Werkzeuge für das wissenschaftliche Arbeiten

Python for Machine Learning and Data Science

Magnus Bender
bender@ifis.uni-luebeck.de
Wintersemester 2022/23

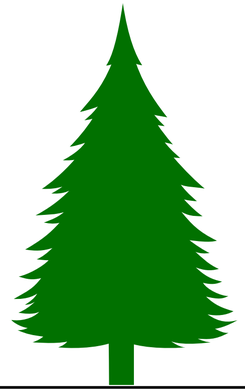

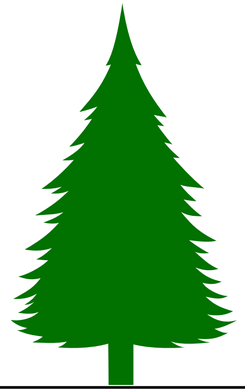

Inhaltsübersicht

1. Programmiersprache Python
   a) *Einführung, Erste Schritte*
   b) *Grundlagen*
   c) *Fortgeschritten*
2. Auszeichnungssprachen
   a) *LaTeX, Markdown*
3. Benutzeroberflächen und Entwicklungsumgebungen
   a) *Jupyter Notebooks lokal und in der Cloud (Google Colab)*
4. Versionsverwaltung
   a) *Git, GitHub*
5. Wissenschaftliches Rechnen
   a) *NumPy, SciPy*
6. Datenverarbeitung und -visualisierung
   a) **Pandas, matplotlib, NLTK**
7. Machine Learning (scikit-learn)
   a) Grundlegende Ansätze (Datensätze, Auswertung)
   b) Einfache Verfahren (Clustering, …)
8. DeepLearning
   a) TensorFlow, PyTorch, HuggingFace Transformers

Themen

I. Projektaufgabe 2
    1. Lösungsvorschlag
II. Datenverarbeitung
    1. Python-intern
    2. Pandas
    3. NLTK
III. Datenvisualisierung
    1. Matplotlib

Projektaufgabe 2

„Objektorientierung in Python“

- Vorstellung möglicher Lösung

  (wird nicht ins Moodle hochgeladen!)

II.
Datenverarbeitung

1. Python-intern

Ablauf

Datenverarbeitung

- JSON
- CSV
- Numpy (npy, npz)
- TXT
- …

python™

NumPy

SciPy

- JSON
- Pickle
- Shelve
- Numpy (npy, npz)

- Tabellen
- Grafiken

Datenvisualisierung

JavaScript Object Notation (JSON)

```python
import json

d = {
   "a" : 1,
   "b" : "B",
   "c" : [1.2, 1.3, 1.4],
   "e" : None
}

json_str = json.dumps(d, indent=2)
print(json_str)

d_ = json.loads(json_str)
print(d_)
```

```
{'a': 1, 'b': 'B', 'c': [1.2, 1.3, 1.4], 'e': None}
```

```
{
  "a": 1,
  "b": "B",
  "c": [
    1.2,
    1.3,
    1.4
  ],
  "e": null
}
```

Unterstützung in (fast) allen Programmiersprachen

Unterstützt die Typen

`dict, list, str, int, float, True, False, None`

Pickle

```python
import pickle

class Triple():
  def __init__(self, a, b, c):
    self.a, self.b, self.c = a, b, c
  def __repr__(self):
    return str((self.a, self.b, self.c))

d = [
  Triple(1, 2, 3),
  Triple(4, 5, 6),
  Triple(7, 8, 9),
]

pickle_data = pickle.dumps(d)
d_ = pickle.loads(pickle_data)
print(d, d_)
```

```
[(1, 2, 3), (4, 5, 6), (7, 8, 9)]
[(1, 2, 3), (4, 5, 6), (7, 8, 9)]
```

```python
pickle.dump(d, open("d.pickle", "wb"))
d__ = pickle.load(open("d.pickle", "rb"))
print(d__)
```

```
[(1, 2, 3), (4, 5, 6), (7, 8, 9)]
```

Achtung, keine Pickles aus unbekannter Quelle laden!

Unterstützt alle Typen, Implementierung muss verfügbar und gleich sein!

Daten sind ein binärer Datenstrom

Direkt in eine Datei schreiben und daraus lesen (ohne s).

