
Introduction à la visualisation de données

3 Novembre 2016

Plan

- Présentation du cours
 - Critique
 - Pourquoi visualiser ?
 - Qu'est ce que la visualisation
 - Type de données
 - Variables graphiques
 - Mapping + visualisation pipeline
 - Un classique
-



Nicolas Bonneel
[nicolas.bonneel
@univ-lyon1.fr](mailto:nicolas.bonneel@univ-lyon1.fr)



Aurélien Tabard
[aurelien.tabard
@univ-lyon1.fr](mailto:aurelien.tabard@univ-lyon1.fr)



Romain Vuillemot
[romain.vuillemot
@ec-lyon.fr](mailto:romain.vuillemot@ec-lyon.fr)

Modèle pour les cours à venir

1e session (4h)

Cours (2h)

- Critique
- Redesign par groupes de 2 ou 3
- Explications théoriques

TP / Code (2h)

2e session (3h)

- Présentations TP + critique
- Présentations d'articles QCM 5 questions PASS/FAIL pour ceux qui ne présentent pas
- Étude d'exemples concrets et discussions
- Suivi des projets

Déroulé

03/11	Introduction à la visualisation de données	(4h)
	Critique + Cours + TP	
10/11	Visualisation de données temporelles	(4h)
	Critique + Cours + TP	
17/11	Visualisation de données temporelles	(3h)
	Review TP + Présentation article + Étude de cas + Projet	
24/11	Visualisation de données spatiales	(4h)
	Critique + Cours + TP	
01/12	Visualisation de données spatiales	(3h)
	Review TP + Présentation article + Étude de cas + Projet	
08/12	Visualisation de graphes	(4h)
	Critique + Cours + TP	
15/12	Visualisation de graphes	(3h)
	Review TP + Présentation article + Étude de cas + Projet	
05/01	TP projet banalisé	(2h)
12/01	Soutenance projet	(3h)

Projet

Travail : en groupe (binôme)

Rendu : une visualisation Web interactive avec D3.js

10 novembre : présentation des sujets

10 → 17 novembre : choix des sujets (ou proposition) et début du travail en groupes (état de l'art)

17 → 12 janvier : design, code et office hour pour questions

5 janvier : dernier TP banalisé

12 janvier : soutenance

Évaluation

Contrôle continu intégral

- TPs (rendu + review)
- Présentation d'article
- Projet

Plan

- Présentation du cours
 - Critique
 - Pourquoi visualiser ?
 - Qu'est ce que la visualisation
 - Type de données
 - Variables graphiques
 - Mapping + visualisation pipeline
 - Un classique
-

Critique

Exercice

Analyse critique d'une visualisation

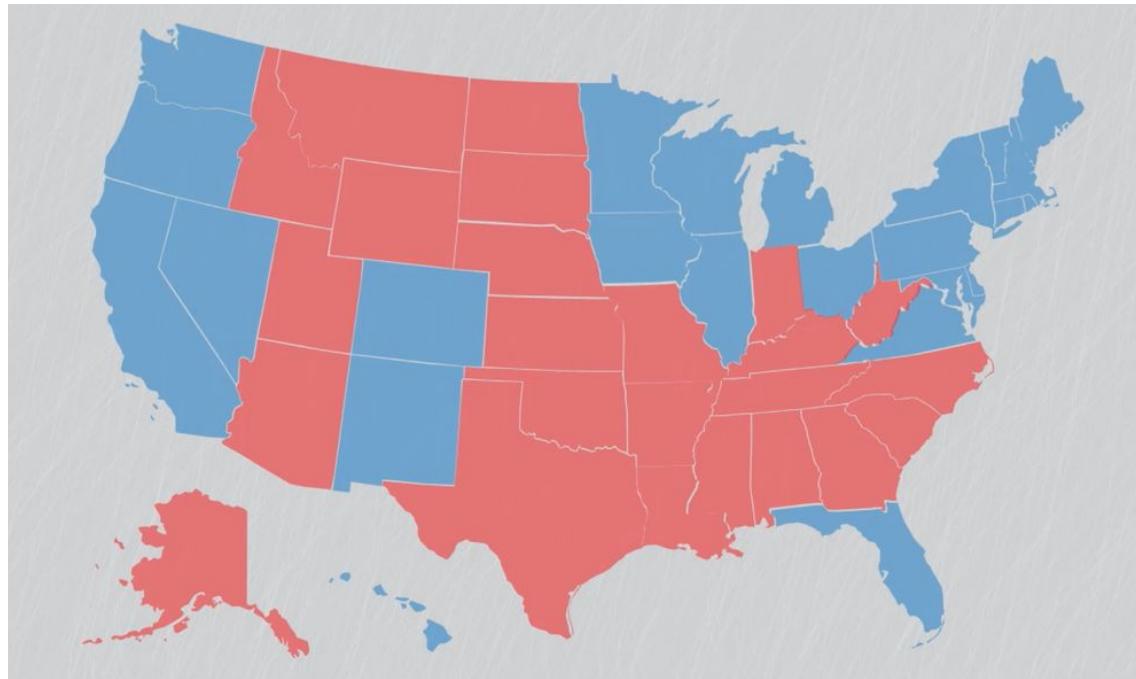
binome

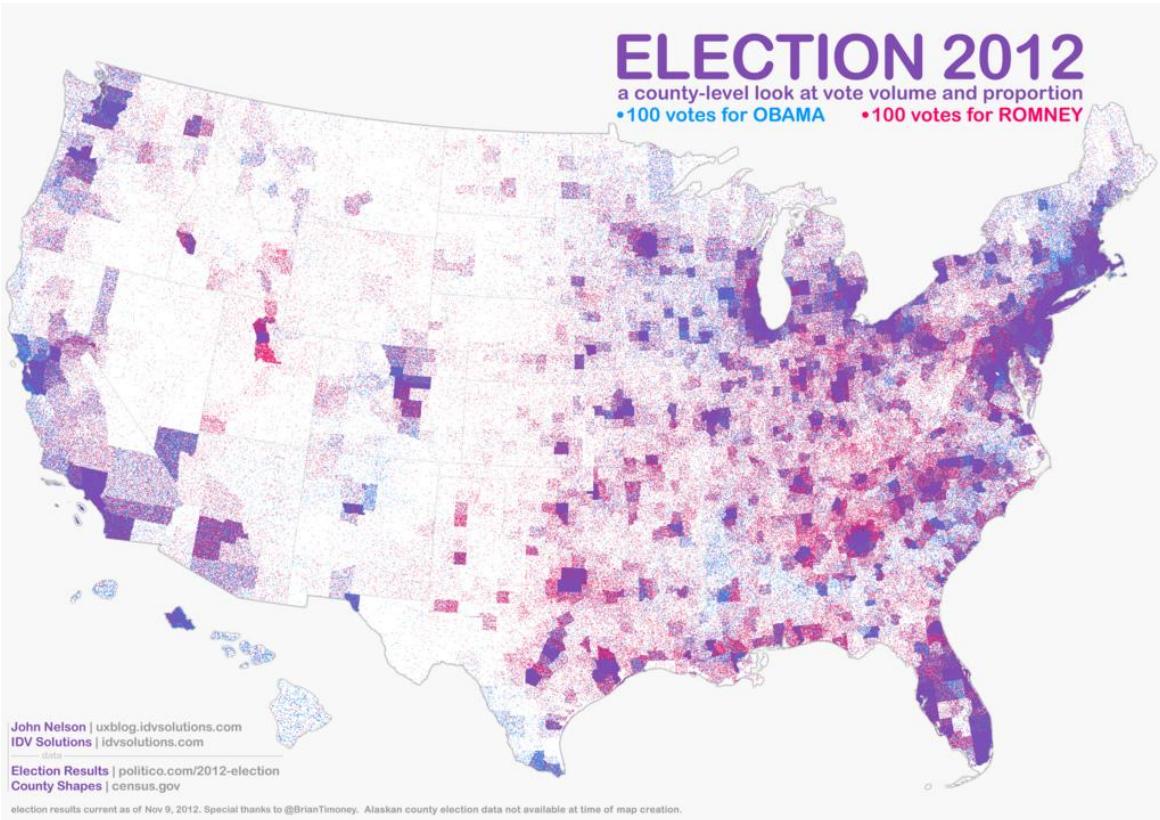
10 minutes

5 questions

Critique

- À qui s'adresse la visualisation ?
-> 1 proposition
- À quelle question la visualisation permet elle de répondre ?
-> 1 proposition
- Pourquoi (n')aimez vous (pas) cette visualisation ?
-> 2 raisons
- Quelles améliorations apporter ?
-> 3 propositions





<https://www.flickr.com/photos/idvsolutions/8182119174/sizes/k/in/photostream/>

The Electoral Map: Building a Path to Victory

[FACEBOOK](#) [TWITTER](#)

◀ Prev

Next ▶

Map 1 2 3 4 5 6 7 8 Make Your Own Scenarios

A New York Times assessment of how states may vote, based on polling, previous election results and the political geography in each state.

Obama
ELECTORAL VOTES
243

Needs 27
to win

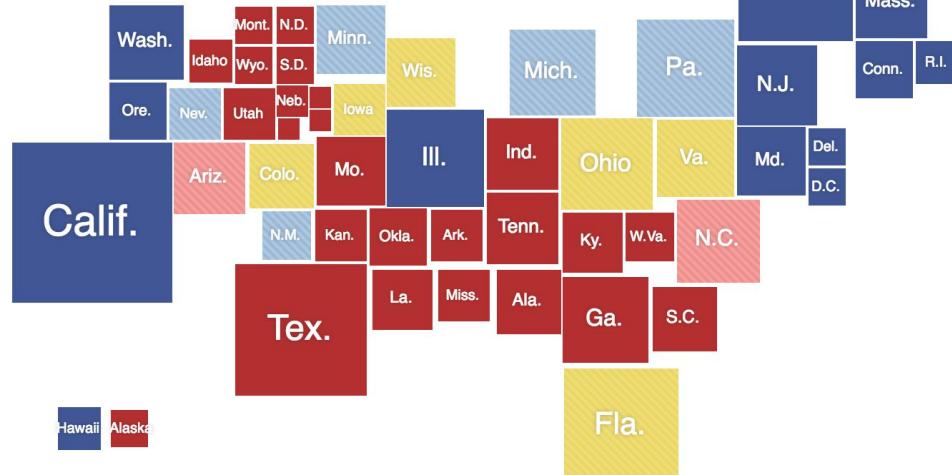
Romney
ELECTORAL VOTES
206

Needs 64
to win



270 needed to win

States sized by number of electoral votes



Maine and Nebraska give two electoral votes to the statewide winner and allocate the rest by congressional district.

