

# 13. Statistische Tests und $p$ -Werte

## 13.1 Das allgemeine Vorgehen bei statistischen Tests

13.1.1 Schritt 1: Wahl der Nullhypothese  $H_0$

13.1.2 Schritte 2 und 3: Test-Statistik

13.1.3 Schritt 4: Test-Entscheidung

13.1.4 Step 4a: The  $p$ -value

## 13.2 Strategien zur Modellauswahl

## 13.3 Logistische Regression

$$\frac{2\sigma_{\varepsilon}}{\sqrt{n}}$$

## 13. Statistische Tests: das allgemeine Vorgehen

1. Formuliere eine **Nullhypothese  $H_0$** , sodass ihre *Ablehnung* Erkenntnisse liefert, z.B.  $\beta_j = \beta_{j0}$  (Punkthypothese) bzw.  $\beta_j \leq \beta_0$  (Intervallhypothese): *Man kann keine  $H_0$  bestätigen!*
2. Wähle eine **Test-Statistik  $T$** 
  - ▶ mit bekannter Verteilung am Rande  $H_0^*$  der Nullhypothese ( $H_0^* = H_0$  bei Punkthypothesen)  
Was tun, wenn die Statistik eine bekannte Verteilung hat, aber die zugehörige Varianz unbekannt ist? Normalisierung auf die geschätzte Standardabweichung
  - ▶ mit klar definierten **Ablehnungsbereichen  $R(\alpha)$**  welche bei  $H_0$  selten erreicht werden, aber häufiger bei  $H_1 = \overline{H_0}$
3. Berechne eine Realisierung  $t_{\text{data}}$  von  $T$  aus den Daten
4. Teste, ob  $t_{\text{data}} \in R(\alpha)$ . Falls ja, kann  $H_0$  bei einer Fehlerwahrscheinlichkeit bzw einem Signifikanzniveau  $\alpha$  verworfen werden. Andernfalls *kann keine Aussage getroffen werden* (Maskenbeispiel mit  $H_0$ : "Maske nutzlos").
- 4a Alternativ und genauer: Berechne den  $p$ -Wert als kleinste Fehlerwahrscheinlichkeit  $\alpha$ , bei der  $H_0$  abgelehnt werden kann.

## 13. Statistische Tests: das allgemeine Vorgehen

1. Formuliere eine **Nullhypothese  $H_0$** , sodass ihre *Ablehnung* Erkenntnisse liefert, z.B.  $\beta_j = \beta_{j0}$  (Punkthypothese) bzw.  $\beta_j \leq \beta_0$  (Intervallhypothese): *Man kann keine  $H_0$  bestätigen!*
2. Wähle eine **Test-Statistik  $T$** 
  - ▶ mit bekannter Verteilung am Rande  $H_0^*$  der Nullhypothese ( $H_0^* = H_0$  bei Punkthypothesen)  
Was tun, wenn die Statistik eine bekannte Verteilung hat, aber die zugehörige Varianz unbekannt ist? Normalisierung auf die geschätzte Standardabweichung
  - ▶ mit klar definierten **Ablehnungsbereichen  $R(\alpha)$**  welche bei  $H_0$  selten erreicht werden, aber häufiger bei  $H_1 = \overline{H_0}$
3. Berechne eine Realisierung  $t_{\text{data}}$  von  $T$  aus den Daten
4. Teste, ob  $t_{\text{data}} \in R(\alpha)$ . Falls ja, kann  $H_0$  bei einer Fehlerwahrscheinlichkeit bzw einem Signifikanzniveau  $\alpha$  verworfen werden. Andernfalls *kann keine Aussage getroffen werden* (Maskenbeispiel mit  $H_0$ : "Maske nutzlos").
- 4a Alternativ und genauer: Berechne den  $p$ -Wert als kleinste Fehlerwahrscheinlichkeit  $\alpha$ , bei der  $H_0$  abgelehnt werden kann.

## 13. Statistische Tests: das allgemeine Vorgehen

1. Formuliere eine **Nullhypothese  $H_0$** , sodass ihre *Ablehnung* Erkenntnisse liefert, z.B.  $\beta_j = \beta_{j0}$  (Punkthypothese) bzw.  $\beta_j \leq \beta_0$  (Intervallhypothese): *Man kann keine  $H_0$  bestätigen!*
2. Wähle eine **Test-Statistik  $T$** 
  - ▶ mit bekannter Verteilung am Rande  $H_0^*$  der Nullhypothese ( $H_0^* = H_0$  bei Punkthypothesen)
    - Was tun, wenn die Statistik eine bekannte Verteilung hat, aber die zugehörige Varianz unbekannt ist? Normalisierung auf die *geschätzte Standardabweichung*
  - ▶ mit klar definierten **Ablehnungsbereichen  $R(\alpha)$**  welche bei  $H_0$  selten erreicht werden, aber häufiger bei  $H_1 = \overline{H_0}$
3. Berechne eine Realisierung  $t_{\text{data}}$  von  $T$  aus den Daten
4. Teste, ob  $t_{\text{data}} \in R(\alpha)$ . Falls ja, kann  $H_0$  bei einer Fehlerwahrscheinlichkeit bzw einem Signifikanzniveau  $\alpha$  verworfen werden. Andernfalls *kann keine Aussage getroffen werden (Maskenbeispiel mit  $H_0$ : "Maske nutzlos")*.
- 4a Alternativ und genauer: Berechne den  $p$ -Wert als kleinste Fehlerwahrscheinlichkeit  $\alpha$ , bei der  $H_0$  abgelehnt werden kann.

## 13. Statistische Tests: das allgemeine Vorgehen

1. Formuliere eine **Nullhypothese  $H_0$** , sodass ihre *Ablehnung* Erkenntnisse liefert, z.B.  $\beta_j = \beta_{j0}$  (Punkthypothese) bzw.  $\beta_j \leq \beta_0$  (Intervallhypothese): *Man kann keine  $H_0$  bestätigen!*
2. Wähle eine **Test-Statistik  $T$** 
  - ▶ mit bekannter Verteilung am Rande  $H_0^*$  der Nullhypothese ( $H_0^* = H_0$  bei Punkthypothesen)
    - Was tun, wenn die Statistik eine bekannte Verteilung hat, aber die zugehörige Varianz unbekannt ist? Normalisierung auf die geschätzte Standardabweichung
  - ▶ mit klar definierten **Ablehnungsbereichen  $R(\alpha)$**  welche bei  $H_0$  selten erreicht werden, aber häufiger bei  $H_1 = \overline{H_0}$
3. Berechne eine Realisierung  $t_{\text{data}}$  von  $T$  aus den Daten
4. Teste, ob  $t_{\text{data}} \in R(\alpha)$ . Falls ja, kann  $H_0$  bei einer **Fehlerwahrscheinlichkeit** bzw einem **Signifikanzniveau  $\alpha$**  verworfen werden. Andernfalls *kann keine Aussage getroffen werden (Maskenbeispiel mit  $H_0$ : "Maske nutzlos")*.
- 4a Alternativ und genauer: Berechne den  $p$ -Wert als kleinste Fehlerwahrscheinlichkeit  $\alpha$ , bei der  $H_0$  abgelehnt werden kann.

## 13. Statistische Tests: das allgemeine Vorgehen

1. Formuliere eine **Nullhypothese  $H_0$** , sodass ihre *Ablehnung* Erkenntnisse liefert, z.B.  $\beta_j = \beta_{j0}$  (Punkthypothese) bzw.  $\beta_j \leq \beta_0$  (Intervallhypothese): *Man kann keine  $H_0$  bestätigen!*
2. Wähle eine **Test-Statistik  $T$** 
  - ▶ mit bekannter Verteilung am Rande  $H_0^*$  der Nullhypothese ( $H_0^* = H_0$  bei Punkthypothesen)
    - Was tun, wenn die Statistik eine bekannte Verteilung hat, aber die zugehörige Varianz unbekannt ist? Normalisierung auf die geschätzte Standardabweichung
  - ▶ mit klar definierten **Ablehnungsbereichen  $R(\alpha)$**  welche bei  $H_0$  selten erreicht werden, aber häufiger bei  $H_1 = \overline{H_0}$
3. Berechne eine Realisierung  $t_{\text{data}}$  von  $T$  aus den Daten
4. Teste, ob  $t_{\text{data}} \in R(\alpha)$ . Falls ja, kann  $H_0$  bei einer **Fehlerwahrscheinlichkeit** bzw einem **Signifikanzniveau  $\alpha$**  verworfen werden. Andernfalls *kann keine Aussage getroffen werden (Maskenbeispiel mit  $H_0$ : "Maske nutzlos")*.
- 4a Alternativ und genauer: Berechne den  **$p$ -Wert** als kleinste Fehlerwahrscheinlichkeit  $\alpha$ , bei der  $H_0$  abgelehnt werden kann.

## 13. Statistische Tests: das allgemeine Vorgehen

1. Formuliere eine **Nullhypothese  $H_0$** , sodass ihre *Ablehnung* Erkenntnisse liefert, z.B.  $\beta_j = \beta_{j0}$  (Punkthypothese) bzw.  $\beta_j \leq \beta_0$  (Intervallhypothese): *Man kann keine  $H_0$  bestätigen!*
2. Wähle eine **Test-Statistik  $T$** 
  - ▶ mit bekannter Verteilung am Rande  $H_0^*$  der Nullhypothese ( $H_0^* = H_0$  bei Punkthypothesen)
    - Was tun, wenn die Statistik eine bekannte Verteilung hat, aber die zugehörige Varianz unbekannt ist? Normalisierung auf die geschätzte Standardabweichung
  - ▶ mit klar definierten **Ablehnungsbereichen  $R(\alpha)$**  welche bei  $H_0$  selten erreicht werden, aber häufiger bei  $H_1 = \overline{H_0}$
3. Berechne eine Realisierung  $t_{\text{data}}$  von  $T$  aus den Daten
4. Teste, ob  $t_{\text{data}} \in R(\alpha)$ . Falls ja, kann  $H_0$  bei einer **Fehlerwahrscheinlichkeit** bzw einem **Signifikanzniveau  $\alpha$**  verworfen werden. Andernfalls *kann keine Aussage getroffen werden (Maskenbeispiel mit  $H_0$ : "Maske nutzlos")*.
- 4a Alternativ und genauer: Berechne den  **$p$ -Wert** als kleinste Fehlerwahrscheinlichkeit  $\alpha$ , bei der  $H_0$  abgelehnt werden kann.

## 13. Statistische Tests: das allgemeine Vorgehen

1. Formuliere eine **Nullhypothese  $H_0$** , sodass ihre *Ablehnung* Erkenntnisse liefert, z.B.  $\beta_j = \beta_{j0}$  (Punkthypothese) bzw.  $\beta_j \leq \beta_0$  (Intervallhypothese): *Man kann keine  $H_0$  bestätigen!*
2. Wähle eine **Test-Statistik  $T$** 
  - ▶ mit bekannter Verteilung am Rande  $H_0^*$  der Nullhypothese ( $H_0^* = H_0$  bei Punkthypothesen)  
Was tun, wenn die Statistik eine bekannte Verteilung hat, aber die zugehörige Varianz unbekannt ist? Normalisierung auf die geschätzte Standardabweichung
  - ▶ mit klar definierten **Ablehnungsbereichen  $R(\alpha)$**  welche bei  $H_0$  selten erreicht werden, aber häufiger bei  $H_1 = \overline{H_0}$
3. Berechne eine Realisierung  $t_{\text{data}}$  von  $T$  aus den Daten
4. Teste, ob  $t_{\text{data}} \in R(\alpha)$ . Falls ja, kann  $H_0$  bei einer **Fehlerwahrscheinlichkeit** bzw einem **Signifikanzniveau  $\alpha$**  verworfen werden. Andernfalls *kann keine Aussage getroffen werden (Maskenbeispiel mit  $H_0$ : "Maske nutzlos")*.
- 4a Alternativ und genauer: Berechne den  **$p$ -Wert** als kleinste Fehlerwahrscheinlichkeit  $\alpha$ , bei der  $H_0$  abgelehnt werden kann.



## 13. Statistische Tests: das allgemeine Vorgehen

1. Formuliere eine **Nullhypothese  $H_0$** , sodass ihre *Ablehnung* Erkenntnisse liefert, z.B.  $\beta_j = \beta_{j0}$  (Punkthypothese) bzw.  $\beta_j \leq \beta_0$  (Intervallhypothese): *Man kann keine  $H_0$  bestätigen!*
2. Wähle eine **Test-Statistik  $T$** 
  - ▶ mit bekannter Verteilung am Rande  $H_0^*$  der Nullhypothese ( $H_0^* = H_0$  bei Punkthypothesen)  
Was tun, wenn die Statistik eine bekannte Verteilung hat, aber die zugehörige Varianz unbekannt ist? Normalisierung auf die geschätzte Standardabweichung
  - ▶ mit klar definierten **Ablehnungsbereichen  $R(\alpha)$**  welche bei  $H_0$  selten erreicht werden, aber häufiger bei  $H_1 = \overline{H_0}$
3. Berechne eine Realisierung  $t_{\text{data}}$  von  $T$  aus den Daten
4. Teste, ob  $t_{\text{data}} \in R(\alpha)$ . Falls ja, kann  $H_0$  bei einer **Fehlerwahrscheinlichkeit** bzw einem **Signifikanzniveau  $\alpha$**  verworfen werden. Andernfalls *kann keine Aussage getroffen werden (Maskenbeispiel mit  $H_0$ : "Maske nutzlos")*.
- 4a Alternativ und genauer: Berechne den  **$p$ -Wert** als kleinste Fehlerwahrscheinlichkeit  $\alpha$ , bei der  $H_0$  abgelehnt werden kann.

## 13.1.1 Wahl der Nullhypothese $H_0$ : Fehler 1. und 2. Art

	$H_0$ not rejected	$H_0$ rejected
$H_0$ is true		
$H_0$ is not true		

- ▶ Ein Signifikanztest hat binären Input und Output.

