Föreläsning 6

CSV-filer, matplotlib.
Genomgång av lektion 8 (intro OU4)

- CSV-filer
- OU4-uppgift A
- Matplotlib
- OU4-uppgift B
- OU4-uppgift C

Läsa csv-data

Python har modulen csv för att läsa och skriva sk csv-data, *comma separated values*. Formatet csv är det vanligaste import- och export-formatet för kalkylblad och databaser. Ex: filen `people.csv`:

Filens innehåll:

```
No, Name, country
1, Alex, USA
2, Erik, Sweden
3, Cheng, China
```

Pythonkod läser csv-filen

=>

och skriver ut innehållet:

```
['No', ' Name', ' country']
['1', ' Alex', ' USA']
['2', ' Erik', ' Sweden']
['3', ' Cheng', ' China']
```

Med följande kod: `readPeoplefile.py`

```
import csv

with open('people.csv', 'r') as csvFile:
    reader = csv.reader(csvFile)
    for row in reader:
        print(row)
```

Öppna filen som en csv-fil för att läsa från. Skapa ett s.k. *reader-objekt* med vilket man kan iterera över varje rad i filen, och returnera ***listor***, en per rad, där elementen är ***strängar***. Elementen separeras med komma.

OU4, uppgift A

Givet är en csv-fil **`CO2Emissions_filtered.csv`** som innehåller data för CO2-utsläppen för 150 st länder under åren 1960 – 2014. Filen finns att ladda ned från kurssidan under lektion 8. Filen går att öppna med exvis med programmet Notepad och den ser då ut så här i början:

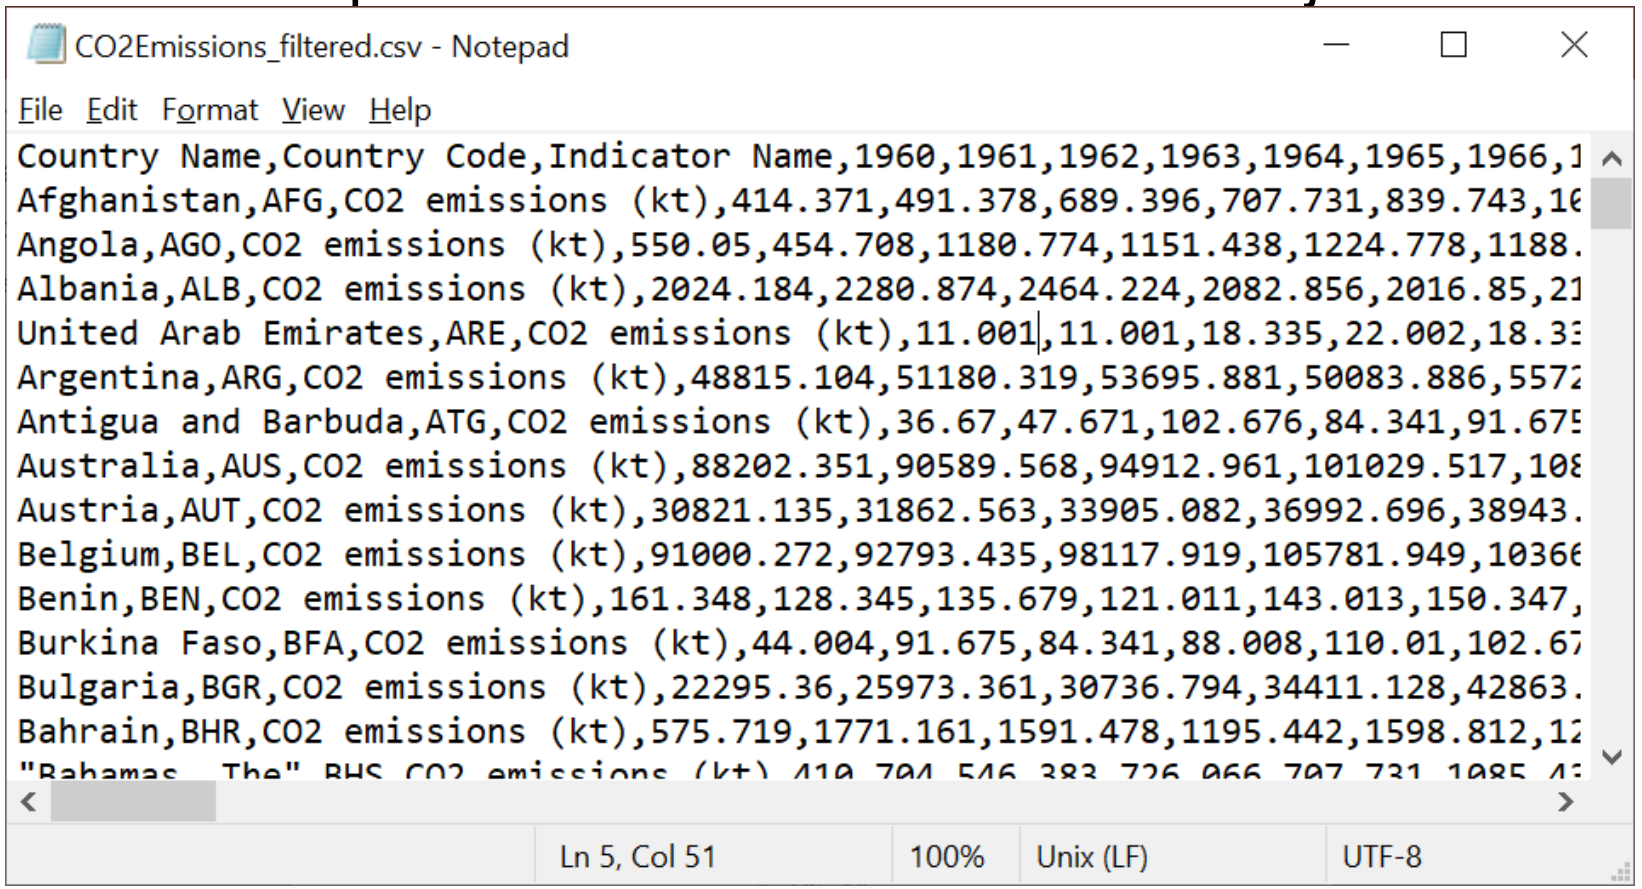

Vi noterar att första raden i filen är en rubrik.

Varje ord i rubriken har motsvarande värde på de andra raderna:

Exempelvis: Country Code → AFG → AGO→ …

Varje land har en landskod, alla CO2-värden för ett land är på en rad.

