ETH zürich

Übungslektion 4 – Arbeiten mit Daten

Informatik II

11. / 12. März 2025

Heutiges Programm

Matplotlib

Pandas

Hausaufgaben

1. Matplotlib

Matplotlib: Liniendiagramm

```
import matplotlib.pyplot as plt

X = range(1, 9)
Y = [1, 2, 3, 1, 2, 3, 1, 2]

fig = plt.figure()
ax = fig.add_subplot()

ax.plot(X, Y)
plt.show()
```

normaler graph

fügt Achse zu Figure hinzu

! wichtig

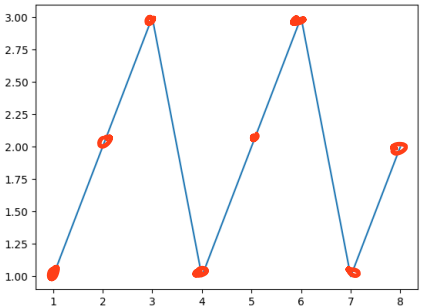

Matplotlib: Streudiagramm

```
import matplotlib.pyplot as plt

X = range(1, 9)
Y = [1, 2, 3, 1, 2, 3, 1, 2]

fig = plt.figure()
ax = fig.add_subplot()

ax.scatter(X, Y)
plt.show()
```

type

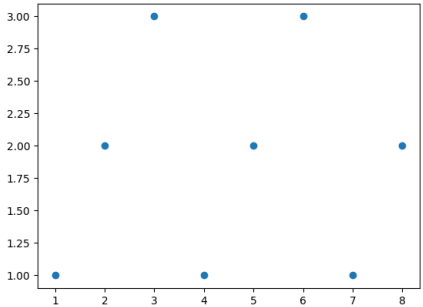

Matplotlib: Farbe und Marker

```
import matplotlib.pyplot as plt

X = range(1, 9)
Y = [1, 2, 3, 1, 2, 3, 1, 2]

fig = plt.figure()
ax = fig.add_subplot()

cols = ["red" if y == 2 else "blue" for y in Y]
ax.scatter(X, Y, marker = "x", c = cols)
plt.show()
```

specify

type von Zeichen

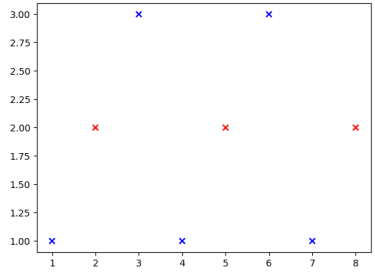

Matplotlib: Beschriftung, Titel, Legende

```
import matplotlib.pyplot as plt
X = range(1, 9)
Y = [1, 2, 3, 1, 2, 3, 1, 2]
fig = plt.figure()
ax = fig.add_subplot()
cols = ["red" if y == 2 else "blue" for y in Y]
ax.scatter(X, Y, marker = "x", c = cols, label="scatter")
ax.set_xlabel('X label') # add an x-label to the X axes
ax.set_ylabel('Y label') # add a y-label to the Y axes
ax.set_title("Scatter Plot") # add a title
ax.legend() # add a legend
plt.show()
```

can change label

// Label

titel

Matplotlib: Beschriftung, Titel, Legende

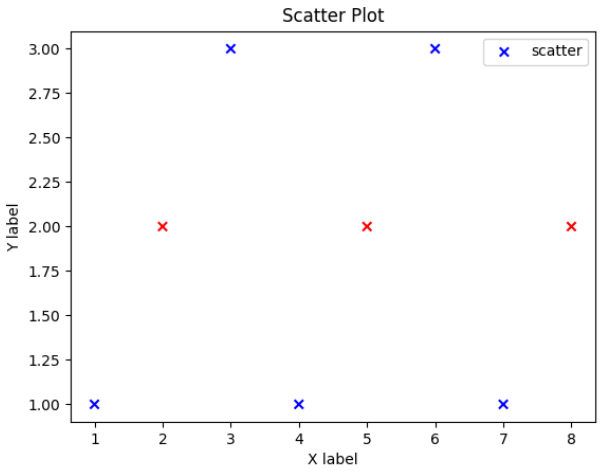

Matplotlib: Mehrere Plots

```
import matplotlib.pyplot as plt
import numpy as np
X = np.linspace(0, 2, 100)
fig = plt.figure()
ax = fig.add_subplot()
ax.plot(X, X, label='linear') # plot a linear line.
ax.plot(X, X**2, label='quadratic') # plot a quadratic line.
ax.plot(X, X**3, label='cubic') # plot a cubic line.
ax.set_xlabel('X label')
ax.set_ylabel('Y label')
ax.set_title("Multiple Plots")
ax.legend()
plt.show()
```

