

Statistik und Datenanalyse: Aufbau

11. Übung – Logistische Regression – Machine Learning

Benjamin Fretwurst

▶ PDF-Version der Folien



Inhalt

- 1 Logistische Regression
 - 1.1 Multinominale Regression
- Übung 4
 - 1.2 Datenaufbereitung
- Take Home – Ausblick – Vokabeln

Orga

Letzte Sitzung am 20.12.2023 ist online only. Es gibt dann einen Zusammenfassung-/Klausurvorbereitungsonlinevodcast.

Lernziele

Übung in logistischer Regression und ML

- Übung 4 und [Text Zerback Wirz!](#) lesen! (liegt beides auch in OLAT unter Materialien bzw. Texte)

1 Logistische Regression



RAQ erklärt Interesse an Maschine Learning

LogReg: Aversion gegen Computer erklärt Interesse an ML

Characteristic	OR ¹	95% CI ¹	p-value	VIF ¹
ML1	0.74	0.53, 1.02	0.065	1.0
ML2	0.54	0.34, 0.83	0.007	1.7
ML3	1.74	1.12, 2.81	0.018	1.7

¹ OR = Odds Ratio, CI = Confidence Interval, VIF = Variance Inflation Factor

Null deviance = 230; Null df = 165; Log-likelihood = -109; AIC = 226; BIC = 238; Deviance = 218; Residual df = 162; No. Obs. = 166

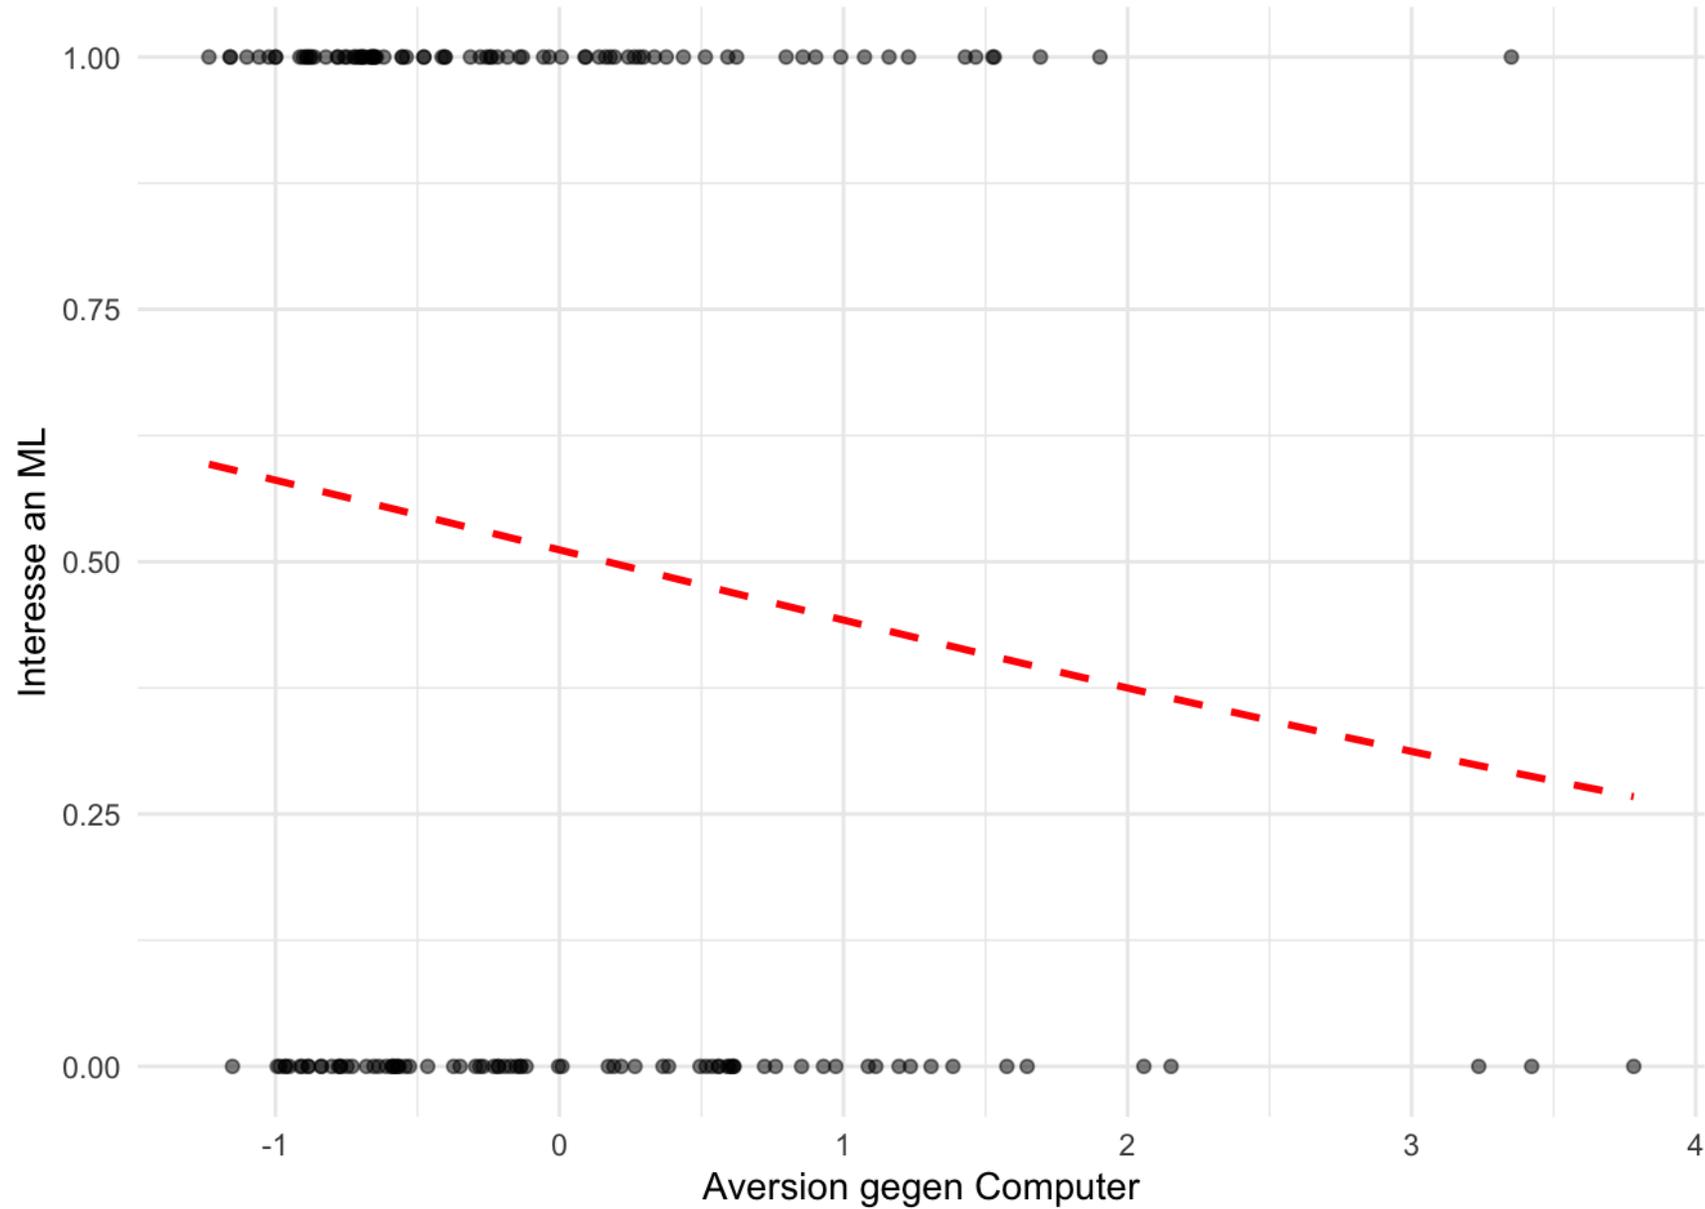
LM: Aversion gegen Computer erklärt Interesse an ML