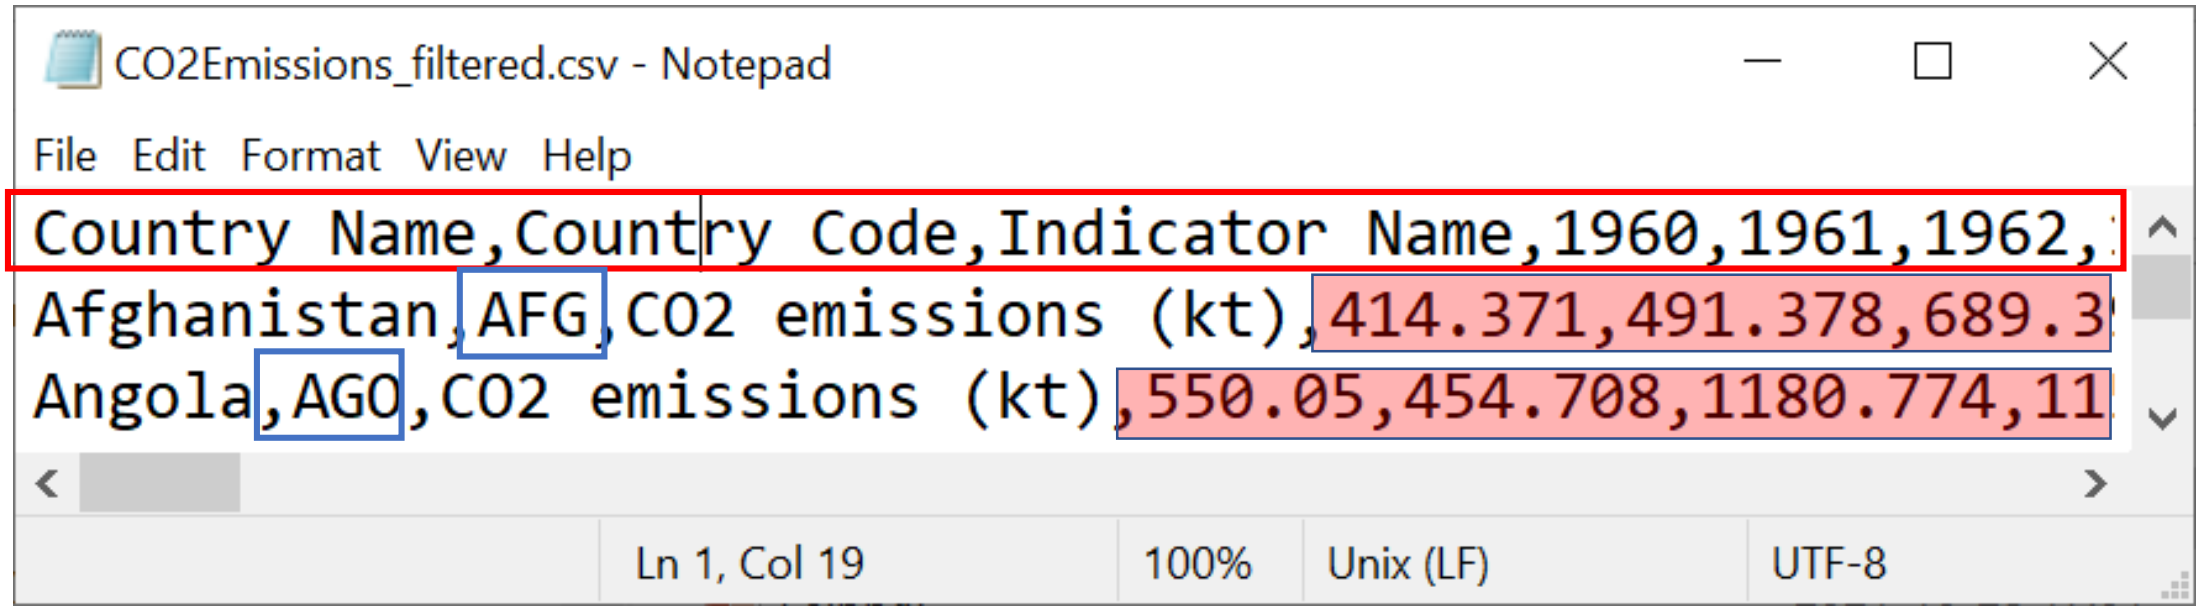

Uppgift A

Skriv en funktion **`load_csv(filename)`** som skapar och returnerar ett lexikon. Nycklarna skall vara landskoder och värdena vara listor med CO2-utsläppen (flyttal) för åren 1960 – 2014:

{AFG: [414.371,491.378, ……..], AGO:[550.05,454.708,…], ALB:[….}

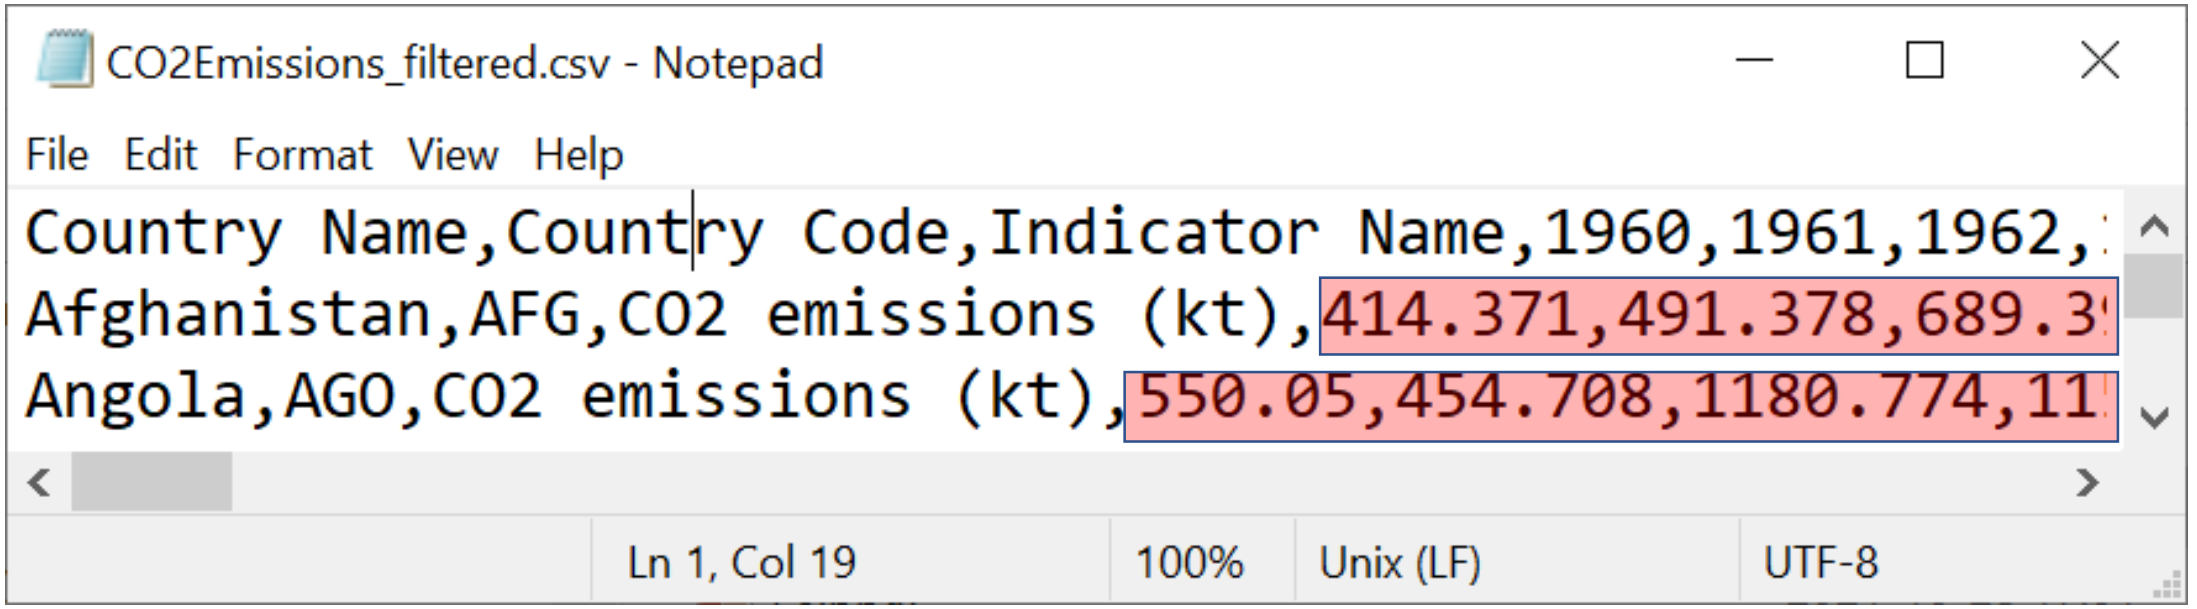

Ett skal (load_csv_skal.txt) till funktionen `load_csv`

Det fattas detaljer som du skall skriva…

```
import csv

def load_csv(filename): # 'CO2Emissions_filtered.csv'
    lex = {}
    with open(filename, 'r') as csvFile: # Öppna filen för läsning
         reader = csv.reader(csvFile)  # Skapa ett s.k. reader-objekt
         for row in reader: # row blir en lista med strängar.

              country_code = ? # Det andra elementet på raden. Alltid?

              data = ? # Gör en lista med alla CO2-data på raden.
                       # Start-kolumn? Alltid? Tips: skivning

              # Lägg in det nya key-value-paret i lex
              …        # ?
    return lex
```

Alternativ:

```
import csv

def load_csv(filename): # 'CO2Emissions_filtered.csv'
    lex = {}
    # Alternativ:
    with open(filename, 'r') as csvFile:
    # Skapa en lista där varje element är en lista med orden
#         rows = list(csv.reader(csvFile))
     …

     return lex
```

Att fundera på:

- Titta på filen `CO2Emissions_filtered.csv`. Finns det "skräp" i datat? (t ex rad 15, 29, 30). Kan programmet hantera att raderna ser olika ut? (Ni får inte ändra i csv-filen).