II.
Datenverarbeitung

2. Pandas

Installation

- Python Paket
  - https://pandas.pydata.org/
- Installation z.B. mit `pip3 install pandas`
- Import

```
import pandas
import pandas as pd
```

Pandas & DataFrame

- Verwaltung und Manipulation von Tabellen
- Verschiedene Datentypen kombiniert
- Geschwindigkeit durch C-Code im Hintergrund
- Import von CSV, JSON, SQL, Excel, …

ID	Name	Age	Species
1	Otto	60	Human
2	Erna	65	Human
3	Bello	10	Dog
	3	45	2

DataFrame

```python
import pandas as pd

df = pd.DataFrame({
  "ID" : pd.Index([1, 2, 3]),
  "Name" : ["Otto", "Erna", "Bello"],
  "Age" : [60, 65, 10],
  "Species" : pd.Categorical(["Human", "Human", "Dog"])
})
```

ID	Name	Age	Species
1	Otto	60	Human
2	Erna	65	Human
3	Bello	10	Dog
	3	45	2

```python
print(df)
```

```
   ID   Name  Age Species
0   1   Otto   60   Human
1   2   Erna   65   Human
2   3  Bello   10     Dog
```

```python
print(df.head(1))
```

```
   ID  Name  Age Species
0   1  Otto   60   Human
```

```python
print(df.tail(2))
```

```
   ID   Name  Age Species
1   2   Erna   65   Human
2   3  Bello   10     Dog
```

```python
print(df.dtypes)
```

```
ID              int64
Name           object
Age             int64
Species     category
dtype: object
```

```python
print(df.index)
```

```
RangeIndex(start=0, stop=3, step=1)
```

```python
print(df.columns)
```

```
Index(['ID', 'Name', 'Age', 'Species'], dtype='object')
```

```python
print(df.describe())
```

```
             ID         Age
count   3.0    3.000000
mean    2.0   45.000000
min     1.0   10.0000000
50%     2.0   60.000000
max     3.0   65.000000
```

```python
print(df.to_numpy())
```

```
[[1 'Otto' 60 'Human']
 [2 'Erna' 65 'Human']
 [3 'Bello' 10 'Dog']]
```

Fortsetzung

- Import und Export
- Selektion (Slices, Indexe)
- Operation (Statistik, Funktionen anwenden)
- Zusammenfügen und Umformen
- Visualisierung

Ich kann hier nicht alle Funktionen vorstellen, daher Verweise ich auf weitere Quellen

D.h. natürlich auch, dass Pandas dann nicht in den Aufgaben drankommt.

→ https://pandas.pydata.org/docs/user_guide/10min.html

→ https://pandas.pydata.org/docs/user_guide/index.html

II.
Datenverarbeitung

3. Natural Language Toolkit (NLTK)

Problem?

Sprachverarbeitung

„Geben Sie den Link zu Ihrem Repository im Moodle ein. Dabei werden Sie auch gefragt, ob das Repository öffentlich oder verborgen ist! Denken Sie bei verborgen Repositories daran, dem GitHub-User `WerkzeugeWissArbeiten` Zugriffsrechte für Ihr erstelltes Git-Repository zu gewähren.“

- Sätze aufsplitten
- Wortvektor(en) erstellen
  - Häufigkeit der Worte pro Satz
  - Wenig aussagekräftige Worte

Ich kann hier nur ein paar Ideen anreißen.

Vorverarbeitung (*Preprocessing*) ist eine sehr wichtige Aufgabe u.a. bei der Sprachverarbeitung (NLP).

Vorverarbeitung mit NLTK I

```
import re
from nltk.corpus import stopwords
from nltk.tokenize import word_tokenize, sent_tokenize
from nltk.stem.snowball import SnowballStemmer

text = "… Repository öffentlich oder verborgen ist! Denken Sie bei verborgen Repositories …"

stop_words = set(stopwords.words("german"))
print(stop_words)

stemmer_de = SnowballStemmer("german")
stemmer_en = SnowballStemmer("english")

print(stemmer_de.stem("öffentlich"))
print(stemmer_de.stem("Öffentlichkeit"))

print(stemmer_en.stem("repository"))
print(stemmer_en.stem("repositories"))
```

```
{'nun', 'weil', 'nichts', 'sie', 'solche',
'einem', 'warst', 'werden', 'das', … }

offent
offent

repositori
repositori
```

Stopwords: Worte die eher wenig zur Kernaussage eines Satzes beitragen.

Wort auf dem Wortstamm reduzieren, sodass es als das selbe Wort betrachtet werden kann.

