



Les données:
pierre angulaire de
l'intelligence artificielle
Guillaume Chicoisne



IVADO

HEC Montréal
Polytechnique Montréal
Université de Montréal

TL;DR

- L'intelligence artificielle actuelle se construit sur les données
- Manipuler et comprendre les données sont deux compétences différentes
- Le monde des données n'est pas le monde réel

Intelligence artificielle et intelligence naturelle

Définition?

- C'est compliqué...
- Autant définir l'intelligence naturelle...



Intelligence artificielle ou *deep learning*?

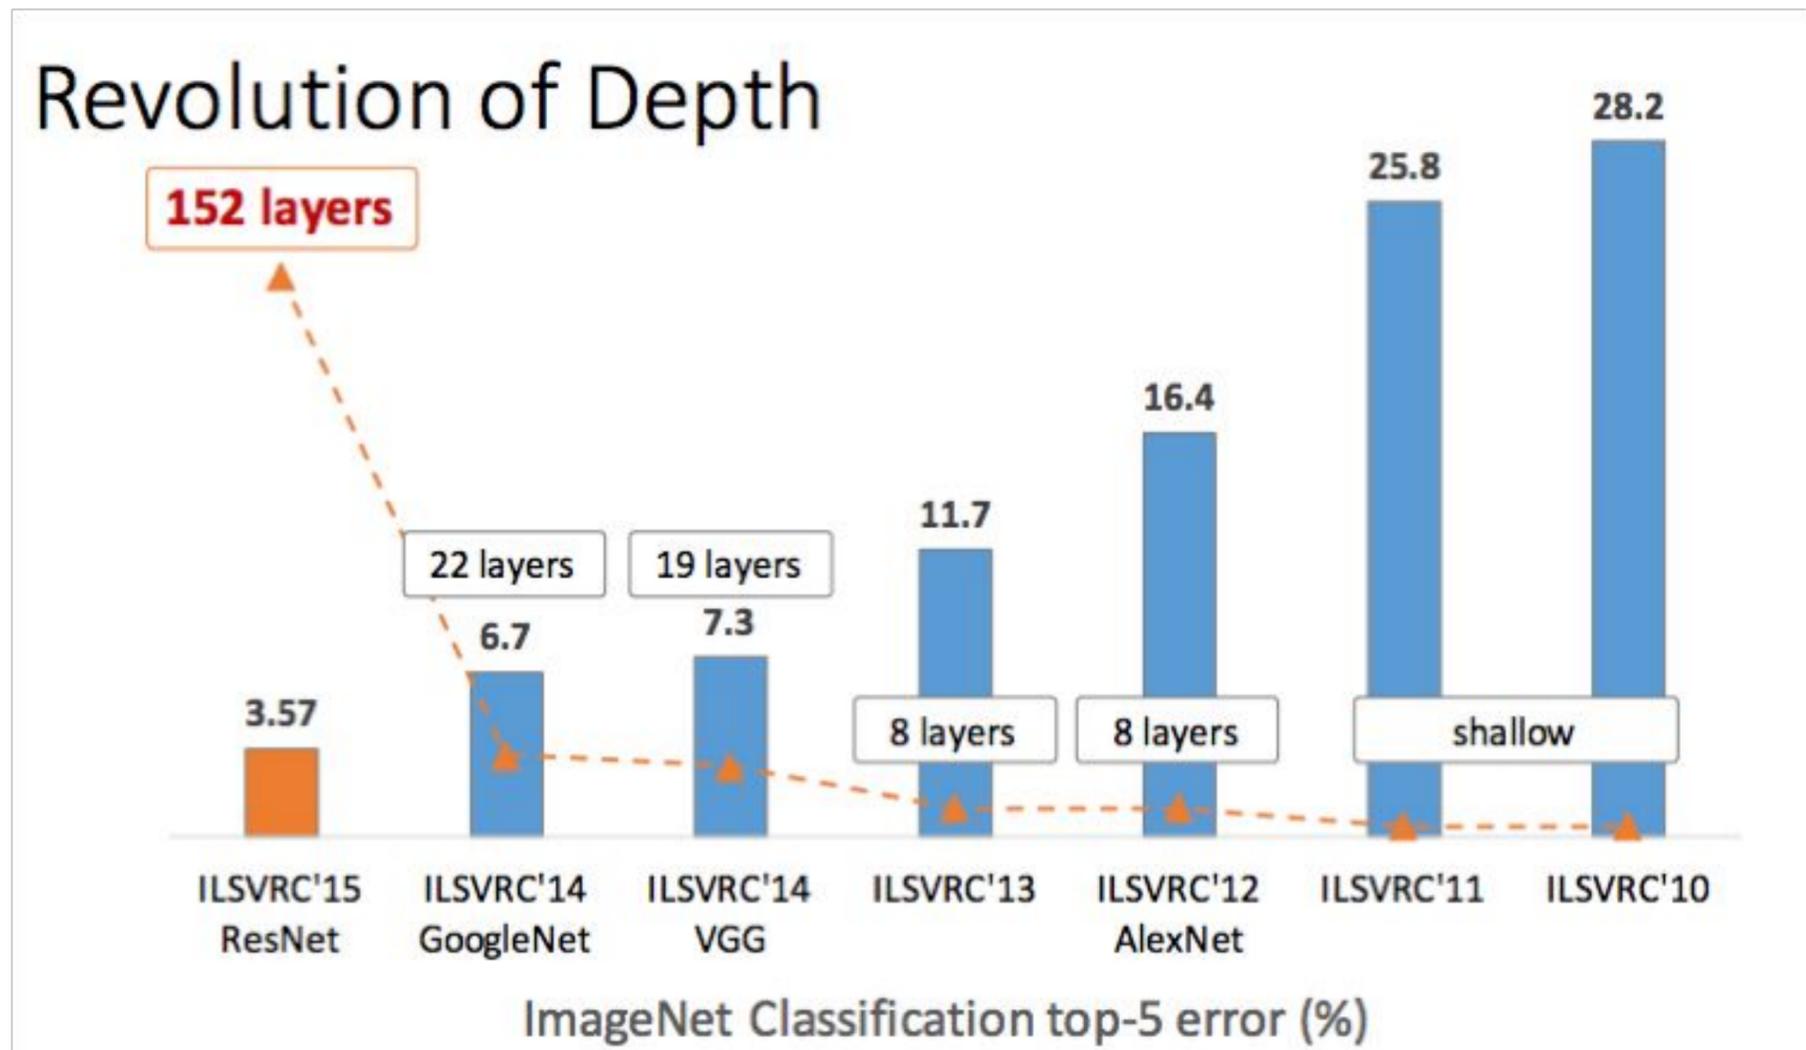
Intelligence artificielle

Apprentissage machine

Apprentissage profond

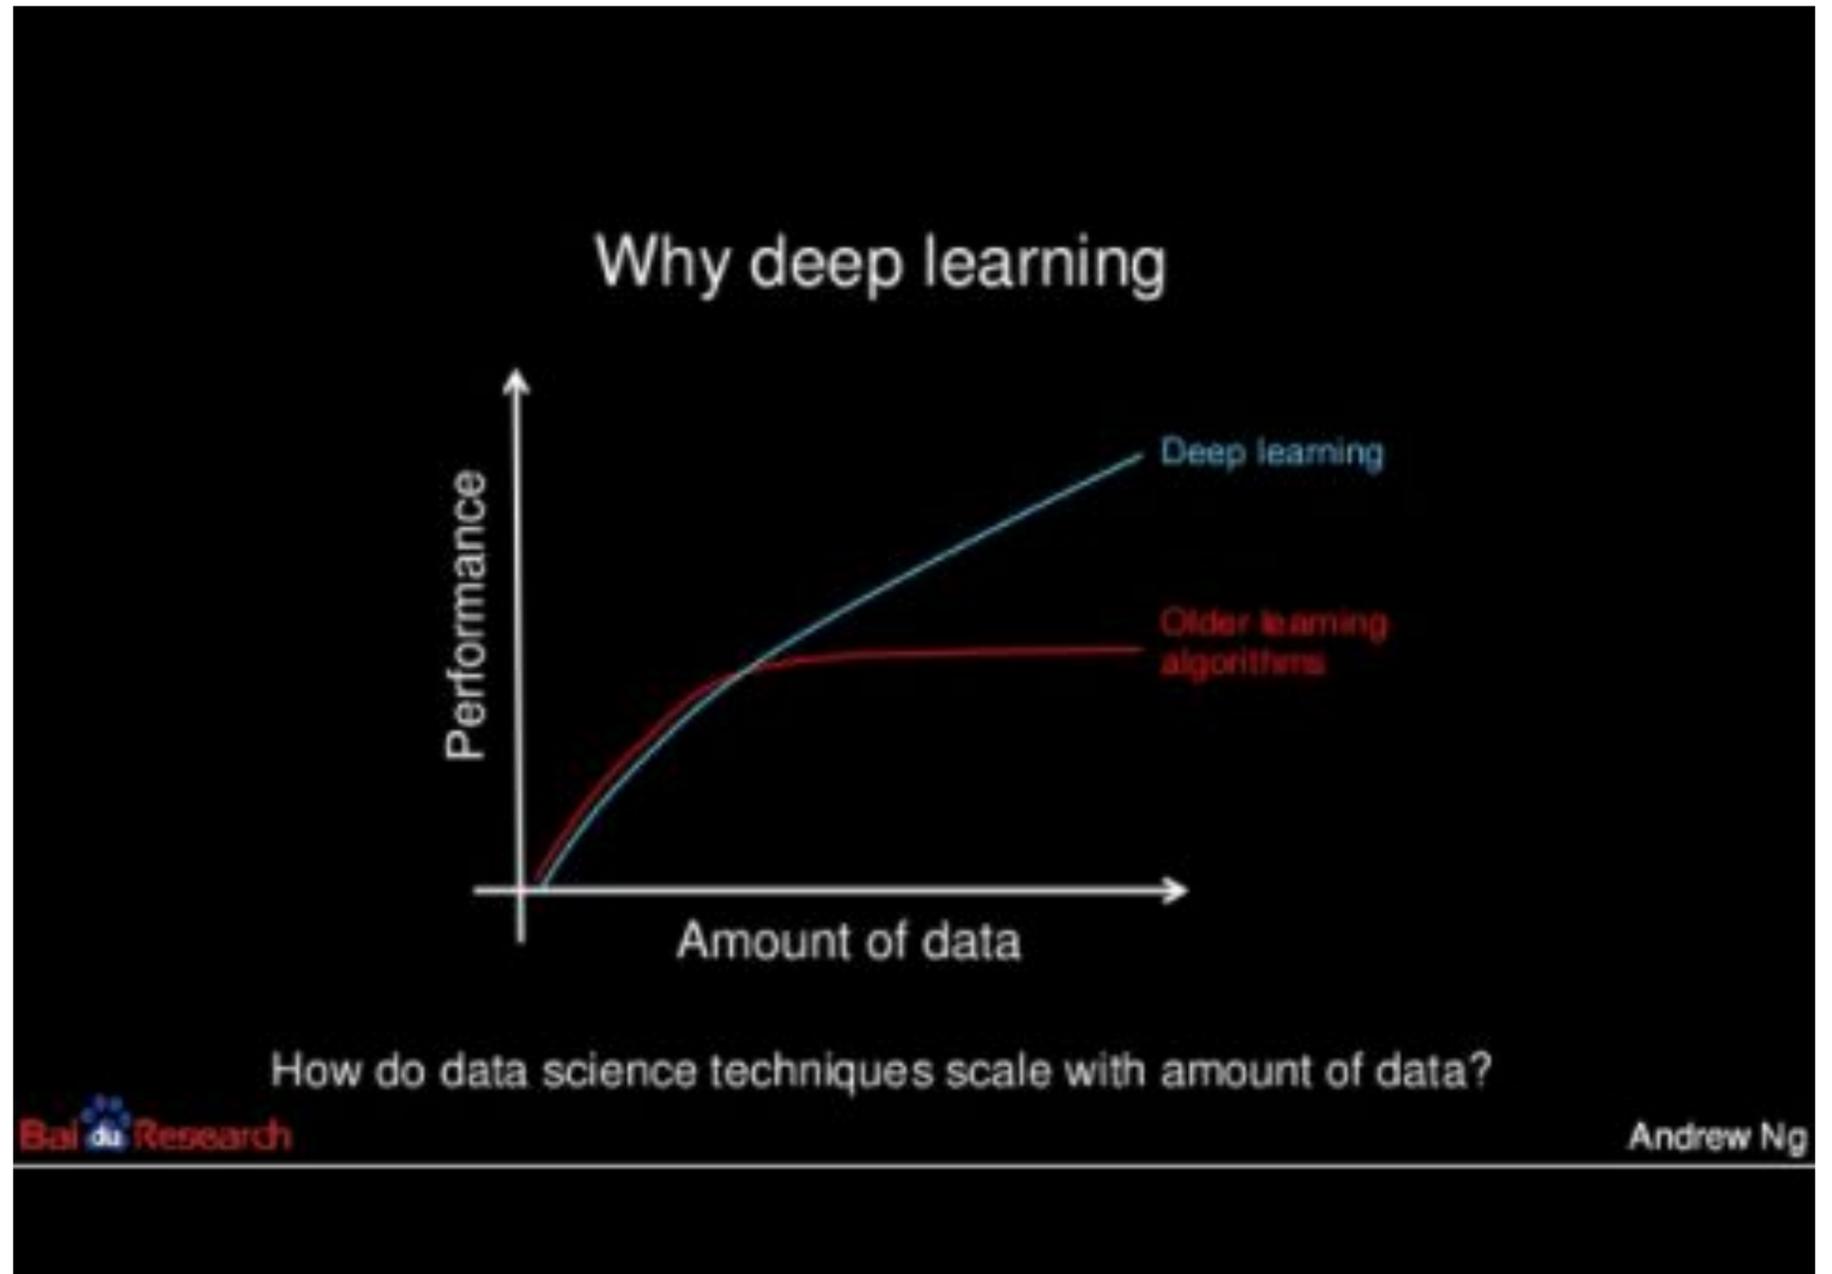
La nouvelle vague de l'IA

- + Des **données** de plus en plus nombreuses et accessibles
 - + Des **outils** capables d'utiliser une grande quantité de données
 - + De la **puissance** de calcul
- = résultats sur des tâches très différentes: reconnaissance de parole, analyse d'image, ...



La nouvelle vague de l'IA

- + Des **données** de plus en plus nombreuses et accessibles
 - + Des **outils** capables d'utiliser une grande quantité de données
 - + De la **puissance** de calcul
- = résultats sur des tâches très différentes: reconnaissance de parole, analyse d'image, ...

