

SciPy & Pandas

Felix Maurer

Universität Hamburg

20. Mai 2019

Inhaltsverzeichnis

① SciPy

- Übersicht

- Wichtige Submodule

- Vergleich

② Pandas

- Übersicht

- Wichtige Funktionen

- Vergleich

③ Anwendungsbeispiel

④ Zusammenfassung

⑤ Literatur

SciPy: Übersicht

- Python-Modul: erweitert Python um komplexere mathematische Funktionen
 - Fokus: Wissenschaftliches Rechnen, Visualisierung
 - Teil des SciPy Stacks
 - Erweiternd auf NumPy aufgebaut
- Open Source
- Kostenlos
- Installation: `pip install scipy`

SciPy: Wichtige Submodule

Ich beschränke mich heute auf:

- `scipy.integrate`
- `scipy.linalg`
- `scipy.interpolate`

SciPy: Wichtige Submodule: scipy.integrate

quad: `scipy.integrate.quad(func, a, b)`

- `func`: Zu integrierende Funktion
- `a`: Anfang des Integrals
- `b`: Ende des Integrals

Beispiel: $\int_0^5 x^2 dx$

```
In [15]: import scipy.integrate
```

```
In [13]: scipy.integrate.quad(lambda x: x**2, 0, 5)
```

```
Out[13]: (41.666666666666666, 4.625929269271485e-13)
```

SciPy: Wichtige Submodule: scipy.integrate (2)

dblquad: `scipy.integrate.dblquad(func, a, b, gfun, hfun)`

- `func`: Zu integrierende Funktion
- `a`: Anfang des äußeren Integrals
- `b`: Ende des äußeren Integrals
- `gfun`: Funktion, die unteres Ende des inneren Integrals beschreibt
- `hfun`: Funktion, die oberes Ende des inneren Integrals beschreibt

Beispiel: $\int_{y=0}^1 \int_{x=0}^{2y} (x+y) dx dy$

```
In [15]: import scipy.integrate
```

```
In [17]: scipy.integrate.dblquad(lambda x,y: x+y,0,1, lambda x: 0, lambda x: 2*x)
```

```
Out[17]: (1.3333333333333335, 4.421626967161769e-14)
```

SciPy: Wichtige Submodule: scipy.linalg

inv: `scipy.linalg.inv(A)`

- A: Quadratische Matrix

Beispiel:

$$\text{Sei } A = \begin{pmatrix} 4 & 2 \\ 3 & 1 \end{pmatrix}. \text{ Was ist } A^{-1}? \left(A \cdot A^{-1} = \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix} \right)$$

```
In [50]: import scipy.linalg
```

```
In [51]: A = np.array([[4,2],[3,1]])  
print(A)
```

```
[[4 2]  
 [3 1]]
```

```
In [52]: scipy.linalg.inv(A)
```

```
Out[52]: array([[ -0.5,  1. ],  
               [ 1.5, -2. ]])
```

SciPy: Wichtige Submodule: scipy.linalg (2)

det: `scipy.linalg.det(A)`

- A: Quadratische Matrix

Beispiel: $\det \begin{pmatrix} 4 & 2 \\ 3 & 1 \end{pmatrix}$

```
In [50]: import scipy.linalg
```

```
In [51]: A = np.array([[4,2],[3,1]])  
print(A)
```

```
[[4 2]  
 [3 1]]
```

```
In [53]: scipy.linalg.det(A)
```

```
Out[53]: -2.0
```