Vorverarbeitung mit NLTK II

```
text = "Geben Sie den Link zu Ihrem Repository im …"

stop_words = set(stopwords.words("german"))
stemmer_de = SnowballStemmer("german")
stemmer_en = SnowballStemmer("english")

text = text.replace("-", " ")

for sentence in sent_tokenize(text, language='german'):
  print(sentence)
```

```
Geben Sie den Link zu Ihrem Repository im Moodle ein.
```

Über Sätze und dann Worte iterieren.

```
  for word in word_tokenize(sentence, language='german'):
    print(word)
```

```
Geben
Sie
den
Link
zu
Ihrem
Repository
im
Moodle
ein
.
```

Vorverarbeitung mit NLTK III

```
text = " … Dabei werden Sie auch gefragt, ob das Repository öffentlich oder verborgen ist! …"
stop_words = set(stopwords.words("german"))
stemmer_de = SnowballStemmer("german")
stemmer_en = SnowballStemmer("english")

text = text.replace("-", " ")
for sentence in sent_tokenize(text, language='german'):
  for word in word_tokenize(sentence, language='german'):
    print(word)

    word = word.lower()
    word = re.sub("[^a-zäüöß]", "", word)
    print(word)

    if word not in stop_words:
      word = stemmer_de.stem(word)
      word = stemmer_en.stem(word)

      print(word)
```

Alles klein und nur Buchstaben

Wortstämme, sowohl Englisch als auch Deutsch

Dabei	dabei	dabei
werden	werden	
Sie	sie	
auch	auch	
gefragt	gefragt	gefragt
,		
ob	ob	
das	das	
Repository	repository	repositori
öffentlich	öffentlich	offent
oder	oder	
verborgen	verborgen	verborg
ist	ist	
!		

Vorverarbeitung mit NLTK IV

```
text = "Geben Sie den Link zu Ihrem Repository im Moodle ein. …"

stop_words = set(stopwords.words("german"))
stemmer_de, stemmer_en = SnowballStemmer("german"), SnowballStemmer("english")

sentences = []
for sentence in sent_tokenize(text.replace("-", " "), language='german'):
  words = []
  for word in word_tokenize(sentence, language='german'):
    word = re.sub("[^a-zäüöß]", "", word.lower())
    if word not in stop_words:
      word = stemmer_en.stem(stemmer_de.stem(word))
      if len(word) > 0:
        words.append(word)
  sentences.append(words)

print(sentences)
```

Alles zusammen :-)

```
[['geb', 'link', 'repositori', 'moodl'],
 ['dabei', 'gefragt', 'repositori', 'offent', 'verborg'],
 ['denk', 'verborg', 'repositori', 'daran', 'github', 'user',
  'werkzeugewissarbeit', 'zugriffsrecht', 'erstellt', 'git',
  'repositori', 'gewahr']]
```

Ergebnis

- *Bag-of-Words*-Modell
  - Dokument ist ein Bitvektor (oder auch Häufigkeitsvektor) seiner Wörter
  - Text sind jetzt Vektoren

Und die können wir vergleichen etc.

Wort	Satz 0	Satz 1	Satz 2
dabei	0	1	0
daran	0	0	1
denk	0	0	1
erstellt	0	0	1
geb	1	0	0
gefragt	0	1	0
gewahr	0	0	1
git	0	0	1
github	0	0	1
link	1	0	0
moodl	1	0	0
offent	0	1	0
repositori	1	1	2
user	0	0	1
verborg	0	1	1
werkzeugewissarbeit	0	0	1
zugriffsrecht	0	0	1

Ergebnis als NumPy

```
import numpy as np

sentences = [
  ['geb', 'link', 'repositori', 'moodl'],
  ['dabei', 'gefragt', 'repositori', 'offent', 'verborg'],
  ['denk', 'verborg', 'repositori', 'daran', ,github',
   'user', 'werkzeugewissarbeit', 'zugriffsrecht', 'erstellt',
   'git', 'repositori', 'gewahr']
]

id2word = list(set([ w for s in sentences for w in s ]))
word2id = { word : i for i, word in enumerate(id2word) }

corpus = np.zeros((len(id2word), len(sentences)), dtype=int)
for s_id, sentence in enumerate(sentences):
  for word in sentence:
    corpus[word2id[word], s_id] += 1

print(word2id)
print(corpus)
```

```
{'dabei': 0, 'daran': 1, … 'repositori': 12, 'user': 13,
 'verborg': 14, 'werkzeugewissarbeit': 15, …}
```

```
[[0 1 0]
 [0 0 1]
 [0 0 1]
 [0 0 1]
 [1 0 0]
 [0 1 0]
 [0 0 1]
 [0 0 1]
 [0 0 1]
 [1 0 0]
 [1 0 0]
 [0 1 0]
 [1 1 2]
 [0 0 1]
 [0 1 1]
 [0 0 1]
 [0 0 1]]
```

