

Comment générer des échantillons uniformes sur des grandes masses de données ?

15 Octobre 2016

Yann Busnel


Crest (Ensai) / Inria Rennes – Bretagne Atlantique

9e Colloque Francophone sur les Sondages
Gatineau, Canada



École nationale
de la statistique
et de l'analyse
de l'information

L'escalade de la puissance



- **Avant 1950** : la statistique

- quelques centaines d'individus et quelques variables
- protocole strict de laboratoire pour une étude scientifique

- **Années 1960-1980** : l'analyse des données

- quelques dizaines de milliers d'individus et quelques dizaines de variables
- recueillies de façon rigoureuse pour une enquête précise

- **Années 1990-2000** : le data mining

- plusieurs millions d'individus et plusieurs centaines de variables
- recueillies dans le système d'information des entreprises pour de l'aide à la décision

- **À partir des années 2010** : le Big Data

- plusieurs centaines de millions d'individus et plusieurs milliers de variables
- de tous types, recueillies dans les entreprises, les systèmes, Internet, pour de l'aide à la décision, de nouveaux services

Quelques chiffres pour se convaincre

10 millions de disques Blu-Ray



La dynamique du Big Data en France

Marché du
Big Data des
entreprises

2014 285 M€

2018 652 M€

+
129%

Répartition du marché du Big Data en 2014

24%

33%

43%



Logiciels



Services




Infrastructures

2.500.000

100 000 par jour

Données générées 4X plus vite
que l'économie mondiale


60 secondes en ligne



© Qmee.com 2014



Variété des données




Il y a 10 ans : explosion du volume des données générées
Les leaders du Web ont du trouver des technologies innovantes

Le Big Data : Buzz ou sujet de fond ?

- Depuis environ 5 ans, le **Big Data** suscite un **intérêt grandissant** auprès des acteurs des systèmes d'information
 - Éditeurs, DSI, intégrateurs, ...
- Concept des **4V**
 - Apporte des **axes de réflexion**
 - Mais : pas de définition claire

Dimensions du Big Data



« Up to eleven »

Variabilité

Variété

Visibilité

Volume

Validité

Valeur

Venue

Velocité

Vocabulaire

Véracité

Vague



Métrologie des réseaux :

Quelques faits

- Plus de 90% des emails sont du spam
- Des milliers de bugs logiciels découverts par an
 - Environ 3 jours pour qu'un virus exploite la faille
 - 30 jours avant la mise à disposition d'un patch
- Environ 8 000 attaques par DoS par jour
- Plus de 150 000 attaques par phishing par an

La surveillance réseaux

- Couramment appelée par son équivalent anglais : Network Monitoring
- Permet de détecter les anomalies de fonctionnement
 - Extraction de données pertinentes
- Utilité : métrologie, dimensionnement dynamique, détection de DoS, ...


Surveillance par historique

- Fondé sur des résumés d'informations sur une période de temps
 - Essentiel pour comprendre et améliorer la performance
 - Indique le besoin de mise à jour / redimensionnement
 - Justifie les dépenses nécessaires

Surveillance en temps-réel

- Observe continuellement la situation courante (au pire, récente)
 - Utilisé pour comprendre les problèmes/bugs en cours
 - Permet de garantir une réponse rapide à un évènement (bug, attaque, ...)
- Plus consommateur de ressources
- Difficile à mettre en oeuvre


Systemes d'information répartis




Info




Systemes d'information répartis




Systemes d'information répartis



Systemes d'information répartis




Systemes d'information répartis




Modélisation

$\{B, D, F\}$



$\equiv$



Décentralisation

- Avantage
 - Passage à l'échelle inhérent
 - Capacité d'auto-organisation
 - Tolérance aux défaillances
- Inconvénient
 - Obtention de statistiques globales difficile
 - Surveillance du système extrêmement complexe

Surveillance en temps-réel : Besoin d'échantillonnage

Temps réel

- Objectif : obtenir des échantillons uniformes récents et en continu
- Service d'échantillonnage uniforme continu :
Obtenir un flux d'échantillon uniforme
 - Abstrait par une fonction `getNode()` qui retourne l'adresse d'un noeud présent dans le système



