LISV Laboratoire d'ingénierie des systèmes de Versailles
UVSQ université PARIS-SACLAY

Apprentissage automatique
TP 1 - Les données

Halim Djerroud

révision 1.0

— Exercices avec solutions —

Objectifs du TP
- Comprendre le processus de préparation des données.
- Appliquer les différentes techniques de nettoyage, transformation et visualisation des données.
- Mettre en pratique la séparation des jeux de données en ensemble d'entraînement, de validation et de test.
- Expérimenter avec des combinaisons de variables pour améliorer les performances des modèles d'apprentissage.

Outils et Environnement Le TP a été réalisé à l'aide des outils et environnements suivants :
- **Langage** : Python 3.x
- **Bibliothèques** : Pandas, NumPy, Matplotlib, Seaborn, Scikit-learn
- **IDE** : Jupyter Notebook / VS Code / Google Colab

Une des solutions consiste à installer anaconda https://www.anaconda.com/download/success. Une fois `anaconda` installé :

```
source ~/anaconda3/bin/activate
```

Créer un nouvel environnement nommé `ml` :

```
conda create --name ml # python=3.9
conda activate ml
(ml) conda install jupyter numpy scikit-learn matplotlib seaborn pandas
```

Lancer jupyter notbook :

```
cd /my/workspace
jupyter notebook
```

Dans un navigateur entrez l'adresse suivante :

```
http://localhost:8888/tree
```

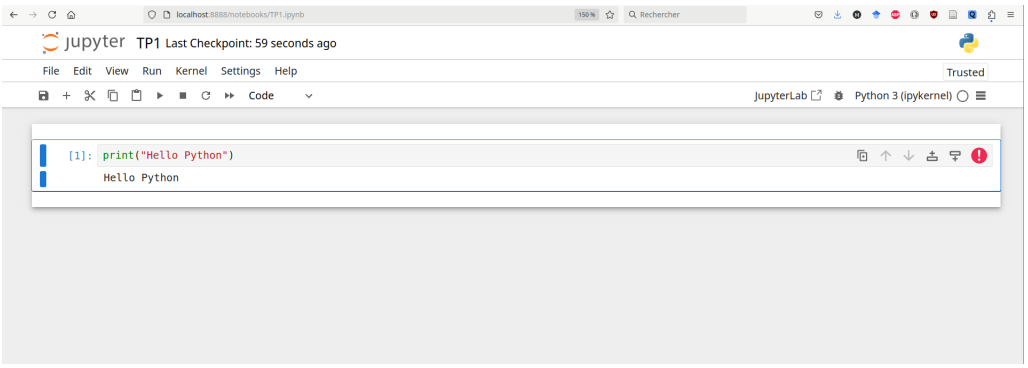

1 Exercice : le dataset *California Housing*

Exercice inspiré du livre d'Aurélien Géron intitulé "Machine Learning avec Scikit-Learn", Chaptre 2 - 'Un projet de Machine Learning de bout en bout".

1.1 Importer les Données

Utilisez la bibliothèque **Scikit-learn** pour charger le dataset California Housing et afficher les 5 premières lignes.

Solution :

```
import pandas as pd
from sklearn.datasets import fetch_california_housing
data = fetch_california_housing(as_frame=True)
df = data.frame
print(df.head())
```

Résultat :

	MedInc	HouseAge	AveRooms	AveBedrms	Population	AveOccup	Latitude	Longitude	MedHouseVal
0	8.3252	41.0	6.984127	1.023810	322.0	2.555556	37.88	-122.23	4.526
1	8.3014	21.0	6.238137	0.971880	2401.0	2.109842	37.86	-122.22	3.585
2	7.2574	52.0	8.288136	1.073446	496.0	2.802260	37.85	-122.24	3.521
3	5.6431	52.0	5.817352	1.073059	558.0	2.547945	37.85	-122.25	3.413
4	3.8462	52.0	6.281853	1.081081	565.0	2.181467	37.85	-122.25	3.422

1.2 Examiner la Structure des Données

1. Affichez les informations générales sur les colonnes.
2. Expliquer le contenu de chaque colonne et indiquer dans quelle unité est exprimée.
3. Lister les types de données et les valeurs manquantes.

