

## Vorlesung: Lineare Modelle

Prof. Dr. Helmut Küchenhoff

Institut für Statistik, LMU München

SoSe 2014

- 5 Metrische Einflußgrößen: Polynomiale Regression, Trigonometrische Polynome, Regressionssplines, Transformationen.
- 6 Modelldiagnose
- 7 Variablenselektion
- 8 Das allgemeine lineare Modell: Gewichtete KQ-Methode, Autokorrelierte und heteroskedastische Störterme
- 9 **Das logistische Regressionsmodell**
- 10 Das gemischte lineare Regressionsmodell („Linear mixed Model“)

## Das logistische Regressionsmodell

$$\pi_i = P(Y_i = 1|x_i) = G(x_i'\beta) \quad (9.1)$$

$$\ln \frac{\pi_i}{1 - \pi_i} = x_i'\beta \quad (9.2)$$

$$Y_i, i = 1, \dots, n \quad \text{unabhängig (bei gegebenem festen } X) \quad (9.3)$$

$$G(t) = (1 + \exp(-t))^{-1} \quad (9.4)$$

$Y_i$ : binäre Zielgröße

$x_i$ : Vektor der Einflussgrößen

$X$ : Design-Matrix der Einflussgrößen mit vollem Rang

## Bezeichnungen

$\ln \frac{\pi_i}{1 - \pi_i}$	:	„Logarithmierte Chance“ Log-odds
$x_i'\beta = \beta_0 + \beta_1 x_{i1} + \dots + \beta_p x_{ip}$	:	linearer Prädiktor
Funktion $G$	:	Response-Funktion (Inverse Link-Funktion)

Die Wahl von  $G$  (Verteilungsfunktion der logistischen Verteilung) als Responsefunktion ermöglicht folgende Interpretation:  
Einfaches Modell:

$$\begin{aligned} P(Y = 1|x_0) &= G(\beta_0 + \beta_1 * x_0) \\ P(Y = 1|x_0 + 1) &= G[\beta_0 + \beta_1 * (x_0 + 1)] \\ \frac{P(Y = 1|x_0 + 1)/(1 - P(Y = 1|x_0 + 1))}{P(Y = 1|x_0)/(1 - P(Y = 1|x_0))} &= \exp(\beta_1) \\ \ln \frac{P(Y = 1|x_0 + 1)}{1 - P(Y = 1|x_0 + 1)} - \ln \frac{P(Y = 1|x_0)}{1 - P(Y = 1|x_0)} &= \beta_1 \end{aligned}$$

# Interpretation

Das logistische Regressionsmodell nimmt einen linearen Zusammenhang zwischen den „Log-odds“ von  $Y$  und den Einflussgrößen  $X$  an.

Interpretation:

- Wenn  $x_k$  um einen Einheit steigt, so ändert sich die logarithmierte Chance von  $Y$  um  $\beta_k$ .
- Wenn  $x_k$  um einen Einheit steigt, so ändert sich die Chance von  $Y$  um den Faktor  $\exp(\beta_k)$ .
- Das Odds Ratio (Chancenverhältnis) zwischen  $Y$  bei  $x_k$  und  $Y$  bei  $x_k + 1$  ist  $\exp(\beta)$ .

W'keit	0.01	0.05	0.1	0.3	0.4	0.5	0.6	0.7	0.9	0.95	0.99
Odds	1/99	1/19	1/9	3/7	2/3	1	1.5	7/3	9	19	99
Log odds	-4.6	-2.9	-2.2	-0.85	-0.41	0	0.41	0.85	2.2	2.9	4.6

# Beispiele

- $Y$ : Kreditwürdigkeit,  
 $X$ : Personenmerkmale
- $Y$ : Auftreten einer Krankheit innerhalb einer bestimmten Zeit,  
 $X$ : Exposition, Geschlecht, Alter etc.
- $Y$ : Auffinden der korrekten Blüte,  
 $X$ : Zeit (Trend), Art (Fledermaus)
- $Y$ : Präferenz für eine Partei,  
 $X$ : Persönlichkeitsmerkmale
- $Y$ : Bestehen eines Tests,  
 $X$ : Lehrmethode, Geschlecht etc.

# Bemerkungen

Die Varianten des multiplen linearen Regressionsmodells lassen sich direkt auf das logistische Modell übertragen:

- Behandlung von Guppenvergleichen (ANOVA) mit Hilfe von Indikatorvariablen
- Behandlung von diskreten Einflussgrößen: verschiedene Codierungen, Interaktionen, etc.
- Behandlung von stetigen Einflussgrößen (Polynome, Splines etc.)

