

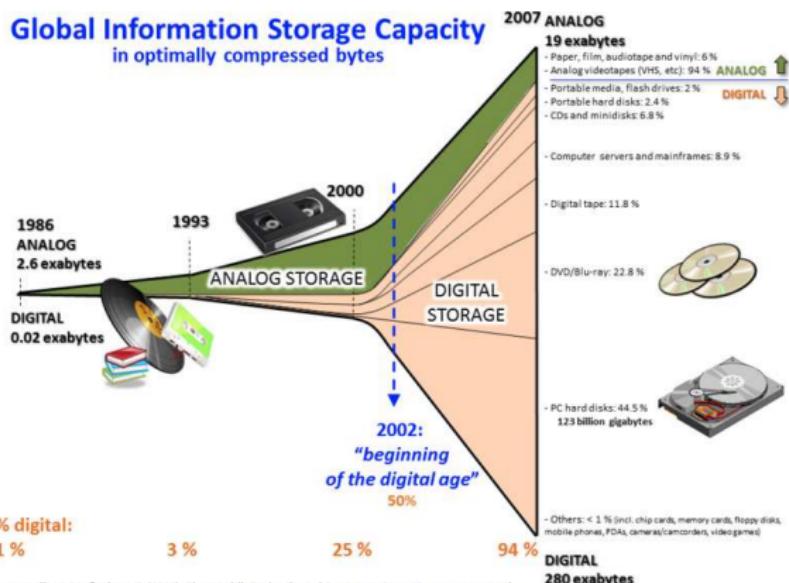
Traitement de données avec PANDAS

F. Alizard

13 mars 2018

Une introduction

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>

Accumulation de données dans tous les secteurs d'activités (modélisation numérique, bibliothèques numériques : classification des données, fouille de textes, annotation extraction de document)

Nature, Volume 455, N. 7209, 4 septembre 2008. Numéro spécial “Science in the petabyte era”.

Une introduction

Méthode classique

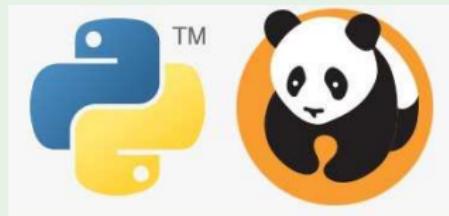
- ❶ Utilisation d'un tableur
- ❷ Données simples, non mixtes
- ❸ Licences, et versions
- ❹ Difficiles pour des données/traitements complexes (VBA, etc...)

Une alternative libre : Pandas

- ❶ Basé sur un vrai langage de programmation (Python)
- ❷ Traitement simple de données complexes
- ❸ Automatisation
- ❹ Facilité pour tracer les données grâce à matplotlib

Une introduction

Python Library for Data Analysis and Statistics



Pandas : <http://pandas.pydata.org>

- ➊ Manipuler des tableaux de données avec des étiquettes pour colonnes et lignes. Structure équivalent à un tableur.
- ➋ Tableaux : DataFrames
- ➌ Entrée (ordonnées ou non) et sortie simple à gérer. Ecriture vers un fichier tabulé (.csv, HDF5)
- ➍ Possibilité de nettoyage des données manquantes simple.
- ➎ Outils de traitement statistiques intégrés

Une introduction

Plan

- ➊ Création de DataFrames (tableaux numpy, dictionnaire, ou fichier), entrée/sortie.
- ➋ Manipulation :
 - ▶ Indexation des données
 - ▶ Extraction
 - ▶ Opérations simples
 - ▶ Tracer
- ➌ Modification des données
- ➍ Regroupement des données