

O'REILLY®



Einführung in Machine Learning mit Python

PRAXISWISSEN DATA SCIENCE

Andreas C. Müller & Sarah Guido
Übersetzung von Kristian Rother

Papier
plus⁺
PDF.

Zu diesem Buch – sowie zu vielen weiteren O'Reilly-Büchern – können Sie auch das entsprechende E-Book im PDF-Format herunterladen. Werden Sie dazu einfach Mitglied bei oreilly.plus⁺:

www.oreilly.plus

Einführung in Machine Learning mit Python

Praxiswissen Data Science

Andreas C. Müller und Sarah Guido

*Deutsche Übersetzung
von Kristian Rother*

O'REILLY®

Andreas C. Müller und Sarah Guido

Übersetzung: Kristian Rother

Lektorat: Alexandra Follenius

Korrektur: Claudia Lötschert, www.richtiger-text.de

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

Herstellung: Susanne Bröckelmann

Umschlaggestaltung: Michael Oréal, www.oreal.de

Druck und Bindung: M.P. Media-Print Informationstechnologie GmbH, 33100 Paderborn

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:

Print 978-3-96009-049-6

PDF 978-3-96010-111-6

ePub 978-3-96010-112-3

mobi 978-3-96010-113-0

Dieses Buch erscheint in Kooperation mit O'Reilly Media, Inc. unter dem Imprint »O'REILLY«. O'REILLY ist ein Markenzeichen und eine eingetragene Marke von O'Reilly Media, Inc. und wird mit Einwilligung des Eigentümers verwendet.

1. Auflage 2017

Copyright © 2017 dpunkt.verlag GmbH

Wiebinger Weg 17

69123 Heidelberg

Authorized German translation of the English edition of *Introduction to Machine Learning with Python*, ISBN 978-1-4493-6941-5 © 2017 Sarah Guido, Andreas Müller. 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.

Die vorliegende Publikation ist urheberrechtlich geschützt. Alle Rechte vorbehalten. Die Verwendung der Texte und Abbildungen, auch auszugsweise, ist ohne die schriftliche Zustimmung des Verlags urheberrechtswidrig und daher strafbar. Dies gilt insbesondere für die Vervielfältigung, Übersetzung oder die Verwendung in elektronischen Systemen.

Es wird darauf hingewiesen, dass die im Buch verwendeten Soft- und Hardware-Bezeichnungen sowie Markennamen und Produktbezeichnungen der jeweiligen Firmen im Allgemeinen warenzeichen-, marken- oder patentrechtlichem Schutz unterliegen.

Die Informationen in diesem Buch wurden mit größter Sorgfalt erarbeitet. Dennoch können Fehler nicht vollständig ausgeschlossen werden. Verlag, Autoren und Übersetzer übernehmen keine juristische Verantwortung oder irgendeine Haftung für eventuell verbliebene Fehler und deren Folgen.

5 4 3 2 1 0

Vorwort	IX
1 Einführung	1
Warum Machine Learning?	1
Welche Probleme kann Machine Learning lösen?	2
Ihre Aufgabe und Ihre Daten kennen	5
Warum Python?	5
scikit-learn	6
Installieren von scikit-learn.	6
Grundlegende Bibliotheken und Werkzeuge	7
Jupyter Notebook	8
NumPy	8
SciPy	8
matplotlib	10
pandas	10
mlearn	11
Python 2 versus Python 3	12
In diesem Buch verwendete Versionen	13
Eine erste Anwendung: Klassifizieren von Iris-Spezies	14
Die Daten kennenlernen	15
Erfolg nachweisen: Trainings- und Testdaten	17
Das Wichtigste zuerst: Sichten Sie Ihre Daten	19
Ihr erstes Modell konstruieren: k-nächste-Nachbarn	21
Vorhersagen treffen	22
Evaluieren des Modells	23
Zusammenfassung und Ausblick	23

2	Überwachtes Lernen	27
	Klassifikation und Regression	27
	Verallgemeinerung, Overfitting und Underfitting	28
	Zusammenhang zwischen Modellkomplexität und Größe des Datensatzes	31
	Algorithmen zum überwachten Lernen	32
	Einige Beispieldatensätze	32
	k-nächste-Nachbarn	36
	Lineare Modelle	45
	Naive Bayes-Klassifikatoren	66
	Entscheidungsbäume	68
	Ensembles von Entscheidungsbäumen	80
	Support Vector Machines mit Kernel	88
	Neuronale Netze (Deep Learning)	99
	Schätzungen der Unsicherheit von Klassifikatoren	112
	Die Entscheidungsfunktion	113
	Vorhersagen von Wahrscheinlichkeiten	116
	Unsicherheit bei der Klassifikation mehrerer Kategorien	118
	Zusammenfassung und Ausblick	120
3	Unüberwachtes Lernen und Vorverarbeitung	123
	Arten von unüberwachtem Lernen	123
	Herausforderungen beim unüberwachten Lernen	124
	Vorverarbeiten und Skalieren	124
	Unterschiedliche Möglichkeiten der Vorverarbeitung	125
	Anwenden von Datentransformationen	126
	Trainings- und Testdaten in gleicher Weise skalieren	128
	Die Auswirkungen der Vorverarbeitung auf überwachtes Lernen	130
	Dimensionsreduktion, Extraktion von Merkmalen und Manifold Learning	132
	Hauptkomponentenzerlegung (PCA)	132
	Nicht-negative-Matrix-Faktorisierung (NMF)	147
	Manifold Learning mit t-SNE	154
	Clusteranalyse	158
	k-Means-Clustering	158
	Agglomeratives Clustering	169
	DBSCAN	174
	Vergleichen und Auswerten von Clusteralgorithmen	178
	Zusammenfassung der Clustering-Methoden	192
	Zusammenfassung und Ausblick	193

4	Repräsentation von Daten und Merkmalsgenerierung	195
	Kategorische Variablen	196
	One-Hot-Kodierung (Dummy-Variablen)	197
	Zahlen können kategorische Daten kodieren	202
	Binning, Diskretisierung, lineare Modelle und Bäume	204
	Interaktionen und Polynome	208
	Univariate nichtlineare Transformation	214
	Automatische Auswahl von Merkmalen	218
	Univariate Statistiken	218
	Modellbasierte Auswahl von Merkmalen	221
	Iterative Auswahl von Merkmalen	222
	Berücksichtigen von Expertenwissen	224
	Zusammenfassung und Ausblick	233
5	Evaluierung und Verbesserung von Modellen	235
	Kreuzvalidierung	236
	Kreuzvalidierung in scikit-learn	237
	Vorteile der Kreuzvalidierung	238
	Stratifizierte k-fache Kreuzvalidierung und andere Strategien	238
	Gittersuche	244
	Einfache Gittersuche	245
	Die Gefahr des Overfittings von Parametern und Validierungsdaten	246
	Gittersuche mit Kreuzvalidierung	248
	Evaluationsmetriken	260
	Das Ziel im Auge behalten	260
	Metriken zur binären Klassifikation	261
	Metriken zur Klassifikation mehrerer Kategorien	282
	Regressionsmetriken	284
	Verwenden von Metriken zur Modellauswahl	285
	Zusammenfassung und Ausblick	287
6	Verkettete Algorithmen und Pipelines	289
	Parameterauswahl mit Vorverarbeitung	290
	Erstellen von Pipelines	292
	Pipelines zur Gittersuche einsetzen	293
	Die allgemeine Pipeline-Schnittstelle	296
	Bequemes Erstellen von Pipelines mit <code>make_pipeline</code>	297
	Zugriff auf Attribute von Schritten	298
	Zugriff auf Attribute in einer Pipeline mit Gittersuche	299

