


Data science

Sébastien AMALLA

Qu'est ce que la data science ?



Qu'est ce que la data science ?

- Science pluridisciplinaire regroupant :
 - Statistiques et mathématiques
 - Algorithmique
 - Expertise métier
- Objectif : extraire des informations à partir de données
- Les "données" sont les entrées bruts
- Les "informations" sont déduites du traitement des données
- Optimiser la prise de décisions, générer de la valeur

Trois domaines clés

- Mathématiques :
 - Statistiques
 - Probabilités
 - Modèles de machine learning
- Informatique (hacking skills) :
 - Python, R
 - Bases de données
 - Architecture et réseau
- Expertise métier

Objectif

- Prendre des décisions basées sur des données plutôt que sur l'intuition
- Prédire des comportements, des tendances
- Optimiser des processus
- Détecter des anomalies
- Santé : détection précoce de maladies, prédiction des épidémies
- Industrie : maintenance prédictive des machines, optimisation des chaînes d'approvisionnement et des stocks
- Finance : prédictions boursières et analyses de risques

Idée de projet perso

- Téléchargez vos relevés de compte -> conversion en data
- Nettoyage et qualité des données
- Analyse descriptive des dépenses avec dashboard
- Détecter des abonnements oubliés
- Prédiction financières
- Décisions concernant l'épargne / l'investissement
- Optimisation du budget

Notion d'approche

- Plusieurs approches sont possibles selon les données et les objectifs
- Approche descriptive : Quoi ?
- Approche diagnostique : Pourquoi ?
- Approche prédictive : Que va-t-il se passer ?
- Approche prescriptive : Que devons-nous faire ?
- Approche expérimentale : Validation d'hypothèses

Approche descriptive (Quoi ?)

- Résumer et comprendre les données
- Analyse statistique :
 - Moyenne, médiane, écart-type, minimum, maximum, pourcentages, ...
 - Corrélations entre variables
- Représentation :
 - Histogrammes, graphes, dashboards, ...
- Identifier les tendances, motifs, anomalies, ...

Approche diagnostique (Pourquoi ?)

- Comprendre pourquoi un phénomène ou un résultat se produit
- Exemple : les ventes ont chuté de 15% ce trimestre
- Analyse de causes et facteurs
- Comparaison par groupes : quels produits ont été impactés ?
 - -25% sur les produits électroniques, +8% sur les meubles, ...
- Regroupement par période : quelles semaines / jours ?
- Analyse de corrélation, heatmap
- Analyse de variance (ANOVA)

