



Algorithmes et Big Data : Peut-on se souvenir du futur ?

Atelier Proustime

19 avril 2017

Maryse Salles

Maryse.Salles@ut-capitole.fr

https://www.canal-u.tv/video/universite_toulouse_ii_le_mirail/algorithmes_et_big_data_peut_on_se_souvenir_du_futur_maryse_salles.35349



Des cartes et des
territoires...

...à ne pas confondre

Oeuvre originale de René Magritte: La trahison des images



Ceci n'est pas une pipe.

Magritte

Le logiciel COMPAS calcule un score de risque de récidive à partir de données quantifiées sur 18 thèmes

- Criminal Involvement, Noncompliance History, Violence History, Current Violence
- Criminal Associates/Peers, Social Environment, Criminal Opportunity
- Family Criminality, Vocation/Education
- Substance Abuse, Financial Problems
- Social Isolation, Social Adjustment, Socialization Failure, Residential Instability
- Criminal Thinking, Criminal Personality, Leisure/Boredom



Bernard Parker

*Score COMPAS : 10
(le plus haut)*

Les 137 données recueillies sur Bernard Parker sont-elles (équivalentes à) Bernard Parker ?



Quel impact ont ces
représentations sur ce
qu'elles représentent ?

La pipe de Magritte

- Nous manquons d'information sur le sujet, mais il semblerait que la pipe n'ait pas été affectée par la peinture que Magritte a faite d'elle ;-)

La carte de la Méditerranée

- La reconnaissance de cet espace comme une unité (la Mer Méditerranée),
- ses représentations sous forme de cartes pour naviguer, pour représenter un empire, ...
- ont eu, en conjonction avec beaucoup d'autres facteurs (évolution des technologies, invasions, guerres de conquête...), une **influence** sur cet espace
 - navigation, intensité des échanges, positionnements géopolitiques, etc.
- Cette influence, **limitée**, s'est exercée sur **une très longue période**

Le score de probabilité de récidive de Bernard Parker

- Aux États-Unis, le score d'un prévenu est transmis au juge qui doit décider de la peine et de ses éventuels aménagements
 - notamment décider d'une peine d'emprisonnement, de sa durée
- Il est également utilisé pour les décisions de remise de peine, de mise en liberté conditionnelle, etc.
- Une différence de catégorie de score (ex. risque élevé vs risque moyen ou bas) peut entraîner une différence de peine ou de montant de caution, suivant le juge concerné
- La représentation de Bernard Parker permettant le calcul de son score de probabilité de récidive a un **impact immédiat et majeur sur sa vie, à court, moyen et long terme**



Big Data et algorithmes : rapide présentation

Big Data

- Grandes masses de données qui mémorisent des "traces" de l'activité d'êtres vivants, de machine, etc. ou leurs états successifs
 - très gros volumes de données : unités de mesure actuelles téraoctet (10^{12} octets), pétaoctet (10^{15}), exaoctet (10^{18})
- Collecte des données : principalement **automatique**
 - "traçage" fait sans acte volontaire de la part de la personne "tracée"
- Données "**historisées**"
 - les données s'accumulent, gardent la trace des différentes valeurs dans le temps
- Grand nombre de "dimensions" pour décrire une personne, ou un objet
 - ex. pour une personne : données biologiques, noms des amis sur Facebook (et les amis de leurs amis), CV, photo, engagements associatifs, conduite automobile, les lieux où elle se rend, les numéros de téléphone entrants et sortants, les sites consultés...
- Possibilité de corréliser différents aspects de l'identité d'une personne **jusque là dissociés**
 - vie actuelle, vie passée, vie professionnelle, activités associatives, goûts musicaux, positions politiques, religion, relations amicales...

