

Prüfung im Fach Ökonometrie im WS 2012/13

Aufgabe 1 (17 Punkte)

Mit einer Regression wird die tägliche Schlafdauer in Stunden in Abhängigkeit von erklärenden Merkmalen geschätzt. Für die Beobachtungen $i = 1, \dots, N$ stellen Sie folgendes Modell auf:

$$sleep_i = \beta_1 + \beta_2 \cdot workhours_i + \beta_3 \cdot m_workhours_i + \beta_4 \cdot male_i + \beta_5 \cdot city_i + \beta_6 \cdot youngkid_i + \varepsilon_i$$

In den folgenden Tabellen finden Sie sowohl deskriptive Statistiken als auch die Regressionsergebnisse.

Variable	Mittelwert	Std. Abw.	Min.	Max.	Beschreibung
<i>sleep</i>	7.78	1.06	1.80	11.18	Tägliche Schlafdauer in Stunden
<i>workhours</i>	5.05	2.26	0	15.27	Tägliche Arbeitszeit in Stunden
<i>m_workhours</i>	3.28	3.25	0	15.27	Interaktionsterm: <i>male</i> · <i>workhours</i>
<i>male</i>	0.56	0.50	0	1	=1, falls Mann, =0, falls Frau.
<i>city</i>	0.40	0.49	0	1	=1, falls in Großstadt wohnen, 0 sonst.
<i>youngkid</i>	0.13	0.34	0	1	=1, falls Person Kinder jünger als 3 Jahre hat, 0 sonst.

Source	SS	df	MS			
Model	96.1511501	5	19.23023	Number of obs =	706	
Residual	693.190306	700	.990271865	F(5, 700) =	19.42	
Total	789.341456	705	1.11963327	Prob > F =	0.0000	
				R-squared =	??????	
				Adj R-squared =	??????	
				Root MSE =	.99512	

	sleep	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
<i>workhours</i>		-.1420164	.0261594	-5.43	0.000	-.1933768	-.0906561
<i>m_workhours</i>		-.0539565	.0124899	-4.32	0.000	-.0784367	-.0294763
<i>male</i>		.4859738	.1939993	2.51	0.012	.1050837	.8668639
<i>city</i>		-.1839444	.0767387	-2.40	0.017	-.3346099	-.0332788
<i>youngkid</i>		-.0739644	.1127516	-0.66	0.512	-.2953362	.1474074
<i>_cons</i>		8.479748	.1257961	67.41	0.000	8.232765	8.726731

1.1 Interpretieren Sie den geschätzten Koeffizienten der Variable *city* statistisch und inhaltlich. (1.5 Punkte)

- Statistisch: der geschätzte Koeffizient von *city* ist auf dem 5%-Niveau statistisch signifikant von Null verschieden, nicht aber auf dem 1%-Niveau.
- Inhaltlich: Personen, die in einer Großstadt wohnen, schlafen c.p. im Durchschnitt 0.18 Stunden pro Tag weniger als Personen, die nicht in einer Großstadt wohnen.

1.2 Berechnen und interpretieren Sie das Bestimmtheitsmaß. Geben Sie den Wert des korrigierten Bestimmtheitsmaßes an. (3 Punkte)

- $R^2 = 96.15/789.34 = 0.1218$. Das Modell erklärt 12.18% der Variation der abhängigen Variable *sleep*.
- $\bar{R}^2 = 1 - [(1/700) \cdot 693.19] / [(1/705) \cdot 789.34] = 0.1155$.

1.3 Berechnen Sie die vorhergesagte Schlafdauer in Stunden für Männer, die in einer Großstadt leben, täglich 5 Stunden arbeiten und keine Kinder jünger als 3 Jahre haben. Runden Sie alle Werte auf die zweite Nachkommastelle. (2 Punkte)

Die vorhergesagte Schlafdauer mit den angegebenen Merkmalen beträgt $8.48 + (-0.14 - 0.05) \cdot 5 + 0.49 - 0.18 = 7.84$ Stunden.

1.4 Testen Sie mit einer Irrtumswahrscheinlichkeit von $\alpha = 0.01$, ob der Zusammenhang zwischen Arbeitszeit und Schlafdauer für Männer und Frauen unterschiedlich ist. Geben Sie hierfür Hypothesen, Teststatistik, kritischen Wert und Testentscheidung an. (3.5 Punkte)

- Hypothesen: $H_0 : \beta_3 = 0, H_1 : \beta_3 \neq 0$
- Teststatistik: $t^{emp} = \frac{-0.0539565}{0.0124899} = -4.32$
- Kritischer Wert: $t_{1-\frac{\alpha}{2}, N-K}^{krit} = t_{0.995, 700}^{krit} = 2.576$
- Testentscheidung: Da $4.32 = |t^{emp}| > t^{krit} = 2.576$ wird die Nullhypothese auf dem 1%-Niveau verworfen. Der Effekt der Arbeitszeit auf die Schlafdauer ist für Männern stärker als für Frauen ($b_3 < 0$).

