¿Cuadernos de Jupyter en producción?

Eduardo Blancas

Ploomber Co-Fundador, CEO

¿Es posible? [1] [2]

[1] Fuente: Unsplash

[2] Prueba: Evidation Health (ploomber.io/blog/evidation)

Jupyter: un **formato** y una **plataforma**

```
{
  "metadata" : {
    "kernel_info": {
        "name" : "name of the kernel"
    },
    "language_info": {
        "name" : "programming language",
        "version": "version of the language",
    }
  },
  "nbformat": 4,
  "nbformat_minor": 0,
  "cells" : [
  ],
}
```

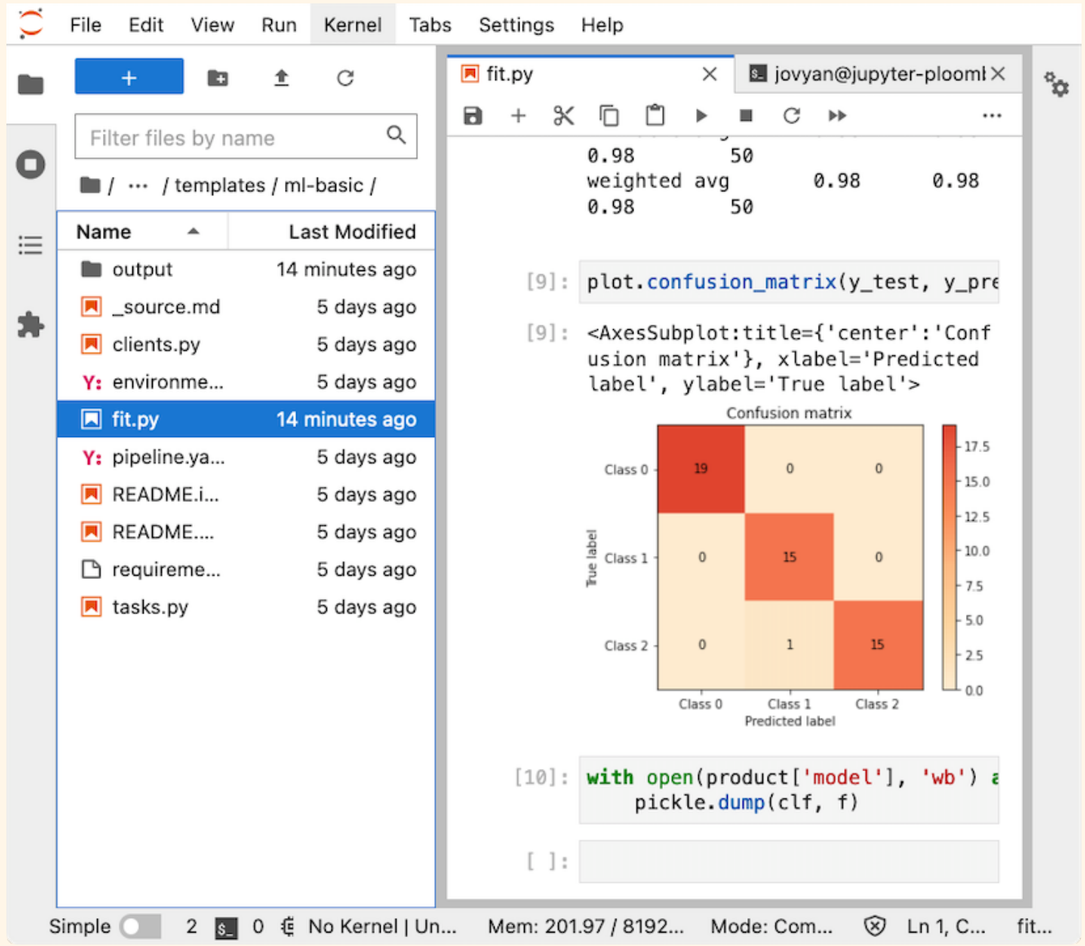

Formato: nbformat

Truco: Cambiar el format! [3]

