

01.Lectura_datos_clima

October 29, 2022

1 Pandas para el manejo de datos tabulares

En esta sección usaremos **Pandas**: [documentación](#), [repositorio del código](#) para leer datos tabulares.

Una de las mejores opciones para trabajar con datos tabulares en Python es usar Python Data Analysis Library (alias **Pandas**). La biblioteca **Pandas** provee estructuras de datos, genera gráficos de alta calidad con matplotlib y se integra de buena forma con otras bibliotecas que usan arrays de NumPy.

1.1 Datos

Los datos que vamos a trabajar fueron descargados desde el [SENAMHI](#) para la estación del Ñaña cerca de Lima.

1.2 Importar librerías

```
[ ]: import pandas as pd
```

1.3 Leer archivo

```
[ ]: data = pd.read_csv('../data/qc00000543.txt')
data
```

```
[ ]:
      1964 2 1 0 25.6 17
0      1964 2 2 0 25.2 16.4
1      1964 2 3 0 26 18
2      1964 2 4 0 -99.9 18
3      1964 2 5 0 -99.9 17
4      1964 2 6 0 -99.9 18.2
...
18257    2014 1 27 0 27.8 17
18258    2014 1 28 0 27.2 17.8
18259    2014 1 29 0 27.6 17.8
18260    2014 1 30 0 27.8 17.4
18261    2014 1 31 0 26.6 17

[18262 rows x 1 columns]
```

Podemos usar **delimiter** para separar las columnas.

```
[ ]: data = pd.read_csv('.././data/qc00000543.txt', delimiter=' ')
data
```

```
[ ]:
      1964  2    1    0  25.6    17
0      1964  2    2  0.0  25.2   16.4
1      1964  2    3  0.0  26.0   18.0
2      1964  2    4  0.0 -99.9   18.0
3      1964  2    5  0.0 -99.9   17.0
4      1964  2    6  0.0 -99.9   18.2
...
18257  2014  1   27  0.0  27.8   17.0
18258  2014  1   28  0.0  27.2   17.8
18259  2014  1   29  0.0  27.6   17.8
18260  2014  1   30  0.0  27.8   17.4
18261  2014  1   31  0.0  26.6   17.0
```

[18262 rows x 6 columns]

El archivo no tiene encabezado. Entonces podemos usar **delimiter** para indicar que el archivo no tiene encabezado.

```
[ ]: data = pd.read_csv('.././data/qc00000543.txt', delimiter=' ', header=None)
data
```

```
[ ]:
      0  1    2    3    4    5
0      1964  2    1  0.0  25.6  17.0
1      1964  2    2  0.0  25.2  16.4
2      1964  2    3  0.0  26.0  18.0
3      1964  2    4  0.0 -99.9  18.0
4      1964  2    5  0.0 -99.9  17.0
...
18258  2014  1   27  0.0  27.8  17.0
18259  2014  1   28  0.0  27.2  17.8
18260  2014  1   29  0.0  27.6  17.8
18261  2014  1   30  0.0  27.8  17.4
18262  2014  1   31  0.0  26.6  17.0
```

[18263 rows x 6 columns]

Los datos tienen valores perdidos y estos están declarados como -99.9. Podemos usar

```
[ ]: data = pd.read_csv('.././data/qc00000543.txt', delimiter=' ', header=None,
    ↪na_values=-99.9)
data
```

```
[ ]:
      0  1    2    3    4    5
0      1964  2    1  0.0  25.6  17.0
1      1964  2    2  0.0  25.2  16.4
```

```

2      1964  2   3  0.0  26.0  18.0
3      1964  2   4  0.0   NaN  18.0
4      1964  2   5  0.0   NaN  17.0
...
18258  2014  1  27  0.0  27.8  17.0
18259  2014  1  28  0.0  27.2  17.8
18260  2014  1  29  0.0  27.6  17.8
18261  2014  1  30  0.0  27.8  17.4
18262  2014  1  31  0.0  26.6  17.0

