

# Multiplizitätskorrektur bei Variablenselektion

Seminar: Multiples Testen  
Dozent: Prof. Dr. T. Dickhaus

Referent: Maximilian Mönch  
- 22.11.2010 -

# Überblick

- 1) Einleitung
- 2) Multiplizitätskorrektur
- 3) Median probability model
- 4) Optimalität bzgl. Vorhersage
- 5) Fazit
- 6) Literatur

# 1) Einleitung

## - Problem der Variablenselektion -

Lineares Modell in der Regressionsanalyse:  $Y = g(X) + \varepsilon = X\beta + \varepsilon$

$Y \in \mathbb{R}^n$  ... Response, Zielgröße,  
 $X \in \mathbb{R}^{n \times m}$  ... Versuchsplan/Designmatrix  
 $X_i = (X_{ij})_{j=1, \dots, m} \in \mathbb{R}^m$  ... Prädiktorenvektor  
 $\beta = (\beta_1, \dots, \beta_m)'$  ... Regressionskoeffizienten  
 $\varepsilon_i \sim N(0, \sigma^2)$  iid,  $\sigma^2$  unbekannt.

Aufgabe: Wähle aus  $\{1, \dots, m\}$   $k$  Zahlen und belasse  $X_{ij_1}, \dots, X_{ij_k}$  im Modell.

Aufgefasst als multiples Testproblem: Teste Hypothesensystem  $H_i : \beta_i = 0, i = 1, \dots, m$

## 2) Multiplizitätskorrektur

Wann treten Multiplizitätsprobleme auf?

- Diese Problematik tritt auf, wenn verhältnismäßig viele Variablen in das Modell aufgenommen werden.
- So erhöht sich die Irrtumswahrscheinlichkeit des multiplen Tests

Veranschaulichung:

Sei  $\varphi = (\varphi_i : i = 1, 2)$  ein multipler Test für ein zweiparametrisches Modell.

Seien  $\varphi_i, i = 1, 2$  stoch. unabhängig.

Weiterhin sei:  $\mathbb{P}(\varphi_j = 1) = 0.05, j = 1, 2$

Daraus ergibt sich:  $\text{FWER}(\varphi) = \mathbb{P}\left(\bigcup_{i=1,2} \{\varphi_i = 1\}\right) = 2 * 0.95 * 0.05 + 0.05^2 = 0.0975 > 0.05$

## 2) Multiplizitätskorrektur

Im Rahmen der Suche nach bester Vorhersage wird die a posteriori Wahrscheinlichkeit betrachtet:

$$\mathbb{P}(M_\gamma|Y) \sim \mathbb{P}(M_\gamma)f(Y|M_\gamma)$$

Wobei  $f(Y|M_\gamma) = \int f(Y|\beta_\gamma, \sigma)\pi(\beta_\gamma, \sigma)d\beta_\gamma d\sigma$  die likelihood von Y, mit  $\pi(\beta_\gamma, \sigma)$  a priori-Dichte der Modellparameter, ist.

Durch die Abhängigkeit der likelihood von der a priori Wahrscheinlichkeit für die Modellparameter, ist demnach ein besonderes Augenmerk auf die Wahl dieser zu legen.

Nach Scott und Berger (2010) ermöglichen der empirische und vollständige Bayes-Ansatz eine automatische Multiplizitätskorrektur.

## 2) Multiplizitätskorrektur - empirischer Ansatz -

Annahme:  $\gamma_i \sim \text{Ber}(p), i = 1, \dots, m$  ,  $p \in [0, 1]$

Daraus folgt für die a priori Wahrscheinlichkeit, dass Modell  $M_\gamma$  vorliegt:  $\mathbb{P}(M_\gamma|p) = p^{k_\gamma} (1-p)^{m-k_\gamma}$

Ansatz ist es nun, p mittels Maximum Likelihood Methode zu schätzen (George und Foster (2000)):  $\hat{p} = \arg \max_{p \in [0,1]} \sum_{\gamma} \mathbb{P}(M_\gamma|p) \cdot f(Y|M_\gamma)$

Nun wählt man das Modell mit der maximalen a posteriori Wahrscheinlichkeit

$$\mathbb{P}(M_\gamma|Y) \sim \hat{p}^{k_\gamma} (1 - \hat{p})^{m-k_\gamma} \cdot f(Y|M_\gamma)$$

