



TECHNIQUES D'EXTRACTION DE CONNAISSANCES (DATA MINING, BIG DATA) : DÉFINITIONS ET ENJEUX.

Éric FILIOL

Laboratoire de Cryptologie et de Virologie Opérationnelles (C + V)⁰

filiol@esiea.fr

AGENDA

- Introduction
 - Que sont le Big Data et techniques assimilées ?
- Méthodes et techniques
 - Enjeux, renseignement, conceptions d'attaques
- Conclusion


AGENDA

- Introduction
 - Que sont le Big Data et techniques assimilées ?
- Méthodes et techniques
 - Enjeux, renseignement, conceptions d'attaques
- Conclusion

CONTEXTE ET PROBLÉMATIQUE

- Techniques existant depuis les années 60 (extraction de données) boostées par les attentats du 9/11
- L'explosion du volume et de la nature des données a donné naissance (fin 90s, début 2000s) au big data
 - Volume traité par la NSA par Projet Muskular (2013 40 Go/j [estimation WP])
 - 2013 : Twitter produit 7 To/j – Facebook 10 To/j
 - *Square Kilometre Array* production annoncée de 50 To/j (données analysées) soit un 7 000 To/sec (données brutes)
 - Estimation Internet (2020) $40 \cdot 10^{21}$ octets
- Explosion de la variété des données : données, métadonnées, textes, images, sons, vidéos, signaux EM....
- Problématiques nouvelles de stockage, de traitement/analyse, de visualisation...

Global Information Storage Capacity in optimally compressed bytes




Source: Hilbert, M., & López, P. (2011). The World's Technological Capacity to Store, Communicate, and Compute Information. *Science*, 332(6025), 60–65. <http://www.martinhilbert.net/WorldInfoCapacity.html>

DATA MINING VERSUS BIG DATA

- Analyse de données brutes, en grand nombre et souvent informes dans le but de
 - comprendre des données par rapport à un ou plusieurs critères,
 - pouvoir prendre une décision par rapport au contexte et aux éléments constituant ce contexte.
- Quand parle t-on de big data ?
 - Pour des données dont la taille dépasse les quelques To.


Informatique décisionnelle	Data Mining	Big Data
Données à forte entropie	Entropie faible à moyenne	Entropie faible
Statistique descriptive	Statistique inférentielle	
	Algorithmique	Algorithmique distribuée
Logiciel R	Weka	Hadoop/MapReduce
Existence d'un modèle absolu	Extraction d'un modèle local et subjectif	

DATA MINING VERSUS BIG DATA



DATA MINING VERSUS BIG DATA

Storing & Querying Big Data in Hadoop Distributed File System (HDFS)



Designed by Sri Prakash, November 2012

MYTHES ET REALITE

- Le big data/data mining tente
 - d'expliquer le passé par l'exploration des données (partie statistiques),
 - de « prédire le futur » par la modélisation des données (partie inférentielle).
- MAIS
 - Ce n'est pas une boule de cristal!
 - Importance critique de l'expertise en amont (bien définir le problème) et en aval (savoir correctement interpréter le résultat et surtout le confronter à la réalité [problème de la distribution d'échantillonnage])
 - Toujours subordonner la technique à la dimension opérationnelle.
 - BD et DM ne sont ni « bons » ni « mauvais » : c'est leur utilisation par l'homme qui peut poser problème
 - Il n'existe pas de « super modèle » ou de « super équation » unificateurs

MYTHES ET REALITE (2)

- Avec le big data nous sommes juste passés d'une connaissance avec un référentiel absolu (ex : loi normale) à une connaissance à référentiel statistique (exemple : traduction Google)

« Nous voilà trois contre toi, il faut que tu te rendes à l'opinion de la majorité. La majorité, vois-tu, mon ami, c'est plus fort que tout le monde cela. Mets dix philosophes d'un côté et onze imbéciles de l'autre, les imbéciles l'emporteront »

Claude Tillier (1842)

- Bien utilisés et bien compris BD et DM peuvent être des outils très puissants... à ne pas mettre dans toutes les mains (voir plus loin)
- Les modèles fournis pour le BD/DM doivent être confrontés au temps et réactualisés en permanence... surtout dans le champ humain.