Geographic View



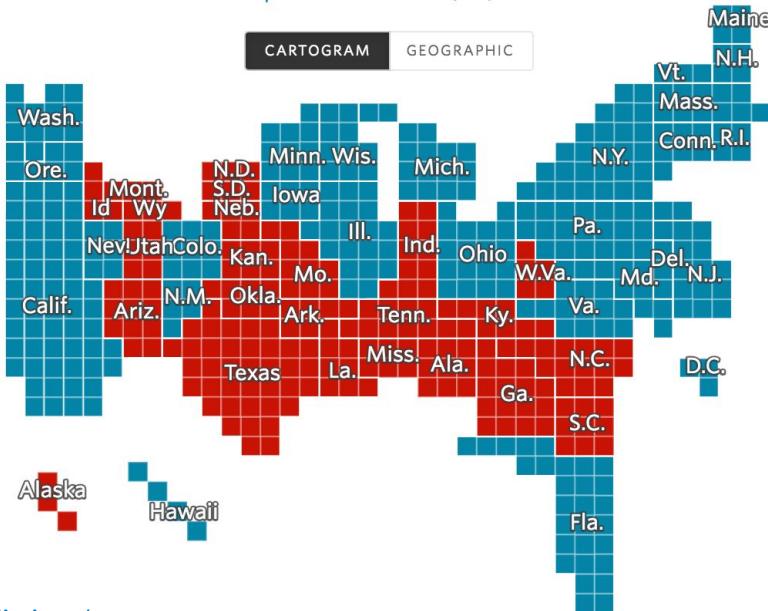
PREDICT THE OUTCOME

A presidential election is a set of 51 contests, in each state plus the District of Columbia, to determine which candidate can build a majority in the Electoral College. Use this map to draw your own path to victory. Click on a state to forecast which political party will carry its electoral votes—it takes 270 votes to win. We've shown how each state voted in the 2012 election. We've also made it easy to flip battleground states and harder to change states that reliably support the same party—click and hold in order to flip those states. You can opt for a traditional map or a cartogram, which shows each state's true weight in the electoral vote. Below are different ways to look at this year's electoral landscape, which may guide your own projections.

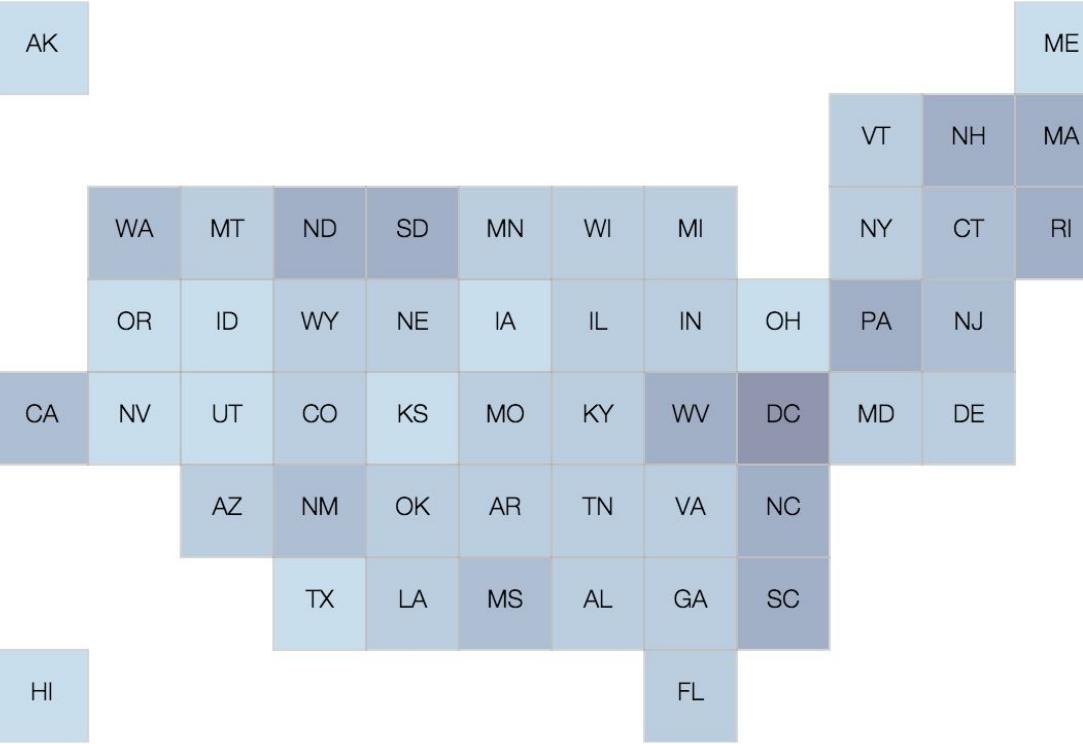
Under this scenario, the **Democrats** would win the election.



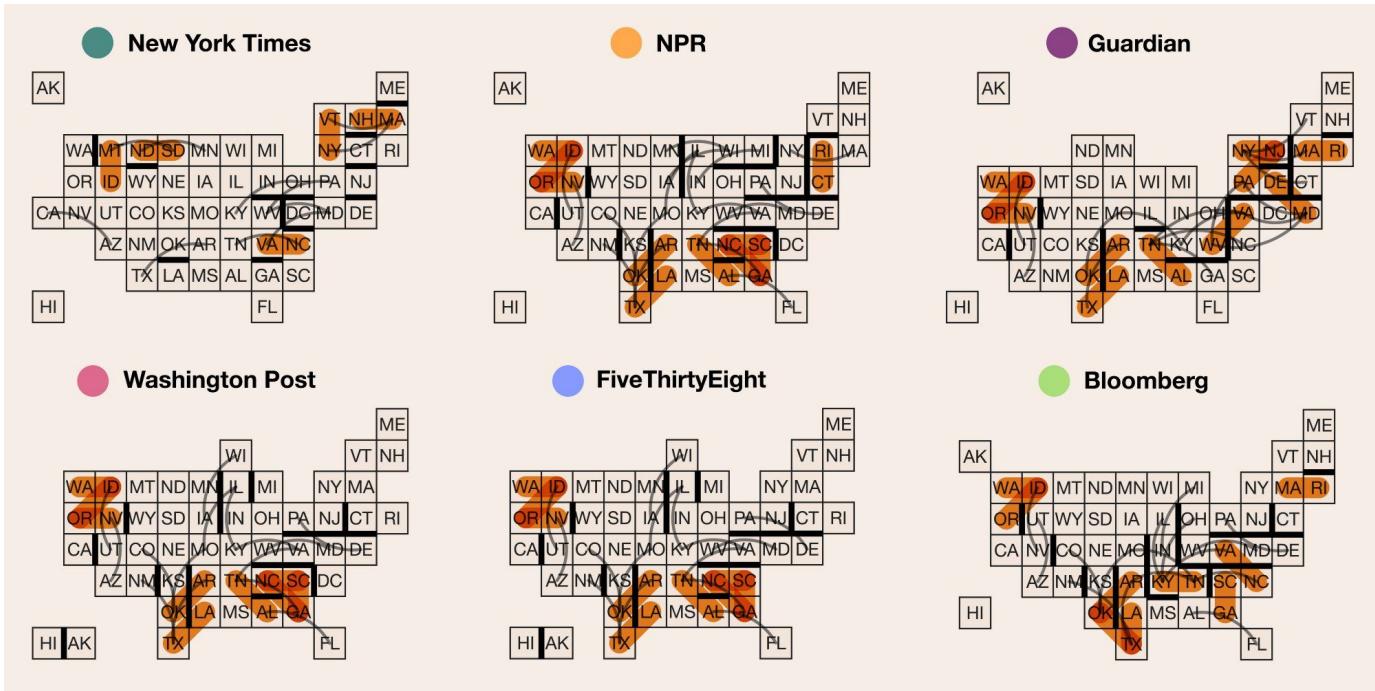
💡 **Click and hold to flip.** States that have historically voted for one party will be harder to turn over, per their [partisan voter index \(PVI\)](#).