1. Mejor integracion con `git`
2. Mejor interoperabilidad con otros ambientes de desarollo (VSCode, Spyder, PyCharm)

```python
# data-cleaning.py
import pandas as pd

# %%
# one cell
df = pd.read_csv('my-data.csv')

# %%
# another cell
df['new-column'] = df['column'] + 1
```

[3] Paquete: jupytext

Parte I: Cuadernos limpios 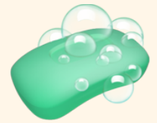 [4]

[4] Lectura recomendada: ploomber.io/blog/clean-nbs (On Writing Clean Notebooks)

Cuadernos cortos

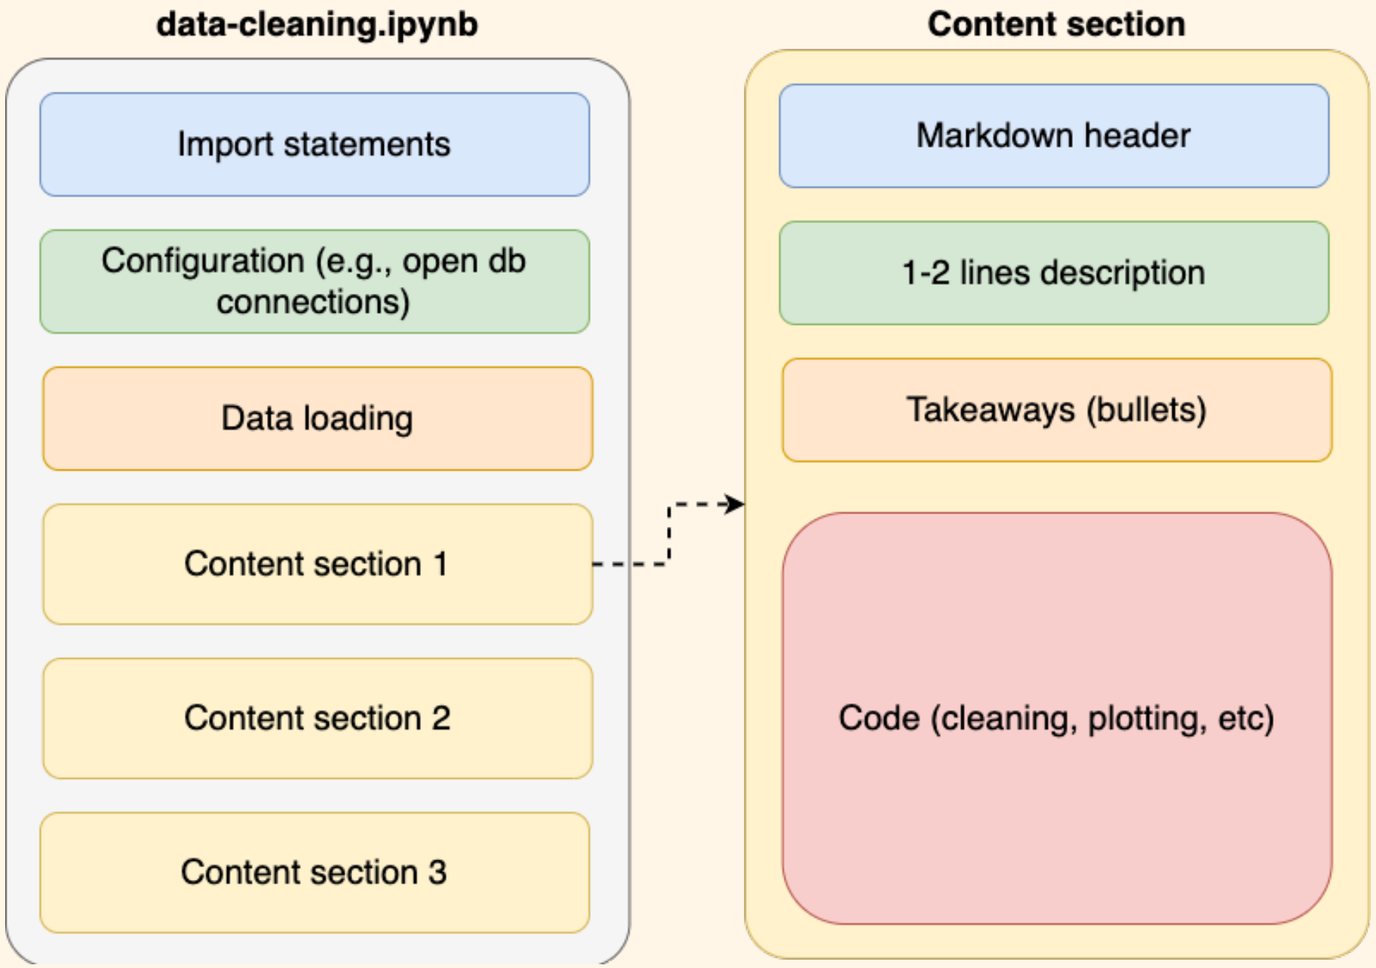

Los cuadernos limpios tienen operaciones sin efectos laterales

Efecto lateral: **evitar!** ⚠️

```
import pandas as pd

def add_one(df):
    df['zeros'] = df['zeros'] + 1

df = pd.DataFrame({'zeros': [0, 0, 0]})

# more code...

# a few dozen cells below...
add_one(df)

df
#    zeros
# 0      1
# 1      1
# 2      1
```

Sin efectos! ✅

```
def add_one(df):
    # copying the data frame!
    another = df.copy()
    another['zeros'] = another['zeros'] + 1
    return another

df = pd.DataFrame({'zeros': [0, 0, 0]})

ones = add_one(df)

df
#    zeros
# 0      0
# 1      0
# 2      0
```

Los cuadernos limpios declaran dependencias 🔒

1. Actualizaciones de paquetes pueden romper tu proyecto
2. Hará más difícil correr el cuaderno en el futuro

```
# requirements.lock.txt
package-a==1.1
package-b==2.4
...
package-z==0.4
```

Después de instalar las dependencies:

```
pip freeze > requirements.lock.txt
```

Para volver a crear el ambiente:

```
pip install -r requirements.lock.txt
```

Los cuadernos limpios siguen estándares [5]

Antes 👀

