Data Science 1

Vorlesung 3 - Intro

Prof. Dr. Christian Bockermann

Hochschule Bochum

Sommersemester 2022

Wo sind wir?

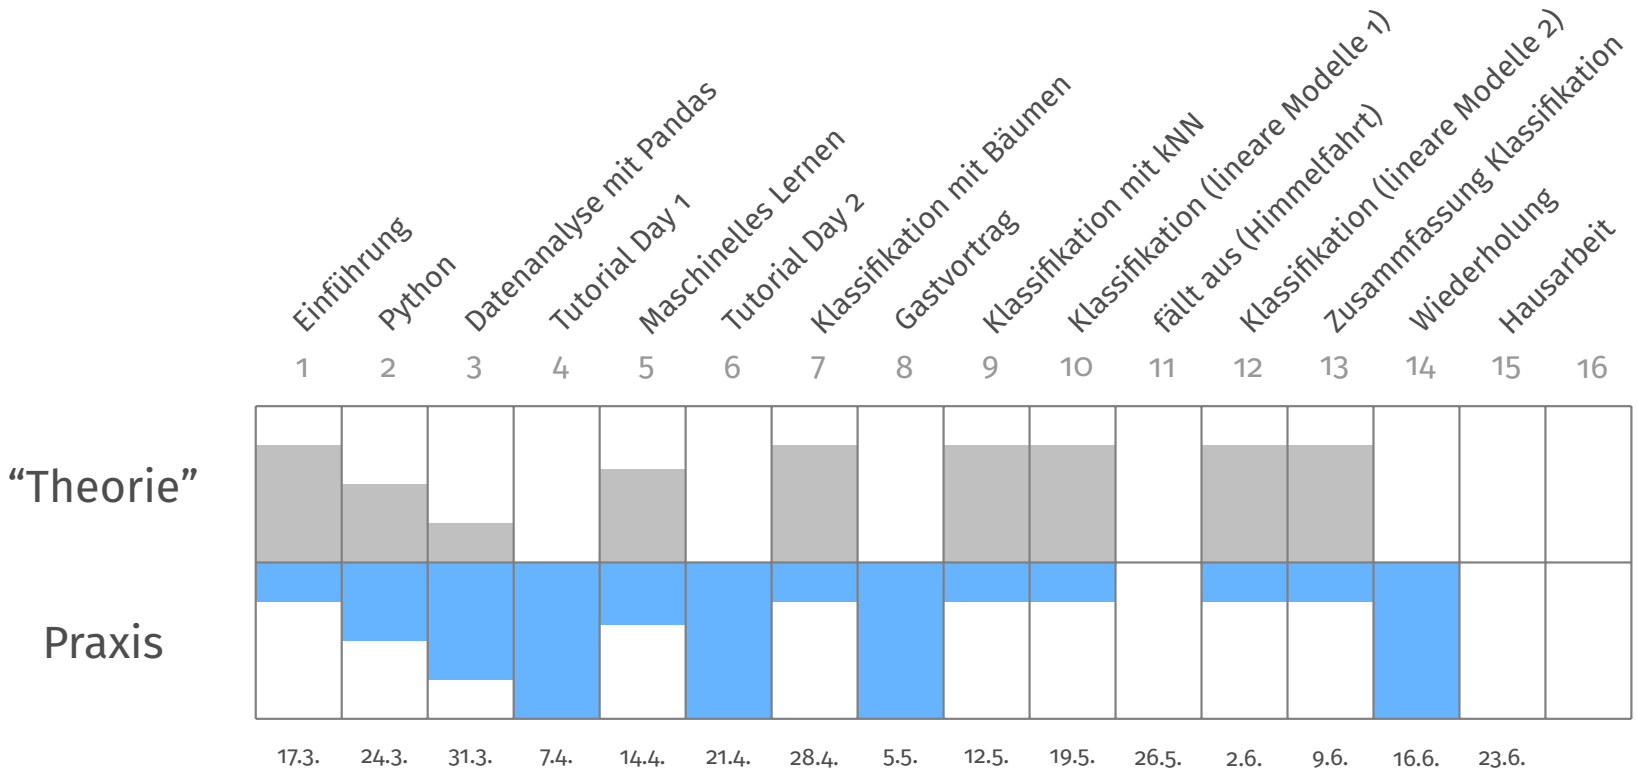
Einführung
Python
Datenanalyse mit Pandas
Tutorial Day 1
Maschinelles Lernen
Tutorial Day 2
Klassifikation mit Bäumen
Gastvortrag
Klassifikation mit kNN
Klassifikation (lineare Modelle 1)
fällt aus (Himmelfahrt)
Klassifikation (lineare Modelle 2)
Zusammfassung Klassifikation
Wiederholung
Hausarbeit
1
2
3
4
5
6
7
8
9
10
11
12
13
14
15
16
“Theorie”
Praxis
17.3.
24.3.
31.3.
7.4.
14.4.
21.4.
28.4.
5.5.
12.5.
19.5.
26.5.
2.6.
9.6.
16.6.
23.6.