1.5 Erläutern Sie formal, welches Problem auftritt, wenn Sie zusätzlich die Dummyvariablen *nokid* (=1, falls Person keine Kinder hat, =0 sonst) und *olderkid* (=1, falls Person Kind von mindestens 3 Jahren hat, =0 sonst) in das Regressionsmodell einfügen. Was bedeutet das für den KQ-Schätzer? (2 Punkte)

- Problem der perfekten Multikollinearität: Linearkombination der Dummyvariablen *youngkid*, *nokid*, *oldkid* ergibt die Konstante.
- Da die Matrix $\mathbf{X}'\mathbf{X}$ nicht mehr den vollen Rang besitzt, kann der KQ-Schätzer nicht berechnet werden.
- (STATA lässt folglich eine der Dummyvariablen aus.)

1.6 Führen Sie einen RESET-Test unter Verwendung von Polynomen 2., 3., 4. und 5. Grades mit einer Irrtumswahrscheinlichkeit von 5% durch. Beschreiben Sie Ihr Vorgehen, indem Sie Hilfsregression, Hypothesen, Teststatistik, Entscheidungsregel und Testentscheidung angeben. *Hinweis* : Verwenden Sie $S_1 = 691.842$ als Fehlerquadratsumme des unrestringierten Modells. (5 Punkte)

- Die Teststatistik basiert auf folgender Hilfsregression:

$$y_i = \mathbf{x}_i' \boldsymbol{\beta} + \alpha_2 \hat{y}_i^2 + \alpha_3 \hat{y}_i^3 + \alpha_4 \hat{y}_i^4 + \alpha_5 \hat{y}_i^5 + v_i$$

- Hypothesen: $H_0 : \alpha_2 = \alpha_3 = \alpha_4 = \alpha_5 = 0, H_1 : \text{mindestens ein } \alpha_j \neq 0 \text{ mit } j = 2, 3, 4, 5$
- Teststatistik:

$$F^{emp} = \frac{(S_0 - S_1)/J}{S_1/(N - K)}$$

- Entscheidungsregel: H_0 verwerfen, falls $F^{emp} > F_{J, N-K, 0.05}^{krit} = F_{4, 706-6-4, 0.05}^{krit} = 2.38$
- Berechnung:

$$F^{emp} = \frac{(693.190 - 691.842)/4}{691.842/696} = 0.339$$

- Testentscheidung: Da $0.339 = F^{emp} < F_{4, 696, 0.05}^{krit} = 2.38$ kann die Nullhypothese auf dem 5%-Niveau nicht verworfen werden. Das Modell ist nicht fehlspezifiziert.

Aufgabe 2 (15 Punkte)

Sie interessieren sich für die Determinanten der monatlichen Ausgaben für Luxusgüter. Ihnen steht ein Datensatz mit 284 Personen zur Verfügung, welcher folgende Informationen beinhaltet:

Variable:	Beschreibung:
<i>luxus</i>	Monatliche Ausgaben für Luxusgüter (in 1000 €)
<i>lnEK</i>	Monatliches Einkommen in € (logarithmiert)
<i>alter</i>	Alter in Jahren
<i>mann</i>	Mann (=1, falls Person männlich, =0, falls Person weiblich.)

Sie führen eine KQ-Schätzung durch und erhalten folgenden STATA-Output:

Source	SS	df	MS	Number of obs = 284		
Model	549.268697	3	183.089566	F(3, 280)	=	165.99
Residual	73.9011373	67	1.10300205	Prob > F	=	0.0000
Total	623.169834	70	8.9024262	R-squared	=	0.8814
				Adj R-squared	=	0.8761
				Root MSE	=	1.0502

luxus	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
lnEK	1.038118	.0478108	21.71	0.000	.9426876	1.133549
alter	0.028573	.0094614	3.02	0.004	.0096998	.0474699
mann	-.0856857	.0321444	-2.67	0.010	-.1498462	-.0215251
_cons	-.1350778	.1272177	-1.06	0.292	-.3890054	.1188498

2.1 Interpretieren Sie den geschätzten Koeffizienten von *lnEK* inhaltlich. (1 Punkt)

- Inhaltlich: Steigt das monatliche Einkommen um 1%, so steigen die monatlichen Ausgaben für Luxusgüter c.p. im Durchschnitt um $(1.038/100) \cdot 1000€ = 10.38€$.

2.2 Erläutern Sie, weshalb bezüglich *lnEK* ein Heteroskedastie-Problem vorliegen könnte. (2 Punkte)

Mögliche Lösung: Es wäre vorstellbar, dass Personen, die vergleichsweise wenig Einkommen erzielen, ähnliche (nämliche niedrigere) Ausgaben für Luxusgüter aufweisen. Zugleich könnten Personen, die viel Einkommen erzielen, im Hinblick auf *luxus* sehr heterogen sein. In diesem Fall würde $Var(luxus|lnEK, \mathbf{x}) = Var(\epsilon|lnEK, \mathbf{x})$ mit steigendem *lnEK* zunehmen.

2.3 Erläutern Sie das Vorgehen beim Breusch-Pagan Test. Gehen Sie dabei auf Hypothesen, Teststatistik, Hilfsregression und Schlußlogik ein. (4 Punkte)

- Hypothesen: $H_0: Var(\epsilon_i) = \sigma^2$ (Homoskedastie), $H_1: Var(\epsilon_i) = \sigma_i^2$ (Heteroskedastie)
- Teststatistik:

$$N \cdot R^2 \sim \chi_K^2$$
 wobei N (Anzahl der Beobachtungen) und R^2 aus einer Hilfsregression stammen.
- Hilfsregression: $e_i^2 = \alpha_1 + \alpha_2 lnEK_i + \alpha_3 alter_i + \alpha_4 mann_i + v_i$
- Schlußlogik: ist $\chi_{emp}^2 > \chi_{krit}^2$, so kann die Nullhypothese verworfen werden.