Propriétés

- Uniformité
 - Garantie que chaque nœud possède la même probabilité d'être sélectionné comme échantillon
- Fraicheur
 - Adaptation continue de la population du système
- **Efficacité**
 - Faible quantité mémoire nécessaire
 - Temps de réponse faible

Modèle de flux de données

- Le flux de données est issu d'échantillons obtenus
 - via marche aléatoire, protocole épidémique, observation des routeurs, ...
- Impossible de tout mémoriser tous les identifiants
- Non résistant à des adversaires malveillants


Un peu de formalisme

- Un flux est une sequence d'items $\sigma = \langle a_1, a_2, \dots \rangle$
- Chaque a_i est tiré d'un très grand univers $U = \{1, 2, \dots, N\}$
 - e.g. IPv6 addresses: $N = 2^{128}$
- Chaque item peut être reçu à plusieurs reprises dans σ
- Un flux définit implicitement un vecteur de fréquences $(x_1, x_2, \dots)$ où x_i est le nombre d'occurrences (ou fréquence) de l'item i reçu jusqu'à présente dans σ
- Le vecteur de fréquences peut-être vu comme la distribution de probabilité empirique de σ

$$\mathbf{p} = (p_i)_{i \in U} \quad \text{où} \quad p_i = \frac{x_i}{\sum_{j \in U} x_j}$$

Modèles d'adversaire


- Capable de manipuler un grand nombre de nœuds
- Adapte ses attaques à la stratégie d'échantillonnage
- Objectif de l'adversaire : biaiser les échantillons des nœuds corrects



Echantillonnage uniforme :

Version omnisciente

- Hypothèse : Pour chaque item j reçu, sa probabilité d'occurrence p_j est connue
- Stratégie omnisciente
 - Si p_j est tout petit : on stocke l'item en mémoire
 - Sinon, on l'ignore la plupart du temps



Echantillonnage uniforme :

Version omnisciente


- Algorithme en détail

On insère j dans la mémoire avec une probabilité

$$a_j = \min_{i \in [N]} p_i / p_j$$

Si j est inséré, on retire un item u de la mémoire selon


$$r_u = 1 / C$$



Echantillonnage uniforme :

Version omnisciente

- Analyse par chaîne de Markov
- Théorème :
L'algorithme omniscient garantit l'uniformité et la fraîcheur en régime stationnaire



Echantillonnage uniforme :

Version à l'aveugle


- Hypothèse très (trop) forte pour être mise en pratique
 - Impossible de prédire la distribution des items
- Nécessité d'évaluer p_i en ligne, pour tout i
 - Estimateur de fréquence : Count-Min Sketch

Count-Min Sketch [CM05]


- Estimation des fréquences de tout item
 - (ϵ, δ) -approximation-additive de x_i
- Maintien d'un vecteur C de taille $k=2/\epsilon$
- Choix d'une fonction de hachage 2-universelle
- Pour chaque item v du flux
 - $C[h(v)]++$

Calcul de $1/\delta$ estimateurs
en parallèle et
retour du minimum

Qu'est ce qu'une fonction de hachage ?



Qu'est ce qu'une fonction de hachage ?



$H = \{h : U \rightarrow [m]\}$ est universelle si $\forall x, y \in U, x \neq y : \mathbb{P}_{h \in H}\{h(x) = h(y)\} \leq \frac{1}{m}$


Exemple d'un CM sketch

	4	14	36	9	29	4	36	15	
$h_1(.)$									$h_1(15)=1$
$h_2(.)$									$h_2(15)=3$
$h_3(.)$									$h_3(15)=2$


			4			
min = 1	min = 1	min = 1	min = 2	min = 1	min = 2	
15	29	9	36	14	4	

Propriétés de [CM05]

- (ε, δ) -approximation-additive du nombre d'occurrences des items du flux
 - $x_j + \varepsilon(m - x_j) \geq \dot{x}_j \geq x_j$
 - L'inégalité de droite est toujours vraie
 - L'inégalité de gauche échoue avec une probabilité au plus δ
- Complexité en espace :
 $O(1/\varepsilon \log 1/\delta (\log m + \log n))$