Wo sind wir?

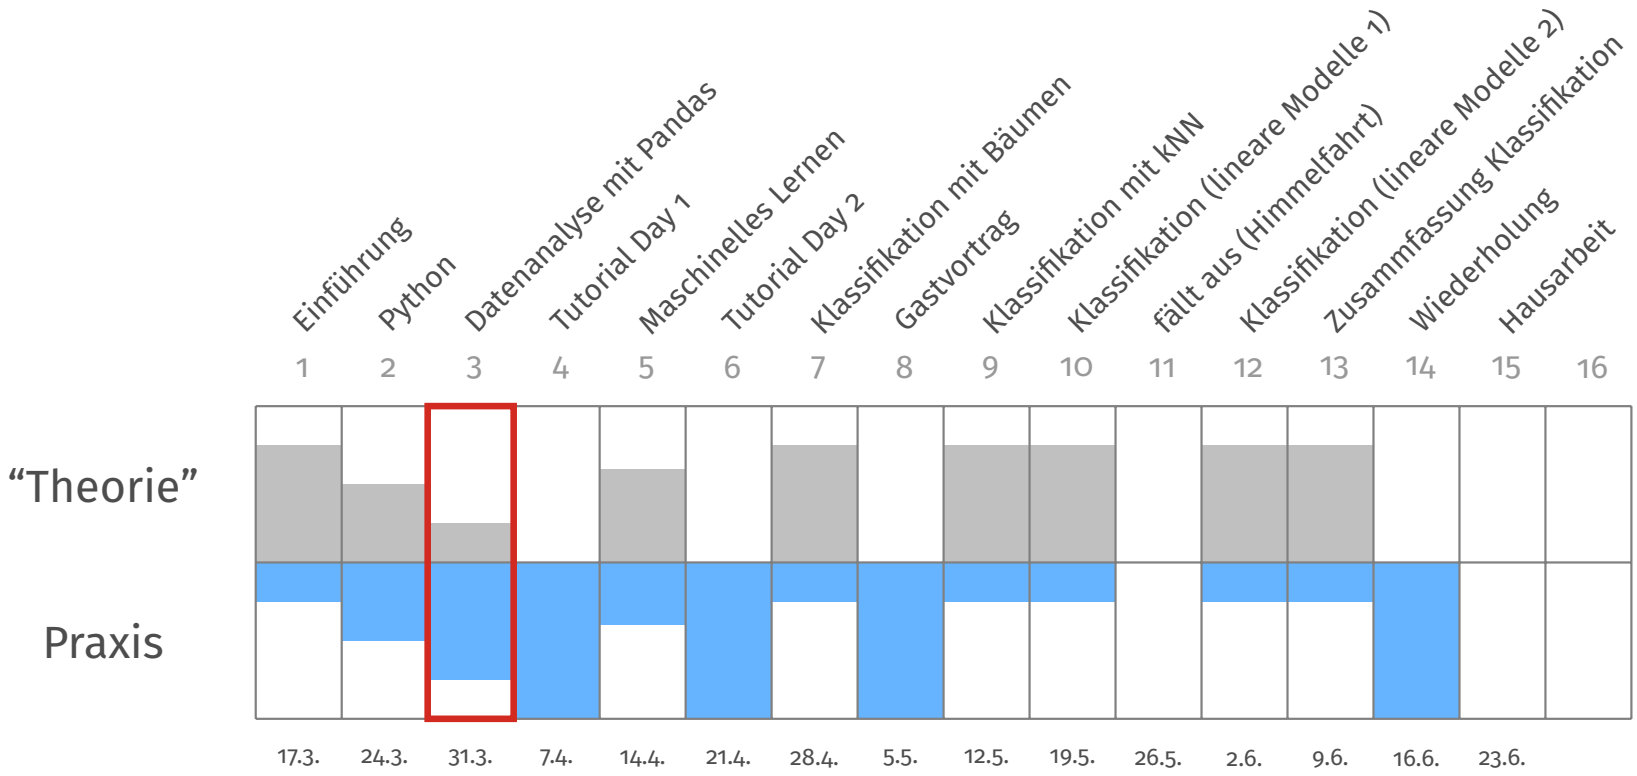
Einführung
Python
Datenanalyse mit Pandas
Tutorial Day 1
Maschinelles Lernen
Tutorial Day 2
Klassifikation mit Bäumen
Gastvortrag
Klassifikation mit kNN
Klassifikation (lineare Modelle 1)
fällt aus (Himmelfahrt)
Klassifikation (lineare Modelle 2)
Zusammfassung Klassifikation
Wiederholung
Hausarbeit
1
2
3
4
5
6
7
8
9
10
11
12
13
14
15
16
“Theorie”
Praxis
17.3.
24.3.
31.3.
7.4.
14.4.
21.4.
28.4.
5.5.
12.5.
19.5.
26.5.
2.6.
9.6.
16.6.
23.6.