Solution :

```
print(data.DESCR)

.. _california_housing_dataset:

California Housing dataset
--------------------------

**Data Set Characteristics:**

:Number of Instances: 20640

:Number of Attributes: 8 numeric, predictive attributes and the target

:Attribute Information:
    - MedInc        median income in block group
    - HouseAge      median house age in block group
    - AveRooms      average number of rooms per household
    - AveBedrms     average number of bedrooms per household
    - Population    block group population
    - AveOccup      average number of household members
    - Latitude      block group latitude
    - Longitude     block group longitude

:Missing Attribute Values: None

This dataset was obtained from the StatLib repository.
https://www.dcc.fc.up.pt/~ltorgo/Regression/cal_housing.html

The target variable is the median house value for California districts,
expressed in hundreds of thousands of dollars ($100,000).

This dataset was derived from the 1990 U.S. census, using one row per census
```

1.2 Examiner la Structure des Données

```
block group. A block group is the smallest geographical unit for which the U.S.
Census Bureau publishes sample data (a block group typically has a population
of 600 to 3,000 people).

A household is a group of people residing within a home. Since the average
number of rooms and bedrooms in this dataset are provided per household, these
columns may take surprisingly large values for block groups with few households
and many empty houses, such as vacation resorts.

It can be downloaded/loaded using the
:func:`sklearn.datasets.fetch_california_housing` function.

.. rubric:: References

- Pace, R. Kelley and Ronald Barry, Sparse Spatial Autoregressions,
  Statistics and Probability Letters, 33 (1997) 291-297
```

En français :

```
MedInc : revenu médian dans le groupe de blocs
HouseAge : âge médian des maisons dans le groupe de blocs
AveRooms : nombre moyen de pièces par ménage
AveBedrms : nombre moyen de chambres par ménage
Population : population du groupe de blocs
AveOccup : nombre moyen de membres par ménage
Latitude : latitude du groupe de blocs
Longitude : longitude du groupe de blocs
```

Informations :

```
print(df.info())
```

```
<class 'pandas.core.frame.DataFrame'>
RangeIndex: 20640 entries, 0 to 20639
Data columns (total 9 columns):
 #   Column       Non-Null Count  Dtype
---  ------       --------------  -----
 0   MedInc       20640 non-null  float64
 1   HouseAge     20640 non-null  float64
 2   AveRooms     20640 non-null  float64
 3   AveBedrms    20640 non-null  float64
 4   Population   20640 non-null  float64
 5   AveOccup     20640 non-null  float64
 6   Latitude     20640 non-null  float64
 7   Longitude    20640 non-null  float64
 8   MedHouseVal  20640 non-null  float64
dtypes: float64(9)
memory usage: 1.4 MB
None
```

Description :

```
print(df.describe())
```

```
             MedInc      HouseAge      AveRooms     AveBedrms    Population  \
count  20640.000000  20640.000000  20640.000000  20640.000000  20640.000000
mean       3.870671     28.639486      5.429000      1.096675   1425.476744
std        1.899822     12.585558      2.474173      0.473911   1132.462122
min        0.499900      1.000000      0.846154      0.333333      3.000000
25%        2.563400     18.000000      4.440716      1.006079    787.000000
50%        3.534800     29.000000      5.229129      1.048780   1166.000000
75%        4.743250     37.000000      6.052381      1.099526   1725.000000
max       15.000100     52.000000    141.909091     34.066667  35682.000000

           AveOccup      Latitude     Longitude   MedHouseVal
count  20640.000000  20640.000000  20640.000000  20640.000000
mean       3.070655     35.631861   -119.569704      2.068558
std       10.386050      2.135952      2.003532      1.153956
min        0.692308     32.540000   -124.350000      0.149990
25%        2.429741     33.930000   -121.800000      1.196000
50%        2.818116     34.260000   -118.490000      1.797000
75%        3.282261     37.710000   -118.010000      2.647250
max     1243.333333     41.950000   -114.310000      5.000010
```

Les valeurs manquantes

```
print(df.isnull().sum())
```

Résultat :

```
MedInc          0
HouseAge        0
AveRooms        0
AveBedrms       0
Population      0
AveOccup        0
Latitude        0
Longitude       0
MedHouseVal     0
dtype: int64
```

