

# Inhalt

<b>Vorwort .....</b>	<b>XIII</b>
<b>Zusatzmaterial online .....</b>	<b>XIV</b>
<b>Teil I Einstieg.....</b>	<b>1</b>
<b>1 Einleitung.....</b>	<b>3</b>
1.1 Informatik und künstliche Intelligenz .....	3
1.2 Expertensysteme.....	4
1.3 Maschinelles Lernen .....	5
1.3.1 Überwachtes Lernen.....	7
1.3.2 Unüberwachtes Lernen .....	7
1.3.3 Verstärkendes Lernen.....	7
1.4 Methoden und Werkzeuge für das maschinelle Lernen .....	7
1.5 Zielsetzungen dieses Buchs und Vorgehensweise .....	9
<b>2 Einführung in R und RStudio .....</b>	<b>11</b>
2.1 Installation unter Windows .....	11
2.2 Installation unter Ubuntu Linux.....	12
2.3 Die RStudio-Oberfläche .....	15
2.3.1 Das Konsolenfenster .....	15
2.3.2 Das Source-Fenster .....	16
2.3.3 Das Files-/Packages-Fenster.....	18
2.3.3.1 Die Files-Registerkarte .....	18
2.3.3.2 Die Plot-Registerkarte .....	20
2.3.3.3 Die Packages-Registerkarte.....	20
2.3.3.4 Das Environment-Fenster .....	22
2.3.4 Daten einlesen und speichern .....	23

2.4	Zuweisungen, Variablen und elementare Datentypen .....	26
2.5	Zusammengesetzte Datentypen .....	27
2.5.1	Vektoren .....	27
2.5.1.1	Union, intersect, setdiff .....	29
2.5.1.2	Umwandeln des Datentyps, Faktorisierung .....	30
2.5.2	Matrizen .....	31
2.5.3	Frames .....	32
2.5.3.1	Hinzufügen von Spalten .....	32
2.5.3.2	Hinzufügen von Zeilen .....	33
2.5.3.3	Auswahl von Spalten .....	33
2.5.3.4	Auswahl von Zeilen und Spalten .....	33
2.5.3.5	Löschen von Spalten oder Zeilen .....	34
2.5.4	tibbles .....	34
2.5.5	Listen .....	35
2.5.6	Zeichenketten .....	36
2.5.7	Datum und Zeit .....	36
2.6	Programmablaufsteuerung .....	37
2.6.1	Blöcke .....	37
2.6.2	Bedingte Ausführung .....	37
2.6.3	Schleifen .....	38
2.6.4	Apply() .....	38
2.6.5	Gefahren und Benachrichtigungen .....	39
2.6.6	Funktionen .....	39
2.6.7	Der Pipe-Operator .....	41
2.7	Debugging .....	41
2.8	Programmierstil .....	43
2.8.1	Variablen- und Funktionsbenennung .....	43
2.8.2	Abstände .....	44
2.8.3	Blöcke .....	44
2.8.4	Abschnitte .....	45
2.9	Formatierhilfen .....	45
2.9.1	Styler .....	45
2.9.2	Lintr .....	45
2.10	Zum Nachschlagen .....	46
2.11	Einstiegsaufgabe .....	46