Einführung in Python

- Skript-Sprache Python, Programme als Scripte (Text-Datei)
- Grundlegende Datentypen, Schleifen und eigene Funktionen
- Module zur Erweiterung des Funktionsumfangs

```
# Liste ['A', 'B', 'a', 'a',...]
liste = list("ABaaBccbbb")
anzahlBs = 0

# Zaehle die B's:
for x in liste:
  if x == 'B' or x == 'b':
    anzahlBs = anzahlBs + 1
```

Listen mit Strings

- Strings sind wie Listen von Buchstaben
- mit **in** kann geprüft werden, ob etwas in einer Liste enthalten ist:

```
wort = "Data Science"
if "en" in wort:
  print("'en' ist enthalten!")
```

- Listen mit Strings funktionieren natürlich auch:

```
woerter = [ "Data", "Science", "Daten"]
for wort in woerter:
  if "at" in wort:
    print(wort)
```

Eigene Funktionen

- Erweiterung um eigene Funktionen mit **def**
- **return** beendet die Funktion mit Rückgabewert

```
def avg(zahlenListe)
  # Wenn Liste leer => Ergebnis 0
  if len(zahlenListe) == 0:
    return 0

  sum = 0
  for zahl in zahlenListe:
    sum = sum + zahl

  return sum / len(zahlenListe)
```

Listen für Fortgeschrittene – *list comprehension*

- Aus der Mathematik – Mengennotation:

$$M = \left\{ x^2 \mid x \in \mathbb{N}, 5 \leq x \leq 10 \right\}$$

Listen für Fortgeschrittene – *list comprehension*

- Aus der Mathematik – Mengennotation:

$$M = \left\{ x^2 \mid x \in \mathbb{N}, 5 \leq x \leq 10 \right\}$$

- *List-comprehension* als Schreibweise für Listen

```
liste = list("ABaaBccbbb")

# extrahiere grosse und kleine B's
#
bs = [x for x in liste if x == 'b' or x == 'B']
anzahlBs = len(bs)
```

Python - Module

- Module als Bibliotheken mit fertigen Funktionen
- Einbindung von Modulen mit **import**
- Module mit Namensraum

```
# Binde das Modul 'datascience' im Namesraum 'ds' ein
import datascience as ds

# Einbinden von 'Zufall' in den globalen Namensraum
from datascience.vorhersage import Zufall

m = Zufall()    # statt ds.Zufall
```