1.3 Utiliser le vrai dataset

Dans cette section au lieu d'utiliser le dataset présent directement sur Scikit-Learn nous allons utiliser le dataset original. Télécharger et extraire le fichier *housing.tar.gz* sur le lien suivant :
https://raw.githubusercontent.com/ageron/handson-ml/master/datasets/housing/housing.tgz

Dans un `Shell` :

```
wget https://raw.githubusercontent.com/ageron/handson-ml/master/datasets/housing/housing.tgz
tar xfvz housing.tgz
```

Puis en Python :

```
pd.read_csv('housing.csv')
```

1.3.1 Étudier la différnce

Examiner le nouveau dataset est determiner les différences entre les deux.
Informations :

```
print(df.info())
```

Résultat :

```
<class 'pandas.core.frame.DataFrame'>
RangeIndex: 20640 entries, 0 to 20639
Data columns (total 10 columns):
 #   Column              Non-Null Count  Dtype
---  ------              --------------  -----
 0   longitude           20640 non-null  float64
 1   latitude            20640 non-null  float64
 2   housing_median_age  20640 non-null  float64
 3   total_rooms         20640 non-null  float64
 4   total_bedrooms      20433 non-null  float64
 5   population          20640 non-null  float64
 6   households          20640 non-null  float64
 7   median_income       20640 non-null  float64
 8   median_house_value  20640 non-null  float64
 9   ocean_proximity     20640 non-null  object
dtypes: float64(9), object(1)
memory usage: 1.6+ MB
None
```

Les valeurs nulles :

```
print(df.isnull().sum())
```

Résultat :

1.3 Utiliser le vrai dataset

```
longitude               0
latitude                0
housing_median_age      0
total_rooms             0
total_bedrooms        207
population              0
households              0
median_income           0
median_house_value      0
ocean_proximity         0
dtype: int64
```

Commentaire :
Toutes les variables sont numérique, excepté ocean_proximity. Elle est de type `object`.

```
df["ocean_proximity"].value_counts()
```

Résultat :

```
ocean_proximity
<1H OCEAN     9136
INLAND        6551
NEAR OCEAN    2658
NEAR BAY      2290
ISLAND           5
Name: count, dtype: int64
```

```
print(df.describe())
```

Résultat :

```
          longitude      latitude  housing_median_age   total_rooms  \
count  20640.000000  20640.000000        20640.000000  20640.000000
mean    -119.569704     35.631861           28.639486   2635.763081
std        2.003532      2.135952           12.585558   2181.615252
min     -124.350000     32.540000            1.000000      2.000000
25%     -121.800000     33.930000           18.000000   1447.750000
50%     -118.490000     34.260000           29.000000   2127.000000
75%     -118.010000     37.710000           37.000000   3148.000000
max     -114.310000     41.950000           52.000000  39320.000000

       total_bedrooms    population    households  median_income  \
count    20433.000000  20640.000000  20640.000000   20640.000000
mean       537.870553   1425.476744    499.539680       3.870671
std        421.385070   1132.462122    382.329753       1.899822
min          1.000000      3.000000      1.000000       0.499900
25%        296.000000    787.000000    280.000000       2.563400
50%        435.000000   1166.000000    409.000000       3.534800
75%        647.000000   1725.000000    605.000000       4.743250
max       6445.000000  35682.000000   6082.000000      15.000100

       median_house_value
count        20640.000000
mean        206855.816909
std         115395.615874
min          14999.000000
25%         119600.000000
50%         179700.000000
75%         264725.000000
max         500001.000000
```

1.4 Explorer et Visualiser les Données

Créez des histogrammes et des nuages de points (scatter plots) pour les variables `MedInc`, `HouseAge` et `MedHouseVal`.

