

Logistische Regression

21.11.2011

Einführung

Beispiele

- ▶ Medikament, Phase-I study (FDA):
Suche Dosis, sd. max. 1/3 von (gesunden) Probanden
Nebenwirkungen zeigt.
- ▶ Tierversuch:
Bei welcher Dosis überleben 50% der Mäuse (=LD50)?
- ▶ Frühgeburten:
Wie hängt die Überlebenswahrscheinlichkeit ab von gewissen
Variablen (Gewicht, Alter, APGAR score, ...)?
- ▶ Technik:
Bei welchen Bedingungen fallen Geräte aus?
- ▶ Customer-Relationship-Management (CRM):
Was für Massnahmen sind erfolgreich, damit ein Kunde z.B.
auf ein teureres Produkt wechselt?
- ▶ Google nach "Nate Silver" (Oscar-, Election-prediction etc.)

Gemeinsamkeiten

- ▶ **Binäre Zielgrösse** (ja/nein, lebt/tot, ...).
- ▶ Beliebige erklärende Variablen.


Dies hat die Form eines Regressionsmodells. Was ist neu?

Die Zielgrösse ist nicht mehr stetig, sondern **binär**.

Beispiel Ader-Verengung

Y: Ader-Verengung ja (1) / nein (0)

Erklärende: Atem-Volumen (Vol) und Atem-Frequenz (Rate)



Ausgefüllte Symbole: Ader-Verengung ja (1).

Modellansatz

Ziel Modelliere $P(Y_i = 1 \mid x_i^{(1)}, x_i^{(2)}, \dots, x_i^{(m)})$

Ansatz $P(Y_i = 1 \mid x_i^{(1)}, x_i^{(2)}, \dots, x_i^{(m)}) = h(x_i^{(1)}, x_i^{(2)}, \dots, x_i^{(m)})$

Bemerkung

Für $Y \in \{0, 1\}$ gilt

$$\begin{aligned} E[Y] &= 1 \cdot P(Y = 1) + 0 \cdot P(Y = 0) \\ &= P(Y = 1). \end{aligned}$$

D.h. wir modellieren eigentlich

$$E[Y_i \mid x_i^{(1)}, \dots, x_i^{(m)}] = h(x_i^{(1)}, \dots, x_i^{(m)})$$

wie in der linearen Regression.

Ansatz mit linearer Regression?

$$Y_i = \beta_0 + \beta_1 x_i^{(1)} + \beta_2 x_i^{(2)} + \dots + \beta_m x_i^{(m)} + E_i$$

Es gilt dann

- ▶ $P(Y_i = 1 | \underline{x}_i) = E(Y_i | \underline{x}_i) = \beta_0 + \beta_1 x_i^{(1)} + \beta_2 x_i^{(2)} + \dots + \beta_m x_i^{(m)}$
D.h. die Funktion h wäre linear.
- ▶ Geschätzte Werte können daher < 0 und > 1 werden ⚡
- ▶ Transformation von Y_i ? 2 Werte bleiben 2 Werte ⚡

Ausweg: Transformation von $E(Y) = P(Y = 1)$!

Am Besten transformieren wir die Wahrscheinlichkeiten so, dass wir **keine Einschränkungen** mehr haben.

Logistisches Regressionsmodell

Benutze **Logit-Funktion** $g : [0, 1] \rightarrow \mathbb{R}$

$$g(\pi) = \log\left(\frac{\pi}{1 - \pi}\right)$$

- ▶ Die Funktion g transformiert die Wahrscheinlichkeiten auf die gesamte reelle Achse!
- ▶ $\log\left(\frac{\pi}{1 - \pi}\right)$ sind die **log-odds** (siehe Vorlesung kategorielle Variablen)!