## 13.1.1 Wahl der Nullhypothese $H_0$ : Fehler 1. und 2. Art

	$H_0$ not rejected	$H_0$ rejected
$H_0$ is true	✓	
$H_0$ is not true		✓

- ▶ Ein Signifikanztest hat binären Input und Output. Zwei Kombinationen davon sind korrekt

## 13.1.1 Wahl der Nullhypothese $H_0$ : Fehler 1. und 2. Art

	$H_0$ not rejected	$H_0$ rejected
$H_0$ is true	✓	Type I error
$H_0$ is not true		✓

- ▶ Ein Signifikanztest hat binären Input und Output. Zwei Kombinationen davon sind korrekt
- ▶ Kontrollierbar: **Fehler 1. Art bzw  $\alpha$ -Fehler**  $P(H_0 \text{ abgelehnt} | H_0) \leq \alpha$

## 13.1.1 Wahl der Nullhypothese $H_0$ : Fehler 1. und 2. Art

	$H_0$ not rejected	$H_0$ rejected
$H_0$ is true	✓	Type I error
$H_0$ is not true	Type II error	✓

- ▶ Ein Signifikanztest hat binären Input und Output. Zwei Kombinationen davon sind korrekt
- ▶ Kontrollierbar: **Fehler 1. Art bzw  $\alpha$ -Fehler**  $P(H_0 \text{ abgelehnt} | H_0) \leq \alpha$
- ▶ Unbekannt und nicht kontrollierbar: **Fehler 2. Art bzw.  $\beta$ -Fehler**  $P(H_0 \text{ nicht abgelehnt} | \overline{H_0})$ . Da dessen Wahrscheinlichkeit unbekannt ist, legt man die ernsthaftere Konsequenz auf den  $\alpha$ -Fehler

## 13.1.1 Wahl der Nullhypothese $H_0$ : Fehler 1. und 2. Art

	$H_0$ not rejected	$H_0$ rejected
$H_0$ is true	✓	Type I error
$H_0$ is not true	Type II error	✓

- ▶ Ein Signifikanztest hat binären Input und Output. Zwei Kombinationen davon sind korrekt
- ▶ Kontrollierbar: **Fehler 1. Art bzw  $\alpha$ -Fehler**  $P(H_0 \text{ abgelehnt} | H_0) \leq \alpha$
- ▶ Unbekannt und nicht kontrollierbar: **Fehler 2. Art bzw.  $\beta$ -Fehler**  $P(H_0 \text{ nicht abgelehnt} | \overline{H_0})$ . Da dessen Wahrscheinlichkeit unbekannt ist, legt man die ernsthaftere Konsequenz auf den  $\alpha$ -Fehler

- ▶ Fundamentales Problem: Gesucht:  $P(H_0 | \text{abgelehnt})$  and  $P(H_0 | \overline{\text{abgelehnt}})$ , kann aber nur  $P(\text{abgelehnt} | H_0) \leq P(\text{abgelehnt} | H_0^*)$  kontrollieren  $\Rightarrow$  **Bayes'sche Statistik**

## 13.1.2 Schritte 2 und 3: Test-Statistik

- ▶ (i) Direkter **Parametertest** wie  $H_0: \beta_j = \beta_{j0}$  or  $\beta_j \geq \beta_{j0}$  or  $\beta_j \leq \beta_{j0}$ : Die Test-Statistik ist der geschätzte Abstand von  $H_0^*$  in Einheiten der *geschätzten* Standardabweichung. Sie ist **student-t** verteilt mit  $\#\text{dataPoints} - \#\text{parameters}$  **Freiheitsgraden (df)**:

$$T = \frac{\hat{\beta}_j - \beta_{j0}}{\sqrt{\hat{V}_{jj}}} \sim T(n - 1 - J)$$

- ▶ (ii) Test einer **Funktion der Parameter**, z.B.  $H_0: \beta_1/\beta_2 = 2, \leq 2$  or  $\geq 2$ : Transformiere in eine Linearkombination, deren Normalisierung unter  $H_0^*$  wieder student-t verteilt ist. Im Beispiel gilt unter  $H_0^*$  die Bedingung  $b = \beta_1 - 2\beta_2 = 0$ :

$$\begin{aligned} \hat{b} &= \hat{\beta}_1 - 2\hat{\beta}_2, \\ \hat{V}(\hat{b}) &= \hat{V}_{11} + 4\hat{V}_{22} - 4\hat{V}_{12}, \\ T &= \frac{\hat{b}}{\sqrt{\hat{V}(\hat{b})}} \sim T(n - 1 - J) \end{aligned}$$

## 13.1.2 Schritte 2 und 3: Test-Statistik

- ▶ (i) Direkter **Parametertest** wie  $H_0: \beta_j = \beta_{j0}$  or  $\beta_j \geq \beta_{j0}$  or  $\beta_j \leq \beta_{j0}$ : Die Test-Statistik ist der geschätzte Abstand von  $H_0^*$  in Einheiten der *geschätzten* Standardabweichung. Sie ist **student-t** verteilt mit  $\#dataPoints - \#parameters$  **Freiheitsgraden (df)**:

$$T = \frac{\hat{\beta}_j - \beta_{j0}}{\sqrt{\hat{V}_{jj}}} \sim T(n - 1 - J)$$

- ▶ (ii) Test einer **Funktion der Parameter**, z.B.  $H_0: \beta_1/\beta_2 = 2, \leq 2$  or  $\geq 2$ : Transformiere in eine Linearkombination, deren Normalisierung unter  $H_0^*$  wieder student-t verteilt ist. Im Beispiel gilt unter  $H_0^*$  die Bedingung  $b = \beta_1 - 2\beta_2 = 0$ :

$$\begin{aligned} \hat{b} &= \hat{\beta}_1 - 2\hat{\beta}_2, \\ \hat{V}(\hat{b}) &= \hat{V}_{11} + 4\hat{V}_{22} - 4\hat{V}_{12}, \\ T &= \frac{\hat{b}}{\sqrt{\hat{V}(\hat{b})}} \sim T(n - 1 - J) \end{aligned}$$



## Teststatistiken II

- ▶ (iii) Test des **Korrelationskoeffizients** von  $xy$ -Daten

$$\hat{\rho} = \frac{s_{xy}}{s_x s_y}, \quad H_0 : \rho = 0, \quad T = \frac{\hat{\rho}}{\sqrt{1 - \hat{\rho}^2}} \sqrt{n - 2} \sim T(n - 2)$$

*Herleitung:*  $\rho = 0$  genau dann, wenn  $\beta_1 = 0$  in einer linearen Einfachregression  $y = \beta_0 + \beta_1 x + \epsilon$ , läuft also auf einen Test von  $\beta_1 = 0$  hinaus. Under  $H_0$  ist die Teststatistik

$$T = \hat{\beta}_1 / \sqrt{\hat{V}_{11}} = \frac{s_{xy}}{\hat{\sigma} s_x} \sqrt{n} \sim T(n - 2)$$

Setzt man  $\hat{\sigma}$  ein, welcher hier analytisch berechnet werden kann:  
 $\hat{\sigma}^2 = n(s_y^2 - s_{xy}^2/s_x^2)/(n - 2)$ , bekommt man obiges Ergebnis

- ▶ (iv) Test der **Varianz** von  $\epsilon$ ,  $H_0: \sigma^2 = \sigma_0^2$ ,  $\sigma^2 \geq \sigma_0^2$ , and  $\sigma^2 \leq \sigma_0^2$ :

$$T = \frac{\hat{\sigma}^2}{\sigma_0^2} (n - 1 - J) \sim \chi^2(n - 1 - J)$$

Die **chi-Quadrat-Verteilung mit  $m$  Freiheitsgraden**  $\chi^2(m) = \sum_{i=1}^m Z_i^2$  ist die Summe von  $m$  quadrierten unabhängigen standardnormalverteilten Zufallsvariablen *Dichte nicht symmetrisch*  $\Rightarrow$  benötigte Tabellen für die  $\alpha$  and  $1 - \alpha$ -Quantile

## Teststatistiken II

- ▶ (iii) Test des **Korrelationskoeffizients** von  $xy$ -Daten

$$\hat{\rho} = \frac{s_{xy}}{s_x s_y}, \quad H_0 : \rho = 0, \quad T = \frac{\hat{\rho}}{\sqrt{1 - \hat{\rho}^2}} \sqrt{n - 2} \sim T(n - 2)$$

*Herleitung:*  $\rho = 0$  genau dann, wenn  $\beta_1 = 0$  in einer linearen Einfachregression  $y = \beta_0 + \beta_1 x + \epsilon$ , läuft also auf einen Test von  $\beta_1 = 0$  hinaus. Under  $H_0$  ist die Teststatistik

$$T = \hat{\beta}_1 / \sqrt{\hat{V}_{11}} = \frac{s_{xy}}{\hat{\sigma} s_x} \sqrt{n} \sim T(n - 2)$$

Setzt man  $\hat{\sigma}$  ein, welcher hier analytisch berechnet werden kann:  
 $\hat{\sigma}^2 = n(s_y^2 - s_{xy}^2/s_x^2)/(n - 2)$ , bekommt man obiges Ergebnis

- ▶ (iv) Test der **Varianz** von  $\epsilon$ ,  $H_0: \sigma^2 = \sigma_0^2$ ,  $\sigma^2 \geq \sigma_0^2$ , and  $\sigma^2 \leq \sigma_0^2$ :

$$T = \frac{\hat{\sigma}^2}{\sigma_0^2} (n - 1 - J) \sim \chi^2(n - 1 - J)$$

Die **chi-Quadrat-Verteilung mit  $m$  Freiheitsgraden**  $\chi^2(m) = \sum_{i=1}^m Z_i^2$  ist die Summe von  $m$  quadrierten unabhängigen standardnormalverteilten Zufallsvariablen *Dichte nicht symmetrisch*  $\Rightarrow$  benötigte Tabellen für die  $\alpha$  and  $1 - \alpha$ -Quantile

## Teststatistiken II

- ▶ (iii) Test des **Korrelationskoeffizients** von  $xy$ -Daten

$$\hat{\rho} = \frac{s_{xy}}{s_x s_y}, \quad H_0 : \rho = 0, \quad T = \frac{\hat{\rho}}{\sqrt{1 - \hat{\rho}^2}} \sqrt{n - 2} \sim T(n - 2)$$

*Herleitung:*  $\rho = 0$  genau dann, wenn  $\beta_1 = 0$  in einer linearen Einfachregression  $y = \beta_0 + \beta_1 x + \epsilon$ , läuft also auf einen Test von  $\beta_1 = 0$  hinaus. Under  $H_0$  ist die Teststatistik

$$T = \hat{\beta}_1 / \sqrt{\hat{V}_{11}} = \frac{s_{xy}}{\hat{\sigma} s_x} \sqrt{n} \sim T(n - 2)$$

Setzt man  $\hat{\sigma}$  ein, welcher hier analytisch berechnet werden kann:  
 $\hat{\sigma}^2 = n(s_y^2 - s_{xy}^2/s_x^2)/(n - 2)$ , bekommt man obiges Ergebnis

- ▶ (iv) Test der **Varianz** von  $\epsilon$ ,  $H_0: \sigma^2 = \sigma_0^2$ ,  $\sigma^2 \geq \sigma_0^2$ , and  $\sigma^2 \leq \sigma_0^2$ :

$$T = \frac{\hat{\sigma}^2}{\sigma_0^2} (n - 1 - J) \sim \chi^2(n - 1 - J)$$

Die **chi-Quadrat-Verteilung mit  $m$  Freiheitsgraden**  $\chi^2(m) = \sum_{i=1}^m Z_i^2$  ist die Summe von  $m$  quadrierten unabhängigen standardnormalverteilten Zufallsvariablen *Dichte nicht symmetrisch*  $\Rightarrow$  benötigte Tabellen für die  $\alpha$  and  $1 - \alpha$ -Quantile

## Teststatistiken III

- ▶ (v) Tests **simultaner Punkthypothesen**, e.g.,  $H_0: (\beta_1 = 0) \text{ AND } (\beta_2 = 2)$  mit dem **Fisher-F test**:

$$T = \frac{(S_0 - S)/(M - M_0)}{S/(n - M)} \sim F(M - M_0, n - M)$$

- ▶  $S$ : SSE des geschätzten vollen Modells mit  $M = J + 1$  Parametern
- ▶  $S_0$ : SSE des geschätzten *restringierten* Modells unter  $H_0$  mit  $M_0$  freien Parametern
- ▶ Die **Fisher-F** distribution ist i.W. der Quotient zweier unabhängiger  $\chi^2$  verteilter Zufallsgrößen

$$F(n, d) = \frac{\chi_n^2/n}{\chi_d^2/d},$$

$n$ : Zähler- und  $d$ : Nenner-Zahl der Freiheitsgrade

? Warum gilt immer  $S_0 \geq S$ ?

? Warum ist der  $F$ -Test mit  $M_0 = M - 1$  äquivalent zum  $T$ -Test?

## Teststatistiken III

- ▶ (v) Tests **simultaner Punkthypothesen**, e.g.,  $H_0: (\beta_1 = 0) \text{ AND } (\beta_2 = 2)$  mit dem **Fisher-F test**:

$$T = \frac{(S_0 - S)/(M - M_0)}{S/(n - M)} \sim F(M - M_0, n - M)$$

- ▶  $S$ : SSE des geschätzten vollen Modells mit  $M = J + 1$  Parametern
- ▶  $S_0$ : SSE des geschätzten *restringierten* Modells unter  $H_0$  mit  $M_0$  freien Parametern
- ▶ Die **Fisher-F** distribution ist i.W. der Quotient zweier unabhängiger  $\chi^2$  verteilter Zufallsgrößen

$$F(n, d) = \frac{\chi_n^2/n}{\chi_d^2/d},$$

$n$ : Zähler- und  $d$ : Nenner-Zahl der Freiheitsgrade

? Warum gilt immer  $S_0 \geq S$ ?

? Warum ist der  $F$ -Test mit  $M_0 = M - 1$  äquivalent zum  $t$ -Test?

## Teststatistiken III

- ▶ (v) Tests **simultaner Punkthypothesen**, e.g.,  $H_0: (\beta_1 = 0) \text{ AND } (\beta_2 = 2)$  mit dem **Fisher-F test**:

$$T = \frac{(S_0 - S)/(M - M_0)}{S/(n - M)} \sim F(M - M_0, n - M)$$

- ▶  $S$ : SSE des geschätzten vollen Modells mit  $M = J + 1$  Parametern
- ▶  $S_0$ : SSE des geschätzten *restringierten* Modells unter  $H_0$  mit  $M_0$  freien Parametern
- ▶ Die **Fisher-F** distribution ist i.W. der Quotient zweier unabhängiger  $\chi^2$  verteilter Zufallsgrößen

$$F(n, d) = \frac{\chi_n^2/n}{\chi_d^2/d},$$

$n$ : Zähler- und  $d$ : Nenner-Zahl der Freiheitsgrade

? Warum gilt immer  $S_0 \geq S$ ?

? Warum ist der  $F$ -Test mit  $M_0 = M - 1$  äquivalent zum  $T$ -Test?

## Teststatistiken III

- ▶ (v) Tests **simultaner Punkthypothesen**, e.g.,  $H_0: (\beta_1 = 0) \text{ AND } (\beta_2 = 2)$  mit dem **Fisher-F test**:

$$T = \frac{(S_0 - S)/(M - M_0)}{S/(n - M)} \sim F(M - M_0, n - M)$$

- ▶  $S$ : SSE des geschätzten vollen Modells mit  $M = J + 1$  Parametern
- ▶  $S_0$ : SSE des geschätzten *restringierten* Modells unter  $H_0$  mit  $M_0$  freien Parametern
- ▶ Die **Fisher-F** distribution ist i.W. der Quotient zweier unabhängiger  $\chi^2$  verteilter Zufallsgrößen

$$F(n, d) = \frac{\chi_n^2/n}{\chi_d^2/d},$$

$n$ : Zähler- und  $d$ : Nenner-Zahl der Freiheitsgrade

? Warum gilt immer  $S_0 \geq S$ ?

