


## Lineare Regression


$$\pi_1 = \beta_0 + \beta_1 x$$

## Logistische Regression (Logit-Modell)

$$\ln\left(\frac{\pi_1}{1 - \pi_1}\right) = \beta_0 + \beta_1 x$$



$$\beta_0=0; \beta_1=1$$



$$\beta_0=0; \beta_1=-1$$

Logit  
(Log-Odd)

$$\ln\left(\frac{\pi_1}{1 - \pi_1}\right) = \beta_0 + \beta_1 x$$

Odd

$$\frac{\pi_1}{1 - \pi_1} = e^{\beta_0 + \beta_1 x} = e^{\beta_0} \times e^{\beta_1 x}$$

Wahrschein-  
lichkeit

$$\pi_1 = \frac{e^{\beta_0 + \beta_1 x}}{1 + e^{\beta_0 + \beta_1 x}}$$

$$\pi_1 = \frac{1}{1 + e^{-(\beta_0 + \beta_1 x)}}$$

Zu den Transformationen

$$(1) \quad \ln\left(\frac{\pi_1}{1-\pi_1}\right) = \beta_0 + \beta_1 x$$

$$\text{da: } e^{\ln Q} = Q$$

$$(2) \quad e^{\ln(\pi_1/(1-\pi_1))} = \frac{\pi_1}{1-\pi_1} = e^{(\beta_0+\beta_1 x)} = e^{\beta_0} \times e^{\beta_1 x} \quad \big| \cdot (1-\pi_1)$$

$$(3) \quad \pi_1 = (1-\pi_1)e^{(\beta_0+\beta_1 x)}$$

$$(4) \quad \pi_1 = e^{(\beta_0+\beta_1 x)} - \pi_1 e^{(\beta_0+\beta_1 x)} \quad \big| + \pi_1 e^{(\beta_0+\beta_1 x)}$$

Zu den Transformationen (Fortsetzung)

---

$$(5) \quad \pi_1 + \pi_1 e^{(\beta_0 + \beta_1 x)} = e^{(\beta_0 + \beta_1 x)}$$

$$(6) \quad \pi_1 (1 + e^{(\beta_0 + \beta_1 x)}) = e^{(\beta_0 + \beta_1 x)} \quad \left| \div (1 + e^{(\beta_0 + \beta_1 x)}) \right.$$

$$(7) \quad \pi_1 = \frac{e^{(\beta_0 + \beta_1 x)}}{1 + e^{(\beta_0 + \beta_1 x)}}$$

## **EQUAL**

Wenn sich die Einkommen in unserer Gesellschaft stärker angleichen würden: Versprechen Sie sich davon Vorteile? [**1**=ja; **0**=nein]

## **EK**

Monatl. Haushaltsnettoeinkommen, dividiert durch die Zahl der Haushaltsmitglieder, die zu diesem Haushaltseinkommen beitragen

Codes der erfragten Einkommensklassen

**1** = *unter* 1.000 DM

**2, ..., 15** = 1.000 bis 8.000 DM, in Stufen à 500 DM

**16** = *über* 8.000 DM

# Statistik und empirische Sozialforschung

## EQUAL

	Häufigkeit	Prozent	Gültige Prozente	Kumulierte Prozente
Gültig ,00	141	43,8	45,8	45,8
1,00	167	51,9	54,2	100,0
Gesamt	308	95,7	100,0	
Fehlend System	14	4,3		
Gesamt	322	100,0		

## Deskriptive Statistiken

	Mittelwert	Standardab weichung	N
EQUAL	,5432	,49903	278
EK	4,6640	2,55603	278

## EK

	Häufigkeit	Prozent	Gültige Prozente	Kumulierte Prozente
Gültig ,50	3	,9	1,0	1,0
1,00	10	3,1	3,4	4,5
1,25	1	,3	,3	4,8
1,50	9	2,8	3,1	7,9
2,00	24	7,5	8,3	16,2
2,33	2	,6	,7	16,9
2,50	13	4,0	4,5	21,4
2,67	2	,6	,7	22,1
3,00	27	8,4	9,3	31,4
3,33	1	,3	,3	31,7
3,50	23	7,1	7,9	39,7
3,67	3	,9	1,0	40,7
4,00	30	9,3	10,3	51,0
4,50	19	5,9	6,6	57,6
5,00	35	10,9	12,1	69,7
5,33	3	,9	1,0	70,7
5,50	8	2,5	2,8	73,4
6,00	16	5,0	5,5	79,0
6,50	5	1,6	1,7	80,7
7,00	15	4,7	5,2	85,9
7,50	3	,9	1,0	86,9
8,00	21	6,5	7,2	94,1
9,00	7	2,2	2,4	96,6
10,00	1	,3	,3	96,9
11,00	3	,9	1,0	97,9
12,00	1	,3	,3	98,3
13,00	1	,3	,3	98,6
14,00	1	,3	,3	99,0
16,00	3	,9	1,0	100,0
Gesamt	290	90,1	100,0	
Fehlend System	32	9,9		
Gesamt	322	100,0		

