

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 com a biblioteca Pandas para classificação, divisão e extração de dados

Parte 1 – Classificação, divisão e extração de dados

A biblioteca do Pandas oferece várias maneiras de classificar, dividir, extrair, filtrar e isolar dados nos DataFrames. Vejamos as formas mais comuns.

Para esta ficha de trabalho, vamos usar o ficheiro `nba1.csv` (que está nesta ficha de trabalho). Como tal, na plataforma do jupyter, deve criar a pasta “ficha_4” e dentro desta o ficheiro “ficha_4.ipynb”. Quando estiver dentro do ficheiro da ficha 4 deve fazer a importação do módulo Pandas e do ficheiro CSV com a função `read_csv()`.

Parte 1.1 – Função `sort_values()`

Para classificar um DataFrame por uma coluna específica com o método `sort_values`. Para além disso, temos ainda 2 parâmetros adicionais:

- `by` → qual a coluna que pretende ordenar os valores;
- `ascending` → `true` para ordenação ascendente e `false` para descendente;

```
#Ordenar coluna TEAM e por ordem crescente
data_ordenada = data.sort_values(by="Team", ascending=True)
print(data_ordenada)
```

	Name	Team	Number	Position	...	Height	Weight
327	Walter Tavares	Atlanta Hawks	22.0	C	...	7-3	260.0
314	Kent Bazemore	Atlanta Hawks	24.0	SF	...	6-5	201.0
315	Tim Hardaway Jr.	Atlanta Hawks	10.0	SG	...	6-6	205.0
316	Kirk Hinrich	Atlanta Hawks	12.0	SG	...	6-4	190.0
317	Al Horford	Atlanta Hawks	15.0	C	...	6-10	245.0
..	...	...	...	...	...	...	...
376	Jarell Eddie	Washington Wizards	8.0	SG	...	6-7	218.0
375	Jared Dudley	Washington Wizards	1.0	SF	...	6-7	225.0

Parte 1.2 – Filtragem de dados usando condições

Para extrair dados com base em uma condição. Como tal, deve primeiro **invocar o dataframe** a trabalhar e depois **referir o índice da coluna a filtrar a informação e colocar a condição**:

```
#Para extrair dados com base numa condição
data_altura = data[data["Weight"] > 195]
print(data_altura)
```

	Name	Team	Number	Position	Age	Height	Weight
1	Jae Crowder	Boston Celtics	99.0	SF	25.0	6-6	235.0
2	Jae Crowder	Boston Celtics	99.0	SF	25.0	6-6	235.0
3	John Holland	Boston Celtics	30.0	SG	27.0	6-5	205.0
5	Jonas Jerebko	Boston Celtics	8.0	PF	29.0	6-10	231.0
6	Amir Johnson	Boston Celtics	90.0	PF	29.0	6-9	240.0
..	...	...	...	...	...	...	...
456	Chris Johnson	Utah Jazz	23.0	SF	26.0	6-6	206.0
457	Trey Lyles	Utah Jazz	41.0	PF	20.0	6-10	234.0
458	Shelvin Mack	Utah Jazz	8.0	PG	26.0	6-3	203.0
459	Tiber Pleiss	Utah Jazz	21.0	C	26.0	7-3	256.0

Parte 1.3 – Isolar colunas (individualmente ou mais do que uma)

Podemos apenas isolar uma única coluna usando os símbolos das chavetas retas [] e indicar o nome de uma coluna que quer exibir.

O resultado é um objeto pandas Series. Uma série pandas é uma matriz unidimensional que contém dados de qualquer tipo, incluindo inteiros, flutuantes, strings, booleanos, objetos python, etc.

Um DataFrame é composto de muitas séries que funcionam como colunas.

Exemplo: exibir apenas a coluna **Glucose**

```
#Exibir apenas uma coluna
coluna = data["Weight"]
print(coluna)
```

```
0      180.0
1      235.0
2      235.0
3      205.0
4      185.0
...
458     203.0
459     179.0
459     256.0
```

Exemplo: Para mostrar mais do que uma coluna, deve colocar dupla chaveta reta e separar os campos por com o símbolo, (vírgula)

```
#Exibir mais que uma coluna
coluna = data[["Weight", "Age"]]
print(coluna)
```

	Weight	Age
0	180.0	25.0
1	235.0	25.0
2	235.0	25.0
3	205.0	27.0
4	185.0	22.0
...	...	...
458	203.0	26.0
459	179.0	24.0

Parte 1.4 – Função .loc[] e .iloc[]

Para listar um subconjunto de linhas ou colunas de um Dataframe, podemos usar a função **iloc()**.