- Vilken typ har datat?

- Fattas det något steg i algoritmen? Kan läsa enstaka rad med satsen `next(reader)`, dvs iterera ett steg utan att ta hand om resultatet

- `reader`-objektet kan man iterera genom i en loop eller göra om direkt till en lista

- Hur ska man felsöka om programmet krashar?
  Tips: Skriv ej ut hela lexikon. Den innehåller 150 länder.
  Skriv istället ut delar av den om du önskar felsöka…

Datavisualisering med Python: matplotlib

"Matplotlib is a comprehensive library for creating static, animated, and interactive visualizations in Python." https://matplotlib.org/

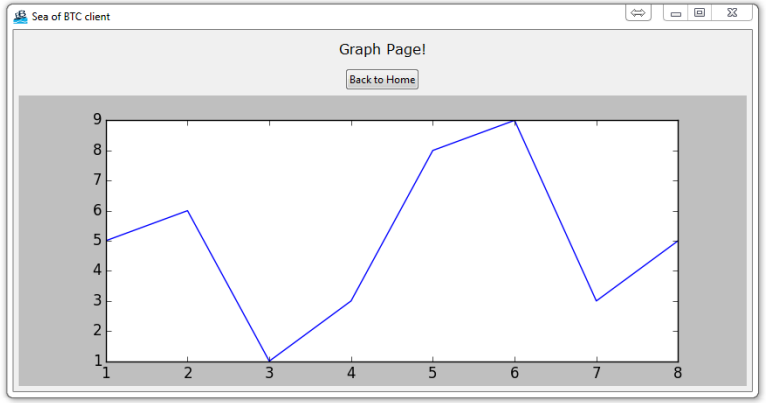

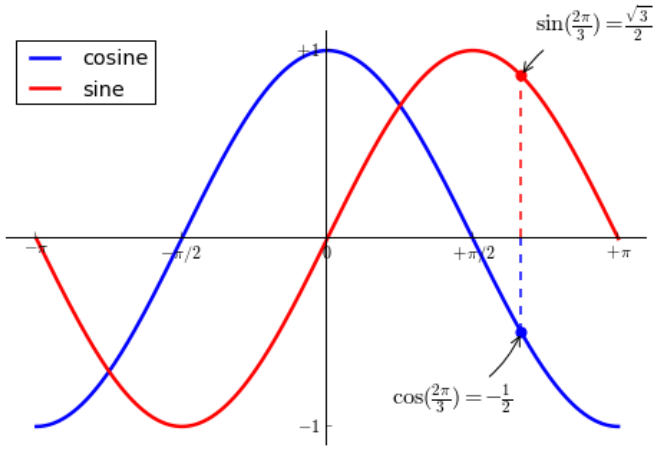

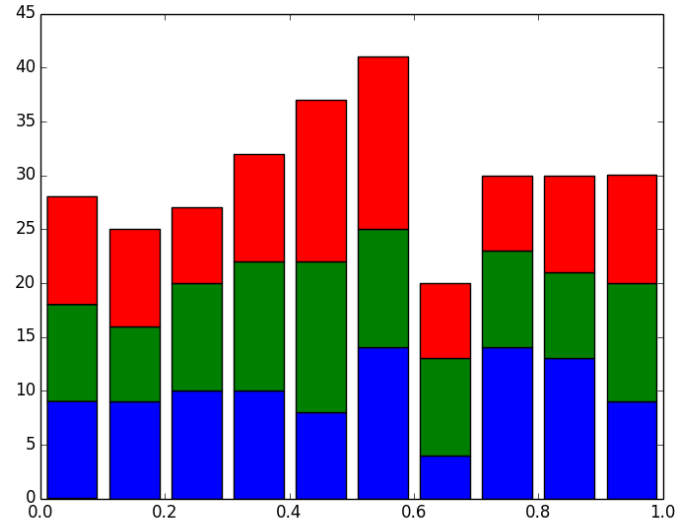

Det här

Det här f

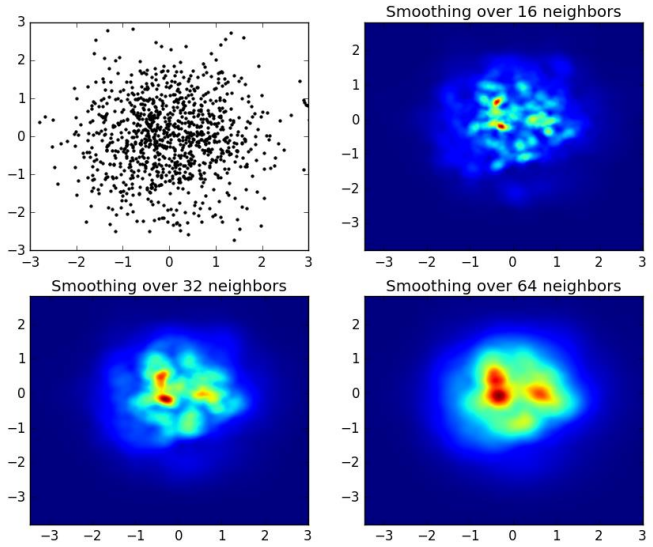

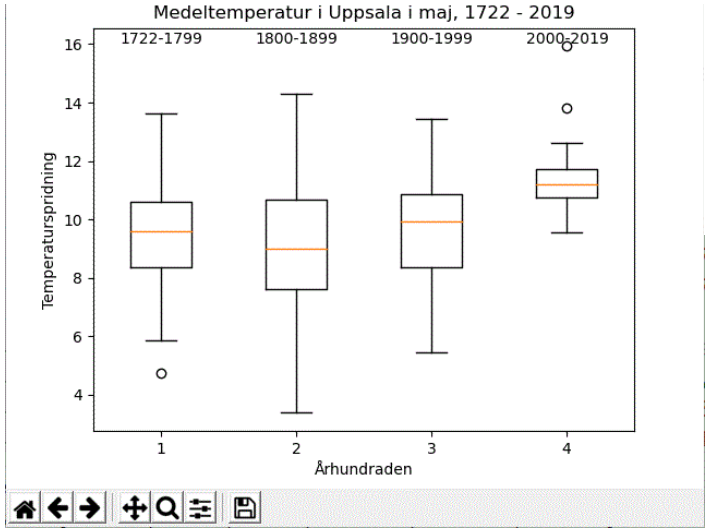

Tips på en tutorial, gör den själva.
https://techvidvan.com/tutorials/matplotlib-tutorial/: Python for Data Visualization.

