Manipulation de données avec Python pour des travaux d'investigation

Partie 1 - Lecture et preparation des données

NOE BOUDON - CECILE LIN

Année 2022 - 2023

Contents

Partie 1 - Lecture et preparation des donnees

Les données obtenues dans le cadre professionnel peuvent avoir **différents formats**, dont certains sont en fait du texte (.csv, .txt, etc.) et ne sont pas toujours utilisables comme telles – **il faut parfois enrichir ces données** en ajoutant des colonnes qui découlent des colonnes initiales, notamment (i) pour nettoyer les données (e.g. identification des doublons, suppression de dates erronées), (ii) pour faire ressortir des indicateurs statistiques plus pertinents par combinaison d'indicateurs unitaires (e.g. calculs de ratios, de maximum), (iii) pour homogénéiser des données qui sont hétérogènes fautes de standards dans l'entreprise.

Le travail d'enrichissement peut également permettre de **fiabiliser** une base de données par calcul d'agrégats, analyse de séquences logiques (si je dépasse ce seuil, alors cette colonne doit être égale à, etc.).

Tout ceci requiert une bonne maîtrise des fonctions de Python que nous allons explorer dans cette partie.

[617]:
```
# imports
import pandas as pd
import datetime
import re
import matplotlib.pyplot as plt
import numpy as np
import os

# Permet d'afficher jusqu'à 50 colonnes lorsqu'on observe un DataFrame
pd.options.display.max_columns = 50

# Permet de définir une taille par défaut de 15x5 pour les graphiques matplotlib
plt.rcParams["figure.figsize"] = (15,5)
```

1 Lire et observer des données avec Python

Les données reçues sont réparties dans 3 fichiers : - *DIT - Application, Personne, Projet.xlsx* - Ce fichier contient 3 jeux de données différents *Application*, *Personne* et *Projet* - *log.txt* - *tache.csv*

Pour commencer, utilisez `pandas` pour lire chacun des 3 fichiers. Attention ces fichiers ont des extensions différentes (*.xlsx*, *.csv* et *.txt*). Il peut également y avoir des difficultés de lecture liées à l'encodage ou aux séparateurs. N'hésitez pas à observer les fichiers !

1.0.1 Création du DataFrame `applications`

Créez un DataFrame `applications` composé des données du fichier *DIT - Application, Personne, Projet.xlsx* issues de la feuille de calcul *Application*. Et enregistrez celui-ci dans une variable nommée `applications`.

Affichez ensuite les 2 premières lignes du DataFrame

[2]:
```
path1 = '_Data/DIT - Application, Personne, Projet.xlsx'
applications = pd.read_excel(path1, 'Application')
applications.head(2)
```

[2]:
```
  AppCode        Name RiskLevel  LastResilienceTest  NombreUtilisateur2017  \
0   A6205      Yearin      HIGH               42795                   9704
1   A7527  Goodsilron       LOW               41477                   6969

   NombreUtilisateur2016
0                   9740
1                   6938
```

1.0.2 Création du DataFrame `personnes`

Créez un DataFrame `personnes` composé des données du fichier *DIT - Application, Personne, Projet.xlsx* issues de la feuille de calcul *Personne*. Et enregistrez celui-ci dans une variable nommée `personnes`.

Affichez ensuite les 2 premières lignes du DataFrame

[568]:
```
path2 = '_Data/Personnes.csv'
personnes = pd.read_csv(path2)
personnes.head(2)
```

[568]:
```
      Prenom      Nom                       Mail          ID  \
0    Charles    Smith                 charles.smith@tgp.com  A692817085
1  Madeleine  Chapman              madeleine.chapman@tgp.com  A185252110

                 Role  ExperienceValeur
0  Developpeur Junior                 1
1  Developpeur Junior                 1
```

1.0.3 Création du DataFrame `projets`

Créez un DataFrame `projets` composé des données du fichier *DIT - Application, Personne, Projet.xlsx* issues de la feuille de calcul *Projet*. Et enregistrez celui-ci dans une variable nommée `projets`.

Puis retirez les 7 dernières colonnes de ce DataFrame et affichez les 3 premières lignes de celui-ci.

[280]:
```
path3 = '_Data/DIT - Application, Personne, Projet.xlsx'
projets = pd.read_excel(path3, 'Projet')
projets = projets.drop(['ExperienceChefDeProjet','Appli2_Nom', 'Appli1_Nom',␣
 ↪'Appli2', 'Appli1', 'DevisBudgetEUR_Clean', 'RankBudget'], axis=1)
projets.head(3)
```

[280]:
```
   Annee  NumeroVersion FicheDeDemande  ReferenceID         NomDuProjet  \
0   2014              1              x       218486   Projet Girl Scout
1   2015              1              +       230240        Projet Cobra
```

```
2   2015             4              x       240101  Projet Bee - LOT 4

   DateCreation                  Statut InterlocuteurMetier  ChefDeProjet  \
0         41741                     RAS      Joseph DICKENS    Jane SHARP
1         42128                 Termine     Madeleine BROWN    Gavin KING
2         42090  En attente de decision       Leonard JONES  Ian HEMMINGS

   DateDemande  DateReponse TypeDemande TypeDevis CauseReestimation  \
0        41640        41883   Catalogue  Reestime             Autre
1        41640        42896      Projet   Initial               NaN
2        41779        42968   Evolution  Reestime             Autre

  CodeApplicAtion  DateDebutTravaux  DateFinTravaux  DateDebutHomologation  \
0    A4701; A7843             41929           42176                  42244
1    A3758; A3774             42917           43083                  43128
2    A4452; A5146             43021           43167                  43195

   DevisBudgetJH DevisBudgetEUR  DevisBudgetJHEUR  DevisBudgetInfraEUR
0           1900       2,6 MEUR           1235000            1365000.0
1           2000       2,7 MEUR           1300000            1400000.0
2           1400         2 MEUR            910000            1090000.0
```

1.0.4 Création du DataFrame `logs`

Nous allons créer un DataFrame `logs`à partir des données issues du fichier *log.txt*. Mais nous ne savons pas quel séparateur est utilisé…

Dans un premier temps, utilisez la fonction `open()` pour lire les données qui y sont contenues et affichez les 100 premiers caractères. Il est possible qu'il y ait également des problèmes liés à l'*encoding*…

[618]:
```
#logs = pd.read_csv('./_Data/log.txt', sep=" ", header=None)
#logs.columns = ['ProjectKey','TaskAssignee','TaskKey','DateFInalLog','MDLogged']

with open('./_Data/log.txt', 'r', encoding = 'utf-16') as f:
    logs = f.read()

print(logs[0:100])
```

```
ProjectKey      TaskAssignee    TaskKey DateFInalLog    MDLogged
218486  A810043709      M1      29/01/2015      1
218486  A8100
```

Maintenant que vous avez identifié le séparateur, utilisez la méthode appropriée de pandas pour créer un DataFrame avec ces données. Puis, affichez les 2 premières lignes de ce dataFrame.