```

```
[18263 rows x 6 columns]
```

Ahora vamos a agragar en nombre de las variables para cada columna. Para eso es importante saber que representa cada columna.

```
[ ]: data.columns = ['Year', 'Month', 'Day', 'Prec', 'Tmax', 'Tmin']
data
```

```
[ ]:
      Year  Month  Day  Prec  Tmax  Tmin
0      1964     2    1   0.0   25.6  17.0
1      1964     2    2   0.0   25.2  16.4
2      1964     2    3   0.0   26.0  18.0
3      1964     2    4   0.0    NaN  18.0
4      1964     2    5   0.0    NaN  17.0
...
18258  2014     1   27   0.0   27.8  17.0
18259  2014     1   28   0.0   27.2  17.8
18260  2014     1   29   0.0   27.6  17.8
18261  2014     1   30   0.0   27.8  17.4
18262  2014     1   31   0.0   26.6  17.0

```

```
[18263 rows x 6 columns]
```

Ahora vamos a gener una variable con formato datetime. Para eso usaremos `to_datetime`.

```
[ ]: # Esto es un ejemplo de como generar una variable con formato tiempo.
pd.to_datetime(data[['Year', 'Month', 'Day']])
```

```
[ ]: 0      1964-02-01
1      1964-02-02
2      1964-02-03
3      1964-02-04
4      1964-02-05
...
18258  2014-01-27
18259  2014-01-28
18260  2014-01-29
18261  2014-01-30

```

```
18262    2014-01-31
Length: 18263, dtype: datetime64[ns]
```

Vamos a ingresar esta variable en nuestro dataframe como el index. Esto hara que python pueda trabajar como una serie temporal.

```
[ ]: data.index = pd.to_datetime(data[['Year', 'Month', 'Day']])
data
```

```
[ ]:
      Year  Month  Day  Prec  Tmax  Tmin
1964-02-01  1964     2    1   0.0  25.6  17.0
1964-02-02  1964     2    2   0.0  25.2  16.4
1964-02-03  1964     2    3   0.0  26.0  18.0
1964-02-04  1964     2    4   0.0   NaN  18.0
1964-02-05  1964     2    5   0.0   NaN  17.0
...
2014-01-27  2014     1   27   0.0  27.8  17.0
2014-01-28  2014     1   28   0.0  27.2  17.8
2014-01-29  2014     1   29   0.0  27.6  17.8
2014-01-30  2014     1   30   0.0  27.8  17.4
2014-01-31  2014     1   31   0.0  26.6  17.0
```

```
[18263 rows x 6 columns]
```

Podemos colocar un nombre a nuestro Index.

```
[ ]: data.index.name = 'Datetime'
data
```

```
[ ]:
      Year  Month  Day  Prec  Tmax  Tmin
Datetime
1964-02-01  1964     2    1   0.0  25.6  17.0
1964-02-02  1964     2    2   0.0  25.2  16.4
1964-02-03  1964     2    3   0.0  26.0  18.0
1964-02-04  1964     2    4   0.0   NaN  18.0
1964-02-05  1964     2    5   0.0   NaN  17.0
...
2014-01-27  2014     1   27   0.0  27.8  17.0
2014-01-28  2014     1   28   0.0  27.2  17.8
2014-01-29  2014     1   29   0.0  27.6  17.8
2014-01-30  2014     1   30   0.0  27.8  17.4
2014-01-31  2014     1   31   0.0  26.6  17.0
```


```
[18263 rows x 6 columns]
```

De esta forma ya estamos listo para usar nuestro dataframe como una serie de tiempo. Ahora podemos aprovechar una gran variedad de funcione disponibles en **pandas** para usar con nuestro dataframe. Por exmplo, podemos usar la función **plot** para hacer un grafico rapido de nuestros

datos.

```
[ ]: data['Tmax'].plot()
```

```
[ ]: <AxesSubplot:xlabel='Datetime'>
```



Podemos explorar nuestros datos en la figura que generamos.

Podemos seleccionar más de dos variables para hacer una figura.

```
[ ]: data[['Tmax', 'Tmin']].plot()
```

```
[ ]: <AxesSubplot:xlabel='Datetime'>
```