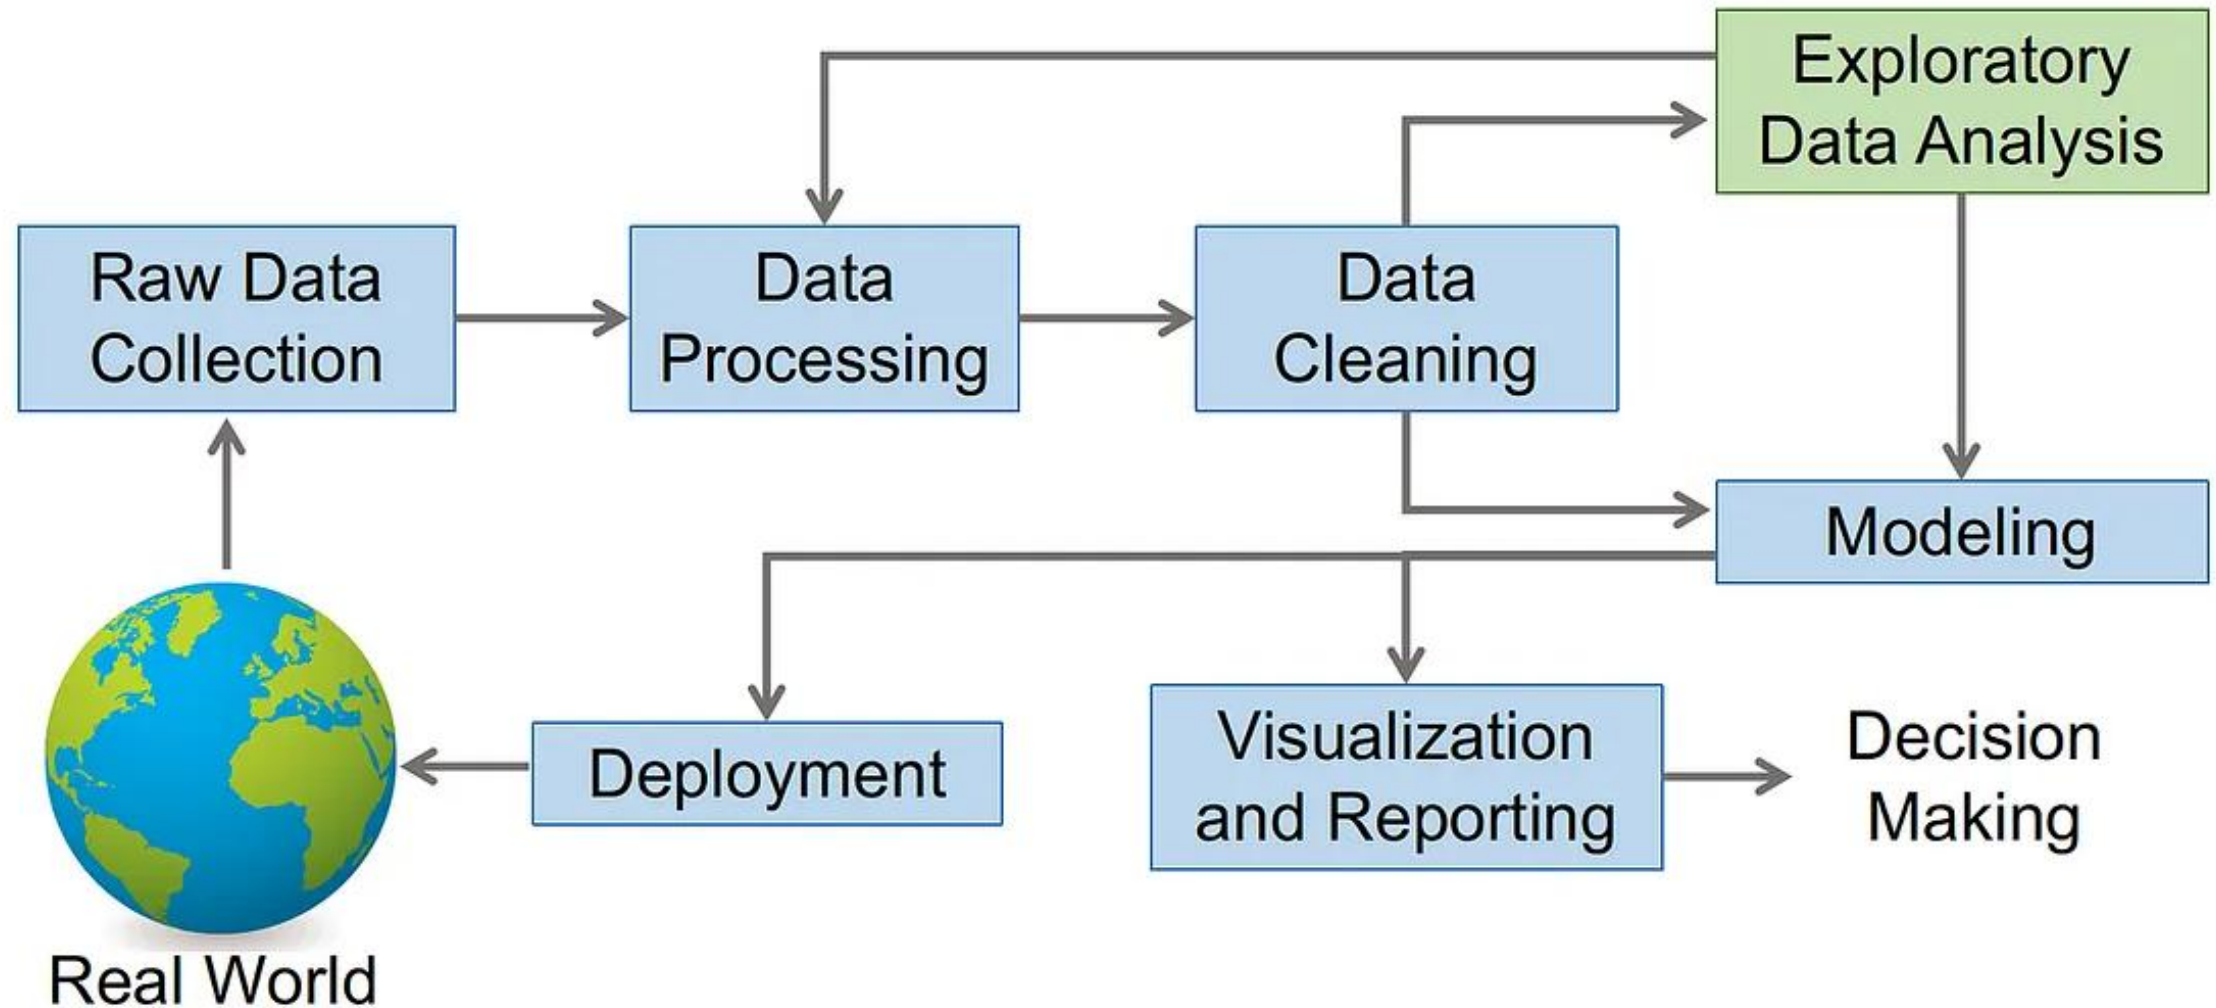
Approche prédictive (Futur ?)