Gittersuche für Vorverarbeitungsschritte und Modellparameter	300
Gittersuche nach dem richtigen Modell	303
Zusammenfassung und Ausblick	304
7 Verarbeiten von Textdaten	307
Arten von als Strings repräsentierter Daten	307
Anwendungsbeispiel: Meinungsanalyse zu Filmbewertungen	309
Repräsentation von Text als Bag-of-Words	311
Anwenden von Bag-of-Words auf einen einfachen Datensatz	313
Bag-of-Words der Filmbewertungen	314
Stoppwörter	318
Umskalieren der Daten mit tf-idf	319
Untersuchen der Koeffizienten des Modells	322
Bag-of-Words mit mehr als einem Wort (n-Gramme)	323
Fortgeschrittene Tokenisierung, Stemming und Lemmatisierung . . .	327
Modellierung von Themen und Clustering von Dokumenten	331
Latent Dirichlet Allocation.	331
Zusammenfassung und Ausblick	338
8 Zusammenfassung und weiterführende Ressourcen	341
Herangehensweise an eine Fragestellung beim maschinellen Lernen .	341
Der menschliche Faktor	342
Vom Prototyp zum Produktivsystem	343
Testen von Produktivsystemen	344
Konstruieren eines eigenen Estimators	344
Wie geht es von hier aus weiter?	345
Theorie.	345
Andere Umgebungen und Programmpakete zum maschinellen	
Lernen	346
Ranking, Empfehlungssysteme und andere Arten von Lernen . . .	347
Probabilistische Modellierung, Inferenz und probabilistische	
Programmierung	347
Neuronale Netze	348
Skalieren auf größere Datensätze	349
Verfeinern Sie Ihre Fähigkeiten	350
Schlussbemerkung	351
Index	353

Machine Learning ist heutzutage ein integraler Bestandteil vieler kommerzieller Anwendungen und Forschungsprojekte in so unterschiedlichen Gebieten wie medizinischer Diagnose und Behandlung oder dem Finden von Freunden in einem sozialen Netzwerk. Viele glauben, dass maschinelles Lernen nur von großen Firmen mit großen Forschungsabteilungen umgesetzt werden kann. In diesem Buch möchten wir Ihnen zeigen, wie einfach es ist, selbst maschinelle Lernsysteme zu bauen, und wie Sie dabei am besten vorgehen. Mit dem Wissen aus diesem Buch können Sie sich Ihr eigenes System zusammenbauen, um herauszufinden, wie Menschen sich auf Twitter fühlen, oder um Vorhersagen über die globale Erwärmung zu treffen. Die Anwendungen von maschinellem Lernen sind schier endlos und mit den heutzutage zur Verfügung stehenden Daten hauptsächlich durch Ihre eigene Vorstellungskraft begrenzt.

Wer sollte dieses Buch lesen?

Dieses Buch ist für gegenwärtige und aufstrebende Anwender maschinellen Lernens geeignet, die reale Fragestellungen mithilfe von maschinellem Lernen beantworten möchten. Dies ist ein Einführungsbuch, das keinerlei Vorwissen über maschinelles Lernen oder künstliche Intelligenz (KI) voraussetzt. Wir werden unser Hauptaugenmerk auf die Verwendung von Python und der Bibliothek scikit-learn richten und sämtliche Schritte beim Entwickeln einer erfolgreichen Anwendung zum maschinellen Lernen abhandeln. Die dabei vorgestellten Methoden sind für Wissenschaftler, Forscher und an kommerziellen Anwendungen arbeitende Data Scientists nützlich. Den größten Nutzen wird dieses Buch für Sie haben, wenn Sie bereits ein wenig mit Python und den Bibliotheken NumPy und matplotlib vertraut sind.

Wir haben uns redlich bemüht, uns weniger um die Mathematik zu kümmern, sondern das Augenmerk vielmehr auf die praktischen Aspekte der Nutzung von Algorithmen zum maschinellen Lernen zu legen. Auch wenn Mathematik (insbesondere Wahrscheinlichkeitstheorie) die Grundlage maschinellen Lernens darstellt, werden

wir die Algorithmen nicht in aller Ausführlichkeit analysieren. Wenn Sie sich für die den maschinellen Lernalgorithmen zugrunde liegende Mathematik interessieren, empfehlen wir Ihnen das Buch *The Elements of Statistical Learning* (Springer) von Trevor Hastie, Robert Tibshirani und Jerome Friedman, das kostenlos auf der Website der Autoren (<http://statweb.stanford.edu/~tibs/ElemStatLearn/>) verfügbar ist. Ebenso werden wir nicht beschreiben, wie man Algorithmen für maschinelles Lernen von null auf implementiert. Stattdessen möchten wir Ihnen vor allem zeigen, wie Sie die zahlreichen bereits in scikit-learn und anderen Bibliotheken implementierten Methoden nutzen können.

Warum wir dieses Buch geschrieben haben

Es gibt zahlreiche Bücher über Machine Learning und KI. Allerdings sind diese alle für Masterstudenten und Doktoranden der Informatik geschrieben und stecken voller fortgeschrittener Mathematik. Das steht in deutlichem Gegensatz dazu, wie maschinelles Lernen tatsächlich verwendet wird, nämlich als bequemes Werkzeug in der Forschung und in kommerziellen Anwendungen. Heutzutage braucht man für Machine Learning keinen Dokortitel. Es gibt aber einige Ressourcen, die die wichtigsten Aspekte der Implementierung von maschinellem Lernen in der Praxis vollständig wiedergeben, ohne dass Sie einen Mathematikurs für Fortgeschrittene besuchen müssen. Wir hoffen, dass dieses Buch beim Anwenden maschineller Lernmethoden hilft, ohne dass dazu jahrelange Lektüre in Analysis, linearer Algebra und Wahrscheinlichkeitstheorie notwendig wäre.

Wegweiser durch dieses Buch

Dieses Buch ist etwa folgendermaßen organisiert:

- Kapitel 1 stellt grundlegende Konzepte und Anwendungen maschinellen Lernens vor und beschreibt die im gesamten Buch verwendete Arbeitsumgebung.
- Die Kapitel 2 und 3 beschreiben die am häufigsten in der Praxis verwendeten Algorithmen zum maschinellen Lernen und besprechen deren Stärken und Schwachstellen.
- Kapitel 4 diskutiert, warum die Repräsentation der von maschinellem Lernen verarbeiteten Daten wichtig ist und welche Aspekte der Daten man beachten sollte.
- Kapitel 5 befasst sich mit fortgeschrittenen Methoden zum Auswerten von Modellen und zur Optimierung von Parametern. Dabei liegt besonderes Augenmerk auf Kreuzvalidierung und Gittersuche.
- Kapitel 6 erklärt die Verwendung von Pipelines zum Verketteten von Modellen und zur Kapselung von Arbeitsabläufen.

- Kapitel 7 zeigt, wie Sie die in den ersten Kapiteln beschriebenen Methoden auf Textdaten anwenden können, und macht Sie mit einigen speziellen Techniken zur Verarbeitung von Textdaten bekannt.
- Kapitel 8 gibt einen allgemeinen Überblick und verweist auf fortgeschrittene Themen.

Die eigentlichen Algorithmen werden in den Kapiteln 2 und 3 vorgestellt, auch wenn das Verständnis all dieser Algorithmen für einen Anfänger nicht unbedingt erforderlich ist. Wenn Sie ein maschinelles Lernsystem so schnell wie möglich konstruieren müssen, empfehlen wir Ihnen, mit Kapitel 1 und den ersten Abschnitten von Kapitel 2 zu beginnen, in denen die wichtigsten Begriffe vorgestellt werden. Sie können dann direkt zu Abschnitt »Zusammenfassung und Ausblick« auf Seite 120 in Kapitel 2 springen, wo Sie eine Liste aller besprochenen überwachten Modelle finden. Wählen Sie das für Ihre Zwecke am besten geeignete Modell aus und blättern Sie dann zum entsprechenden Abschnitt, der sich mit den Details auseinandersetzt. Danach können Sie die Techniken in Kapitel 5 anwenden, um Ihr Modell zu evaluieren und zu optimieren.

