

Vorwort	13
1 Einleitung	19
1.1 Worum geht es in diesem Buch?	19
Welche Arten von Daten?	19
1.2 Warum Python für die Datenanalyse?	20
Python als Kleister	21
Das »Zwei-Sprachen-Problem« lösen	21
Warum nicht Python?	22
1.3 Grundlegende Python-Bibliotheken	22
NumPy	22
pandas	23
matplotlib	24
IPython und Jupyter	25
SciPy	26
scikit-learn	26
statsmodels	27
Andere Pakete	27
1.4 Installation und Einrichtung	28
Miniconda auf Windows	28
GNU/Linux	29
Miniconda auf macOS	29
Python-Pakete installieren oder aktualisieren	30
Integrierte Entwicklungsumgebungen und Texteditoren	31
1.5 Community und Konferenzen	32
1.6 Navigation durch dieses Buch	33
Codebeispiele	33
Daten für die Beispiele	34
Importkonventionen	35

2	Grundlagen von Python, IPython und Jupyter-Notebooks	37
2.1	Der Python-Interpreter	38
2.2	IPython-Grundlagen	39
	Die IPython-Shell ausführen	39
	Das Jupyter-Notebook ausführen	40
	Befehlsergänzung mit Tab	43
	Introspektion	44
2.3	Grundlagen der Sprache Python	45
	Sprachsemantik	46
	Skalare Typen	54
	Kontrollfluss	61
2.4	Schlussbemerkung	65
3	In Python integrierte Datenstrukturen, Funktionen und Dateien	67
3.1	Datenstrukturen und Sequenzen	67
	Tupel	67
	Listen	71
	Dictionarys	75
	Set	79
	Eingebaute Funktionen von Sequenzen	81
	List, Set und Dictionary Comprehensions	83
3.2	Funktionen	85
	Namensraum, Gültigkeitsbereich und lokale Funktionen	86
	Mehrere Rückgabewerte	88
	Funktionen sind Objekte	88
	Anonyme oder Lambda-Funktionen	90
	Generatoren	91
	Fehler und die Behandlung von Ausnahmen	94
3.3	Dateien und das Betriebssystem	96
	Bytes und Unicode mit Dateien	100
3.4	Schlussbemerkung	102
4	Grundlagen von NumPy: Arrays und vektorisierte Berechnung	103
4.1	Das ndarray von NumPy: ein mehrdimensionales Array-Objekt	105
	ndarrays erzeugen	107
	Datentypen für ndarrays	109
	Rechnen mit NumPy-Arrays	112
	Einfaches Indizieren und Slicing	113
	Boolesches Indizieren	118
	Fancy Indexing	120
	Arrays transponieren und Achsen tauschen	122

4.2	Erzeugen von Pseudozufallszahlen	123
4.3	Universelle Funktionen: schnelle elementweise Array-Funktionen	125
4.4	Array-orientierte Programmierung mit Arrays	128
	Bedingte Logik als Array-Operationen ausdrücken	130
	Mathematische und statistische Methoden	131
	Methoden für boolesche Arrays	133
	Sortieren	133
	Unique und andere Mengenlogik	135
4.5	Dateiein- und -ausgabe bei Arrays	136
4.6	Lineare Algebra	136
4.7	Beispiel: Random Walks	138
	Viele Random Walks auf einmal simulieren	140
4.8	Schlussbemerkung	141
5	Erste Schritte mit pandas	143
5.1	Einführung in die pandas-Datenstrukturen	144
	Series	144
	DataFrame	148
	Indexobjekte	156
5.2	Wesentliche Funktionalität	158
	Neuindizierung	158
	Einträge von einer Achse löschen	161
	Indizierung, Auswahl und Filterung	162
	Fallstricke bei Integer-Indizes	169
	Arithmetik und Datenausrichtung	172
	Funktionsanwendung und Mapping	178
	Sortieren und Rangbildung	180
	Achsenindizes mit duplizierten Labels	184
5.3	Zusammenfassen und Berechnen deskriptiver Statistiken	185
	Korrelation und Kovarianz	188
	Eindeutigkeit, Werteanzahl und Mitgliedschaft	190
5.4	Schlussbemerkung	193
6	Laden und Speichern von Daten sowie Dateiformate	195
6.1	Lesen und Schreiben von Daten im Textformat	195
	Stückweises Lesen von Textdateien	202
	Daten in Textformaten schreiben	204
	Arbeiten mit anderen Formaten	205
	JSON-Daten	207
	XML und HTML: Web-Scraping	209

