

# Statistische Methoden der Datenanalyse

Markus Schumacher

## Übung IX

Matthew Beckingham und Markus Warsinsky

1.7.2009

### Anwesenheitsaufgaben

#### Aufgabe 39 Fisherdiskriminante und Likelihoodverhältnis

Betrachten Sie die Fisherdiskriminante für den Fall zweier Wahrscheinlichkeitsdichtefunktionen  $f(\vec{x}|H_0)$  und  $f(\vec{x}|H_1)$ , die jeweils multidimensionale Gaussverteilungen mit identischen Kovarianzmatrizen  $V_0 = V_1 = V$  sein sollen. Die Wahrscheinlichkeitsdichtefunktion ist also gegeben als:

$$f(\vec{x}|H_k) = \frac{1}{(2\pi)^{n/2}|V|^{1/2}} \exp\left[-\frac{1}{2}(\vec{x} - \vec{\mu}_k)^T V^{-1}(\vec{x} - \vec{\mu}_k)\right] \quad k \in \{0,1\} \quad (1)$$

(i) Zeigen Sie, dass das Likelihoodverhältnis gegeben ist durch

$$r = \frac{f(\vec{x}|H_0)}{f(\vec{x}|H_1)} = \exp(t), \quad (2)$$

wobei  $t$  die Fisherdiskriminante

$$t(\vec{x}) = a_0 + (\vec{\mu}_0 - \vec{\mu}_1)^T V^{-1} \vec{x} \quad (3)$$

mit einem beliebigem Schwellenwert  $a_0$  ist. Dementsprechend ist eine Optimierung des Likelihoodverhältnisses äquivalent zu einer Optimierung der Fisherdiskriminante.

(ii) Benutzen Sie das Bayes-Theorem mit Aprioriwahrscheinlichkeiten  $\pi_0$  und  $\pi_1$  für  $H_0$  bzw.  $H_1$ , um zu zeigen, dass die bedingte Wahrscheinlichkeit für  $H_0$  bei gegebenen Daten  $\vec{x}$  gegeben ist durch

$$P(H_0|\vec{x}) = \frac{1}{1 + e^{-t}} = s(t), \quad (4)$$

wobei  $s(t)$  die Logistische Funktion ist. Betrachten Sie dazu eine Redefinition des Schwellenwertes von der Form  $a'_0 = a_0 + \ln \frac{\pi_0}{\pi_1}$ .

#### Aufgabe 40 Zählexperiment für eine Signal- und Untergrundmessung

Betrachtet wird ein Experiment, dessen Ziel die Entdeckung eines neuen Teilchens oberhalb eines von momentanen Theorien vorhergesagten Untergrundes ist. Dabei könnte es sich beispielsweise um das Higgs-Boson oder auch um supersymmetrische Teilchen handeln, wobei die Untergrundvorhersage durch das Standardmodell der Teilchenphysik erfolgt.

Die zu betrachtenden Hypothesen sind also die Nullhypothese  $H_0$ , dass nur Ereignisse aus Untergrundprozessen gemessen wurden, sowie die Alternativhypothese  $H_1$ , dass sowohl Signal- als auch Untergründereignisse beobachtet wurden.

Im Experiment wurde eine Gesamtanzahl  $x$  von Ereignissen aufgezeichnet. Weiterhin wurde eine andere, signalfreie kinematische Region definiert, aus der man die Normierung des Untergrundes bestimmen kann. In dieser Region wurden  $y$  Ereignisse gefunden. Das Verhältnis der Untergründereignisse in der signalfreien Region zu denjenigen in der Signalregion sei  $\tau$ . Die mittlere Anzahl der Untergründereignisse in der Signalregion sei  $b$  und die mittlere Anzahl der Signaleereignisse im Falle von Hypothese  $H_1$  sei  $s$ .