Ressourcen im Netz

Beim Studium dieses Buches sollten Sie unbedingt die Webseite von scikit-learn (<http://scikit-learn.org>) besuchen, um die detaillierte Dokumentation der Klassen und Funktionen zu sichten und weitere Beispiele zu finden. Es gibt auch einen Videokurs von Andreas Müller, »Advanced Machine Learning with scikit-learn,« der dieses Buch begleitet. Sie können diesen auf http://bit.ly/advanced_machine_learning_scikit-learn finden.

In diesem Buch verwendete Konventionen

Die folgenden typografischen Konventionen werden in diesem Buch verwendet:

Kursiv

Kennzeichnet sprachliche Hervorhebungen, neue Begriffe, URLs, E-Mail-Adressen, Dateinamen und Dateiendungen.

Feste Zeichenbreite

Wird für Programmlistings und für Programmelemente wie Namen von Variablen, Funktionen, Datenbanken, Datentypen, Umgebungsvariablen, Anweisungen und Schlüsselwörter verwendet. Auch Befehle sowie Namen von Modulen und Paketen verwenden diese Notation.

Konstante Zeichenbreite, fett

Kennzeichnet Befehle oder anderen Text, den der Nutzer wörtlich eingeben sollte.

Konstante Zeichenbreite, kursiv

Kennzeichnet Text, den der Nutzer je nach Kontext durch entsprechende Werte ersetzen sollte.



Dieses Zeichen steht für einen Tipp oder eine Empfehlung.



Dieses Zeichen steht für einen allgemeinen Hinweis.



Dieses Piktogramm steht für eine Warnung oder erhöhte Aufmerksamkeit.

Verwenden von Codebeispielen

Zusätzliche Materialien (Codebeispiele, IPython Notebooks usw.) stehen unter https://github.com/amueller/introduction_to_ml_with_python zum Download bereit.

Dieses Buch ist dazu da, Ihnen bei Ihren Aufgaben zu helfen. Im Allgemeinen dürfen Sie die mit diesem Buch bereitgestellten Codebeispiele in Ihren Programmen und der dazugehörigen Dokumentation nutzen. Sie müssen uns dazu nicht um Erlaubnis fragen, es sei denn, Sie reproduzieren einen signifikanten Teil des Codes. Beispielsweise benötigen Sie keine Erlaubnis, um ein Programm zu schreiben, das mehrere Codeabschnitte aus diesem Buch enthält. Eine CD-ROM mit Beispielen aus Büchern von O'Reilly zu verkaufen oder zu verteilen, benötigt dagegen eine Erlaubnis. Eine Frage mit einem Zitat aus diesem Buch unter Angabe eines Codebeispiels zu beantworten, benötigt keine Erlaubnis. Einen wesentlichen Anteil der Codebeispiele aus diesem Buch in Ihr eigenes Buch zu integrieren, benötigt dagegen eine Erlaubnis.

Wir freuen uns über Zitate, verlangen diese aber nicht. Ein Zitat enthält Titel, Autor, Verlag und ISBN. Beispiel: »*Einführung in Machine Learning mit Python* von Andreas C. Müller and Sarah Guido, O'Reilly 2017, ISBN 978-3-96009-049-6.«

Wenn Sie glauben, dass Ihre Verwendung von Codebeispielen über gewöhnliche Nutzung hinausgeht oder außerhalb der oben vorgestellten Nutzungsbedingungen liegt, kontaktieren Sie uns bitte unter kommentar@oreilly.de.

Danksagungen

Von Andreas

Ohne die Hilfe und Unterstützung einer großen Gruppe von Menschen wäre dieses Buch nie entstanden.

Ich möchte den Lektoren Meghan Blanchette, Brian MacDonald und besonders Dawn Schanafelt dafür danken, dass sie Sarah und mir bei der Verwirklichung dieses Buches geholfen haben.

Ich möchte meinen Reviewern Thomas Caswell, Olivier Grisel, Stefan van der Walt und John Myles White danken, die sich die Zeit zum Lesen früher Versionen des Buches genommen und mir wertvolles Feedback gegeben haben – und außerdem zu den Eckpfeilern im wissenschaftlichen Open Source-Ökosystem gehören.

Ich bin der herzlichen wissenschaftlichen Open Source Python-Community auf ewig dankbar, besonders den Mitwirkenden an scikit-learn. Ohne die Unterstützung und Hilfe dieser Gemeinde, insbesondere von Gael Varoquaux, Alex Gramfort und Olivier Grisel, wäre ich niemals ein Kernentwickler von scikit-learn geworden oder hätte dieses Paket nie so durchgehend verstanden wie heute. Ich danke auch allen anderen Mitwirkenden, die ihre Zeit in die Verbesserung und Pflege dieses Pakets investieren.

Ich bin außerdem für die vielen Diskussionen mit zahlreichen meiner Kollegen dankbar, durch die ich die Herausforderungen beim maschinellen Lernen verstehen und Ideen für die Struktur eines Grundlagenbuches sammeln konnte. Unter den Leuten, mit denen ich mich über Machine Learning unterhalten habe, möchte ich Brian McFee, Daniela Huttenkoppen, Joel Nothman, Gilles Louppe, Hugo Bowne-Anderson, Sven Kreis, Alice Zheng, Kyunghyun Cho, Pablo Baberas und Dan Cervone besonders danken.

Ich danke auch Rachel Rakov, die eine unermüdliche Betatesterin und Korrekturleserin der frühen Versionen dieses Buches war und mir bei der Ausarbeitung auf vielerlei Weise geholfen hat.

Danken möchte ich meinen Eltern, Harald und Margot, und meiner Schwester Miriam für ihre anhaltende Unterstützung und Ermutigung. Ich möchte auch den vielen Menschen in meinem Leben danken, deren Liebe und Freundschaft mir die Kraft und den Beistand für dieses fordernde Unterfangen gaben.

Von Sarah

Ich möchte Meg Blanchette danken, ohne deren Hilfe und Beistand dieses Projekt nicht einmal existieren würde. Ich danke Celia La und Brian Carlson für das Lesen der frühen Entwürfe. Ich danke den Leuten von O'Reilly für ihre unendliche Geduld. Schließlich danke ich DTS für deine ewige und endlose Unterstützung.

Einführung

Beim Machine Learning geht es darum, Wissen aus Daten zu extrahieren. Es handelt sich dabei um ein Forschungsfeld in der Schnittmenge von Statistik, künstlicher Intelligenz und Informatik und ist ebenfalls als prädiktive Analytik oder statistisches Lernen bekannt. Die Anwendung von Methoden maschinellen Lernens sind in den letzten Jahren Teil unseres Alltags geworden. Von automatischen Empfehlungen für Filme, Nahrungsmittel oder andere Produkte über personalisiertes Online-Radio bis zur Erkennung von Freunden in Ihren Fotos enthalten viele moderne Webseiten und Geräte als Herzstück Algorithmen für maschinelles Lernen. Wenn Sie sich eine komplexe Webseite wie Facebook, Amazon oder Netflix ansehen, ist es sehr wahrscheinlich, dass jeder Teil der Seite mehrere maschinelle Lernmodelle enthält.

Außerhalb kommerzieller Anwendungen hat Machine Learning einen immensen Einfluss auf die heutige Methodik datengetriebener Forschung gehabt. Die in diesem Buch vorgestellten Werkzeuge sind auf so unterschiedliche wissenschaftliche Fragestellungen angewandt worden wie das Verstehen von Sternen, das Finden weit entfernter Planeten, das Entdecken neuer Elementarteilchen, die Analyse von DNA-Sequenzen und die personalisierte Krebsbehandlung.

Um von maschinellem Lernen zu profitieren, muss Ihre Anwendung dabei gar nicht so gewaltig oder weltverändernd sein wie diese Beispiele. In diesem Kapitel werden wir erklären, warum Machine Learning so beliebt geworden ist, und werden erörtern, was für Fragestellungen damit beantwortet werden können. Anschließend werden wir Ihnen zeigen, wie Sie Ihr erstes Modell mithilfe von maschinellem Lernen bauen können, und dabei wichtige Begriffe vorstellen.