6.2	Binäre Datenformate	213
	Lesen von Microsoft-Excel-Dateien	214
	Benutzung von HDF5	215
6.3	Interaktion mit Web-APIs	218
6.4	Interaktion mit Datenbanken	220
6.5	Schlussbemerkung	221
7	Daten bereinigen und vorbereiten	223
7.1	Der Umgang mit fehlenden Daten	223
	Fehlende Daten herausfiltern	225
	Fehlende Daten einsetzen	227
7.2	Datentransformation	229
	Duplikate entfernen	229
	Daten mithilfe einer Funktion oder eines Mappings transformieren	231
	Werte ersetzen	232
	Achsenindizes umbenennen	234
	Diskretisierung und Klassifizierung	235
	Erkennen und Filtern von Ausreißern	237
	Permutation und zufällige Stichproben	238
	Berechnen von Indikator-/Platzhaltervariablen	240
7.3	Extension-Datentypen	243
7.4	Manipulation von Strings	247
	Methoden von String-Objekten in Python	247
	Reguläre Ausdrücke	249
	String-Funktionen in pandas	252
7.5	Kategorische Daten	255
	Hintergrund und Motivation	255
	Der Extension-Typ Categorical in pandas	257
	Berechnungen mit Categoricals	260
	Kategorische Methoden	262
7.6	Schlussbemerkung	265
8	Datenaufbereitung: Verknüpfen, Kombinieren und Umformen	267
8.1	Hierarchische Indizierung	267
	Ebenen neu anordnen und sortieren	270
	Zusammenfassende Statistiken nach Ebene	271
	Indizierung mit den Spalten eines DataFrame	272
8.2	Kombinieren und Verknüpfen von Datensätzen	273
	Datenbankartige Verknüpfung von DataFrames	273
	Daten über einen Index verknüpfen	279
	Verketteten entlang einer Achse	283
	Überlappende Daten zusammenführen	288

8.3	Umformen und Transponieren	290
	Umformen mit hierarchischer Indizierung	290
	Transponieren vom »langen« zum »breiten« Format	293
	Transponieren vom »breiten« zum »langen« Format	296
8.4	Schlussbemerkung	298
9	Plotten und Visualisieren	299
9.1	Kurze Einführung in die matplotlib-API	300
	Diagramme und Subplots	301
	Farben, Beschriftungen und Linienformen	305
	Skalenstriche, Beschriftungen und Legenden	307
	Annotationen und Zeichnungen in einem Subplot	310
	Diagramme in Dateien abspeichern	312
	Die Konfiguration von matplotlib	313
9.2	Plotten mit pandas und seaborn.	313
	Liniendiagramme.	314
	Balkendiagramme	316
	Histogramme und Dichteplots	322
	Streu- oder Punktdiagramme.	324
	Facettenraster und kategorische Daten	326
9.3	Andere Visualisierungswerkzeuge in Python	328
9.4	Schlussbemerkung	329
10	Aggregation von Daten und Gruppenoperationen	331
10.1	Grundlagen zu Gruppierungsoperationen	332
	Iteration über Gruppen	336
	Auswählen einer Spalte oder einer Teilmenge von Spalten	337
	Gruppieren mit Dictionarys und Series	338
	Gruppieren mit Funktionen	339
	Gruppieren nach Ebenen eines Index	340
10.2	Aggregation von Daten.	341
	Spaltenweise und mehrfache Anwendung von Funktionen	343
	Aggregierte Daten ohne Zeilenindizes zurückgeben	346
10.3	Apply: Allgemeine Operationen vom Typ split-apply-combine.	347
	Unterdrücken der Gruppenschlüssel.	349
	Analyse von Quantilen und Größenklassen	349
	Beispiel: Fehlende Daten mit gruppenspezifischen Werten auffüllen.	352
	Beispiel: Zufällige Stichproben und Permutation	354
	Beispiel: Gewichteter Mittelwert für Gruppen und Korrelation.	356
	Beispiel: Gruppenweise lineare Regression	358

10.4	Gruppentransformationen und »ausgepackte« GroupBys	358
10.5	Pivot-Tabellen und Kreuztabellierung.	362
	Kreuztabellen	365
10.6	Schlussbemerkung	366
11	Zeitreihen.	367
11.1	Datentypen und Werkzeuge für Datum und Zeit	368
	Konvertieren zwischen String und datetime.	369
11.2	Grundlagen von Zeitreihen	372
	Indizieren, auswählen und Untermengen bilden	373
	Zeitreihen mit doppelten Indizes	375
11.3	Datumsbereiche, Frequenzen und Verschiebungen	376
	Erzeugen von Datumsbereichen	377
	Frequenzen und Offsets von Kalenderdaten.	380
	Verschieben von Datumsangaben (Vorlauf und Verzögerung)	381
11.4	Berücksichtigung von Zeitzonen	384
	Lokalisieren und Konvertieren von Zeitzonen	385
	Operationen mit Zeitstempeln bei zugeordneter Zeitzone	387
	Operationen zwischen unterschiedlichen Zeitzonen	388
11.5	Perioden und Arithmetik von Perioden.	389
	Umwandlung der Frequenz von Perioden	390
	Quartalsweise Perioden	392
	Zeitstempel zu Perioden konvertieren (und zurück)	393
	Erstellen eines PeriodIndex aus Arrays	395
11.6	Resampling und Konvertieren von Frequenzen.	396
	Downsampling	398
	Upsampling und Interpolation	400
	Resampling mit Perioden	402
	Gruppiertes Zeit-Resampling	403
11.7	Funktionen mit gleitenden Fenstern	405
	Exponentiell gewichtete Funktionen	408
	Binäre Funktionen mit gleitendem Fenster.	409
	Benutzerdefinierte Funktionen mit gleitenden Fenstern	411
11.8	Schlussbemerkung	412
12	Einführung in Modellierungsbibliotheken in Python	413
12.1	Die Kopplung zwischen pandas und dem Modellcode	413
12.2	Modellbeschreibungen mit Patsy herstellen	416
	Datentransformationen in Patsy-Formeln	419
	Kategorische Daten und Patsy	420