This tutorial will help you learn about plots, kinds of plot, subplots, labels, and much more.
“Matplotlib is a comprehensive library for creating static, animated, and interactive visualizations in Python.”
***Matplotlib is the most extensively used Data Visualization library in Python programming**. You can generate plots, graphs, bar graphs, scatter graphs, histograms, arrays etc. in a 2D form easily.*

Några exempel

```
import matplotlib.pyplot as plt
# plt blir alias för matplotlib.pyplot
# pyplot är en modul i paketet matplotlib
# matplotlib.pyplot.plot([1,2,3],[1,4,9],"-")  Onödigt långt!
```

```
plt.plot([1,2,3],[1,4,9],"-")
# linje mellan (1,1), (2,4), (3,9)
plt.show()
```

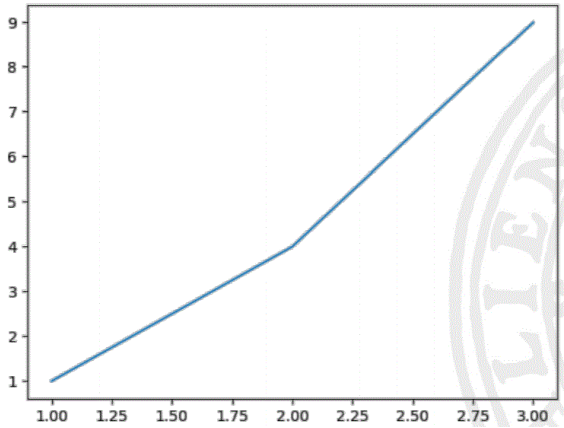


```
plt.plot([1,2,3],[1,4,9], ".")
# ritar punkterna
plt.show()
```

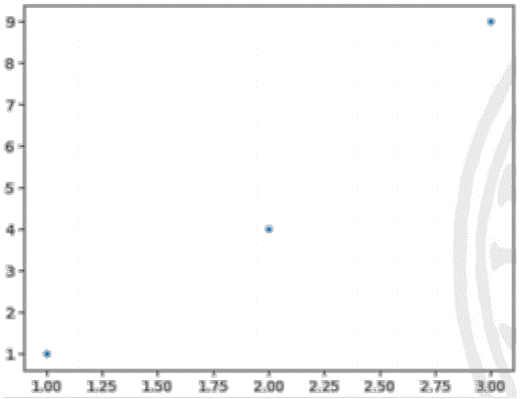

Ex1.py som skapar följande.

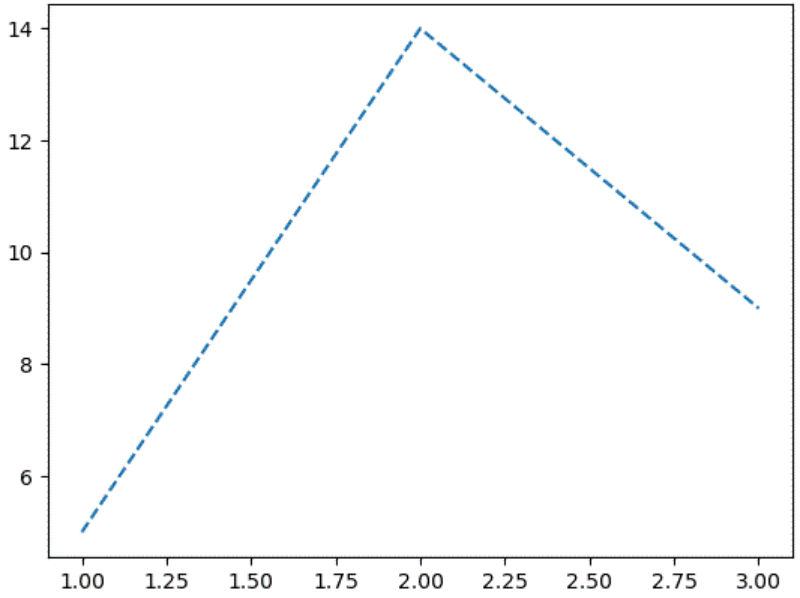

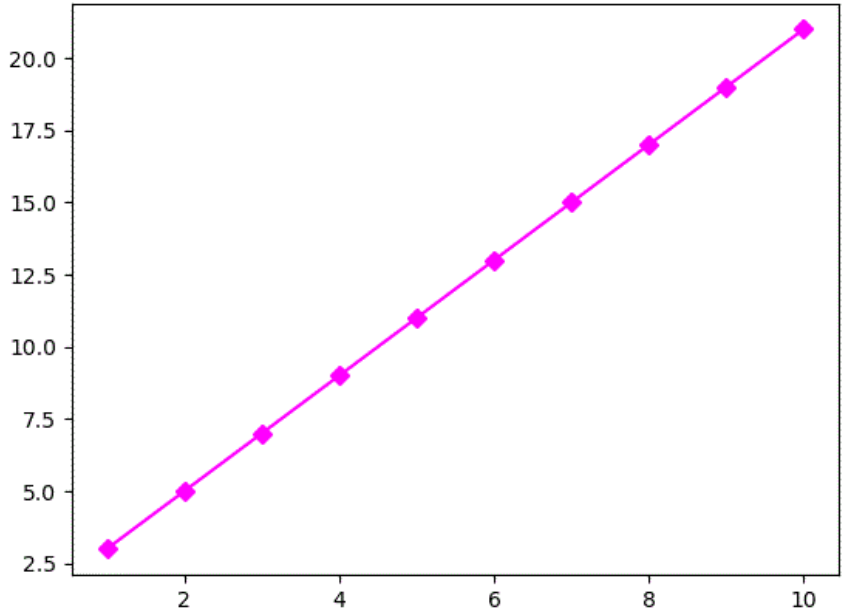

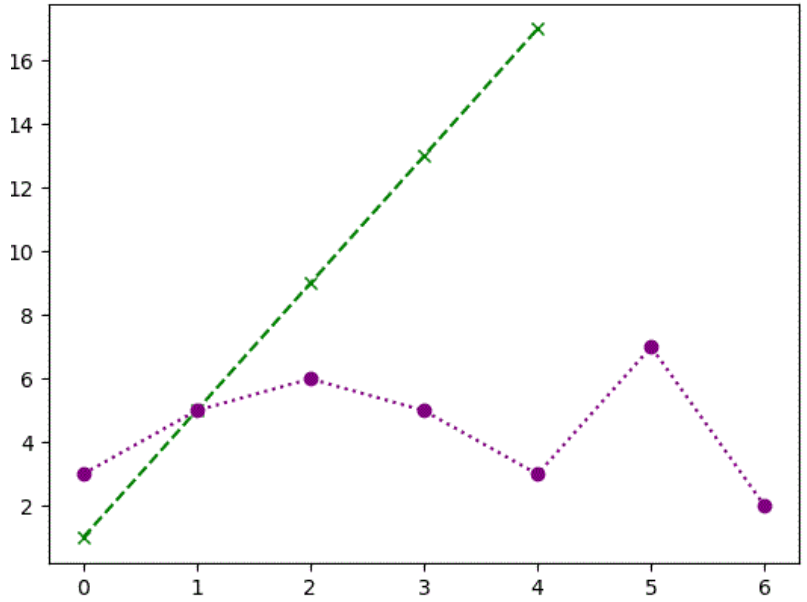

Ex2.py som skapar följande.