## 2) Multiplizitätskorrektur - empirischer Ansatz -

Die Multiplizitätskorrektur erfolgt hierbei folgendermaßen:

Angenommen, wir haben  $k$  wahre Parameter  $\beta_i$ . Dann folgt aus  $m \rightarrow \infty: \hat{p} \rightarrow 0$

Grund:  $m \rightarrow \infty \Rightarrow \mathbb{P}(M_\gamma | p) \rightarrow 0 \Rightarrow \hat{p} \rightarrow 0$

Das heißt, dass Modelle mit einer hohen Anzahl an Variablen unwahrscheinlich sind, wenn es darum geht, das Modell mit der höchsten a posteriori Wahrscheinlichkeit zu wählen.

## 2) Multiplizitätskorrektur - vollst. Bayes-Ansatz -

Annahme:  $p \sim \text{Beta}(a, b)$

Für die Wahrscheinlichkeit, dass Modell  $M_\gamma$  vorliegt,  
gilt dann:

$$\mathbb{P}(M_\gamma) = \int_0^1 f(M_\gamma|p)\pi(p)dp = \frac{\beta(a+k_\gamma, b+m-k_\gamma)}{\beta(a, b)}$$

Im Spezialfall  $a=b=1$ , d.h. Parameter  $p$  ist gleichverteilt, vereinfacht sich die a priori Wahrscheinlichkeit:

$$\beta(1+k_\gamma, 1+m-k_\gamma) = \frac{\Gamma(1+k_\gamma)\Gamma(1+m-k_\gamma)}{\Gamma(2+m)} = \frac{(k_\gamma)!(m-k_\gamma)!}{(m+1)!} = \frac{(k_\gamma)!(m-k_\gamma)!}{(m+1)(m!)} = \frac{1}{m+1} \binom{m}{k_\gamma}^{-1}$$

## 2) Multiplizitätskorrektur - vollst. Bayes-Ansatz -

Das heißt, die für die a posteriori Wahrscheinlichkeit, die es zu maximieren gilt, gilt dann:

$$\mathbb{P}(M_\gamma|Y) \sim \frac{1}{m+1} \binom{m}{k_\gamma}^{-1} \cdot f(Y|M_\gamma)$$

Auch wenn der Parameter  $p$  nicht mehr direkt vorhanden ist, so erfolgt dennoch eine Multiplizitätskorrektur. Denn offensichtlich gilt bei fester Anzahl wahrer Parameter und wachsendem  $m$ , dass die a posteriori Wahrscheinlichkeit gegen 0 konvergiert.

## 2) Multiplizitätskorrektur - Nachteil des empir. Bayes Ansatz -

Trotz Konvergenz der empirischen Bayes-Lösung gegen den wahren Parameter, hilft der Ansatz nicht immer, das optimale Vorhersagemodell zu finden:

### **Lemma 1. :**

*Beim Problem der Variablenselektion gilt:*

*Hat das Nullmodell die echt größte likelihood, so ist der MLE-Schätzer  $\hat{p}$  von  $p$  gleich 0.*

*Hat das vollständige Modell die echt größte likelihood, so ist der MLE-Schätzer  $\hat{p}$  von  $p$  gleich 1.*

### 3) Median probability model

Ziel: Finden einer Theorie eines optimalen Vorhersagemodells

Barbieri und Berger (2004) wiesen nach, dass dies das sogenannte „Median probability model“ ist.

**Definition 1. :**

*Existiert die Gesamt-a-posteriori-Inklusionswahrscheinlichkeit*

$$p_i \equiv \sum_{\gamma: \gamma_i=1} \mathbb{P}(M_\gamma|y)$$

*für Variable  $i$ , so ist das Median probability model  $M_{\gamma^*}$  als das Modell definiert, welches aus denjenigen Variablen besteht, deren a-posteriori-Inklusions-Wahrscheinlichkeit mindestens  $\frac{1}{2}$  beträgt.*

### 3) Median probability model

Formal lässt sich das Modell wie folgt ausdrücken:

$$\gamma_i^* = \begin{cases} 1 & , p_i \geq 1/2 \\ 0 & , \text{sonst} \end{cases}$$

### 3) Median probability model

Existenz:

Es muss gewährleistet sein, dass die Menge der somit gewählten Kovariate zu der Menge der betrachteten Modelle und somit zum Hypothesensystem  $H$  gehört.