- Statistiques et machine learning
- Apprentissage automatique:
 - Régressions : prédiction d'une valeur continue (prix, température)
 - Classifications : prédiction d'une catégorie (fraude ou pas)
 - Séries temporelles : tendances, saisonnalités, cyclicités, bruit, ...
- Choix du modèle
- Entraînement
- Validation
- Déploiement

Approche prescriptive : Que faire ?

- Définir des actions optimales pour un objectif donné
- Déterminer le meilleur stock à commander pour minimiser les coûts et les risques de rupture
- Déterminer un prix de vente
- Trajet d'une livraison
- Répartition des tâches dans une usine

Processus



Datascience VS Machine Learning










- Data Science = Discipline globale qui exploite les données pour créer de la valeur
- Machine learning = sous-domaine qui crée des modèles capable d'apprendre à partir des données
- Le ML est un outil que la datascience utilise, pas l'inverse
- La datascience concerne tout le cycle de vie des données

Projet concret

*Prédiction du prix médian des maisons
d'un quartier en Californie*

Marché de l'immobilier en Californie

- Chaque ligne représente un district
- On a la population totale
- Le nombre de maisons
- L'âge médian des maisons
- Le revenu médian des ménages
- La valeur médiane des maisons




Que peut-on en déduire ?

- L'échelle de median_income n'est pas en dollar. Il faut demander à l'équiper qui a récolté les datas
- C'est une échelle qui va de 0,5 à 15 et chaque chiffre représente environ 10 000\$
- housing_median_age et median_house_value ont également été bornées. Le ML va apprendre que les chiffres ne dépassent jamais ces limites
- Check avec les équipes métier : est-ce que les prédictions doivent dépasser les 500 000\$?

Que peut-on en déduire ?

- Si oui, deux options :
 - Récolter des données plus précises
 - Enlever ces datas du set
- Les échelles des données sont très variables
- Le ML a besoin de données dans des échelles de même ordre de grandeur
- Les données s'étendent beaucoup plus à droite de leur médiane qu'à gauche
- "Normalisation des données" à faire plus tard