Matplotlib: Mehrere Plots

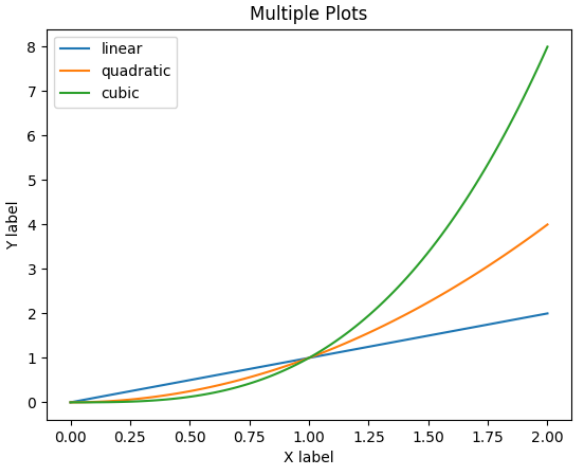

Matplotlib: Zeichnen Sie eine Funktion

→ Good for Lab Report!

```
import matplotlib.pyplot as plt
import numpy as np
fig = plt.figure()
ax = fig.add_subplot()

X = np.linspace(0, 2*np.pi, 100)
Y = np.sin(X)
ax.plot(X, Y)

Z = Y + np.random.normal(0, 0.1, 100)
ax.plot(X, Z, "rx") # "rx" means red color and x marker
plt.show()
```

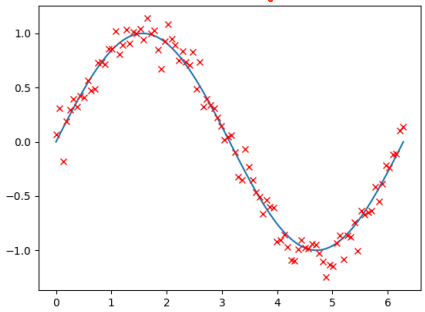

Matplotlib: Histogrammdiagramm

```
import matplotlib.pyplot as plt
import numpy as np
fig = plt.figure()
ax = fig.add_subplot()

X = np.random.randint(0, 100, 500)
# low: 0, high: 100, size: 500
ax.hist(X, bins=10)
plt.show()
```

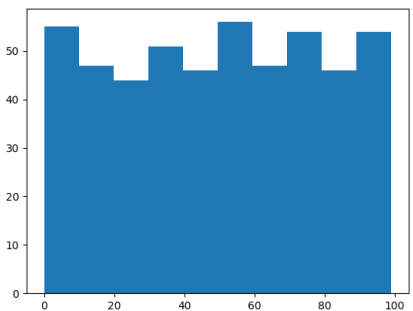

Matplotlib: Informationen mit „Hilfe“ abrufen

```
help(plt)
help(plt.figure)
help(plot.axes)
help(ax.plot)
help(ax.scatter)
help(ax.hist)
help(ax.set_xlabel)
...
```

Matplotlib: In-class Exercise

Raindrops exercise

Üben Sie das Plotten mit Matplotlib und lernen Sie, wie man Animationen erstellt.

Schreibe ein Python Programm welches:

- Streupunkte mit vorgegebenen Positionen, Größen und Farben.
- Aktualisieren Sie die Streudaten bei jedem Frame.

Eine ausführliche Aufgabenbeschreibung finden Sie im Jupyter Notebook.

2. Pandas

wie daten eintragen für plot?

Pandas: CSV-Daten

CSV steht für **`Comma Separated Values`**.

show CodeXpert

Eine CSV-Datei enthält eine Tabelle von Daten

CSV ist ein textuelles Format. Zeilen sind durch Zeilensprungzeichen voneinander getrennt

Spalten sind durch Kommas oder ein anderes vereinbartes Zeichen (oftmals Tabulatorzeichen **`\t`**) getrennt.