Modell

Auf der transformierten Skala verwenden wir den “alten” linearen Ansatz, d.h.

$$\begin{aligned}g(P(Y_i = 1 | \underline{x}_i)) &= \log \left(\frac{P(Y_i = 1 | \underline{x}_i)}{P(Y_i = 0 | \underline{x}_i)} \right) \\&= \beta_0 + \beta_1 x_i^{(1)} + \beta_2 x_i^{(2)} + \dots + \beta_m x_i^{(m)} \\&= \underline{x}_i^T \underline{\beta} \\&= \eta_i.\end{aligned}$$



Terminologie

▶ $\eta_i = \underline{x}_i^T \underline{\beta}$ heisst **linearer Prädiktor**.

▶ g heisst **Linkfunktion**.

Die Linkfunktion transformiert den Erwartungswert auf die “geeignete Skala”.

Link- und inverse Linkfunktion



Kennt man den linearen Prädiktor (oder die β_k 's), so erhält man die Wahrscheinlichkeiten durch


$$P(Y_i = 1) = g^{-1}(\eta_i) = \frac{\exp\{\eta_i\}}{1 + \exp\{\eta_i\}},$$

bzw.

$$P(Y_i = 0) = 1 - P(Y_i = 1) = \frac{1}{1 + \exp\{\eta_i\}}.$$

Aus notationellen Gründen lassen wir das Bedingen auf \underline{x}_i weg.

Ader-Verengung: Illustration W'keiten vs. linearer Prädiktor



Beispiel Ader-Verengung

Angepasstes Modell liefert

$$g(P(Y = 1)) = -9.53 + 3.88 \cdot \text{Vo1} + 2.65 \cdot \text{Rate}.$$


Punkte mit gleichen W' keiten haben die Eigenschaft, dass

$$-9.53 + 3.88 \cdot \text{Vo1} + 2.65 \cdot \text{Rate} = \text{const.}$$

D.h. Rate hängt dann linear von Vo1 ab.

Bzw. Punkte mit gleichen W' keiten liegen auf (parallelen) Geraden im Raum (Vo1, Rate).

Illustration angepasstes Modell für Ader-Verengung



Punkte auf gestrichelten Geraden liefern alle die gleichen W'keiten.

Interpretation der Parameter

Wir betrachten die **odds**

$$\begin{aligned}\text{odds}(Y = 1 | \underline{x}) &= \frac{P(Y = 1 | \underline{x})}{P(Y = 0 | \underline{x})} \\ &= \exp \left\{ \beta_0 + \beta_1 x^{(1)} + \dots + \beta_m x^{(m)} \right\}. \\ &= \exp\{\beta_0\} \cdot \exp\{\beta_1\}^{x^{(1)}} \dots \exp\{\beta_m\}^{x^{(m)}}.\end{aligned}$$

- ▶ Wenn man $x^{(j)}$ um eine Einheit erhöht (und alles andere fix lässt), so ändern sich die odds um den Faktor $\exp\{\beta_j\}$.
- ▶ Das Doppelverhältnis (**odds ratio**) ist $\exp\{\beta_j\}$

$$\frac{\text{odds}(Y = 1 | x^{(j)} = c_j + 1)}{\text{odds}(Y = 1 | x^{(j)} = c_j)} = \exp\{\beta_j\}, \text{ für beliebiges } c_j.$$

- ▶ Das **log odds-ratio** ist dann entsprechend β_j .

Gruppierte Daten

Manchmal hat man zu den gleichen erklärenden Variablen **mehrere Beobachtungen** (Replikate) der Zielvariable.

Notation

m_ℓ Beobachtungen Y_i zu gleichen $\underline{x}_i = \underline{\tilde{x}}_\ell$.

Definiere $\tilde{Y}_\ell = \frac{1}{m_\ell} \sum_{i:\underline{x}_i=\underline{\tilde{x}}_\ell} Y_i$ (Anteil "Erfolge").

