



Jake
VanderPlas

Data Science mit Python

Das **Handbuch** für den Einsatz von
IPython, Jupyter, NumPy, Pandas, Matplotlib, Scikit-Learn



Hinweis des Verlages zum Urheberrecht und Digitalen Rechtemanagement (DRM)

Der Verlag räumt Ihnen mit dem Kauf des ebooks das Recht ein, die Inhalte im Rahmen des geltenden Urheberrechts zu nutzen. Dieses Werk, einschließlich aller seiner Teile, ist urheberrechtlich geschützt. Jede Verwertung außerhalb der engen Grenzen des Urheberrechtsgesetzes ist ohne Zustimmung des Verlages unzulässig und strafbar. Dies gilt insbesondere für Vervielfältigungen, Übersetzungen, Mikroverfilmungen und Einspeicherung und Verarbeitung in elektronischen Systemen.

Der Verlag schützt seine ebooks vor Missbrauch des Urheberrechts durch ein digitales Rechtemanagement. Bei Kauf im Webshop des Verlages werden die ebooks mit einem nicht sichtbaren digitalen Wasserzeichen individuell pro Nutzer signiert.

Bei Kauf in anderen ebook-Webshops erfolgt die Signatur durch die Shopbetreiber. Angaben zu diesem DRM finden Sie auf den Seiten der jeweiligen Anbieter.

Jake VanderPlas

Data Science mit Python

Das Handbuch für den Einsatz von IPython, Jupyter,
NumPy, Pandas, Matplotlib, Scikit-Learn

Übersetzung aus dem Englischen
von Knut Lorenzen



Bibliografische Information der Deutschen Nationalbibliothek

Die Deutsche Nationalbibliothek verzeichnet diese Publikation in der Deutschen Nationalbibliografie; detaillierte bibliografische Daten sind im Internet über <http://dnb.d-nb.de> abrufbar.

ISBN 978-3-95845-696-9

1. Auflage 2018

www.mitp.de

E-Mail: mitp-verlag@sigloch.de

Telefon: +49 7953 / 7189 - 079

Telefax: +49 7953 / 7189 - 082

© 2018 mitp Verlags GmbH & Co. KG, Frechen

Dieses Werk, einschließlich aller seiner Teile, ist urheberrechtlich geschützt. Jede Verwertung außerhalb der engen Grenzen des Urheberrechtsgesetzes ist ohne Zustimmung des Verlages unzulässig und strafbar. Dies gilt insbesondere für Vervielfältigungen, Übersetzungen, Mikroverfilmungen und die Einspeicherung und Verarbeitung in elektronischen Systemen.

Die Wiedergabe von Gebrauchsnamen, Handelsnamen, Warenbezeichnungen usw. in diesem Werk berechtigt auch ohne besondere Kennzeichnung nicht zu der Annahme, dass solche Namen im Sinne der Warenzeichen- und Markenschutz-Gesetzgebung als frei zu betrachten wären und daher von jedermann benutzt werden dürften.

Authorized German translation of the English edition of
Python Data Science Handbook – Essential Tools for Working with Data
ISBN 978-1491912058 © 2017 Jake VanderPlas

This translation is published and sold by permission of O'Reilly Media, Inc., which owns or controls all rights to publish and sell the same.

Lektorat: Sabine Schulz

Sprachkorrektorat: Sibylle Feldmann

Coverbild: © agsandrew / fotolia.com

Satz: III-satz, Husby, www.drei-satz.de

Inhaltsverzeichnis

	Einleitung	13
	Über den Autor	18
1	Mehr als normales Python: IPython	19
1.1	Shell oder Notebook?	19
1.1.1	Die IPython-Shell starten	20
1.1.2	Das Jupyter-Notebook starten	20
1.2	Hilfe und Dokumentation in IPython	21
1.2.1	Mit ? auf die Dokumentation zugreifen	22
1.2.2	Mit ?? auf den Quellcode zugreifen	23
1.2.3	Module mit der Tab-Vervollständigung erkunden	24
1.3	Tastaturkürzel in der IPython-Shell	26
1.3.1	Tastaturkürzel zum Navigieren	27
1.3.2	Tastaturkürzel bei der Texteingabe	27
1.3.3	Tastaturkürzel für den Befehlsverlauf	28
1.3.4	Sonstige Tastaturkürzel	29
1.4	Magische Befehle in IPython	29
1.4.1	Einfügen von Codeblöcken mit %paste und %cpaste	29
1.4.2	Externen Code ausführen mit %run	31
1.4.3	Messung der Ausführungszeit von Code mit %timeit	31
1.4.4	Hilfe für die magischen Funktionen anzeigen mit ?, %magic und %lsmagic	32
1.5	Verlauf der Ein- und Ausgabe	32
1.5.1	Die IPython-Objekte In und Out	33
1.5.2	Der Unterstrich als Abkürzung und vorhergehende Ausgaben	34
1.5.3	Ausgaben unterdrücken	34
1.5.4	Weitere ähnliche magische Befehle	35
1.6	IPython und Shell-Befehle	35
1.6.1	Kurz vorgestellt: die Shell	36
1.6.2	Shell-Befehle in IPython	37
1.6.3	Werte mit der Shell austauschen	37
1.7	Magische Befehle für die Shell	38
1.8	Fehler und Debugging	39
1.8.1	Exceptions handhaben: %xmode	39
1.8.2	Debugging: Wenn das Lesen von Tracebacks nicht ausreicht	41
1.9	Profiling und Timing von Code	44
1.9.1	Timing von Codeschnipseln: %timeit und %time	45
1.9.2	Profiling kompletter Skripte: %prun	46

1.9.3	Zeilenweises Profiling mit %lprun	47
1.9.4	Profiling des Speicherbedarfs: %memit und %mprun	48
1.10	Weitere IPython-Ressourcen	50
1.10.1	Quellen im Internet	50
1.10.2	Bücher	50
2	Einführung in NumPy	51
2.1	Die Datentypen in Python.	52
2.1.1	Python-Integers sind mehr als nur ganzzahlige Werte	53
2.1.2	Python-Listen sind mehr als nur einfache Listen.	54
2.1.3	Arrays feststehenden Typs in Python	56
2.1.4	Arrays anhand von Listen erzeugen	56
2.1.5	Neue Arrays erzeugen	57
2.1.6	NumPys Standarddatentypen	58
2.2	Grundlagen von NumPy-Arrays.	59
2.2.1	Attribute von NumPy-Arrays	60
2.2.2	Indizierung von Arrays: Zugriff auf einzelne Elemente	61
2.2.3	Slicing: Teilmengen eines Arrays auswählen.	62
2.2.4	Arrays umformen	65
2.2.5	Arrays verketten und aufteilen.	66
2.3	Berechnungen mit NumPy-Arrays: universelle Funktionen	68
2.3.1	Langsame Schleifen	68
2.3.2	Kurz vorgestellt: UFuncs	70
2.3.3	NumPys UFuncs im Detail	70
2.3.4	UFunc-Features für Fortgeschrittene	75
2.3.5	UFuncs: mehr erfahren	77
2.4	Aggregationen: Minimum, Maximum und alles dazwischen	77
2.4.1	Summieren der Werte eines Arrays	77
2.4.2	Minimum und Maximum	78
2.4.3	Beispiel: Durchschnittliche Größe der US-Präsidenten	80
2.5	Berechnungen mit Arrays: Broadcasting.	82
2.5.1	Kurz vorgestellt: Broadcasting	82
2.5.2	Für das Broadcasting geltende Regeln	84
2.5.3	Broadcasting in der Praxis	87
2.6	Vergleiche, Maskierungen und boolesche Logik	88
2.6.1	Beispiel: Regentage zählen.	89
2.6.2	Vergleichsoperatoren als UFuncs	90
2.6.3	Boolesche Arrays verwenden	91
2.6.4	Boolesche Arrays als Maskierungen	94
2.7	Fancy Indexing	97
2.7.1	Fancy Indexing im Detail.	97
2.7.2	Kombinierte Indizierung.	98
2.7.3	Beispiel: Auswahl zufälliger Punkte	99
2.7.4	Werte per Fancy Indexing modifizieren	101
2.7.5	Beispiel: Daten gruppieren	102