Algorithme aveugle



Algorithme aveugle



En cas d'attaque du flux

- On a vu que
 - La stratégie omnisciente génère un flux uniforme et « frais » à partir de n'importe quel flux d'entrée
 - La stratégie aveugle émule la version omnisciente par approximation des fréquences des items
- L'unique possibilité d'attaque est d'accroître artificiellement les fréquences estimées

La stratégie aveugle en présence de collusions

- Attaque ciblée
 - L'adversaire se concentre sur un item j spécifique
 - Doit générer suffisamment d'item $o_1, \dots, o_l$ tels que
 - pour chaque ligne s de CM, il existe o_i , $h_s(o_i) = h_s(j)$
- Attaque par inondation
 - L'adversaire souhaite surestimer tous les items
 - Doit générer suffisamment d'item $o_1, \dots, o_l$ tels que
 - pour toute case v de CM, il existe o_i , $h_s(o_i) = v$

La stratégie aveugle en présence de collusions

- Attaque ciblée

- L'adversaire se concentre sur une valeur v que
- Doit générer suffisamment d'items pour que
- pour

Question

Quel effort doit exercer un adversaire pour réussir ces attaques avec une probabilité $1-n$?

pour obtenir tous les items


Ensamblage d'item $o_1, \dots, o_l$ tels que

pour toute case v de CM, il existe $o_i, h_s(o_i) = v$




Analyse des attaques

- Modélisation par un problème d'urnes :
 - Chaque case de CM est représenté par une urne
 - Chaque item distinct est représenté par une boule
- On cherche les valeurs de
 - $L_{k,t}$: nombre de balles pour obtenir une collision avec un item j donné
 - E_k : nombre de balles pour obtenir une collision avec tous les items



Analyse des attaques



Analyse des attaques

Settings		η_T or η_F	$L_{k,t}$	E_k
k	t			
10 ($\varepsilon \sim 0.3$)	5 ($\delta \sim 10^{-2}$)	10^{-1}	38	44
10	5	10^{-4}	104	110
50 ($\varepsilon \sim 0.05$)	5	10^{-1}	193	306
50	10 ($\delta \sim 10^{-3}$)	10^{-1}	227	
50	40 ($\delta \sim 10^{-12}$)	10^{-1}	296	
50	5	10^{-4}	537	651
50	10	10^{-4}	571	
50	40	10^{-4}	640	
250 ($\varepsilon \sim 0.01$)	10	10^{-1}	1,138	1,617
250	10	10^{-4}	2,871	3,363

Analyse des attaques

Evaluation de performances

- Evaluation de l'impact d'identifiants malveillants largement surreprésentés
- Traces synthétiques
 - Distributions : Poissons, Pareto, Binomial
- Traces réelles
 - Serveurs http : NASA, ClarkNet, Université de Saskatchewan


$m = 40\,000$ items

$n = 1\,000$ distincts

$c = 15$

$k = 15$

$t = 17$




Evaluation de performances

$m = 100\,000$ items
 $n = 1\,000$ distincts
 $c = 10$
 $k = 10$
 $t = 5$

L'adversaire injecte 50 000
fois le même item
Tous les autres présent $\sim 50x$

La stratégie aveugle réussit
à réduire la plus haute
fréquence par un facteur 50

La stratégie omnisciente
réussit à produire un flux
totalement uniforme




Evaluation de performances


$m = 100\,000$ items
 $n = 1\,000$ distincts
 $c = 10$
 $k = 10$
 $t = 5$

Attaque ciblée :
~50 items sur-représentés

D'après le calcul de $L_{k,t}$:
Attaque réussie avec une
probabilité de 0.9 si $L = 48$



Evaluation de performances



$m \sim 2\,000\,000$ items / $n = 100\,000$ distincts / $t = 5$

Evaluation de performances

Comment générer des échantillons uniformes sur des grandes masses de données ?

Merci de votre attention



15 Octobre 2016

Yann Busnel

Crest (Ensai) / Inria Rennes – Bretagne Atlantique

9e Colloque Francophone sur les Sondages
Gatineau, Canada



École nationale
de la statistique
et de l'analyse
de l'information