資料科學
DATA SCIENCE

資料分析 | 數據分析 (Data Analysis)
資料視覺化 (data Visualization)

陳怡芬 yfchen@gapps.fg.tp.edu.tw 2017

數據科學家

- **所謂數據科學家就是：運用數據和科學，創造新東西的人**
- 數據科學家這個職位的頭銜則是 2009 年由 Natahn Yau 首次提及的，他認為數據科學家就是能夠從大型數據集中析取出數據，並提供某些可供非數據專家使用的東西的人。

> 數據科學家、創業家 Mike Driscoll 則認為數據有三個性感之處：建模、轉換、可視化。
>
> 而一種比較有詩意的表述方式是：數據科學家好比是哥倫布遇上科倫坡，目光如炬的探險家與懷疑一切的大偵探的合體。

而在《數據科學家：二十一世紀最性感的職業》一文中，設計 LinkedIn 的「你可能認識的人」功能的數據科學家 Jonathan Goldman 的工作，也許是對數據科學家工作方式的最好詮釋：首先構建理論、印證預感，然後尋找出模式，對應該推出某人的哪一個網絡做出預測。

數據科學家

- 數據科學家就是採用科學方法、運用數據挖掘工具尋找新的數據洞察的工程師。
- 科學辦法就是構思假設、測試想法、精心設計實驗、經由他人驗證，這些是他們從統計身上掌握的知識，經科學訓練出來的經驗； 而工具的運用則是來自其工程經驗，或者更確切地說，來自於其計算機科學與編程背景。
- 最好的數據科學家是產品與流程的創新者，有時候還是新的數據挖掘工具的開發者。

如何成為資料科學家

draw by Swami Chandrasekaran

DATA ANALYSIS
資料分析

DATA ANALYSIS

教育部統計處

http://depart.moe.edu.tw/ed4500/News.aspx?n=EED2462F7B4EE089&sms=2017CA908D8E0BE9

經濟部國際貿易局

http://www.trade.gov.tw/Pages/List.aspx?nodeID=1591

文化部統計研究分析

http://stat.moc.gov.tw/StatisticsResearchList.aspx

兩人一組學習任務

定義問題- 收集資料 – 統計分析資料 – 資料視覺化 – 解釋資料 – 提供建議與行動方案

OPEN DATA

開放資料

開放資料 (Open data) 指的是一種經過挑選與許可的資料，這些資料不受著作權、專利權，以及其他管理機制所限制，可以開放給社會公眾，任何人都可以自由出版使用，不論是要拿來出版或是做其他的運用都不加以限制。

Open data 運動希望達成的目標與開放原始碼、內容開放、開放獲取。Open data 背後的核心思想由來已久，但 Open data 這名詞直到近代才出現，拜網際網路崛起而為人所知。

OPEN DATA

- 美國國家政府資料開放平臺 https://www.data.gov/
- 政府資料開放平臺　http://data.gov.tw/
- 臺北市政府資料開放平台 http://data.taipei/

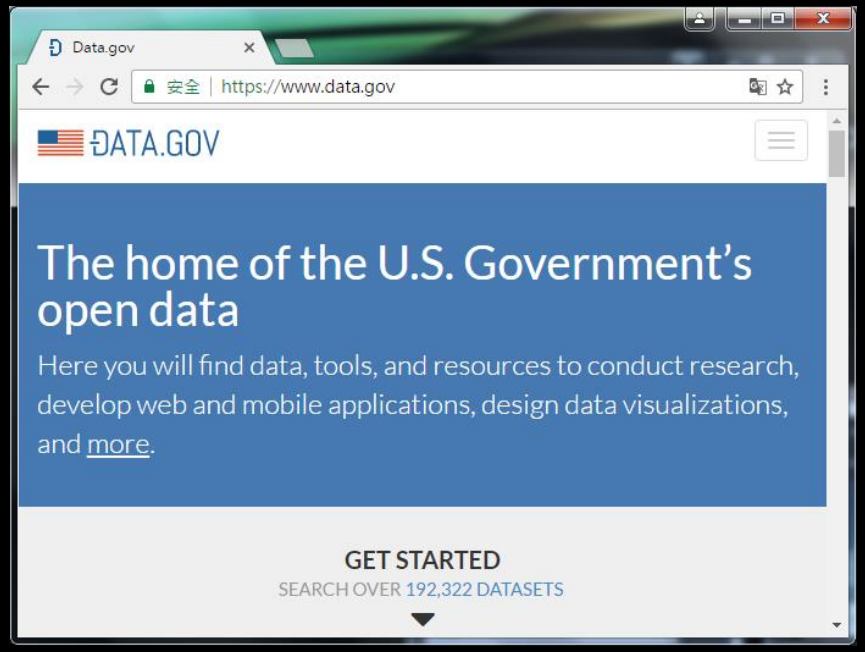

DATA ANALYSIS TOOLS

Excel, Matlab, Matplotlib in python, R…..

DATA ANALYSIS IN EXCEL

- Range 範圍
- Formulas and Functions 公式與函式
- Ribbon 標籤頁
- Workbook 活頁簿
- Worksheets 活頁紙
- Format Cells 儲存格
- Find & Select 尋找
- Data Validation資料驗證

- Sort 排序
- Filter 篩選
- Conditional Formatting 條件格式化
- Charts 圖表
- Pivot Tables樞紐分析表
- Tables 表格
- What-If Analysis 假設分析

http://www.excel-easy.com/data-analysis.html

DATA VISUALIZATION

資料視覺化

TED：David McCandless – 資料視覺化的美麗

David McCandless將全世界的軍隊開銷、媒體活動、Facebook的狀態更新等複雜的資料，轉化成簡單又美麗的圖表。他提倡人們應該使用設計工具，來整理當今過多的資訊，找出獨特的模式與關連性，也許就能改變我們對這個世界的看法。

CHARTS

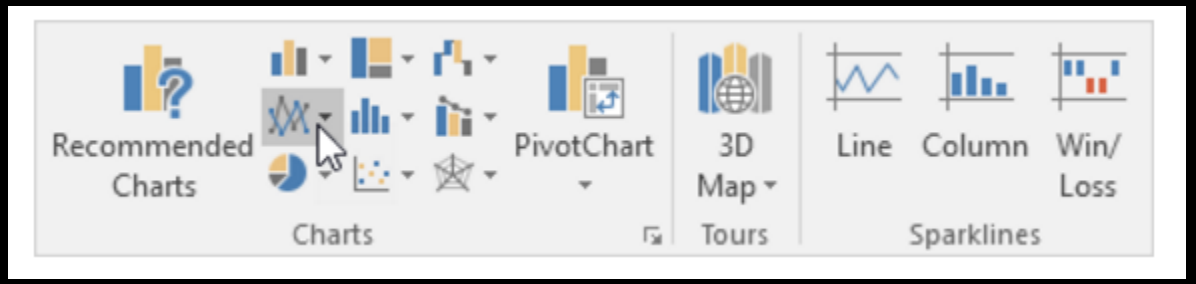

- Create a Chart 建立圖表
- Change Chart Type 圖表類型
- Switch Row/Column 切換欄與列
- Legend Position 圖例的位置
- Data Labels 資料標籤

http://www.excel-easy.com/data-analysis/charts.html

DATA ANALYSIS WITH PYTHON

https://pythonprogramming.net/data-analysis-python-pandas-tutorial-introduction/

DATA VISUALIZATION VIA MATPLOTLIB PLOTTING

- line graphs 折線圖
- scatter plots xy散佈圖
- bar charts 長條圖
- pie charts 圓餅圖
- stack plots 堆疊圖
- 3D graphs
- geographic map graphs

