

## Statistik: Bachelor/2. Vordiplom/SD

1. (8 Punkte) Alle Teilaufgaben ergeben +1 Punkt, falls richtig beantwortet, -1 Punkt, falls falsch beantwortet, und bei keiner Antwort 0 Punkte. Ein allfälliges negatives Punktetotal wird als Null gezählt.

Geben Sie bei a)–g) jeweils an, ob die Aussage richtig oder falsch ist.

- a) Die Nullhypothese kann auf dem 5%-Niveau nicht verworfen werden, wenn der  $P$ -Wert des Tests 0.029 beträgt.
- b) Wenn das Signifikanzniveau eines Tests vergrößert wird, dann wird der Annahmehereich grösser.
- c) Wenn der Wert der Teststatistik im Verwerfungsbereich liegt, dann kann ein Fehler 2. Art vorliegen.
- d) Wir testen die Hypothese  $\mu = 0$  zweiseitig mit dem  $t$ -Test. Die Wahrscheinlichkeit eines Fehlers 2. Art ist grösser unter der Alternative  $\mu = -0.2$  als unter  $\mu = -0.3$ .
- e) Der Chi-Quadrat-Test wird verwendet, wenn man beobachtete Häufigkeiten mit den Häufigkeiten vergleichen will, die man auf Grund einer bestimmten Theorie erwartet.
- f) Der Wert der Teststatistik für den Zweistichproben-Wilcoxon-Test ändert sich nicht, wenn man an Stelle der ursprünglichen positiven Werte  $(x_1, \dots, x_n)$  und  $(y_1, \dots, y_m)$  die logarithmierten Werte  $(\log x_1, \dots, \log x_n)$  und  $(\log y_1, \dots, \log y_m)$  verwendet.
- g) Wenn  $X$  lognormal verteilt ist, dann ist auch  $Y = \frac{1}{X}$  lognormal verteilt.

Geben Sie bei h) an, welche der angegebenen Antworten richtig ist.

- h)  $X$  und  $Y$  sind unabhängig mit Standardabweichung  $\sigma_X = 2$  und  $\sigma_Y = 1$ . Dann ist die Standardabweichung von  $Z = X - Y$  gleich

A) 1      B) 3      C)  $\sqrt{3}$       D)  $\sqrt{5}$

**Bitte wenden!**


## 2. (10 Punkte)

a) In einer Studie über das Fortpflanzungsverhalten einer Wespenart wurde bei einer Stichprobe von 197 Tieren mit Hilfe von genetischen Tests je der Inzuchtskoeffizient bestimmt. Der Inzuchtskoeffizient liegt zwischen  $-1$  und  $+1$  und ist bei Arten, die keine Tendenz zur Inzucht haben, sondern sich zufällig paaren, gleich Null. Bei Arten, die eine Tendenz zur Inzucht haben, ist er positiv. Das arithmetische Mittel des Inzuchtskoeffizienten in der Stichprobe war  $0.044$  und die empirische Standardabweichung der Einzelwerte war  $0.884$ . Das Ziel der Studie war herauszufinden, ob diese Wespenart eine Tendenz zur Inzucht hat.

- i) Formulieren Sie die Nullhypothese und die Alternative, die hier angebracht sind.
- ii) Testen Sie diese Nullhypothese auf dem  $5\%$ -Niveau mit einem geeigneten Test.
- iii) Braucht man, dass die Inzuchtskoeffizienten der einzelnen Tiere normalverteilt sind, damit der in ii) verwendete Test gültig ist? Begründen Sie ganz kurz (ein Stichwort genügt).

**Hinweis:** Es genügt, mit der Näherung  $\sqrt{197} \approx 14$  zu rechnen.

b) Eine Zufallsvariable  $X$  habe die folgende kumulative Verteilungsfunktion.



- i) Geben Sie die Dichte von  $X$  an.
- ii) Bestimmen Sie  $P(X > 1)$ .
- iii) Bestimmen Sie den Median von  $X$ .

**Siehe nächstes Blatt!**

3. (11 Punkte) Die Härte von Holz ist entscheidend für die Verwendung als Baumaterial. Die Messung der Härte ist jedoch aufwendig. Die Dichte von Holz ist verwandt mit der Härte und wesentlich einfacher zu messen. Um einen Zusammenhang zwischen Härte und Dichte zu bestimmen, wurden die Härten  $y_i$  und die Dichten  $x_i$  bei 36 Hölzern gemessen. Wir betrachten die folgenden drei Modelle

$$y_i = \beta_0 + \beta_1 x_i + E_i \quad (1)$$

$$y_i = \beta_0 + \beta_1 x_i + \beta_2 x_i^2 + E_i \quad (2)$$

$$\log y_i = \gamma_0 + \gamma_1 \log x_i + E_i \quad (3)$$

Die Fehlerterme  $E_i$  werden in allen Modellen als i.i.d. und  $\mathcal{N}(0, \sigma^2)$ -verteilt angenommen. Systat ergibt für die drei Modelle den folgenden Output:

```
Dep Var: HARD  N: 36  Multiple R: 0.974  Squared multiple R: 0.949
Adjusted squared multiple R: 0.948  Standard error of estimate: 183.059
```

Effect	Coefficient	Std Error	Std Coef	Tolerance	t	P(2 Tail)
CONSTANT	-1160.500	108.580	0.000	.	-10.688	0.000
DENS	57.507	2.279	0.974	1.000	25.238	0.000

```
Analysis of Variance
```

