

Dynamique de la topologie de l'Internet

Clémence Magnien

clemence.magnien@lip6.fr

LIP6 – CNRS et Université Pierre et Marie Curie (UPMC – Paris 6)

avec Matthieu Latapy, Frédéric Ouédraogo, Guillaume Valadon, Assia Hamzaoui, ...

Outline

- 1 Contexte et approche
- 2 Outil
 - Outil
 - Paramètres
- 3 Mesures
- 4 Analyse
 - Analyses élémentaires
 - Évolution des adresses IP observées
 - Détection d'événements


Topologie de l'Internet au niveau IP

- Adresses IP
- Sauts au niveau IP

—→ Internet vu comme un **graphe**,
étude de la **structure**


Mesure avec traceroute

Pas de carte disponible → Besoin de **mesurer**



Mesure avec traceroute

Pas de carte disponible $\longrightarrow$ Besoin de **mesurer**




Mesure avec traceroute

Pas de carte disponible → Besoin de **mesurer**




Mesure avec traceroute

Pas de carte disponible $\longrightarrow$ Besoin de **mesurer**




Mesure avec traceroute

Pas de carte disponible $\longrightarrow$ Besoin de **mesurer**




Mesure avec traceroute

Pas de carte disponible $\longrightarrow$ Besoin de **mesurer**




Mesure avec traceroute

Pas de carte disponible $\longrightarrow$ Besoin de **mesurer**



Mesure avec traceroute

Pas de carte disponible $\longrightarrow$ Besoin de **mesurer**



Mesure avec traceroute

Pas de carte disponible → Besoin de **mesurer**

Plus d'informations

Multiplier

- Les destinations (~ 1 million)
- Les sources ($\sim$ quelques dizaines)

Propriétés inattendues

[Sigcomm 99, Infocom 00, Science 99, ...]

Propriétés inattendues et importantes

Degrés des nœuds (nombre de liens) hétérogènes

Distributions hétérogènes

Distribution des degrés :


4 nœuds, degrés : 2 3 3 1

Distributions hétérogènes

Distribution des degrés :

4 nœuds, degrés : 2 3 3 1

Distribution : $1 \rightarrow 1, 2 \rightarrow 1, 3 \rightarrow 2$.



Distributions hétérogènes

Deux grands types de distribution

Homogène


Hétérogène

Homogène : valeurs centrées sur la moyenne

Hétérogène : pas de notion de valeur **typique**

Distributions hétérogènes

Échelle logarithmique



Proche d'une droite (**loi de puissance**, décroissance polynômiale)

Propriétés inattendues

[Sigcomm 99, Infocom 00, Science 99, ...]

Propriétés inattendues et importantes

Degrés des nœuds (nombre de liens) hétérogènes

Conséquences sur


- La robustesse
- La propagation de virus
- ...

Actuellement : courant de travaux visant à cartographier l'internet

Propriétés observées vs réelles

[Infocom 02, Infocom 03, STOC 05, ...]

Une source, beaucoup de destinations :



Propriétés observées vs réelles

[Infocom 02, Infocom 03, STOC 05, ...]

- biais sur la **structure observée**
- Travaux théoriques et empiriques pour :
- Évaluer le biais
 - Évaluer de façon sûre certaines propriétés

Problèmes des outils de mesure


Traceroute → Information manquante ou fausse

- Machines ne répondant pas aux sondes apparaissent comme des étoiles *
- Faux liens

Problèmes des outils de mesure

Traceroute → Information manquante ou fausse


- Machines ne répondant pas aux sondes
- Faux liens



Problèmes des outils de mesure

Traceroute → Information manquante ou fausse


- Machines ne répondant pas aux sondes
- Faux liens



Problèmes des outils de mesure

Traceroute → Information manquante ou fausse


- Machines ne répondant pas aux sondes
- Faux liens



Problèmes des outils de mesure

Traceroute → Information manquante ou fausse


- Machines ne répondant pas aux sondes
- Faux liens



Problèmes des outils de mesure

Traceroute → Information manquante ou fausse

- Machines ne répondant pas aux sondes
- Faux liens



Problèmes des outils de mesure

Traceroute → Information manquante ou fausse

- Machines ne répondant pas aux sondes
- Faux liens

→ Travaux visant à améliorer les outils de mesure

- Augmenter l'information récoltée
- Améliorer la fiabilité

Résumé

Cartographie au niveau IP

Long et coûteux

Tendances actuelles

- Données massives
(multiplier sources et destinations, mesures distribuées, ...)
- Améliorer la qualité

Dynamique ?

