

Structure et Dynamique des Réseaux

Métrologie de la topologie de l'internet

Clémence Magnien, Lionel Tabourier, Fabien Tarissan

LIP6 – CNRS and Université Pierre et Marie Curie

`prenom.nom@lip6.fr`

1 Introduction

2 Métrologie

- Influence des sources et des destinations
- Biais sur les degrés

Outline

1 Introduction

2 Métrologie

- Influence des sources et des destinations
- Biais sur les degrés

Topologie de l'internet

Exploration : traceroute

Quelques sources, bcp de destinations :

- On sait qu'on ne voit pas tout
- Vue représentative ? (→ **biais ?**)

Distribution des degrés

Une propriété dont on a beaucoup parlé :


Distribution des degrés de l'internet en **loi de puissance**

[Pansiot, Grad, 1998
Faloutsos, Faloutsos, Faloutsos, 1999]

Loi de puissance (power-law)

Loi de puissance

- $N_k \sim k^{-\alpha}$
- droite en échelle log-log



Distributions normalisées

Distribution des degrés, deux choix :

- N_k : nombre de sommets de degré k
- p_k : fraction de sommets de degré k



→ Distribution normalisée

$$p_k = \frac{N_k}{n}$$

Permet de comparer des graphes de tailles différentes

Distribution cumulative inverse



- N_k : nombre de nœuds de degré égal à k
- C_k : nombre de nœuds de degré inférieur ou égal à k



Échelle **linéaire**

Distribution cumulative inverse

- N_k : nombre de nœuds de degré égal à k
- C_k : nombre de nœuds de degré inférieur ou égal à k



Échelle log-log

Distribution cumulative inverse

- N_k : nombre de nœuds de degré égal à k
- C_k : nombre de nœuds de degré inférieur ou égal à k

Échelle

Distributions homogènes/hétérogènes

- Se distingue sur la distribution normale ou cumulative

Ex : loi de puissance

- $N_k \sim k^{-\alpha} \implies C_k \sim k^{-\alpha+1}$

Distribution des degrés observée **surprenante** → **biais ?**

Conséquences :

Diminuer le biais

Mesure depuis un plus grand nombre de sources

Estimer le biais

Études théoriques et expérimentales

Outline

1 Introduction

2 Métrologie

- Influence des sources et des destinations
- Biais sur les degrés

Outline

1 Introduction

2 Métrologie

- Influence des sources et des destinations
- Biais sur les degrés

Multiplier les sources et les destinations

Intérêt d'utiliser plusieurs sources et destinations

- Quantité d'information ?
- Diminution du biais ?

Quantité d'information

[On the Marginal Utility of Network Topology Measurements
Barford, Bestavros, Byers, Crovella, 2001]

Idée

- Utiliser des données issues de mesures (vs simulation)
- Estimer le nombre de nœuds/liens vus en fonction du nombre de sources/destinations

Données

Deux jeux de données

- 8 sources
- 1277 destinations
- 1 traceroute toute les 30 minutes
- 7 mois (?)

- 12 sources
- > 300 000 destinations
- même méthode de mesure
- durée ?

Données

Note :

Intérêt de répéter les mesures ?

Load-balancing, ...

→ répéter donne plus d'informations

Plus de détails dans le prochain cours

Méthodologie

Estimer le **nombre de nœuds** vus en fonction :

- du nombre de sources
- du nombre de destinations

s sources, d destinations


→ $s \times d$ valeurs possibles

Beaucoup d'informations

Interprétation ?


Méthodologie

Ce qu'on veut :




Méthodologie

Ce qu'on veut :



même chose pour les destinations

Problème



Nombre d'IP vues avec 3 sources : **quelles** 3 sources ?