Characteristic	Beta	95% CI ¹	p-value	VIF ¹
ML1	-0.07	-0.15, 0.00	0.066	1.0
ML2	-0.14	-0.24, -0.04	0.005	1.6
ML3	0.13	0.02, 0.23	0.016	1.6

¹ CI = Confidence Interval, VIF = Variance Inflation Factor

R² = 0.071; Adjusted R² = 0.054; Sigma = 0.488; Statistic = 4.13; p-value = 0.007; df = 3; Log-likelihood = -114; AIC = 239; BIC = 254; Deviance = 38.5; Residual df = 162; No. Obs. = 166

RAQ-ML-«S-Kurve» sieht gerade aus



1.1 Multinominale Regression

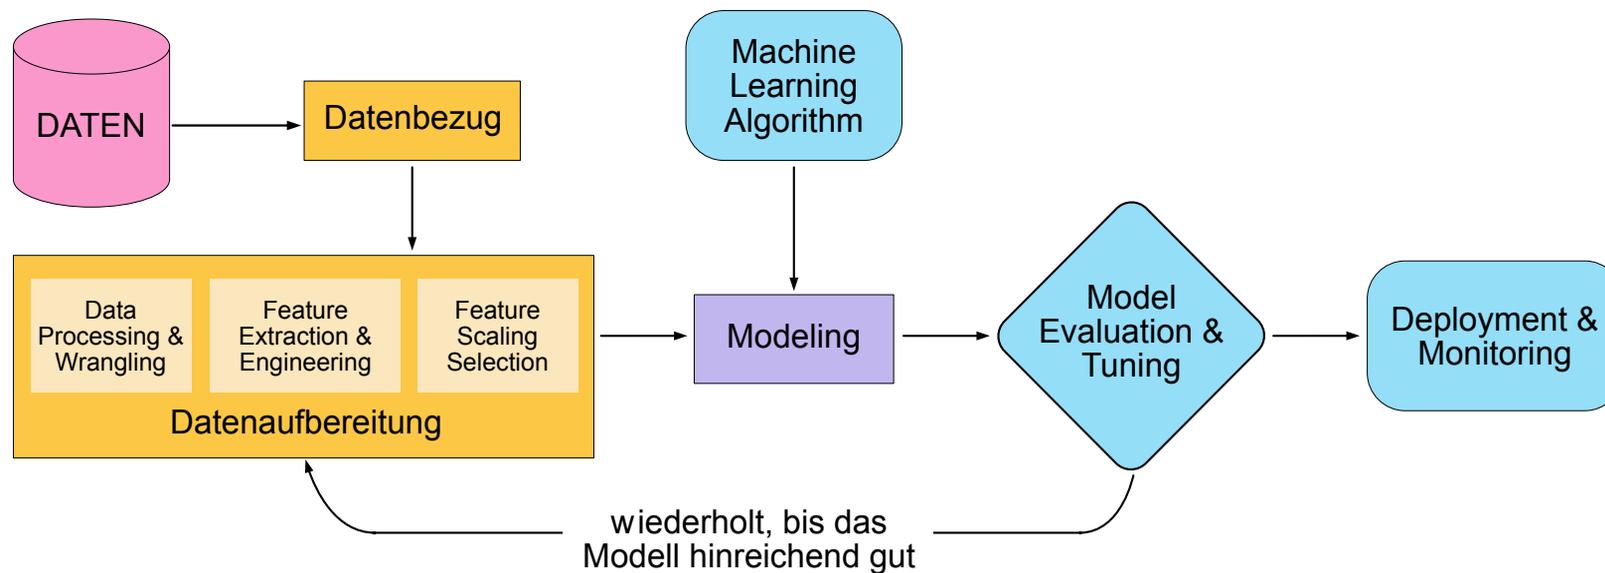
Multinomial bedeutet, dass es eine kategoriale (multinomiale) AV gibt. Im Prinzip werden mehrere binäre logistische Regressionen durchgeführt und zusätzlich ausgegeben, wie gut das Gesamtmodell ist. Es kommen die Fit-Kennungen AIC und BIC dazu.

Supervised ML

Trainieren → Testen → Anwenden

Die verfügbaren Daten werden in einen grösseren und einen kleineren Teil getrennt:

1. Trainingsdaten, an denen das Modell trainiert wird (Modelling)
2. Testdaten, an denen das Modell evaluiert wird.



Übung 4

In der Übung beschäftigen wir uns mit Daten des Untergangs der Titanic. Schauen Sie sich jeweils die Befehle an und finden Sie heraus, was die Befehle machen. Machen Sie sich Notizen, wenn Sie etwas nicht verstehen.