? Warum ist der  $F$ -Test mit  $M_0 = M - 1$  äquivalent zum  $T$ -Test?

## Teststatistiken III

- ▶ (v) Tests **simultaner Punkthypothesen**, e.g.,  $H_0: (\beta_1 = 0) \text{ AND } (\beta_2 = 2)$  mit dem **Fisher-F test**:

$$T = \frac{(S_0 - S)/(M - M_0)}{S/(n - M)} \sim F(M - M_0, n - M)$$

- ▶  $S$ : SSE des geschätzten vollen Modells mit  $M = J + 1$  Parametern
- ▶  $S_0$ : SSE des geschätzten *restringierten* Modells unter  $H_0$  mit  $M_0$  freien Parametern
- ▶ Die **Fisher-F** distribution ist i.W. der Quotient zweier unabhängiger  $\chi^2$  verteilter Zufallsgrößen

$$F(n, d) = \frac{\chi_n^2/n}{\chi_d^2/d},$$

$n$ : Zähler- und  $d$ : Nenner-Zahl der Freiheitsgrade

? Warum gilt immer  $S_0 \geq S$ ?

? Warum ist der  $F$ -Test mit  $M_0 = M - 1$  äquivalent zum  $T$ -Test?



## Teststatistiken III

- ▶ (v) Tests **simultaner Punkthypothesen**, e.g.,  $H_0: (\beta_1 = 0) \text{ AND } (\beta_2 = 2)$  mit dem **Fisher-F test**:

$$T = \frac{(S_0 - S)/(M - M_0)}{S/(n - M)} \sim F(M - M_0, n - M)$$

- ▶  $S$ : SSE des geschätzten vollen Modells mit  $M = J + 1$  Parametern
- ▶  $S_0$ : SSE des geschätzten *restringierten* Modells unter  $H_0$  mit  $M_0$  freien Parametern
- ▶ Die **Fisher-F** distribution ist i.W. der Quotient zweier unabhängiger  $\chi^2$  verteilter Zufallsgrößen

$$F(n, d) = \frac{\chi_n^2/n}{\chi_d^2/d},$$

$n$ : Zähler- und  $d$ : Nenner-Zahl der Freiheitsgrade

- ? Warum gilt immer  $S_0 \geq S$ ?
- ? Warum ist der  $F$ -Test mit  $M_0 = M - 1$  äquivalent zum  $T$ -Test?

## 13.1.3 Schritt 4: Test-Entscheidung

- ▶ Die Testentscheidung basiert auf den *Ablehnungsbereich* der Realisierungen  $t_{\text{data}}$ :

Der **Ablehnungsbereich**  $R^{(H_0)}(\alpha)$  zur Fehlerwahrscheinlichkeit  $\alpha$  enthält unter  $H_0^*$  den Anteil  $\alpha$  der Realisierungen  $t$  von  $T$ , welcher am weitesten von  $H_0$  entfernt ist

- ▶ Entscheidung:

$H_0$  is abgelehnt zur Fehlerwahrscheinlichkeit  $\alpha$ , falls  $t_{\text{data}} \in R^{(H_0)}(\alpha)$

- ▶ Für gute Teststatistiken ist  $R(\alpha)$  intuitiv definiert und die Ablehnungsregion ist so nahe an  $H_0^*$  wie möglich
- ▶ Im Gegensatz zu  $T$  und  $t_{\text{data}}$ , die nur vom Rand  $H_0^*$  abhängen ( $\Rightarrow$  dieselben für alle Arten von Punkt- und einseitigen Intervallhypothesen) hängt  $R^{(H_0)}(\alpha)$  von der Art der Nullhypothese und ggf vom Vergleichsoperator ( $=, >, <$ ) ab

### 13.1.3 Schritt 4: Test-Entscheidung

- ▶ Die Testentscheidung basiert auf den *Ablehnungsbereich* der Realisierungen  $t_{\text{data}}$ :

Der **Ablehnungsbereich**  $R^{(H_0)}(\alpha)$  zur Fehlerwahrscheinlichkeit  $\alpha$  enthält unter  $H_0^*$  den Anteil  $\alpha$  der Realisierungen  $t$  von  $T$ , welcher am weitesten von  $H_0$  entfernt ist

- ▶ Entscheidung:

$H_0$  is abgelehnt zur Fehlerwahrscheinlichkeit  $\alpha$ , falls  $t_{\text{data}} \in R^{(H_0)}(\alpha)$

- ▶ Für gute Teststatistiken ist  $R(\alpha)$  intuitiv definiert und die Ablehnungsregion ist so nahe an  $H_0^*$  wie möglich
- ▶ Im Gegensatz zu  $T$  und  $t_{\text{data}}$ , die nur vom Rand  $H_0^*$  abhängen ( $\Rightarrow$  dieselben für alle Arten von Punkt- und einseitigen Intervallhypothesen) hängt  $R^{(H_0)}(\alpha)$  von der Art der Nullhypothese und ggf vom Vergleichsoperator ( $=, >, <$ ) ab

### 13.1.3 Schritt 4: Test-Entscheidung

- ▶ Die Testentscheidung basiert auf den *Ablehnungsbereich* der Realisierungen  $t_{\text{data}}$ :

Der **Ablehnungsbereich**  $R^{(H_0)}(\alpha)$  zur Fehlerwahrscheinlichkeit  $\alpha$  enthält unter  $H_0^*$  den Anteil  $\alpha$  der Realisierungen  $t$  von  $T$ , welcher am weitesten von  $H_0$  entfernt ist

- ▶ Entscheidung:

$H_0$  is abgelehnt zur Fehlerwahrscheinlichkeit  $\alpha$ , falls  $t_{\text{data}} \in R^{(H_0)}(\alpha)$

- ▶ Für gute Teststatistiken ist  $R(\alpha)$  intuitiv definiert und die Ablehnungsregion ist so nahe an  $H_0^*$  wie möglich
- ▶ Im Gegensatz zu  $T$  und  $t_{\text{data}}$ , die nur vom Rand  $H_0^*$  abhängen ( $\Rightarrow$  dieselben für alle Arten von Punkt- und einseitigen Intervallhypothesen) hängt  $R^{(H_0)}(\alpha)$  von der Art der Nullhypothese und ggf vom Vergleichsoperator ( $=, >, <$ ) ab

### 13.1.3 Schritt 4: Test-Entscheidung

- ▶ Die Testentscheidung basiert auf den *Ablehnungsbereich* der Realisierungen  $t_{\text{data}}$ :


Der **Ablehnungsbereich**  $R^{(H_0)}(\alpha)$  zur Fehlerwahrscheinlichkeit  $\alpha$  enthält unter  $H_0^*$  den Anteil  $\alpha$  der Realisierungen  $t$  von  $T$ , welcher am weitesten von  $H_0$  entfernt ist

- ▶ Entscheidung:

$H_0$  is abgelehnt zur Fehlerwahrscheinlichkeit  $\alpha$ , falls  $t_{\text{data}} \in R^{(H_0)}(\alpha)$

- ▶ Für gute Teststatistiken ist  $R(\alpha)$  intuitiv definiert und die Ablehnungsregion ist so nahe an  $H_0^*$  wie möglich
- ▶ Im Gegensatz zu  $T$  und  $t_{\text{data}}$ , die nur vom Rand  $H_0^*$  abhängen ( $\Rightarrow$  dieselben für alle Arten von Punkt- und einseitigen Intervallhypothesen) hängt  $R^{(H_0)}(\alpha)$  von der Art der Nullhypothese und ggf vom Vergleichsoperator ( $=, \geq, \leq$ ) ab


# 1. Ablehnungsbereich für $H_0$ : “ $<$ ” or “ $\leq$ ” (Intervallhypothese)



- ▶  $H_0$  is abgelehnt zum Signifikanzniveau bzw. zur Fehlerwahrscheinlichkeit  $\alpha$  falls

$$t_{\text{data}} > t_{1-\alpha}$$


# 1. Ablehnungsbereich für $H_0$ : “ $<$ ” or “ $\leq$ ” (Intervallhypothese)



- ▶  $H_0$  is abgelehnt zum Signifikanzniveau bzw. zur Fehlerwahrscheinlichkeit  $\alpha$  falls

$$t_{\text{data}} > t_{1-\alpha}$$

## 2. Ablehnungsbereich für $H_0$ : “>” or “ $\geq$ ” (Intervallhypothese)




- ▶  $H_0$  ist abgelehnt zur Fehlerwahrscheinlichkeit  $\alpha$  falls

$$t_{\text{data}} < t_\alpha = 1 - t_{1-\alpha}$$

- ▶ (Das Gleichheitszeichen gilt nur für symmetrisch verteilte Statistiken)



## 2. Ablehnungsbereich für $H_0$ : “>” or “ $\geq$ ” (Intervallhypothese)




- ▶  $H_0$  ist abgelehnt zur Fehlerwahrscheinlichkeit  $\alpha$  falls

$$t_{\text{data}} < t_\alpha = 1 - t_{1-\alpha}$$

- ▶ (Das Gleichheitszeichen gilt nur für symmetrisch verteilte Statistiken)

## 2. Ablehnungsbereich für $H_0$ : “>” or “ $\geq$ ” (Intervallhypothese)




- ▶  $H_0$  ist abgelehnt zur Fehlerwahrscheinlichkeit  $\alpha$  falls

$$t_{\text{data}} < t_{\alpha} = 1 - t_{1-\alpha}$$

- ▶ (Das Gleichheitszeichen gilt nur für symmetrisch verteilte Statistiken)

### 3. Ablehnungsbereich für $H_0$ : “=” (Punkthypothese)




- ▶ Symmetrisch Teststatistiken:  $H_0$  zum Niveau  $\alpha$  abgelehnt, falls

$$|t_{\text{data}}| > t_{1-\alpha/2}$$

- ▶ Nichtsymmetrische Teststatistiken wie die  $\chi^2$  Verteilung des Varianztests: Definition “was ist am weitesten entfernt” nicht eindeutig  $\Rightarrow$  nehme auf beiden Seiten gleiche statistische Gewichte  $\alpha/2$  an:

$$\text{abgelehnt} \Leftrightarrow (t_{\text{data}} < t_{\alpha/2}) \cup (t_{\text{data}} > t_{1-\alpha/2})$$

### 3. Ablehnungsbereich für $H_0$ : “=” (Punkthypothese)



- ▶ Symmetrisch Teststatistiken:  $H_0$  zum Niveau  $\alpha$  abgelehnt, falls

$$|t_{\text{data}}| > t_{1-\alpha/2}$$

- ▶ Nichtsymmetrische Teststatistiken wie die  $\chi^2$  Verteilung des Varianztests: Definition “was ist am weitesten entfernt” nicht eindeutig  
 $\Rightarrow$  nehme auf beiden Seiten gleiche statistische Gewichte  $\alpha/2$  an:

$$\text{abgelehnt} \Leftrightarrow (t_{\text{data}} < t_{\alpha/2}) \cup (t_{\text{data}} > t_{1-\alpha/2})$$

## Hotel-Beispiel

Zweifachregression der Hotelbelegung  $y(x)$  [%]:

$$y = \beta_0 x_0 + \beta_1 x_1 + \beta_2 x_2 + \epsilon$$

$x_0 = 1$ ,  $x_1$ : Qualitäts-Proxy [# Sterne];  $x_2$ : Preis [€/night],

$$\hat{\beta}_0 = 25.5, \quad \hat{\beta}_1 = 38.2, \quad \hat{\beta}_2 = -0.952$$

mit der geschätzten Varianz-Kovarianz-Matrix

$$\hat{\mathbf{V}} = \begin{pmatrix} 28.0 & -6.40 & -0.119 \\ -6.40 & 26.0 & -0.941 \\ -0.119 & -0.941 & 0.0397 \end{pmatrix}$$

? Formuliere und teste  $H_{01}$ : "Die Sterne sind egal"

!  $H_{01} : \beta_1 = 0$ ,  $T = \hat{\beta}_1 / \sqrt{\hat{V}_{11}} \sim T(12 - 3)$ , also  $df = 9$  Freiheitsgrade,  $t_{\text{data}} = 7.49$ ,  $t_{0.975}^{(9)} = 2.26 < |t_{\text{data}}| \Rightarrow H_0$  abgelehnt, die Sterne sind relevant

? Bevorzugen die Leute mehr Sterne? (bei  $\alpha = 5\%$ )?

!  $H_{02} : \beta_1 \leq 0$  (wähle  $H_{01}$  so, dass eine Ablehnung eine Aussage ergibt!), Intervalltest mit  $T$  und  $t_{\text{data}}$  wie oben, aber neue Entscheidung:

$t_{0.05}^{(9)} = 1.83 < t_{\text{data}} \Rightarrow H_{02}$  abgelehnt, mehr Sterne sind besser als weniger Sterne

## Hotel-Beispiel

Zweifachregression der Hotelbelegung  $y(x)$  [%]:

$$y = \beta_0 x_0 + \beta_1 x_1 + \beta_2 x_2 + \epsilon$$

$x_0 = 1$ ,  $x_1$ : Qualitäts-Proxy [# Sterne];  $x_2$ : Preis [€/night],

$$\hat{\beta}_0 = 25.5, \quad \hat{\beta}_1 = 38.2, \quad \hat{\beta}_2 = -0.952$$

mit der geschätzten Varianz-Kovarianz-Matrix

$$\hat{\mathbf{V}} = \begin{pmatrix} 28.0 & -6.40 & -0.119 \\ -6.40 & 26.0 & -0.941 \\ -0.119 & -0.941 & 0.0397 \end{pmatrix}$$

? Formuliere und teste  $H_{01}$ : "Die Sterne sind egal"

!  $H_{01} : \beta_1 = 0$ ,  $T = \hat{\beta}_1 / \sqrt{\hat{V}_{11}} \sim T(12 - 3)$ , also  $df = 9$  Freiheitsgrade,  $t_{\text{data}} = 7.49$ ,  $t_{0.975}^{(9)} = 2.26 < |t_{\text{data}}| \Rightarrow H_0$  abgelehnt, die Sterne sind relevant

? Bevorzugen die Leute mehr Sterne? (bei  $\alpha = 5\%$ )?