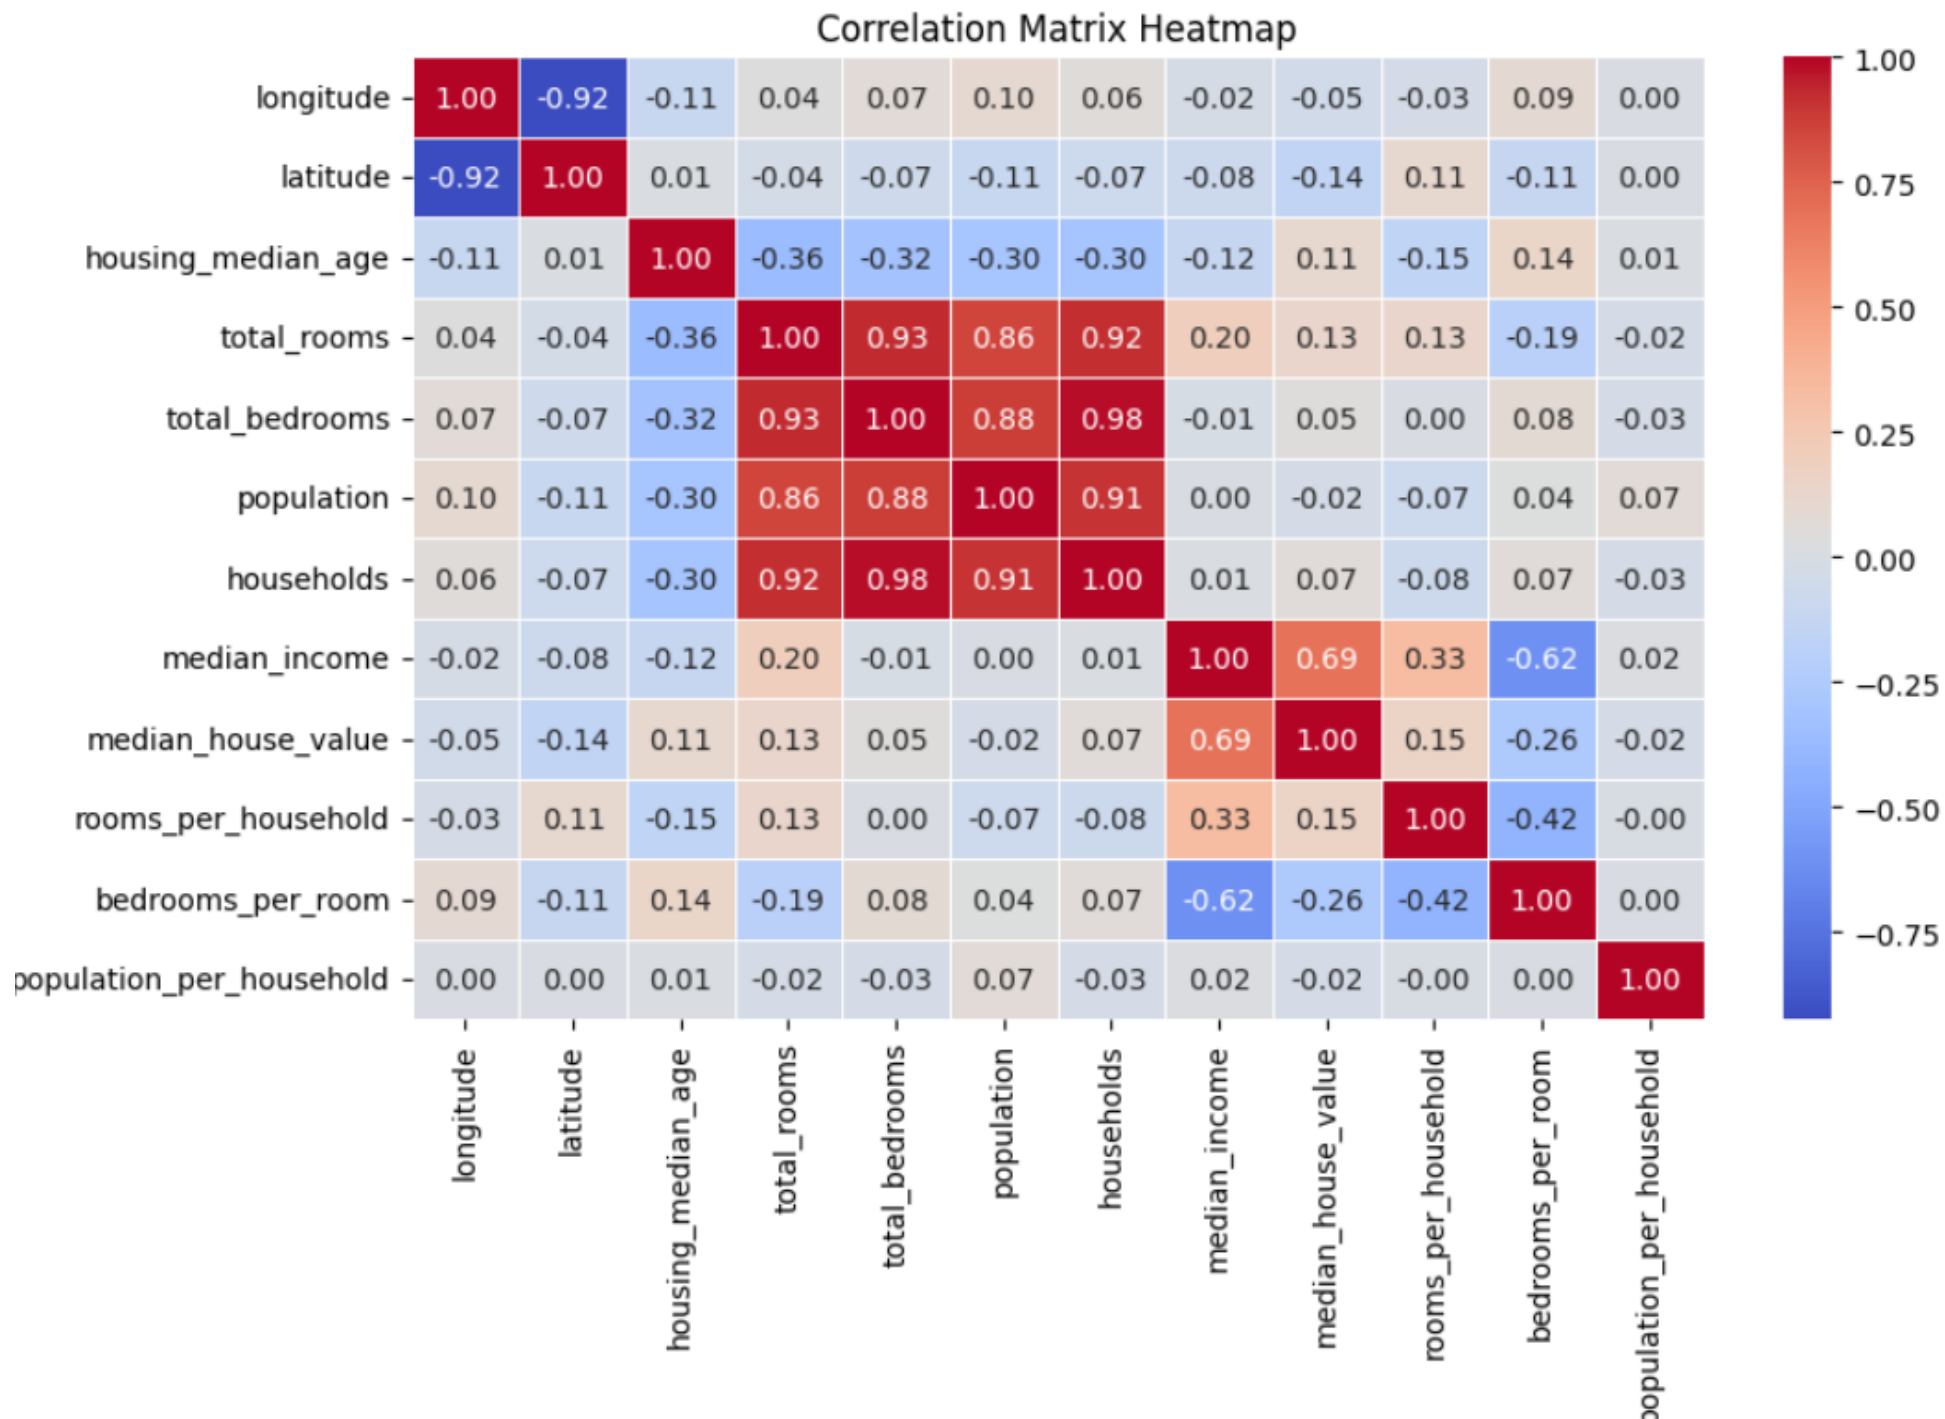
- Des zones sont plus représentées que d'autres
- Les prix sont plus élevés proche de l'océan

