

|             |                                                                    |               |       |
|-------------|--------------------------------------------------------------------|---------------|-------|
| MODALIDADE: | Aprendizagem +                                                     | Não aplicável |       |
| CURSO:      | Técnico/a Especialista em Gestão de Informação e Ciência dos Dados |               |       |
| UFCD:       | Limpeza e transformação de dados em Python                         | CÓDIGO UFCD:  | 10808 |
| FORMADOR/A: | Bruno Silva                                                        | DATA:         |       |

## OBJETIVOS

- Comandos para tratar a manipulação dos dados e tratamento da informação

## Parte 1 – Funções tratamento de dados com dataframes

Para esta parte deve carregar o ficheiro **dados.csv**

```
#Importar a biblioteca pandas
import pandas as pd

#Carregar o ficheiro com os dados dos clientes
data = pd.read_csv("dados.csv")

#verificar os dados que forma carregados
print(data.info())
```

Como podem ver ao longo do ficheiro, temos alguns erros significativos tais como nomes mal preenchidos (com símbolos de reticências, barras, entre outras situações).

|   | Nomes    | Idades | Locais  |
|---|----------|--------|---------|
| 0 | Anabela  | 31     | Braga   |
| 1 | _Ana123  | 27     | Porto   |
| 2 | Car los  | 24     | Viseu   |
| 3 | rita     | 22     | Coimbra |
| 4 | zeLIA    | 32     | faro    |
| 5 | Luis_    | 17     | Beja    |
| 6 | Ri_cardo | 14     | Guarda  |
| 7 | INES_    | 12     | Lisboa  |
| 8 | Julia    | 25     | Porto   |

### 1 - Função str()

Função **str()** de string (texto em português), oferece várias operações de tratamento de informação textual para trabalhar em ciência de dados, especialmente, quando queremos fazer a mesma operação para vários tratamentos de dados.

#### 1.1 - Função `str.upper()`

Converter texto em letras maiúsculas para melhor consistência (por exemplo, converter nomes ou categorias em maiúsculas).

```
print("Função .upper():")
data_upper = data["Nomes"].str.upper()
print(data_upper)
```

```
Função .upper():
0    ANABELA
1    _ANA123
2    CAR LOS
3      RITA
4    ZELIA
5    LUIS_
6  RI_CARDO
7    INES_
8    JULIA
```

#### 1.2 - Função `str.lower()`

Faz o contrário do exercício anterior, convertendo o texto em letras minúsculas.

```
print("Função .lower():")
data_lower = data["Nomes"].str.lower()
print(data_lower)
```

```
Função .lower():
0    anabela
1    _ana123
2    car los
3      rita
4    zelia
5    luis_
6  ri_cardo
7    ines_
8    julia
```

#### 1.3 - Função `str.isupper()`

Verifica e retorna valores booleanos se encontra texto todo em maiúsculas ou não.

```
print("Função .isupper():")
data_isupper = data["Nomes"].str.isupper()
print(data_isupper)
```

```
Função .isupper():
0    False
1    False
2    False
3    False
4    False
5    False
6    False
7     True
8    False
Name: Nomes, dtype: bool
```

### 1.4 - Função `str.islower()`

Faz o contrário do exercício anterior, verificando se encontra texto todo em minúsculas ou não.

```
print("Função .islower():")
data_islower = data["Nomes"].str.islower()
print(data_islower)
```

```
Função .islower():
0    False
1    False
2    False
3     True
4    False
5    False
6    False
7    False
8    False
Name: Nomes, dtype: bool
```

### 1.5 - Função `str.len()`

Devolve qual a quantidade de caracteres (comprimento) de cada texto.

```
print("Função .len():")
data_len = data["Nomes"].str.len()
print(data_len)
```

```
Função .len():
0     7
1     7
2     7
3     4
4     5
5     5
6     8
7     5
8     5
```

### 1.6 - Função `str.startswith()`

Retorna valores booleanos com base se a expressão **começa com uma determinada sequência de caracteres** ou não. Atenção, pois o python é case-sensitive (sensível com letras maiúsculas e minúsculas)

```
#apenas uma letra/expressão
print("Função .startswith() mais do que uma letra/expressão:")
data_startswith = data["Nomes"].str.startswith("A")
print(data_startswith)

#mais do que uma letra/expressão
print("Função .startswith() mais do que uma letra/expressão:")
data_startswith = data["Nomes"].str.startswith(("A", "L"))
print(data_startswith)
```

```
Função .startswith() apenas uma letra/expressão:
0 True
1 False
2 False
3 False
4 False
5 False
6 False
7 False
8 False
```

```
Função .startswith() mais do que uma letra/expressão:
0 True
1 False
2 False
3 False
4 False
5 True
6 False
7 False
8 False
```

