Data Science

Tutorial Day

Prof. Dr. Christian Bockermann

Hochschule Bochum

Wintersemester 2020/2021

Tutorial Day am Dienstag, 17.11.2020

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

Ablauf:

- Treffpunkt um 12 Uhr im Big Blue Button (Vorlesung)
- Es gibt Übungsaufgaben/Folien und Notebooks
- Selbststudium mit Unterstützung über Big Blue Button während der Zeit von 12 bis 16 Uhr (s.t.)

Der Tutorial Day gibt Aufgaben zu den folgenden Themen

1. Python Listen, Strings (Aufgaben P1, P2, ...)
2. Pandas Series (Aufgaben S1, S2, ...)
3. Pandas DataFrame (Aufgaben D1, D2, ...)

Wiederholung

Zur Wiederholung:

Ein DataFrame `df` ist eine Tabellenstruktur:

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

Zur Wiederholung:

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`

Zur Wiederholung:

Ein DataFrame `df` ist eine Tabellenstruktur:

“Positionsindex”

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

Spalten-Index

`df.columns`

Zeilen-Index

`df.index`

Ein DataFrame df mit anderen Indizes

```
df.index = ['A', 'B', 'C']
df.columns = ['x1','x2','x3']
```

“Positionsindex”

		0	1	2
		x1	x2	x3
0	A	4	1	2
1	B	5	1	3
2	C	3	8	7

Spalten-Index
df.columns

Zeilen-Index
df.index

Einzelne Zeilen/Spalten sind `Series` Objekte

Zugriff auf `df` über verschiedene Elemente:

```
df[0:2]     # Zeilen mit Slicing
df[['a1','a2']]  # Spalten durch Namensliste

# Zugriff mit Positionsindex:
df.iloc[zeilen,spalten]

# Zugriff mit Zeilen/Spalten-Index:
df.loc[zeilen,spalten]
```

Mit **df.iloc[...]** wird nach Position selektiert

```
df.iloc[ ZEILEN,SPALTEN ]
```

ZEILEN bzw. SPALTEN sind Zahlen, Listen von Zahlen, Slices

```
# Zelle in erster Zeile, dritter Spalte:
df.iloc[0,2]

#  Die erste Zeile (als Series Objekt!)
df.iloc[0,:]

# Die erste Spalte:
df.iloc[:,0]
```

Selektieren mit `.iloc[..]`

Beim Slicing a:b gehört a dazu, b nicht mehr:

```
# die Zeilen 0 und 1:
df.iloc[0:2,:]

# die Spalten 0 und 1:
df.iloc[:,0:2]
```

