

Python Grundlagen

Julian Huber & Matthias Panny

Scientific Computing II

Lernziele

- Studierende können Daten in das tidy data Format bringen
- Studierende können Daten mit pandas auswerten

“ Happy families are all alike; every unhappy family is unhappy in its own way

— *Leo Tolstoy* ”

“ Like families, tidy datasets are all alike but every messy dataset is messy in its own way. Tidy datasets provide a standardized way to link the structure of a dataset (its physical layout) with its semantics (its meaning).

— *Hadley Wickham* ”

Idee von tidy data

- Viele Funktionen erwarten die gleichen ordentliche Datenstrukturen as input
- Entspricht der Struktur von Datenbanken (Codd's 3. Normalform)
- H. Wickham, “[Tidy Data](#)”, J. Stat. Soft., vol. 59, no. 10, pp. 1–23, Sep. 2014.

Beispiel

Robot_ID	Timestamp	Sensor_Type	Sensor_Value	Unit
1	2023-09-27 08:00:00	Temperature	25.3	°C
1	2023-09-27 08:00:15	Temperature	25.5	°C
1	2023-09-27 08:00:30	Humidity	45.2	%
2	2023-09-27 08:00:00	Temperature	24.8	°C
2	2023-09-27 08:00:15	Temperature	24.9	°C
2	2023-09-27 08:00:30	Humidity	46.0	%
3	2023-09-27 08:00:00	Temperature	25.0	°C
3	2023-09-27 08:00:15	Temperature	25.1	°C
3	2023-09-27 08:00:30	Humidity	45.8	%

- Jede Variable steht in einer eigenen Spalte
- Jede Beobachtung/jeder Fall steht in einer eigenen Zeile
- Jeder einzelne Wert steht in einer Zelle

Diskussion

- Inwiefern macht es Sinn den Zeitstempel (inkl. Datum und Uhrzeit) in eine Spalte zu setzen?

Untidy Data: Mehr als ein Wert pro Zelle

Robot_ID	Sensor_Data
1	{"Timestamp": "2023-09-27 08:00:00", "Type": "Temperature", "Value": 25.3}
1	{"Timestamp": "2023-09-27 08:00:15", "Type": "Temperature", "Value": 25.5}
1	{"Timestamp": "2023-09-27 08:00:30", "Type": "Humidity", "Value": 45.2}
2	{"Timestamp": "2023-09-27 08:00:00", "Type": "Temperature", "Value": 24.8}
2	{"Timestamp": "2023-09-27 08:00:15", "Type": "Temperature", "Value": 24.9}
2	{"Timestamp": "2023-09-27 08:00:30", "Type": "Humidity", "Value": 46.0}
3	{"Timestamp": "2023-09-27 08:00:00", "Type": "Temperature", "Value": 25.0}
3	{"Timestamp": "2023-09-27 08:00:15", "Type": "Temperature", "Value": 25.1}
3	{"Timestamp": "2023-09-27 08:00:30", "Type": "Humidity", "Value": 45.8}

Tidy Data

- Wie alle Regeln gibt es auch Ausnahmen
- Vorteile einer Spalte für `Temperature_C` und `Humidity_%`:
 - Platzsparend
- Vorteile `Sensor_Type`, `Sensor_Value`, `Unit`:
 - Flexibler z.B: bei verschiedenen Einheiten
 - Einfacher zu verarbeiten
 - Kann leichter in erste Form umgewandelt werden als umgekehrt

Untidy Data?

Robot_ID	Timestamp	Temperature_C	Humidity_%
1	2023-09-27 08:00:00	25.3	45.2
1	2023-09-27 08:00:15	25.5	45.1
2	2023-09-27 08:00:00	24.8	46.0
2	2023-09-27 08:00:15	24.9	46.2
3	2023-09-27 08:00:00	25.0	45.8
3	2023-09-27 08:00:15	25.1	45.9



Comma Separated Values (CSV-Files)

- speichert Tabellen als einfache Textdatei
- Namenskonvention `<file_name>.csv`
- kann mit Excel oder jedem Texteditor geöffnet werden
- `README.txt` könnte ergänzt werden, um weitere Informationen (z.B. Einheit der Größen) zu ergänzen
- teilweise hierfür auch zweite Kopfzeile