[622]:
```
logs = pd.read_csv('./_Data/log.txt', encoding = 'utf-16', sep= "\t" , decimal =␣
↪".")
logs.head(2)
```

[622]:
```
   ProjectKey TaskAssignee TaskKey DateFInalLog  MDLogged
0      218486   A810043709      M1   29/01/2015         1
1      218486   A810043709      M1   11/01/2015         1
```

1.0.5 Création du DataFrame `taches`

Créez un DataFrame `taches` composé des données du fichier *tache.csv* et enregistrez celui-ci dans une variable nommée `taches`.

Puis affichez les 3 premières lignes de celui-ci.

[620]:
```
path4 = './_Data/tache.csv'
taches = pd.read_csv(path4, encoding = 'latin-1', sep=';', decimal='.')
taches.head(3)
```

[620]:
```
   ProjectKey TaskAssignee  Priority TaskKey  MDPlanned  MDUpdatedPlanned  \
0      218486   A810043709  VERY LOW      M1          5                 4
1      218486   A722019848       LOW      M2          8                12
2      218486    A69888201    MEDIUM      M3          9                 7

           TaskType   Location
0            CODING  Bangalore
1  STRUCTURE CHANGE  Bangalore
2               BUG      Paris
```

2 Vérifications et préparation des données

Quelques informations sur les différents jeux de données disponibles : - `applications` contient des données relatives aux différentes applications - i.e. les identifiants, noms, niveau de risque (criticité), date du dernier test de résilience et nombre d'utilisateurs sur deux années successives (2017 et 2018). - `personnes`contient des données relatives aux collaborateurs de la société TGP (une ESN - Entreprise de services du numérique). On y retrouve les noms, prénoms, adresses mail, identifiants de chacun des collaborateurs ainsi que leur poste et leur expérience (en années). - `projets`contient des données concernant des informations concernant les différents projets réalisées par TGP. Entre autres, (i) le nom du chef de projet, (ii) les dates des différentes étapes, (iii) les applications concernées par chaque projet... - `logs`contient les informations relatives au *time tracking* de ces projets - i.e. le nombre de jours (*Jour Homme* JH, également appelé *Man Day* MD) passé par chaque collaborateur sur chaque tâche du projet. - `taches` contient des informations sur les différentes tâches des projets. En particulier le nombre de jours (MD) planifiés sur chacune des tâches, leur niveau de priorité, l'endroit (ville) où elles ont été réalisées.

Maintenant que les données ont été chargées dans des DataFrames, nous allons en vérifier la qualité. Les objectifs de cette partie sont (i) découvrir les données disponibles, (ii) d'identifier les différents problèmes dans les données pouvant bloquer nos analyses et (iii) résoudre ces problèmes.

2.1 Base des projets

[105]:
```
projets.head()
```

[105]:
```
   Annee  NumeroVersion FicheDeDemande  ReferenceID         NomDuProjet  \
0   2014              1              x       218486   Projet Girl Scout
1   2015              1              +       230240        Projet Cobra
2   2015              4              x       240101  Projet Bee - LOT 4
3   2016              3              x       294007      Projet Templer
4   2017              1              +       304283        Projet Alpha

   DateCreation                  Statut InterlocuteurMetier   ChefDeProjet  \
0         41741                     RAS      Joseph DICKENS     Jane SHARP
1         42128                 Termine     Madeleine BROWN     Gavin KING
2         42090  En attente de decision       Leonard JONES   Ian HEMMINGS
3         42518                      GO     Madeleine BROWN  David JACKSON
4         42746                      GO     Madeleine BROWN  David JACKSON

   DateDemande  DateReponse TypeDemande TypeDevis   CauseReestimation  \
0        41640        41883   Catalogue  Reestime               Autre
1        41640        42896      Projet   Initial                 NaN
2        41779        42968   Evolution  Reestime               Autre
3        41814        42607      Projet  Reestime               Autre
4        41848        42790   Evolution  Reestime  Ajout contributeur

  CodeApplicAtion  DateDebutTravaux  DateFinTravaux  DateDebutHomologation  \
0   A4701; A7843             41929           42176                  42244
1   A3758; A3774             42917           43083                  43128
2   A4452; A5146             43021           43167                  43195
3   A4317; A8067             42675           42957                  43009
4   A3774; A5876             42827           42976                  43058

   DevisBudgetJH DevisBudgetEUR  DevisBudgetJHEUR  DevisBudgetInfraEUR
0           1900       2,6 MEUR           1235000            1365000.0
1           2000       2,7 MEUR           1300000            1400000.0
2           1400         2 MEUR            910000            1090000.0
3           2200         3 MEUR           1430000            1570000.0
4           1500       2,2 MEUR            975000            1225000.0
```

Modification des colonnes devant contenir des dates En observant rapidement le DataFrame, on se rend compte que les colonnes *DateCreation*, *DateDemande*, *DateReponse*, *DateFinTravaux* et *DateDebutHomologation* contiennent des nombres…

Or, vu le nom de ces colonnes, elles devraient contenir des dates ! Cela est dû au fait qu'Excel enregistre les dates comme étant le nombre de jours depuis le 30 décembre 1899.

Pour corriger ce problème, écrivez un script permettant de transformer les valeurs de ces colonnes en dates (i.e. 1899-12-30 + n jours, avec n - valeurs présentes actuellement dans ces colonnes).

