

# Caractérisation et analyse du trafic Internet en fonction du type d'application

Nicolas LARRIEU, Yu ZHANG, Philippe OWEZARSKI

LAAS – CNRS  
7, avenue du Colonel ROCHE  
31077 TOULOUSE Cedex 4  
FRANCE

{nlarrieu, yzhang, owe}@laas.fr

**Résumé** – Les projets de métrologie actuels et passés ont montré que les caractéristiques et les modèles du trafic Internet étaient très éloignés des connaissances traditionnelles étant donné qu'ils mettent en évidence des propriétés de plus en plus complexes comme l'auto-similarité et la dépendance longue mémoire (LRD pour Long Range Dependence). Ces propriétés sont très dangereuses pour la régularité du profil du trafic Internet ainsi que pour la QoS (Qualité de Service) du réseau. Ces projets ont aussi prouvé que la LRD est causée par la transmission de flux longs (appelés "éléphants") qui utilisent le protocole TCP. En conséquence, de nombreuses propositions ont été faites pour différencier la méthode de transmission des flux courts (appelés "souris") et des flux éléphants. Cependant, cette décomposition du trafic en souris et éléphants ne fournit pas des résultats explicites étant donné que de nombreux comportements sont mélangés au travers de ces deux classes. Ce papier propose donc une évolution de la décomposition souris / éléphants en se basant sur les différentes applications (P2P, "streaming", Web, etc.) qui génèrent la majorité des flux éléphants mais qui ne suivent probablement pas toutes le même modèle de trafic. De plus, une décomposition basée sur le volume d'information généré par ces applications est aussi proposée pour caractériser plus précisément les propriétés du trafic des flux éléphants. Cette analyse apporte des informations permettant d'isoler les classes applicatives qui ont un impact négatif sur la LRD et la QoS. En conséquence, les résultats fournis par cette méthode de décomposition du trafic fourniront des indications pour permettre une meilleure gestion de ces flux applicatifs et leur meilleur transfert dans le réseau.

**Abstract** – Past and recent monitoring projects showed that Internet traffic model and characteristics are very far from common beliefs and that it more and more exhibits complex properties as self-similarity and long range dependence (LRD), which are very damageable for traffic profile and network QoS. These projects also proved that LRD is due to the transmission of elephant flows using TCP. As a consequence, it has been proposed many times to differentiate the way elephants and mice are managed in the network. However, this decomposition of traffic into elephants and mice do not provide "clear" results as many different behaviors are still mixed in each of these classes. This paper then deals with extending the traffic decomposition approach in order to refine the mice / elephants classification as the many different applications as P2P, streaming, Web, etc. that generate elephants, probably do not match the same traffic model. A volume-based decomposition method is also proposed to further characterize the elephants flow traffic. We expect this analysis to provide information allowing us to isolate classes of applicative flows having a bad negative impact on LRD and thus QoS and helping us understanding how they behave. The application of this traffic decomposition into classes deals with getting indications on how such applicative flows should be managed while transmitted in the network.

## 1 Introduction

Les usages de l'Internet ont connu plusieurs révolutions ces dernières années : d'un réseau pour le simple transfert de données binaires et textuelles sans contraintes de temps ou de débit, l'Internet a connu une première révolution avec l'apparition et la démocratisation du web avec une demande de plus en plus importante en terme de bande passante. De nos jours, les usages imposent des contraintes encore plus fortes, avec l'apparition des applications de "streaming", comme la transmission vidéo en temps réel, de téléphonie sur IP ou de télévision sur Internet. Mais la principale source de trafic dans l'Internet est due aux échanges de fichiers par des applications pair à pair (P2P), notamment pour l'échange de musique ou de films. L'Internet doit donc être capable de fournir aux utilisateurs et leurs applications les qualités de Service (QoS) dont ils ont besoin, et donc d'optimiser l'utilisation des ressources de communication pour y parvenir. L'Internet doit évoluer d'une offre de service "best effort" unique vers une offre multi-services.