<http://graphics.wsj.com/elections/2016/2016-electoral-college-map-predictions/>



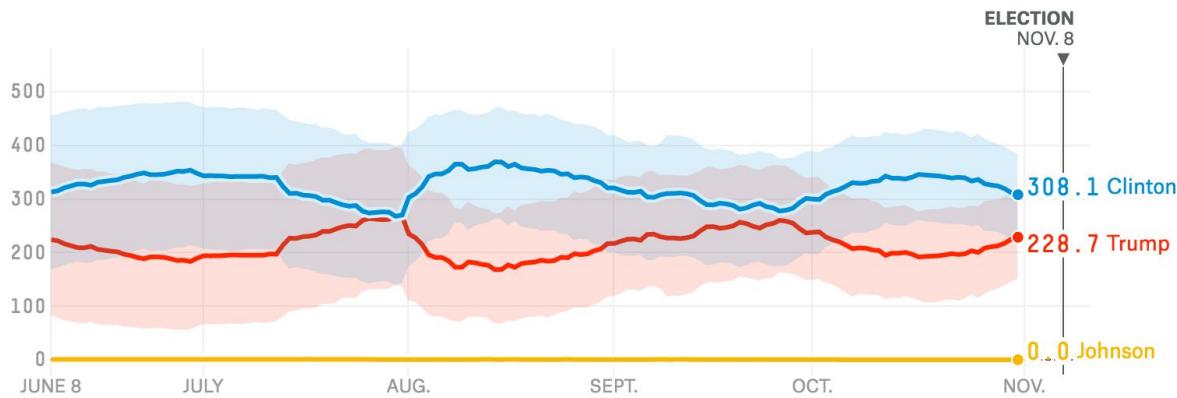
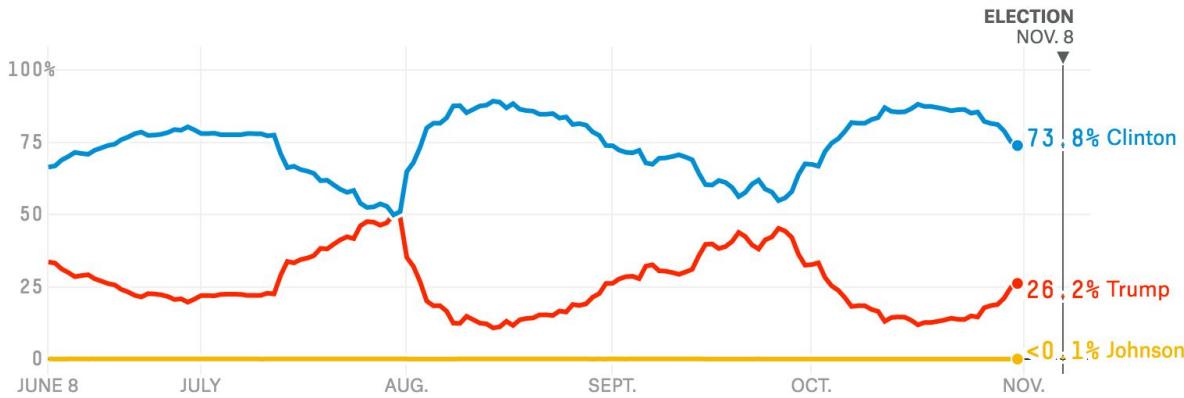
<https://github.com/kristw/gridmap-layout-usa>



Different US map layouts from six publishers.

Black border = invalid neighbors, Thick orange line = misdirection, Curve line = missing neighbors.

<https://medium.com/@kristw/whose-grid-map-is-better-quality-metrics-for-grid-map-layouts-e3d6075d9e80>



KEY AVERAGE ————— 80% CHANCE OF FALLING IN RANGE

Plan

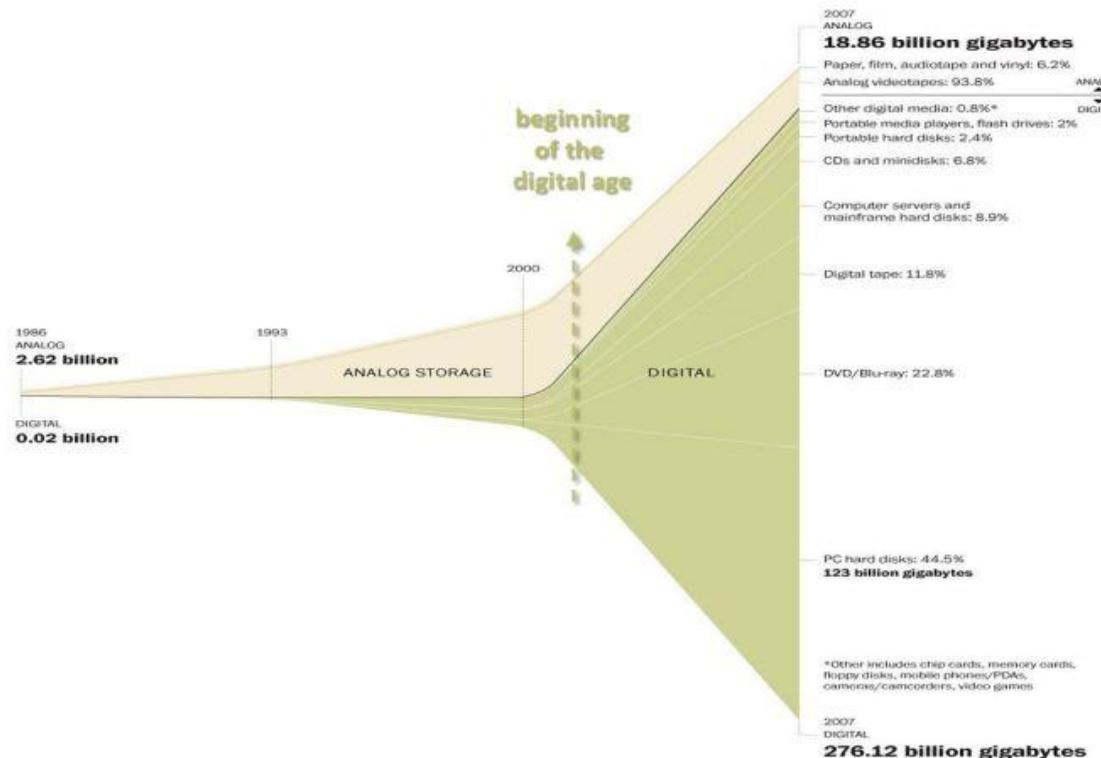
- Présentation du cours
 - Critique
 - Pourquoi visualiser ?
 - Qu'est ce que la visualisation
 - Type de données
 - Variables graphiques
 - Mapping + visualisation pipeline
 - Un classique
-

Explosion des données

Neuman, Park et Panek, 2012.

Tracking the Flow of Information into the Home: An Empirical Assessment of the Digital Revolution in the U.S. from 1960–2005.

<http://ijoc.org/index.php/ijoc/article/view/1369/745>



<http://www.forbes.com/sites/gilpress/2013/05/09/a-very-short-history-of-big-data>

Explosion de la quantité de données

- Comment faire sens des données ?
- Comment utiliser ces données dans les processus de décision ?
- Comment ne pas être surchargé ?

Défi: transformer les données en connaissance (découverte, compréhension) pour qu'elles deviennent utiles

“What information consumes is rather obvious: it consumes the attention of its recipients. Hence a wealth of information creates a poverty of attention, and a need to allocate that attention efficiently among the overabundance of information sources that might consume it.”

Herb Simon

as quoted by Hal Varian
Scientific American
September 1995

Traiter les données : où l'ordinateur est plus efficace ?

Question bien définie, sur des données connues

- Quel est le taux de chômage ?
- Quel gène mute fréquemment sur tel ensemble de patients ?

Décisions doivent être faites en un minimum de temps

- High-frequency trading
- Détection de défaut sur une chaîne d'assemblage

Traiter les données : où l'humain est-il plus performant ?

Quand les questions ne sont pas bien définies (exploration)

- Quelle combinaison de gènes peut être associée à un cancer ?

Quand les résultats peuvent donner lieu à plusieurs interprétations

- Quelle est la relation entre l'emploi et la politique industrielle d'un pays?

Pourquoi ne pas s'appuyer sur l'analyse de données ?

Le Quartet d'Anscombe

https://en.wikipedia.org/wiki/Anscombe%27s_quartet

I		II		III		IV	
x	y	x	y	x	y	x	y
10	8.04	10	9.14	10	7.46	8	6.58
8	6.95	8	8.14	8	6.77	8	5.76
13	7.58	13	8.74	13	12.74	8	7.71
9	8.81	9	8.77	9	7.11	8	8.84
11	8.33	11	9.26	11	7.81	8	8.47
14	9.96	14	8.10	14	8.84	8	7.04
6	7.24	6	6.13	6	6.08	8	5.25
4	4.26	4	3.10	4	5.39	19	12.5
12	10.84	12	9.13	12	8.15	8	5.56
7	4.82	7	7.26	7	6.42	8	7.91
5	5.68	5	4.74	5	5.73	8	6.89

Statistiques

Moyenne

x: 9 y: 7.50

Variance

x: 11 y: 4.122

Corrélation

x - y: 0.816

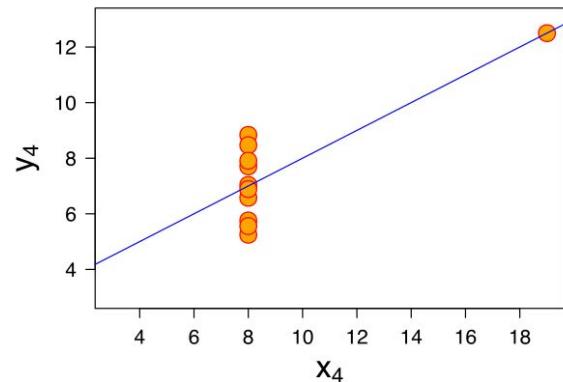
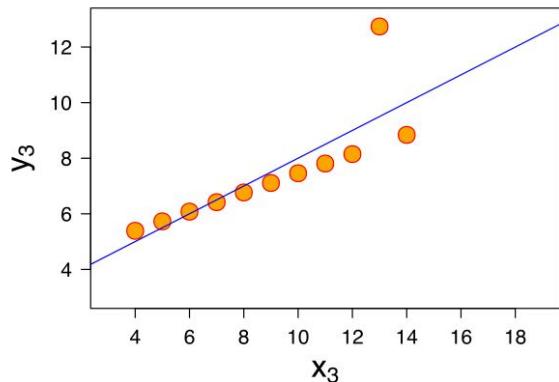
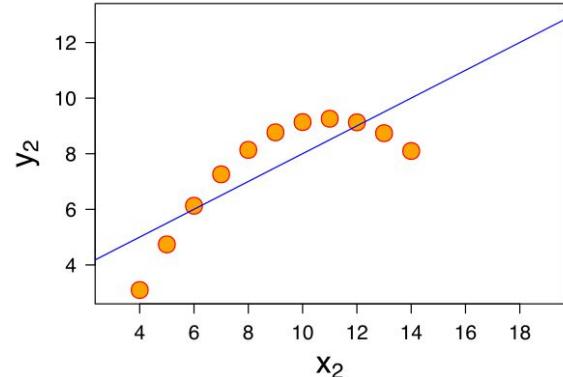
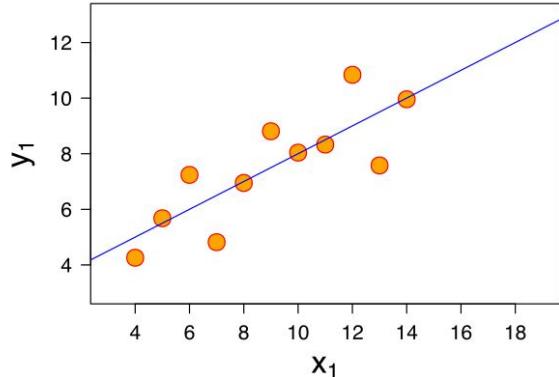
Régression linéaire:

y = 3.00 + 0.500x

Pourquoi ne pas s'appuyer sur l'analyse de données ?