2.8	Arrays sortieren	104
2.8.1	Schnelle Sortierung in NumPy: np.sort und np.argsort.....	105
2.8.2	Teilsortierungen: Partitionierung	107
2.8.3	Beispiel: k nächste Nachbarn	107
2.9	Strukturierte Daten: NumPys strukturierte Arrays.....	112
2.9.1	Strukturierte Arrays erzeugen	113
2.9.2	Erweiterte zusammengesetzte Typen	114
2.9.3	Record-Arrays: strukturierte Arrays mit Pfiff	115
2.9.4	Weiter mit Pandas.....	115
3	Datenbearbeitung mit Pandas	117
3.1	Pandas installieren und verwenden	117
3.2	Kurz vorgestellt: Pandas-Objekte	118
3.2.1	Das Pandas-Series-Objekt.....	118
3.2.2	Das Pandas-DataFrame-Objekt	122
3.2.3	Das Pandas-Index-Objekt	126
3.3	Daten indizieren und auswählen	127
3.3.1	Series-Daten auswählen	127
3.3.2	DataFrame-Daten auswählen.....	131
3.4	Mit Pandas-Daten arbeiten	135
3.4.1	UFuncs: Indexerhaltung.....	136
3.4.2	UFuncs: Indexanpassung.....	137
3.4.3	UFuncs: Operationen mit DataFrame und Series	139
3.5	Handhabung fehlender Daten	140
3.5.1	Überlegungen zu fehlenden Daten	141
3.5.2	Fehlende Daten in Pandas	141
3.5.3	Mit null-Werten arbeiten	145
3.6	Hierarchische Indizierung	149
3.6.1	Mehrfach indizierte Series	149
3.6.2	Methoden zum Erzeugen eines MultiIndex	153
3.6.3	Indizierung und Slicing eines MultiIndex	156
3.6.4	Multi-Indizes umordnen	159
3.6.5	Datenaggregationen mit Multi-Indizes	162
3.7	Datenmengen kombinieren: concat und append	164
3.7.1	Verkettung von NumPy-Arrays	165
3.7.2	Einfache Verkettungen mit pd.concat	165
3.8	Datenmengen kombinieren: Merge und Join	169
3.8.1	Relationale Algebra.....	170
3.8.2	Join-Kategorien	170
3.8.3	Angabe der zu verknüpfenden Spalten	173
3.8.4	Mengenarithmetik bei Joins.....	176
3.8.5	Konflikte bei Spaltennamen: das Schlüsselwort suffixes	177
3.8.6	Beispiel: Daten von US-Bundesstaaten	178
3.9	Aggregation und Gruppierung	183
3.9.1	Planetendaten	183

3.9.2	Einfache Aggregationen in Pandas	184
3.9.3	GroupBy: Aufteilen, Anwenden und Kombinieren	186
3.10	Pivot-Tabellen	195
3.10.1	Gründe für Pivot-Tabellen	195
3.10.2	Pivot-Tabellen von Hand erstellen.	196
3.10.3	Die Syntax von Pivot-Tabellen	197
3.10.4	Beispiel: Geburtenraten	199
3.11	Vektorisierte String-Operationen	204
3.11.1	Kurz vorgestellt: String-Operationen in Pandas.	204
3.11.2	Liste der Pandas-Stringmethoden	206
3.11.3	Beispiel: Rezeptdatenbank	211
3.12	Zeitreihen verwenden	215
3.12.1	Kalenderdaten und Zeiten in Python	215
3.12.2	Zeitreihen in Pandas: Indizierung durch Zeitangaben	219
3.12.3	Datenstrukturen für Zeitreihen in Pandas	220
3.12.4	Häufigkeiten und Abstände.	222
3.12.5	Resampling, zeitliches Verschieben und geglättete Statistik	224
3.12.6	Mehr erfahren.	229
3.12.7	Beispiel: Visualisierung von Fahrradzählungen in Seattle	229
3.13	Leistungsstarkes Pandas: eval() und query()	236
3.13.1	Der Zweck von query() und eval(): zusammengesetzte Ausdrücke	236
3.13.2	Effiziente Operationen mit pandas.eval()	237
3.13.3	DataFrame.eval() für spaltenweise Operationen	239
3.13.4	Die DataFrame.query()-Methode	241
3.13.5	Performance: Verwendung von eval() und query()	242
3.14	Weitere Ressourcen.	242
4	Visualisierung mit Matplotlib.	245
4.1	Allgemeine Tipps zu Matplotlib.	246
4.1.1	Matplotlib importieren	246
4.1.2	Stil einstellen.	246
4.1.3	show() oder kein show()? – Anzeige von Diagrammen	246
4.1.4	Grafiken als Datei speichern	248
4.2	Zwei Seiten derselben Medaille	250
4.3	Einfache Liniendiagramme	251
4.3.1	Anpassen des Diagramms: Linienfarben und -stile	254
4.3.2	Anpassen des Diagramms: Begrenzungen.	256
4.3.3	Diagramme beschriften	258
4.4	Einfache Streudiagramme	260
4.4.1	Streudiagramme mit plt.plot() erstellen	260
4.4.2	Streudiagramme mit plt.scatter() erstellen	263
4.4.3	plot kontra scatter: eine Anmerkung zur Effizienz	265
4.5	Visualisierung von Fehlern.	265
4.5.1	Einfache Fehlerbalken	265
4.5.2	Stetige Fehler	267

4.6	Dichtediagramme und Konturdiagramme	268
4.6.1	Visualisierung einer dreidimensionalen Funktion.	268
4.7	Histogramme, Binnings und Dichte	272
4.7.1	Zweidimensionale Histogramme und Binnings	274
4.8	Anpassen der Legende.	277
4.8.1	Legendenelemente festlegen	279
4.8.2	Legenden mit Punktgrößen	280
4.8.3	Mehrere Legenden	282
4.9	Anpassen von Farbskalen	283
4.9.1	Farbskala anpassen	284
4.9.2	Beispiel: Handgeschriebene Ziffern	288
4.10	Untergeordnete Diagramme.	290
4.10.1	plt.axes: Untergeordnete Diagramme von Hand erstellen.	290
4.10.2	plt.subplot: Untergeordnete Diagramme in einem Raster anordnen	292
4.10.3	plt.subplots: Das gesamte Raster gleichzeitig ändern	293
4.10.4	plt.GridSpec: Kompliziertere Anordnungen	294
4.11	Text und Beschriftungen	296
4.11.1	Beispiel: Auswirkungen von Feiertagen auf die Geburtenzahlen in den USA	296
4.11.2	Transformationen und Textposition	299
4.11.3	Pfeile und Beschriftungen	300
4.12	Achsenmarkierungen anpassen	303
4.12.1	Vorrangige und nachrangige Achsenmarkierungen	304
4.12.2	Markierungen oder Beschriftungen verbergen.	305
4.12.3	Anzahl der Achsenmarkierungen verringern oder erhöhen	306
4.12.4	Formatierung der Achsenmarkierungen.	307
4.12.5	Zusammenfassung der Formatter- und Locator-Klassen.	310
4.13	Matplotlib anpassen: Konfigurationen und Stylesheets	311
4.13.1	Diagramme von Hand anpassen	311
4.13.2	Voreinstellungen ändern: rcParams	312
4.13.3	Stylesheets	314
4.14	Dreidimensionale Diagramme in Matplotlib.	318
4.14.1	Dreidimensionale Punkte und Linien	319
4.14.2	Dreidimensionale Konturdiagramme	320
4.14.3	Drahtgitter- und Oberflächendiagramme	322
4.14.4	Triangulation von Oberflächen	323
4.15	Basemap: geografische Daten verwenden	326
4.15.1	Kartenprojektionen	328
4.15.2	Zeichnen eines Kartenhintergrunds	332
4.15.3	Daten auf einer Karte anzeigen	334
4.15.4	Beispiel: Kalifornische Städte	335
4.15.5	Beispiel: Oberflächentemperaturen.	337
4.16	Visualisierung mit Seaborn.	339
4.16.1	Seaborn kontra Matplotlib	339
4.16.2	Seaborn-Diagramme	341