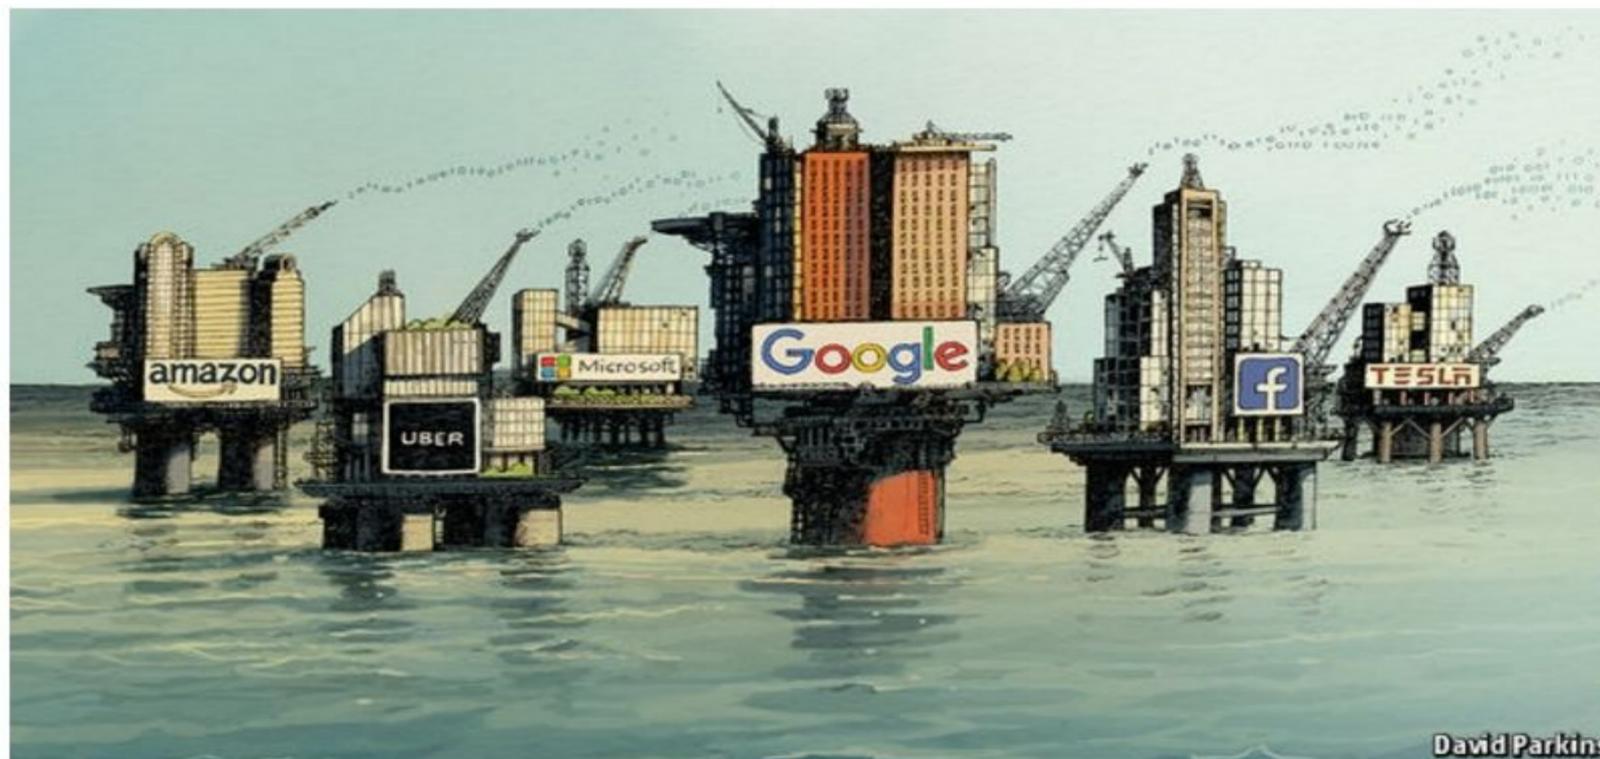


Le nouveau pétrole?

Regulating the internet giants

The world's most valuable resource is no longer oil, but data

The data economy demands a new approach to antitrust rules



- L'accès est parfois difficile et coûteux
- La valeur augmente avec le raffinage
- Raffiner coûte cher
- Avantage économique à la concentration des ressources
- ...

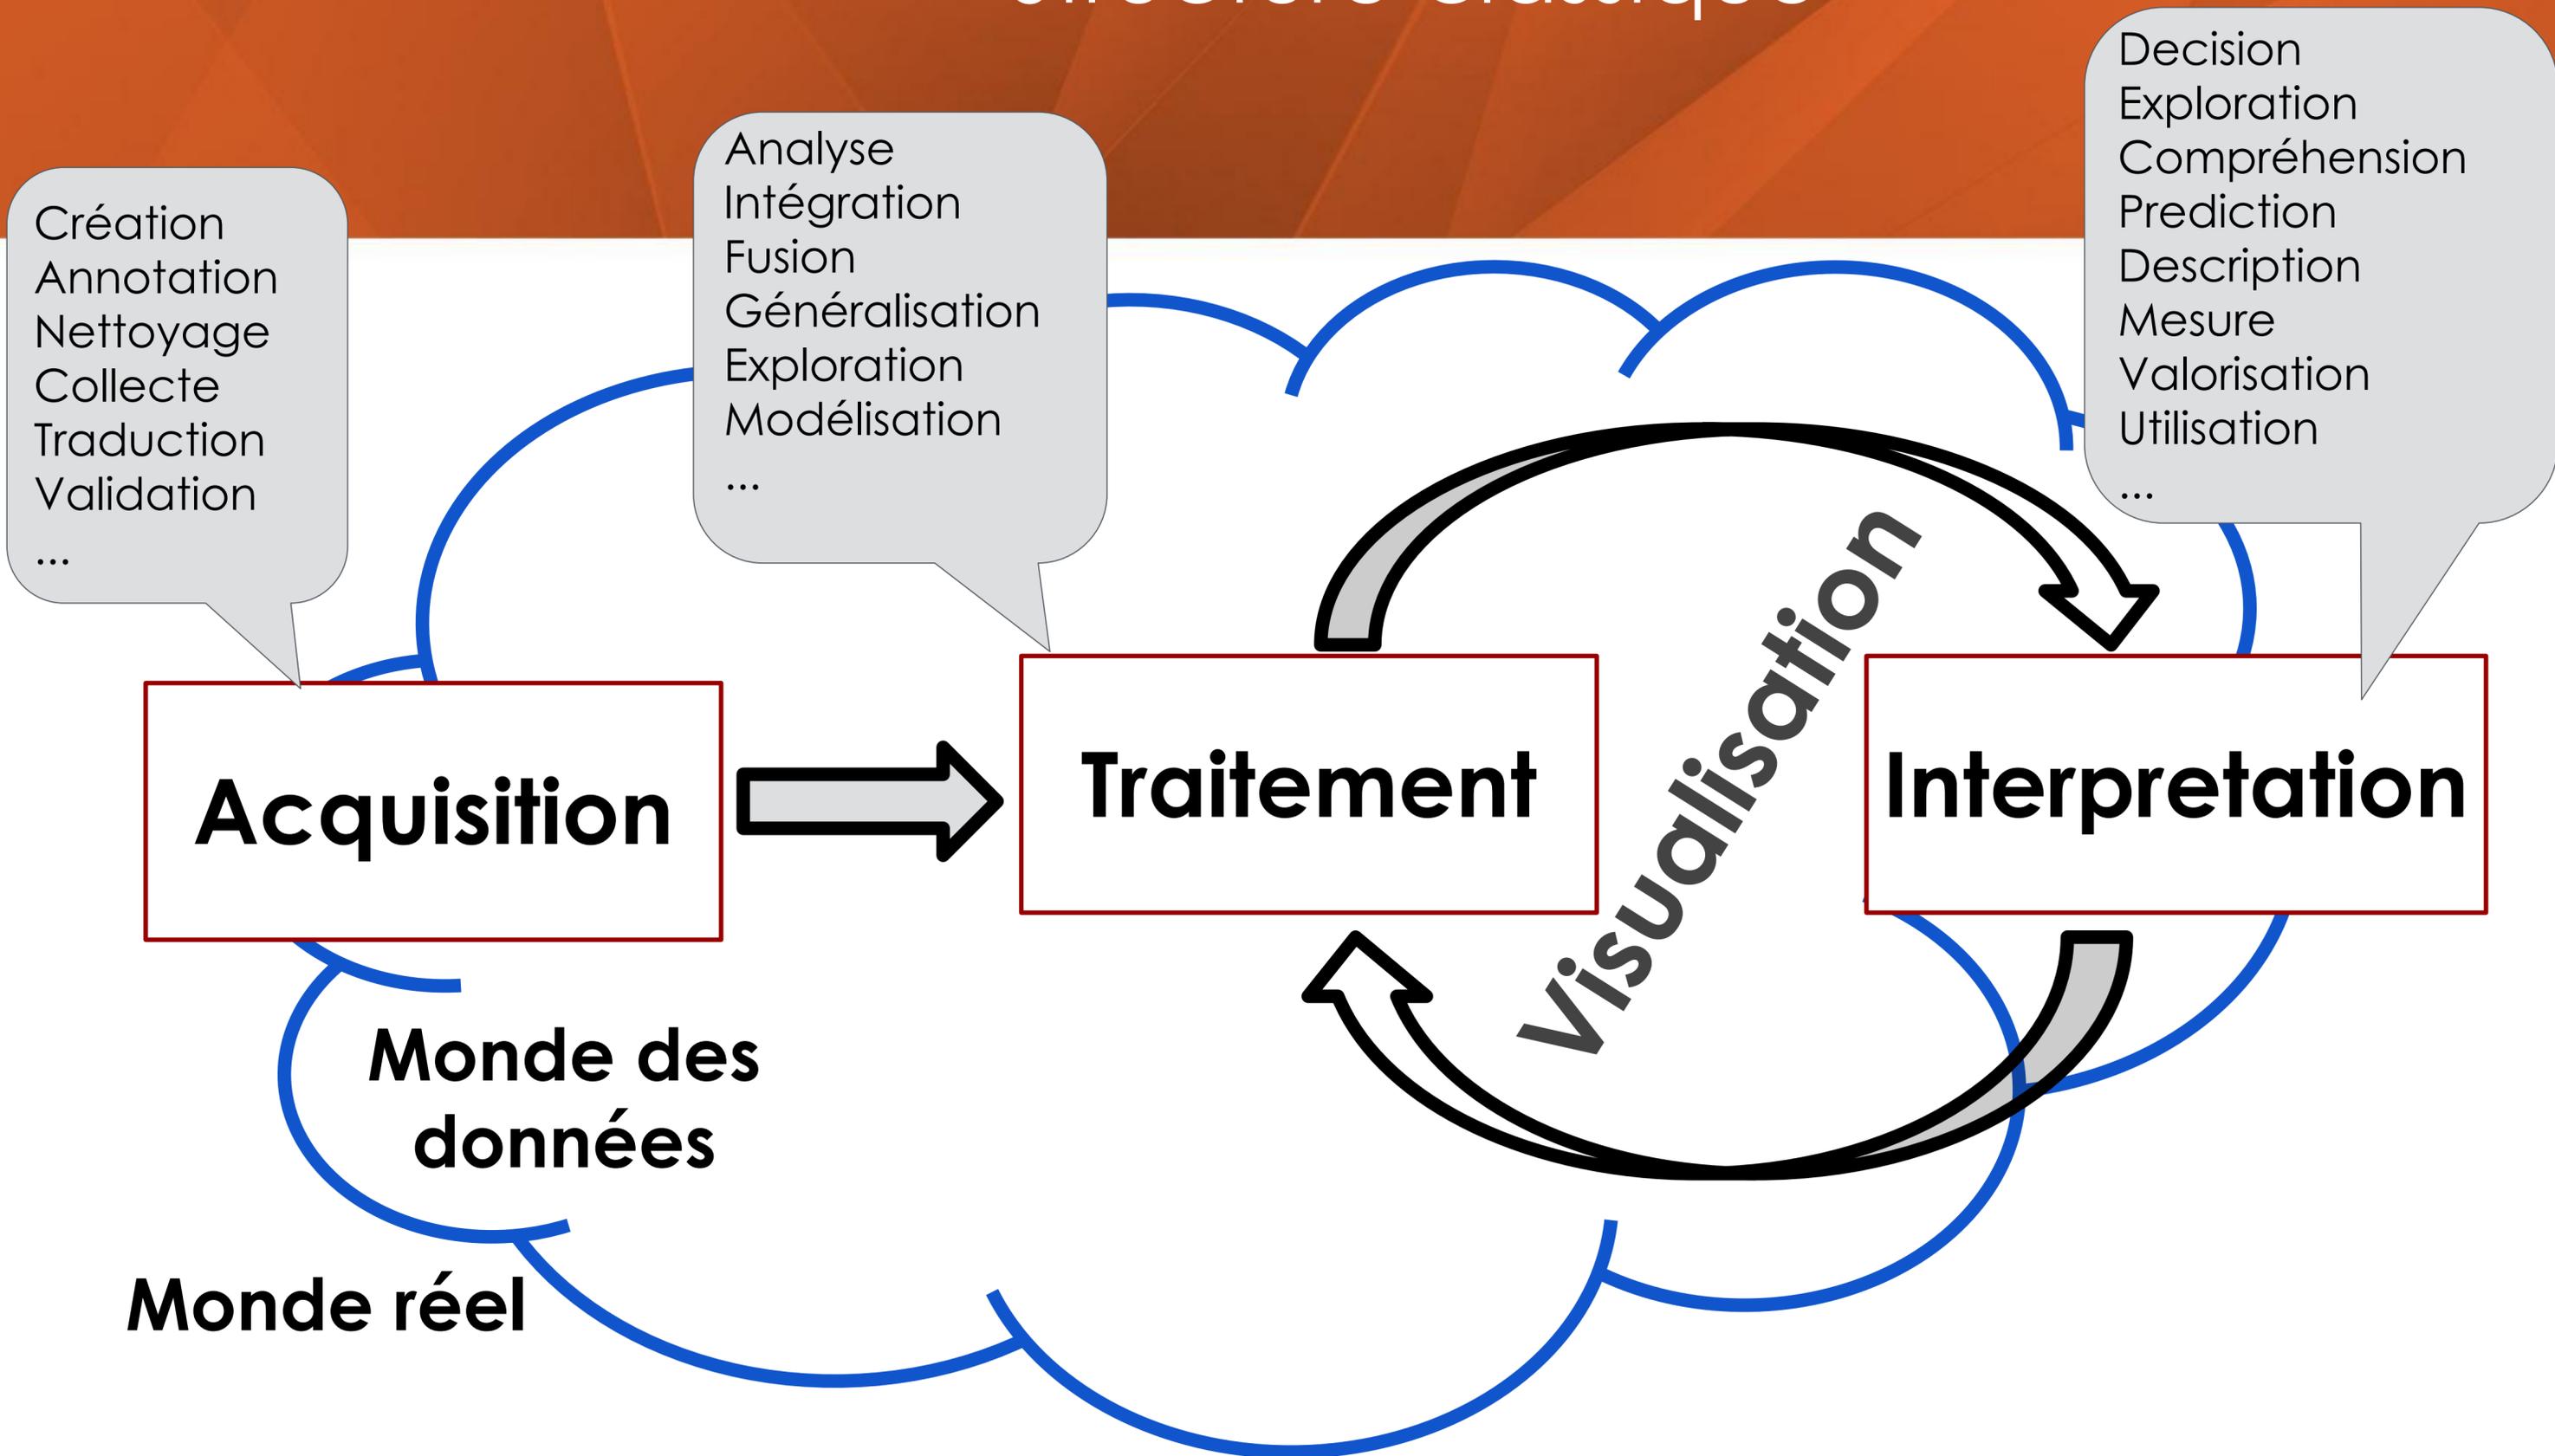
Données?

Les données sont une façon de numériser le monde.