Exemple

une source \rightarrow ensemble des IP vues

Exemple

$$s_1 : \{a, b, c, d, e\}$$

$$s_2 : \{a, b, c, d, f\}$$

$$s_3 : \{a, b\}$$

$$s_4 : \{g, h\}$$

$$s_5 : \{i, j, k\}$$

$$s_6 : \{a, d\}$$

$$s_1 + s_3 + s_6 \rightarrow 5 \text{ IP}$$

$$s_1 + s_4 + s_5 \rightarrow 10 \text{ IP}$$

Pas de choix naturel

Exemple

une source \rightarrow ensemble des IP vues

Exemple

$$s_1 : \{a, b, c, d, e\}$$

$$s_2 : \{a, b, c, d, f\}$$

$$s_3 : \{a, b\}$$

$$s_4 : \{g, h\}$$

$$s_5 : \{i, j, k\}$$

$$s_6 : \{a, d\}$$

$$s_1 + s_3 + s_6 \rightarrow 5 \text{ IP}$$

$$s_1 + s_4 + s_5 \rightarrow 10 \text{ IP}$$

Pas de choix naturel

Stratégie gloutonne

À chaque étape :
ajouter la source qui ajoute **le plus** d'informations

Exemple

$s_1 : \{a, b, c, d, e\}$

$s_2 : \{a, b, c, d, f\}$

$s_3 : \{a, b\}$

$s_4 : \{g, h\}$

$s_5 : \{i, j, k\}$

$s_6 : \{a, d\}$

Stratégie gloutonne

À chaque étape :
ajouter la source qui ajoute **le plus** d'informations

Exemple

$s_1 : \{a, b, c, d, e\}$

$s_2 : \{a, b, c, d, f\}$

$s_3 : \{a, b\}$

$s_4 : \{g, h\}$

$s_5 : \{i, j, k\}$

$s_6 : \{a, d\}$

1 sources : s_1

Stratégie gloutonne

À chaque étape :
ajouter la source qui ajoute **le plus** d'informations

Exemple

$s_1 : \{a, b, c, d, e\}$

$s_2 : \{a, b, c, d, f\}$

$s_3 : \{a, b\}$

$s_4 : \{g, h\}$

$s_5 : \{i, j, k\}$

$s_6 : \{a, d\}$

2 sources : $s_1 s_5$

Stratégie gloutonne

À chaque étape :
ajouter la source qui ajoute **le plus** d'informations

Exemple

$s_1 : \{a, b, c, d, e\}$

$s_2 : \{a, b, c, d, f\}$

$s_3 : \{a, b\}$

$s_4 : \{g, h\}$

$s_5 : \{i, j, k\}$

$s_6 : \{a, d\}$

3 sources : $s_1 s_5 s_4$

Stratégie gloutonne

À chaque étape :
ajouter la source qui ajoute **le plus** d'informations

Exemple

$s_1 : \{a, b, c, d, e\}$

$s_2 : \{a, b, c, d, f\}$

$s_3 : \{a, b\}$

$s_4 : \{g, h\}$

$s_5 : \{i, j, k\}$

$s_6 : \{a, d\}$

4 sources : $s_1 s_5 s_4 s_2$

Stratégie gloutonne

À chaque étape :
ajouter la source qui ajoute **le plus** d'informations

Exemple

$s_1 : \{a, b, c, d, e\}$

$s_2 : \{a, b, c, d, f\}$

$s_3 : \{a, b\}$

$s_4 : \{g, h\}$

$s_5 : \{i, j, k\}$

$s_6 : \{a, d\}$

5 sources : $s_1 s_5 s_4 s_2 s_3$

Stratégie gloutonne

À chaque étape :
ajouter la source qui ajoute **le plus** d'informations

Exemple

$s_1 : \{a, b, c, d, e\}$

$s_2 : \{a, b, c, d, f\}$

$s_3 : \{a, b\}$

$s_4 : \{g, h\}$

$s_5 : \{i, j, k\}$

$s_6 : \{a, d\}$

6 sources : $s_1 s_5 s_4 s_2 s_3 s_6$

Stratégie gloutonne

À chaque étape :
ajouter la source qui ajoute **le plus** d'informations

Exemple

$s_1 : \{a, b, c, d, e\}$

$s_2 : \{a, b, c, d, f\}$

$s_3 : \{a, b\}$

$s_4 : \{g, h\}$

$s_5 : \{i, j, k\}$

$s_6 : \{a, d\}$

sources : $s_1 s_5 s_4 s_2 s_3 s_6$

Motivation : “meilleur” des cas

Complexité

Union de deux ensembles

complexité minimum : taille du plus petit
(dépend de l'implémentation)

Deuxième étape

calcul de $n - 1$ unions

→ $(n - 1) \times k$ si tous les ensembles ont taille k .