Notre approche

Ce qu'une machine voit de l'internet est :

- intéressant en soi
- (plus) facile à mesurer
- (plus) facile à interpréter
- peut être mesuré efficacement (temps, charge)

notion de vision **égo-centrée**

Mesure efficace + simple $\implies$ Répétition

étude de la dynamique

Radar

une source, des destinations, mesures périodiques

Notre approche

Ce qu'une machine voit de l'internet est :

- intéressant en soi
- (plus) facile à mesurer
- (plus) facile à interpréter
- peut être mesuré efficacement (temps, charge)

notion de vision **égo-centrée**

Mesure efficace + simple $\implies$ Répétition

étude de la dynamique

Radar

une source, des destinations, mesures périodiques

Notre approche

Ce qu'une machine voit de l'internet est :

- intéressant en soi
- (plus) facile à mesurer
- (plus) facile à interpréter
- peut être mesuré efficacement (temps, charge)

notion de vision **égo-centrée**


Mesure efficace + simple $\implies$ Répétition

étude de la dynamique


Radar

une source, des destinations, mesures périodiques

Vue égo-centrée



Vue égo-centrée



Limites de traceroute

- **charge déséquilibrée**
⇒ **information redondante**
- **pas un arbre**
⇒ **complique l'analyse**


↪ **nécessité d'un outil dédié**
tracertree

Limites de traceroute

- **charge déséquilibrée**
⇒ **information redondante**
- **pas un arbre**
⇒ **complique l'analyse**


↪ **nécessité d'un outil dédié**
tracertree

Tracetree




mesures **en arrière**, en parallèle
arrêt quand les chemins se rejoignent

Tracetree




mesures **en arrière**, en parallèle
arrêt quand les chemins se rejoignent

Tracetree



mesures **en arrière**, en parallèle
arrêt quand les chemins se rejoignent

Tracetree



mesures **en arrière**, en parallèle
arrêt quand les chemins se rejoignent

Tracetree

- 1 paquet par lien
- mesure homogène et rapide
- arbre

→ programme disponible, écrit en C.

Radar

- Une source
- Un ensemble de destinations
- Mesures périodiques avec tracetree


Tracetree : mêmes problèmes que traceroute pour la qualité de la mesure

Radar


- Une source
- Un ensemble de destinations
- Mesures périodiques avec tracetree

Tracetree : mêmes **problèmes** que traceroute pour la qualité de la mesure

tracetree vs traceroute : comparaison empirique




tracetree vs traceroute : comparaison empirique



$x = \text{nb de passes}$, $y = \text{nb d'adresses IP}$

tracetree vs traceroute : comparaison empirique



$x = \text{nb de passes}$, $y = \text{nb d'adresses IP}$

Paramètres

Plusieurs paramètres

Quelles sources / destinations ?

Combien de destinations ?

Délai entre passes ?

Timeout ?

...

Compromis

Haute fréquence

Grande quantité de données

Faible charge sur le réseau

Nos mesures

Deux **ensembles de paramètres** :

- *normal* : 3000 destinations, 10 min. délai entre passes,
TTL max 30, ... ~ 100 passes / jour
- *rapide* : 1000 destinations, 1 min. délai entre passes,
TTL max 15, ... > 800 passes / jour

Sources : PlanetLab et autres (> 100)

Destinations : Aléatoires, répondant au ping

Plusieurs mois de mesure ininterrompue
Données disponibles pour étude

Nos mesures

Deux **ensembles de paramètres** :

- *normal* : 3000 destinations, 10 min. délai entre passes,
TTL max 30, ... ~ 100 passes / jour
- *rapide* : 1000 destinations, 1 min. délai entre passes,
TTL max 15, ... > 800 passes / jour

Sources : PlanetLab et autres (> 100)

Destinations : Aléatoires, répondant au ping

Plusieurs mois de mesure ininterrompue
Données disponibles pour étude

Outline

- 1 Contexte et approche
- 2 Outil
 - Outil
 - Paramètres
- 3 Mesures
- 4 Analyse
 - Analyses élémentaires
 - Évolution des adresses IP observées
 - Détection d'événements

Analyse

Quelle dynamique ?

Pour :

- mieux comprendre
- modéliser, simuler
- détecter des événements
- ...

Comment répondre à cette question ?

Pas de méthode toute faite

Analyse

Quelle dynamique ?

Pour :

- mieux comprendre
- modéliser, simuler
- détecter des événements
- ...

Comment répondre à cette question ?

Pas de méthode toute faite

Étude d'une passe

Variations en fonction :

- de la source
- du moment

Quelques tendances générales

- ~ 12 000 IP
- ~ 12 000 étoiles
- la plupart des nœuds à distance 13-18

On observe toujours le même **type** de comportements

Étude d'une passe

Variations en fonction :

- de la source
- du moment

Quelques tendances générales

- ~ 12 000 IP
- ~ 12 000 étoiles
- la plupart des nœuds à distance 13-18

On observe toujours le même **type** de comportements


Propriétés simples au fil du temps

Première approche :

Évolution de propriétés simples au fil du temps


- nombre d'IP
- nombre d'étoiles
- durée des passes
- ...