Algorithmes

1/2

Du nom du mathématicien persan Al-Kwarizmi (9^{ème} siècle), considéré comme le père de l'algèbre

- Description de toutes les actions élémentaires nécessaires à la réalisation d'un but, dans l'ordre dans lequel elles doivent être faites, avec d'éventuelles répétitions de groupes d'actions...
 - manuel de montage d'un meuble, recette de cuisine
 - suite des opérations pour faire un calcul (par exemple pour résoudre une équation du second degré)
- En informatique, après avoir défini l'algorithme, on le code dans un langage compréhensible par un ordinateur, afin qu'il exécute la procédure décrite par l'algorithme
- Dans le contexte des Big Data : traitements divers dans le but d'identifier des motifs qui se répètent dans un ensemble des données

=> => =>

- En particulier : traitements statistique pour identifier des groupes d'entités se comportant d'une manière proche => profils
 - les données d'une nouvelle entité seront comparées aux profils déjà définis afin de la classer , ce qui permet d'inférer son comportement futur sur la base des comportements des entités de son profil
 - ex. : on compare les données biologiques, d'activité physique... d'une personne donnée à l'ensemble des profils sanitaires calculés, pour déterminer son niveau de risque
 - ex. : on compare le type de navigation dans un site marchand, les produits regardés, les achats effectués avec ceux des groupes de consommateurs que l'on a définis...

- Ces traitements statistiques cherchent à établir des corrélations entre certaines variables (c'est-à-dire des liens qui font qu'elles évoluent en même temps). Une variable est un type de donnée : l'âge, le sexe, le niveau de diplôme, le lieu...
 - ex. de corrélations : précocité maladie Alzheimer et niveau de diplôme, consommation chocolat et nombre de prix Nobel (mais aussi consommation chocolat et nombre de tueurs en série !), baisse de nombre de cigognes et de la natalité en Allemagne après-guerre...
 - **attention** : un lien de corrélation n'équivaut pas à un lien de cause à effet. La variable 1 peut être la cause de la variable 2... ou l'inverse (performance d'une entreprise et présence de femmes au CA). Les variables 1 et 2 peuvent être la conséquence d'une troisième variable inconnue au moment du traitement (cigognes et natalité). En analyse statistique, **le lien de causalité est toujours une interprétation**

Quelques exemples d'utilisation

- Utilisation dans la recherche scientifique, par aide à la compréhension de phénomènes impliquant de grands nombres de variables quantifiables
 - ex. : météorologie, épidémiologie, changement climatique..., sociologie des usages d'Internet, des comportements électoraux...
 - ex. : nouveaux domaines comme la "physique sociale"
- Recherche de **modification de comportement**
 - ex. : achats suggérés sur Internet, modulation des tarifs d'assurance en fonction du comportement (assurance automobile, assurance santé)...
 - ex. : interface UBER pour pousser les chauffeurs à rester en service (alors que leur espoir de revenu est faible sur le créneau)
- En **aide à la prise de décision**. Quelques exemples :
 - aide au recrutement, à la sélection des étudiants (États-Unis)
 - maintenance préventive de machines (suggestion de pièces à changer)
 - planification de travaux dans l'espace public
 - répartition des forces de police dans les quartiers (États-Unis)
 - **aide aux décisions de justice** (peines, libérations sous caution...) (États-Unis), aide à l'identification de terroristes potentiels



Des données
qui ne sont pas *données*,
mais bien *construites*

Des données *données* ?

- Donnée : du latin *datum*, donné (pluriel *data*)
- Mais les données ne sont **pas données**, elles sont le résultat d'un **ensemble de choix** de représentation
 - choix du type de support et du type de codage
 - ◆ quels traitements permettront le support et le codage ? Quelle automatisation possible des traitements ?
 - choix de **ce qui est représenté, ce qui ne l'est pas**

=> => =>

Les choix de représentation

- La vision du monde (paradigme)
 - vision sous-jacente au **score de probabilité de récidive**
 - ◆ tout peut être quantifié, comparé, classé
 - ◆ le réel existe de façon indépendante de sa représentation
 - ◆ la quantification quantifie ce qui existe (le réel) de façon objective, neutre ; c'est une simple technique
- Ce qui est représenté, ce qui ne l'est pas
 - la pipe : la pipe (pas le fumeur), pas de décor, pas de fumée...
 - la carte de la méditerranée
 - ◆ pays (frontières, noms des pays), relief, noms des mers...
 - ◆ **mais pas** : les lignes maritimes, pas les vents dominants, les noms des îles au temps d'Homère, les bancs de poissons...
 - calcul du score de probabilité de récidive : quelques exemples de ce qui est représenté
 - ◆ Criminal Associates/Peers, Social Environment
 - ◆ Family Criminality, Vocation/Education, Residential Instability
 - ◆ Social Isolation, Social Adjustment, Socialization Failure,
 - ◆ Criminal Thinking, Criminal Personality

Sur la représentation d'un pays au travers de son PNB...

