

### Aufgabenblatt 14 (30.6.2011)

1. Es gibt folgende Daten:  $S$  = Geschlecht,  $X$  = Bildungsniveau,  $Y$  = Arbeitslohn.

$S$	$X$	$Y$
0	1	1000
0	2	1500
0	3	1700
0	4	1700
0	5	2000
0	5	2500
0	7	2200
0	7	2600
0	8	2200
0	8	2500
1	1	500
1	2	700
1	3	500
1	3	1000
1	4	1000
1	5	800
1	6	1200
1	7	1300
1	7	1200
1	8	1100
1	8	1200

Eine lineare Regression liefert

$$M(Y|X = x, S = s) = 1088.2 + 180.4x - 613.6s - 82.6xs$$

- Zeichnen Sie die Daten in ein Streuungsdiagramm ein.
- Leiten Sie zwei separate Regressionsfunktionen für  $S = 0$  und  $S = 1$  ab und zeichnen Sie diese Funktionen in das Streuungsdiagramm ein.

2. Es gibt folgende Daten für drei statistische Variablen:  $X$  (Bildungsniveau),  $Y$  (Höhe des Arbeitseinkommens) und  $Z$  (Indikator für Gruppe).

$X$	$Y$	$Z$
2	2000	0
3	3000	0
3	3200	0
2	2500	0
2	2800	0
4	4000	0
4	1000	1
5	2000	1
5	2200	1
4	1500	1
4	1700	1
6	2900	1

Man findet folgende Regressionsfunktionen:

$$M(Y|X = x) = 2635.7 - 64.3x$$

$$M(Y|X = x, Z = z) = 890.0 + 760.0x - 2460.0z - 20.0xz$$

- Zeichnen Sie die Daten in ein Streuungsdiagramm ein.
  - Berechnen Sie die gesonderten Regressionsgeraden für  $Z = 0$  und  $Z = 1$ .
  - Zeichnen Sie die gemeinsame und die beiden separaten Regressionsgeraden in das Streuungsdiagramm ein.
  - Berechnen und interpretieren Sie exemplarisch:  $M(Y|X = 2)$ ,  $M(Y|X = 2, Z = 0)$ ,  $M(Y|X = 2, Z = 1)$  und  $M(Y|X = 3)$ ,  $M(Y|X = 3, Z = 0)$ ,  $M(Y|X = 3, Z = 1)$ .
  - Erläutern Sie, inwiefern es sich um ein Beispiel für Simpsons Paradox handelt.
3. Durch  $Y$  wird die Lohnhöhe, durch  $X$  das Geschlecht erfasst ( $X = 0$  bei Männern,  $X = 1$  bei Frauen). Ein lineares Regressionsmodell liefert:  $M(Y|X = x) = 1300 - 300x$ .
- Welches Regressionsmodell würde sich ergeben, wenn man die Kodierung der  $X$ -Variablen umkehrt (Männer = 1, Frauen = 0)?
  - Welches Regressionsmodell würde sich ergeben, wenn man die Kodierung der  $X$ -Variablen folgendermaßen verändert: Männer = 1, Frauen = 2?
  - Welches Regressionsmodell würde sich ergeben, wenn man die Kodierung der  $X$ -Variablen folgendermaßen verändert: Männer = -1, Frauen = +1?

**Tabelle 1** Datensatz zur Erwerbsbeteiligung verheirateter Frauen in 1971 (Arminger, 1983).

$X$	$Y$	$Z$	$N$	$M$	$X$	$Y$	$Z$	$N$	$M$
1	1	450	32	16	3	2	1000	14	9
1	2	450	96	52	3	3	1000	15	13
1	3	450	57	43	1	1	1500	207	100
2	1	450	16	5	1	2	1500	1246	927
2	2	450	35	13	1	3	1500	1126	1022
2	3	450	26	17	2	1	1500	617	178
1	1	700	383	132	2	2	1500	2036	1581
1	2	700	1155	640	2	3	1500	2420	2118
1	3	700	793	607	3	1	1500	23	10
2	1	700	217	47	3	2	1500	51	39
2	2	700	461	260	3	3	1500	109	95
2	3	700	364	265	1	1	2000	32	16
3	1	700	3	1	1	2	2000	162	143
3	3	700	1	0	1	3	2000	153	147
1	1	1000	845	329	2	1	2000	199	106
1	2	1000	4398	2925	2	2	2000	820	722
1	3	1000	3359	2838	2	3	2000	960	908
2	1	1000	913	242	3	1	2000	23	16
2	2	1000	2926	1874	3	2	2000	102	94
2	3	1000	2877	2384	3	3	2000	217	209
3	1	1000	13	1					