<b>Teil II Datenvorbereitung .....</b>	<b>47</b>
<b>3 Daten visualisieren und vorbereiten .....</b>	<b>49</b>
3.1 Plots mit ggplot2 .....	50
3.1.1 Plot-Architekturen .....	50
3.1.2 Erster Plot mit ggplot2.....	50
3.1.3 Aufbau eines Plots.....	51
3.1.4 Ebenen.....	54
3.1.5 Geome .....	55
3.1.6 Stats .....	57
3.1.7 Themes .....	60
3.2 Datenaufbereitung .....	61
3.3 Strukturierung der Daten .....	62
3.3.1 Werte in Spaltenüberschriften .....	63
3.3.2 Mehrere Werte in einer Spalte .....	63
3.3.3 Imputation und Grafikdarstellung.....	65
3.3.4 Überwachung von Datentypen/Bereichsgrenzen .....	66
3.4 Datenaufbereitung an Zeitreihen – ein Beispiel .....	66
3.4.1 Erster Überblick .....	66
3.4.2 Messfehler.....	67
3.4.3 Überprüfen der zeitlichen Abfolge.....	68
3.4.4 Zeitserie generieren.....	69
3.4.4.1 Bestimmung der mittleren Tagestemperatur .....	69
3.4.4.2 Bestimmung der mittleren Jahrestemperatur .....	70
3.4.4.3 Imputation – Ersetzen von NA-Werten .....	70
3.5 Zwei kleine Checklisten .....	72
3.6 Aufgaben .....	73
<b>4 Datenplausibilität .....</b>	<b>75</b>
4.1 Hypothesen-Betrachtung.....	76
4.2 Allgemeine Kenngrößen als Hilfsmittel.....	77
4.2.1 Mittelwert und Median .....	77
4.2.2 Varianz .....	79
4.2.3 Momente höherer Ordnung .....	80
4.3 Grafische Hilfsmittel .....	81
4.3.1 Histogramme .....	81
4.3.2 Box-Plots .....	81
4.3.3 Summenhäufigkeiten und QQ-Plots .....	82
4.4 R-Packages zum Erkennen von Ausreißern .....	83

4.4.1	Das Package „Outliers“ .....	83
4.4.1.1	scores() .....	84
4.4.1.2	Dixon() .....	85
4.4.1.3	Cochran.test() .....	86
4.4.1.4	Grubbs-Test.....	87
4.4.1.5	Weitere Funktionen.....	88
4.5	Datenplausibilität bei mehreren Variablen und weitere Funktionen.....	88
4.6	Aufgaben .....	89
	<b>Teil III Statistische Lernmodelle.....</b>	<b>91</b>
<b>5</b>	<b>Regression .....</b>	<b>93</b>
5.1	Regression mit einer unabhängigen Variablen .....	94
5.1.1	Methode der kleinsten Fehlerquadrate .....	94
5.1.2	Homoskedastizität .....	96
5.1.3	Modellvalidierung.....	98
5.1.3.1	Residuen .....	101
5.1.4	Vorbeugende Wartung.....	105
5.1.4.1	Das Modellbeispiel .....	105
5.1.4.2	Etwas mehr Residuenanalyse .....	106
5.1.4.3	Vorhersagen .....	110
5.1.5	Erweiterung der Regression auf nichtlineare Funktionen.....	113
5.1.6	Kreuzvalidierung .....	114
5.2	Regression mit mehreren unabhängigen Variablen.....	116
5.2.1	Der Boston-Datensatz .....	116
5.2.2	Durchführung der Regression .....	122
5.2.3	Modellvalidierung.....	124
5.2.4	Regressionen robuster machen .....	128
5.2.4.1	Regularisierung .....	128
5.2.4.2	M-Schätzer.....	130
5.2.4.3	Weitere Alternativen.....	131
5.3	Aufgaben .....	133
<b>6</b>	<b>Klassifikation .....</b>	<b>135</b>
6.1	Logistische Regression .....	136
6.2	Der Perceptron-Algorithmus .....	140
6.3	Support Vector Machines .....	143
6.3.1	Der Iris-Datensatz.....	145

