

# AULA 3

Estruturas de controlo e Organização do Código.

Determinação da constante de Planck por mínimos quadrados.

# Modularização do código PYTHON

O código deve ser **legível**, **comentado** e **reutilizável**.

Existem diversas estruturas básicas que ajudam:

Funções (internas ao script, ou **importadas**)

Estruturas de controlo

**if ; elif; else**

**for**

**while**

# funções

```
def func (x1 , x2 , x3) : #input
    xsum=x1+x2+x3
    xx=x1*x2*x3
    return xsum, xx #output
```

```
Soma , SS=func (1 , 2 , 4)
```

```
print (Soma , SS)
```

```
>>7 8
```

# Estrutura de execução condicional **if**

```
if x==7:  
    s=7  
elif x>0:  
    s=math.sqrt(x)  
elif x!=-10:  
    s=math.sqrt(abs(x))  
...  
else:  
    s=0
```

## Ciclo com contador (iterador) **for**

```
X=[0,1,2,3,4,5] #len(X)==6
```

```
S=0
```

```
for k in range(len(X)) :
```

```
    S=S+X[k]
```

```
#range(len(X)) == [0,1,2,3,4,5]
```

```
SS=0
```

```
for x in X:
```

```
    SS=SS+x
```

## Ciclo com condição **while**

```
X=[0,1,2,3,4,5]
```

```
k=0
```

```
S=0
```

```
while k<len(X) : #len(X)==6
```

```
    S=S+X[k]
```

```
    k=k+1
```

# Problema

Determinação experimental da constante de Planck

$$E = h\nu$$

Experiência: Calcular o potencial de paragem de uma célula fotoelétrica em função da frequência da radiação incidente:

Energia do electrão = Energia do fotão – Energia de arranque

$$eV_p = h\nu - W$$

2 incógnitas ( $h, W$ ). Precisamos de 2 equações (2 medidas de  $\nu$  e  $V_p$ ). Mas é conveniente ter muitas medidas para controlar o erro experimental.

# Dados experimentais efeito fotoelétrico

Comprimento de onda (nm)	Frequência ( $10^{12}\text{Hz}$ )	$V_p$ (V)
400	749	1
414	724	0.99
429	699	0.89
444	674	0.79
462	649	0.68
480	624	0.57
500	599	0.47
522	574	0.37
545	549	0.28
571	524	0.17
600	499	0.07

$$eV_p = h\nu - W$$



## Discussão ( $eV_p = h\nu - W$ ) $y = ax + b$

Com 1 medida o problema é subdeterminado: não é possível calcular  $h$

Com 2 medidas o problema tem solução única. No entanto, se as medidas não forem exactas os valores obtidos têm erro desconhecido

Com mais de duas medidas temos um problema **sobre-determinado**:  $N^\circ$  equações  $>$   $N^\circ$  incógnitas. Qualquer solução implica um erro.

A solução que corresponde ao **menor erro médio quadrático** é interessante

## **$N$ medidas $(x_k, y_k) (k=1, 2, \dots, N)$**

Erro médio quadrático (função de  $(a, b)$ )

$$\overline{e^2} = \frac{1}{N} \sum_{k=1}^N [y_k - (ax_k + b)]^2$$

Erro mínimo:

$$\frac{\partial}{\partial a} (\overline{e^2}) = \frac{\partial}{\partial b} (\overline{e^2}) = 0$$

$$a = \frac{\sum x_k y_k - \frac{1}{N} \sum x_k \sum y_k}{\sum x_k^2 - \frac{1}{N} (\sum x_k)^2} \quad b = \frac{1}{N} \left( \sum y_k - a \sum x_k \right)$$

# O que precisamos de fazer

Definir variáveis com  $N$  valores (medidas experimentais) **vectores**

- Digitando os valores ou
- Lendo um ficheiro de dados

Calcular somatórios

Calcular os coeficientes

Representar graficamente o resultado (pontos experimentais e curva de ajuste)

Estimar o erro?