[312]:
```
#nb_annee_en_plus_C = projets['DateCreation']//365
#annee_C = nb_annee_en_plus_C + 1 + 1899 # en prenant en compte qu'on demarre du
 ↪30/12 et non pas du 31/12

#nb_annee_en_plus_D = projets['DateDemande']//365
#annee_D = nb_annee_en_plus_D + 1 + 1899

#nb_annee_en_plus_R = projets['DateReponse']//365
#annee_R = nb_annee_en_plus_R + 1 + 1899

#nb_annee_en_plus_T = projets['DateFinTravaux']//365
#annee_T = nb_annee_en_plus_T + 1 + 1899

#nb_annee_en_plus_H = projets['DateDebutHomologation']//365
#annee_H = nb_annee_en_plus_H + 1 + 1899
from datetime import *

import warnings
warnings.filterwarnings('ignore')
warnings.warn('DelftStack')
warnings.warn('Do not show this message')

j = 0
for i in projets['DateCreation']:
    projets['DateCreation'][j] = datetime.fromordinal(datetime(1900, 1, 1).
 ↪toordinal() + i - 2)
    #print(projets['DateCreation'][j])
    j = j + 1

j = 0
for i in projets['DateDemande']:
    projets['DateDemande'][j] = datetime.fromordinal(datetime(1900, 1, 1).
 ↪toordinal() + i - 2)
    j = j + 1

j = 0
for i in projets['DateReponse']:
    projets['DateReponse'][j] = datetime.fromordinal(datetime(1900, 1, 1).
 ↪toordinal() + i - 2)
    j = j + 1

j = 0
for i in projets['DateFinTravaux']:
    projets['DateFinTravaux'][j] = datetime.fromordinal(datetime(1900, 1, 1).
 ↪toordinal() + i - 2)
    j = j + 1
```

```
j = 0
for i in projets['DateDebutHomologation']:
    projets['DateDebutHomologation'][j] = datetime.fromordinal(datetime(1900, 1,␣
 ↪1).toordinal() + i - 2)
    j = j + 1

projets.head()
```

[312]:

	Annee	NumeroVersion	FicheDeDemande	ReferenceID	NomDuProjet	DateCreation	Statut	InterlocuteurMetier	ChefDeProjet	DateDemande	DateReponse	TypeDemande	TypeDevis	CauseReestimation	CodeApplicAtion	DateDebutTravaux	DateFinTravaux	DateDebutHomologation	DevisBudgetJH	DevisBudgetEUR	DevisBudgetJHEUR	DevisBudgetInfraEUR
0	2014	1	x	218486	Projet Girl Scout	2014-04-12 00:00:00	RAS	Joseph DICKENS	Jane SHARP	2014-01-01 00:00:00	2014-09-01 00:00:00	Catalogue	Reestime	Autre	A4701; A7843	41929	2015-06-21 00:00:00	2015-08-28 00:00:00	1900	2,6 MEUR	1235000	1365000.0
1	2015	1	+	230240	Projet Cobra	2015-05-04 00:00:00	Termine	Madeleine BROWN	Gavin KING	2014-01-01 00:00:00	2017-06-10 00:00:00	Projet	Initial	NaN	A3758; A3774	42917	2017-12-14 00:00:00	2018-01-28 00:00:00	2000	2,7 MEUR	1300000	1400000.0
2	2015	4	x	240101	Projet Bee - LOT 4	2015-03-27 00:00:00	En attente de decision	Leonard JONES	Ian HEMMINGS	2014-05-20 00:00:00	2017-08-21 00:00:00	Evolution	Reestime	Autre	A4452; A5146	43021	2018-03-08 00:00:00	2018-04-05 00:00:00	1400	2 MEUR	910000	1090000.0
3	2016	3	x	294007	Projet Templer	2016-05-28 00:00:00	GO	Madeleine BROWN	David JACKSON	2014-06-24 00:00:00	2016-08-25 00:00:00	Projet	Reestime	Autre	A4317; A8067	42675	2017-08-10 00:00:00	2017-10-01 00:00:00	2200	3 MEUR		
4	2017	1	+	304283	Projet Alpha	2017-01-11 00:00:00	GO	Madeleine BROWN	David JACKSON	2014-07-28 00:00:00	2017-02-24 00:00:00	Evolution	Reestime	Ajout contributeur	A3774; A5876	42827	2017-08-29 00:00:00	2017-11-19 00:00:00	1500	2,2 MEUR		

```
3            1430000             1570000.0
4             975000             1225000.0
```

[314]:
```
# Vous pourriez également utiliser le package xlrd !
# Exemple pour DateCreation de la première ligne

import xlrd
xlrd.xldate_as_datetime(41741,0)
```

[314]:
```
datetime.datetime(2014, 4, 12, 0, 0)
```

Observation et correction des valeurs nulles Créez un *barchart* permettant d'observer le nombre de valeurs nulles dans chacune des colonnes.

[315]:
```
#import missingno as msno
#msno.bar(projets)

a = []

for i in projets:
    a = a + [projets[i].isna().sum()]

bc = pd.DataFrame(
    {"Nombre de valeur nulle":a},
    index = projets.columns
)

bc.plot(kind = 'bar', y = "Nombre de valeur nulle");
plt.xlabel("Colonne")
plt.legend()
plt.show()
```

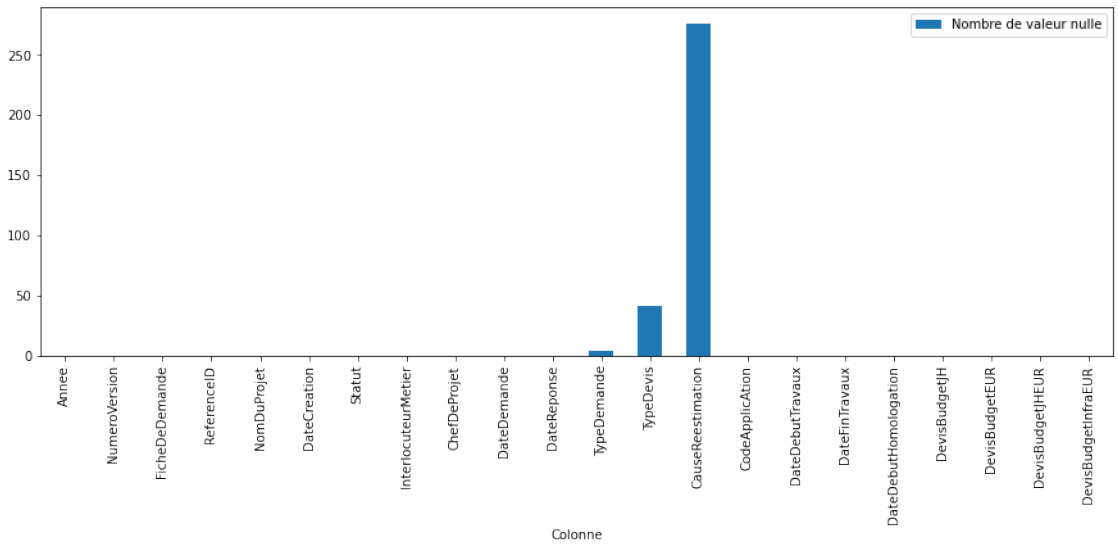

```
[0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 4, 41, 276, 0, 0, 0, 0, 0, 0, 0, 0]
```

Puis remplacez les valeurs nulles des colonnes TypeDemande et TypeDevis par les chaînes de caractères "Inconnu" et "Sans devis" respectivement.