4. Durch  $Y$  wird die Lohnhöhe, durch  $X$  das Geschlecht und durch  $Z$  das Alter erfasst. Bilden Sie zwei lineare Regressionsmodelle für  $M(Y|X = x, Z = z)$ , einmal ohne, einmal mit einem Interaktionseffekt der beiden Regressorvariablen. Erklären Sie, warum die Einbeziehung eines Interaktionseffekts sinnvoll sein kann.
5. Es sei  $X$  eine qualitative Variable mit den Werten 1 (vollzeit beschäftigt), 2 (teilzeit beschäftigt), 3 (arbeitslos), 4 (nicht mehr im Erwerbsleben). Außerdem wird durch  $Y$  das Einkommen, durch  $Z$  das Geschlecht ( $M = 0$ ,  $F = 1$ ) erfasst.
- a) Definieren und beschreiben Sie die Dummy-Variablen, durch die man  $X$  erfassen kann.
- b) Es seien folgende Mittelwerte gegeben:

$X$	$M(Y X = x)$
1	2400
2	1900
3	1200
4	1600

**Tabelle 2** Parameterwerte für das Logitmodell.

Variable	Parameter	Wert
	$\hat{\alpha}$	1.2030
$X_2$	$\hat{\beta}_1$	0.1638
$X_3$	$\hat{\beta}_2$	-0.0089
$Y_2$	$\hat{\beta}_3$	-1.4531
$Y_3$	$\hat{\beta}_4$	-2.4119
$Z_2$	$\hat{\beta}_5$	-0.0679
$Z_3$	$\hat{\beta}_6$	-0.4847
$Z_4$	$\hat{\beta}_7$	-0.9392
$Z_5$	$\hat{\beta}_8$	-1.7951

Formulieren Sie ein lineares Regressionsmodell für  $M(Y|X = x)$  mit Hilfe der Dummy-Variablen und geben Sie die Parameterwerte an.

- c) Bilden Sie zwei lineare Regressionsmodelle für  $M(Y|X = x, Z = z)$ , wobei  $X$  durch Dummy-Variablen erfasst wird, einmal ohne, einmal mit einem Interaktionseffekt der Regressorvariablen.
6. Die Variablen für die Daten in Tabelle 1 haben folgende Bedeutung:  $X$  Schulbildung (1 = nur Volksschule, 2 = mittlere Ausbildung, 3 = höhere Ausbildung);  $Y$  Kinder (1 = keine Kinder, 2 = Kinder älter als 6 Jahre, 3 = Kinder jünger als 6 Jahre);  $Z$  Einkommen des Mannes.  $N$  gibt die Gesamtzahl der Frauen,  $M$  die Anzahl der davon erwerbstätigen Frauen an. Weiterhin wird eine Variable  $B$  verwendet, die den Wert 1 hat, wenn eine Frau erwerbstätig ist, und die andernfalls den Wert 0 hat.
- a) Berechnen und interpretieren Sie  $P(B = 1|X = 2, Y = 3, Z = 1000)$ .
- b) Berechnen und interpretieren Sie  $P(B = 1|X = 2, Y = 3, Z = 1000) - P(B = 1|X = 2, Y = 2, Z = 1000)$ .
- c) Bilden (definieren und beschreiben) Sie für  $X$  drei Dummy-Variablen.
- d) Bilden (definieren und beschreiben) Sie für  $Y$  drei Dummy-Variablen.
- e) Bilden (definieren und beschreiben) Sie für  $Z$  fünf Dummy-Variablen.
- f) Betrachten Sie ein Logit-Modell

$$\hat{P}(B = 1|\dots) = \frac{\exp(v)}{1 + \exp(v)}$$

wobei  $v$  durch

$$v = \alpha + x_2\beta_1 + x_3\beta_2 + y_2\beta_3 + y_3\beta_4 + x_2\beta_5 + z_3\beta_6 + z_4\beta_7 + z_5\beta_8$$

definiert ist. Tabelle 2 zeigt Parameterwerte für das mit den Daten aus Tabelle 1 geschätzte Modell.

- g) Berechnen Sie einerseits mit dem Modell und andererseits mit den Daten in Tabelle 1 Werte für die Anteile erwerbstätiger Frauen für folgende Konstellationen der Regressorvariablen:  $X=1, Y=1, Z=1$ ; und  $X=2, Y=2, Z=1, 2, 3, 4, 5$ ; und  $X=2, Y=3, Z=1, 2, 3, 4, 5$ . Interpretieren Sie die Ergebnisse.
- h) Erklären Sie, warum sich  $P(B = 1 | \dots)$  und  $\hat{P}(B = 1 | \dots)$  bei gleichen Werten der Regressorvariablen unterscheiden.