Daten einlesen

Legen Sie für diese Übung einen Ordner an, erstellen Sie dort eine qmd und kopieren Sie die folgenden Daten in einen dortigen Unterordner «data»:

Suchen und nehmen Sie den Datensatz “train.csv”: Download der Daten:

<https://www.kaggle.com/competitions/titanic/data>

► Code

1.2 Datenaufbereitung

► Code

... und mal die Daten angucken:

► Code

PassengerId Survived Pclass Name

Min. : 1.0 Min. :0.0000 Min. :1.000 Length:891

1st Qu.:223.5 1st Qu.:0.0000 1st Qu.:2.000 Class :character

Median :446.0 Median :0.0000 Median :3.000 Mode :character

Mean :446.0 Mean :0.3838 Mean :2.309

3rd Qu.:668.5 3rd Qu.:1.0000 3rd Qu.:3.000

Max. :891.0 Max. :1.0000 Max. :3.000

Sex

Age

SibSp

Parch

Length:891 Min. : 0.42 Min. :0.000 Min. :0.0000

Class :character 1st Qu.:20.12 1st Qu.:0.000 1st Qu.:0.0000

Mode :character Median :28.00 Median :0.000 Median :0.0000

Mean :29.70 Mean :0.523 Mean :0.3816

3rd Qu.:38.00 3rd Qu.:1.000 3rd Qu.:0.0000

Max. :80.00 Max. :8.000 Max. :6.0000

NA's :177

Ticket Fare Cabin Embarked

Length:891 Min. : 0.00 Length:891 S :644

Class :character 1st Qu.: 7.91 Class :character C :168

Mode :character Median : 14.45 Mode :character Q : 77

Mean : 32.20 NA's: 2

3rd Qu.: 31.00

Max. :512.33

Kinder Age_z Pclass_f Cabin_D

Mode :logical Min. :-29.279 3:491 Min. :0.000

FALSE:643 1st Qu.: -9.574 2:184 1st Qu.:0.000
TRUE :71 Median : -1.699 1:216 Median :0.000
NA's :177 Mean : 0.000 Mean :0.229
3rd Qu.: 8.301 3rd Qu.:0.000
Max. : 50.301 Max. :1.000
NA's :177

Die PassengerId ist einfach eine Identifikationsnummer.

- Es gibt dann eine Variable, die "Survived" heisst, die ein Minimum von 0 hat und ein Maximum von 1. Das deutet sehr auf eine Dummy hin. Da der Durchschnitt ("Mean") = 0.38 ist, wissen wir jetzt schon, dass 38 Prozent der Passagiere überlebt haben (der Mittelwert einer Dummy ist immer der Prozentsatz der 1er-Gruppe).
- Dann kommt noch der Name als Zeichenvariable,
- das Alter, das von 0.42 bis 80 geht. Von 177 Personen fehlen die Altersangaben.

Informieren Sie sich über die übrigen Variablen auf (<https://www.kaggle.com/competitions/titanic/data>)[«Kaggle»].

Daten in Trainings- und Testdaten aufteilen

Was passiert hier?