Was passiert bei `.loc[..]`?

```
df.loc['A':'B']
```

		0	1	2
		x1	x2	x3
0	A	4	1	2
1	B	5	1	3
2	C	3	8	7

Was passiert bei `.loc[..]`?

```
df.loc['A':'B']
```

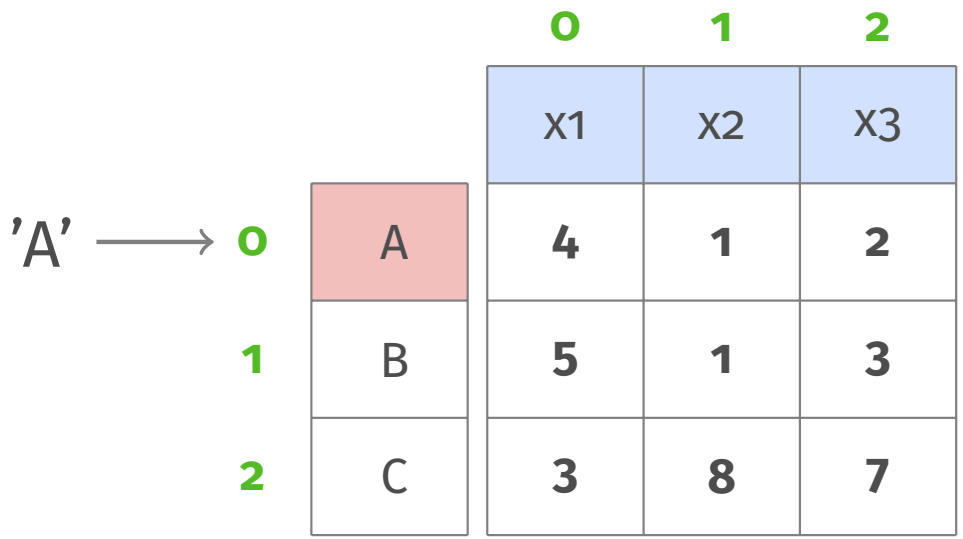

Was passiert bei `.loc[..]`?

```
df.loc['A':'B']
```

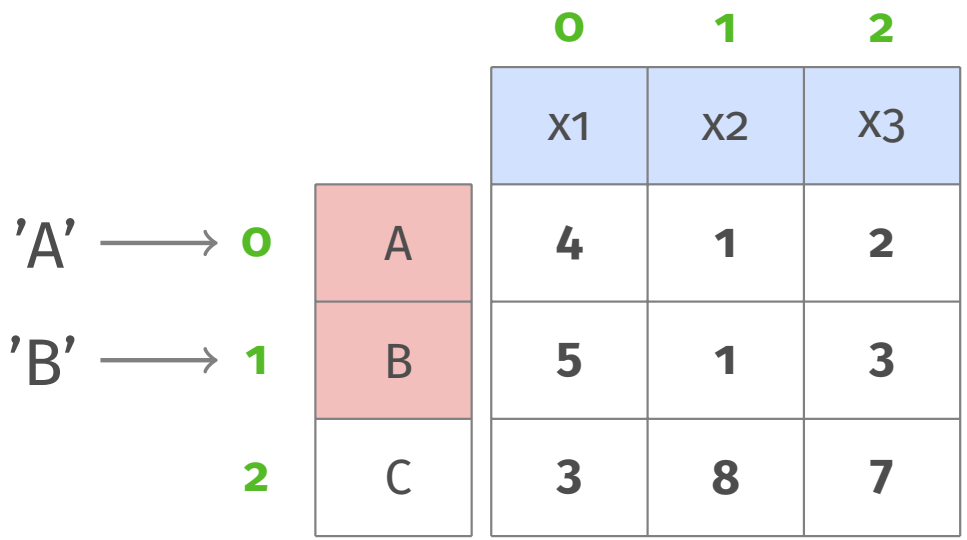

Was passiert bei `.loc[..]`?

```
df.loc['A':'B']
```

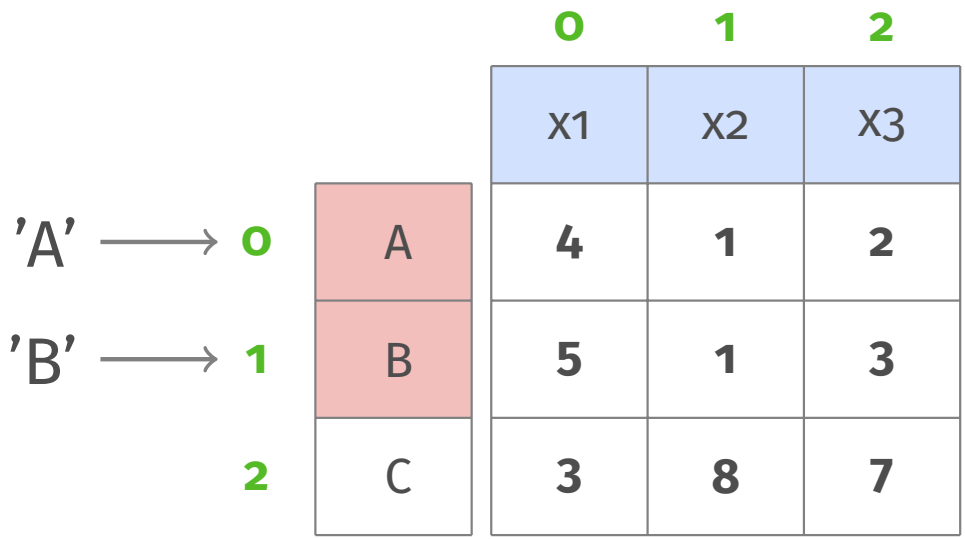

Es werden beide Zeilen (A und B) selektiert!

Notebooks für Übungen

- Notebook Server enthält `TutorialDay` Verzeichnis
- Drei Notebooks: Python, Series und DataFrame
- Für viele Aufgaben `tutorial` Modul mit Selbsttest

Demo Notebook-Server

Python Listen, Strings

Die P-Aufgaben drehen sich um Python und Listen.