Source	Sum-of-Squares	df	Mean-Square	F-ratio	P
Regression	2.13457E+07	1	2.13457E+07	636.979	0.000
Residual	1139366.476	34	33510.779		

```
*** WARNING ***
Case 32 is an outlier (Studentized Residual = 4.473)

Durbin-Watson D Statistic 2.194
First Order Autocorrelation -0.166
```

Abbildung 1: Systat Output für Modell (1)

```
Dep Var: HARD  N: 36  Multiple R: 0.981  Squared multiple R: 0.962
Adjusted squared multiple R: 0.959  Standard error of estimate: 161.745
```

Effect	Coefficient	Std Error	Std Coef	Tolerance	t	P(2 Tail)
CONSTANT	-118.007	334.967	0.000	.	-0.352	0.727
DENS	9.434	14.936	0.160	0.018	0.632	0.532
SQUAREDENS	0.509	0.157	0.822	0.018	3.248	0.003

```
Analysis of Variance
```

Source	Sum-of-Squares	df	Mean-Square	F-ratio	P
Regression	2.16217E+07	2	1.08109E+07	413.237	0.000
Residual	863325.419	33	26161.376		

```
*** WARNING ***
Case 32 is an outlier (Studentized Residual = 4.431)

Durbin-Watson D Statistic 2.707
First Order Autocorrelation -0.373
```

Abbildung 2: Systat Output für Modell (2)

- Was schliessen Sie aus der Spalte  $P(2 Tail)$  im Output für Modell (2)?
- Liegt 2 im 95%-Vertrauensintervall für den Parameter  $\gamma_1$  von Modell (3)?
- Wie lauten die Schätzungen für die Standardabweichung der Fehler  $E_i$  in den 3 Modellen? Weshalb gibt es bei Modell (3) einen ganz anderen Wert als bei den Modellen (1) und (2)?

**Bitte wenden!**

Dep Var: LOGHARD N: 36 Multiple R: 0.986 Squared multiple R: 0.973  
Adjusted squared multiple R: 0.972 Standard error of estimate: 0.098

Effect	Coefficient	Std Error	Std Coef	Tolerance	t	P(2 Tail)
CONSTANT	0.015	0.204	0.000	.	0.076	0.940
LOGDENS	1.885	0.054	0.986	1.000	35.091	0.000

Analysis of Variance

Source	Sum-of-Squares	df	Mean-Square	F-ratio	P
Regression	11.768	1	11.768	1231.361	0.000
Residual	0.325	34	0.010		

Durbin-Watson D Statistic 2.392  
First Order Autocorrelation -0.223

Abbildung 3: Systat Output für Modell (3)

- d) Schreiben Sie das Modell (3) um in eine Beziehung zwischen den ursprünglichen Grössen  $y_i$  und  $x_i$  (ohne Logarithmen). Worin unterscheidet sich das Modell (2) mit  $\beta_0 = \beta_1 = 0$  vom Modell (3) mit  $\gamma_1 = 2$ ?
- e) Beurteilen Sie mit Hilfe der Tukey-Anscombe Darstellungen der Residuen gegen angepasste Werte, ob die Modelle (1), bzw. (2), bzw. (3) zu den Daten passen. Welches der drei Modelle würden Sie bevorzugen?




Abbildung 4: Tukey-Anscombe Plots für Modell (1) (links), Modell (2) (Mitte) und Modell (3) (rechts)

**Siehe nächstes Blatt!**

## Quantile der $t$ -Verteilung mit $\nu$ Freiheitsgraden

$\nu$	$q_{0.60}$	$q_{0.70}$	$q_{0.80}$	$q_{0.90}$	$q_{0.95}$	$q_{0.975}$	$q_{0.99}$	$q_{0.995}$
1	0.325	0.727	1.376	3.078	6.314	12.706	31.821	63.657
2	0.289	0.617	1.061	1.886	2.920	4.303	6.965	9.925
3	0.277	0.584	0.978	1.638	2.353	3.182	4.541	5.841
4	0.271	0.569	0.941	1.533	2.132	2.776	3.747	4.604
5	0.267	0.559	0.920	1.476	2.015	2.571	3.365	4.032
6	0.265	0.553	0.906	1.440	1.943	2.447	3.143	3.707
7	0.263	0.549	0.896	1.415	1.895	2.365	2.998	3.499
8	0.262	0.546	0.889	1.397	1.860	2.306	2.896	3.355
9	0.261	0.543	0.883	1.383	1.833	2.262	2.821	3.250
10	0.260	0.542	0.879	1.372	1.812	2.228	2.764	3.169
11	0.260	0.540	0.876	1.363	1.796	2.201	2.718	3.106
12	0.259	0.539	0.873	1.356	1.782	2.179	2.681	3.055
13	0.259	0.538	0.870	1.350	1.771	2.160	2.650	3.012
14	0.258	0.537	0.868	1.345	1.761	2.145	2.624	2.977
15	0.258	0.536	0.866	1.341	1.753	2.131	2.602	2.947
30	0.256	0.530	0.854	1.310	1.697	2.042	2.457	2.750
60	0.254	0.527	0.848	1.296	1.671	2.000	2.390	2.660
120	0.254	0.526	0.845	1.289	1.658	1.980	2.358	2.617
$\infty$	0.253	0.524	0.842	1.282	1.645	1.960	2.326	2.576