Es gilt dann

- ▶ $m_\ell \tilde{Y}_\ell \sim \text{Bin}(m_\ell, \tilde{\pi}_\ell)$
- ▶ $E[\tilde{Y}_\ell] = \tilde{\pi}_\ell,$

wobei $\tilde{\pi}_\ell = P(Y = 1 | \underline{\tilde{x}}_\ell)$, $g(\tilde{\pi}_\ell) = \underline{\tilde{x}}_\ell^T \underline{\beta}$.

Wir verwenden das gleiche Modell wie vorher.


Bei gruppierten Daten hat man den Vorteil, dass man **mehr Informationen** hat. Man könnte eigentlich für jede Gruppe die W 'keit einzeln schätzen wenn m_ℓ genügend gross ist.

Beispiel gruppierte Daten: Frühgeburten

- ▶ 247 Säuglinge
- ▶ Erklärende Variable: Geburtsgewicht
- ▶ Klassen von je 100g Gewicht
- ▶ Zielvariable: Survival (ja / nein)

	<i>n</i>	Surv.no	Surv.yes	Weight
1	10	10	0	550
2	14	12	2	650
3	27	18	9	750
4	22	14	8	850
5	32	9	23	950
6	28	7	21	1050
7	22	3	19	1150
8	26	7	19	1250
9	34	3	31	1350
10	32	3	29	1450

Illustration: Frühgeburten



Die Fläche der Kreise ist proportional zu der Anzahl Beobachtungen gewählt.

Modell der latenten Variablen

Nehme an, es ex. nicht-beobachtbare Z_i , sd.

$$Z_i = \underline{x}_i^T \underline{\tilde{\beta}} + E_i.$$

Wir beobachten aber nur, ob Z_i grösser oder kleiner als ein Schwellenwert c ist.

$$Y_i = \begin{cases} 1 & Z_i \geq c \\ 0 & Z_i < c \end{cases}.$$

Jetzt gilt aber:

$$\begin{aligned} \pi_i &= P(Y_i = 1) = P(Z_i \geq c) = P(E_i \geq c - \underline{x}_i^T \underline{\tilde{\beta}}) \\ &= 1 - F_E \left(c - \left(\tilde{\beta}_0 + \sum_j \tilde{\beta}_j x_i^{(j)} \right) \right), \end{aligned}$$

wobei F_E : kumulative Verteilungsfunktion der Zufallsfehler E_i .

Definiere nun $\underline{\beta} = [\tilde{\beta}_0 - c, \tilde{\beta}_1, \dots, \tilde{\beta}_m]$. Jetzt gilt


$$P(Y_i = 1) = g^{-1}(\underline{x}_i^T \underline{\beta})$$

mit $g^{-1}(\eta) = 1 - F_E(-\eta) = F_{-E}(\eta)$.

$E_i \sim$ Logistische Verteilung	Logistische Regressionsmodell
$E_i \sim$ Normalverteilung	Probitmodell
$E_i \sim$ Extremwertverteilung	Komplementäres log-log Modell

Das logistische Regressionsmodell hat den Vorteil, dass die Parameter die "schöne" Interpretation mit den odds-ratio haben.

Illustration latente Variable



c

Schätzungen und Tests

Verwende **Maximum-Likelihood** Prinzip.

Wähle $\underline{\beta}$ so, dass die Wahrscheinlichkeit des beobachteten Ereignisses maximal wird.

Wir haben für unsere n unabhängigen Beobachtungen

$$\ell(\underline{\beta}) = P_{\underline{\beta}}(Y_1 = y_1, \dots, Y_n = y_n) = \prod_{i=1}^n P_{\underline{\beta}}(Y_i = y_i),$$

mit $P_{\underline{\beta}}(Y_i = y_i) = \pi_i^{y_i} (1 - \pi_i)^{1 - y_i}$. π_i hängt natürlich von $\underline{\beta}$ ab.