Vorlesung 3
Pandas & Visualisierung

Vorgehen bei der Datenanalyse

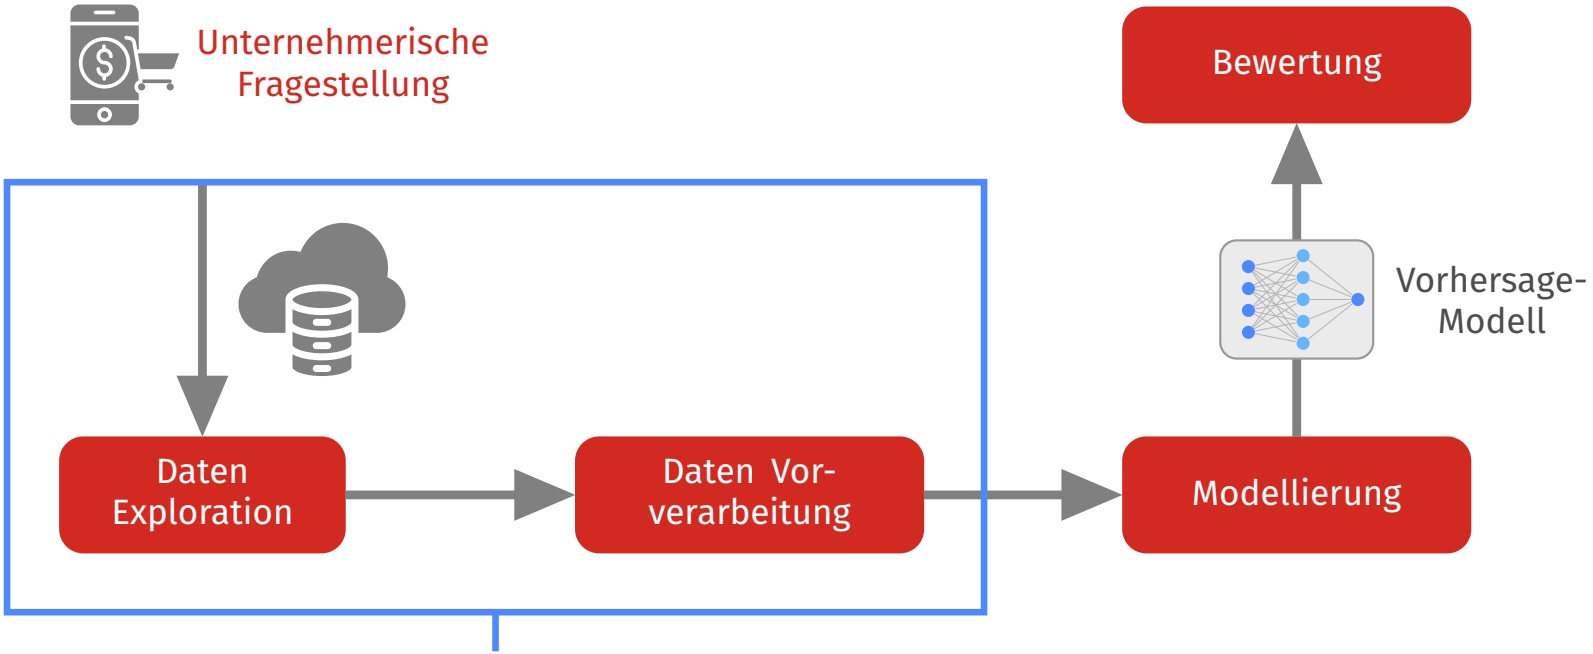

Datenvorverarbeitung

hier: Mit Python und Pandas

Vorlesung 3 (heute):

- Vorstellung des Moduls Pandas
- Selektieren/Filtern von Daten
- Grundlagen zur Arithmetik mit Pandas

Vorlesung 3 (heute):

- Vorstellung des Moduls Pandas
- Selektieren/Filtern von Daten
- Grundlagen zur Arithmetik mit Pandas