Warum Machine Learning?

In den ersten Tagen »intelligenter« Anwendungen verwendeten viele Systeme von Hand kodierte Regeln in Form von »if/else«-Entscheidungen, um Daten zu verarbeiten oder Benutzereingaben anzupassen. Stellen Sie sich einen Spam-Filter vor,

dessen Aufgabe es ist, eingehende Nachrichten in den Spam-Ordner zu verschieben. Sie könnten eine schwarze Liste von Wörtern erstellen, die zum Einstufen einer E-Mail als Spam führen. Dies ist ein Beispiel für ein von Experten entwickeltes Regelsystem als »intelligente« Anwendung. Bei manchen Anwendungen ist das Festlegen von Regeln von Hand praktikabel, besonders wenn Menschen ein gutes Verständnis für den zu modellierenden Prozess besitzen. Allerdings hat das Verwenden von Hand erstellter Regeln zwei große Nachteile:

- Die Entscheidungslogik ist für ein bestimmtes Fachgebiet und eine Aufgabe spezifisch. Selbst eine kleine Veränderung der Aufgabe kann dazu führen, dass das gesamte System neu geschrieben werden muss.
- Das Entwickeln von Regeln erfordert ein tiefes Verständnis davon, wie ein menschlicher Experte diese Entscheidung treffen würde.

Ein Beispiel, bei dem der händische Ansatz fehlschlägt, ist das Erkennen von Gesichtern in Bildern. Heutzutage kann jedes Smartphone ein Gesicht in einem Bild erkennen. Allerdings war Gesichtserkennung bis 2001 ein ungelöstes Problem. Das Hauptproblem dabei war, dass ein Computer die Pixel (aus denen ein Computerbild besteht) im Vergleich zu Menschen auf sehr unterschiedliche Weise »wahrnimmt«. Diese unterschiedliche Repräsentation macht es einem Menschen praktisch unmöglich, ein gutes Regelwerk zu entwickeln, mit dem sich umschreiben lässt, was ein Gesicht in einem digitalen Bild ausmacht. Mit maschinellem Lernen ist es dagegen ausreichend, einem Programm eine große Sammlung von Bildern mit Gesichtern vorzulegen, um die Charakteristiken zum Erkennen von Gesichtern auszuarbeiten.

Welche Probleme kann Machine Learning lösen?

Die erfolgreichsten Arten maschineller Lernalgorithmen sind diejenigen, die den Entscheidungsprozess durch Verallgemeinerung aus bekannten Beispielen automatisieren. In diesem als *überwachtes Lernen* bekannten Szenario beliefert der Nutzer einen Algorithmus mit Paaren von Eingabewerten und erwünschten Ausgabewerten, und der Algorithmus findet heraus, wie sich die gewünschte Ausgabe erstellen lässt. Damit ist der Algorithmus ohne menschliche Hilfe in der Lage, aus zuvor unbekanntem Eingaben eine Ausgabe zu berechnen. Bei unserem Beispiel der Spam-Klassifizierung würde der Nutzer dem Algorithmus eine große Anzahl E-Mails (die Eingaben) sowie die Angabe, welche dieser E-Mails Spam sind (die erwünschte Ausgabe), zur Verfügung stellen. Für eine neue E-Mail kann der Algorithmus dann vorhersagen, ob die neue E-Mail Spam ist.

Maschinelle Lernalgorithmen, die aus Eingabe-Ausgabe-Paaren lernen, bezeichnet man als überwachte Lernalgorithmen, weil ein »Lehrer« den Algorithmus in Form der erwünschten Ausgaben für jedes Lernbeispiel anleitet. Obwohl das Erstellen eines Datensatzes geeigneter Ein- und Ausgaben oft mühevoll Handarbeit bedeu-

tet, sind überwachte Lernalgorithmen gut verständlich, und ihre Leistung ist leicht messbar. Wenn Ihre Anwendung sich als überwachte Lernaufgabe formulieren lässt und Sie einen Datensatz mit den gewünschten Ergebnissen erstellen können, lässt sich Ihre Fragestellung vermutlich durch Machine Learning beantworten.

Beispiele für überwachtes maschinelles Lernen sind:

Auf einem Briefumschlag die Postleitzahl aus handschriftlichen Ziffern zu erkennen

Hier besteht die Eingabe aus der eingescannten Handschrift, und die gewünschte Ausgabe sind die Ziffern der Postleitzahl. Um einen Datensatz zum Erstellen eines maschinellen Lernmodells zu erzeugen, müssen Sie zuerst viele Umschläge sammeln. Dann können Sie die Postleitzahlen selbst lesen und die Ziffern als gewünschtes Ergebnis abspeichern.

Anhand eines medizinischen Bildes entscheiden, ob ein Tumor gutartig ist

Hierbei ist die Eingabe das Bild, und die Ausgabe, ob der Tumor gutartig ist. Um einen Datensatz zum Erstellen eines Modells aufzubauen, benötigen Sie eine Datenbank mit medizinischen Bildern. Sie benötigen auch eine Expertenmeinung, es muss sich also ein Arzt sämtliche Bilder ansehen und entscheiden, welche Tumore gutartig sind und welche nicht. Es ist sogar möglich, dass zur Entscheidung, ob der Tumor im Bild krebsartig ist oder nicht, zusätzlich zum Bild weitere Diagnosen nötig sind.

Erkennen betrügerischer Aktivitäten bei Kreditkartentransaktionen

Hierbei sind die Eingaben Aufzeichnungen von Kreditkartentransaktionen, und die Ausgabe ist, ob diese vermutlich betrügerisch sind oder nicht. Wenn Ihre Organisation Kreditkarten ausgibt, müssen Sie sämtliche Transaktionen aufzeichnen und ob ein Nutzer betrügerische Transaktionen meldet.

Bei diesen Beispielen sollte man hervorheben, dass das Sammeln der Daten bei diesen Aufgaben grundsätzlich unterschiedlich ist, auch wenn die Ein- und Ausgabedaten sehr klar wirken. Das Lesen von Umschlägen ist zwar mühevoll, aber auch unkompliziert. Medizinische Bilder und Diagnosen zu sammeln, erfordert dagegen nicht nur teure Geräte, sondern auch seltenes und teures Expertenwissen, von den ethischen und datenschutztechnischen Bedenken einmal abgesehen. Beim Erkennen von Kreditkartenbetrug ist das Sammeln der Daten deutlich einfacher. Ihre Kunden werden Sie mit den nötigen Ausgabedaten versorgen. Um die Ein-/Ausgabedaten für betrügerische und ehrliche Aktivitäten zu erhalten, müssen Sie nichts anderes tun, als zu warten.

Unüberwachte Algorithmen

sind eine weitere Art in diesem Buch behandelte Algorithmen. Beim unüberwachten Lernen sind nur die Eingabedaten bekannt, und dem Algorithmus werden keine bekannten Ausgabedaten zur Verfügung gestellt. Es sind viele erfolgreiche Anwendungen dieser Methoden bekannt, sie sind aber in der Regel schwieriger zu verstehen und auszuwerten.

Beispiele für unüberwachtes Lernen sind:

Themen in einer Serie von Blogeinträgen erkennen

Sie haben eine große Menge Textdaten und möchten diese zusammenfassen und die darin vorherrschenden Themen herausfinden. Wenn Sie nicht im Voraus wissen, welches diese Themen sind oder wie viele Themen es gibt, so gibt es keine bekannte Ausgabe.

Kunden in Gruppen mit ähnlichen Vorlieben einteilen

Mit einem Satz Kundendaten könnten Sie ähnliche Kunden erkennen und herausfinden, ob es Kundengruppen mit ähnlichen Vorlieben gibt. Bei einem Online-Geschäft könnten diese »Eltern«, »Bücherwürmer« oder »Spieler« sein. Weil diese Gruppen nicht im Voraus bekannt sind, oft nicht einmal deren Anzahl, haben Sie keine bekannte Ausgabe.