[311]:
```
path3 = '_Data/DIT - Application, Personne, Projet.xlsx'
projets = pd.read_excel(path3, 'Projet')
projets = projets.drop(['ExperienceChefDeProjet','Appli2_Nom', 'Appli1_Nom',␣
 ↪'Appli2', 'Appli1', 'DevisBudgetEUR_Clean', 'RankBudget'], axis=1)
projets.head(3)
```

[311]:

	Annee	NumeroVersion	FicheDeDemande	ReferenceID	NomDuProjet	DateCreation	Statut	InterlocuteurMetier	ChefDeProjet	DateDemande	DateReponse	TypeDemande	TypeDevis	CauseReestimation	CodeApplicAtion	DateDebutTravaux	DateFinTravaux	DateDebutHomologation	DevisBudgetJH	DevisBudgetEUR	DevisBudgetJHEUR	DevisBudgetInfraEUR
0	2014	1	x	218486	Projet Girl Scout	41741	RAS	Joseph DICKENS	Jane SHARP	41640	41883	Catalogue	Reestime	Autre	A4701; A7843	41929	42176	42244	1900	2,6 MEUR	1235000	1365000.0
1	2015	1	+	230240	Projet Cobra	42128	Termine	Madeleine BROWN	Gavin KING	41640	42896	Projet	Initial	NaN	A3758; A3774	42917	43083	43128	2000	2,7 MEUR	1300000	1400000.0
2	2015	4	x	240101	Projet Bee - LOT 4	42090	En attente de decision	Leonard JONES	Ian HEMMINGS	41779	42968	Evolution	Reestime	Autre	A4452; A5146	43021	43167	43195	1400	2 MEUR	910000	1090000.0

[318]:
```
#projets['TypeDemande'] = projets['TypeDemande'].fillna('Inconnu')
#projets['TypeDevis'] = projets['TypeDevis'].fillna('Sans devis')

valeur_null = projets['TypeDevis'].isna()

j = 0
for i in range(len(valeur_null)):
    if valeur_null[i]:
        projets['TypeDevis'][i] = 'Sans devis'
        j +=1

#print(projets['TypeDevis'])
```

```
#print(j)

valeur_null = projets['TypeDemande'].isna()

j = 0
for i in range(len(valeur_null)):
    if valeur_null[i]:
        projets['TypeDemande'][i] = 'Inconnu'
        j +=1 #permet de verifier qu'on a bien tout remplacer

#print(projets['TypeDemande'])
#print(j)
```

```
0
```

Y a-t-il des lignes pour lesquelles le TypeDevis est "Reestime" mais la colonne CauseReestimation est nulle (NaN) ?

Ecrivez un script pour vérifier cela.

[330]:
```
valeur_null_TypeDevis = (projets['TypeDevis'] == 'Reestime')
valeur_null_Cause = projets['CauseReestimation'].isna()

for i in range(len(valeur_null_TypeDevis)):
    if valeur_null_TypeDevis[i] and valeur_null_Cause[i] and i > 1:
        # la condition i > 1 pour s'assurer que plusieurs lignes ont les deux␣
 ↪conditions demandées
        # neanmoins la condition n'aurait pas été necessaire si la question␣
 ↪avait été 'Y a-t-il au moins une ligne..'
        print(True)
        break
```

```
True
```

Ecrivez maintenant un script permettant remplacer les valeurs nulles de la colonne CauseReestimation mais cela uniquement lorsque TypeDevis est "Reestime"

[346]:
```
l_null_reestime = []
for i in range(len(valeur_null_TypeDevis)):
    if valeur_null_TypeDevis[i] and valeur_null_Cause[i]:
        l_null_reestime = l_null_reestime + [i]

for i in l_null_reestime:
    #print(i)
    #print(projets['CauseReestimation'][i])
    x = input('par quoi on remplace la valeur nulle à la ligne? ' + str(i) + ' :␣
 ↪')
    projets['CauseReestimation'][i] = x
```

Modification de la colonne CodeApplication La colonne code application peut contenir jusqu'à 2 codes d'applications (séparés par un ";")...

Créez 2 nouvelles colonnes: - `Appli1` - qui contient le premier code application (celui avant le ";") ; - `Appli2` - qui contient le second code application, si il existe (et `NaN` sinon).

Attention : dans la colonne "CodeApplicAtion", il pourrait y avoir des espaces avant ou après les codes... Cela pourrait causer des problèmes. Il faudra utiliser la méthode `.strip()` pour supprimer ces espaces inutiles.

[362]:
```
projets['CodeApplicAtion'].str.strip()

projets['Appli1'] = projets['CodeApplicAtion'].copy()
projets['Appli2'] = projets['CodeApplicAtion'].copy()

j = 0
for i in projets['CodeApplicAtion']:
    #print(i)
    position = i.find(';')
    #print(position)
    projets['Appli1'][j] = i[0:position]
    projets['Appli2'][j] = i[position+1:len(i)]
    j += 1

projets.head()
```

[362]:
```
   Annee  NumeroVersion FicheDeDemande  ReferenceID         NomDuProjet  \
0   2014              1              x       218486   Projet Girl Scout
1   2015              1              +       230240        Projet Cobra
2   2015              4              x       240101  Projet Bee - LOT 4
3   2016              3              x       294007      Projet Templer
4   2017              1              +       304283        Projet Alpha

          DateCreation                   Statut InterlocuteurMetier  \
0  2014-04-12 00:00:00                      RAS      Joseph DICKENS
1  2015-05-04 00:00:00                  Termine     Madeleine BROWN
2  2015-03-27 00:00:00  En attente de decision       Leonard JONES
3  2016-05-28 00:00:00                       GO     Madeleine BROWN
4  2017-01-11 00:00:00                       GO     Madeleine BROWN

    ChefDeProjet          DateDemande          DateReponse TypeDemande  \
0     Jane SHARP  2014-01-01 00:00:00  2014-09-01 00:00:00   Catalogue
1     Gavin KING  2014-01-01 00:00:00  2017-06-10 00:00:00      Projet
2   Ian HEMMINGS  2014-05-20 00:00:00  2017-08-21 00:00:00   Evolution
3  David JACKSON  2014-06-24 00:00:00  2016-08-25 00:00:00      Projet
4  David JACKSON  2014-07-28 00:00:00  2017-02-24 00:00:00   Evolution

  TypeDevis   CauseReestimation CodeApplicAtion  DateDebutTravaux  \
```

```
0  Reestime               Autre    A4701; A7843            41929
1   Initial                 NaN    A3758; A3774            42917
2  Reestime               Autre    A4452; A5146            43021
3  Reestime               Autre    A4317; A8067            42675
4  Reestime  Ajout contributeur    A3774; A5876            42827

        DateFinTravaux DateDebutHomologation  DevisBudgetJH DevisBudgetEUR  \
0  2015-06-21 00:00:00   2015-08-28 00:00:00           1900       2,6 MEUR
1  2017-12-14 00:00:00   2018-01-28 00:00:00           2000       2,7 MEUR
2  2018-03-08 00:00:00   2018-04-05 00:00:00           1400          2 MEUR
3  2017-08-10 00:00:00   2017-10-01 00:00:00           2200          3 MEUR
4  2017-08-29 00:00:00   2017-11-19 00:00:00           1500       2,2 MEUR

   DevisBudgetJHEUR  DevisBudgetInfraEUR Appli1  Appli2
0           1235000            1365000.0  A4701   A7843
1           1300000            1400000.0  A3758   A3774
2            910000            1090000.0  A4452   A5146
3           1430000            1570000.0  A4317   A8067
4            975000            1225000.0  A3774   A5876
```