Hochschule Bochum
Bochum University
of Applied Sciences

Fachbereich Wirtschaft
Prof. Dr. Christian Bockermann

Data Science

Wintersemester 2021/2022

Übungsblatt 3

Dieses Übungsblatt beschäftigt sich mit dem Einlesen, dem Filtern und der Exploration von Daten. Die Daten liegen als CSV-Dateien in Ihrem Verzeichnis

pandas ist ein zentrales Modul für die Datenverarbeitung in Python

- Datentypen für Tabellen (`DataFrame`) und Zeitreihen (`Series`)
- Funktionen zum Lesen/Transformieren von Daten
- Unterstützung einer Vielzahl von Formaten: CSV, Excel, Datenbanken, usw.

```python
import pandas as pd

# Lesen von Daten aus CSV-Datei
df = pd.read_csv('meine_Daten.csv')
```

Einbinden des Moduls in ein Python Program

```
import pandas as pd

# optional dazu noch:
from pandas import Series, DataFrame
```

- Importiert Pandas als Modul mit Namensraum **pd**
- **pd** ist allgemein verbreiteter Namensraum für Pandas
- Häufig werden **Series** und **DataFrame** noch in den globalen Namensraum importiert (optional)

Pandas bietet Datentypen und Funktionen

- `pandas.read_csv`
- `pandas.read_excel`
- `pandas.to_csv`
- `Series.plot`
- `Series + Series`
- `DataFrame.plot`
- `DataFrame + DataFrame`
- `...`

Funktionen

0	**4**
1	**5**
2	**8**
3	**2**

Series

	a1	a2	a3	a4
0	**4**	**1**	**2**	**9**
1	**5**	**1**	**3**	**6**
2	**3**	**8**	**7**	**4**

DataFrame

Datentyp: Series

Datentyp für Reihe von Meßwerten: **`Series`**

Index	**Werte**
0	4
1	5
2	8
3	2

Ein `Series` Objekt aus einer Liste von Werten erzeugen:

```
data = Series([4,5,8,2])
```

Series ist wie Liste von Werten

- Series fast wie normale Python-Liste
- Kombinierbar mit **for**-Schleife:

```
data = Series([4,5,8,2])
laenge = len(data)  # ergibt 4

sum = 0
for zahl in data:
  sum = sum + zahl

print(sum / laenge)
```

Pandas Datentypen unterstützen Rechenoperationen

Zum Beispiel:

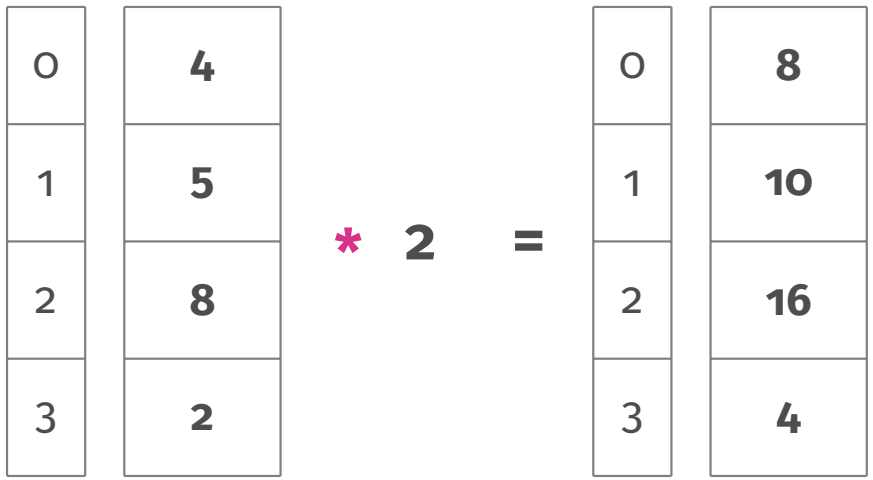


```
a = Series([4,5,8,2])
b = a * 2
```

DataFrame:

Ein DataFrame `df` ist eine Tabellenstruktur:

	a1	a2	a3
0	**4**	**1**	**2**
1	**5**	**1**	**3**
2	**3**	**8**	**7**

DataFrame:

Ein DataFrame `df` ist eine Tabellenstruktur:

	a1	a2	a3
0	**4**	**1**	**2**
1	**5**	**1**	**3**
2	**3**	**8**	**7**

Spalten-Index

`df.columns`

Zeilen-Index

`df.index`

DataFrame:

Ein DataFrame `df` ist eine Tabellenstruktur:

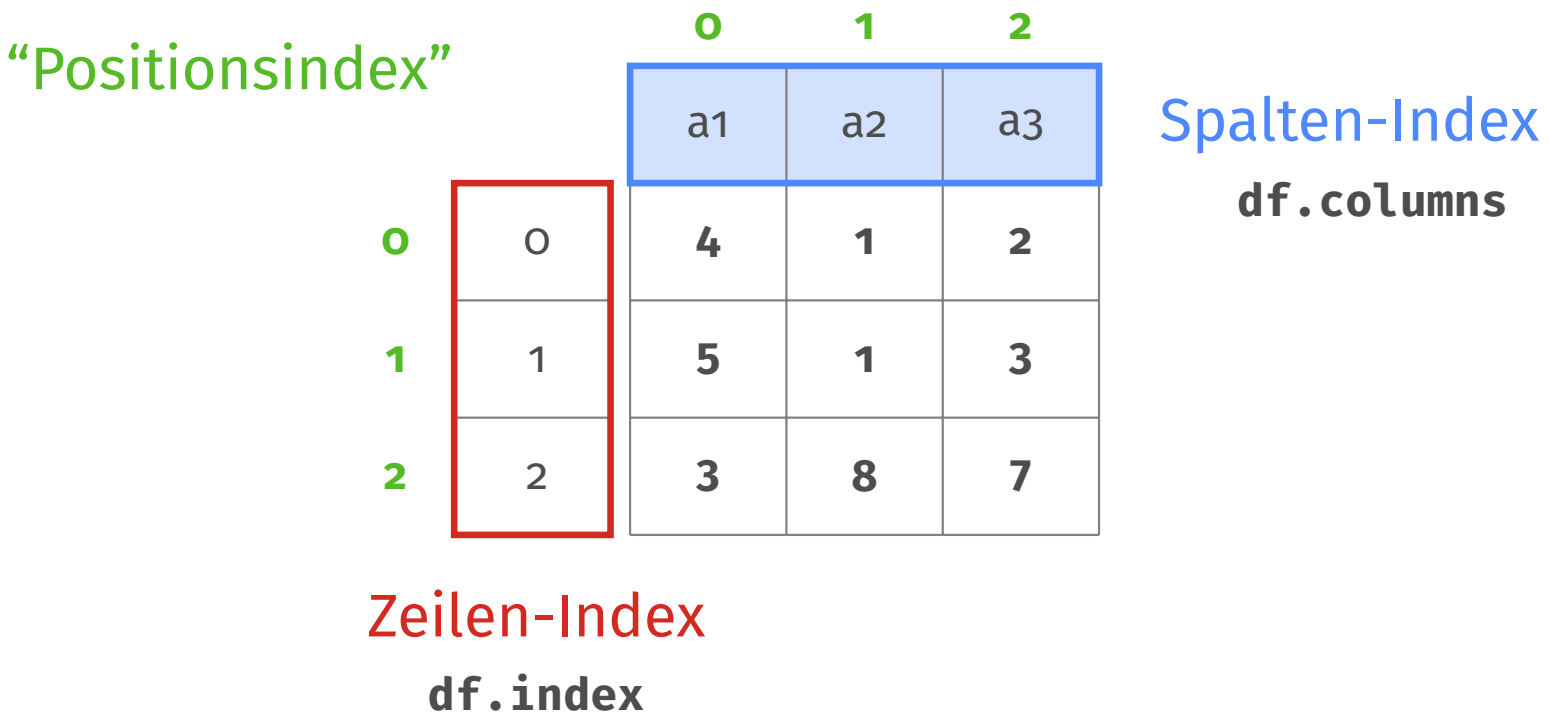

Die Form eines DataFrame

df =

	a1	a2	a3	a4
0	**4**	**1**	**2**	**9**
1	**5**	**1**	**3**	**6**
2	**3**	**8**	**7**	**4**

