

# Inhalt

<b>Vorwort .....</b>	<b>XIII</b>
<b>1 Explorative Datenanalyse .....</b>	<b>1</b>
Strukturierte Datentypen .....	2
Weiterführende Literatur .....	4
Tabellarische Daten .....	5
Data Frames und Tabellen .....	6
Nicht tabellarische Datenstrukturen .....	7
Weiterführende Literatur .....	8
Lagemaße .....	8
Mittelwert .....	9
Median und andere robuste Lagemaße .....	11
Beispiel: Lagemaße für Einwohnerzahlen und Mordraten .....	12
Weiterführende Literatur .....	14
Streuungsmaße .....	14
Standardabweichung und ähnliche Maße .....	15
Streuungsmaße auf Basis von Perzentilen .....	17
Beispiel: Streuungsmaße für die Einwohnerzahlen der Bundesstaaten in den USA .....	19
Weiterführende Literatur .....	20
Exploration der Datenverteilung .....	20
Perzentile und Box-Plots .....	21
Häufigkeitstabellen und Histogramme .....	23
Dichtediagramme und -schätzer .....	25
Weiterführende Literatur .....	27
Binäre und kategoriale Daten untersuchen .....	28
Modus .....	30
Erwartungswert .....	30
Wahrscheinlichkeiten .....	31
Weiterführende Literatur .....	32

Korrelation . . . . .	32
Streudiagramme . . . . .	35
Weiterführende Literatur . . . . .	37
Zwei oder mehr Variablen untersuchen . . . . .	37
Hexagonal-Binning- und Konturdiagramme (Diagramme für mehrere numerische Variablen) . . . . .	38
Zwei kategoriale Variablen . . . . .	41
Kategoriale und numerische Variablen . . . . .	42
Mehrere Variablen visualisieren . . . . .	44
Weiterführende Literatur . . . . .	47
Zusammenfassung . . . . .	47
<b>2 Daten- und Stichprobenverteilungen . . . . .</b>	<b>49</b>
Zufallsstichprobenziehung und Stichprobenverzerrung . . . . .	50
Verzerrung . . . . .	52
Zufallsauswahl . . . . .	53
Größe versus Qualität: Wann spielt die Stichprobengröße eine Rolle? . . . . .	54
Unterschied zwischen dem Stichproben- und dem Populationsmittelwert . . . . .	56
Weiterführende Literatur . . . . .	56
Auswahlverzerrung . . . . .	57
Regression zur Mitte . . . . .	58
Weiterführende Literatur . . . . .	60
Stichprobenverteilung einer statistischen Größe . . . . .	60
Zentraler Grenzwertsatz . . . . .	63
Standardfehler . . . . .	64
Weiterführende Literatur . . . . .	65
Bootstrap-Verfahren . . . . .	65
Unterschiede zwischen Resampling und dem Bootstrap-Verfahren . . . . .	69
Weiterführende Literatur . . . . .	69
Konfidenzintervalle . . . . .	70
Weiterführende Literatur . . . . .	72
Normalverteilung . . . . .	73
Standardnormalverteilung und Q-Q-Diagramme . . . . .	75
Verteilungen mit langen Verteilungsenden . . . . .	76
Weiterführende Literatur . . . . .	79
Studentsche t-Verteilung . . . . .	79
Weiterführende Literatur . . . . .	81
Binomialverteilung . . . . .	81
Weiterführende Literatur . . . . .	84