Die Funktion `tutorial.wortliste()` aus dem Tutorial-Modul liefert eine Liste von Wörtern:

```
words = tutorial.wortliste()
```

Diese Liste können Sie für die Aufgaben gerne als Test-Daten nutzen.

Aufgabe P1:

1. Schreiben Sie eine Funktion `last_word(ws)`, die eine Liste von Wörtern als Parameter bekommt und das letzte Wort aus der Liste zurückiefert.
2. Testen Sie Ihre Funktion in dem Sie der Variablen `letztesWort` das letzte Wort aus der Wortliste zuweisen.

Rufen Sie anschließend `tutorial.AufgabeP1()` auf, um Ihre Funktion zu testen!

Aufgabe P2:

1. Schreiben Sie eine Funktion `words_with(xs, w)`, die aus einer Liste von Wörtern die Wörter heraussucht, die die Zeichenfolge `w` enthalten.

Beispiel:

```
words = ["abc", "bcd", "cde"]

words_with(words, "cd")
# sollte  ['bcd', 'cde']  zurueckgeben
```

Rufen Sie anschließend `tutorial.AufgabeP2()` auf, um Ihre Funktion zu testen!

Aufgabe P3:

1. Schreiben Sie eine Funktion `max_words`, die aus einer Liste von Wörtern die längsten Wörter heraussucht.
2. Definieren Sie auch eine Funktion `min_words` für die kürzesten Wörter einer Liste.

Hinweis:
Falls es ein eindeutiges längstes/kürzestes Wort in der Liste gibt, soll Ihre Funktion eine 1-elementige Liste mit diesem Wort zurückgeben.

Aufgabe P4:

Mit `range(n)` kann man in Python Folgen erzeugen

1. Benutzen Sie `range` und `list` um eine Liste `n10` der Zahlen von 1 bis 10 zu erzeugen.
2. Schreiben Sie eine Funktion `alle_vorhanden`, die überprüft, ob eine Liste der Länge *n* alle Zahlen von 1 bis *n* enthält.

Beispiel:

```
xs = [1,2,3,4,5]
alle_vorhanden(xs, 5)  # ergibt True

xs2 = [1,1,2,4,2]
alle_vorhanden(xs2, 5) # ergibt False
```

Pandas Series

Pandas Series

Die folgenden S-Aufgaben, beziehen sich auf Pandas `Series`.

Es geht um

- das Erstellen von Series Objekten,
- den Zugriff auf Elemente von Series Objekten,
- die Berechnung einfacher Werten.

Aufgabe S1

Betrachten Sie die Folgen

$$4, 8, 7 \quad \text{und} \quad 1, -3, -2, 5$$

1. Definieren Sie eine Variable `series1` mit der ersten Folge 4, 8, 7.
2. Definieren Sie eine Variable `series2` mit der zweiten Folge.

Aufgabe S2 - Zugriff auf Elemente

Sie haben in Aufgabe S1 die Series `series1` definiert

1. Definieren Sie eine Variable a, die das zweite Element der Series enthält.
2. Definieren Sie eine Variable b, die das letzte Element der Series enthält
   (Erinnern Sie sich an *Slicing* und negative Indizes?).

Aufgabe S4 - Filtern

Über den Zugriffsoperator `s[...]` lassen sich Series Werte filtern:

1. Schreiben Sie eine Funktion `groessere0`, die eine Series übergeben bekommt und eine Series mit den Werten zurückliefert, die größer oder gleich 0 sind.

Aufgabe S5 - Funktionen auf `Series` Objekten

1. Schreiben Sie eine Funktion `smax`, die den maximalen Wert einer Series zurückgibt.
2. Schreiben Sie eine Funktion `smin`, die den minimalen Wert zurückgibt.

Aufgabe S6 - Funktionen auf `Series` Objekten

Die Min-Max Normalisierung ist dadurch definiert, dass jeder Wert v durch

$$v' = \frac{v - min}{max - min}$$

ersetzt wird.

1. Schreiben Sie eine Funktion `snorm(series)`, die aus einer Series eine normalisierte Series nach der Min-Max Normalisierung berechnet.