À l'étape i

$n - i$ unions

→ $(n - i) \times k$

Complexité

À l'étape i


$n - i$ unions

$\rightarrow (n - i) \times k$


$$\begin{aligned} &k(n - 1 + n - 2 + \dots + 2 + 1) \\ &= \frac{kn(n-1)}{2} \\ &\mathcal{O}(kn^2) \end{aligned}$$

Long si on a un grand nombre de sources

Résultats



Résultats



Observations

Convergence de la courbe :
les dernières sources n'apportent quasiment pas d'informations →
marginal utility

à discuter plus tard

Utilité des destinations

Dans l'idéal, approche inverse :

Chaque destination \rightarrow ensemble des IP vues

Stratégie gloutonne coûteuse

\rightarrow stratégie aléatoire


Pour une source

À chaque étape :

- Rajouter une destination au hasard

Comparer les courbes pour toutes les sources

Résultats



Observations

Croissance **linéaire** :
apport *similaire* pour toutes les destinations

Différence entre sources et destinations

Différence entre les courbes

→ **différence** entre les sources et les destinations ?

s sources, d destinations $\iff d$ sources, s destinations

→ Importance de la **stratégie** utilisée pour les courbes

gloutonne, aléatoire

Différence entre sources et destinations

Différence entre les courbes

→ **différence** entre les sources et les destinations ?

s sources, d destinations $\iff d$ sources, s destinations

→ Importance de la **stratégie** utilisée pour les courbes

gloutonne, aléatoire

Différence entre sources et destinations

Différence entre les courbes

→ **différence** entre les sources et les destinations ?

s sources, d destinations $\iff d$ sources, s destinations

→ Importance de la **stratégie** utilisée pour les courbes

gloutonne, aléatoire

Critiques

Papier intéressant, mais :

Manque de détails sur :


→ disparité entre les sources

(une source voit seulement 184 nœuds (> 4000 pour la plus grande))

→ influence de la stratégie

Question : **choix** des sources plus important que le **nombre** ?

Critiques



Dernières sources : peu d'apport en soi

La stratégie gloutonne conditionne l'allure de la courbe

pas de stratégie naturelle

Pour mieux comprendre

Comparer les différentes stratégies

Données

[Ouédraogo, Magnien, 2009]

Données

- 11 sources
- 3 000 destinations
- 100 traceroutes par jour
- ~ 2 mois

Différence entre les sources

Nombre d'IP vues par sources

Varie entre :

- ~ 16 500
- ~ 26 500

Toutes les sources ne sont pas **équivalentes**

Influence des sources ou des destinations

Trois stratégies naturelles

- gloutonne
- aléatoire
- gloutonne-min

ajouter la source qui apporte **le moins** d'information

Influence des sources ou des destinations

Stratégie gloutonne \neq maximum possible avec k sources

Exemple

$s_1 : \{a, b, c, d, e\}$

$s_2 : \{a, b, e, f\}$

$s_3 : \{a, c, d, g\}$

Influence des sources ou des destinations

Stratégie gloutonne \neq maximum possible avec k sources

Exemple

$s_1 : \{a, b, c, d, e\}$

$s_3 : \{a, c, d, g\}$

$s_2 : \{a, b, e, f\}$

1 sources : s_1

Influence des sources ou des destinations

Stratégie gloutonne \neq maximum possible avec k sources

Exemple

$s_1 : \{a, b, c, d, e\}$

$s_3 : \{a, c, d, g\}$

$s_2 : \{a, b, e, f\}$

2 sources : $s_1 s_2$

Influence des sources ou des destinations

Stratégie gloutonne \neq maximum possible avec k sources

Exemple

$s_1 : \{a, b, c, d, e\}$

$s_3 : \{a, c, d, g\}$

$s_2 : \{a, b, e, f\}$

3 sources : $s_1 s_2 s_3$

Influence des sources ou des destinations

Stratégie gloutonne \neq maximum possible avec k sources

Exemple

$s_1 : \{a, b, c, d, e\}$

$s_3 : \{a, c, d, g\}$

$s_2 : \{a, b, e, f\}$

3 sources : $s_1 s_2 s_3$

$s_2 + s_3 : 7$ IP

Représentativité du maximum ?