Chi-Quadrat-Verteilung .....	84
Weiterführende Literatur .....	85
F-Verteilung.....	86
Weiterführende Literatur .....	86
Poisson- und verwandte Verteilungen.....	87
Poisson-Verteilung .....	87
Exponentialverteilung.....	88
Die Hazardrate schätzen.....	89
Weibull-Verteilung.....	89
Weiterführende Literatur .....	90
Zusammenfassung .....	90
<b>3 Statistische Versuche und Signifikanztests .....</b>	<b>91</b>
A/B-Test.....	92
Warum eine Kontrollgruppe nutzen? .....	94
Warum lediglich A/B? Warum nicht auch C, D usw.? .....	95
Weiterführende Literatur .....	97
Hypothesentests .....	97
Die Nullhypothese .....	99
Die Alternativhypothese .....	99
Einseitige und zweiseitige Hypothesentests .....	99
Weiterführende Literatur .....	100
Resampling .....	101
Permutationstest.....	101
Beispiel: Die Affinität von Nutzern zu einem Webinhalt messen (Web-Stickiness) .....	102
Exakte und Bootstrap-Permutationstests .....	106
Permutationstests: ein geeigneter Ausgangspunkt in der Data Science .....	107
Weiterführende Literatur .....	108
Statistische Signifikanz und p-Werte.....	108
p-Wert.....	111
Signifikanzniveau .....	112
Fehler 1. und 2. Art.....	113
Data Science und p-Werte .....	114
Weiterführende Literatur .....	114
t-Tests .....	115
Weiterführende Literatur .....	117
Testen mehrerer Hypothesen .....	117
Weiterführende Literatur .....	120
Die Anzahl der Freiheitsgrade .....	121
Weiterführende Literatur .....	122

Varianzanalyse (ANOVA) . . . . .	122
F-Statistik . . . . .	126
Zweifaktorielle Varianzanalyse . . . . .	128
Weiterführende Literatur . . . . .	128
Chi-Quadrat-Test . . . . .	128
Chi-Quadrat-Test: ein Resampling-Ansatz . . . . .	129
Chi-Quadrat-Test: die statistische Theorie . . . . .	131
Exakter Test nach Fisher . . . . .	133
Relevanz in der Data Science . . . . .	135
Weiterführende Literatur . . . . .	136
Mehrarmige Banditen . . . . .	136
Weiterführende Literatur . . . . .	139
Trennschärfe und Stichprobengröße . . . . .	140
Stichprobengröße . . . . .	142
Weiterführende Literatur . . . . .	144
Zusammenfassung . . . . .	144
<b>4 Regression und Vorhersage . . . . .</b>	<b>145</b>
Lineare Einfachregression . . . . .	145
Die Regressionsgleichung . . . . .	147
Angepasste Werte und Residuen . . . . .	149
Die Methode der kleinsten Quadrate . . . . .	151
Unterschied zwischen Vorhersage- und erklärenden Modellen . . . . .	152
Weiterführende Literatur . . . . .	153
Multiple lineare Regression . . . . .	153
Beispiel: Die King-County-Immobiliedaten . . . . .	154
Das Modell bewerten . . . . .	155
Kreuzvalidierung . . . . .	158
Modellauswahl und schrittweise Regression . . . . .	159
Gewichtete Regression . . . . .	163
Weiterführende Literatur . . . . .	164
Vorhersage mittels Regression . . . . .	164
Risiken bei der Extrapolation . . . . .	165
Konfidenz- und Prognoseintervalle . . . . .	165
Regression mit Faktorvariablen . . . . .	167
Darstellung durch Dummy-Variablen . . . . .	168
Faktorvariablen mit vielen Stufen . . . . .	171
Geordnete Faktorvariablen . . . . .	173
Interpretieren der Regressionsgleichung . . . . .	174
Korrelierte Prädiktorvariablen . . . . .	175
Multikollinearität . . . . .	176

Konfundierende Variablen . . . . .	177
Interaktions- und Haupteffekte . . . . .	178
Regressionsdiagnostik . . . . .	180
Ausreißer . . . . .	181
Einflussreiche Beobachtungen . . . . .	183
Heteroskedastische, nicht normalverteilte und korrelierte Fehler .	186
Partielle Residuendiagramme und Nichtlinearität . . . . .	190
Polynomiale und Spline-Regression. . . . .	192
Polynome . . . . .	193
Splines . . . . .	195
Verallgemeinerte additive Modelle . . . . .	197
Weiterführende Literatur . . . . .	199
Zusammenfassung . . . . .	199
<b>5 Klassifikation . . . . .</b>	<b>201</b>
Naiver Bayes-Klassifikator . . . . .	203
Warum eine exakte bayessche Klassifikation nicht praktikabel ist . . . . .	204
Die naive Lösung . . . . .	204
Numerische Prädiktorvariablen . . . . .	207
Weiterführende Literatur . . . . .	207
Diskriminanzanalyse . . . . .	208
Kovarianzmatrix . . . . .	209
Lineare Diskriminanzanalyse nach Fisher . . . . .	209
Ein einfaches Beispiel . . . . .	210
Weiterführende Literatur . . . . .	213
Logistische Regression . . . . .	214
Logistische Antwortfunktion und Logit-Funktion . . . . .	215
Logistische Regression und verallgemeinerte lineare Modelle . . . . .	217
Verallgemeinerte lineare Modelle . . . . .	218
Vorhergesagte Werte aus der logistischen Regression . . . . .	219
Interpretation der Koeffizienten und Odds-Ratios . . . . .	220
Lineare und logistische Regression: Gemeinsamkeiten und Unterschiede . . . . .	221
Das Modell prüfen und bewerten . . . . .	223
Weiterführende Literatur . . . . .	226
Klassifikationsmodelle bewerten . . . . .	227
Konfusionsmatrix . . . . .	228
Die Problematik seltener Kategorien . . . . .	230
Relevanz, Sensitivität und Spezifität . . . . .	231
ROC-Kurve . . . . .	232