Erkennung außergewöhnlicher Zugriffsmuster auf eine Webseite

Um unrechtmäßige Nutzung oder Fehler zu erkennen, ist es oft hilfreich, Zugriffe zu finden, die sich von der Durchschnittsnutzung abheben. Jedes außergewöhnliche Muster kann sehr unterschiedlich sein, und Sie haben womöglich keinerlei Aufzeichnungen über abnorme Nutzung. Weil Sie in diesem Fall die Zugriffe einer Webseite beobachten und nicht wissen, was normale Nutzung ist und was nicht, handelt es sich hier um eine unüberwachte Fragestellung.

Sowohl bei überwachten als auch bei unüberwachten Lernaufgaben ist es wichtig, eine für den Computer verständliche Repräsentation Ihrer Eingabedaten zu haben. Oft hilft es, sich die Daten als Tabelle vorzustellen. Jeder zu untersuchende Datenpunkt (jede E-Mail, jeder Kunde, jede Transaktion) ist eine Zeile, und jede Eigenschaft, die diesen Datenpunkt beschreibt (z. B. das Alter eines Kunden oder die Menge oder der Ort der Transaktion), ist eine Spalte. Sie können Nutzer durch Alter, Geschlecht, das Datum der Registrierung und wie oft sie in Ihrem Online-Geschäft eingekauft haben, charakterisieren. Das Bild eines Tumors lässt sich durch die Graustufenwerte jedes Pixels beschreiben oder aber durch Größe, Gestalt und Farbe des Tumors.

Jede Entität oder Zeile bezeichnet man beim maschinellen Lernen als *Datenpunkt* (oder Probe), die Spalten – also die Eigenschaften, die diese Entitäten beschreiben werden – nennt man *Merkmale*.

Im weiteren Verlauf dieses Buches werden wir uns genauer mit dem Aufbau einer guten Datenrepräsentation beschäftigen, was man als *Extrahieren von Merkmalen* oder *Merkmalsgenerierung* bezeichnet. Sie sollten auf jeden Fall bedenken, dass kein maschinelles Lernverfahren ohne entsprechende Information zu Vorhersagen in der Lage ist. Wenn zum Beispiel das einzige bekannte Merkmal eines Patienten der Nachname ist, wird kein Algorithmus in der Lage sein, das Geschlecht vorherzusagen. Diese Information ist schlicht nicht in Ihren Daten enthalten. Wenn Sie

ein weiteres Merkmal mit dem Vornamen des Patienten hinzufügen, haben Sie mehr Glück, da sich das Geschlecht häufig aus dem Vornamen vorhersagen lässt.

Ihre Aufgabe und Ihre Daten kennen

Der möglicherweise wichtigste Teil beim maschinellen Lernen ist, dass Sie Ihre Daten verstehen und wie diese mit der zu lösenden Aufgabe zusammenhängen. Es ist nicht sinnvoll, zufällig einen Algorithmus auszuwählen und Ihre Daten hineinzuwerfen. Bevor Sie ein Modell konstruieren können, ist es notwendig, zu verstehen, was in Ihrem Datensatz vorgeht. Jeder Algorithmus unterscheidet sich darin, bei welchen Daten und welchen Aufgabenstellungen er am besten funktioniert. Wenn Sie eine Aufgabe mit maschinellem Lernen bearbeiten, sollten Sie folgende Fragen beantworten oder zumindest im Hinterkopf behalten:

- Welche Fragen versuche ich zu beantworten? Glaube ich, dass die erhobenen Daten diese Frage beantworten können?
- Wie lässt sich meine Frage am besten als maschinelle Lernaufgabe ausdrücken?
- Habe ich genug Daten gesammelt, um die zu beantwortende Fragestellung zu repräsentieren?
- Welche Merkmale der Daten habe ich extrahiert? Sind diese zu den richtigen Vorhersagen in der Lage?
- Wie messe ich, ob meine Anwendung erfolgreich ist?
- Wie interagiert mein maschinelles Lernmodell mit anderen Teilen meiner Forschungsarbeit oder meines Produkts?

In einem breiteren Kontext sind die Algorithmen und Methoden für maschinelles Lernen nur Teil eines größeren Prozesses zum Lösen einer bestimmten Aufgabe. Es ist sinnvoll, das große Ganze stets im Blick zu behalten. Viele Leute investieren eine Menge Zeit in das Entwickeln eines komplexen maschinellen Lernsystems, nur um hinterher herauszufinden, dass sie das falsche Problem gelöst haben.

Wenn man sich eingehend mit den technischen Aspekten maschinellen Lernens beschäftigt (wie wir es in diesem Buch tun werden), ist es leicht, die endgültigen Ziele aus den Augen zu verlieren. Wir werden die hier gestellten Fragen nicht im Detail diskutieren, halten Sie aber dazu an, sämtliche explizit oder implizit getroffenen Annahmen beim Aufbau maschineller Lernmodelle zu berücksichtigen.

Warum Python?

Python ist für viele Anwendungen aus dem Bereich Data Science die lingua franca geworden. Python kombiniert die Ausdruckskraft allgemein nutzbarer Programmiersprachen mit der einfachen Benutzbarkeit einer domänenspezifischen Skript-

sprache wie MATLAB oder R. Für Python gibt es Bibliotheken zum Laden von Daten, Visualisieren, Berechnen von Statistiken, Sprachverarbeitung, Bildverarbeitung usw. Dies gibt Data Scientists einen sehr umfangreichen Werkzeugkasten mit Funktionalität für allgemeine und besondere Einsatzgebiete. Einer der Hauptvorteile von Python ist die Möglichkeit, direkt mit dem Code zu interagieren, sei es in einer Konsole oder einer anderen Umgebung wie dem Jupyter Notebook, das wir uns in Kürze ansehen werden. Machine Learning und Datenanalyse sind von Grund auf iterative Prozesse, bei denen die Daten die Analyse bestimmen. Es ist entscheidend, diese Prozesse mit Werkzeugen zu unterstützen, die schnelle Iterationen und leichte Benutzbarkeit ermöglichen.

Als allgemein einsetzbare Programmiersprache lassen sich mit Python auch komplexe grafische Benutzeroberflächen (GUIs) und Webdienste entwickeln und in bestehende Systeme integrieren.

scikit-learn

scikit-learn ist ein Open Source-Projekt, Sie dürfen es also kostenlos verwenden und verbreiten. Jeder kommt leicht an die Quelltexte heran und kann sehen, was hinter den Kulissen passiert. Das scikit-learn-Projekt wird kontinuierlich weiterentwickelt und verbessert und besitzt eine große Nutzergemeinde. Es enthält eine Anzahl hochentwickelter maschineller Lernalgorithmen und eine umfangreiche Dokumentation (<http://scikit-learn.org/stable/documentation>) zu jedem Algorithmus. scikit-learn ist sehr beliebt, und die Nummer Eins der Python-Bibliotheken für Machine Learning. Es wird in Wirtschaft und Forschung eingesetzt, und im Netz existieren zahlreiche Tutorials und Codebeispiele. scikit-learn arbeitet eng mit einigen weiteren wissenschaftlichen Python-Werkzeugen zusammen, die wir im Verlauf dieses Kapitels kennenlernen werden.

Wir empfehlen, dass Sie beim Lesen dieses Buches auch den User Guide (http://scikit-learn.org/stable/user_guide.html) und die Dokumentation der API von scikit-learn lesen, um zusätzliche Details und weitere Optionen zu jedem Algorithmus kennenzulernen. Die Online-Dokumentation ist sehr ausführlich, und dieses Buch liefert Ihnen die Grundlagen in maschinellem Lernen, um es im Detail zu verstehen.