Beachte:

Beim logistischen Modell „fehlt“ der Varianz-Parameter  $\sigma$ , da  $Var(Y) = E(Y) * [1 - E(Y)]$

Weiter ist keine Verteilungsannahme nötig, da  $Y$  immer Bernoulli-verteilt ist.

# Logistische Regression als Klassifikationsproblem

- Prognose in der Logistischen Regression entspricht Klassifikationsproblem mit 2 Gruppen
- Analogien zu Verfahren der Diskriminanzanalyse
- Diskriminanzregeln aus logistischer Regression möglich

# ML-Schätzung im logistischen Regressionsmodell

Sei das Modell (9.1)–(9.4) gegeben.

$$\hat{\beta}_{ML} := \arg \max L(\beta) = \arg \max \ln L(\beta) \tag{9.5}$$

$$L(\beta) = \prod_{i=1}^n G(x_i' \beta)^{Y_i} (1 - G(x_i' \beta))^{1 - Y_i} \tag{9.6}$$

$$\ln L(\beta) = \sum_{i=1}^n Y_i \ln(G(x_i' \beta)) + (1 - Y_i) \ln(1 - G(x_i' \beta)) \tag{9.7}$$

Ableiten nach  $\beta$  und Null setzen liefert unter Benutzung von  $G' = G(1 - G)$  die Score-Gleichungen für  $\hat{\beta}_{ML}$ .

$$s(\hat{\beta}_{ML}) := \sum_{i=1}^n (Y_i - G(x_i' \hat{\beta}_{ML})) x_i = 0. \tag{9.8}$$

## Existenz und Eindeutigkeit des ML-Schätzers im logistischen Modell

### Eindeutigkeit:

Da die Likelihood-Funktion konkav ist, ist die Lösung der Score-Gleichung immer eindeutig

### Existenz:

Der ML-Schätzer existiert  $\iff$  Die Werte 0 und 1 sind nicht linear trennbar, d.h. es existiert kein  $\alpha$  mit  $Y = 1$  für  $x' \alpha > 0$  und  $Y = 0$  für  $x' \alpha < 0$   
 Im Fall der Nicht-Existenz geht mindestens eine Komponente gegen  $\infty$ .  
 Im einfachen Modell bedeutet die Bedingung, dass  $Y=1$  für  $x > c$  und  $Y=0$  für  $x < c$ .

# Eigenschaften des ML-Schätzers

Die allgemeine Theorie der Maximum-Likelihood-Schätzung liefert:  
 Für  $n \rightarrow \infty$  gilt unter Regularitätsbedingungen:

$$\hat{\beta}_{ML} \rightarrow N(\beta, F^{-1}(\beta)) \tag{9.9}$$

$$F(\beta) = X' D(\beta) X \tag{9.10}$$

$$D(\beta) = \text{diag}\{(G(x_i' \beta)(1 - G(x_i' \beta)))\} \tag{9.11}$$

$$\hat{\beta}' F(\beta) \hat{\beta} \rightarrow \chi^2(p') \tag{9.12}$$

- Die asymptotische Varianzmatrix ergibt sich als Inverse der Fischer-Information (negative Ableitung der Score-Funktion)
- Die asymptotische Varianzmatrix entspricht auch der Varianzmatrix aus der gewichteten (heteroskedastischen) Regression, da  $\text{Var}(Y) = D(\beta) = \text{diag}(G(x_i' \beta)(1 - G(x_i' \beta)))$
- Die numerische Berechnung des ML-Schätzers erfolgt nach der Methode der „iterierten gewichteten kleinsten Quadrate“ (IWLS Iteratively Weighted Least Squares)

## Inferenz im logistischen Regressionsmodell

### Beachte:

Alle Aussagen gelten - im Gegensatz zum linearen Regressionsmodell - nur asymptotisch, d.h. für hinreichend große Stichprobenumfänge!

### Wald-Konfidenzintervalle:

Wir benutzen die asymptotische Normalität und erhalten folgende Konfidenzintervalle für  $\beta$  zum Niveau  $\alpha$  :

$$\hat{\beta}_k \pm \hat{\sigma}_{\hat{\beta}_k} z_{1-\alpha/2}$$

$$\hat{\sigma}_{\hat{\beta}_k} = \sqrt{c_{kk}} \text{ (k-tes Diagonalelement der Matrix } F^{-1}(\hat{\beta}))$$

Für die Odds-ratios  $\exp(\beta_k)$  ergibt sich das transformierte Konfidenzintervall zum Niveau  $\alpha$  :

$$\exp \left[ \hat{\beta}_k \pm \hat{\sigma}_{\hat{\beta}_k} z_{1-\alpha/2} \right]$$

Da kein Varianzparameter zu schätzen ist, kommt die t-Verteilung hier nicht vor.