Item	noah	liame	emma	mia
Food	270	140	188	200
Insurance	72	310	88	72
Fun	410	–	60	130
Salary	–	1510	–	–
Tuition	720	820	720	720
Rent	–	430	390	–
…				

show xlsx to csv

Pandas: CSV-Daten lesen

```
import pandas as pd
```

Daten aus der CSV-Datei lesen

separator auch (,)

```
data = pd.read_csv("Expense.csv", sep="\t", index_col="Item")
```

Item	noah	liam	emma	mia
Food	270	140	188	200
Insurance	72	310	88	72
Fun	410	-	60	130
Salary	-	1510	-	-
Tuition	720	820	720	720
Rent	-	430	390	-

Pandas: CSV-Daten lesen

Lesen Sie hartcodierte Daten

```
import io
csv_file = io.StringIO("""
Item;noah;liame;emma;mia
Food;270;140;188;200
Insurance;72;310;88;72
Fun;410;-;60;130
Salary;-;1510;-;-
Tuition;720;820;720;720
Rent;-;430;390;-
""")
data = pd.read_csv(csv_file, sep=";", index_col="Item")
```

Pandas: Spalten umbenennen

Verwenden Sie die Funktion „Umbenennen“

```
data = data.rename(columns={
        "noah": "Noah", "liame": "Liam", \
        "emma": "Emma", "mia": "Mia"})
```

Suche existierender Name

	noah	liam	emma	mia
Item				
Food	270	140	188	200
Insurance	72	310	88	72
Fun	410	–	60	130
Salary	–	1510	–	–
Tuition	720	820	720	720
Rent	–	430	390	–

→

	Noah	Liam	Emma	Mia
Item				
Food	270	140	188	200
Insurance	72	310	88	72
Fun	410	–	60	130
Salary	–	1510	–	–
Tuition	720	820	720	720
Rent	–	430	390	–

Pandas: Spalten umbenennen

Spaltennamen direkt festlegen

```
data.columns = ["Noah", "Liam", "Emma", "Mia"]
```

	noah	liam	emma	mia
Item				
Food	270	140	188	200
Insurance	72	310	88	72
Fun	410	–	60	130
Salary	–	1510	–	–
Tuition	720	820	720	720
Rent	–	430	390	–

→

	Noah	Liam	Emma	Mia
Item				
Food	270	140	188	200
Insurance	72	310	88	72
Fun	410	–	60	130
Salary	–	1510	–	–
Tuition	720	820	720	720
Rent	–	430	390	–

Pandas: Umgang mit ungültigen Daten

Normalerweise erkennt Pandas Spalten mit Zahlen und setzt den Datentyp der Spalte automatisch auf **Numerisch**.
Leider sind die Spalten nicht numerisch, da sie das Zeichen „-“ haben.

```
pd.Series([1, 2, 3]).dtype # check default data type
```

print

```
dtype('int64')
```

```
data["Noah"].dtype, data["Liam"].dtype, \
data["Emma"].dtype, data["Mia"].dtype
```

```
(dtype('O'), dtype('O'), dtype('O'), dtype('O')) # not numeric
```

b - boolean
i - signed int
u - unsigned int
f - float
O - Python objects → string in pandas
v - void

Pandas: Umgang mit ungültigen Daten

Wandeln Sie die Spalten in numerische Spalten um

```
for column_name in data.columns:
    data[column_name] = pd.to_numeric(\
    data[column_name], errors="coerce")
    # if 'coerce', then invalid parsing will be set as NaN.
```

Not a Number

(?)

	noah	liam	emma	mia
Item				
Food	270	140	188	200
Insurance	72	310	88	72
Fun	410	–	60	130
Salary	–	1510	–	–
Tuition	720	820	720	720
Rent	–	430	390	–

→

	Noah	Liam	Emma	Mia
Item				
Food	270.0	140.0	188.0	200.0
Insurance	72.0	310.0	88.0	72.0
Fun	410.0	NaN	60.0	130.0
Salary	NaN	1510.0	NaN	NaN
Tuition	720.0	820.0	720.0	720.0
Rent	NaN	430.0	390.0	NaN

Pandas: Umgang mit ungültigen Daten

Löschen Sie die Zeilen mit NaN-Werten

```
data = data.dropna(how="any")
# how="any" -> If any NaN is present, drop the row.
```

→ unusable Data

	Noah	Liam	Emma	Mia
Item				
Food	270.0	140.0	188.0	200.0
Insurance	72.0	310.0	88.0	72.0
Fun	410.0	NaN	60.0	130.0
Salary	NaN	1510.0	NaN	NaN
Tuition	720.0	820.0	720.0	720.0
Rent	NaN	430.0	390.0	NaN

→

	Noah	Liam	Emma	Mia
Item				
Food	270.0	140.0	188.0	200.0
Insurance	72.0	310.0	88.0	72.0
Tuition	720.0	820.0	720.0	720.0

Pandas: Umgang mit ungültigen Daten

Füllen Sie die NaN-Werte mit einem anderen Wert, z. B. 0

```
data = data.fillna(0)
```

← füllen mit was?