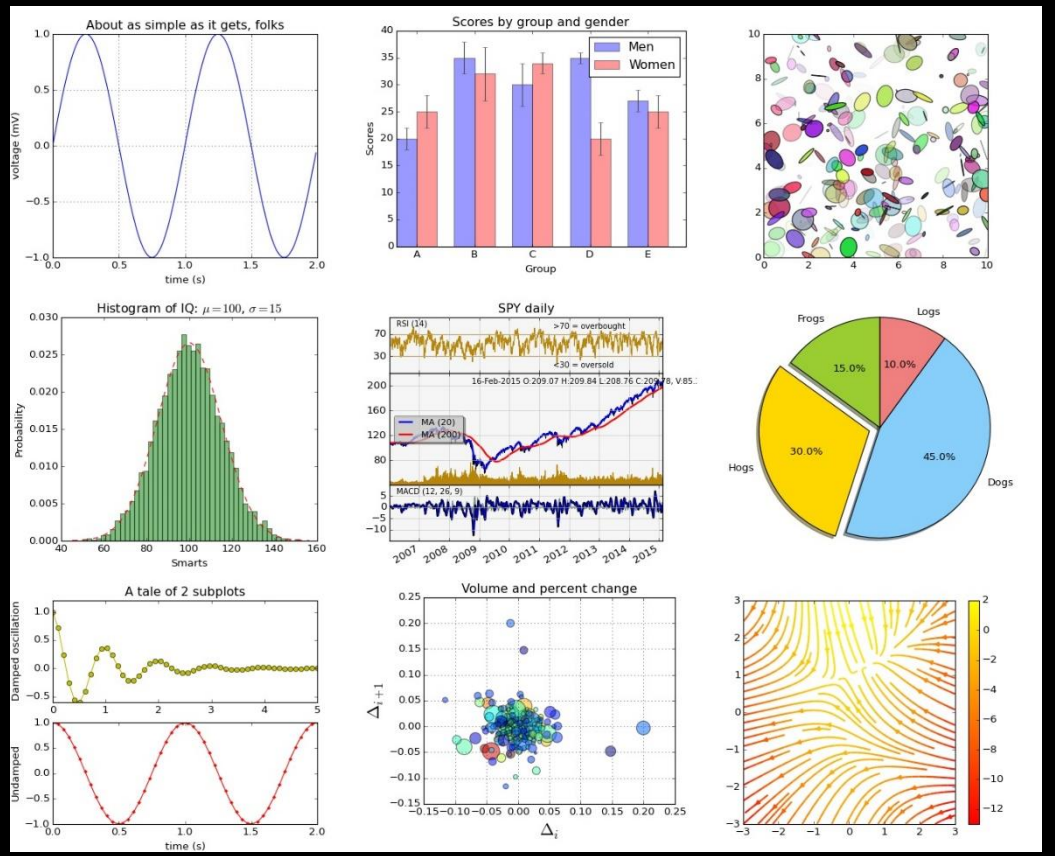

matplotlib

GETTING START-1

- Install **python 3.6.1** https://www.python.org/
  - Optional Features: 選項設定 (**全選**)
  - Advanced Options: 進階選項(**全選**)