# Wald-Test für die lineare Hypothese

Sei das logistische Regressionsmodell (9.1)–(9.4) gegeben.  
 $H_0 : A\beta = c$  mit  $\text{rg}(A) = a$ .

Analog zum linearen Modell wird folgende quadratische Form betrachtet:

$$W = (A\hat{\beta} - c)'(AF^{-1}(\hat{\beta})A')^{-1}(A\hat{\beta} - c)$$

W heißt Wald-Statistik.

Aus der asymptotischen Normalität folgt unmittelbar:

$$W \underset{\text{as}}{\sim} \chi^2(a)$$

Mit dieser Statistik lässt sich die allgemeine lineare Hypothese testen.

# Likelihood-Quotienten-Konfidenzintervalle

Mit Hilfe des LQ-Tests lassen sich auch Konfidenzintervalle zum Niveau  $\alpha$  konstruieren:

$$KI := \{\tilde{\beta}_k | H_0 : \beta_k = \tilde{\beta}_k \text{ wird mit LQ-Test zum Niveau } \alpha \text{ nicht abgelehnt}\}$$

# Likelihood-Quotienten-Test für die lineare Hypothese

Sei das logistische Regressionsmodell (9.1)–(9.4) gegeben.  
 $H_0 : A\beta = c$  mit  $\text{rg}(A)=a$ .

Wir definieren folgende Teststatistik:

$$LQ = -2 \{ \ln L(\hat{\hat{\beta}}) - \ln L(\hat{\beta}) \}$$

$\hat{\hat{\beta}} : \text{ML-Schätzer unter } H_0$

Aus der allgemeine Theorie von Likelihood-Quotienten-Tests folgt:  
Es gilt unter  $H_0$ :

$$LQ \underset{\text{as}}{\sim} \chi^2(a)$$

**Beachte:** Der LQ-Test ist mit dem Wald-Test für endliche Stichproben nicht äquivalent. Äquivalenz gilt nur asymptotisch.

# Devianz im logistischen Modell

Analog zur ANOVA-Tafel betrachtet man im logistischen Modell die Log-Likelihood als Maß für die Modellgüte: Dabei wird definiert:

Modell mit Konstante (SST):	$P(Y_i = 1) = G(\beta_0)$
Modell (SSE):	$P(Y_i = 1) = G(x_i' \beta)$
"volles Modell"	$P(Y_i = 1) = p_i$

Von diesen Modellen wird jeweils der Wert von  $-2 \log(L)$  verglichen.

Wir betrachten das logistische Regressionsmodell mit **gruppierten** Daten:

Jeweils  $n_j$  Datenpunkte werden zu einer Gruppe zusammengefasst. Dabei sind in einer Gruppe die Kovariablen identisch.

Sei  $\hat{\pi}_j := G(x_j' \hat{\beta})$ .  
 $Y_j$  : Anzahl der Erfolge in Gruppe  $j$ .

Das Modell ist dann:

$$Y_j | x_j \sim B(n_j, G(x_j' \beta)), \quad j = 1, \dots, g \quad (9.13)$$

## Anpassungstests

### a) Pearson-Statistik

$$\chi_P^2 = \sum_{j=1}^g n_j \frac{(y_j/n_j - G(x_j' \hat{\beta}))^2}{\hat{\pi}_j(1 - \hat{\pi}_j)}$$

### b) Devianz (siehe (9.14)) Verteilungsapproximation ( $n_i/n \rightarrow \lambda_i$ )

$$\chi_P^2, D, \stackrel{(a)}{\sim} \chi^2(g - p')$$

### c) Bei kleinen Gruppenumfängen oder im Fall $n_i = 1$ :

#### Hosmer-Lemeshow-Test

Bilde ca.  $g = 10$  Gruppen nach der Größe des linearen Prädiktors  $x' \hat{\beta}$  und bilde Anpassungsstatistik wie unter a). Die Testverteilung ist ein  $\chi^2(g - 2)$ -Verteilung.

$$D = -2 \sum_{j=1}^g (\ln L(\hat{\beta}) - \ln L(y_j)) \quad (9.14)$$

heißt **Devianz**.