► Code

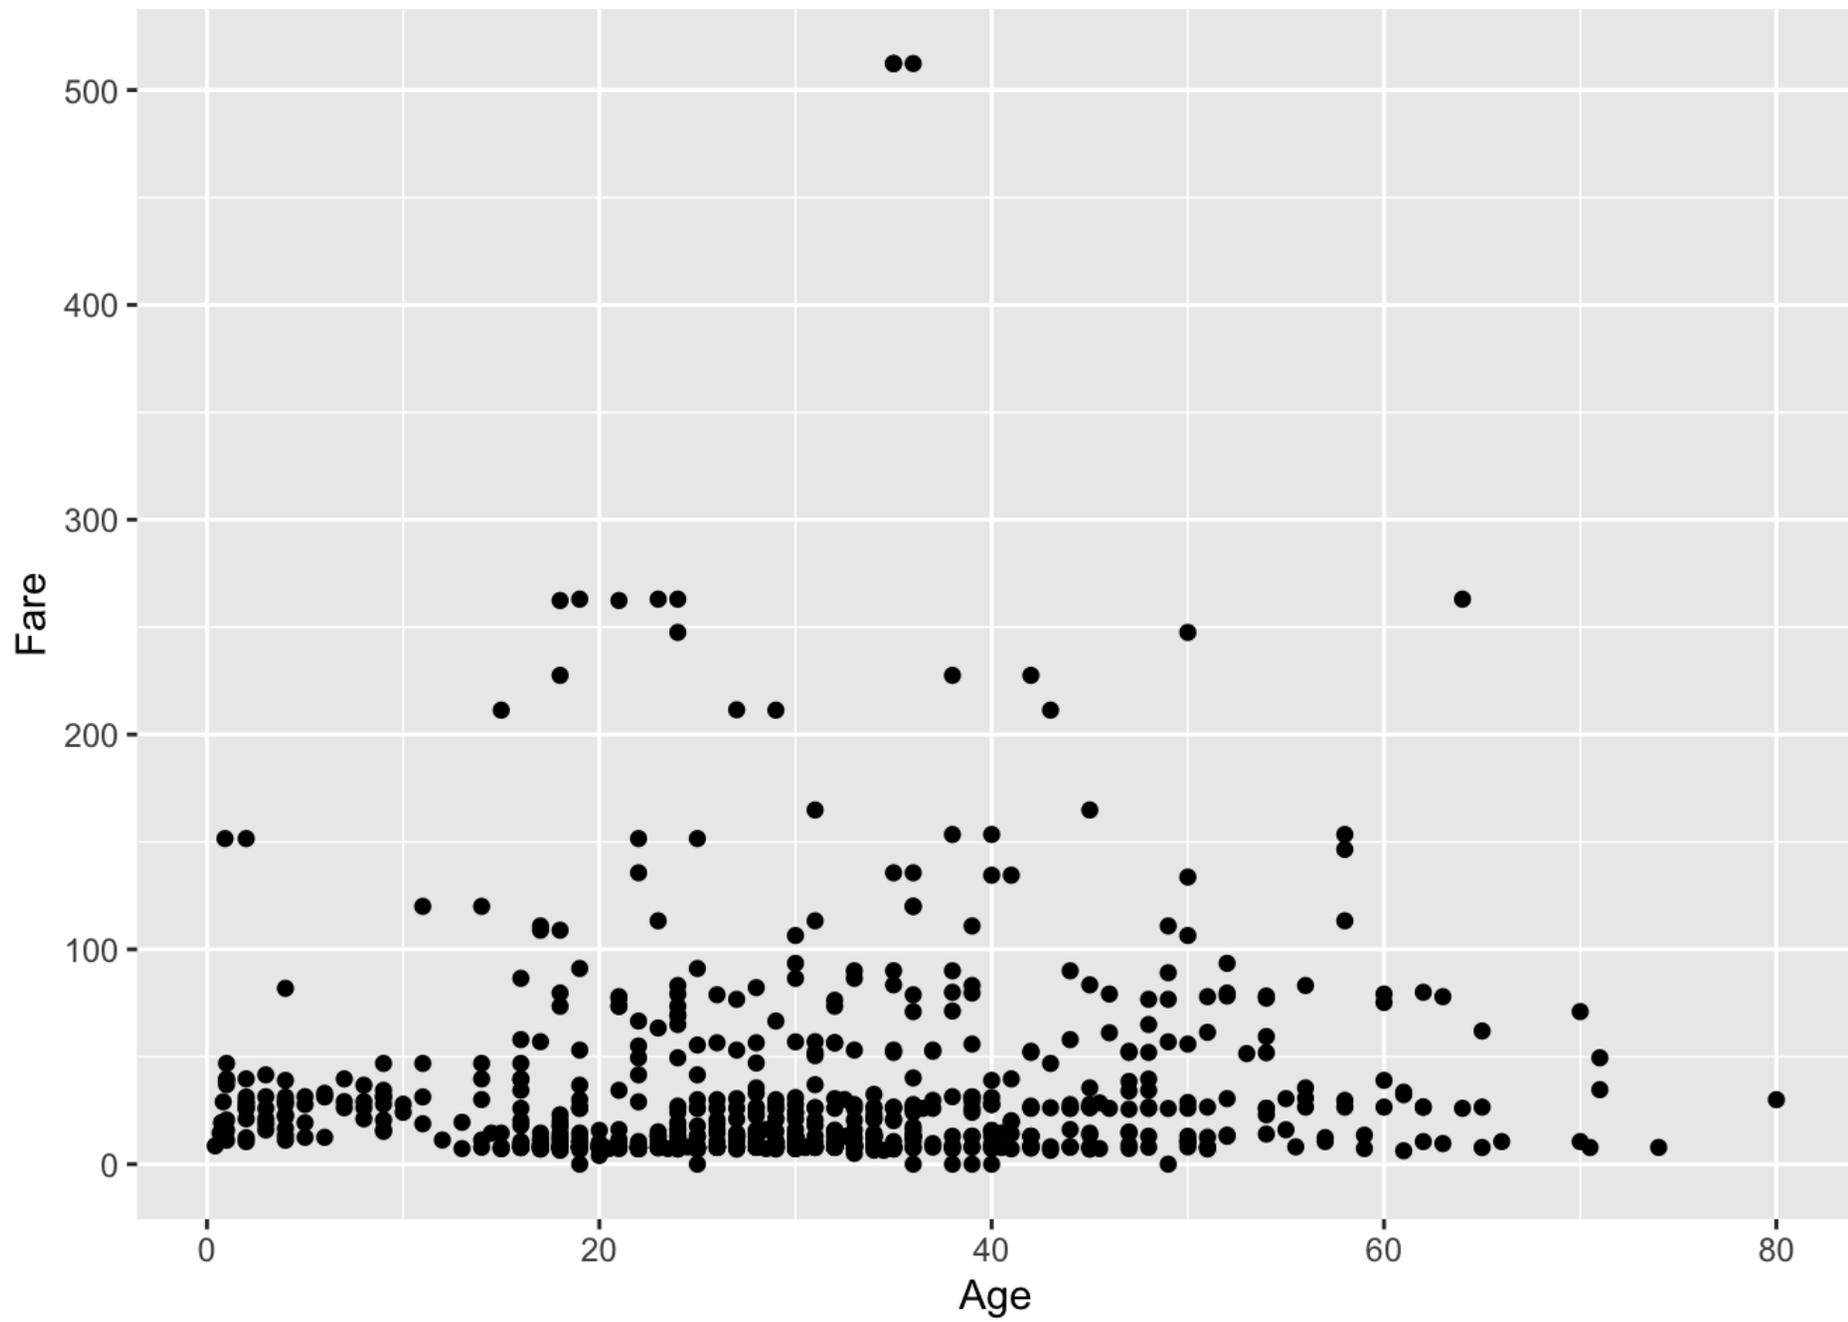
Sehen kann man nach diesem r-Chunk übrigens nichts, weil nur Datensätze im Hintergrund aufgeteilt wurden. Also suchen wir mal nach guten Datenvisualisierungen.