6.4	Entscheidungsbaumverfahren.....	146
6.4.1	Entscheidungsbäume .....	146
6.4.2	Der Iris-Datensatz.....	148
6.4.3	Bagging .....	148
6.4.4	Random Forests .....	149
6.4.5	Boosted Regression Trees .....	149
6.5	Naive Bayes-Klassifikatoren .....	150
6.5.1	Multinomiale naive Bayes-Klassifikatoren .....	150
6.5.2	Das spam-Beispiel .....	152
6.5.3	Likelihood .....	155
6.5.4	Gauß'sche naive Bayes-Klassifizierer .....	156
6.6	KNN Nächste-Nachbarn-Klassifikation .....	158
6.7	Modellbewertung: Devianzen und universellere Kenngrößen .....	161
6.7.1	Receiver Operating Characteristic, ROC und AUC.....	161
6.7.2	Die $R^2$ -Metrik.....	163
6.7.3	Eine generalisierte Metrik.....	164
6.7.3.1	Pseudo- $R^2$ .....	164
6.7.3.2	Devianzen.....	167
6.8	Aufgaben .....	167
<b>7</b>	<b>Objekte clustern, Merkmale reduzieren und Zeitreihen zerlegen ...</b>	<b>169</b>
7.1	K-means-Clustering .....	170
7.2	Korrelationen und Merkmalsreduktion durch Hauptkomponentenanalyse .....	173
7.2.1	Der beste Standpunkt .....	173
7.2.2	Kovarianzen .....	174
7.2.3	Kovarianzmatrizen.....	176
7.2.4	Anwendungen .....	180
7.2.4.1	Eine kleine Weinprobe .....	180
7.2.4.2	Der Boston-Datensatz.....	185
7.2.4.3	Erweiterungen der Hauptkomponentenanalyse .....	188
7.2.4.4	Ausreißererkennung.....	189
7.3	Zeitreihen .....	189
7.3.1	Komponentenmodelle .....	189
7.3.2	Glättungsverfahren bei Zeitreihen .....	190
7.3.2.1	Gleitender Durchschnitt .....	191
7.3.2.2	Exponentielle Glättung.....	192
7.3.2.3	Holt-Winters-Glättung .....	194
7.3.2.4	Weitere Glättungsmethoden .....	195

7.3.3	AR-Modelle .....	196
7.3.3.1	Autokorrelationsfunktionen .....	197
7.3.3.2	Partielle Autokorrelationsfunktion .....	198
7.3.4	MA-Modelle .....	198
7.3.5	ARMA- und ARIMA-Modelle .....	200
7.4	Aufgaben .....	202
<b>Teil IV Lernen mit neuronalen Netzen.....</b>		<b>203</b>
<b>8</b>	<b>Neuronale Netze .....</b>	<b>205</b>
8.1	Das Perceptron .....	205
8.2	Layers .....	207
8.3	Aktivierungsfunktionen .....	208
8.4	Warum das Stapeln linearer Funktionen nicht sinnvoll ist .....	211
8.5	Der Regelkreis eines Lernvorgangs .....	213
8.5.1	Verlustfunktionen und Metriken .....	213
8.5.2	Epochen und Batches .....	214
8.5.3	Gradienten, lokale Gradienten und Autodiff .....	215
8.5.3.1	Manuelle Bestimmung des Gradienten eines Perceptrons ....	216
8.5.3.2	Berechnung des Gradienten mit CAS oder Differenzenquotienten .....	217
8.5.3.3	Berechnung des Gradienten mit Forward-Mode Autodiff ....	217
8.5.3.4	Berechnung des Gradienten mit Backpropagation Autodiff ...	218
8.5.4	Der Optimizer .....	224
8.5.4.1	Stochastisches Gradientenverfahren (SGD) .....	225
8.5.4.2	Momenten-Update .....	226
8.5.4.3	Nesterov-Moment .....	226
8.5.4.4	Adagrad .....	226
8.5.4.5	Rmsprop .....	227
8.5.4.6	Adadelta .....	227
8.5.4.7	Adam .....	228
8.5.4.8	ADAMax .....	228
8.5.4.9	Was tun, wenn ...? .....	229
8.6	Regularisierung und Dropouts .....	230
8.6.1	Regularisierung .....	230
8.6.2	Dropouts .....	230
8.7	Aufgaben .....	231