Es gilt:

$$D = 2 \sum_{j=1}^g y_j \ln \frac{y_j/n_j}{G(x_j' \hat{\beta})} + (n_j - y_j) \ln \frac{(n_j - y_j)/n_j}{(1 - G(x_j' \hat{\beta}))} \quad (9.15)$$

## Residualanalyse I

Wir betrachten wie oben das logistische Regressionsmodell mit gruppierten Daten. Sei  $\hat{\pi}_j := G(x_j' \hat{\beta})$ .

### a) Devianz-Residuen

$$d_j = \text{sign}(y_j - n_j \hat{\pi}_j) \sqrt{y_j \ln \frac{y_j/n_j}{\hat{\pi}_j} + (n_j - y_j) \ln \frac{(n_j - y_j)/n_j}{(1 - \hat{\pi}_j)}} \quad (9.16)$$

### b) Pearson-Residuen

$$r_j = \frac{y_j - n_j \hat{\pi}_j}{\sqrt{n_j \hat{\pi}_j (1 - \hat{\pi}_j)}} \quad (9.17)$$

c) Standardisierung der Residuen

H := D^{1/2} X (X' D X)^{-1} X' D^{1/2} (9.18)

D = diag(n\_j \hat{\pi}\_j (1 - \hat{\pi}\_j)) (9.19)

d\_j^\* := d\_j / \sqrt{1 - h\_{jj}} (9.20)

r\_j^\* := r\_j / \sqrt{1 - h\_{jj}} (9.21)

d) Likelihood-Residuen

lr\_j := sign(y\_j - n\_j G(x\_j' \beta)) \sqrt{2(\ln L(\tilde{\beta}, \hat{\gamma}\_j) - \ln L(\hat{\beta}))} (9.22)

L(\tilde{\beta}, \hat{\gamma}\_j) : Likelihood des Modells mit dem der zusätzlichen Indikatorvariablen für die Beobachtung j mit zugehörigem Parameter \gamma\_j.

Sensitivität und Spezifität

Richtig Positiv = Sensitivität:

(m) P(\hat{Y} = 1 | Y = 1) = P(m \ge c | Y = 1) = S\_1(c) (9.25)

(k) P(\hat{Y} = 1 | Y = 1) = P(s \le c | Y = 1) = F\_1(c) (9.26)

S\_1(c) stellt die Survivorfunktion dar, F\_1(c) die Verteilungsfunktion.

Falsch Positiv = 1- Spezifität:

(m) P(\hat{Y} = 1 | Y = 0) = P(m \ge c | Y = 0) = S\_0(c) (9.27)

(k) P(\hat{Y} = 1 | Y = 0) = P(s \le c | Y = 0) = F\_0(c) (9.28)

Die ROC-Kurve besteht aus den Punkten (S\_0(c), S\_1(c)) bzw. (F\_0(c), F\_1(c)).

Allgemein

Y = 1 -> Ausfall (krank)

Y = 0 -> kein Ausfall (gesund)

In der medizinischen Literatur ist das Testergebnis m:

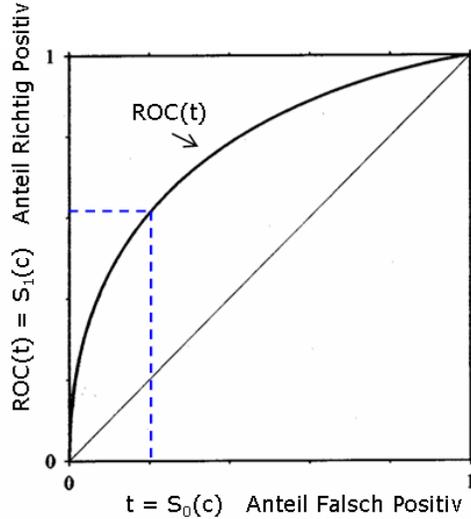
\hat{Y}\_i = 1 \Leftrightarrow m\_i \ge c (9.23)

In der Literatur zum Kreditrisiko ist der Score s:

\hat{Y}\_i = 1 \Leftrightarrow s\_i \le c (9.24)

c ist dabei ein Grenzwert. Beide Ansätze sind offensichtlich äquivalent: Betrachte dazu m\_i = -s\_i

Beispiel für ROC-Kurve



$$m_i = G(x_i' \beta)$$

$$m_i = x_i' \beta$$

Beachte die Invarianz der ROC Kurve bzgl. monotoner Funktionen! Die Verteilung von  $F_0, F_1$  bzw.  $S_0, S_1$  kann aus den Daten geschätzt werden  $\Rightarrow$  ROC-Kurve

Alternative: Schätze  $F_0, F_1$  bzw.  $S_0, S_1$  aus Validierungsdaten.

