

**1. Je 1 Punkt.**

- 1) c
- 2) a
- 3) a
- 4) a
- 5) b
- 6) d
- 7) c
- 8) d

- 2. a)** Der Effekt von  $x$  auf  $y$  ist verschieden in den beiden Gruppen (0.5 P): Der Achsenabschnitt und die Steigung unterscheiden sich in den beiden Gruppen. (0.5 P) **(1 Punkt)**
- b)** Die Variablen  $x$  und  $z$  sind stark positiv korreliert. Für  $z = 0$  nimmt  $x$  kleinere Werte an als für  $z = 1$ . **(1 Punkt)**
- c)** Model mit Interaktion zwischen  $x$  und  $z$ . (0.5 P)  $y = \beta_0 + \beta_1x + \beta_2z + \beta_3xz + \epsilon$  (0.5 P) **(1 Punkt)**
- d)** Für die Gruppe  $z = 0$ :

$$y = 1.312 + 1.09x.$$

(0.5 P) Für die Gruppe  $z = 1$ :

$$y = (1.312 - 1.253) + (1.09 - 0.352)x = 0.059 + 0.738x.$$

(0.5 P) **(1 Punkt)**

- e)** Nein ist es nicht, denn die Interaktion  $x : z$  im Model ist nicht signifikant. **(1 Punkt)**
- f)** bei adjusted R-squared (0.5 P), bei F-statistic (0.5 P), bei Residual standard error (0.5 P), wenn multiple R-squared genannt wird (-0.5 P) maximal(**(1 Punkt)**) minimal(**(0 Punkte)**)
- 3. a)**
- i. Falsch. Der zugehörige 5%-Test akzeptiert die Nullhypothese  $\beta_1 = 0$ , da 0 im 95%-Vertrauensbereich liegt; dies gilt daher erst Recht für den 1%-Test. **(1 Punkt)**
  - ii. Richtig.  $R^2$  hängt von der Streuung der Fehler in der Zielvariable ab. Bei verschiedenen Datensätzen könnte diese unterschiedlich sein. **(1 Punkt)**
  - iii. Falsch. Wenn mehr Parameter geschätzt werden müssen, ist i.A. auch die Varianz der Prognose grösser. Bei einfacheren Modellen ist der Bias i.A. natürlich grösser; es muss also eine geeignete Balance zwischen Bias und Varianz der Prognose gefunden werden. **(1 Punkt)**
  - iv. Richtig.  $x*y = x + y + x:y$ . Da  $x^2 = x:x = x$  gilt  $(x + y)^2 = x + x:y + y$ . **(1 Punkt)**
  - v. Richtig. Das kann passieren wenn die erklärenden Variablen stark korreliert sind.
- b)**  $\hat{Y}|X = x \sim \text{Poisson}(\hat{\beta}x)$ , daher ist die geschätzte Varianz einer neuen Beobachtung an der Stelle  $x = 3$  gegeben durch  $e^{\hat{\beta}x} = e^{1.8 \cdot 3} = e^{5.4} = 221.4064 \approx 221.41$ . **(1 Punkt)**
- c)** In einem gesättigten Modell sind alle Residuen = 0. Der Residual Standard Error wird daher auf 0 geschätzt. **(1 Punkt)**

- d) Das adjusted  $R^2$  lässt sich berechnen mit der Formel  $adjR^2 = 1 - \frac{n-1}{p} \cdot \frac{R^2}{F} = 1 - \frac{9}{5} \cdot \frac{0.86}{20.5} = 0.9244878 \approx 0.924$

4. a) (1 Punkt)

$$\log\left(\frac{p}{1-p}\right) = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3$$

- b) (2 Punkt) Das relevante Quantil für einen zweiseitigen  $z$ -Test mit Niveau 5% ist 1.96. Daher ist der Koeffizient von  $x_3$  (1P) und der Intercept (1P) signifikant von 0 verschieden.

- c) (1 Punkt)  $n = df_{Resid} + p = 20$

- d) (1 Punkt) Die gesuchte Odds Ratio beträgt  $\exp(\hat{\beta}_2) = 1.758267$ .

- e) (2 Punkte)  $\text{logit}(\hat{p}) = -15.5543 - 0.5859 \cdot 3 + 0.5643 \cdot 25 + 1.9639 \cdot 2 = 0.7239306$

$$\hat{p} = \frac{\exp(0.7239306)}{1 + \exp(0.7239306)} = 0.673472 \approx 0.673 \text{ (1P)}$$

Daher prognostiziert man  $\hat{y} = 1$  (1P).

- f) (2 Punkt) Damit die Wahrscheinlichkeit, dass  $y = 1$ , genau 50% (also  $p = 0.5$ ) beträgt, müssen die Log-Odds  $\eta = \log(p/(1-p)) = \log(1) = 0$  sein. Bei  $x_1 = 5$  und  $x_2 = 25$  erhalten wir aus der Modellgleichung

$$\eta = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3$$

die Gleichung

$$0 = -15.5543 - 0.5859 \cdot 5 + 0.5643 \cdot 25 + 1.9639 \cdot x_3 ,$$

(1P) was sich auflösen lässt zu  $x_3 = 2.228076 \approx 2.23$ . (1P)

- g) (2 Punkt) Das grössere Modell, da der AIC für dieses Modell kleiner ist.  $AIC = \text{Residual deviance} + 2 \cdot \text{number of parameters}$

grosses Modell  $AIC = 14.177 + 2 \cdot 4 = 22.177$  (1P)

kleines Modell  $AIC = 18.177 + 2 \cdot 3 = 24.158$  (1P)

5. a) Die Prävalenz von Lungenkrebs Toten nimmt mit dem Alter zu. (0.5P) Die Prävalenz ist höher für rauchende Personen. (0.5P) (1 Punkt)

- b) Wenn wir die Interaktion `smoke:age` noch ins Modell aufnehmen, hat das Modell mehr Parameter als Beobachtungen. Das heisst, dieses Modell wäre nicht identifizierbar. (1 Punkt)

- c) Die erwartete Anzahl von Todesfällen ist proportional zur Populationsgrösse. (1 Punkt)

- d)  $656 \cdot e^{-3.70919} = 16.07027 \approx 16.07$  (1 Punkt)

- e)  $e^{0.41044} = 1.507481 \approx 1.51$  (1 Punkt)

- f)  $436 \cdot e^{-3.70919} \cdot e^{2.59447} \cdot e^{0.41044} = 215.5865 \approx 215.59$  (1 Punkt)

- g) Nein es ist nicht plausibel. Ein 95% Vorhersageintervall für eine  $Pois(\lambda)$ -verteilte Zufallsvariable ist approximativ gegeben durch

$$[\lambda - 1.96 \cdot \sqrt{\lambda}, \lambda + 1.96 \cdot \sqrt{\lambda}]$$

für grosses  $\lambda$ . Wenn wir nun unsere Schätzung für  $\lambda$ ,  $\hat{\lambda} \approx 215.59$ , einsetzen erhalten wir das Intervall  $[186.8114, 244.3686] \approx [186, 244]$ . (1P) Ein 95% Vorhersageintervall für die Zahl in f) muss mindestens so gross sein da wir auch noch die Unsicherheit der Parameterschätzung beachten müssen. (1P) (2 Punkte)