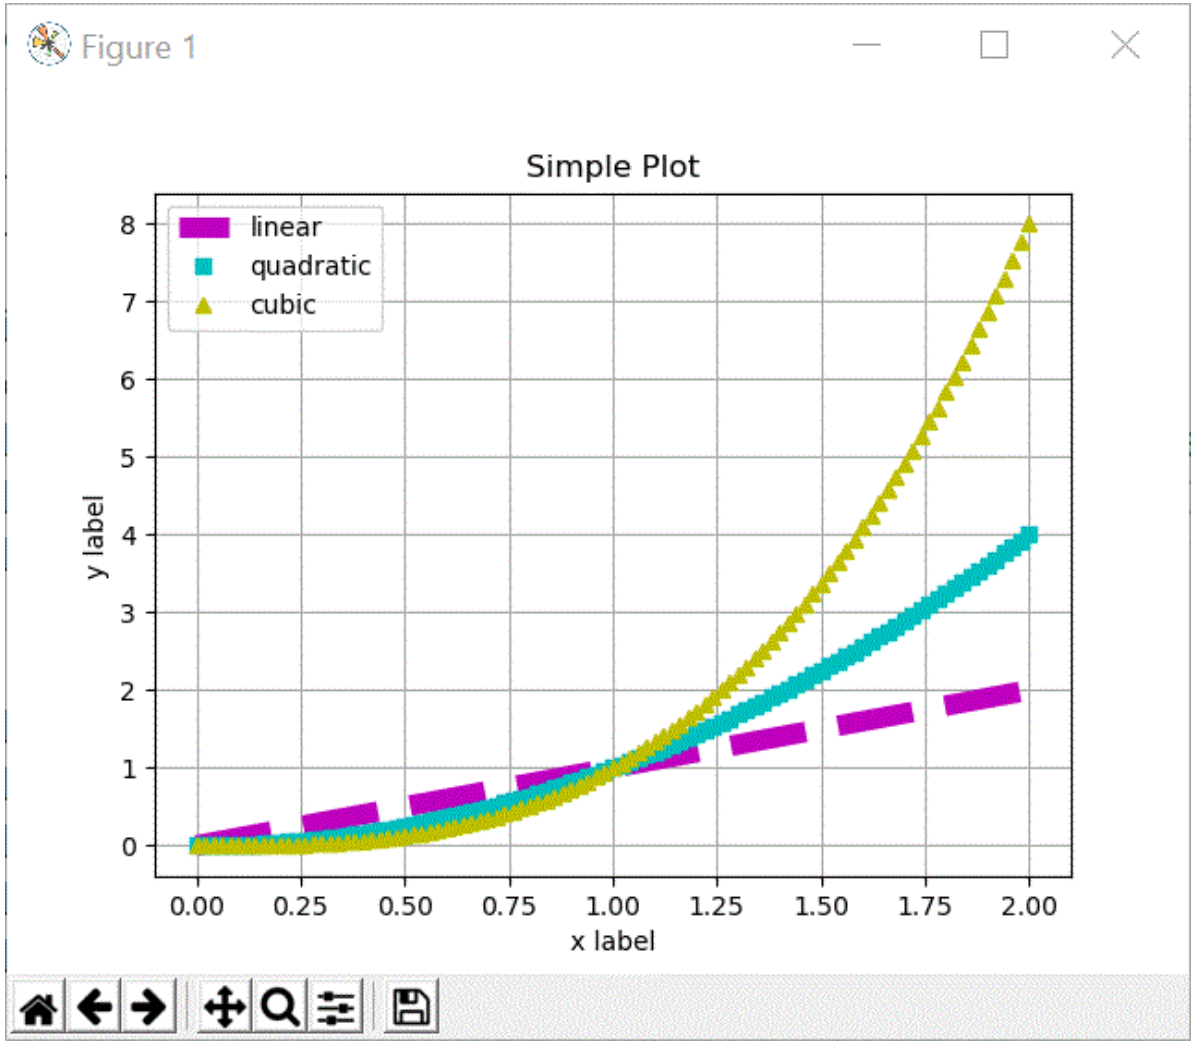

Ex3.py Visar hur man kan plotta flera diagram i samma fönster

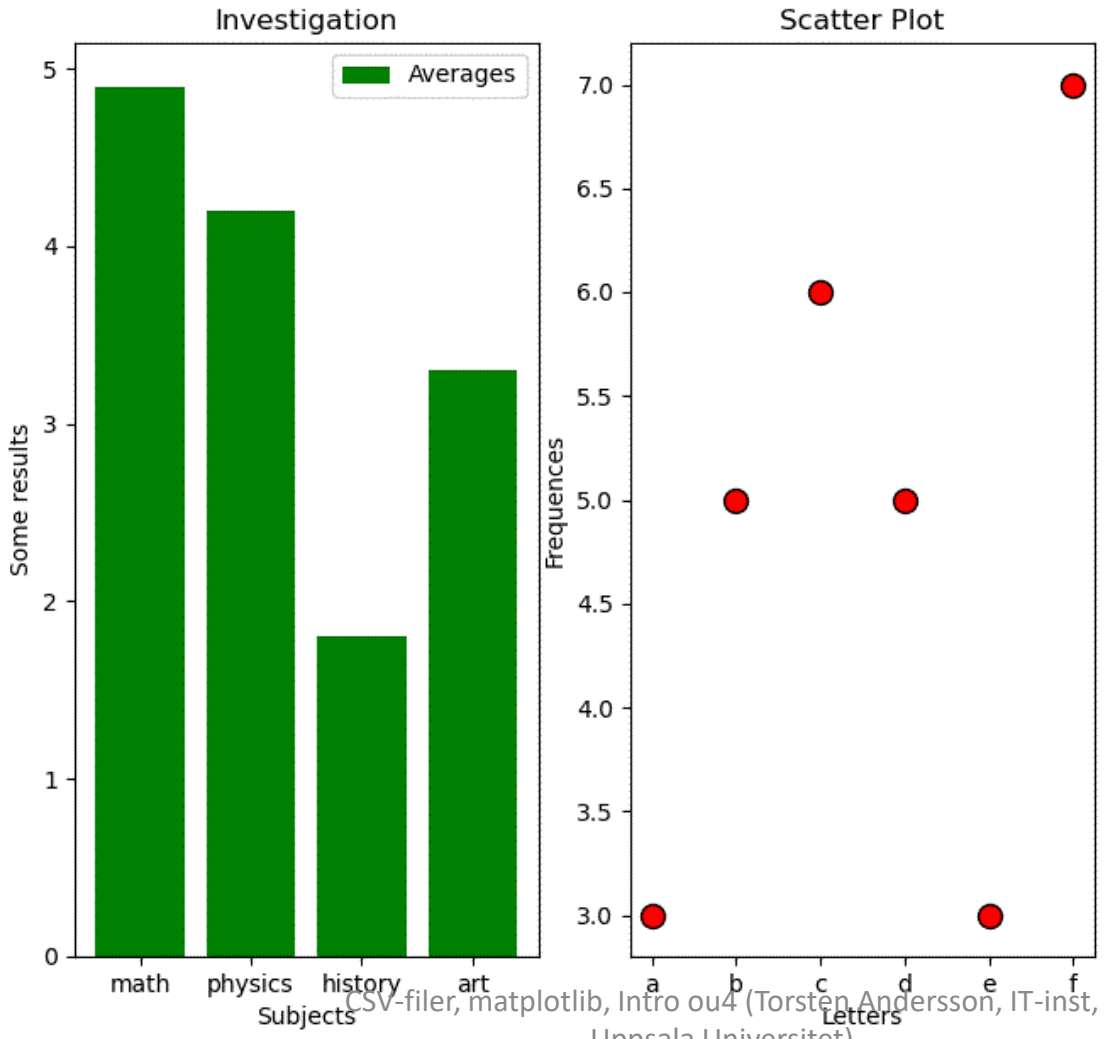

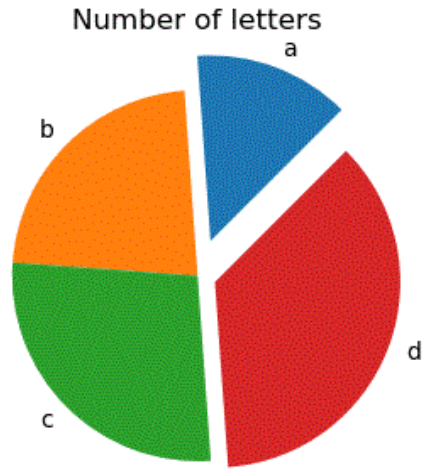

Boxplot (lådadiagram)

```
measures = [-1.2, 1.2, -5.3, -9.9, 0.7, -7.5, 0.4, 2.8,\
2.7, 4.8, 1.3, 1.1, 6.6, 4.2, 5.8, 6.5, 2.4, 3.4, 5.9,\
2.4, -0.9, -1.5, 4.1, 8.3, 7.9, 9.2, 9.9, 6.0]

plt.boxplot(measures)

plt.show()
```