- Ce qui nous intéresse n'est pas forcément mesurable
- Ce qui est facilement mesurable n'est pas forcément ce qui nous intéresse
- Les mesures indirectes doivent générer d'autant plus de méfiance

Le monde des données n'est pas le monde réel

Structure classique



Créer, acquérir, accéder (le 80% laborieux)

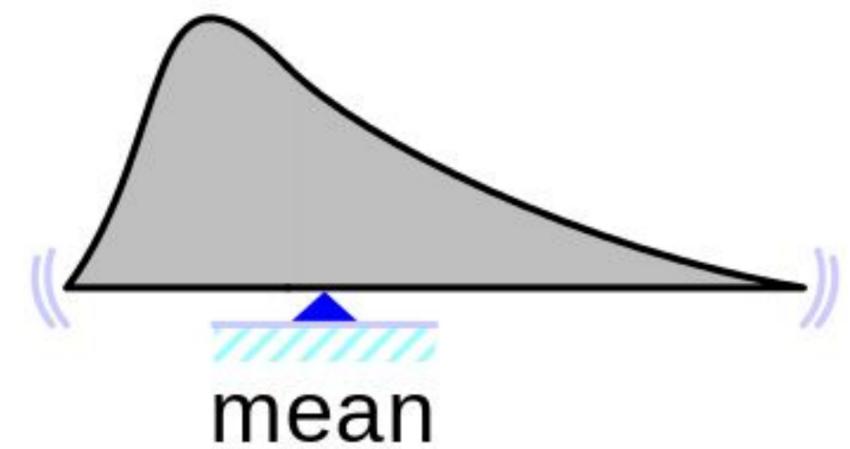
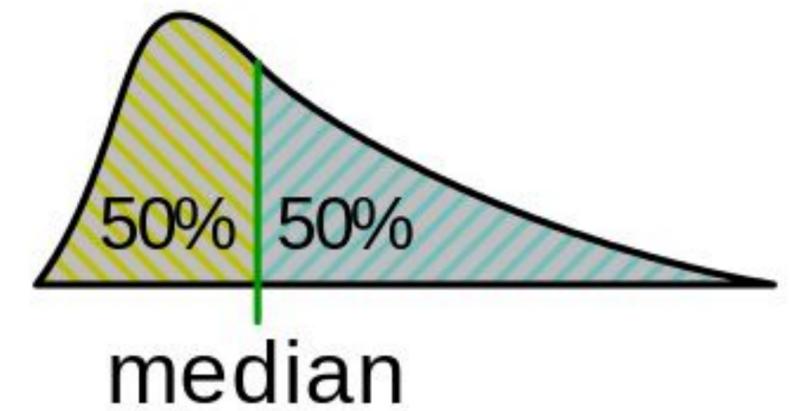
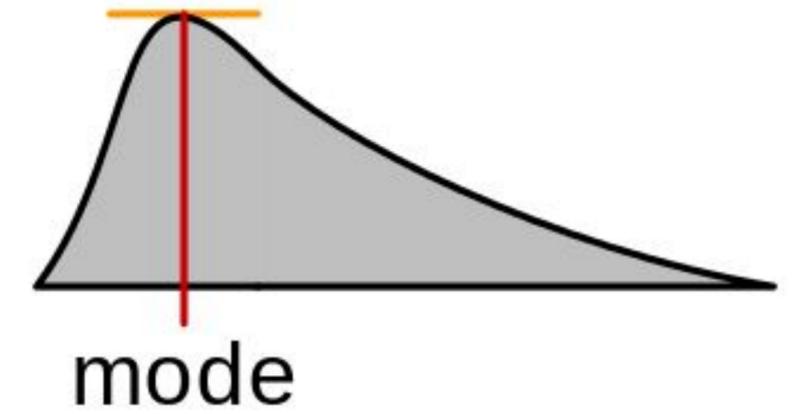
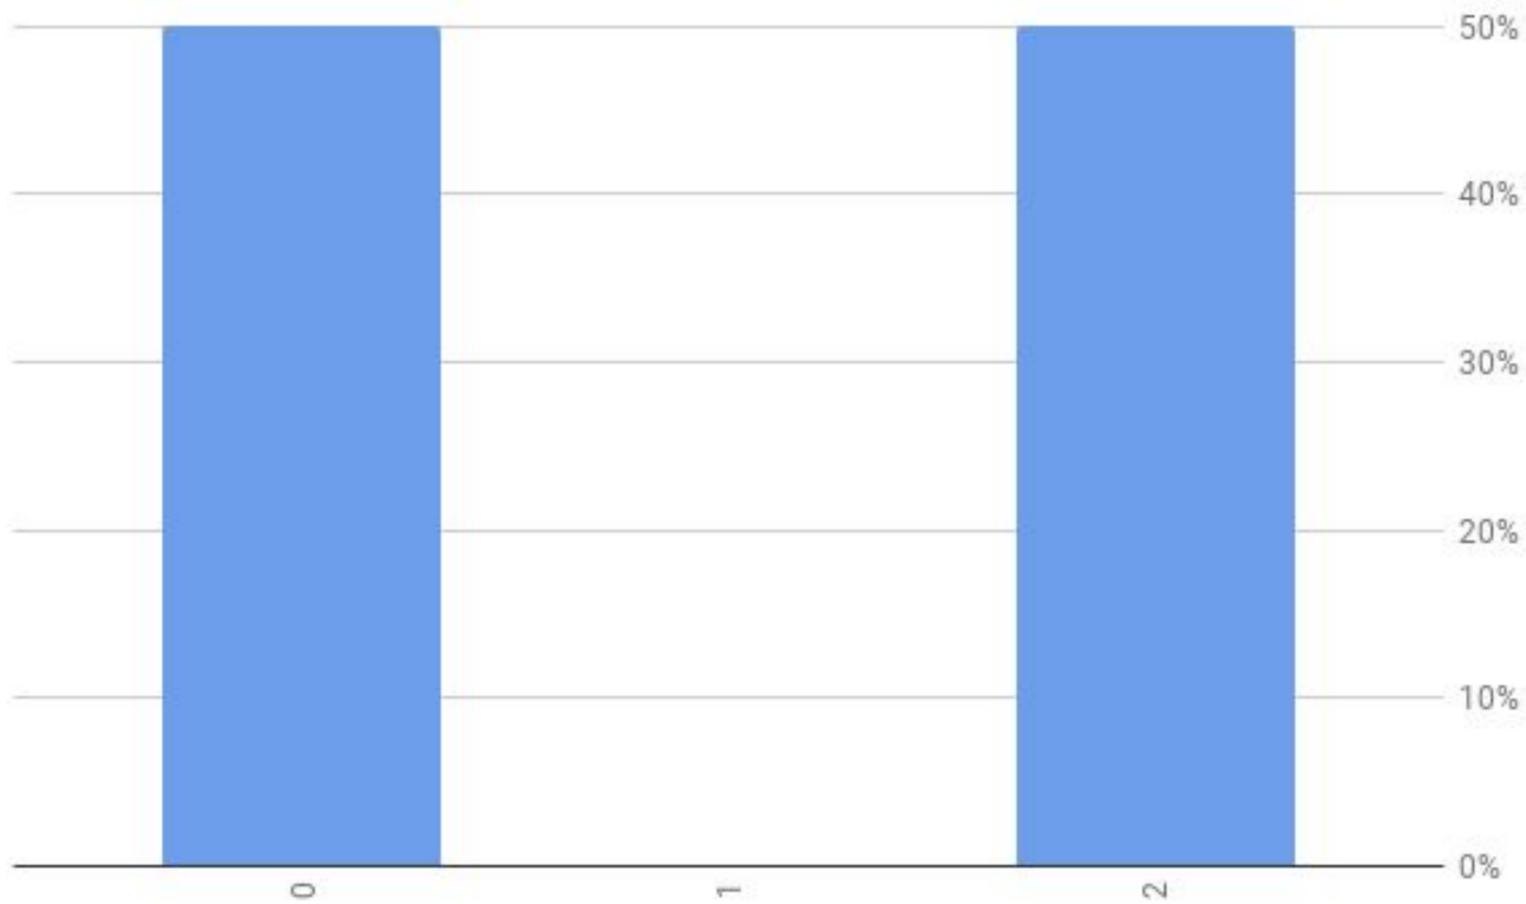
(un banquier et son client)

- C'est quoi l'problème mes dollars m'appartiennent, j'suis supposé pouvoir les retirer facilement?!
- Non!
- Quoi?
- Vos fémurs aussi vous appartiennent, pis vous pouvez pas les retirer facilement!

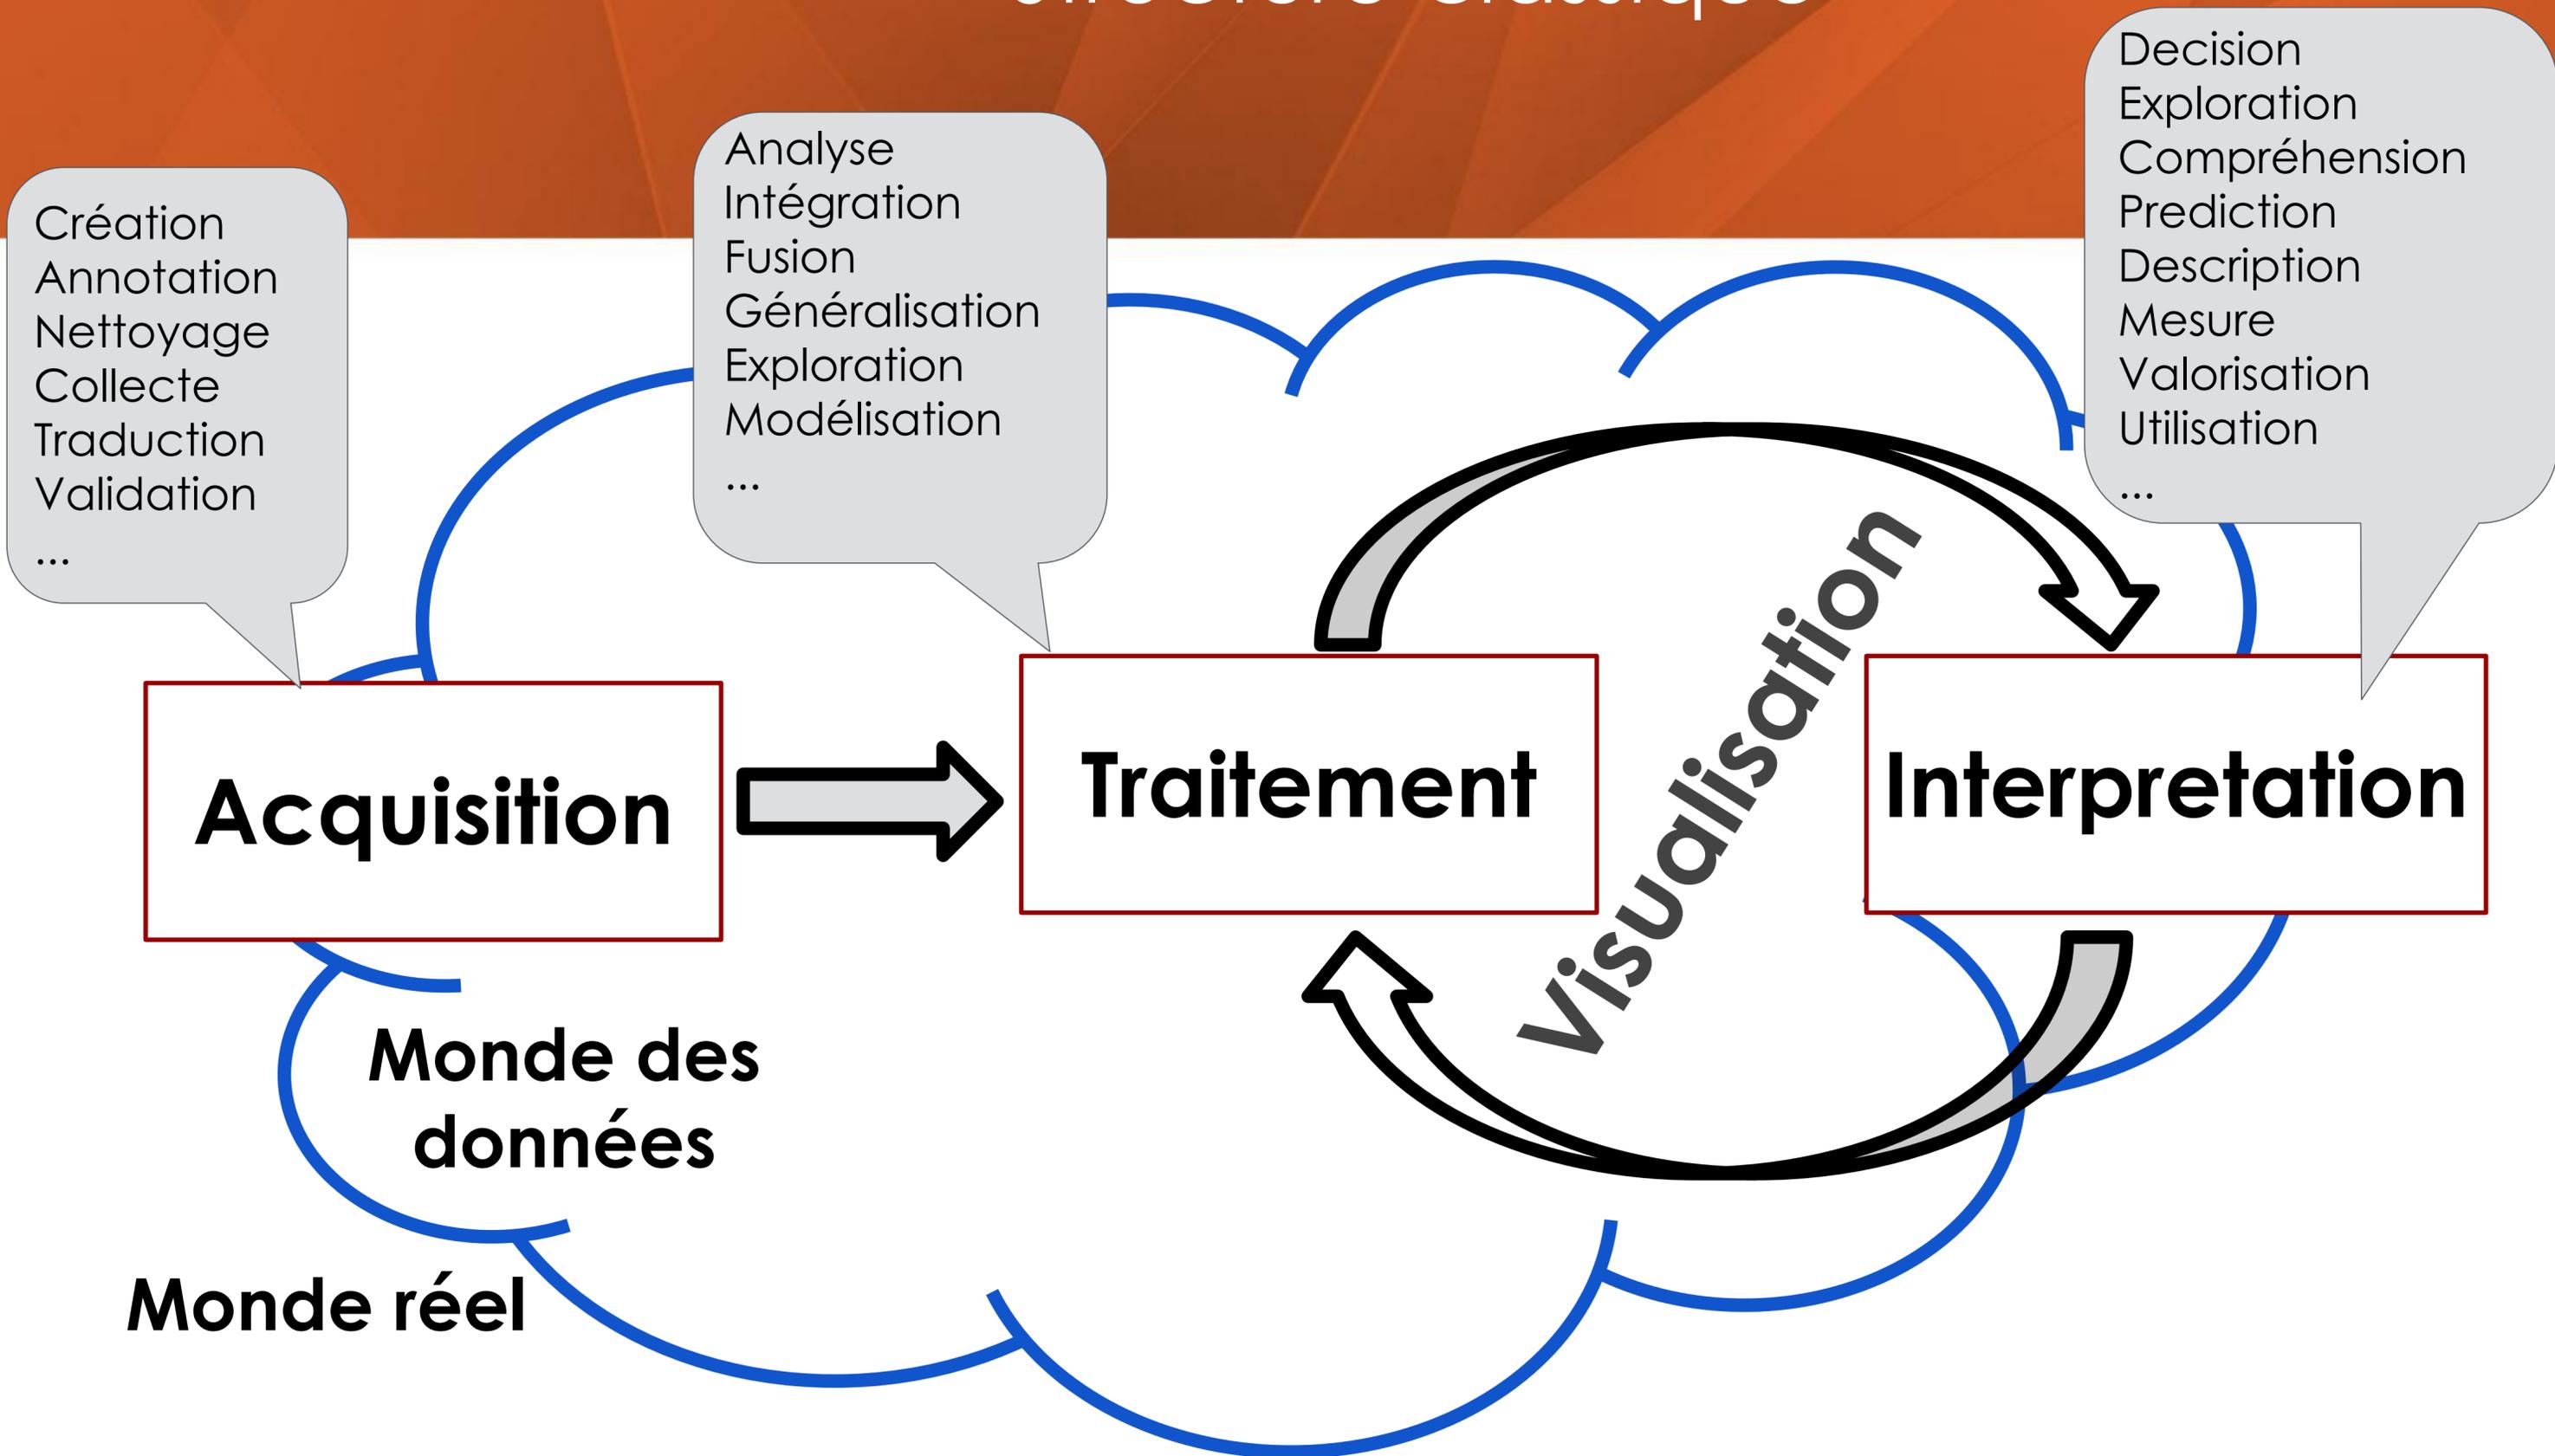
(François Pérusse, Philosophe québécois)