2.4 Nach der Schätzung führen Sie einen Breusch-Pagan Test auf Heteroskedastie durch.

```
Breusch-Pagan / Cook-Weisberg test for heteroskedasticity
Ho: Constant variance
Variables: ln_EK alter mann

chi2(3)      =    15.55
Prob > chi2  =    0.0014
```

Interpretieren Sie das Ergebnis kurz. (1 Punkt)

Es liegt Heteroskedastie vor, da der p-Wert kleiner als 0.01 ist. Die Nullhypothese kann somit auf dem 1%-Niveau verworfen werden.

2.5 Erläutern Sie die Schritte des FGLS-Verfahrens, um das Heteroskedastie-Problem zu lösen, wenn Sie davon ausgehen, dass die Varianz der Störterme eine Funktion von $\ln EK$ ist. (4 Punkte)

- Problem: die funktionale Form der Heteroskedastie ist nicht bekannt und muss geschätzt werden ($\text{Var}(\boldsymbol{\varepsilon}|\mathbf{x}) = \sigma^2 \cdot h(\mathbf{x})$).
- 1. Man schätzt die Regression, z.B. $y_i = \mathbf{x}'_i \boldsymbol{\beta} + \varepsilon_i$, und erhält die Residuen e_i für jede Beobachtung.
- 2. Man schätzt ein parametrisches Modell der quadrierten Residuen als Funktion von $\ln EK$.
- 3. Die vorhergesagten Werte werden für die Transformation des Modell genutzt.
- 4. Man schätzt das Hauptmodell auf die transformierten Variablen.

2.6 Erläutern Sie ausgehend von der Formel $\text{Var}(\mathbf{b}|\mathbf{X}) = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\text{Diag}\{\sigma_i^2\}\mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}$ kurz die Idee von White (1980) zur Berechnung robuster Standardfehler und legen Sie dar, wie diese durchgeführt wird. (3 Punkte)

- Die Matrix $\text{Diag}\{\sigma_i^2\}$ kann nicht ohne zusätzliche Annahmen geschätzt werden, da sie N unbekannte Parameter σ_i^2 enthält.
- Die Idee von White (1980) ist, stattdessen die $[K \times K]$ -Matrix $\mathbf{X}'\text{Diag}\{\sigma_i^2\}\mathbf{X}$ konsistent mit Hilfe der Residuen (d.h. mit $\sum_{i=1}^N e_i^2 \mathbf{x}_i \mathbf{x}'_i$) zu schätzen.
- Die Wurzeln der Diagonalelemente der auf diese Weise geschätzten Kovarianzmatrix der Schätzer werden als robuste Standardfehler bezeichnet.

Aufgabe 3 (17 Punkte)

3.1 Definieren Sie verbal, was unter Autokorrelation zu verstehen ist und welche Gauß-Markow Annahme verletzt wird. (1 Punkt)

Unter Autokorrelation versteht man eine Situation, in der die Störterme miteinander korrelieren. Die Gauß-Markow Annahme 4, $\text{cov}(\varepsilon_i, \varepsilon_j) = 0$ für alle $i \neq j$, ist verletzt.

3.2 Zeigen Sie formal, ob sich Autokorrelation auf die Unverzerrtheit des KQ-Schätzers auswirkt. Gehen Sie von deterministischen X aus. (3 Punkte)

Für deterministische X gilt:

$$E[\mathbf{b}] = E[(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{y}] = E[(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{X}\boldsymbol{\beta} + (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\boldsymbol{\epsilon}] = E[\boldsymbol{\beta} + (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\boldsymbol{\epsilon}] = \boldsymbol{\beta} + E[(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'] \cdot E[\boldsymbol{\epsilon}]$$

$$= \boldsymbol{\beta} + (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}' \cdot E[\boldsymbol{\epsilon}] = \boldsymbol{\beta}$$

Solange $E[\boldsymbol{\epsilon}] = \mathbf{0}$ gilt, beeinflusst Autokorrelation die Unverzerrtheit des KQ-Schätzers nicht.

Sie interessieren sich für die Determinanten von Immobilienpreisen. Ihnen liegt ein US-amerikanischer Datensatz für die Jahre 1947-1988 mit folgenden Variablen vor:

Variable:	Beschreibung:
<i>lprice</i>	Realer Hauspreis (in US-Dollar, logarithmiert)
<i>t</i>	Zeittrend in Jahren: $t=1, \dots, 42$
<i>inv</i>	Reales Investitionsvolumen in Immobilien (in Millionen US-Dollar)
<i>pop</i>	Bevölkerung (in 1000)

Mittels KQ-Verfahren schätzen Sie folgendes Modell:

$$\ln price_t = \beta_1 + \beta_2 t + \beta_3 inv_t + \beta_4 pop_t + \epsilon_t$$

Source	SS	df	MS	Number of obs =	42
Model	.136717016	3	.045572339	F(3, 38) =	60.85
Residual	.02846113	38	.000748977	Prob > F =	0.0000
Total	.165178146	41	.004028735	R-squared =	0.8277
				Adj R-squared =	0.8141
				Root MSE =	.02737

	lprice	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
t		.0329951	.0061595	5.36	0.000	.0205257 .0454644
inv		-4.16e-07	2.68e-07	-1.55	0.128	-9.58e-07 1.26e-07
pop		0.0000111	2.43e-06	4.59	0.000	.0000161 6.22e-06
_cons		1.439702	.3525777	4.08	0.000	.7259455 2.153458

3.3 Interpretieren Sie den geschätzten Koeffizienten der Variable *t* inhaltlich. (1 Punkt)

- Inhaltlich: Mit jedem zusätzlichen Jahr steigt der Hauspreis c.p. im Mittel um ca. 3.29%.