4.17	Weitere Ressourcen	357
4.17.1	Matplotlib	357
4.17.2	Weitere Grafikbibliotheken für Python	357
5	Machine Learning	359
5.1	Was ist Machine Learning?	360
5.1.1	Kategorien des Machine Learnings	360
5.1.2	Qualitative Beispiele für Machine-Learning-Anwendungen	361
5.1.3	Zusammenfassung	369
5.2	Kurz vorgestellt: Scikit-Learn	369
5.2.1	Datenrepräsentierung in Scikit-Learn	370
5.2.2	Scikit-Learns Schätzer-API	372
5.2.3	Anwendung: Handgeschriebene Ziffern untersuchen	380
5.2.4	Zusammenfassung	385
5.3	Hyperparameter und Modellvalidierung	385
5.3.1	Überlegungen zum Thema Modellvalidierung	385
5.3.2	Auswahl des besten Modells	389
5.3.3	Lernkurven	396
5.3.4	Validierung in der Praxis: Rastersuche	399
5.3.5	Zusammenfassung	401
5.4	Merkmalerstellung	401
5.4.1	Kategoriale Merkmale	402
5.4.2	Texte als Merkmale	403
5.4.3	Bilder als Merkmale	404
5.4.4	Abgeleitete Merkmale	405
5.4.5	Vervollständigung fehlender Daten	407
5.4.6	Pipelines mit Merkmalen	408
5.5	Ausführlich: Naive Bayes-Klassifikation	409
5.5.1	Bayes-Klassifikation	409
5.5.2	Gauß'sche naive Bayes-Klassifikation	410
5.5.3	Multinomiale naive Bayes-Klassifikation	413
5.5.4	Einsatzgebiete für naive Bayes-Klassifikation	416
5.6	Ausführlich: Lineare Regression	417
5.6.1	Einfache lineare Regression	417
5.6.2	Regression der Basisfunktion	419
5.6.3	Regularisierung	423
5.6.4	Beispiel: Vorhersage des Fahrradverkehrs	427
5.7	Ausführlich: Support Vector Machines	432
5.7.1	Gründe für Support Vector Machines	433
5.7.2	Support Vector Machines: Maximierung des Randbereichs	434
5.7.3	Beispiel: Gesichtserkennung	443
5.7.4	Zusammenfassung Support Vector Machines	447
5.8	Ausführlich: Entscheidungsbäume und Random Forests	448
5.8.1	Gründe für Random Forests	448
5.8.2	Schätzerensembles: Random Forests	454
5.8.3	Random-Forest-Regression	455

5.8.4	Beispiel: Random Forest zur Klassifikation handgeschriebener Ziffern	457
5.8.5	Zusammenfassung Random Forests	459
5.9	Ausführlich: Hauptkomponentenanalyse	460
5.9.1	Kurz vorgestellt: Hauptkomponentenanalyse	460
5.9.2	Hauptkomponentenanalyse als Rauschfilter	467
5.9.3	Beispiel: Eigengesichter	469
5.9.4	Zusammenfassung Hauptkomponentenanalyse	472
5.10	Ausführlich: Manifold Learning	473
5.10.1	Manifold Learning: »HELLO«	473
5.10.2	Multidimensionale Skalierung (MDS)	475
5.10.3	MDS als Manifold Learning	477
5.10.4	Nichtlineare Einbettungen: Wenn MDS nicht funktioniert	479
5.10.5	Nichtlineare Mannigfaltigkeiten: lokal lineare Einbettung	480
5.10.6	Überlegungen zum Thema Manifold-Methoden	482
5.10.7	Beispiel: Isomap und Gesichter	483
5.10.8	Beispiel: Visualisierung der Strukturen in Zifferndaten	487
5.11	Ausführlich: k-Means-Clustering	490
5.11.1	Kurz vorgestellt: der k-Means-Algorithmus	490
5.11.2	k-Means-Algorithmus: Expectation-Maximization	492
5.11.3	Beispiele	497
5.12	Ausführlich: Gauß'sche Mixture-Modelle	503
5.12.1	Gründe für GMM: Schwächen von k-Means	503
5.12.2	EM-Verallgemeinerung: Gauß'sche Mixture-Modelle	507
5.12.3	GMM als Dichteschätzung	511
5.12.4	Beispiel: GMM zum Erzeugen neuer Daten verwenden	515
5.13	Ausführlich: Kerndichteschätzung	518
5.13.1	Gründe für Kerndichteschätzung: Histogramme	518
5.13.2	Kerndichteschätzung in der Praxis	522
5.13.3	Beispiel: Kerndichteschätzung auf Kugeloberflächen	524
5.13.4	Beispiel: Nicht ganz so naive Bayes-Klassifikation	527
5.14	Anwendung: Eine Gesichtserkennungs-Pipeline	532
5.14.1	HOG-Merkmale	533
5.14.2	HOG in Aktion: eine einfache Gesichtserkennung	534
5.14.3	Vorbehalte und Verbesserungen	539
5.15	Weitere Machine-Learning-Ressourcen	541
5.15.1	Machine Learning in Python	541
5.15.2	Machine Learning im Allgemeinen	541
	Stichwortverzeichnis	543

Einleitung

Was ist Data Science?

In diesem Buch geht es darum, Data Science mithilfe von Python zu betreiben, daher stellt sich unmittelbar die Frage: Was ist *Data Science* überhaupt? Das genau zu definieren, erweist sich als überraschend schwierig, insbesondere in Anbetracht der Tatsache, wie geläufig dieser Begriff inzwischen geworden ist. Von lautstarken Kritikern wird dieser Begriff mitunter als eine überflüssige Bezeichnung abgetan (denn letzten Endes kommt keine Wissenschaft ohne Daten aus) oder für ein leeres Schlagwort gehalten, das lediglich dazu dient, Lebensläufe aufzupolieren, um die Aufmerksamkeit übereifriger Personalverantwortlicher zu erlangen.

Meiner Ansicht nach übersehen diese Kritiker dabei einen wichtigen Punkt. Trotz des mit dem Begriff einhergehenden Hypes ist Data Science wohl die beste Beschreibung für fachübergreifende Fähigkeiten, die in vielen industriellen und akademischen Anwendungsbereichen immer wichtiger werden. Entscheidend ist hier die Interdisziplinarität: Ich halte Drew Conways Venn-Diagramm, das er im September 2010 erstmals in seinem Blog veröffentlichte, für die beste Definition von Data Science (siehe Abbildung 0.1).




Abb. 0.1: Das Venn-Diagramm zur Data Science von Drew Conway

Zwar sind einige der Bezeichnungen für die Schnittmengen nicht ganz ernst gemeint, aber dennoch erfasst dieses Diagramm das Wesentliche dessen, was gemeint ist, wenn man von »Data Science« spricht: Es handelt sich um ein grundlegend interdisziplinäres Thema. Data Science umfasst drei verschiedene und sich überschneidende Bereiche: die Aufgaben

eines Statistikers, der (immer größer werdende) Datenmengen modellieren und zusammenfassen kann, die Arbeit des Informatikers, der Algorithmen für die effiziente Speicherung, Verarbeitung und Visualisierung dieser Daten entwerfen kann, und das erforderliche Fachwissen – das wir uns als das »klassisch« Erlernte eines Fachgebiets vorstellen können –, um sowohl die angemessenen Fragen zu stellen als auch die Antworten im richtigen Kontext zu bewerten.

Das habe ich im Sinn, wenn ich Sie dazu auffordere, Data Science nicht als ein neu zu erlernendes Fachwissensgebiet zu begreifen, sondern als neue Fähigkeiten, die Sie im Rahmen Ihres vorhandenen Fachwissens anwenden können. Ob Sie über Wahlergebnisse berichten, Aktienrenditen vorhersagen, Mausclicks auf Onlinewerbung optimieren, Mikroorganismen auf Mikroskopbildern identifizieren, nach neuen Arten astronomischer Objekte suchen oder mit irgendwelchen anderen Daten arbeiten: Ziel dieses Buchs ist es, Ihnen die Fähigkeit zu vermitteln, neuartige Fragen über das von Ihnen gewählte Fachgebiet zu stellen und diese zu beantworten.

An wen richtet sich das Buch?

Sowohl in meinen Vorlesungen an der Universität Washington als auch auf verschiedenen technisch orientierten Konferenzen und Treffen wird mir am häufigsten diese Frage gestellt: »Wie kann man Python am besten erlernen?« Bei den Fragenden handelt es sich im Allgemeinen um technisch interessierte Studenten, Entwickler oder Forscher, die oftmals schon über umfangreiche Erfahrung mit dem Schreiben von Code und der Verwendung von rechnergestützten und numerischen Tools verfügen. Die meisten dieser Personen möchten Python erlernen, um die Programmiersprache als Tool für datenintensive und rechnergestützte wissenschaftliche Aufgaben zu nutzen. Für diese Zielgruppe ist eine Vielzahl von Lernvideos, Blogbeiträgen und Tutorials online verfügbar. Allerdings frustriert mich bereits seit geraumer Zeit, dass es auf obige Frage keine wirklich eindeutige und gute Antwort gibt – und das war der Anlass für dieses Buch.