RÉALITÉ

- Par nature big data et data mining visent à extraire des informations potentiellement sensibles, dissimulées dans des données en apparence anodines
 - Exemple : la liste de vos achats pendant une période de quelques mois peut permettre de « deviner » vos habitudes de vie les plus intimes (religieuses, sexuelles, culturelles, idéologiques...)

AGENDA

- Introduction
 - Que sont le Big Data et techniques assimilées ?
- Méthodes et techniques
 - Enjeux, renseignement, conceptions d'attaques
- Conclusion

APPRENTISSAGES

- Pour tout problème (décidable!) il faut un algorithme.
- Dans beaucoup de situations, cet algorithme n'est pas disponible (trop complexe, non connu...)
 - Exemples : détection d'un terroriste.
- Les « données » vont servir pour « apprendre » ce qu'est un terroriste et l'ordinateur va automatiquement extraire l'algorithme pour résoudre ce problème.
- L'apprentissage consiste donc à programmer un ordinateur pour optimiser un critère de performance en utilisant des données produites par l'expérience.
- Définition d'un « modèle » conditionné par un certain nombre de paramètres. L'apprentissage consiste donc à optimiser les paramètres de ce modèle.
- Les termes « *données* », « *apprendre* », « *optimiser* », « *expérience* » et « *paramètres* » soulignent le caractère subjectif et local du modèle obtenu.

APPRENTISSAGES (2)

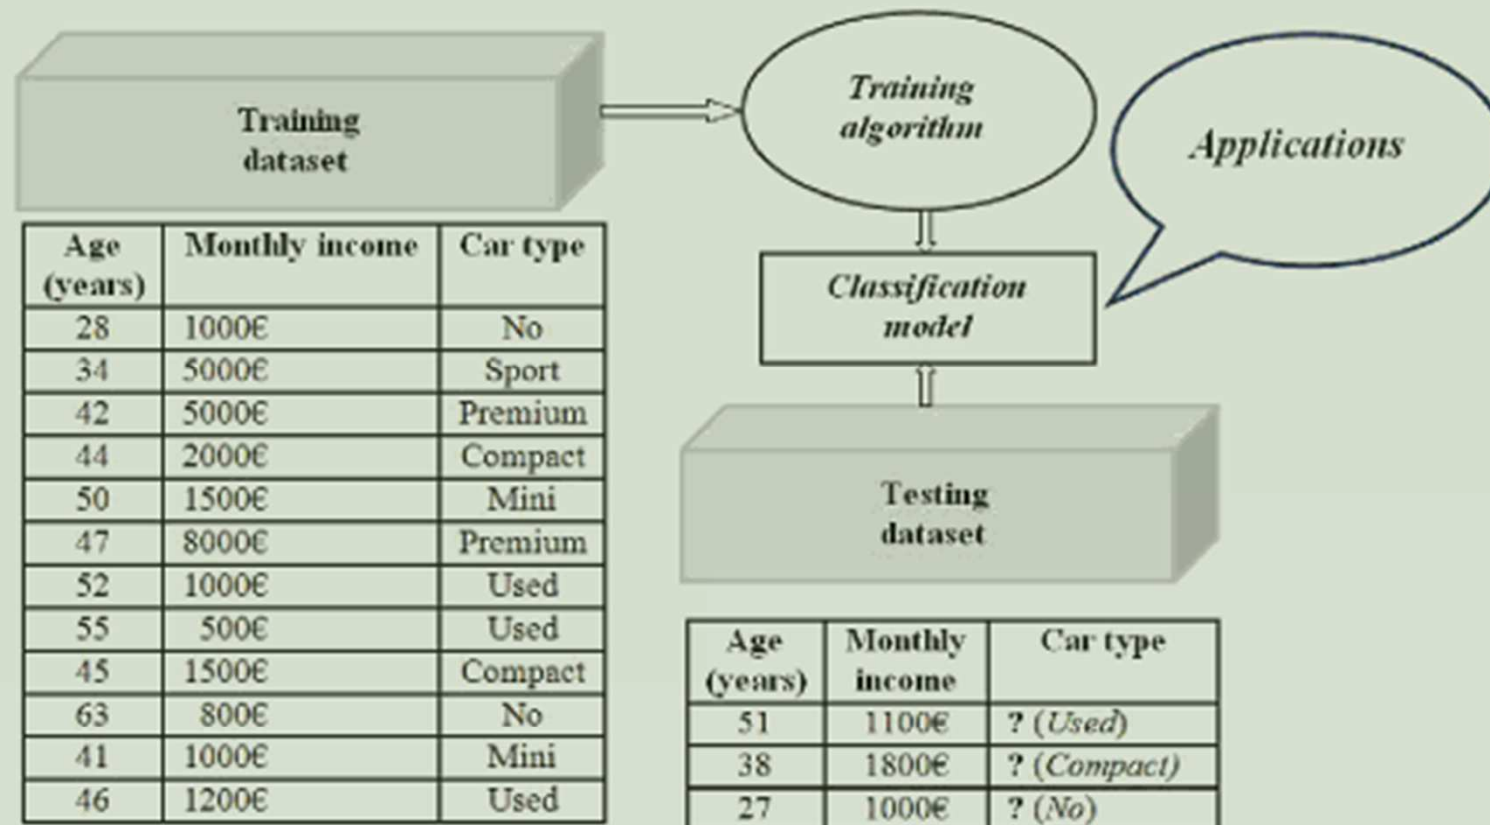
- Deux types d'apprentissage :
- **Apprentissage supervisé** : les données sont déjà caractérisées (traitées et validées) par un superviseur (données avec label, base de données d'apprentissage).
 - Méthode des k plus proches voisins, SVM, classification naïve bayésienne, arbres de décision, réseau de neurones...
- **Apprentissage non supervisé** : technique d'apprentissage automatique où les données sont brutes (sans label) et non interprétées. Il faut les classifier selon un ou plusieurs critères de similarité.
 - Techniques d'estimation de densité (*clustering*), réseaux de neurones (par exemple : cartes auto-adaptatives)...