Intermède statistique

- Moyenne? Mode? Médiane?
- Corrélation?

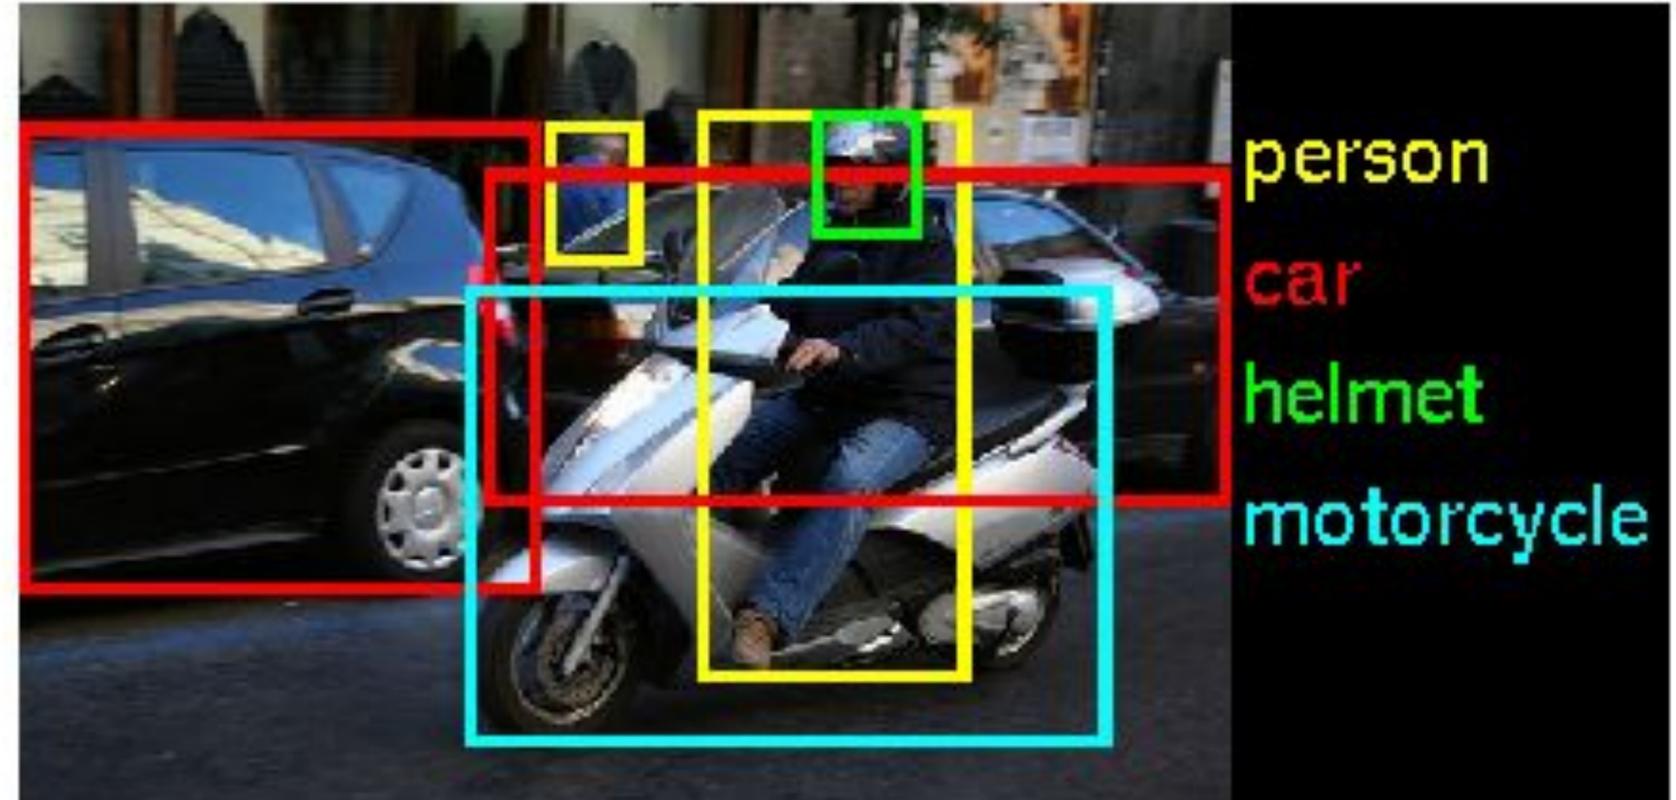
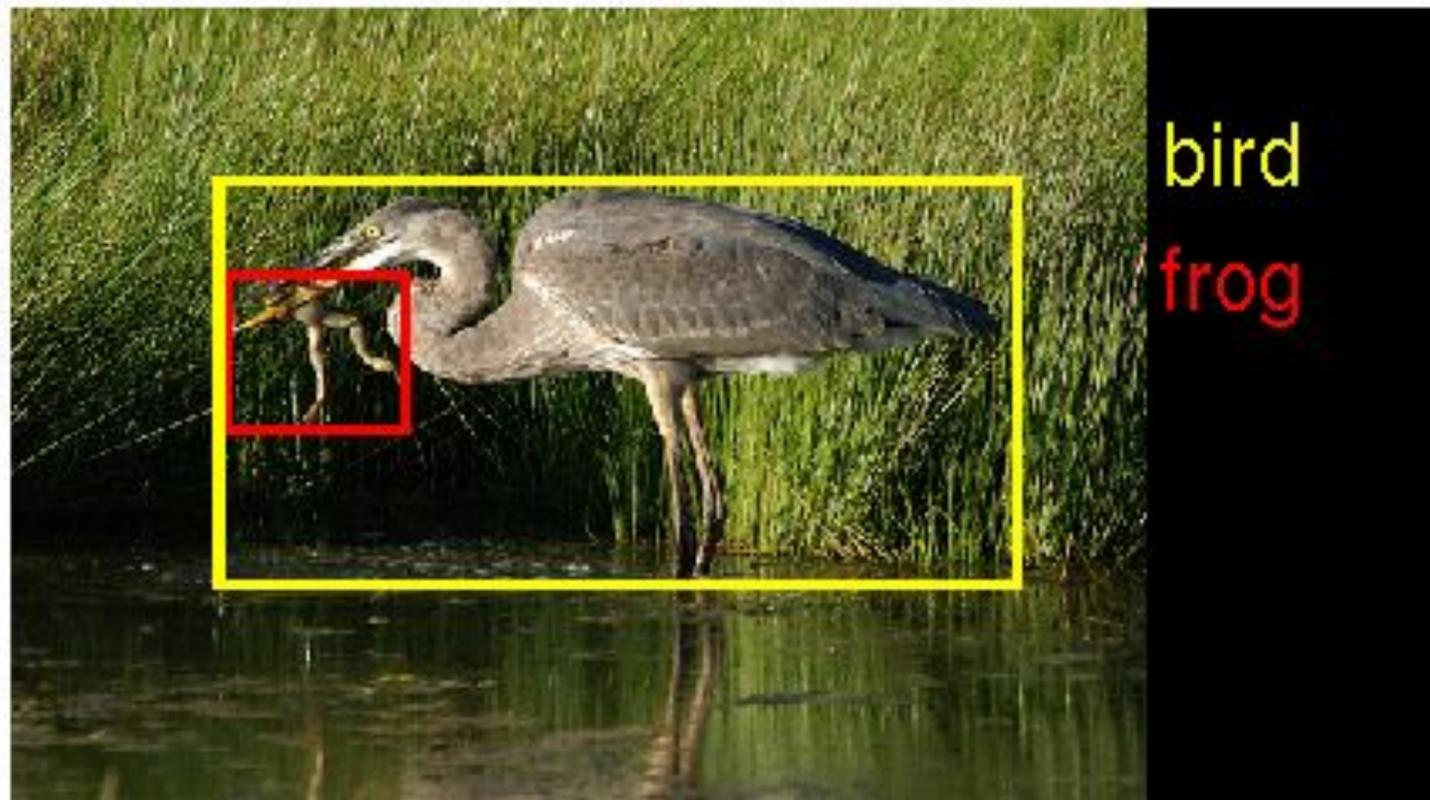