Coût du calcul du maximum

Influence des sources ou des destinations

Autres stratégies

- Max → **max** sur 1000 ordres aléatoires
- Min → **min** sur 1000 ordres aléatoires
- Aléatoire → **moyenne** sur 1000 ordres aléatoires


Influence des sources ou des destinations

Exemple

 $s_1 : \{a, b, c, d, e\}$ $s_2 : \{a, b, c, d, f\}$ $s_3 : \{a, b\}$ $s_4 : \{g, h\}$ $s_5 : \{i, j, k\}$ $s_6 : \{a, d\}$


	s_3	s_4	s_6	s_5	s_2	s_1
	2	4	5	8	10	11
<hr/>						
	s_5	s_6	s_2	s_4	s_3	s_1
	3	5	7	9	10	11
<hr/>						
Min	2	4	5	8	10	11
Max	3	5	7	9	10	11
Moyenne	2.5	4.5	6	8.5	10	11

Résultats



Influence des sources

Résultats



Influence des destinations

Observations

- Toutes les courbes finissent au même point : n
- Glouton + moyenne : comportements similaires pour les sources et les destinations
- Variabilité plus grande en pratique pour les sources

Peu de sources

Conclusion

Utilité diminue, ne devient pas nulle

Choix des sources peut-être plus important que le nombre

Outline

1 Introduction

2 Métrologie

- Influence des sources et des destinations
- Biais sur les degrés

Biais lié à l'exploration

[Sampling Biases in IP Topology Measurements
Lakhina, Byers, Crovella, Xie, 2003]

Principe : simulations

- Générer des graphes → topologie
- Simuler des traceroute → mesure
- Observer les résultats

Caractère **explicatif**

Implémentation

Générer des graphes

- Aléatoires → Erdős-Rényi
- Degrés fixés → modèle de configurations

Implémentation – traceroute

Comment **simuler** traceroute ?
Plusieurs possibilités

Implémentation – traceroute

Comment **simuler** traceroute ?
Plusieurs possibilités

Choix courants

- route = plus court chemin (faux mais on n'a pas mieux)

Plus court chemin

- Un seul/tous les plus courts chemins ?
- Si un seul, lequel ?

Choix des auteurs

Associer un **poids** à chaque lien (\rightarrow graphe **pondéré**)

$$1 + \epsilon, \epsilon \in [-1/n, 1/n]$$

Longueur d'un chemin : **somme des poids** des liens

\rightarrow Tous les chemins ont des longueurs différentes


Choix des auteurs

Associer un **poids** à chaque lien (\rightarrow graphe **pondéré**)

$$1 + \epsilon, \epsilon \in [-1/n, 1/n]$$


Longueur d'un chemin : **somme des poids** des liens

\rightarrow Tous les chemins ont des longueurs différentes



Calcul du plus court chemin pondéré

Parcours en largeur **pas adapté**



→ Algorithme de **Dijkstra** (pas détaillé ici)

Notre choix – parcours en largeur

Pas de poids


Distances calculées par parcours en largeur

Stockage de la sortie d'un parcours → tableau

La case i contient le **père**
de i

Le père de la **racine** est
la **racine** elle-même

0	0	1	4	0	0	5	4
0	1	2	3	4	5	6	7



Restreindre aux destinations


Tableau initialisé à -1

Pour chaque destination d :

- Tant que $AR[d] == -1$
 - $AR[d] = A[d]$
 - $d = A[d]$

A							
0	0	1	4	0	0	5	4
0	1	2	3	4	5	6	7

AR							
0	0	-1	4	0	0	5	-1
0	1	2	3	4	5	6	7



Calcul des degrés

Degré d'un nœud dans l'arbre des parcours en largeur :
nombre de fois où il apparaît + 1

(**racine** : nombre de fois -1)

0	0	-1	4	0	0	5	-1
0	1	2	3	4	5	6	7

(cases à -1 : nœuds qui ne sont pas dans l'arbre)

Plusieurs sources

Plusieurs sources :


un parcours en largeur **par source**

Comment calculer le degré des nœuds ?