SciPy: Wichtige Submodule: scipy.linalg (3)

det: `scipy.linalg.solve(A, b)`

- A: Quadratische Matrix eines Gleichungssystems
- b: Rechte Seite der Gleichung

Bestimmt x eines Gleichungssystem der Form $A \times x = b$

Beispiel: $\begin{pmatrix} 4 & 2 \\ 3 & 1 \end{pmatrix} \times x = \begin{pmatrix} 1 \\ 2 \end{pmatrix}$

```
In [50]: import scipy.linalg
```

```
In [58]: A= np.array([[4,2],[3,1]])  
b= np.array([[1],[2]])  
print(A)  
print('.....')  
print(b)
```

```
[[4 2]  
 [3 1]]  
  
.....  
[[1]  
 [2]]
```

```
In [59]: scipy.linalg.solve(A,b)
```

```
Out[59]: array([[ 1.5],  
                [-2.5]])
```

SciPy: Wichtige Submodule: `scipy.interpolate`

interp1d: `scipy.interpolate.interp1d(x, y, kind)`

- x: Werte aus Definitionsmenge
- y: Zugehörige Werte aus Zielmenge
- kind: Art der Annäherung (linear, quadratisch, kubisch etc.)

SciPy: Wichtige Submodule: scipy.interpolate (Beispiel 1)


Beispiel 1:

x	y
0	0
1	1
2	2
20	20

```
In [87]: import numpy as np
import matplotlib.pyplot as plt
import scipy.interpolate
```

```
In [154]: x = [0,1,2,20]
y = [0,1,2,20]
f = interp1d(x, y, kind='linear')
f2 = interp1d(x, y, kind='quadratic') #in diesem Fall identisch
```

```
In [155]: xnew = np.linspace(0, 20, num=20)
plt.plot(x, y, 'o', xnew, f(xnew), '--', xnew, f2(xnew), '--')
plt.show()
```



SciPy: Wichtige Submodule: scipy.interpolate (Beispiel 2)

Beispiel 2:


x	y
0	0
1	0.841
2	0.909
3	0.141
4	-0.757
5	-0.959
6	-0.279
7	0.657
8	0.989
9	0.412

```
In [233]: import numpy as np
import matplotlib.pyplot as plt
import scipy.interpolate
```

```
In [239]: x = [0,1,2,3,4,5,6,7,8,9]
y = [0.0, 0.841, 0.909, 0.141, -0.757,
     -0.959, -0.279, 0.657, 0.989, 0.412]
```

```
f = interp1d(x, y, kind='linear')
f2 = interp1d(x, y, kind='quadratic')
```

```
In [240]: xnew = np.linspace(0, 9, num=15)
plt.plot(x, y, 'o', xnew, f(xnew), '--', xnew, f2(xnew), '-')
plt.show()
```



SciPy: Wichtige Submodule: scipy.interpolate (Beispiel 2)

Beispiel 2:


x	y
0	0
1	0.841
2	0.909
3	0.141
4	-0.757
5	-0.959
6	-0.279
7	0.657
8	0.989
9	0.412

```
In [233]: import numpy as np
import matplotlib.pyplot as plt
import scipy.interpolate
```

```
In [239]: x = [0,1,2,3,4,5,6,7,8,9]
y = [0.0, 0.841, 0.909, 0.141, -0.757,
     -0.959, -0.279, 0.657, 0.989, 0.412]

f = interp1d(x, y, kind='linear')
f2 = interp1d(x, y, kind='quadratic')
```

```
In [242]: xnew = np.linspace(0, 9, num=1000)
plt.plot(x, y, 'o', xnew, f(xnew), '--', xnew, f2(xnew), '-')
plt.show()
```



Vergleich: SciPy

Alternative: MATLAB

- Anwendung zur Visualisierung und Verarbeitung von Daten
- eigene Programmiersprache


Vorteile gegenüber SciPy:

- GUI
- weit verbreitet

Nachteile gegenüber SciPy:

- Nicht Open-Source, kostenpflichtig
- Deutlich langsamer (Python zwar langsam, SciPy-Stack jedoch C-Code mit Wrapper)
- Kein Python $\Rightarrow$ weniger Modularität, andere Syntax