`pandas_data.csv`

```
Robot_ID, Timestamp, Sensor_Type, Sensor_Value, Unit
1, 2023-09-27 08:00:00, Temperature, 25.3, °C
1, 2023-09-27 08:00:15, Temperature, 25.5, °C
1, 2023-09-27 08:00:30, Humidity, 45.2, %
2, 2023-09-27 08:00:00, Temperature, 24.8, °C
2, 2023-09-27 08:00:15, Temperature, 24.9, °C
2, 2023-09-27 08:00:30, Humidity, 46.0, %
3, 2023-09-27 08:00:00, Temperature, 25.0, °C
3, 2023-09-27 08:00:15, Temperature, 25.1, °C
3, 2023-09-27 08:00:30, Humidity, 45.8, %
```



Comma Separated Values (CSV-Files)

- In jeder Zeile werden die gleichen Spalten, am besten im gleichen Datentyp erwartet (vgl. `Array`, `Series`)
 - leider nicht immer so (vgl. `"45.8"`)
- Der Delimiter oder Separator ist das Trennzeichen zwischen Spalten (z.B. `,`, `;`, `\t`)
- Je nach Spracheinstellung kann dies zu Problemen mit den Dezimaltrennzeichen führen (`3,14` vs. `3.14`)

`data.csv` - Einige Fehlerquellen

```
Robot_ID, Timestamp, Sensor_Type, Sensor_Value
1;2023-09-27 08:00:00;Temperature,25.3
1;2023-09-27 08:00:15;Temperature,
1;2023-09-27 08:00:30;45.2
2;2023-09-27 08:00:00;Temperature,24.8
2;2023-09-27 08:00:15;Temperature,24.9
2;2023-09-27 08:00:30;Humidity,"46.0"
3;2023-09-27 08:00:00;Temperature,25.0
3;2023-09-27 08:00:15;Temperature,25.1
3;2023-09-27 08:00:30;Humidity,"45.8"
```

Tabellendaten in Python

- Python ist gut geeignet um mit tabellarischen Daten zu arbeiten
- Meistverwendetes package: `pandas` → `pip install pandas`

pandas

- Eigner Datentyp für Tabellen: `DataFrame`
- Viele Funktionen zum Einlesen, Bearbeiten und Auswerten
- Testdaten: `pandas_data.csv`

```
import pandas as pd
```

```
df = pd.read_csv(r"01_Python_Grundlagen\Examples\pandas\pandas_data.csv", sep = ",")  
print(df.head())
```

	Robot_ID	Timestamp	Sensor_Type	Sensor_Value
0	1	2023-09-27 08:00:00	Temperature	25.3
1	1	2023-09-27 08:00:15	Temperature	25.5
2	1	2023-09-27 08:00:30	Humidity	45.2
3	2	2023-09-27 08:00:00	Temperature	24.8
4	2	2023-09-27 08:00:15	Temperature	24.9

Index

- Bei der ersten (unbeschrifteten) Spalte handelt es sich um den Index (vgl. Liste)
- Dieser macht jede Zeile (Beobachtung) eindeutig identifizierbar
- Oft ist der Index einfach durchnummeriert (**RangeIndex**)

```
print(df.index)  
# RangeIndex(start=0, stop=9, step=1)
```

- Es könnte aber jeder Datentyp in Frage kommen, sofern der Index für jede Zeile eindeutig ist (hier z.B. *nicht* der **Timestamp**)

Adressierung über Index

- Beobachtungen können über den Index mittels `.loc[]` aufgerufen werden

```
print(df.loc[0])
```

```
Robot_ID          1
Timestamp    2023-09-27 08:00:00
Sensor_Type      Temperature
Sensor_Value      25.3
Name: 0, dtype: object
```

- `[]` anstelle von `()`, da `loc` keine Funktion, sondern ein Objekt ist und die Notation so `numpy` ähnelt

