite maximiser sur l'ensemble $[0, \mu]^2$ lorsque l'équilibre n'est pas trivial, i.e. lorsque $(N_v, N_d) = (N_v^*, N_d^*)$. Le

cas trivial correspond à avoir un unique type de paquet dans le système et donc le modèle ne prend alors pas en compte la différenciation de service. Nous optimisons le paramètre de partage de bande-passante γ en considérant les prix q_1 et q_2 fixés.

4.2 Optimisation du partage de bande-passante

On s'intéresse à l'optimisation du revenu dans le cas de l'équilibre non trivial. La condition sur q_2 donnée par le théorème 5 nous donne une condition équivalente sur γ avec q_1 , q_2 et μ fixés :

$$\gamma^- = \frac{q_1}{q_1 + q_2} \frac{\mu \frac{q_2}{q_1} - q_1}{\mu - q_1} < \gamma < \frac{q_2}{q_1 + q_2} \frac{\mu - q_1}{\mu - q_2} = \gamma^+. \quad (12)$$

La fonction de revenu à optimiser en fonction de γ sur l'intervalle $[\gamma^-, \gamma^+]$ est définie par :

$$\Pi(\gamma) = \frac{(q_2^{1+\alpha_d} - q_1^{1+\alpha_v})\mu}{\gamma q_2 - (1-\gamma)q_1} + \frac{q_1 q_2 (q_1^{\alpha_v} - q_2^{\alpha_d})}{\gamma q_1 - (1-\gamma)q_2},$$

Pour réaliser cette étude, nous avons partitionné le carré $[0, \mu]^2$ en trois sous-ensembles et enfin optimiser le paramètre de bande-passante sur chacun de ces sous-ensembles.

5 Discussion

Le principal résultat obtenu par Mandjes (Mandjes, 2003) indique qu'il est intéressant d'un point de vue économique, d'offrir de la différenciation de service sur son réseau en utilisant un algorithme de type priorités strictes pour gérer les différents classes de service. En fait, avoir plus d'une classe de service peut augmenter les revenus même s'il n'y a qu'un seul type de trafic dans le réseau. Donc, ajouter un autre service au classique *best-effort* peut engendrer un meilleur revenu pour le fournisseur de service s'il applique un algorithme de gestion des classes de service de type PQ ou DPS.

Néanmoins, comme nous l'avons montré précédemment, le choix de l'algorithme d'ordonnancement (politique de gestion des classes) peut avoir un impact sur le revenu maximum du fournisseur. En effet, nos résultats suggèrent que les revenus peuvent être plus faibles lorsque le fournisseur offre une différenciation de service en utilisant un algorithme de gestion des classes de type GPS. Nous remarquons que nous obtenons les mêmes conclusions que dans (Tuffin & Ros, 2004) alors que le modèle est sensiblement différent.

D'autre part, le mécanisme d'ordonnancement affecte fortement les performances des flux et applications utilisant le réseau. Nous avons supposé que les flux étaient infiniment élastiques, dans le sens qu'ils acceptent un long délai si le prix décroît en circonstance. Dans le cas non-élastiques, une analyse mérite aussi d'être réalisée.

6 Conclusions et perspectives

Dans cet article nous avons étudié les aspects économiques de la différenciation de service sur un réseau de type Internet. Basé sur la modélisation de Mandjes, nous avons évalué les implications économiques de trois différents algorithmes d'ordonnancement, PQ, GPS et DPS, qui sont communément proposés dans une architecture de type *DiffServ*. Nous avons étendu le modèle de Mandjes au cas d'un serveur GPS dans un contexte de trafic "important" et au cas d'un serveur DPS. Nous avons montré que PQ engendre un gain pour le revenu du fournisseur face aux modèles GPS et DPS.

Concernant les perspectives de nos travaux, plusieurs axes sont possibles :

- Prouver théoriquement que le revenu optimal obtenu avec la politique de service PQ est toujours supérieur à celui obtenu avec la politique DPS.
- Incorporer un modèle de trafic TCP dans le modèle de file d'attente ce qui permettrait de mettre en évidence le phénomène de famine dû à l'utilisation de PQ.
- Prendre en compte d'autres paramètres de qualité de service telle la probabilité de perte.
- Étendre nos résultats à un réseau entier et dans le même temps résoudre les problèmes de routage associés.

Références

- QBone Scavenger Service (QBSS). internet2 QBone Initiative. <http://qbone.internet2.edu/qbss>.
- BLESS R., NICHOLS K. & WEHRLE K. (2002). *A Lower Effort Per-Domain Behavior for Differentiated Services*. work in progress.
- BORST S., BOXMA O. & NÚÑEZ QUEIJA R. (2002). Heavy Tails : The Effect of the Service Discipline. In *Proceedings of Performance TOOLS*.
- BRADEN R., CLARK D. & SHENKER S. (1994). *Integrated Services in the Internet Architecture :an Overview*. Rapport interne, RFC 1663 IETF.
- CHOWN T., FERRARI T., LEINEN S., SABATINO R., SIMAR N. & VENAAS S. (2003). Less Than Best Effort : Application Scenarios and Experimental Results. In *Proceedings of QoS-IP*.
- COURCOUBETIS C. & WEBER R. (2003). *Pricing Communications Networks*. Wiley.
- DUBE P., BORKAR V. & MANJUNATH D. (2002). Differential Join Prices for Parallel Queues : Social Optimality, Dynamic Pricing Algorithms and Application to Internet Pricing. In *proceedings of IEEE INFOCOM*.
- FAYOLLE G., MITRANI I. & IASNOGORODSKI R. (1980). Sharing a Processor Among Many Job Classes. *Journal of the Association for Computing Machinery*, **27**(3).
- GIBBENS R., MASON R. & STEINBERG R. (2000). Internet Service Classes Under Competition. *IEEE Journal on Selected Areas in Communications*, **18**(12).
- HAYEL Y., ROS D. & TUFFIN B. (2004). Less-than-Best-Effort Services : Pricing and Scheduling. In *proceedings of IEEE INFOCOM*.
- KLEINROCK L. (1967). Time-shared Systems : A Theoretical Treatment. *Journal of the Association for Computing Machinery*, **14**(2).
- KLEINROCK L. (1975). *Queuing Systems : Theory*, volume I. J. Wiley & Sons.
- MANDJES M. (2003). Pricing Strategies under Heterogeneous Service Requirements. In *proceedings of IEEE INFOCOM*.
- MEDINA O. & TOUTAIN L. (2001). *State of the Art in DiffServ*. Rapport interne, ITEA Project 99011 "RTIPA".
- ODLYZKO A. (1999). Paris Metro Pricing for the Internet. In *ACM Conference on Electronic Commerce (EC'99)*, p. 140–147.
- PAREKH A. & GALLAGER R. (1993). A Generalized Processor Sharing Approach to Flow Control in Integrated Services Networks : The Single Node Case. *IEEE/ACM Transactions on Networking*, **6**(4), 344–357.
- SHENKER S. (1995). Fundamental Design Issues for the Future Internet. *IEEE Journal on selected areas in communications*, **13**(7), 1176–1188.
- TUFFIN B. & ROS D. (2004). A Mathematical Model of the Paris Metro Pricing Scheme for Charging Packet Networks. *To appear in Computer Networks*.