PRINCIPALES ÉTAPES EN DM/BD

1. Traiter, extraire et explorer les données. On part de données brutes, souvent malformées, partiellement non pertinentes... pour obtenir des données utilisables pour le traitement.
 - bruit (e.g. traitement de signal nécessaire), outliers/anomalies, données dupliquées ou redondantes, données obsolètes, fausses, manquantes...
2. Construction et validation d'un modèle (description d'un ensemble d'objets, de leurs propriétés et relations/interactions par un programme). Entre plusieurs modèles, il faut pouvoir choisir le plus adapté pour notre problème, dans le contexte opérationnel donné (nécessité de mesures de performances).
3. Application du modèle à de nouvelles données pour une approche prédictive/décisionnelle relative au problème.
4. Evaluation de la performances : cout (temps, mémoire, impact opérationnel d'une mauvaise décision...), robustesse, rapidité, efficacité, sensibilité, scalabilité...

Univariate Analysis - Numerical

Statistics	Visualization	Equation	Description
Count	Histogram	N	The number of values (observations) of the variable.
Minimum	Box Plot	Min	The smallest value of the variable.




Kurtosis	Histogram	$\left[\frac{(N-1)(N-2)(N-3)}{3(N-1)^2} \sum \left(\frac{s}{s} \right) \right]$	A measure of whether the data are peaked or flat relative to a normal distribution.
----------	-----------	---	---

Univariate Analysis - Numerical

Statistics	Visualization	Equation	Description
Count	Histogram	N	The number of values (observations) of the variable.
Minimum	Box Plot	Min	The smallest value of the variable.
Maximum	Box Plot	Max	The largest value of the variable.
Mean	Box Plot	$\bar{X} = \frac{\sum X}{N}$	The sum of the values divided by the count.
Median	Box Plot	$\tilde{X}$	The middle value. Below and above median lies an equal number of values.
Mode	Histogram		The most frequent value. There can be more than one mode.
Quantile	Box Plot	Q_k	A set of 'cut points' that divide a set of data into groups containing equal numbers of values (Quartile, Quintile, Percentile, ...).
Range	Box Plot	$Max-Min$	The difference between maximum and minimum.
Variance	Histogram	$S^2 = \frac{\sum(X - \bar{X})^2}{N - 1}$	A measure of data dispersion.
Standard Deviation	Histogram	$S = \sqrt{S^2}$	The square root of variance.
Coefficient of Deviation	Histogram	$CV = \frac{S}{\bar{X}} \times 100\%$	A measure of data dispersion divided by mean.
Skewness	Histogram	$\frac{N}{(N-1)(N-2)} \sum \left(\frac{X - \bar{X}}{S} \right)^3$	A measure of symmetry or asymmetry in the distribution of data.
Kurtosis	Histogram	$\left[\frac{N(N+1)}{(N-1)(N-2)(N-3)} \sum \left(\frac{X - \bar{X}}{S} \right)^4 - \frac{3(N-1)^2}{(N-2)(N-3)} \right]$	A measure of whether the data are peaked or flat relative to a normal distribution.