Das Buch ist nicht als Einführung in Python oder die Programmierung im Allgemeinen gedacht. Ich setze voraus, dass der Leser mit der Programmiersprache Python vertraut ist. Dazu gehören das Definieren von Funktionen, die Zuweisung von Variablen, das Aufrufen der Methoden von Objekten, die Steuerung des Programmablaufs und weitere grundlegende Aufgaben. Das Buch soll vielmehr Python-Usern dabei helfen, die zum Betreiben von Data Science verfügbaren Pakete zu nutzen – Bibliotheken wie IPython, NumPy, Pandas, Matplotlib, Scikit-Learn und ähnliche Tools –, um Daten effektiv zu speichern, zu handhaben und Einblick in diese Daten zu gewinnen.

Warum Python?

Python hat sich in den letzten Jahrzehnten zu einem erstklassigen Tool für wissenschaftliche Berechnungen entwickelt, insbesondere auch für die Analyse und Visualisierung großer Datensätze. Die ersten Anhänger der Programmiersprache Python dürfte das ein wenig überraschen: Beim eigentlichen Design der Sprache wurde weder der Datenanalyse noch wissenschaftlichen Berechnungen besondere Beachtung geschenkt.

Dass sich Python für die Data Science als so nützlich erweist, ist vor allem dem großen und aktiven Ökosystem der Programmpakete von Drittherstellern zu verdanken: Da gibt es

NumPy für die Handhabung gleichartiger Array-basierter Daten, Pandas für die Verarbeitung verschiedenartiger und gekennzeichneteter Daten, SciPy für gängige wissenschaftliche Berechnungen, Matplotlib für druckreife Visualisierungen, IPython für die interaktive Ausführung und zum Teilen von Code, Scikit-Learn für Machine Learning sowie viele weitere Tools, die später im Buch noch Erwähnung finden.

Falls Sie auf der Suche nach einer Einführung in die Programmiersprache Python sind, empfehle ich das dieses Buch ergänzende Projekt *A Whirlwind Tour of the Python Language* (<https://github.com/jakevdp/WhirlwindTourOfPython>). Hierbei handelt es sich um eine Tour durch die wesentlichen Features der Sprache Python, die sich an Data Scientists richtet, die bereits mit anderen Programmiersprachen vertraut sind.

Python 2 kontra Python 3

In diesem Buch wird die Syntax von Python 3 verwendet, die Spracherweiterungen enthält, die mit Python 2 inkompatibel sind. Zwar wurde Python 3 schon 2008 veröffentlicht, allerdings verbreitete sich diese Version insbesondere in den Communitys von Wissenschaft und Webentwicklung nur langsam. Das lag vor allem daran, dass die Anpassung vieler wichtiger Pakete von Drittherstellern an die neue Sprachversion Zeit benötigte. Seit Anfang 2014 gibt es jedoch stabile Versionen der für die Data Science wichtigsten Tools, die sowohl mit Python 2 als auch mit Python 3 kompatibel sind, daher wird in diesem Buch die neuere Syntax von Python 3 genutzt. Allerdings funktionieren die meisten Codeabschnitte dieses Buchs ohne Änderungen auch in Python 2. Wenn Py2-inkompatible Syntax verwendet wird, weise ich ausdrücklich darauf hin.

Inhaltsübersicht

Alle Kapitel in diesem Buch konzentrieren sich auf ein bestimmtes Paket oder Tool, das für die mit Python betriebene Data Science von grundlegender Bedeutung ist.

IPython und Jupyter (Kapitel 1)

Diese Pakete bieten eine Umgebung für Berechnungen, die von vielen Data Scientists genutzt wird, die Python einsetzen.

NumPy (Kapitel 2)

Diese Bibliothek stellt das `ndarray`-Objekt zur Verfügung, das ein effizientes Speichern und die Handhabung dicht gepackter Datenarrays in Python ermöglicht.

Pandas (Kapitel 3)

Diese Bibliothek verfügt über das `DataFrame`-Objekt, das ein effizientes Speichern und die Handhabung gekennzeichneteter bzw. spaltenorientierter Daten in Python gestattet.

Matplotlib (Kapitel 4)

Diese Bibliothek ermöglicht flexible und vielfältige Visualisierungen von Daten in Python.

Scikit-Learn (Kapitel 5)

Diese Bibliothek stellt eine effiziente Implementierung der wichtigsten und gebräuchlichsten Machine-Learning-Algorithmen zur Verfügung.

Natürlich umfasst die PyData-Welt viel mehr als diese fünf Pakete – und sie wächst mit jedem Tag weiter. Ich werde mich im Folgenden daher bemühen, Hinweise auf andere interessante Projekte, Bestrebungen und Pakete zu geben, die die Grenzen des mit Python Machbaren erweitern. Dessen ungeachtet sind die fünf genannten Pakete derzeit für viele der mit Python möglichen Aufgaben der Data Science von grundlegender Bedeutung, und ich erwarte, dass sie wichtig bleiben, auch wenn das sie umgebende Ökosystem weiterhin wächst.

Verwendung der Codebeispiele

Unter <https://github.com/jakevdp/PythonDataScienceHandbook> steht ergänzendes Material (Codebeispiele, Abbildungen usw.) zum Herunterladen zur Verfügung. Das Buch soll Ihnen helfen, Ihre Arbeit zu erledigen. Den im Buch aufgeführten Code können Sie generell in Ihren eigenen Programmen und der Dokumentation verwenden. Sie brauchen uns nicht um Erlaubnis zu fragen, solange Sie nicht erhebliche Teile des Codes nutzen. Wenn Sie beispielsweise ein Programm schreiben, das einige der im Buch aufgeführten Codeschnipsel verwendet, benötigen Sie dafür keine Erlaubnis. Der Verkauf oder Vertrieb einer CD-ROM, die Codebeispiele aus dem Buch enthält, bedarf hingegen einer Genehmigung. Das Beantworten von Fragen durch Verwendung von Zitaten oder Beispielcode aus diesem Buch muss nicht extra genehmigt werden. Die Verwendung erheblicher Teile des Beispielcodes in der Dokumentation Ihres eigenen Produkts erfordert jedoch eine Genehmigung.

Wir freuen uns über Quellennennungen, machen sie jedoch nicht zur Bedingung. Üblich ist die Nennung von Titel, Autor(en), Verlag, Erscheinungsjahr und ISBN, also beispielsweise »*Data Science mit Python*« von *Jake VanderPlas* (mitp Verlag 2017), ISBN 978-3-95845-695-2.

Installation der Software

Die Installation von Python und der für wissenschaftliche Berechnungen erforderlichen Bibliotheken ist unkompliziert. In diesem Abschnitt finden Sie einige Überlegungen, denen Sie bei der Einrichtung Ihres Computers Beachtung schenken sollten.

Es gibt zwar verschiedene Möglichkeiten, Python zu installieren, allerdings empfehle ich zum Betreiben von Data Science die Anaconda-Distribution, die unter Windows, Linux und macOS auf ähnliche Weise funktioniert. Es gibt zwei Varianten der Anaconda-Distribution:

- Miniconda (<http://conda.pydata.org/miniconda.html>) besteht aus dem eigentlichen Python-Interpreter und einem Kommandozeilenprogramm namens *conda*, das als plattformübergreifender Paketmanager für Python-Pakete fungiert. Das Programm arbeitet in ähnlicher Weise wie die Tools *apt* oder *yum*, die Linux-Usern bekannt sein dürften.
- Anaconda (<https://www.continuum.io/downloads>) enthält sowohl Python als auch *conda* und darüber hinaus eine Reihe vorinstallierter Pakete, die für wissenschaftliche Berechnungen konzipiert sind. Aufgrund der Größe dieser Pakete müssen Sie davon ausgehen, dass die Installation mehrere Gigabyte Speicherplatz auf der Festplatte belegt.

Alle in Anaconda enthaltenen Pakete können auch nachträglich der Miniconda-Installation hinzugefügt werden. Daher empfehle ich, mit Miniconda anzufangen.

Laden Sie zunächst das Miniconda-Paket herunter und installieren Sie es. Vergewissern Sie sich, dass Sie eine Version auswählen, die Python 3 enthält. Installieren Sie dann die in diesem Buch verwendeten Pakete:

```
[~]$ conda install numpy pandas scikit-learn matplotlib seaborn ipython-notebook
```

Wir werden im gesamten Buch noch weitere, spezialisiertere Tools verwenden, die zum wissenschaftlich orientierten Ökosystem in Python gehören. Für gewöhnlich ist zur Installation lediglich eine Eingabe wie `conda install paketname` erforderlich. Weitere Informationen über conda, beispielsweise über das Erstellen und Verwenden von conda-Umgebungen (die ich nur nachdrücklich empfehlen kann), finden Sie in der Onlinedokumentation (<http://conda.pydata.org/docs/>).