### 3) Median probability model

Dies ist gewährleistet, wenn:

- 1) Es werden alle möglichen Modelle  $H_i$  betrachtet.
- 2) Die betrachteten Modelle gehören zur Klasse der graphischen Modelle

Was ist ein graphisches Modell?

**Definition 2. :**

*Sei  $I(i)$  die zu einer Variablen  $x_i$  gehörenden Menge von Parameter-Indizes. Eine Teilklasse linearer Modelle besitzt graphische Modellstruktur, wenn es aus allen Modellen besteht, die die folgende Bedingung erfüllen:*

*„ Wenn für jedes  $i$  die Variable  $x_i$  zu dem Modell gehört, dann gehören die Variablen  $x_j, j \in I(i)$  ebenfalls dazu.“*

# 4) Optimalität

## - Theorie zum besten Vorhersagemodell -

Nach dem Bayesianischen Ansatz müsste das Modell mit der höchsten a posteriori Wahrscheinlichkeit die beste Datenprädiktion ermöglichen.

Doch das ist nicht immer der Fall, da diese Wahrscheinlichkeiten oft sehr klein sind. Barbieri und Berger (2004) nutzten die a posteriori Inklusionswahrscheinlichkeiten, eine Summation der a posteriori Wahrscheinlichkeiten, um das zuvor genannte Median probability model zu definieren.

Dieses weist die gewünschte beste Prädiktion auf.

# 4) Optimalität

## - Theorie zum besten Vorhersagemodell -

Betrachten die Kovarianzmatrix  $Q = \mathbb{E}[(X'X)]$

Ist Q Diagonalmatrix, so erfüllen die a posteriori Mittelwerte  $\tilde{\beta}_\gamma = H'_\gamma \tilde{\beta}$

mit

$$(H)_{ij} = \begin{cases} 1 & , \quad \gamma_i = 1 \text{ und } j = \sum_{r=1}^i \gamma_r \\ 0 & , \quad \text{sonst} \end{cases}$$

Beste Vorhersage bedeutet auch, das quadratische Risiko zu minimieren.  
In diesem Fall gilt:

$$R(M_\gamma) = \sum_{i=1}^k \tilde{\beta}_i^2 q_i (\gamma_i - p_i)^2$$

# 4) Optimalität

- Theorie zum besten Vorhersagemodell -

Fall 1: Es wird nur eine Auswahl an Modellen betrachtet

**Theorem 1. :**

*Sei  $Q$  Diagonalmatrix mit Diagonaleinträgen  $q_i > 0$ , es gelte  $\tilde{\beta}_\gamma = H'_\gamma \tilde{\beta}$  und die betrachteten Modellhypothesen besitzen graphische Modellstruktur.*

*Dann ist das Median probability model das beste Vorhersagemodell.*

# 4) Optimalität

## - Theorie zum besten Vorhersagemodell -

Fall 2: Es werden alle möglichen Modelle betrachtet:

### **Korollar 1. :**

*Sei  $Q$  diagonal mit  $q_i > 0$ , es gelte  $\tilde{\beta}_\gamma = H'_\gamma \tilde{\beta}$  und alle Modelle  $M_\gamma$  werden betrachtet.*

*Dann ist das beste Vorhersagemodell das Median probability model.*

*Ist  $\sigma^2$  bekannt und die a priori-Wahrscheinlichkeiten der Modelle erfüllen*

$$\mathbb{P}(M_\gamma) = \prod_{i=1}^k (p_i^0)^{\gamma_i} (1 - p_i^0)^{1-\gamma_i}$$

*, wobei  $p_i^0$  die a priori-Wahrscheinlichkeit dafür ist, dass  $x_i$  im Modell ist, dann gilt*

*$\mathbb{P}(M_\gamma|y) = \prod_{i=1}^k (p_i)^{\gamma_i} (1 - p_i)^{1-\gamma_i}$ , wobei  $p_i$  die a posteriori Inklusionswahrscheinlichkeit ist, und das*

*Median probability model ist das Modell mit der größten a posteriori Wahrscheinlichkeit.*

# 4) Optimalität

## - Theorie zum besten Vorhersagemodell -

Bemerkung:

1)

Viele a priori Wahrscheinlichkeiten erfüllen die Bedingung im Korollar.