```
[ ]: df = pd.DataFrame({"x": np.random.rand(10),
"y": np.random.rand(10),
        "x": np.random.rand(10),})
```

```
[ ]: something = True
another = False

if something
\or another:
    print("at least one is True!")
```

Después 🫛

```
[ ]: df = pd.DataFrame(
    {
        "x": np.random.rand(10),
        "y": np.random.rand(10),
        "x": np.random.rand(10),
    }
)
```

```
[ ]: something = True
another = False

if something or another:
    print("at least one is True!")
```

Comando: `soorgeon clean nb.ipynb`

[5] Paquete Soorgeon (Ploomber)

Cuadernos limpios: separan **lógica** de **narrativa**

1. **Lógica:** funciones, clases
2. **Narrativa:** gráficas, transformaciones de datos

Define la lógica en un archivo:

```python
# transformations.py
def add_one(series):
    return series + 1
```

```
[1]: import pandas as pd
     import numpy as np

[2]: # import from transformations.py
     from transformations import add_one

[3]: df = pd.DataFrame({"x": np.random.rand(10)})

[4]: df["y"] = add_one(df.x)

[5]: df.head(3)
```

[5]:

	x	y
0	0.010910	1.010910
1	0.201756	1.201756
2	0.404869	1.404869

Parte II: Probando cuadernos 🧪 [6]

[6] Lectura recomendada: ploomber.io/blog/ci-for-ds y ploomber.io/blog/ml-testing-i

Probando cuadernos: salidas de las celdas [7]

```
[7]: y_pred = clf.predict(X_test)

[8]: acc = accuracy_score(y_test,
                          y_pred)
     print(f'{acc:.3f}')
     0.963
```

```
nbsnapshot test nb.ipynb

Testing nb.ipynb...
Checking "accuracy"...
Value within expected range!
No issues found.
```