- (i) Stellen Sie die Likelihoodfunktionen für die Hypothesen  $H_0$  und  $H_1$  auf. Nehmen Sie dabei an, dass die Gesamtanzahlen von Ereignissen in Signal- und Kontrollregion jeweils Poissonverteilt sind.
- (ii) Betrachten Sie jetzt die Schätzer für  $s$  und  $b$  unter der Hypothese  $H_1$  ( $\hat{s}$  bzw.  $\hat{b}$ ) sowie den Schätzer für  $b$  unter der Nullhypothese,  $\hat{\hat{b}}$ .
- a) Stellen Sie die Profile Likelihood  $\lambda$  auf.
- b) Bestimmen Sie Ausdrücke für  $\hat{s}$ ,  $\hat{b}$  und  $\hat{\hat{b}}$ . Betrachten Sie dazu

$$\left. \frac{\partial L(H_0)}{\partial b} \right|_{\hat{\hat{b}}}, \quad (5)$$

sowie die die beiden gleichzeitigen Einschränkungen

$$\left. \frac{\partial L(H_1)}{\partial s} \right|_{\hat{s}} \quad \text{und} \quad \left. \frac{\partial L(H_1)}{\partial b} \right|_{\hat{b}}. \quad (6)$$

- c) Berechnen Sie  $q = -2 \ln \lambda$ .

## Hausaufgaben

### Aufgabe 41 Zählexperiment für eine Signal- und Untergrundmessung 2

7 Punkte

In dieser Aufgabe sollen Sie die Ergebnisse von Aufgabe 40 benutzen, um die erwartete Sensitivität des ATLAS-Experimentes auf eine Entdeckung des Higgs-Bosons im Zerfallskanal  $H \rightarrow \gamma\gamma$  zu ermitteln.

Monte-Carlo-Studien von Proton-Proton-Kollisionen im ATLAS-Detektor haben gezeigt, dass der Wirkungsquerschnitt für  $pp \rightarrow H + X \rightarrow \gamma\gamma + X$ -Ereignisse, die die Ereigniselektion passieren, gegeben ist durch  $\sigma_S = 25,4 \text{ fb}$ . Der Wirkungsquerschnitt für Untergrundereignisse, die dieselbe Ereigniselektion passieren, beträgt  $\sigma_B = 947 \text{ fb}$ . In einer weiteren Analyse kann ein reiner Untergrunddatensatz mit einem Wirkungsquerschnitt von  $\sigma_T = 10300 \text{ fb}$  ausgewählt werden.

- (i) Benutzen Sie die Relation

$$N = \mathcal{L}\sigma, \quad (7)$$

um die Anzahlen von Signal- ( $x$ ), Untergrundereignissen ( $y$ ) sowie die Anzahl von Ereignissen in der Seitenbandregion ( $\tau b$ ) für eine integrierte Luminosität von  $\mathcal{L} = 10 \text{ fb}^{-1}$  auszurechnen.

- (ii) Berechnen Sie die Schätzer für die Anzahl der Signalereignisse  $\hat{s}$ , der Untergrundereignisse  $\hat{b}$  unter der Hypothese von Signal plus Untergrund, sowie den Schätzer  $\hat{\hat{b}}$  auf die Anzahl der Untergrundereignisse in der Nur-Untergrund Hypothese.
- (iii) Berechnen Sie die Größe

$$q = -2 \ln \lambda, \quad (8)$$

wobei  $\lambda$  die in Aufgabe 40 berechnete Profile Likelihood ist.

- (iv) Berechnen Sie daraus die Signifikanz des vorhergesagten Signals.
- (v) Nehmen Sie nun an, dass die Untergrundrate in der Signalregion mit einer relativen Genauigkeit von  $\Delta b/b = 5\%$  abgeschätzt werden kann. Wenn man annimmt, dass es sich dabei um einen Poissonfehler handelt, kann man eine effektive Seitenbandregion konstruieren mit Ereignisanzahl  $y' = \tau' b$ . Dazu setzt man die relative statistische Unsicherheit in der hypothetischen Seitenbandregion (Poissonfehler) gleich der relativen Genauigkeit der Untergrundvorhersage:

$$\frac{\sqrt{\tau' b}}{\tau' b} = \frac{\Delta b}{b} \Leftrightarrow \tau' = \frac{b}{(\Delta b)^2} \quad (9)$$

Berechnen Sie die Werte für  $\tau'$  und  $y'$  für die effektive Seitenbandregion.