Modification de la colonne DevisBudgetEUR Cette colonne contient des chaînes de caractères. En effet, le nombre est ici suivi de "MEUR" ou "KEUR" selon les cas.

Proposez un script permettant de créer une colonne "DevisBudgetEUR_clean" contenant les valeurs présentes dans "DevisBudgetEUR" transformées en nombres. Il faudra ici multiplier le nombre par 1000000 dans le cas "MEUR" et par 1000 dans le cas "KEUR".

Vous pourrez par exemple créer une fonction pour convertir un budget en nombre puis l'utiliser dans un `.apply()`.

[411]:
```
projets['DevisBudgetEUR_clean'] = projets['DevisBudgetEUR']

def effacer_virgule(x):
    position_r1 = x.find(',')
    return(x[0:position_r1] + x[position_r1 + 1:len(x)])

#effacer_virgule('2,5')

j = 0
for i in projets['DevisBudgetEUR']:
    #print(i)
    position = i.find(' ')
    #print(position)
    projets['DevisBudgetEUR_clean'][j] = i[0:position]
    projets['DevisBudgetEUR_clean'][j] =␣
 ↪effacer_virgule(projets['DevisBudgetEUR_clean'][j])
    if i[position + 1] == 'M':
```

```
        projets['DevisBudgetEUR_clean'][j] = projets['DevisBudgetEUR_clean'][j]␣
↪+ '00000'
    if i[position + 1] == 'K':
        projets['DevisBudgetEUR_clean'][j] = projets['DevisBudgetEUR_clean'][j]␣
↪+ '00'
    if i[position - 2] != ',':
        projets['DevisBudgetEUR_clean'][j] = projets['DevisBudgetEUR_clean'][j]␣
↪+ '0'
    j += 1

projets.head()
```

[411]:

	Annee	NumeroVersion	FicheDeDemande	ReferenceID	NomDuProjet
0	2014	1	x	218486	Projet Girl Scout
1	2015	1	+	230240	Projet Cobra
2	2015	4	x	240101	Projet Bee - LOT 4
3	2016	3	x	294007	Projet Templer
4	2017	1	+	304283	Projet Alpha

	DateCreation	Statut	InterlocuteurMetier
0	2014-04-12 00:00:00	RAS	Joseph DICKENS
1	2015-05-04 00:00:00	Termine	Madeleine BROWN
2	2015-03-27 00:00:00	En attente de decision	Leonard JONES
3	2016-05-28 00:00:00	GO	Madeleine BROWN
4	2017-01-11 00:00:00	GO	Madeleine BROWN

	ChefDeProjet	DateDemande	DateReponse	TypeDemande
0	Jane SHARP	2014-01-01 00:00:00	2014-09-01 00:00:00	Catalogue
1	Gavin KING	2014-01-01 00:00:00	2017-06-10 00:00:00	Projet
2	Ian HEMMINGS	2014-05-20 00:00:00	2017-08-21 00:00:00	Evolution
3	David JACKSON	2014-06-24 00:00:00	2016-08-25 00:00:00	Projet
4	David JACKSON	2014-07-28 00:00:00	2017-02-24 00:00:00	Evolution

	TypeDevis	CauseReestimation	CodeApplicAtion	DateDebutTravaux
0	Reestime	Autre	A4701; A7843	41929
1	Initial	NaN	A3758; A3774	42917
2	Reestime	Autre	A4452; A5146	43021
3	Reestime	Autre	A4317; A8067	42675
4	Reestime	Ajout contributeur	A3774; A5876	42827

	DateFinTravaux	DateDebutHomologation	DevisBudgetJH	DevisBudgetEUR
0	2015-06-21 00:00:00	2015-08-28 00:00:00	1900	2,6 MEUR
1	2017-12-14 00:00:00	2018-01-28 00:00:00	2000	2,7 MEUR
2	2018-03-08 00:00:00	2018-04-05 00:00:00	1400	2 MEUR
3	2017-08-10 00:00:00	2017-10-01 00:00:00	2200	3 MEUR
4	2017-08-29 00:00:00	2017-11-19 00:00:00	1500	2,2 MEUR

```
   DevisBudgetJHEUR  DevisBudgetInfraEUR Appli1  Appli2 DevisBudgetEUR_clean
0           1235000            1365000.0  A4701   A7843              2600000
1           1300000            1400000.0  A3758   A3774              2700000
2            910000            1090000.0  A4452   A5146              2000000
3           1430000            1570000.0  A4317   A8067              3000000
4            975000            1225000.0  A3774   A5876              2200000
```

Création d'une colonne DevisBudgetJH_Rank Créez une nouvelle colonne `DevisBudgetJH_Rank` en utilisant la méthode `.rank()` de pandas appliquée à la colonne "DevisBudgetJHEUR".

[423]:
```
projets['DevisBudgetJH_Rank'] = projets['DevisBudgetJHEUR'].rank()

projets.head()
```