Konventionen dieses Buchs

In diesem Buch gelten die folgenden typografischen Konventionen:

Kursive Schrift

Kennzeichnet neue Begriffe, Dateinamen und Dateinamenserweiterungen.

Nicht proportionale Schrift

Wird für URLs, Programmlistings und im Fließtext verwendet, um Programmbestandteile wie Variablen- oder Funktionsbezeichnungen, Datenbanken, Datentypen Umgebungsvariablen, Anweisungen und Schlüsselwörter zu kennzeichnen.

Fette nicht proportionale Schrift

Kommandos oder sonstiger Text, der vom User buchstabengetreu eingegeben werden soll.

Kursive nicht proportionale Schrift

Text, der durch eigene Werte oder durch kontextabhängige Werte zu ersetzen ist.

Die Webseite zum Buch

Der Verlag hält auf seiner Website weiteres Material zum Buch bereit. Unter <http://www.mipt.de/695> können Sie sich Beispielcode herunterladen.



Über den Autor

Jake VanderPlas ist seit Langem User und Entwickler der SciPy-Umgebung. Derzeit ist er als interdisziplinärer Forschungsdirektor an der Universität Washington tätig, führt eigene astronomische Forschungsarbeiten durch und berät dort ansässige Wissenschaftler, die auf vielen verschiedenen Fachgebieten arbeiten.

Mehr als normales Python: IPython

Für Python stehen viele verschiedene Entwicklungsumgebungen zur Verfügung, und häufig werde ich gefragt, welche ich für meine eigenen Arbeiten verwende. Einige Leute überrascht die Antwort: Meine bevorzugte Entwicklungsumgebung ist IPython (<http://ipython.org/>) in Kombination mit einem Texteditor (entweder Emacs oder Atom – das hängt von meiner Stimmung ab). IPython (Abkürzung für *Interactive Python*) wurde 2001 von Fernando Perez in Form eines erweiterten Python-Interpreters ins Leben gerufen und hat sich seither zu einem Projekt entwickelt, das es sich zum Ziel gesetzt hat, »Tools für den gesamten Lebenszyklus in der forschenden Informatik« – so Perez' eigene Worte – bereitzustellen. Wenn man Python als Motor einer Aufgabe von Data Science betrachtet, können Sie sich IPython als die interaktive Steuerkonsole dazu vorstellen.

IPython ist nicht nur eine nützliche interaktive Schnittstelle zu Python, sondern stellt darüber hinaus eine Reihe praktischer syntaktischer Erweiterungen der Sprache bereit. Die nützlichsten dieser Erweiterungen werden wir gleich erörtern. IPython ist außerdem sehr eng mit dem Jupyter-Projekt verknüpft (<http://jupyter.org>), das ein browserbasiertes sogenanntes Notebook zur Verfügung stellt, das bei der Entwicklung, der Zusammenarbeit, dem Teilen und sogar der Veröffentlichung von Ergebnissen der Data Science gute Dienste leistet. Tatsächlich ist das IPython-Notebook eigentlich ein Sonderfall der umfangreicheren Jupyter-Notebook-Struktur, die Notebooks für Julia, R und andere Programmiersprachen umfasst. Um ein Beispiel für die Nützlichkeit dieses Notebook-Formats zu geben: Betrachten Sie einfach nur die Seite, die Sie gerade lesen. Das vollständige Manuskript dieses Buchs wurde in Form einer Reihe von IPython-Notebooks verfasst.

Bei IPython geht es darum, Python effizient für wissenschaftliche und datenintensive Berechnungen interaktiv einsetzen zu können. In diesem Kapitel werden wir zunächst einige der Features von IPython betrachten, die sich in der Praxis der Data Science als nützlich erweisen. Der Schwerpunkt liegt hierbei auf der bereitgestellten Syntax, die mehr zu bieten hat als die Standardfeatures von Python. Anschließend werden wir uns etwas eingehender mit einigen der sehr nützlichen »magischen Befehle« befassen, die gängige Aufgaben bei der Erstellung und Verwendung des Data-Science-Codes beschleunigen können. Zum Abschluss erörtern wir dann einige der Features des Notebooks, die dem Verständnis der Daten und dem Teilen der Ergebnisse dienen können.

1.1 Shell oder Notebook?

Es gibt im Wesentlichen zwei verschiedene Methoden, IPython zu verwenden, die wir in diesem Kapitel betrachten: die IPython-Shell und das IPython-Notebook. Ein Großteil des Inhalts dieses Kapitels betrifft beide, und die Beispiele verwenden im Wechsel Shell und Notebook – je nachdem, was am praktischsten ist. In den Abschnitten, die lediglich für eines der beiden Verfahren von Bedeutung sind, werde ich ausdrücklich darauf hinweisen.

Doch zunächst einmal folgen einige Hinweise zum Starten der IPython-Shell und zum Öffnen eines Notebooks.

1.1.1 Die IPython-Shell starten

Wie die meisten Teile dieses Buchs sollte dieses Kapitel nicht passiv gelesen werden. Ich empfehle Ihnen, während der Lektüre mit den vorgestellten Tools und der angegebenen Syntax herumzuexperimentieren. Die durch das Nachvollziehen der Beispiele erworbenen Fingerfertigkeiten werden sich als sehr viel nützlicher erweisen, als wenn Sie nur darüber lesen. Geben Sie auf der Kommandozeile `ipython` ein, um den Python-Interpreter zu starten. Sollten Sie eine Distribution wie Anaconda oder EPD (*Enthought Python Distribution*) installiert haben, können Sie möglicherweise alternativ einen systemspezifischen Programmstarter verwenden. (Wir erörtern das ausführlicher in Abschnitt 1.2, »Hilfe und Dokumentation in IPython«.)

Nach dem Start des Interpreters sollte Ihnen eine Eingabeaufforderung wie die folgende angezeigt werden:

```
IPython 4.0.1 -- An enhanced Interactive Python.
?          -> Introduction and overview of IPython's features.
%quickref -> Quick reference.
help      -> Python's own help system.
object?   -> Details about 'object', use 'object??' for extra
           details.
In [1]:
```

Nun können Sie fortfahren.

1.1.2 Das Jupyter-Notebook starten

Das Jupyter-Notebook ist eine browserbasierte grafische Schnittstelle für die Python-Shell und besitzt eine große Vielfalt dynamischer Anzeigemöglichkeiten. Neben der Ausführung von Python-/IPython-Anweisungen gestattet das Notebook dem User das Einfügen von formatiertem Text, statischen und dynamischen Visualisierungen, mathematischen Formeln, JavaScript-Widgets und vielem mehr. Darüber hinaus können die Dokumente in einem Format gespeichert werden, das es anderen Usern ermöglicht, sie auf ihren eigenen Systemen zu öffnen und den Code auszuführen.

Das IPython-Notebook wird zwar in einem Fenster Ihres Webbrowsers angezeigt und bearbeitet, allerdings ist eine Verbindung zu einem laufenden Python-Prozess erforderlich, um Code auszuführen. Geben Sie in Ihrer System-Shell folgenden Befehl ein, um diesen Prozess (der als »Kernel« bezeichnet wird) zu starten:

```
$ jupyter notebook
```

Dieser Befehl startet einen lokalen Webserver, auf den Ihr Browser zugreifen kann. Er gibt sofort einige Meldungen aus, die zeigen, was vor sich geht. Dieses Log sieht in etwa folgendermaßen aus:

```
$ jupyter notebook
[NotebookApp] Serving notebooks from local directory: /Users/jakevdp/...
[NotebookApp] 0 active kernels
[NotebookApp] The IPython Notebook is running at: http://localhost:8888/
[NotebookApp] Use Control-C to stop this server and shut down all kernels...
```

Nach der Eingabe des Befehls sollte sich automatisch Ihr Standardbrowser öffnen und die genannte lokale URL anzeigen. Die genaue Adresse ist von Ihrem System abhängig. Öffnet sich Ihr Browser nicht automatisch, können Sie von Hand ein Browserfenster öffnen und die Adresse (in diesem Beispiel `http://localhost:8888/`) eingeben.