## 1.7 - Função str.endswith()

Retorna valores booleanos com base se a expressão **termina com uma determinada sequência de caracteres** ou não. Atenção, pois o python é case-sensitive (sensível com letras maiúsculas e minúsculas)

```
#apenas uma letra/expressão
print("Função .endswith() apenas uma letra/expressão:")
data_endswith = data["Nomes"].str.endswith("a")
print(data_endswith)

#mais do que uma letra/expressão
print("Função .endswith() mais do que uma letra/expressão:")
data_endswith = data["Nomes"].str.endswith(("a", "o"))
print(data_endswith)
```

```
Função .endswith() apenas uma letra/expressão:
0 True
1 False
2 False
3 True
4 False
5 False
6 False
7 False
8 True
```

```
Função .endswith() mais do que uma letra/expressão:
0 True
1 False
2 False
3 True
4 False
5 False
6 True
7 False
8 True
```

## 1.8 - Função str.find()

Esta função faz a pesquisa de um carácter ou sequência de caracteres, e se encontrar alguma coisa, devolve a posição de onde está a informação. Ou devolve a posição ou então -1 (não encontrou nada).

```
print("Função Find com a letra 'o':")
data_find = data["Nomes"].str.find('o')
print(data_find)
```

```
Função Find com a letra 'o':
0    -1
1    -1
2     5
3    -1
4    -1
5    -1
6     7
7    -1
8    -1
Name: Nomes, dtype: int64
```

### 1.11 - Função str.count()

Esta função retorna a contagem de quantos elementos existem no DataFrame, do qual, temos de indicar o carácter ou a expressão a encontrar. Neste caso, retorna o total de letras 'a' por cada registo.

```
print("Função count():")
data_count = data["Nomes"].str.count('a')
print(data_count)
```

```
Função count():
0    2
1    1
2    1
3    1
4    0
5    0
6    1
7    0
8    1
Name: Nomes, dtype: int64
```

### 1.9 - Função str.strip()

A função strip() é algo que temos de ter cuidado. Como tal, vamos sempre indicar qual a coluna que desejamos trabalhar, antes de trabalhar com a função.

A função strip() tem algumas funcionalidades adicionais tais como:

- strip() -> apenas retira espaços em branco do início e do fim;
- lstrip() -> limpa as irregularidades que estão à esquerda da informação;
- rstrip() -> limpa as irregularidades que estão à direita da informação;

```
print("Função strip (e variantes):")
data["Nomes"] = data["Nomes"].str.strip()
data["Nomes"] = data["Nomes"].str.lstrip(".")
data["Nomes"] = data["Nomes"].str.lstrip("/")
data["Nomes"] = data["Nomes"].str.rstrip("_")
print(data["Nomes"])
```

```
Função strip (e variantes):
0    Anabela
1    Ana123
2    Car los
3      rita
4    zÉLIA
5      Luis
6    Ri_cardo
7      INÊS
8     Júlia
Name: Nomes, dtype: object
```

Mas, também podemos eliminar todos os casos de uma só vez com a função `strip()`. Como tal, vamos correr o seguinte comando e excluir os outros símbolos e os números 123.

```
data["Nomes"] = data["Nomes"].str.strip("123._/")  
print(data["Nomes"])
```

### 1.10 - Função `str.replace()`

Esta função ajuda a remover certas sequências de caracteres às vezes que estão presentes em todas as cadeias e são indesejáveis.

```
print("Função replace():")  
data["Nomes"] = data["Nomes"].str.replace(' ', '')  
data["Nomes"] = data["Nomes"].str.replace('_', '')  
print(data["Nomes"])
```

```
Função replace():  
0    Anabela  
1    Ana123  
2    Carlos  
3    rita  
4    zÉLIA  
5    Luis  
6    Ricardo  
7    INÊS  
8    Júlia  
Name: Nomes, dtype: object
```

## Parte 2 – Funções tratamento de dados avançado com dataframes

Para esta parte deve carregar o ficheiro `Lista_Clientes.csv`

```
#Importar a biblioteca pandas
import pandas as pd

#Carregar o ficheiro com os dados dos clientes
data = pd.read_csv("Lista_Clientes.csv", sep=";")
#verificar os dados que forma carregados
print(data.info())
#mostrar os dados
print(data)
```

Como podem ver ao longo do ficheiro, temos alguns erros significativos tais como nomes mal preenchidos (com símbolos de reticências, barras, entre outros números de telefone mal preenchidos).

|   | CustomerID | First_Name | Last_Name | ... | Paying | Customer | Do_Not_Contact | Not_Useful_Column |
|---|------------|------------|-----------|-----|--------|----------|----------------|-------------------|
| 0 | 1001       | Frodo      | Baggins   | ... | Yes    | Yes      | No             | VERDADEIRO        |
| 1 | 1002       | Abed       | Nadir     | ... | No     | No       | Yes            | FALSO             |
| 2 | 1003       | Walter     | /White    | ... | N      | NaN      | NaN            | VERDADEIRO        |
| 3 | 1004       | Dwight     | Schrute   | ... | Yes    | Y        | Y              | VERDADEIRO        |
| 4 | 1005       | Jon        | Snow      | ... | Y      | No       | No             | VERDADEIRO        |
| 5 | 1006       | Ron        | Swanson   | ... | Yes    | Yes      | Yes            | VERDADEIRO        |
| 6 | 1007       | Jeff       | Winger    | ... | No     | No       | No             | FALSO             |
| 7 | 1008       | Sherlock   | Holmes    | ... | N      | No       | No             | FALSO             |
| 8 | 1009       | Gandalf    | NaN       | ... | Yes    | NaN      | NaN            | FALSO             |