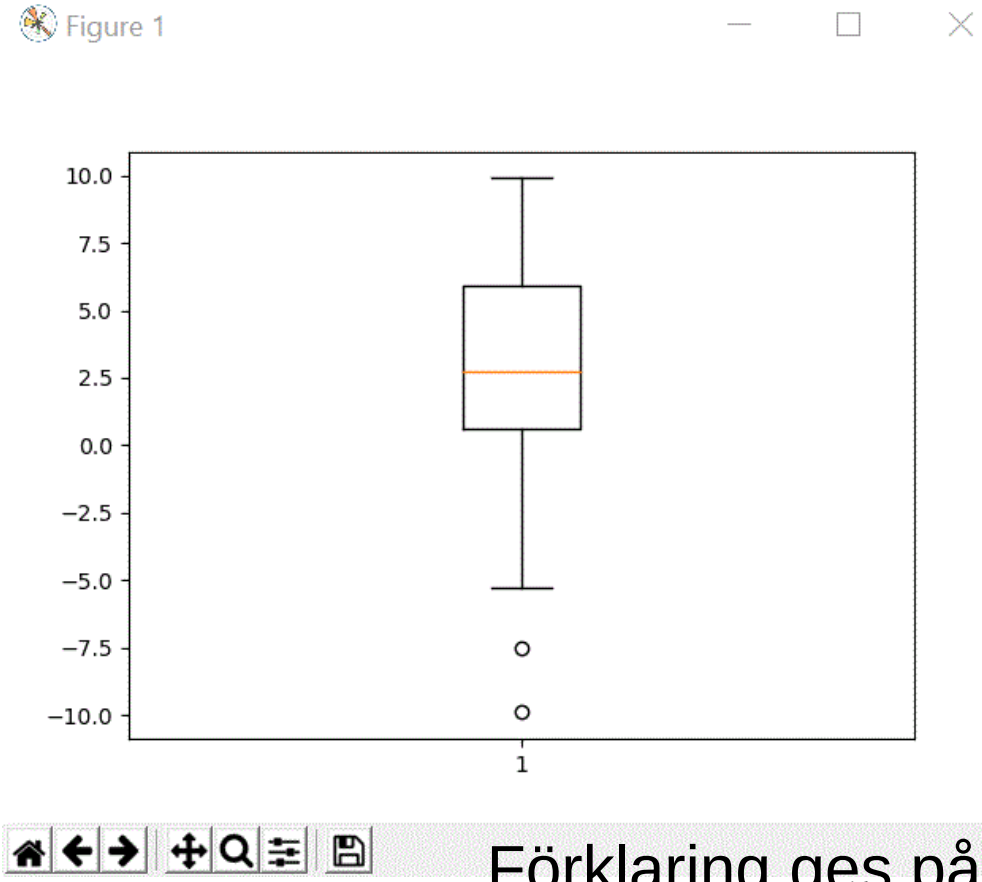

Förklaring ges på nästa sida →

```
measures = [-1.2, 1.2, -5.3, -9.9, 0.7, -7.5, 0.4, 2.8,\
2.7, 4.8, 1.3, 1.1, 6.6, 4.2, 5.8, 6.5, 2.4, 3.4, 5.9,\
2.4, -0.9, -1.5, 4.1, 8.3, 7.9, 9.2, 9.9, 6.0]
```