1.2 Hilfe und Dokumentation in IPython

Auch wenn Sie die anderen Abschnitte dieses Kapitels überspringen, sollten Sie doch wenigstens diesen lesen: Ich habe festgestellt, dass die hier erläuterten IPython-Tools den größten Einfluss auf meinem alltäglichen Arbeitsablauf haben.

Wenn ein technologisch interessierter Mensch darum gebeten wird, einem Freund, Familienmitglied oder Kollegen bei einem Computerproblem zu helfen, geht es meistens gar nicht darum, die Lösung zu kennen, sondern zu wissen, wie man schnell eine noch unbekannte Lösung findet. Mit Data Science verhält es sich genauso: Durchsuchbare Webressourcen wie Onlinedokumentationen, Mailinglisten und auf Stackoverflowbusiness.com gefundene Antworten enthalten jede Menge Informationen, auch (und gerade?) wenn es sich um ein Thema handelt, nach dem Sie selbst schon einmal gesucht haben. Für einen leistungsfähigen Praktiker der Data Science geht es weniger darum, das in jeder erdenklichen Situation einzusetzende Tool oder den geeigneten Befehl auswendig zu lernen, sondern vielmehr darum, zu wissen, wie man die benötigten Informationen schnell und einfach findet – sei es nun mithilfe einer Suchmaschine oder auf anderem Weg.

Zwischen dem User und der erforderlichen Dokumentation sowie den Suchvorgängen, die ein effektives Arbeiten ermöglichen, klafft eine Lücke. Diese zu schließen, ist eine der nützlichsten Funktionen von IPython/Jupyter. Zwar spielen Suchvorgänge im Web bei der Beantwortung komplizierter Fragen nach wie vor eine Rolle, allerdings stellt IPython bereits eine bemerkenswerte Menge an Informationen bereit. Hier einige Beispiele für Fragen, bei deren Beantwortung IPython nach einigen wenigen Tastendrücken hilfreich sein kann:

- Wie rufe ich eine bestimmte Funktion auf? Welche Argumente und Optionen besitzt sie?
- Wie sieht der Quellcode eines bestimmten Python-Objekts aus?
- Was ist in einem importierten Paket enthalten? Welche Attribute oder Methoden besitzt ein Objekt?

Wir erörtern nun die IPython-Tools für den schnellen Zugriff auf diese Informationen, nämlich das Zeichen `?` zum Durchsuchen der Dokumentation, die beiden Zeichen `??` zum Erkunden des Quellcodes und die `[Tab]`-Taste, die eine automatische Vervollständigung ermöglicht.

1.2.1 Mit ? auf die Dokumentation zugreifen

Die Programmiersprache Python und das für die Data Science geeignete Ökosystem schenken dem User große Beachtung. Dazu gehört insbesondere der Zugang zur Dokumentation. Alle Python-Objekte enthalten einen Verweis auf einen String, den sogenannten *Docstring*, der wiederum in den meisten Fällen eine kompakte Übersicht über das Objekt und dessen Verwendung enthält. Python verfügt über eine integrierte `help()`-Funktion, die auf diese Informationen zugreift und sie ausgibt. Um beispielsweise die Dokumentation der integrierten Funktion `len` anzuzeigen, können Sie Folgendes eingeben:

```
In [1]: help(len)
Help on built-in function len in module builtins:
len(...)
    len(object) -> integer
    Return the number of items of a sequence or mapping.
```

Je nachdem, welchen Interpreter Sie verwenden, wird der Text auf der Konsole oder in einem eigenen Fenster ausgegeben.

Die Suche nach der Hilfe für ein Objekt ist äußerst nützlich und geschieht sehr häufig. Daher verwendet IPython das Zeichen `?` als Abkürzung für den Zugriff auf die Dokumentation und weitere wichtige Informationen:

```
In [2]: len?
Type:          builtin_function_or_method
String form: <built-in function len>
Namespace:    Python builtin
Docstring:
len(object) -> integer
Return the number of items of a sequence or mapping.
```

Diese Schreibweise funktioniert praktisch mit allem, auch mit Objektmethoden:

```
In [3]: L = [1, 2, 3]
In [4]: L.insert?
Type:          builtin_function_or_method
String form: <built-in method insert of list object at 0x1024b8ea8>
Docstring:    L.insert(index, object) -- insert object before index
```

Und sogar mit Objekten selbst – dann wird die Dokumentation des Objekttyps angezeigt:

```
In [5]: L?
Type:        list
String form: [1, 2, 3]
Length:      3
Docstring:
```



```
list() -> new empty list  
list(iterable) -> new list initialized from iterable's items
```

Wichtig zu wissen ist, dass das ebenfalls mit Funktionen und anderen von Ihnen selbst erzeugten Objekten funktioniert:

```
In [6]: def square(a):  
.....:     """a zum Quadrat zurückgeben."""  
.....:     return a ** 2  
.....:
```

Beachten Sie hier, dass wir zum Erstellen des Docstrings unserer Funktion einfach eine literale Zeichenkette in die erste Zeile eingegeben haben. Da Docstrings für gewöhnlich mehrzeilig sind, haben wir gemäß Konvention Pythons Schreibweise für mehrzeilige Strings mit dreifachem Anführungszeichen verwendet.

Nun verwenden wir das Zeichen `?`, um diesen Docstring anzuzeigen:

```
In [7]: square?  
Type:      function  
String form: <function square at 0x103713cb0>  
Definition: square(a)  
Docstring: a zum Quadrat zurückgeben.
```

Dieser schnelle Zugriff auf die Dokumentation via Docstring ist einer der Gründe dafür, dass Sie sich angewöhnen sollten, den von Ihnen geschriebenen Code immer zu dokumentieren!

1.2.2 Mit `??` auf den Quellcode zugreifen

Da die Programmiersprache Python sehr leicht verständlich ist, können Sie für gewöhnlich tiefere Einblicke gewinnen, wenn Sie sich den Quellcode eines Objekts ansehen, das Sie interessiert. Mit einem doppelten Fragezeichen (`??`) stellt IPython eine Abkürzung für den Zugriff auf den Quellcode zur Verfügung:

```
In [8]: square??  
Type:      function  
String form: <function square at 0x103713cb0>  
Definition: square(a)  
Source:  
def square(a):  
    "a zum Quadrat zurückgeben."  
    return a ** 2
```

Bei so einfachen Funktionen wie dieser können Sie mit dem doppelten Fragezeichen einen schnellen Blick darauf werfen, was unter der Haube vor sich geht.

Sollten Sie damit weiter herumexperimentieren, werden Sie feststellen, dass ein angehängtes `??` manchmal überhaupt keinen Quellcode anzeigt. Das liegt im Allgemeinen daran, dass das fragliche Objekt nicht in Python implementiert ist, sondern in C oder einer anderen kompilierten Erweiterungssprache. In diesem Fall liefert `??` dieselbe Ausgabe wie `?`. Das kommt insbesondere bei vielen in Python fest integrierten Objekten und Typen vor, wie beispielsweise bei der vorhin erwähnten Funktion `len`:

```
In [9]: len??
Type:      builtin_function_or_method
String form: <built-in function len>
Namespace: Python builtin
Docstring:
len(object) -> integer
Return the number of items of a sequence or mapping.
```

Der Einsatz von `?` und/oder `??` bietet eine schnelle und leistungsfähige Schnittstelle für das Auffinden von Informationen darüber, was in einer Python-Funktion oder einem Python-Modul eigentlich geschieht.

1.2.3 Module mit der Tab-Vervollständigung erkunden

IPython besitzt eine weitere nützliche Schnittstelle: die Verwendung der `[Tab]`-Taste zur automatischen Vervollständigung und zum Erkunden des Inhalts von Objekten, Modulen und Namensräumen. In den folgenden Beispielen wird durch `<TAB>` angezeigt, dass die `[Tab]`-Taste gedrückt werden muss.