[423]:
```
   Annee  NumeroVersion FicheDeDemande  ReferenceID         NomDuProjet  \
0   2014              1              x       218486   Projet Girl Scout
1   2015              1              +       230240        Projet Cobra
2   2015              4              x       240101  Projet Bee - LOT 4
3   2016              3              x       294007      Projet Templer
4   2017              1              +       304283        Projet Alpha

          DateCreation                  Statut InterlocuteurMetier  \
0  2014-04-12 00:00:00                     RAS      Joseph DICKENS
1  2015-05-04 00:00:00                 Termine     Madeleine BROWN
2  2015-03-27 00:00:00  En attente de decision       Leonard JONES
3  2016-05-28 00:00:00                      GO     Madeleine BROWN
4  2017-01-11 00:00:00                      GO     Madeleine BROWN

    ChefDeProjet          DateDemande          DateReponse TypeDemande  \
0     Jane SHARP  2014-01-01 00:00:00  2014-09-01 00:00:00   Catalogue
1     Gavin KING  2014-01-01 00:00:00  2017-06-10 00:00:00      Projet
2   Ian HEMMINGS  2014-05-20 00:00:00  2017-08-21 00:00:00   Evolution
3  David JACKSON  2014-06-24 00:00:00  2016-08-25 00:00:00      Projet
4  David JACKSON  2014-07-28 00:00:00  2017-02-24 00:00:00   Evolution

  TypeDevis   CauseReestimation CodeApplicAtion  DateDebutTravaux  \
0  Reestime             Autre    A4701; A7843             41929
1   Initial               NaN    A3758; A3774             42917
2  Reestime             Autre    A4452; A5146             43021
3  Reestime             Autre    A4317; A8067             42675
4  Reestime  Ajout contributeur    A3774; A5876             42827

        DateFinTravaux DateDebutHomologation  DevisBudgetJH DevisBudgetEUR  \
0  2015-06-21 00:00:00   2015-08-28 00:00:00           1900       2,6 MEUR
1  2017-12-14 00:00:00   2018-01-28 00:00:00           2000       2,7 MEUR
2  2018-03-08 00:00:00   2018-04-05 00:00:00           1400         2 MEUR
```

```
3  2017-08-10 00:00:00   2017-10-01 00:00:00           2200         3 MEUR
4  2017-08-29 00:00:00   2017-11-19 00:00:00           1500       2,2 MEUR

   DevisBudgetJHEUR  DevisBudgetInfraEUR Appli1  Appli2 DevisBudgetEUR_clean  \
0           1235000            1365000.0  A4701   A7843               2600000
1           1300000            1400000.0  A3758   A3774               2700000
2            910000            1090000.0  A4452   A5146               2000000
3           1430000            1570000.0  A4317   A8067               3000000
4            975000            1225000.0  A3774   A5876               2200000

   DevisBudgetJH_Rank
0               128.5
1               137.0
2                90.0
3               154.0
4                98.5
```

Vérification des budgets Assurez-vous que DevisBudgetJHEUR + DevisBudgetInfraEUR = DevisBudgetEUR_Clean.

[506]:
```
somme = projets['DevisBudgetJHEUR'] + projets['DevisBudgetInfraEUR']

projets['DevisBudgetEUR_clean'] = projets['DevisBudgetEUR_clean'].astype(float)

#somme == projets['DevisBudgetEUR_clean']

j = 0

for i in range(len(somme)):
    if projets['DevisBudgetEUR_clean'][i] != somme[i] and np.
 ↪abs(projets['DevisBudgetEUR_clean'][i] - somme[i]) > 10**(-6):
            print("égalité non respecté à la ligne d'indice", i)
    else:
        j += 1

if j == len(somme):
    print("Ok on a bien projets['DevisBudgetJHEUR'] +␣
 ↪projets['DevisBudgetInfraEUR'] = projets['DevisBudgetEUR_clean']")

# on aurait pu verifier juste avec somme == projets['DevisBudgetEUR_clean'] mais␣
 ↪on aurait dû verfier
# qu'on ait bien True à chaque ligne
# Avec ce tableau qui n'est pas "trop" grand, utilisé une boucle permet de voir␣
 ↪de suite en sortie s'il y a ou non un probleme sur une des lignes
```

```
Ok on a bien projets['DevisBudgetJHEUR'] + projets['DevisBudgetInfraEUR'] =
projets['DevisBudgetEUR_clean']
```

2.2 Base des applications

[19]:
```
applications.head()
```

[19]:

	AppCode	Name	RiskLevel	LastResilienceTest	NombreUtilisateur2017	NombreUtilisateur2016
0	A6205	Yearin	HIGH	42795	9704	9740
1	A7527	Goodsilron	LOW	41477	6969	6938
2	A7194	Condax	MEDIUM	42572	1754	1716
3	A4701	Opentech	MEDIUM	41049	12692	12653
4	A1956	Golddex	HIGH	41647	7559	7594

Comptez le nombre de valeurs nulles dans le DataFrame `applications`

[510]:
```
print('Nombre de valeurs nulles :', applications.isnull().sum().sum())
```

```
Nombre de valeurs nulles : 0
```

Comptez le nombre d'AppCode dupliqués et le nombre d'AppCode uniques dans `applications`

[516]:
```
#dup = applications.pivot_table(index = ['AppCode'], aggfunc = 'size')

nb_duplique = len(applications['AppCode']) - applications['AppCode'].nunique()
nb_unique = applications['AppCode'].nunique()

print("Nombre d'AppCode dupliqués :", nb_duplique)
print("Nombre d'AppCode dupliqués :", nb_unique)
```

```
Nombre d'AppCode dupliqués : 0
Nombre d'AppCode dupliqués : 64
```

Affichez la fréquence d'apparition de chaque RiskLevel

[540]:
```
risk_level = applications.pivot_table(index = ['RiskLevel'], aggfunc = 'size')
risk_level
```

[540]:
```
RiskLevel
HIGH         13
LOW          10
MEDIUM       22
VERY HIGH     4
VERY LOW     15
dtype: int64
```

Ecrivez un script permettant de transformer LastResilienceTest en date

[543]:
```
applications['LastResilienceTest'] = pd.
 ↪to_datetime(applications['LastResilienceTest'], unit='D', origin='1899-12-30')
#applications['LastResilienceTest']

applications.head()
```

[543]:

	AppCode	Name	RiskLevel	LastResilienceTest	NombreUtilisateur2017	NombreUtilisateur2016
0	A6205	Yearin	HIGH	2017-03-01	9704	9740
1	A7527	Goodsilron	LOW	2013-07-22	6969	6938
2	A7194	Condax	MEDIUM	2016-07-21	1754	1716
3	A4701	Opentech	MEDIUM	2012-05-20	12692	12653
4	A1956	Golddex	HIGH	2014-01-08	7559	7594

Utilisez la fonction `describe` pour afficher des statistiques descriptives des 2 dernières colonnes i.e. NombreUtilisateur2017 & NombreUtilisateur2016

[544]:
```
applications.describe()
```

[544]:

	NombreUtilisateur2017	NombreUtilisateur2016
count	64.000000	64.000000
mean	6735.562500	6734.546875
std	3721.294018	3726.222215
min	166.000000	117.000000
25%	3295.750000	3262.750000
50%	6776.000000	6751.000000
75%	9917.000000	9894.750000
max	12692.000000	12653.000000

2.3 Base des personnes

[569]:
```
personnes.head()
```

[569]:

	Prenom	Nom	Mail	ID
0	Charles	Smith	charles.smith@tgp.com	A692817085
1	Madeleine	Chapman	madeleine.chapman@tgp.com	A185252110
2	Colin	King	colin.king@tgp.com	A769284797
3	Piers	Skinner	piers.skinner@tgp.com	A370950207
4	Gavin	Turner	gavin.turner@tgp.com	A234744045

```
                 Role  ExperienceValeur
0  Developpeur Junior                 1
1  Developpeur Junior                 1
2  Developpeur Junior                 4
3  Developpeur Junior                 1
4  Developpeur Junior                 0
```

Vérification des adresses mails Vérifiez que chaque adresse mail a bien le format suivant "xxx.xxx@tgp.com".