Structure classique

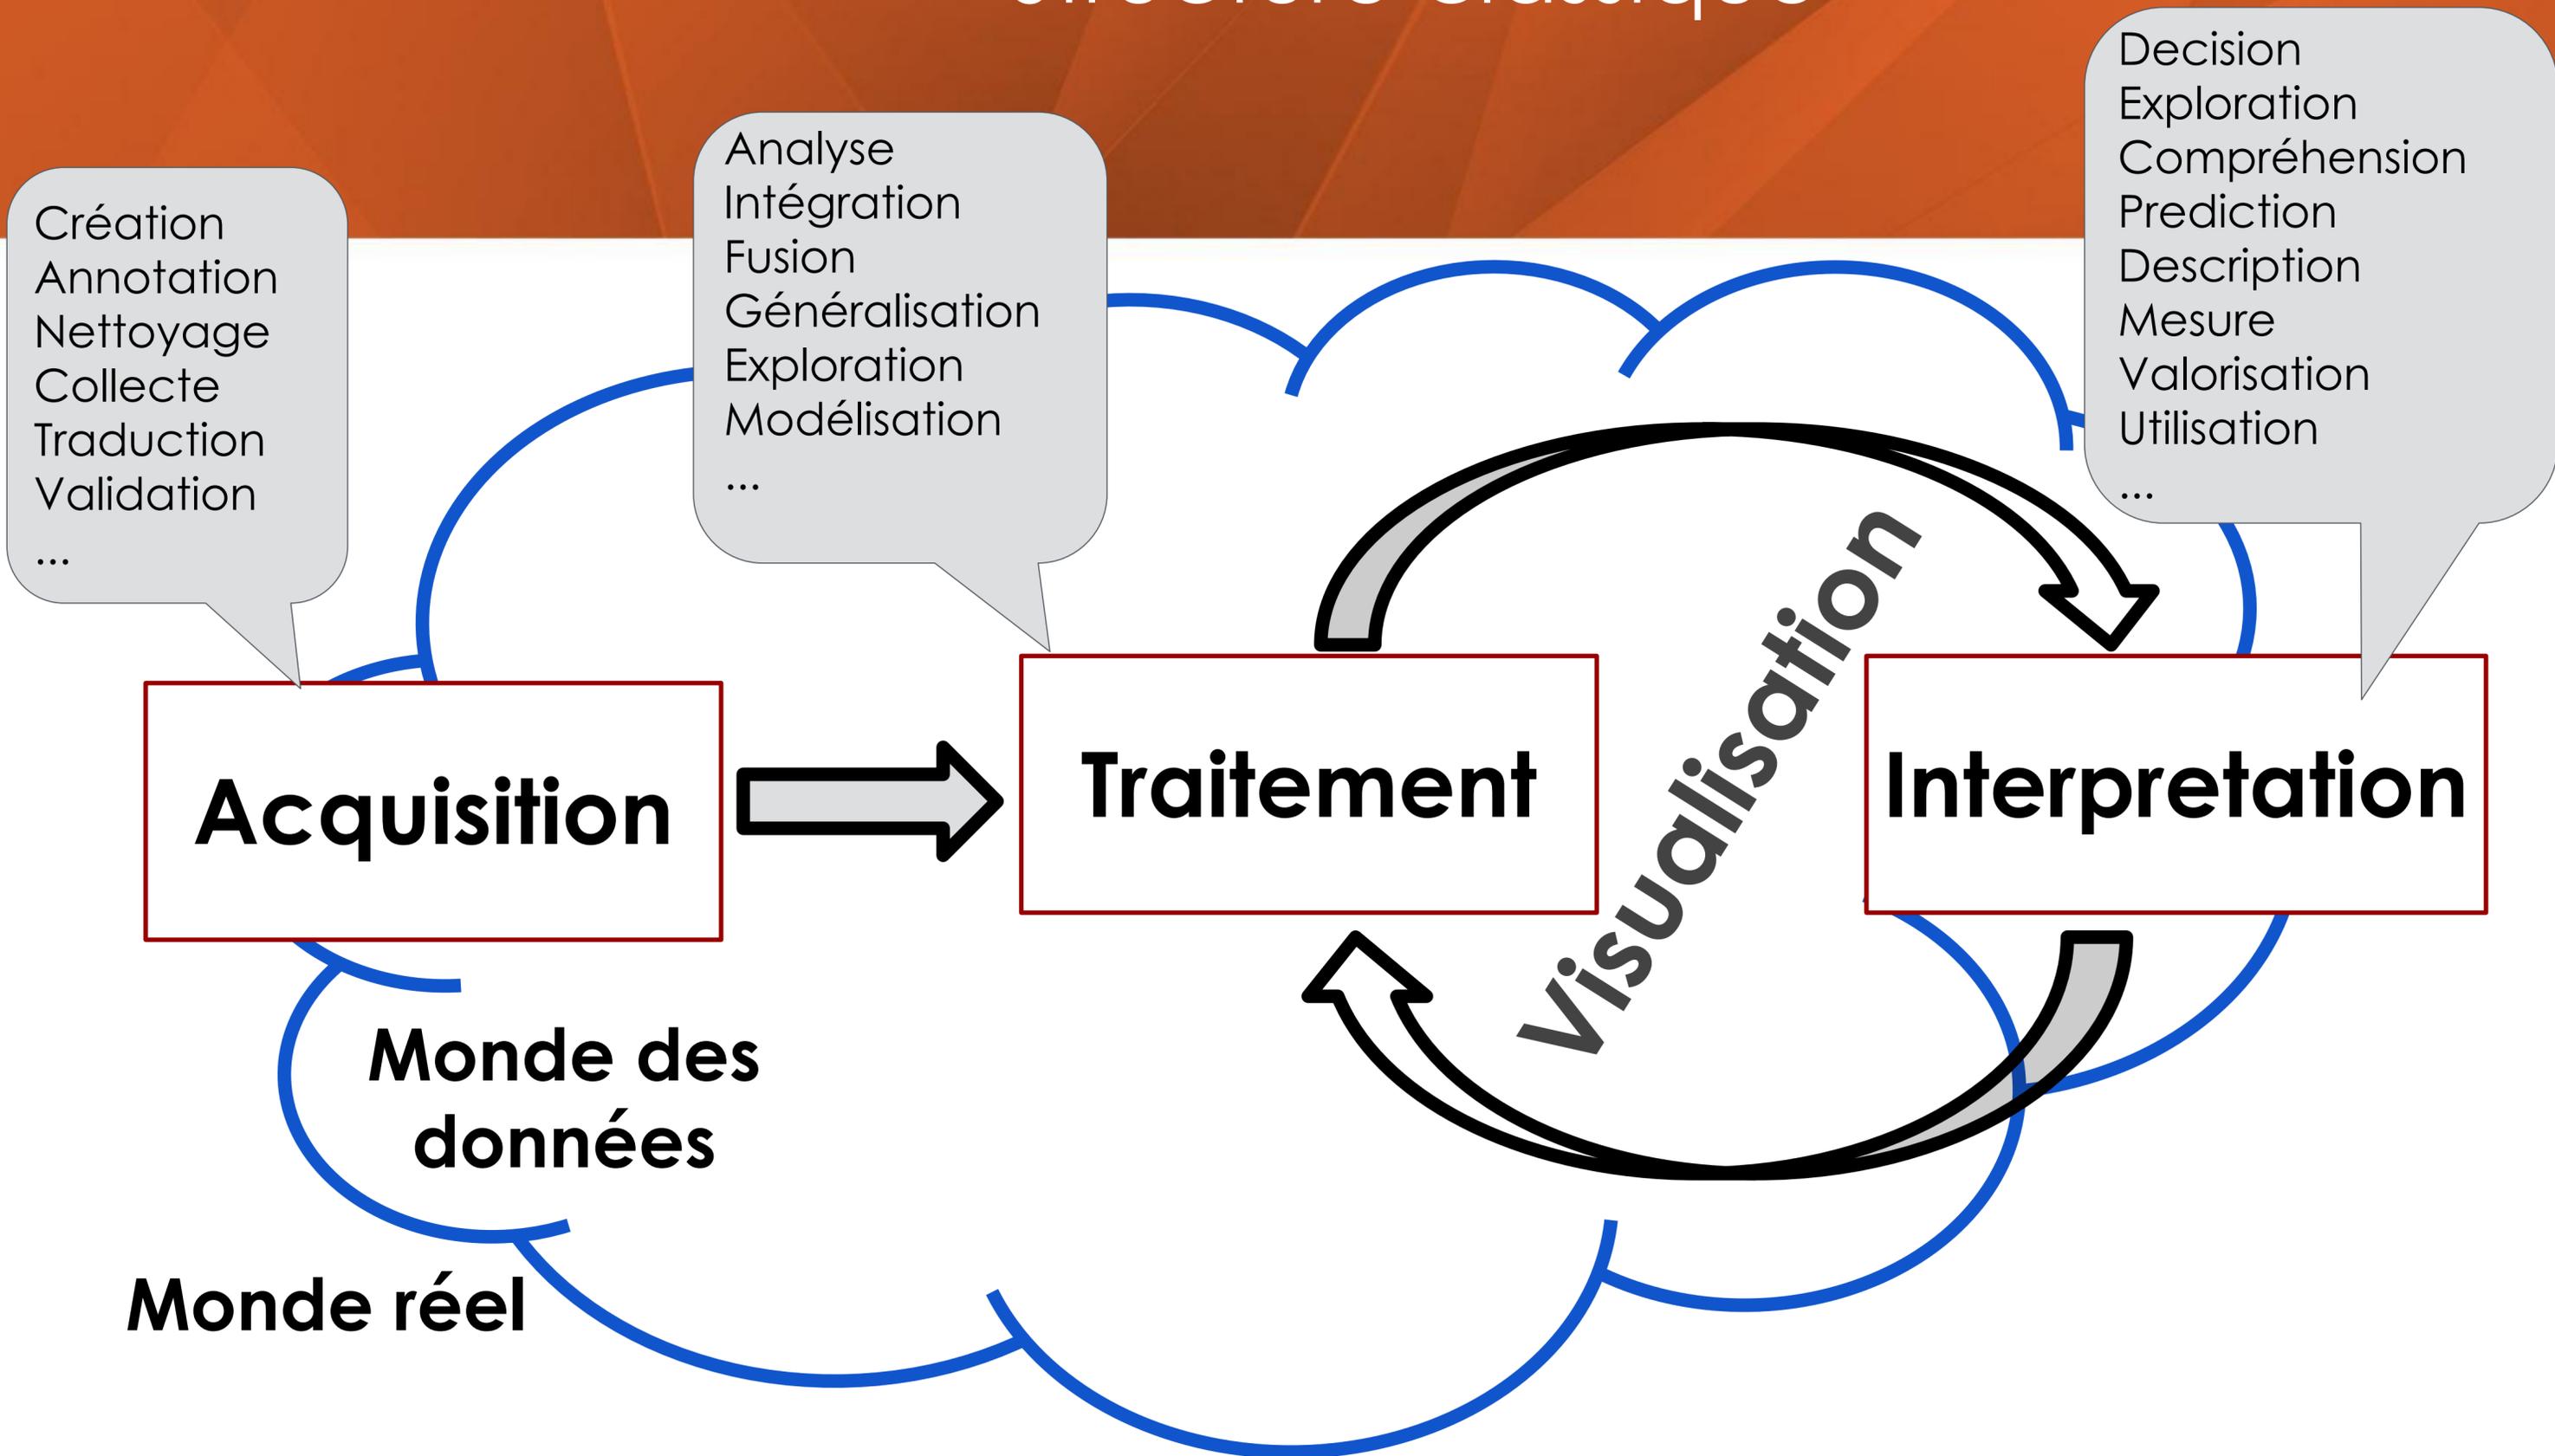


Traitement

- Grand choix de méthodes, depuis les modèles statistiques simples, jusqu'à l'apprentissage profond.
- Les méthodes les plus simples sont parfois les plus adaptées