## GINI- Koeffizient

Normierte Fläche zwischen Winkelhalbierender und ROC- Kurve

$$GINI = 2 \cdot (AUC - \frac{1}{2}) = 2 \cdot AUC - 1 \tag{9.32}$$

$$\widehat{GINI} = \frac{N_c - N_d}{N} \tag{9.33}$$

Der empirische GINI entspricht dem Somers D.

$$AUC = \int_{t=0}^1 ROC(t) dt \tag{9.29}$$

Dies stellt die Fläche unter der Kurve dar.

Es gilt:

$$AUC = P(m_1 \leq m_0) \tag{9.30}$$

$m_1$  ist dabei aus der Verteilung  $m|Y = 1$   
 $m_0$  ist dabei aus der Verteilung  $m|Y = 0$

Daher ist das empirische AUC:

$$\widehat{AUC} = \frac{N_c}{N} \tag{9.31}$$

Dabei bezeichnet  $N_c$  die Anzahl der konkordanten Paare und N die Anzahl der Paare mit unterschiedlichem Y.  
 Mit  $N_d$  gleich der Anzahl der diskordanten Paare ist der GINI dann:

## Die logistische Regression für Fall-Kontroll-Studien

Sei in der Grundgesamtheit folgende Beziehung gegeben:

$$P_0(Y = 1|X = x) = G(\alpha + \beta x) \tag{9.34}$$

mit  $G(t) = (1 + \exp(-t))^{-1}$   
 X: Exposition  
 Y: Erkrankung

Es wird nun aus der GG gezogen:  
 $n_1$  Fälle ( $Y = 1$ ) und  $n_2$  Kontrollen ( $Y = 0$ )

Gesucht ist

$$P_S(Y = 1|X = x) \tag{9.35}$$

Mit  $P_S$  werden die Wahrscheinlichkeiten (Dichten) in der Stichprobe bezeichnet, mit  $P_0$  die in der GG.

## Berechnung von $P_S$ I

$$P_S(Y = 1|X = x) = \frac{P_S(Y = 1, X = x)}{P_S(X = x)} = \frac{P_S(Y = 1)P_S(X = x|Y = 1)}{P_S(Y = 1)P_S(X = x|Y = 1) + P_S(Y = 0)P_S(X = x|Y = 0)} = \frac{c_1 P_0(X = x|Y = 1)}{c_1 P_0(X = x|Y = 1) + c_2 P_0(X = x|Y = 0)}$$

Die letzte Identität gilt wegen

$$P_0(X = x|Y = 1) = P_S(X = x|Y = 1) \quad (9.36)$$

und mit  $c_1 = \frac{n_1}{n_1 + n_2}$  und  $c_2 = \frac{n_2}{n_1 + n_2}$

$$c_1 P_0(X = x|Y = 1) = \frac{c_1}{P_0(Y = 1)} P_0(X = x) P_0(Y = 1|X = x)$$

$$c_2 P_0(X = x|Y = 0) = \frac{c_2}{P_0(Y = 0)} P_0(X = x) P_0(Y = 0|X = x)$$

## Berechnung von $P_S$ II

Mit  $\frac{c_1}{P_0(Y = 1)} = d_1$  und  $\frac{c_2}{P_0(Y = 0)} = d_2$  folgt:

$$P_S(Y = 1|X = x) = \frac{d_1 P(Y = 1|X = x)}{d_1 P(Y = 1|X = x) + d_2 (1 - P(Y = 1|X = x))} = \frac{1}{1 + \frac{d_2}{d_1} \frac{1 - G(\alpha + \beta x)}{G(\alpha + \beta x)}} = \frac{1}{1 + \exp(-\alpha - \ln(\frac{d_1}{d_2}) - \beta x)}$$

Die letzte Gleichung folgt aus  $\frac{1 - G(t)}{G(t)} = \frac{1}{G(t)} - 1 = \exp(-t)$ .

## Berechnung von $P_S$ III

Insgesamt gilt:

$$P_S(Y = 1|X = x) = G\left(\alpha + \ln\left(\frac{d_1}{d_2}\right) + \beta x\right) \quad (9.37)$$

Die Auswertung bezüglich  $\beta$  kann also durch eine logistische Regression erfolgen. Der Parameter  $\alpha$  in der Grundgesamtheit kann dabei nicht geschätzt werden.