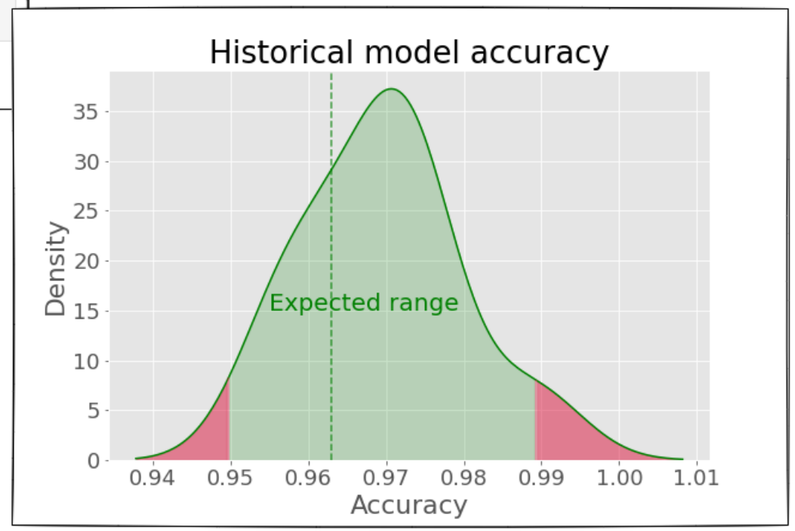

[7] Paquete: nbsnapshot (por Ploomber)

Probando cuadernos: archivos de salida [8]

- Ejemplo: Pruebas de calidad de datos

```
# assume your notebook produces df
def check_data_quality(df):
    # no nas
    assert df['column'].isna().sum() == 0
    # no negative numbers
    assert (df['column'] < 0).sum() == 0
```

[8] Paquete: Ploomber

Probando cuadernos: definiciones

Narrativa y lógica separada [9]

```python
from transformations import add_one

def test_add_one():
    assert add_one(1, 2) == 3
```

Lógica embebida [10]

```python
from testbook import testbook


@testbook('path/to/nb.ipynb')
def test_func(tb):
    add_one = tb.get("add_one")

    assert add_one(1, 2) == 3
```

---

[9] Paquete: pytest

[10] Paquete: testbook

Parte III: Construyendo *pipelines* de datos 🛠️ [11]

[11] Lectura recomendada: ploomber.io/blog/clean-pipelines

Construyendo *pipelines* de datos [12]

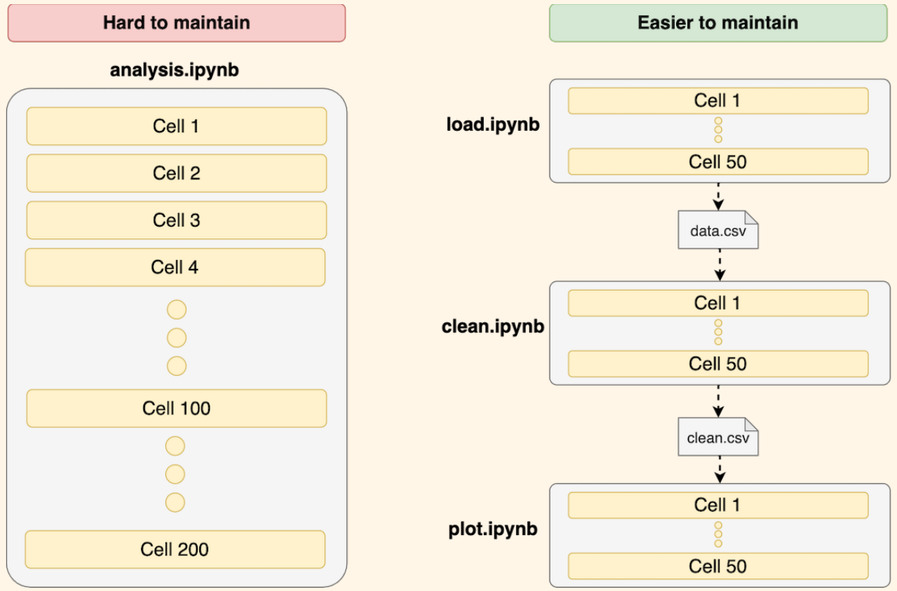

[12] Construyendo pipelines: Ploomber. Convertir cuadernos existentes: Soorgeon (por Ploomber)

Recursos

- Curso gratuito:
  notebooks.academy
- Presentación (con ligas):
  blancas.io/talks/python-boston-22.pdf

Gracias! 🎉

Contacto: eduardo@ploomber.io