Le Quartet d'Anscombe

https://en.wikipedia.org/wiki/Anscombe%27s_quartet



Pourquoi visualiser ?

Exercice

Brainstorming sur l'utilité
de la visualisation de données.

binome
3 minutes
5 raisons

Les trois raisons de la visualisation

Enregistrer de l'information

- Plan, photo

Faciliter le raisonnement sur de l'information (analyser)

- Analyser et calculer
- Raisonner sur les données
- Feedback et interaction

Transmettre de l'information (présenter)

- Partager et persuader
- Collaborer et itérer
- Mettre en avant un aspect des données

Enregistrer de l'information



© Mike Kelley – Photoviz <http://shop.gestalten.com/photoviz.html>

Faciliter le raisonnement

Épidémie de Choléra à Londres (1854)

Analyse de données visuelle pour comprendre le problème

[https://fr.wikipedia.org/wiki/%C3%89pid%C3%A9mie_de_chol%C3%A9ra_de_Broad_Street_\(1854\)](https://fr.wikipedia.org/wiki/%C3%89pid%C3%A9mie_de_chol%C3%A9ra_de_Broad_Street_(1854))



John Snow, 1854

Transmettre de l'information

<http://www.oecdbetterlifeindex.org/>



How's life?

Pourquoi la visualisation est difficile ?

Exercice

Visualiser les quantités suivantes :

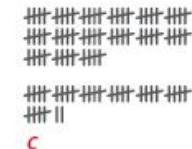
75 et 37

75, 37

a

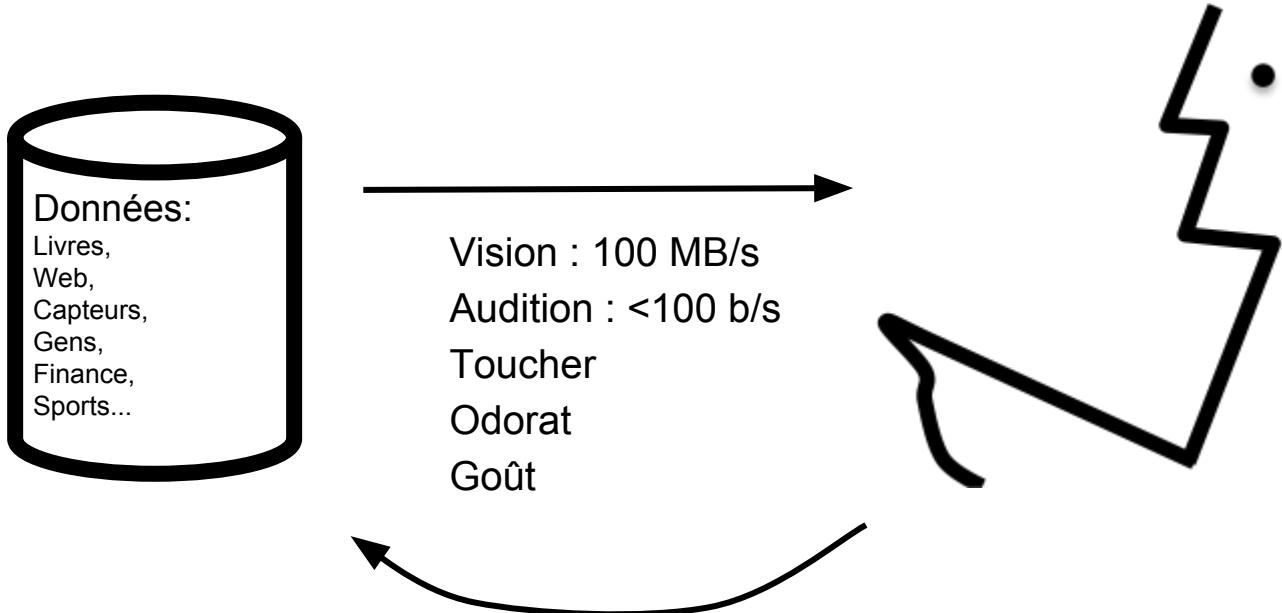


b



c

Le défi



Plan

- Présentation du cours
 - Critique
 - Pourquoi visualiser ?
 - **Qu'est ce que la visualisation**
 - Type de données
 - Variables graphiques
 - Mapping + visualisation pipeline
 - Un classique
-

Les différents types de visualisation :

Infographics

WHEN THE WORLD WASHES

WASHING HABITS ARE DIFFERENT ACROSS THE GLOBE

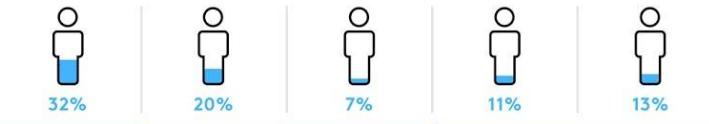


SHOWER vs. BATH

SHOWERING IS THE MOST COMMON METHOD OF WASHING
% Of People Showering Per Week



BUT BATHING IS STILL POPULAR IN EUROPE
% Of People Bathing Per Week



BRAZIL WATER CRISIS

ENVIRONMENTAL CHANGES CAN FORCE BEHAVIOUR TO CHANGE

Weekly showers and showering duration declined



Despite water shortage, they are still taking longer showers than most other countries



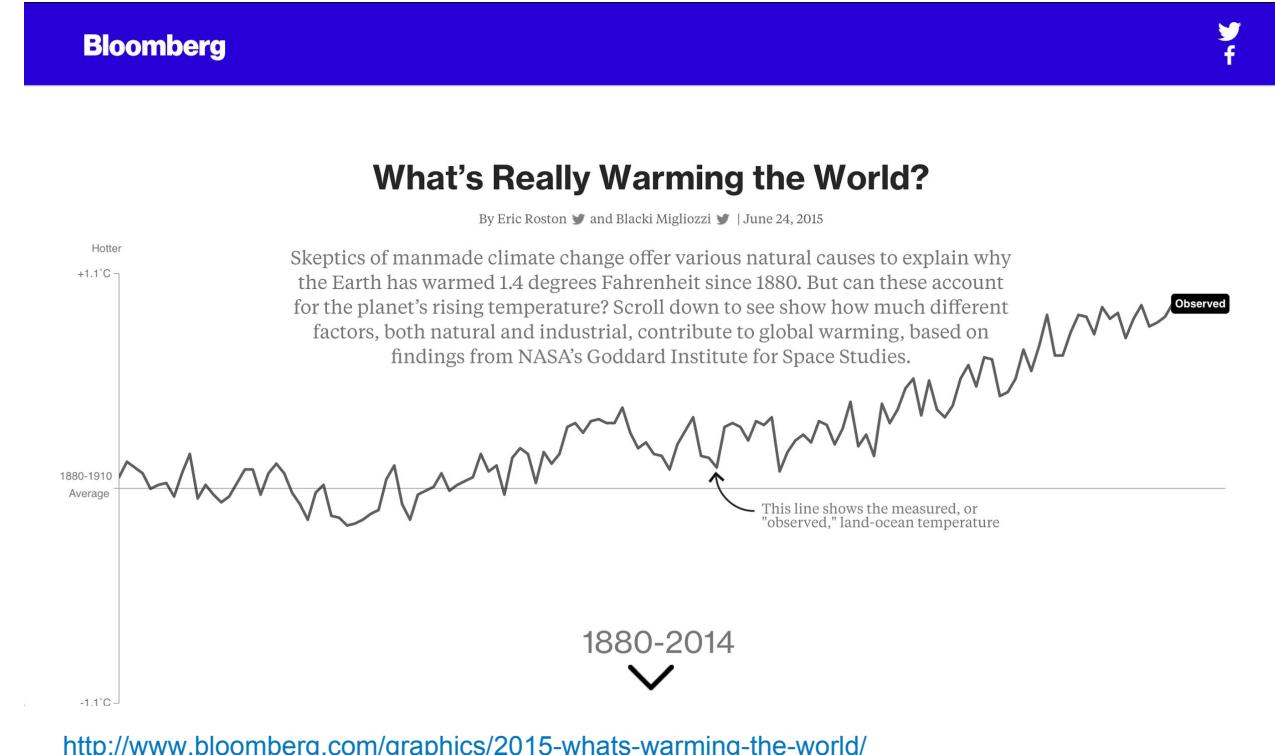
PEOPLE IN BRAZIL STILL TAKE MORE SHOWERS

Average Number Of Showers Per Week



Les différents types de visualisation :

Storytelling



—

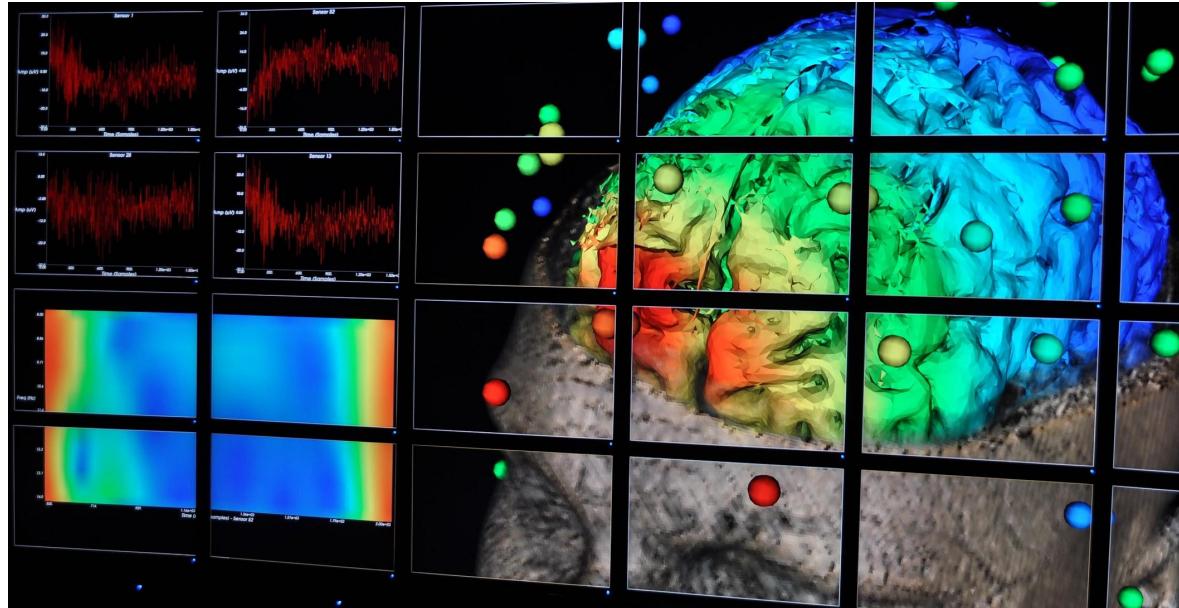
Les différents types de visualisation :