Auch hierfür würde man i.A. eine Bibliothek nutzen

Numpy-Array und ein Wörterbuch um IDs auf Worte zu übersetzen.

III.
Datenvisualisierung

Matplotlib

Installation

- Python Paket
  - https://matplotlib.org/
- Installation z.B. mit `pip3 install matplotlib`
- Import

```
import matplotlib as mpl
import matplotlib.pyplot as plt
```

Der erste Plot

```
import matplotlib.pyplot as plt
import numpy as np

x = np.arange(-10, 10.5, step=0.5)

plt.plot(x, x**2)
plt.plot(x, x**3)

plt.show()

print(x)
```

„Linie“ mittels zwei Arrays, jeweils x- und y-Wert

Öffnen des Plot

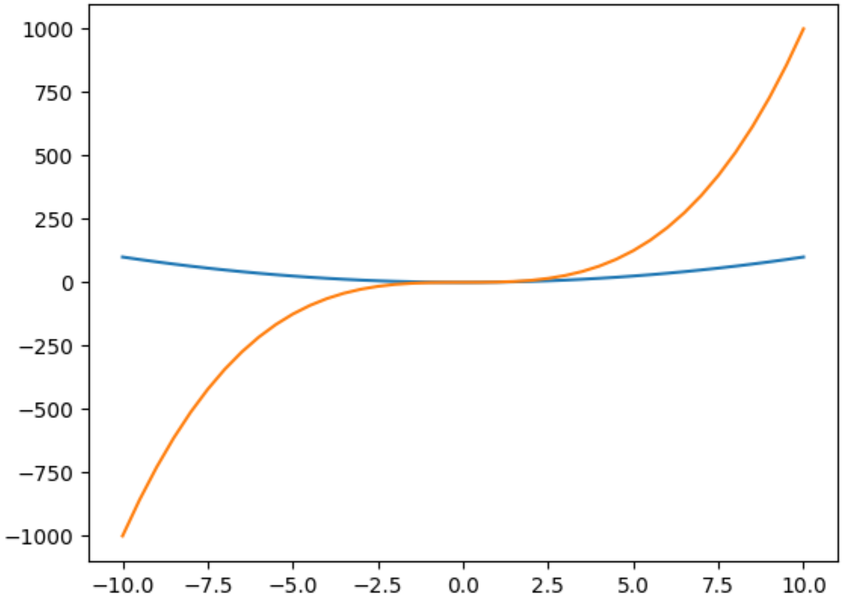


```
[-10.   -9.5  -9.   -8.5  -8.   -7.5  -7.   -6.5  -6.   -5.5  -5.   -4.5
  -4.   -3.5  -3.   -2.5  -2.   -1.5  -1.   -0.5   0.    0.5   1.    1.5
   2.    2.5   3.    3.5   4.    4.5   5.    5.5   6.    6.5   7.    7.5
   8.    8.5   9.    9.5  10. ]
```

PyPlot und Objektorientiert

```python
import matplotlib.pyplot as plt
import numpy as np

x = np.arange(-10, 10.5, step=0.5)

plt.plot(x, x**2, label='x^2')
plt.plot(x, x**3, label=r'$x^3$')
plt.legend()

plt.show()
```