Item	Noah	Liam	Emma	Mia
Food	270.0	140.0	188.0	200.0
Insurance	72.0	310.0	88.0	72.0
Fun	410.0	NaN	60.0	130.0
Salary	NaN	1510.0	NaN	NaN
Tuition	720.0	820.0	720.0	720.0
Rent	NaN	430.0	390.0	NaN

→

Item	Noah	Liam	Emma	Mia
Food	270.0	140.0	188.0	200.0
Insurance	72.0	310.0	88.0	72.0
Fun	410.0	0.0	60.0	130.0
Salary	0.0	1510.0	0.0	0.0
Tuition	720.0	820.0	720.0	720.0
Rent	0.0	430.0	390.0	0.0

Pandas: Datenfilterung

```
data["Noah"] > 0
```

```
Item
Food          True
Insurance     True
Fun           True
Salary       False
Tuition       True
Rent         False
Name: Noah, dtype: bool
```

```
data[data["Noah"] > 0]
```

Item	Noah	Liam	Emma	Mia
Food	270.0	140.0	188.0	200.0
Insurance	72.0	310.0	88.0	72.0
Fun	410.0	0.0	60.0	130.0
Tuition	720.0	820.0	720.0	720.0

Pandas: Datenfilterung

Filtern Sie Daten mit mehreren Bedingungen

```
data[(data["Noah"] > 0) & (data["Liam"] > 0) & \
    (data["Emma"] > 0) & (data["Mia"] > 0)]
```

	Noah	Liam	Emma	Mia
Item				
Food	270.0	140.0	188.0	200.0
Insurance	72.0	310.0	88.0	72.0
Tuition	720.0	820.0	720.0	720.0

Pandas: Datenfilterung

Wähle Sie bestimmte Zeilen aus

```
data[data.index != "Fun"]
```

alle außer fun

	Noah	Liam	Emma	Mia
Item				
Food	270.0	140.0	188.0	200.0
Insurance	72.0	310.0	88.0	72.0
Salary	0.0	1510.0	0.0	0.0
Tuition	720.0	820.0	720.0	720.0
Rent	0.0	430.0	390.0	0.0

```
data.loc[["Food", "Rent"], :]
```

	Noah	Liam	Emma	Mia
Item				
Food	270.0	140.0	188.0	200.0
Rent	0.0	430.0	390.0	0.0

Pandas: Datenänderung

Fügen Sie eine neue Spalte hinzu

```
data["Total"] = data["Noah"] + data["Liam"] + \
                data["Emma"] + data["Mia"]
```

Item	Noah	Liam	Emma	Mia
Food	270.0	140.0	188.0	200.0
Insurance	72.0	310.0	88.0	72.0
Fun	410.0	0.0	60.0	130.0
Salary	0.0	1510.0	0.0	0.0
Tuition	720.0	820.0	720.0	720.0
Rent	0.0	430.0	390.0	0.0

→

Item	Noah	Liam	Emma	Mia	Total
Food	270.0	140.0	188.0	200.0	798.0
Insurance	72.0	310.0	88.0	72.0	542.0
Fun	410.0	0.0	60.0	130.0	600.0
Salary	0.0	1510.0	0.0	0.0	1510.0
Tuition	720.0	820.0	720.0	720.0	2980.0
Rent	0.0	430.0	390.0	0.0	820.0

Pandas: Datenänderung

Entfernen Sie eine Spalte

```
data = data.drop(columns="Total")
```

Item	Noah	Liam	Emma	Mia	Total
Food	270.0	140.0	188.0	200.0	798.0
Insurance	72.0	310.0	88.0	72.0	542.0
Fun	410.0	0.0	60.0	130.0	600.0
Salary	0.0	1510.0	0.0	0.0	1510.0
Tuition	720.0	820.0	720.0	720.0	2980.0
Rent	0.0	430.0	390.0	0.0	820.0

→

Item	Noah	Liam	Emma	Mia
Food	270.0	140.0	188.0	200.0
Insurance	72.0	310.0	88.0	72.0
Fun	410.0	0.0	60.0	130.0
Salary	0.0	1510.0	0.0	0.0
Tuition	720.0	820.0	720.0	720.0
Rent	0.0	430.0	390.0	0.0