Series

- Über eckige Klammern (indexing) direkt lassen sich hingegen die Spalten (Variablen) aufrufen
- In der Ausgabe erkennen wir auch links den **Index** wieder
- Bei der Rückgabe handelt sich um ein **Series**-Objekt mit einem **Index** und einer Sammlung von Daten gleichen Datentyps (**dtype**)

```
print(df["Timestamp"])
```

```
0      2023-09-27 08:00:00
1      2023-09-27 08:00:15
2      2023-09-27 08:00:30
3      2023-09-27 08:00:00
4      2023-09-27 08:00:15
5      2023-09-27 08:00:30
6      2023-09-27 08:00:00
7      2023-09-27 08:00:15
8      2023-09-27 08:00:30
Name: Timestamp, dtype: object
```

Datentypen einer Series

- `int64`
 - Beispiele: 1, -42, 1000
- `float64`
 - Beispiele: 3.14, -0.5, 2.71828
- `bool`
 - Beispiele: True, False
- `object`
 - Vielzahl von Python-Objekte. Auch bei "gemischten" `Series`
 - Beispiele: "Hallo", None, [1, 2, 3]
- `datetime64`
 - Beispiele: 2023-09-27 08:00:00, 2022-03-15 12:30:00
- `timedelta64`
 - Beispiele: 1 day, 2 hours, 30 minutes
- `categorical`
 - Dieser Datentyp wird für kategorische Daten verwendet, die eine begrenzte Anzahl von eindeutigen Werten haben.
 - Beispiele: "Rot", "Grün", "Blau"

Beispieldatensatz

	sensor_id	component_status	temp_C	pressure_pa
0	1	Operational	98.2	101325.0
1	2	Faulty	NaN	100984.0
2	3	Operational	3.0	102045.0
3	4	Operational	24.8	102045.0
4	5	Faulty	101.7	NaN

```
# Das Abrufen von Spalten durch den Spaltennamen gibt nur diese Spalte zurück.  
first_column = df["sensor_id"]  
print(first_column)
```

```
0    1  
1    2  
2    3  
3    4  
4    5  
Name: sensor_id, dtype: int64
```

Aufruf von Methoden

	sensor_id	component_status	temp_C	pressure_pa
0	1	Operational	98.2	101325.0
1	2	Faulty	NaN	100984.0
2	3	Operational	3.0	102045.0
3	4	Operational	24.8	102045.0
4	5	Faulty	101.7	NaN

Funktionen, die für eine Spalte aufgerufen werden und einen Wert zurückgeben

```
df["component_status"].mode()
```

> "Operational"

```
df["temp_C"].mean()
```

> 56.925

Auswahl von Daten-Schnitten

	sensor_id	component_status	temp_C	pressure_pa
0	1	Operational	98.2	101325.0
1	2	Faulty	NaN	100984.0
2	3	Operational	3.0	102045.0
3	4	Operational	24.8	102045.0
4	5	Faulty	101.7	NaN

```
# Das Abrufen von Zeilen durch den Indexierungs-Operator  
# gibt alle Werte (Spalten) für diese Zeile zurück.  
second_row = df.loc[1]  
print(second_row)
```

```
sensor_id                2  
component_status        Faulty  
temp_C                  NaN  
pressure_pa            100984.0  
Name: 1, dtype: object
```

Auswahl von Daten-Schnitten

	sensor_id	component_status	temp_C	pressure_pa
0	1	Operational	98.2	101325.0
1	2	Faulty	NaN	100984.0
2	3	Operational	3.0	102045.0
3	4	Operational	24.8	102045.0
4	5	Faulty	101.7	NaN

Das Abrufen einer Zelle über Index und Spaltennamen

```
cell = df.loc[1]["component_status"]
```

```
print(cell)
```

```
#> "Faulty"
```

Abrufen einer Zelle über den iloc operator

(hierbei werden Zeilen und Spalten durchnummeriert)

cell = df.iloc[1][1] --> funktioniert, aber FutureWarning

```
cell = df.iloc[1, 1]
```

```
print(cell)
```

```
#> "Faulty"
```