Il y a plusieurs manière de faire cela, par exemple : - Utiliser une expression régulière avec (i) `[a-z]` représentant n'importe quel caractère de l'alphabet, (ii) le signe + qui, placé derrière un caractère, signifie qu'il apparaît une ou plusieurs fois d'affilé, (iii) `\.` qui représente un point et enfin ^ et $ représentant respectivement le début et la fin d'une chaîne de caractères. - Vérifier avec une boucle que tous les caractères avant "@" sont des lettres et qu'il y a un unique point avec au moins une lettre avant et après celui-ci. Puis vérifier que "tgp.com" est présent après le signe "@".

[26]:
```
# Exemple d'utilisation des regex vérifier un pattern
# Ici - 1 ou plusieurs lettres, suivies de 1 ou plusieurs chiffres, suivies d'un␣
 ↪point

bool(re.search('^[a-z]+[0-9]+\.$', 'abc12.'))
```

[26]:
```
True
```

Quelles sont les lignes pour lesquelles l'adresse mail (colonne Mail) n'a pas le bon format ?

[574]:
```
personnes2 = personnes.copy() # nous utilisons une copie du tableau pour ne pas␣
 ↪avoir a reimporter le tableau si la modification est fausse
# neanmoins on aurait pu appliquer le code direct sur le tableau de depart
# on modifiera le tableau de depart a chaque fois qu'on obtiendra la reponse␣
 ↪souhaitee par des boucles puisque le tableau reste de taille raisonnable

pattern = re.compile(r"(^[a-zA-Z0-9_.+-]+\.[a-zA-Z0-9_.+-]+@tgp.com$)")

personnes2['isemail'] = personnes2['Mail'].apply(lambda x: True if pattern.
 ↪match(x) else False)
wrong_mail_df = personnes.loc[personnes2['isemail'] == False]

wrong_mail_df
```

[574]:
```
     Prenom                    Nom                  Mail          ID  \
44   Joshua    Skinner                joshua.skinner@tgp  A431854713
107   Isaac    Chapman              isaac.chapmantgp.com  A627677732
158    Jane    Randall                      jane.randall  A761729136
249    Ryan     Watson                      ryan@tgp.com  A494768410
304  Sophie     Wilson              sophie.wilsontgp.com  A197223116
```

```
313    Phil  Mackenzie                  phil.mackenzie@com  A582718828

                   Role  ExperienceValeur
44   Developpeur Junior                 3
107  Developpeur Junior                 1
158  Developpeur Junior                 3
249  Developpeur Senior                 3
304      Chef de projet                16
313                 COO                39
```

Modification des adresses mails erronées Proposez un script permettant de modifier les adresses mails ayant un format erroné. Pour cela, on remplacera les valeurs erronées par `prenom.nom@tgp.com` et cela en minuscule.

Attention : dans les colonnes "Nom" et "Prenom", il pourrait y avoir des espaces avant ou après le nom… Cela pourrait causer des problèmes. Il faudra utiliser la méthode `.strip()` pour supprimer ces espaces inutiles.

[594]:
```
wrong_mail_df['Prenom'] = wrong_mail_df['Prenom'].str.strip()
wrong_mail_df['Nom'] = wrong_mail_df['Nom'].str.strip()

wrong_mail_df['Full_Name'] = np.where(wrong_mail_df[['Prenom', 'Nom']].eq('').
 ↪any(axis=1),
                           wrong_mail_df['ID'],
                           wrong_mail_df[['Prenom', 'Nom']].apply(' '.join,␣
 ↪axis=1))

wrong_mail_df['Mail'] = wrong_mail_df.Full_Name.str.replace('\s+', '.') + '@tgp.
 ↪com'

wrong_mail_df['Mail'] = wrong_mail_df['Mail'].str.lower()

wrong_mail_df

# on pourrait appliquer cela sur le tableau entier pour changer tous les mails,␣
 ↪y compris ceux ayant le bon format
# puisque dans la question precedente on n'a verifié que le format xxx.xxx@tgp.
 ↪com
# sans preciser que xxx ne doit contenir que des lettres minuscules

for i in wrong_mail_df.index:
    personnes['Mail'][i] = wrong_mail_df['Mail'][i]
```

On peut d'ailleurs vérifier maintenant que l'ensemble des adresses mail ont le bon format !

[596]:
```
pattern = re.compile(r"(^[a-zA-Z0-9_.+-]+\.[a-zA-Z0-9_.+-]+@tgp.com$)")
```

```
personnes2['isemail'] = personnes2['Mail'].apply(lambda x: True if pattern.
 ↪match(x) else False)
wrong_mail_df2 = personnes.loc[personnes2['isemail'] == False]

wrong_mail_df2

# le tableau est vide donc ils ont tous le format xxx.xxx@tgp.com
```

[596]:
```
Empty DataFrame
Columns: [Prenom, Nom, Mail, ID, Role, ExperienceValeur]
Index: []
```

Création d'un clé de jointure Nous aurons besoin d'une clé de correspondance pour réaliser une jointure entre les DataFrame `personneset` `projets`.

En effet, dans la colonne "ChefDeProjet" de la base `projet` le format est `Prenom NOM`.

Créez une nouvelle colonne "Cle" concaténant, pour chaque ligne, la valeur de la colonne "Prenom", suivie d'un espace et enfin de la valeur de la colonne "Nom" en majuscule.

Attention : dans les colonnes "Nom" et "Prenom", il pourrait y avoir des espaces avant ou après le nom... Cela pourrait causer des problèmes. Il faudra utiliser la méthode `.strip()` pour supprimer ces espaces inutiles.