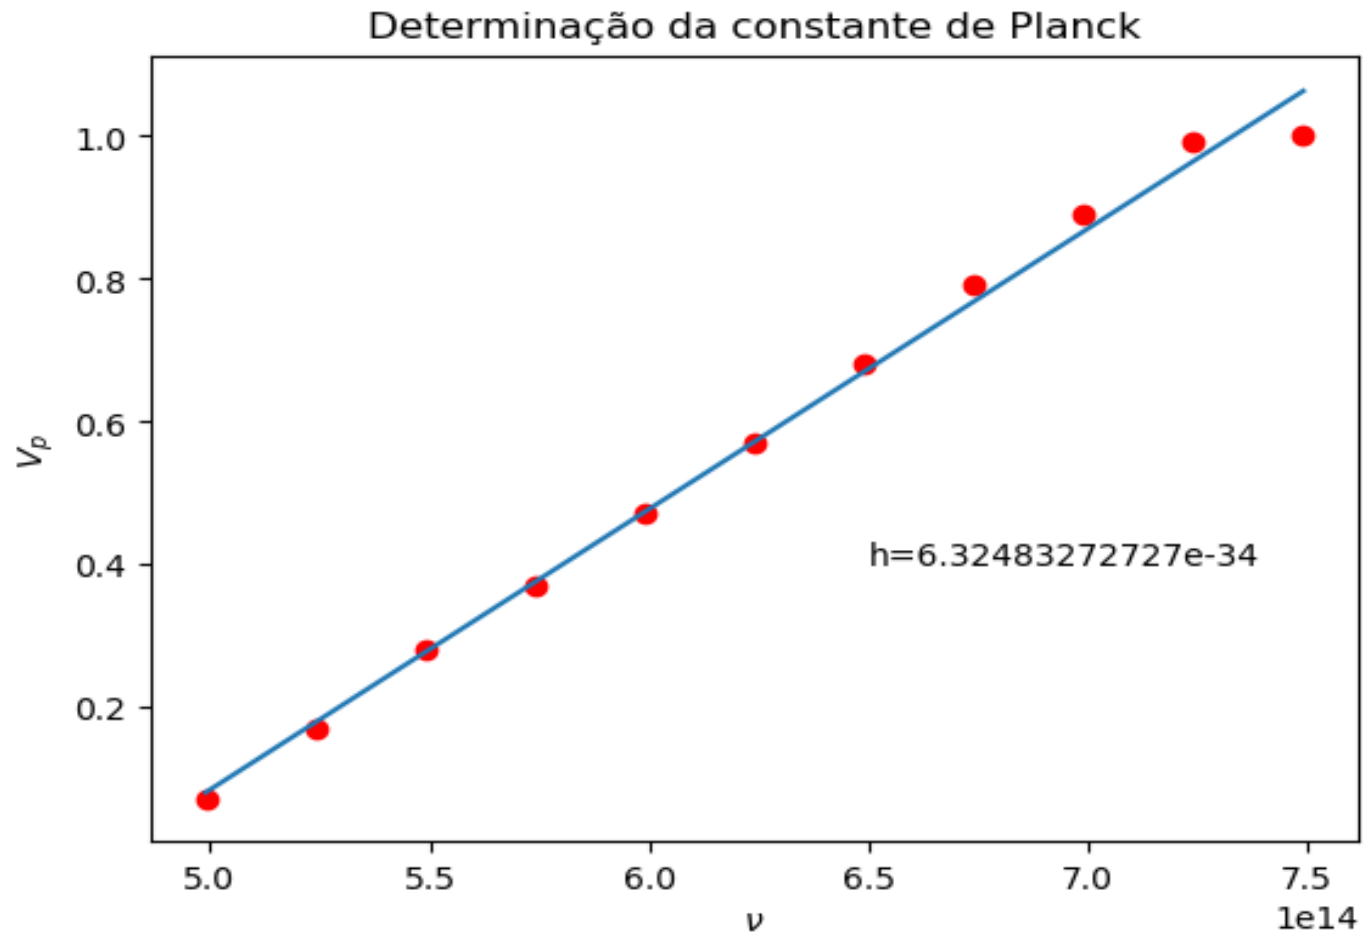
## Código(1/2)

```
import numpy as np
import matplotlib.pyplot as plt
nu=1e12*np.array (749,724,699,674,649,624,599,574,549,524,499, dtype
=float)
Vp=np.array (1,0.99,0.89,0.79,0.68,0.57,0.47,0.37,0.2
8,0.17,0.07)
e=1.609e-19
eVp=e*Vp
Sxx=0 ; Sxy=0 ; N=len (nu)
for k in range (N) :
    Sxy=Sxy+nu [k] *eVp [k]
    Sxx=Sxx+nu [k] *nu [k]
Sx=np . sum (nu)
Sy=np . sum (eVp)
```

## Código (2/2)

```
a= (Sxy-Sx*Sy/N) / (Sxx-Sx**2/N)
b= (Sy-a*Sx) /N
h=a
W=-b
plt.scatter(nu, Vp)
fit=(h*nu-W) /e;
plt.plot(nu, fit)
plt.text(6.5e14, 0.4, 'h='+str(h))
plt.xlabel(r'$\nu$')
plt.ylabel(r'$V_p$')
plt.title('Determinação da constante de
Planck')
print('h=', h)
```