Data Mining



TECHNIQUES DE BD/DM

- Très nombreuses techniques selon la nature (supervisée ou non) de l'apprentissage et du traitement
- Le passage au big data impose une vision algorithmique totalement différente
 - Exemple : en data mining comparaison de N objets $\rightarrow O(N^2)$. En big data on passe sur des méthodes proches de $O(N)$ (*minhashing*, techniques LSH...)
 - Techniques de multihashing dans le domaine des règles d'association
- Voyons quelques exemples
 - Partitionnement (*clustering*)
 - Règles d'association (*association rules*)

- Très trait
- Le p
-
-
- Voy
-
-



TECHNIQUES DE PARTITIONNEMENT

- Méthodes non supervisées, les objets (caractérisés par un ensemble d'attributs), doivent être répartis dans des groupes homogènes par rapport à des propriétés de similarité prédéterminées.
 - Pas de labellisation des objets (les groupes ne sont pas *a priori* connus).
 - Le nombre de classes (clusters) n'est *a priori* pas connu (utilisation d'arbres hiérarchiques ascendants)
 - Utilisation d'une ou plusieurs mesures de similarité ou de distances.
- A la fin du partitionnement :
 - Les objets d'un même groupe sont plus similaires les uns par rapport aux autres.
 - Les objets de groupes différents sont moins similaires les uns par rapport aux autres.
- Une étape additionnelle (manuelle, supervisée, statistique...) peut permettre de caractériser (labelliser) les classes.
- Analyse des outliers

0

100

200

300

400

500

600

700

800

900

1000

1100

1200

1300

1400

1500

1600

1700

1800

1900

2000

2100

2200

2300

2400

2500

2600

2700

2800

2900

3000

3100

3200

3300

3400

3500

3600

3700

3800

3900

4000

4100

4200

4300

4400

4500

4600

4700

4800

4900

5000

5100

5200

5300

5400

5500

5600

5700

5800

5900

6000

6100

6200

6300

6400

6500

6600

6700

6800

6900

7000

7100

7200

7300

7400

7500

7600

7700

7800

7900

8000

8100

8200

8300

8400

8500

8600

8700

8800

8900

9000

9100

9200

9300

9400

9500

9600

9700

9800

9900

10000

10100

10200

10300

10400

10500

10600

10700

10800

10900

11000

11100

11200

11300

11400

11500

11600

11700

11800

11900

12000

12100

12200

12300

12400

12500

12600

12700

12800

12900

13000

13100

13200

13300

13400

13500

13600

13700

13800

13900

14000

14100

14200

14300

14400

14500

14600

14700

14800

14900

15000

15100

15200

15300

15400

15500

15600

15700

15800

15900

16000

16100

16200

16300

16400

16500

16600

16700

16800

16900

17000

17100

17200

17300

17400

17500

17600

17700

17800

17900

18000

18100

18200

18300

18400

18500

18600

18700

18800

18900

19000

19100

19200

19300

19400

19500

19600

19700

19800

19900

20000

20100

20200

20300

20400

20500

20600

20700

20800

20900

21000

21100

21200

21300

21400

21500

21600

21700

21800

21900

22000

22100

22200

22300

22400

22500

22600

22700

22800

22900

23000

23100

23200

23300

23400

23500

23600

23700

23800

23900

24000

24100

24200

24300

24400

24500

24600

24700

24800

24900

25000

25100

25200

25300

25400

25500

25600

25700

25800

25900

26000

26100

26200

26300

26400

26500

26600

26700

26800

26900

27000

27100

27200

27300

27400

27500

27600

27700

27800

27900

28000

28100

28200

28300

28400

28500

28600

28700

28800

28900

29000

29100

29200

29300

29400

29500

29600

29700

29800

29900

30000

30100

30200

30300

30400

30500

30600

30700

30800

30900

31000


31100

31200


31300



31400


IP :
DNS :
Total :
Inco :
Out :