Tab-Vervollständigung des Inhalts von Objekten

Jedes Python-Objekt besitzt verschiedene Attribute und Methoden, die ihm zugeordnet sind. Neben dem bereits erläuterten `help` verfügt Python über eine integrierte `dir`-Funktion, die eine Liste dieser Attribute und Methoden ausgibt. Allerdings ist es in der Praxis viel einfacher, die Tab-Vervollständigung zu verwenden. Um eine Liste aller verfügbaren Attribute anzuzeigen, geben Sie einfach den Namen des Objekts ein, gefolgt von einem Punkt (`.`) und der `[Tab]`-Taste:

```
In [10]: L.<TAB>
L.append  L.copy    L.extend  L.insert  L.remove  L.sort
L.clear   L.count   L.index   L.pop     L.reverse
```

Um die Anzahl der Treffer in der Liste zu verringern, geben Sie einfach den ersten oder mehrere Buchstaben des Namens ein. Nach dem Betätigen der `[Tab]`-Taste werden dann nur noch die übereinstimmenden Attribute und Methoden angezeigt:

```
In [10]: L.c<TAB>
L.clear  L.copy  L.count
In [10]: L.co<TAB>
L.copy  L.count
```

Wenn der Treffer eindeutig ist, wird die Zeile durch ein weiteres Drücken der `[Tab]`-Taste vervollständigt. Die folgende Eingabe wird beispielsweise sofort zu `L.count` vervollständigt:

```
In [10]: L.cou<TAB>
```

Python erzwingt zwar keine strenge Unterscheidung zwischen öffentlichen/externen und privaten/internen Attributen, allerdings gibt es die Konvention, Letztere durch einen vorangestellten Unterstrich zu kennzeichnen. Der Einfachheit halber werden die privaten und besonderen Methoden in der Liste standardmäßig weggelassen. Es ist jedoch möglich, sie durch ausdrückliche Eingabe des Unterstrichs anzuzeigen:

```
In [10]: L.<TAB>
L.__add__          L.__gt__          L.__reduce__
L.__class__       L.__hash__       L.__reduce_ex__
```

Wir zeigen hier nur kurz die ersten paar Zeilen der Ausgabe. Bei den meisten handelt es sich um Pythons spezielle Methoden, deren Namen mit einem doppelten Unterstrich beginnen (oft auch bezeichnet mit dem Spitznamen »dunder«-Methoden).

Tab-Vervollständigung beim Importieren

Auch beim Importieren von Objekten eines Pakets erweist sich die Tab-Vervollständigung als nützlich. Hier verwenden wir sie, um alle möglichen Importe des `itertools`-Pakets zu finden, deren Namen mit `co` beginnen:

```
In [10]: from itertools import co<TAB>
combinations          compress
combinations_with_replacement  count
```

Auf ähnliche Weise können Sie die Tab-Vervollständigung einsetzen, um zu prüfen, welche Importe für Ihr System verfügbar sind (das hängt davon ab, welche Skripte und Module von Drittherstellern für Ihre Python-Sitzung zugänglich sind):

```
In [10]: import <TAB>
Display all 399 possibilities? (y or n)
Crypto                dis                py_compile
Cython                distutils         pyc1br
...                  ...                ...

diff1ib              pwd                zmq
In [10]: import h<TAB>
hashlib              hmac                http
heapq                html                hus1
```

(Der Kürze halber sind hier wieder nicht alle 399 importierbaren Pakete und Module aufgeführt, die auf meinem System verfügbar sind.)

Mehr als die Tab-Vervollständigung: Suche mit Wildcards

Die Tab-Vervollständigung ist nützlich, wenn Ihnen die ersten paar Buchstaben des Namens eines Objekts oder Attributs bekannt sind, das Sie suchen, hilft aber nicht weiter, wenn Sie nach übereinstimmenden Zeichen in der Mitte oder am Ende einer Bezeichnung suchen. Für diesen Anwendungsfall hält IPython mit dem Zeichen `*` eine Suche mit Wildcards bereit.

Wir können das Zeichen beispielsweise verwenden, um alle Objekte im Namensraum anzuzeigen, deren Namen auf `Warning` enden:

```
In [10]: *Warning?
BytesWarning          RuntimeError
DeprecationWarning   SyntaxWarning
FutureWarning         UnicodeWarning
ImportWarning         UserWarning
PendingDeprecationWarning Warning
ResourceWarning
```

Beachten Sie, dass das Zeichen `*` mit allen Strings übereinstimmt – auch mit einer leeren Zeichenkette.

Nehmen wir nun an, wir suchten nach einer Stringmethode, die an irgendeiner Stelle das Wort `find` enthält. Auf diese Weise können wir sie finden:

```
In [10]: str.*find*?
str.find
str.rfind
```

Ich finde diese Art der flexiblen Suche mit Wildcards äußerst nützlich, um einen bestimmten Befehl zu finden, wenn ich ein neues Paket erkunde oder mich mit einem bereits bekannten erneut vertraut mache.

1.3 Tastaturkürzel in der IPython-Shell

Auch wenn Sie nur wenig Zeit mit dem Computer verbringen, werden Sie vermutlich bereits festgestellt haben, dass sich das eine oder andere Tastaturkürzel für Ihren Arbeitsablauf als nützlich erweist. Am bekanntesten sind vielleicht `Cmd-C` und `Cmd-V` (bzw. `Strg-C` und `Strg-V`) zum Kopieren und Einfügen in vielen ganz verschiedenen Programmen und Systemen. Erfahrene User gehen oft sogar noch einen Schritt weiter: Gängige Texteditoren wie Emacs, Vim und andere stellen dem User einen immensen Umfang an verschiedenen Funktionen durch komplizierte Kombinationen von Tastendrücken zur Verfügung.

Ganz so weit geht die IPython-Shell nicht, dennoch bietet sie einige Tastaturkürzel zum schnellen Navigieren beim Eingeben von Befehlen. Diese Tastaturkürzel stellt tatsächlich nicht IPython selbst zur Verfügung, sondern die von dem Programm genutzte GNU-Readline-Bibliothek. Aus diesem Grund unterscheiden sich einige Tastaturkürzel auf Ihrem Sys-

tem abhängig von der Konfiguration womöglich von den nachstehend aufgeführten. Einige der Tastaturkürzel funktionieren eventuell auch im browserbasierten Notebook, allerdings geht es in diesem Abschnitt vornehmlich um die Tastaturkürzel in der IPython-Shell.

Sobald Sie sich daran gewöhnt haben, sind sie äußerst nützlich, um schnell bestimmte Befehle auszuführen, ohne die Hände von der Tastatur nehmen zu müssen. Sollten Sie Emacs-User sein oder Erfahrung mit Linux-Shells haben, wird Ihnen das Folgende bekannt vorkommen. Wir gruppieren die Befehle nach bestimmten Kategorien: Tastaturkürzel zum Navigieren, Tastaturkürzel bei der Texteingabe, Tastaturkürzel für den Befehlsverlauf und sonstige Tastaturkürzel.

1.3.1 Tastaturkürzel zum Navigieren

Dass die nach links und rechts weisenden Pfeiltasten dazu dienen, den Cursor in der Zeile rückwärts bzw. vorwärts zu bewegen, ist ziemlich offensichtlich, es gibt jedoch weitere Möglichkeiten, die es nicht erforderlich machen, Ihre Hände aus der gewohnten Schreibposition zu bewegen (siehe Tabelle 1.1).

Tastaturkürzel	Beschreibung
<code>Strg</code> - <code>A</code>	Bewegt den Cursor an den Zeilenanfang.
<code>Strg</code> - <code>E</code>	Bewegt den Cursor an das Zeilenende.
<code>Strg</code> - <code>B</code> (oder Pfeil nach links)	Bewegt den Cursor ein Zeichen rückwärts.
<code>Strg</code> - <code>F</code> (oder Pfeil nach rechts)	Bewegt den Cursor ein Zeichen vorwärts.

Tabelle 1.1: Tastaturkürzel zum Navigieren

1.3.2 Tastaturkürzel bei der Texteingabe

Jedem User ist die Verwendung der Rückschritttaste zum Löschen des zuvor eingegebenen Zeichens bekannt, allerdings sind oftmals einige Fingerverrenkungen erforderlich, um sie zu erreichen, und außerdem löscht sie beim Betätigen jeweils nur ein einzelnes Zeichen. In IPython gibt es einige Tastaturkürzel zum Löschen bestimmter Teile der eingegebenen Textzeile. Sofort nützlich sind die Befehle zum Löschen der ganzen Textzeile. Sie sind Ihnen in Fleisch und Blut übergegangen, wenn Sie feststellen, dass Sie die Tastenkombinationen `Strg`-`B` und `Strg`-`D` verwenden, anstatt die Rückschritttaste zu benutzen, um das zuvor eingegebene Zeichen zu löschen!

Tastaturkürzel	Beschreibung
Rückschritttaste	Zeichen links vom Cursor löschen.
<code>Strg</code> - <code>D</code>	Zeichen rechts vom Cursor löschen.
<code>Strg</code> - <code>K</code>	Text von der Cursorposition bis zum Zeilenende ausschneiden.
<code>Strg</code> - <code>U</code>	Text vom Zeilenanfang bis zur Cursorposition ausschneiden.
<code>Strg</code> - <code>Y</code>	Zuvor ausgeschnittenen Text einfügen.
<code>Strg</code> - <code>T</code>	Die beiden zuletzt eingegebenen Zeichen vertauschen.