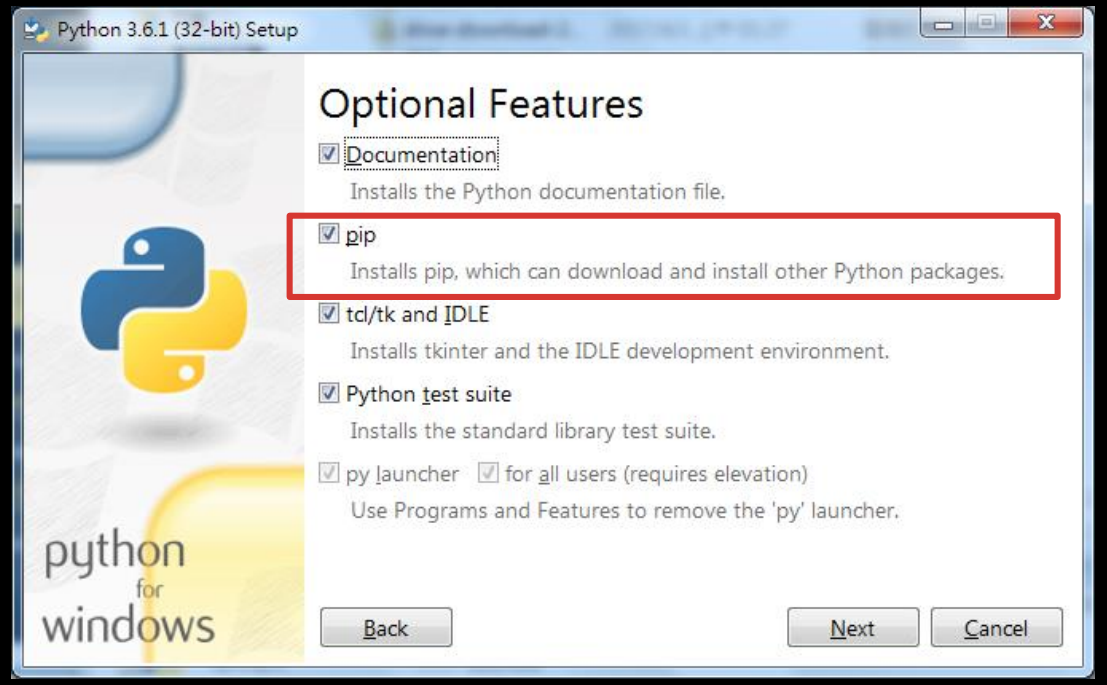

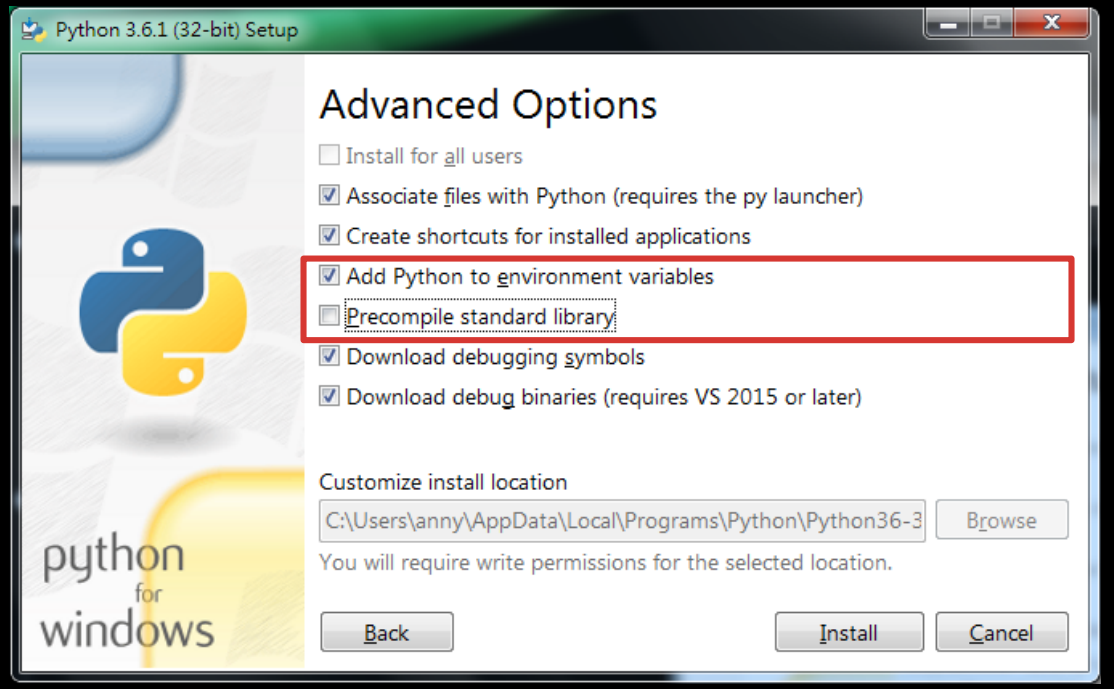

GETTING START-2

- **cmd** (開啟命令提示字元視窗)
- **pip install matplotlib**

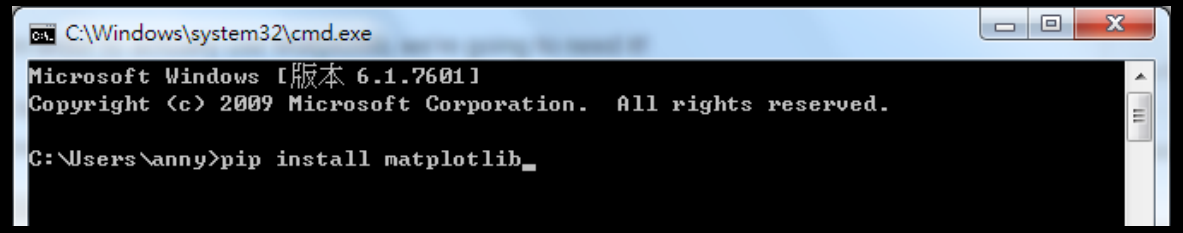

INTRODUCTION TO MATPLOTLIB AND BASIC **LINE**

```
#plot1.py
import matplotlib.pyplot as plt

plt.plot([1,2,3],[5,7,4])
plt.show()
```

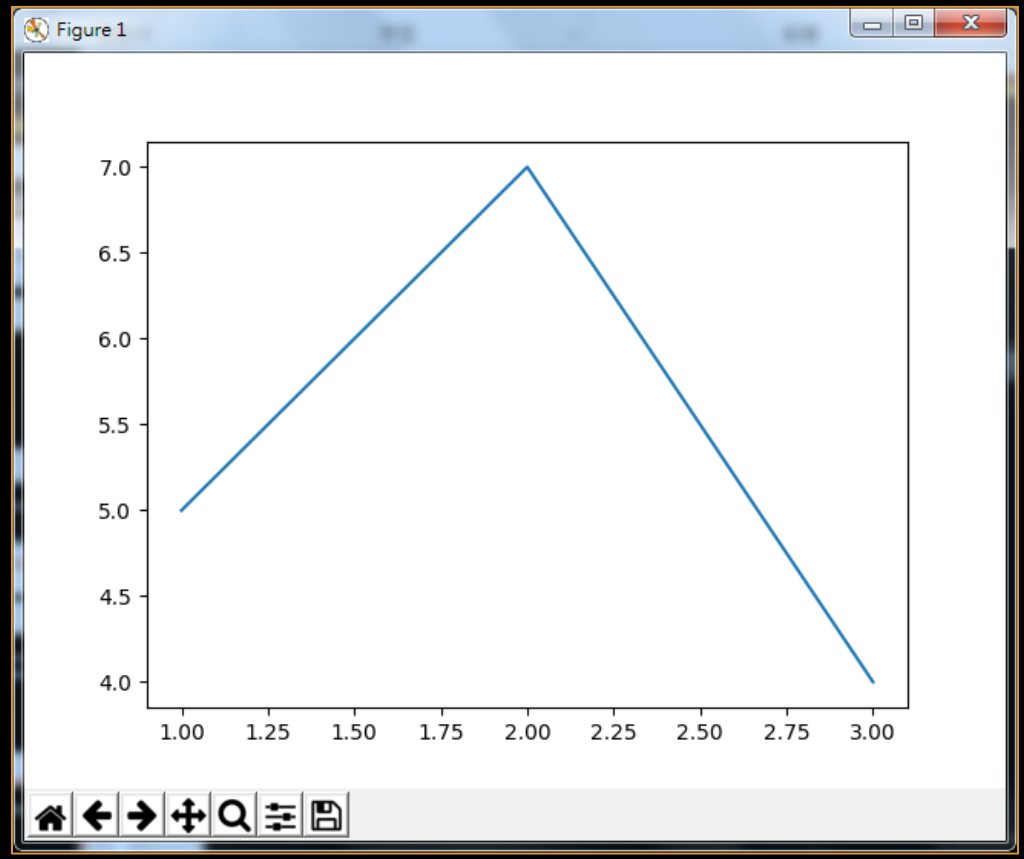

Try1:修改 x,y 的 value list，觀察變化

https://pythonprogramming.net/matplotlib-intro-tutorial/

LEGENDS, TITLES, AND LABELS WITH MATPLOTLIB

```
#plot2.py
import matplotlib.pyplot as plt

x = [1,2,3]
y = [5,7,4]

x2 = [1,2,3]
y2 = [10,14,12]

plt.plot(x, y, label='First Line')
plt.plot(x2, y2, label='Second Line')

plt.xlabel('Plot Number')
plt.ylabel('Important var')
plt.title('Interesting Graph\nCheck it out')
plt.legend()
plt.show()
```