Au cours des dix dernières années, la QoS est apparue comme un enjeu majeur dans l'Internet. De nombreuses propositions ont été faites, comme IntServ ou DiffServ, mais jusqu'à présent elles n'ont pas été déployées (ou alors de façon limitée). En effet, les solutions avancées par la communauté Internet pour la mise en place de services différenciés et/ou garantis ne sont pas celles attendues par les utilisateurs ou les opérateurs. L'analyse

de ce constat d'échec fait apparaître un certain nombre de difficultés toujours d'actualité : la complexité de l'Internet et ses nombreuses interconnexions, l'hétérogénéité de ses ressources en terme de technologies mais aussi de dimensionnement ou encore les caractéristiques de son trafic. En effet, l'augmentation de la complexité de l'Internet ainsi que les nouvelles applications aux besoins divers et évolutifs introduisent dans le trafic Internet de nombreuses caractéristiques qui sont très loins des croyances traditionnelles. En particulier, il a été montré que les applications P2P, utilisées pour l'échange de musique ou de films – et donc des données volumineuses – changeaient la distribution des tailles de fichiers, ce qui avait la particularité de créer des propriétés de dépendance longue (LRD) et d'auto-similarité dans le trafic [7] [5]. Cette auto-similarité / LRD se traduit par une variabilité importante du trafic qui nuit à la stabilité et à la qualité des services offerts, et diminue globalement la performance des réseaux [6]. [4] a en particulier montré que cette LRD était due à l'inadéquation de TCP (le protocole de transport principal dans l'Internet) pour le transfert de fichiers volumineux sur des liens à hauts débits, mais également que la LRD peut être un bon paramètre pour qualifier et quantifier la grande variabilité du trafic et par la même la dégradation de QoS / performance.

L'amélioration des architectures et protocoles de l'Internet est ainsi étroitement liée à la connaissance et la compréhension des caractéristiques de son trafic car elles indiquent les types

de mécanismes à déployer pour être en adéquation avec les besoins utilisateurs et les contraintes réseaux. En conséquence, le développement d'outils basés sur la métrologie, de technologies permettant la collecte d'informations dans le trafic Internet ou de méthodes permettant l'analyse de ses caractéristiques est un sujet très important pour les domaines de l'ingénierie et de la recherche en réseau. Par exemple, comme il a été montré que la LRD étaient due à l'inadéquation de TCP pour le transfert de fichiers volumineux, [4] a proposé de différencier les techniques de transmission pour les gros flux (éléphants) et les petits (souris). Cette approche présente néanmoins des limites de mise en œuvre, car avec les interfaces de programmation réseau actuelles, on ne peut pas savoir a priori si le fichier à transmettre va être long ou court.

Il faut donc revenir à une analyse du trafic par application (information disponible au début de chaque session) pour en déduire les applications les plus pénalisantes pour la qualité de service du réseau, et en déduire des mécanismes adaptés pour transmettre les données associées à ces applications... En ciblant plus particulièrement celles qui induisent la transmission d'éléphants sur le réseau. Ce papier présente donc les principaux résultats d'analyse et de caractérisation du trafic obtenus dans le cadre du projet METROPOLIS. Les traces analysées dans ce papier ont été obtenues en utilisant des outils de mesure passive qui collectent les en-têtes TCP/IP de chaque paquet avec une estampille temporelle GPS. Le système de capture est basé sur des cartes DAG [3] développées par la société ENDACE.

La suite de ce papier débute en confirmant les résultats connus sur la contribution respective des éléphants et souris à la LRD globale observée dans le trafic (section 2). Cette analyse sera effectuée en utilisant l'outil MDestimate [1] qui s'appuie sur une décomposition en ondelettes pour une analyse multi-échelles du trafic. Puis, une nouvelle décomposition du trafic éléphant sera proposée. Elle s'appuie sur le type d'application génératrice et analyse le niveau de LRD induit par les éléphants générés par chaque application (sections 3 et 4). Nous espérons que cette analyse apporte des informations nous permettant d'isoler les classes de flux applicatifs qui sont responsables de la LRD et par là même de la dégradation de la QoS du réseau. Ce travail devrait aussi nous donner des indications pour comprendre comment les flux applicatifs doivent être gérés lors de leur transfert dans l'Internet.