IQR = Q3-Q1
Interquartile
Range

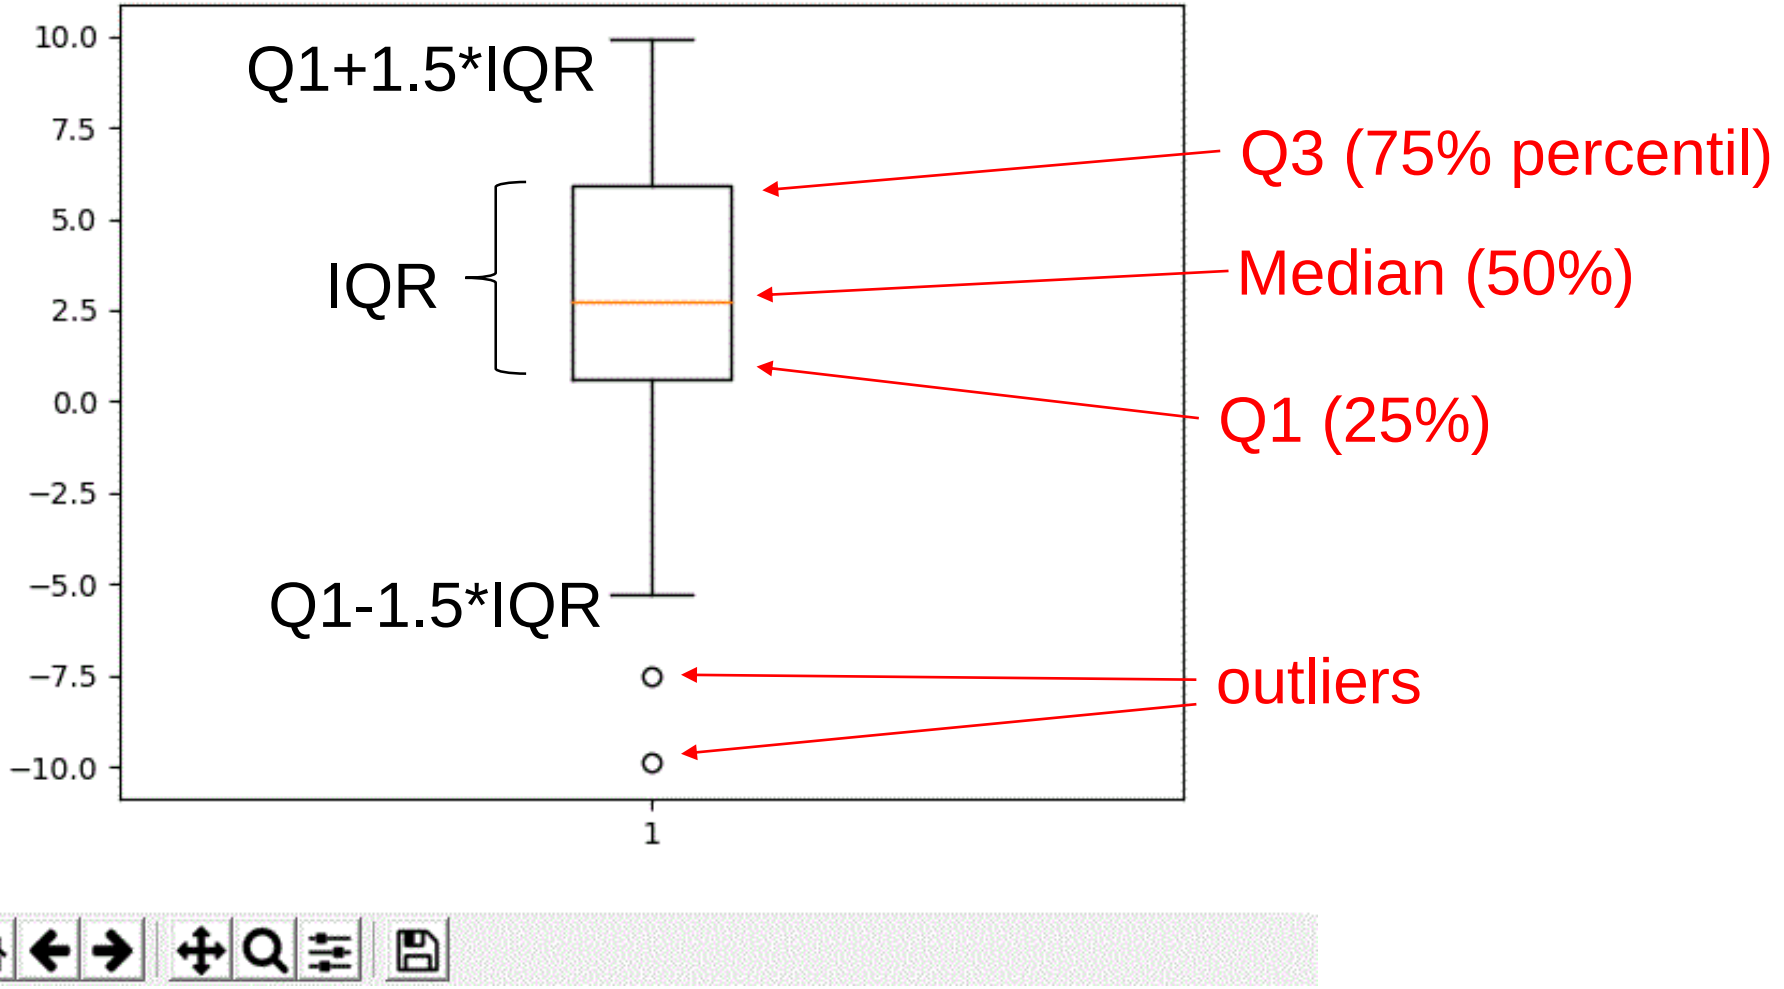

Ex4.py (två boxplot i samma figur)

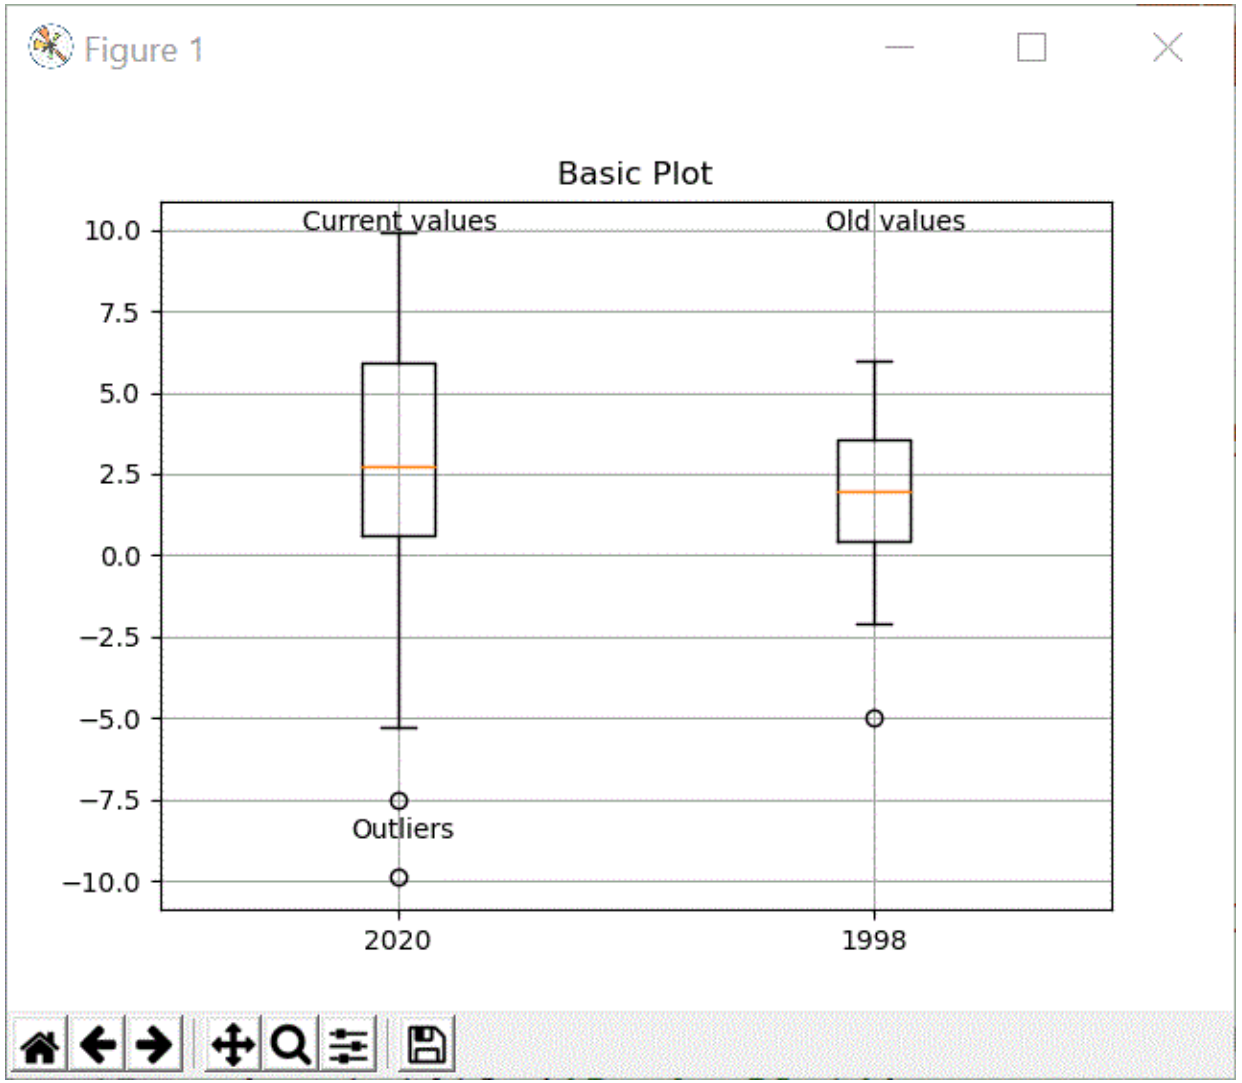

Några viktiga funktioner:

- **`plot()`:** Används för att plotta punkter eller ‘linje’
- **`label`:** Används för att ge namn till graferna
- **`xlabel()`** / **`ylabel()`:** Används för att namnge axlarna (x och y) i grafen.
- **`title()`:** Sätter rubrik på grafen.
- **`annotate()`:** Lägg in text på angivna koordinater
- **`legend()`:** Används för att de label som satts ska visas.
- **`grid()`:** Ger (rut)nät
- **`show()`:** Används för att visa upp hela grafen.

Exempel på olika diagram:

- **`plt.plot(…)`** linjediagram
- **`plt.bar(…)`** stapeldiagram
- **`plt.scatter(…)`** punktdiagram/spridningsdiagram
- **`plt.pie(…)`** cirkeldiagram
- `plt.hist(…)` histogram
- **`plt.boxplot()`** lådagram: median, 1:a och 3:a kvartilen, mm.

OU4, uppgift B

1. Använd funktionen **`load_csv`** från uppgift A och rita med plot-funktionen CO2-utsläppen för Danmark, Finland, Island, Norge och Sverige för åren 1960 till och med 2014. Resultatet blir som den prickade kurvorna nedan, vilka visar sig vara ganska brusiga.
2. Minska bruset genom att (åter)använda funktionen **`smooth_a`** från Lektion 6. Illustrera resultaten från **`smooth_a`** med heldragen kurva och ursprungsdata med prickad kurva, för alla fem länderna.