<b>9 H2O .....</b>	<b>233</b>
9.1 Das Unternehmen H2O .....	234
9.2 Installation und erste Schritte .....	234
9.3 Univariate lineare Regression .....	236
9.3.1 Generalisierte lineare Modelle .....	237
9.3.1.1 Lambda-Suche .....	239
9.3.1.2 Grid-Suche .....	239
9.4 Entscheidungsbäume, Random Forests und Gradient Boosting .....	240
9.5 Neuronale Netze .....	245
9.6 Der Boston-Datensatz .....	249
9.6.1 AutoML .....	254
9.6.2 Explain .....	256
9.6.2.1 Residuenanalyse .....	257
9.6.2.2 Variablenwichtigkeit .....	257
9.6.2.3 Heatmap der Variablenwichtigkeit .....	258
9.6.2.4 Modell-Korrelation .....	258
9.6.2.5 Partielles Abhängigkeitsdiagramm .....	260
9.7 Iris .....	260
9.7.1 Stacked Ensemble .....	261
9.8 MNIST .....	266
9.8.1 Der Standarddatensatz .....	266
9.8.2 Bewertung .....	270
9.9 Aufgaben .....	271
<b>10 Keras/Tensorflow .....</b>	<b>273</b>
10.1 Einrichtung und Nutzung von Keras .....	274
10.1.1 Dimensionen und Tensoren .....	274
10.1.2 Normalisierung .....	276
10.2 Boston .....	276
10.2.1 Normalisierung .....	276
10.2.2 Modelldefinition .....	277
10.2.3 Compilierung .....	278
10.2.4 Fit .....	279
10.3 Diagnosemöglichkeiten und Optimierung .....	282
10.3.1 Eine kleine Regression .....	282
10.3.2 Speichern und Laden des Modells und der Gewichte .....	285
10.3.3 Auslesen des Modells .....	286
10.3.4 Callbacks .....	287

10.3.5 TensorBoard .....	287
10.4 Convolutional Networks .....	291
10.4.1 Faltung und Feature Learning .....	291
10.4.1.1 Diskrete 2D-Faltung .....	292
10.4.1.2 Aufbau von Mustern .....	294
10.4.1.3 Pooling Layers .....	296
10.4.2 Komposition der Layer .....	297
10.4.3 MNIST .....	298
10.4.4 ImageNet .....	300
10.5 Transferlernen .....	304
10.5.1 Modelldefinition .....	304
10.5.2 Datenbereitstellung .....	306
10.5.3 Augmentation .....	309
10.5.4 Lernvorgänge .....	311
10.6 Recurrent Networks .....	314
10.6.1 Simple Recurrent Networks .....	314
10.6.2 LSTM .....	316
10.6.3 Wettervorhersage .....	318
10.7 Aufgaben .....	326
 <b>Teil V Anhang .....</b>	 <b>329</b>
 <b>A Basiswissen Statistik .....</b>	 <b>331</b>
A.1 Beschreibende Statistik .....	331
A.1.1 Mittelwert und Median .....	331
A.1.2 Varianz .....	333
A.1.3 Momente höherer Ordnung .....	334
A.1.4 Histogramme, Summenhäufigkeiten und Quantile .....	334
A.1.5 Box-Plots .....	338
A.2 Schließende Statistik .....	338
A.2.1 Normalverteilung .....	339
A.2.2 t-(Student-)Verteilung .....	342
A.2.3 Chi-Quadrat-Verteilung .....	344
A.2.4 F-Verteilung .....	346
 <b>Literatur .....</b>	 <b>349</b>
 <b>Stichwortverzeichnis .....</b>	 <b>361</b>

Diese Leseprobe haben Sie beim  
 [edv-buchversand.de](#) heruntergeladen.  
Das Buch können Sie online in unserem  
Shop bestellen.

[Hier zum Shop](#)