Um das Produkt zu vermeiden, arbeitet man mit der **log-likelihood**

$$\ell\ell(\underline{\beta}) = \log(\ell(\underline{\beta})).$$

Schlussendlich erhält man

$$\ell(\underline{\beta}) = \sum_{i=1}^n y_i \underline{x}_i^T \underline{\beta} - \log(1 + \exp\{\underline{x}_i^T \underline{\beta}\}).$$

Maximiere dies bzgl. $\underline{\beta} \rightsquigarrow$ Schätzer $\hat{\underline{\beta}}$.

- ▶ Im Gegensatz zur linearen Regression haben wir **keine geschlossen darstellbare Lösung** ⚡
- ▶ **Iterative numerische Verfahren** werden benötigt.
- ▶ Grundidee: Aproximiere das Problem mit einem gewichteten linearen Regressionsproblem und löse dann sukzessive viele gewichtete lineare Regressionen.
- ▶ Entsprechende Routinen sind in allen Statistikpaketen implementiert (Stichwort: Generalized Linear Models, GLM)

Verteilung der geschätzten Koeffizienten

Approximation mit linearen Regressionsproblemen liefert auch (approximative) Verteilung der Parameter (\rightsquigarrow Standardfehler).

- ▶ $\hat{\beta}$ ist approximativ normalverteilt mit Erwartungswert β und einer Kovarianzmatrix V .
- ▶ Teststatistiken sind dann

$$T_j = \frac{\hat{\beta}_j - \beta_j}{\sqrt{\hat{V}_{jj}}} \underset{\text{approx.}}{\sim} N(0, 1).$$

Verwende hier Normal- statt t -Verteilung.

Dies ist ein sogenannter **Wald-Test**.

R-Output im Beispiel der Ader-Verengungen

Call:

```
glm(formula = Y ~ Volume + Rate, family = binomial, data = vaso)
```

Coefficients:

	Estimate	Std. Error	z value	Pr(> z)	
(Intercept)	-9.5296	3.2332	-2.947	0.00320	**
Volume	3.8822	1.4286	2.717	0.00658	**
Rate	2.6491	0.9142	2.898	0.00376	**

(Dispersion parameter for binomial family taken to be 1)

Null deviance: 54.040 on 38 degrees of freedom
Residual deviance: 29.772 on 36 degrees of freedom
AIC: 35.772

Number of Fisher Scoring iterations: 6

Devianzen

► **Residuen-Devianz** (früher: Residuenquadratsumme)

Für gruppierte Daten \tilde{Y}_l . Vergleiche log-likelihood des geschätzten Modells mit derjenigen des maximalen Modells.

$$D(\underline{\tilde{y}}; \underline{\hat{\pi}}) = 2 \left(\ell\ell^{(M)} - \ell\ell \left(\underline{\hat{\beta}} \right) \right).$$

$\ell\ell^{(M)}$: Kann für jede Gruppe $\tilde{\pi}_\ell$ frei wählen (grösstes mögliches Modell).

Bei ungruppierten Daten gilt: $\ell\ell^{(M)} = 0$ (perfekter fit).

Residuen-Devianz vergleicht geschätztes Modell mit maximalen Modell ("Anpassungstest"). Geht nur bei nicht zu kleinen m_ℓ .

► **Devianz-Differenz** (zum Vergleich von Modellen)

Likelihood-Ratio Test für Modellvergleich $K \subset G$:

$$\tilde{D}(\underline{y}; \hat{\pi}^{(K)}, \hat{\pi}^{(G)}) = D(\underline{y}; \hat{\pi}^{(K)}) - D(\underline{y}; \hat{\pi}^{(G)}) = 2(\ell^{(G)} - \ell^{(K)}).$$

Asymptotisch χ_d^2 -verteilt, wenn das kleine Modell stimmt.

Anzahl Freiheitsgrade d ist die Differenz der Anzahl Parameter der beiden Modelle: $d = |G| - |K|$.

Kann also geschachtelte Modelle miteinander vergleichen.

