



Module 3 - Task 1

## DATA READING



### EN ESTE MÓDULO VAS A NECESITAR...

#### Software:

- Jupyter Notebook - <https://jupyter.org/install>

#### Datos:

- Módulo 3: <http://geonode.mygeoproject.eu/documents/86>

### EN ESTE MÓDULO TIENES QUE...

- Sube una de las databases resultado de la limpieza de datos a GEONODE
- Módulo 3 Exam (5 preguntas, 4 intentos).

### Lectura de datos

#### i. Descripción de los datos a manejar

Vamos a practicar la descarga de conjuntos de datos en un *Jupyter Notebook* con la librería *Pandas* de un archivo Excel con información acerca de producción de granjas en Europa.

Archivo local: *datos/animalEurostatNuts2.xlsx*

#### ii. Lectura de archivos de datos

### PARA APRENDER MÁS....

Los formatos de datos soportados por las librerías *Pandas* y como leerlos se describen en: [https://pandas.pydata.org/pandas-docs/stable/user\\_guide/io.html](https://pandas.pydata.org/pandas-docs/stable/user_guide/io.html)

Format	Read	Write
csv	pd.read_csv()	pac.to_csv()
json	pd.read_json()	pac.to_json()
excel	pd.read_excel()	pac.to_excel()
hdf	pd.read_hdf()	pac.to_hdf()
sql	pd.read_sql()	pac.to_sql()
...	...	...

Cada operación de lectura de un archivo diferente tiene parámetros distintos para ajustar el proceso.





Module 3 – Task 1

## DATA READING



### a. Lectura de archivos de Excel

Usamos `pandas.read_excel()` para leer el archivo Excel y almacenar los datos en un marco de datos (*dataframe*).

Los parámetros más relevantes son:

*io* = la dirección (directorio) del archivo

*sheet\_name* = la hoja que se va a leer

### PARA APRENDER MÁS...

Hay muchos parámetros para tener en cuenta

[https://pandas.pydata.org/pandas-docs/stable/reference/api/pandas.read\\_excel.html](https://pandas.pydata.org/pandas-docs/stable/reference/api/pandas.read_excel.html)

La carga de la información se puede hacer desde un archivo local o desde una archivo de una web.

Input [1]:

```
import pandas as pd
import numpy as np
file = 'datos/animalEurostatNuts2.xlsx'
data = pd.read_excel(file, sheet_name='Data', )
print("Done")
```

Output [1]:

Done

### b. Visualización básica de los datos

Podemos visualizar las primeras y últimas filas de la table para comprobar que se han cargado correctamente.

Input [2]:

```
data.head(10)
```

Output [2]:





# Module 3 - Task 1

## DATA READING



Animal populations by NUTS 2 regions [agr_r_animal]	Unnamed: 1	Unnamed: 2	Unnamed: 3	Unnamed: 4	Unnamed: 5	Unnamed: 6	Unnamed: 7	Unnamed: 8	Unnamed: 9	...	Unnamed: 49	Unnamed: 50	Unnamed: 51	
0	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	
1	Last update	2020-01-28 10:00:49	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	
2	Extracted on	2020-02-02 22:09:53.978000	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	
3	Source of data	Eurostat	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	
4	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	
5	ANIMALS	Live bovine animals	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	
6	UNIT	Thousand heads (animals)	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	
7	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	
8	GEO/TIME	1991	Flags and footnotes	1992	Flags and footnotes	1993	Flags and footnotes	1994	Flags and footnotes	1995	...	2015	Flags and footnotes	2016
9	European Union (EU6-1958, EU9-1973, EU10-1981,...	:	NaN	:	NaN	:	NaN	:	NaN	:	...	:	NaN	

10 rows x 59 columns

```
Input [3]:
data.tail(14)
```

Output [3]:

Animal populations by NUTS 2 regions [agr_r_animal]	Unnamed: 1	Unnamed: 2	Unnamed: 3	Unnamed: 4	Unnamed: 5	Unnamed: 6	Unnamed: 7	Unnamed: 8	Unnamed: 9	...	Unnamed: 49	Unnamed: 50	Unnamed: 51	
545	Bosnia and Herzegovina	:	NaN	:	NaN	:	NaN	:	NaN	:	...	455	e	455
546	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	
547	Available flags:	NaN	NaN	NaN	Special value:	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	
548	b	break in time series	NaN	NaN	:	not available	NaN	NaN	NaN	NaN	NaN	NaN	NaN	
549	c	confidential	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	
550	d	definition differs, see metadata	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	
551	e	estimated	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	
552	f	forecast	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	
553	n	not significant	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	
554	p	provisional	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	
555	r	revised	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	
556	s	Eurostat estimate	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	
557	u	low reliability	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	
558	z	not applicable	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	NaN	

14 rows x 59 columns



Module 3 - Task 1

# DATA READING



c. Ajustes y parámetros de los procesos de carga

Podemos ver que las primeras 9 filas y las últimas 13 no contienen datos válidos, son filas de metadatos de la tabla.

Estas filas deberían ser ignoradas cuando se lee la tabla. La primera fila para leer debe contener los encabezados de la columna.

Además, la primera columna es descriptiva de la información de cada fila.

Input [4]:

```
data = pd.read_excel(file, sheet_name='Data', skiprows=9, skipfooter=13, index_col=0)
print("Done")
```

Output [4]:

Done

Input [5]:

```
data.head(2)
```

Output [5]:

	1991	Flags and footnotes	1992	Flags and footnotes.1	1993	Flags and footnotes.2	1994	Flags and footnotes.3	1995	Flags and footnotes.4	...	2015	Flags and footnotes.24	2016	Flags and footnotes.2!
<b>GEO/TIME</b>															
European Union (EU6-1958, EU9-1973, EU10-1981, EU12-1986, EU15-1995, EU25-2004, EU27-2007, EU28-2013)	:	NaN	:	NaN	:	NaN	:	NaN	:	NaN	...	:	NaN	:	NaN
Belgium	3105.5	NaN	3099.6	NaN	3084.2	NaN	3161.1	NaN	3158.7	NaN	...	2503.26	NaN	2501.35	NaN

2 rows x 58 columns

Input [6]:

```
data.tail(3)
```

Output [6]:



Module 3 - Task 1

# DATA READING



	1991	Flags and footnotes	1992	Flags and footnotes.1	1993	Flags and footnotes.2	1994	Flags and footnotes.3	1995	Flags and footnotes.4	...	2015	Flags and footnotes.24	2016	Flags and footnotes.25	2017	F foot
GEO/TIME																	
Saniurfa, Diyarbakir	:	NaN	:	NaN	:	NaN	:	NaN	107.4	NaN	...	:	NaN	:	NaN	:	
Mardin, Batman, Sirmak, Siirt	:	NaN	:	NaN	:	NaN	:	NaN	44.3	NaN	...	:	NaN	:	NaN	:	
Bosnia and Herzegovina	:	NaN	:	NaN	:	NaN	:	NaN	:	NaN	...	455	e	455	e	445	

3 rows x 58 columns

[Continua... Módulo 3 – Tarea 2](#)