3.4 Nennen Sie zwei Gründe dafür, dass Autokorrelation in diesem Fall vorliegen könnte (d.h. der Autokorrelationskoeffizient $\rho \neq 0$). (1.5 Punkte)

- Ausgelassene Variable, z.B. Hauspreise unterliegen den Schwankungen des Wirtschaftswachstums, welches nicht in der Regression vorkommt.
- Fehlspezifikation, z.B. der Zeittrend muss nicht linear im Modell berücksichtigt werden.
- (auch andere Nennungen möglich).

3.5 Beschreiben Sie die Grundidee des Breusch-Godfrey Tests auf Autokorrelation 1. Ordnung. Führen Sie den Test am 1% Signifikanzniveau für das Modell durch. Geben Sie Hypothesen, Teststatistik, Hilfsregression und Entscheidungsregel an. Wie entscheiden Sie sich, basierend auf folgendem STATA-Output? (5.5 Punkte)

```
estat bgodfrey, lags(1)

Breusch-Godfrey LM test for autocorrelation
-----
      lags(p) |          chi2      df      Prob > chi2
-----+-----+-----
           1 |          23.100      1           ?
-----+-----+-----
                    H0: no serial correlation
```

Der Breusch-Godfrey Test untersucht, ob die verzögerten KQ-Residuen einen signifikanten Einfluss auf die KQ-Residuen haben.

- H_0 : Es liegt keine Autokorrelation 1. Ordnung vor: $\rho = 0$. H_1 : nicht H_0 .
- $\chi_{empirisch}^2 = (T - 1) \cdot R^2$ ist χ_1^2 verteilt, mit R^2 und $T - 1$ (Anzahl der Beobachtungen) aus der Hilfsregression.
- Hilfsregression (je nach Annahme bzgl. Exogenität der erklärenden Variablen: $e_t = \alpha_1 + \rho e_{t-1} + \alpha_2 t + \alpha_3 inv_t + \alpha_4 pop_t + v_t$ oder $\varepsilon_t = \rho \varepsilon_{t-1} + v_t$).
- Wenn $\chi_{empirisch}^2 > \chi_{kritisch}^2$ wird die Nullhypothese verworfen.
- Kritischer Wert: $\chi_{kritisch}^2 = \chi_1^2 = 6.635$
- Da $23.1 > 6.635$ wird die Nullhypothese verworfen. Es liegt wohl Autokorrelation vor.

3.6 In dem Modell $y_t = \beta_1 + \beta_2 x_t + \varepsilon_t$ folgt der Störterm einem autoregressiven Prozess zweiter Ordnung, d.h. $\varepsilon_t = \rho_1 \varepsilon_{t-1} + \rho_2 \varepsilon_{t-2} + v_t$ mit $E(v_t) = 0$ und $Var(v_t) = \sigma_v^2$. Zeigen Sie anhand dieses Beispiels formal die Vorgehensweise einer GLS-Transformation nach Cochrane-Orcutt. Wie ist die Konstante im transformierten Schätzmodell definiert? Wieviele Beobachtungen stehen zur Schätzung des transformierten Modells zur Verfügung? (5 Punkte)

- AR(2) Prozess: $\varepsilon_t = \rho_1 \varepsilon_{t-1} + \rho_2 \varepsilon_{t-2} + v_t$
- Für ε_t in Hauptgleichung einsetzen:
 $y_t = \beta_1 + \beta_2 x_t + \rho_1 \varepsilon_{t-1} + \rho_2 \varepsilon_{t-2} + v_t$
- Mit $\varepsilon_{t-1} = y_{t-1} - \beta_1 - \beta_2 x_{t-1}$, und $\varepsilon_{t-2} = y_{t-2} - \beta_1 - \beta_2 x_{t-2}$
- ε_{t-1} und ε_{t-2} einsetzen:
 $y_t = \beta_1 + \beta_2 x_t + \rho_1 (y_{t-1} - \beta_1 - \beta_2 x_{t-1}) + \rho_2 (y_{t-2} - \beta_1 - \beta_2 x_{t-2}) + v_t$
- Auflösen und Umstellen zu: $y_t - \rho_1 y_{t-1} - \rho_2 y_{t-2} = \beta_1 (1 - \rho_1 - \rho_2) + \beta_2 (x_t - \rho_1 x_{t-1} - \rho_2 x_{t-2}) + v_t$.
- Die Konstante ist wie folgt definiert: $\beta_1 (1 \cdot 1 - \rho_1 \cdot 1 - \rho_2 \cdot 1) = \beta_1 (1 - \rho_1 - \rho_2)$
- Das transformierte Modell kann für die Beobachtungen $3, \dots, T$ mit dem KQ-Verfahren geschätzt werden. Die ersten beiden Beobachtungen können nicht genutzt werden.