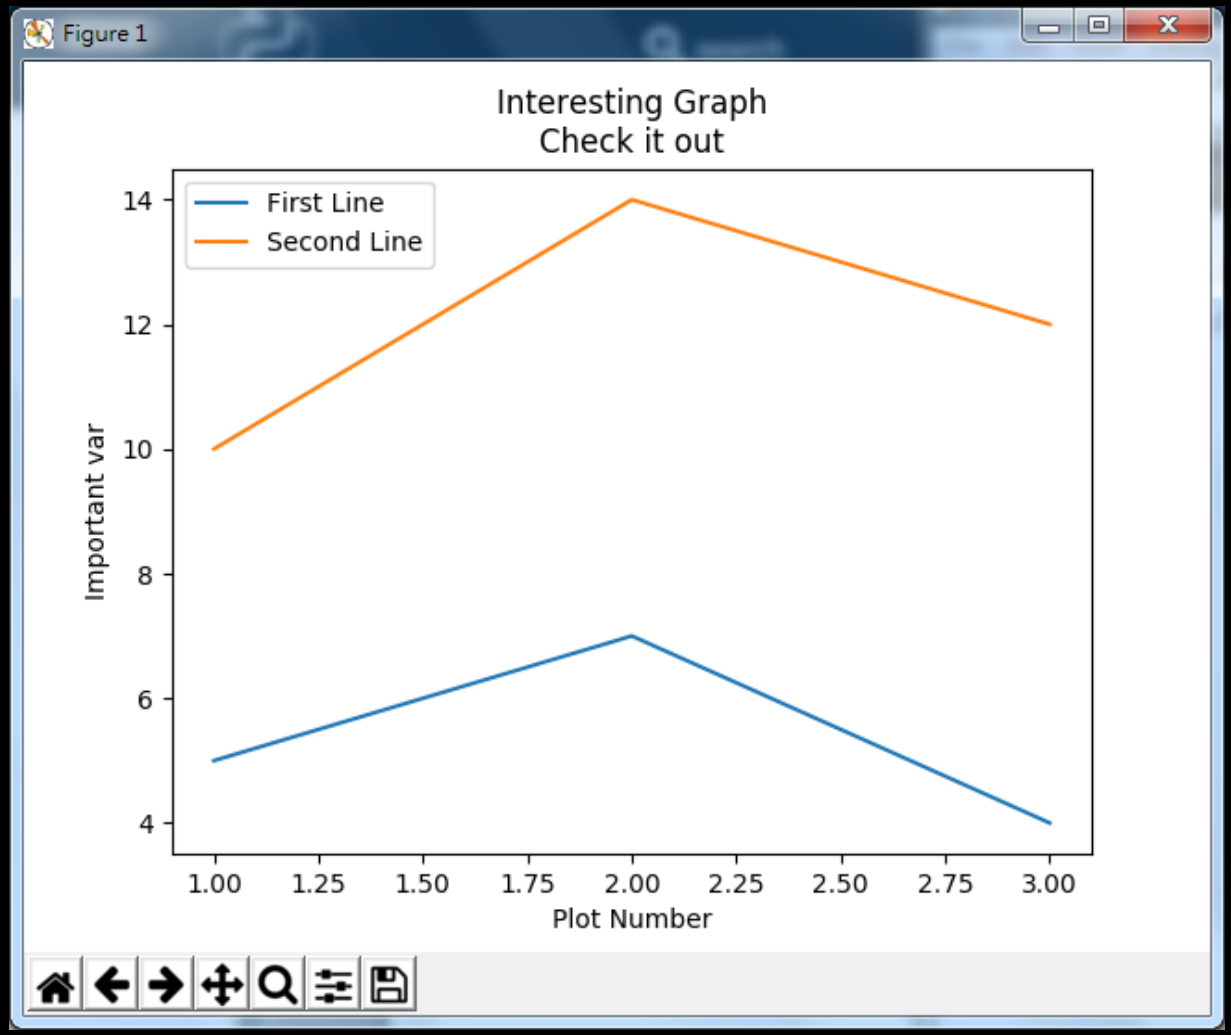

https://pythonprogramming.net/legends-titles-labels-matplotlib-tutorial/?completed=/matplotlib-intro-tutorial/

BAR CHARTS WITH MATPLOTLIB

```
#plot3.py
import matplotlib.pyplot as plt
plt.bar([1,3,5,7,9],[5,2,7,8,2], label="Example one")
plt.bar([2,4,6,8,10],[8,6,2,5,6], label="Example two", color='g')

plt.legend()
plt.xlabel('bar number')
plt.ylabel('bar height')
plt.title('Epic Graph\nAnother Line! Whoa')

plt.show()
```