Marquer les liens comme **présents** ou **absents**

Plusieurs sources

Allocation d'une structure graphe identique



- 0 : lien absent
- 1 : lien présent

Pour chaque lien dans chaque parcours en largeur :
→ passer le lien à 1 dans la copie

Connexité

Problème si le graphe n'est pas connexe

Plusieurs solutions

- Choisir les sources et destinations dans la même composante connexe
- Garder uniquement les chemins qui existent
- Utiliser uniquement des graphes connexes

Pas de solution parfaite

Connexité

Problème si le graphe n'est pas connexe

Choix des auteurs :

se restreindre à la plus grande composante connexe

Simulations

Examen de deux hypothèses

Graphes d'Erdős-Rényi (degrés homogènes)

- $n = 100\,000$
- $m = 750\,000$ ($d^\circ(G) = 15$)
- sources : 1, 5, 10
- destinations : 1000


Choisies au hasard

Distribution des degrés fixés (hétérogène)

- $n \sim 100\,000$
- $m \sim 190\,000$
- loi de puissance, $\alpha \sim 2.1$


Résultats

Graphes d'Erdős-Rényi




Résultats

Graphes d'Erdős-Rényi




Résultats

Graphes d'Erdős-Rényi




Résultats

Graphes à degrés fixés hétérogènes




Résultats

Graphes à degrés fixés hétérogènes



Résultats

Graphes à degrés fixés hétérogènes



Observations

- Distribution observée \neq distribution réelle
- Graphes aléatoires : différence **qualitative**
homogène \rightarrow **hétérogène**
- Graphes à degrés fixés : différence **quantitative**
pente, degré max, ...

Attention :

Graphes aléatoires : Degré maximum observé ~ 30

\rightarrow impossible de conclure sur l'hétérogénéité

Observations

- Distribution observée \neq distribution réelle
- Graphes aléatoires : différence **qualitative**
homogène \rightarrow **hétérogène**
- Graphes à degrés fixés : différence **quantitative**
pente, degré max, ...

Attention :

Graphes aléatoires : Degré maximum observé ~ 30

\rightarrow impossible de conclure sur l'hétérogénéité

Conclusion de l'article

On peut avoir une différence

Distribution observée hétérogène $\not\Rightarrow$ distribution réelle
hétérogène

Pas de conclusion sur la distribution réelle

Discussion (1/2)

Résultat très important

- D'un point de vue théorique
- Besoin de faire attention en pratique

Quelles conclusions tirer en pratique ?

Distribution observée hétérogène

- Distribution réelle homogène ?
- Distribution réelle hétérogène ?

Discussion (2/2)

Cas de graphes aléatoires :
Degré maximal observé :
proche du **degré moyen** du graphe.

En pratique, degré maximum observé > 1000
→ graphe aléatoire de **degré moyen = 1000** ?

→ **distribution réelle probablement hétérogène**
Besoin de plus d'études

Sources du biais


Biais dans l'échantillon des noeuds?

Pour chaque nœud : comparer le degré **observé** au **vrai** degré


Sources du biais

Biais dans l'échantillon des noeuds?

distrib. observée / distrib. du
graphe



distrib. des vrais degrés / dis-
trib. du graphe




Avec 1 source


Sources du biais

Biais dans l'échantillon des noeuds?

distrib. observée / distrib. du
graphe



distrib. des vrais degrés / dis-
trib. du graphe




Avec 5 sources


Sources du biais

Biais dans l'échantillon des noeuds?

distrib. observée / distrib. du
graphe



distrib. des vrais degrés / dis-
trib. du graphe




Avec 10 sources

Les nœuds sont choisis **sans biais** sur le degré

Sources du biais

Biais dans l'échantillon des liens?


degré observé vs degré réel
Avec 1 source



Sources du biais

Biais dans l'échantillon des liens?

degré observé vs degré réel
Avec 5 sources




Sources du biais

Biais dans l'échantillon des liens?

degré observé vs degré réel

Avec 10 sources





Sources du biais

Visibilité des arêtes en fonction de leur distance à la source

gauche : 10 000 sommets

droite : 1 000 000 sommets





Sources du biais

Visibilité des arêtes en fonction de leur distance à la source

gauche : 10 000 sommets

droite : 1 000 000 sommets



Plus une arête est **loin** de la source,
moins elle a de chances d'être vue


Échantillon donné \rightarrow biais ?

Étant donné un **échantillon** (et pas le graphe original),
peut-on savoir s'il y a du **biais** ?

Échantillon donné \rightarrow biais ?

Étant donné un **échantillon** (et pas le graphe original),
peut-on savoir s'il y a du **biais** ?

Probabilité d'avoir degré d et distance h



Les nœuds les plus éloignés ont les plus faibles degrés