Cartographie



Les différents types de visualisation :

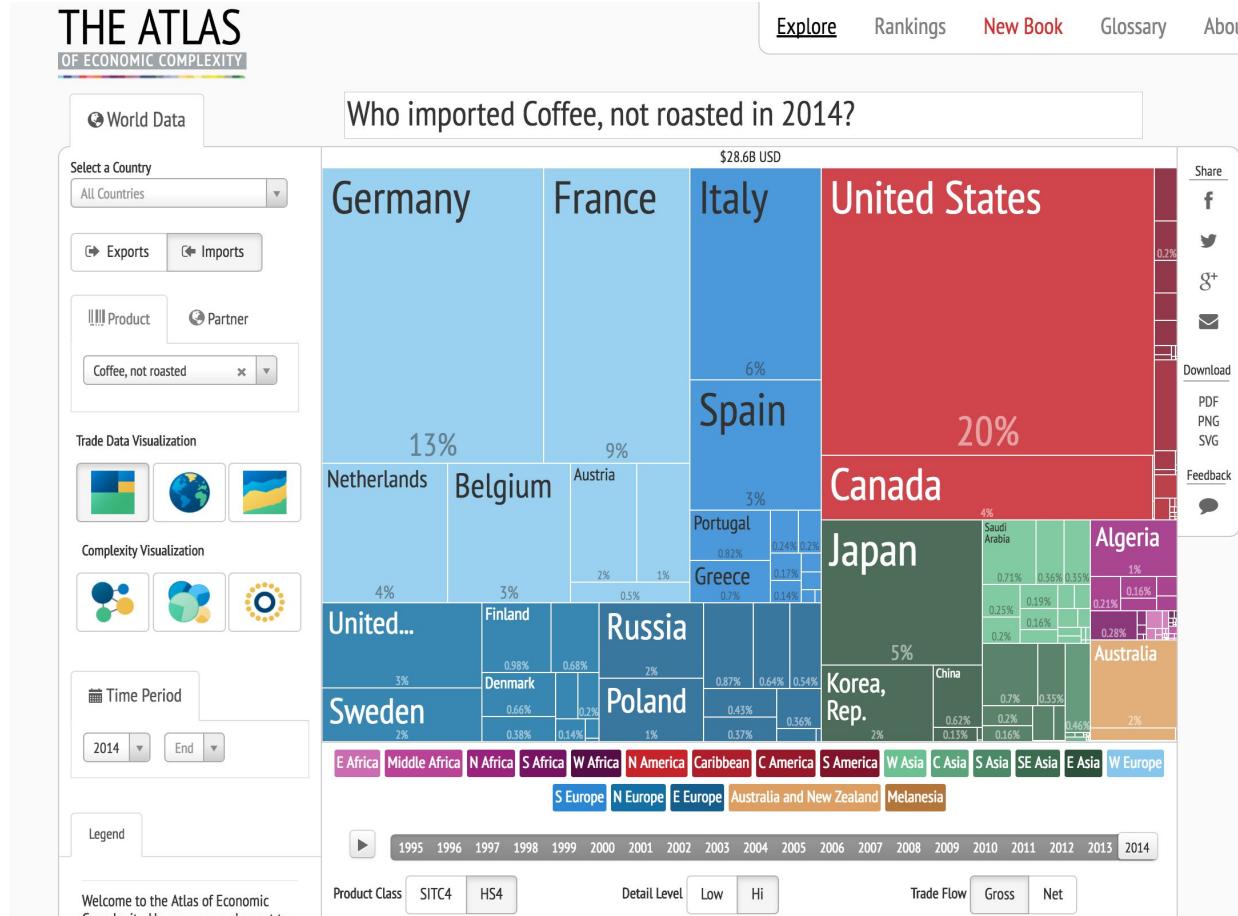
Visualisation scientifique



VisTrails https://www.nsf.gov/discoveries/disc_images.jsp?cntn_id=114322&org=NSF

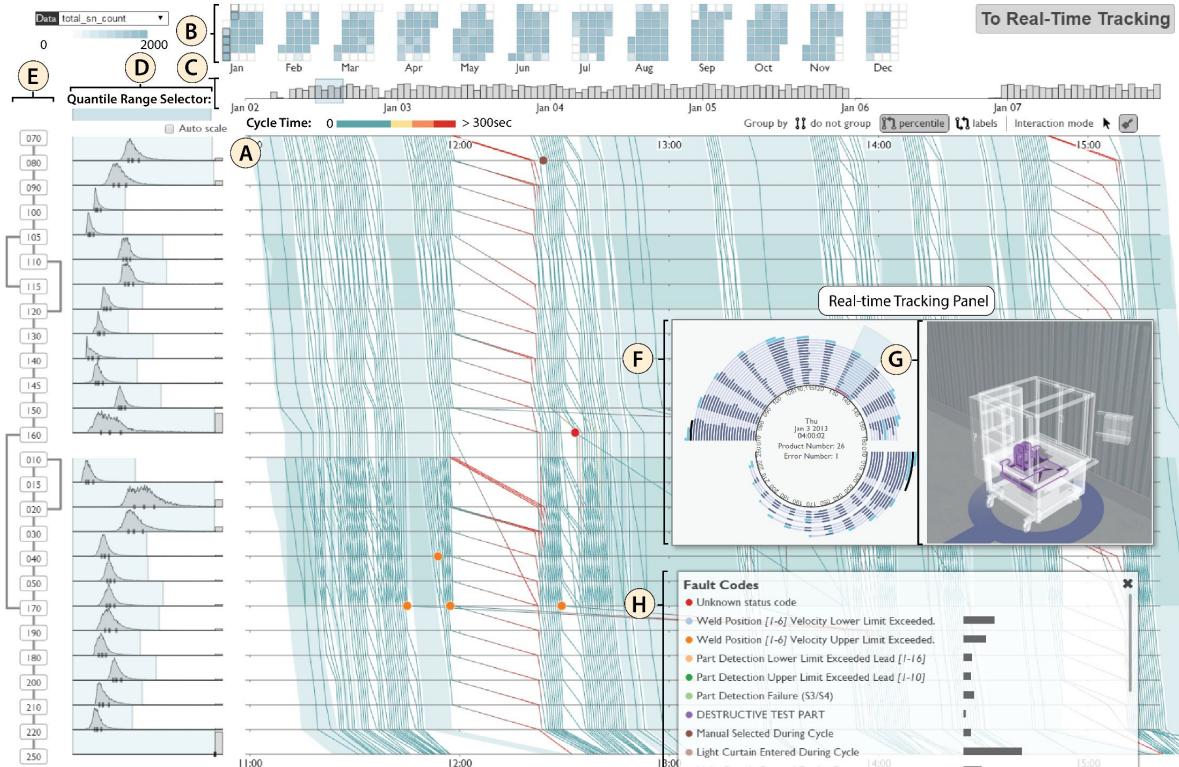
Les différents types de visualisation :

Visualisation d'information



Les différents types de visualisation :

Visual Analytics



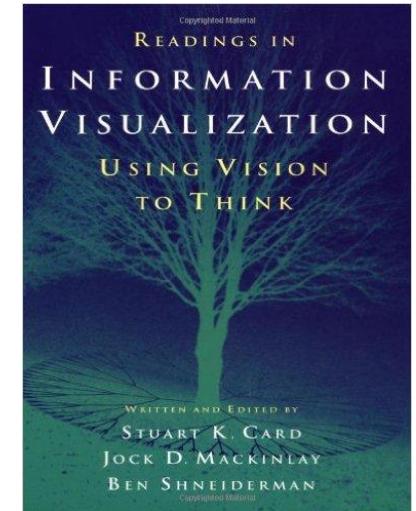
<https://www.computer.org/csdl/trans/tg/preprint/07536610-abs.html>