Solution :

```
import matplotlib.pyplot as plt
df.hist(bins=50, figsize=(20,15))
plt.show()
```

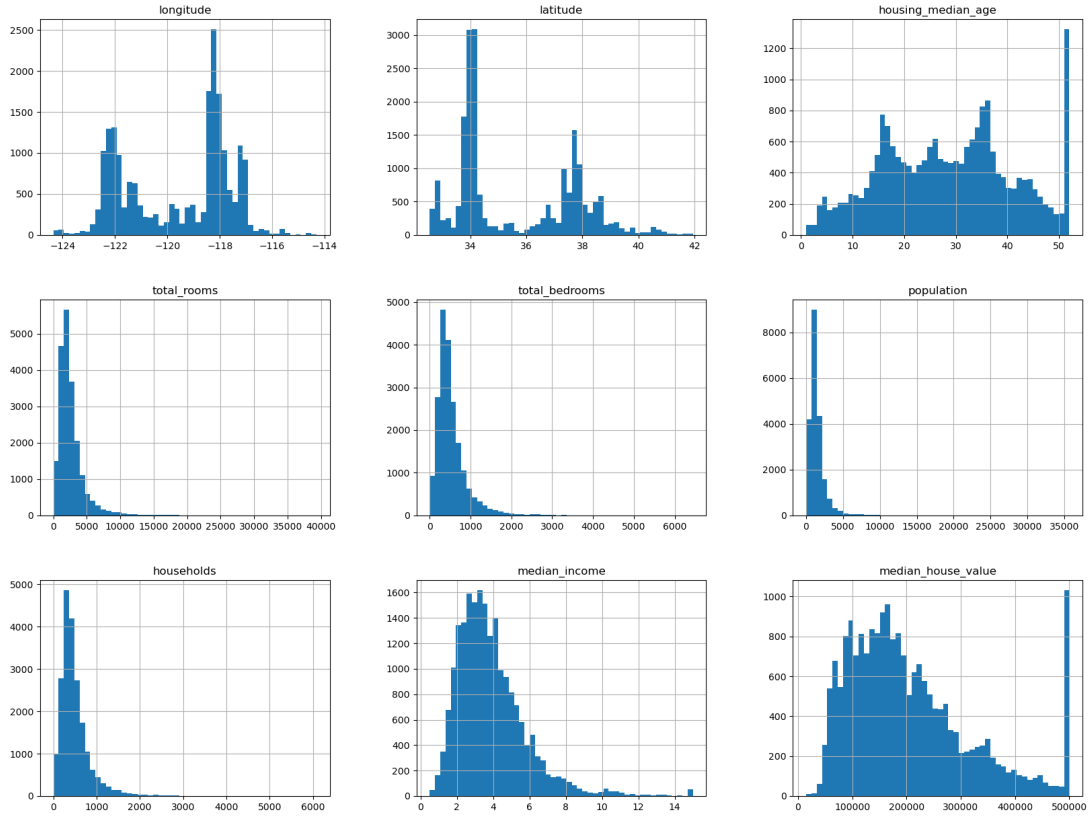

Commentaire :

- La variable *median_ income* (revenu moyen) ne semble pas exprimée en $. Après vérification, on vous dit que variable a été mise à l'échelle et plafonnée à 15 (plus exactement = 15.0001) pour les revenus les plus élevés et à 0.5 (plus exactement à 0.49999) pour les revenus les plus bas.
- L'âge moyen des habitations est également plafonné.

Commentaire :
Notez que certains histogrammes sont fortement dissymétriques, ils s'étendent bien plus loin à droite qu'à gauche. Certains algorithmes d'apprentissage peuvent avoir de mal à détecter des structurations.

1.4.1 Visualiser des données géographiques

Utiliser la longitude et la latitude pour afficher la concentration des habitations.

Solution :

```
df.plot(kind="scatter", x="longitude", y="latitude", alpha=0.1)
plt.savefig('geo.png')
plt.show()
```

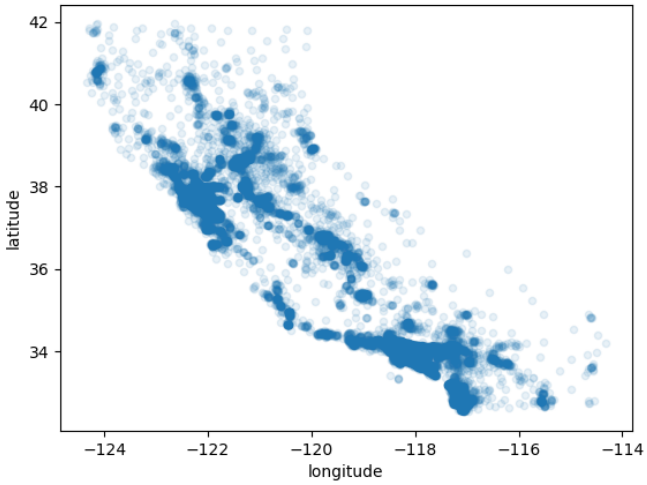

Ajouter dans le même graphique la concentration des habitations et le prix de l'immobilier.

