

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_{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 α** 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 α , 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	✓	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 α -Fehler** $P(H_0 \text{ abgelehnt} | H_0) \leq \alpha$
- ▶ Unbekannt und nicht kontrollierbar: **Fehler 2. Art bzw. β -Fehler** $P(H_0 \text{ nicht abgelehnt} | \overline{H_0})$. Da dessen Wahrscheinlichkeit unbekannt ist, legt man die ernsthaftere Konsequenz auf den α -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 ≥ 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 ϵ , $H_0: \sigma^2 = \sigma_0^2$, $\sigma^2 \geq \sigma_0^2$, 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 α 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 χ^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_{data} :


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

- ▶ Entscheidung:

H_0 is abgelehnt zur Fehlerwahrscheinlichkeit α , 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_{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 α falls

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

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




- ▶ H_0 ist abgelehnt zur Fehlerwahrscheinlichkeit α 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 α abgelehnt, falls

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

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

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

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_0 so, dass eine Ablehnung eine Aussage ergibt!), Intervalltest mit T und t_{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 $\beta_1 = 30$, $\beta_2 = 1 \Rightarrow \hat{\beta}_0 = 49.0$:

$\hat{\beta}_r = (49.0, 30, -1)'$, $S_0 = S(\hat{\beta}_r) = 1808$; $M - M_0 = 2$ 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 α 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_{data} enthält alle möglichen Realisierungen von T , welche *weiter* von H_0 entfernt sind als t_{data} , also liegt t_{data} auf dem Rand von E_{data} Zusammenhang mit Ablehnungsbereich?

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


- ▶ $p \geq 5\%$: nicht signifikant (kein Stern beim Wert für β , 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 $\beta > \beta_0$
 $p = P(T < t_{\text{data}} | \beta = \beta_0) = F_T(t_{\text{data}})$



- ▶ 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 ≥ 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

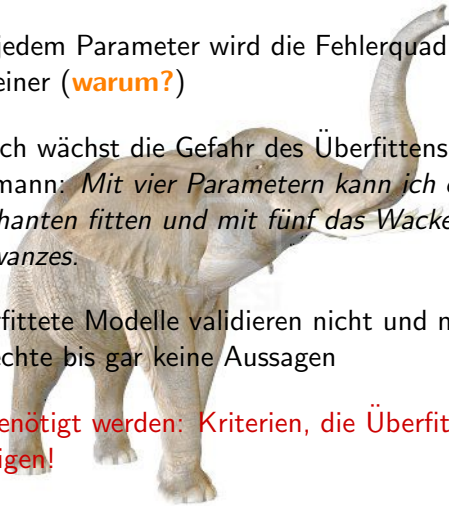


- ▶ Türkise Linien: Grenzen der $\alpha = 5\%$ -KI von β_1 und β_2
- ▶ Schwarze Linie: Punkthypothese (t -test): $H_0 : \beta_1 = 45$
- ▶ Blaue Punkte: Grenze der funktionalen Intervallhypothese (t -test)
 $H_0 = H_{04} : \gamma = \beta_1 + 30\beta_2 < 0$
- ▶ Schwarze Symbole: Simultane Nullhypothese (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!



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

13.3. Logistische Regression

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

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

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



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

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

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



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

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 5th 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 5th data point



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