- (vi) Benutzen Sie die Werte für  $\tau'$  und  $y'$  sowie die ursprüngliche Anzahl von Ereignissen in der Signalregion  $x$ , um den neuen Wert für  $q$  und daher der Signifikanz für eine Messung mit einem Fehler von 5% auf die Untergrundvorhersage zu bekommen.

**Aufgabe 42** Maximale Separation der Fisherdiskriminante**6 Punkte**

Ein Maß für die Separation zweier Hypothesen  $H_0$  und  $H_1$  mittels einer Fisherdiskriminanten ist gegeben durch

$$J(\vec{a}) = \frac{\vec{a}^T B \vec{a}}{\vec{a}^T W \vec{a}}, \quad (10)$$

wobei die Fisherdiskriminante definiert ist als

$$t(\vec{x}) = \vec{a}^T \vec{x}. \quad (11)$$

Die Separation zwischen  $H_0$  und  $H_1$  wird repräsentiert durch

$$B_{ij} = (\mu_0 - \mu_1)_i (\mu_0 - \mu_1)_j, \quad (12)$$

und die Summe der Kovarianzen zwischen den zwei Klassen ist gegeben durch

$$W_{ij} = (V_0 + V_1)_{ij}. \quad (13)$$

- (i) Bilden Sie die Ableitung  $\partial J(\vec{a})/\partial \vec{a}$  von  $J(\vec{a})$  nach  $\vec{a}$  und zeigen Sie, dass das Maximum von  $J(\vec{a})$  durch die Eigenwertgleichungen

$$W^{-1} B \vec{a} = \lambda \vec{a} \quad (14)$$

gegeben ist.

- (ii) Zeigen Sie, dass für einen beliebigen Vektor  $\vec{a}$  der Vektor  $B \vec{a}$  parallel zu  $(\vec{\mu}_0 - \vec{\mu}_1)$  ist.

- (iii) Zeigen Sie damit, dass

$$\vec{y} \propto W^{-1}(\vec{\mu}_0 - \vec{\mu}_1) \quad (15)$$

eine Lösung der Eigenwertgleichungen aus (i) ist und daher  $J(\vec{a})$  maximiert.

**Aufgabe 43** Likelihoodverhältnis für die  $\Xi^0$  Lebensdauer**7 Punkte**

Gegeben sei ein Datensatz von  $n$  gemessenen Zerfallszeiten  $t_1, t_2, \dots, t_n$  eines  $\Xi^0$ -Teilchens. Betrachten Sie einen Test der Nullhypothese  $H_0 : \tau = 1$ , wobei  $\tau$  die wahre Lebensdauer der  $\Xi^0$ -Teilchens ist, gegenüber der Alternativhypothese  $H_1 : \tau \neq 1$ .

- (i) Wie lauten die zwei Likelihoodfunktionen  $\alpha(\vec{x}, \vec{\lambda}(\omega))$  für  $H_0$  und für den vollen Parameterraum  $\alpha(\vec{x}, \vec{\lambda}(\Omega))$ ?

- (ii) Zeigen Sie, dass das Likelihoodverhältnis gegeben ist durch

$$T = \frac{\alpha(\vec{x}, \vec{\lambda}(\omega))}{\alpha(\vec{x}, \vec{\lambda}(\Omega))} = \bar{t}^n \exp(-n(\bar{t} - 1)), \quad (16)$$

wobei  $\bar{t} = \frac{1}{n} \sum_{i=1}^n t_i$  der arithmetische Mittelwert der gemessenen Zerfallszeiten ist.

- (iii) Für große  $n$  ist  $\bar{t}$  nach  $N(1, \frac{1}{n})$  verteilt. Berechnen Sie damit den kritischen Wert von  $\bar{t}$  für eine Signifikanz  $\alpha = 0.05$ .
- (iv) Berechnen Sie den kritischen Wert  $T_{\text{cr}}$  des Likelihoodverhältnisses und zeigen Sie, dass  $T_{\text{cr}} \rightarrow 0$  für  $n \rightarrow \infty$ .