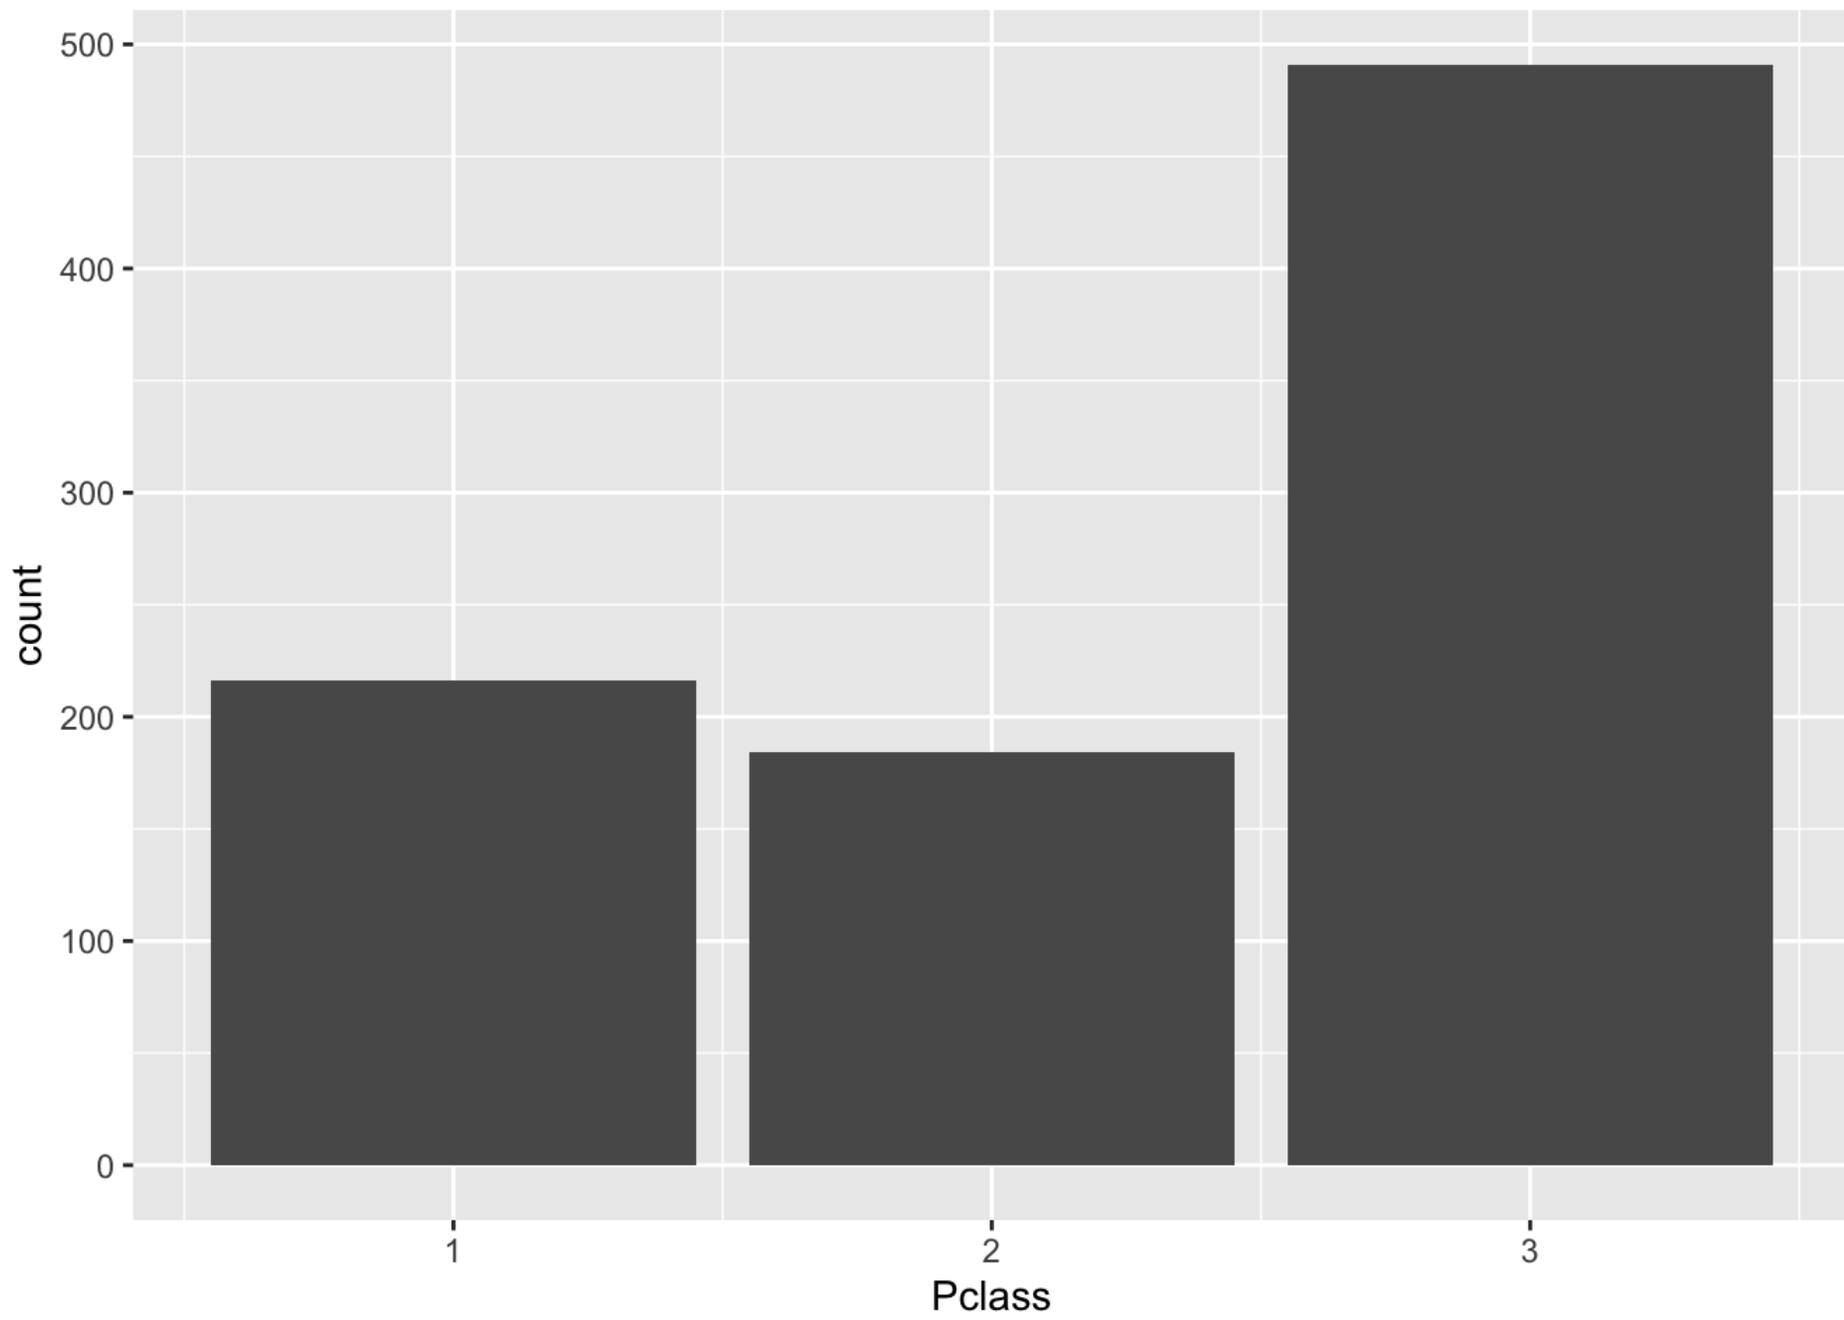
Übung: Experimentieren Sie mit verschiedenen Zahlen in `set.seed()` und grösseren und kleineren Werten in `sample_frac()`.