Tabelle 1.2: Tastaturkürzel bei der Texteingabe

1.3.3 Tastaturkürzel für den Befehlsverlauf

Unter den hier aufgeführten von IPython bereitgestellten Tastaturkürzeln dürften diejenigen zur Navigation im Befehlsverlauf die größten Auswirkungen haben. Der Befehlsverlauf umfasst nicht nur die aktuelle IPython-Sitzung, Ihr gesamter Befehlsverlauf ist in einer SQLite-Datenbank im selben Verzeichnis gespeichert, in dem sich auch Ihr IPython-Profil befindet. Die einfachste Zugriffsmöglichkeit auf Ihren Befehlsverlauf ist das Betätigen der Pfeiltasten nach oben und unten, mit denen Sie ihn schrittweise durchblättern können, es stehen aber noch andere Möglichkeiten zur Verfügung (siehe Tabelle 1.3).

Tastaturkürzel	Beschreibung
<code>[Strg]-[P]</code> (oder Pfeiltaste nach oben)	Vorhergehenden Befehl im Verlauf auswählen.
<code>[Strg]-[N]</code> (oder Pfeiltaste nach unten)	Nachfolgenden Befehl im Verlauf auswählen.
<code>[Strg]-[R]</code>	Rückwärtssuche im Befehlsverlauf.

Tabelle 1.3: Tastaturkürzel für den Befehlsverlauf

Die Rückwärtssuche kann besonders praktisch sein. Wie Sie wissen, haben wir im vorigen Abschnitt eine Funktion namens `square` definiert. Durchsuchen Sie nun in einer neuen IPython-Shell den Befehlsverlauf nach dieser Definition. Wenn Sie im IPython-Terminal die Tastenkombination `[Strg]-[R]` drücken, wird Ihnen die folgende Eingabeaufforderung angezeigt:

```
In [1]:
(reverse-i-search) ` `:
```

Beginnen Sie nun damit, Zeichen einzugeben, zeigt IPython den zuletzt eingegebenen Befehl an (sofern vorhanden), der mit den eingegebenen Zeichen übereinstimmt:

```
In [1]:
(reverse-i-search) `squ`: square??
```

Sie können jederzeit weitere Zeichen eingeben, um die Suche zu verfeinern, oder drücken Sie erneut `[Strg]-[R]`, um nach einem weiter zurückliegenden Befehl zu suchen, der zur Suchanfrage passt. Wenn Sie die Eingaben im letzten Abschnitt nachvollzogen haben, wird nach zweimaligem Betätigen von `[Strg]-[R]` Folgendes angezeigt:

```
In [1]:
(reverse-i-search) `squ': def square(a):
    """a zum Quadrat zurückgeben."""
    return a ** 2
```

Sobald Sie den gesuchten Befehl gefunden haben, können Sie die Suche mit der `[Enter]`-Taste beenden. Jetzt können Sie den gefundenen Befehl ausführen und die Sitzung fortsetzen:

```
In [1]: def square(a):
    """a zum Quadrat zurückgeben."""
```

```

return a ** 2
In [2]: square(2)
Out[2]: 4

```

Sie können auch die Tastenkombinationen `[Strg]-[P]`/`[Strg]-[N]` oder die Pfeiltasten nach oben und unten verwenden, um den Befehlsverlauf zu durchsuchen, allerdings werden dann bei der Suche lediglich die Zeichen am Anfang der Eingabezeile berücksichtigt. Wenn Sie also `def` eingeben und dann `[Strg]-[P]` drücken, wird der zuletzt eingegebene Befehl im Verlauf angezeigt (falls vorhanden), der mit den Zeichen `def` beginnt.

1.3.4 Sonstige Tastaturkürzel

Darüber hinaus gibt es einige weitere nützliche Tastaturkürzel, die sich keiner der bisherigen Kategorien zuordnen lassen (siehe Tabelle 1.4).

Tastaturkürzel	Beschreibung
<code>[Strg]-[L]</code>	Terminalanzeige löschen.
<code>[Strg]-[C]</code>	Aktuellen Python-Befehl abbrechen.
<code>[Strg]-[D]</code>	Python-Sitzung beenden.

Tabelle 1.4: Sonstige Tastaturkürzel

Insbesondere der Befehl `[Strg]-[C]` kann sich als nützlich erweisen, wenn Sie versehentlich einen sehr zeitaufwendigen Job gestartet haben.

Einige der hier vorgestellten Befehle mögen auf den ersten Blick vielleicht uninteressant erscheinen, Sie werden sie aber mit etwas Übung wie im Schlaf benutzen. Haben Sie sich diese Fingerfertigkeiten einmal angeeignet, werden Sie sich sogar wünschen, dass diese Befehle auch an anderer Stelle zur Verfügung stünden.

1.4 Magische Befehle in IPython

Die beiden letzten Abschnitte zeigen, wie IPython es Ihnen ermöglicht, Python effektiv und interaktiv zu verwenden und zu erkunden. Nun kommen wir zu einigen Erweiterungen, die IPython der normalen Python-Syntax hinzufügt. Diese werden in IPython als »magische« Befehle oder Funktionen bezeichnet, und ihnen wird ein `%`-Zeichen vorangestellt. Die magischen Befehle sind dazu gedacht, verschiedene gängige Aufgaben, die bei einer Standarddatenanalyse immer wieder vorkommen, kurz und bündig zu erledigen. Von den magischen Befehlen/Funktionen (den sogenannten *Magics*) gibt es zwei Varianten: *Line-Magics*, denen ein einzelnes `%` vorangestellt wird und die jeweils eine einzelne Zeile verarbeiten, sowie *Cell-Magics*, die durch ein vorangestelltes `%%` gekennzeichnet sind und mehrzeilige Eingaben verarbeiten. Wir werden einige kurze Beispiele betrachten und befassen uns dann später in diesem Kapitel mit einer eingehenderen Erläuterung verschiedener nützlicher Magics.

1.4.1 Einfügen von Codeblöcken mit `%paste` und `%cpaste`

Beim Einsatz des IPython-Interpreters gibt es häufig das Problem, dass es beim Einfügen mehrzeiliger Codeblöcke zu unerwarteten Fehlern kommt, vor allem wenn der Text Einrück-

Kapitel 1

Mehr als normales Python: IPython

ckungen und vom Interpreter als Markierungen verwendete Zeichen enthält. Häufig ist das der Fall, wenn man auf einer Website Beispielcode entdeckt, den man im Interpreter einfügen möchte. Betrachten Sie die folgende einfache Funktion:

```
>>> def donothing(x):  
...     return x
```

Der Code ist so formatiert, wie er im Python-Interpreter angezeigt werden soll. Wenn Sie ihn jedoch kopieren und direkt in IPython einfügen, erscheint eine Fehlermeldung:

```
In [2]: >>> def donothing(x):  
...:     ...     return x  
...:  
File "<ipython-input-20-5a66c8964687>", line 2  
...     return x  
          ^  
SyntaxError: invalid syntax
```

Beim direkten Einfügen gerät der Interpreter durch die zusätzlich vorhandenen Zeichen zur Eingabeaufforderung durcheinander. Aber keine Sorge – IPythons magische Funktion `%paste` ist dafür ausgelegt, genau diesen Typ mehrzeiliger mit Textauszeichnungen versehener Eingaben korrekt zu handhaben:

```
In [3]: %paste  
>>> def donothing(x):  
...     return x  
  
## -- End pasted text --
```

Der `%paste`-Befehl fügt den Code ein und führt ihn aus, die Funktion kann nun also verwendet werden:

```
In [4]: donothing(10)  
Out[4]: 10
```

Der Befehl `%cpaste` hat einen ganz ähnlichen Zweck und zeigt eine interaktive mehrzeilige Eingabeaufforderung an, in der Sie einen oder mehrere Codeschnipsel einfügen und der Reihe nach ausführen lassen können:

```
In [5]: %cpaste  
Pasting code; enter '--' alone on the line to stop or use Ctrl-D.  
:>>> def donothing(x):  
...     return x  
:--
```

Diese magischen Befehle – und andere, auf die wir später noch zu sprechen kommen – stellen eine Funktionalität bereit, die mit einem herkömmlichen Python-Interpreter nur sehr schwer zu erzielen oder sogar unmöglich wäre.