

# Les concepts de la visualisation des données

---

LA VISUALISATION DES DONNÉES ET LES TABLEAUX DE BORD

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. Thiers, de Ségur, 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 du Maréchal Davoust qui avaient été détachés sur Minsk et Mohilow et ont rejoint vers Orscha et Witebsk, avaient toujours marché avec l'armée.

Paris, le 20 Novembre 1869.





TABLEAU GRAPHIQUE de la température en degrés du thermomètre de Réaumur au dessous de zéro.



# 1. L'analyse exploratoire des données

# Le processus d'analyse (désordonné)



# Quelques questions de base

---

Quel **système** vos données représentent-elles - **objets, attributs, relations** ?

Comment représente-t-il ce système - c-à-d quel est le **modèle de données** ?

Qui a créé cet ensemble de données ? Quand ? Dans quel but ?

Supposons un fichier “plat” - que représentent les lignes et les colonnes ?

Disposez-vous de suffisamment d'informations (e.g., des **métadonnées**) pour répondre à ces questions ? Où pouvez-vous trouver plus d'informations ?

# Les résumés non visuels

---

	CL	N03	NH4
Min.	: 0.222	Min. : 0.000	Min. : 5.00
1st Qu.:	10.994	1st Qu.: 1.147	1st Qu.: 37.86
Median :	32.470	Median : 2.356	Median : 107.36
Mean :	42.517	Mean : 3.121	Mean : 471.73
3rd Qu.:	57.750	3rd Qu.: 4.147	3rd Qu.: 244.90
Max. :	391.500	Max. :45.650	Max. :24064.00
NA's :	16	NA's :2	NA's :2

```

season
Length:340
Class :character      autumn spring summer winter
Mode  :character      80      84      86      90


```


# L'utilisation avant l'analyse

---

La visualisation des données peut être utilisée pour préparer l'étape de l'analyse :

- **détecter les entrées anormales**  
entrées non valides, valeurs manquantes, valeurs aberrantes
- **façonner les transformations des données**  
“binning”, normalisation, transformations Box-Cox, transformations de type PCA
- **se faire une idée des données**  
analyse des données en tant que forme d'art, analyse exploratoire
- **identification de la structure cachée des données**  
regroupement, associations, modèles informant les étapes suivantes






Heures de travail autodéclarées (mins)

## Life Expectancy vs. GDP per Capita from 1800 to 2012 – by Max Roser


GDP per capita is measured in International Dollars. This is a currency that would buy a comparable amount of goods and services a U.S. dollar would buy in the United States in 1990. Therefore incomes are comparable across countries and across time.



Ce graphique montre la corrélation entre l'espérance de vie et le PIB par habitant.

Les pays dont le PIB est plus élevé ont une espérance de vie plus élevée, en général.

La relation semble suivre une tendance logarithmique : l'augmentation de l'espérance de vie par unité d'augmentation du PIB diminue à mesure que le PIB par habitant augmente.



## Les valeurs traditionnelles

importance de la religion, des liens parents-enfants, de la déférence envers l'autorité et des valeurs familiales traditionnelles.

## Valeurs laïques et rationnelles

Moins d'importance accordée à la religion, aux valeurs familiales traditionnelles et à l'autorité.

## Valeurs de survie

accent mis sur la sécurité économique et physique.

## Valeurs d'expression personnelle

priorité élevée à la protection de l'environnement, tolérance croissante à l'égard des étrangers, des gays et lesbiennes et de l'égalité des sexes

# Quelques graphiques d'exploration

---

Texte et tableaux

Cartes à tapis/Lignes de nombres

Histogrammes/Chartes à barres

Boxplots/Graphiques à moustache

Graphiques en ligne

Diagrammes de dispersion

# Les lignes de nombres (“rugs”)

---

Les lacunes dans la ligne numérique : l’**absence** de ces valeurs numériques dans les données.

Rappelez-vous : ceci est (peut-être) différent de l'ordre dans lequel les valeurs apparaissent dans l'ensemble de données – puisqu'il s'agit d'une ligne de nombres, elle montre où les valeurs tombent numériquement.

Si certaines valeurs sont **identiques**, elles sont superposées.




# Du texte simple

---

Un ou deux chiffres sur lesquels se concentrer.