12.3	Einführung in statsmodels	423
	Lineare Modelle schätzen	424
	Zeitreihenprozesse schätzen	427
12.4	Einführung in scikit-learn.	428
12.5	Schlussbemerkung	431
13	Beispiele aus der Datenanalyse	433
13.1	Bitly-Daten von 1.USA.gov	433
	Zählen von Zeitzonen in reinem Python	434
	Zeitzone mit pandas zählen.	436
13.2	MovieLens-1M-Datensatz	443
	Messen von Unterschieden in der Bewertung	447
13.3	US-Babynamen von 1880–2010	450
	Namenstrends analysieren.	455
13.4	Die USDA-Nahrungsmitteldatenbank	464
13.5	Datenbank des US-Wahlausschusses von 2012.	469
	Spendenstatistik nach Beruf und Arbeitgeber	472
	Spenden der Größe nach klassifizieren	475
	Spendenstatistik nach Bundesstaat	477
13.6	Schlussbemerkung	478
Anhang A	NumPy für Fortgeschrittene	479
A.1	Internas des ndarray-Objekts.	479
	Die Datentyphierarchie in NumPy	480
A.2	Fortgeschrittene Manipulation von Arrays	482
	Arrays umformen.	482
	Anordnung von Arrays in C und FORTRAN	484
	Arrays verketteten und aufspalten	485
	Wiederholen von Elementen: tile und repeat	487
	Alternativen zum Fancy Indexing: take und put	489
A.3	Broadcasting.	490
	Broadcasting über andere Achsen	492
	Werte von Arrays durch Broadcasting setzen	494
A.4	Fortgeschrittene Nutzung von ufuncs	495
	Instanzmethoden von ufunc	495
	Neue ufuncs in Python schreiben	498
A.5	Strukturierte und Record-Arrays	499
	Geschachtelte Datentypen und mehrdimensionale Felder	499
	Warum sollte man strukturierte Arrays verwenden?	500
A.6	Mehr zum Thema Sortieren	501
	Indirektes Sortieren: argsort und lexsort	502
	Alternative Sortieralgorithmen	503

	Arrays teilweise sortieren	504
	numpy.searchsorted: Elemente in einem sortierten Array finden	505
A.7	Schnelle NumPy-Funktionen mit Numba schreiben.	506
	Eigene numpy.ufunc-Objekte mit Numba herstellen.	508
A.8	Ein- und Ausgabe von Arrays für Fortgeschrittene	508
	Memory-mapped Dateien.	509
	HDF5 und weitere Möglichkeiten zum Speichern von Arrays	510
A.9	Tipps für eine höhere Leistung	510
	Die Bedeutung des zusammenhängenden Speichers	511
Anhang B	Mehr zum IPython-System	513
B.1	Tastenkürzel im Terminal	513
B.2	Magische Befehle	514
	Der Befehl %run	516
	Code aus der Zwischenablage ausführen	517
B.3	Die Befehlshistorie benutzen	518
	Die Befehlshistorie durchsuchen und wiederverwenden	518
	Eingabe- und Ausgabevariablen	519
B.4	Mit dem Betriebssystem interagieren	520
	Shell-Befehle und -Aliase	521
	Das Verzeichnis-Bookmark-System	522
B.5	Werkzeuge zur Softwareentwicklung	523
	Interaktiver Debugger.	523
	Zeitmessung bei Code: %time und %timeit.	528
	Grundlegende Profilierung: %prun and %run -p.	529
	Eine Funktion Zeile für Zeile profilieren	531
B.6	Tipps für eine produktive Codeentwicklung mit IPython.	533
	Modulabhängigkeiten neu laden	534
	Tipps für das Codedesign.	535
B.7	Fortgeschrittene IPython-Funktionen	536
	Profile und Konfiguration.	536
B.8	Schlussbemerkung.	538
	Index	539