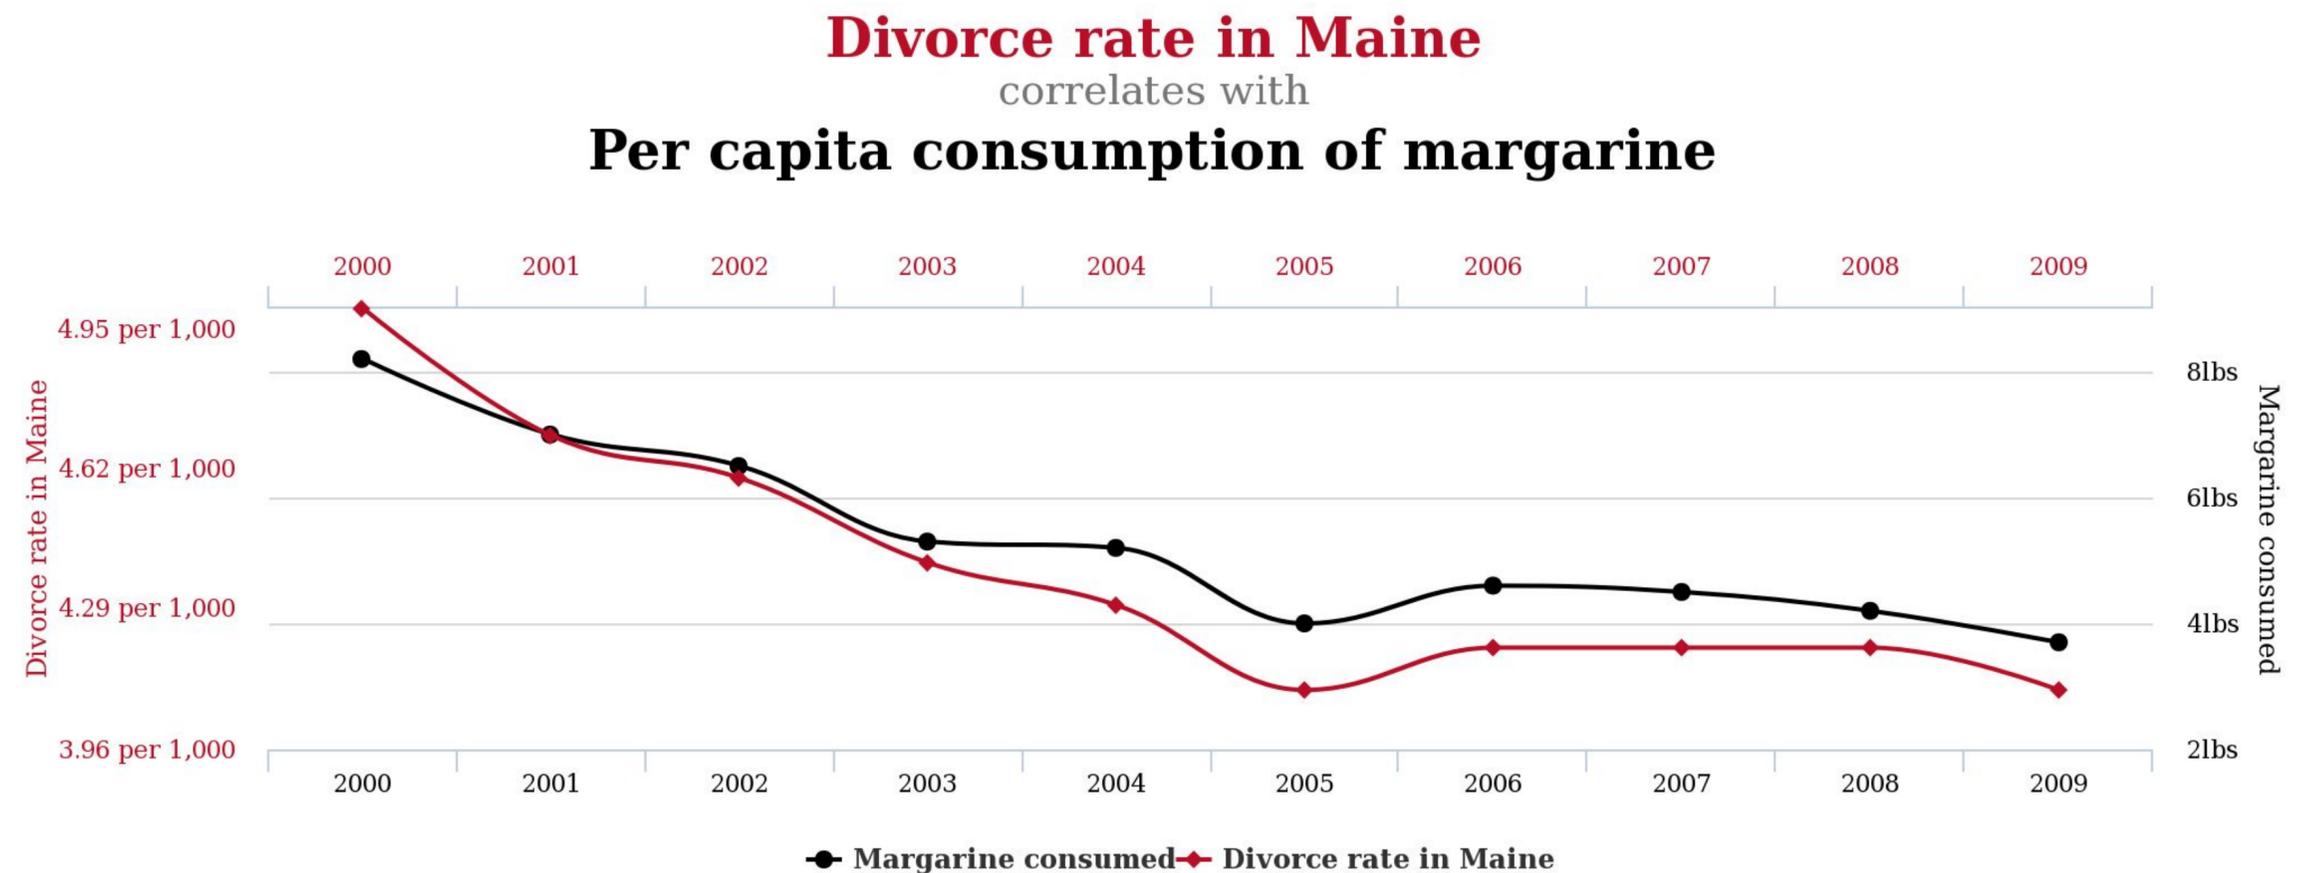


Structure classique

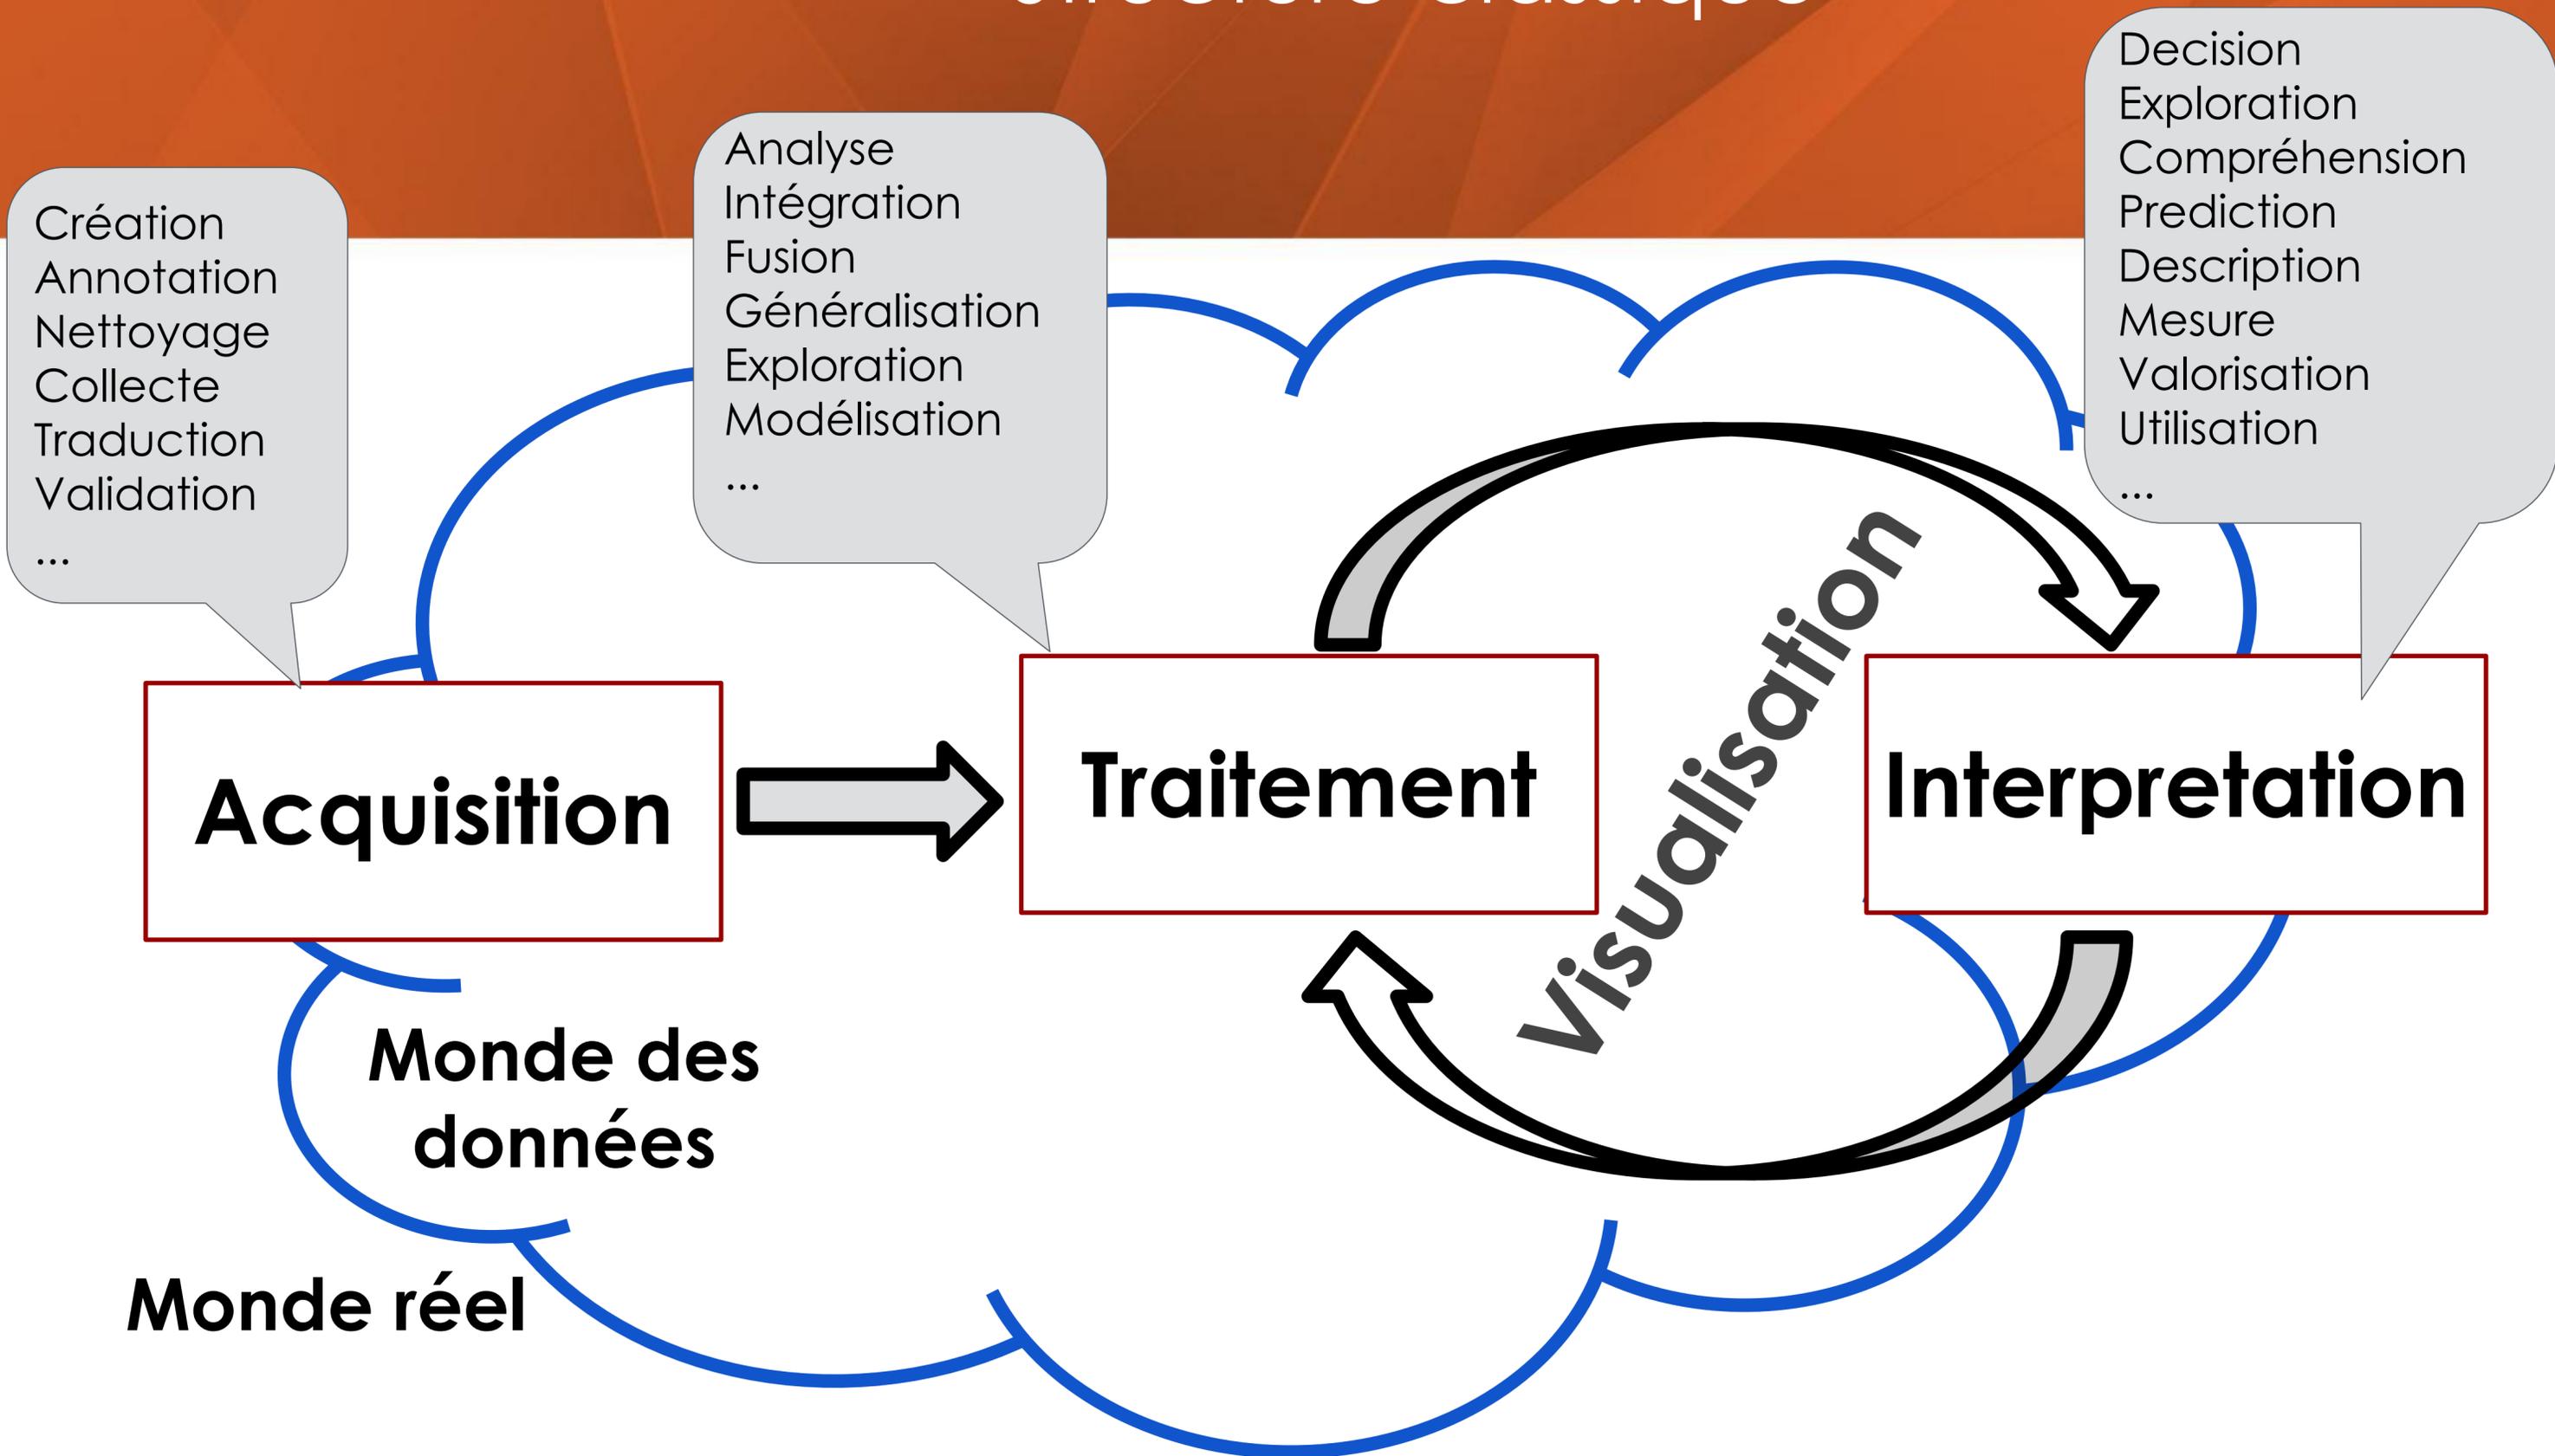


Interprétation

- Confronter les analyses au monde réel:
 - Prendre ou appuyer une décision, mesurer une progression, explorer ...
 - Valider les résultats!