IP :
DNS :
Total :
Inco :
Out :








TECHNIQUES DE PARTITIONNEMENT



TECHNIQUES DE PARTITIONNEMENT



ASPECTS COMBINATOIRES DU PARTITIONNEMENT


- Pour trouver le meilleur partitionnement, on peut imaginer explorer toutes les partitions possibles (à nombre fixe de classes ou non) et choisir celles qui optimisent le critère (classifieur) considéré.
- L'explosion combinatoire rend cette tâche impossible : en traitant 10^9 partitions par seconde, il faudrait 126 ans pour traiter toutes les partitions d'un ensemble de 25 objets.
- Nombre de partitions de n objets en k classes (nombre de Stirling de 2^{nde} espèce)

$$P_{n,1} = P_{n,n} = 1 \quad P_{n,n-1} = \frac{n(n-1)}{2} \quad P_{n,2} = 2^{n-1} - 1$$
$$P_{n,k} = P_{n-1,k-1} + k \cdot P_{n-1,k} \quad P_{n,k} = \frac{1}{k!} \sum_{i=1}^k k \binom{k}{i} (-1)^{k-i} i^n$$

- Dans les problèmes classiques de data mining/big data, n est de l'ordre de quelques dizaines de milliers à quelques dizaines de milliards d'objets.
- BD/DM ne fournissent qu'une approximation (problème du choix des vecteurs initiaux de classes)

RÈGLES D'ASSOCIATION

- Processus d'identification des règles de dépendance entre différents groupes de phénomènes.
- Ces règles permettent ensuite de prédire les occurrences d'un phénomène en fonction d'un autre (exemple : « suggestions d'Amazon »)
- En big data : problème algorithmique d'identification des « *frequent item sets* » (techniques de hashing et multihashing)
- Exemple (historique ? Légende urbaine ?) : Wal-mart



RÈGLES D'ASSOCIATION - EXEMPLE

- $T = 1\,000\,000$ consultations de sites web « sensibles »
 - 40 000 consultations concernent le site A (4 %)
 - 60 000 consultations concernent le site B (6 %)
 - 20 000 consultations concernent à la fois A et B (2 %)
- Sur un ensemble de d objets, on peut extraire $R = (3^d - 2^{d+1} + 1)$ règles du type $X \rightarrow Y$
- Ici $d = 2$ soit deux règles possibles $A \rightarrow B$ ou $B \rightarrow A$
- Règle $A \rightarrow B$: 50 % de confiance (20 000/40 000). On en déduit que ceux qui consultent le site A ont 8.33 (0,5/0.06) plus de chances de consulter aussi le site B.
- Comme $8.33 \gg 1$, il y a une très forte corrélation entre la consultation du site A et celle du site B
- NB : dans $X \rightarrow Y$, X et Y décrivent des sous-ensembles d'« objets » (item sets)

APPLICATION : ATTAQUE D'UN RÉSEAU ÉLECTRIQUE

- Etude publiée dans les Cahiers de la Revue de Défense Nationale et présentée à ICCWS 2016 (Boston)
- Optimisation d'une attaque conventionnelle contre le réseau électrique US par la phase de renseignement et de planification
 - Utilisation de données ouvertes (media et open data)
- Aspect critique : déterminer les points sensibles du réseau (pylônes, sous-stations...) nécessitant un temps de réparation plus long que pour les autres points sensibles (but : prolongement des effets de l'attaque)
- Règles d'association
 - {critères géographiques, critères climatiques, largeur des routes, critères démographiques, équipements, ressources de sécurité} → {durée de réparation}

APPLICATION : ATTAQUE D'UN RÉSEAU ÉLECTRIQUE

RDN

Penser autrement :
pour une approche critique
et créative des affaires militaires



Les Cahiers de la
Revue Défense Nationale



87 Les hybrides de Mars

LUDOVIC VESTIEU

Les menaces contemporaines sont de moins en moins portées par les seuls acteurs étatiques. Terrorisme, trafics des êtres humains, trafics de drogue ou piraterie, les acteurs non étatiques désagrégent l'échelle de la menace pour descendre au niveau de la personne. Confrontées depuis 1989 à des violences issues des sociétés civiles, les forces armées opèrent un effort d'adaptation qui les conduit à quitter le champ de bataille pour investir le contrôle social. Elles s'engagent dans un processus de « policiarisation ».