Fläche unter der ROC-Kurve (AUC) .....	234
Lift .....	236
Weiterführende Literatur.....	238
Strategien bei unausgewogenen Daten .....	238
Undersampling.....	239
Oversampling und Up/Down Weighting.....	240
Generierung von Daten .....	241
Kostenbasierte Klassifikation.....	242
Die Vorhersagen untersuchen .....	243
Weiterführende Literatur.....	244
Zusammenfassung .....	244
<b>6 Statistisches maschinelles Lernen .....</b>	<b>247</b>
K-Nächste-Nachbarn .....	248
Ein kleines Beispiel: Vorhersage von Kreditausfällen.....	249
Distanzmaße .....	252
1-aus-n-Codierung .....	253
Standardisierung (Normierung, z-Werte) .....	254
K festlegen .....	257
KNN zur Merkmalskonstruktion.....	258
Baummodelle .....	260
Ein einfaches Beispiel.....	262
Der Recursive-Partitioning-Algorithmus .....	264
Homogenität und Unreinheit messen .....	266
Den Baum daran hindern, weiterzuwachsen .....	267
Vorhersage eines kontinuierlichen Werts .....	270
Wie Bäume verwendet werden .....	270
Weiterführende Literatur.....	271
Bagging und Random Forests .....	271
Bagging.....	273
Random Forest.....	273
Variablenwichtigkeit .....	278
Hyperparameter.....	281
Boosting .....	282
Der Boosting-Algorithmus .....	283
XGBoost .....	284
Regularisierung: Überanpassung vermeiden .....	287
Hyperparameter und Kreuzvalidierung .....	292
Zusammenfassung .....	295

<b>7 Unüberwachtes Lernen</b> . . . . .	<b>297</b>
Hauptkomponentenanalyse . . . . .	298
Ein einfaches Beispiel . . . . .	299
Die Hauptkomponenten berechnen . . . . .	302
Die Hauptkomponenten interpretieren . . . . .	302
Korrespondenzanalyse . . . . .	305
Weiterführende Literatur . . . . .	307
K-Means-Clustering . . . . .	307
Ein einfaches Beispiel . . . . .	308
Der K-Means-Algorithmus . . . . .	311
Die Cluster interpretieren . . . . .	312
Die Anzahl von Clustern bestimmen . . . . .	314
Hierarchische Clusteranalyse . . . . .	317
Ein einfaches Beispiel . . . . .	317
Das Dendrogramm . . . . .	318
Der agglomerative Algorithmus . . . . .	320
Ähnlichkeitsmaße . . . . .	321
Modellbasierte Clusteranalyse . . . . .	322
Multivariate Normalverteilung . . . . .	323
Zusammengesetzte Normalverteilungen (gaußsche Mischverteilungen) . . . . .	324
Die Anzahl der Cluster bestimmen . . . . .	327
Weiterführende Literatur . . . . .	329
Skalierung und kategoriale Variablen . . . . .	329
Variablen skalieren . . . . .	330
Dominierende Variablen . . . . .	332
Kategoriale Daten und die Gower-Distanz . . . . .	334
Probleme bei der Clusteranalyse mit verschiedenen Datentypen . . . . .	336
Zusammenfassung . . . . .	338
<b>Quellenangaben</b> . . . . .	<b>339</b>
<b>Index</b> . . . . .	<b>341</b>