Aufgabe 4 (11 Punkte)

Sie schätzen den Zusammenhang zwischen Kindergesundheit und ausgewählten erklärenden Variablen mit einem binären Logit Modell. Die folgenden Tabellen präsentieren die deskriptiven Statistiken der verwendeten Variablen und die Schätzergebnisse.

Variable	Mittelwert	Std. Abw.	Min.	Max.	Beschreibung
<i>ghealth</i>	0.85	0.36	0	1	=1, falls Kind in guter Gesundheit, =0 sonst.
<i>lincome</i>	9.93	0.66	6.33	11.37	Reales Haushaltseinkommen (in €, logarithmiert)
<i>mage</i>	34.97	6.10	18	69	Alter der Mutter in Jahren
<i>male</i>	0.51	0.49	0	1	=1, falls Kind ein Junge ist, =0, falls Mädchen.
<i>lhhszise</i>	1.13	0.41	0	2.94	Haushaltsgröße (logarithmiert)

```

Logistic regression                                Number of obs   =    28743
                                                    LR chi2(4)      =    788.78
                                                    Prob > chi2     =    0.0000
Log likelihood = -11949.049                       Pseudo R2      =    0.0320

```

	ghealth	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
lincome		.6105914	.0276457	22.09	0.000	.5564069 .6647759
mage		.0143377	.0029246	4.90	0.000	.0086056 .0200699
male		-.2050511	.0332941	-6.16	0.000	-.2703064 -.1397958
lhhszise		-.4392864	.0404419	-10.86	0.000	-.5185511 -.3600217
_cons		-4.184366	.2467145	-16.96	0.000	-4.667918 -3.700814

4.1 Berechnen und interpretieren Sie den marginalen Effekt des Alters der Mutter auf die Kindergesundheit am Mittelwert der Kovariaten. Runden Sie alle Werte auf die dritte Nachkommastelle.

Hinweis: $\bar{\mathbf{x}}'\hat{\boldsymbol{\beta}} = 1.62$. (3 Punkte)

- ME im Logit Modell: $\frac{\exp(\bar{\mathbf{x}}'\hat{\boldsymbol{\beta}})}{(1+\exp(\bar{\mathbf{x}}'\hat{\boldsymbol{\beta}}))^2} \cdot \hat{\beta}_{mage} = \frac{\exp(1.62)}{(1+\exp(1.62))^2} \cdot 0.014 = 0.0019$
- Interpretation: Steigt das Alter der Mutter um ein Jahr, so steigt die Wahrscheinlichkeit, dass ein Kind in guter Gesundheit ist, c.p. im Mittel um 0.19 Prozentpunkte (bei durchschnittlichen Merkmalsausprägungen).

4.2 Berechnen Sie die Wahrscheinlichkeit, dass die Tochter einer Familie mit einem Haushaltseinkommen von 15000€ in guter Gesundheit ist, bei sonst durchschnittlichen Merkmalen. Interpretieren Sie Ihr Ergebnis.

Hinweis: $P(y_i = 1 | \mathbf{x}_i) = F(\mathbf{x}_i'\boldsymbol{\beta}) = \frac{\exp(\mathbf{x}_i'\boldsymbol{\beta})}{1+\exp(\mathbf{x}_i'\boldsymbol{\beta})}$. (3.5 Punkte)

- $\ln(15000) = 9.616$
- $P(y_i = 1 | \ln(\text{income}) = \ln(15000), \text{male} = 0, \bar{\mathbf{x}}) = F(-4.184 + 0.611 \cdot 9.616 + 0.014 \cdot 34.97 - 0.205 \cdot 0 - 0.439 \cdot 1.13) = F(1.685) = \frac{\exp(1.685)}{1+\exp(1.685)} = 0.844$
- Interpretation: Die Wahrscheinlichkeit, dass ein Mädchen einer Familie mit einem Haushaltseinkommen von 15000€ und sonst durchschnittlichen Merkmalsausprägungen in guter Gesundheit ist, liegt bei 84.4 Prozent.

4.3 Sie vermuten, dass die Gesundheit eines Kindes auch von der Gesundheit der Mutter abhängt. Sie nehmen die Variable zusätzlich in das Modell auf und erhalten nach erneuter Schätzung einen Log-Likelihood Wert von -11233.995. Testen Sie am 5% Signifikanzniveau, ob sich der Erklärungsgehalt des Modells verbessert hat. Nennen Sie Testverfahren, Hypothesen, Teststatistik, Entscheidungsregel und Testentscheidung. (4.5 Punkte)

- Testverfahren: LR-Test
- Hypothesen: H_0 : Steigungsparameter für Muttergesundheit = 0. H_1 : nicht H_0
- Teststatistik: $\xi_{LR} = -2[\ln(\tilde{\theta}) - \ln(\hat{\theta})] \sim \chi^2_j$
- Entscheidungsregel: H_0 verwerfen, falls $\xi_{LR} > \chi^2_{j=1; \alpha=0.05} = 3.84$.
- Berechnung: $\xi_{LR} = -2[-11949.049 - (-11233.995)] = 1430.108$
- Entscheidung: H_0 wird verworfen. Die neu aufgenommene Variable (Gesundheit der Mutter) enthält Informationen zur Erklärung der Kindergesundheit und verbessert den Erklärungsgehalt des Modells.