Erläuterung: MATLAB-GUI



Quelle: wikipedia.com/wiki/matlab

Pandas: Übersicht

- Ermöglicht effiziente, tabellarische Verwaltung von Daten in Python
 - Statt (NumPy-)Arrays zweidimensionale Tabellen ("Spreadsheets")
 - Datensätze leichter verwalten
 - Teil des Scipy-Stacks, also kompatibel mit NumPy und SciPy
- Name → "Panel Data"
- Open-Source
- Kostenlos
- Installation: `pip install pandas`

Pandas: Wichtige Funktionen: Datenstrukturen (1)

Series: `pandas.Series(data, index)`

- data: iterierbare Datenmenge (Array, Liste...)
- index Zeilenbezeichner (optional)

```
In [4]: import pandas  
import numpy as np
```

```
In [11]: pandas.Series(np.random.randn(3), ['rand1', 'rand2', 'rand3'])
```

```
Out[11]: rand1    -0.055388  
rand2     0.446007  
rand3     0.511584  
dtype: float64
```

Pandas: Wichtige Funktionen: Datenstrukturen (2)

Series: `pandas.DataFrame(data, index, columns)`

- data: Zweidimensionale Datenmenge
- index: Zeilenbezeichner (optional)
- columns: Spaltenbezeichner (optional)

```
In [4]: import pandas  
import numpy as np
```

```
In [15]: pandas.DataFrame(np.random.randn(3,3), columns=['rand1', 'rand2', 'rand3'])
```

Out[15]:

	rand1	rand2	rand3
0	1.061519	1.799274	-0.894694
1	0.913425	1.871492	-1.093921
2	0.687447	2.048325	1.289202

Pandas: Wichtige Funktionen: DataFrames (1)

DataFrame: Basics

Sei `df` ein DataFrame.

- `df.to_numpy()`: DataFrame $\rightarrow$ Numpy-Array
- `df[a]`, `df.a`: Spalte mit Titel 'a' als Series
- `df[a:b]`: Zeilen zwischen a (inklusive) und b (exklusiv)
- `df.head(a)`: Alle Zeilen bis Index a (exklusiv); default 5
- `df.tail(a)`: Die letzten a Zeilen; default 5
- `df.sort_values(a)`: Zeilen werden aufsteigend nach Spalte 'a' sortiert
- `df.columns`
- `df.index`

Pandas: Wichtige Funktionen: DataFrames (2)

DataFrame: loc,iloc und ix

Sei df ein DataFrame.

- `df.loc[a,b]`: In Zeile(n) 'a' und Spalte(n) 'b'
- `df.iloc[a,b]`: In Zeile(n) a und Spalte(n) b
- `df.ix[a,b]`: Hybrid aus loc und iloc

```
In [4]: import pandas  
import numpy as np
```

```
In [16]: df = pandas.DataFrame(np.random.randn(3,3), columns=['rand1', 'rand2', 'rand3'])
```

```
In [40]: print(df.loc[1])  
print('.....')  
print(df.iloc[:,1:3])
```

```
rand1    -0.717296  
rand2    -0.101526  
rand3     0.087465  
Name: 1, dtype: float64  
.....  
      rand2    rand3  
0  0.271276  1.120179  
1 -0.101526  0.087465  
2 -1.570037  1.229410
```

Pandas: Wichtige Funktionen: DataFrames (3)

DataFrame: at und apply

Sei df ein DataFrame.

- `df.at[a,b] = c`: Element(e) bei `[a,b]` wird/werden durch `c` ersetzt.
- `df.apply(func)`: Für jedes Element $a \in df$ wird ein `func(a)` gegeben.

```
In [4]: import pandas
import numpy as np
```

```
In [66]: df = pandas.DataFrame(np.random.randn(3,3), columns=['rand1', 'rand2', 'rand3'])
print(df)
```

	rand1	rand2	rand3
0	1.683432	-1.597399	-1.017243
1	0.525464	0.269870	0.094475
2	-0.824175	-0.166633	-0.346628

```
In [68]: df['rand1'] = df['rand1'].apply(np.sqrt)
df.at[:, 'rand3'] = 50
print(df)
```

	rand1	rand2	rand3
0	1.297472	-1.597399	50
1	0.724889	0.269870	50
2	NaN	-0.166633	50

Pandas: Wichtige Funktionen: DataFrames (4)

DataFrame: dropna und fillna

Sei df ein DataFrame.