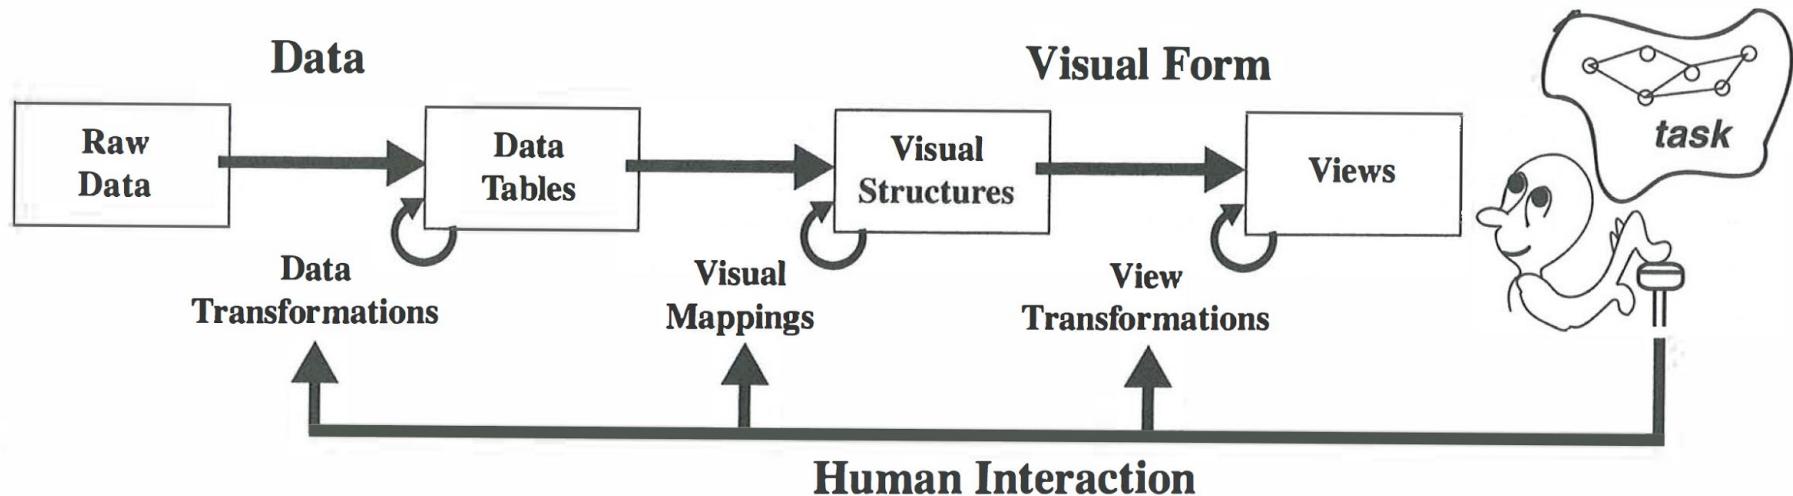
Définition

Visualisation d'information

“L'utilisation de représentation visuelles, interactives et informatique de données abstraites pour amplifier la cognition.”

Card, Mackinlay, & Shneiderman, 1999





Raw Data: idiosyncratic formats

Data Tables: relations (cases by variables) + metadata

Visual Structures: spatial substrates + marks + graphical properties

Views: graphical parameters (position, scaling, clipping, ...)

[Card, Mackinlay, Shneiderman, Readings in Information Visualization: Using Vision to Think, 1999]

Plan

- Présentation du cours
 - Critique
 - Pourquoi visualiser ?
 - Qu'est ce que la visualisation
 - Type de données
 - Variables graphiques
 - Mapping + visualisation pipeline
 - Un classique
-

Les données

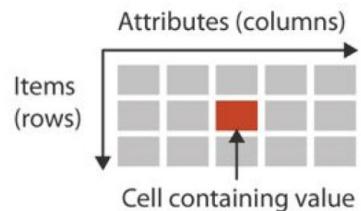
À la base de toute visualisation

Un bon designer de visualisation doit connaître :

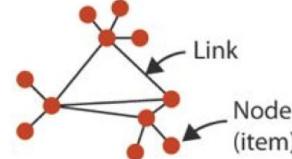
- Les propriétés des données
- Les métadonnées associées
- Ce que les gens veulent tirer des données

Types de jeux de données

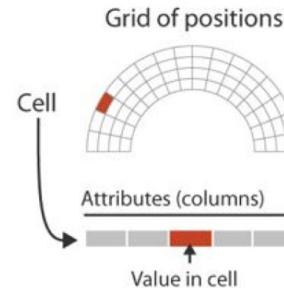
→ Tables



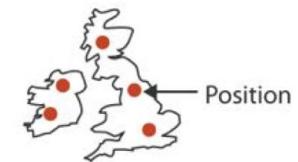
→ Networks



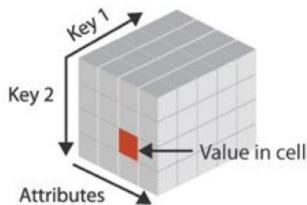
→ Fields (Continuous)



→ Geometry (Spatial)



→ Multidimensional Table



→ Trees



-> *Ce qu'on veut visualiser*

Type de données de base

Unités fondamentales

Constituent les jeux de données

- Item / élément
- Lien
- Attribut
- Position
- Grille

Élément et attribut

Élément :

- Entité individuelle, discrète.
- Ex: un patient, une voiture

Attribut :

- Propriété mesurée ou observée
- Ex: taille, pression sanguine (patient), vitesse (voiture)

Lien, Position et Grille

Lien

- Relation entre deux éléments
- Ex : “amitié sur Facebook”

Position

- Données spatiales (en 2D ou 3D)
- Ex : latitude/longitude

Grille

- Stratégie d'échantillonnage pour données continues
- Ex: positions de stations météo

Données

The screenshot shows a Google Sheets spreadsheet with the following details:

- Title:** Élections américaines
- Owner:** aurelienlabard@gmail.com
- Last edit:** 4 minutes ago
- Table Structure:** The table has 29 rows and 14 columns. The columns are labeled A through M. Column A is "Abbreviation", B is "Total_EV", C is "Shift", D is "Shift tooltip", E is "Nominee tooltip", F is "Nominee_pro", G is "Color Bins", H is "Independent spa", I is "Direction", J is "D_%", K is "D_Difference%", L is "D_Difference", M is "D_EV", and N is "D".
- Data:** The data includes state abbreviations like KS, MO, ND, NE, OH, DC, NH, AL, AR, FL, GA, KY, LA, MD, MS, NC, OK, SC, TN, TX, VA, AZ, CA, CO, ID, MT, NM, and NV, along with their respective Total EV, Shift, Nominee tooltip, Color Bin, Independent spa, Direction, and other statistical values.

Exercice : <https://goo.gl/5bPs9s>

Trouver à quoi correspond :

- Un item / un élément / une variable (indépendante)
- Un attribut / une dimension / une variable (dépendante) / une feature
- Les clés

Où est définie la sémantique de la table ?

Type d'échelles

Nominale (catégoriel)

- Fruits: pommes, oranges, ...

Ordinal (ordonné)

- Qualité d'un frigo: A+, A++, A+++ ...
- Peut être compté et ordonné mais pas mesuré

Intervalle (zéro arbitraire)

- Dates, longitude, latitude

Ratio (zero fixé)

- Le zéro a un sens (rien)
- Mesure physique : poids, longueur, ...

Type d'échelles

Nominale (catégoriel)

- Opérations : =, ≠

Ordinal (ordonné)

- Opérations : =, ≠, >, <

Intervalle (zéro arbitraire)

ex : [1989 – 1999] + [2002 – 2012]

- Opérations : =, ≠, >, <, +, –

peut mesurer les distances

Ratio (zero fixé)

ex : 10kg / 5kg

- Opérations: =, ≠, >, <, +, –, ×, ÷

peut mesurer les proportions

Modèle de données vs. conceptuel

Modèle de données (description bas niveau)

- Flottants : 32.5, 54.0, -17.3

Modèle conceptuel (construction mentale)

- Température

Type de données

- Valeur continue avec 1 chiffre significatif (Quantitatif)
- Chaud - tiède - froid - glacé (Ordinal)
- Brûlé / pas brûlé (Nominal)

Plan

- Présentation du cours
 - Critique
 - Pourquoi visualiser ?
 - Qu'est ce que la visualisation
 - Type de données
 - **Variables graphiques**
 - Mapping + visualisation pipeline
 - Un classique
-

Les variables de Jacques Bertin

Cartographe français,
auteur de la sémiologie graphique



LES VARIABLES DE L'IMAGE

	POINTS	LIGNES	ZONES	
XY 2 DIMENSIONS DU PLAN	x x x	/ \ 2 1	14 15 9 16 21 2 1 1 21 15 1 14 15 1 1 2 9	OQ ≠
Z TAILE	.	/ \ 2 1	[] []	OQ ≠
VALEUR	.	/ \ 2 1	[] []	O ≠

LES VARIABLES DE SÉPARATION DES IMAGES

	GRAIN	LIGNES	ZONES	
GRAIN	[] []	/ \ 2 1	[] []	== O ≠
COULEUR		/ \ 2 1	[] []	== ≠
ORIENTATION		/ \ 2 1	[] []	== ≠
FORME	▲ ●	/ \ 2 1	[] []	== ≠

Marques simples

Munzner, 2014,
Visualization Analysis and Design.

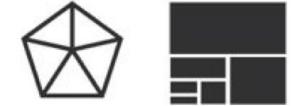
④ Points



④ Lines



④ Areas



Canaux visuels

Munzner, 2014,
Visualization Analysis and Design.

④ Position

- Horizontal
- Vertical
- Both



④ Color



④ Shape



④ Tilt



④ Size

- Length
- Area



- Volume



Plan

- Présentation du cours
 - Critique
 - Pourquoi visualiser ?
 - Qu'est ce que la visualisation
 - Type de données
 - Variables graphiques
 - Mapping + visualisation pipeline
 - Un classique
-

Mapping

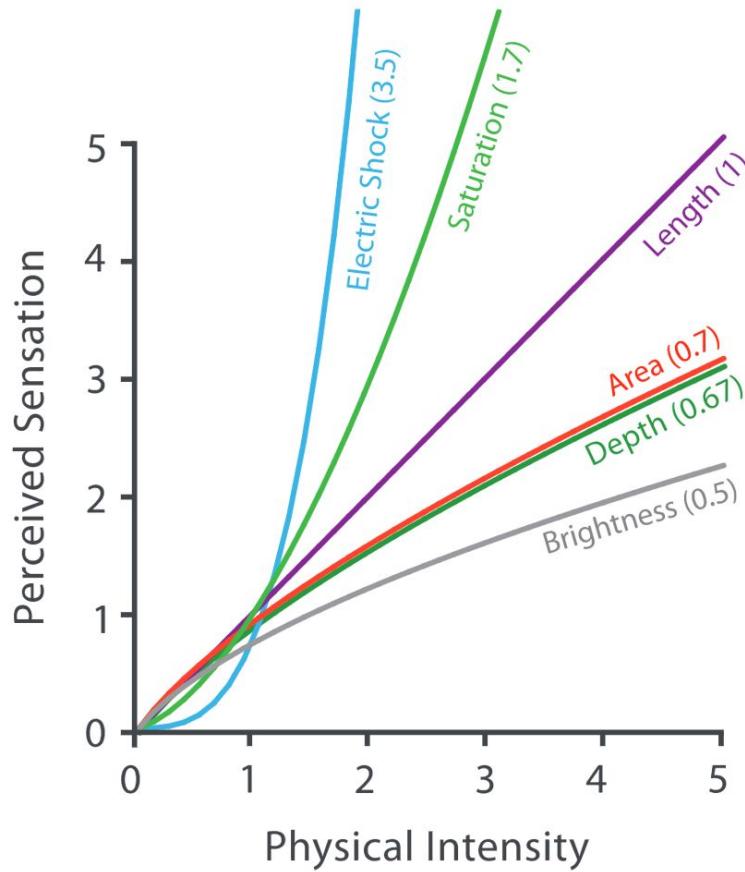
- Le travail de base consiste à mapper des données → des marques graphiques et propriétés
- Ensuite rajouter de l'interaction pour naviguer dans et manipuler les données

Question:

- Quels mapping choisir ?
Quelles marques pour quelles données ?