Aufgabe 5 - MC Fragen (30 Punkte)

Welche Antwort ist richtig? Kreuzen Sie nur eine Antwort pro Aufgabe an. Falls mehrere Aussagen korrekt sind, kreuzen Sie nur die entsprechende Antwortkombination an. Für jede richtige Antwort gibt es 1 Punkt. Für falsche Antworten werden keine Punkte abgezogen. **Verwenden Sie für Ihre Antworten ausschließlich den separaten MC-Lösungsbogen. Einträge in dieser Aufgabenstellung werden nicht gewertet!**

1.		Das Bestimmtheitsmaß R^2 im einfachen linearen Regressionsmodell
a	<input checked="" type="checkbox"/>	ist größer als das korrigierte Bestimmtheitsmaß.
b	<input type="checkbox"/>	berücksichtigt die zur Schätzung benötigten Freiheitsgrade.
c	<input type="checkbox"/>	gibt das Verhältnis von unerklärter Variation zu Gesamtvariation an.
d	<input type="checkbox"/>	kann negative Werte annehmen.

2.		Wenn es einen nicht-linearen Zusammenhang zwischen zwei Zufallsvariablen gibt, dann kann
a	<input type="checkbox"/>	die Kovarianz gleich 0 sein.
b	<input type="checkbox"/>	die Kovarianz negativ sein.
c	<input type="checkbox"/>	dieser Zusammenhang nicht korrekt mit der Kovarianz abgebildet werden.
d	<input checked="" type="checkbox"/>	alle der Antworten.

3.		Die Nullhypothese im Breusch-Pagan Test
a	<input type="checkbox"/>	wird abgelehnt, wenn $R^2 \cdot N \leq \chi_{J,kritisch}^2$.
b	<input type="checkbox"/>	besagt, dass keine Autokorrelation vorliegt.
c	<input type="checkbox"/>	besagt, dass Heteroskedastie vorliegt.
d	<input checked="" type="checkbox"/>	keine der Antworten.

4.		Wird die Nullhypothese eines Strukturbruchtests abgelehnt, so
a	<input type="checkbox"/>	liegt ein Problem ausgelassener Variablen vor.
b	<input checked="" type="checkbox"/>	liegen signifikante Unterschiede in den Steigungsparametern der verschiedenen Gruppen vor.
c	<input type="checkbox"/>	liegt Heteroskedastie vor.
d	<input type="checkbox"/>	ist das restringierte Modell korrekt spezifiziert.

5.		Der geschätzte Koeffizient b_2 des Modells $y_i = \beta_1 + \beta_2 x_i + \varepsilon_i$ ist nach unten verzerrt, falls eine ausgelassene Variable z_i
a	<input type="checkbox"/>	positiv mit x_i korreliert ist und y_i positiv beeinflusst.
b	<input type="checkbox"/>	negativ mit x_i korreliert ist und y_i negativ beeinflusst.
c	<input type="checkbox"/>	nicht mit x_i korreliert ist und y_i negativ beeinflusst.
d	<input checked="" type="checkbox"/>	negativ mit x_i korreliert ist und y_i positiv beeinflusst.

6.		Bei GLS-Schätzern
a	<input type="checkbox"/>	ist die funktionale Form der Varianz-Kovarianz Matrix des Störterms unbekannt und muss geschätzt werden.
b	<input type="checkbox"/>	sind die Gauß-Markow Annahmen verletzt.
c	<input checked="" type="checkbox"/>	gilt für das transformierte Modell die Annahme A3: $Var(\varepsilon_i) = \sigma^2$, für alle $i = 1, \dots, N$.
d	<input type="checkbox"/>	b und c.

7.		Welche der angegebenen Verteilungsfunktionen ist symmetrisch?
a	<input checked="" type="checkbox"/>	Die t-Verteilung.
b	<input type="checkbox"/>	Die χ^2 -Verteilung.
c	<input type="checkbox"/>	Die F-Verteilung.
d	<input type="checkbox"/>	alle der genannten Verteilungen.

8.		Der Prais-Winsten Schätzer
a	<input type="checkbox"/>	ist effizienter als der Cochrane-Orcutt Schätzer.
b	<input type="checkbox"/>	ist nicht BLUE.
c	<input type="checkbox"/>	benutzt die erste Beobachtung.
d	<input checked="" type="checkbox"/>	a und c.

9.		Das Informationskriterium AIC
a	<input type="checkbox"/>	nimmt ausschließlich Werte zwischen 0 und 1 an.
b	<input type="checkbox"/>	sinkt, wenn zusätzliche Regressoren dem Modell hinzugefügt werden (bei gegebener Fehlerquadratsumme und Beobachtungszahl).
c	<input checked="" type="checkbox"/>	steigt an, wenn die Fehlerquadratsumme der Regression ansteigt (bei gegebener Parameter- und Beobachtungszahl).
d	<input type="checkbox"/>	wird ausschließlich zum Vergleich genesteter Modelle verwendet.

10.		Unabhängigkeit der zwei Zufallsvariablen X und Y impliziert,
a	<input type="checkbox"/>	dass die Korrelation zwischen X und Y gleich 0 ist.
b	<input type="checkbox"/>	dass die Kovarianz von X und Y gleich 0 ist.
c	<input type="checkbox"/>	dass die Summe von X und Y gleich 0 ist.
d	<input checked="" type="checkbox"/>	a und b.