Bon pour "planter le décor".

Attire l'attention sur une zone du rapport.



**95%** de la population  
boit du thé aujourd'hui, par rapport à  
**75%** en 2007

# Les tables et tableaux

Les tableaux interagissent avec notre système **verbal**, ce qui signifie que nous les **lisons** :

- utilisés pour comparer les valeurs
- le public cherche les rangées

Le design de la table doit **se fondre** dans le décor

- les données doivent ressortir, pas les bordures
- tableaux/données denses : utilisez des couleurs de ligne qui alternent

Nom	L'année dernière	Cette année
Bob	20	30
Fred	30	40
George	10	15

Nom	L'année dernière	Cette année
Bob	20	30
Fred	30	40
George	10	15

# Les tables “heatmap”

Tirez parti de la couleur pour transmettre l'ampleur des quantités



- utilisez la **saturation d'une seule couleur** plutôt que la différenciation (différentes couleurs)
- avec une légende (blanc = faible, bleu = élevé), les chiffres peuvent être supprimés sans altérer le message

	Last Year	This Year	Next Year	Optimum
George	20	20	20	20
Peter	40	35	30	25
John	10	10	5	5
Sandra	25	30	35	40

	Last Year	This Year	Next Year	Optimum
George	20	20	20	20
Peter	40	35	30	25
John	10	10	5	5
Sandra	25	30	35	40

	Last Year	This Year	Next Year	Optimum
George				
Peter				
John				
Sandra				

# Les diagrammes à barres




Très polyvalent et utile : utilisez TOUJOURS (?) une ligne de référence au zéro.

Utilisez soit l'axe du graphique OU des étiquettes pour les données (l'axe pour les déclarations générales, les étiquettes de données pour plus de détails).

Les graphiques horizontaux sont apparemment **plus faciles à lire** (selon de nombreuses études).


Pensez à l'ordre des catégories.

# Les diagrammes à barres empilées




Conçus pour **comparer les totaux**, mais peuvent rapidement devenir “**écrasant**”.

Difficile de trier / ordonner.



Le filtrage est assez compliqué (sur quoi faut-il cliquer et comment le graphique réagit-il lorsque l'on clique sur le filtre ?)

# Les diagrammes à barres à 100%




Fonctionnent bien pour visualiser des **portions** d'un tout sur une échelle allant du négatif au positif.


Ligne de base cohérente aux extrêmes.

Aucune mesure relative à l'**ampleur** des données.

La recherche montre que l'horizontal est plus facile à lire que le vertical.




# Les histogrammes




# Les histogrammes empilés

Nombre de diagnostics (patients hospitalisés)




# Les graphiques en ligne



Proportion de toutes les blessures liées à la bicyclette qui ont été classées comme des blessures à la tête parmi les villes ayant un programme de vélos en libre-service et les villes témoins, centrées sur la date d'intervention.



# Les graphiques en ligne



Les données d'une nouvelle étude montrent une baisse de toutes les blessures, y compris les traumatismes crâniens, après la mise en place du système de vélos en libre-service.



Comme les traumatismes crâniens diminuent moins que les autres blessures, ils représentent aujourd'hui une proportion plus importante de toutes les blessures.

# Les boîtes à moustaches (“boxplots”)



Expérience de Michelson-Morley afin de déterminer la vitesse de la lumière

# Les diagrammes de dispersion



# Lectures suggérées

L'analyse exploratoire des données

*Data Understanding, Data Analysis, Data Science*  
**Data Visualization and Data Exploration**

## Data and Charts

- Pre-Analysis Uses
- 

*The Practice of Data Visualization*  
**Basics of Data Visualization**

## Data Exploration

## Workhorse Data Visualizations

# Exercices

L'analyse exploratoire des données

1. Trouvez des exemples de présentations de données que vous considérez comme particulièrement perspicaces et/ou puissantes. Discutez de leurs forces/faiblesses.
2. Trouvez des exemples de présentations de données que vous considérez comme particulièrement trompeuses et/ou inutiles. Discutez de leurs forces/faiblesses.
3. Comment pensez-vous que les nouvelles technologies (par exemple, la réalité virtuelle ou augmentée, l'impression 3D, l'informatique portable) influenceront les présentations de données ?