Propriétés simples au fil du temps



- source au Japon
- deux mois de mesures
- $\sim 6\,000$ passes

Propriétés simples au fil du temps



- Plus ou moins constant
- Pics vers le bas → déconnexions ?
- Pas de pics vers le haut


Présence des IP

Distribution du nombre de présences

Toutes les IP vues pendant la mesure ($\sim 29\,000$)
Pour chaque IP : **nombre de passes** où on l'a vue
→ Distribution


Présence des IP

2 mois ~ 6000 passes




Présence des IP

1 mois $\sim$ 3000 passes



Présence des IP


2 mois ~ 6000 passes — Échelle log-log



hétérogène → pas de valeur typique


Présence des IP

1 mois $\sim$ 3000 passes — Échelle log-log



hétérogène $\rightarrow$ pas de valeur typique


Dynamique : stabilisation ?



nouvelles IP observées en permanence


Disparitions

Nombre d'IP distinctes qu'on ne verra plus jamais




Renouvellement continu des IP observées


Influence des IP vues une seule fois ?




Influence des IP vues une seule fois ?




Influence des IP vues une seule fois ?



Influence des IP vues une seule fois ?



Influence des IP vues une seule fois ?




Autonomous Systems

Autonomous System (AS) : institution indépendante

Chaque IP est dans un AS

→ Nombre d'**AS** vus depuis le début de la mesure

Autonomous Systems



Routeviews

Projet Routeviews

Nombreux moniteurs

Historique des tables de routage

Routeviews

Simulation du radar au niveau AS

Moniteur **proche** de la source

Table de routage

4.23.112.0/24	4777 2516 215 17132
	7500 2497 215 17132
4.23.113.0/24	4777 2516 324 21889
	7500 2497 324 21889
	2497 174 21889
4.23.114.0/24	4812 3015 174 5313
	7500 2497 174 5313

Routeviews

Simulation du radar au niveau AS

Moniteur **proche** de la source

Destination → **préfixe**

Table de routage

4.23.112.0/24	4777 2516 215 17132
	7500 2497 215 17132
4.23.113.0/24	4777 2516 324 21889
	7500 2497 324 21889
	2497 174 21889
4.23.114.0/24	4812 3015 174 5313
	7500 2497 174 5313

Routeviews

Simulation du radar au niveau AS

Moniteur **proche** de la source


Destination → **préfixe**

→ ensemble de **chemins d'AS**


Table de routage

4.23.112.0/24	4777 2516 215 17132
	7500 2497 215 17132
4.23.113.0/24	4777 2516 324 21889
	7500 2497 324 21889
	2497 174 21889
4.23.114.0/24	4812 3015 174 5313
	7500 2497 174 5313

Routeviews



Routeviews



Nouveaux AS ?

AS observés après le début de la mesure (72)

→ Nouveaux ?


Historique des tables de routage

70 AS dans la première table de routage

Observations dûes à la dynamique BGP


Tous les AS sont-ils équivalents ?

Distribution de la taille observée



Nouveautés à l'intérieur des AS ?

Plus gros AS : 1333 IP



Conclusion sur les apparitions d'IP

Renouvellement continu des IP observées


- pour les IP volatiles
- pour les IP stables

Nouvelles IP observées


- à l'intérieur des AS déjà vus
- dans des AS nouvellement observés

Observation de nouveaux AS ← dynamique BGP

Présences vs apparitions




Présences vs apparitions



Triangle : $\text{Nb apparitions} \leq \max(\text{nb présences}, \text{nb absences})$


Présences vs apparitions



Parabole : Nombre d'apparitions attendues en moyenne pour ce nombre de présences

$$x(1 - x)$$


Présences vs apparitions




Trois classes d'IP

clignotent || aléatoires || majorité de stables

Détection d'événements



Détection d'événements




pics → **identification d'événements**

Identification formelle des pics ?

Pic → valeur significativement plus grande que les autres.
Moyen de les identifier **formellement** ?


Identification formelle des pics ?

Distribution des valeurs observées
Nombre d'IP par passe




Identification formelle des pics ?

Distribution **cumulative** des valeurs observées
Nombre d'IP par passe




Identification formelle des pics ?

Distribution cumulative des valeurs observées
Nombre d'IP dans 5 passes consécutives



Valeurs hautes atypiques

Visualisation d'un événement



Conclusion

- méthodes pour comprendre la **dynamique**
 - propriétés inattendues, complexes
 - identification d'événements
-
- propriétés de la dynamique, analyse
 - normal vs événement
 - échelle(s) de temps pertinente(s)
 - visualisation(s)
 - modélisation
 - ...

Conclusion

- méthodes pour comprendre la **dynamique**
- propriétés inattendues, complexes
- identification d'événements

- propriétés de la dynamique, analyse
- normal vs événement
- échelle(s) de temps pertinente(s)
- visualisation(s)
- modélisation
- ...