

# Statistische Methoden der Datenanalyse

Markus Schumacher, Stan Lai, Florian Kiss

## Übung XI

22.1.2013, 25.1.2013

### Anwesenheitsaufgaben

#### Aufgabe 61 *Anpassungsgüte bei einer Maximum Likelihood Anpassung*

In dieser Übung sollen Sie die Ergebnisse der “Binned” Maximum Likelihood Anpassung an die  $e^+e^- \rightarrow \mu^+\mu^-$ -Ereignisse aus Übung VII benutzen. Betrachtet werden sollen die Verhältnisse der Likelihoodfunktionen

$$\lambda = \frac{\mathcal{L}(\vec{n}|\vec{\nu})}{\mathcal{L}(\vec{n}|\vec{n})}$$

Damit soll gezeigt werden, dass

$$\chi_M^2 = -2 \ln \lambda_M$$

gemäß einer  $\chi^2$ -Verteilung mit  $N - m - 1$  Freiheitsgraden verteilt ist. Dabei ist  $N$  die Anzahl der Datenbins und  $m$  die Anzahl der angepassten Parameter.

Das Makro `/home/slai/StatisticsCourse/PS11/aufgabe61_anfang.C` gibt ein Beispiel, wie man die generierten  $e^+e^- \rightarrow \mu^+\mu^-$ -Ereignisse (Anzahl  $N_{\text{tot}}$ ) einliest, ihre  $\cos\theta$ -Verteilung berechnet und in ein Histogramm namens `hist` einfüllt.

- (i) Definieren Sie eine TF1-Funktion gemäß

$$f(x; \alpha, \beta) = \frac{1 + \alpha x + \beta x^2}{2 + \frac{2\beta}{3}},$$

und führen Sie eine Anpassung dieser Funktion an das  $\cos\theta$ -Histogramm mit dem Befehl

```
hist.Fit("FunkName", "IL");
```

durch. Die Option "IL" steht für eine Maximum Likelihood Anpassung unter Benutzung der Integrale über die Bins des Histogramms `hist`.

- (ii) Definieren Sie als nächstes eine weitere TF1-Funktion gemäß  $f(x; \alpha, \beta)$  unter Benutzung der angepassten Werte  $\hat{\alpha}$  und  $\hat{\beta}$ . Die Werte von  $\hat{\alpha}$  und  $\hat{\beta}$  können Sie mit

```
TF1::GetParameter(int i)
```

ermitteln, wobei der Wert des  $i$ -ten Parameters zurückgegeben wird. Zum Fixieren der Parameter in der neuen Funktion benutzen Sie

```
TF1::FixParameter(int i, float wert)
```

um den Wert des  $i$ -ten Parameters auf `wert` zu setzen. Benutzen Sie dann

```
TF1::GetRandom(),
```

um eine gemäß der so definierten Funktion verteilte Zufallszahl zu erhalten.

- (iii) Erzeugen Sie  $N_{\text{tot}}$  neue Werte für  $\cos\theta$  und füllen Sie diese in ein neues Histogramm. Führen Sie eine Anpassung der ursprünglichen Funktion  $f(x; \alpha, \beta)$  an das neue  $\cos(\theta)$ -Histogramm durch.

- (iv) Ermitteln Sie als nächstes den  $\chi^2$ -Wert für das erzeugte Histogramm, indem Sie die Formel

$$\chi_M^2 = 2 \sum_{i=1}^N \left( n_i \ln \frac{n_i}{\hat{\nu}_i} \right)$$

benutzen. Dabei sind  $N$  die Anzahl der Histogrammbins und  $\hat{\nu}_i$  die Erwartungswerte der angepassten Funktion  $f(x; \hat{\alpha}, \hat{\beta})$ , die gegeben sind durch

$$\hat{\nu}_i = N_{\text{tot}} \int_{x_i^{\text{min}}}^{x_i^{\text{max}}} f(x; \hat{\alpha}, \hat{\beta}) dx.$$

Zum Integrieren der Funktion  $f(x; \hat{\alpha}, \hat{\beta})$  sollten Sie die Methode

```
TF1::Integral(int binMin,int binMax)
```

verwenden. Die untere Bingrenze des  $i$ -ten Bins erhalten Sie mittels

```
TH1::GetBinLowEdge(int i).
```

Schreiben Sie eine Schleife über alle Histogrammbins, in der Sie die Einzelbeiträge zu  $\chi_M^2$  aufsummieren.

- (v) Wiederholen Sie dieses Vorgehen 1000 mal und füllen Sie jedesmal den Wert von  $\chi_M^2$  in ein Histogramm ein. Denken Sie daran, das neue Histogramm für die zufällig ermittelten Werte von  $\cos \theta$  am Anfang jedes Zufallsexperiments wieder zurückzusetzen. Dies geschieht am einfachsten mit der Methode

```
TH1::Reset();
```

- (vi) Stellen Sie das Histogramm am Bildschirm dar und überzeugen Sie sich davon, dass es einer  $\chi^2$ -Verteilung folgt. Führen Sie, falls Sie noch Zeit haben, eine Anpassung einer  $\chi^2$ -Funktion an das Histogramm durch. Stimmt die Anzahl der Freiheitsgrade mit der Erwartung überein?