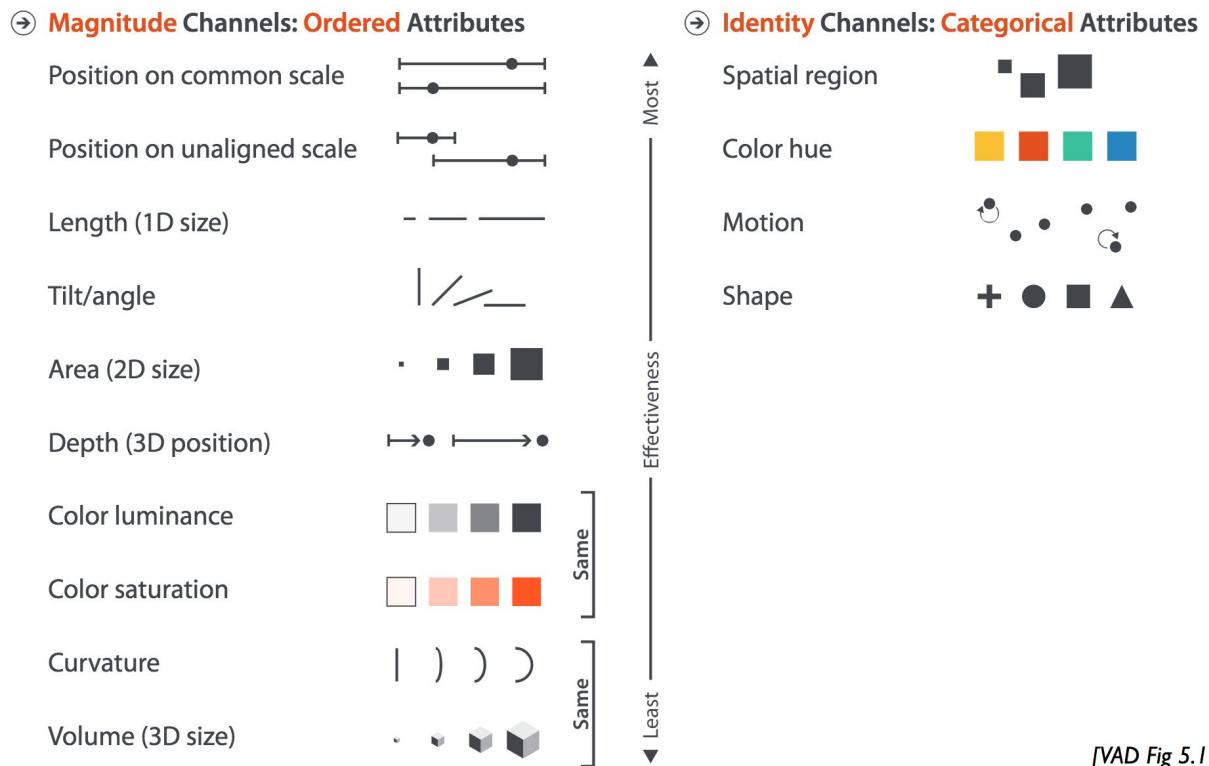
Steven's Psychophysical Power Law: $S = I^N$