Installieren von scikit-learn

scikit-learn benötigt zwei weitere Python-Pakete, *NumPy* und *SciPy*. Zum Plotten und zur interaktiven Entwicklung sollten Sie außerdem *matplotlib*, *IPython* und *Jupyter Notebook* installieren. Wir empfehlen Ihnen, eine der folgenden Python-Distributionen zu verwenden, in denen die notwendigen Pakete bereits enthalten sind:

Anaconda (<https://store.continuum.io/cshop/anaconda/>)

Eine Python-Distribution für Datenverarbeitung in großem Stil, vorhersagende Analyse und wissenschaftliche Berechnungen. Anaconda enthält NumPy, SciPy, matplotlib, pandas, IPython, Jupyter Notebook und scikit-learn. Dies ist eine sehr bequeme Lösung unter Mac OS, Windows und Linux, und wir empfehlen sie Anwendern ohne bestehende Installation einer wissenschaftlichen Python-Umgebung. Anaconda enthält inzwischen auch eine kostenlose Ausgabe der Bibliothek *Intel MKL*. Das Verwenden von MKL (was bei Installation von Anaconda automatisch geschieht) führt zu deutlichen Geschwindigkeitsverbesserungen bei vielen der Algorithmen in scikit-learn.

Enthought Canopy (<https://www.enthought.com/products/canopy/>)

Eine weitere Python-Distribution für wissenschaftliches Arbeiten. Diese enthält NumPy, SciPy, matplotlib, pandas und IPython, aber in der kostenlosen Version ist scikit-learn nicht enthalten. Wenn Ihre Institution akademische Abschlüsse vergibt, können Sie eine akademische Lizenz beantragen und freien Zugang zu einem Abonnement von Enthought Canopy erhalten. Enthought Canopy ist für Python 2.7.x verfügbar und läuft auf Mac OS, Windows und Linux.

Python(x,y) (<http://python-xy.github.io/>)

Eine freie Python-Distribution für wissenschaftliches Arbeiten, insbesondere unter Windows. Python(x,y) enthält NumPy, SciPy, matplotlib, pandas, IPython und scikit-learn.

Wenn Sie bereits eine Python-Installation haben, können Sie die folgenden Pakete mit pip installieren:

```
$ pip install numpy scipy matplotlib ipython scikit-learn pandas
```

Grundlegende Bibliotheken und Werkzeuge

Es ist wichtig zu verstehen, was scikit-learn ist und wie es funktioniert. Es gibt jedoch einige weitere Bibliotheken, die Ihre Produktivität verbessern werden. scikit-learn basiert auf den Python-Bibliotheken NumPy und SciPy. Außer NumPy und SciPy werden wir auch pandas und matplotlib verwenden. Außerdem werden wir Jupyter Notebook, eine browsergestützte interaktive Programmierumgebung, kennenlernen. Kurz gesagt, sollten Sie etwas über folgende Hilfsmittel wissen, um das Beste aus scikit-learn herauszuholen.¹

¹ Wenn Sie sich mit NumPy oder matplotlib gar nicht auskennen, empfehlen wir Ihnen die Lektüre des ersten Kapitels der SciPy Lecture Notes (<http://www.scipy-lectures.org/>).

Jupyter Notebook

Das Jupyter Notebook ist eine interaktive Umgebung, um Code über den Browser auszuführen. Es ist ein großartiges Werkzeug zur erkundenden Datenanalyse und wird von Data Scientists in großem Stil eingesetzt. Obwohl das Jupyter Notebook viele Programmiersprachen unterstützt, benötigen wir nur die Python-Unterstützung. In einem Jupyter Notebook können Sie leicht Code, Texte und Bilder einbinden. Dieses gesamte Buch wurde als Jupyter Notebook geschrieben. Sie können sich sämtliche enthaltenen Codebeispiele von GitHub (https://github.com/amueller/introduction_to_ml_with_python) herunterladen.

NumPy

NumPy ist eines der grundlegenden Pakete für wissenschaftliche Berechnungen in Python. Es enthält die Funktionalität für mehrdimensionale Arrays, mathematische Funktionen wie lineare Algebra und Fourier-Transformationen sowie Generatoren für Pseudozufallszahlen.

In `scikit-learn` ist das NumPy-Array die fundamentale Datenstruktur. `scikit-learn` verarbeitet Daten in Form von NumPy-Arrays. Jegliche Daten, die Sie verwenden, müssen in ein NumPy-Array umgewandelt werden. Der wichtigste Bestandteil von NumPy ist die Klasse `ndarray`, ein mehrdimensionales (n -dimensionales) Array. Sämtliche Elemente eines Arrays müssen vom gleichen Typ sein. Ein NumPy-Array sieht folgendermaßen aus:

In[1]:

```
import numpy as np

x = np.array([[1, 2, 3], [4, 5, 6]])
print("x:\n{}".format(x))
```

Out[1]:

```
x:
[[1 2 3]
 [4 5 6]]
```

Wir werden NumPy in diesem Buch sehr viel verwenden und die Objekte der Klasse `ndarray` als »NumPy-Arrays« oder einfach »Arrays« bezeichnen.

SciPy

SciPy ist eine Sammlung von Funktionen zum wissenschaftlichen Rechnen in Python. Sie enthält unter anderem Routinen für fortgeschrittene lineare Algebra, Optimierung mathematischer Funktionen, Signalverarbeitung, spezielle mathematische Funktionen und statistische Verteilungen. `scikit-learn` bedient sich aus dem Funktionspool in SciPy, um seine Algorithmen zu implementieren. Der für uns wichtigste Bestandteil von SciPy ist `scipy.sparse`: Dieser stellt *dünn besetzte Matrizen*

zen zur Verfügung, eine weitere Datenrepräsentation in scikit-learn. Dünn besetzte Matrizen werden immer dann eingesetzt, wenn ein 2-D-Array zum größten Teil aus Nullen besteht:

In[2]:

```
from scipy import sparse

# Erstelle ein 2-D NumPy Array mit einer Diagonale aus Einsen und sonst Nullen
eye = np.eye(4)
print("NumPy Array:\n{}".format(eye))
```

Out[2]:

```
NumPy Array:
[[ 1.  0.  0.  0.]
 [ 0.  1.  0.  0.]
 [ 0.  0.  1.  0.]
 [ 0.  0.  0.  1.]]
```

In[3]:

```
# Wandle das NumPy Array in eine SciPy sparse matrix im CSR-Format um
# Nur die Einträge ungleich null werden gespeichert
sparse_matrix = sparse.csr_matrix(eye)
print("\nSciPy sparse CSR matrix:\n{}".format(sparse_matrix))
```

Out[3]:

```
SciPy sparse CSR matrix:
(0, 0) 1.0
(1, 1) 1.0
(2, 2) 1.0
(3, 3) 1.0
```

Normalerweise ist es nicht möglich, eine dichte Repräsentation einer dünn besetzten Matrix zu erzeugen (sie würde nämlich nicht in den Speicher passen), daher müssen wir die dünn besetzte Matrix direkt erzeugen. Hier ist eine Möglichkeit, die gleiche sparse matrix wie oben im COO-Format zu erstellen:

In[4]:

```
data = np.ones(4)
row_indices = np.arange(4)
col_indices = np.arange(4)
eye_coo = sparse.coo_matrix((data, (row_indices, col_indices)))
print("COO-Repräsentation:\n{}".format(eye_coo))
```

Out[4]:

```
COO-Repräsentation:
(0, 0) 1.0
(1, 1) 1.0
(2, 2) 1.0
(3, 3) 1.0
```

Weitere Details zu dünn besetzten Matrizen in SciPy finden Sie in den SciPy Lecture Notes (<http://www.scipy-lectures.org/>).