`df.shape` liefert die Form von `df`: (zeilen,spalten)

```
# 'shape' des obigen DataFrames  df

zeilen, spalten = df.shape      # zeilen=3, spalten=4
```

Einzelne Spalten sind `Series` Objekte

	a1	a2	a3	a4
0	**4**	**1**	**2**	**9**
1	**5**	**1**	**3**	**6**
2	**3**	**8**	**7**	**4**

Einzelne Spalten sind `Series` Objekte

	a1	a2	a3	a4
0	**4**	**1**	**2**	**9**
1	**5**	**1**	**3**	**6**
2	**3**	**8**	**7**	**4**

```python
a2 = df['a2']   # Spalte 'a2' selektieren
type(a2)        # -> pandas.core.series.Series

print(a2[2])    # gibt 8 aus
```

Mehrere Spalten ergeben wieder einen DataFrame

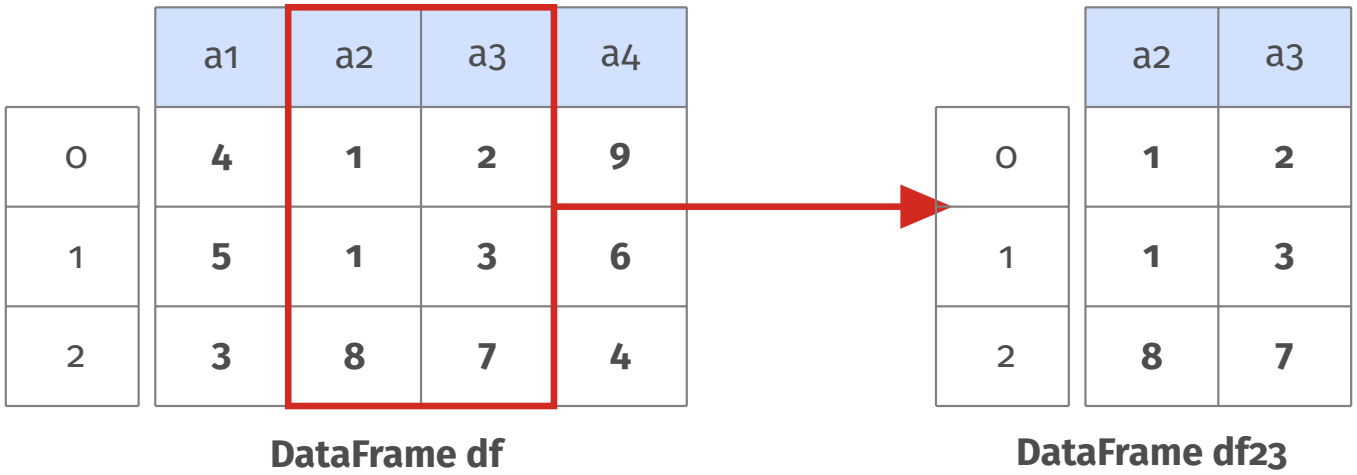


```
# z0,z1,z2 wie in Folie 29
df = DataFrame([z0, z1, z2],
               columns=['a1', 'a2', 'a3', 'a4'])
df23 = df[['a2','a3']]
```

Pandas enthält Funktionen zum Lesen von `DataFrames`

- `pd.read_csv` - Lesen aus CSV-Datei
- `pd.read_excel` - Lesen aus Excel-Datei

`DataFrame` aus CSV-Datei lesen:

```
# Lesen aus der Datei 'meine-daten.csv'
df = pd.read_csv("meine-daten.csv")

# Funktioniert auch mit URLs
u = "https://datascience.hs-bochum.de/data/iris.csv"
df = pd.read_csv(u)
```

Nachdem Laden – Was ist drin, im DataFrame?