!  $H_{02} : \beta_1 \leq 0$  (wähle  $H_0$  so, dass eine Ablehnung eine Aussage ergibt!), Intervalltest mit  $T$  und  $t_{\text{data}}$  wie oben, aber neue Entscheidung:

$t_{0.95}^{(9)} = 1.83 < t_{\text{data}} \Rightarrow H_{02}$  abgelehnt, mehr Sterne sind besser als weniger Sterne

## Hotel-Beispiel

Zweifachregression der Hotelbelegung  $y(x)$  [%]:

$$y = \beta_0 x_0 + \beta_1 x_1 + \beta_2 x_2 + \epsilon$$

$x_0 = 1$ ,  $x_1$ : Qualitäts-Proxy [# Sterne];  $x_2$ : Preis [€/night],

$$\hat{\beta}_0 = 25.5, \quad \hat{\beta}_1 = 38.2, \quad \hat{\beta}_2 = -0.952$$

mit der geschätzten Varianz-Kovarianz-Matrix

$$\hat{\mathbf{V}} = \begin{pmatrix} 28.0 & -6.40 & -0.119 \\ -6.40 & 26.0 & -0.941 \\ -0.119 & -0.941 & 0.0397 \end{pmatrix}$$

? Formuliere und teste  $H_{01}$ : "Die Sterne sind egal"

!  $H_{01} : \beta_1 = 0$ ,  $T = \hat{\beta}_1 / \sqrt{\hat{V}_{11}} \sim T(12 - 3)$ , also  $df = 9$  Freiheitsgrade,  $t_{\text{data}} = 7.49$ ,  $t_{0.975}^{(9)} = 2.26 < |t_{\text{data}}| \Rightarrow H_0$  abgelehnt, die Sterne sind relevant

? Bevorzugen die Leute mehr Sterne? (bei  $\alpha = 5\%$ )?

!  $H_{02} : \beta_1 \leq 0$  (wähle  $H_0$  so, dass eine Ablehnung eine Aussage ergibt!), Intervalltest mit  $T$  und  $t_{\text{data}}$  wie oben, aber neue Entscheidung:

$t_{0.95}^{(9)} = 1.83 < t_{\text{data}} \Rightarrow H_{02}$  abgelehnt, mehr Sterne sind besser als weniger Sterne

## Hotel-Beispiel

Zweifachregression der Hotelbelegung  $y(x)$  [%]:

$$y = \beta_0 x_0 + \beta_1 x_1 + \beta_2 x_2 + \epsilon$$

$x_0 = 1$ ,  $x_1$ : Qualitäts-Proxy [# Sterne];  $x_2$ : Preis [€/night],

$$\hat{\beta}_0 = 25.5, \quad \hat{\beta}_1 = 38.2, \quad \hat{\beta}_2 = -0.952$$

mit der geschätzten Varianz-Kovarianz-Matrix

$$\hat{\mathbf{V}} = \begin{pmatrix} 28.0 & -6.40 & -0.119 \\ -6.40 & 26.0 & -0.941 \\ -0.119 & -0.941 & 0.0397 \end{pmatrix}$$

? Formuliere und teste  $H_{01}$ : "Die Sterne sind egal"

!  $H_{01} : \beta_1 = 0$ ,  $T = \hat{\beta}_1 / \sqrt{\hat{V}_{11}} \sim T(12 - 3)$ , also  $df = 9$  Freiheitsgrade,  $t_{\text{data}} = 7.49$ ,  $t_{0.975}^{(9)} = 2.26 < |t_{\text{data}}| \Rightarrow H_0$  abgelehnt, die Sterne sind relevant

? Bevorzugen die Leute mehr Sterne? (bei  $\alpha = 5\%$ )?

!  $H_{02} : \beta_1 \leq 0$  (wähle  $H_0$  so, dass eine Ablehnung eine Aussage ergibt!), Intervalltest mit  $T$  und  $t_{\text{data}}$  wie oben, aber neue Entscheidung:

$t_{0.95}^{(9)} = 1.83 < t_{\text{data}} \Rightarrow H_{02}$  abgelehnt, mehr Sterne sind besser als weniger Sterne



## Hotel-Beispiel

Zweifachregression der Hotelbelegung  $y(x)$  [%]:

$$y = \beta_0 x_0 + \beta_1 x_1 + \beta_2 x_2 + \epsilon$$

$x_0 = 1$ ,  $x_1$ : Qualitäts-Proxy [# Sterne];  $x_2$ : Preis [€/night],

$$\hat{\beta}_0 = 25.5, \quad \hat{\beta}_1 = 38.2, \quad \hat{\beta}_2 = -0.952$$

mit der geschätzten Varianz-Kovarianz-Matrix

$$\hat{\mathbf{V}} = \begin{pmatrix} 28.0 & -6.40 & -0.119 \\ -6.40 & 26.0 & -0.941 \\ -0.119 & -0.941 & 0.0397 \end{pmatrix}$$

? Formuliere und teste  $H_{01}$ : "Die Sterne sind egal"

!  $H_{01} : \beta_1 = 0$ ,  $T = \hat{\beta}_1 / \sqrt{\hat{V}_{11}} \sim T(12 - 3)$ , also  $df = 9$  Freiheitsgrade,  $t_{\text{data}} = 7.49$ ,  $t_{0.975}^{(9)} = 2.26 < |t_{\text{data}}| \Rightarrow H_0$  abgelehnt, die Sterne sind relevant

? Bevorzugen die Leute mehr Sterne? (bei  $\alpha = 5\%$ )

!  $H_{02} : \beta_1 \leq 0$  (wähle  $H_0$  so, dass eine Ablehnung eine Aussage ergibt!), Intervalltest mit  $T$  und  $t_{\text{data}}$  wie oben, aber neue Entscheidung:  
 $t_{0.95}^{(9)} = 1.83 < t_{\text{data}} \Rightarrow H_{02}$  abgelehnt, mehr Sterne sind besser als weniger Sterne

## Hotelbeispiel (Fortsetzung)

? Reduziert eine Preiserhöhung um einen € pro nacht die Auslastung um höchstens 1%?

!  $H_{03} : \beta_2 < -1$  ( $H_{03}$  is wieder das Gegenereignis!),

$t_{\text{data}} = (\hat{\beta}_2 + 1) / \sqrt{\hat{V}_{22}} = 0.24 > t_{0.95}^{(9)} = 1.83 \Rightarrow H_{03}$  nicht abgelehnt  
 $\Rightarrow$  der Hotelmanager riskiert einen Verlust von möglicherweise mehr als einen Prozentpunkt

? Lohnt sich die Investition für einen zusätzlichen Stern sodass ich 30€ mehr verlangen kann, ohne Gäste zu verlieren?

! Definiere wieder das Gegenereignis  $H_{04} : \beta_1 \leq -30\beta_2$  bzw.  $\gamma = \beta_1 + 30\beta_2 \leq 0$

$$\begin{aligned}\hat{\gamma} &= \hat{\beta}_1 + 30\hat{\beta}_2 = 9.63, \\ \hat{V}(\hat{\gamma}) &= \hat{V}_{11} + 900\hat{V}_{22} + 2 * 1 * 30\hat{V}_{12} = 5.27\end{aligned}$$

$t_{\text{data}} = \hat{\gamma} / \sqrt{\hat{V}(\hat{\gamma})} = 4.20 > t_{0.95}^{(9)} = 1.83 \Rightarrow H_{04}$  abgelehnt bei 5%  $\Rightarrow$  Das Risiko einer geringeren Belegung liegt unter 5%

? Kann simultan  $\beta_1 = 30$  und  $\beta_2 = -1$  gelten?

! Volles Modell:  $\hat{\beta} = (25.5, 38.2, -0.952)'$ ,  $S(\hat{\beta}) = 498.2$ ;

Restringiertes Modell mit festem  $\beta_1 = 30$ ,  $\beta_2 = 1 \Rightarrow \hat{\beta}_0 = 49.0$ :

$\hat{\beta}_* = (49.0, 30, -1)'$ ,  $S_0 = S(\hat{\beta}_*) = 1808$ ;  $M - M_0 = 2$  df,  $n - M = 9$  df.

$T \Rightarrow F(2, 9)$ ,  $t_{\text{data}} = 9/2 (S_0 - S) / S = 11.8 > f_{0.95}^{(2, 9)} = 4.26 \Rightarrow H_0$  abgelehnt

## Hotelbeispiel (Fortsetzung)

? Reduziert eine Preiserhöhung um einen € pro nacht die Auslastung um höchstens 1%?

!  $H_{03} : \beta_2 < -1$  ( $H_{03}$  is wieder das Gegenereignis!),

$t_{\text{data}} = (\hat{\beta}_2 + 1) / \sqrt{\hat{V}_{22}} = 0.24 > t_{0,95}^{(9)} = 1.83 \Rightarrow H_{03}$  nicht abgelehnt  
 $\Rightarrow$  der Hotelmanager riskiert einen Verlust von möglicherweise mehr als einen Prozentpunkt

? Lohnt sich die Investition für einen zusätzlichen Stern sodass ich 30€ mehr verlangen kann, ohne Gäste zu verlieren?

! Definiere wieder das Gegenereignis  $H_{04} : \beta_1 \leq -30\beta_2$  bzw.  $\gamma = \beta_1 + 30\beta_2 \leq 0$

$$\begin{aligned}\hat{\gamma} &= \hat{\beta}_1 + 30\hat{\beta}_2 = 9.63, \\ \hat{V}(\hat{\gamma}) &= \hat{V}_{11} + 900\hat{V}_{22} + 2 * 1 * 30\hat{V}_{12} = 5.27\end{aligned}$$

$t_{\text{data}} = \hat{\gamma} / \sqrt{\hat{V}(\hat{\gamma})} = 4.20 > t_{0,95}^{(9)} = 1.83 \Rightarrow H_{04}$  abgelehnt bei 5%  $\Rightarrow$  Das Risiko einer geringeren Belegung liegt unter 5%

? Kann simultan  $\beta_1 = 30$  und  $\beta_2 = -1$  gelten?

! Volles Modell:  $\hat{\beta} = (25.5, 38.2, -0.952)'$ ,  $S(\hat{\beta}) = 498.2$ ;

Restringiertes Modell mit festem  $\beta_1 = 30$ ,  $\beta_2 = -1 \Rightarrow \hat{\beta}_0 = 49.0$ ;

$\hat{\beta}_* = (49.0, 30, -1)'$ ,  $S_0 = S(\hat{\beta}_*) = 1808$ ;  $M - M_0 = 2$  df,  $n - M = 9$  df.

$T \Rightarrow F(2, 9)$ ,  $t_{\text{data}} = 9/2 (S_0 - S) / S = 11.8 > f_{0,95}^{(2,9)} = 4.26 \Rightarrow H_0$  abgelehnt

## Hotelbeispiel (Fortsetzung)

? Reduziert eine Preiserhöhung um einen € pro nacht die Auslastung um höchstens 1%?

!  $H_{03} : \beta_2 < -1$  ( $H_{03}$  is wieder das Gegenereignis!),

$t_{\text{data}} = (\hat{\beta}_2 + 1) / \sqrt{\hat{V}_{22}} = 0.24 > t_{0,95}^{(9)} = 1.83 \Rightarrow H_{03}$  nicht abgelehnt  
 $\Rightarrow$  der Hotelmanager riskiert einen Verlust von möglicherweise mehr als einen Prozentpunkt

? Lohnt sich die Investition für einen zusätzlichen Stern sodass ich 30€ mehr verlangen kann, ohne Gäste zu verlieren?

! Definiere wieder das Gegenereignis  $H_{04} : \beta_1 \leq -30\beta_2$  bzw.  $\gamma = \beta_1 + 30\beta_2 \leq 0$

$$\begin{aligned}\hat{\gamma} &= \hat{\beta}_1 + 30\hat{\beta}_2 = 9.63, \\ \hat{V}(\hat{\gamma}) &= \hat{V}_{11} + 900\hat{V}_{22} + 2 * 1 * 30\hat{V}_{12} = 5.27\end{aligned}$$

$t_{\text{data}} = \hat{\gamma} / \sqrt{\hat{V}(\hat{\gamma})} = 4.20 > t_{0,95}^{(9)} = 1.83 \Rightarrow H_{04}$  abgelehnt bei 5%  $\Rightarrow$  Das Risiko einer geringeren Belegung liegt unter 5%

? Kann simultan  $\beta_1 = 30$  und  $\beta_2 = -1$  gelten?

! Volles Modell:  $\hat{\beta} = (25.5, 38.2, -0.952)'$ ,  $S(\hat{\beta}) = 498.2$ ;

Restringiertes Modell mit festem  $\beta_1 = 30$ ,  $\beta_2 = -1 \Rightarrow \hat{\beta}_0 = 49.0$ ;

$\hat{\beta}_* = (49.0, 30, -1)'$ ,  $S_0 = S(\hat{\beta}_*) = 1808$ ;  $M - M_0 = 2$  df,  $n - M = 9$  df.

$T = F(2, 9)$ ,  $t_{\text{data}} = 9/2 (S_0 - S) / S = 11.8 > f_{0,95}^{(2,9)} = 4.26 \Rightarrow H_0$  abgelehnt

## Hotelbeispiel (Fortsetzung)

? Reduziert eine Preiserhöhung um einen € pro nacht die Auslastung um höchstens 1%?

!  $H_{03} : \beta_2 < -1$  ( $H_{03}$  is wieder das Gegenereignis!),

$t_{\text{data}} = (\hat{\beta}_2 + 1) / \sqrt{\hat{V}_{22}} = 0.24 > t_{0,95}^{(9)} = 1.83 \Rightarrow H_{03}$  nicht abgelehnt  
 $\Rightarrow$  der Hotelmanager riskiert einen Verlust von möglicherweise mehr als einen Prozentpunkt

? Lohnt sich die Investition für einen zusätzlichen Stern sodass ich 30€ mehr verlangen kann, ohne Gäste zu verlieren?

! Definiere wieder das Gegenereignis  $H_{04} : \beta_1 \leq -30\beta_2$  bzw.  $\gamma = \beta_1 + 30\beta_2 \leq 0$

$$\begin{aligned}\hat{\gamma} &= \hat{\beta}_1 + 30\hat{\beta}_2 = 9.63, \\ \hat{V}(\hat{\gamma}) &= \hat{V}_{11} + 900\hat{V}_{22} + 2 * 1 * 30\hat{V}_{12} = 5.27\end{aligned}$$

$t_{\text{data}} = \hat{\gamma} / \sqrt{\hat{V}(\hat{\gamma})} = 4.20 > t_{0,95}^{(9)} = 1.83 \Rightarrow H_{04}$  abgelehnt bei 5%  $\Rightarrow$  Das Risiko einer geringeren Belegung liegt unter 5%

? Kann simultan  $\beta_1 = 30$  und  $\beta_2 = -1$  gelten?

! Volles Modell:  $\hat{\beta} = (25.5, 38.2, -0.952)'$ ,  $S(\hat{\beta}) = 498.2$ ;

Restringiertes Modell mit festem  $\beta_1 = 30$ ,  $\beta_2 = 1 \Rightarrow \hat{\beta}_0 = 49.0$ :

$\hat{\beta}_r = (49.0, 30, -1)'$ ,  $S_0 = S(\hat{\beta}_r) = 1808$ ;  $M - M_0 = 2$  d.f.,  $n - M = 9$  d.f.

$T_{\text{data}} \sim F(2, 9)$ ,  $t_{\text{data}} = 9/2 (S_0 - S)/S = 11.8 > f_{0,95}^{(2,9)} = 4.26 \Rightarrow H_0$  abgelehnt

## Hotelbeispiel (Fortsetzung)

? Reduziert eine Preiserhöhung um einen € pro nacht die Auslastung um höchstens 1%?