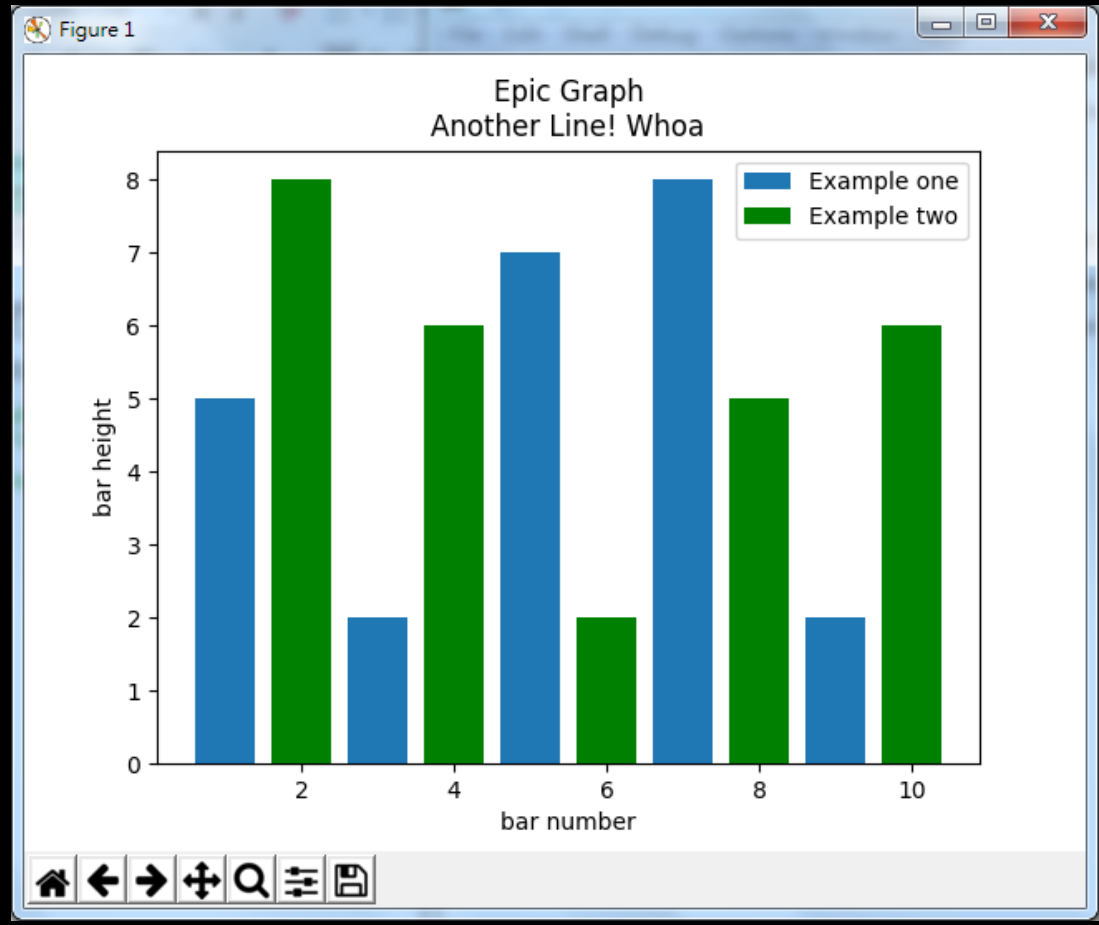

https://pythonprogramming.net/bar-chart-histogram-matplotlib-tutorial/?completed=/legends-titles-labels-matplotlib-tutorial/

HISTOGRAMS WITH MATPLOTLIB

```
#plot4.py
#Histgram
import matplotlib.pyplot as plt

population_ages =
[22,55,62,45,21,22,34,42,42,4,99,102,110,120,121,122,130,11
1,115,112,80,75,65,54,44,43,42,48]

bins = [0,10,20,30,40,50,60,70,80,90,100,110,120,130]

plt.hist(population_ages, bins, histtype='bar', rwidth=0.8)
plt.xlabel('x')
plt.ylabel('y')
plt.title('Interesting Graph\nCheck it out')
plt.legend()

plt.show()
```

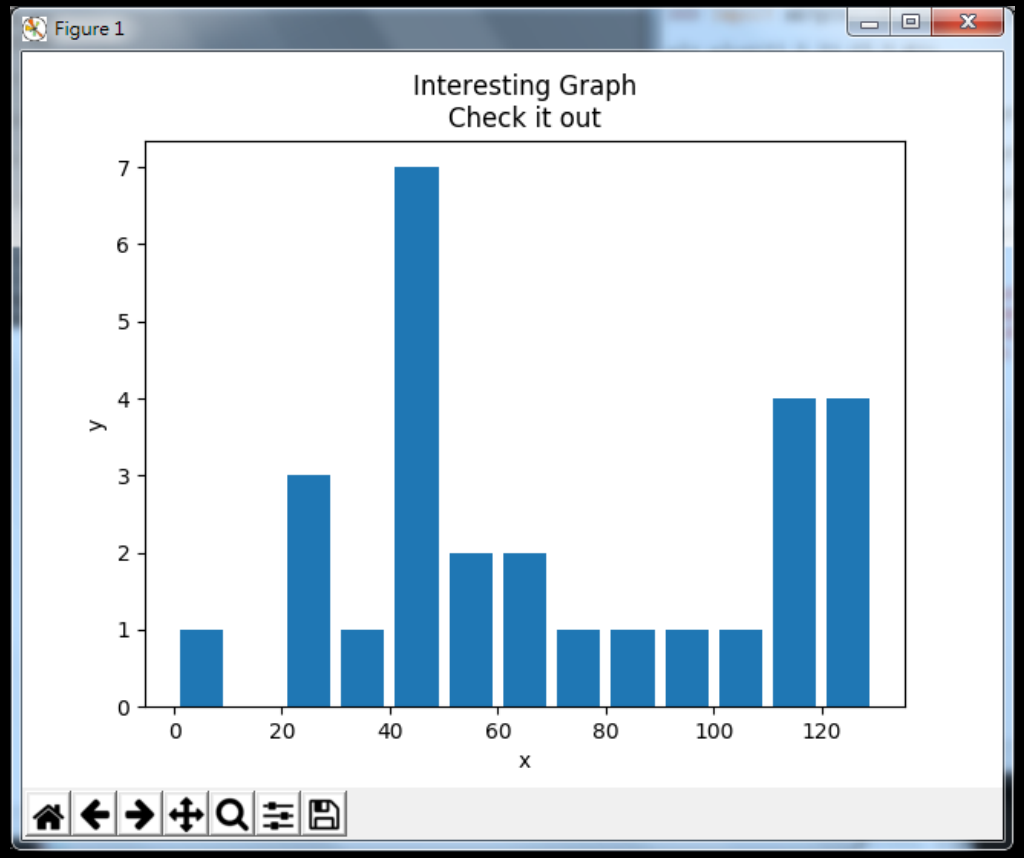

https://pythonprogramming.net/bar-chart-histogram-matplotlib-tutorial/?completed=/legends-titles-labels-matplotlib-tutorial/

SCATTER PLOTS WITH MATPLOTLIB

```
#plot5.py
#Scatter plots

import matplotlib.pyplot as plt

x = [1,2,3,4,5,6,7,8]
y = [5,2,4,2,1,4,5,2]

plt.scatter(x,y, label='skitscat', color='k', s=25, marker="o")

plt.xlabel('x')
plt.ylabel('y')
plt.title('Interesting Graph\nCheck it out')
plt.legend()

plt.show()
```