- `df.dropna()`: Entfernt eine Zeile, wenn in ihr Einträge NaN sind.
- `df.fillna(a)`: Ersetzt jedes NaN in df durch a.

```
In [4]: import pandas
import numpy as np
```

```
In [76]: df = pandas.DataFrame([[np.nan, np.nan, 3], [4, 5, 6], [7, 8, np.nan]], )
print(df)
```

	0	1	2
0	NaN	NaN	3.0
1	4.0	5.0	6.0
2	7.0	8.0	NaN

```
In [91]: print(df.dropna())
print()
print(df.fillna(10))
```

	0	1	2
1	4.0	5.0	6.0

	0	1	2
0	10.0	10.0	3.0
1	4.0	5.0	6.0
2	7.0	8.0	10.0

Pandas: Wichtige Funktionen: DataFrames (5)

DataFrame: append und concat

Sei `df` ein DataFrame.

- `df.append(a)`: Fügt alle Zeilen aus `a` (DataFrame) `df` hinzu.
- `pandas.concat([a,b,c])`: Erstellt aus `a`, `b` und `c` einen DataFrame.

```
In [1]: import pandas
import numpy as np
```

```
In [14]: df = pandas.DataFrame([[ 'a', 'b' ]])
print(df)
```

```
   0  1
0  a  b
```

```
In [15]: print(df.append(df))
print()
print(pandas.concat([df,df,df]))
```

```
   0  1
0  a  b
0  a  b
```

```
   0  1
0  a  b
0  a  b
0  a  b
```

Pandas: I/O

Pandas versteht viele verschiedene Dateiformate!

- scv, html, json, Excel, SQL...
- Input: `pandas.read_<Dateiformat>` (Alternative: `DataFrame.from_csv`)
- Output: `pandas.to_<Dateiformat>` (Alternative: `DataFrame.to_csv`)

Vergleich: Pandas vs Vanilla Python (1)

Vergleich mit direkter Python-Implementation:

```
In [12]: import pandas as pd
import numpy as np
s = pd.DataFrame([[1,11],[2,22],[3,33]],index=['rot', 'gelb', 'gruen'])

def funcPandas(x,y):
    return s.iloc[x,y]

funcPandas(0,1) #example
```

Out[12]: 11

```
In [13]: dict = {
    "rot": [1,11],
    "gelb": [2,22],
    "gruen": [3,33],
}

def funcPython(x,y):
    if x==0:
        relevant=dict["rot"]
    elif x==1:
        relevant=dict["gelb"]
    elif x==2:
        relevant=dict["gruen"]
    return relevant[y]

funcPython(0,1) #example
```

Out[13]: 11

Vergleich: Pandas vs Vanilla Python (2)

Performancevergleich: %timeit

```
In [19]: %timeit funcPandas(0,1)
```

7.42 μ s $\pm$ 37.7 ns per loop (mean $\pm$ std. dev. of 7 runs, 100000 loops each)

```
In [20]: %timeit funcPython(0,1)
```

108 ns $\pm$ 0.14 ns per loop (mean $\pm$ std. dev. of 7 runs, 1000000 loops each)

Anwendungsbeispiel: Import von .txt

```
In [82]: import numpy as np  
import pandas as pd  
import matplotlib.pyplot as plt  
import scipy.interpolate as ip
```


```
In [94]: data = pd.read_csv('/home/felix/Documents/astrodata', sep=" ")  
data.columns = ['Day', 'X', 'Y', 'Z']
```