!  $H_{03} : \beta_2 < -1$  ( $H_{03}$  is wieder das Gegenereignis!),

$t_{\text{data}} = (\hat{\beta}_2 + 1) / \sqrt{\hat{V}_{22}} = 0.24 > t_{0,95}^{(9)} = 1.83 \Rightarrow H_{03}$  nicht abgelehnt  
 $\Rightarrow$  der Hotelmanager riskiert einen Verlust von möglicherweise mehr als einen Prozentpunkt

? Lohnt sich die Investition für einen zusätzlichen Stern sodass ich 30€ mehr verlangen kann, ohne Gäste zu verlieren?

! Definiere wieder das Gegenereignis  $H_{04} : \beta_1 \leq -30\beta_2$  bzw.  $\gamma = \beta_1 + 30\beta_2 \leq 0$

$$\begin{aligned}\hat{\gamma} &= \hat{\beta}_1 + 30\hat{\beta}_2 = 9.63, \\ \hat{V}(\hat{\gamma}) &= \hat{V}_{11} + 900\hat{V}_{22} + 2 * 1 * 30\hat{V}_{12} = 5.27\end{aligned}$$

$t_{\text{data}} = \hat{\gamma} / \sqrt{\hat{V}(\hat{\gamma})} = 4.20 > t_{0,95}^{(9)} = 1.83 \Rightarrow H_{04}$  abgelehnt bei 5%  $\Rightarrow$  Das Risiko einer geringeren Belegung liegt unter 5%

? Kann simultan  $\beta_1 = 30$  und  $\beta_2 = -1$  gelten?

! Volles Modell:  $\hat{\beta} = (25.5, 38.2, -0.952)'$ ,  $S(\hat{\beta}) = 498.2$ ;

Restringiertes Modell mit festem  $\beta_1 = 30$ ,  $\beta_2 = 1 \Rightarrow \hat{\beta}_0 = 49.0$ :

$\hat{\beta}_r = (49.0, 30, -1)'$ ,  $S_0 = S(\hat{\beta}_r) = 1808$ ;  $M - M_0 = 2$  df,  $n - M = 9$  df,

$T \sim F(2, 9)$ ,  $t_{\text{data}} = 9/2 (S_0 - S)/S = 11.8 > f_{0,95}^{(2,9)} = 4.26 \Rightarrow H_0$  abgelehnt

## Hotelbeispiel (Fortsetzung)

? Reduziert eine Preiserhöhung um einen € pro nacht die Auslastung um höchstens 1%?

!  $H_{03} : \beta_2 < -1$  ( $H_{03}$  is wieder das Gegenereignis!),

$t_{\text{data}} = (\hat{\beta}_2 + 1) / \sqrt{\hat{V}_{22}} = 0.24 > t_{0,95}^{(9)} = 1.83 \Rightarrow H_{03}$  nicht abgelehnt  
 $\Rightarrow$  der Hotelmanager riskiert einen Verlust von möglicherweise mehr als einen Prozentpunkt

? Lohnt sich die Investition für einen zusätzlichen Stern sodass ich 30€ mehr verlangen kann, ohne Gäste zu verlieren?

! Definiere wieder das Gegenereignis  $H_{04} : \beta_1 \leq -30\beta_2$  bzw.  $\gamma = \beta_1 + 30\beta_2 \leq 0$

$$\begin{aligned}\hat{\gamma} &= \hat{\beta}_1 + 30\hat{\beta}_2 = 9.63, \\ \hat{V}(\hat{\gamma}) &= \hat{V}_{11} + 900\hat{V}_{22} + 2 * 1 * 30\hat{V}_{12} = 5.27\end{aligned}$$

$t_{\text{data}} = \hat{\gamma} / \sqrt{\hat{V}(\hat{\gamma})} = 4.20 > t_{0,95}^{(9)} = 1.83 \Rightarrow H_{04}$  abgelehnt bei 5%  $\Rightarrow$  Das Risiko einer geringeren Belegung liegt unter 5%

? Kann simultan  $\beta_1 = 30$  und  $\beta_2 = -1$  gelten?

! Volles Modell:  $\hat{\beta} = (25.5, 38.2, -0.952)'$ ,  $S(\hat{\beta}) = 498.2$ ;

Restringiertes Modell mit festem  $\beta_1 = 30$ ,  $\beta_2 = 1 \Rightarrow \hat{\beta}_0 = 49.0$ :

$\hat{\beta}_r = (49.0, 30, -1)'$ ,  $S_0 = S(\hat{\beta}_r) = 1808$ :  $M - M_0 = 2$  df,  $n - M = 9$  df,

$T \sim F(2, 9)$ ,  $t_{\text{data}} = 9/2 (S_0 - S)/S = 11.8 > f_{0,95}^{(2,9)} = 4.26 \Rightarrow H_0$  abgelehnt

## Hotelbeispiel (Fortsetzung)

? Reduziert eine Preiserhöhung um einen € pro nacht die Auslastung um höchstens 1%?

!  $H_{03} : \beta_2 < -1$  ( $H_{03}$  is wieder das Gegenereignis!),

$t_{\text{data}} = (\hat{\beta}_2 + 1) / \sqrt{\hat{V}_{22}} = 0.24 > t_{0,95}^{(9)} = 1.83 \Rightarrow H_{03}$  nicht abgelehnt  
 $\Rightarrow$  der Hotelmanager riskiert einen Verlust von möglicherweise mehr als einen Prozentpunkt

? Lohnt sich die Investition für einen zusätzlichen Stern sodass ich 30€ mehr verlangen kann, ohne Gäste zu verlieren?

! Definiere wieder das Gegenereignis  $H_{04} : \beta_1 \leq -30\beta_2$  bzw.  $\gamma = \beta_1 + 30\beta_2 \leq 0$

$$\begin{aligned}\hat{\gamma} &= \hat{\beta}_1 + 30\hat{\beta}_2 = 9.63, \\ \hat{V}(\hat{\gamma}) &= \hat{V}_{11} + 900\hat{V}_{22} + 2 * 1 * 30\hat{V}_{12} = 5.27\end{aligned}$$

$t_{\text{data}} = \hat{\gamma} / \sqrt{\hat{V}(\hat{\gamma})} = 4.20 > t_{0,95}^{(9)} = 1.83 \Rightarrow H_{04}$  abgelehnt bei 5%  $\Rightarrow$  Das Risiko einer geringeren Belegung liegt unter 5%

? Kann simultan  $\beta_1 = 30$  und  $\beta_2 = -1$  gelten?

! Volles Modell:  $\hat{\beta} = (25.5, 38.2, -0.952)'$ ,  $S(\hat{\beta}) = 498.2$ ;

Restringiertes Modell mit festem  $\beta_1 = 30$ ,  $\beta_2 = 1 \Rightarrow \hat{\beta}_0 = 49.0$ :

$\hat{\beta}_r = (49.0, 30, -1)'$ ,  $S_0 = S(\hat{\beta}_r) = 1808$ ;  $M - M_0 = 2$  df,  $n - M = 9$  df,

$T \sim F(2, 9)$ ,  $t_{\text{data}} = 9/2 (S_0 - S)/S = 11.8 > f_{0,95}^{(2,9)} = 4.26 \Rightarrow H_0$  abgelehnt



## Hotelbeispiel (Fortsetzung)

? Reduziert eine Preiserhöhung um einen € pro nacht die Auslastung um höchstens 1%?

!  $H_{03} : \beta_2 < -1$  ( $H_{03}$  is wieder das Gegenereignis!),

$t_{\text{data}} = (\hat{\beta}_2 + 1) / \sqrt{\hat{V}_{22}} = 0.24 > t_{0.95}^{(9)} = 1.83 \Rightarrow H_{03}$  nicht abgelehnt  
 $\Rightarrow$  der Hotelmanager riskiert einen Verlust von möglicherweise mehr als einen Prozentpunkt

? Lohnt sich die Investition für einen zusätzlichen Stern sodass ich 30€ mehr verlangen kann, ohne Gäste zu verlieren?

! Definiere wieder das Gegenereignis  $H_{04} : \beta_1 \leq -30\beta_2$  bzw.  $\gamma = \beta_1 + 30\beta_2 \leq 0$

$$\begin{aligned}\hat{\gamma} &= \hat{\beta}_1 + 30\hat{\beta}_2 = 9.63, \\ \hat{V}(\hat{\gamma}) &= \hat{V}_{11} + 900\hat{V}_{22} + 2 * 1 * 30\hat{V}_{12} = 5.27\end{aligned}$$

$t_{\text{data}} = \hat{\gamma} / \sqrt{\hat{V}(\hat{\gamma})} = 4.20 > t_{0.95}^{(9)} = 1.83 \Rightarrow H_{04}$  abgelehnt bei 5%  $\Rightarrow$  Das Risiko einer geringeren Belegung liegt unter 5%

? Kann simultan  $\beta_1 = 30$  und  $\beta_2 = -1$  gelten?

! Volles Modell:  $\hat{\beta} = (25.5, 38.2, -0.952)'$ ,  $S(\hat{\beta}) = 498.2$ ;

Restringiertes Modell mit festem  $\beta_1 = 30$ ,  $\beta_2 = 1 \Rightarrow \hat{\beta}_0 = 49.0$ :

$\hat{\beta}_r = (49.0, 30, -1)'$ ,  $S_0 = S(\hat{\beta}_r) = 1808$ ;  $M - M_0 = 2$  df,  $n - M = 9$  df,

$T \sim F(2, 9)$ ,  $t_{\text{data}} = 9/2 (S_0 - S)/S = 11.8 > f_{0.95}^{(2,9)} = 4.26 \Rightarrow H_0$  abgelehnt

## 13.1.4 Der $p$ -Wert

- ▶ Ein Test auf eine feste Fehlerwahrscheinlichkeit  $\alpha$  ist nicht sonderlich effizient, da man im Dunkeln über die *wirkliche Signifikanz* stochert:
- ▶ Ich will eigentlich die *minimale* Fehlerwahrscheinlichkeit wissen, die eine Ablehnung ergibt: Das ist der  **$p$ -Wert**.
- ▶ Allgemeinste Definition:

$$p = \text{Prob}(T \in E_{\text{data}} | H_0^*)$$

Die *Extremregion*  $E_{\text{data}}$  enthält alle möglichen Realisierungen von  $T$ , welche *weiter* von  $H_0$  entfernt sind als  $t_{\text{data}}$ , also liegt  $t_{\text{data}}$  auf dem Rand von  $E_{\text{data}}$  Zusammenhang mit Ablehnungsbereich?  
 $p$  is so definiert, dass  $E_{\text{data}} = R(p)$

- ▶  $p \geq 5\%$ : nicht signifikant (kein Stern beim Wert für  $\beta_1$ , manchmal "+", falls zwischen 5% und 10%, z.B.  $\beta_1 = 4.2^+$ )
- ▶  $p < 5\%$ : signifikant (ein Stern, z.B.  $\beta_1 = 4.2^*$ )
- ▶  $p < 1\%$ : sehr signifikant (zwei Sterne,  $\beta_1 = 4.2^{**}$ )
- ▶  $p < 0.001$ : hochgradig signifikant (drei Sterne,  $\beta_1 = 4.2^{***}$ )

## 13.1.4 Der $p$ -Wert

- ▶ Ein Test auf eine feste Fehlerwahrscheinlichkeit  $\alpha$  ist nicht sonderlich effizient, da man im Dunkeln über die *wirkliche Signifikanz* stochert:
- ▶ Ich will eigentlich die *minimale* Fehlerwahrscheinlichkeit wissen, die eine Ablehnung ergibt: Das ist der  **$p$ -Wert**.
- ▶ Allgemeinste Definition:

$$p = \text{Prob}(T \in E_{\text{data}} | H_0^*)$$

Die *Extremregion*  $E_{\text{data}}$  enthält alle möglichen Realisierungen von  $T$ , welche *weiter* von  $H_0$  entfernt sind als  $t_{\text{data}}$ , also liegt  $t_{\text{data}}$  auf dem Rand von  $E_{\text{data}}$  Zusammenhang mit Ablehnungsbereich?  
 $p$  is so definiert, dass  $E_{\text{data}} = R(p)$

- ▶  $p \geq 5\%$ : nicht signifikant (kein Stern beim Wert für  $\beta_1$ , manchmal "+", falls zwischen 5% und 10%, z.B.  $\beta_1 = 4.2^+$ )
- ▶  $p < 5\%$ : signifikant (ein Stern, z.B.  $\beta_1 = 4.2^*$ )
- ▶  $p < 1\%$ : sehr signifikant (zwei Sterne,  $\beta_1 = 4.2^{**}$ )
- ▶  $p < 0.001$ : hochgradig signifikant (drei Sterne,  $\beta_1 = 4.2^{***}$ )

## 13.1.4 Der $p$ -Wert

- ▶ Ein Test auf eine feste Fehlerwahrscheinlichkeit  $\alpha$  ist nicht sonderlich effizient, da man im Dunkeln über die *wirkliche Signifikanz* stochert:
- ▶ Ich will eigentlich die *minimale* Fehlerwahrscheinlichkeit wissen, die eine Ablehnung ergibt: Das ist der  **$p$ -Wert**.
- ▶ Allgemeinste Definition:

$$p = \text{Prob}(T \in E_{\text{data}} | H_0^*)$$

Die *Extremregion*  $E_{\text{data}}$  enthält alle möglichen Realisierungen von  $T$ , welche *weiter* von  $H_0$  entfernt sind als  $t_{\text{data}}$ , also liegt  $t_{\text{data}}$  auf dem Rand von  $E_{\text{data}}$  Zusammenhang mit Ablehnungsbereich?

$p$  is so definiert, dass  $E_{\text{data}} = R(p)$

- ▶  $p \geq 5\%$ : nicht signifikant (kein Stern beim Wert für  $\beta$ , manchmal "+", falls zwischen 5% und 10%, z.B.  $\beta_1 = 4.2^+$ )
- ▶  $p < 5\%$ : signifikant (ein Stern, z.B.  $\beta_1 = 4.2^*$ )
- ▶  $p < 1\%$ : sehr signifikant (zwei Sterne,  $\beta_1 = 4.2^{**}$ )
- ▶  $p < 0.001$ : hochgradig signifikant (drei Sterne,  $\beta_1 = 4.2^{***}$ )

## 13.1.4 Der $p$ -Wert

- ▶ Ein Test auf eine feste Fehlerwahrscheinlichkeit  $\alpha$  ist nicht sonderlich effizient, da man im Dunkeln über die *wirkliche Signifikanz* stochert:
- ▶ Ich will eigentlich die *minimale* Fehlerwahrscheinlichkeit wissen, die eine Ablehnung ergibt: Das ist der  **$p$ -Wert**.
- ▶ Allgemeinste Definition:

$$p = \text{Prob}(T \in E_{\text{data}} | H_0^*)$$

Die *Extremregion*  $E_{\text{data}}$  enthält alle möglichen Realisierungen von  $T$ , welche *weiter* von  $H_0$  entfernt sind als  $t_{\text{data}}$ , also liegt  $t_{\text{data}}$  auf dem Rand von  $E_{\text{data}}$  Zusammenhang mit Ablehnungsbereich?