- Wie sieht der DataFrame aus? → `df.head(5)`
- Anzahl der Zeilen/Spalten? → `df.shape`
- Welche Spalten/Datentypen? → `df.columns` / `df.dtypes`
- Wertebereiche der Spalten? → `df.describe()`

```python
import pandas as pd
df = pd.read_csv( "Kurse/DataScience1/data/iris.csv")

# Anfang anzeigen (ersten 5 Zeilen)
df.head(5)

# Spalten-Statistiken
df.describe()
```

Hochschule Bochum
Bochum University
of Applied Sciences

Spalten-Statistiken mit `describe()`

`describe()` berechnet Statistiken für numerische Spalten

```
# Statistiken berechnen:
df.describe()
```

	a1	a2	a3
count	3.00	3.00	3.00
mean	4.00	3.33	4.00
std	1.00	4.04	2.65
min	3.00	1.00	2.00
25%	3.50	1.00	2.50
50%	4.00	1.00	3.00
75%	4.50	4.50	5.00
max	5.00	8.00	7.00

Spalten-Statistiken mit `describe()`

`describe()` berechnet Statistiken für numerische Spalten

```
# Statistiken berechnen:
df.describe()
```

```
# Und das Ergebnis
# von df.describe()?
stats = df.describe()
```

Ist natürlich wieder ein DataFrame

	a1	a2	a3
count	3.00	3.00	3.00
mean	4.00	3.33	4.00
std	1.00	4.04	2.65
min	3.00	1.00	2.00
25%	3.50	1.00	2.50
50%	4.00	1.00	3.00
75%	4.50	4.50	5.00
max	5.00	8.00	7.00

Einfache Plots mit DataFrame

```
iris = pd.read_csv('data/iris.csv')
iris.plot.scatter(x='sepal_length', y='sepal_width')
```

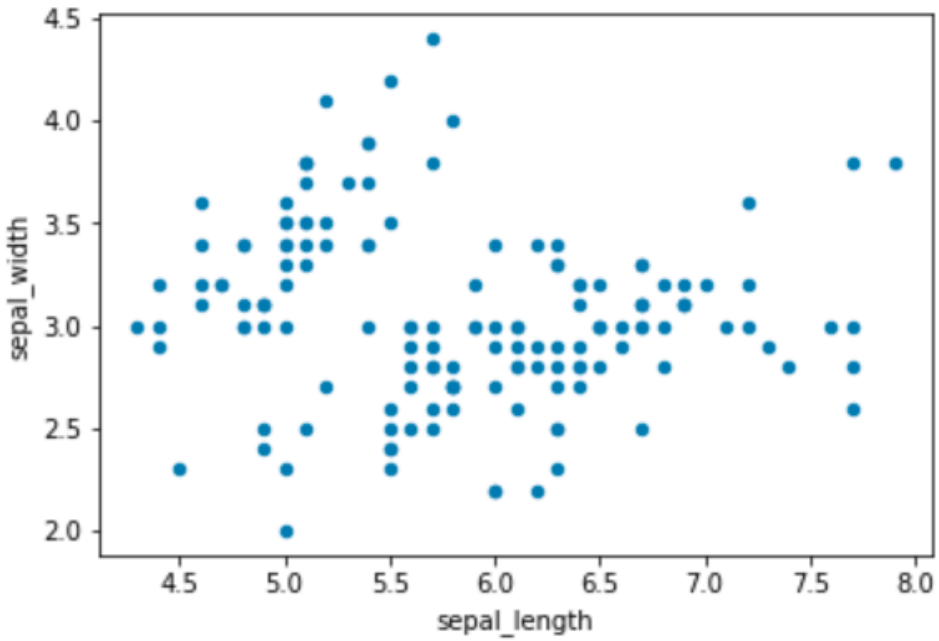

Vorschau auf nächste Woche

Vorlesung 4 (nächste Woche): Tutorial Day

- Keine neuen Inhalte (bzgl. Maschinelles Lernen)
- Wiederholung + Vertiefung
- Zentrales Thema: Python + Pandas

Ablauf:

- Vorlesung um 8:30 Uhr in Präsenz
- Es gibt Übungsaufgaben/Folien und Notebooks