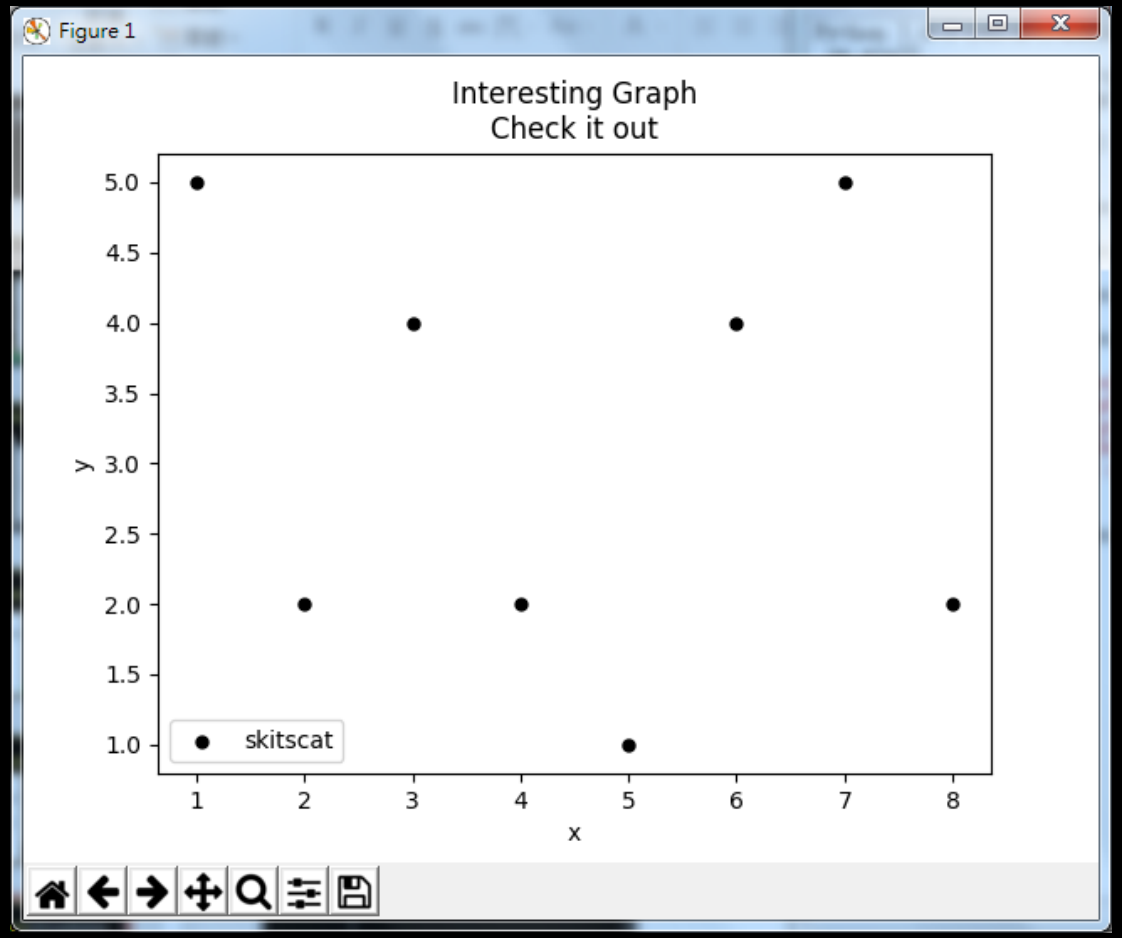

https://pythonprogramming.net/scatter-plot-matplotlib-tutorial/?completed=/bar-chart-histogram-matplotlib-tutorial/

STACK PLOTS WITH MATPLOTLIB

```
#plot6.py
#
i
o
sl
e
w
p
```

```
plt.stackplot(days, sleeping,eating,working,
colors=['m','c','r','k'])


plt.xlabel('x')
plt.ylabel('y')
plt.title('Interesting Graph\nCheck it out')
plt.legend()
plt.show()
```

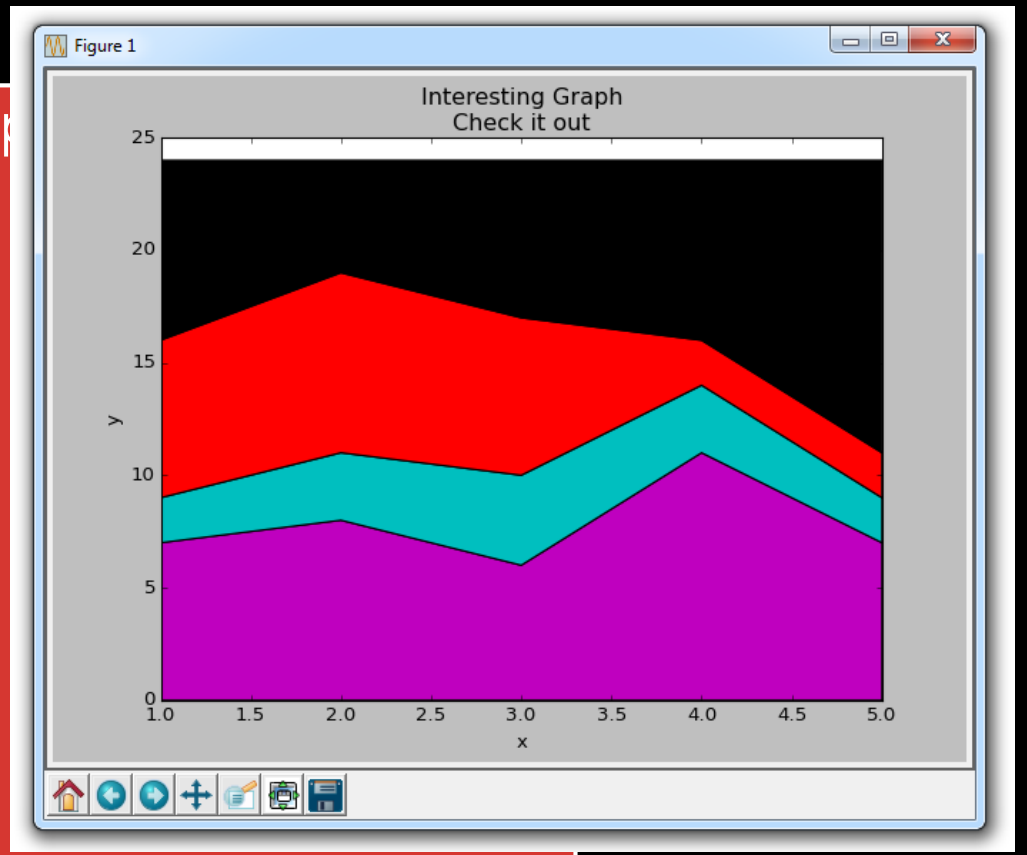

https://pythonprogramming.net/stack-plot-matplotlib-tutorial/?completed=/scatter-plot-matplotlib-tutorial/

STACK PLOTS WITH MATPLOTLIB

```
plt.stackplot(days, sleeping,eating,working,playing,
colors=['m','c','r','k'])


plt.xlabel('x')
plt.ylabel('y')
plt.title('Interesting Graph\nCheck it out')
plt.legend()
plt.show()
```

https://pythonprogramming.net/stack-plot-matplotlib-tutorial/?completed=/scatter-plot-matplotlib-tutorial/

PIE CHARTS WITH MATPLOTLIB

```
#plot7.py
#pie chart

import matplotlib.pyplot as plt

slices = [7,2,2,13]
activities = ['sleeping','eating','working','playing']
cols = ['c','m','r','b']

plt.pie(slices,
        labels=activities,
        colors=cols,
        startangle=90,
        shadow= True,
        explode=(0,0.1,0,0),
        autopct='%1.1f%%')

plt.title('Interesting Graph\nCheck it out')
plt.show()
```