Anwendungsbeispiel: Interpolation (1)

```
In [89]: fx = ip.interpld(data.Day,data.X)
fy = ip.interpld(data.Day,data.Y)
fz = ip.interpld(data.Day,data.Z)

days = np.arange(0, 400)

plt.plot(data.Day,data.X, 'o',
         data.Day,data.Y, 'o',
         data.Day,data.Z, 'o',
         days,fx(x), days,fy(x), days,fz(x))
plt.show()
```




Anwendungsbeispiel: Interpolation (2)

```
In [90]: fx = ip.interpld(data.Day,data.X, kind='quadratic')
fy = ip.interpld(data.Day,data.Y, kind='quadratic')
fz = ip.interpld(data.Day,data.Z)


days = np.arange(0, 400)

plt.plot(data.Day,data.X, 'o',
         data.Day,data.Y, 'o',
         data.Day,data.Z, 'o',
         days,fx(x), days,fy(x), days,fz(x))
plt.show()
```



Anwendungsbeispiel: Append von weiteren Datensätzen

```
In [91]: data = data.append(pd.read_csv('/home/felix/Downloads/ss19_2.txt', sep=" "))  
plt.plot(data.Day,data.X,'o', data.Day,data.Y,'o', data.Day,data.Z,'o')  
plt.show()
```



Zusammenfassung

- Scipy
 - Komplexere mathematische Operationen, zB. Integrale, Matrixoperationen, Interpolation, Optimierung...
 - Code teilweise in C → hohe Performanz
- Pandas
 - Datenspeicherung in Panelen, Verwaltung von Daten
 - Selektionsfunktionen nach Spalten-/Zeilenbezeichner
 - Kompatibilität mit anderen Verwaltungsformen
- SciPy-Stack
- Open-Source, kostenlos

Literatur (1)

Alle Websites wurden zuletzt am 19.05.2019 aufgerufen.

- "The SciPy Stack Specification",
<https://www.scipy.org/stackspec.html>
- "SciPy", <https://scipy.github.io/devdocs>
- Eric van Rees: "pandas and NumPy arrays explained",
<https://medium.com/@ericvanrees/pandas-series-objects-and-numpy-arrays-15dfe05919d7>
- "pandas: powerful Python data analysis toolkit",
<https://pandas.pydata.org/pandas-docs/stable/>
- Jonathan Kinlay: "A Comparison of Programming Languages",
<http://jonathankinlay.com/2018/10/comparison-programming-languages/>
- Shane Lynn: "Using iloc, loc, ix to select rows and columns in Pandas DataFrames", <https://www.shanelynn.ie/select-pandas-dataframe-rows-and-columns-using-iloc-loc-and-ix/>

Literatur (2)

- LaTeX-Template: "Knowledge graph in Neo4J",
<https://de.overleaf.com/articles/knowledge-graph-in-neo4j/dfmppvtndqhg>
- Wikipedia: "NumPy", <https://de.wikipedia.org/wiki/NumPy>
- Wikipedia: "SciPy", <https://de.wikipedia.org/wiki/SciPy>
- Wikipedia: "Pandas (Software)",
[https://de.wikipedia.org/wiki/Pandas_\(Software\)](https://de.wikipedia.org/wiki/Pandas_(Software))
- Dharmindar Devsidas: "Python Scientific Programming - SciPy Basic Interpolation", <https://www.youtube.com/watch?v=b0jo2g3iKJM>
- John Foster: "SciPy - Scientific Toolkit",
<https://www.youtube.com/watch?v=MtdLd2Irvag>
- Harrison Kinsley: "Data Analysis with Python and Pandas Tutorial Introduction", <https://www.youtube.com/watch?v=lqjy9UqKKuo>
- "Profiling and Timing Code",
<https://jakevdp.github.io/PythonDataScienceHandbook/01.07-timing-and-profiling.html>