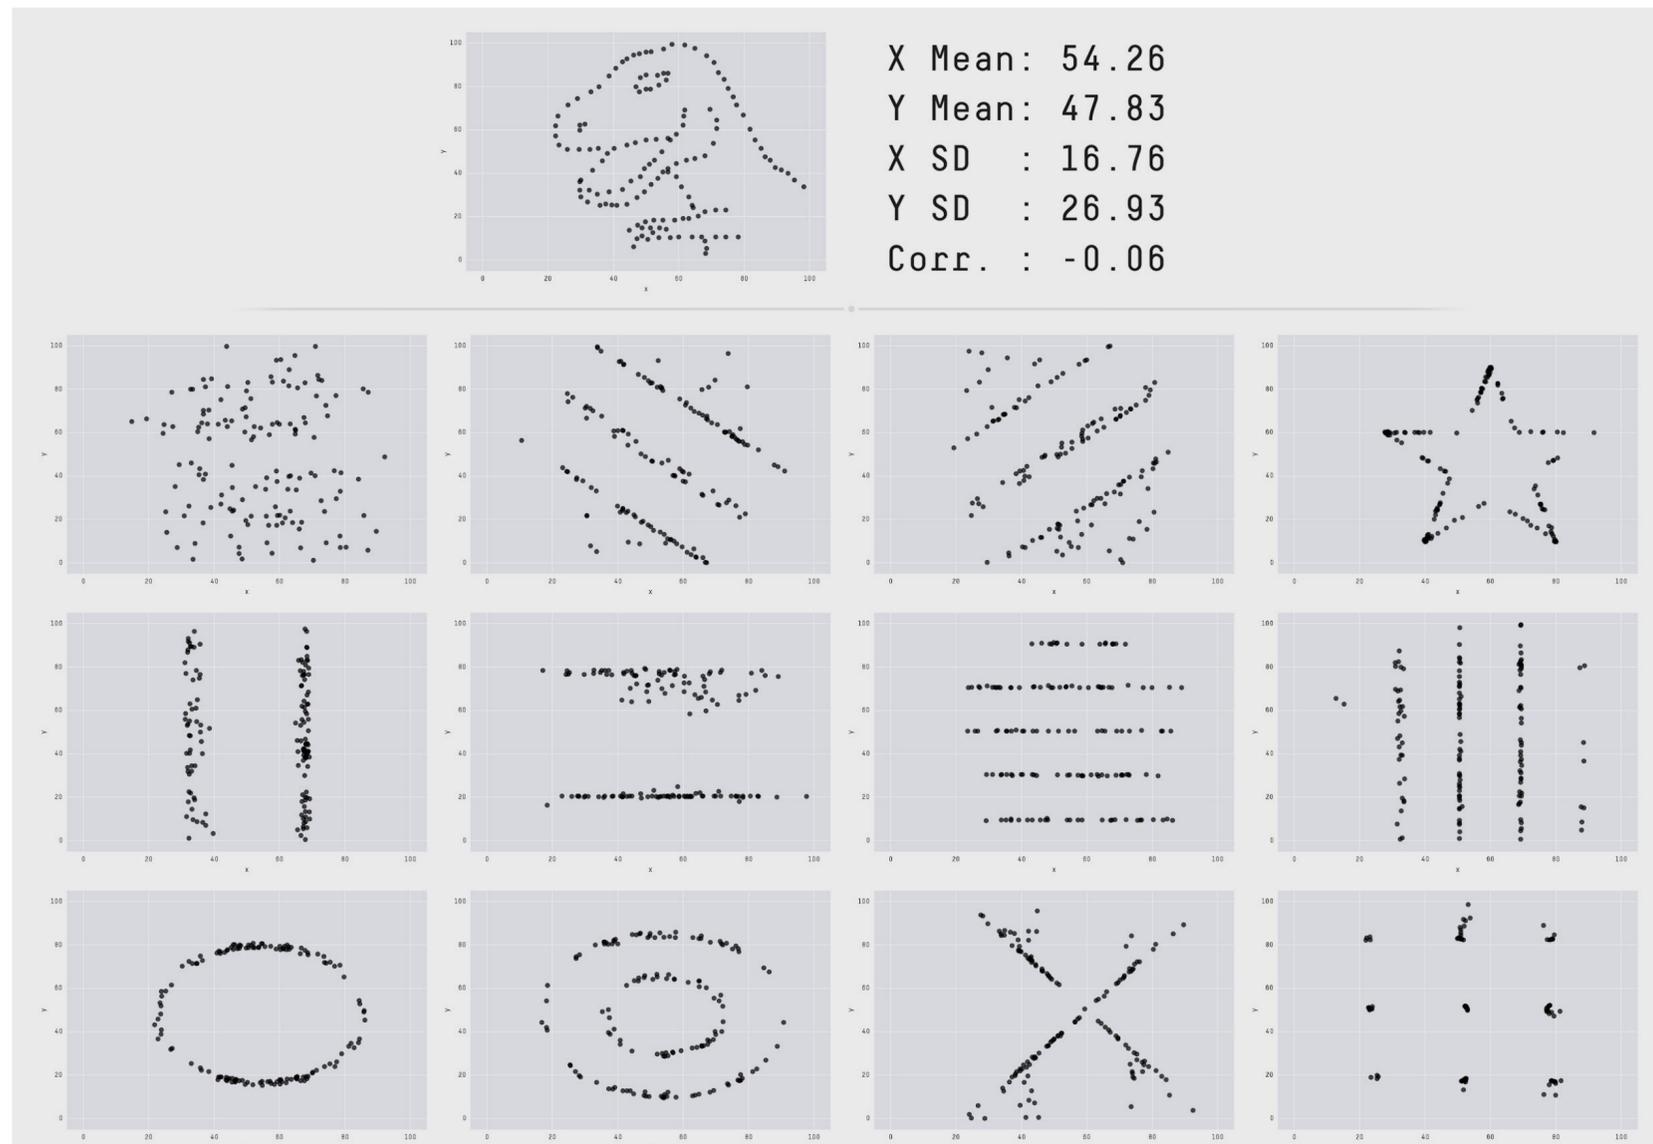


Structure classique



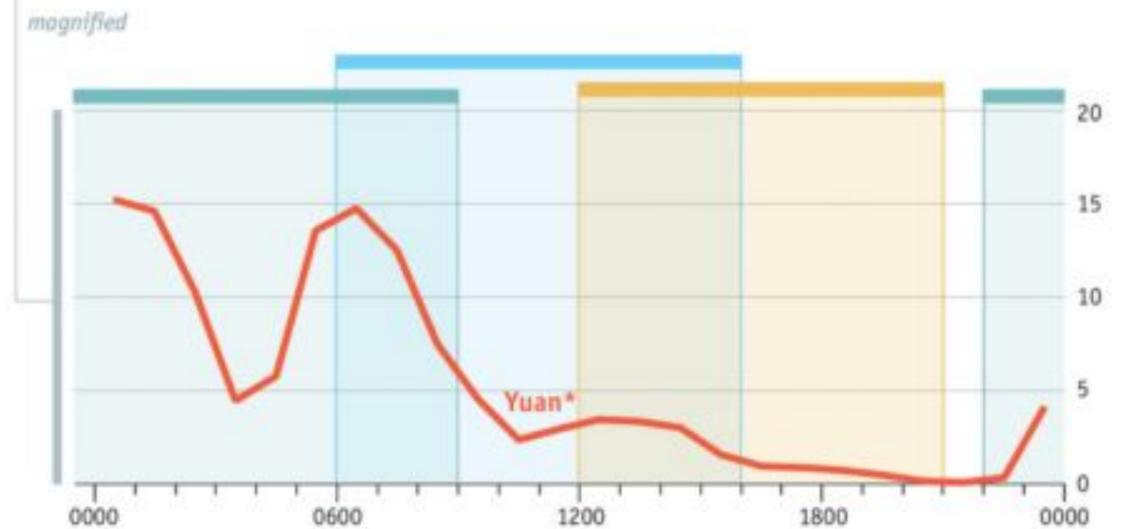
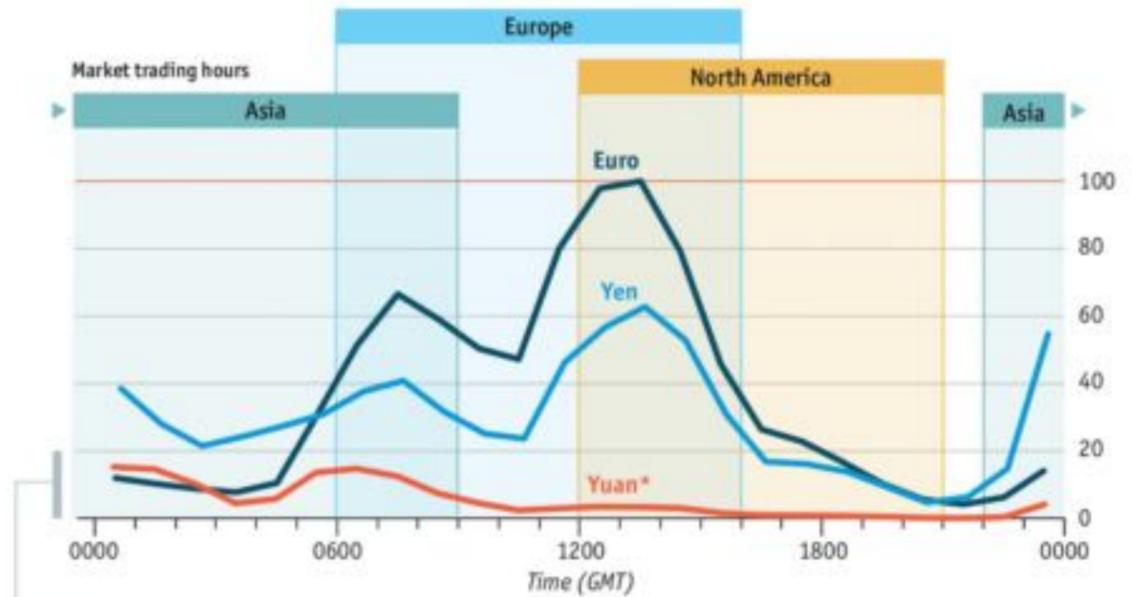
Visualisation

- Permet de “voir” où on en est
- Peut être un objectif en soi



The yuan that I want

Daily average trading volume, dollar currency pairs
Index, highest trading volume=100

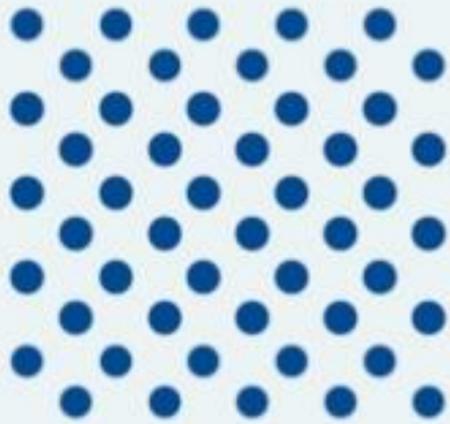


Source: IMF
Economist.com

*Offshore market

Données massives - une définition parmi d'autres

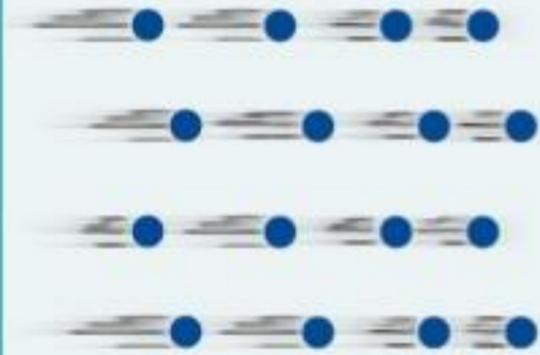
Volume



**Données brutes
d'origine**

Terabytes à exabytes
de données
disponibles

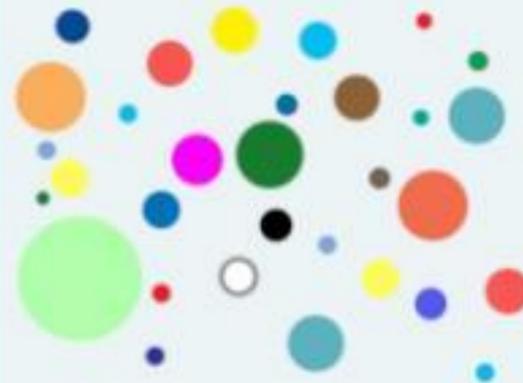
Vitesse



**Données
dynamiques**

Analyse en temps réel,
décision en une
fraction de seconde

Variété



**Données
hétérogènes**

Format structuré,
non structuré, texte,
multimédia

Véracité



**Données
incertaines**

Cohérence, fiabilité,
qualité et prédictibilité
des données

Volume

Byte : one grain of rice

Kilobyte : cup of rice

Megabyte : 8 bags of rice

Gigabyte : 3 Semi trucks

Terabyte : 2 Container Ships

Petabyte : Blankets Manhattan

Exabyte : Blankets west coast states

Zettabyte : Fills the Pacific Ocean

Yottabyte : A EARTH SIZE RICE BALL!

facebook

YAHOO!

amazon.com

ebay

Google

N.B.: La perfection est inatteignable. Un test médical valide à 99,9% appliqué la population du Canada (35 millions) va se tromper pour 35,000 personnes

Volume

- Un **mega**octet: une minute de musique
- Un **giga**octet: **une heure de film**
- Un **tera**octet: **40 jours de films** non-stop
- Un **peta**octet: **un siècle** devant un écran
- Un **exa**octet: **100 000 ans**
 - (et pourtant: c'est la durée de films regardés **chaque jour** sur YouTube en 2017)
- Un **zetta**octet: **100 millions d'années**
 - (ancêtre commun homme/souris)
- Un **yota**octet: **100 milliards d'années**
 - (penser à recharger la tablette en attendant l'apparition de l'univers)

Vitesse

2017 *This Is What Happens In An Internet Minute*



Et ça ne compte pas les objets connectés...

Variété

Comment fonctionne une voiture autonome ?

- 1 Une caméra principale**
Elle voit très bien les formes de jour mais évalue mal les distances
- 2 Deux caméras latérales**
(une à chaque coin du véhicule)
Elles élargissent le champ de vision
- 3 Un scanner laser (Scala)**
Il repère les objets sur une très longue distance (150 m)
- 4 Quatre radars** (un à chaque coin du véhicule)
Ils évaluent mal les formes mais calculent avec une grande précision les distances
- 5 Douze capteurs ultrason** (trois à chaque coin de la voiture)
Comme les radars, ils permettent de calculer la distance les séparant des obstacles



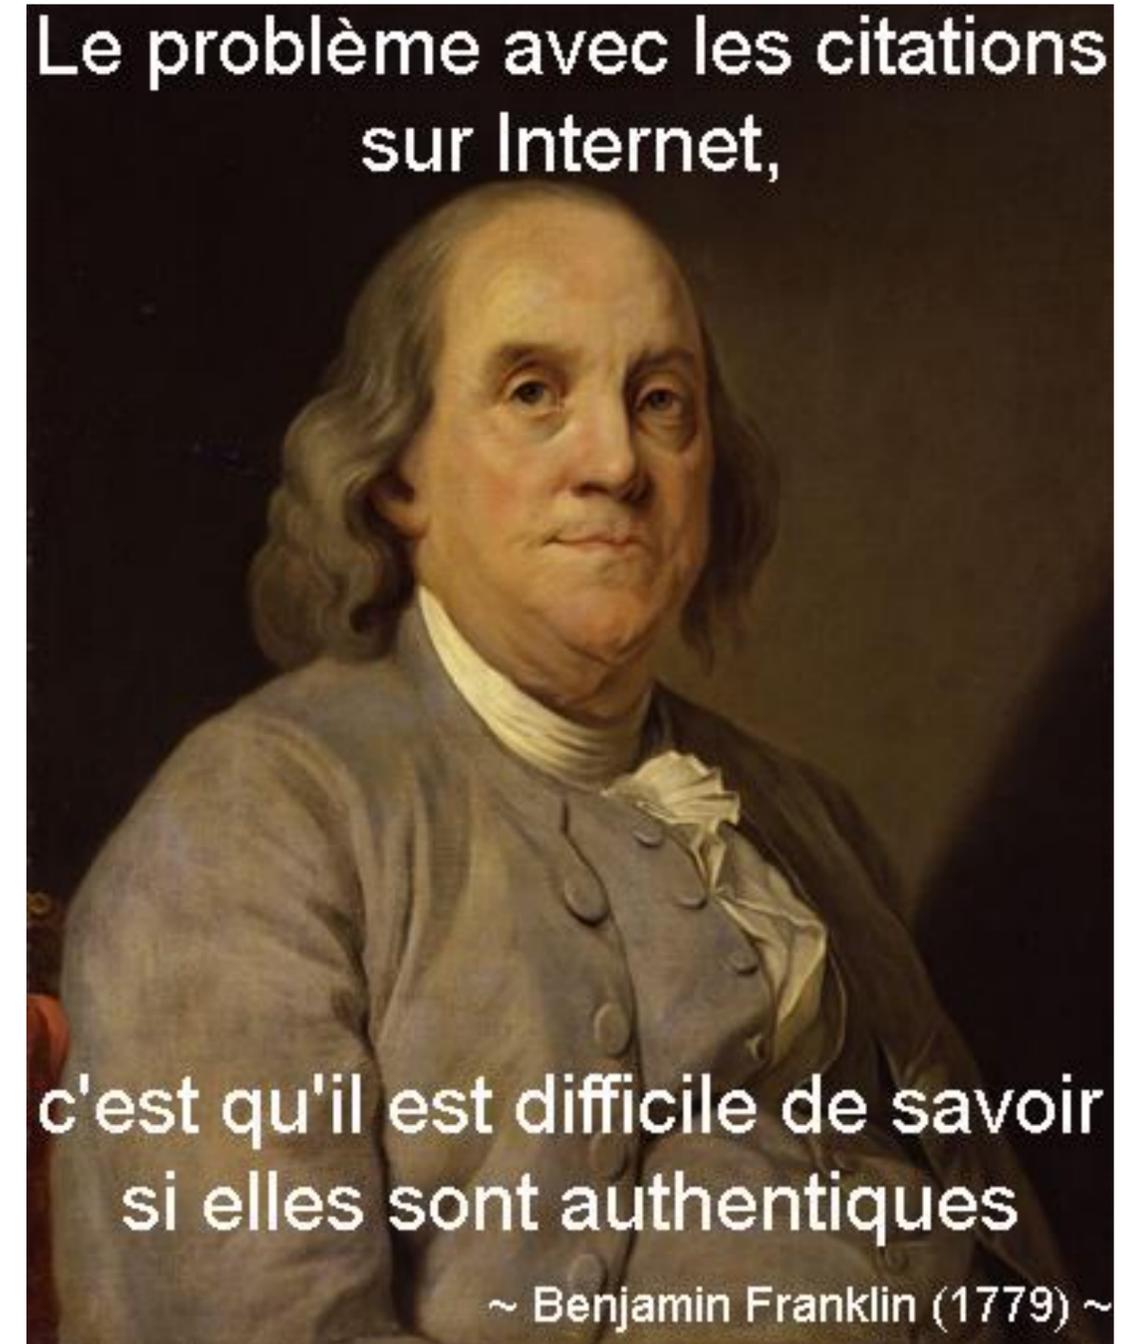
Un GPS, une liaison cellulaire, des ordinateurs, le WIFI, un réseau local, de la musique, des films, des jeux, ... et des mises à jour logiciel!



Véracité

- Pas seulement les données fausses ou trompeuses
 - Données anciennes, données “rien à voir”, données trop indirectes
 - Données biaisées
 - Erreur, bruit, ...
- Pas toujours malicieux
 - Fake news vs. protection de la vie privée

(rappel: une IA ne peut pas être meilleure que ses données)



Un autre V: la Valeur

Coûts

- Acquisition
 - Capteurs, achat, plateforme, ...
- Traitement
 - Puissance de calcul, experts, ...
- Stockage et accès
- ...

Revenus

- Prise de décision
- Publicité
- Revente des données
- Valeur future espérée
- ...

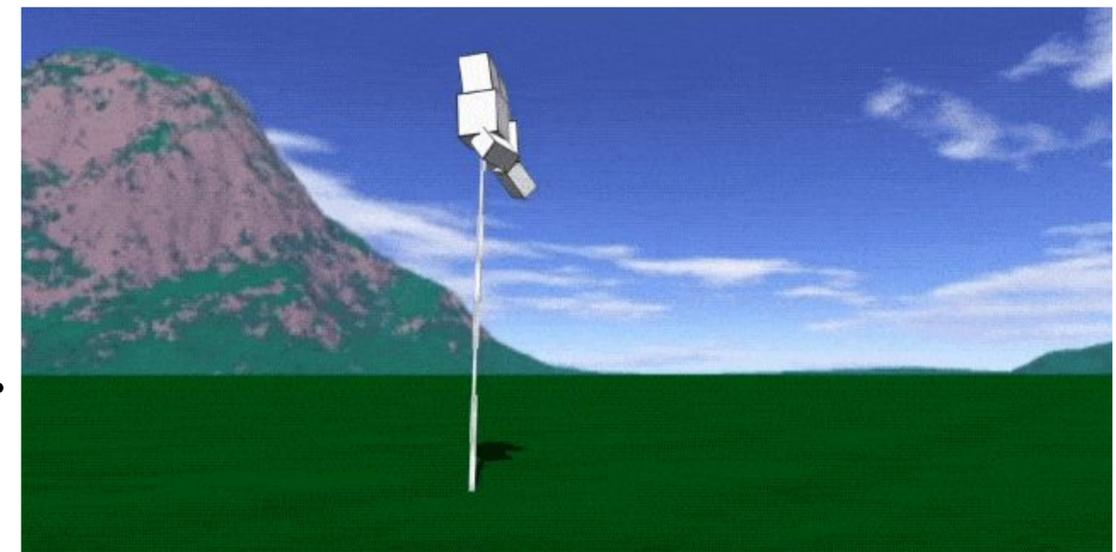
Approches basées sur les données

- Attention:
 - Prolongation de l'historique, risque de limiter l'innovation
 - le système optimise ce qu'on lui demande d'optimiser
- Mais le système a une intelligence *artificielle*
 - ce qui lui permet d'explorer des solutions "non-humaines"



...pour le meilleur

et pour le pire...



Accès aux données: pas seulement des défis techniques

Aspects techniques: volume de données, réseau rapide, accès aux sources, distribution des données et du calcul, consommation, etc.