Lineare  
Regression

## Modellzusammenfassung

Modell	R	R-Quadrat	Korrigiertes R-Quadrat	Standardf ehler des Schätzers
1	,176 <sup>a</sup>	,031	,027	,49218

a. Einflußvariablen : (Konstante), EK

Koeffizienten<sup>a</sup>

Modell	Nicht standardisierte Koeffizienten		Standardisie rte Koeffizienten	T	Signifikanz
	B	Standar dfehler	Beta		
1 (Konstante)	,703	,062		11,429	,000
EK	-3,426E-02	,012	-,176	-2,962	,003

a. Abhängige Variable: EQUAL

n=278



# Logistische Regression

## Modellzusammenfassung


Schritt	-2 Log-Likelihood	Cox & Snell R-Quadrat	Nagelkerkes R-Quadrat
1	374,590	,031	,041

## Variablen in der Gleichung

		Regressions koeffizientB	Standar dfehler	Wald	df	Sig.	Exp(B)
Schritt	EK	-,144	,051	8,080	1	,004	,866
1	Konstante	,847	,266	10,160	1	,001	2,332

a. In Schritt 1 eingegebene Variablen: EK.

n=278



## Likelihood-Prinzip

Besagt, dass man aus der Menge der möglichen Parameter der Population denjenigen auswählen sollte, bei dem es am wahrscheinlichsten ist, dass man die vorliegende Stichprobe beobachtet.

$\Pr(f \mid \pi, n, M)$  Wenn **Verteilungsfunktion**  $M$  = Binomialverteilung:

$$\Pr(f \mid \pi, n) = \binom{n}{f} \pi^f (1 - \pi)^{n-f}$$

### 3 Gruppen (Populationen) á 10 Personen

G1: 3 von 10 haben gesuchte Eigenschaft

G2: 5 von 10 haben gesuchte Eigenschaft

G3: 8 von 10 haben gesuchte Eigenschaft

Es wird eine Stichprobe vom Umfang  $n=3$  (mit Zurücklegen) gezogen;  
alle 3 Personen hatten die gesuchte Eigenschaft ( $f=3$ )

Frage: aus welcher der 3 Gruppen stammt die Stichprobe?

$$\Pr(f|\pi, n) = \binom{n}{f} \pi^f (1 - \pi)^{n-f}$$

$$\Pr(3|\pi, 3) = \binom{3}{3} \pi^3 (1 - \pi)^{3-3}$$

$$\Pr(3|0,30,3) = \binom{3}{3} 0,30^3 (1 - 0,30)^{3-3} = \underline{\underline{0,027}}$$

$$\Pr(3|0,50,3) = \binom{3}{3} 0,50^3 (1 - 0,50)^{3-3} = \underline{\underline{0,125}}$$

$$\Pr(3|0,80,3) = \binom{3}{3} 0,80^3 (1 - 0,80)^{3-3} = \underline{\underline{0,512}}$$

$$\Pr(f \mid \pi, n, M) \quad \Pr(f \mid \pi, n) = \binom{n}{f} \pi^f (1 - \pi)^{n-f}$$

Likelihood-Funktion:

$$L(\pi \mid f, n, M) \quad L(\pi \mid f, n) = \binom{n}{f} \pi^f (1 - \pi)^{n-f}$$

$$L = K \pi^f (1 - \pi)^{n-f}$$

Zu maximieren:  $\ln L = \ln(K) + f \ln \pi + (n - f) \ln(1 - \pi)$

## Gütemaße

$$\mathbf{-2LL [Devianz] = -2 \times \text{LogLikelihood}}$$

(entspricht Fehlerquadratsumme der linearen Regression)

Chi<sup>2</sup>-verteilt mit df=N-K-1

N = Anzahl der Beobachtungen

K = Anzahl der unabh. Variablen

H<sub>0</sub>: Modell besitzt perfekte Anpassung

H<sub>1</sub>: Modell besitzt keine perfekte Anpassung

Perfekter Modellfit: Likelihood=1, Devianz=0

## Likelihood-Ratio- bzw. Devianztest

$$LR = -2 \times \ln(L_r / L_u) = -2 \times [\ln(L_r) - \ln(L_u)] = -2 \times \ln(L_r) - 2 \times \ln(L_u)$$