11.		Im log-linearen Modell $\ln(y_i) = \beta_1 + \beta_2 x_i + \varepsilon_i$
a	<input checked="" type="checkbox"/>	ist die abhängige Variable eine lineare Funktion von x_i .
b	<input type="checkbox"/>	werden prozentuale Änderungen von x_i betrachtet.
c	<input type="checkbox"/>	wird b_2 als Elastizität interpretiert.
d	<input type="checkbox"/>	ist y_i eine konkave Funktion von x_i .

12.		Mit welcher Annahme lässt sich die Erwartungstreue von \mathbf{b} bei stochastischem \mathbf{X} herleiten, wenn die Annahme, dass $\{\varepsilon_1, \dots, \varepsilon_N\}$ und $\{x_1, \dots, x_N\}$ unabhängig sind, verletzt ist?
a	<input type="checkbox"/>	A4: $cov(\varepsilon_i, \varepsilon_j) = 0$ für $i, j = 1, \dots, N$ und $i \neq j$.
b	<input type="checkbox"/>	A5: $\varepsilon \sim \mathbf{N}(\mathbf{0}, \sigma^2 \mathbf{I}_N)$.
c	<input type="checkbox"/>	A7: $E\{\mathbf{x}_i \varepsilon_i\} = 0$.
d	<input checked="" type="checkbox"/>	keine der Antworten.

13.		Gegeben sei $y_i = \beta_1 + \beta_2 D_i + \varepsilon_i$, wobei D_i eine binäre Variable darstellt. Welche Schätzergebnisse ändern sich, wenn Sie in dem Modell D_i durch $(1 - D_i)$ ersetzen?
a	<input type="checkbox"/>	b_2 .
b	<input checked="" type="checkbox"/>	b_1 und b_2 .
c	<input type="checkbox"/>	b_1 und R^2 .
d	<input type="checkbox"/>	b_2 und R^2 .

14.		Wenn $\Psi \neq \mathbf{I}$ gilt und Ψ eine diagonale Matrix ist, dann impliziert $Var(\varepsilon) = \sigma^2 \Psi$,
a	<input type="checkbox"/>	dass $cov(\varepsilon_i, \varepsilon_j) \neq 0$ für alle $i \neq j$.
b	<input checked="" type="checkbox"/>	dass Heteroskedastie vorliegt.
c	<input type="checkbox"/>	dass der KQ-Schätzer verzerrt ist.
d	<input type="checkbox"/>	a und b.

15.		Ein Interaktionsterm
a	<input checked="" type="checkbox"/>	ist das Produkt von mindestens zwei Variablen.
b	<input type="checkbox"/>	ist die Summe von mindestens zwei Variablen.
c	<input type="checkbox"/>	ist eine Linearkombination mehrerer Variablen.
d	<input type="checkbox"/>	muss eine Dummyvariable beinhalten.

16.		Weist der Störterm einen autoregressiven Prozess zweiter Ordnung auf, so
a	<input type="checkbox"/>	sind die mit den KQ-Schätzern ausgewiesenen p-Werte gültig.
b	<input type="checkbox"/>	gilt die Annahme A11 ($\varepsilon_t \sim IID(0, \sigma^2)$) nicht mehr.
c	<input type="checkbox"/>	sind alle Elemente der Varianz-Kovarianz Matrix des Störterms von Null verschieden.
d	<input checked="" type="checkbox"/>	b und c.

17.		Der marginale Effekt in einem binären Modell
a	<input type="checkbox"/>	entspricht dem logarithmierten Koeffizienten.
b	<input type="checkbox"/>	wird immer als Elastizität interpretiert.
c	<input checked="" type="checkbox"/>	hat dasselbe Vorzeichen wie der geschätzte Koeffizient.
d	<input type="checkbox"/>	a und c.

18.		Das Kleinstquadratverfahren basiert auf der Minimierung
a	<input type="checkbox"/>	der Summe der Störterme.
b	<input type="checkbox"/>	der Summe der Residuen.
c	<input checked="" type="checkbox"/>	der Summe der quadrierten Residuen.
d	<input type="checkbox"/>	der quadrierten Summe der Residuen.

19.		Für das Modell $\ln \text{lohn}_i = \beta_1 + \beta_2 \text{Alter}_i + \beta_3 \text{Alter}_i^2 + \varepsilon_i$ berechnen Sie folgende statistisch signifikante Koeffizienten: $b_1 = 8.7, b_2 = 0.4, b_3 = -0.005$. Der marginale Effekt des Alters auf den logarithmierten Stundenlohn
a	<input type="checkbox"/>	beträgt für jedes Alter 0.4.
b	<input type="checkbox"/>	ist positiv für $\text{Alter}_i = 65$.
c	<input type="checkbox"/>	ist negativ für $\text{Alter}_i = 35$.
d	<input checked="" type="checkbox"/>	ist negativ für $\text{Alter}_i = 45$.

20.		Der Durbin-Watson-Test
a	<input checked="" type="checkbox"/>	ist auch bei kleinen Stichproben gültig.
b	<input type="checkbox"/>	darf angewendet werden, wenn verzögerte endogene Variablen im Modell vorkommen.
c	<input type="checkbox"/>	unterstellt positive Autokorrelation in der Nullhypothese.
d	<input type="checkbox"/>	keine der Antworten.