Jeffreys Vorschlag (1961), dass die Wahrscheinlichkeit für die Modellordnung  $j$  ungefähr  $1/j$  sein kann, erfüllt diese Bedingung allerdings nicht.

2)

Ist allen Modellen ein Intercept gemein, so wird die zugehörige a priori Wahrscheinlichkeit  $p_i^0$  gleich 1 gesetzt.

# 4) Optimalität

- Anwendungsbeispiel -

ANOVA: 2-Faktor-Modell

Sei  $y_{ijk} = \mu + a_i + b_j + ab_{ij} + \varepsilon_{ijk}, i = 1, 2, j = 1, 2, k = 1, 2, \dots, K, \varepsilon \sim N(0, \sigma^2)$  iid

Kurz:  $y = X\beta + \varepsilon$

$$y = (y_{111}, \dots, y_{11K}, y_{121}, \dots, y_{12K}, y_{211}, \dots, y_{21K}, y_{221}, y_{22K})'$$

$$\beta = (\mu, a_1, b_1, ab_{11})', a_1 = -b_2, ab_{11} = ab_{22} = -ab_{12} = -ab_{21}$$

# 4) Optimalität

- Anwendungsbeispiel -

Mit der Designmatrix

$$X = \begin{pmatrix} 1 & 1 & 1 & 1 \\ \vdots & \vdots & \vdots & \vdots \\ 1 & 1 & 1 & 1 \\ 1 & 1 & -1 & -1 \\ \vdots & \vdots & \vdots & \vdots \\ 1 & 1 & -1 & -1 \\ 1 & -1 & 1 & -1 \\ \vdots & \vdots & \vdots & \vdots \\ 1 & -1 & 1 & -1 \\ 1 & -1 & -1 & 1 \\ \vdots & \vdots & \vdots & \vdots \\ 1 & -1 & -1 & 1 \end{pmatrix}$$

folgt für die Kovarianzmatrix:  $Q = 4 * K * I_4$

Wir können also die obige Theorie anwenden.

# 4) Optimalität

## - Anwendungsbeispiel -

Fall 1: Modellsystem:  $\{M_{1000}, M_{1100}, M_{1010}, M_{1001}, M_{1101}, M_{1011}, M_{1110}, M_{1111}\}$   
Im Rahmen des multiplen Testens mit  $H_\gamma = \beta_{\gamma_j} = 0, j = 1, \dots, k$ :  
 $\{H_{123}, H_{23}, H_{13}, H_{12}, H_1, H_2, H_3\}$ .  
D.h. wir testen, ob die indizierten Parameter von  $\tilde{\beta} = (a_1, b_1, ab_{11})$  gleich Null sind oder nicht.

Fall 2:  
Annahme: Interaktion nur dann möglich, wenn beide Haupteffekte vorhanden sind.

Modellsystem:  $\{M_{1000}, M_{1100}, M_{1010}, M_{1110}, M_{1111}\}$

Dieses Modell besitzt graphische Modellstruktur.

In beiden Fällen bietet das Median probability model die beste Datenvorhersage.

## 5) Fazit

Es werden starke Bedingungen an das Median probability model gestellt, damit es eine optimale Vorhersage ermöglicht.  
Daher hilft dieses Modell nicht immer.

Beispiel:

Modelle mit Intercept  $\alpha$  und einer Prädiktorenvariable  $x_i, i = 1, \dots, k, k \geq 3$   
sowie das Nullmodell.

Nehme als a priori Wahrscheinlichkeit  $1/(k+1)$  für Modellordnung.  
Weiterhin seien alle Kovariate hoch miteinander sowie mit  $y$  korreliert.

Damit ist die a posteriori Wahrscheinlichkeit für das Nullmodell fast gleich 0 und die für die anderen Modelle stimmen mit den a posteriori Inklusionswahrscheinlichkeiten überein. Diese sind aber kleiner als  $1/2$  und damit ist das beste Vorhersagemodell das Nullmodell.

## 6) Literatur

- Scott, James G., Berger, James O. (2010). Bayes and empirical-Bayes multiplicity adjustment in the variable-selection problem, *The Annals of Statistics*
- Barbieri, Maria M., Berger, James O.(2004). Optimal predictive model selection. *The Annals of Statistics*, Vol. 32, 870-897