**Exercício 1** – Vamos verificar se existe dados duplicados (fazendo o somatório). Se tiver, deve remover os dados duplicados com a função `drop_duplicates()`;

**Exercício 2** – Vamos verificar se existe dados nulos (fazendo o somatório). Se tiver, deve remover os dados nulos com a função `dropna()`;

**Exercício 3** – Eliminar colunas desnecessárias, neste caso, a coluna `"Not_Useful_Column"`;

**Exercício 4** – Os campos `CostumerID` e `First_Name` parecem ter os dados em condições, mas, quando passamos para o campo `Last_Name`, temos algumas irregularidades:

- reticências atrás dos nomes;
- underscores ( `_` ) antes e depois dos nomes;
- barras invertidas;
- entre outros pontos;



A função `strip()` é algo que temos de ter cuidados. Se não especificar a coluna que seja trabalhar, pode fazer as mesmas ações para as outras colunas. Como tal, vamos sempre indicar qual a coluna que desejamos trabalhar, antes de trabalhar com a função.

A função `strip()` tem algumas funcionalidades adicionais tais como:

- `strip()` -> apenas retira espaços em branco do início e do fim
- `lstrip()` -> limpa as irregularidades que estão à esquerda da informação
- `rstrip()` -> limpa as irregularidades que estão à direita da informação

**Exercício 4.1** – Use as funções `lstrip()` e `rstrip()` para remover irregularidade atrás dos nomes como por exemplo reticências, barras invertidas, underscores.

**P.S.:** Só queremos apenas alterar os dados da coluna. Coloque atrás do nome da coluna a trabalhar e depois a frente é que colocamos o igual e a operação a trabalhar.

**Exercício 4.2** – Use a função `strip()` para remover todos os símbolos e os números 123.

### Exercício 5 – Funções para tratar dos dados telefónicos.

**Exercício 5.1** – Função `replace()` - vamos tratar os dados dos contactos telefónicos (colocar apenas números). Se reparar nos dados, estes estão muito inconsistentes e queremos colocar o formato de apenas números

Como tal vamos utilizar a função **`replace`** permite uma funcionalidade adicional chamada de **Regex** (expressões regulares). No primeiro parâmetro podemos colocar apenas uma instrução ou combinação de várias instruções e arranjar os dados sem que:

- `\d` – devolve tudo o que não são dígitos;
- `\D` – devolve os dígitos equivalente no intervalo entre 0 até 9.
- `\s` – devolve tudo o que não são espaços;
- `\S` – devolve espaços;

```
data["Phone_Number"] = data["Phone_Number"].str.replace('\D', '', regex=True)
print(data["Phone_Number"])
```



### Exercício 6 – Função Split() - Tratar moradas (coluna Address)

O objetivo será dividir a morada em partes. Muitas vezes as pessoas utilizam vírgulas ou outros símbolos para separar informações, como rua, número da porta, concelhos, cidade, código-postal, país, entre outras situações.

Neste ficheiro, os dados das moradas estão separados por vírgulas (.). Vamos usar a função split para separar o texto em porções e verificar a resposta.

A função split() tem 3 parâmetros em causa:

- **Parâmetro 1** → qual o símbolo a encontrar (neste caso estamos a assumir a , );
- **Parâmetro 2** → qual o limite de repetições para fazer a operação (pois temos moradas com mais de uma vírgula);
- **Parâmetro 3** → se permite expandir a operação do split nas diferentes colunas (como indicados no início da expressão);

```
data[["Street", "State", "Zip Code"]] = data["Address"].str.split(',', n=2, expand=True)
print(data.head())
```

### Exercício 7 – Funções para colocar valores com o mesmo formato

Se analisar a coluna **Paying Customer** ou **Do\_Not\_Contact** ambos tem irregularidade de informação, isto é, alguns dados têm Y outros Yes e o oposto N outros NO. O objetivo será fazer uma regra para colocar tudo com o mesmo formato.

**Exercício 7.1** – Primeiro convertemos as palavras extensas para letra simples e fica tudo igual:

```
data["Paying Customer"] = data["Paying Customer"].str.replace('Yes', 'Y')
print(data["Paying Customer"])
```

Faça o mesmo para o No:

```
data["Paying Customer"] = data["Paying Customer"].str.replace('No', 'N')
print(data["Paying Customer"])
```

Pode continuar com as mesmas operações para a coluna "Do\_Not\_Contact":

```
data["Do_Not_Contact"] = data["Do_Not_Contact"].str.replace('Yes', 'Y')
data["Do_Not_Contact"] = data["Do_Not_Contact"].str.replace('No', 'N')
print(data["Do_Not_Contact"])
```

**Exercício 8** – Gere um novo ficheiro excel com os dados tratados.