21.		Der kritische Wert eines White-Tests auf Heteroskedastie für ein lineares Modell mit 3 stetigen unabhängigen Variablen und einer Konstanten gegeben eine Irrtumswahrscheinlichkeit von $\alpha = 0.1$ beträgt
a	<input type="checkbox"/>	6.25
b	<input type="checkbox"/>	10.64
c	<input type="checkbox"/>	13.36
d	<input checked="" type="checkbox"/>	14.68

22.		Welche Aussage ist richtig?
a	<input checked="" type="checkbox"/>	Zur Durchführung des Likelihood-Ratio- oder Wald-Tests wird das unrestringierte Modell geschätzt.
b	<input type="checkbox"/>	Die Teststatistik des Wald-Tests folgt asymptotisch der F-Verteilung.
c	<input type="checkbox"/>	In kleinen Stichproben sind Wald-, Likelihood-Ratio- und Lagrange-Multiplier-Tests äquivalent.
d	<input type="checkbox"/>	a und c.

23.		Welche Größe ändert sich, wenn in einem einfachen linearen Regressionsmodell die erklärende Variable umskaliert wird?
a	<input type="checkbox"/>	das R^2 .
b	<input type="checkbox"/>	die geschätzte Konstante.
c	<input checked="" type="checkbox"/>	das für den geschätzten Steigungskoeffizienten ausgegebene Konfidenzintervall.
d	<input type="checkbox"/>	b und c.

24.		Um einen RESET-Test durchzuführen, regressiert man in einer Hilfsregression
a	<input checked="" type="checkbox"/>	die abhängige Variable auf Polynome der vorhergesagten abhängigen Variable.
b	<input type="checkbox"/>	quadrierte Residuen auf alle unabhängigen Variablen, deren Quadrate und deren Interaktionen.
c	<input type="checkbox"/>	Residuen auf alle unabhängigen Variablen und zeitlich verzögerte Residuen.
d	<input type="checkbox"/>	keine der Antworten ist richtig.

25.		Das Maximum-Likelihood Schätzverfahren
a	<input type="checkbox"/>	maximiert die Wahrscheinlichkeit, die Summe der quadrierten Residuen zu minimieren.
b	<input checked="" type="checkbox"/>	bestimmt die geschätzten Parameter so, dass die Wahrscheinlichkeit für das Auftreten der Stichprobe maximiert wird.
c	<input type="checkbox"/>	maximiert die Wahrscheinlichkeit der quadrierten Residuen.
d	<input type="checkbox"/>	berechnet die Bevölkerungsparameter so, dass die Wahrscheinlichkeit für das Auftreten der Stichprobe maximiert wird.

26.		Welcher Test kann verwendet werden, um in dem linearen Modell $y_i = \beta_1 + \beta_2 x_{2i} + \beta_3 x_{3i} + \beta_4 x_{4i} + \beta_5 x_{5i} + \epsilon_i$ auf gemeinsame Signifikanz der Parameter β_3 und β_4 zu testen?
a	<input checked="" type="checkbox"/>	Wald-Test.
b	<input type="checkbox"/>	RESET-Test.
c	<input type="checkbox"/>	Durbin-Watson-Test.
d	<input type="checkbox"/>	White-Test.

27.		Bei korrekter Spezifizierung der Likelihoodfunktion ist der ML-Schätzer:
a	<input checked="" type="checkbox"/>	asymptotisch effizient.
b	<input type="checkbox"/>	unverzerrt.
c	<input type="checkbox"/>	t-verteilt.
d	<input type="checkbox"/>	alle der Antworten.

28.		Der KQ-Schätzer $\mathbf{b} = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{y}$ lässt sich nur berechnen, wenn
a	<input type="checkbox"/>	die Matrix \mathbf{Xy} eine quadratische Matrix ist.
b	<input type="checkbox"/>	die Matrix \mathbf{Xy} invertierbar ist.
c	<input checked="" type="checkbox"/>	die Matrix $\mathbf{X}'\mathbf{X}$ vollen Rang besitzt.
d	<input type="checkbox"/>	die Matrix $\mathbf{X}'\mathbf{X}$ nicht symmetrisch ist.

29.		Im Log-log-Modell $\ln(y_i) = \beta_1 + \beta_2 \ln(x_i) + \varepsilon_i$ mit $\beta_2 > 0$
a	<input type="checkbox"/>	variiert die Elastizität von y_i bezüglich x_i mit dem Ausgangsniveau von x_i .
b	<input checked="" type="checkbox"/>	besteht ein nicht-linearer Zusammenhang zwischen $\ln(y_i)$ und x_i .
c	<input type="checkbox"/>	gibt der Koeffizient b_2 eine Semi-Elastizität an.
d	<input type="checkbox"/>	ist der Logarithmus von y_i eine nicht-lineare Funktion des Logarithmus von x_i .

30.		Autokorrelation im Störterm kann behoben werden durch:
a	<input type="checkbox"/>	die Aufnahme von irrelevanten erklärenden Variablen.
b	<input checked="" type="checkbox"/>	eine GLS Transformation.
c	<input type="checkbox"/>	die Aufnahme zusätzlicher Beobachtungen.
d	<input type="checkbox"/>	b und c.