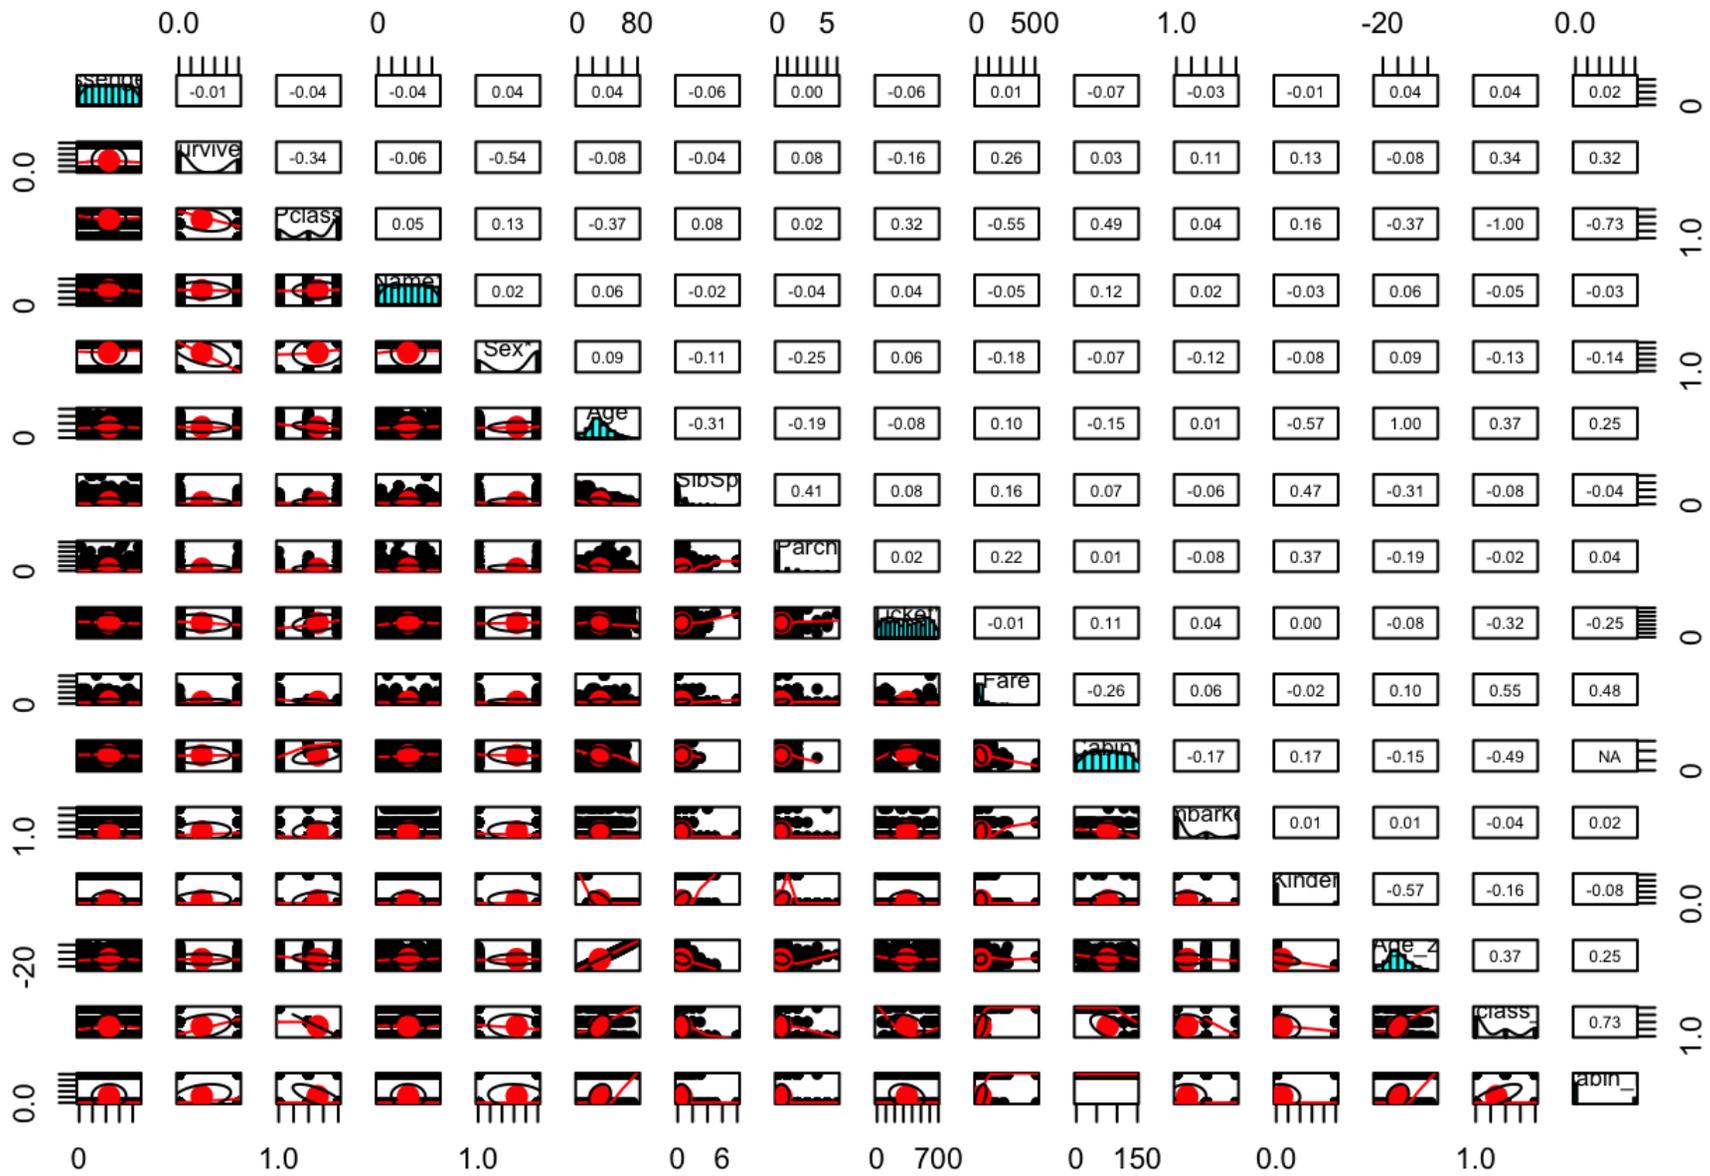
Datenvisualisierung

Eine einfache Darstellungsmöglichkeit ist ein sogenannter “Scatterplot” der die Lage von Fällen in ein Koordinatensystem einteilt, das durch zwei Variablen gebildet wird. Im Beispiel (Abbildung @ref(titanic-Datenvisualisierungen)) ist es das Alter der Passagiere “Age” und der Fahrpreis “Fare”. Als Zweites haben wir ein Balkendiagramm für die Passagierklassen. Im letzten sehr aufwendigen Plotgrafik werden die Zweierbeziehungen aller Variablen dargestellt, also wie sie miteinander korrelieren (obere Nebendiagonalen), wie ihre Verteilung ist (auf der Diagonale mit Namen) und wie ihre gemeinsame Streuung ist, also ein Scatterplot in der unteren Nebendiagonalen. Mehr zu diesen SPLOM finden Sie hier: <https://cran.r-project.org/web/packages/psych/vignettes/intro.pdf>.