## 2 Les limites de la décomposition du trafic en souris / éléphants

L'analyse du trafic Renater que nous avons réalisée depuis 4 années confirme qu'il y a une évolution très forte du trafic en ce qui concerne la taille des flux échangés avec de plus en plus de flux très longs. Dans cette section, nous avons considéré des traces de trafic collectées sur le réseau RENATER (au niveau du point de présence en Midi-Pyrénées au cours du mois de novembre 2003 à partir de 14 H et pendant une heure) que nous avons décomposées en flux souris et éléphants<sup>1</sup>. Nous avons appliqué la méthode de décomposition en ondelettes implémentée dans MDestimate<sup>2</sup> [1] sur ces deux classes de trafic<sup>3</sup>. Les diagrammes de LRD de la figure 1 montrent que le trafic éléphant introduit la plus grande part de LRD dans le trafic global ( $H(\text{éléphant}) > H(\text{trafic global})$ ). D'autre part, le trafic souris

1. Un éléphant est défini comme un flux de plus de 100 paquets et un flux souris comme un flux de moins de 10 paquets.

2. Cet outil permet de calculer le niveau de variabilité présent dans la série analysée pour une gamme d'échelles donnée (appelées plage d'octaves par les auteurs). L'échelle de l'analyse est fonction de la granularité initiale avec laquelle la série a été extraite.

3. Dans notre étude, les échantillons de signal sont des séries de débit et les granularités reposent sur la fenêtre temporelle nécessaire pour calculer les valeurs de débit.

présente plus de LRD que ce qui était attendu : ( $H(\text{trafic souris}) \gg 0,5^4$ ). Ces résultats préliminaires montrent qu'une méthode de caractérisation reposant uniquement sur une décomposition souris et éléphants ne fournit pas des résultats clairs. Le trafic souris n'est pas aussi régulier qu'attendu et la variabilité des éléphants ne peut pas être observée à toute les échelles.

Ainsi, dans la suite nous allons répondre à la question suivante : quel est le type d'application qui génère le plus de LRD dans le trafic Internet actuel ? Pour cela, nous avons besoin de décomposer le trafic Internet des éléphants en différentes classes de trafic de façon à trouver des propriétés plus simples que celles analysées jusqu'à présent. Nous introduisons ainsi dans la prochaine section notre méthode de décomposition du trafic éléphant par type d'application (qui sera exploitable avec les principes architecturaux actuels de l'Internet).

## 3 Analyse de l'impact des principales applications sur la LRD

### 3.1 Méthodologie


Notre méthode de classification applicative du trafic utilise une méthode de détection qui reconnaît la famille applicative de chaque flux en se basant sur les premiers paquets échangés par l'application considérée. A l'aide de cette méthode (et contrairement aux méthodes "classiques" d'analyse des numéros de port) nous sommes capables de reconnaître un trafic échangé sur un numéro de port qui n'est pas traditionnellement dédié à cette application. D'autre part, il est ainsi possible de détecter tout le trafic généré par une application dont les numéros de port changent de façon dynamique. Par exemple, si une application P2P utilise le port 80 (port utilisé en standard par les applications Web) nous pouvons la détecter et classifier ce trafic comme P2P et non du trafic Web. Nous réalisons cette opération en "rejouant" les traces DAG dans le boîtier Traffic Designer de la société QoSmos<sup>5</sup> grâce au logiciel TD Player associé. Traffic Designer est un boîtier permettant l'analyse du trafic, s'appuyant sur une architecture PC et équipé avec une carte Ethernet "bypass". Il permet l'analyse en temps réel du trafic entrant et sortant sur un lien donné et fournit des statistiques macroscopiques sur ce trafic.