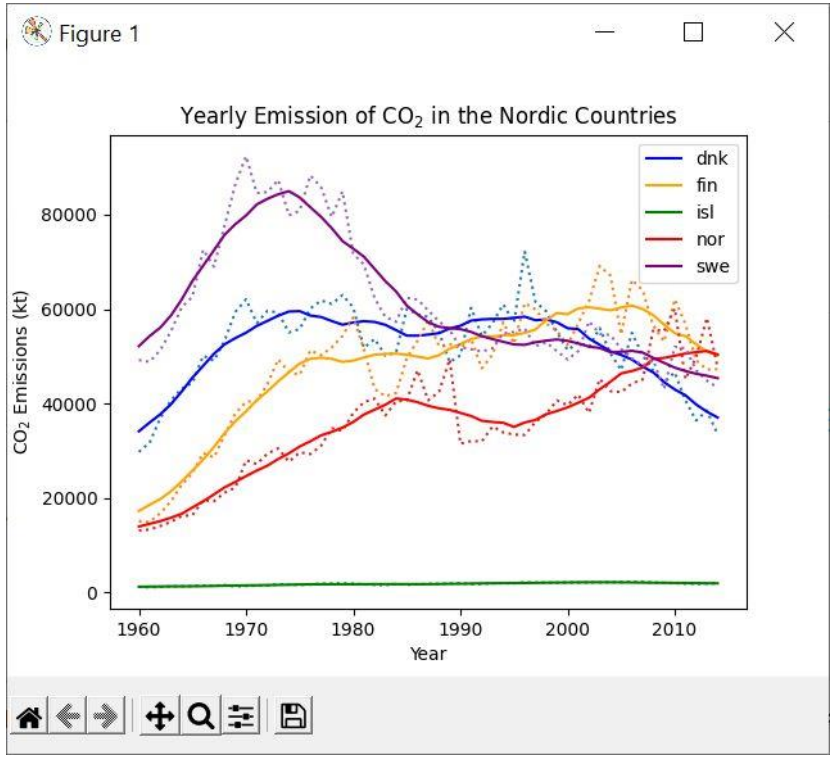

Tio olika dataset, som illusteras med varsin kurva

OU4, uppgift B

FÖRENKLAD ALGORITM, förslag (det fattas detaljer):

```
from filnamnet import load_csv  # importera filen med fkn
```

Gör en lista med landskoderna `'dnk', 'fin', 'isl', 'nor', 'swe'`

Anropa **`load_csv`** → returnerar ett lexikon:

```
{AFG: [414.371,491.378,……..],AGO:[550.05,454.708,…],ALB:[….}
```

Loopa igenom lexikonet:

är det landskoden för ett nordiskt land? spara i så fall data i ett nytt lexikon

```
time = list(range(1960, 2015)) # Skapa en lista [1960, …]
fig, ax = plt.subplots() # skapar figurens ram.
```

Loopa igenom nya lexikonet. För varje värdepar:

```
ax.plot(…) # Vad ska vara på x-axeln och vad på y-axeln?
           # Se uppgiften
  ax.plot(…) # använd smooth_a
  …
```

OU4, uppgift C

Rita upp lådagram (boxplot) för maj månads medeltemperaturer för Uppsala uppdelat på 1700-, 1800-, 1900- och 2000-talen. Hämta data från textfilen **`uppsala_tm_1722-2019.dat`** från kurswebben, lektion 8. (***OBS! Inte csv-fil***).

Förslag: Beräkna, spara i listor, dvs

[*medeltemp maj 1722, medeltemp maj 1723, ….,medeltemp maj 1799*]

```
list_average_per_year_1700=[9.8, 8.7, … , 10.1] # för hela 1700-talet
list_century.append(list_ average_per_year_1700)
```

Filen uppsala_tm_1722-2021.dat:

```
1722  4 27   4.8   4.4 1
1722  4 28   4.8   4.4 1
1722  4 29   5.7   5.3 1
1722  4 30   5.7   5.3 1
1722  5  1   4.6   4.2 1
1722  5  2   3.9   3.5 1
1722  5  3   5.0   4.6 1
1722  5  4   5.6   5.2 1
1722  5  5   6.1   5.7 1
1722  5  6   9.0   8.6 1
1722  5  7   9.8   9.5 1
1722  5  8  11.7  11.4 1
1722  5  9  12.4  12.1 1
1722  5 10  12.3  12.0 1
```

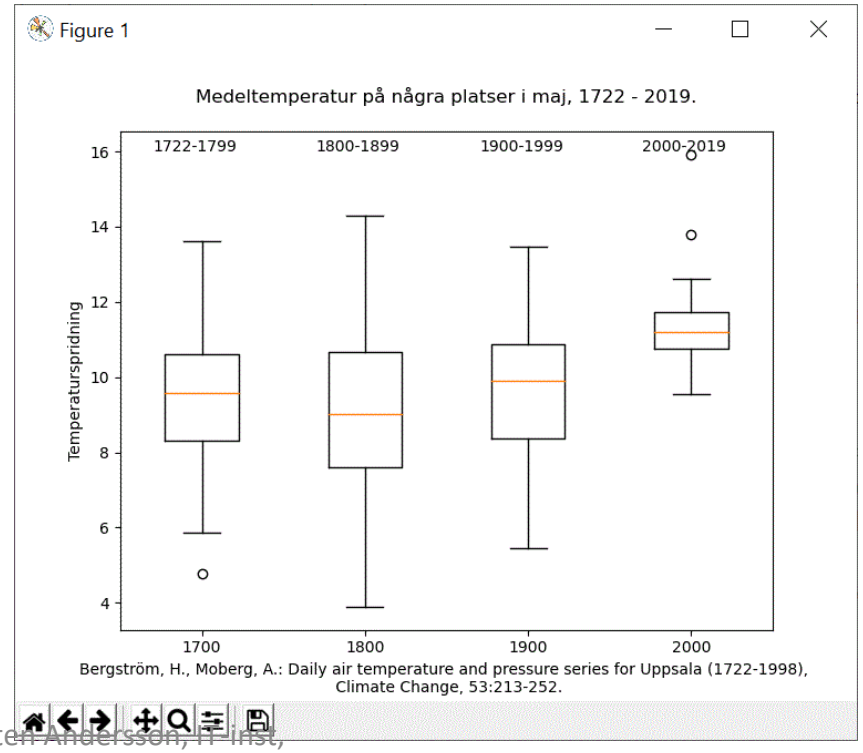

OU4, uppgift C

1. Öppna filen **`uppsala_tm_1722-2019.dat`** för läsning (inte en csv-fil)
2. För varje rad i filen:

   ta bort mellanslag - ta bara med decimaltal. Använd reguljära uttryck eller split()-funktionen.

   lägg raden i en lista
3. För varje rad i listan med alla data:

   summera temperaturerna i kolumn 4 för maj månad
4. Beräkna medeltemperaturen.
5. Spara i en lista
6. Rita upp

Det fattas saker i algoritmen….

Obs! Nu finns data till och med år 2022 i filen

FÖRENKLAD ’ALGORITM’, ett förslag (det fattas detaljer):

```
import matplotlib.pyplot as plt, (re)

# Läs filens data och lagra i en lämplig variabel
all_text = [] #Filens innehåll ska sparas i en lista
with open('uppsala_tm_1722-2019.dat', 'r') as infil:
    # Gör varje rad till en lista utan extra mellanslag:
    for line in infil:
        # ta ut alla decimaltal) # eller .split()
        line_text = ?
        …     # Lägg in line_text i all_text
```

Forts nästa sida→

```
this_year = int(all_text[0][0]) # börjar år 1722
year_average_temp=[]
# Spara medeltemp per år för maj under ETT århundrade
century_average_temp = []
# Spara en lista per århundrade - blir 4 listor
#loopa över all_text:
    #om det är maj this_year:
       sum_temp += float(row[3]) #summera temperaturen i maj det året
    # Nytt år?
    # Lägg in (sum_temp/31) i year_average_temp,
    # dvs medeltemp 1722, 1723, … 1799
    # Nytt århundrade?
    # Spara listan i fyra århundradelistan century_average_temp

    # Glöm inte 2000-talet!

# Rita upp de 4 listorna som ligger i århundradelistan som lådagram
```

Forts nästa sida→

Glöm inte att erkänna upphovsmakarna, se text i filen `uppsala_tm_1722-2019` genom att lägga en lämplig text i plotten.