# Resultado



# Estruturas de controlo: ciclo com contador

```
for k in range(N) : #k=0,1,...,N-1
```

```
    a=xk**2
```

```
    ...
```

```
X=1,10,100
```

```
for xX in X:
```

```
    a=xX**2
```

```
    ...
```

A linha inicial termina com :

O fim da estrutura é definido por **indentação**

# Ciclo com contador vs operação vetorial np

## *benchmark simples*

```
import numpy as np; import time
N=10**6
x=np.ones ( (N) ,dtype=float)
y=np.ones ( (N) ) *5
t0=time.perf_counter()
Sxy=0
for k in range(len(x)):
    Sxy=Sxy+x[k]*y[k]
t1=time.perf_counter()
SSxy=np.sum(x*y)
t2=time.perf_counter()
print('ciclo=%10.7f npsum=%10.7f aceleração=%7.1f' % (t1-
t0,t2-t1, (t1-t0)/(t2-t1)))
>>ciclo= 0.6691751 npsum= 0.0048059 aceleração= 139.2
```

Atenção: o tempo gasto é muito sensível ao valor de N



# Leitura de um ficheiro ascii

...

```
Dados=np.loadtxt('dados.dat')
```

```
nu=1.e12*Dados[:,0]
```

```
Vp=Dados[:,1]
```

## Dados.dat

7.49e+02 1.00e+00

7.24e+02 9.90e-01

6.99e+02 8.90e-01

6.74e+02 7.90e-01

6.49e+02 6.80e-01

6.24e+02 5.70e-01

5.99e+02 4.70e-01

5.74e+02 3.70e-01

5.49e+02 2.80e-01

5.24e+02 1.70e-01

4.99e+02 7.00e-02

## De volta ao problema $y = ax + b$

Vamos escrever uma função genérica para resolver o problema do ajuste de uma reta a um conjunto de dados por mínimos quadrados. Em relação à Aula 3, vamos acrescentar dois detalhes:

A função considera os dois ajustes lineares:

$$y = ax + b \text{ ou } y = ax$$

A função calcula uma medida da qualidade do ajuste linear, o coeficiente de correlação de **Pearson**

## Novos cálculos

No caso  $y = ax$ , pode mostrar-se (exercício!) que

$$a = \frac{\sum x_k y_k}{\sum x_k x_k}$$

Em ambos os casos, o coeficiente de correlação de Pearson é:

$$r = \frac{\sum x_k y_k - \frac{1}{N} \sum x_k \sum y_k}{\sqrt{\left[ \sum x_k^2 - \frac{1}{N} (\sum x_k)^2 \right] \left[ \sum y_k^2 - \frac{1}{N} (\sum y_k)^2 \right]}}$$

Precisamos de calcular todos os somatórios.


# Função linreg (sem ciclos for)

```
import numpy as np #executar antes de chamar linreg
def linreg(x,y,origin):
    n=len(x)
    sx=np.sum(x)
    sy=np.sum(y)
    sx2=np.sum(x*x)
    sy2=np.sum(y*y)
    sxy=np.sum(x*y)
    r=(sxy-sx*sy/n)/np.sqrt((sx2-sx*sx/n)*(sy2-sy*sy/n))
    if origin:
        a=sxy/sx2
        b=0.
    else:
        a=(sxy-sx*sy/n)/(sx2-sx*sx/n)
        b=(sy-a*sx)/n
    return(a,b,r)
```

# Utilização da função

```
import matplotlib.pyplot as plt
plt.close('all')
nu=1e12*np.array([749,724,699,674,649,624,599,574,549,524,499],dtype=float)
Vp=np.array([1,0.99,0.89,0.79,0.68,0.57,0.47,0.37,0.28,0.17,0.07])
e=1.609e-19; eVp=e*Vp
(a,b,r)=linreg(nu,eVp,False)
h=a; W=-b
plt.scatter(nu,Vp,color='red') #argumento por dicionário
fit=(h*nu-W)/e;
plt.plot(nu,fit,color='blue')
plt.text(6.5e14,0.4,'h='+str(h)+'\n'+ 'r='+str(r))
plt.xlabel(r'$\nu$');plt.ylabel(r'$V_p$')
plt.title('Determinação da constante de Planck')
print('h=',h,'r=',r)
```

## Determinação da constante de Planck



$$y = ax + b \text{ vs } y = ax$$

O coeficiente de correlação não depende do *fit*

Em certos problemas a reta de regressão **tem** que passar na origem, por razões físicas (por exemplo os valores negativos são inaceitáveis)

Para um dado conjunto de dados as duas opções dão declives diferentes. A opção  $y = ax + b$  tem  $\leq$  erro médio quadrático (tem mais graus de liberdade).