Ainsi, nous sommes capables de quantifier précisément la contribution de chaque application à la variabilité globale du trafic et ainsi infirmer ou confirmer les a priori à ce sujet. Par exemple, nous analyserons si un trafic Web "pur" (c'est à dire excluant toutes les applications qui utilisent le protocole HTTP et le port 80 uniquement pour passer les pare-feux) qui génère en majorité des petits flux, génère par la même un trafic avec peu de LRD. D'autre part, les applications P2P qui sont bien connues pour générer des flux très volumineux dans le réseau, seront analysées et nous étudieront dans quelle mesure elles contribuent à dégrader les performances du réseau. Ainsi, nous avons choisi cinq familles d'applications différentes pour caractériser nos traces de trafic. Elles ont été choisies en fonction de leur popularité actuelle dans l'Internet et bien sur, leur capacité à générer un nombre important de flux éléphants :


- Web : trafic généré par tous les navigateurs (IE Explorer, Netscape, Mozilla, Firefox, etc.) ;
- Streaming : trafic temps réel échangé par les applications orientées flux (MediaPlayer, RealPlayer, NetMeeting, etc.) ;
- P2P : trafic échangé par toutes les applications P2P (Edonkey, Emule, Bittorrent, etc.) ;
- Terminal : trafic généré par les terminaux clients comme Telnet ou SSH ;

4. La valeur 0,5 est caractéristique d'un processus sans dépendance.


5. QoSmos est une jeune pousse issue du laboratoire LIP6 à Paris : <http://www.qosmos.fr/EN/home.htm>.



(a) Trafic global



(b) Trafic souris



(c) Trafic éléphants

FIG. 1: Niveau de LRD (mesurée sur les octaves  $> 10$ ) pour le trafic global, souris et éléphant (calcul effectué sur les séries de débit avec une granularité de 1 ms)

- FTP : trafic de données échangé en utilisant le protocole FTP.

### 3.2 Résultats préliminaires

Pour pouvoir obtenir un maximum de classes applicatives différentes dans les données analysées, nous avons considéré dans le cadre de cette étude des traces de trafic collectées en bordure du réseau universitaire du campus de Jussieu. Ces traces sont collectées sur un lien à très haut débit (1 Gbps)<sup>6</sup>. Les premiers résultats (cf. valeurs de LRD<sup>7</sup> de la table 1) calculés pour chaque famille applicative montrent que les tendances intuitives sont confirmées. En effet, les trafics P2P et FTP mettent en évidence un très fort niveau de LRD ainsi qu'une queue de distribution très lourde (cf. figure 2). Cependant, d'autres résultats sont plus surprenants ! En effet, si nous considérons l'exemple du trafic Web collecté sur le réseau Renater nous observons que même si la distribution de la taille des flux du trafic Web n'est pas aussi lourde que la distribution du trafic global, le niveau de LRD est beaucoup plus important. D'autre part, quand nous analysons ce trafic Web nous pouvons observer que 0,00058 % du nombre total de flux Web génère plus de 37,3 % de la quantité totale de données du trafic Web (cf. table 2 pour détails). Ainsi, il apparaît clairement que les clients Web utilisés dans cette trace n'ont pas uniquement servi à charger des pages Web. De plus, nous pouvons affirmer que dans ce cas de figure les clients Web ont été utilisés pour télécharger des grands volumes de données (il s'agit d'une utilisation du protocole HTTP comme un protocole FTP parallèle). Ainsi, en ne considérant qu'une décomposition au niveau applicatif nous ne pouvons pas prendre en compte tous les paramètres qui sont responsables de la LRD du trafic Internet actuel. Cette limitation dans la méthode de classification nous a amené à proposer son évolution que nous présentons dans la section suivante.