Filtern und `where`-clause

	sensor_id	component_status	temp_C	pressure_pa
0	1	Operational	98.2	101325.0
1	2	Faulty	NaN	100984.0
2	3	Operational	3.0	102045.0
3	4	Operational	24.8	102045.0
4	5	Faulty	101.7	NaN

```
# liefert eine Serie, für alle Sensoren mit Status "Operational" wahr ist
filter1 = df["component_status"] == "Operational"
print(filter1)
```

```
0      True
1     False
2      True
3      True
4     False
Name: component_status, dtype: bool
```

Filtern und `where`-clause

```
# Wir können diese Serie verwenden, um nur nach funktionierenden Sensoren zu filtern.  
filtered_df = df.where(filter1)  
print(filtered_df)
```

	sensor_id	component_status	temp_C	pressure_pa
0	1.0	Operational	98.2	101325.0
1	NaN	NaN	NaN	NaN
2	3.0	Operational	3.0	102045.0
3	4.0	Operational	24.8	102045.0
4	NaN	NaN	NaN	NaN

Filtern und `where`-clause

```
# Es gibt auch einen kürzeren Weg, dies zu schreiben  
# Nimm df an allen Indexpositionen, bei denen "component_status" "Operational" ist.  
filtered_df = df[df["component_status"] == "Operational"]  
print(filtered_df)
```

	sensor_id	component_status	temp_C	pressure_pa
0	0	1	Operational	98.2
2	2	3	Operational	3.0
3	3	4	Operational	24.8

- Beachten Sie, dass ein letzter Befehl nicht der üblichen Syntax entspricht: `df[<column_name>]` vs `df[<series_of_bools>]`

Gruppieren

sensor_id		component_status	temp_C	pressure_pa
0	1	Operational	98.2	101325.0
1	2	Faulty	NaN	100984.0
2	3	Operational	3.0	102045.0
3	4	Operational	24.8	102045.0
4	5	Faulty	101.7	NaN

liefert eine die Durchschnittswerte nach Sensor Status
`df.groupby("component_status").mean()`

sensor_id		temp_C	pressure_pa
component_status			
Faulty		3.500000	101.7
Operational		2.666667	42.0

liefert eine die Durchschnittswerte nach Sensor Status
und gibt nur die Temperatur zurück
`df.groupby("component_status").mean()["temp_C"]`

Erstellen von neuen Spalten

	sensor_id	component_status	temp_C	pressure_pa
0	1	Operational	98.2	101325.0
1	2	Faulty	NaN	100984.0
2	3	Operational	3.0	102045.0
3	4	Operational	24.8	102045.0
4	5	Faulty	101.7	NaN

Erstellt eine neue Spalte durch Berechnung
`df['pressure_hpa'] = df['pressure_pa'] / 100`
`df`

	sensor_id	...	pressure_pa	pressure_hpa
0	1	...	101325.0	1013.25
1	2	...	100984.0	1009.84
2	3	...	102045.0	1020.45
3	4	...	102045.0	1020.45
4	5	...	NaN	NaN

`inplace`-Argumente

- die meisten Methoden auf DataFrames haben als Rückgabe einen neuen DataFrame
 - `new_df = df.where(filter1)`
- `inplace`-Argument erlaubt es, die Änderungen direkt auf dem DataFrame durchzuführen
 - `df.where(filter1, inplace=True)`
 - vgl. `list.append()` verändert die Liste direkt
 - `print(df.where(filter1, inplace=True))` gibt dann `None` zurück

Aufgabe

Um das Verständnis für `pandas` weiter zu vertiefen kann das hier verlinkte Notebook bearbeitet werden.

[Jupyter Notebook](#)



Hausübung

- Es wurde ein Windkanalversuch durchgeführt um den Luftwiderstand eines neuentwickelten Motorrades im Modellversuch zu bestimmen.
- Dazu wurde das Modell des Motorrades in den Windkanal gestellt und bei verschiedenen Windgeschwindigkeiten mit einem Kraft-Momenten-Sensor die aus dem Luftwiderstand resultierenden Kräfte und Momente gemessen.

Aufgabe

- Laden & transformieren Sie die gemessenen Daten
- Bestimmen Sie den c_w -Wert des Motorrads
- Visualisieren Sie die Ergebnisse