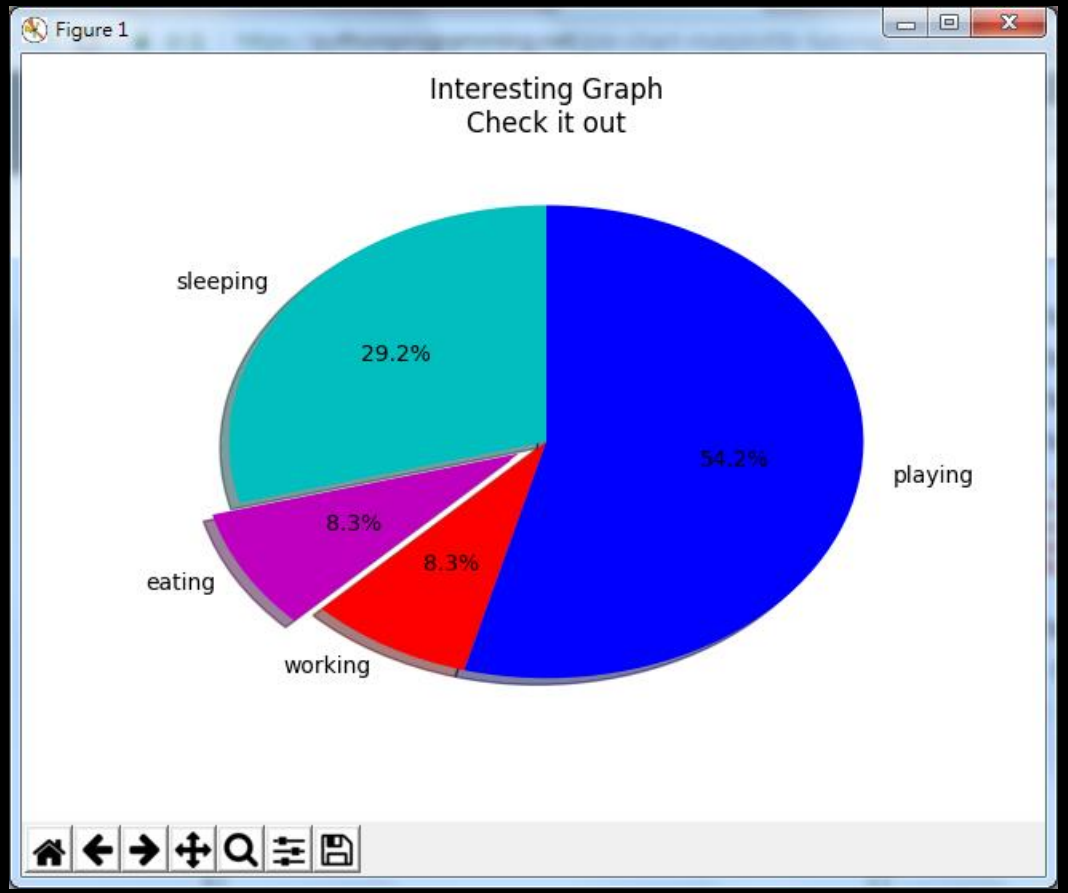

https://pythonprogramming.net/pie-chart-matplotlib-tutorial/?completed=/stack-plot-matplotlib-tutorial/

LOADING DATA FROM FILES FOR MATPLOTLIB

```
#plot8
#loac plt.plot(x,y, label='Loaded from file!')
      plt.xlabel('x')
impor plt.ylabel('y')
impor plt.title('Interesting Graph\nCheck it out')
      plt.legend()
x = []
y = []  plt.show()

with o
    plot
    for r
        x
        y
```

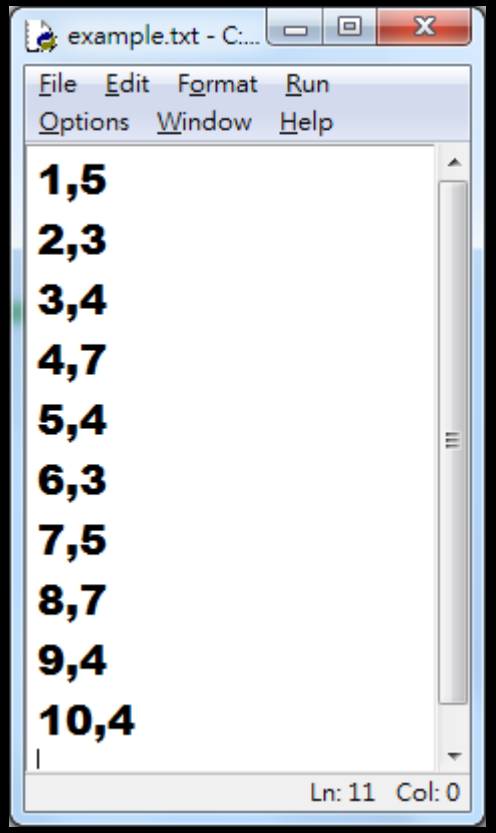

Example.txt

LOADING DATA FROM FILES FOR MATPLOTLIB

plot8_loadFile.py - C:/Users/anny/Desktop/Anny/DataAnalysis/plot8_loadFile.py (3.6.1)

File Edit Format Run Options Window Help

```
#plot8.py
#load data from file

import matplotlib.pyplot as plt
import csv

x = []
y = []

with open('example.txt','r') as csvfile:
    plots = csv.reader(csvfile, delimiter=',')
    for row in plots:
        x.append(int(row[0]))
        y.append(int(row[1]))

plt.plot(x,y, label='Loaded from file!')
plt.xlabel('x')
plt.ylabel('y')
plt.title('Interesting Graph\nCheck it out')
plt.legend()
plt.show()
```

example.txt - C:...

File Edit Format Run Options Window Help

```
1,5
2,3
3,4
4,7
5,4
6,3
7,5
8,7
9,4
10,4
```