[614]:
```
personnes['Cle'] = personnes['Prenom'] + ' ' + personnes['Nom'].str.upper()

personnes.head()
```

[614]:

	Prenom	Nom	Mail	ID	\
0	Charles	Smith	charles.smith@tgp.com	A692817085	
1	Madeleine	Chapman	madeleine.chapman@tgp.com	A185252110	
2	Colin	King	colin.king@tgp.com	A769284797	
3	Piers	Skinner	piers.skinner@tgp.com	A370950207	
4	Gavin	Turner	gavin.turner@tgp.com	A234744045	

	Role	ExperienceValeur	Cle
0	Developpeur Junior	1	Charles SMITH
1	Developpeur Junior	1	Madeleine CHAPMAN
2	Developpeur Junior	4	Colin KING
3	Developpeur Junior	1	Piers SKINNER
4	Developpeur Junior	0	Gavin TURNER

2.4 Base des logs

[623]:
```
logs.head()
```

[623]:

	ProjectKey	TaskAssignee	TaskKey	DateFInalLog	MDLogged
0	218486	A810043709	M1	29/01/2015	1

```
1       218486    A810043709       M1    11/01/2015          1
2       218486    A810043709       M1    29/01/2015          1
3       218486    A810043709       M1    04/03/2015          1
4       218486    A722019848       M2    03/05/2015          1
```

Comptez le nombre de valeurs nulles dans la base

[624]:
```
print('Nombre de valeurs nulles :',logs.isnull().sum().sum())
```

```
Nombre de valeurs nulles : 0
```

Transformez la colonne DateFInalLog en vraie date (`datetime`)

[632]:
```
logs['DateFInalLog'] = pd.to_datetime(logs['DateFInalLog'])
#logs['DateFInalLog']

logs.head()
```

[632]:
```
   ProjectKey TaskAssignee TaskKey DateFInalLog  MDLogged
0       218486    A810043709       M1   2015-01-29         1
1       218486    A810043709       M1   2015-11-01         1
2       218486    A810043709       M1   2015-01-29         1
3       218486    A810043709       M1   2015-04-03         1
4       218486    A722019848       M2   2015-03-05         1
```

Comptez le nombre de valeurs unique dans la colonne MDLogged

[643]:
```
#pd.unique(logs['MDLogged'])[0]

logs.pivot_table(index = ['MDLogged'], aggfunc = 'size')
```

[643]:
```
MDLogged
1    347895
dtype: int64
```

Cette colonne est-elle réellement utile ? Si oui, gardez-la, sinon, supprimez-la.

[654]:
```
# je ne pense pas qu'elle soit utile puisqu'identique a chaque ligne

logs = logs.drop(['MDLogged'],axis = 1)
logs
```

[654]:
```
        ProjectKey TaskAssignee TaskKey DateFInalLog
0           218486   A810043709      M1   2015-01-29
1           218486   A810043709      M1   2015-11-01
2           218486   A810043709      M1   2015-01-29
3           218486   A810043709      M1   2015-04-03
4           218486   A722019848      M2   2015-03-05
...            ...          ...     ...          ...
347890      390064   A382829264    M154   2017-06-19
```

```
347891      390064   A382829264    M154   2017-07-25
347892      390064   A382829264    M154   2017-05-18
347893      390064   A382829264    M154   2017-05-29
347894      390064   A382829264    M154   2017-07-16

[347895 rows x 4 columns]
```

2.5 Base des tâches

[649]:
```
taches.head()
```

[649]:
```
   ProjectKey TaskAssignee  Priority TaskKey  MDPlanned  MDUpdatedPlanned  \
0      218486   A810043709  VERY LOW      M1          5                 4
1      218486   A722019848       LOW      M2          8                12
2      218486    A69888201    MEDIUM      M3          9                 7
3      218486   A434385931    MEDIUM      M4          2                 4
4      218486   A331360422    MEDIUM      M5          4                 2

           TaskType   Location
0           CODING  Bangalore
1  STRUCTURE CHANGE  Bangalore
2              BUG      Paris
3  STRUCTURE CHANGE  Bangalore
4           CODING  Bangalore
```

Comptez le nombre de valeurs nulles dans le DataFrame `taches`

[650]:
```
print('Nombre de valeurs nulles :',taches.isnull().sum().sum())
```

```
Nombre de valeurs nulles : 0
```

Nous nous arrêterons là pour la préparation de ce dernier DataFrame.

3 Sauvegarde des jeux de données

Sauvegardez chacun des DataFrames modifiés dans un dossier “03 - Data prep” que vous aurez préalablement créé.

Vous pouvez les enregistrer au format Excel ou CSV. Une bonne méthode, pour éviter toute confusion avec les fichiers de départ et de nommer un peu différemment ces nouveaux fichiers. Par exemple, vous pourriez les appeler "_prep.csv" (en remplaçant bien sûr par le nom approprié).

[651]:
```
out_path = './03 - Data prep/projets_prep.xlsx'
writer = pd.ExcelWriter(out_path , engine='xlsxwriter')
projets.to_excel(writer)
writer.save()

out_path1 = './03 - Data prep/applications_prep.xlsx'
writer1 = pd.ExcelWriter(out_path1 , engine='xlsxwriter')
```

```
applications.to_excel(writer1)
writer1.save()

out_path2 = './03 - Data prep/personnes_prep.xlsx'
writer2 = pd.ExcelWriter(out_path2 , engine='xlsxwriter')
personnes.to_excel(writer2)
writer2.save()

out_path3 = './03 - Data prep/logs_prep.xlsx'
writer3 = pd.ExcelWriter(out_path3 , engine='xlsxwriter')
logs.to_excel(writer3)
writer3.save()

out_path4 = './03 - Data prep/taches_prep.xlsx'
writer4 = pd.ExcelWriter(out_path4 , engine='xlsxwriter')
taches.to_excel(writer4)
writer4.save()
```

3.1 Conclusion

Nous avons abordé ici différentes méthodes de préparation des données. Cette étape est capitale car des données de mauvaise qualité empêchent de réaliser certaines analyses et/ou conduisent à des analyses fausses.

Il est donc nécessaire (i) d'adresser les problèmes de qualité de la donnée dans toutes les bases de données que vous pourrez reçevoir à l'avenir et (ii) tenter au maximum de les corriger (mais il faut à minima en avoir conscience).

Les méthodes vues ici ne sont bien sûr pas exhaustives. Soyez créatifs, posez-vous des questions et utilisez votre esprit critique !

Pour vous aider, voici des indicateurs usuels de la qualité de données : - l'exactitude : les données reflètent-elles l'activité / le métier ? Elle se mesure en comptant le taux de valeurs incorrectes dans les données ; - la complétude : toutes les données nécessaires à l'observation de l'activité métier sont-elles présentes ? Elle se mesure en comptant le nombre de valeurs manquantes dans la base ; - la conformité : toutes les valeurs de l'activité respectent-elles les règles métier spécifiées ? ; - l'intégrité : les données sont-elles cohérentes les unes par rapport aux autres ? ; - la consistance : les données renferment-elles des doublons ? ; - la disponibilité : les données sont-elles disponibles dans des délais raisonnables ?

[ ]: