

seance5_cube_multidimensionnel_enonce

July 2, 2023

1 Cube multidimensionnel - énoncé

Ce notebook aborde différentes solutions pour traiter les données qu'on représente plus volontiers en plusieurs dimensions. Le mot-clé associé est [OLAP](#) ou cube OLAP. [Mondrian](#) est une solution open source, [cubes](#) est écrit en python. [Kylin](#) propose ce service sur des données stockées sur Hadoop. L'objectif est ici de découvrir pas d'explorer ces solutions.

```
[1]: %matplotlib inline
import matplotlib.pyplot as plt
plt.style.use('ggplot')
import pyensae
from pyquickhelper.helpgen import NbImage
from jyquickhelper import add_notebook_menu
add_notebook_menu()
```

Populating the interactive namespace from numpy and matplotlib

```
[1]: <IPython.core.display.HTML object>
```

1.0.1 Représentation

Le module [pandas](#) manipule des tables et c'est la façon la plus commune de représenter les données. Lorsque les données sont multidimensionnelles, on distingue les coordonnées des valeurs :

```
[2]: NbImage("cube1.png")
```

```
[2]:
```

Profession	Age	Année	Espérance de vie	Population
Actuaire	30	1980	x1	x2
Enseignant	35	1990	x3	x4

Dans cet exemple, il y a :

- 3 coordonnées : Age, Profession, Année
- 2 valeurs : Espérance de vie, Population

On peut représenter les données également comme ceci :

```
[3]: NbImage("cube2.png")
```

```
[3]:
```

Profession	Age	Année	Nom_Valeur	Valeur
Actuaire	30	1980	Espérance de vie	x1
Actuaire	30	1980	Population	x2
Enseignant	35	1990	Espérance de vie	x3
Enseignant	35	1990	Population	x4

C'est assez simple. Prenons un exemple : [table de mortalité de 1960 à 2010](#) qu'on récupère à l'aide de la fonction `table_mortalite_euro_stat`. C'est assez long (4-5 minutes) sur l'ensemble des données car elles doivent être prétraitées (voir la documentation de la fonction). Pour écouter, il faut utiliser le paramètre `stop_at`.

```
[4]: from actuariat_python.data import table_mortalite_euro_stat
table_mortalite_euro_stat()
```

```
[4]: 'mortalite.txt'
```

```
[5]: import os
os.stat("mortalite.txt")
```

```
[5]: os.stat_result(st_mode=33206, st_ino=73183493945221205, st_dev=2797837379,
st_nlink=1, st_uid=0, st_gid=0, st_size=104871002, st_atime=1445699900,
st_mtime=1445699915, st_ctime=1445699900)
```

```
[6]: import pandas
df = pandas.read_csv("mortalite.txt", sep="\t", encoding="utf8", low_memory=False)
df.head()
```

```
[6]:   annee  valeur  age  age_num  indicateur  genre  pays
0  2009  0.00080  Y01         1  DEATHRATE     F    AM
1  2008  0.00067  Y01         1  DEATHRATE     F    AM
2  2007  0.00052  Y01         1  DEATHRATE     F    AM
3  2006  0.00123  Y01         1  DEATHRATE     F    AM
4  2013  0.00016  Y01         1  DEATHRATE     F    AT
```

1.0.2 Cubes de données avec xarray

création Cette représentation sous forme de table n'est pas toujours très lisible. Les informations sont souvent répétées et les données sont vraiment multidimensionnelles. Le module `xarray` propose de distinguer les coordonnées des valeurs pour proposer des manipulations plus intuitives. Le module propose un DataFrame multidimensionnelle `DataSet`.

```
[7]: from actuariat_python.data import table_mortalite_euro_stat
table_mortalite_euro_stat()
```

```
import pandas
df = pandas.read_csv("mortalite.txt", sep="\t", encoding="utf8", low_memory=False)
df.columns
```

```
[7]: Index(['annee', 'valeur', 'age', 'age_num', 'indicateur', 'genre', 'pays'],
dtype='object')
```

Dans ce cas-ci, pour reprendre la terminologie du module `xarray`, nous avons :

- les **dimensions** : annee, age_num, pays, genre
- les **valeurs** : une valeur par indicateur

On peut passer d'un `DataFrame` à un `DataSet` de la façon suivante :

- les colonnes indexées représentent les dimensions
- les colonnes non indexées sont les valeurs

On garde supprime les colonnes qui ne nous intéressent pas et les valeurs manquantes :

```
[8]: df2 = df[["annee", "age_num", "indicateur", "pays", "genre", "valeur"]].dropna().
      ↪reset_index(drop=True)
df.columns, df2.columns
```

```
[8]: (Index(['annee', 'valeur', 'age', 'age_num', 'indicateur', 'genre', 'pays'],
dtype='object'),
      Index(['annee', 'age_num', 'indicateur', 'pays', 'genre', 'valeur'],
dtype='object'))
```

```
[9]: df2.head()
```

```
[9]:   annee  age_num  indicateur  pays  genre  valeur
0   2009         1  DEATHRATE   AM     F  0.00080
1   2008         1  DEATHRATE   AM     F  0.00067
2   2007         1  DEATHRATE   AM     F  0.00052
3   2006         1  DEATHRATE   AM     F  0.00123
4   2013         1  DEATHRATE   AT     F  0.00016
```

```
[10]: df2["indicateur"] = df2["indicateur"].astype(str)
df2["genre"] = df2["genre"].astype(str)
df2["pays"] = df2["pays"].astype(str)
```

```
[11]: df2.dtypes
```

```
[11]: annee          int64
age_num         float64
indicateur       object
pays             object
genre            object
valeur          float64
dtype: object
```

L'opération complexe consiste à faire passer les valeurs de la colonne *indicateur* en tant que colonnes. C'est l'objet de la méthode `pivot_table` :

```
[12]: piv = df2.pivot_table(index=["annee", "age_num", "pays", "genre"],
                             columns=["indicateur"],
                             values="valeur")
piv.head()
```

```
[12]: indiqueur          DEATHRATE  LIFEXP  PROBDEATH  PROBSURV  PYLIVED  \
annee age_num pays genre
1960  1      BE  F      0.00159   73.7    0.00159    0.99841    97316
      M      0.00207   68.2    0.00207    0.99793    96420
      T      0.00184   70.9    0.00184    0.99816    96856
      BG  F      0.00652   73.2    0.00650    0.99350    95502
      M      0.00644   70.0    0.00642    0.99358    94801

indicateur          SURVIVORS  TOTPYLIVED
annee age_num pays genre
1960  1      BE  F          97393    7179465
      M          96520    6580601
      T          96945    6874529
      BG  F          95813    7017023
      M          95107    6653130
```

```
[13]: piv.dtypes
```

```
[13]: indiqueur
DEATHRATE      float64
LIFEXP         float64
PROBDEATH      float64
PROBSURV       float64
PYLIVED        float64
SURVIVORS      float64
TOTPYLIVED     float64
dtype: object
```

Les données sont maintenant prêtes à passer sous *xarray* :

```
[14]: import xarray
ds = xarray.Dataset.from_dataframe(piv)
ds
```

```
[14]: <xarray.Dataset>
Dimensions:      (age_num: 84, annee: 54, genre: 3, pays: 54)
Coordinates:
  * annee        (annee) int64 1960 1961 1962 1963 1964 1965 1966 1967 1968 ...
  * age_num      (age_num) float64 1.0 2.0 3.0 4.0 5.0 6.0 7.0 8.0 9.0 10.0 ...
  * pays        (pays) object 'AM' 'AT' 'AZ' 'BE' 'BG' 'BY' 'CH' 'CY' 'CZ' ...
  * genre       (genre) object 'F' 'M' 'T'
Data variables:
  DEATHRATE     (annee, age_num, pays, genre) float64 nan nan nan nan nan ...
  LIFEXP        (annee, age_num, pays, genre) float64 nan nan nan nan nan ...
  PROBDEATH     (annee, age_num, pays, genre) float64 nan nan nan nan nan ...
  PROBSURV      (annee, age_num, pays, genre) float64 nan nan nan nan nan ...
  PYLIVED       (annee, age_num, pays, genre) float64 nan nan nan nan nan ...
  SURVIVORS     (annee, age_num, pays, genre) float64 nan nan nan nan nan ...
  TOTPYLIVED    (annee, age_num, pays, genre) float64 nan nan nan nan nan ...
```

sélection Il est facile ensuite d'extraire les données d'un pays avec la méthode `sel` :

```
[15]: ds.sel(pays=["FR"])
```

```
[15]: <xarray.Dataset>
Dimensions:      (age_num: 84, annee: 54, genre: 3, pays: 1)
Coordinates:
  * annee        (annee) int64 1960 1961 1962 1963 1964 1965 1966 1967 1968 ...
  * age_num      (age_num) float64 1.0 2.0 3.0 4.0 5.0 6.0 7.0 8.0 9.0 10.0 ...
  * pays         (pays) object 'FR'
  * genre        (genre) object 'F' 'M' 'T'
Data variables:
  DEATHRATE     (annee, age_num, pays, genre) float64 nan nan nan nan nan ...
  LIFEXP        (annee, age_num, pays, genre) float64 nan nan nan nan nan ...
  PROBDEATH     (annee, age_num, pays, genre) float64 nan nan nan nan nan ...
  PROBSURV     (annee, age_num, pays, genre) float64 nan nan nan nan nan ...
  PYLIVED      (annee, age_num, pays, genre) float64 nan nan nan nan nan ...
  SURVIVORS    (annee, age_num, pays, genre) float64 nan nan nan nan nan ...
  TOTPYLIVED   (annee, age_num, pays, genre) float64 nan nan nan nan nan ...
```

Ou de plusieurs pays :

```
[16]: ds.sel(pays=["FR", "BE"])
```

```
[16]: <xarray.Dataset>
Dimensions:      (age_num: 84, annee: 54, genre: 3, pays: 2)
Coordinates:
  * annee        (annee) int64 1960 1961 1962 1963 1964 1965 1966 1967 1968 ...
  * age_num      (age_num) float64 1.0 2.0 3.0 4.0 5.0 6.0 7.0 8.0 9.0 10.0 ...
  * pays         (pays) object 'FR' 'BE'
  * genre        (genre) object 'F' 'M' 'T'
Data variables:
  DEATHRATE     (annee, age_num, pays, genre) float64 nan nan nan 0.00159 ...
  LIFEXP        (annee, age_num, pays, genre) float64 nan nan nan 73.7 68.2 ...
  PROBDEATH     (annee, age_num, pays, genre) float64 nan nan nan 0.00159 ...
  PROBSURV     (annee, age_num, pays, genre) float64 nan nan nan 0.9984 ...
  PYLIVED      (annee, age_num, pays, genre) float64 nan nan nan 9.732e+04 ...
  SURVIVORS    (annee, age_num, pays, genre) float64 nan nan nan 9.739e+04 ...
  TOTPYLIVED   (annee, age_num, pays, genre) float64 nan nan nan 7.179e+06 ...
```

Ou plusieurs dimensions :

```
[17]: ds.sel(pays="FR", annee=2000)
```

```
[17]: <xarray.Dataset>
Dimensions:      (age_num: 84, genre: 3)
Coordinates:
  annee         int64 2000
  * age_num     (age_num) float64 1.0 2.0 3.0 4.0 5.0 6.0 7.0 8.0 9.0 10.0 ...
  pays          object 'FR'
  * genre       (genre) object 'F' 'M' 'T'
Data variables:
  DEATHRATE     (age_num, genre) float64 0.00043 0.00046 0.00044 0.00021 ...
  LIFEXP        (age_num, genre) float64 82.3 74.7 78.5 81.3 73.7 77.6 80.3 ...
  PROBDEATH     (age_num, genre) float64 0.00043 0.00046 0.00044 0.00021 ...
  PROBSURV     (age_num, genre) float64 0.9996 0.9995 0.9996 0.9998 0.9997 ...
```

```

PYLIVED      (age_num, genre) float64 9.957e+04 9.944e+04 9.951e+04 ...
SURVIVORS    (age_num, genre) float64 9.959e+04 9.947e+04 9.953e+04 ...
TOTPYLIVED   (age_num, genre) float64 8.196e+06 7.432e+06 7.817e+06 ...

```

Pour accéder à la série LIFEXP pour les hommes, les années 2000 et 2010, le pays FR, on fait la différence, puis on la récupère sous forme de DataFrame :

```
[18]: (ds.sel(pays="FR", annee=2010, genre="T")["LIFEXP"] -
       ds.sel(pays="FR", annee=2000, genre="T")["LIFEXP"]).to_dataframe().head()
```

```
[18]:      LIFEXP genre pays
age_num
1         2.6     T   FR
2         2.6     T   FR
3         2.6     T   FR
4         2.6     T   FR
5         2.6     T   FR
```

On a gagné presque deux ans et demi d'espérance de vie à la naissance en 10 ans.

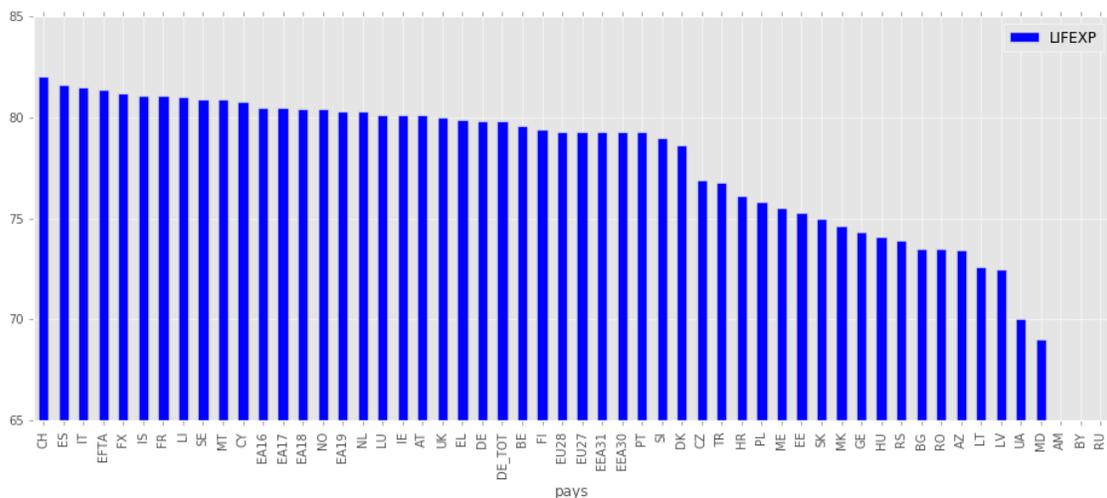
```
[19]: (ds.sel(pays="FR", annee=2010, genre=["F", "M"])["LIFEXP"] -
       ds.sel(pays="UK", annee=2010, genre=["F", "M"])["LIFEXP"]).to_dataframe().head()
```

```
[19]:      LIFEXP annee
age_num genre
1         F         2.6  2010
         M        -0.3  2010
2         F         2.7  2010
         M        -0.4  2010
3         F         2.7  2010
```

Quelques graphes

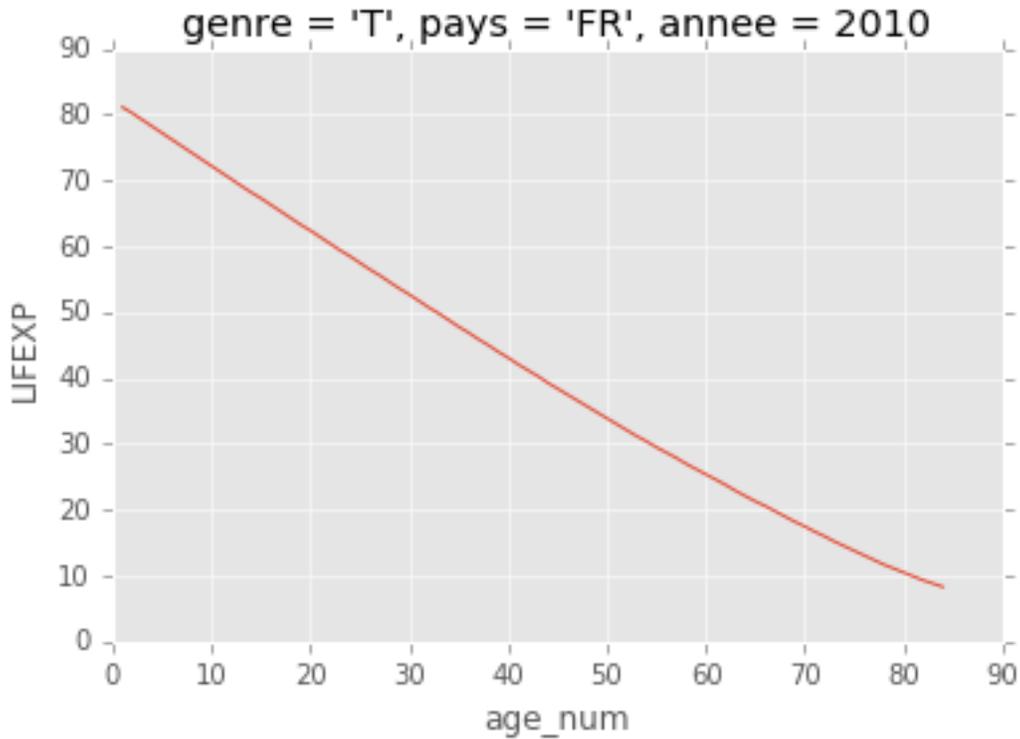
```
[20]: ds.sel(annee=2010, age_num=1, genre="T")["LIFEXP"].to_dataframe() \
       .sort_values("LIFEXP", ascending=False) \
       .plot(y="LIFEXP", kind="bar", figsize=(16,6), ylim=[65,85])
```

```
[20]: <matplotlib.axes._subplots.AxesSubplot at 0x1bf22320>
```



```
[21]: ds.sel(annee=2010,genre="T",pays="FR")["LIFEXP"].plot()
```

```
[21]: [ <matplotlib.lines.Line2D at 0x1539ca58 > ]
```



1.0.3 Exercice 1 : que font les lignes suivantes ?

On pourra s'aider des pages :

- [align nad reindex](#)
- [transforming datasets](#)

```
[22]: ds.assign(LIFEEXP_add = ds.LIFEEXP-1)
```

```
[22]: <xarray.Dataset>
```

```
Dimensions: (age_num: 84, annee: 54, genre: 3, pays: 54)
```

```
Coordinates:
```

```
* annee      (annee) int64 1960 1961 1962 1963 1964 1965 1966 1967 1968 ...
* age_num    (age_num) float64 1.0 2.0 3.0 4.0 5.0 6.0 7.0 8.0 9.0 10.0 ...
* pays       (pays) object 'AM' 'AT' 'AZ' 'BE' 'BG' 'BY' 'CH' 'CY' 'CZ' ...
* genre      (genre) object 'F' 'M' 'T'
```

```
Data variables:
```

```
DEATHRATE    (annee, age_num, pays, genre) float64 nan nan nan nan nan ...
LIFEEXP      (annee, age_num, pays, genre) float64 nan nan nan nan nan ...
```

```

PROBDEATH (annee, age_num, pays, genre) float64 nan nan nan nan nan ...
PROBSURV (annee, age_num, pays, genre) float64 nan nan nan nan nan ...
PYLIVED (annee, age_num, pays, genre) float64 nan nan nan nan nan ...
SURVIVORS (annee, age_num, pays, genre) float64 nan nan nan nan nan ...
TOTPYLIVED (annee, age_num, pays, genre) float64 nan nan nan nan nan ...
LIFEEXP_add (annee, age_num, pays, genre) float64 nan nan nan nan nan ...

```

```
[23]: meanp = ds.mean(dim="pays")
      ds1, ds2 = xarray.align(ds, meanp, join='outer')
```

```
[24]: joined = ds1.assign(meanp = ds2["LIFEEXP"])
```

```
[25]: joined.to_dataframe().head()
```

```
[25]:
```

				DEATHRATE	LIFEEXP	PROBDEATH	PROBSURV	PYLIVED	\
age_num	annee	genre	pays						
1	1960	F	AM	NaN	NaN	NaN	NaN	NaN	
			AT	NaN	NaN	NaN	NaN	NaN	
			AZ	NaN	NaN	NaN	NaN	NaN	
			BE	0.00159	73.7	0.00159	0.99841	97316	
			BG	0.00652	73.2	0.00650	0.99350	95502	

					SURVIVORS	TOTPYLIVED	meanp
age_num	annee	genre	pays				
1	1960	F	AM	NaN	NaN	73.52	
			AT	NaN	NaN	73.52	
			AZ	NaN	NaN	73.52	
			BE	97393	7179465	73.52	
			BG	95813	7017023	73.52	

1.0.4 Lire, écrire des datasets

Le module `xarray` s'appuie sur le module `netCDF4` qui lui-même est un `wrapper` python de la librairie `netCDF-c`. Celle-ci est spécialisée dans la lecture et l'écriture de données scientifiques. Concrètement, ce n'est pas `xarray` qui s'en occupe mais `netCDF4`. Cela explique la syntaxe décrite par [Serialization and IO](#) :

```
[26]: ds.data_vars
```

```
[26]: Data variables:
      DEATHRATE (annee, age_num, pays, genre) float64 nan nan nan nan nan ...
      LIFEEXP (annee, age_num, pays, genre) float64 nan nan nan nan nan ...
      PROBDEATH (annee, age_num, pays, genre) float64 nan nan nan nan nan ...
      PROBSURV (annee, age_num, pays, genre) float64 nan nan nan nan nan ...
      PYLIVED (annee, age_num, pays, genre) float64 nan nan nan nan nan ...
      SURVIVORS (annee, age_num, pays, genre) float64 nan nan nan nan nan ...
      TOTPYLIVED (annee, age_num, pays, genre) float64 nan nan nan nan nan ...
```

```
[27]: try:
      ds.to_netcdf('mortalite.nc')
except ValueError as e:
    # it breaks with pandas 0.17
    # xarray has to be updated
    print("l'écriture a échoué")
    pass
```

l'écriture a échoué

C'est un format binaire plus efficace que le format texte :

```
[28]: import os
      if os.path.exists("mortalite.nc"):
          os.stat('mortalite.nc').st_size, os.stat('mortalite.txt').st_size
```

On relit :

```
[29]: if os.path.exists("mortalite.nc"):
      ds_lu = xarray.open_dataset('mortalite.nc')
      ds_lu
```

Le module `xarray` propose également de lire des données de plusieurs fichiers pour ne former qu'un seul dataset (voir [Combining multiple files](#)) :

```
[30]: pays = list(_.values for _ in ds["pays"])
      pays[:5]
```

```
[30]: ['AM', 'AT', 'AZ', 'BE', 'BG']
```

```
[31]: for p in pays[:5]:
      print("enregistre", p)
      d = ds.sel(pays=[p])
      try:
          d.to_netcdf("mortalite_pays_%s.nc" % p)
      except ValueError:
          print("l'écriture a échoué pour", p)
```

```
enregistre AM
l'écriture a échoué pour AM
enregistre AT
l'écriture a échoué pour AT
enregistre AZ
l'écriture a échoué pour AZ
enregistre BE
l'écriture a échoué pour BE
enregistre BG
l'écriture a échoué pour BG
```

On relit :

```
[32]: import os
      if os.path.exists("mortalite_pays_AM.nc"):
          ds_lu2 = xarray.open_mfdataset('mortalite_pays*.nc')
          ds_lu2
```

A quoi ça sert ?

Lorsqu'on travaille avec des gros fichiers de données, on cherche à retarder le plus possible l'exécution d'un calcul, on manipule les données sans les charger en mémoire. On appelle ceci [évaluation paresseuse](#) ou [lazy evaluation](#) en anglais. `xarray` et `dask` permettent de faire cela (voir [Using dask with xarray](#)). La logique qu'on suit est alors assez proche de la [programmation fonctionnelle](#).

```
[33]:
```