Por exemplo, o comando **.iloc[0:4, 0:3]** vai listar apenas as **primeiras 4 linhas** e as **primeiras 3 colunas** do Dataframe que estiver a trabalhar.

```
#Função iloc (seleção de colunas e linhas)
data_loc = data.iloc[0:4, 0:3]
print(data_loc)
```

	Name	Team	Number
0	Avery Bradley	Boston Celtics	0.0
1	Jae Crowder	Boston Celtics	99.0
2	Jae Crowder	Boston Celtics	99.0
3	John Holland	Boston Celtics	30.0

Se quisermos listar ou filtrar os dados do DataFrame através dos rótulos das linhas e/ou colunas, podemos usar a função **.loc[]**

Esta função aceita um ou dois argumentos:

- **1º argumento:** refere-se as linhas, indicando o intervalo de colunas a exibir);
- **2º argumento:** refere-se as colunas (indicando os nomes que quer exibir);

```
#Função loc (seleção de colunas e linhas)
data_loc = data.loc[0:3, ["Age", "Height", "College"]]
print(data_loc)
```

	Age	Height	College
0	25.0	6-2	Texas
1	25.0	6-6	Marquette
2	25.0	6-6	Marquette
3	27.0	6-5	Boston University

Parte 1.5 – Operações aritméticas (mínimo, máximo, média, mediana)

Podemos realizar operações aritméticas com valores numéricos. Como por exemplo, vamos calcular a idade mínima, máxima, média e mediana.

```
#Exemplo para calcular a média, mínimo e máximo da coluna idade
print(f"Idade Minima: {data["Age"].min()}")
print(f"Idade Máxima: {data["Age"].max()}")
print(f"Idade Média: {data["Age"].mean()}")
print(f"Idade Mediana: {data["Age"].median()}")
```

```
Idade Minima: 21
Idade Máxima: 81
Idade Média: 33.240885416666664
Idade Mediana: 29.0
```

Parte 1.6 – Função .value_counts(): Contar e agrupar valores da coluna

Podemos realizar operações para contar os valores únicos de uma coluna com a função .value_counts(), como por exemplo a coluna Idade:

```
#Contar os valores únicos da coluna (Idade – Age)
contagem_idades = data["Age"].value_counts()
print(f"Idades Agrupadas: {contagem_idades}")
```

```
Idades Agrupadas: Age
22    72
21    63
25    48
24    46
23    38
28    35
26    33
27    32
29    29
31    24
```

Parte 1.7 – Isolar apenas uma linha (pelo índice)

Podemos apenas obter um registo, bastando indicar o valor do índice que deseja exibir. No exemplo mais abaixo, utilizamos o método **index** e igualar o valor a procurar 3 (**exemplo**: `data.index == 3`):

```
#Isolar apenas uma linha de informação (pelo indice do registo)
print(data[data.index == 3])
```

	Name	Team	Number	Position	Age	Height	Weight	College
3	John Holland	Boston Celtics	30.0	SG	27.0	6-5	205.0	Boston University

Parte 1.8 – Função `index.isin()`: Isolar várias linhas (pelo índice)

No entanto, também podemos indicar um intervalo de vários índices. Como tal, para além do método `index`, deve adicionar a função `.isin(range(x,y))` onde **x** representa o início do índice a procurar e o **y** é o fim da sequência:

```
#Isolar informação (num intervalo de registos)
print(data[data.index.isin(range(2, 6))])
```

	Name	Team	Number	Position	Age	Height
2	Jae Crowder	Boston Celtics	99.0	SF	25.0	6-5
3	John Holland	Boston Celtics	30.0	SG	27.0	6-5
4	R.J. Hunter	Boston Celtics	28.0	SG	22.0	6-5
5	Jonas Jerebko	Boston Celtics	8.0	PF	29.0	6-11

Parte 1.9 – Função `.groupby()`

Na classificação da informação, podemos fazer agrupamento da informação, para resumir dados repetidos. Como tal, podemos usar a função `.groupby()` para agrupar os dados pela coluna `Team` e a partir desse agrupamento da informação, pedir para criar uma variável estruturada com 3 campos:

- **Campo `Salario_Total`** → campo para guardar a soma do campo `Salary` (salários);
- **Campo `Contagem_Jogadores`** → campo para guardar a contagem do campo `Name` (nomes);

```
#Total da soma de salarios por equipa

Total_Salarios = data.groupby("Team").agg(
    Salario_total=('Salary', 'sum'),
    Contagem_Jogadores=('Name', 'count')
)

print(Total_Salarios)
```

Team	Salario_total	Contagem_Jogadores
Atlanta Hawks	72902950.0	15
Boston Celtics	58541068.0	15
Brooklyn Nets	52528475.0	15
Charlotte Hornets	78340920.0	15
Chicago Bulls	86783378.0	15

Parte 1.10 – Procura de informação (por valor)

Imagine que não sabe o índice do registo. Temos de realizar uma pesquisa por alguma informação específica. Se pretendermos encontrar uma informação numa coluna, temos de usar a pesquisa por coluna.

Exemplo:

Queremos obter os dados na coluna **College** com o nome “Marquette”. Como tal, vamos a data, indicar que quero seleccionar a coluna **College** e indicar qual o texto a encontrar:

```
#Procurar informação na coluna College por um nome especifico
print(data["College"] == "Marquette")
```

Resultado: Como pode existir mais do que uma encomenda com o mesmo cliente, é devolvida uma lista resumida se encontrou informação:

```
0      False
1       True
2       True
3      False
4      False
...
458     False
459     False
460     False
```

Mas se desejar obter a informação da linha em causa, deve colocar a pesquisa dentro da instrução data e depois o resto da informação da filtragem:

```
#Procurar informação na coluna College por um nome especifico
print(data[data["College"] == "Marquette"])
```

	Name	Team	Number	Position	Age	Height	Weight	College	Salary
1	Jae Crowder	Boston Celtics	99.0	SF	25.0	6-6	235.0	Marquette	6796117.0
2	Jae Crowder	Boston Celtics	99.0	SF	25.0	6-6	235.0	Marquette	6796117.0
156	Jimmy Butler	Chicago Bulls	21.0	SG	26.0	6-7	220.0	Marquette	16407500.0
225	Steve Novak	Milwaukee Bucks	6.0	SF	32.0	6-10	225.0	Marquette	295327.0
237	Wesley Matthews	Dallas Mavericks	23.0	SG	29.0	6-5	220.0	Marquette	16407500.0
354	Dwyane Wade	Miami Heat	3.0	SG	34.0	6-4	220.0	Marquette	20000000.0

Parte 1.11 – Procura de informação (por valor)

O exemplo anterior permite devolver os dados, mas, também existe o método **query** que consegue ser mais eficiente na escrita de condições de filtragem.

Como tal, basta indicar o objeto com a data e a função dentro da função query, indicamos qual a coluna a trabalhar e o valor dentro de películas (aspa simples).

Veja o seguinte exemplo:

```
#Procurar informação na coluna College com a função query()
print(data.query('College == "Marquette"'))
```

	Name	Team	Number	Position	Age	Height	Weight	College	Salary
1	Jae Crowder	Boston Celtics	99.0	SF	25.0	6-6	235.0	Marquette	6796117.0
2	Jae Crowder	Boston Celtics	99.0	SF	25.0	6-6	235.0	Marquette	6796117.0
156	Jimmy Butler	Chicago Bulls	21.0	SG	26.0	6-7	220.0	Marquette	16407500.0
225	Steve Novak	Milwaukee Bucks	6.0	SF	32.0	6-10	225.0	Marquette	295327.0
237	Wesley Matthews	Dallas Mavericks	23.0	SG	29.0	6-5	220.0	Marquette	16407500.0
354	Dwyane Wade	Miami Heat	3.0	SG	34.0	6-4	220.0	Marquette	20000000.0

Mas, também pode colocar várias condições:

```
#Procurar informação na coluna College com a função query()
print(data.query('College == "Marquette" and Age < 27'))
```

	Name	Team	Number	Position	Age	Height	Weight	College	Salary
1	Jae Crowder	Boston Celtics	99.0	SF	25.0	6-6	235.0	Marquette	6796117.0
2	Jae Crowder	Boston Celtics	99.0	SF	25.0	6-6	235.0	Marquette	6796117.0
156	Jimmy Butler	Chicago Bulls	21.0	SG	26.0	6-7	220.0	Marquette	16407500.0