Pandas: Datenzusammenfassung

```
data.sum()
```

```
Noah    1472.0
Liam    3210.0
Emma    1446.0
Mia     1122.0
dtype: float64
```

```
data.max()
```

```
Noah    720.0
Liam   1510.0
Emma    720.0
Mia     720.0
dtype: float64
```

```
data["Noah"].sum()
```

```
1472.0
```

```
data["Noah"].max()
```

```
720.0
```

Pandas: Datenzusammenfassung

```
data.agg(["max", "sum"]) # use a list of aggregate functions
```

	Noah	Liam	Emma	Mia
max	720.0	1510.0	720.0	720.0
sum	1472.0	3210.0	1446.0	1122.0

Pandas: Datenzusammenfassung

```
data.T.describe() # get statistical information
```

Item	Food	Insurance	Fun	Salary	Tuition	Rent
count	4.000000	4.000000	4.000000	4.0	4.0	4.00000
mean	199.500000	135.500000	150.000000	377.5	745.0	205.00000
std	53.674948	116.577585	181.291662	755.0	50.0	237.27621
min	140.000000	72.000000	0.000000	0.0	720.0	0.00000
25%	176.000000	72.000000	45.000000	0.0	720.0	0.00000
50%	194.000000	80.000000	95.000000	0.0	720.0	195.00000
75%	217.500000	143.500000	200.000000	377.5	745.0	400.00000
max	270.000000	310.000000	410.000000	1510.0	820.0	430.00000

Pandas: Datengruppierung

```
# add a new column "method" used for grouping
data["method"] = ["credit card", "transfer", "transfer", \
           "cash", "credit card", "cash"]
```

	Noah	Liam	Emma	Mia	method
Item					
Food	270.0	140.0	188.0	200.0	credit card
Insurance	72.0	310.0	88.0	72.0	transfer
Fun	410.0	0.0	60.0	130.0	transfer
Salary	0.0	1510.0	0.0	0.0	cash
Tuition	720.0	820.0	720.0	720.0	credit card
Rent	0.0	430.0	390.0	0.0	cash

Pandas: Datengruppierung

```
data.groupby("method")
```

```
<pandas.core.groupby.generic.DataFrameGroupBy object at 0x7fca90646d30>
```

```
data.groupby("method").sum()
```

	Noah	Liam	Emma	Mia
method				
cash	0.0	1940.0	390.0	0.0
credit card	990.0	960.0	908.0	920.0
transfer	482.0	310.0	148.0	202.0

```
data.groupby("method").max()
```

	Noah	Liam	Emma	Mia
method				
cash	0.0	1510.0	390.0	0.0
credit card	720.0	820.0	720.0	720.0
transfer	410.0	310.0	88.0	130.0

Pandas: Datengruppierung

```
data.groupby("method").describe() # get statistical information
```

	Noah								Liam	...
	count	mean	std	min	25%	50%	75%	max	count	...
method										...
cash	2.0	0.0	0.000000	0.0	0.0	0.0	0.0	0.0	2.0	...
credit card	2.0	495.0	318.198052	270.0	382.5	495.0	607.5	720.0	2.0	...
transfer	2.0	241.0	239.002092	72.0	156.5	241.0	325.5	410.0	2.0	...

[3 rows x 32 columns]

Pandas: In-class Exercise

Code-Experte — CSVs & Pandas: Verwenden Sie Pandas, um die CSV-Datei (auseinsteiger.csv) zu verarbeiten und benötigte Informationen abzurufen.

Schreibe ein Python Programm welches:

- Benennen Sie die Spalten um (Aufgabe 1).
- Entfernen Sie ungültige Zeilen (Aufgabe 2).
- Drucken Sie die zusammenfassenden Informationen aus (Aufgabe 3, 4).
- Geben Sie die Anzahl der Daten aus, die die Bedingungen erfüllen (Aufgabe 5, 6).
- Drucken Sie die zusammenfassenden Informationen gruppierter Daten aus (Aufgabe 7).

Eine ausführliche Aufgabenbeschreibung finden Sie in Code Expert.

In Class Jupyter Notebook
In Class Code Examples
Homework

3. Hausaufgaben

Übung 3: Python III

Auf `https://expert.ethz.ch/mycourses/SS25/mavt2/exercises`

Exercise 3: Python III

- Processing Earthquake Data
- Working with Data
- Bar Charts with matplotlib

Abgabedatum: Montag 17.03.2025, 20:00 MEZ

KEINE HARDCODIERUNG

Fragen?