Solution :

```
df.plot(kind="scatter", x="longitude", y="latitude", alpha=0.4,
        s=df["population"]/100, label="Population",
        c="median_house_value", cmap=plt.get_cmap("jet"), colorbar=True)
plt.legend()
plt.savefig('geo2.png')
plt.show()
```

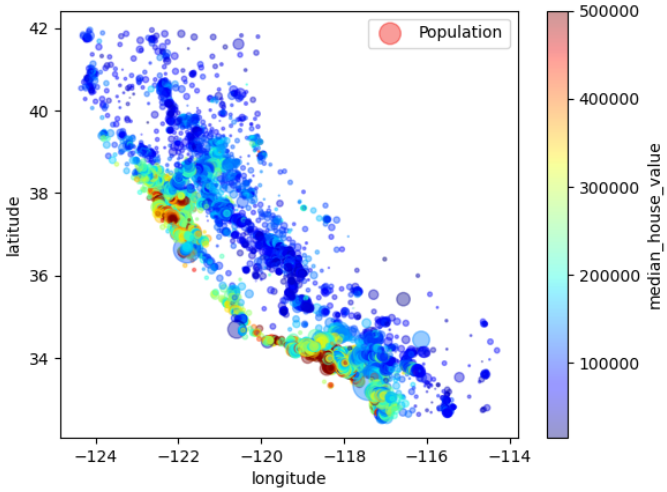

1.5 Recherche de corrélations

Calculer le coefficient de corrélation entre chaque couple de variables.

Solution :

```
df_copy = df.copy()
df_copy.drop(columns=['ocean_proximity'], inplace=True)
corr_matrix = df_copy.corr()
print(corr_matrix)
```

Commentaire :
La colonne *ocean_ proximity* est supprimée, car elle n'est pas possible d'effectuer de calcul sur une colonne de type chaine de caractères.

Résultats :

```
                    longitude  latitude  housing_median_age  total_rooms  \
longitude            1.000000 -0.924664           -0.108197     0.044568
latitude            -0.924664  1.000000            0.011173    -0.036100
housing_median_age  -0.108197  0.011173            1.000000    -0.361262
total_rooms          0.044568 -0.036100           -0.361262     1.000000
total_bedrooms       0.069608 -0.066983           -0.320451     0.930380
population           0.099773 -0.108785           -0.296244     0.857126
households           0.055310 -0.071035           -0.302916     0.918484
median_income       -0.015176 -0.079809           -0.119034     0.198050
median_house_value  -0.045967 -0.144160            0.105623     0.134153

                    total_bedrooms  population  households  median_income  \
longitude                 0.069608    0.099773    0.055310      -0.015176
latitude                 -0.066983   -0.108785   -0.071035      -0.079809
housing_median_age       -0.320451   -0.296244   -0.302916      -0.119034
total_rooms               0.930380    0.857126    0.918484       0.198050
total_bedrooms            1.000000    0.877747    0.979728      -0.007723
population                0.877747    1.000000    0.907222       0.004834
households                0.979728    0.907222    1.000000       0.013033
median_income            -0.007723    0.004834    0.013033       1.000000
median_house_value        0.049686   -0.024650    0.065843       0.688075

                    median_house_value
longitude                    -0.045967
latitude                     -0.144160
housing_median_age            0.105623
total_rooms                   0.134153
total_bedrooms                0.049686
population                   -0.024650
households                    0.065843
median_income                 0.688075
median_house_value            1.000000
```

```
import pandas as pd
from pandas.plotting import scatter_matrix
import matplotlib.pyplot as plt
atts = ["median_house_value", "median_income", "total_rooms", "housing_median_age"]
scatter_matrix(df[atts], figsize=(12, 8))
plt.savefig('matrix_corr.png')
plt.show()
```

1.6 Expérimenter avec des combinaisons de variables

Le nombre total de pièces dans un district n'est pas très utile si vous ne conaissez pas le nombre de logements. Ce qu'on souhaite, c'est d'avoir le nombre de pièces par logement. De même le nombre total de chambres n'est pas très utile en lui-même, mais il sera utile de le comparer au nombre de pièces. Il est aussi intéressant de calculer le nombre de personnes par logement.

Créer de nouvelles colonnes qui exprimes ces nouvelles données. Et examiner à nouveau la matrice de corrélation.

Solution :

```
df["rooms_per_household"]=df["total_rooms"]/df["households"]
df["bedromms_per_room"]=df["total_bedrooms"]/df["total_rooms"]
```

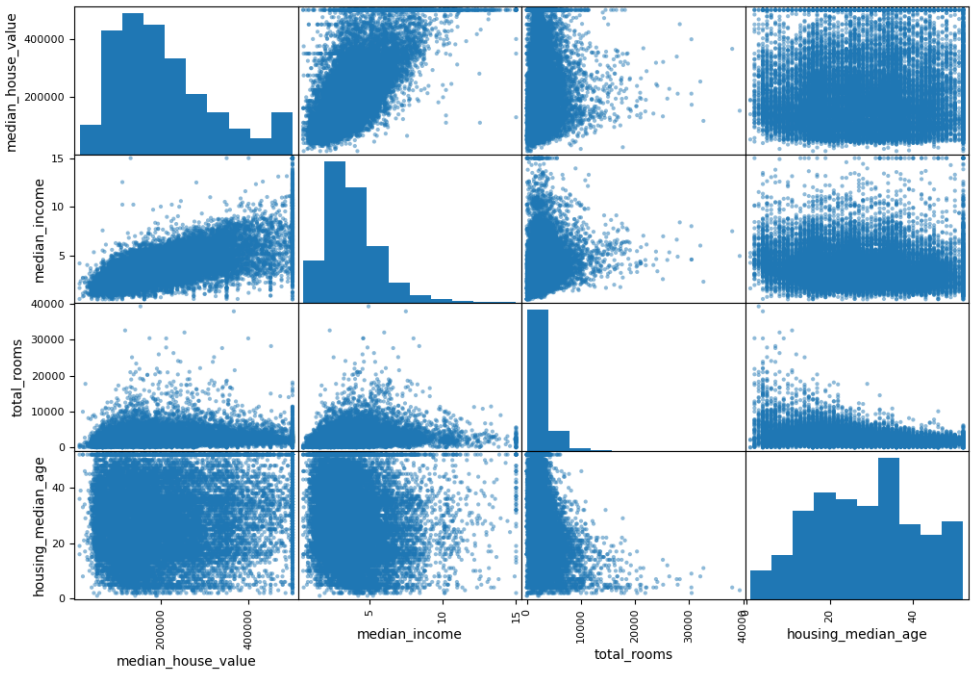


```
df["population_per_household"]=df["population"]/df["households"]

df_copy = df.copy()
df_copy.drop(columns=['ocean_proximity'], inplace=True)
corr_matrix = df_copy.corr()
print(corr_matrix["median_house_value"].sort_values(ascending=False))
```

Résultats :

```
median_house_value          1.000000
median_income               0.688075
rooms_per_household         0.151948
total_rooms                 0.134153
housing_median_age          0.105623
households                  0.065843
total_bedrooms              0.049686
population_per_household   -0.023737
population                 -0.024650
longitude                  -0.045967
latitude                   -0.144160
bedromms_per_room          -0.255880
Name: median_house_value, dtype: float64
```

Commentaire :
La nouvelle variable *bedrooms_per_room* est bien plus corrélée avec la valeur moyenne des habitations que le nombre total de pièces ou de chambres. Les maisons avec un faible ratio chambres/pièces ont tendances à être plus chères.

1.7 Nettoyer les Données

Pour les variables manquantes, trois options s'offrent à nous :

1. Supprimer les districts correspondants.
2. Supprimer cette variable.
3. Mettre la valeur à : (zéro, la moyenne, la médiane, etc.).