Efficacité de la perception humaine



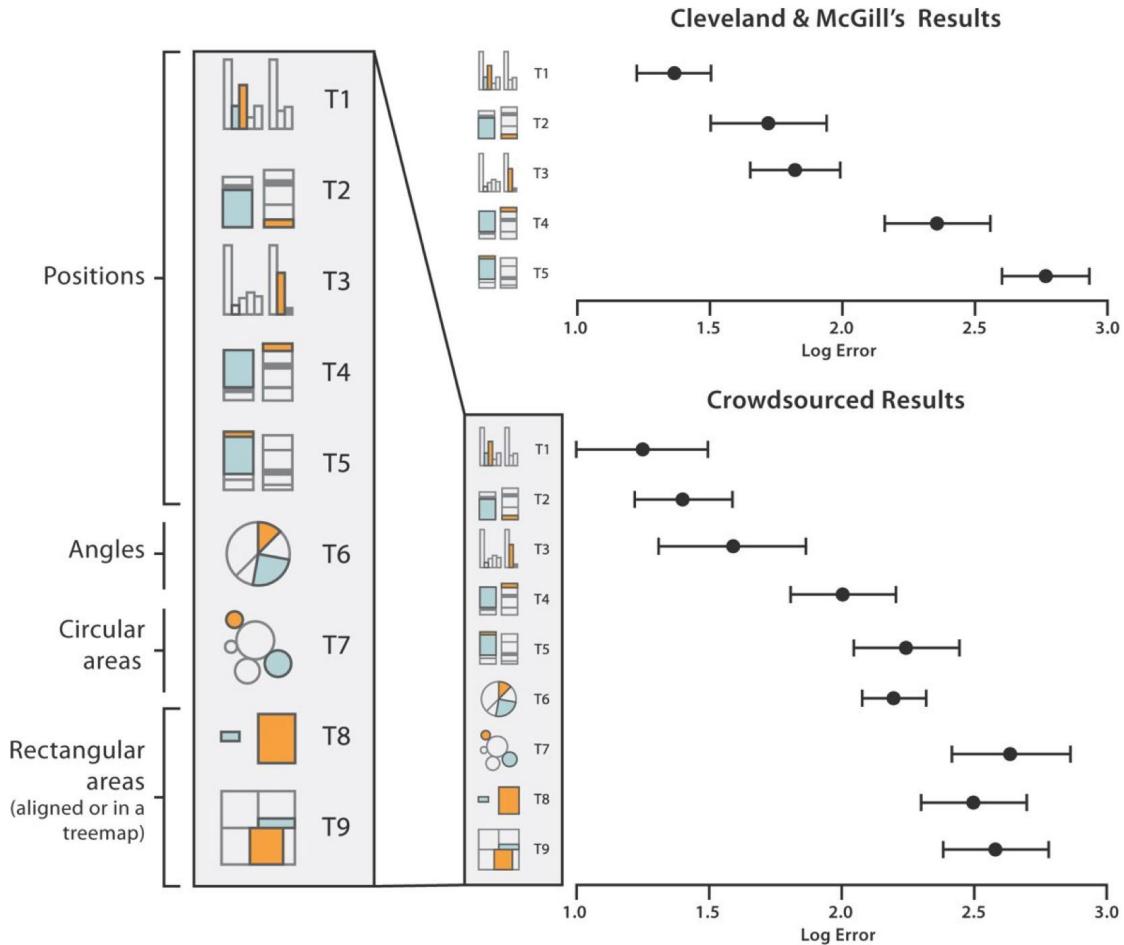
Efficacité des canaux

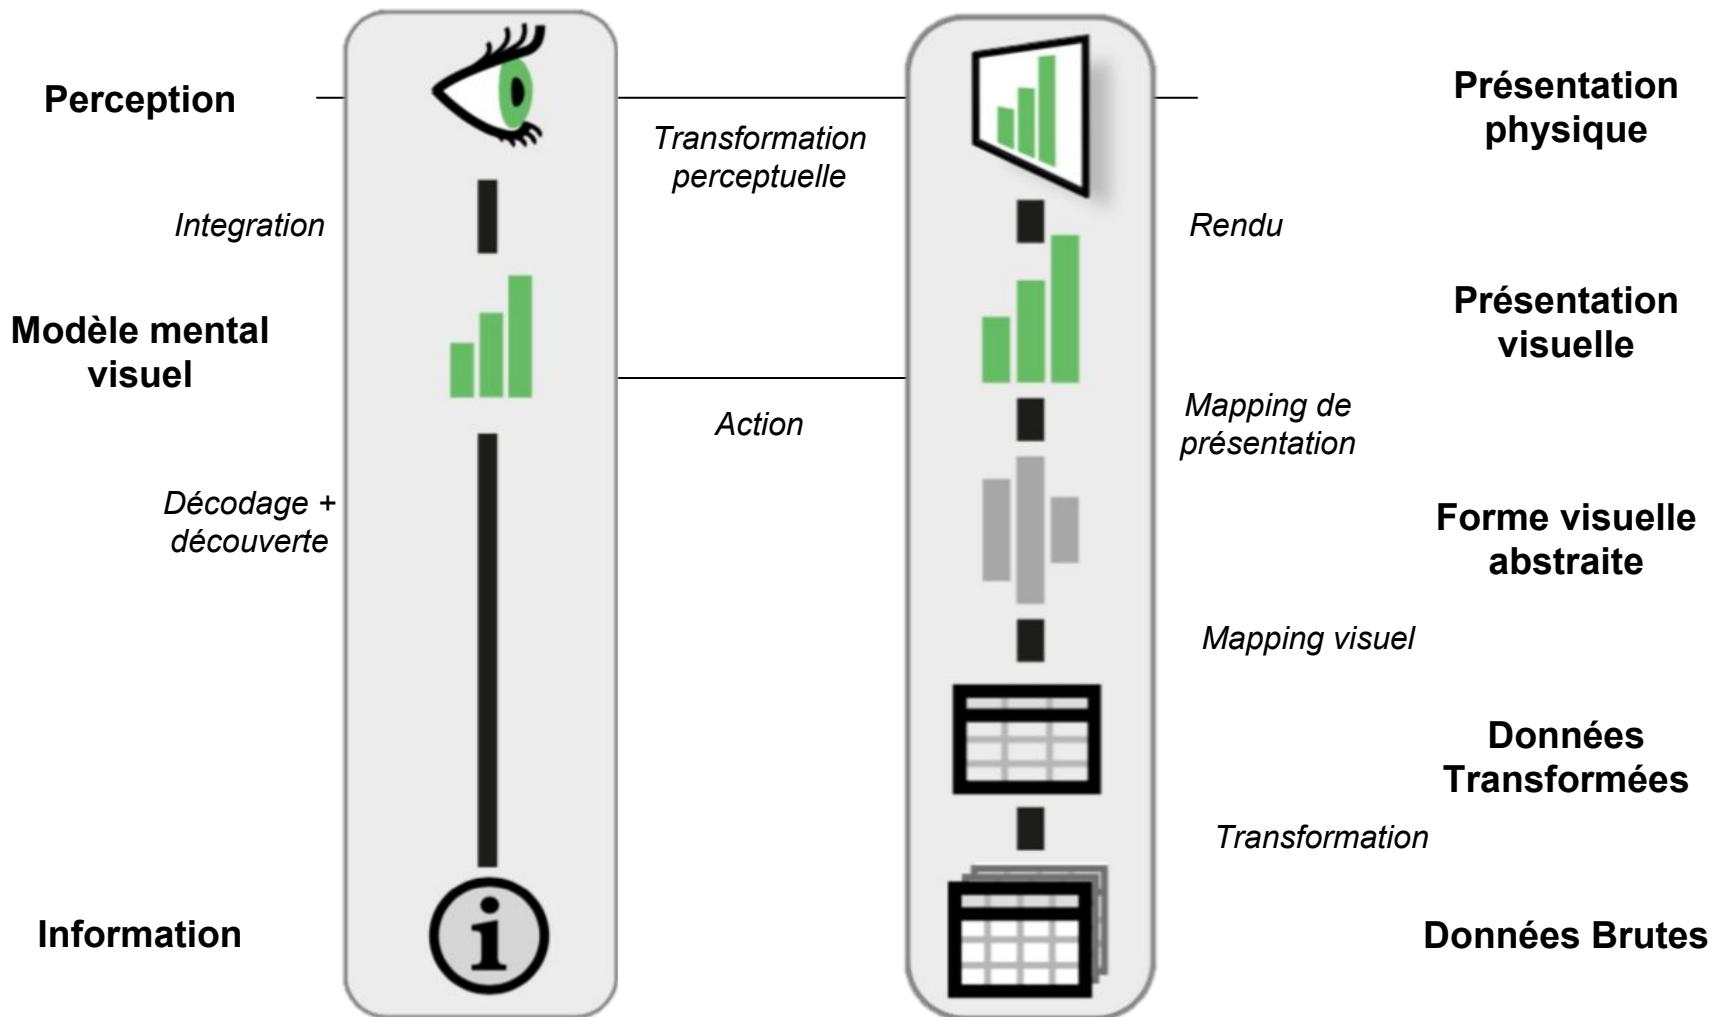
Munzner, 2014,
Visualization Analysis and Design.



Taux d'erreurs des canaux

Cleveland et McGill, 84
Heer et Bostock, 10





Plan

- Présentation du cours
 - Critique
 - Pourquoi visualiser ?
 - Qu'est ce que la visualisation
 - Type de données
 - Variables graphiques
 - Mapping + visualisation pipeline
 - Un classique
-

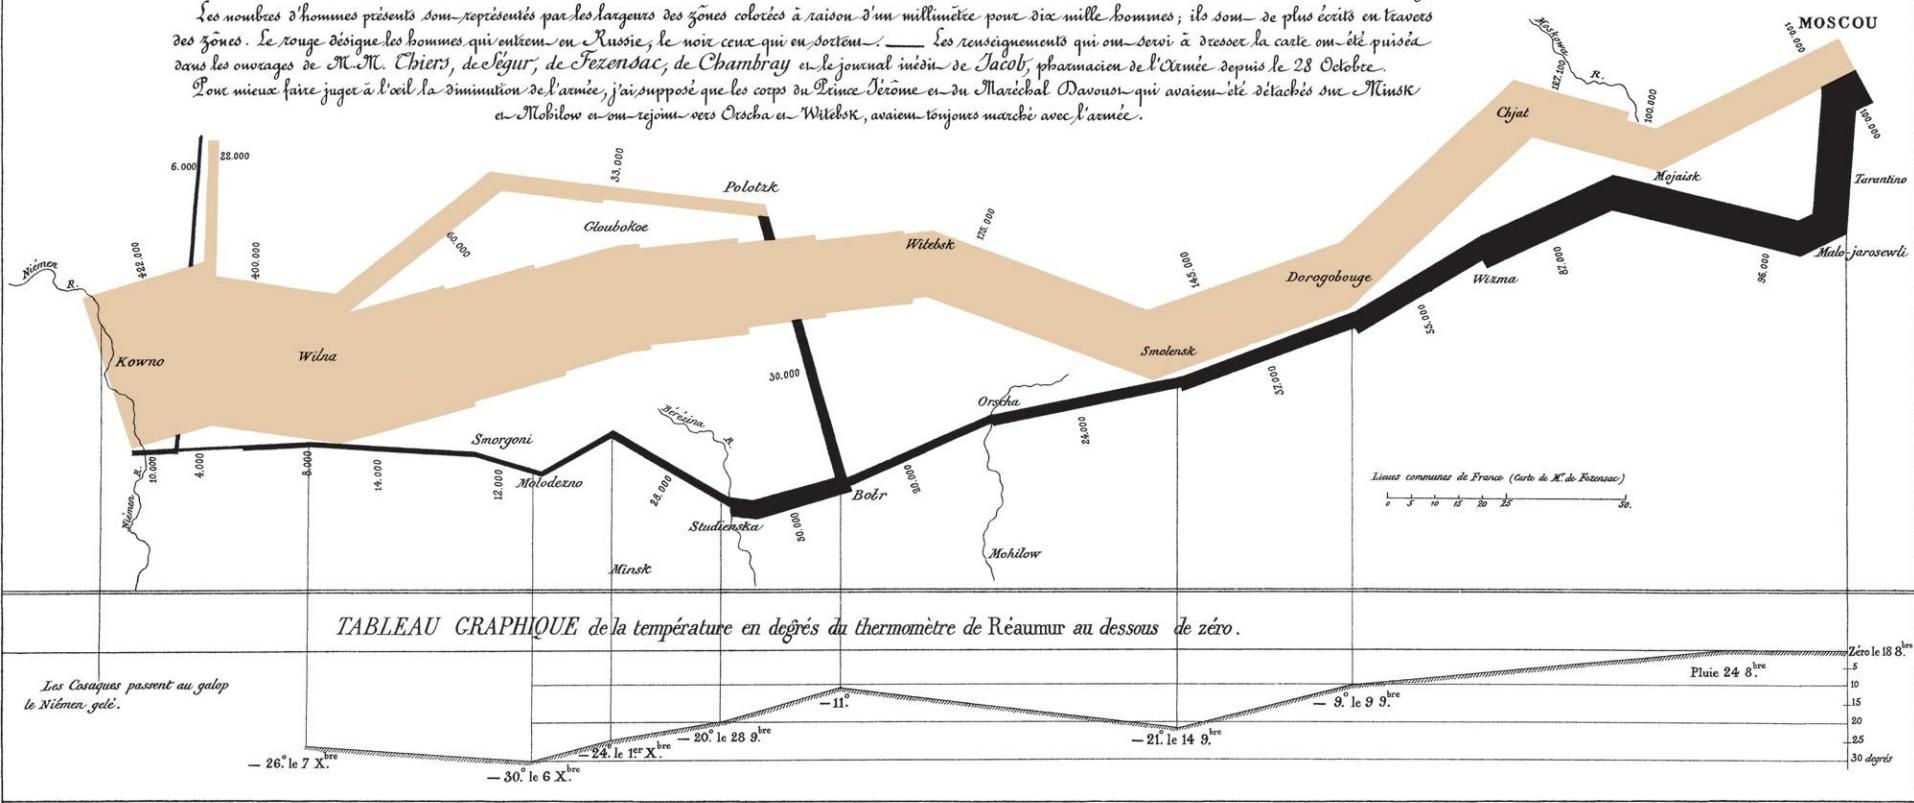
Carte Figurative des pertes successives en hommes de l'Armée Française dans la campagne de Russie 1812-1813.

Dessiné par M. Minard, Inspecteur Général des Ponts et Chaussées en retraite.

Paris, le 20 Novembre 1869.

Les nombres d'hommes présents sont représentés par les largeurs des zones colorées à raison d'un millimètre pour dix mille hommes; ils sont de plus écrits en travers des zones. Le rouge désigne les hommes qui entrent en Russie; le noir ceux qui en sortent. — Les renseignements qui ont servi à dresser la carte ont été puisés dans les ouvrages de M. M. Chier, de Clément, de Fezensac, de Chambray et le journal inédit de Jacob, pharmacien de l'Armée depuis le 28 Octobre.

Pour mieux faire juger à l'œil la diminution de l'armée, j'ai supposé que les corps du Prince Jérôme et de Maréchal Davout, qui avaient été détachés sur Minsk et Mohilow et se rejoignent vers Orsha en Witelsk, avaient toujours marché avec l'armée.



Joseph Minard 1869 : Perte Napoléonienne de la campagne de Russie (diagramme de Sankey)

BILAN

Bilan

- Présentation du cours
- Critique
- Pourquoi visualiser ?
- Qu'est ce que la visualisation ?
- Type de données
- Variables graphiques
- Mapping + visualisation pipeline

PAUSE

Exercice Tableau

Visualiser avec Tableau les résultats
des élections présidentielles américaines

<https://lyondataviz.github.io/teaching/lyon1-m2/tp1.html>

[http://www.dummies.com/programming/big-data/
big-data-visualization/tableau-for-dummies-cheat-sheet/](http://www.dummies.com/programming/big-data/big-data-visualization/tableau-for-dummies-cheat-sheet/)

Dimensions vs. measures

Dimensions:

- Discrete variables describing data
- Dates, categories of values (independent vars)

Measures:

- Data values that can be aggregated
- Numbers to be analyzed (dependent vars)
- Aggregate as sum, count, average, std. deviation