"Our Gross National Product, now, is over \$800 billion dollars a year, but that GNP - if we judge the USA by that - that GNP counts air pollution and cigarette advertising, and ambulances to clear our highways of carnage. It counts special locks for our doors and the jails for the people who break them. It counts the destruction of the redwood and the loss of our natural wonder in chaotic sprawl. It counts napalm and counts nuclear warheads and armored cars for the police to fight the riots in our cities. It counts (...) the television programs which glorify violence in order to sell toys to our children. Yet the GNP does not allow for the health of our children, the quality of their education or the joy of their play. It does not include the beauty of our poetry or the strength of our marriages, the intelligence of our public debate or the integrity of our public officials. It measures neither our wit nor our courage, neither our wisdom nor our learning, neither our compassion nor our devotion to our country, it measures everything in short, except that which makes life worthwhile. "

Robert F. Kennedy, University of Kansas, March 18, 1968



L'interpolation du futur dans le présent

Le futur, un passé extrapolé ?

- Prendre une décision, c'est vouloir **contrôler le futur**
 - modifier une situation présente pour atteindre une situation future souhaitée
 - ◆ décision de lancer une campagne de publicité pour accroître les ventes
 - faire qu'un évènement futur ne survienne pas
 - ◆ panne machine, crime en récidive
- Pour prendre une décision, il faut donc calculer (ou imaginer) le **futur probable**
 - pour calculer le futur, il faut limiter l'infini complexité du réel, en traitant un nombre **fini** de variables (Big Data : en très grand nbre)
 - ◆ il faut créer des "cartes" du réel, plus simples que le "territoire" représenté
 - cas extrême : la carte au 1/1 de Borgès...
- **Le futur, un passé extrapolé ?**
 - Big Data : le futur est projeté (calculé) à partir des traces passées mémorisées

Les effets de distorsion

Malgré un "effet de réalité" massif, l'exhaustivité des Big Data est une illusion

- Les **erreurs** dans les données (et/ou les traitements)
 - données : ex. "traçage" d'un mobile, mais qui n'est pas celui de la personne que l'on trace, unités de mesure hétérogènes (ex. hors B.Data : crash sonde Climate Orbiter)
 - (traitements : ex. les erreurs de Google Flu Trend)
- Les **effets de biais** dans la collecte des données
 - plus la police est présente dans un quartier, plus il y a de délits enregistrés
 - ◆ "broken windows policy" => une personne d'un tel quartier aura beaucoup plus de chances d'être arrêtée pour un délit mineur qu'une personne d'un quartier "calme" pour le même délit
 - les "angles morts". Ex. : StreetBump, tweets sur l'ouragan Sandy
- Ce qui est **perdu dans la numérisation** : expérience sensible vs codage numérique
 - le codage d'un "objet" n'est pas l'objet lui-même
 - ◆ les données décrivant un client, un sentiment codé par l'informatique affective, la somme des traces numériques laissées par un étudiant sur le Web...
 - le futur réel peut être très différent du futur calculé (récidive réelle B. Parker = 0)

Retour vers le présent

Effets de rétroaction et prophéties auto-réalisatrices

- Ces effets ne sont pas propres aux Big Data
 - notion de "**perverse incentive**"
 - ◆ ex. dératisation en Indochine, paléontologues en Chine (19ème)
 - effets de rétroaction des indicateurs d'évaluation
 - ◆ salariés travaillent pour améliorer l'objectif, fût-ce au détriment de la qualité : ex. opérateurs centre d'appel évalués au nombre d'appels pris
 - ◆ comportement des chercheurs : multiplication des publications, choix des sujets...
- Mais : généralisés par les Big Data (rétroactions souvent recherchées)
 - **prophétie auto-réalisatrice**
 - ◆ ex. score de récidive : plus une personne est lourdement condamnée plus elle aura plus de difficulté à se réinsérer après sa sortie de prison...
 - **rétroaction**
 - ◆ renforcement des structures existantes : groupes partageant les mêmes opinions, inégalités (assurances santé, recrutements...), comportements standards
 - ◆ pb. aggravé par le caractère caché des algorithmes : ex. notation d'enseignants (É.-U.)