Corrélation linéaire entre variables

- Chaque variable peut être corrélée à toutes les autres
- Différence entre corrélation et causalité
- Différentes façon de la calculer : la plus commune est le coefficient de pearson
 - 0 = pas de corrélation
 - -1 = 100% de corrélation négative
 - +1 = 100% de corrélation positive
- Exemple "median_house_value" a une corrélation de -0,025 avec "population" et de +0,69 avec "median income"
- Que peut-on en déduire ?

Combinaisons d'attributs

- Nombre total de pièces et nombre total de foyer par district ne sont pas vraiment pertinents
- On va combiner les attributs pour en créer de nouveaux :
- Nombre de pièces par habitation
- Pourcentage de pièces qui sont des chambres
- Population par foyer
- On observe une grande corrélation entre `bedrooms_per_rooms` et `median_house_value`



Création d'un set de test


- Séparation des données en un set d'entraînement et un set de test
- En général 80% des données en train, 20% en test
- On veut pouvoir tester nos modèles avec des données sur lesquelles il ne s'est pas entraîné
- Façon simple : prendre 20% du dataset total au hasard

```
from sklearn.model_selection import train_test_split
```


- Problème induit : il faut garder des échantillon représentatifs
- Pas un soucis pour un dataset large et homogène
- Étude sur 500 personnes
 - S'assurer d'avoir un échantillon représentatif des tranches d'âge en test et en train. Pas sûr si séparation faite au hasard

Stratified sampling

- Les données sont divisées dans des groupes homogènes : "strates"
- Identifier les strates par rapport au besoin métier
- L'équipe métier vous dit que le median_income est très important pour prédire le median_housing_prices
- Il faut s'assurer que les sets de train et de test soient représentatif de la distribution du set complet
- Il faut regarder de plus près la distribution de median_income



- Va de 0,5 à 15. La plupart se trouve entre 0,5 et 6, mais quelques unes vont bien plus loin
- On va le répartir en strates. Le but est d'avoir un nombre pertinent de strates : pas trop de strates, strates assez importantes
- On va faire 5 strates : la première de 0 à 1,5, la deuxième de 1,5 à 3, ..., la dernière de 6 à +infiny
- Fonction pandas "cut"



Préparation des données pour le ML

- La variable à prédire est la "target feature"
- On va l'extraire de notre set d'entraînement, la mettre dans un tableau "labels"
- Entrée ayant "total_bedrooms" vide:
 - Soit on drop toutes les entrées vides
 - Soit on fill avec une valeur (zéro, moyenne, médiane, ...)
- On va choisir de fill par la médiane. Il va falloir calculer la médiane et la stocker ! Car il faudra fill le test_set avec la même valeur
- Objet "SimpleImputer" de sk-learn

sk-learn

- Utilisé dans dataiku
- Propose une multitude d'objets
- Ces objets sont à instancier et à "fit" sur les données
- Une fois "fit", ils peuvent "transform"
- Souvent, transforme sort un array numpy qui va devoir être converti en DataFrame pandas
- Souvent, quand on doit fit sur des données puis les transformer, il existe une fonction "fit_transform" qui fait l'un puis l'autre

Variables catégorielles

- Les variables peuvent être non-numériques, comme du texte
 - Elles peuvent aussi être des images
- La variable "Ocean proximity" est un texte classant les entrées dans des catégories :
 - <1H OCEAN
 - INLAND
 - NEAR OCEAN
 - NEAR BAY
 - ISLAND
- Les modèles de machine learning apprennent sur des données numériques uniquement

Encoding

- Les variables catégorielles doivent être encodées
- Plusieurs choix différents, on en liste deux ici :
- **Ordinal encoding** = associe un chiffre à chaque catégorie :
 - 0 : <1H OCEAN
 - 1 : INLAND
 - 2 : NEAR OCEAN
 - 3 : NEAR BAY
 - 4 : ISLAND
- Induit une hiérarchie $4 > 3 > 2 > 1 > 0$, des fois très problématique
- Très bien pour "good", "excellent", "bad" par exemple
- Pas d'appartenance à plusieurs catégories pour chaque entrée

Encoding

- **One-hot encoding** : On ajoute autant de colonnes que de catégories différentes
- Ces colonnes seront binaires : 0 ou 1
- Permet l'appartenance à deux catégories
- Pas de hiérarchie induite
- Peut grandement augmenter la taille du dataset si beaucoup de catégories
- Plusieurs autres encoding possibles...

Feature scaling

- Les modèles de ML ne fonctionnent pas bien si les variables ont des échelles très différentes
 - total_rooms : de 0 à 39 320
 - median_income : de 0 à 15
- Deux choix courants:
- Min-max scaling = Soustraire le min, diviser par max-min
 - On scale toutes les données dans une échelle allant de 0 à 1
- Standardization = Soustraire la moyenne et diviser par l'écart-type
 - Moyenne à zéro et écart-type de 1 sur une range infinie

Machine learning