94 Le cyber en opérations

OLIVIER KEMPF

Le cyber appartient aux opérations. Si l'on peut discuter de la possibilité d'une « guerre dans le cyber-espace » ou de « cyberguerre », il y a à coup sûr du cyber dans la guerre. C'est pourquoi cet article examine comment les armées s'organisent pour manipuler l'information avant d'esquisser les fonctions cyberopératives.

103 Comment vraiment paralyser un pays à l'aide du cyber

ÉRIC FILIOL

Contrairement à l'idée générale selon laquelle les cyberattaques deviennent la nouvelle forme de guerre, reléguant la guerre conventionnelle au domaine du passé, cet article entend montrer qu'en réalité le « cyber » n'est qu'une dimension supplémentaire, dont le rôle est surtout essentiel dans les phases de renseignement et de planification des attaques classiques. L'article illustre ce propos avec une étude décrivant, selon cette vision, une attaque (fictive) généralisée contre le réseau électrique des États-Unis.

111 Les drones Male : une capacité fondamentale dans la lutte antiterroriste

CHRISTOPHE FONTAINE

Les drones Male avec leurs multiples capteurs, leur endurance inégalée, et les équipages expérimentés sont une capacité unique et sous-employée en Métropole. Ils peuvent être engagés depuis Cognac dans toute la profondeur du territoire national. Si la plupart des drones Male sont déployés en soutien des forces conventionnelles et spéciales en Opex, l'Armée de l'air disposera toujours en permanence de moyens indispensables à la formation et au maintien des compétences qui permettront de soutenir efficacement en préventif et en réactif, l'action antiterroriste engagée sur le territoire national.



BLACKOUT TRACKER

[Other Trackers ▼](#)[Download The Annual Report](#)[Submit an Outage](#)

United States — Since 11/23/2015

SORT BY

Duration ▼



1,000

AFFECTED

900

MINUTES

700

AFFECTED

720

MINUTES

N/A

AFFECTED

720

MINUTES

N/A

AFFECTED

720

MINUTES

N/A

AFFECTED

720

MINUTES

1,700

AFFECTED

720

MINUTES

CAUSE KEY



Weather



Animal



Equipment



Vehicle



Vandalism



Planned



Overdemand



Unknown

[Share](#)

Assault on California Power Station Raises Alarm on Potential for Terrorism

April Sniper Attack Knocked Out Substation, Raises Concern for Country's Power Grid

Email Print Save 301 Comments



By REBECCA SMITH [CONNECT](#)

Feb. 4, 2014 10:30 p.m. ET



Shots in the Dark

A look at the April 16 attack on PG&E's Metcalf Transmission Substation

- | | | | | | | |
|---|--|---|--|---|--|--|
| 1
12:58 a.m., 1:07 a.m.
Attackers cut telephone cables | 2
1:31 a.m.
Attackers open fire on substation | 3
1:41 a.m.
First 911 call from power plant operator | 4
1:45 a.m.
Transformers all over the substation start crashing | 5
1:50 a.m.
Attack ends and gunmen leave | 6
1:51 a.m.
Police arrive but can't enter the locked substation | 7
3:15 a.m.
Utility electrician arrives |
|---|--|---|--|---|--|--|

Sources: PG&E; Santa Clara County Sheriff's Dept.; California Independent System Operator; California Public Utilities Commission; Google (image)
The Wall Street Journal

Popular Now

ARTICLES

1 Best Places to Find Love



2 Comcast Acquiring Time Warner Cable In All-Stock Deal



3 \$2.2 Billion Bird-Scorching Solar Project



4 Assault on Power Grid Raises Alarms



5 BNP Hit by \$1.1 Billion Provision



AGENDA

- Introduction
 - Que sont le Big Data et techniques assimilées ?
- Méthodes et techniques
 - Enjeux, renseignement, conceptions d'attaques
- Conclusion