Aspects non-techniques: vie privée, droits d'utilisation, conformité, confidentialité, sécurité... **Responsabilité.**

Trois notions parmi d'autres:

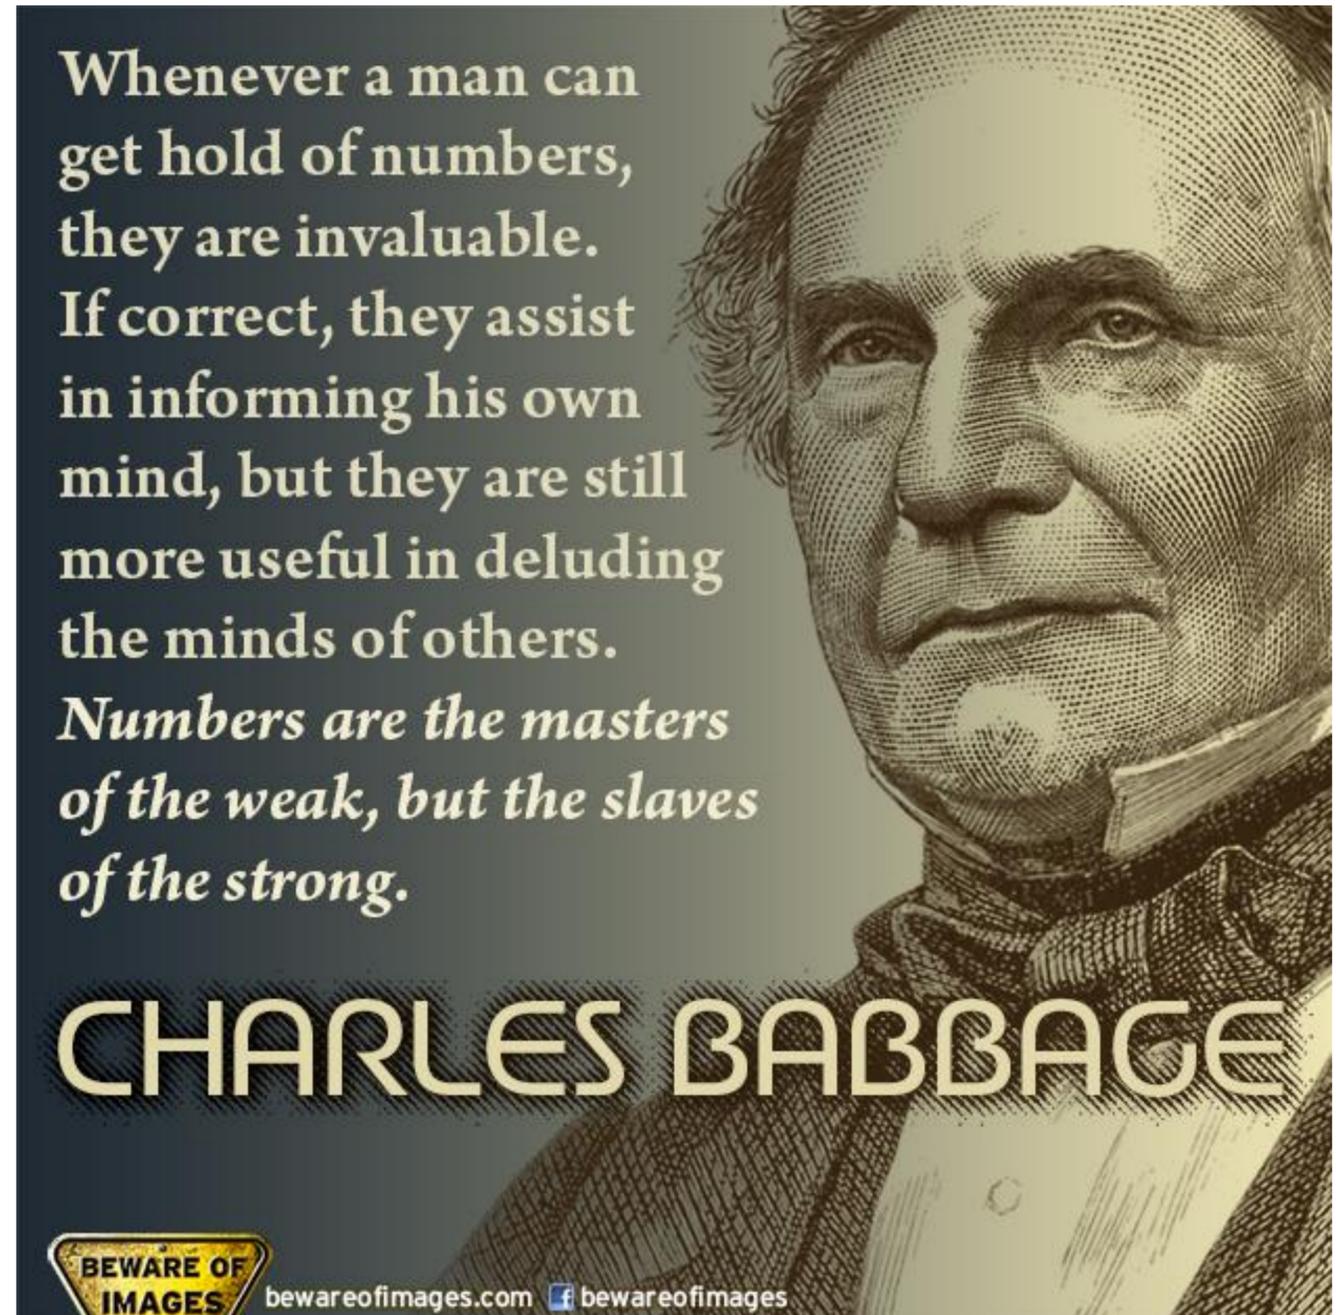
- Quasi-identificateurs
- *Mi data es su data...*
- Sécurité: attaques, défaillances, accidents, bévues, ...

Les données n'ont pas d'odeur...

Chaque fois qu'un homme peut obtenir des chiffres, ils sont inestimables: s'ils sont corrects, ils aident à informer son propre esprit, mais ils sont encore plus utiles pour tromper l'esprit des autres. Les nombres sont les maîtres des faibles, mais les esclaves des forts.

Charles Babbage (1864)

(traduction: google translate... et réseaux de neurones profonds)



La nouvelle vague de l'IA

26 mars à l'UPop!
(Guillaume)

+ Des **données** de plus en plus nombreuses et accessibles

+ Des **outils** capables d'utiliser une grande quantité de données

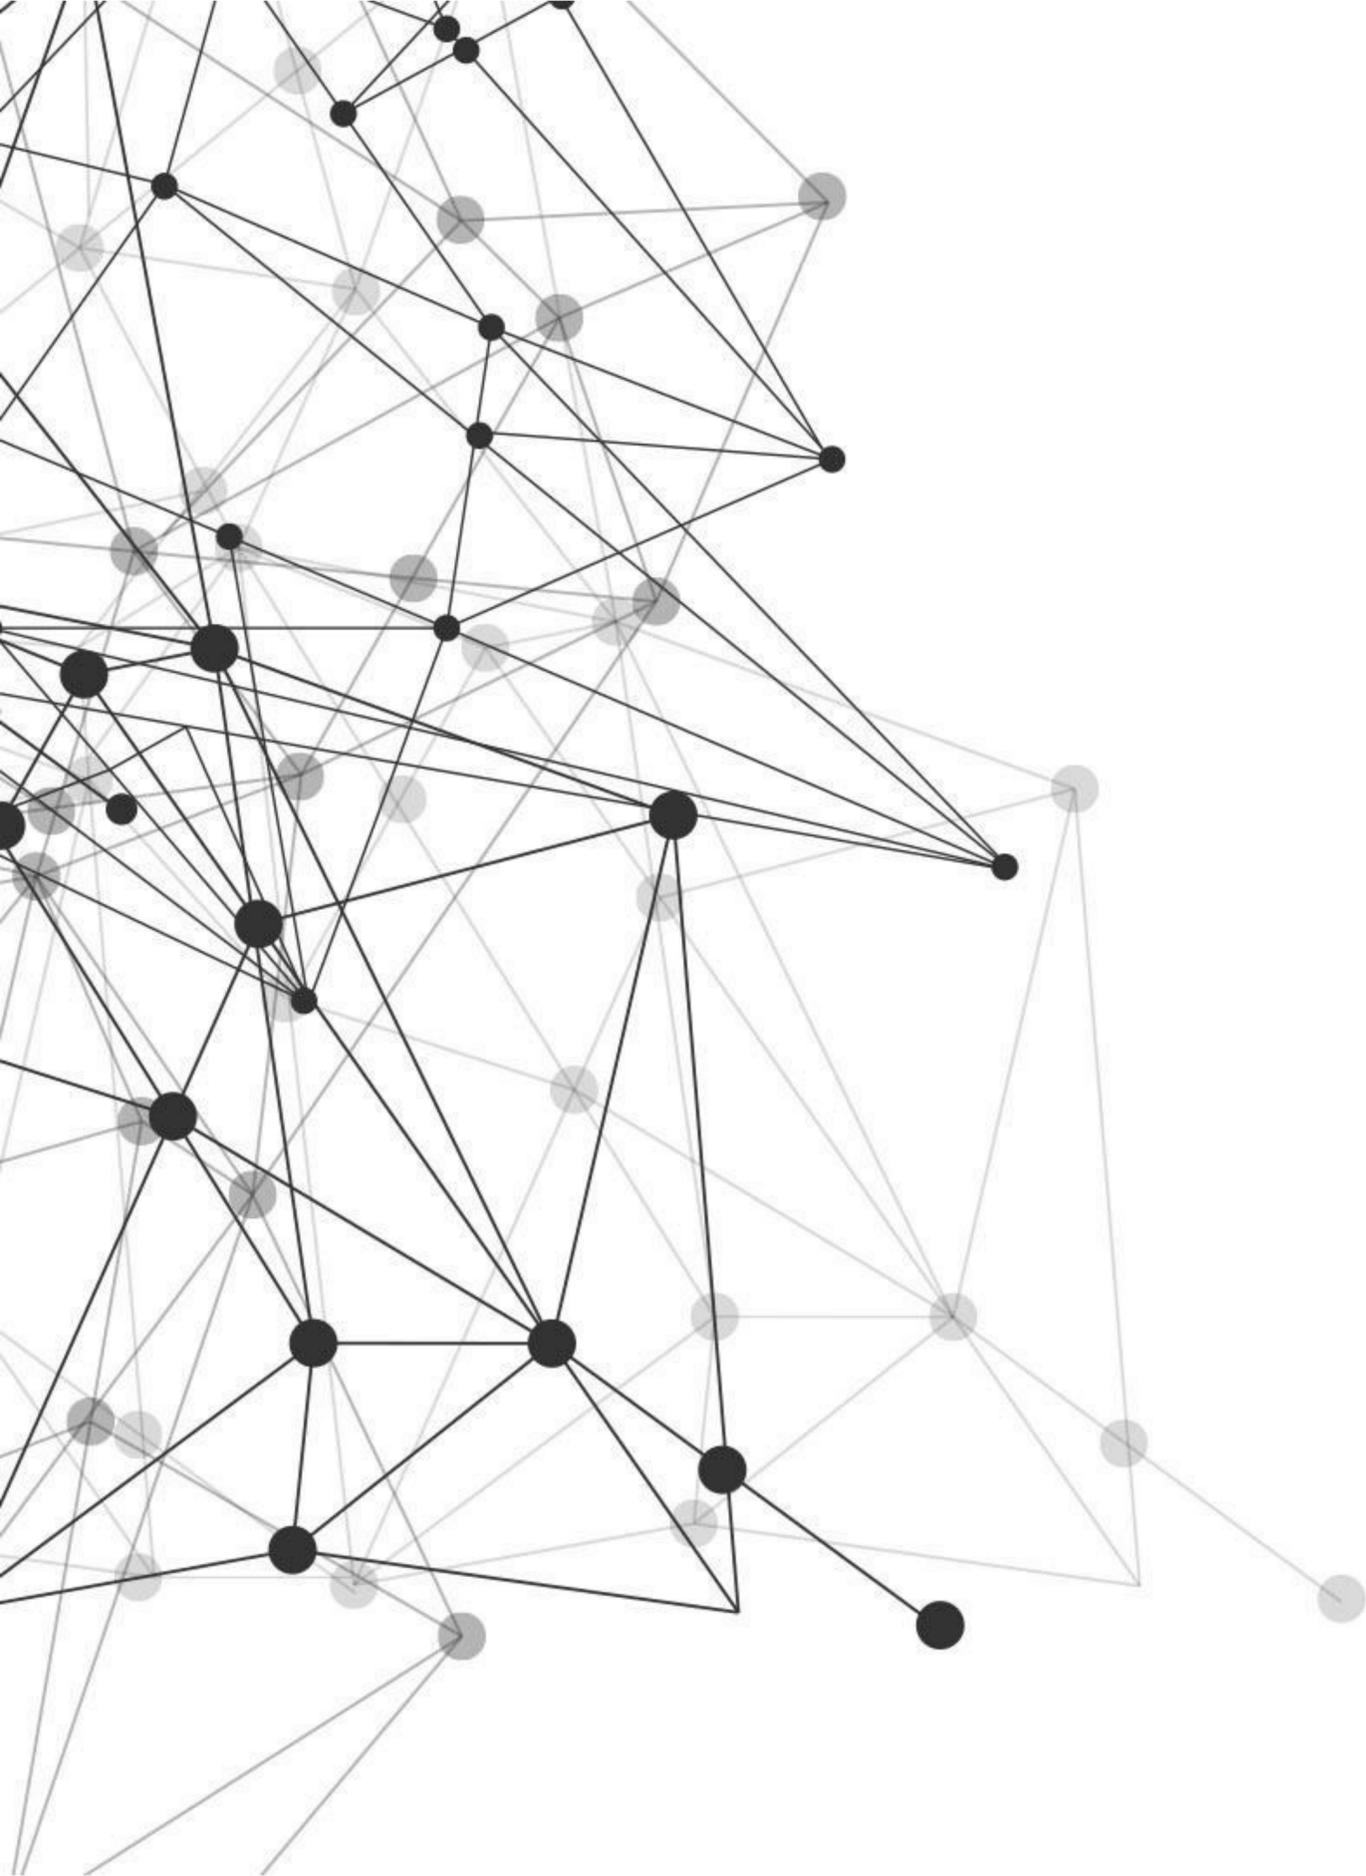
+ De la **puissance** de calcul

= résultats sur des tâches très différentes: reconnaissance de parole, analyse d'image, ...

9 et 23 avril à l'UPop!
(Bruno, Margaux, Guillaume)

Et avec ces grands pouvoirs viennent... de grandes responsabilités: **que faire** avec ces outils?

7 mai à l'UPop!
(Martin)



Merci!

Besoin de détails?

Guillaume.chicoisne@ivado.ca

ivado.ca



IVADO

—
HEC Montréal
Polytechnique Montréal
Université de Montréal

Sources

- <https://www.eff.org/ai/metrics>
- <https://www.economist.com/technology-quarterly/2017-05-01/language>
- <https://minghsiehee.usc.edu/2017/04/the-machines-are-coming/>
- <https://medium.com/@Lidinwise/the-revolution-of-depth-fac174924f5>
- https://en.wikipedia.org/wiki/File:Visualisation_mode_median_mean.svg
- <http://www.leparisien.fr/automobile/voiture-autonome-un-blesse-dans-une-tesla-en-pilotage-automatique-30-09-2016-6163713.php>
- <https://www.tubmanchev.com/chevrolet-spark/>
- http://www.polecat.com/wp-content/uploads/2016/10/20161008_woc112_1-466x540.png Yuan
- <https://www.economist.com/blogs/graphicdetail/2016/05/daily-chart-18-extreme-droite>
- <http://www.businessinsider.com/everything-that-happens-in-one-minute-on-the-internet-2017-9>
- https://en.wikipedia.org/wiki/Simpson%27s_paradox#/media/File:Simpson%27s_paradox_continuous.svg
- https://www.happybeertime.com/wp-content/uploads/2014/07/Benjamin_Franklin_final_quote.jpg
- https://www.washingtonpost.com/news/the-switch/wp/2018/02/01/google-parent-alphabet-reports-soaring-ad-revenue-despite-youtube-backlash/?utm_term=.36d000e466ef
-