$p$  is so definiert, dass  $E_{\text{data}} = R(p)$

- ▶  $p \geq 5\%$ : nicht signifikant (kein Stern beim Wert für  $\beta$ , manchmal "+", falls zwischen 5% und 10%, z.B.  $\beta_1 = 4.2^+$ )
- ▶  $p < 5\%$ : signifikant (ein Stern, z.B.  $\beta_1 = 4.2^*$ )
- ▶  $p < 1\%$ : sehr signifikant (zwei Sterne,  $\beta_1 = 4.2^{**}$ )
- ▶  $p < 0.001$ : hochgradig signifikant (drei Sterne,  $\beta_1 = 4.2^{***}$ )

## 13.1.4 Der $p$ -Wert

- ▶ Ein Test auf eine feste Fehlerwahrscheinlichkeit  $\alpha$  ist nicht sonderlich effizient, da man im Dunkeln über die *wirkliche Signifikanz* stochert:
- ▶ Ich will eigentlich die *minimale* Fehlerwahrscheinlichkeit wissen, die eine Ablehnung ergibt: Das ist der  **$p$ -Wert**.
- ▶ Allgemeinste Definition:

$$p = \text{Prob}(T \in E_{\text{data}} | H_0^*)$$

Die *Extremregion*  $E_{\text{data}}$  enthält alle möglichen Realisierungen von  $T$ , welche *weiter* von  $H_0$  entfernt sind als  $t_{\text{data}}$ , also liegt  $t_{\text{data}}$  auf dem Rand von  $E_{\text{data}}$  Zusammenhang mit Ablehnungsbereich?

$p$  is so definiert, dass  $E_{\text{data}} = R(p)$

- ▶  $p \geq 5\%$ : nicht signifikant (kein Stern beim Wert für  $\beta$ , manchmal "+", falls zwischen 5% und 10%, z.B.  $\beta_1 = 4.2^+$ )
- ▶  $p < 5\%$ : signifikant (ein Stern, z.B.  $\beta_1 = 4.2^*$ )
- ▶  $p < 1\%$ : sehr signifikant (zwei Sterne,  $\beta_1 = 4.2^{**}$ )
- ▶  $p < 0.001$ : hochgradig signifikant (drei Sterne,  $\beta_1 = 4.2^{***}$ )

## 13.1.4 Der $p$ -Wert

- ▶ Ein Test auf eine feste Fehlerwahrscheinlichkeit  $\alpha$  ist nicht sonderlich effizient, da man im Dunkeln über die *wirkliche Signifikanz* stochert:
- ▶ Ich will eigentlich die *minimale* Fehlerwahrscheinlichkeit wissen, die eine Ablehnung ergibt: Das ist der  **$p$ -Wert**.
- ▶ Allgemeinste Definition:

$$p = \text{Prob}(T \in E_{\text{data}} | H_0^*)$$

Die *Extremregion*  $E_{\text{data}}$  enthält alle möglichen Realisierungen von  $T$ , welche *weiter* von  $H_0$  entfernt sind als  $t_{\text{data}}$ , also liegt  $t_{\text{data}}$  auf dem Rand von  $E_{\text{data}}$  Zusammenhang mit Ablehnungsbereich?

$p$  is so definiert, dass  $E_{\text{data}} = R(p)$

- ▶  $p \geq 5\%$ : nicht signifikant (kein Stern beim Wert für  $\beta$ , manchmal "+", falls zwischen 5% und 10%, z.B.  $\beta_1 = 4.2^+$ )
- ▶  $p < 5\%$ : signifikant (ein Stern, z.B.  $\beta_1 = 4.2^*$ )
- ▶  $p < 1\%$ : sehr signifikant (zwei Sterne,  $\beta_1 = 4.2^{**}$ )
- ▶  $p < 0.001$ : hochgradig signifikant (drei Sterne,  $\beta_1 = 4.2^{***}$ )

## 13.1.4 Der $p$ -Wert

- ▶ Ein Test auf eine feste Fehlerwahrscheinlichkeit  $\alpha$  ist nicht sonderlich effizient, da man im Dunkeln über die *wirkliche Signifikanz* stochert:
- ▶ Ich will eigentlich die *minimale* Fehlerwahrscheinlichkeit wissen, die eine Ablehnung ergibt: Das ist der  **$p$ -Wert**.
- ▶ Allgemeinste Definition:

$$p = \text{Prob}(T \in E_{\text{data}} | H_0^*)$$

Die *Extremregion*  $E_{\text{data}}$  enthält alle möglichen Realisierungen von  $T$ , welche *weiter* von  $H_0$  entfernt sind als  $t_{\text{data}}$ , also liegt  $t_{\text{data}}$  auf dem Rand von  $E_{\text{data}}$  Zusammenhang mit Ablehnungsbereich?

$p$  is so definiert, dass  $E_{\text{data}} = R(p)$

- ▶  $p \geq 5\%$ : nicht signifikant (kein Stern beim Wert für  $\beta$ , manchmal "+", falls zwischen 5% und 10%, z.B.  $\beta_1 = 4.2^+$ )
- ▶  $p < 5\%$ : signifikant (ein Stern, z.B.  $\beta_1 = 4.2^*$ )
- ▶  $p < 1\%$ : sehr signifikant (zwei Sterne,  $\beta_1 = 4.2^{**}$ )
- ▶  $p < 0.001$ : hochgradig signifikant (drei Sterne,  $\beta_1 = 4.2^{***}$ )



## 13.1.4 Der $p$ -Wert

- ▶ Ein Test auf eine feste Fehlerwahrscheinlichkeit  $\alpha$  ist nicht sonderlich effizient, da man im Dunkeln über die *wirkliche Signifikanz* stochert:
- ▶ Ich will eigentlich die *minimale* Fehlerwahrscheinlichkeit wissen, die eine Ablehnung ergibt: Das ist der  **$p$ -Wert**.
- ▶ Allgemeinste Definition:

$$p = \text{Prob}(T \in E_{\text{data}} | H_0^*)$$


Die *Extremregion*  $E_{\text{data}}$  enthält alle möglichen Realisierungen von  $T$ , welche *weiter* von  $H_0$  entfernt sind als  $t_{\text{data}}$ , also liegt  $t_{\text{data}}$  auf dem Rand von  $E_{\text{data}}$  Zusammenhang mit Ablehnungsbereich?

$p$  is so definiert, dass  $E_{\text{data}} = R(p)$

- ▶  $p \geq 5\%$ : nicht signifikant (kein Stern beim Wert für  $\beta$ , manchmal "+", falls zwischen 5% und 10%, z.B.  $\beta_1 = 4.2^+$ )
- ▶  $p < 5\%$ : signifikant (ein Stern, z.B.  $\beta_1 = 4.2^*$ )
- ▶  $p < 1\%$ : sehr signifikant (zwei Sterne,  $\beta_1 = 4.2^{**}$ )
- ▶  $p < 0.001$ : hochgradig signifikant (drei Sterne,  $\beta_1 = 4.2^{***}$ )

## Berechnung von $p$ für einige Tests

- ▶ Intervalltest  $H_0 : \beta \leq \beta_0$  or  $\beta < \beta_0$   
 $p = P(T > t_{\text{data}} | \beta = \beta_0) = 1 - F_T(t_{\text{data}})$




- ▶ Intervalltest  $H_0 : \beta \geq \beta_0$  or  $\beta > \beta_0$   
 $p = P(T < t_{\text{data}} | \beta = \beta_0) = F_T(t_{\text{data}})$

- ▶ Punkttest  $H_0 : \beta = \beta_0$  (Symmetrie von  $f_T$  beim 3. Gleichheitszeichen angenommen)  


$$\begin{aligned}
 p &= P((T > |t_{\text{data}}|) \cup (T < -|t_{\text{data}}|)) \\
 &= (1 - F_T(|t_{\text{data}}|)) + F_T(-|t_{\text{data}}|) \\
 &= 1 - F_T(|t_{\text{data}}|) + 1 - F_T(|t_{\text{data}}|) \\
 &= 2(1 - F_T(|t_{\text{data}}|))
 \end{aligned}$$

## Berechnung von $p$ für einige Tests

- ▶ Intervalltest  $H_0 : \beta \leq \beta_0$  or  $\beta < \beta_0$   
 $p = P(T > t_{\text{data}} | \beta = \beta_0) = 1 - F_T(t_{\text{data}})$



- ▶ Intervalltest  $H_0 : \beta \geq \beta_0$  or  $\beta > \beta_0$   
 $p = P(T < t_{\text{data}} | \beta = \beta_0) = F_T(t_{\text{data}})$




- ▶ Punktttest  $H_0 : \beta = \beta_0$  (Symmetrie von  $f_T$  beim 3. Gleichheitszeichen angenommen)  


$$\begin{aligned}
 p &= P((T > |t_{\text{data}}|) \cup (T < -|t_{\text{data}}|)) \\
 &= (1 - F_T(|t_{\text{data}}|)) + F_T(-|t_{\text{data}}|) \\
 &= 1 - F_T(|t_{\text{data}}|) + 1 - F_T(|t_{\text{data}}|) \\
 &= 2(1 - F_T(|t_{\text{data}}|))
 \end{aligned}$$

## Berechnung von $p$ für einige Tests

- ▶ Intervalltest  $H_0 : \beta \leq \beta_0$  or  $\beta < \beta_0$   
 $p = P(T > t_{\text{data}} | \beta = \beta_0) = 1 - F_T(t_{\text{data}})$




- ▶ Intervalltest  $H_0 : \beta \geq \beta_0$  or  $\beta > \beta_0$   
 $p = P(T < t_{\text{data}} | \beta = \beta_0) = F_T(t_{\text{data}})$



- ▶ Punktttest  $H_0 : \beta = \beta_0$  (Symmetrie von  $f_T$  beim 3. Gleichheitszeichen angenommen)  

$$\begin{aligned}
 p &= P((T > |t_{\text{data}}|) \cup (T < -|t_{\text{data}}|)) \\
 &= (1 - F_T(|t_{\text{data}}|)) + F_T(-|t_{\text{data}}|) \\
 &= 1 - F_T(|t_{\text{data}}|) + 1 - F_T(|t_{\text{data}}|) \\
 &= 2(1 - F_T(|t_{\text{data}}|))
 \end{aligned}$$



## $p$ -Werte der Nullhypothesen des Hotelbeispiels

$$y = \beta_0 x_0 + \beta_1 x_1 + \beta_2 x_2 + \epsilon$$

$x_0 = 1$ ,  $x_1$ : Qualitäts-Proxy [# Sterne];  $x_2$ : Preis [€/night],

- ▶  $H_{01}$  "Sterne egal": Punkt-Hypothese  $\beta_1 = 0$   
 $t_{\text{data}} = 7.49$ ,  $p = 2(1 - F_T^{(9)}(|t_{\text{data}}|)) = 3.7E - 5^{***}$
- ▶  $H_{02}$  "Mehr Sterne sind besser": Intervall-Hypothese  $\beta_1 < 0$   
 $t_{\text{data}} = 7.49$ ,  $p = 1 - F_T^{(9)}(t_{\text{data}}) = 1.9E - 5^{***}$
- ▶  $H_{03}$  "Belegung geht um  $\geq 1$  Prozentpunkte pro € Preisanstieg zurück": Intervallhypothese  $\beta_2 < -1$   
 $t_{\text{data}} = 0.24$ ,  $p = 1 - F_T^{(9)}(t_{\text{data}}) = 40\%$
- ▶  $H_{04}$  "Ein Stern ist mindestens 30€ wert":  
 Funktions-Intervallhypothese  $\gamma = \beta_1 + 30\beta_2 < 0$   
 $t_{\text{data}} = 4.20$ ,  $p = 1 - F_T^{(9)}(t_{\text{data}}) = 0.12\%^{**}$
- ▶  $H_{05}$  "Stern- und Preissensitivität ist gleichzeitig gegeben":  
 Simultane Nullhypothese  $(\beta_1 = 30) \cap (\beta_2 = -1)$   
 $t_{\text{data}} = 11.8$ ,  $p = 1 - F_F^{(2,9)}(t_{\text{data}}) = 0.30\%^{**}$

## $p$ -Werte der Nullhypothesen des Hotelbeispiels

$$y = \beta_0 x_0 + \beta_1 x_1 + \beta_2 x_2 + \epsilon$$

$x_0 = 1$ ,  $x_1$ : Qualitäts-Proxy [# Sterne];  $x_2$ : Preis [€/night],

- ▶  $H_{01}$  "Sterne egal": Punkt-Hypothese  $\beta_1 = 0$   
 $t_{\text{data}} = 7.49$ ,  $p = 2(1 - F_T^{(9)}(|t_{\text{data}}|)) = 3.7E - 5^{***}$
- ▶  $H_{02}$  "Mehr Sterne sind besser": Intervall-Hypothese  $\beta_1 < 0$   
 $t_{\text{data}} = 7.49$ ,  $p = 1 - F_T^{(9)}(t_{\text{data}}) = 1.9E - 5^{***}$
- ▶  $H_{03}$  "Belegung geht um  $\geq 1$  Prozentpunkte pro € Preisanstieg zurück": Intervallhypothese  $\beta_2 < -1$   
 $t_{\text{data}} = 0.24$ ,  $p = 1 - F_T^{(9)}(t_{\text{data}}) = 40\%$
- ▶  $H_{04}$  "Ein Stern ist mindestens 30€ wert":  
 Funktions-Intervallhypothese  $\gamma = \beta_1 + 30\beta_2 < 0$   
 $t_{\text{data}} = 4.20$ ,  $p = 1 - F_T^{(9)}(t_{\text{data}}) = 0.12\%^{**}$
- ▶  $H_{05}$  "Stern- und Preissensitivität ist gleichzeitig gegeben":  
 Simultane Nullhypothese  $(\beta_1 = 30) \cap (\beta_2 = -1)$   
 $t_{\text{data}} = 11.8$ ,  $p = 1 - F_F^{(2,9)}(t_{\text{data}}) = 0.30\%^{**}$