CONCLUSION

- Ces techniques offrent un potentiel énorme d'un point de vue opérationnel
 - Mais au-delà des outils et des techniques, cela requiert avant tout une expertise métier et/ou opérationnelle.
 - Il faut correctement définir le problème et surtout correctement interpréter les « réponses » fournies
 - Ces « réponses » sont subjectives par nature !
 - Les risques pour la vie privée et les libertés (surveillance sans contrôles des citoyens) sont à la hauteur de ce potentiel et sont bien réels
 - Capteurs divers (Windows 10, imsi-catcher, « boitiers noirs », smart compteur...)
- « Si vous voyez un seul article qui remet en cause la liberté publique, dites-le moi. En revanche, il y a des articles qui remettent en cause la vie privée »*

Bernard Cazeneuve 14 Avril 2015, Assemblée Nationale

- Nécessité de préserver le droit à la solitude, à l'intimité, à l'anonymat dans la foule et à réserve (Askland, 2006)

CONCL

- Ces tech
 - Mais mét
 - Il fa
« ré
 - Ces
- Les risqu
sont à la
 - Cap

« Si vo
revanch
- Nécessit
réserve (

Pavel Khorenyan et Benjamin Goodie/Stockphoto



PIRATAGE. Des hackers ont découvert que le compteur d'ERDF identifiait les différents appareils connectés de la maison et la chaîne de télé regardée.

Le compteur Linky dévoile votre vie privée

CONCL

Pour Cazeneuve, la vie privée n'est pas une liberté !



Guillaume Champeau - 14 avril 2015 - Politique

TICLÉ PREMIER
n° 112 de M. MORIN
n° 408 du Gouvernement
n° 396 de M. CHERKI
n° 17
n° 13

Accueil > Politique > Pour Cazeneuve, la vie privée n'est pas une liberté !



Le compteur Linky dévoile votre vie privée

(PRÉ)TRAITEMENT DES DONNÉES CLIENTS

- Pour l'UE (G29, directive 95/46/CE), les données personnelles doivent être anonymisées lorsque susceptibles de faire objet d'analyse de type *big-data* (ce que font certains opérateurs)
- Trois critères pour évaluer une solution d'anonymisation
 - L'individualisation : est-il toujours possible d'isoler un individu ?
 - La corrélation : est-il possible de relier entre eux des ensembles de données distincts concernant un même individu ?
 - L'inférence : peut-on déduire de l'information sur un individu ?
- Voir site de la CNIL (<http://www.cnil.fr/documentation/fiches-pratiques/fiche/article/cloud-computing-les-7-etapes-cles-pour-garantir-la-confidentialite-des-donnees>)

BIBLIOGRAPHIE (1)

- Leskovec, J., Rajaraman, A. et Ullman J. D. (2014) *Mining of Massive Datasets* (cours de Stanford CS 246). Cambridge University Press. Voir <http://http://mmds.org/>
- Aggarwal, C. C. (2013). *Outlier Analysis*. Springer Verlag
- Mohanty, H., Bhuyan, P., Chenthati, . (2015). *Big data – A Primer*. Springer Verlag
- Gorunescu, F. (2011). *Data Mining – Concepts, Models and Techniques*. Springer Verlag
- Alpaydin, E. (2010). *Introduction to Machine Learning*. The MIT Press
- Nakache, J.-P. et Confais, J. (2005). *Approches pragmatiques de la classification*. Technip
- Hastie, T., Tibshirani, R. and Friedman, J. (2001), *The Elements of Statistical Learning – Data Mining, Inference and Prediction*. Springer Verlag.

BIBLIOGRAPHIE (2)

- Andrew Askland (2006) *What, Me Worry: The Multi-Front Assault on Privacy*. St. Louis University Public Law Review, Vol. 25, No. 1, pp. 33--61
- Andrew Askland (2009). *Science and Socially Responsible Freedom*. Science and Engineering Ethics, Vol. 15, No. 3, pp. 343--349.
- Gaston Bachelard (1927). *Essai sur la connaissance approchée*. Jean Vrin éd.
- Auguste Comte (1830). *Cours de Philosophie Positive*.
<http://gallica.bnf.fr/ark:/12148/bpt6k76267p/>
- #DATAGUEULE (2014). *Big data : données, données, donnez-moi !*
<https://www.youtube.com/watch?v=5otaBKsz7k4>
- #DATAGUEULE (2015). *Privés de vie privée ?*
<https://www.youtube.com/watch?v=wShQYeH9qJk>



Merci de votre attention

QUESTIONS & RÉPONSES