PyPlot: Direkt `plt` genutzt

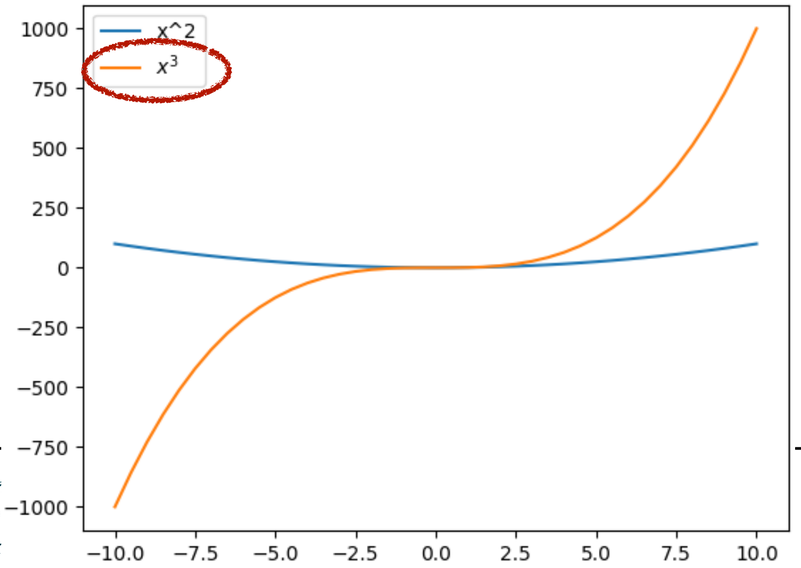

Objektor.: Objekt erstellt und dann dieses genutzt.

```python
fig1, ax1 = plt.subplots()

ax1.plot(x, x**2, label='x^2')
ax1.plot(x, x**3, label='x^3')
ax1.legend()

fig2, ax2 = plt.subplots()

ax2.plot(x, x**2, label='x^2')
ax2.plot(x, x**4, label='x^4')
ax2.legend()

plt.show()
```

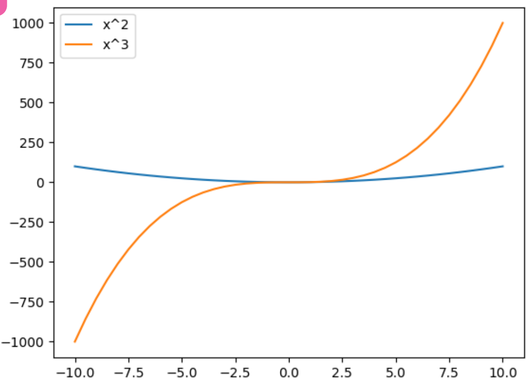

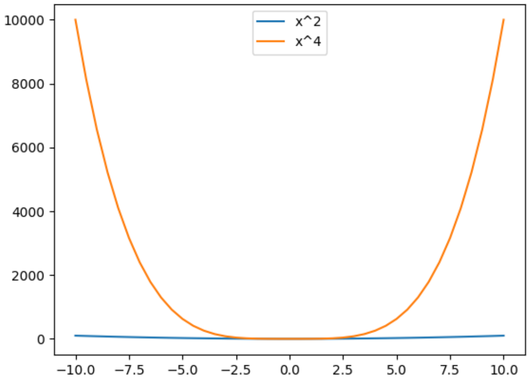

Zwei Objekte, also es öffnet sich ein Fenster mit zwei Plots.

Beispiel

```
import matplotlib.pyplot as plt
import numpy as np

y = np.array([1, 2, 3, 4, 5, 4, 3, 2, 1])
x = np.arange(9)

fig, ax = plt.subplots(figsize=(8, 4))

ax.plot(x, y,           label='y')
ax.plot(x, y+0.5,       label='y+0.5', linewidth=3, linestyle='--')
ax.plot(x, y+1.5, 'o', label='y+1.5')
ax.bar( x, y-0.5)

ax.legend();

ax.set_xlabel("X-Achse")
ax.set_ylabel("Y-Achse")
ax.set_title('Eine Grafik mit Punkten,
              Linien und Balken')

ax.text(2, 6, 'Ein Text!')

plt.savefig("plot.png")
```

Größe (Seitenverhältnis des Plot)