## $p$ -Werte der Nullhypothesen des Hotelbeispiels

$$y = \beta_0 x_0 + \beta_1 x_1 + \beta_2 x_2 + \epsilon$$

$x_0 = 1$ ,  $x_1$ : Qualitäts-Proxy [# Sterne];  $x_2$ : Preis [€/night],

- ▶  $H_{01}$  "Sterne egal": Punkt-Hypothese  $\beta_1 = 0$   
 $t_{\text{data}} = 7.49$ ,  $p = 2(1 - F_T^{(9)}(|t_{\text{data}}|)) = 3.7E - 5^{***}$
- ▶  $H_{02}$  "Mehr Sterne sind besser": Intervall-Hypothese  $\beta_1 < 0$   
 $t_{\text{data}} = 7.49$ ,  $p = 1 - F_T^{(9)}(t_{\text{data}}) = 1.9E - 5^{***}$
- ▶  $H_{03}$  "Belegung geht um  $\geq 1$  Prozentpunkte pro € Preisanstieg zurück": Intervallhypothese  $\beta_2 < -1$   
 $t_{\text{data}} = 0.24$ ,  $p = 1 - F_T^{(9)}(t_{\text{data}}) = 40\%$
- ▶  $H_{04}$  "Ein Stern ist mindestens 30€ wert":  
 Funktions-Intervallhypothese  $\gamma = \beta_1 + 30\beta_2 < 0$   
 $t_{\text{data}} = 4.20$ ,  $p = 1 - F_T^{(9)}(t_{\text{data}}) = 0.12\%^{**}$
- ▶  $H_{05}$  "Stern- und Preissensitivität ist gleichzeitig gegeben":  
 Simultane Nullhypothese  $(\beta_1 = 30) \cap (\beta_2 = -1)$   
 $t_{\text{data}} = 11.8$ ,  $p = 1 - F_F^{(2,9)}(t_{\text{data}}) = 0.30\%^{**}$

## $p$ -Werte der Nullhypothesen des Hotelbeispiels

$$y = \beta_0 x_0 + \beta_1 x_1 + \beta_2 x_2 + \epsilon$$

$x_0 = 1$ ,  $x_1$ : Qualitäts-Proxy [# Sterne];  $x_2$ : Preis [€/night],

- ▶  $H_{01}$  "Sterne egal": Punkt-Hypothese  $\beta_1 = 0$   
 $t_{\text{data}} = 7.49$ ,  $p = 2(1 - F_T^{(9)}(|t_{\text{data}}|)) = 3.7E - 5^{***}$
- ▶  $H_{02}$  "Mehr Sterne sind besser": Intervall-Hypothese  $\beta_1 < 0$   
 $t_{\text{data}} = 7.49$ ,  $p = 1 - F_T^{(9)}(t_{\text{data}}) = 1.9E - 5^{***}$
- ▶  $H_{03}$  "Belegung geht um  $\geq 1$  Prozentpunkte pro € Preisanstieg zurück": Intervallhypothese  $\beta_2 < -1$   
 $t_{\text{data}} = 0.24$ ,  $p = 1 - F_T^{(9)}(t_{\text{data}}) = 40\%$
- ▶  $H_{04}$  "Ein Stern ist mindestens 30€ wert":  
 Funktions-Intervallhypothese  $\gamma = \beta_1 + 30\beta_2 < 0$   
 $t_{\text{data}} = 4.20$ ,  $p = 1 - F_T^{(9)}(t_{\text{data}}) = 0.12\%^{**}$
- ▶  $H_{05}$  "Stern- und Preissensitivität ist gleichzeitig gegeben":  
 Simultane Nullhypothese  $(\beta_1 = 30) \cap (\beta_2 = -1)$   
 $t_{\text{data}} = 11.8$ ,  $p = 1 - F_F^{(2,9)}(t_{\text{data}}) = 0.30\%^{**}$




## $p$ -Werte der Nullhypothesen des Hotelbeispiels

$$y = \beta_0 x_0 + \beta_1 x_1 + \beta_2 x_2 + \epsilon$$

$x_0 = 1$ ,  $x_1$ : Qualitäts-Proxy [# Sterne];  $x_2$ : Preis [€/night],

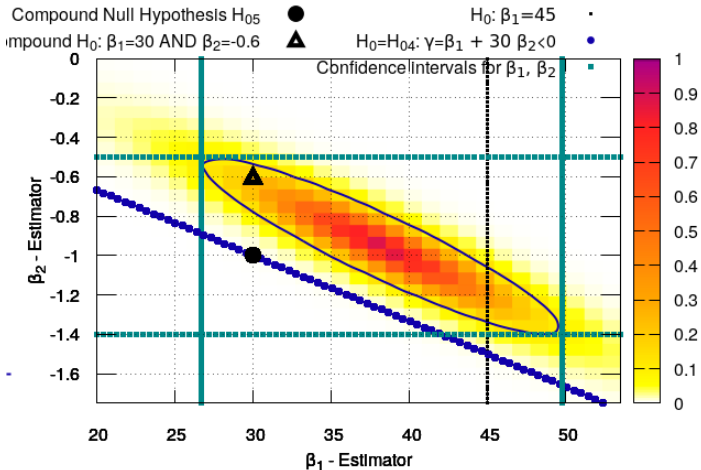
- ▶  $H_{01}$  "Sterne egal": Punkt-Hypothese  $\beta_1 = 0$   
 $t_{\text{data}} = 7.49$ ,  $p = 2(1 - F_T^{(9)}(|t_{\text{data}}|)) = 3.7E - 5^{***}$
- ▶  $H_{02}$  "Mehr Sterne sind besser": Intervall-Hypothese  $\beta_1 < 0$   
 $t_{\text{data}} = 7.49$ ,  $p = 1 - F_T^{(9)}(t_{\text{data}}) = 1.9E - 5^{***}$
- ▶  $H_{03}$  "Belegung geht um  $\geq 1$  Prozentpunkte pro € Preisanstieg zurück": Intervallhypothese  $\beta_2 < -1$   
 $t_{\text{data}} = 0.24$ ,  $p = 1 - F_T^{(9)}(t_{\text{data}}) = 40\%$
- ▶  $H_{04}$  "Ein Stern ist mindestens 30€ wert":  
 Funktions-Intervallhypothese  $\gamma = \beta_1 + 30\beta_2 < 0$   
 $t_{\text{data}} = 4.20$ ,  $p = 1 - F_T^{(9)}(t_{\text{data}}) = 0.12\%^{**}$
- ▶  $H_{05}$  "Stern- und Preissensitivität ist gleichzeitig gegeben":  
 Simultane Nullhypothese  $(\beta_1 = 30) \cap (\beta_2 = -1)$   
 $t_{\text{data}} = 11.8$ ,  $p = 1 - F_F^{(2,9)}(t_{\text{data}}) = 0.30\%^{**}$

## Visualisierung




- ▶ Türkise Linien: Grenzen der  $\alpha = 5\%$ -KI von  $\beta_1$  und  $\beta_2$
- ▶ Schwarze Linie: Punkthypothese ( $t$ -test):  $H_0 : \beta_1 = 45$
- ▶ Blaue Punkte: Grenze der funktionalen Intervallhypothese ( $t$ -test)  
 $H_0 = H_{04} : \gamma = \beta_1 + 30\beta_2 < 0$
- ▶ Schwarze Symbole: Simultane Nullhypothese ( $F$ -test)  
 \*  $H_0 = H_{05} : (\beta_1 = 30) \cap (\beta_2 = -1)$ ,     $\Delta : H_0 : (\beta_1 = 30) \cap (\beta_2 = -0.6)$

## Visualisierung




- ▶ Türkise Linien: Grenzen der  $\alpha = 5\%$ -KI von  $\beta_1$  und  $\beta_2$
- ▶ Schwarze Linie: Punkthypothese ( $t$ -test):  $H_0 : \beta_1 = 45$
- ▶ Blaue Punkte: Grenze der funktionalen Intervallhypothese ( $t$ -test)  
 $H_0 = H_{04} : \gamma = \beta_1 + 30\beta_2 < 0$
- ▶ Schwarze Symbole: Simultane Nullhypothese ( $F$ -test)  
 ●:  $H_0 = H_{05} : (\beta_1 = 30) \cap \beta_2 = -1$ ,    ▲:  $H_0 : (\beta_1 = 30) \cap (\beta_2 = -0.6)$

## Visualisierung




- ▶ Türkise Linien: Grenzen der  $\alpha = 5\%$ -KI von  $\beta_1$  und  $\beta_2$
- ▶ Schwarze Linie: Punkthypothese ( $t$ -test):  $H_0 : \beta_1 = 45$
- ▶ Blaue Punkte: Grenze der funktionalen Intervallhypothese ( $t$ -test)  
 $H_0 = H_{04} : \gamma = \beta_1 + 30\beta_2 < 0$
- ▶ Schwarze Symbole: Simultane Nullhypothese ( $F$ -test)  
 ●:  $H_0 = H_{05} : (\beta_1 = 30) \cap \beta_2 = -1$ ,    ▲:  $H_0 : (\beta_1 = 30) \cap (\beta_2 = -0.6)$

## Visualisierung



- ▶ Türkise Linien: Grenzen der  $\alpha = 5\%$ -KI von  $\beta_1$  und  $\beta_2$
- ▶ Schwarze Linie: Punkthypothese ( $t$ -test):  $H_0 : \beta_1 = 45$
- ▶ Blaue Punkte: Grenze der funktionalen Intervallhypothese ( $t$ -test)  
 $H_0 = H_{04} : \gamma = \beta_1 + 30\beta_2 < 0$
- ▶ Schwarze Symbole: Simultane Nullhypothese ( $F$ -test)
  - :  $H_0 = H_{05} : (\beta_1 = 30) \cap \beta_2 = -1$ ,
  - ▲:  $H_0 : (\beta_1 = 30) \cap (\beta_2 = -0.6)$

## Visualisierung



- ▶ Türkise Linien: Grenzen der  $\alpha = 5\%$ -KI von  $\beta_1$  und  $\beta_2$
- ▶ Schwarze Linie: Punkthypothese ( $t$ -test):  $H_0 : \beta_1 = 45$
- ▶ Blaue Punkte: Grenze der funktionalen Intervallhypothese ( $t$ -test)  
 $H_0 = H_{04} : \gamma = \beta_1 + 30\beta_2 < 0$
- ▶ Schwarze Symbole: Simultane Nullhypothese ( $F$ -test)
  - :  $H_0 = H_{05} : (\beta_1 = 30) \cap (\beta_2 = -1)$ ,    ▲:  $H_0 : (\beta_1 = 30) \cap (\beta_2 = -0.6)$ .

## 13.2 Strategien zur Modellauswahl

### Problemstellung

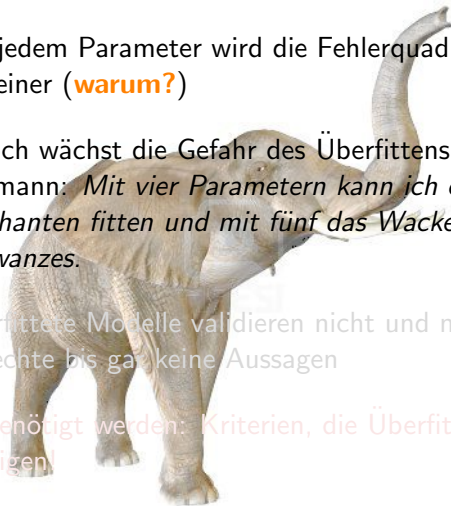
- ▶ Mit jedem Parameter wird die Fehlerquadratsumme  $S$  kleiner (**warum?**)
- ▶ Jedoch wächst die Gefahr des Überfittens. John Neumann: *Mit vier Parametern kann ich einen Elefanten fitten und mit fünf das Wackeln seines Schwanzes.*
- ▶ Überfittete Modelle validieren nicht und machen schlechte bis gar keine Aussagen
- ▶  $\Rightarrow$  benötigt werden: Kriterien, die Überfitten anzeigen!



## 13.2 Strategien zur Modellauswahl

### Problemstellung

- ▶ Mit jedem Parameter wird die Fehlerquadratsumme  $S$  kleiner (**warum?**)
- ▶ Jedoch wächst die Gefahr des Überfittens. John Neumann: *Mit vier Parametern kann ich einen Elefanten fitten und mit fünf das Wackeln seines Schwanzes.*
- ▶ Überfittete Modelle validieren nicht und machen schlechte bis gar keine Aussagen
- ▶ ⇒ benötigt werden: Kriterien, die Überfitten anzeigen!

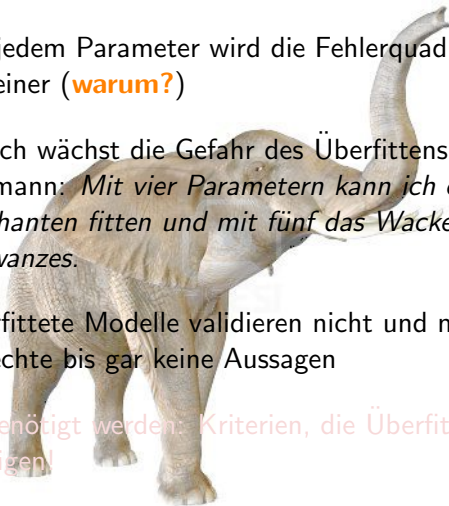




## 13.2 Strategien zur Modellauswahl

### Problemstellung

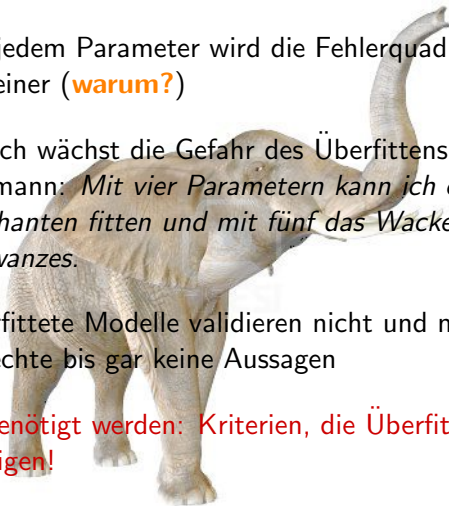
- ▶ Mit jedem Parameter wird die Fehlerquadratsumme  $S$  kleiner (**warum?**)
- ▶ Jedoch wächst die Gefahr des Überfittens. John Neumann: *Mit vier Parametern kann ich einen Elefanten fitten und mit fünf das Wackeln seines Schwanzes.*
- ▶ Überfittete Modelle validieren nicht und machen schlechte bis gar keine Aussagen
- ▶  $\Rightarrow$  benötigt werden: Kriterien, die Überfitten anzeigen!



## 13.2 Strategien zur Modellauswahl

### Problemstellung

- ▶ Mit jedem Parameter wird die Fehlerquadratsumme  $S$  kleiner (**warum?**)
- ▶ Jedoch wächst die Gefahr des Überfittens. John Neumann: *Mit vier Parametern kann ich einen Elefanten fitten und mit fünf das Wackeln seines Schwanzes.*
- ▶ Überfittete Modelle validieren nicht und machen schlechte bis gar keine Aussagen
- ▶  $\Rightarrow$  benötigt werden: Kriterien, die Überfitten anzeigen!



## Standard-Kriterien zur Modellauswahl

► (1) Korrigiertes  $R^2$ :

$$\bar{R}^2 = 1 - \frac{n-1}{n-J-1} (1 - R^2), \quad R^2 = 1 - \frac{S}{S_0},$$

$$S = \text{SSE}(\text{kalibr. volles Modell}), \quad S_0 = \text{SSE}(\text{kalibr. Modell } \hat{y} = \beta_0).$$

► (2) Akaike Informationskriterium AIC:

$$\text{AIC} = \ln \hat{\sigma}_{\text{descr}}^2 + J \frac{2}{n},$$

► (3) Bayes'sches Informationskriterium BIC:

$$\text{BIC} = \ln \hat{\sigma}_{\text{descr}}^2 + J \frac{\ln n}{n}.$$

## Standard-Kriterien zur Modellauswahl

▶ **(1) Korrigiertes  $R^2$ :**

$$\bar{R}^2 = 1 - \frac{n-1}{n-J-1} (1 - R^2), \quad R^2 = 1 - \frac{S}{S_0},$$

$S = \text{SSE}(\text{kalibr. volles Modell}), \quad S_0 = \text{SSE}(\text{kalibr. Modell } \hat{y} = \beta_0).$

▶ **(2) Akaike Informationskriterium AIC:**

$$\text{AIC} = \ln \hat{\sigma}_{\text{descr}}^2 + J \frac{2}{n},$$

▶ **(3) Bayes'sches Informationskriterium BIC:**

$$\text{BIC} = \ln \hat{\sigma}_{\text{descr}}^2 + J \frac{\ln n}{n}.$$

## Standard-Kriterien zur Modellauswahl

► (1) Korrigiertes  $R^2$ :

$$\bar{R}^2 = 1 - \frac{n-1}{n-J-1} (1 - R^2), \quad R^2 = 1 - \frac{S}{S_0},$$

$$S = \text{SSE}(\text{kalibr. volles Modell}), \quad S_0 = \text{SSE}(\text{kalibr. Modell } \hat{y} = \beta_0).$$

► (2) Akaike Informationskriterium AIC:

$$\text{AIC} = \ln \hat{\sigma}_{\text{descr}}^2 + J \frac{2}{n},$$

► (3) Bayes'sches Informationskriterium BIC:

$$\text{BIC} = \ln \hat{\sigma}_{\text{descr}}^2 + J \frac{\ln n}{n}.$$

Hinweis: Bei AIC und BIC wird der deskriptive Varianzschätzer  $\hat{\sigma}_{\text{descr}}^2 = S/n$  anstelle des Unverzerrten,  $\hat{\sigma}^2 = S/(n-1-J)$ , genommen

## Modellauswahl: Strategy à la “Occam’s Rasiermesser”

- ▶ Identifiziere  $J$  möglicherweise relevante exogene Faktoren (einschließlich der Konstanten) und berechne  $\bar{R}^2$ , AIC, oder BIC für alle  $2^J$  möglichen Modelle (jeder der Faktoren  $j$  ist entweder enthalten oder nicht) durch *rohe Gewalt*.
- ▶ Das beste Modell maximiert  $\bar{R}^2$  bzw minimiert AIC oder BIC.
- ▶ Da AIC (und auch  $\bar{R}^2$  komplexe Modelle mit vielen Parametern zu gering “bestrafen”, ist üblicherweise BIC das Kriterium der Wahl
- ▶ Neben dem Ansatz der *rohen Gewalt* gibt es zwei “schnellere” Strategien, die jedoch nicht garantieren, das beste Modell zu finden (BIC etc sind nicht transitiv)
  - ▶ **Top-down:** Starte mit allen  $J$  Faktoren. Eliminiere in jeder Runde den Faktor, der den höchsten Zuwachs in  $\bar{R}^2$  bzw die höchste Abnahme von AIC oder BIC bewirkt. Stoppe, falls es keine Verbesserung mehr gibt
  - ▶ **Bottom-up:** Starte mit dem Konstantenmodell  $\hat{y} = \beta_0$  und füge jeweils den Faktor mit der höchsten inkrementellen Verbesserung hinzu, solange es Verbesserungen gibt
- ▶ Standard Statistik-Software enthält diese Strategien

## Modellauswahl: Strategy à la “Occam’s Rasiermesser”

- ▶ Identifiziere  $J$  möglicherweise relevante exogene Faktoren (einschließlich der Konstanten) und berechne  $\bar{R}^2$ , AIC, oder BIC für alle  $2^J$  möglichen Modelle (jeder der Faktoren  $j$  ist entweder enthalten oder nicht) durch *rohe Gewalt*.
- ▶ Das beste Modell maximiert  $\bar{R}^2$  bzw minimiert AIC oder BIC.
- ▶ Da AIC (und auch  $\bar{R}^2$  komplexe Modelle mit vielen Parametern zu gering “bestrafen”, ist üblicherweise BIC das Kriterium der Wahl
- ▶ Neben dem Ansatz der *rohen Gewalt* gibt es zwei “schnellere” Strategien, die jedoch nicht garantieren, das beste Modell zu finden (BIC etc sind nicht transitiv)
  - ▶ **Top-down**: Starte mit allen  $J$  Faktoren. Eliminiere in jeder Runde den Faktor, der den höchsten Zuwachs in  $\bar{R}^2$  bzw die höchste Abnahme von AIC oder BIC bewirkt. Stoppe, falls es keine Verbesserung mehr gibt
  - ▶ **Bottom-up**: Starte mit dem Konstantenmodell  $\hat{y} = \beta_0$  und füge jeweils den Faktor mit der höchsten inkrementellen Verbesserung hinzu, solange es Verbesserungen gibt
- ▶ Standard Statistik-Software enthält diese Strategien

## Modellauswahl: Strategy à la “Occam’s Rasiermesser”

- ▶ Identifiziere  $J$  möglicherweise relevante exogene Faktoren (einschließlich der Konstanten) und berechne  $\bar{R}^2$ , AIC, oder BIC für alle  $2^J$  möglichen Modelle (jeder der Faktoren  $j$  ist entweder enthalten oder nicht) durch *rohe Gewalt*.
- ▶ Das beste Modell maximiert  $\bar{R}^2$  bzw minimiert AIC oder BIC.
- ▶ Da AIC (und auch  $\bar{R}^2$  komplexe Modelle mit vielen Parametern zu gering “bestrafen”, ist üblicherweise BIC das Kriterium der Wahl
- ▶ Neben dem Ansatz der *rohen Gewalt* gibt es zwei “schnellere” Strategien, die jedoch nicht garantieren, das beste Modell zu finden (BIC etc sind nicht transitiv)
  - ▶ **Top-down**: Starte mit allen  $J$  Faktoren. Eliminiere in jeder Runde den Faktor, der den höchsten Zuwachs in  $\bar{R}^2$  bzw die höchste Abnahme von AIC oder BIC bewirkt. Stoppe, falls es keine Verbesserung mehr gibt
  - ▶ **Bottom-up**: Starte mit dem Konstantenmodell  $\hat{y} = \beta_0$  und füge jeweils den Faktor mit der höchsten inkrementellen Verbesserung hinzu, solange es Verbesserungen gibt
- ▶ Standard Statistik-Software enthält diese Strategien



## Modellauswahl: Strategy à la “Occam’s Rasiermesser”

- ▶ Identifiziere  $J$  möglicherweise relevante exogene Faktoren (einschließlich der Konstanten) und berechne  $\bar{R}^2$ , AIC, oder BIC für alle  $2^J$  möglichen Modelle (jeder der Faktoren  $j$  ist entweder enthalten oder nicht) durch *rohe Gewalt*.
- ▶ Das beste Modell maximiert  $\bar{R}^2$  bzw minimiert AIC oder BIC.
- ▶ Da AIC (und auch  $\bar{R}^2$  komplexe Modelle mit vielen Parametern zu gering “bestrafen”, ist üblicherweise BIC das Kriterium der Wahl
- ▶ Neben dem Ansatz der *rohen Gewalt* gibt es zwei “schnellere” Strategien, die jedoch nicht garantieren, das beste Modell zu finden (BIC etc sind nicht transitiv)
  - ▶ **Top-down**: Starte mit allen  $J$  Faktoren. Eliminiere in jeder Runde den Faktor, der den höchsten Zuwachs in  $\bar{R}^2$  bzw die höchste Abnahme von AIC oder BIC bewirkt. Stoppe, falls es keine Verbesserung mehr gibt
  - ▶ **Bottom-up**: Starte mit dem Konstantenmodell  $\hat{y} = \beta_0$  und füge jeweils den Faktor mit der höchsten inkrementellen Verbesserung hinzu, solange es Verbesserungen gibt
- ▶ Standard Statistik-Software enthält diese Strategien

## 13.3. Logistische Regression

- ▶ Normale lineare Modelle der Form  $Y = \beta'x + \epsilon$  haben zwingend eine stetige endogene Variable (**Warum?**)
- ▶ Verkettung mit einem nichtbeobachtbaren Zwischenzustand  $Y^*$  erlaubt es, dichotome endogene Variable zu modellieren:

$$Y(x) = \begin{cases} 1 & Y^*(x) > 0 \\ 0 & \text{otherwise,} \end{cases} \quad Y^*(x) = \hat{y}^*(x) + \epsilon = \beta'x + \epsilon$$

$\epsilon$  gehorcht der **logistischen Verteilung** mit  $F_\epsilon(x) = e^x / (e^x + 1)$

- ▶ Wahrscheinlichkeit  $P_1$  des Ergebnisses  $Y = 1$ :

$$P_1 = P(Y^*(x) > 0) = F_\epsilon(\beta'x) = \frac{e^{\beta'x}}{e^{\beta'x} + 1}$$

- ▶ Formal ist dies ein normales lineares Regressionsmodell für das **log-odds ratio**  $\ln(P_1/P_0) = \ln(P_1/(1 - P_1))$ :

$$\hat{y}^*(x) = \beta'x = \ln\left(\frac{P_1}{P_0}\right)$$

## 13.3. Logistische Regression

- ▶ Normale lineare Modelle der Form  $Y = \beta'x + \epsilon$  haben zwingend eine stetige endogene Variable (**Warum?**)
- ▶ Verkettung mit einem nichtbeobachtbaren Zwischenzustand  $Y^*$  erlaubt es, dichotome endogene Variable zu modellieren:

$$Y(x) = \begin{cases} 1 & Y^*(x) > 0 \\ 0 & \text{otherwise,} \end{cases} \quad Y^*(x) = \hat{y}^*(x) + \epsilon = \beta'x + \epsilon$$

$\epsilon$  gehorcht der **logistischen Verteilung** mit  $F_\epsilon(x) = e^x / (e^x + 1)$

- ▶ Wahrscheinlichkeit  $P_1$  des Ergebnisses  $Y = 1$ :

$$P_1 = P(Y^*(x) > 0) = F_\epsilon(\beta'x) = \frac{e^{\beta'x}}{e^{\beta'x} + 1}$$

- ▶ Formal ist dies ein normales lineares Regressionsmodell für das **log-odds ratio**  $\ln(P_1/P_0) = \ln(P_1/(1 - P_1))$ :

$$\hat{y}^*(x) = \beta'x = \ln\left(\frac{P_1}{P_0}\right)$$

## 13.3. Logistische Regression

- ▶ Normale lineare Modelle der Form  $Y = \beta'x + \epsilon$  haben zwingend eine stetige endogene Variable (**Warum?**)
- ▶ Verkettung mit einem nichtbeobachtbaren Zwischenzustand  $Y^*$  erlaubt es, dichotome endogene Variable zu modellieren:

$$Y(x) = \begin{cases} 1 & Y^*(x) > 0 \\ 0 & \text{otherwise,} \end{cases} \quad Y^*(x) = \hat{y}^*(x) + \epsilon = \beta'x + \epsilon$$

$\epsilon$  gehorcht der **logistischen Verteilung** mit  $F_\epsilon(x) = e^x / (e^x + 1)$

- ▶ Wahrscheinlichkeit  $P_1$  des Ergebnisses  $Y = 1$ :

$$P_1 = P(Y^*(x) > 0) = F_\epsilon(\beta'x) = \frac{e^{\beta'x}}{e^{\beta'x} + 1}$$

- ▶ Formal ist dies ein normales lineares Regressionsmodell für das **log-odds ratio**  $\ln(P_1/P_0) = \ln(P_1/(1 - P_1))$ :

$$\hat{y}^*(x) = \beta'x = \ln\left(\frac{P_1}{P_0}\right)$$

## 13.3. Logistische Regression

- ▶ Normale lineare Modelle der Form  $Y = \beta'x + \epsilon$  haben zwingend eine stetige endogene Variable (**Warum?**)
- ▶ Verkettung mit einem nichtbeobachtbaren Zwischenzustand  $Y^*$  erlaubt es, dichotome endogene Variable zu modellieren:

$$Y(\mathbf{x}) = \begin{cases} 1 & Y^*(\mathbf{x}) > 0 \\ 0 & \text{otherwise,} \end{cases} \quad Y^*(\mathbf{x}) = \hat{y}^*(\mathbf{x}) + \epsilon = \beta'x + \epsilon$$

$\epsilon$  gehorcht der **logistischen Verteilung** mit  $F_\epsilon(x) = e^x / (e^x + 1)$



- ▶ Wahrscheinlichkeit  $P_1$  des Ergebnisses  $Y = 1$ :

$$P_1 = P(Y^*(\mathbf{x}) > 0) = F_\epsilon(\beta'x) = \frac{e^{\beta'x}}{e^{\beta'x} + 1}$$

- ▶ Formal ist dies ein normales lineares Regressionsmodell für das **log-odds ratio**  $\ln(P_1/P_0) = \ln(P_1/(1 - P_1))$ :

$$\hat{y}^*(\mathbf{x}) = \beta'x = \ln\left(\frac{P_1}{P_0}\right)$$



## Example: naive OLS-estimation (RP student interviews)



- ▶ Alternatives:  $i = 1$ : motorized and  $i = 2$  (not)
- ▶ Intermediate variable estimated by percentaged choices:  


$$y^* = \ln(f_1/(1 - f_1))$$
- ▶ Model: Log. regression,  $\hat{y}^*(x_1) = \beta_0 + \beta_1 x_1$
- ▶ OLS Estimation:  $\beta_0 = -0.58$ ,  $\beta_1 = 0.79$

## Method consistent? added 5<sup>th</sup> data point with $f=0.9999$



- ▶ Same model:  $\hat{y}^*(x_1) = \beta_0 + \beta_1 x_1$
- ▶ New estimation:  $\beta_0 = -3.12$ ,  $\beta_1 = 2.03$
- ▶ Estimation would fail if  $f_1 = 0$  or  $=1 \Rightarrow$  real discrete-choice model necessary!


## Comparison: real Maximum-Likelihood (ML) estimation



- ▶ Model: Logit,  $V_i(x_1) = \beta_0 \delta_{i1} + \beta_1 x_1 \delta_{i1}$ ,  $V_2 = 0$ .
- ▶ Estimation:  $\beta_0 = -0.50 \pm 0.65$ ,  $\beta_1 = +0.71 \pm 0.30$



## Comparison: real ML estimation with added 5<sup>th</sup> data point



- ▶ Same logit model,  $V_i(x_1) = \beta_0 \delta_{i1} + \beta_1 x_1 \delta_{i1}$ ,  $V_2 = 0$ .
- ▶ New estimation:  $\beta_0 = -0.55 \pm 0.63$ ,  $\beta_1 = +0.75 \pm 0.27$