Ln: 11 Col: 0

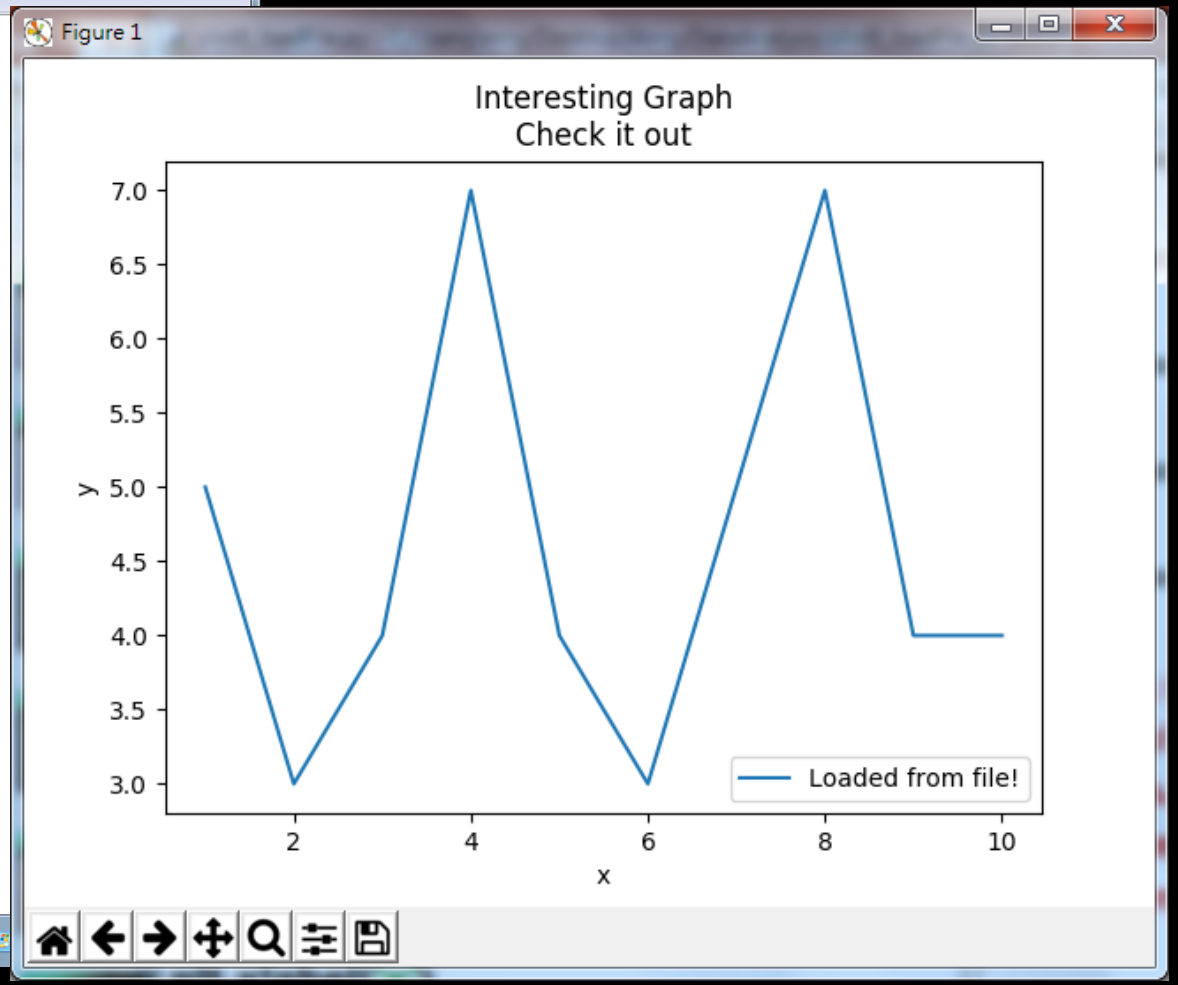

USING THE **NUMPY** MODULE TO LOAD OUR FILES

- **cmd** (開啟命令提示字元視窗)
- **pip install numpy**

NumPy(Numeric Python) 是Python語言的一個擴充程式庫。支援高階大量的維度陣列與矩陣運算，此外也針對陣列運算提供大量的數學函式函式庫。

USING THE **NUMPY** MODULE TO LOAD OUR FILES

plot9_loadFile_numpy.py - C:/Users/anny/Desktop/Anny/DataAnalysis/plot9_loadFile_numpy.py (3.6.1)

File Edit Format Run Options Window Help

```
#plot9
#load file using numpy

import matplotlib.pyplot as plt
import numpy as np

x, y = np.loadtxt('example.txt', delimiter=',', unpack=True)
plt.plot(x,y, label='Loaded from file!')

plt.xlabel('x')
plt.ylabel('y')
plt.title('Interesting Graph\nCheck it out')
plt.legend()
plt.show()
```

Ln: 15 Col: 0

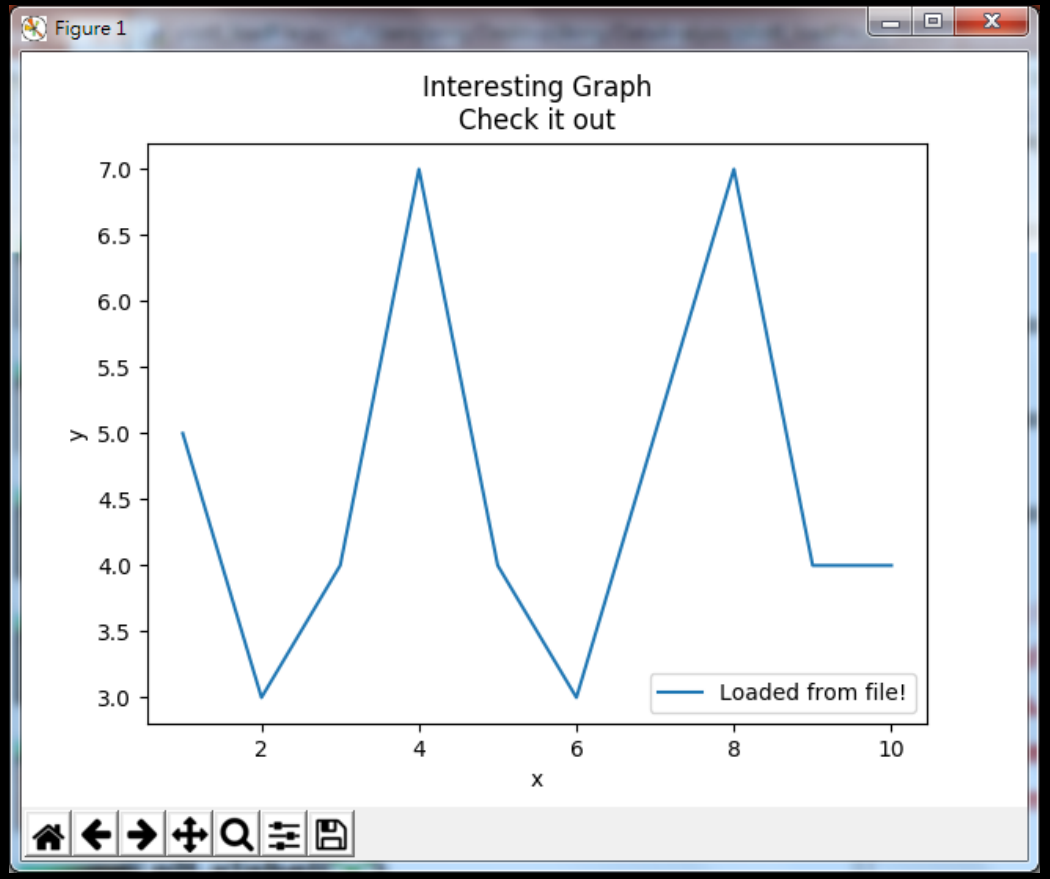

https://pythonprogramming.net/loading-file-data-matplotlib-tutorial/?completed=/pie-chart-matplotlib-tutorial/