## 4 Extension de la méthode d'analyse : caractérisation du niveau de LRD basée sur une décomposition en volume

Aux vues des résultats précédents, nous ne devons pas considérer seulement le type d'application qui génère chaque flux

6. La trace analysée dans cet article a été collectée le 20 janvier 2004 à partir de 14 H et pendant 40 minutes.

7. Certaines valeurs du facteur de Hurst présentées dans ce papier sont supérieures à 1. Il est en théorie impossible d'obtenir de telles valeurs. Néanmoins, cet écart dans l'estimation est dû à l'impossibilité d'obtenir, pour certains types d'applications, des séries de données assez grandes pour réduire suffisamment l'intervalle de confiance et ainsi ne pas dépasser la valeur 1. Néanmoins, notre objectif est de réaliser une comparaison entre les différents niveaux de LRD des différentes applications considérées. Cette comparaison reste en effet possible car une valeur de H très grande (i.e. même supérieure à 1) traduit toujours la présence d'un fort comportement dépendant à long terme.





FIG. 2: Distribution de la taille des flux pour chaque famille applicative – diagramme Log-Log


Famille applicative	Niveau de LRD (valeur de Hurst)
Trafic Web	0.905
Trafic P2P	1.010
Trafic Terminal	1.15
Trafic FTP	1.245

TAB. 1: LRD des flux éléphants en fonction de leur famille d'application (calcul effectué sur les séries de débit avec une granularité de 1 ms et pour la gamme d'échelles représentée par les octaves  $> 10$ )


éléphant mais nous allons plutôt prendre en compte les comportements que les applications mettent en œuvre quand elles envoient ce type de flux dans le réseau. Pour cela, nous considérons deux nouvelles métriques : la durée et la quantité de données échangées pour chaque flux analysé. De plus, nous avons analysé la contribution en LRD pour l'ensemble des familles applicatives définies dans la section 3 et ainsi, nous sommes capables de conclure sur l'impact des très longs flux en terme de durée (cf. table 3) ou de quantité de données échangées (cf. table 4). Il apparaît que seule la taille des flux a un impact important sur l'augmentation de la LRD du trafic. En effet, le seul paramètre durée des flux ne fait pas varier de façon significative la LRD du trafic associé. Dès lors, une décomposition en volume basée sur la taille des flux a été appliquée en particulier, sur la famille de trafic P2P : les résultats obtenus sont très intéressants. Si nous considérons la famille de trafic P2P et deux sous-classes différentes de ce trafic (les très longs flux en termes de quantité (i.e. leur taille en octets) de données échangées – ceux générés par une version ancienne d'un client P2P : Kazaa – et les autres – générés par un client P2P plus



(a) Niveau de LRD du trafic éléphant Kazaa



(b) Niveau de LRD du trafic éléphant E-donkey



(c) Distribution de la taille des flux P2P

FIG. 3: Résultats concernant les éléphants de la famille P2P (analyse de la série de débit avec une granularité de 1 ms et pour la gamme d'échelles représentée par les octaves > 10)

	Volume (%)	Nombre de flux (%)	Niveau de LRD (valeur de Hurst)
Trafic Web total	14,4 Goctets (100 %)	1.167.579 (100 %)	H = 0,905
Trafic généré par les flux Web les plus volumineux (taille > 1 Moctets)	5,31 Goctets (37,3 %)	679 (0,00058 %)	H = 1,011
Trafic généré par les 100 flux les plus volumineux	3,99 Goctets (27,7 %)	100 (0,000086 %)	H = 1,201

TAB. 2: Détails de la contribution de la taille des flux sur la LRD des flux éléphants de la famille Web (calcul effectué sur les séries de débit avec une granularité de 1 ms et pour la gamme d'échelles représentée par les octaves > 10)

Durée du flux	Volume total (GOctets)	Pourcentage du Volume total (%)	Niveau de LRD (H)
> à 0 seconde	43,4	100 %	0,855
> à 60 secondes	29,6	68,2 %	0,826
> à 600 secondes	24,5	56,5 %	0,803
> à 3000 secondes	13,3	30,6 %	0,812