Konfiguration der Linie und Dicke

Kreise statt Linie

Balkendiagramm

Beschriftungen

Text im Plot

Als Datei speichern statt zu öffnen

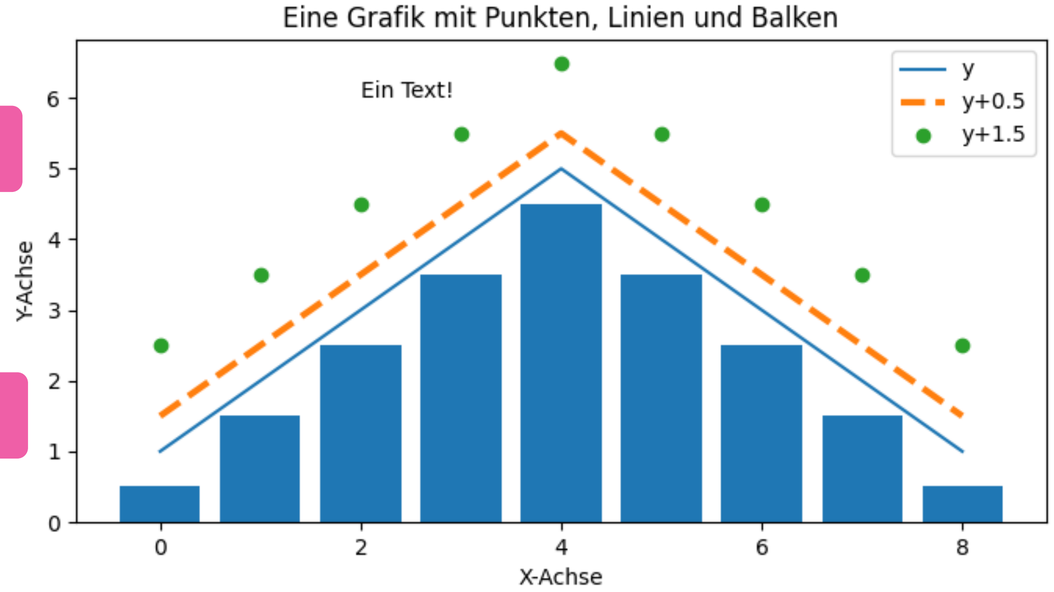

Zusammenfassung

I. Projektaufgabe 2
    1. Lösungsvorschlag
II. Datenverarbeitung
    1. Python-intern
    2. Pandas
    3. NLTK
III. Datenvisualisierung
    1. Matplotlib

Aufgabe 4 wird über Weihnachten bereits freigeschaltet.

Es ist aber auch im neuen Jahr genug Zeit.

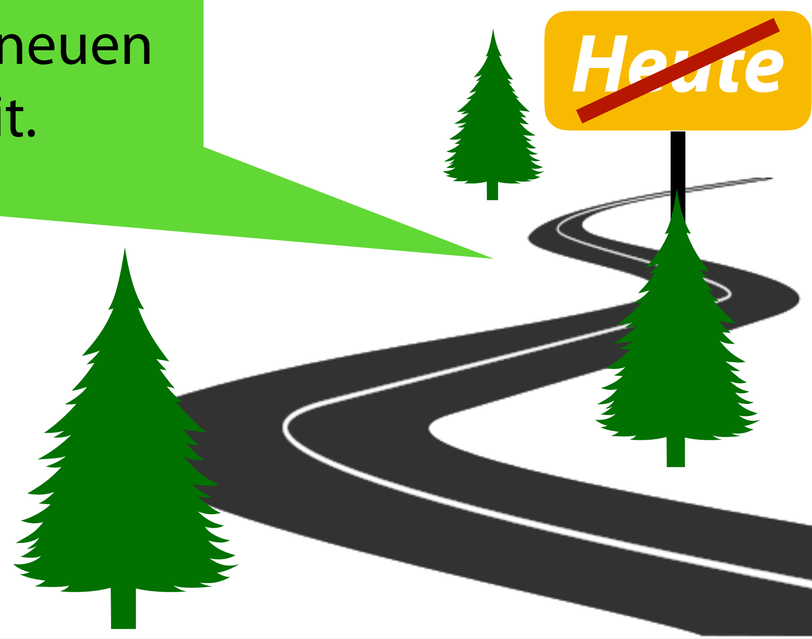

Inhaltsübersicht

1. Programmiersprache Python
   a) *Einführung, Erste Schritte*
   b) *Grundlagen*
   c) *Fortgeschritten*
2. Auszeichnungssprachen
   a) *LaTeX, Markdown*
3. Benutzeroberflächen und Entwicklungsumgebungen
   a) *Jupyter Notebooks lokal und in der Cloud (Google Colab)*
4. Versionsverwaltung
   a) *Git, GitHub*
5. Wissenschaftliches Rechnen
   a) *NumPy, SciPy*
6. Datenverarbeitung und -visualisierung
   a) *Pandas, matplotlib, NLTK*
7. Machine Learning (scikit-learn)
   a) Grundlegende Ansätze (Datensätze, Auswertung)
   b) Einfache Verfahren (Clustering, …)
8. DeepLearning
   a) TensorFlow, PyTorch, HuggingFace Transformers