matplotlib

matplotlib ist die wichtigste Python-Bibliothek zum wissenschaftlichen Plotten. Sie enthält Funktionen zum Erstellen von Diagrammen in Publikationsqualität, z. B. Liniendiagramme, Histogramme, Streudiagramme usw. Ihre Daten und unterschiedliche Aspekte Ihrer Daten zu visualisieren, liefert wichtige Erkenntnisse, und wir werden matplotlib für sämtliche Visualisierungsaufgaben einsetzen. Wenn Sie mit einem Jupyter Notebook arbeiten, können Sie Diagramme über die Befehle `%matplotlib notebook` und `%matplotlib inline` direkt im Browser darstellen. Wir empfehlen Ihnen `%matplotlib notebook`, wodurch Sie eine interaktive Umgebung erhalten (obwohl wir zur Produktion dieses Buches `%matplotlib inline` eingesetzt haben). Zum Beispiel erstellt der folgende Code das Diagramm in Abbildung 1-1:

In[5]:

```
%matplotlib inline
import matplotlib.pyplot as plt

# Erstelle eine Zahlenfolge von -10 bis 10 mit 100 Zwischenschritten
x = np.linspace(-10, 10, 100)
# Erstelle ein zweites Array mit einer Sinusfunktion
y = np.sin(x)
# Die Funktion plot zeichnet ein Liniendiagramm eines Arrays über dem anderen
plt.plot(x, y, marker="x")
```

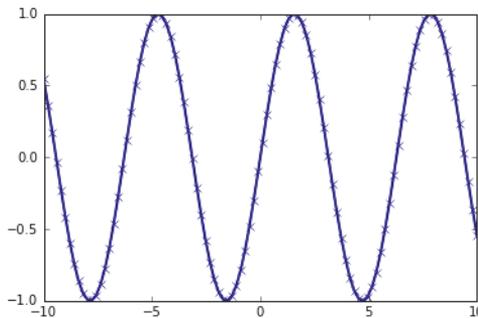


Abbildung 1-1: Mit matplotlib erstelltes Liniendiagramm einer Sinusfunktion

pandas

pandas ist eine Python-Bibliothek zur Datenaufbereitung und Analyse. Sie ist um eine Datenstruktur namens DataFrame herum aufgebaut, die dem DataFrame in R nachempfunden ist. Einfach gesagt, ist ein pandas DataFrame eine Tabelle, einem Excel-Tabellenblatt nicht unähnlich. pandas enthält eine große Bandbreite an Methoden zum Modifizieren und Verarbeiten dieser Tabellen; insbesondere sind SQL-artige Suchanfragen und Verbindungsoperationen möglich. Im Gegensatz zu NumPy, bei dem sämtliche Einträge eines Arrays den gleichen Typ haben müssen, lässt pandas in jeder Spalte unterschiedliche Typen zu (z. B. Integer, Datum, Fließ-

kommazahl oder String). Ein weiteres wertvolles Werkzeug in pandas sind Einleseprozeduren für eine große Anzahl Dateiformate und Datenbanken wie SQL, Excel-Dateien und kommaseparierte Dateien (CSV). Wir werden in diesem Buch die Funktionalität von pandas nicht im Detail besprechen. Allerdings gibt das Buch *Datenanalyse mit Python* von Wes McKinney (O'Reilly 2015, ISBN 978-3-96009-000-7) eine großartige Einführung. Hier ist ein kleines Beispiel für das Erstellen eines DataFrames über ein Dictionary:

In[6]:

```
import pandas as pd

# erstelle einen einfachen Datensatz mit Personen
data = {'Name': ["John", "Anna", "Peter", "Linda"],
        'Location': ["New York", "Paris", "Berlin", "London"],
        'Age': [24, 13, 53, 33]
        }

data_pandas = pd.DataFrame(data)
# IPython.display erlaubt das "pretty printing" von Data Frames
# im Jupyter Notebook
display(data_pandas)
```

Dadurch erhalten wir folgende Ausgabe:

	Age	Location	Name
0	24	New York	John
1	13	Paris	Anna
2	53	Berlin	Peter
3	33	London	Linda

Es gibt mehrere Möglichkeiten, Anfragen an diese Tabelle zu senden. Beispielsweise:

In[7]:

```
# Wähle alle Zeilen mit einem Wert für age größer 30 aus
display(data_pandas[data_pandas.Age > 30])
```

Dadurch erhalten wir folgendes Ergebnis:

	Age	Location	Name
2	53	Berlin	Peter
3	33	London	Linda

mglearn

Dieses Buch wird von Code begleitet, den Sie auf GitHub (https://github.com/amueller/introduction_to_ml_with_python) finden. Der begleitende Code enthält

nicht nur sämtliche Beispiele aus diesem Buch, sondern auch die Bibliothek `mglearn`. Dies ist eine Bibliothek von Hilfsfunktionen, die wir für dieses Buch geschrieben haben, um die Codebeispiele nicht mit Details zum Plotten und Laden von Daten zu verunstanen. Bei Interesse können Sie die Details sämtlicher Funktionen im Repository nachschlagen, aber die Details des Moduls `mglearn` sind für das Material in diesem Buch nicht wirklich wichtig. Wenn Sie einen Aufruf von `mglearn` im Code sehen, ist es normalerweise eine Möglichkeit, schnell ein ansprechendes Bild zu erzeugen oder interessante Daten in die Finger zu bekommen.



Im Verlauf dieses Buches werden wir ständig `NumPy`, `matplotlib` und `pandas` einsetzen. Alle Codebeispiele setzen die folgenden `import`-Befehle voraus:

```
import numpy as np
import matplotlib.pyplot as plt
import pandas as pd
import mglearn
from IPython import display
```

Wir gehen außerdem davon aus, dass Sie den Code in einem Jupyter Notebook unter Verwendung der Funktionen `%matplotlib notebook` oder `%matplotlib inline` zum Darstellen von Diagrammen ausführen. Wenn Sie kein Notebook oder keinen dieser Befehle verwenden, müssen Sie `plt.show` aufrufen, um die Diagramme zu sehen.

Python 2 versus Python 3

Es gibt zwei größere Versionen von Python, die im Moment weitverbreitet sind: Python 2 (genauer 2.7) und Python 3 (die gegenwärtig jüngste Version ist 3.5). Das sorgt bisweilen für Verwirrung. Python 2 wird nicht mehr weiterentwickelt, aber wegen tief greifender Änderungen in Python 3 läuft für Python 2 geschriebener Code meist nicht unter Python 3. Wenn Python für Sie neu ist oder Sie ein neues Projekt beginnen, empfehlen wir Ihnen wärmstens die neueste Version von Python 3. Wenn Sie von einer größeren Menge unter Python 2 geschriebenen Codes abhängig sind, sind Sie vorläufig von einem Upgrade entschuldigt. Sie sollten jedoch so bald wie möglich auf Python 3 umsteigen. Beim Schreiben neuer Programme ist es meist einfach, Code zu schreiben, der sowohl unter Python 2 als auch unter Python 3 läuft.² Wenn Sie sich nicht auf bestehende Software stützen müssen, sollten Sie definitiv Python 3 verwenden. Sämtliche Codebeispiele in diesem Buch funktionieren mit beiden Versionen. Allerdings kann sich die genaue Ausgabe unter Python 2 stellenweise von der unter Python 3 unterscheiden.

² Das Paket `six` (<https://pypi.python.org/pypi/six>) kann dabei sehr hilfreich sein.

In diesem Buch verwendete Versionen

Wir verwenden in diesem Buch die folgenden Versionen der oben erwähnten Bibliotheken:

In[8]:

```
import sys
print("Python Version: {}".format(sys.version))

import pandas as pd
print("pandas Version: {}".format(pd.__version__))

import matplotlib
print("matplotlib Version: {}".format(matplotlib.__version__))

import numpy as np
print("NumPy Version: {}".format(np.__version__))

import scipy as sp
print("SciPy Version: {}".format(sp.__version__))

import IPython
print("IPython Version: {}".format(IPython.__version__))

import sklearn
print("scikit-learn Version: {}".format(sklearn.__version__))
```

Out[8]:

```
Python Version: 3.5.2 |Anaconda 4.1.1 (64-bit)| (default, Jul  2 2016, 17:53:06)
[GCC 4.4.7 20120313 (Red Hat 4.4.7-1)]
pandas Version: 0.18.1
matplotlib Version: 1.5.1
NumPy Version: 1.11.1
SciPy Version: 0.17.1
IPython Version: 5.1.0
scikit-learn Version: 0.18
```

Auch wenn es nicht entscheidend ist, genau diese Versionen zu verwenden, sollten Sie eine Version von scikit-learn haben, die mindestens so neu ist wie unsere.