► R-Code







Modellbildung für den Fahrpreis

Übung: Experimentieren Sie mit dem Syntax! Kopieren Sie sich die Zeile für das Modell, löschen von “Age_z” bis “Kinder” alles heraus und schätzen Sie mal. Schauen Sie sich das Ergebnis gut an und achten Sie darauf, was passiert, wenn Sie die Summanden für $I(\text{Age}_z^2)$ usw. wieder in das Modell tun. Am Ende können Sie versuchen das Modell durch weitere Variablen ergänzen und verbessern oder andere Teile wieder herausnehmen. Manche Variablen wurden erst noch erstellt (zB “Kinder” oder “Age_z”). Die entsprechende Datenaufbereitung.qmd können Sie [hier](#) abrufen .

Übung: Interpretieren Sie den Output!

► Code

term	estimate	std.error	statistic	p.value
(Intercept)	2.657	0.076	35.047	0.000
Sexmale	-0.316	0.070	-4.520	0.000
Age_z	-0.003	0.003	-1.009	0.314
$I(\text{Age}_z^2)$	0.000	0.000	-0.406	0.685
Survived	-0.077	0.073	-1.050	0.294
Pclass_f2	0.492	0.072	6.859	0.000
Pclass_f1	1.778	0.077	23.104	0.000
KinderTRUE	0.607	0.173	3.515	0.000

► Code

r.squared	adj.r.squared	sigma	statistic	p.value	df	logLik	AIC	BIC	deviance	df.residual	nobs
0.58	0.57	0.64	103.29	0	7	-517.85	1053.7	1092.26	216.7	528	536

Regressionsoutput mit `sjPlot::tab_model`

► Code

log(Fare+1)							
<i>Predictors</i>	<i>b</i>	<i>std. b</i>	<i>CI</i>	<i>standardized CI</i>	<i>p</i>	<i>std. p</i>	
(Intercept)	2.66	0.83	2.51 – 2.81	0.80 – 0.87	<0.001	<0.001	
Sex [male]	-0.32	-0.06	-0.45 – -0.18	-0.10 – -0.02	<0.001	0.003	
Age z	-0.00	-0.02	-0.01 – 0.00	-0.05 – 0.00	0.314	0.063	
Age z^2	-0.00	-0.00	-0.00 – 0.00	-0.02 – 0.01	0.685	0.639	
Survived	-0.08	-0.00	-0.22 – 0.07	-0.02 – 0.02	0.294	0.914	
Pclass f [2]	0.49	0.06	0.35 – 0.63	0.02 – 0.10	<0.001	0.004	
Pclass f [1]	1.78	0.44	1.63 – 1.93	0.39 – 0.48	<0.001	<0.001	
KinderTRUE	0.61	0.05	0.27 – 0.95	-0.04 – 0.15	<0.001	0.272	
Observations	536						
R ² / R ² adjusted	0.578 / 0.572						

Regressionsoutput mit gtsummary::tbl_regression

Übung: Was für ein Problem sehen Sie im folgenden Output? Bei welcher Befehlszeile müssten Sie das # wegnehmen, um das Problem zu lösen?

► Code

Characteristic	Beta	95% CI ¹	p-value	GVIF ¹	Adjusted GVIF ^{2,1}
Sex				1.5	1.2
female	—	—			
male	-0.32	-0.45, -0.18	<0.001		
Age_z	0.00	-0.01, 0.00	0.3	3.1	1.8
I(Age_z^2)	0.00	0.00, 0.00	0.7	2.5	1.6
Survived	-0.08	-0.22, 0.07	0.3	1.7	1.3
Pclass_f				1.4	1.1
3	—	—			
2	0.49	0.35, 0.63	<0.001		
1	1.8	1.6, 1.9	<0.001		

R² = 0.578; Adjusted R² = 0.572; Sigma = 0.641; Statistic = 103; p-value = <0.001; df = 7; Log-likelihood = -518; AIC = 1,054; BIC = 1,092; Deviance = 217; Residual df = 528; No. Obs. = 536

Characteristic	Beta	95% CI ¹	p-value	GVIF ¹	Adjusted GVIF ^{2,1}
Kinder				3.5	1.9
FALSE	—	—			
TRUE	0.61	0.27, 0.95	<0.001		

¹ CI = Confidence Interval, GVIF = Generalized Variance Inflation Factor

² $GVIF^{1/(2*df)}$

R² = 0.578; Adjusted R² = 0.572; Sigma = 0.641; Statistic = 103; p-value = <0.001; df = 7; Log-likelihood = -518; AIC = 1,054; BIC = 1,092; Deviance = 217; Residual df = 528; No. Obs. = 536

Voraussetzungschecks

Übung: Suchen Sie die Befehle und führen Sie sie aus:

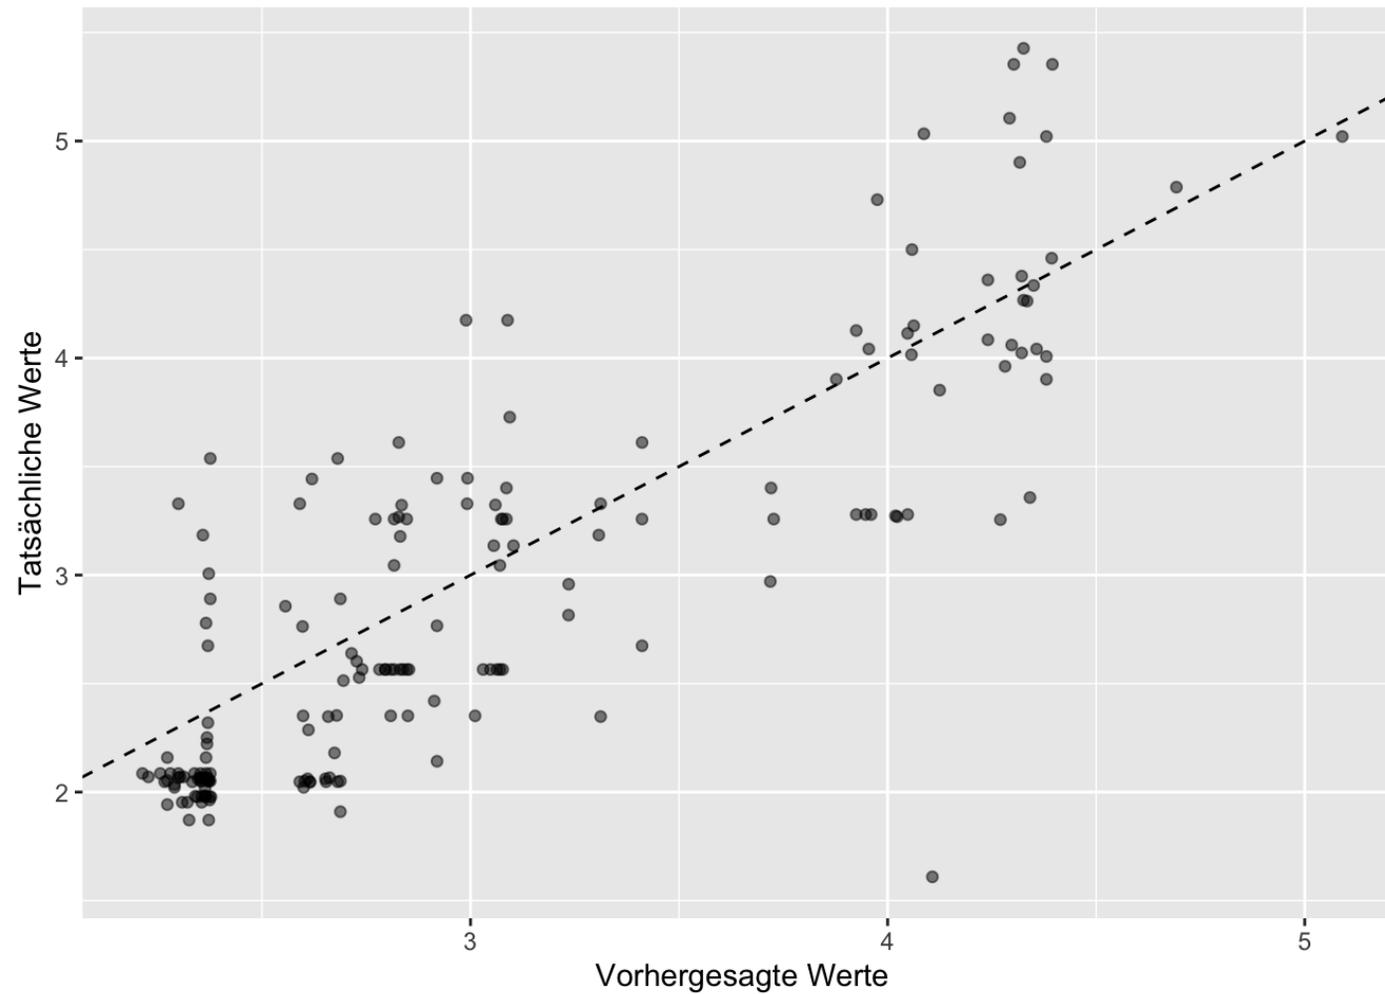
Die möglichen Verletzungen der Voraussetzungen sind:

- Multikollinearität
- Deutliche Abweichung von der Normalverteilung in den Fehlern
- Heteroskedastizität
- Outlier

Algorithmus für den Fahrpreis

Prognosewerte erstellen:

► Code



Überlebensprognose

Zweite Analyse: Überlebensprognose (Dummy) mit linearer Regression. Was denken Sie?

► Code

term	estimate	std.error	statistic	p.value
(Intercept)	0.579	0.038	15.427	<0.001
Pclass_f2	0.180	0.042	4.285	<0.001
Pclass_f1	0.376	0.043	8.772	<0.001
Sexmale	-0.508	0.035	-14.392	<0.001
Age_z	-0.003	0.002	-1.464	0.144
I(Age_z^2)	0.000	0.000	-0.184	0.854
KinderTRUE	0.125	0.103	1.217	0.224

► Code

r.squared	adj.r.squared	sigma	statistic	p.value	df	logLik	AIC	BIC	deviance	df.residual	nobs
0.403	0.397	0.382	59.587	<0.001	6	-241.157	498.314	532.587	77.177	529	536

Logistische Regression

► Code

term	estimate	std.error	statistic	p.value
(Intercept)	0.235	0.221	1.065	0.287
Pclass_f2	1.130	0.286	3.946	<0.001
Pclass_f1	2.158	0.287	7.518	<0.001
Sexmale	-2.703	0.244	-11.087	<0.001
KinderTRUE	1.173	0.373	3.142	0.002

► Code

null.deviance	df.null	logLik	AIC	BIC	deviance	df.residual	nobs
724.287	535	-241.935	493.871	515.291	483.871	531	536

Kennwerte

Übung: Interpretieren Sie den Output

► Code

Überlebensanalyse zum Titanicunglück mit sjPlot

Survived			
<i>Predictors</i>	<i>Odds Ratios</i>	<i>CI</i>	<i>p</i>
(Intercept)	1.27	0.82 – 1.96	0.287
Pclass f [2]	3.10	1.77 – 5.47	<0.001
Pclass f [1]	8.65	4.99 – 15.41	<0.001
Sex [male]	0.07	0.04 – 0.11	<0.001
KinderTRUE	3.23	1.56 – 6.78	0.002
Observations	536		
R ² Tjur	0.404		

Wieder auch mit `gtsummary` :

► Code

Überlebensanalyse zum Titanicunglück mit `gtsummary`

Characteristic	OR ¹	95% CI ¹	p-value	GVIF ¹	Adjusted GVIF ^{2,1}
Pclass_f				1.2	1.0
3	—	—			
2	3.10	1.77, 5.47	<0.001		
1	8.65	4.99, 15.4	<0.001		
Sex				1.1	1.0
female	—	—			
male	0.07	0.04, 0.11	<0.001		
Kinder				1.1	1.0
FALSE	—	—			
TRUE	3.23	1.56, 6.78	0.002		

¹ OR = Odds Ratio, CI = Confidence Interval, GVIF = Generalized Variance Inflation Factor

² $GVIF^{1/(2*df)}$

Null deviance = 724; Null df = 535; Log-likelihood = -242; AIC = 494; BIC = 515; Deviance = 484; Residual df = 531; No. Obs. = 536

Voraussetzungschecks

Übung: Führen Sie die Checks für die Voraussetzungen aus!

Vorhersagetest

Was sagt dieser Test?

► Code

Take Home – Ausblick – Vokabeln



Take Home

Logistische Regression

- Sie können eine logistische Regression in R rechnen und interpretieren
- Sie können Machine Learning in R anwenden

Ausblick

Sie lernen Clusteranalysen kennen. Wie man also Gruppen anhand von Eigenschaften identifiziert