Likelihood-Ratio Chi-Quadrat

$$L^2 = 2 \sum_k f_k \ln \left( \frac{f_k}{\hat{F}_k} \right)$$

$f$  beobachtete  
 $F$  erwartete Häufigkeiten

(ML Schätzungen sind äquivalent mit der Minimierung von  $L^2$ );  
 $L^2$  = Spezialfall von LR, wenn das unrestringierte Modell saturiert ist\*)

---

$$McFaddens - R^2 = 1 - \frac{LL_V}{LL_0}$$

$LL_0$ : LogLikelihood des Nullmodells (nur mit Konstante)  
 $LL_V$ : LogLikelihood des vollständigen Modells

---

$$Cox \& Snell - R^2 = 1 - \left[ \frac{L_0}{L_V} \right]^{\frac{2}{N}}$$

$L_0$ : Likelihood des Nullmodells (nur mit Konstante)  
 $L_V$ : Likelihood des vollständigen Modells  
 $N$ : Stichprobenumfang

$$\text{Nagelkerke } R^2 = \frac{R^2}{R_{\max}^2}$$

$$R_{\max}^2 = 1 - \left(L_0\right)^{\frac{2}{N}}$$

$L_0$ : Likelihood des Nullmodells (nur mit Konstante)

N: Stichprobenumfang

---

### Wald-Statistik

$$W = \left( \frac{b_k}{s_{b_k}} \right)^2$$

- asymptotisch  $\chi^2$ -verteilt,
- bei  $df=1$  Freiheitsgrad



## Erweiterung um erklärende Variablen

$$\ln\left(\frac{\pi_1}{1-\pi_1}\right) = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k$$

$$\frac{\pi_1}{1-\pi_1} = e^{\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k} = e^{\beta_0} \times e^{\beta_1 x_1} \times e^{\beta_2 x_2} \times \dots \times e^{\beta_k x_k}$$

$$\pi_1 = \frac{e^{\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k}}{1 + e^{\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k}}$$

## Polytome abhängige Variable

mit  $I$  Ausprägungen

Die  $\frac{I \times (I-1)}{2}$  unterscheidbaren Odds bzw. Logits

sind durch  $I - 1$  Modellgleichungen darzustellen.

z.B.:

$$\ln\left(\frac{\pi_1}{\pi_3}\right) = \beta_{0,1/3} + \beta_{1,1/3}x_1$$

$$\ln\left(\frac{\pi_2}{\pi_3}\right) = \beta_{0,2/3} + \beta_{1,2/3}x_1$$


# Kategoriale unabhängige Variablen

## Logit Modell

$$\ln\left(\frac{\pi_1}{1 - \pi_1}\right) = \ln\left(\frac{m_{q1}}{m_{q2}}\right) = \beta_0 + \beta_1 x_{1q}$$

## Loglineares Modell:

$$\ln(m_{ql}) = \lambda + \lambda_q^X + \lambda_l^Y + \lambda_{ql}^{XY}$$



**Zur Äquivalenz von loglinearen und Logit Modellen:**

$$\ln\left(\frac{m_{q1}}{m_{q2}}\right) = \beta_0 + \beta_1 x_q = 2\lambda_1^Y + 2\lambda_{q1}^{XY} \quad \text{wenn: } \underline{\lambda_1^Y = -\lambda_2^Y} \quad \text{und} \quad \underline{\lambda_{q1}^{XY} = -\lambda_{q2}^{XY}}$$

$$\ln\left(\frac{m_{q1}}{m_{q2}}\right) = \ln(m_{q1}) - \ln(m_{q2})$$

$$\ln(m_{q1}) = \lambda + \lambda_q^X + \lambda_1^Y + \lambda_{q1}^{XY}$$

$$\ln(m_{q2}) = \lambda + \lambda_q^X + \lambda_2^Y + \lambda_{q2}^{XY}$$

$$\begin{aligned} \ln(m_{q1}) - \ln(m_{q2}) &= \lambda - \lambda + \lambda_q^X - \lambda_q^X + \lambda_1^Y - \lambda_2^Y + \lambda_{q1}^{XY} - \lambda_{q2}^{XY} \\ &= \lambda_1^Y - (-\lambda_1^Y) + \lambda_{q1}^{XY} - (-\lambda_{q1}^{XY}) = 2\lambda_1^Y + 2\lambda_{q1}^{XY} \end{aligned}$$

	d=1	d=2	d=3		d=1	d=2
q=1	1	0	0		1	0
q=2	0	1	0		0	1
q=3	0	0	1		-1	-1

Dummykodierung      Effektkodierung