Solution :

```
#option 1
df.dropna(subset=["total_bedrooms"])
#option 2
df.drop("total_bedrooms", axis=1)
#option 3
median = df["total_bedrooms"].median()
df["total_bedrooms"].fillna(median, inplace=True)
```

Commentaire :
Scikit-Learn fourni la lasse *Imputer* qui permet de traiter les valeurs manquantes. Utiliser cette classe pour réaliser chacune des options précédentes.

1.8 Gérer les variables qualitatives

Trouver un moyen de gérer la colonne *ocean_ proximity*. Deux options s'offrent a nous :

1. Label encoding
2. One hot encoding

Solution :

```
#Option 1

from sklearn.preprocessing import LabelEncoder
encoder = LabelEncoder()
housing_cat = df["ocean_proximity"]
housing_cat_encoded = encoder.fit_transform(housing_cat)
housing_cat_encoded

#Option 2
from sklearn.preprocessing import OneHotEncoder
encoder = OneHotEncoder()
housing_cat_1hot = encoder.fit_transform(housing_cat_encoded.reshape(-1,1))
housing_cat_1hot
```

1.9 Recalibrage des variables

Il existe deux façon de recalibrer les variables :

1. Transformation *(min-max)* ou *Normalisation* : Les valeurs sont décalées afin qu'elles se situent entre 0 et 1.
$$X_{norm} = \frac{x - x_{min}}{x_{max} - x_{min}} \in [0, 1]$$
2. *Normalisation standard* ou simplement *Standardisation* : tout d'abord, on les soustrait à la valeur moyenne (de sorte que les valeurs normalisées auront toujours une moyenne nulle), puis à les diviser par l'écart-type afin que la distribution qui en résulte ait une variance = 1.
$$X_{standard} = \frac{X - \mu}{\sigma}$$

Utiliser les pipelines offerts par Scikit-Learn pour réaliser une normalisation.

1.10 Séparer les Jeux d'Entraînement, de Validation et de Test

Divisez les données en ensembles d'entraînement, de validation et de test.

Solution :

```
from sklearn.model_selection import train_test_split

X = df.drop(columns=['MedHouseVal'])
y = df['MedHouseVal']

X_train, X_temp, y_train, y_temp = train_test_split(X, y, test_size=0.3, random_state=42)
X_val, X_test, y_val, y_test = train_test_split(X_temp, y_temp, test_size=0.5, random_state=42)
```

2 Exercice : Le dataset IRIS

2.1 Importer les Données

Utilisez la bibliothèque **Scikit-learn** pour charger le dataset Iris. Puis réaliser l'étape de préparation de données en vue de les soumettre à un algorithme d'apprentissage.

1. Examiner la structure des Données.
2. Explorer et visualiser les Données
3. Expérimenter avec des combinaisons de variables
4. Rechercher des corrélations
5. Rédiger une conclusion sur les données
6. Nettoyer les données
7. Gérer les variables qualitatives
8. Recalibrer des variables
9. Séparer les jeux d'entraînement, de validation et de test

3 Dataset : Titanic (Survie des passagers)

Le dataset Titanic est l'un des jeux de données les plus utilisés pour l'apprentissage des concepts de classification. Ce dataset est disponible sur Kaggle.

Réaliser les étapes suivantes :

1. Examiner la structure des Données.
2. Explorer et visualiser les Données
3. Expérimenter avec des combinaisons de variables
4. Rechercher des corrélations
5. Rédiger une conclusion sur les données
6. Nettoyer les données
7. Gérer les variables qualitatives
8. Recalibrer des variables
9. Séparer les jeux d'entraînement, de validation et de test

4 Dataset qualité de l'air à paris

4.1 Importer les Données

Téléchargez le fichier `qualite_air.csv` depuis data.gouv.fr et importez-le à l'aide de Pandas. https://www.data.gouv.fr/fr/datasets/indice-de-la-qualite-de-lair-quotidien-par-commune-indice-atmo/

Réaliser les étapes suivantes :

1. Examiner la structure des Données.
2. Explorer et visualiser les Données
3. Expérimenter avec des combinaisons de variables
4. Rechercher des corrélations
5. Rédiger une conclusion sur les données
6. Nettoyer les données
7. Gérer les variables qualitatives
8. Recalibrer des variables
9. Séparer les jeux d'entraînement, de validation et de test