Diese **Likelihood-Ratio Tests** sind in der Regel den Wald-Tests vorzuziehen.

R-Befehle

- Teste z.B. Faktoren
 - > `drop1(fit, test = "Chisq")`
- Allg. zum Vergleich von geschachtelten Modellen
 - > `anova(fit.1, fit.2, test = "Chisq")`

► **Null-Devianz** (früher: $\sum_i (Y_i - \bar{Y})^2$)

Kleinstes Modell (Nullmodell): Besteht nur aus Intercept, d.h. π_i ist für alle Beobachtungen gleich: $\hat{\pi}^{(0)} = \sum_{i=1}^n y_k / n$ (globaler Anteil).

$$D(\underline{y}; \hat{\pi}^{(0)}) = 2 \left(\ell^{(M)} - \ell \left(\hat{\underline{\beta}}^{(0)} \right) \right).$$

Damit kann man einen Gesamt-Test für das Modell konstruieren (H_0 : alle $\beta_j = 0, j = 1, \dots, m$)

$$D(\underline{y}; \hat{\pi}^{(0)}) - D(\underline{y}; \hat{\pi}) = 2 \left(\ell \left(\hat{\underline{\beta}} \right) - \ell \left(\hat{\underline{\beta}}^{(0)} \right) \right).$$

Unter H_0 ist dies approximativ χ_{p-1}^2 verteilt.

Residuenanalyse

Schwieriger als früher. Was ist hier ein Residuum?

Es ex. mehrere mögliche Definitionen.

▶ Response Residuals, Raw Residuals

$$R_\ell = \tilde{Y}_\ell - \hat{\pi}_\ell, \quad \hat{\pi}_\ell = g^{-1}(\underline{\tilde{x}}_\ell^T \underline{\hat{\beta}}) \quad (\text{gruppierte Daten})$$

▶ Pearson Residuals

$$R_\ell^{(P)} = R_\ell / \sqrt{\hat{\pi}_\ell(1 - \hat{\pi}_\ell)/m_\ell} \quad (\text{standardisiert})$$

▶ Working Residuals, Link Residuals

Berechnung der logistischen Regression: iterativ gewichtete
Kleinste Quadrate

↪ lineare Näherung ↪ Residuen: „working residuals“.

► **Devianz-Residuen**

$$R_i^{(D)} = \text{sign}(Y_i - \hat{\pi}_i) \sqrt{d_i},$$

wobei d_i der entsprechende Summand der Residuendevianz ist.
 d_i entspricht R_i^2 in der gewöhnlichen linearen Regression.

Grafische Darstellungen



QQ-Plot machen in der Regel keinen Sinn.

Tukey-Anscombe Plot am geeignetsten. Z.B.

- ▶ Raw Residuals vs. geschätzte $\hat{\pi}_i$
- ▶ Working Residuals vs. linearer Prädiktor $\hat{\eta}_i$.


Insbesondere bei nicht gruppierten Daten braucht man einen Glätter (wegen "Artefakten").

Beispiel: Residuenplot bei ungruppierten Daten



Man hat immer die beiden Kurven (Artefakt).

Residuenplot bei gruppierten Daten



Besser interpretierbar.

Merkmale

- ▶ Logistische Regression für **binäre Zielgrößen**. Gleiche Flexibilität wie gewöhnliche lineare Regression.
- ▶ Interpretation mit **odds** bzw. **odds-ratio**:
 $\log(\text{odds}) = \text{linearer Prädiktor}$
 β_j : $\log(\text{odds ratio})$ falls man j -te Variable um eine Einheit erhöht.
- ▶ **Schätzungen**, Tests, Vertrauensintervalle via Likelihood-Methoden (Devianzen) und entsprechende Asymptotik.
- ▶ **Residuen**: Mehrere Möglichkeiten, wegen Artefakten wird Glätter benötigt ⚡