Pandas DataFrame

Die folgenden Aufgaben beziehen sich auf `DataFrame`

1. Erstellen von DataFrames
2. Selektieren von Zeilen/Spalten
3. Eigene Funktionen auf DataFrame Objekten

Aufgabe D1

Erstellen Sie den folgenden `DataFrame` und weisen Sie ihn der Variablen **`df1`** zu:

A	B
1	**2**
3	**4**

Aufgabe D2

Erstellen Sie ein `Series` Objekt mit den Werten 5 und 6 und fügen Sie es als neue Spalte “C” in den DataFrame **`df1`** ein. Der DataFrame sollte dann folgendermaßen aussehen:

A	B	C
1	**2**	**5**
3	**4**	**6**

Aufgabe D3

Erstellen Sie im `DataFrame` **`df1`** die Spalte “Z”, die die Summe der Spalten “A”, “B” und “C” enthält:

A	B	C	Z
1	**2**	**5**	**8**
3	**4**	**6**	**13**

Aufgabe D4

Teilen Sie im DataFrame **`df1`** alle Spalten ausser der Spalte “Z” durch die Werte der “Z”-Spalte.

Das Ergebnis sollte folgendermaßen aussehen:

A	B	C	Z
0.125	**0.250**	**0.625**	**8**
0.231	**0.308**	**0.462**	**13**

Selektieren von Zellen/Bereichen

Die Funktion `tutorial.toy_data()` liefert das folgende `DataFrame` Objekt zurück:

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

1. Definieren Sie die Variable `df_rot`, die den rot markierten Teil des DataFrames enthält.
2. Definieren Sie die Variable `df_blau`, für den blau markierten Teil.

Selektieren von Zellen/Bereichen

1. Definieren Sie einen quadratischen DataFrame `qf`, indem Sie aus dem `toy_data()` DataFrame die ersten $n = 3$ Zeilen/Spalten selektieren.
2. Schreiben Sie eine Funktion `quadrat(df)`, die aus einem DataFrame den größten quadratischen Block extrahiert (von oben links beginnend).
3. Schreiben Sie eine Funktion `diag(df)`, die für einen DataFrame die Liste der Elemente auf der Hauptdiagonalen zurückliefert.

Aufgabe D7*

Mit .apply(f, axis=1) wird eine Funktion auf alle Zeilen angewandt:

```
# f gibt fuer jede Zeile 1 zurueck:
def f(row):
    # row ist ein Series Objekt!
  return 1

# f auf alle Zeilen anwenden
series = df.apply(f, axis=1)
```

Aufgabe D7*

Betrachten Sie die folgende Tabelle:

Länge (cm)	**Breite** (cm)	**Höhe** (cm)	**Entfernung** (km)	**Dienstleister**
100	100	40	20	WPS
110	100	100	60	UPS
100	210	100	70	WPS
50	100	70	89	DHL

(Aufgabenblatt 4 aus Wirtschaftsinformatik 1)

Der Datensatz (ohne die Dienstleister-Spalte) ist als CSV-Datei im `data` Verzeichnis enthalten.

Aufgabe D7*

1. Laden Sie den Versand-Datensatz in einen DataFrame.
2. Schreiben Sie eine Funktion, die den Dienstleister pro Zeile berechnet.
3. Berechnen Sie die Spalte Dienstleister mit ihrer Funktion.

Regeln für die Dienstleister-Funktion:

- Paketvolumen < $1m^3$, dann Dienstleister DHL
- $1m^3 \leq$ Paketvolumen $< 2m^3$, dann Dienstleister UPS
- Paketvolumen $\geq 2m^3$, dann Dienstleister WPS
- Wenn Entfernung $< 50km$, dann auf jeden Fall WPS

Selektieren von Zellen/Bereichen

Die Funktion `tutorial.sudoku()` liefert einen 4x4 DataFrame:

0	1	2	3
2	1	3	4
4	3	1	2
1	2	4	3
3	4	2	1

Beim Spiel **Sudoku**, müssen in jeder Zeile, jeder Spalte und jedem Block die Ziffern 1 bis 4 genau einmal vorkommen.

Aufgabe D8*

1. Schreiben Sie eine Funktion `sudoku_zeile`, die für eine Zeile eines 4x4 DataFrame `True` liefert, wenn es eine gültige Sudoku Zeile ist.
2. Schreiben Sie eine Funktion `sudoku_spalte`, die für eine Spalte eines 4x4 DataFrame `True` zurückgibt, wenn es eine gültige Sudoku Spalte ist.
3. Schreiben Sie eine Funktion `sudoku_block`, die für einen 2x2 Block eines DataFrame `True` zurückgibt, wenn es ein gültiger Sudoku Block ist.