TAB. 3: Contribution de la durée des flux sur la LRD du trafic éléphant pour l'ensemble des familles applicatives (calcul effectué sur les séries de débit avec une granularité de 1 ms et pour la gamme d'échelles représentée par les octaves > 10)

récent : E-donkey ) nous pouvons noter deux niveaux différents de LRD pour chaque sous-classe considérée dans le trafic de la famille P2P (cf. les figures 3(a) et 3(b) où  $LRD(Kazaa) > LRD(E-donkey)$ ). Ces valeurs de LRD sont fonctions du degré de queue-lourde de la distribution de leur taille de flux. En effet, la figure 3(c) met en évidence le principe de E-donkey et son impact sur le trafic : cette application découpe les très longs flux en plus petits flux (appelés "mini-éléphants" par [2]) et ainsi la distribution de la taille de flux est réellement moins lourde que celle de Kazaa.

Taille du flux (MOctets)	Volume total (GOctets)	Pourcentage du Volume total (%)	Niveau de LRD (H)
> 0	43,4	100 %	0,855
Entre 1 et 10	6,36	15,1 %	0,814
Entre 10 et 50	5,34	12,3 %	0,834
Entre 50 et 100	1,91	4,4 %	0,873
Entre 100 et 300	5,39	12,4 %	1,03
> 300	14,1	32,5 %	1,07

TAB. 4: Contribution de la taille des flux sur la LRD du trafic éléphant pour l'ensemble des familles applicatives (calcul effectué sur les séries de débit avec une granularité de 1 ms et pour la gamme d'échelles représentée par les octaves > 10)

## 5 Conclusion

Dans nos travaux futurs, nous allons étendre ces résultats de caractérisation pour tous les types de famille d'application. Ainsi, nous allons appliquer cette méthode basée sur une décomposition en fonction du volume sur chaque type de famille de trafic présentées dans la section 3. D'autre part, nous aurons à analyser en détail les résultats basés sur la décomposition de niveau applicatif, pour ainsi caractériser en détail les autres familles de trafic. Nous attendons de ce travail de caractérisation et d'analyse qu'il nous fournisse des informations intéressantes pour permettre le développement d'architectures et de protocoles permettant de mieux gérer ces flux, pour réduire la LRD et la variabilité du trafic et ainsi optimiser l'utilisation des ressources réseaux et la QoS. Par exemple, nous avons déjà pu confirmer que segmenter les très longs flux applicatifs (comme le fait E-donkey) est une approche appropriée pour réduire la LRD dans l'Internet.

## Références

- [1] P. Abry and D. Veitch, *Wavelet Analysis of Long Range Dependent Traffic*, Transaction on Information Theory, Vol.44, No.1, January 1998.
- [2] N. Ben Azzouna and F. Guillemin, *Analysis of ADSL traffic on an IP backbone link*, In Proc. Globecom 2003, San Francisco, December 2003.
- [3] J. Cleary, S. Donnely, I. Graham, A. McGregor and M. Pearson, *Design principles for accurate passive measurement*, PAM (Passive and Active Measurements) Workshop, Hamilton, New Zealand, April 2000.
- [4] P. Owezarski, N. Larrieu, *Internet traffic characterization - An analysis of traffic oscillations*, 7th IEEE International Conference on High Speed Networks and Multimedia Communications (HSNMC'2004), Toulouse, France, July 2004.
- [5] K. Park, G. Kim, M. Crovella, *On the relationship between file sizes, transport protocols, and self-similar network traffic*, IEEE ICNP, 1996.
- [6] K. Park, G. Kim and M. Crovella, *On the Effect of Traffic Self-similarity on Network Performance*, SPIE International Conference on Performance and Control of Network Systems, November, 1997.
- [7] W. Willinger, M. Taqqu, R. Sherman and D. Wilson, *Self-similarity through highvariability: statistical analysis of Ethernet LAN traffic at the source level*, In ACM Sigcomm'95, pages 100-113, 1995.