➔ **Le futur : un présent caricaturé ?**

Main basse sur le futur

Du prédictif au prescriptif

- De même qu'il est tentant d'assimiler corrélation et causalité, **il est facile de glisser du prédictif au prescriptif**
 - en oubliant les distorsions, en confondant futur projeté / futur effectif (réel)
- Risque majeur : qu'un grand nombre de décisions soient prises **sur la seule base du futur projeté**
 - condamnation à x années de prison sur la base d'un délit/crime qui **pourrait** être commis dans le futur
 - ◆ condamnation pour un acte non accompli => contraire aux principes du droit
 - assassinat par drones de personnes sur **la base de leur profil**
- La baisse des dépenses publiques pourrait accroître ce risque
 - les décisions "automatiques" sont moins coûteuses
 - ◆ si l'on ne considère que le court terme, la ligne budgétaire et non les effets systémiques

Démocratie, hasard et diversité

- Big Data : l'horreur du risque
 - c'est-à-dire du hasard, de l'imprévu, de l'imprévisible
- Or, il n'y a pas de diversité sans hasard...
- pas de diversité sans **temps long**...
- pas de démocratie sans diversité
- Responsabilité citoyenne
 - défendre une démocratie de débat
 - ◆ limiter les collectes de données automatiques
 - contrôler la mise en place et le fonctionnement des décisions automatiques
 - ◆ nota : progrès avec la Loi sur le numérique (Fr.) et le règlement européen
- Plus largement, discuter et décider collectivement de **ce que le numérique ne saurait coder***

* *En hommage à Michael Sandel ("Ce que l'argent ne saurait acheter")*



Éléments de bibliographie

- Boyd D., Crawford K., "Six Provocations for Big Data", A Decade in Internet Time: Symposium on the Dynamics of the Internet and Society, 2012. https://papers.ssrn.com/sol3/papers.cfm?abstract_id=1926431
- Crawford K., "The Hidden Biases in Big Data", Harvard Business Review, avril, 2013.
- Davis K., Patterson D., Ethics of Big Data, O'Reilly Media, 2012.
- Mayer-Schonberger V., Cukier K., "Big Data: A Revolution That Will Transform How We Live, Work, and Think", John Murray Publishers Ltd, 2013. Traduction française : "Big Data. La révolution des données est en marche", Robert Laffont, 2014.
- O'Neil C., "Weapons of Math Destruction", Crown, New York, 2016. <https://mathbabe.org/>
- Rouvroy A., travaux divers : https://works.bepress.com/antoinette_rouvroy/
- Salles M., "La responsabilité économique et sociale des concepteurs de systèmes d'information : contribution à une éthique appliquée", Innovations, Revue d'Économie et de Management de l'Innovation (I-REMI), n° 46, vol. 1, pp. 197-226, 2015.
- Salles Maryse, "Décision et système d'information", Collection Systèmes d'information avancés, Vol. 2, ISTE-WILEY, 2015.
- Schneier B., "Data and Goliath", W. W. Norton, New York, 2015. www.schneier.com
- Stahl B. C., "Researching Ethics and Morality in Information Systems: Some Guiding Questions", ICIS 2008, 2008
- Stiegler B., "De la gouvernementalité algorithmique de fait au nouvel état de droit qu'il lui faut", Notes du Séminaire Digital Studies, 7 octobre, 2014. <https://digital-studies.org/wp/antoinette-rouvroy-et-bernard-stiegler-07102014/>
- Weizenbaum J., "Computer Power and Human Reason: From Judgment To Calculation", W. H. Freeman, San Francisco, 1976. Traduction française : "Puissance de l'ordinateur et raison de l'homme : du jugement au calcul", Éditions Informatique, 1981.