# Hausaufgaben

## Aufgabe 62 *F-Test für zwei verschiedene Messungen*

7 Punkte

Betrachten Sie zwei unabhängige Chi-Quadrat verteilte Variablen,  $u_1$  und  $u_2$ , mit  $\nu_1$  und  $\nu_2$  Freiheitsgraden, d.h.  $u_1$  ist gemäß  $\chi^2(\nu_1)$  verteilt und  $u_2$  nach gemäß  $\chi^2(\nu_2)$ . Dann ist die Variable  $F$ , definiert durch

$$F \equiv \frac{u_1/\nu_1}{u_2/\nu_2} \quad 0 \leq F \leq \infty; \nu_1, \nu_2 > 0 \quad (1)$$

verteilt nach der WDF

$$f(F; \nu_1, \nu_2) = \frac{\Gamma\left(\frac{1}{2}(\nu_1 + \nu_2)\right)}{\Gamma\left(\frac{1}{2}\nu_1\right)\Gamma\left(\frac{1}{2}\nu_2\right)} \left(\frac{\nu_1}{\nu_2}\right)^{\frac{1}{2}\nu_1} \frac{F^{\frac{1}{2}\nu_1-1}}{\left(1 + \frac{\nu_1 F}{\nu_2}\right)^{\frac{1}{2}(\nu_1 + \nu_2)}} \quad (2)$$

welche "F-Verteilung für  $(\nu_1, \nu_2)$  Freiheitsgrade" genannt wird (siehe Abb. 1).

Für zwei Datensätze  $x_1, x_2, \dots, x_n$ , gaussverteilt nach  $N(\mu_1, \sigma_1^2)$ , und  $y_1, y_2, \dots, y_n$ , gaussverteilt nach  $N(\mu_2, \sigma_2^2)$ , wobei die Mittelwerte  $\mu_1$  und  $\mu_2$  beider Verteilungen bekannt sind, ist die Größe

$$F = \frac{s_1}{s_2} = \frac{\frac{1}{n-1} \sum_{i=1}^n (x_i - \mu_1)^2}{\frac{1}{m-1} \sum_{i=1}^m (y_i - \mu_2)^2} \quad (3)$$

durch die F-Verteilung mit  $(n, m)$  Freiheitsgraden verteilt, wenn  $\sigma_1^2 = \sigma_2^2$ . Daher kann das Verhältnis  $s_1/s_2$  benutzt werden, um die Hypothese, dass beide Verteilungen die selbe Varianz ( $H_0 : \sigma_1^2 = \sigma_2^2$ ) aufweisen, gegen die Hypothese, dass beide Varianzen verschieden sind ( $H_1 : \sigma_1^2 > \sigma_2^2$ ), zu testen.

Kehren wir noch einmal zur Messung des Teilchenimpulses aus Aufgabe 60 zurück. Beide Messungen haben den selben Mittelwert  $\mu_1 = \mu_2 = \mu_0$ . Betrachten Sie hier nun folgende beiden Hypothesen für die Varianzen des inversen Impulses:

$$H_0 : \frac{1}{\sigma_1^2} = \frac{1}{\sigma_2^2}$$
$$H_1 : \frac{1}{\sigma_1^2} < \frac{1}{\sigma_2^2}$$

- (i) Berechnen Sie den Wert von  $F$  für beide Messungen.
- (ii) Wie viele Freiheitsgrade haben die Messungen?
- (iii) Was ist der kritische Wert von  $F$  bei einer Signifikanz von 5%? Sollte der Test auf einer oder auf zwei Seiten durchgeführt werden?
- (iv) Sind daher die Präzisionen der beiden Messungen miteinander konsistent?

## Aufgabe 63 *Zählexperiment für eine Signal- und Untergrundmessung*

13 Punkte

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,  $\hat{\hat{b}}$ .
- Stellen Sie die Profile Likelihood  $\lambda$  auf.
  - Bestimmen Sie Ausdrücke für  $\hat{s}$ ,  $\hat{b}$  und  $\hat{\hat{b}}$ . Betrachten Sie dazu

$$\left. \frac{\partial L(H_0)}{\partial b} \right|_{\hat{\hat{b}}}, \quad (4)$$

sowie die die beiden gleichzeitigen Einschränkungen

$$\left. \frac{\partial L(H_1)}{\partial s} \right|_{\hat{s}} \quad \text{und} \quad \left. \frac{\partial L(H_1)}{\partial b} \right|_{\hat{b}}. \quad (5)$$

- c) Berechnen Sie  $q = -2 \ln \lambda$  und zeigen Sie dadurch, dass die in der Vorlesung angegebene Gleichung

$$q = 2 \left[ x \ln x + y \ln y - (x + y) \ln \left( \frac{x + y}{1 + \tau} \right) - y \ln \tau \right]$$

korrekt ist.




Abbildung 1: Die F-Verteilung