Nun haben wir alles eingerichtet und können in unsere erste Anwendung maschinellen Lernens starten.



Dieses Buch geht davon aus, dass Sie mindestens Version 0.18 von scikit-learn installiert haben. Das Modul `model_selection` wurde in 0.18 hinzugefügt, und wenn Sie eine frühere Version von scikit-learn verwenden, werden Sie die `import`-Anweisungen für dieses Modul anpassen müssen.

Eine erste Anwendung: Klassifizieren von Iris-Spezies

In diesem Abschnitt werden wir eine einfache Anwendung maschinellen Lernens durchgehen und unser erstes Modell erstellen. Dabei werden wir einige zentrale Konzepte und Begriffe kennenlernen.

Nehmen wir an, dass eine Hobbybotanikerin daran interessiert ist, die Spezies einiger gefundener Irisblüten zu unterscheiden. Sie hat einige Messdaten zu jeder Iris gesammelt: Länge und Breite der Kronblätter (petals) und Länge und Breite der Kelchblätter (sepals). Alle Längen sind in Zentimetern gemessen worden (siehe Abbildung 1-2).

Sie besitzt darüber hinaus die Messdaten einiger Irisblüten, die zuvor von einem professionellen Botaniker den Spezies *setosa*, *versicolor* und *virginica* zugeordnet wurden. Bei diesen Messungen kann sie sich sicher sein, welchen Spezies jede Iris zugeordnet wurde. Nehmen wir an, dies seien die einzigen Spezies, denen unsere Hobbybotanikerin in freier Wildbahn begegnet.

Unser Ziel ist es, ein maschinelles Lernmodell zu entwickeln, das anhand der Messdaten für Iris mit bekannter Spezies lernen kann, sodass wir die Spezies einer neuen Iris vorhersagen können.

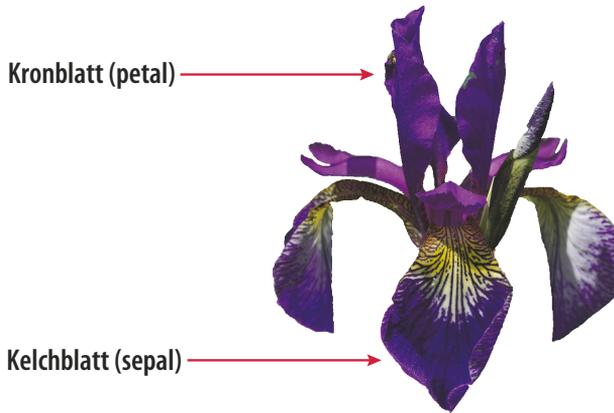


Abbildung 1-2: Teile der Irisblüte

Weil wir Messungen haben, für die wir die korrekte Iris-Spezies kennen, handelt es sich hier um eine überwachte Lernaufgabe. Bei dieser Aufgabe möchten wir eine von mehreren Möglichkeiten (die Iris-Spezies) vorhersagen. Dies ist ein Beispiel für eine *Klassifikationsaufgabe*. Die möglichen Ausgaben (unterschiedliche Iris-Spezies) nennt man *Kategorien*. Jede Iris im Datensatz gehört einer von drei Kategorien an, daher handelt es sich hier um eine Klassifikationsaufgabe mit drei Kategorien.

Für einen einzelnen Datenpunkt (eine Iris) ist die gewünschte Ausgabe die Spezies dieser Blüte. Man bezeichnet die einem bestimmten Datenpunkt zugehörige Spezies auch als *Label*.

Die Daten kennenlernen

Die Daten, die wir in diesem Beispiel verwenden werden, sind der Datensatz Iris, ein klassischer Datensatz aus dem maschinellen Lernen und der Statistik. Er ist in scikit-learn im Modul datasets enthalten. Wir können ihn durch Aufruf der Funktion `load_iris` laden:

In[9]:

```
from sklearn.datasets import load_iris
iris_dataset = load_iris()
```

Das von `load_iris` zurückgegebene Objekt `iris` ist ein Objekt vom Typ `Bunch`, das einem Dictionary sehr ähnlich ist. Es enthält Schlüssel und Werte:

In[10]:

```
print("Schlüssel von iris_dataset: {}".format(iris_dataset.keys()))
```

Out[10]:

```
Schlüssel von iris_dataset:
dict_keys(['target_names', 'feature_names', 'DESCR', 'data', 'target'])
```

Der Wert des Schlüssels `DESCR` ist eine kurze Beschreibung des Datensatzes. Wir führen hier den Anfang der Beschreibung auf (Sie können gerne den Rest selbst nachschlagen):

In[11]:

```
print(iris_dataset['DESCR'][:193] + "\n...")
```

Out[11]:

```
Iris Plants Database
=====
Notes
----
Data Set Characteristics:
    :Number of Instances: 150 (50 in each of three classes)
    :Number of Attributes: 4 numeric, predictive att
    ...
----
```

Der Wert des Schlüssels `target_names` ist ein Array aus Strings, die die Spezies der vorherzusagenden Blüten enthalten:

In[12]:

```
print("Zielbezeichnungen: {}".format(iris_dataset['target_names']))
```

Out[12]:

```
Zielbezeichnungen: ['setosa' 'versicolor' 'virginica']
```

Der Wert von `feature_names` ist eine Liste von Strings mit den Beschreibungen jedes Merkmals:

In[13]:

```
print("Namen der Merkmale: \n{}".format(iris_dataset['feature_names']))
```

Out[13]:

```
Namen der Merkmale:  
['sepal length (cm)', 'sepal width (cm)', 'petal length (cm)',  
 'petal width (cm)']
```

Die Daten selbst sind in den Feldern `target` und `data` enthalten. `data` enthält die Messwerte für Länge und Breite der Kelch- und Kronblätter als NumPy-Array:

In[14]:

```
print("Typ der Daten: {}".format(type(iris_dataset['data'])))
```

Out[14]:

```
Typ der Daten: <class 'numpy.ndarray'>
```

Die Zeilen im Array `data` entsprechen einzelnen Blüten, die Spalten entsprechen den vier für jede Blüte erhobenen Messwerten:

In[15]:

```
print("Abmessung der Daten: {}".format(iris_dataset['data'].shape))
```

Out[15]:

```
Abmessung der Daten: (150, 4)
```

Wir sehen, dass das Array Messungen von 150 unterschiedlichen Blüten enthält. Bedenken Sie, dass einzelne Datenpunkte beim maschinellen Lernen auch *Proben* genannt und ihre Eigenschaften als *Merkmale* bezeichnet werden. Die *Abmessungen* (shape) des Arrays `data` sind die Anzahl der Proben mit der Anzahl der Merkmale multipliziert. Dies ist eine Konvention in `scikit-learn`, und es wird stets angenommen, dass sich Ihre Daten in diesem Format befinden. Hier sind die Werte der Merkmale der ersten vier Datenpunkte:

In[16]:

```
print("Die ersten fünf Zeilen der Daten:\n{}".format(iris_dataset['data'][:5]))
```

Out[16]:

```
Die ersten fünf Zeilen der Daten:  
[[ 5.1  3.5  1.4  0.2]  
 [ 4.9  3.   1.4  0.2]  
 [ 4.7  3.2  1.3  0.2]  
 [ 4.6  3.1  1.5  0.2]  
 [ 5.   3.6  1.4  0.2]]
```

Aus diesen Daten können wir ersehen, dass die fünf ersten Blüten alle 0.2 cm breite Kronblätter haben und dass die erste Blüte mit 5.1 cm die längsten Kelchblätter hat.

Das Array `target` enthält die Spezies jeder vermessenen Blüte ebenfalls als NumPy-Array: